



# **Politecnico di Torino**

**Corso di Laurea Magistrale  
in Ingegneria Energetica e Nucleare**

**Tesi di Laurea di II livello**

## **Analisi dei dati di consumo energetico dell'Energy Center attraverso l'utilizzo di tecniche di data analytics**

**Relatore:**  
Prof. Davide Papurello

**Candidato:**  
Pasquale Massimiliano Milella

**Anno Accademico 2020-2021**

# Sommario

Gli edifici ricoprono un ruolo centrale nella lotta al cambiamento climatico, numerose, a tal proposito, sono state le direttive e i bonus promossi dall'UE negli ultimi anni, che ha fissato entro il 2050 l'obiettivo della decarbonizzazione. Tra i consumi imputati di maggior rilievo occupa sicuramente grande spazio la climatizzazione degli ambienti interni. L'obiettivo dell'elaborato di tesi è l'analisi dei consumi energetici, in particolare della potenza di raffrescamento, erogata dal gruppo polivalente dell'Energy Center di Torino, edificio adibito ad uso uffici e situato nel campus del Politecnico di Torino. L'analisi energetica sui dati di monitoraggio ha previsto una fase iniziale di pulizia del dataset al quale sono state successivamente applicate alcune delle tecniche di *data analytics* per estrapolare informazioni utili a promuovere azioni di efficientamento energetico. Sono state utilizzate sia tecniche non supervisionate tra cui la *cluster analysis*, utile alla ricerca di profili di potenza tipologici, e sia tecniche supervisionate col fine di creare modelli di predizione di *benchmark*, che permette di stimare come dovrebbe consumare l'edificio, e di *forecast*, che permette di predire il consumo dell'edificio nelle ore successive. Dalle analisi è stata rilevata la presenza di profili con picchi di potenza di circa 400 [kW], registrati durante la fase di accensione, identificati attraverso la *cluster analysis*, utilizzata in seguito come punto di partenza per dimostrare la maggior accuratezza di previsione dei dataset composti da profili simili rispetto ai dataset tradizionali. Tale studio è stato effettuato tramite il modello ANN (*Artificial Neural Network*) il cui confronto dei risultati, attraverso l'utilizzo dei KPI (*Key Performance Indicators*), ha permesso di rilevare una precisione di stima maggiore del dataset suddiviso a seconda dei profili tipologici che presenta valori del MSE (*Mean Squared Error*) minori di circa il 45% e del MAE (*Mean Absolute Error*) minori di circa il 25% rispetto al dataset completo.

# Indice

|                                                          |           |
|----------------------------------------------------------|-----------|
| Elenco delle figure .....                                | 5         |
| Elenco delle tabelle.....                                | 9         |
| Nomenclatura .....                                       | 10        |
| <b>INTRODUZIONE .....</b>                                | <b>12</b> |
| <b>1 CONTESTO DELLA RICERCA.....</b>                     | <b>14</b> |
| 1.1 Situazione internazionale.....                       | 18        |
| 1.2 Situazione energetica negli edifici .....            | 21        |
| 1.3 Quadro normativo europeo .....                       | 24        |
| 1.3.1 Il contesto italiano .....                         | 26        |
| <b>2 DEMAND SIDE MANAGEMENT .....</b>                    | <b>29</b> |
| 2.1 Tecnologie .....                                     | 30        |
| 2.1.1 Efficienza Energetica .....                        | 31        |
| 2.1.2 Generazione distribuita .....                      | 33        |
| 2.1.3 Demand Response .....                              | 33        |
| 2.2 Strategie .....                                      | 35        |
| 2.3 Concetto di flessibilità negli edifici .....         | 38        |
| <b>3 GESTIONE ENERGETICA NEGLI EDIFICI .....</b>         | <b>40</b> |
| 3.1 Bacs .....                                           | 41        |
| 3.2 Modelli energetici per gli edifici .....             | 45        |
| 3.2.1 Modelli white-box.....                             | 46        |
| 3.2.2 Modelli grey-box.....                              | 47        |
| 3.2.3 Modelli black-box .....                            | 48        |
| 3.3 Monitoraggio energetico .....                        | 49        |
| 3.4 Tecniche di data analytics .....                     | 53        |
| 3.4.1 Tecniche di apprendimento supervisionato .....     | 54        |
| 3.4.2 Tecniche di apprendimento non supervisionato ..... | 58        |
| <b>4 CASO STUDIO .....</b>                               | <b>62</b> |
| 4.1 Descrizione dell’edificio .....                      | 62        |
| 4.1.1 Centrale termica .....                             | 64        |
| 4.1.2 Analisi consumi energetici .....                   | 76        |
| <b>5 ANALISI DEI DATI DI POTENZA FRIGORIFERA .....</b>   | <b>81</b> |

|          |                                                                                   |            |
|----------|-----------------------------------------------------------------------------------|------------|
| 5.1      | Pulizia e preparazione del dataset .....                                          | 81         |
| 5.2      | Cluster analysis.....                                                             | 91         |
| 5.3      | Utilizzo di tecniche supervisionate per la creazione di modelli previsionali..... | 97         |
| 5.3.1    | Modello di benchmark .....                                                        | 99         |
| 5.3.2    | Modello di forecast .....                                                         | 108        |
| 5.3.3    | Modelli di forecast per ciascun cluster .....                                     | 113        |
| 5.4      | Risultati .....                                                                   | 124        |
| <b>6</b> | <b>CONCLUSIONI .....</b>                                                          | <b>126</b> |
|          | <b>Bibliografia.....</b>                                                          | <b>129</b> |

# Elenco delle figure

|                                                                                         |    |
|-----------------------------------------------------------------------------------------|----|
| Figura 1.1 <i>Concentrazione CO2 monitorata presso la stazione di Mauna Loa</i> .....   | 15 |
| Figura 1.2 <i>Proiezione consumi energetici [6]</i> .....                               | 17 |
| Figura 1.3 <i>Proiezione delle emissioni di anidride carbonica [6]</i> .....            | 17 |
| Figura 1.4 <i>Andamento emissioni CO2 espressi in [Gt]</i> .....                        | 19 |
| Figura 1.5 <i>Emissioni di CO2 divise per tipologia di carburante</i> .....             | 19 |
| Figura 1.6 <i>Andamento emissioni di CO2 in economie selezionate</i> .....              | 20 |
| Figura 1.7 <i>Variazione del PIL in economie selezionate</i> .....                      | 21 |
| Figura 1.8 <i>Passaggio a tecnologie energetiche pulite</i> .....                       | 22 |
| Figura 1.9 <i>Consumi energetici divisi per settore</i> .....                           | 23 |
| Figura 2.1 <i>Schema tecnologie di DSM</i> .....                                        | 31 |
| Figura 2.2 <i>Schema POET - efficienza energetica</i> .....                             | 32 |
| Figura 2.3 <i>Programmi di DR basati sui prezzi</i> .....                               | 35 |
| Figura 2.4 <i>Strategie di DSM</i> .....                                                | 36 |
| Figura 2.5 <i>Schema semplificativo dell'applicazione delle tecnologie di DSM</i> ..... | 37 |
| Figura 3.1. <i>Ambiente in cui opera la gestione energetica dell'edificio</i> .....     | 40 |
| Figura 3.2. <i>Piramide dell'automazione e suoi componenti</i> .....                    | 43 |
| Figura 3.3 <i>Dispositivi di campo</i> .....                                            | 44 |
| Figura 3.4 <i>Interfacce grafiche BACS</i> .....                                        | 45 |
| Figura 3.5 <i>Schema modello white-box</i> .....                                        | 46 |
| Figura 3.6 <i>Schema modello grey-box con analogia elettrica</i> .....                  | 47 |
| Figura 3.7 <i>Schema modello black-box</i> .....                                        | 48 |
| Figura 3.8 <i>Schema modelli di simulazione energetica</i> .....                        | 49 |
| Figura 3.9 <i>Classificazione variabili database</i> .....                              | 50 |
| Figura 3.10 <i>Visualizzazione boxplot, carpet plot e calendar plot</i> .....           | 53 |
| Figura 3.11 <i>Training e Testing test</i> .....                                        | 55 |
| Figura 3.12. <i>Modello Rete Neurale Artificiale</i> .....                              | 57 |
| Figura 3.13 <i>Andamento funzione di attivazione</i> .....                              | 57 |
| Figura 3.14 <i>Cluster analysis</i> .....                                               | 59 |
| Figura 3.15 <i>Clustering partitivo</i> .....                                           | 60 |
| Figura 3.16 <i>Clustering gerarchico</i> .....                                          | 60 |

|                                                                                        |    |
|----------------------------------------------------------------------------------------|----|
| Figura 3.17 <i>Clustering basata sulla densità</i> .....                               | 61 |
| Figura 4.1 <i>Edificio Energy Center</i> .....                                         | 62 |
| Figura 4.2 <i>Macchina ad assorbimento</i> .....                                       | 65 |
| Figura 4.3 <i>Schema gruppo polivalente Climaveneta</i> .....                          | 66 |
| Figura 4.4 <i>Andamento Potenza termica e frigorifera stagione estiva 2021</i> .....   | 68 |
| Figura 4.5 <i>Accumulo acqua refrigerata</i> .....                                     | 68 |
| Figura 4.6 <i>Tubazione acqua di falda con filtro</i> .....                            | 69 |
| Figura 4.7 <i>Scambiatore teleriscaldamento</i> .....                                  | 70 |
| Figura 4.8 <i>Schema sottostazione termica con scambiatori teleriscaldamento</i> ..... | 71 |
| Figura 4.9 <i>Pompe di circolazione</i> .....                                          | 72 |
| Figura 4.10 <i>Schema riscaldamento serbatoio ACS</i> .....                            | 72 |
| Figura 4.11 <i>Grafico consumi energia frigorifera</i> .....                           | 77 |
| Figura 4.12 <i>Grafico consumi mensili energia frigorifera</i> .....                   | 78 |
| Figura 4.13 <i>Grafico consumi energia termica</i> .....                               | 79 |
| Figura 4.14 <i>Grafico consumi mensili energia termica</i> .....                       | 79 |
| Figura 4.15 <i>Grafico andamento settimanale potenza termica</i> .....                 | 80 |
| Figura 5.1 <i>Diagramma lineare del dataset</i> .....                                  | 82 |
| Figura 5.2 <i>Diagramma lineare dataset 2019</i> .....                                 | 82 |
| Figura 5.3 <i>Diagramma lineare dataset 2020</i> .....                                 | 83 |
| Figura 5.4 <i>Diagramma lineare dataset 2021</i> .....                                 | 83 |
| Figura 5.5 <i>Rappresentazione mensile dataset 2019</i> .....                          | 84 |
| Figura 5.6 <i>Rappresentazione mensile dataset 2020</i> .....                          | 84 |
| Figura 5.7 <i>Rappresentazione mensile dataset 2021</i> .....                          | 85 |
| Figura 5.8 <i>Rappresentazione settimanale dataset 2019</i> .....                      | 85 |
| Figura 5.9 <i>Rappresentazione settimanale 2020</i> .....                              | 86 |
| Figura 5.10 <i>Rappresentazione settimanale 2021</i> .....                             | 86 |
| Figura 5.11 <i>Diagramma lineare temperatura e radiazione solare 2019</i> .....        | 87 |
| Figura 5.12 <i>Diagramma lineare temperatura e radiazione solare 2020</i> .....        | 88 |
| Figura 5.13 <i>Diagramma lineare temperatura e radiazione solare 2021</i> .....        | 88 |
| Figura 5.15 <i>Carpet plot 2019 e 2020</i> .....                                       | 89 |
| Figura 5.16 <i>Carpet plot 2021</i> .....                                              | 89 |

|                                                                                                    |     |
|----------------------------------------------------------------------------------------------------|-----|
| Figura 5.17 Dendogramma con normalizzazione nessuna; metodo: complete; distanza: Manhattan.....    | 92  |
| Figura 5.18 Dendogramma con normalizzazione sul max; metodo: single; distanza: Euclidea .....      | 92  |
| Figura 5.19 Dendogramma con normalizzazione sul max-min; metodo:complete; distanza: Manhattan..... | 93  |
| Figura 5.20 Metodo: complete; distanza: Manhattan; no normalizzazione.....                         | 94  |
| Figura 5.21 Metodo: complete; distanza: Euclidea; no normalizzazione.....                          | 94  |
| Figura 5.22 Metodo: complete; distanza: Euclidea; no normalizzazione.....                          | 95  |
| Figura 5.23 Metodo: complete; distanza: Manhattan; normalizzazione sul max .....                   | 95  |
| Figura 5.24 Albero di clusterizzazione scelta migliore .....                                       | 96  |
| Figura 5.25 Training set.....                                                                      | 99  |
| Figura 5.26 Testing set .....                                                                      | 99  |
| Figura 5.27 Albero di regressione dataset.....                                                     | 101 |
| Figura 5.28 Modello di stima del training set.....                                                 | 102 |
| Figura 5.29 Modello di stima del testing set .....                                                 | 102 |
| Figura 5.30 Albero di regressione con variabili esogene aggiuntive .....                           | 103 |
| Figura 5.31. Modello di stima del training set con variabili aggiunti .....                        | 104 |
| Figura 5.32. Modello di stima del testing set con variabili aggiuntive .....                       | 104 |
| Figura 5.33 Andamento metriche MSE MAE e MAPE .....                                                | 106 |
| Figura 5.34 Modello di stima del training set con rete neurale.....                                | 107 |
| Figura 5.35 Modello di stima del testing set con rete neurale .....                                | 107 |
| Figura 5.36 Forecasting di 1 step in avanti.....                                                   | 108 |
| Figura 5.37 Modello di stima del training set con rete neurale.....                                | 109 |
| Figura 5.38 Modello di stima del testing set con rete neurale .....                                | 109 |
| Figura 5.39 Andamento delle metriche di valutazione della performance .....                        | 110 |
| Figura 5.40 Modello di stima del training set con rete neurale (input 12 ore) .....                | 111 |
| Figura 5.41 Modello di stima del testing set con rete neurale (input 12 ore) .....                 | 111 |
| Figura 5.42 Modello di stima del training set con rete neurale (input 24 ore) .....                | 112 |
| Figura 5.43 Modello di stima del testing set con rete neurale (input 24 ore) .....                 | 112 |
| Figura 5.44 Modello di stima del training set con rete neurale (input 24 ore) .....                | 115 |
| Figura 5.45 Modello di stima del testing set con rete neurale (input 24 ore) .....                 | 115 |

|                                                                                      |     |
|--------------------------------------------------------------------------------------|-----|
| Figura 5.46 Andamento metriche di performance MSE e MAE .....                        | 116 |
| Figura 5.47 Modello di stima del training set con rete neurale (input 24 ore) .....  | 117 |
| Figura 5.48 Modello di stima del testing set con rete neurale (input 24 ore).....    | 118 |
| Figura 5.49 Andamento metriche MSE e MAE .....                                       | 118 |
| Figura 5.50 Modello di stima del training set con rete neurale (input 24 ore) .....  | 120 |
| Figura 5.51 Modello di stima del testing set con rete neurale (input 24 ore).....    | 120 |
| Figura 5.52 Andamento delle metriche di valutazione della performance MSE e MAE .... | 121 |
| Figura 5.53 Modello di stima del training set con rete neurale (input 24 ore) .....  | 122 |
| Figura 5.54 Modello di stima del testing set con rete neurale (input 24 ore).....    | 122 |
| Figura 5.55 Andamento metriche di valutazione MSE e MAE .....                        | 123 |



## Elenco delle tabelle

|                                                                                       |    |
|---------------------------------------------------------------------------------------|----|
| Tabella 1. <i>Obiettivi 2030 presenti nel PNIEC [17]</i> .....                        | 27 |
| Tabella 2. <i>Caratteristiche impianti della centrale termica</i> .....               | 64 |
| Tabella 3. <i>Caratteristiche tecniche terminali di erogazione</i> .....              | 75 |
| Tabella 4. <i>Temperature mandata/ritorno acqua nei terminali di erogazione</i> ..... | 76 |
| Tabella 5. <i>Confusion matrix e metriche di valutazione</i> .....                    | 97 |

# Nomenclatura

## Acronimi

|      |                                           |
|------|-------------------------------------------|
| ACS  | Acqua Calda Sanitaria                     |
| ANN  | Artificial Neural Network                 |
| AR   | Assessment Reports                        |
| BACS | Building Automation and Control System    |
| BMS  | Building Management System                |
| CEI  | Comitato Elettrotecnico Italiano          |
| DG   | Generazione Distribuita                   |
| DR   | Demand Response                           |
| DSM  | Demand Side Management                    |
| ECI  | Energy Center Initiative                  |
| EE   | Efficienza Energetica                     |
| EED  | Energy Efficiency Directive               |
| EPBD | Energy Performance of Buildings Directive |
| FDD  | Fault Detection and Diagnosis             |
| GHG  | GreenHouse Gases                          |
| GO   | Garanzie di Origine                       |
| GPL  | Gas di Petrolio Liquefatto                |
| HVAC | Heating Ventilation and Air Conditioning  |
| ICT  | Information and Communications Technology |
| IEA  | International Energy Agency               |
| IoT  | Internet of Things                        |
| IPCC | Intergovernmental Panel on Climate Change |
| KPI  | Key Performance Indicators                |
| LCC  | Life Cycle Cost                           |
| MAE  | Mean Absolute Error                       |
| MAPE | Mean Absolute Percentage Error            |

|       |                                                             |
|-------|-------------------------------------------------------------|
| MLP   | Multi Layer Perceptron                                      |
| MPC   | Model Predictive Controller                                 |
| MSE   | Mean Squared Error                                          |
| MT    | Media Tensione                                              |
| NOAA  | National Oceanic and Atmospheric Administration             |
| nZEB  | nearly Zero Energy Building                                 |
| PAA   | Piecewise Aggregate Approximation                           |
| PIL   | Prodotto Interno Lordo                                      |
| PNIEC | Piano Nazionale Integrato per l'Energia e il Clima          |
| POET  | Performance, Operation, Equipment and Technology efficiency |
| SDS   | Scenario di Sviluppo Sostenibile                            |
| UNEP  | United Nations Environment Programme                        |
| UPS   | Uninterruptible Power Supply                                |
| UTA   | Unità di Trattamento Aria                                   |
| WMO   | World Meteorological Organization                           |

# INTRODUZIONE

Da pochi anni è ormai maturata, in maniera unanime, l'idea che il cambiamento climatico e l'innalzamento della temperatura media globale siano considerati i problemi principali a livello mondiale.

In passato soltanto alcuni modelli matematici, a cui numerosi esponenti del mondo scientifico mostravano scetticismo, ne dimostravano la presenza, ma il continuo verificarsi di fenomeni climatici sempre più estremi e frequenti negli ultimi anni, coincidenti con l'aumento del riscaldamento globale, ne hanno eliminato qualsiasi dubbio vigente [1].

L'*Intergovernmental Panel on Climate Change* (IPCC) è il principale organismo internazionale per la valutazione dei cambiamenti climatici, istituito nel 1988 dalla *World Meteorological Organization* (WMO) e dallo *United Nations Environment Programme* (UNEP), il cui scopo è quello di fornire una visione globale, chiara e scientificamente fondata, dei cambiamenti climatici e dei loro potenziali impatti ambientali e socio-economici. In particolare, produce periodicamente degli *Assessment Reports* (AR), ovvero dei Rapporti di Valutazione scientifica, sullo stato delle conoscenze nel campo del clima e dei cambiamenti climatici.

Tra questi, nel primo volume del Sesto rapporto di valutazione (AR6), tra le varie cause ai fenomeni climatici, l'IPCC considera l'inquinamento atmosferico e i cambiamenti climatici come due fattori strettamente legati tra loro. Nel documento viene delineato il panorama attuale con riferimento alla presenza di fenomeni climatici irreversibili, presenti ormai in ogni parte del globo. Tra questi alcuni risultano già in atto come il continuo aumento del livello del mare, l'aumento delle ondate di calore, soprattutto in aree urbane, e l'aumento di piogge intense e inondazioni in alcune regioni, a differenza di altre in cui, invece, si registra un aumento dei periodi di siccità.

Come testimoniato in precedenza dal rapporto scientifico, tali fenomeni sono causati soprattutto dall'inquinamento atmosferico, in particolare dei livelli record di gas serra (GHG – *GreenHouse Gases*) registrati in atmosfera, che tendono ad intrappolarne il calore provocando l'aumento della temperatura media superficiale. Molti di questi gas serra sono presenti in natura, ma l'attività umana ha incrementato in modo esponenziale la concentrazione di alcuni di essi nell'atmosfera, tra cui  $CO_2$ ,  $CH_4$ ,  $N_2O$ , soprattutto

attraverso la combustione dei combustibili fossili. La combustione genera in modo preponderante anidride carbonica ( $CO_2$ ), che risulta essere la componente principale dei gas responsabili dell'aumento dell'effetto serra antropico.

Tutte le organizzazioni internazionali e la stragrande maggioranza degli scienziati affermano che l'unico modo per provare a mitigare gli effetti del riscaldamento globale è ridurre in maniera sostanziale la composizione e le fonti delle emissioni di gas serra generate dall'uomo.

L'Unione europea (UE) si è posta in prima linea come modello a livello globale nella lotta alle emissioni di gas serra stabilendo degli obiettivi in materia di emissioni di gas serra, fonti rinnovabili ed efficienza energetica da raggiungere entro il 2030. Tale politica energetica prevede la riduzione del 40% delle emissioni di gas effetto serra, un aumento del 32% di produzione di energia da fonti rinnovabili e un miglioramento del 32,5% in termini di efficienze energetiche.

A tal proposito la città rivesta un ruolo principale in quanto il settore edilizio è uno dei più grandi produttori di gas serra climalteranti per la produzione di energia. Il CEI (Comitato Elettrotecnico Italiano) ha pubblicato un articolo in cui il contributo maggiore del consumo di energia finale totale in Europa risulta ad opera degli edifici con un valore pari al 40%.

Negli edifici è possibile aumentare l'efficienza intervenendo con azioni di retrofit oppure con azioni di gestione andando ad ottimizzare i consumi energetici. È in queste tematiche che si inserisce il concetto del DSM (*Demand Side Management*) ovvero una serie di azioni che influenzano la quantità o la modalità d'uso dell'energia consumata da parte degli utenti finali.

In tale elaborato di tesi si ricorrerà alla descrizione delle tecniche di DSM in particolare, per la riduzione della cosiddetta "domanda di punta", ovvero picchi di potenza assorbita, dagli impianti di climatizzazione, rilevata prevalentemente in alcuni giorni della settimana. Il presente lavoro di tesi si svolge con l'obiettivo di studiare e analizzare i dati di monitoraggio energetico di un edificio non residenziale, situato a Torino, al fine di proporre soluzioni per gestire la domanda di energia attraverso l'utilizzo di tecniche di *data analytics* utili per una pianificazione razionale della produzione e della distribuzione di energia.

# 1 CONTESTO DELLA RICERCA

Il funzionamento di una società moderna dipende oggi totalmente dall'energia, basti pensare ai principali servizi di acqua potabile, comfort delle abitazioni, istruzione, trasporti e non per ultima l'alimentazione. Per ottenerli, lo sfruttamento delle risorse disponibili è aumentato nel tempo ad opera soprattutto delle attività dell'uomo a cui oggi sono attribuite le cause principali delle modifiche territoriali, strutturali e climatiche del pianeta, tanto che la comunità scientifica ha denominato l'epoca geologica attuale Antropocene [2].

Il clima del nostro pianeta è sempre stato soggetto a cambiamenti forti e repentini, ai quali l'umanità si è spesso adattata: basti pensare alle glaciazioni. Tuttavia, però, l'attuale sviluppo sociale, incluso l'aumento demografico e tecnologico, potrebbero mettere a dura prova la capacità di adattamento e sopravvivenza non solo dell'uomo ma dell'intero ambiente vivente. Oggi, infatti, l'atmosfera sta subendo dei cambiamenti senza precedenti nella storia umana e, sebbene i cambiamenti cui stiamo assistendo ora sono grandi tanto quanto quelli avvenuti nelle passate ere geologiche, relativamente pochi di essi sono accaduti con la stessa velocità.

