

PIACER

Piattaforma
Progettazione
Gestione

Comunità
Energetiche
Rinnovabili

Meeting di progetto

Secondo Meeting Online



Sviluppo tool di forecast

PR FESR 2021-2027 AZIONE 1.1.2 BANDO PER PROGETTI DI RICERCA INDUSTRIALE
STRATEGICA RIVOLTI AGLI AMBITI PRIORITARI DELLA STRATEGIA DI
SPECIALIZZAZIONE INTELLIGENTE



14/01/2025

M. Gabba, G. Taromboli, F. Bovera, M. Zatti



Forecasting – Dove eravamo rimasti?

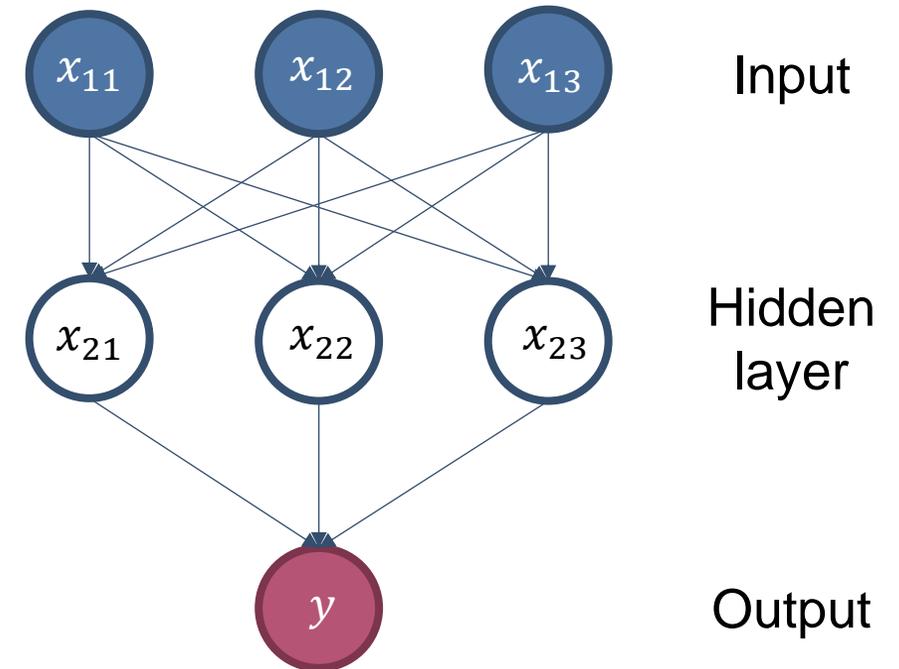
Durante l'ultimo meeting di progetto, abbiamo presentato una prima rassegna delle prestazioni ottenute da diversi metodi di forecasting testati per prevedere la domanda elettrica legata alla climatizzazione (annidata nella domanda complessiva) di un edificio del Politecnico di Milano.

Avevamo inoltre dichiarato i seguenti obiettivi:

- **Evoluzione e selezione degli algoritmi:** analisi dei diversi algoritmi disponibili per il forecasting di produzione PV e domanda elettrica e framework adatti al loro utilizzo in modalità federata:
 - Approfondire l'utilizzo di Reti Neurali Artificiali, per le quali esistono già librerie che permettono la scrittura e implementazione di Modelli Federati (e.g., TensorFlow Federated).
 - Approfondire l'utilizzo di framework che permettano di utilizzare gli altri algoritmi previsionali esaminati in un contesto Federato (e.g., Flower Framework).
- **Raccolta dati:** Raccolta dei dati di consumo elettrico associati a diversi edifici del Politecnico di Milano e consolidamento in un dataset pronto per l'applicazione dei metodi previsionali studiati