Le concentrazioni di gas serra sono in aumento, l'ozono della stratosfera è diminuito e le modifiche della composizione chimica dell'atmosfera, probabilmente, stanno riducendo la propria capacità di auto pulirsi attraverso l'ossidazione. Tali cambiamenti globali perturbano l'equilibrio delle condizioni climatiche sotto le quali la vita si è sviluppata. Le temperature stanno aumentando, la radiazione ultravioletta è in crescita sulla superficie, come pure i livelli di inquinamento dell'aria. Molti di tali mutamenti possono essere attribuiti all'industrializzazione, alla deforestazione e ad altre attività della popolazione, essa pure in forte crescita.

Le misurazioni strumentali, la frequenza e la violenza degli eventi climatici, i cambiamenti nelle abitudini migratorie e riproduttive di molte specie animali e vegetali lasciano poco spazio a interpretazioni: la crisi climatica è ormai un dato di fatto [1].

La causa principale della crisi climatica è l'effetto serra, un fenomeno dovuto alla presenza di alcuni gas nell'atmosfera che agiscono da barriera impedendo ai raggi solari di

ritornare nello spazio. Molti di questi gas sono presenti in natura ma l'attività umana ne ha aumentato notevolmente le concentrazioni sino a raggiungere valori di, anidride carbonica ad esempio, pari a 419,3 [ppmv], come riportato, in figura 1, dagli scienziati della *Scripps Institution of Oceanography* e della *National Oceanic and Atmospheric Administration* (NOAA) [3].




Figura 1.1 Concentrazione CO<sub>2</sub> monitorata presso la stazione di Mauna Loa

In figura 1.1, i dati sono riferiti a misurazione dell'aria raccolte settimanalmente presso l'osservatorio di Mauna Loa, nelle Hawaii, famoso in quanto a partire dal 1965 ha misurato ininterrottamente il contenuto di diossido di carbonio nell'atmosfera. In particolare, i dati in azzurro fanno riferimento ad una zona della troposfera ben miscelata, i simboli in verde ad una zona scarsamente miscelata mentre i dati in arancione sono dati preliminari, ovvero sono i dati più recenti non ancora sottoposti a procedure di garanzia di qualità.

La commissione europea ha individuato come cause principali dell'aumento delle emissioni di gas serra climalteranti [4], le seguenti:

- Combustione di combustibili fossili tra cui carbone, petrolio e gas;
- Deforestazione;

- Allevamento di bestiame in quanto sia i bovini che ovini durante il processo di digestione producono grandi quantità di metano;
- Fertilizzanti azotati;
- Gas fluorurati emessi da apparecchiature che utilizzano tali gas;

I cambiamenti climatici stanno già influenzando molti estremi meteorologici e climatici, come ondate di calore, precipitazioni intense, siccità e cicloni tropicali, in ogni regione del mondo, e le prove che attribuiscono queste variazioni all'influenza umana si sono rafforzate rispetto al precedente Rapporto di Valutazione dell'IPCC (AR5) [5]. In particolare, si sono evidenziate:

- Ondate di calore più frequenti e più intense;
- La frequenza e l'intensità delle precipitazioni sono aumentate a partire dalla metà del secolo scorso;
- In alcune regioni, è aumentato il fenomeno della siccità sia agricola che ecologica;
- la percentuale di forti cicloni tropicali (categoria 3-5) è aumentata negli ultimi quattro decenni;
- Il riscaldamento globale ha causato l'aumento del livello medio del mare attraverso la perdita di ghiaccio terrestre (con un contributo pari al 42%), l'espansione termica (con un contributo del 50%) dovuta al riscaldamento degli oceani e i cambiamenti nell'immagazzinamento delle acque terrestri (con un contributo del 8%).

La comunità scientifica è ormai unanime nell'indicare le attività umane come le responsabili principali della crisi climatica, in particolare a causa dell'aumento dei gas serra immessi nell'atmosfera.

Secondo una statistica condotta dall'IEA (*International Energy Agency*) è stata stimata una ampia crescita energetica sino al 2040, rappresentata nel grafico in figura 1.2, dovuta alla somma di differenti fattori come la crescita demografica, la crescita dell'economia globale e dell'urbanizzazione e l'aumento della richiesta di veicoli.






Figura 1.2 *Proiezione consumi energetici* [6]

La fonte principale di tale incremento, suddiviso a seconda del tipo di combustibile in figura 1.2, è dovuto soprattutto ai paesi in via di sviluppo in cui l'energia è responsabile di circa il 60% dell'aumento di energia globale. Unico fattore positivo, di tale crescita, risiede nella crescente sensibilizzazione verso l'utilizzo di risorse rinnovabili, le quali risultano la risorsa con il maggior tasso di crescita.

Ulteriore conseguenza, negativa questa volta, di tale incremento è l'aumento delle emissioni di gas serra, visibile nel grafico in figura 1.3, dove è mostrato l'andamento delle emissioni di  $CO_2$  fino al 2040.




Figura 1.3 *Proiezione delle emissioni di anidride carbonica* [6]

Dal grafico è possibile notare una crescita meno pronunciata delle emissioni rispetto ai consumi di energia, figura 1.2, dovuta principalmente al cambiamento della miscela di risorse fossili impiegate, come attesta la riduzione del carbone dal 28% al 22%, la quale risulta la fonte che genera la più alta quantità di  $CO_2$ .

La promozione dello sviluppo sostenibile e la lotta al cambiamento climatico sono diventati aspetti integranti della pianificazione, dell'analisi e della definizione delle politiche energetiche. L'energia rappresenta i due terzi del totale dei gas serra; quindi, gli sforzi per ridurre le emissioni e mitigare i cambiamenti climatici devono obbligatoriamente includere il settore energetico [7].

## 1.1 Situazione internazionale

Questi ultimi due anni (2020-2021) possono essere descritti come anni al di fuori dell'ordinario a causa dell'arrivo della pandemia del Covid-19, che, come unico lato positivo, ha portato alla riduzione delle emissioni di gas serra a causa dei lunghi periodi di chiusura delle aziende in tutto il globo e dei vari settori ad esse collegati (trasporti, ristorazione, vendite, ecc..).

L'IEA, Organismo internazionale autonomo nato allo scopo di garantire la disponibilità e l'uso di energia ai Paesi Membri e a livello internazionale, ha registrato una diminuzione del 5,8% delle emissioni globali di  $CO_2$  nel 2020, ovvero quasi 2 [Gt], il calo più grande mai registrato e cinque volte maggiore rispetto al calo del 2009 dovuto alla crisi finanziaria globale [6]. Tale riduzione è stata causata principalmente dalla pandemia che ha colpito la domanda di petrolio e carbone, le maggiori fonti inquinanti di gas serra, più duramente rispetto alle altre fonti energetiche (vedi figura 1.5). Nonostante il calo nel 2020, le emissioni globali di anidride carbonica legate all'energia sono rimaste a valori di circa 31,5 [Gt] contribuendo a raggiungere la concentrazione media annua più alta di sempre nell'atmosfera, maggiore del 50% rispetto all'inizio della rivoluzione industriale [6]. Tali risultati sono visibili nel grafico in figura 1.4, in cui è evidenziato l'andamento delle emissioni globali di  $CO_2$ , legate alla produzione di energia, dal 1990 al 2021.




Figura 1.4 Andamento emissioni  $CO_2$  espressi in [Gt]

Dal grafico si nota come le emissioni globali di  $CO_2$  previste per la fine del 2021 dovrebbero aumentare di un valore pari al 4,8% man mano che la domanda di petrolio, carbone e gas cresca con l'economia [6].

Secondo l'ultimo report '*Global Energy Review 2021*' redatto dall'IEA, l'accelerazione del lancio delle vaccinazioni contro il Covid-19 in molte delle principali economie e i diffusi vantaggi fiscali proposti per far fronte alla crisi economica, stanno aumentando le prospettive di crescita economica e portando ad un repentino aumento della domanda di energia nel 2021 con un conseguente aumento delle emissioni di gas serra [6].

Tale crescita è ben visibile anche nel grafico in figura 1.5 in cui è possibile notare la variazione delle emissioni di  $CO_2$  a seconda della tipologia di carburante a partire dal 1990 sino al 2021.




Figura 1.5 Emissioni di  $CO_2$  divise per tipologia di carburante

L'incremento previsto per il 2021, visibile anche nel grafico in figura 1.4 è dovuto in particolare modo ai mercati emergenti e alle economie in via di sviluppo che rappresentano circa i due terzi delle emissioni globali di  $CO_2$ , a differenza delle emissioni delle economie avanzate che risultano in calo strutturale.

Tra le economie emergenti la Cina risulta la principale, dove, nonostante la rapida crescita della produzione da fonti rinnovabili, la produzione delle centrali elettriche a carbone è aumentata di 330 [TWh], quasi il 7%, tra il 2019 e il 2021. Per tali ragioni, si prevede un aumento delle emissioni di  $CO_2$  di circa il 6% a fine 2021, ovvero quasi 600 [Mt], rispetto ai livelli registrati nel 2019 [6] .

Dal grafico in figura 1.6 si evidenzia, in Cina, la crescita più elevata delle emissioni di gas a effetto serra derivante dalla combustione di combustibili fossili, a differenza delle altre economie selezionate in cui il trend risulta decrescente in UE e Stati Uniti e in lieve aumento in India.




Figura 1.6 Andamento emissioni di  $CO_2$  in economie selezionate

Tali risultati, anche se negativi dal punto di vista del cambiamento climatico, sono stati raggiunti dalla Cina in quanto ha differenze delle altre economie vigenti è stata in grado di ridurre il virus nella fase iniziale riuscendo così da essere una delle poche economie ad espandersi nel 2020.

L'UE così come gli Stati Uniti, invece, presentano un trend decrescente in linea con l'andamento della pandemia, in quanto nell'inverno 2020/2021, sono state colpite da una

grave seconda ondata che ha portato a rinnovate chiusure e lockdown economici con una ripresa ulteriormente ostacolata da un lento avvio delle campagne vaccinali.

Andamento crescente, dovuto soprattutto ad una crescita economica, è stato monitorato in India, che a differenza delle altre potenze economiche, ha attivato sin dall'inizio della pandemia misure di blocco molto severe che hanno portato inizialmente, al calo economico/di emissioni più brusco di qualsiasi altra grande economia, e successivamente, ad una crescita, che persiste ancora oggi, le cui stime del PIL (Prodotto Interno Lordo) annuale raggiungono il 12%, il valore più alto rispetto a qualsiasi altra potenza economica [8].

Tali risultati sono visibili anche nel grafico seguente in figura 1.7 dove sono rappresentate le stime di variazione del PIL delle principali potenze economiche dal 2019 al 2021.




Figura 1.7 *Variazione del PIL in economie selezionate*

## 1.2 Situazione energetica negli edifici

Il crescente consumo di energia suscita preoccupazione a livello mondiale per questioni di degrado ambientale, di sicurezza energetica e geopolitica. Ruolo critico per la lotta alla diminuzione delle emissioni di gas serra è ricoperto dagli edifici responsabili del 40% del consumo di energia totale in Europa come esplicitato nel rapporto annuale ENEA [2].

Coerentemente a quanto affermato dalla Commissione europea sul raggiungimento della neutralità climatica entro il 2050 e sulla riduzione di almeno il 55% delle emissioni nette di gas serra rispetto al 1990, l'obiettivo principale risulta quello di puntare su strategie a lungo termine per un'economia più resiliente ed equa in grado di valorizzare la qualità e non la quantità.

In Europa più della metà degli edifici ha un'età media elevata e tale dato risulta importante in quanto esalta la necessità di riqualificare gli edifici, integrando le nuove tecnologie con le vecchie. In questi edifici è nascosto quindi un grande potenziale, in termini di risparmio energetico, ottenibile grazie ad un incremento generale dell'efficienza.

La maggior parte degli edifici, oggi, posseggono impianti per il riscaldamento e il raffrescamento alimentati con combustibili fossili come le caldaie a metano, GPL e gasolio che continuano a dominare il mercato globale degli edifici, escludendo le apparecchiature alimentate con biomassa. Secondo l'IEA, per essere in linea con lo scenario di sviluppo sostenibile (SDS), la quota di tecnologie energetiche pulite come le pompe di calore, il riscaldamento solare termico e le caldaie a biomassa deve superare il 50% delle vendite delle nuove apparecchiature in grado di garantire comfort in ambiente entro il 2030 [8]. Oltre ai miglioramenti dell'involucro edilizio durante la fase di riqualificazione risulta dunque fondamentale l'adozione di nuove tecnologie di condizionamento ad alta efficienza e a basse emissioni di carbonio. Tutto questo contribuirebbe a ridurre l'intensità energetica media globale di circa il 4% annuo nel prossimo decennio, i cui effetti, combinati con il cambio di carburante e la decarbonizzazione del settore energetico, ridurrebbero le emissioni legate al riscaldamento degli edifici del 30% entro il 2030 [9].




Figura 1.8 *Passaggio a tecnologie energetiche pulite*

Lo studio 'Una strategia per la decarbonizzazione dei sistemi di riscaldamento degli edifici in Italia' realizzato da Elemens e Kyoto Club [10] afferma che, nel 2021, il riscaldamento domestico contribuisce ancora in maniera significativa, a inquinare le città e a surriscaldare il Pianeta, incentivato da una serie di sussidi e misure che, come l'ecobonus, anziché favorire soprattutto la diffusione di impianti a fonti rinnovabili, incentiva ancora soluzioni che utilizzano combustibili fossili come il gas naturale nel caso delle caldaie a condensazione, per le quali è previsto il totale rimborso delle spese da parte dello Stato.

Analizzando i consumi da un punto di vista settoriale ci sono tre categorie principali: trasporto, edifici e industria che, secondo le statistiche condotte da Eurostat, ricoprono rispettivamente il 33,1%, il 25,4% e il 25,3% dei consumi di energia europei. Tali risultati sono visibili in figura 1.9.




Figura 1.9 Consumi energetici divisi per settore

Da tale grafico è possibile evidenziare quanto il settore edilizio sia importante nella definizione dei consumi energetici e nella loro effettiva riduzione. A differenza degli altri settori occorrono ingenti investimenti sia economici che temporali per sostituire gli edifici esistenti con altri più nuovi, rendendo così molto difficile il raggiungimento degli obiettivi europei di risparmio energetico. Per tali ragioni, le politiche energetiche hanno stabilito, come strategia principale, di concentrare gli investimenti nella riqualificazione degli edifici.

Ridurre i consumi è quindi possibile, grazie all'utilizzo di soluzioni impiantistiche ad alta efficienza e a basso impatto ambientale in grado di limitare notevolmente le spese delle famiglie.

Nel corso degli ultimi anni però, si è sempre più spesso riscontrato che il risparmio non si consegue soltanto sulla base dell'introduzione di componenti a migliore prestazione

energetica, ma anche attraverso il controllo del loro corretto utilizzo attraverso il monitoraggio delle prestazioni energetiche in modo che il consumo di energia dell'edificio avvenga sulla base dell'effettivo bisogno.

Per fare ciò è necessario quindi 'smartizzare' gli edifici attraverso l'installazione di dispositivi per il monitoraggio dei consumi e del livello di comfort indoor, di sistemi di attuazione e di trasmissione dati e di un'infrastruttura (ICT - *Information and Communications Technology*) dove risiedono gli algoritmi di ottimizzazione [11].

Il monitoraggio *real time* e la conoscenza del comportamento reale degli edifici consentono di sviluppare modelli previsionali, ovvero prevedere in anticipo i consumi attesi del singolo edificio. Tale opportunità desta interesse in quanto collegata alla possibilità di introdurre strategie di gestione della domanda (DSM), ottimizzazione della produzione energetica o della prestazione di un sistema impiantistico [11].

La previsione energetica di profili di picco o del profilo di carico giornaliero, trattati in modo specifico, nel paragrafo ..., offrono importanti opportunità gestionali per la stabilità della rete energetica e incentivano l'utente verso azioni pro-attive guidate dalla convenienza economica verso un uso più razionale dell'energia.

## 1.3 Quadro normativo europeo

L'Unione europea (UE) si pone in prima linea come modello a livello globale, investendo le proprie energie nella lotta alle emissioni di gas serra. Nel 2019 aveva già ridotto le sue emissioni di gas serra del 24 % rispetto ai livelli del 1990, dimostrando di essere all'altezza dell'obiettivo stabilito nel protocollo di Kyoto di ridurre le emissioni del 20 % entro il 2020 [12]. Nel dicembre 2019 la Commissione europea ha presentato il *Green Deal europeo* proponendo una serie di misure volte a fissare obiettivi più ambiziosi in termini di riduzione delle emissioni di GHG per il 2030 e a decarbonizzare l'economia dell'UE entro il 2050.

All'interno del 'Quadro 2030 per il clima e l'energia', per far fronte all'emergenza climatica, l'UE ha stabilito gli obiettivi in materia di emissioni di gas serra, fonti rinnovabili ed efficienza energetica da raggiungere entro il 2030 [1]. In particolare, tale politica energetica ha previsto la riduzione del 40% delle emissioni di gas effetto serra, un



incremento del 32% di produzione di energia da fonti rinnovabili e un miglioramento del 32,5% in termini di efficienze energetiche. L'obiettivo di riduzione delle emissioni è stato in seguito modificato con il Regolamento (UE) 2021/1119 del Parlamento europeo e del Consiglio del 30 giugno 2021 che istituisce il quadro per il conseguimento della neutralità climatica. Tale regolamento stabilisce l'obiettivo vincolante per l'UE per una riduzione interna netta delle emissioni di gas serra di almeno il 55%, anziché il 40%, rispetto ai livelli del 1990 entro il 2030 e l'obiettivo di neutralità climatica nell'UE entro il 2050.

Ulteriore direttiva utile al raggiungimento dei nuovi obiettivi europei fissati per il 2030 in materia di clima ed energia risulta la Direttiva (UE) 2018/2002 che fa parte del pacchetto di misure legislative europee noto come '*Clean Energy Package*'. Tale direttiva propone di rimuovere gli ostacoli sul mercato dell'energia e di superare le carenze del mercato che frenano l'efficienza nella fornitura e nell'uso dell'energia. Prevede inoltre la fissazione di obiettivi e contributi nazionali indicativi in materia di efficienza energetica per il 2030.

Per rispettare gli obiettivi di riduzione decarbonizzazione e di riduzione delle emissioni di gas serra, esplicitati in precedenza nel *Green Deal europeo*, la commissione europea utilizza anche la Direttiva 2018/844 dove tra le novità più importanti introdotte per raggiungere tali obiettivi vi è l'obbligo di migliorare la prestazione energetica degli edifici nuovi ed esistenti e viene richiesto di prevedere strategie nazionali di ristrutturazione degli immobili e indicatori di intelligenza. L'obiettivo dell'indicatore è quello di sensibilizzare i proprietari e gli occupanti sul valore dell'automazione degli edifici e del monitoraggio elettronico dei sistemi tecnici per l'edilizia in modo da assicurare gli occupanti circa i risparmi reali di tali nuove funzionalità [13].

Entrambe le precedenti direttive fanno parte integrante della 'nuova governance europea dell'energia', che approva il principio dell'*energy efficiency first*'. Secondo questo principio, gli Stati membri dovranno considerare, prima di adottare decisioni di pianificazione, politica e di investimento in ambito energetico, se esistono misure di efficienza energetica alternative solide dal punto di vista tecnico, economico, ambientale e dell'efficienza in termini di costi che consentano comunque di conseguire gli obiettivi delle decisioni politiche [14].

Ulteriore direttiva per far fronte alla riduzione delle emissioni dei GHG emanata dall'UE è la Direttiva 2003/87/CE, anche denominata '*EU Emission Trading System*', la quale prevede che dal primo gennaio 2005 gli impianti maggiormente energivori dell'UE non possono funzionare senza un'autorizzazione alle emissioni di gas serra. In particolare, ogni impianto autorizzato deve compensare annualmente le proprie emissioni con quote EUA (*European Union Allowances*), equivalenti a 1 tonnellata di  $CO_2$ , che possono essere comprate e vendute dai singoli operatori interessati [15].

L'adozione di queste direttive focalizzate sulla prestazione energetica degli edifici trova ragione in quanto, secondo i dati della Commissione europea, agli edifici è riconducibile circa il 36% di tutte le emissioni di  $CO_2$  dell'UE. Il conseguimento degli obiettivi energetici e climatici europei è dunque fortemente legato al rinnovamento e all'adeguamento del parco immobiliare in quanto quasi il 50% del consumo dell'energia finale dell'UE è usato per riscaldamento e rinfrescamento, di cui l'80% negli edifici [16].

### 1.3.1 Il contesto italiano

In Italia il settore civile rappresenta oltre il 45% del fabbisogno energetico nazionale ed ha fatto registrare negli ultimi anni una crescita progressiva dei consumi [11]. L'efficienza energetica negli edifici è diventata, pertanto, un obiettivo nazionale fondamentale sul quale si indirizzano molti provvedimenti, strategie ed azioni.

L'Italia si ritrova oggi a dover ripartire, con nuove direttive per adempiere ai target europei imposti al 2030, da una posizione che la vede favorevole rispetto agli obiettivi nazionali, presenti nel piano 20-20-20, riguardanti la percentuale di energia prodotta da fonti rinnovabili e di efficienza energetica ma in una sfavorevole, anche se di poco, per quando riguarda la percentuale di riduzione delle emissioni di gas a effetto serra.

Con il nuovo Piano Nazionale Integrato per l'Energia e il Clima (PNIEC), fornito e successivamente accettato dalla Commissione europea, l'Italia ha definito quali sono le strategie e le misure da introdurre per raggiungere i nuovi target europei per il 2030 [17]. Gli obiettivi da conseguire sono di seguito visibili in tabella 1 differenziati a seconda dei quattro macro-temi dominanti la transizione energetica.

Tabella 1. *Obiettivi 2030 presenti nel PNIEC* [17]

|                                                                                     | <b>Obiettivi 2030</b>          |                                |
|-------------------------------------------------------------------------------------|--------------------------------|--------------------------------|
|                                                                                     | <b>UE</b>                      | <b>ITALIA<br/>(PNIEC)</b>      |
| <b>Energie rinnovabili (FER)</b>                                                    |                                |                                |
| Quota di energia da FER nei Consumi Finali Lordi di energia                         | 32%                            | 30%                            |
| Quota di energia da FER nei Consumi Finali Lordi di energia nei trasporti           | 14%                            | 22%                            |
| Quota di energia da FER nei Consumi Finali Lordi per riscaldamento e raffrescamento | +1,3% annuo<br>(indicativo)    | +1,3% annuo<br>(indicativo)    |
| <b>Efficienza energetica</b>                                                        |                                |                                |
| Riduzione dei consumi di energia primaria rispetto allo scenario PRIMES 2007        | -32,5%<br>(indicativo)         | -43%<br>(indicativo)           |
| Risparmi consumi finali tramite regimi obbligatori efficienza energetica            | -0,8% annuo<br>(con trasporti) | -0,8% annuo<br>(con trasporti) |
| <b>Emissioni gas serra</b>                                                          |                                |                                |
| Riduzione dei GHG vs 2005 per tutti gli impianti vincolati dalla normativa ETS      | -43%                           |                                |
| Riduzione dei GHG vs 2005 per tutti i settori non ETS                               | -30%                           | -33%                           |
| Riduzione complessiva dei gas a effetto serra rispetto ai livelli del 1990          | -40%                           |                                |
| <b>Interconnettività elettrica</b>                                                  |                                |                                |
| Livello di interconnettività elettrica                                              | 15%                            | 10% <sup>1</sup>               |
| Capacità di interconnessione elettrica (MW)                                         |                                | 14.375                         |

Per favorire il raggiungimento di tali obiettivi l'Italia ha recepito le direttive europee tra le quali: la Direttiva (UE) 2018/2002 sull'efficienza energetica, recepita in Italia con il Decreto Legislativo (D.Lgs.) n.73 del 14 luglio 2020 anche denominata Direttiva EED – *Energy Efficiency Directive*, e il D.Lgs. n.48 del 10 giugno 2020 che ha recepito la Direttiva (UE) 2018/844 sulla prestazione energetica dell'edilizia denominata anche Direttiva EPBD – *Energy Performance of Buildings Directive*.

Per rispettare gli obiettivi al 2030 in materia di emissioni di gas serra, l'Italia ha inoltre emanato il D.Lgs. n.47 del 9 giugno 2020 che modifica la Direttiva 2003/87/CE per sostenere una riduzione delle emissioni e promuovere investimenti a favore di basse emissioni di carbonio [15].

Per aumentare la promozione dell'uso dell'energia prodotta da fonti rinnovabili l'ordinamento italiano ha attuato la Direttiva 23/04/2009 n.28 tramite il D.Lgs.

03/03/2011 n.28 in cui vengono stabilite norme relative al sostegno finanziario e all'autoconsumo dell'energia elettrica prodotta da fonti rinnovabili e alle garanzie di origine (GO) dell'energia da fonti rinnovabili, ovvero titoli, rilasciati in formato elettronico, che attestano l'origine rinnovabile delle fonti utilizzate.

Per quanto riguarda la progettazione di nuovi edifici, il D.Lgs. 63/2013, convertito in Legge n.90 del 3 agosto 2013, obbliga a partire dal primo gennaio 2021 a progettare edifici, sia pubblici che privati, a consumo quasi zero (nZEB). Per edificio nZEB '*nearly Zero Energy Building*', si intende un edificio a 'energia quasi zero' funzionante grazie all'installazione di impianti che utilizzano fonti rinnovabili [18]. Tali edifici sono progettati e realizzati sfruttando al meglio le risorse naturali come il sole e il vento, e risultano ben isolati e alimentati ad energia rinnovabile con impianti tecnologicamente avanzati in modo da richiedere una quantità di energia davvero minima.

## 2 DEMAND SIDE MANAGEMENT

Il concetto di Demand Side Management (DSM), non è più nuovo ormai da qualche decennio e pone le sue radici molti anni fa. Ricorrono agli inizi degli anni Trenta le prime applicazioni riguardanti il concetto di gestione della domanda, in cui si cercava di riempire i periodi con minore richiesta di carica di carico (valli del profilo di carico), attraverso l'utilizzo dei primi scaldabagni ad accumulo. Nei primi anni Settanta, poi, a seguito dell'embargo petrolifero del 1973 e del conseguente aumento dei costi del servizio di fornitura di energia elettrica, i programmi di DSM sono iniziati a comparire lentamente anche nei piani strategici delle aziende elettriche [19]. Gli elevati aumenti dei costi energetici fecero lievitare i prezzi dell'energia elettrica bloccando la crescita della domanda di elettricità. In tali anni, il numero dei programmi di gestione energetica fu in forte aumento a causa dall'elevata crescita economica del settore elettrico che preannunciava la mancanza di capacità da parte degli impianti esistenti per poter soddisfare la richiesta. Furono costruiti, a tal proposito, numerosi impianti di produzione, la maggior parte dei quali risultarono completi in corrispondenza della crisi economica, periodo in cui, il tasso di crescita della domanda, passò dal 7% degli anni 60' al 3,5%, risultando così non più necessari. Fu proprio a questo punto che le organizzazioni del settore iniziarono a rendersi conto dell'importanza che poteva avere, la gestione del carico, all'interno dei piani strategici delle aziende elettriche.

In passato, l'obiettivo principale della maggior parte dei programmi DSM era quello di fornire risorse energetiche e di capacità convenienti per aiutare a rinviare la necessità di nuove fonti di energia, inclusi impianti di generazione, acquisti di energia e aggiunte di capacità di trasmissione e distribuzione. Oggi, invece, a causa dei cambiamenti in via di sviluppo nel settore energetico, i programmi di DSM vengono utilizzati come mezzo per migliorare il servizio con gli utenti finali [19]. In particolare, i programmi di gestione della domanda sono definiti come tutte quelle attività di pianificazione, implementazione e monitoraggio delle utenze elettriche progettate per incoraggiare i consumatori a modificare il proprio livello di utilizzo dell'elettricità, ovvero fanno riferimento ad una serie di tecnologie, strategie e azioni che influenzano la quantità o la modalità d'uso dell'energia consumata da parte degli utenti finali [20].

Un esempio di DSM è possibile riscontrarlo nelle attività finalizzate alla riduzione della cosiddetta “domanda di punta”, che sarà analizzata in modo approfondito nel paragrafo seguente. Ricorrere all'utilizzo di programmi di DSM, nei periodi in cui i sistemi di produzione di energia sono limitati, permette di gestire la domanda da parte degli utenti finali attraverso l'utilizzo di tecnologie e strumenti per una pianificazione più razionale della produzione e della distribuzione di energia.

L'attuale dibattito sui cambiamenti climatici ha portato alla luce l'importanza di una domanda flessibile che possa essere ridotta anche nel caso in cui vi siano carenze nella fornitura di energia in quanto, una domanda eccessivamente elevata comporta notevoli impatti negativi sull'ambiente e sul benessere dei consumatori. In corrispondenza dei periodi di picco, infatti, dove gli utenti consumano in modo simultaneo elettricità, occorre attivare le centrali di produzione più vecchie, alimentate a combustibili fossili, il cui basso rendimento favorisce l'aumento delle emissioni di anidride carbonica e dei costi di generazione.

La flessibilità della domanda, attraverso l'utilizzo di programmi di DSM, rappresenta oggi un'alternativa efficiente alla regolazione dell'offerta in grado di aumentare, al contempo, il benessere degli utenti finali limitando sia i picchi di domanda, sia i picchi di prezzo ed esercitando di conseguenza, un abbassamento delle bollette [21].

## 2.1 Tecnologie

L'aumento della domanda di energia, in particolare del picco della domanda, comporta sfide per la sicurezza della rete e la necessità di nuove centrali elettriche, necessarie solo a soddisfare il picco della domanda nel periodo di punta. La diffusione delle tecnologie di DSM come l'efficienza energetica (EE), la gestione della domanda (DR) e la generazione distribuita (DG), è considerata una delle soluzioni alternative più utili per ridurre la domanda di punta, la domanda di energia e le emissioni di gas a effetto serra causate dalla produzione di elettricità [22].

Queste tecnologie, schematizzate in figura 2.1, sono capaci di creare una rete energetica più dinamica ed efficiente in grado di offrire ai consumatori l'opportunità di svolgere un ruolo essenziale per il suo funzionamento.




Figura 2.1 Schema tecnologie di DSM

La prima distinzione tra le diverse tecnologie è dovuta alla differente scala temporale dell'intervento considerato. In particolare, le tecnologie di Pianificazione (*Planning*) considerano interventi all'incirca permanenti come, ad esempio, l'installazione di un nuovo componente mentre, le tecnologie Operative (*Operational*) prevedono interventi temporanei come la variazione dei prezzi. Di seguito sono descritte singolarmente le caratteristiche principali delle tre tecnologie di DSM.

### 2.1.1 Efficienza Energetica

Il primo tipo di tecnologia di DSM è il miglioramento dell'efficienza energetica, classificata da Xia e Zhang [23] con l'acronimo POET (*Performance, Operation, Equipment and Technology efficiency*).

In particolare, l'efficienza tecnologica (*Technology efficiency*) è intesa come una misura legata all'efficienza della conversione, della trasformazione, della trasmissione e dell'uso razionale dell'energia ed è spesso valutata attraverso indicatori come il *Life Cycle Cost* (LCC) che rappresenta il costo del ciclo di vita e da coefficienti di conversione/trasformazione e trasmissione.

La seconda tipologia di efficienza, l'*Equipment efficiency*, invece, rappresenta l'efficienza delle singole apparecchiature energetiche considerate come parti separate dal sistema.

Tale efficienza è valutata considerando indicatori come la capacità o la manutenzione del componente stesso. L'obiettivo principale dell'efficienza delle apparecchiature è quello di ridurre al minimo la differenza dei parametri effettivi dei componenti rispetto a quelli espressi nelle specifiche durante la progettazione.

A differenza dell'efficienza delle apparecchiature precedente, l'efficienza di funzionamento (*Operation efficiency*), è una misura a livello di sistema e indica il corretto coordinamento dei diversi componenti del sistema stesso. In particolare, è utilizzata soprattutto nella fase di dimensionamento di un componente del sistema quando si considerano le relazioni del componente rispetto agli altri componenti del sistema. L'efficienza operativa viene infatti valutata attraverso gli indicatori di coordinamento fisico, coordinamento temporale e coordinamento umano.

Infine, l'ultima tipologia è l'efficienza delle prestazioni (*Performance efficiency*), che indica una misura dell'efficienza energetica determinata attraverso indicatori di sistema che valutano la produzione, i costi e l'impatto ambientale. Talvolta questi indicatori sono contraddittori tra loro, ad esempio, quando si vuole massimizzare la produzione e al tempo stesso minimizzare i costi e le emissioni. Per tali ragioni l'efficienza delle prestazioni può essere migliorata soltanto in corrispondenza di compromessi tra i diversi indicatori.

Tutte e quattro le componenti di efficienza POET sono influenzate, oltre che dagli indicatori, anche da fattori tecnici, umani e temporali che non permettono di creare dei confini netti e chiari tra le diverse tipologie. Per tali ragioni è possibile considerare le quattro tipologie di efficienza parte di una struttura multistrato come visibile in figura 2.2.



Figura 2.2 Schema POET - efficienza energetica



### 2.1.2 Generazione distribuita

Le generazioni distribuite (DG) in aggiunta alle generazioni centralizzate, quali le centrali nucleari, a gas o a carbone, introducono un'ulteriore capacità energetica per contribuire alla crescente domanda di energia. Le risorse della DG contribuiscono ad aumentare la quantità di energia elettrica in modo decentrato in termini di tecnologia, spazio e tempo [22]. A differenza delle generazioni centralizzate, le risorse energetiche della DG quali il solare, l'eolico, il piccolo idroelettrico e altre risorse scelte in funzione della disponibilità fisica e ambientale, possono essere disperse o localizzate in più punti del territorio e collegate alla rete elettrica. Molto spesso però, sono situate nelle vicinanze del carico da servire così da consentire una minore dispersione di energia lungo la rete e quindi una maggiore affidabilità. Tali fonti di energia elettrica, a causa della natura discontinua delle energie rinnovabili, sono intermittenti in quanto non producono energia in modo continuativo nel tempo perché fortemente dipendenti dalle condizioni atmosferiche. Gli impianti di generazione sono classificati in due tipologie:

- **Impianti di generazione in loco:** comprendono tutti i generatori collegati direttamente alla rete di distribuzione, nelle vicinanze dell'utente finale, e sono distinte in due tipologie, quali: i generatori a potenza continua e i generatori a potenza intermittente. I primi sono utilizzati per abbassare il picco del carico o in situazione di indisponibilità della rete, mentre i generatori a potenza intermittente, così come preannuncia il loro nome, sono caratterizzati da una produzione intermittente dipendente dalla disponibilità delle fonti rinnovabili come, ad esempio, i pannelli solari o le turbine eoliche.
- **Impianti di stoccaggio:** rappresentano tutte quelle tecnologie in grado di immagazzinare, per un periodo abbastanza lungo, energia al loro interno. Sono generalmente utilizzate in presenza di impianti di generazioni a fonti rinnovabili data la natura intermittente di tali risorse energetiche.

### 2.1.3 Demand Response

L'ultima tipologia di tecnologia del DSM è il *Demand Response* (DR) che consiste in programmi specifici che motivano il cliente finale a cambiare il proprio modello tradizionale di consumo energetico con dei modelli più innovativi che tengono conto dei

cambiamenti di prezzo o della disponibilità di energia elettrica nel tempo [22]. Per tali ragioni, i programmi di DR sono considerati un'opzione fondamentale per ottimizzare le prestazioni del sistema energetico grazie alla loro flessibilità che permette di utilizzare in modo più efficiente le infrastrutture e le risorse energetiche. I programmi di DR rappresentano la tecnologia di DSM che rende gli utenti finali partecipanti attivi al funzionamento della rete in condizioni di sicurezza ed efficienza permettendo, inoltre, notevoli riduzioni dei costi dell'energia elettrica sulle loro bollette senza introdurre inconvenienti.

In particolare, i programmi di DR sono divisi in programmi basati sugli incentivi e programmi basati sui prezzi [21]. I programmi basati sugli incentivi includono:

- misure di controllo diretto del carico: misure in cui è prevista la possibilità di spegnere da remoto i macchinari dei partecipanti sulla base di un breve preavviso;
- programmi di interruzione di carico: programmi in cui, ai consumatori, viene chiesto di ridurre i consumi fino ad un valore predefinito incorrendo in penalità per chi non lo rispetta;
- misure di *capacity markets*: offerte fornite ai consumatori che hanno la possibilità di impegnarsi a fornire specifiche riduzioni di carico in corrispondenza di contingenze di sistema;
- servizi ancillari: servizi in cui i consumatori si impegnano a rimanere in *stand-by*, quando richiesto dalla rete, in cambio di ricompense;

I programmi basati sui prezzi, invece, si fondano su tariffe dinamiche che variano a seconda del costo reale dell'elettricità. L'obiettivo di queste misure è quello di appiattire il più possibile la curva di domanda tramite l'offerta di prezzi più bassi durante i periodi di non picco e di prezzi più alti durante i periodi di picco. Le principali misure sono:

- *Time of Use*, ovvero tariffe biorarie dove solitamente vengono applicati prezzi dell'energia elettrica inferiori durante il fine settimana e la settimana lavorativa dalle 19:00 alle 8:00 circa, ovvero in corrispondenza di periodi di stabilità della rete e, al contrario, prezzi più elevati in corrispondenza dei periodi di picco;

- *Critical Peak Pricing*, misura di DSM in cui i clienti pagano una quota fissa annuale per l'energia elettrica a differenza dei giorni in cui si verificano eventi o situazioni critiche dal punto di vista della stabilità del sistema, in cui il prezzo aumenta. Tale misura incentiva i consumatori a ridurre il consumo durante i periodi di stress della rete.
- *Real Time Pricing*: con tale misura i consumatori pagano prezzi che riflettono il costo reale dell'elettricità sul mercato. Di tali variazioni vengono però informati l'ora o al massimo il giorno prima in modo da avere una migliore gestione dei carichi.

Le tre misure di DR basate sui prezzi sono di seguito rappresentate in figura 2.3:




Figura 2.3 Programmi di DR basati sui prezzi

## 2.2 Strategie

Le strategie del DSM sono classificate a seconda dell'effetto che le tecnologie, precedentemente citate, possono fornire sulla forma del carico. Le differenti tecniche applicabili a seconda del profilo di carico sono di seguito mostrate in figura 2.4.




Figura 2.4 Strategie di DSM

È possibile definire le seguenti tecniche sulla forma del carico:

- *Flexible load shape:* la forma di carico flessibile, è fortemente legata alla capacità di bilanciare in modo continuativo domanda e offerta e può essere ottenuta attraverso interventi come l'accettazione da parte del cliente della variazione di qualità di un servizio in cambio di incentivi o attraverso la riduzione o sospensione dei carichi;
- *Strategic load growth:* la crescita del carico strategico fornisce un aumento complessivo del carico energetico e quindi dei consumi. Si verifica in periodi di forte sviluppo economico dovuto alle elevate misure di elettrificazione a causa, ad esempio, dell'elevata diffusione dei veicoli o di altre apparecchiature elettriche;
- *Strategic conservation:* la conservazione strategica al contrario della crescita del carico strategico ha l'obiettivo di ridurre i consumi energetici;
- *Load shifting:* lo spostamento del carico mira a spostare il carico dai periodi di punta ai periodi di carico minimo comportando l'appiattimento del profilo di carico;

- *Peak clipping*: il ritaglio del picco rappresenta una riduzione del carico nei periodi di punta portando all'appiattimento del profilo di carico proprio come nel *load shifting*;
- *Valley filling*: il riempimento della valle focalizza l'attenzione sui carichi minimi risultando utile soprattutto in presenza di un'elevata produzione di energia da fonti rinnovabili in periodi di bassa richiesta;

Per effettuare le modifiche sulla forma di carico occorre utilizzare le tecnologie di DSM illustrate in precedenza e applicabili nel seguente modo come mostrato in figura 2.5.




Figura 2.5 Schema semplificato dell'applicazione delle tecnologie di DSM

Dalla figura 2.5 vengono riassunti graficamente gli effetti che le tecnologie possono avere sul cambiamento di forma del profilo di carico. In particolare, l'*energy efficiency* è utilizzata per abbassare il picco del profilo nelle ore di punta a differenza dell'*energy storage* che tende ad appiattire il profilo di carico spostando il carico dalle ore di punta a quelle in cui la richiesta è inferiore, attraverso l'utilizzo, ad esempio, dei sistemi di accumulo termico. Il *Demand Response*, invece, incoraggia l'utente a spostare il carico

nelle ore non di punta quando il prezzo dell'elettricità è inferiore, ricavando per quest'ultimo, un risparmio notevole in bolletta.

## 2.3 Concetto di flessibilità negli edifici

Gli edifici sono responsabili del 40% del consumo totale di energia nei paesi sviluppati e una porzione analoga può essere considerata anche a livello globale. I sistemi di riscaldamento e raffreddamento, utili a soddisfare il comfort termico degli occupanti, sono la causa dell'elevato consumo energetico all'interno degli edifici residenziali e non. Attraverso l'utilizzo delle tecnologie e delle strategie di DSM, descritte nel paragrafo precedente, è possibile contribuire, in modo significativo, alla flessibilità energetica degli edifici definita dall'AIE come: *"...la capacità di gestire la propria domanda e generazioni in base alle condizioni climatiche locali, all'esigenza degli utenti e ai requisiti della rete energetica"*.

L'obiettivo di tutte le misure di miglioramento del concetto di flessibilità è quello di raggiungere un equilibrio tra domanda e offerta di elettricità negli edifici in modo da diminuire lo stress della rete elettrica [24].

Dal punto di vista della rete elettrica ci sono diverse ragioni per migliorare la flessibilità della domanda di energia da parte degli edifici. In particolare:

- L'aumento di elettricità prodotta da fonti rinnovabili immesse in rete, come l'eolico e il solare, che costituiscono fonti di produzione energetica intermittente;
- Il verificarsi del cambiamento climatico che influenza in modo significativo l'affidabilità e il corretto funzionamento dei componenti elettrici;
- La diminuzione dell'utilizzo delle vecchie centrali fossili da parte dei paesi industrializzati per via del forte sviluppo delle fonti rinnovabili;

A causa di queste tre ragioni, i problemi di bilanciamento sulla rete elettrica stanno diventando sempre più frequenti.

La letteratura attuale considera il DR una delle misure principali ed essenziali per rendere gli edifici più flessibili in termini di richiesta energetica dalla rete attraverso l'utilizzo di apparecchiature intelligenti altamente sviluppate. Tale approccio (DR) ha dimostrato di

essere efficiente per lo spostamento e l'appiattimento dei carichi senza dover richiedere alcun tipo di investimento aggiuntivo, rispetto al sistema convenzionale di energia, migliorando la capacità di flessibilità energetica sfruttando il prezzo dinamico dell'energia e gli incentivi [25].

A seconda della tipologia dell'edificio, residenziale, commerciale o industriale, il potenziale di flessibilità cambia in modo consistente. Infatti, per gli edifici industriali il margine di flessibilità risulta davvero limitato a differenza degli edifici residenziali e commerciali che presentano rispettivamente una flessibilità nel processo produttivo e i sistemi BACS utili all'attuazione degli algoritmi di DSM.

In questo lavoro di tesi l'attenzione sarà focalizzata sugli edifici commerciali, in particolare su edifici adibiti ad uso ufficio.

### 3 GESTIONE ENERGETICA NEGLI EDIFICI

Ci si è accorti nel tempo che la progettazione di edifici ben strutturati dal punto di vista fisico e impiantistico non è sufficiente per raggiungere l'obiettivo di ottimizzazione energetica, in quanto parte fondamentale, per adempiere a tale obiettivo, è il miglioramento della gestione dell'edificio in condizioni di esercizio, considerando il comportamento dell'occupante, il malfunzionamento di sistemi o altre cause che aumentano la differenza tra la prestazione energetica reale dell'edificio e la prestazione attesa (*Energy Performance Gap*). Oggi è possibile ridurre questo *gap* attraverso l'applicazione dei programmi di DSM, precedentemente illustrati, i quali, però, richiedono una stretta interazione delle parti coinvolte, quali l'occupante/edificio, da un lato, e i mercati energetici dall'altro. Molti studi, nel corso degli anni, hanno dimostrato che per ottenere riscontri soddisfacenti dall'attuazione dei programmi di DSM è necessario sia informare gli occupanti sulle esigenze e sui suoi benefici e sia comprendere quali sono le motivazioni che spingono gli utenti finali ad applicarli in modo da migliorarli [26]. Tutto questo è possibile attraverso l'utilizzo di tecnologie che consentono il monitoraggio dei dati e la loro successiva analisi utile all'ottimizzazione della prestazione energetica dell'edificio. Oggi l'edificio è immerso, grazie allo sviluppo dell'*Internet of Things* (IoT), in un sistema in grado di collegarsi in qualsiasi momento, in modo bidirezionale, con l'edificio in modo da permettere un continuo scambio di azioni e informazioni utili ad operare una gestione energetica che sia la più ottimale possibile.




Figura 3.1. Ambiente in cui opera la gestione energetica dell'edificio



È in questo contesto che si inserisce il concetto di gestione dell'energia (*Energy Management*) definito come il set di azioni organizzate e sistematiche utilizzate con lo scopo di razionalizzare l'uso di energia considerando gli obiettivi sia economici che globali. Parte dell'*Energy Management* è occupato dalla *Building automation* caratterizzata da sistemi di controllo (attuatori) programmati con logiche, in modo coordinato, al fine di ottimizzare l'uso e il consumo energetico. Con il termine ottimizzazione vengono intese tutte le azioni utili all'eliminazione degli sprechi energetici assicurando un'ottima performance del sistema sfruttando la variabilità della rete. Per tali ragioni si parla di edifici flessibili in cui l'occupante insieme alle sue necessità di comfort diventa un dato utile per ottimizzare l'edificio.

Misurare oggi è diventato facile ed economico, infatti, ciò ha avuto la conseguenza di avere a disposizione database contenenti un numero elevatissimo di dati da trattare in modo opportuno. Nasce da qui la necessità di utilizzare le tecniche di *data analytics* che, tramite l'utilizzo di algoritmi, permettono di analizzare database con un numero elevato di dati, ricavando informazioni utili alla gestione energetica dell'edificio.

Tale gestione non è però disponibile a costo nullo, ma necessita dell'investimento iniziale di un'infrastruttura che consente di operare una gestione energetica e che include tutti i servizi ingegneristici allo scopo di ottenere, tramite dei controlli automatici, l'efficienza sia energetica che economica utilizzando nel modo più intelligente possibile i dati di monitoraggio. Tale infrastruttura prende il nome di BACS (*Building Automation Control System*) in cui il termine "*Control*" non indica soltanto la funzione di controllo ma anche quella di processamento dei dati.

## 3.1 Bacs

Con l'espressione BACS, anche denominato BMS (*Building Management System*), si intende il sistema che comprende tutti i prodotti, i software e i servizi di ingegneria utili per i controlli automatici, per il monitoraggio, per l'ottimizzazione e la gestione al fine di ottenere un funzionamento efficiente, economico e in sicurezza dell'edificio [27]. Gli edifici in cui è installato un BACS tendono a mantenere l'ambiente in comfort in modo più efficiente riducendo l'impatto ambientale e i costi energetici.

Le funzioni principali e più comuni di un BACS sono il controllo dei sistemi di riscaldamento, ventilazione e condizionamento (HVAC) ma è anche utilizzato per impianti e apparecchiature adibite al controllo:

- dell'illuminazione;
- della potenza elettrica;
- della sicurezza;
- dei sistemi di allarme antincendio;
- di ascensori, scale mobili e impianti di risalita;

Un BACS è possibile descriverlo come un sistema composto dai seguenti componenti principali:

- sensori: sono dispositivi in grado di rilevare una grandezza come la temperatura, l'umidità, il livello di luminosità e altre grandezze misurabili all'interno dell'edificio in cui sono installati;
- controllori: sono dispositivi che ricevono le grandezze misurate in campo dai sensori e attraverso l'utilizzo di algoritmi inviano in uscita dei comandi;
- dispositivi di uscita: sono strumenti che hanno il compito di eseguire i comandi inviati dai controllori;
- protocolli di comunicazione: è il linguaggio di comunicazione usato dai componenti del BACS che, essendo connessi ad internet, consentono l'integrazione di più sistemi da qualsiasi parte del mondo;
- dashboard: è l'interfaccia utente utilizzata per la segnalazione e il monitoraggio dei dati da cui è possibile interagire con il sistema BACS;

Un BACS, inoltre, comprende tutti i sottosistemi collegati in modo da formare un sistema completo progettato e definito ad hoc per i servizi dello stesso. Ulteriore caratteristica fondamentale di tale sistema è la scalabilità ovvero la capacità di aumentare o diminuire il numero di dispositivi con cui è collegato a seconda delle necessità. In particolare, il BACS è scalabile da uno a migliaia di dispositivi e permette di:

- Collegare le funzionalità dei singoli componenti in modo che funzionino come un sistema integrato completo;
- Fornire ai proprietari degli edifici e agli operatori gli strumenti software per gestire le prestazioni e l'efficienza energetica dei loro edifici;
- Poter essere integrato con tutti gli altri servizi presenti nell'edificio come il servizio di sicurezza, il sistema antincendio, gli ascensori e altri sistemi di controllo.