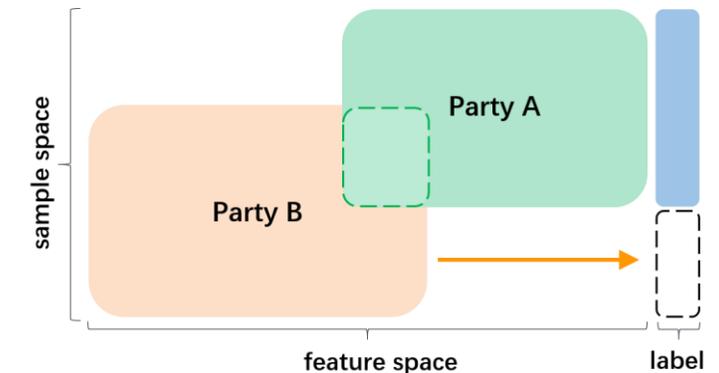
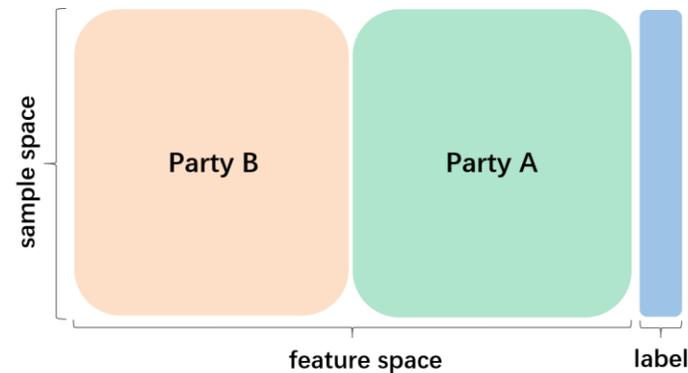
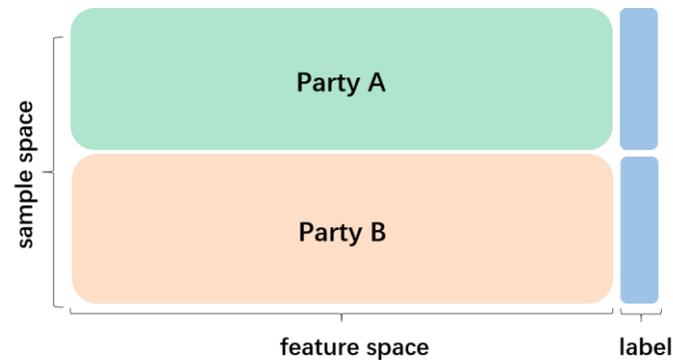
Forecasting – Anatomia di una rete neurale

- Nella sua forma più basilare, una rete neurale è costituita da una serie di **neuroni**, divisi in **layer**
- I neuroni di ogni layer sono connessi a tutti quelli del layer successivo (i.e., l'input di ogni neurone di un layer è dato dalla combinazione lineare di tutti i neuroni del layer precedente)
- Per consentire la modellazione di grandezze non lineari, gli output di ogni neurone possono essere alimentati a una funzione di attivazione (e.g. sigmoide, ReLU, ecc.)
- **La rete neurale addestrata**, quindi, può essere rappresentata dal **vettore di tutti i pesi** che caratterizzano le combinazioni lineari nei **diversi layer**
- Le reti neurali consentono **addestramenti incrementali**: posso ad esempio **partire da una rete pre-addestrata da altri**, e fornire i miei dati per **migliorare i pesi adattandoli al mio caso specifico**
- Questa proprietà è fondamentale per comprendere la logica alla base dell'**Apprendimento Federato**



Federated Learning – tipologie

Esistono tre tipologie principali di apprendimento federato:



Horizontal Federated Learning:

I dati sono distribuiti tra i diversi dispositivi/server, e il modello è addestrato in maniera collaborativa

Vertical Federated Learning:

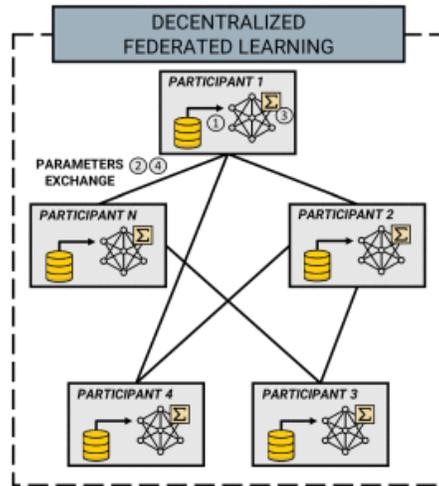
Le caratteristiche (feature) sono distribuite attraverso i dispositivi, e il modello è addestrato su feature complementari

Federated Transfer Learning:

I modelli pre-addestrati sono affinati attraverso dati decentralizzati per svolgere un compito specifico, riducendo il bisogno di dati locali

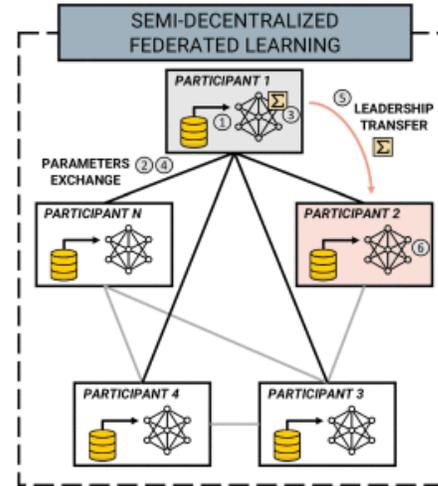
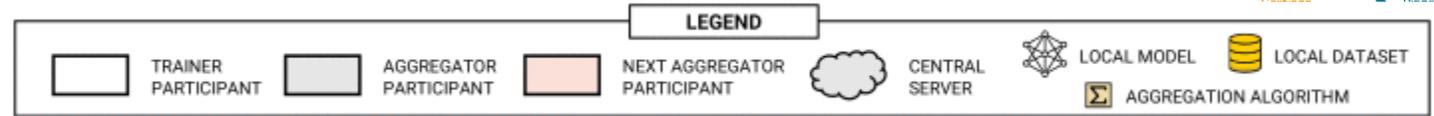
Fonte: Liu et al. – Vertical Federated Learning – 2022

Federated Learning – tipologie



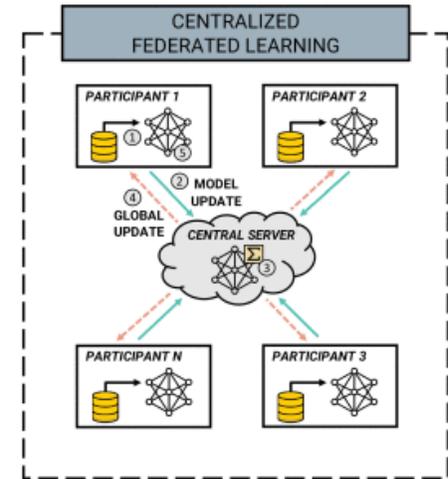
FL Decentralizzato:

I partecipanti eseguono 4 passaggi indipendentemente: addestramento del modello locale, scambio dei parametri, aggregazione dei modelli locale, nuovo scambio di parametri



FL semi-decentralizzato:

I partecipanti eseguono i primi due passaggi, mentre un partecipante con ruolo di aggregatore gestisce il terzo passaggio e trasferisce la leadership di aggregazione (passaggio 5)



FL centralizzato:

Un server centrale gestisce l'aggregazione dei parametri (passaggio 3), mentre il resto della rete riceve e aggiorna i propri modelli locali (passaggi 4 e 5)

Fonte: Beltran et al. – Decentralized Federated Learning: Fundamentals, State of the Art, Frameworks, Trends, and Challenge– 2023

Federated Learning – tecniche di Federazione

Federated Stochastic Gradient Descent (FedSGD)

Ogni client effettua l'addestramento sui propri dati e calcola i gradienti che vengono inviati al server centrale. Il server poi calcola la media dei gradienti provenienti da tutti i client e aggiorna il modello globale applicando i gradienti mediati.