Il professor Alberto Servida, docente dell'Università di Genova, classifica i dispositivi BACS attraverso la *"piramide dell'automazione"* riportata in figura 3.2 dove risulta ben visibile la suddivisione della piramide in tre differenti livelli. In particolare, il primo livello è costituito dai dispositivi hardware come ad esempio sensori e valvole, mentre il secondo è, invece, occupato dai controllori che raccolgono i parametri rilevati dai sensori, li elaborano e li utilizzano per guidare gli attuatori in base alla logica di controllo. Infine, l'ultimo livello, definito *"Management level"*, è composto dai sistemi di gestione come, ad esempio, le *workstation* [28].




Figura 3.2. Piramide dell'automazione e suoi componenti

I dispositivi presenti nel primo livello della piramide dell'automazione costituiscono l'input utilizzato successivamente dai dispositivi hardware da cui inviano in uscita un segnale (output) agli attuatori, ovvero alle apparecchiature del secondo livello, che trasformano in azione l'informazione iniziale. Tale processo è ben visibile anche

nell'immagine in figura 3.3 [29] dove sono mostrati anche alcuni esempi di apparecchiature dei due livelli.




Figura 3.3 Dispositivi di campo

L'ultimo livello, il *Management level*, è invece costituito dalle cosiddette *workstation* ovvero delle postazioni di lavoro dell'operatore grafico. Data l'importanza di tale livello per la gestione energetica, sono di seguito definite le caratteristiche principali che un'interfaccia grafica, ben progettata, dovrebbe avere:

1. Essere intuitiva da utilizzare e non richiedere alcun grado di ingegneria per l'interpretazione visiva;
2. Deve fornire informazioni all'operatore utili all'apprendimento della situazione attuale e anche di quella futura;
3. Deve avere una grafica che permette di effettuare manovre di regolazione e di modifica dell'algoritmo di controllo;

Un esempio delle apparecchiature grafiche comunemente utilizzate è visibile in figura 3.4.



Figura 3.4 *Interfacce grafiche BACS*

Il flusso teorico che collega i dispositivi presenti nei tre livelli della piramide dell'automazione sarà descritto in maniera dettagliata nel capitolo successivo, dando priorità alle fasi e alle tecniche che saranno utilizzate nell'analisi del caso studio successivo, riguardante i profili di potenza frigorifera del gruppo polivalente a servizio dell'Energy Center di Torino.

Di seguito verranno esposti i principali step riguardanti il flusso teorico precedentemente esplicitato in cui vengono monitorati i dati rilevati dai sensori, successivamente vengono analizzati e processati dagli hardware di controllo e infine questi ultimi forniranno in uscita l'output contenente l'azione da mandare agli attuatori di campo.

## 3.2 Modelli energetici per gli edifici

La simulazione svolge oggi un ruolo centrale nei sistemi di controllo avanzati HVAC in quanto consentono di individuare, in maniera automatica, le anomalie e di capire quali sono state le possibili cause attraverso l'utilizzo dei processi di FDD (*Fault Detection and Diagnosis*) con cui è possibile identificare le deviazioni della prestazione energetica da un comportamento normale di riferimento. Le simulazioni possono inoltre essere utilizzate sia per prevedere le condizioni interne future, in funzione delle condizioni climatiche esterne e dell'occupazione, sia per ottimizzare le strategie di controllo attraverso l'utilizzo di modelli di controllo predittivo (MPC) [30].

Lo sviluppo e la creazione di modelli di edifici risulta ancora oggi il principale ostacolo all'uso di simulazioni basate sui dati che confrontano i risultati attesi con le misure effettive così da evidenziare eventuali malfunzionamenti nel sistema. Gli approcci di modellazione utilizzati sono divisi in:

- Modelli *white-box*
- Modelli *grey-box*
- Modelli *black-box*

Di seguito verranno trattati singolarmente andando ad evidenziare differenze, similitudini e le possibili applicazioni nell'ambito di un processo di gestione energetica degli edifici.

### 3.2.1 Modelli *white-box*

I modelli *white-box* sono i modelli più dettagliati tra gli approcci di modellazione in quanto si basano sulla fisica attraverso l'utilizzo di equazioni algebriche e differenziali che permettono di fornire informazioni dettagliate sul funzionamento dell'edificio oggetto di studio. Se da un lato si evidenziano vantaggi come l'accuratezza e la precisione nella modellazione di edifici, d'altro canto è possibile evidenziare anche svantaggi come l'elevato sforzo computazionale della modellazione che risulta soggetta a frequenti errori e l'inadattabilità sia per il controllo che per il funzionamento in tempo reale. A causa di queste caratteristiche, i modelli *white-box* sono utilizzati per quantificare l'effetto di sistemi difettosi ovvero in applicazioni come l'analisi di retrofit o la FDD, o per valutare le strategie e le misure di rinnovamento termico [31]. Un esempio grafico dei *white-box* è fornito di seguito in figura 3.5.




Figura 3.5 Schema modello *white-box*

### 3.2.2 Modelli grey-box

I modelli *grey-box* sono modelli *data-driven* supervisionati, ovvero modelli guidati dai dati, e sono classificabili come ibridi tra i modelli *white* e *black box*. In particolare, i modelli *grey-box* combinano la conoscenza del sistema fisico, attraverso equazioni e parametri interpretabili fisicamente, con i dati monitorati dell'oggetto di studio. Nonostante ciò, il processo di implementazioni risulta soggetto ad errori, come nel caso dei *white-box*, ma rispetto a questi risultano più semplici e snelli da implementare motivo per cui hanno un minore costo computazionale. Ulteriore differenza, rispetto ai modelli *white-box*, è l'adattabilità per le operazioni di controllo in tempo reale. Tali modelli, infatti, sono implementati in controllori che utilizzano strategie di controllo avanzato come il MPC che offre opportunità di risparmio e ottimizzazione nell'ambito della gestione energetica dell'edificio sfruttando, ad esempio, l'inerzia dell'edificio ottimizzando i tempi di accensione e spegnimento o acquistando energia dalla rete in periodi in cui il costo risulta più basso.

I modelli *grey-box*, in particolare, hanno l'obiettivo di trasformare il sistema fisico in un circuito R-C (Resistenza-Capacità) sfruttando l'analogia tra i sistemi termici ed elettrici per cui, ad esempio, il flusso di calore attraverso le pareti dell'involucro di un edificio, può essere schematizzato con una serie di resistenze elettriche attraversate da corrente. Un esempio di tale approccio è graficamente visibile dall'immagine in figura 3.6.




Figura 3.6 Schema modello grey-box con analogia elettrica

### 3.2.3 Modelli black-box

I modelli *black-box*, infine, sono modelli completamente *data-driven*, ovvero guidati esclusivamente dai dati di monitoraggio per identificare la struttura del sistema analizzato. Per tale ragione sono infatti i modelli che hanno la maggior efficienza e flessibilità computazionale e risultano avere un alto livello di accuratezza seppur utilizzando poche informazioni sul sistema.

A differenza dei precedenti modelli però risultano nel complesso meno precisi, in quanto fortemente dipendenti dalla qualità dei dati forniti, e non sono indicati per prevedere modelli inesplorati, ovvero di cui non si hanno dati a disposizione. Un esempio grafico dei modelli *black-box* è visibile in figura 3.7 che permette di spiegare il motivo per cui tali modelli sono così denominati. Come visibili dall'immagine, i modelli ricevono in input i dati di monitoraggio e all'interno della scatola nera, attraverso l'utilizzo di tecniche e algoritmi di *machine learning*, elaborano e inviano in uscita un output che permette di modellare l'oggetto di studio. Proprio per l'utilizzo di tali tecniche, i modelli *black-box* hanno lo svantaggio di risultare difficili da spiegare pur restano i modelli di maggior utilizzo nell'ambito della modellazione degli ultimi anni.




Figura 3.7 Schema modello black-box

Un riassunto concettuale è rappresentato nella figura seguente, figura 3.8, che mostra le principali caratteristiche dei modelli precedentemente descritti, visualizzandone anche gli aspetti comuni e non.






Figura 3.8 Schema modelli di simulazione energetica

### 3.3 Monitoraggio energetico

Il primo step per poter effettuare un'ottima analisi di gestione energetica basata sui dati, con l'ausilio dei modelli energetici degli edifici, precedentemente illustrati, non può che essere il monitoraggio energetico.

*“Non si può gestire ciò che non si può misurare”*. Celebre e appropriata al contesto è la frase di Robert Kaplan, ideatore della *“Balanced Scorecard”* che definisce tale strategia fondamentale per il raggiungimento degli obiettivi aziendali.

Il monitoraggio è il primo e fondamentale step per poter ottimizzare l'edificio in quanto permette di comprendere la situazione interna tramite le misure registrate in campo dai sensori, che inviano dati, non sempre ottimali. Infatti, fase principale del monitoraggio è il *Data pre-processing* diviso in *Data preparation* e *Data characterization*.

Questa fase occupa circa l'80% del tempo impiegato per sviluppare l'intera analisi, la quale per risultare di qualità, deve necessariamente basarsi su dati affidabili. Famoso, a tal proposito, è il detto *“Garbage in=Garbage out”* che esprime come tutto quello che è in uscita da un processo dipende principalmente da quello che c'è in ingresso.

La qualità dei dati purtroppo è generalmente minacciata da diverse sorgenti di anomalie di natura differente tra cui:

- Comunicazioni errate dei sensori con il cloud;
- Malfunzionamenti dei sensori;

- Modifiche dell'edificio non comunicate al sensore quando questo, ad esempio, viene spostato in diverse zone dell'edificio;
- Eventi catastrofici come la più recente pandemia globale;

Il problema principale del verificarsi di tali problematiche è dovuto alla mancanza di sistemi che attraverso delle logiche riescano a rilevarle e successivamente risolverle. Le apparecchiature di misura dovrebbero, infatti, essere controllate quotidianamente in modo da non effettuare analisi errate che porterebbero l'edificio in condizioni di discomfort.

Le variabili misurate, che influenzano il consumo energetico all'interno dell'edificio oggetto di studio, sono principalmente tutti i parametri riguardanti l'occupante, il suo comportamento con l'edificio, le caratteristiche fisiche e impiantistiche di quest'ultimo e infine i dati climatici esterni, essenziali per l'analisi energetica. I dati sono classificati in due principali categorie illustrate in figura 3.9.




Figura 3.9 *Classificazione variabili database*

In particolare, la classificazione considera:

- Variabili numeriche: variabili rappresentate da numeri i cui valori possono essere continui o discreti. I primi considerano ad esempio misure come la temperatura o il consumo energetico mentre le variabili discrete considerano soltanto misure esprimibili con numeri interi come, ad esempio, il numero degli occupanti o i piani dell'edificio;
- Variabili categoriche: variabili che considerano misure prese da un insieme definito di valori e possono essere ordinali, ovvero variabili intrinsecamente

definite da un ordine come i giorni della settimana, oppure nominali, ossia variabili che descrivono l'aspetto di un sistema come la destinazione d'uso dell'edificio;

Tali variabili caratterizzano il database su cui verrà svolta l'intera analisi che prevede, come precedentemente annunciato, lo step iniziale del *Data pre-processing*, diviso in due step, tra cui il primo denominato *Data preparation* che sarà di seguito descritta.

Tale step prevede inizialmente l'applicazione del *Data cleaning* ovvero il processo di pulizia e rimozione dei dati dalla presenza di dati mancanti (*missing data*) e di eventuali inconsistenze (*outliers*).

In particolare, per la rimozione dei valori mancanti i metodi più comuni utilizzati sono:

- Costante Globale (*Global Constant*): i dati mancanti sono sostituiti con la media di tutto il campione di dati, infatti, non costituisce un'ottima rappresentazione del dato mancante;
- Costante Locale (*Local Constant*): i dati mancanti sono sostituiti con la media soltanto di alcuni intervalli del dataset. Tale metodologia risulta più accurata della precedente;
- Media Mobile (*Moving Average*): i valori mancanti sono sostituiti con la media degli N valori precedenti, dove il numero N varia a seconda del caso, solitamente è un numero compreso tra 4 e 10 [27];
- Interpolazione Lineare (*Linear Interpolation*): è uno dei metodi più utilizzati che consiste nel sostituire i dati mancanti con i valori che si trovano sulla retta di congiunzione tra il primo e l'ultimo dato disponibile;

La fase di *Data Cleaning* prevede, inoltre, anche la rimozione di eventuali inconsistenze ovvero di valori che si discostano notevolmente dall'andamento generale del dataset. La presenza di inconsistenze all'interno del dataset può essere dovuta a diverse cause, oltre quelle già citate, tra cui le differenze tra le scale o tra le unità di misura dei dati dovute a malfunzionamenti di connessione che molto spesso sono anche causa della duplicazione dei dati. Gli *outliers*, come sono anche definite le inconsistenze, sono facilmente identificabili graficamente in quanto sono punti, o intere sequenze di dati, che deviano

significativamente l'andamento rappresentato. Tali incoerenze sono eliminabili attraverso l'utilizzo di metodi automatici o semiautomatici dato la loro numerosa presenza all'interno dei dataset. Tra questi i principali sono:

- Metodo dell'inter-quartile: in tale metodo gli *outlier* vengono identificati attraverso il precedente calcolo di alcune grandezze come il primo quartile, l'ultimo quartile e l'inter-quartile grazie ai quali è possibile definire i limiti oltre i quali i valori sono definiti *outlier*;
- Metodo dello z-score: come predetto dal nome, la fase iniziale di tale metodologia prevede il calcolo dello z-score che indica il numero di deviazioni standard superiori o inferiori alla media. È possibile così determinare gli *outliers* ovvero quei valori che sono posizionati al di fuori del range identificato dagli z-score.

Fase successiva del *Data preparation* è la *Data transformation* che permette di riportare tutti i dati su una stessa scala in modo da organizzare il dataset in un formato applicabile agli algoritmi, i quali si basano su distanza tra punti e non sui valori espressi a seconda delle grandezze. Generalmente il compito più comune in tale processo è la conversione dei dati numerici in variabili categoriche. In particolare, per poter scalare i dati, si ricorre a diverse strategie tra cui:

- *Max scaling*: consiste nello scalare l'intero dataset rispetto al valore massimo;
- *Min-Max scaling*: permette di scalare il dataset riportandolo con valori compresi tra 0 e 1;
- *Normalization*: permette di riportare i dati nei loro z-score;

Ultima fase del *Data preparation* è, invece, la *Data reduction* che permette di ridurre un certo numero di dati a disposizione per una buona analisi a seconda del caso. In particolare, i dati sono generalmente monitorati con frequenze elevatissime, ogni 15 minuti circa, qualora fosse però necessaria una quantità inferiore di dati, tale da diminuire il costo computazionale dell'algoritmo, è utile ricorrere alla *Data reduction* la quale utilizza strategie di riduzione come la PAA (*Piecewise Aggregate Approximation*). In particolare, tale strategia di riduzione permette di eseguire un'approssimazione del dataset sostituendo i valori delle serie temporali originali, che si trovano all'interno della

stessa finestra temporale, con il loro valore medio, riducendo così la quantità di dati che l'algoritmo dovrà processare.

Terminato lo step del *Data preparation* si passa al secondo step del *Data pre-processing* ovvero la *Data characterization*.

La *Data characterization* è caratterizzata principalmente dalla fase di visualizzazione del dataset che svolge un ruolo essenziale nello step del *Data pre-processing*. Questa fase permette di avere una prima visione complessiva dei dati che saranno in seguito utilizzati per effettuare l'analisi. Tra le diverse visualizzazioni le più comuni sono, ad esempio, i *boxplot*, i *carpet plot* e i *calendar plot*, visibili graficamente anche nella figura 3.10.




Figura 3.10 Visualizzazione *boxplot*, *carpet plot* e *calendar plot*

## 3.4 Tecniche di data analytics

Una ricerca recente mostra come il termine “*Big Data*” sia una delle parole chiave più ricercate sul web dagli utenti di Google a partire dal 2011. La sua traduzione letterale “grande quantità di dati” non aiuta a comprendere appieno il suo vero significato in quanto evidenzia principalmente la grande disponibilità di informazioni in termini quantitativi senza focalizzarsi all'utilizzo elevato dei dati in qualsiasi ambito e a tutto ciò che ne deriva. Utile è a tal proposito la definizione proposta da *Dan Ariely*, professore di psicologia ed economia comportamentale che afferma: “*I Big Data rappresentano una raccolta di dati così estesa in termini di volume, velocità e varietà da richiedere tecnologie e metodi analitici specifici per l'estrazione di valore*”.

Tali metodi sono quelli utilizzati dalle tecniche di *data analytics* che risultano la soluzione degli analisti al problema del numero elevato e crescente di dati all'interno dei database, i quali vengono utilizzati nell'ambito edilizio per ricavare informazioni utili alla gestione energetica.

In particolare, le tecniche di *data analytics* permettono di esplorare dataset caratterizzati da un numero elevato di dati al fine di trovare delle linee guida. Tali tecniche però non risultano utili senza conoscere i fenomeni fisici energetici che interessano l'edificio, infatti, tale condizione risulta necessaria per poter interpretare i risultati degli algoritmi. Attraverso le tecniche di *data analytics* è possibile operare anche processi di *commissioning* verificando, in seguito all'applicazione di misure di risparmio energetico, l'effetto che tali misure hanno nel tempo.

È possibile classificare tali tecniche in due differenti tipologie quali le tecniche di apprendimento supervisionato e le tecniche di apprendimento non supervisionato. Entrambe saranno trattate in modo approfondito nei successivi paragrafi.

### 3.4.1 Tecniche di apprendimento supervisionato

Gli algoritmi di *machine learning* supervisionati sono algoritmi di apprendimento automatico progettati per imparare da un esempio; infatti, tale algoritmo lavora allo stesso modo di un insegnante che supervisiona l'intero processo [27].

L'obiettivo delle tecniche supervisionate è conoscere la relazione che esiste tra input e output, inizialmente forniti, tramite l'identificazione di un modello di stima che permette di identificare l'etichetta corretta dei nuovi dati forniti in input. Gli algoritmi di apprendimento supervisionato si basano quindi sull'idea di aumentare l'esperienza del modello aumentando il numero di esempi forniti al sistema. La procedura che generalmente si utilizza consiste nel dividere in maniera randomica il dataset di partenza in due parti quali il *training set* e il *testing set*. Successivamente fornisco al modello i dati di *training set*, da cui imparerà le relazioni che ci sono tra i dati forniti in input, e i dati di output. Il *testing set*, invece, verrà utilizzato per validare i risultati tramite i dati che non ho fornito al modello. In particolare, dopo aver creato il modello vengono forniti in ingresso i dati di input del *testing set* ottenendo in uscita degli output che saranno confrontati con gli output del *testing set*, non ancora utilizzati. Il confronto tra i due

output permette di validare il modello qualora i risultati siano abbastanza simili. Una volta validato il modello viene utilizzato come modello di previsione fornendo nuovi dati in input e ottenendo altrettanti output di previsione. Spiegazione grafica del processo appena descritto è visibile in figura 3.11.




Figura 3.11 *Training e Testing test*

Gli esempi principali di tecniche supervisionate sono:

- La regressione: è un processo statistico predittivo in cui il modello tenta di trovare le relazioni che sussistono tra le variabili dipendenti e le variabili indipendenti. Sono generalmente utilizzate per predire il consumo energetico o la potenza assorbita.
- La classificazione: è un processo che consiste nell'apprendimento di una funzione o di un insieme di regole utili allo sviluppo di un modello in grado di assegnare per un nuovo oggetto statistico la sua classe di appartenenza. Ovvero permette, ad esempio, di andare a classificare un semplice dato di potenza ad un particolare giorno della settimana (classe di appartenenza).

Di seguito verranno descritti in modo dettagliato i modelli utilizzati all'interno del caso studio analizzato nel capitolo 4.

### 3.4.1.1 Albero di classificazione

Gli alberi di classificazione rientrano nella categoria degli alberi decisionali delle tecniche di classificazione e permettono di prevedere variabili di tipo categorico. Tali modelli sono costruiti dividendo continuamente i dati di partenza in sottoinsiemi, chiamati nodi, creando una struttura ad albero. Le relazioni che si instaurano tra i vari dati avvengono secondo regole *if-then* che creano un legame tra un evento o una condizione chiamata antecedente con un'altra denominata conseguente. La struttura ad albero è caratterizzata da due tipologie di nodi:

- Nodi decisionali: dividono il dataset a seconda di una serie di attributi *if-then*. Il primo nodo decisionale è denominato "nodo radice" e costituisce la variabile principale della classificazione;
- Nodi foglia: costituiscono i nodi finali dell'albero e permettono di identificare l'effettiva classificazione del dataset;

Gli oggetti vengono classificati seguendo il percorso della struttura ad albero con partenza dal nodo radice e arrivo al nodo foglia.

### 3.4.1.2 Albero di regressione

Gli alberi di regressione, così come gli alberi di classificazione, rientrano nella categoria degli alberi decisionali con la differenza di predire soltanto variabili di tipo continuo.

L'albero di regressione viene costruito utilizzando tecniche di apprendimento supervisionato che permettono di costruire un modello con struttura ad albero, come il caso precedente, con la sola differenza di predire un valore continuo in output anziché la classe di appartenenza.

### 3.4.1.3 Rete Neurale Artificiale

Le reti neurali artificiali ANN (*Artificial Neural Network*) permette di creare modelli sia per calcoli previsionali che di classificazione a seconda della tipologia dell'output. La loro applicazione è già da diversi anni utilizzata come alternativa, nella previsione, ai metodi statistici tradizionali in quanto risultano più tolleranti dei dati imperfetti e permettono di stimare bene le funzioni non lineari [32].



In particolare, il modello ANN è costituito da funzioni matematiche innestate, organizzate su più livelli, definiti *layer* (vedi figura 3.12) i cui output vengono utilizzati come input al *layer* successivo. Le unità fondamentali di un *layer* sono i neuroni.




Figura 3.12. Modello Rete Neurale Artificiale

La tipologia di rete neurale considerata, nel caso studio nel capitolo 4, è la MLP (*Multi Layer Perceptron*), la cui struttura è osservabile in figura 3.12, e la funzione di attivazione  $g$  implementata è la *rectified linear unit*, il cui andamento è visualizzabile nella seguente figura:




Figura 3.13 Andamento funzione di attivazione

Nonostante siano l'approccio più utilizzato per la previsione del consumo energetico degli edifici, le reti neurali presentano lo svantaggio di trattare solo variabili numeriche e di non essere facilmente interpretabili, in quanto modelli totalmente *black box*.

### 3.4.2 Tecniche di apprendimento non supervisionato

Gli algoritmi di *machine learning* non supervisionato, a differenza delle tecniche supervisionate, si basano su un dataset in cui non è possibile distinguere i valori di input dai valori di output. Il loro obiettivo è infatti scoprire dei pattern o dei profili di associazione significativi attraverso processi di ricerca compiuti sul dataset. Per tali ragioni le tecniche non supervisionate sono utilizzate per individuare particolarità presenti all'interno del dataset. Le principali tecniche sono:

- *Association rule mining*: metodo utilizzato per identificare tutte le relazioni e associazioni di tipo *if-then*, precedentemente descritte, tra le variabili del dataset. L'output è un insieme di regole che vengono utilizzate per rappresentare modelli in grado di determinare peculiarità all'interno del dataset.
- *Cluster analysis*: metodo che permette di raggruppare, in gruppi differenti, oggetti dello stesso dataset in modo da esaltarne le particolarità. In particolare, i subset identificati sono caratterizzati da alte similarità interne ma basse similarità esterne. Tale metodo sarà sviluppato in modo più dettagliato nel capitolo seguente in quanto verrà utilizzato per identificare i profili tipologici presenti all'interno del dataset, oggetto di studio, in cui sono registrati i valori di potenza frigorifera del gruppo polivalente a servizio dell'Energy Center di Torino.

#### 3.4.2.1 Cluster analysis

La *cluster analysis* può essere definita come il processo di partizionamento di un insieme di oggetti (osservazioni) in modo che gli oggetti appartenenti allo stesso cluster risultano simili l'uno con l'altro ma dissimili dagli oggetti appartenenti ad altri cluster [33]. Un esempio grafico di tale concetto è visibile nella figura seguente:




Figura 3.14 Cluster analysis

L'immagine in figura 3.14 mostra la suddivisione del dataset in tre gruppi, denominati *cluster*, i cui valori all'interno risultano essere omogenei (stesso colore) tra di loro e disomogenei (colori differenti) con i valori di altri *cluster*. In particolare, il criterio utilizzato per raggruppare il dataset in gruppi varia a seconda di prestabilite misure di similarità o distanza degli attributi dei dati analizzati [34].

Il partizionamento viene eseguito da algoritmi di raggruppamento che portano alla scoperta di gruppi di dati precedentemente sconosciuti. Esistono diversi algoritmi di *clustering* a seconda dei quali si generano cluster differenti dallo stesso set di dati.

I principali algoritmi di clustering sono suddivisi in tre gruppi:

- *Clustering partitivo*: è un metodo di partizionamento che divide i dati in  $K$  gruppi in modo che ogni partizione rappresenta un *cluster* contenente almeno un oggetto. Tipicamente questo metodo adotta una partizione esclusiva ovvero suddivide il dataset in gruppi che non possono contenere oggetti sovrapposti, ovvero ciascun oggetto (dato) può appartenere soltanto ad un solo *cluster*. La maggior parte delle applicazioni adotta metodi di partizionamento euristici come, ad esempio, gli algoritmi *k-means* che migliorano progressivamente la qualità del *clustering* avvicinandosi, ma senza mai raggiungere, l'ottimizzazione globale i cui costi computazionali risultano elevatissimi [33]. Un esempio di *clustering partitivo* è riportato in figura 3.15.




Figura 3.15 *Clustering partitivo*

- Clustering gerarchico*: è uno dei metodi più utilizzati e permette di scomporre, un dato insieme di oggetti, in gruppi in cui ogni *cluster* è generato a sua volta da un altro *cluster*. Il metodo gerarchico può seguire due approcci di scomposizione quali l'approccio *bottom-up* in cui ogni oggetto inizialmente forma un *cluster* e successivamente si fondono gli oggetti o i gruppi più vicini fino ad essere tutti inclusi in un unico grande *cluster*. Il secondo approccio, invece, è definito *top-down* e segue la logica completamente opposta alla precedente considerando tutti gli oggetti inizialmente contenuti in un unico *cluster* che in seguito, ad ogni iterazione, viene suddiviso in *cluster* più piccoli fino a quando ogni oggetto costituisce una singola partizione [33]. L'utilizzo di tale metodo porta alla creazione di un dendrogramma, ovvero una struttura ad albero, in cui sono ben visibili le sequenze di aggregazione dei dati fino alla creazione dei *cluster* finali. Un esempio di *clustering gerarchico* è riportato in figura 3.16.




Figura 3.16 *Clustering gerarchico*

- *Clustering basata sulla densità*: è un metodo di partizionamento che, a differenza dei precedenti, tende a raggruppare i dati all'interno di *cluster* aumentandone la loro grandezza finché la densità, ovvero il numero di oggetti al suo interno, supera una certa soglia. Tale metodo è per lo più utilizzato per filtrare valori anomali (*outlier*) e scoprire *cluster* di forma diversa. Un esempio è riportato nella figura seguente:




Figura 3.17 *Clustering basata sulla densità*

## 4 CASO STUDIO

L'oggetto di studio dell'elaborato di Tesi è, come precedentemente anticipato, l'analisi energetica dell'Energy Center di Torino attraverso l'applicazione di tecniche di DSM.

L'edificio è situato a Torino in via Paolo Borsellino 18, e nasce dall' *Energy Center Initiative* (ECI), un'idea lanciata dal Politecnico di Torino nel 2016 per offrire supporto e consigli ad autorità locali, enti nazionali e internazionali sulle tecnologie energetiche più innovative. Una delle iniziative proposte dall'ECI è proprio l'*Energy Center House*, ovvero l'edificio oggetto di studio, costruito all'interno del campus del Politecnico di Torino, ospita diverse aziende, start-up e amministrazioni pubbliche in campo energetica che hanno la possibilità di collaborare in un ambiente che stimola il coinvolgimento con l'innovazione scientifica. Difatti, le soluzioni alle emergenti sfide energetiche ed ambientali necessitano il coordinamento di competenze e background di diverse aziende che sono state, per tali ragioni, riunite all'interno di un unico ambiente.



Figura 4.1 Edificio Energy Center

### 4.1 Descrizione dell'edificio

L'edificio occupa un volume lordo di circa  $300075 \text{ m}^3$  con una superficie utile di  $5441 \text{ m}^2$  distribuita su cinque piani di cui uno interrato. Parte del piano interrato è adibito a parcheggio auto, dotato di due colonnine di ricarica per veicoli elettrici, mentre il restante spazio è occupato da laboratori e locali tecnici i quali ospitano:

- Impianti di riscaldamento e raffrescamento
- Due Unità di Trattamento Aria (UTA)
- Il gruppo UPS (*Uninterruptible Power Supply*) per la continuità del servizio elettrico
- Generatore diesel d'emergenza

Il piano terra è caratterizzato da una sala centrale che si sviluppa per tutti i tre piani dell'edificio ed ospita una Hall, in cui presiede la reception, un Auditorium da circa 150 posti e un laboratorio di ricerca. Il piano superiore è il piano ammezzato che presenta la sala controllo adibita alla gestione delle operazioni di monitoraggio e sicurezza dell'edificio. Infine, a partire dal primo fino al terzo piano sono l'edificio ospita uffici e sale riunioni in cui risiedono aziende e start-up generalmente operanti nel settore energetico.

I servizi energetici dell'edificio sono soddisfatti attraverso due principali vettori energetici quali l'elettricità, attraverso la connessione alla rete elettrica a MT (media tensione), e il calore fornito attraverso il collegamento con la rete di Teleriscaldamento della città di Torino. L'Energy Center presenta, inoltre, due fonti di energia rinnovabili quali:

- Sistema di pannelli solari con una potenza installata di circa 57 [kW] adibito alla produzione di corrente elettrica;
- Impianto solare termico per la produzione di acqua calda sanitaria (ACS);

Il risultato dell'utilizzo di fonti rinnovabili e di un'accurata scelta dei componenti e materiali innovativi ha permesso all'edificio di rientrare nella classe energetica A+ e di ottenere un punteggio pari a 3 nel Protocollo Itaca (Istituto per l'innovazione e Trasparenza degli Appalti e la Compatibilità Ambientale), sistema di rating per la valutazione e certificazione di edifici sostenibili, risultando uno degli edifici torinesi più innovativi dal punto di vista energetico.

Nei paragrafi successivi verranno presentati i principali impianti energetici installati all'interno della centrale termica focalizzando l'attenzione sugli impianti di produzione di energia termica e frigorifera che permettono di mantenere le condizioni di comfort termo-igrometrico all'interno dell'edificio.

### 4.1.1 Centrale termica

La centrale termofrigorifera si sviluppa nel piano interrato con l'obiettivo di produrre sia acqua refrigerata che acqua calda utilizzati dagli impianti di riscaldamento, raffrescamento e ACS per garantire le condizioni di comfort all'interno dell'edificio. Parte dei dati di targa caratterizzanti gli impianti precedentemente citati, sono di seguito riportati in tabella 2.

Tabella 2. *Caratteristiche impianti della centrale termica*

| <b>Componente</b>                              | <b>Produzione</b>                          | <b>Parametro</b>             | <b>Valore</b> |
|------------------------------------------------|--------------------------------------------|------------------------------|---------------|
| <i>Gruppo<br/>Polivalente</i>                  | <i>Riscaldamento</i>                       | <i>Potenza Nominale [kW]</i> | <i>474</i>    |
|                                                | <i>Raffrescamento<br/>(senza recupero)</i> | <i>Potenza Nominale [kW]</i> | <i>443</i>    |
|                                                | <i>Raffrescamento<br/>(con recupero)</i>   | <i>Potenza Nominale [kW]</i> | <i>362</i>    |
|                                                |                                            |                              |               |
| <i>Chiller<br/>ad assorbimento</i>             | <i>Raffrescamento</i>                      | <i>Potenza Nominale [kW]</i> | <i>155</i>    |
| <i>Sottostazione<br/>del Teleriscaldamento</i> | <i>Riscaldamento</i>                       | <i>Potenza Nominale [kW]</i> | <i>350</i>    |
|                                                | <i>ACS</i>                                 | <i>Potenza Nominale [kW]</i> | <i>50</i>     |
|                                                | <i>chiller ad<br/>assorbimento</i>         | <i>Potenza Nominale [kW]</i> | <i>255</i>    |
| <i>Serbatoi per<br/>accumulo termico</i>       | <i>Acqua calda</i>                         | <i>Capacità [l]</i>          | <i>4000</i>   |
|                                                | <i>Acqua fredda</i>                        | <i>Capacità [l]</i>          | <i>4000</i>   |
|                                                | <i>Acqua calda</i>                         |                              | <i>1000</i>   |
|                                                | <i>Solare termico</i>                      | <i>Capacità [l]</i>          |               |
| <i>Boiler</i>                                  | <i>ACS</i>                                 | <i>Capacità [l]</i>          | <i>1500</i>   |



Tra gli impianti più innovativi, presenti in tabella, ruolo principale è ricoperto dal gruppo ad assorbimento ad acqua e bromuro di litio (LiBr), visibile in figura 4.2, installato per la produzione di acqua refrigerata. Il suo funzionamento prevede l'utilizzo dell'acqua calda prodotta dalle centrali IREN che attraverso il ciclo ad assorbimento a LiBr permette di produrre l'acqua refrigerata inviata successivamente al collettore freddo. La macchina ad assorbimento non è però in funzione in quanto la temperatura di alimentazione dell'acqua calda in arrivo dal Teleriscaldamento di circa 90 [°C], è molto più bassa rispetto alla temperatura di 110 [°C] richiesta dalla macchina per funzionare in condizioni ottimali. L'installazione di tale macchina è stata comunque effettuata in quanto in linea con l'obiettivo dell'Energy Center di sperimentare e testare diverse tipologie impiantistiche.



Figura 4.2 *Macchina ad assorbimento*

#### 4.1.1.1 Impianti produzione acqua refrigerata

L'edificio per produrre acqua refrigerata utile a garantire le condizioni di comfort all'interno dei locali climatizzati, utilizza esclusivamente il gruppo polivalente data l'impossibilità di utilizzo della macchina ad assorbimento per i motivi sopra evidenziati. La descrizione dettagliata delle caratteristiche e del funzionamento del gruppo polivalente sono di seguito riportate.

#### 4.1.1.1.1 Gruppo Polivalente

L'unità polivalente, installata nel locale tecnico dell'edificio, è una macchina a espansione diretta che utilizza il gas refrigerante, in particolare il fluido R134A, che, attraversando i vari componenti caratterizzanti il ciclo, permette di produrre sia acqua calda che acqua refrigerata contemporaneamente. In particolare, l'acqua refrigerata, che attraversa il circuito freddo, è utilizzata per refrigerare e condizionare i locali durante la stagione estiva mentre l'acqua calda è impiegata per alimentare le batterie di post-riscaldamento delle UTA per il controllo dell'umidità, durante il periodo delle mezze stagioni o in estate.

In Inverno l'impianto viene generalmente spento in quanto la richiesta di energia termica è soddisfatta dalla rete di Teleriscaldamento.

Il gruppo polivalente installato all'interno dei locali tecnici del piano interrato è il gruppo "Climaveneta ERACS2-WQ/S 1702", riportato in figura 4.3, costituito da due circuiti frigoriferi distinti caratterizzati da due compressori di tipologia a vite e tre scambiatori a fascio tubiero in comune quali l'evaporatore, il condensatore e uno scambiatore ausiliario sempre visibili nella figura seguente.




Figura 4.3 Schema gruppo polivalente Climaveneta

Il gruppo possiede, in particolare, tre differenti modalità di funzionamento a seconda delle richieste termiche dell'impianto quali: produzione di acqua calda, produzione di acqua refrigerata e produzione simultanea di acqua calda e acqua fredda. Il passaggio da

una modalità all'altra è gestito da un microprocessore automatico, installato a bordo macchina, in grado di ottimizzare l'energia spesa in funzione delle richieste di carico termico da parte delle utenze.

Le modalità di funzionamento sono di seguito descritte singolarmente:

- **Produzione di acqua calda:** Il gruppo polivalente lavora in questo caso come pompa di calore in cui lo scambiatore ausiliario è utilizzato come evaporatore, rilasciando energia termica, prelevata dall'acqua di falda, al condensatore lato utenza;
- **Produzione acqua refrigerata:** Il gruppo lavora come macchina frigorifera (*chiller*) in cui lo scambiatore ausiliario è utilizzato come condensatore asportando energia termica, ceduta all'acqua di falda, dall'evaporatore lato utenza fredda;
- **Produzione simultanea di acqua calda e acqua fredda:** Il gruppo lavora come un *chiller* con recupero e non utilizza lo scambiatore ausiliario. In tale configurazione l'evaporatore è utilizzato per asportare energia termica dal circuito primario freddo, mentre il condensatore per cedere l'energia termica al circuito primario caldo per la produzione di acqua calda.

### *Regolazione Gruppo Polivalente*

La tipologia di regolazione del gruppo polivalente, descritta all'interno della documentazione fornita da "Climaveneta", avviene tramite una valvola a cassetto che, a seconda della posizione, determina una riduzione a gradini della camera di compressione, permettendo così al compressore di erogare il 100%, 75% e 50% della sua capacità. In particolare, la termoregolazione avviene sui due circuiti idraulici a seconda della temperatura di ritorno dell'acqua.

In figura 4.4 è mostrato l'andamento della potenza termica e frigorifera erogate dal gruppo polivalente durante la passata stagione estiva (anno 2021). I profili di potenza sono diagrammati in modo da poter evidenziare la modalità di funzionamento del gruppo polivalente durante i mesi centrali della stagione estiva quali giugno, luglio e agosto in cui si evidenzia la produzione simultanea di entrambe le potenze. La modalità di

funzionamento impostata risulta infatti quella del *chiller* con recupero in cui viene prodotta simultaneamente sia acqua calda che acqua refrigerata.




Figura 4.4 Andamento Potenza termica e frigorifera stagione estiva 2021

Caratteristica ulteriore del gruppo polivalente risiede nella presenza di accumuli termici nei circuiti caldo e freddo, utilizzati allo scopo di stabilizzare il flusso di acqua, calda o refrigerata a seconda dell'accumulo, e di evitare di far accendere e spegnere continuamente il compressore, aumentando così l'inerzia globale del sistema. Un esempio di accumulo di acqua refrigerata, presente nella centrale termica, è riportato in figura 4.5.



Figura 4.5 Accumulo acqua refrigerata

A partire da questi serbatoi termici di accumulo, l'acqua refrigerata o calda, viene inviata al collettore di mandata, rispettivamente freddo o caldo, da cui, grazie alla spinta delle

pompe a portata variabile installate sulla mandata, l'acqua viene inviata per alimentare le varie utenze.

La macchina polivalente, inoltre, è costituita, oltre che da tubi di uscita dell'acqua calda o refrigerata, anche da una tubazione che giunge all'interno dei pozzi geotermici contenenti acqua di falda che permette di smaltire l'eccesso di calore. In particolare, il circuito con acqua di falda giunge in centrale attraverso una tubazione, visibile in figura 4.6, contenente un filtro che trattiene la sabbia e le impurità presenti nell'acqua di falda così da far circolare soltanto acqua pulita all'interno dell'impianto.



Figura 4.6 Tubazione acqua di falda con filtro

Il circuito dell'acqua di falda, inoltre, presenta sia misuratori di portata che di temperatura in quanto vi è l'obbligo di comunicare annualmente alla città di Torino le portate emunte dalla falda con le temperature di prelievo e restituzione. Particolare attenzione è prevista per la temperatura di restituzione, la quale ha il vincolo di non poter raggiungere valori inferiori a 22 [°C], in accordo con la città di Torino.

#### 4.1.1.2 Impianti produzione acqua calda

La produzione di acqua calda utile a garantire il riscaldamento dei locali interni dell'edificio è soddisfatta interamente dalla rete di Teleriscaldamento della città di Torino, la città più teleriscaldata d'Italia. La produzione di acqua calda non interessa soltanto

l'impianto di riscaldamento ma anche la produzione di acqua calda sanitaria la cui produzione sarà descritta in modo dettagliato successivamente.

### *Sottostazione Teleriscaldamento*

La rete di Teleriscaldamento produce acqua calda sia per l'impianto di riscaldamento che per l'impianto di ACS. Tramite circa 1000 [km] di rete di distribuzione l'acqua, prodotta in moderne centrali in assetto cogenerativo a ciclo combinato con circa 2600 [MW] di potenza termica, giunge ai singoli edifici della città [35].

In particolare, l'acqua prodotta all'interno delle centrali termiche giunge all'interno della centrale termica dell'Energy Center in fase surriscaldata a 130 [°C] dove transita all'interno di uno scambiatore di calore, visibile in figura 4.7 in cui avviene lo scambio termico con il circuito secondario che alimenta gli impianti dell'edificio.



Figura 4.7 Scambiatore teleriscaldamento

L'Energy Center dispone di tre scambiatori di calore collegati alla rete di Teleriscaldamento, ognuno dei quali alimenta utenze specifiche. In figura 4.8 è presente lo schema della sottostazione termica con i tre scambiatori di calore che producono rispettivamente:



- SC-01 → acqua calda per ACS;
- SC-02 → acqua calda per il riscaldamento;
- SC-03 → acqua calda per gruppo ad assorbimento;




Figura 4.8 Schema sottostazione termica con scambiatori teleriscaldamento

L'acqua calda del circuito secondario, all'uscita dallo scambiatore, raggiunge una temperatura di 90 [°C] ritornando successivamente all'interno dello scambiatore con un salto termico di circa 30 [°C] a differenza del salto termico del circuito primario di circa 60 [°C].

L'acqua calda, prodotta nel passaggio attraverso lo scambiatore di calore, viene inviata al collettore caldo che la distribuisce per mezzo delle pompe ai vari circuiti delle varie utenze installate nei diversi piani dell'edificio. Le pompe installate sul collettore di mandata sono, in particolare, pompe a portata variabile, visibili in figura 4.9, dotate di inverter che modula la velocità in modo da mantenere la pressione costante e far circolare soltanto le portate di acqua necessarie risparmiando sia energia elettrica in termini di pompaggio che acqua in termini di dispersione delle tubazioni.



Figura 4.9 Pompe di circolazione

La regolazione della sottostazione del teleriscaldamento avviene modulando la portata di acqua nel circuito primario attraverso una valvola in grado di aprire o interrompere l'afflusso di acqua surriscaldata allo scambiatore attraverso l'utilizzo di sonde di temperature installate sulla mandata del circuito secondario.

### *Serbatoi per accumulo termico*

La centrale termica presenta due serbatoi per l'accumulo termico di acqua refrigerata e acqua calda di capacità pari a 4000 [l] e un boiler di circa 1500 [l] alimentato dalla rete di riscaldamento o dal gruppo polivalente per produrre l'ACS e riportato di seguito in figura 4.10.




Figura 4.10 Schema riscaldamento serbatoio ACS



L'acqua all'interno del boiler viene riscaldata fino ad una temperatura di circa 60 [°C] attraverso la serpentina, visibile in figura 4.10, alimentata dall'acqua proveniente dalla rete di teleriscaldamento o dal gruppo polivalente a seconda della logica di controllo impostate sul sistema di valvole a tre vie che stabilisce quale dei due circuiti deve alimentare il boiler. Raggiunta la temperatura di set-point la pompa (EP 13), rappresentata in figura 4.10, si arresta bloccando il flusso d'acqua di alimentazione della serpentina. Il bollitore è alimentato anche durante le ore notturne in modo da effettuare il lavaggio anti-legionella del serbatoio data l'importanza dell'acqua al suo interno utilizzata per usi sanitari.

Dalla tabella ... precedente, è possibile osservare la presenza anche di un quarto serbatoio con una capacità di 1000 [l] utilizzato per la produzione di ACS prodotta dall'impianto solare termico installato in copertura. L'impianto è costituito da tubi in vetro sottovuoto e una superficie captante utile di 30 [m<sup>2</sup>] che permette di produrre circa 13500  $\left[\frac{kWh}{anno}\right]$  con una potenza di 9,87 [kW] [36].

## Terminali di erogazione

Gli impianti precedentemente descritti permettono di produrre acqua calda e refrigerata da inviare ai vari terminali di climatizzazione presenti nei singoli locali dell'edificio. La climatizzazione degli ambienti interni è di fondamentale importanza per raggiungere le condizioni termo-igrometriche di comfort degli occupanti. La norma UNI 10339 definisce i valori di temperatura e umidità relativa da garantire all'interno degli ambienti a seconda della stagione. I valori sono di seguito descritti:

- Condizioni Invernali:  $T_{setpoint} = 20 \pm 2$  [°C]  $U.R. = 50 \pm 5$  %
- Condizioni Estive:  $T_{setpoint} = 26 \pm 2$  [°C]  $U.R. = 50 \pm 5$  %

Il dimensionamento degli impianti di climatizzazione è stato effettuato seguendo le indicazioni presenti nella norma UNI/TS 11300 parte 2-3 a seconda della tipologia di circuito ad acqua e/o ad aria presente all'interno dell'Energy Center.

Per i circuiti ad aria si fa generalmente riferimento alle UTA che hanno il compito di trattare l'aria a seconda delle necessità termo-igrometriche, quali la temperatura, l'umidità, la velocità e la qualità dell'aria, da garantire in ambiente.

L'edificio presenta 5 UTA di cui 3 ad aria primaria, installate in copertura, che contribuiscono al solo controllo della qualità dell'aria ovvero al monitoraggio della  $CO_2$  all'interno dell'ambiente e 2 a tutt'aria, installate nel piano interrato all'interno dei locali tecnici, che permettono il controllo di tutti i parametri termo-igrometrici, precedentemente citati.

I circuiti ad acqua, invece, sono caratterizzati da terminali come i pannelli radianti a soffitto e pavimento, installati nell'atrio di ingresso all'edificio e nei locali uffici a primo, secondo e terzo piano. Le caratteristiche di tali soluzioni impiantistiche adottate sono descritte dettagliatamente di seguito.

### *Impianto a pannelli radianti a soffitto*

L'impianto a pannelli radianti a soffitto è stato installato per riscaldare e condizionare i locali uffici presenti al primo, secondo e terzo piano lato NO (nord-ovest) e lato NE (nord-est). I controsoffitti radianti stagni installati sono costituiti da pannelli modulari piani in lamiera metallica montati su appositi bandraster e presentano le seguenti emissioni:

- Emissione Termica:  $89,7 \left[ \frac{W}{m^2} \right]$
- Emissione Frigorifera:  $91,2 \left[ \frac{W}{m^2} \right]$

I controsoffitti radianti sono alimentati da una rete a due tubi a collettori che presentano sia sulla mandata che sul ritorno le valvole a sfere di intercettazione, le valvole di bilanciamento e delle elettrovalvole che consentono il controllo della condensa e della temperatura in ambiente. Il sistema, in particolare, è costituito da valvole a tre vie utilizzate per miscelare l'acqua regolando la temperatura di mandata la quale non deve raggiungere temperature molto elevate in inverno e molto basse in estate per evitare la formazione di condensa. Ogni ambiente, inoltre, è provvisto di uno o più sensori di temperatura e umidità, a seconda delle dimensioni dell'ambiente, collegati con il sistema

di supervisione della sala di controllo che controlla ininterrottamente tali grandezze al fine di evitare i fenomeni prima descritti.