Federated Averaging (FedAvg)

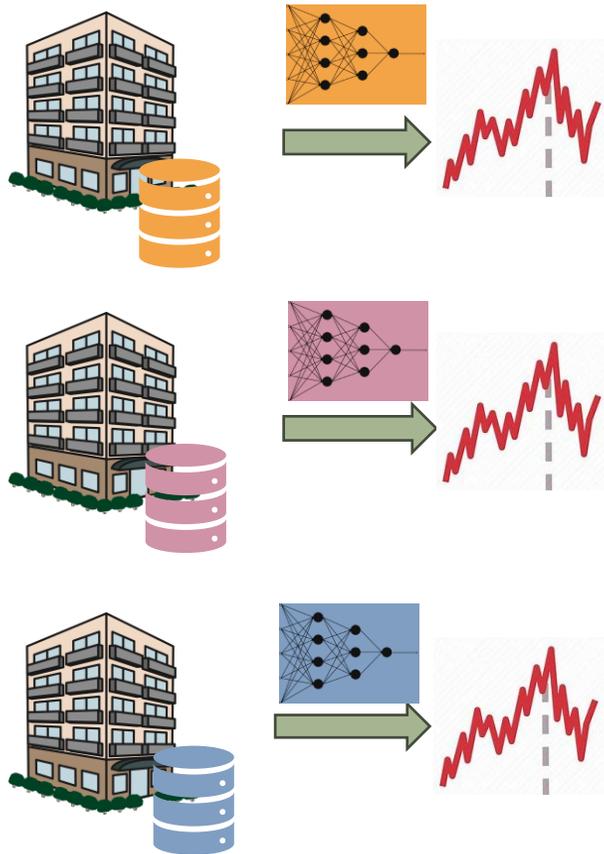
E' il framework principale utilizzato nell'apprendimento federato. Ogni client addestra un modello locale sui propri dati e invia i pesi del modello (ossia, i parametri aggiornati) al server. Il server calcola la media dei pesi effettuando una media ponderata, dove il peso di ciascun modello locale è proporzionale alla quantità di dati utilizzata per addestrarlo (dataset più grandi contribuiscono maggiormente al modello globale).

Weighted Federated Averaging (FedProx)

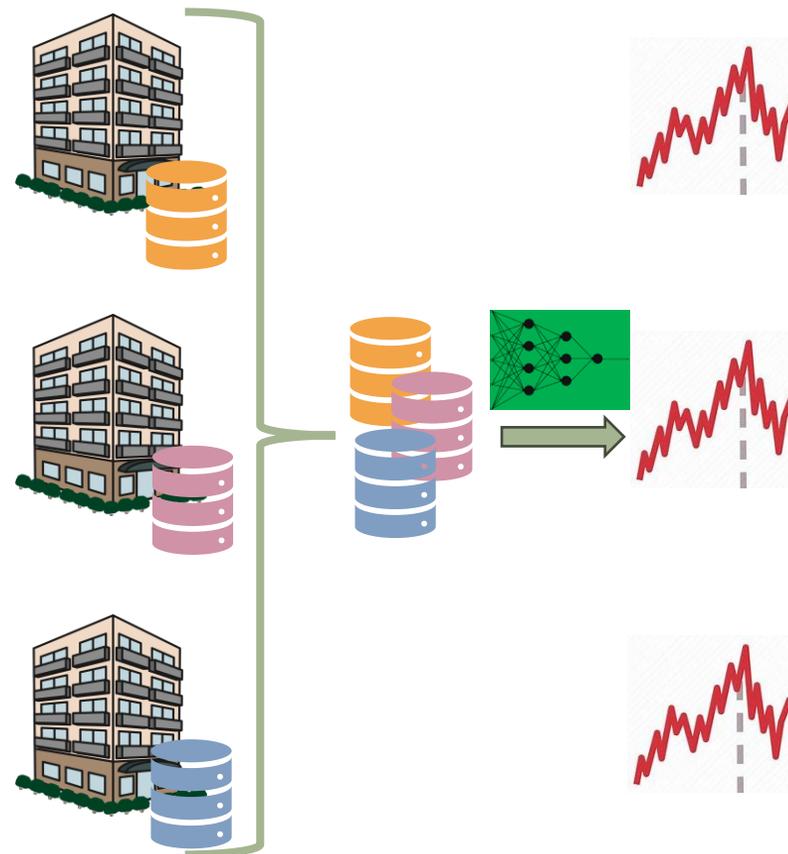
FedProx è una estensione di FedAvg progettata per affrontare il problema dei dati eterogenei (i client hanno distribuzioni di dati differenti). In FedProx, il server non si limita ad aggregare i modelli locali, ma introduce anche un termine di prossimità che limita la divergenza di ciascun modello locale rispetto al modello globale, garantendo una convergenza più fluida.