### *Impianto a pannelli radianti a pavimento*

L'impianto a pannelli radianti a pavimento è utilizzato per riscaldare e raffrescare gli uffici a primo, secondo e terzo piano e l'atrio di ingresso all'edificio. L'impianto, così come quello a soffitto, è del tipo a due tubi ed è stato dimensionato in modo da consentire un'emissione termica di circa  $90 \left[ \frac{W}{m^2} \right]$  a differenza dell'emissione frigorifera che non è possibile valutare con precisione in quanto è molto influenzata dalla quantità di umidità presente in ambiente ma che da alcune stime risulta di circa  $40 \left[ \frac{W}{m^2} \right]$ . La struttura a pannelli radianti a pavimento è stata costruita con tubazioni in multistrato posati a pavimento a serpentina, incorporate in lastre in polistirene espanso ed annegate all'interno del massetto di cemento con l'aggiunta di additivi per aumentare la compattezza del calcestruzzo. Anche in questo caso, ogni locale è dotato di sonde ambiente di temperatura e umidità che collegate al sistema di supervisione permettono di agire sulle valvole a due vie miscelatrici e deviatrici per evitare la formazione di condensa.

I valori di potenza termica e frigorifera e di temperatura dei terminali di erogazione precedentemente descritti sono di seguito osservabili nelle tabelle 3 e 4 in cui sono indicati anche i locali climatizzati:

Tabella 3. Caratteristiche tecniche terminali di erogazione

| <b><i>Impianto</i></b><br><b><i>(ubicazione)</i></b> | <b><i>Locali</i></b><br><b><i>Climatizzati</i></b> | <b><i>Potenza</i></b><br><b><i>Frigorifera [kW]</i></b> | <b><i>Potenza</i></b><br><b><i>Termica [kW]</i></b> |
|------------------------------------------------------|----------------------------------------------------|---------------------------------------------------------|-----------------------------------------------------|
| UTA<br>(Piano Interrato)                             | Auditorium                                         | 55,4                                                    | 50,2                                                |
| UTA<br>(copertura)                                   | Uffici NE<br>P1, P2, P3                            | 31,7                                                    | 32,6                                                |
| UTA<br>(copertura)                                   | Uffici NO<br>P1, P2, P3                            | 121,9                                                   | 217,4                                               |

|                                                |                                                     |             |             |
|------------------------------------------------|-----------------------------------------------------|-------------|-------------|
| <i>UTA</i><br><i>(Piano Interrato)</i>         | <i>Ristorante</i>                                   | <i>45,4</i> | <i>15,9</i> |
| <i>UTA</i><br><i>(Piano Interrato)</i>         | <i>Atrio Ingresso</i>                               | <i>43,5</i> | <i>33,2</i> |
| <i>Pannelli radianti</i><br><i>a soffitto</i>  | <i>Uffici</i><br><i>P1, P2, P3</i>                  | <i>65</i>   | <i>68</i>   |
| <i>Pannelli radianti</i><br><i>a pavimento</i> | <i>Atrio ingresso e</i><br><i>uffici P1, P2, P3</i> | <i>20</i>   | <i>36</i>   |
| <i>Radiatori e</i><br><i>recuperatori</i>      | <i>Servizi</i><br><i>sanitari WC</i>                | <i>-</i>    | <i>96</i>   |
| <i>Split ad</i><br><i>Espansione diretta</i>   | <i>UPS</i><br><i>Sala controllo</i>                 | <i>22</i>   | <i>-</i>    |

Tabella 4. Temperature mandata/ritorno acqua nei terminali di erogazione

| <i>Fluido</i>                      | <i>Impianto</i>                                | <i>Temperatura</i><br><i>Mandata-Ritorno [°C]</i> |
|------------------------------------|------------------------------------------------|---------------------------------------------------|
| <i>Acqua</i><br><i>refrigerata</i> | <i>UTA</i>                                     | <i>7-12</i>                                       |
|                                    | <i>Pannelli radianti</i><br><i>a soffitto</i>  | <i>16-20</i>                                      |
|                                    | <i>Pannelli radianti</i><br><i>a pavimento</i> | <i>14-20</i>                                      |
|                                    | <i>UTA</i>                                     | <i>45-40</i>                                      |
| <i>Acqua</i><br><i>calda</i>       | <i>Pannelli radianti</i><br><i>a soffitto</i>  | <i>35-30</i>                                      |
|                                    | <i>Pannelli radianti</i><br><i>a pavimento</i> | <i>37-31</i>                                      |
|                                    | <i>Radiatori</i>                               | <i>45-40</i>                                      |
|                                    |                                                |                                                   |

#### 4.1.2 Analisi consumi energetici

L'Energy Center possiede un sistema di monitoraggio all'avanguardia che permette di poter quantificare i consumi spesi dalle macchine per la produzione dei vettori energetici

utili a fornire i servizi di riscaldamento, raffrescamento e ACS indispensabili per garantire condizioni di comfort all'interno dei locali.

### Consumi per raffrescamento

Il sistema di monitoraggio prevede una raccolta dei dati misurati su una scala di 15 minuti, i quali, riordinati, hanno permesso di poter sviluppare il grafico visibile in figura 4.11 in cui sono rappresentati i consumi energetici per il raffrescamento durante il periodo estivo del 2021 con riferimento anche all'andamento della temperatura esterna.




Figura 4.11 Grafico consumi energia frigorifera

Il periodo illustrato in figura tende a far risaltare l'elevato consumo energetico riscontrato durante i mesi centrali della stagione estiva quali giugno, luglio e agosto dove si raggiungono punte di circa 2500 [kWh]. In particolare, grazie alla rappresentazione della temperatura è possibile osservare l'elevata dipendenza dei consumi di raffrescamento con la temperatura esterna in quanto all'aumentare di tale variabile aumentano i consumi.

Per poter meglio comprendere il quantitativo di energia utilizzato dall'edificio per poter raffrescare i locali interni durante la stagione estiva è stato rappresentato il grafico seguente, in figura 4.12, che riporta i consumi energetici per raffrescamento a livello mensile.




Figura 4.12 Grafico consumi mensili energia frigorifera

Anche dal grafico in figura 4.12 è possibile osservare il maggior utilizzo del gruppo polivalente durante i mesi centrali del periodo estivo considerato in cui si raggiungono valori di energia di quasi  $5000 \left[ \frac{kWh}{mese} \right]$ , nel mese di luglio, a differenza dei circa  $3000 \left[ \frac{kWh}{mese} \right]$  registrati nel mese di settembre. Tale valore risulta non molto distante dai consumi registrati durante il mese di agosto in quanto, soprattutto durante la prima metà del mese di settembre, si sono riscontrate temperature elevate, come visibile dalla figura precedente.

### Consumi per riscaldamento

Il sistema di monitoraggio registra anche i consumi energetici del Teleriscaldamento per soddisfare il fabbisogno di riscaldamento all'interno dell'edificio. I dati sono riportati graficamente nella figura 4.13.




Figura 4.13 Grafico consumi energia termica

Il periodo di riferimento considerato in figura è imposto dalla Legge 10-1991 che impone, per gli edifici localizzati nella città di Torino (zona climatica E), l'accensione degli impianti di riscaldamento a partire dal 15 ottobre fino al 15 aprile. Il grafico in figura 4.13 presenta, inoltre, anche l'andamento della temperatura esterna al diminuire della quale corrisponde un aumento di energia consumata per il riscaldamento. Il consumo maggiore, infatti, si ha durante i mesi centrali della stagione invernali quali dicembre, gennaio e febbraio dove si raggiungono picchi di consumo di circa  $3300 \left[ \frac{kWh}{giorno} \right]$ . L'andamento dei consumi mensili è rappresentato in modo più dettagliato dal grafico seguente in figura 4.14.




Figura 4.14 Grafico consumi mensili energia termica

Il maggior consumo di energia termica dal teleriscaldamento risulta durante il mese di gennaio in cui si registrano consumi di circa  $55000 \left[ \frac{kWh}{mese} \right]$ , rispetto ai circa  $40000 \left[ \frac{kWh}{mese} \right]$  consumati durante i mesi di dicembre e febbraio.

Per una migliore visualizzazione dei consumi del teleriscaldamento per riscaldare l'edificio è stata rappresentato l'andamento di potenza termica divisa settimanalmente, vedi figura 4.15, del periodo compreso tra il 15 ottobre e il 15 aprile.




Figura 4.15 Grafico andamento settimanale potenza termica

Dalla figura 4.15 è possibile osservare l'andamento settimanale della potenza termica in cui quotidianamente è presente un picco di potenza all'accensione dell'impianto. Tale consumo è dovuto alle basse temperature dell'acqua, raggiunte durante la notte all'interno delle tubazioni, la quale, per raggiungere le temperature richieste dalle utenze, viene riscaldata con una potenza termica maggiore scambiata con il circuito primario del teleriscaldamento, aumentando così i consumi. Per risolvere tale problema potrebbe essere utile l'installazione di un accumulo termico latente con materiali ad assorbimento di fase in modo da ridurre il carico prelevato dalla rete di teleriscaldamento nelle ore di picco. Tale soluzione viene soltanto accennata in tale elaborato in quanto lo studio è stato svolto per analizzare le potenze frigorifere, erogate dal gruppo polivalente durante la stagione estiva, trattate dettagliatamente nel capitolo seguente.



# 5 ANALISI DEI DATI DI POTENZA

## FRIGORIFERA

Nel capitolo seguente sono stati analizzati i dati di monitoraggio energetico relativi alla potenza frigorifera erogata dal gruppo polivalente, durante la stagione estiva, al fine di rilevare informazioni utili, attraverso l'utilizzo di tecniche di *data analytics*, per proporre e attuare azioni di efficientamento energetico all'interno dell'edificio. Inizialmente è stata attuata la fase di pulizia e preparazione del dataset in cui sono stati descritti e rappresentati, attraverso diverse visualizzazioni, i dati di potenza frigorifera evidenziando le prime informazioni del dataset. Le fasi successive hanno invece previsto l'applicazione di tecniche non supervisionate prima e supervisionate dopo per evidenziare rispettivamente le caratteristiche principali del dataset e creare dei modelli di previsione in grado di prevedere i valori di potenza frigorifera prodotti dal gruppo polivalente.

Lo studio è stato sviluppato con l'ausilio del software di programmazione per il calcolo statistico '*Rstudio*'.

### 5.1 Pulizia e preparazione del dataset

Il lavoro seguente è stato effettuato utilizzando il dataset fornito dall'Energy Center di Torino in cui sono presenti i dati di monitoraggio relativi alla potenza frigorifera del gruppo polivalente a servizio dell'edificio, misurati durante la stagione estiva, rispettivamente dal 16/06 al 14/10 degli anni 2019, 2020 e 2021.

L'analisi ha inizialmente previsto il caricamento, sul software di programmazione, del dataset oggetto di studio in cui, per ogni valore del dataset, sono state esplicitate le seguenti caratteristiche:

- data dell'anno comprensiva di orario;
- indicazione relativa alla festività dei giorni considerati;
- valore della potenza frigorifera [*kW*];

In particolare, per una migliore analisi, l'informazione relativa alla data dell'anno è stata divisa andando a visualizzare in modo separato i valori del giorno della settimana, mese, anno e orario, quest'ultimo diviso secondo le ore e i minuti.

Di seguito è mostrato la rappresentazione grafica del dataset:




Figura 5.1 *Diagramma lineare del dataset*

Il dataset, in figura 5.1, rappresenta le potenze frigorifere, relative al gruppo polivalente, registrate tra il 16 giugno e il 14 ottobre del 2019, 2020 e 2021 in modo da considerare il periodo centrale della stagione estiva in cui il fabbisogno di energia frigorifera risulta più elevato.

Per una migliore visualizzazione del dataset, di seguito vengono riportate, separatamente, le precedenti potenze frigorifere in funzione dell'anno di riferimento.




Figura 5.2 *Diagramma lineare dataset 2019*




Figura 5.3 *Diagramma lineare dataset 2020.*




Figura 5.4 *Diagramma lineare dataset 2021*

Da un primo confronto generale è possibile osservare un andamento comune del profilo di potenza frigorifera che presenta una richiesta maggiore nei periodi centrali della stagione con picchi di circa 450 [kW]. Nelle figure 5.2 e 5.3, relative alle potenze frigorifere registrate rispettivamente durante l'anno 2019 e 2020, si notano, durante il periodo di metà agosto, dei valori nulli di potenza dovuti alla chiusura dell'edificio per le vacanze estive di Ferragosto. Tale andamento non è invece presente per il periodo estivo dell'anno 2021, visibile in figura 5.4.

La presenza di valori di potenza frigorifera più elevati durante i mesi di luglio, agosto e settembre è visibile in maniera più dettagliata nelle figure seguenti, in cui i tre dataset, differenziati a seconda dell'anno, sono stati rappresentati con la divisione mensile.




Figura 5.5 *Rappresentazione mensile dataset 2019*




Figura 5.6 *Rappresentazione mensile dataset 2020*




Figura 5.7 *Rappresentazione mensile dataset 2021*

Dalla rappresentazione del dataset a seconda dei mesi della stagione estiva si osserva un andamento più elevato della potenza frigorifera durante i mesi centrali con picchi di circa 400 [kW] registrati soprattutto durante il mese di agosto. D'altro canto, è possibile evidenziare dei valori molto più bassi durante i mesi di giugno e ottobre dove i picchi raggiungono valori di circa 250 – 300 [kW] ad eccezione di alcuni giorni in cui si registrano anche potenze di 350 [kW] sicuramente dovute ad eventi tenuti in edificio o a situazioni climatiche particolari.

Per una visualizzazione ancor più dettagliata è stata diviso il dataset in settimane come visibile nelle seguenti figure:




Figura 5.8 *Rappresentazione settimanale dataset 2021*






Figura 5.9 Rappresentazione settimanale 2020




Figura 5.10 Rappresentazione settimanale 2021

Da queste visualizzazioni è possibile notare come le potenze frigorifere rispecchiano il profilo di occupazione dell'edificio, in quanto durante i giorni feriali le potenze oscillano mediamente intorno a valori di 150 – 200 [kW], a differenza del fine settimana (giorni di sabato e domenica) in cui si registrano potenze nulle, dato lo spegnimento degli impianti, ad eccezione di qualche fine settimana.

Attraverso la rappresentazione settimanale del dataset, inoltre, è possibile osservare la presenza frequente di picchi di potenza nei giorni di inizio settimana rispetto ai restanti giorni, in cui, ad eccezione di qualche settimana (settimana 28 e 32 figura 5.8, 30 e 34 figura 5.9, 26 e 38 figura 5.10), sono del tutto assenti.

In particolare, la presenza di valori di potenza più elevati ad inizio settimana è dovuto all'elevato carico termico dell'edificio che durante il fine settimana, dato lo spegnimento degli impianti, tende ad accumulare potenza termica dall'esterno. Per tali ragioni, per poter raggiungere il valore di set point all'interno dei locali climatizzati, il gruppo polivalente, non appena acceso, raggiunge picchi di potenza fino a valori di 450 [kW] in modo da raggiungere le condizioni di comfort prima dell'arrivo dei dipendenti all'interno dell'edificio, previsto per le ore 9.00. Ulteriore verifica di tale fenomeno è visibile durante le settimane '34' delle figure 5.8 e 5.9 in cui si evidenzia il valore di picco maggiore di tutto il dataset in corrispondenza del lunedì successivo alle vacanze estive di Ferragosto. In tale periodo, infatti, essendo nel periodo centrale della stagione, le condizioni climatiche esterne, visibili anche dai grafici seguenti relativi all'andamento di temperatura e radiazione solare, aumentano il carico termico dell'edificio che, per raggiungere le condizioni di comfort, deve necessariamente aumentare la potenza dell'impianto di raffrescamento.




Figura 5.11 *Diagramma lineare temperatura e radiazione solare 2019*




Figura 5.12 *Diagramma lineare temperatura e radiazione solare 2020*




Figura 5.13 *Diagramma lineare temperatura e radiazione solare 2021*

Le variabili meteo quali la temperatura e la radiazione solare riferite alle tre stagioni estive rispettivamente del 2019 (figura 5.11), 2020 (figura 5.12), 2021 (figura 5.13), presenti nel dataset permettono di spiegare i profili di potenza frigorifera precedentemente mostrati. Infatti, durante il mese d'agosto si notano picchi di temperatura elevati con valori di circa  $32\text{ }^{\circ}\text{C}$  in corrispondenza di valori, altrettanto elevati, della radiazione solare con picchi di  $900\left[\frac{\text{W}}{\text{m}^2}\right]$ .



Il dataset, in seguito, è stato rappresentato anche attraverso il *carpet plot* a secondo dell'anno di riferimento. I risultati sono visibili nelle seguenti figure in cui è possibile notare l'andamento della potenza frigorifera, diversa a seconda del colore, in funzione dei giorni compresi nei periodi di riferimento precedentemente esplicitati.




Figura 5.14 *Carpet plot* 2019 e 2020




Figura 5.15 *Carpet plot* 2021

Dai *carpet plot* precedenti è possibile osservare l'andamento giornaliero della potenza frigorifera che mostra dei consumi nulli fino alle ore 8.00 circa, orario di accensione dell'impianto, un picco iniziale fino alle ore 9.00, orario di apertura degli uffici, e un periodo di stabilità dei valori intorno a 150 [kW] fino alle ore 22.00 circa, orario di spegnimento del gruppo polivalente. I valori di potenza frigorifera più elevati, registrati durante le prime ore della mattina, presentano valori di circa 300 [kW] con dei picchi, rappresentati con rettangoli rossi e arancioni, di circa 350 [kW] registrati in corrispondenza dei primi giorni settimanali, come spiegato in precedenza.

Ulteriori andamenti, che è possibile notare, sono riferiti ai giorni feriali del giovedì e del venerdì in cui solitamente non si registrano, diversamente dagli altri giorni feriali, valori di potenza più elevati al mattino, durante l'accensione, in quanto l'edificio ha ormai smaltito l'apporto termico dovuto allo spegnimento dell'impianto durante il fine settimana. Per tale motivo, infatti, l'andamento della potenza durante questi giorni risulta circa costante con valori di 150 – 200 [kW]. Per quanto riguarda invece i giorni del fine settimana, quali il sabato e la domenica, nel *carpet plot*, presentano dei valori continui di colore blu che corrispondono al valore nullo di potenza poiché, in tali giorni, l'impianto risulta spento data la destinazione d'uso dell'edificio.

Ultima considerazione utile che è possibile effettuare dai *carpet plot* è la presenza di spazi bianchi che indica l'assenza di valori. In particolare, da esperto di dominio, è stato scelto, in seguito alla precedente rappresentazione grafica, di eliminare dal dataset i giorni della domenica e i giorni festivi che presentano una potenza nulla costante. Tale decisione è stata presa in considerazione dell'analisi di *clustering*, che sarà successivamente effettuata, dove la presenza di valori nulli reca problemi all'algoritmo di clusterizzazione.

La fase di preparazione e pulizia del dataset, nel caso oggetto di studio, ha evidenziato le problematiche della presenza sia di dati mancanti (*missing data*) che di inconsistenze (*outlier*), entrambe risolte con la tecnica l'interpolazione lineare in quanto verificate sono in pochi punti all'interno del dataset.

La fase di pulizia e preparazione del dataset è inoltre stata condotta anche per le variabili meteorologiche utilizzate nell'analisi, quali la temperatura esterna e la radiazione solare, rappresentati graficamente in precedenza. I valori di tali variabili sono stati prelevati, in

formato orario e completamente validati, dal sito dell'ARPA PIEMONTE'. Per questo motivo la fase di processamento di dati non ha individuato nessun valore mancante e nessun valore anomalo.

## 5.2 Cluster analysis

Fase successiva della preparazione e pulizia dei dati, relativi alle variabili climatiche e alle potenze frigorifere del gruppo polivalente a servizio dell'edificio Energy Center, è stata l'applicazione di tecniche di apprendimento non supervisionato. In particolare, il metodo utilizzato è stata la *cluster analysis* che permette l'individuazione dei profili tipologici presenti all'interno del dataset.

Tra i diversi algoritmi di *clustering* è stata utilizzata la tipologia del *clustering gerarchico* che, a differenza delle altre due tipologie di *clustering*, considera il dataset come un unico *cluster* globale diviso in seguito in cluster più piccoli ad esso connessi. Sempre attraverso l'utilizzo del software di programmazione *Rstudio* è stato scritto il codice che ha permesso di effettuare l'analisi di *clustering* seguente.

In particolare, è stata inizialmente definita la matrice  $M \times N$  dove  $M$  rappresenta le righe del dataset, in cui sono presenti le date dei giorni considerati, mentre  $N$  rappresenta le colonne in cui sono presenti le ore del giorno. In seguito, è stata realizzata la matrice delle distanze aggiornata ad ogni iterazione dell'algoritmo per poter fondere i *cluster* più vicini fino ad ottenerne uno unico.

Per effettuare l'analisi di *cluster* sono stati utilizzati tre iperparametri principali quali la distanza, il metodo di collegamento e il tipo di normalizzazione. In particolare, i metodi usati per unire i *cluster* sono stati quattro quali: *single*, *complete*, *average* e *ward.D2*, mentre per le normalizzazioni sono state utilizzate la normalizzazione sul massimo e la normalizzazione massimo-minimo e infine come distanze sono state considerate la distanza Euclidea e la distanza di Manhattan.

Attraverso l'implementazione di tutte le combinazioni possibili, contenti una tipologia di ciascun iperparametro, è stata effettuata la migliore configurazione.

La scelta è stata effettuato in diversi step. In particolare, tramite l'utilizzo di '*Rstudio*' è stato possibile implementare e rappresentare i dendogrammi tagliati in modo da ottenere

un numero di *cluster* diverso a seconda del valore dell'iperparametro *k*. Tale valore è stabilito secondo il criterio della *Majority Rule* che determina il numero di partizioni concorde per la maggioranza delle metriche implementate sul software.

In particolare, ad ogni step sono state eliminate le configurazioni meno rappresentative giungendo così all'ultimo step con la configurazione migliore.

Nel primo step, dopo avere rappresentato i dendogrammi di tutte le configurazioni possibili, è stato deciso di non considerare le configurazioni che prevedono l'utilizzo del metodo di collegamento *single linkage* in quanto presentano partizioni non eque dei *cluster* individuati, come visibile in figura 5.17. Tale risultato era prevedibile, in quanto il metodo del *single linkage* è particolarmente suscettibile alla presenza di *outlier*, ovvero valori errati presenti nel dataset. Infatti, tale metodo di collegamento, è maggiormente utilizzato per operare la tecnica di *outlier detection* in quanto tende a lasciare isolati oggetti fino al termine dell'algoritmo.




Figura 5.17 Dendrogramma con normalizzazione sul max; metodo: single; distanza: Euclidea




Figura 5.16 Dendrogramma con normalizzazione nessuna; metodo: complete; distanza: Manhattan

In figura 5.17, di fianco al dendrogramma con metodo *single linkage*, è presente anche quello con metodo di collegamento *complete* e distanza di Manhattan. In tale step, infatti, sono state eliminate anche le configurazioni effettuate con distanza Euclidea e metodo di collegamento *average* con entrambe le normalizzazioni. Tali configurazioni, concordemente alle configurazioni precedenti con metodo di collegamento *single linkage*, presentano una divisione non equa dei *cluster*.

Nel secondo step, invece, con il punto di vista di esperto del dominio, sono state eliminate le configurazioni che presentano un numero di partizioni maggiore di 4, valore considerato opportuno per l'analisi oggetto di studio in quanto riferita al solo periodo estivo comprendente circa 4 mensilità. In particolare, in questo step non sono state considerate le configurazioni ottenute con la distanza di Manhattan con il metodo di collegamento *complete*, con normalizzazione minimo-massimo, e ward.D2, senza normalizzazione con distanza Euclidea. Un esempio è riportato in figura 5.19, in cui il dendrogramma presenta 5 *cluster* differenti.




Figura 5.18 Dendrogramma con normalizzazione sul max-min; metodo:complete; distanza: Manhattan

Per quanto riguarda le restanti configurazioni, sono stati rappresentati i profili di carico con evidenza dei profili centroidi, con i profili minimi e massimi normalizzati e la deviazione standard. Attraverso queste visualizzazioni è stato possibile, nel terzo step, andare ad eliminare le configurazioni che presentano delle rappresentazioni dei profili di carico con andamenti simili.

In particolare, di seguito è mostrato il confronto tra il grafico con metodo di collegamento *complete linkage*, senza normalizzazione e distanza Euclidea e il grafico in figura 5.20, sviluppato con metodo *complete*, distanza di Manhattan e senza normalizzazione.




Figura 5.20 Metodo: *complete*; distanza: Euclidea; no normalizzazione




Figura 5.19 Metodo: *complete*; distanza: Manhattan; no

Dal confronto dei due grafici risulta abbastanza evidente la maggior chiarezza del grafico in figura 5.20 in quanto identifica un *cluster* in più e senza evidenziare alcun andamento simile tra i 4. La figura 5.19 presenta invece andamenti circa simili soprattutto tra il cluster 2 e cluster 3 in cui, anche i periodi temporali dei picchi, coincidono. Per tali ragioni non è stata considerata la rappresentazione in tale figura. Per le stesse ragioni non sono state considerate anche le configurazioni che mostrano profili simili a quello in figura 5.19, in particolare quelle con metodo *ward.D2*, distanza di Manhattan con e senza normalizzazione sul massimo.

Infine, l'ultimo step ha permesso di identificare la configurazione migliore in base al profilo che meglio esplicita le caratteristiche del dataset. In particolare, il confronto è stato effettuato tra l'andamento di potenza mostrato in figura 5.22 e la configurazione in figura 5.21 riguardante il precedente profilo centroide.




Figura 5.22 Metodo: complete; distanza: Manhattan; normalizzazione sul max




Figura 5.21 Metodo: complete; distanza: Euclidea; no normalizzazione

Dal confronto è possibile notare, così come nello step precedente, che le configurazioni non presentano lo stesso numero di *cluster*. La figura 5.21 presenta un *cluster* in più, in particolare il *cluster* numero 3 che permette di identificare i primi giorni della settimana in cui l'elevato carico termico, dovuto allo spegnimento degli impianti durante il fine settimana, porta il gruppo polivalente, appena attivata, a lavorare con potenze elevatissime in modo da portare l'edificio in condizioni di comfort prima dell'arrivo degli occupanti. Tale caratteristica risulta di fondamentale importanza per poter effettuare un'ottima caratterizzazione del dataset per cui non può essere trascurata nella scelta migliore della divisione in *cluster*.

La scelta della configurazione più adatta alla descrizione del dataset risulta per queste ragioni quella caratterizzata dalla distanza Euclidea, senza alcuna normalizzazione e con metodo di collegamento *complete*.

Per tale configurazione è stato rappresentato l'albero di classificazione visibile nella figura seguente:






Figura 5.23 Albero di clusterizzazione scelta migliore

L'albero di classificazione in figura presenta, in particolare, 7 nodi decisionali e 8 nodi fogli. La variabile principale (nodo radice) risulta quella relativa alla variabile del giorno della settimana che permette di differenziare il diverso profilo di potenza frigorifera registrato durante il sabato, in cui gli impianti vengono accessi per metà giornata, da quello relativo ai restanti giorni feriali dal lunedì al venerdì.

Mettendo a confronto i grafici delle figure 5.21 e 5.23 , relative alla configurazione scelta come migliore, è possibile comprendere parte della logica utilizzata dall'algoritmo per etichettare i vari profili tipologici individuati dal dataset. In particolare, è possibile notare come gli splittaggi dovuti alla variabile temperatura media e radiazione solare abbiano fatto emergere la classe di appartenenza dei giorni di ritorno dalle vacanze estive di Ferragosto e dei primi giorni della settimana in cui il profilo di potenza presenta dei picchi all'accensione. L'albero, infatti, conferma le motivazioni precedentemente date riguardo la presenza di potenze elevate in tali periodi visibili anche nel profilo centroide in figura 5.21 nel *cluster* numero 3.



Attraverso l'utilizzo del software è stato possibile, inoltre, calcolare la *confusion matrix* attraverso cui è possibile valutare le prestazioni dell'albero di classificazione precedentemente rappresentato.

Nella tabella 5 sono raffigurate la *confusion matrix* e le metriche utilizzate per la valutazione quali la precisione (*precision*) e il richiamo (*recall*):

Tabella 5. *Confusion matrix e metriche di valutazione*

| <i>y_pred</i> |     |   |    |    |           |          |
|---------------|-----|---|----|----|-----------|----------|
| <i>y_true</i> | 1   | 2 | 3  | 4  | Precision | 88,9 [%] |
| 1             | 104 | 2 | 6  | 15 | Recall    | 81,9 [%] |
| 2             | 0   | 6 | 26 | 8  |           |          |
| 3             | 1   | 1 | 44 | 13 |           |          |
| 4             | 12  | 1 | 14 | 42 |           |          |

Lo studio appena effettuato è stato in seguito utilizzato per poter predire la potenza frigorifera a seconda del tipo di *cluster*, attraverso l'utilizzo di un modello a rete neurale e di uno effettuato con l'albero di regressione, entrambi analizzati in modo dettagliato di seguito.

## 5.3 Utilizzo di tecniche supervisionate per la creazione di modelli previsionali

L'obiettivo di tale paragrafo è quello di creare dei modelli previsionali attraverso l'utilizzo di tecniche supervisionate di *data analytics*. Tali tecniche permettono di creare un modello di stima in grado di descrivere la relazione funzionale tra variabili di input e di output. Quest'ultima è l'analisi effettuata nel seguente paragrafo, per cui lo scopo consiste nel creare modelli previsionali che riescano a predire, in funzione di variabili di input, la potenza frigorifera di un edificio, che nel caso specifico è l'Energy Center di

Torino. Tali modelli, realizzati tramite un approccio supervisionato, una volta allenati e testati, possono essere utilizzati con due scopi diversi, in funzione delle variabili fornite in input al modello durante la sua creazione.

In particolare, se lo scopo è quello di predire come dovrebbe consumare energia l'edificio, il modello è definito di *benchmark*, se, invece, il modello è realizzato per predire come consumerà in una o più ore successive, allora è definito di *forecast*. Entrambi gli approcci sono stati descritti nel seguente paragrafo, in cui ci si avvale dell'utilizzo di modelli supervisionati, come gli alberi di regressioni e le reti neurali artificiali.

Dovendo creare dei modelli previsionali, secondo un approccio supervisionato, il dataset è stato suddiviso in due parti:

- *Training set*
- *Testing set*

Tale suddivisione è stata prevista in modo tale da avere in entrambi i dataset lo stesso periodo di riferimento, ovvero quello della stagione estiva dal 16 giugno al 14 ottobre.

In particolare, il primo dataset verrà utilizzato per allenare il modello, il quale una volta creato, sfrutterà i valori del secondo set di dati, a lui sconosciuto, per valutarne le performance e verificare che sia o meno un modello robusto, capace di prevedere al meglio la potenza frigorifera futura.

Entrambi i dataset sono stati sottoposti alla fase di *data pre-processing* in modo da ripulirli da eventuali inconsistenze e valori mancanti così come fatto precedentemente per l'analisi di *clustering*. Data l'uguaglianza delle tecniche utilizzate in questa fase con quelle utilizzate nel paragrafo precedente, per non risultare ridondanti nella trattazione, è stato deciso di riportare soltanto i risultati finali dei due dataset osservabili in figura 5.24 e 5.25.




Figura 5.24 Training set




Figura 5.25 Testing set

### 5.3.1 Modello di benchmark

In tale paragrafo verranno utilizzate alcune tecniche supervisionate per creare un modello di *benchmark* basato sui due dataset precedentemente definiti. In particolare, l'analisi di previsione della potenza frigorifera, per l'edificio oggetto di studio, è stata effettuata

tramite l'utilizzo sia dell'albero di regressione che della rete neurale, tratti in modo dettagliato nei prossimi paragrafi.

Per entrambe le tecniche i due *dataframe* sono stati inizialmente ridotti da una frequenza di 15 minuti ad una scala oraria, tramite un metodo di riduzione definito *Piecewise Aggregate Approximation* (PAA). Per la costruzione di modelli previsionali, infatti, risulta più efficiente l'utilizzo di un livello di dettaglio basato su scala oraria, anziché uno più dettagliato, in termini soprattutto di costo computazionale.

### *Albero di regressione*

L'albero di regressione è un processo statistico predittivo, che ha lo scopo di predire una variabile continua, ossia, nel caso specifico, la potenza frigorifera.

Essendo un modello di apprendimento supervisionato, viene allenato sul *training set*, avendo come input una serie di variabili forzanti ed influenzanti la potenza frigorifera, la quale rappresenta la variabile da predire e quindi l'output del modello.

Tale metodo è di facile interpretazione, in quanto stabilisce la relazione tra i vari input e output secondo delle semplici regole *IF-THEN*, seguendo un approccio ricorsivo: ad ogni livello di decisione l'algoritmo cerca di ottenere il massimo miglioramento di accuratezza del modello.

Se non si imponessero dei limiti a tale algoritmo, però, si potrebbe incorrere nel problema dell'*overfitting*, per cui il modello risulterebbe molto ben allenato sui dati del *training set* risultando accurato solo con quel set di valori.

A tal proposito, nella costruzione dell'algoritmo predittivo sono stati inseriti due parametri di controllo che limitano la profondità dell'albero (*maxdepth*) ed il numero nodi foglia (*minbucket*), i quali permettono la visualizzazione dell'output del modello tramite un *boxplot*, in cui la mediana rappresenta il valore di consumo predetto dall'algoritmo.

Step fondamentale risulta la scelta del giusto set di variabili da inputare al modello, per far sì che esso riesca al meglio a mimare il fenomeno. Per far ciò con il punto di vista di esperto del dominio, sono state definite le prime variabili da considerare, in grado di influenzare la potenza frigorifera. Dovendo analizzare il periodo estivo comprendente le

mensilità da giugno ad ottobre, le variabili considerate sono state la temperatura dell'aria esterna e la radiazione solare.

È possibile così caratterizzare il primo albero di regressione rappresentato di seguito in figura 5.26.




Figura 5.26 Albero di regressione dataset

Il primo split dell'albero di regressione, in figura 5.26, rappresenta la variabile che influenza maggiormente la potenza frigorifera, che in questo caso risulta essere la temperatura esterna.

Per poter valutare le prestazioni dell'albero di regressione risulta necessario il confronto tra gli andamenti della potenza frigorifera stimata e quelli reali, sia nel caso del *training set* che nel caso del *testing set*. Tale confronto è osservabili nelle figure 5.27 e 5.28, di seguito riportate:




Figura 5.27 Modello di stima del training set




Figura 5.28 Modello di stima del testing set

Osservando la figura 5.27 e la figura 5.28, è possibile notare come le variabili climatiche utilizzate come input non riescano bene a stimare l'andamento della potenza frigorifera reale rappresentato dalla curva nera nelle figure precedenti.

Per tale ragione, risulta utile aggiungere altre variabili in grado di influenzare la potenza frigorifera nel modello di previsione così da renderlo più efficiente nella stima delle potenze. In particolare, le variabili aggiunte, nell'albero di regressione seguente rappresentato in figura 5.26, sono quelle dei giorni settimanali, variabile indicata come "DayOfWeek" e dell'ora del giorno, indicata come "Hour". L'aggiunta di tali variabili ha

permesso di differenziare le potenze registrate nei primi giorni settimanali e durante le prime ore di accensione, in cui risultano potenze maggiori, dai giorni di fine settimana o delle ultime ore della giornata in cui si registrano valori di potenza molto bassi.




Figura 5.29 Albero di regressione con variabili esogene aggiuntive

Osservando l'albero in figura 5.29, si nota che la variabile che influenza maggiormente il modello non è più la temperatura esterna, come visibile in figura 5.26, ma è l'ora del giorno che differenzia le potenze registrate durante la notte, con valori nulli dato lo spegnimento dell'impianto, dai valori giornalieri molto più elevati.

Le variabili aggiunte, inoltre, hanno permesso di associare al giorno settimanale del sabato, indicato con il numero '7', durante le ore pomeridiane, una potenza nulla, visibile dal nodo 13 in figura 5.29, in quanto in tale giorno l'edificio risulta occupato soltanto per metà giornata, motivo per cui l'impianto viene spento.

Per valutare, anche in questo caso, la performance di tale modello è utile rappresentare il confronto tra i profili di potenza stimati, di colore rosso, e i profili reali, colore nero. Tale confronto è visibile nelle figure seguenti:




Figura 5.30. Modello di stima del training set con variabili aggiunti




Figura 5.31. Modello di stima del testing set con variabili aggiuntive

Osservando le figure 5.30 e 5.31, si nota subito come tale modello abbia predetto la potenza frigorifera in modo più accurato rispetto al precedente (vedi figura 5.27 e 5.28), riuscendo a seguire molto meglio l'andamento della potenza reale, rappresentato dalla curva nera nelle figure.



Tale modello, appena allenato e testato, rappresenta un discreto modello di *benchmark*, in quanto le uniche variabili inputate all'algoritmo sono state variabili esogene, per cui il modello ottenuto non è influenzato dai dati storici di consumo alle ore precedenti.

### *Rete neurale artificiale*

Il modello a rete neurale, a differenza dell'albero di regressione, riesce meglio a descrivere relazioni non lineari presenti nei dati, per cui ci si aspetta che la predizione sia più accurata, in quanto la potenza frigorifera all'interno dell'edificio non varia linearmente in funzione delle variabili forzanti.

La prima operazione necessaria da effettuare al dataset è la normalizzazione delle variabili. In particolare, la potenza frigorifera essendo una variabile strettamente positiva, è stata normalizzata sul valore massimo così come per la radiazione solare, mentre la temperatura esterna è stata invece normalizzata secondo l'approccio minimo-massimo di seguito mostrato:

$$y = \frac{y - \min(y)}{\max(y) - \min(y)}$$

Anche in questo caso il dataset considerato risulta suddiviso in *training set*, che comprende i valori di potenza registrati durante il periodo estivo del 2019 e del 2020, e in *testing set* che contiene le potenze misurate durante l'ultimo periodo estivo ovvero del 2021.

In particolare, al modello sono stati forniti in input, sottoforma di matrici, le variabili esogene della temperatura esterna, della radiazione solare, dell'ora del giorno e del giorno settimanale.

Una volta compilato, il modello è stato allenato sui dati forniti in input, facendogli osservare il dataset 100 volte, valore inputato nell'algoritmo come numero di epoche, per poter attuare un processo di *back propagation*, il quale consiste nel rimandare la derivata dell'errore (differenza tra output stimato e output reale) indietro e poter aggiustare i pesi, rappresentati dai parametri "w" e "b" osservabili in figura 3.12.

In seguito, sono stati effettuati diversi tentativi di configurazione con il fine di determinare quello più ottimale, variando il numero di *layer* e il numero di neuroni. La

configurazione migliore è risultata la rete neurale con numero di *layer* pari a 3 e numero di neuroni pari a 300. L'andamento delle metriche utilizzate per valutare la performance della rete neurale con le caratteristiche precedentemente citate, sono riportate in figura 5.32.




Figura 5.32 Andamento metriche MSE MAE e MAPE

Dalla figura 5.32 è possibile osservare l'andamento del MAPE (*Mean Absolute Percentage Error*), che permette di valutare l'accuratezza del modello, con valori elevatissimi tali da non poter essere presi in considerazione. Tali valori sono dovuti alla presenza di dati di potenza frigorifera nulli, soprattutto durante le ore notturne o durante i periodi di vacanza, che portano il valore del MAPE, calcolato come rapporto tra l'errore assoluto a ciascun istante e la domanda rispettiva di potenza, a valori non considerabili per misurare l'accuratezza del modello.

Per comprendere appieno la performance di tale modello risulta utile, come fatto in precedenza con l'albero di regressione, riportare il confronto tra l'andamento della potenza predetta e l'andamento di quella reale. Tale confronto è osservabile nelle figure seguenti:




Figura 5.33 *Modello di stima del training set con rete neurale*




Figura 5.34 *Modello di stima del testing set con rete neurale*

Osservando la figura 5.33 e la figura 5.34, si riesce a percepire, anche da non esperto del dominio, l'accuratezza maggiore e la differenza sostanziale rispetto al modello supervisionato ad albero del paragrafo precedente (vedi figura 5.30 e 5.31).

La rete neurale, infatti, riuscendo a cogliere le non linearità tra la variabile di output e le variabili di input, riesce bene nella predizione dei valori di potenza frigorifera.

### 5.3.2 Modello di forecast

La previsione della potenza può anche essere effettuata con lo scopo di conoscere come consumerà l'edificio nel futuro, in tal caso si parla di *forecast*.

In tale paragrafo verrà utilizzato un modello a rete neurale che, come nel caso precedente, sarà allenato sugli stessi dataset di *training set* e *testing set* per predire il valore di potenza frigorifera, erogata dal gruppo polivalente, ma con la differenza di utilizzare come variabili di input soltanto i valori di potenza precedenti all'istante di predizione.

Lo studio ha inizialmente previsto la creazione di un modello di previsione della potenza frigorifera attraverso l'utilizzo di una rete neurale, i cui valori di input sono stati i valori di potenza alle quattro ore precedenti l'istante di predizione. Lo scopo, a tal proposito, è stata la predizione dei valori di potenza frigorifera di 1 step in avanti, ovvero di 1 ora. Per rendere più chiaro il concetto è possibile osservare la figura 5.35 seguente, in cui è rappresentato graficamente il processo precedentemente esposto.




Figura 5.35 *Forecasting di 1 step in avanti*

In particolare, partendo dai dataset precedenti, sono state create quattro nuove colonne contenenti la potenza frigorifera delle 4 ore precedenti all'istante di predizione. La rete è stata inoltre compilata in modo che l'ultimo *layer* fornisca un solo output, in quanto la predizione è di un'ora avanti. La configurazione migliore utilizzata tra le combinazioni possibili variando il numero di *layer* e il numero di neuroni è risultata quella con 3 *layer* e 300 neuroni da cui si ottengono gli andamenti riportati in figura 5.36 e 5.37.




Figura 5.36 *Modello di stima del training set con rete neurale*




Figura 5.37 *Modello di stima del testing set con rete neurale*

Osservando la predizione del modello con in input i valori delle variabili del *testing set*, sconosciute alla rete, essa riesce a stimare la potenza frigorifera del gruppo polivalente installato nell'edificio, con una buona accuratezza anche se non ottimale. Ciò si può notare dalla figura 5.37, in cui l'andamento di potenza predetta (curva rossa) è quasi sovrapposto, soprattutto per valori più bassi di potenza, all'andamento della potenza reale (curva nera).

Per valutare la performance di tale modello sono state utilizzate le stesse metriche precedenti con la sola eccezione del MAPE che non è stato considerato in quanto riporta valori non opportuni per la validazione a causa dei valori nulli di potenza presenti nei due dataset.




Figura 5.38 Andamento delle metriche di valutazione della performance

Sono state condotte, in seguito, altre prove per l'identificazione di un modello di previsione della potenza frigorifera sempre attraverso l'utilizzo di una rete neurale ma utilizzando valori di potenza a diverse ore precedenti l'istante di predizione.

In particolare, le prove sono state effettuate dando in input alla rete valori di potenza rispettivamente a 6, 8, 12 e 24 ore precedenti l'istante di predizione. Le configurazioni che meglio hanno permesso di ottenere valori di potenza frigorifera predetta più vicini ai valori di potenza reale risultano quelle con in input valori di potenza a 12 e 24 ore precedenti la predizione. Gli andamenti di tali configurazioni sono di seguito rappresentati:




Figura 5.39 Modello di stima del training set con rete neurale (input 12 ore)




Figura 5.40 Modello di stima del testing set con rete neurale (input 12 ore)






Figura 5.41 Modello di stima del training set con rete neurale (input 24 ore)




Figura 5.42 Modello di stima del testing set con rete neurale (input 24 ore)

Dagli andamenti in figura è possibile notare come la rete neurale riesca in entrambi i casi a stimare la potenza frigorifera nel *Training set* (vedi figure 5.39 e 5.41) in modo accurato tanto che l'andamento di potenza predetta (curva rossa) tende ad essere sovrapposto quasi del tutto all'andamento della potenza reale (curva nera). Differenza invece più evidente tra i due andamenti è in entrambi i casi visibile nel *Testing set* in cui le potenze predette si discostano maggiormente da quelle reali.



Tra le due configurazioni rappresentate è stata scelta quella che presenta come input i valori di potenza predetti alle 12 ore precedenti l'istante di predizione. Tale scelta è stata effettuata considerando le metriche di performance quali il MAE e l'MSE. In particolare, i valori di tali metriche risultano più simili, tra il *training set* e il *testing set*, per la configurazione scelta, a differenza dell'altra che presenta valori di metriche differenti di circa un ordine di grandezza in favore del *training set*. Per tali ragioni, come è anche visibile dagli andamenti sopra riportati, è possibile considerare quest'ultima configurazione come tendente al fenomeno dell'*overfitting* in quanto riporta valori quasi del tutto coincidenti per il set di allenamento e valori molto più discordanti nel set di test.

Decidere di utilizzare lo storico delle potenze alle ore precedenti come input del modello di previsione può portare però ad una minore precisione di stima. Tale problema risulta più frequente qualora si faccia riferimento a potenze di un intervallo di ore precedenti molto ampio, come nei due casi discussi in precedenza. Considerare valori di potenza riferiti al giorno precedente potrebbe infatti portare a previsioni errate in quanto, ad esempio, il profilo di potenza risulta molto differente soprattutto dai giorni di fine settimana, come il sabato in cui il gruppo polivalente viene acceso soltanto per metà giornata, ai giorni di inizio settimana come il lunedì in cui durante le prime ore di funzionamento la potenza raggiunge valori di picco.

Per risolvere questa problematica si è pensato di dividere in sotto dataset più piccoli il dataset di partenza. In particolare, tale divisione è stata effettuata considerando la precedente analisi di *clustering* che ha permesso l'identificazione di 4 profili tipologici, ovvero quattro sotto dataset, che è possibile utilizzare in maniera singola, per effettuare l'analisi di *forecasting*, al fine di prevedere le potenze frigorifere future erogate dalla pompa di calore dell'edificio oggetto di studio.

### 5.3.3 Modelli di forecast per ciascun cluster

L'analisi di *clustering* precedente è stata utilizzata in tale paragrafo come punto di partenza per effettuare l'analisi di *forecasting*, tratta in precedenza, ma con la differenza di creare quattro modelli differenti di previsione a seconda dei *cluster*. In tale modo, ogni modello utilizzerà, come variabili di input, la potenza alle ore precedenti dei giorni con un profilo di potenza frigorifera identico così che l'output di previsione risulti più preciso.

Di seguito verrà descritta l'analisi di *forecasting* effettuata per ognuno dei quattro *cluster* precedentemente individuati.

In particolare, per poter effettuare l'analisi di *forecasting* i dataset, relativi a ciascun *cluster*, sono stati ulteriormente divisi considerando un *training set* contenente il 70% del dataset dell'intero *cluster* e un *testing set* contenente il corrispettivo 30% restante. Entrambe le partizioni, inoltre, sono state processate con la fase di pulizia in particolare dai valori di *outlier* presenti nei singoli intervalli.

### *Analisi di forecast cluster 1*

Il *cluster 1*, identificato nel paragrafo (inserire numero paragrafo cluster), permette di descrivere il profilo dei giorni settimanali come il sabato che presenta un profilo di potenza frigorifera che registra valori, non nulli, solo per metà giornata, in quanto l'edificio risulta generalmente chiuso durante il pomeriggio. Tale andamento, come osservabile dall'albero di classificazione in figura 5.23, caratterizza anche i giorni settimanali in cui la temperatura esterna risulta piuttosto bassa, in particolare, con valori di temperatura minima al di sotto di 12 [°C] circa.

L'analisi di *forecasting*, applicata a tale partizione del dataset, permetterà di identificare un modello di previsione della potenza frigorifera associata ai giorni settimanali, soprattutto relativo al giorno settimanale del sabato per le motivazioni esplicitate precedentemente.

L'analisi di previsione è stata svolta, così come fatto in precedenza con l'intero dataset, fornendo diversi valori, in input, di potenza alle ore precedenti l'istante di predizione, in particolare con 4, 6, 8, 12 e 24 ore. Di seguito è stata riportata la configurazione più efficiente con la relativa rappresentazione dei profili di potenza reale e predetta.




Figura 5.43 Modello di stima del training set con rete neurale (input 24 ore)




Figura 5.44 Modello di stima del testing set con rete neurale (input 24 ore)

La configurazione rappresentate nelle figure precedenti è stata effettuata fornendo, in input al modello, i valori delle potenze relativi alle 24 ore precedenti l'istante di predizione risultando la configurazione migliore in termini di previsione.

Tale risultato è bene evidente nelle figure 5.43 e 5.44 in cui il profilo di potenza predette (curva rossa) risulta coincidente, per molti valori, al profilo di potenza reale (curva nera). Testimonianza di tale performance è osservabile dall'andamento delle metriche, utilizzate per valutare l'efficacia del modello, di seguito riportato:




Figura 5.45 Andamento metriche di performance MSE e MAE

In particolare, i valori medi di entrambe le metriche risultano rispettivamente:

- *training set*:  $MSE = 0,00137$ ;  $MAE = 0,01610$
- *testing set*:  $MSE = 0,09172$ ;  $MAE = 0,1525$

### *Analisi di forecast cluster 2*

Il *cluster 2*, identificato precedentemente nella *cluster analysis*, caratterizza, invece, il profilo dei giorni settimanali in cui la temperatura esterna risulta elevata e la radiazione solare presenta valori al di sotto di circa  $172 \left[ \frac{W}{m^2} \right]$ , come visibile dall'albero di classificazione in figura 5.23.

In particolare, il profilo di potenza frigorifera di tale *cluster* presenta dei consumi giornalieri di circa  $200 [kW]$  senza però alcun picco nell'andamento, come invece verificato nel *cluster 3*.

Anche per tale partizione del dataset è stata applicata la divisione in *training set* e *testing set* analizzati singolarmente con la procedura di *data pre-processing* per l'individuazione di eventuali anomalie

L'analisi di *forecasting*, nel caso in questione, permetterà di predire i valori di potenza frigorifera per i giorni settimanali che presenteranno determinate condizioni climatiche esterne, espresse in precedenza, che da esperto di dominio è possibile affidare ai giorni settimanali centrali in cui, durante l'accensione, la pompa di calore non registra grandi picchi di potenza in quanto l'edificio ha ormai smaltito l'apporto termico dovuto allo spegnimento degli impianti nel fine settimana.

Il modello è stato creato, anche in questo caso, con tutte le configurazioni descritte in precedenza, da cui è stata scelta la migliore i cui andamenti sono di seguito riportati:




Figura 5.46 Modello di stima del training set con rete neurale (input 24 ore)




Figura 5.47 Modello di stima del testing set con rete neurale (input 24 ore)

Anche in questo caso la configurazione migliore risulta quello con i valori in input della potenza frigorifera alle 24 ore precedenti l'istante di predizione. Gli andamenti dei valori di potenza predetta risultano, sia per il *training set* che per il *testing set*, quasi del tutto sovrapposti ai dati di potenza reale.

Per valutare la performance di tale modello sono state utilizzate le metriche MSE e MAE il cui andamento è di seguito rappresentato:




Figura 5.48 Andamento metriche MSE e MAE

In particolare, i valori di entrambe le metriche risultano rispettivamente:

- *training set*:  $MSE = 0,00107$ ;  $MAE = 0,01825$
- *testing set*:  $MSE = 0,0122$ ;  $MAE = 0,0717$

### *Analisi di forecast cluster 3*

Il *cluster 3*, identificato come i precedenti durante *la cluster analysis*, permette di descrivere i giorni settimanali caratterizzati da condizioni climatiche tipicamente estive in cui sia la temperatura esterna che la radiazione solare presentano valori elevati.

Tale profilo, come osservabile nella figura 5.21 precedente, presenta un andamento della potenza frigorifera molto simile al *cluster 2* ma con la differenza della presenza di un picco durante l'accensione del gruppo polivalente. Tale picco, come descritto nel paragrafo (numero paragrafo cluster), è tipico, soprattutto, dei primi giorni settimanali in cui l'edificio ha accumulato potenza termica durante il fine settimana a causa dello spegnimento degli impianti per mancanza di occupazione. I valori di picco registrati raggiungono valori di circa 350 [kW] a differenza dei valori di potenza registrati nei restanti periodi della giornata che risultano pari a circa 250 [kW].

Anche in questo caso, il dataset è stato inizialmente suddiviso in *training set* e *testing set* e successivamente entrambe le partizioni sono state sottoposte alla fase di *data pre-processing*.

L'analisi di *forecasting*, utile alla predizione della potenza registrati in tali giorni e condizioni, è stata sviluppata inviando in input al modello i valori di potenza alle ore 4, 6, 8, 12 e 24 precedenti l'istante di predizione. La configurazione che meglio consente di predire i valori di potenza, concordemente ai valori reali, risulta essere, come nei casi precedenti, il modello realizzato fornendo in input i valori di potenza alle 24 ore precedenti l'istante di predizione, i cui andamenti sono di seguito riportati:




Figura 5.49 *Modello di stima del training set con rete neurale (input 24 ore)*




Figura 5.50 *Modello di stima del testing set con rete neurale (input 24 ore)*

In entrambe le rappresentazioni precedenti si nota come la potenza frigorifera predetta (curva di colore rosso) sia quasi coincidente con la curva di potenza reale (curva di colore nero). Ciò permette di affermare che il modello è in grado di predire in maniera abbastanza efficiente i valori di potenza frigorifera futura.

L'andamento delle metriche di performance è di seguito riportate in figura 5.51, seguite dai valori medi di MSE e MAE per il dataset di *training* e quello di *testing*.






Figura 5.51 Andamento delle metriche di valutazione della performance MSE e MAE

I valori medi delle metriche utilizzate risultano:

- *training set*:  $MSE = 0,00079$ ;  $MAE = 0,0165$
- *testing set*:  $MSE = 0,01339$ ;  $MAE = 0,0723$

#### Analisi di forecast cluster 4

L'ultimo *cluster*, identificato attraverso l'analisi di clusterizzazione effettuata nel paragrafo precedente, è il numero 4. Tale partizione permette di descrivere i giorni settimanali in cui si hanno condizioni climatiche caratterizzate da una temperatura esterna relativamente bassa, con valori di circa  $15 [^{\circ}C]$ , e da una radiazione solare media con valori minori di  $103 \left[ \frac{W}{m^2} \right]$ . Infatti, il profilo di potenza, visibile in figura 5.21 precedente, riporta un andamento più basso in termini di potenza, rispetto ai precedenti due *cluster*, con valori di circa  $120 - 130 [kW]$ .

Anche per quest'ultima classe di *cluster* è stata effettuata l'analisi di *forecasting* andando inizialmente a suddividere i dataset in *training* e *testing set* e successivamente a

sottoporre entrambe le suddivisioni alla fase di data *pre-processing* per eliminare eventuali inconsistenze presenti.

La fase di previsione è stata effettuata, come per i *cluster* precedenti, con le 4 configurazioni possibili fornendo in input, al modello, i valori di potenza alle 4, 6, 12, e 24 ore precedenti. La configurazione migliore è risultata essere, anche in questo caso, quella in cui in input sono stati forniti i valori di potenza alle 24 ore precedenti l'istante di predizione. Gli andamenti di tale configurazione sono di seguito riportate nelle figure 5.52 e 5.53.




Figura 5.52 Modello di stima del training set con rete neurale (input 24 ore)




Figura 5.53 Modello di stima del testing set con rete neurale (input 24 ore)

In entrambe le configurazioni è possibile osservare come la potenza predetta segua in modo quasi identico la curva della potenza frigorifera reale rappresentata di colore nero.

La performance del modello, per tali ragioni, risulta abbastanza accurata per la previsione della potenza frigorifera futura dei giorni che riportano il profilo del *cluster 4*.

Le metriche utilizzate per valutare l'efficacia del modello sono state, anche in questo caso, l'MSE e il MAE, i cui valori medi sono di seguito riportati sia per il *training set* che per il *testing set*:

- *training set*:  $MSE = 0,00112$ ;  $MAE = 0,0193$
- *testing set*:  $MSE = 0,02938$ ;  $MAE = 0,1115$

In particolare, è possibile notare il loro andamento dalla figura seguente:




Figura 5.54 Andamento metriche di valutazione MSE e MAE

## 5.4 Risultati

In tali capitoli sono stati realizzati vari modelli di stima, sia di *benchmark* che di *forecast*, della potenza frigorifera del gruppo polivalente installato all'interno dell'Energy Center, edificio oggetto di studio.

Entrambi i modelli di stima sono stati utilizzati per l'intero dataset contenente i dati di potenza frigorifera del periodo estivo compreso tra il 16 giugno e il 14 ottobre del 2019, 2020 e 2021.

In particolare, per l'analisi di *benchmark* sono stati costruiti due diversi modelli di previsione con l'obiettivo di predire come avrebbe dovuto consumare potenza frigorifera il gruppo polivalente attraverso diverse variabili esogene fornite in input al modello. Il primo modello utilizzato è stato quello costruito con l'albero di regressione, il quale è riuscito a predire l'andamento della potenza reale in modo non molto accurato nonostante le variabili fornite in input fossero abbastanza rappresentative della variazione della potenza.

Il modello che è invece riuscito a predire la potenza frigorifera erogata dal gruppo polivalente in modo più accurato è stato quello costruito per mezzo della rete neurale artificiale in grado di cogliere le relazioni non lineari tra variabili di input e di output, non note apriori. Tale considerazione è stata confermata in questo studio; infatti, la differenza di predizione della potenza tra i due modelli è resa nota anche graficamente osservando la figura 5.31 e la figura 5.34.

L'analisi successiva è stata l'analisi di *forecasting*, effettuata prima sull'intero dataset di partenza e successivamente sui quattro dataset differenti a seconda del *cluster* di appartenenza. Quest'ultima analisi è stata effettuata con l'obiettivo di poter mettere a confronto le stime di entrambi i casi, osservando, attraverso l'utilizzo delle metriche, quale previsione risultasse più accurata. In particolare, i risultati mostrano per il *training set* valori dell'MSE, di un ordine di grandezza inferiore, nel caso dei quattro dataset, e un MAE che presenta una riduzione dei valori di circa il 74% sempre rispetto al caso del dataset completo.

Le riduzioni, in termini di accuratezza del modello, sono anche verificate per il *testing set*, anche se in maniera più contenuta, dove, i modelli divisi per *cluster*, sono risultati più accurati nella predizione della potenza frigorifera erogata dal gruppo polivalente installato nell'edificio. In particolare, l'MSE dei quattro modelli risulta più basso rispetto al modello contenente il dataset completo di circa il 43%, ad eccezione del modello riferito al *cluster 1* che presenta un MSE maggiore di circa la stessa percentuale. Stesso risultato è riportato dal confronto con la metrica del MAE, in quanto, per tutti i modelli divisi in *cluster*, risulta un valore del MAE più basso del 35% circa, rispetto al caso con il dataset completo, ad eccezione del modello contenente i dati appartenenti al *cluster 1* per cui risulta un valore del MAE maggiore di circa il 25%.

L'accuratezza rilevata per il *testing set* risulta probabilmente influenzata dall'utilizzo di dati riferiti al periodo della pandemia del 2020, presenti nel set di allenamento, in cui l'edificio non è stato utilizzato abitualmente come invece accade per i restanti anni analizzati. Tale considerazione è evidenziata anche dall'osservazione dei profili di potenza. I dati di potenza dell'anno 2020 infatti, sono stati incluso nel *training set* insieme ai dati registrati nel 2019, anno precedente alla pandemia, in modo da poter allenare il modello anche sulla base di dati standard dal punto di vista dei consumi e dell'occupazione dell'edificio. L'influenza di tale periodo è quindi da considerare e potrebbe essere la causa della non elevata accuratezza del modello. In aggiunta risulta necessario giustificare i valori delle metriche riguardanti il *cluster 1*. Tale cluster contiene i valori di potenza frigorifera riferiti sia ai giorni di fine settimana come il sabato in cui risultano valori di potenza nulli durante il pomeriggio e sia a giorni settimanali in presenza di condizioni climatiche sfavorevoli al raffrescamento dati i bassi valori di potenza frigorifera. Per tale motivo il modello andando a predire il valore di potenza all'ora successiva considerando i valori di potenza delle 24 ore precedenti, di giorni differenti, non riesce a predire in modo accurato la potenza frigorifera.

I risultati precedentemente descritti confermano comunque generalmente l'ipotesi di una migliore previsione della potenza frigorifera da parte di dataset contenenti valori di profili tipologici simili.

## 6 CONCLUSIONI

Il lavoro di tesi è stato svolto con l'obiettivo di rilevare informazioni utili per proporre e attuare azioni di efficientamento energetico all'interno dell'Energy Center, un edificio non residenziale situato nella città di Torino. Lo studio è stato effettuato sui dati di potenza frigorifera, erogata dal gruppo polivalente, attraverso l'applicazione di tecniche di *data analytics* sia non supervisionate che supervisionate. Tali tecniche hanno permesso rispettivamente di poter identificare i profili tipologici presenti nel dataset oggetto di studio e di realizzare modelli predittivi di stima della potenza frigorifera che permettono di identificare precise indicazioni di risparmio.

Il lavoro è stato sviluppato in due fasi principali. La prima fase ha previsto l'utilizzo delle tecniche non supervisionate, in particolare della *cluster analysis*. Tale analisi ha permesso di evidenziare la presenza di quattro profili tipologici in grado di evidenziare le particolarità del dataset oggetto di studio. In particolare, l'analisi ha individuato la presenza di profili con picchi di potenza frigorifera riferiti soprattutto ai primi giorni settimanali a causa della condizione di elevato carico termico, in cui si trova l'edificio durante il fine settimana, dato lo spegnimento degli impianti. Tale risultato è stato confermato dalla rappresentazione dell'albero di classificazione, tramite l'utilizzo di variabili esogene come il giorno della settimana, che ha permesso di evidenziare anche il profilo tipologico del sabato caratterizzato da valori di potenza non nulli soltanto per la prima metà della giornata. La seconda fase ha invece previsto l'utilizzo di tecniche non supervisionate utilizzate per costruire modelli previsionali sia di benchmark che di forecast. L'analisi di benchmark ha permesso di prevedere come avrebbe dovuto consumare il gruppo polivalente attraverso la realizzazione di un modello con albero di regressione e di uno con la rete neurale artificiale. Il modello con l'albero di regressione è risultato non molto accurato nella previsione della potenza frigorifera nonostante le variabili fornite in input fossero abbastanza rappresentative della variazione della potenza. Tale risultato era prevedibile, in quanto gli alberi di regressione non riescono bene a cogliere le non linearità tra le variabili, ma trovano comunque spazio in ambito energetico grazie soprattutto alla loro semplicità di interpretazione e alla loro flessibilità nel consentire l'utilizzo di variabili sia numeriche che categoriche. Il modello realizzato

con la ANN, invece, ha permesso di predire la potenza frigorifera in modo più accurato grazie alla capacità della rete neurale di cogliere le relazioni non lineari tra le variabili di input e output, non note apriori. L'analisi di forecast ha consentito, invece, di prevedere come il gruppo polivalente consumerà la potenza frigorifera prodotta dal gruppo polivalente attraverso la costruzione di modelli con rete neurale. Tali modelli riescono a stimare i valori di potenza futuri, l'output, utilizzando i dati di potenza, forniti come input, alle ore precedenti l'istante di predizione. Un modello così fatto, qualora si utilizzino potenze di intervalli temperali molto ampi, porta ad una bassa accuratezza di stima data la diversità dei profili giornalieri settimanali. Per tale ragione, sono stati realizzati quattro modelli di previsione della potenza frigorifera utilizzando i dati appartenenti ai quattro profili tipologici individuati con la *cluster analysis* precedente e sono stati confrontati con il modello previsionale realizzato con il dataset completo. Attraverso l'utilizzo dei KPI, in particolare MAE e MSE è stato possibile definire la maggior accuratezza dei quattro modelli previsionali rispetto al modello costruito con l'intero dataset. In particolare, la miglior accuratezza del *testing set* è dimostrata da valori di MAE e di MSE rispettivamente maggiori del 43% del 25% rispetto al modello realizzato con il dataset completo. L'unica eccezione, per tali risultati, deriva dal modello contenente i dati afferiti al *cluster 1* che identifica un profilo di potenza con valori molto bassi durante le ore pomeridiane. Per tale modello, infatti, i valori di MSE e MAE risultano più elevati rispetto a quelli definiti per il modello con dataset completo, rispettivamente del 43% e del 25%. La minor accuratezza del modello costruito con valori afferiti al *cluster 1* si presuppone dovuta alla presenza contemporanea sia di profili che presentano valori nulli di potenza, come previsto per il sabato, e sia di profili con valori molto bassi di potenza, anche se non nulli, riferiti ai giorni settimanali in corrispondenza di condizioni climatiche non molto favorevoli al raffrescamento dell'edificio.

Tale lavoro di tesi si pone come punto di partenza per l'applicazione di azioni utili per migliorare la gestione dei consumi energetici dell'Energy Center. Lo studio ha permesso infatti di individuare periodi di picco, verificati maggiormente durante i primi giorni settimanali, a cui potrebbe far seguito l'utilizzo del *free cooling* notturno che permetterebbe di raffrescare l'edificio durante le ore notturne sfruttando l'aria esterna a temperatura inferiore diminuendo così il carico termico che l'indomani mattina deve

diminuire il gruppo polivalente all'accensione. Ulteriore possibilità vantaggiosa per la diminuzione dei picchi potrebbe risultare anche l'accensione anticipata del gruppo polivalente che porterebbe l'edificio a raggiungere le condizioni di comfort con tempistiche maggiori, risparmiando così sia in termini energetici che di usura e manutenzione del gruppo polivalente. L'utilizzo dei modelli previsionali potrebbe portare, d'altro canto, all'ottimizzazione dei tempi di carica e scarica degli accumuli termici o all'applicazione delle diverse strategie di gestione della domanda (DSM) descritte all'interno del lavoro. Tra queste è stata proposta l'installazione di un sistema di accumulo latente con materiali a cambiamento di fase per poter diminuire i picchi di consumo registrate durante la fase di accensione durante il periodo di riscaldamento dell'edificio.

Numerosi risultano gli studi presenti in letteratura che evidenziano l'utilizzo di modelli previsionali, come quelli creati nell'elaborato, per proporre strategie di retrofit vantaggiose sia dal punto di vista energetico che gestionale.



# Bibliografia

- [1] «Cambiamenti climatici,» WWF, [Online]. Available: <https://www.wwf.it/cosa-facciamo/clima/cambiamenti-climatici/>.
- [2] M. P. C. V. Alessandro Federici, «RAPPORTO ANNUALE EFFICIENZA ENERGETICA 2020,» *ENEA*, 2020.
- [3] A. F. d. Cesco, «Pianeta 2021,» *Corriere della sera*, 10 giugno 2021. [Online].
- [4] «Commissione Europea,» Sito Ufficiale dell'Unione Europea, [Online]. Available: [https://ec.europa.eu/clima/climate-change/causes-climate-change\\_it](https://ec.europa.eu/clima/climate-change/causes-climate-change_it).
- [5] «IPCC,» IPCC Italia, [Online]. Available: <https://ipccitalia.cmcc.it/messaggi-chiave-ar6-wg1/>.
- [6] «Global Energy Review 2021,» IEA, 2021. [Online]. Available: <https://www.iea.org/reports/global-energy-review-2021>.
- [7] «Agenzia europea dell'ambiente,» Sito Unione Europea. [Online].
- [8] «IEA,» Global Energy Review 2021, 2021. [Online]. Available: <https://www.iea.org/reports/global-energy-review-2021>.
- [9] «Riscaldamento,» AIE, 2021. [Online]. Available: <https://www.iea.org/reports/heating>.
- [10] «Greenreport,» *la Repubblica*, 15 aprile 2021. [Online].
- [11] S. Pizzuti, M. Chinnici e S. Romano, «Tecnologie, dispositivi e strategie per smart building». *FOCUS ENEA*.
- [12] «Lotta contro i cambiamenti climatici,» Sito del Parlamento Europea. [Online].
- [13] «Direttiva (UE) del Parlamento europeo e del Consiglio,» 2018.
- [14] «Camera dei deputati, documentazione parlamentare,» Ottobre 2020. [Online].
- [15] «Ministero dello sviluppo economico,» 22 dicembre 2020. [Online]. Available: <https://www.mise.gov.it/index.php/it/energia/sostenibilita/gas-effetto-serra/sistema-europeo-per-lo-scambio-di-emissioni-eu-ets>.
- [16] C. d. d. Documentazione parlamentare, «Risparmio ed efficienza energetica».
- [17] «PIANO NAZIONALE INTEGRATO PER L'ENERGIA E IL CLIMA,» *Ministero dello Sviluppo Economico*.
- [18] A. G. Mussi, «Infobuildenergia,» 2021. [Online].
- [19] W. L. K. P. F. R. Ioannis Lampropoulos, «History of Demand Side Management and Classification of Demand Response Control Schemes».

- [20] «DIPARTIMENTO UNITÀ PER L'EFFICIENZA ENERGETICA,» ENEA. [Online].
- [21] J. TORRITI, «DEMAND SIDE MANAGEMENT: POTENZIALITÀ BARRIERE, POLITICHE».
- [22] Z. W. X. Xia, «A Portfolio Approach of Demand Side Management,» *ScienceDirect*.
- [23] X. X. a. J. Zhang<sup>1</sup>, «Energy Efficiency and Control Systems—from a POET Perspective,» *Department of Electrical, University of Pretoria, South Africa*.
- [24] Y. Chen, P. Xu, J. Gu, F. Schmidt e W. Li, «Measures to improve energy demand flexibility in buildings for demand response,» 2018.
- [25] Y. Chen, P. Xu, J. Gu, F. Schmidt e W. Li, «Measures to improve energy demand flexibility in buildings for demand response».
- [26] \*. A. S.-T. s. Sole` ne Goya, «Load management in buildings».
- [27] P. A. Capozzoli, *Dispense corso di Gestione e automazione negli edifici*, 2021.
- [28] M. Crisantemi, «Innovation Post,» 26 agosto 2021. [Online].
- [29] A. Smith, «Building Management System - Seminar 1».
- [30] G. P. Henze, «Model predictive control for buildings: a quantum leap?,» 2013.
- [31] M. F. C. S. C. G. M. M. B. K. C. V. a. B. N. J. ] Jradi, «A World Class Energy Efficient University Building by Danish 2020 Standards».
- [32] S. C. K. A. L. W. TURNER, «Neural network forecasting of tourism demand,» *Tourism Economics*.
- [33] M. K. a. J. P. Jiawei Han, «Data Mining: Concepts and Techniques,» *Elsevier*, 2012.
- [34] S. F. e. E. P. Susi Dulli, «Data mining, Metodi e Strategie».
- [35] «Data Mining: Concepts and Techniques,» *Elsevier*, 2012.

# Ringraziamenti

Vorrei ringraziare me stesso e tutte le persone che hanno affrontato con me questo incredibile percorso. Sì incredibile, ma non per le difficoltà quanto per le soddisfazioni raggiunte. Se dovessi raffigurare la mia carriera universitaria disegnerei una montagna, la cui cima dal basso non la si riesce a vedere ma, nonostante ciò, sono sempre stato convinto che ci fosse e che avrei potuto raggiungerla. Questo percorso non mi ha soltanto permesso di acquisire un titolo di studio ma ha fatto molto di più. Mi ha permesso soprattutto di crescere, formarmi, prendere atto delle mie capacità e degli obiettivi che voglio raggiungere. Ed è questo che insieme a persone fantastiche lo ha reso davvero incredibile.

Vorrei ringraziare innanzitutto il mio relatore, il prof. Davide Papurello per il supporto e la fiducia dimostratami lungo entrambi i percorsi di tesi, triennale e magistrale. Per la disponibilità e l'incoraggiamento nei momenti difficili che hanno permesso di riuscire a terminare il lavoro di tesi con tranquillità e dedizione.

Vorrei tanto ringraziare i miei genitori, per la possibilità di aver permesso di realizzare tutto questo. Ringraziarli non sarà mai abbastanza ma è anche grazie alla loro presenza, alla comprensione e all'incoraggiamento costante, nonostante i tanti chilometri di lontananza, che questo percorso si è potuto concludere come meglio non avrei potuto immaginare.

Grazie anche ai miei amici d'università per la stima e lo scambio di incoraggiamenti soprattutto nei periodi esami. A Lucio e Pier, conosciuti dalle prime lezioni di università, per il forte legame costruito in questi 5 anni. Ai miei amici di corso, Erika, Robbi, Matteo e Massimiliano per il supporto, la serietà e la leggerezza trasmessa durante i gruppi studio.

E infine un grazie ai amici di vecchia data, per la spensieratezza trasmessa, e a tutte le persone che hanno contribuito, anche se in piccola parte, a rendere tutto questo possibile.