Federated Learning – ma quindi, perché FL per le CER?

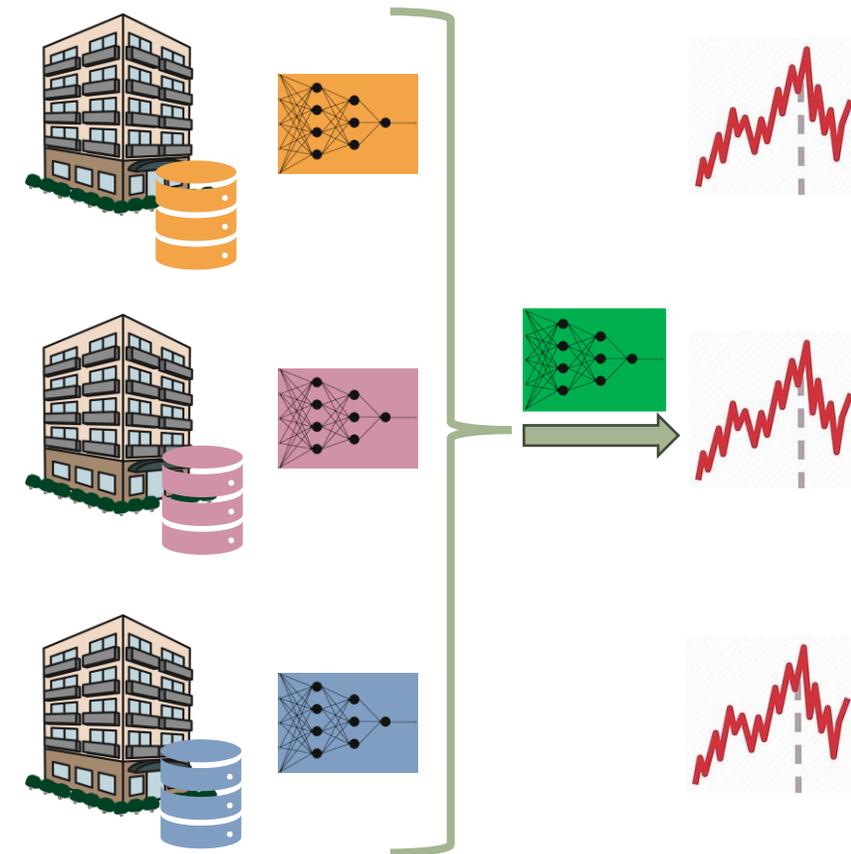
Un modello per ogni edificio



Modello centralizzato



Modello federato



Un esempio pratico: PoliMi

- I dati inerenti i campus del Politecnico di Milano sono stati suddivisi in tre dataset (Campus Leonardo, Campus Candiani, Campus La Masa, ciascuno reso disponibile con due granularità temporali (1h, 15min).
- Per il Campus di Leonardo i dati sono disponibili dal 2019, mentre per gli altri campus dal 2020
- Nel corso del prossimo semestre saranno aggiunti al dataset i dati inerenti l'anno 2024

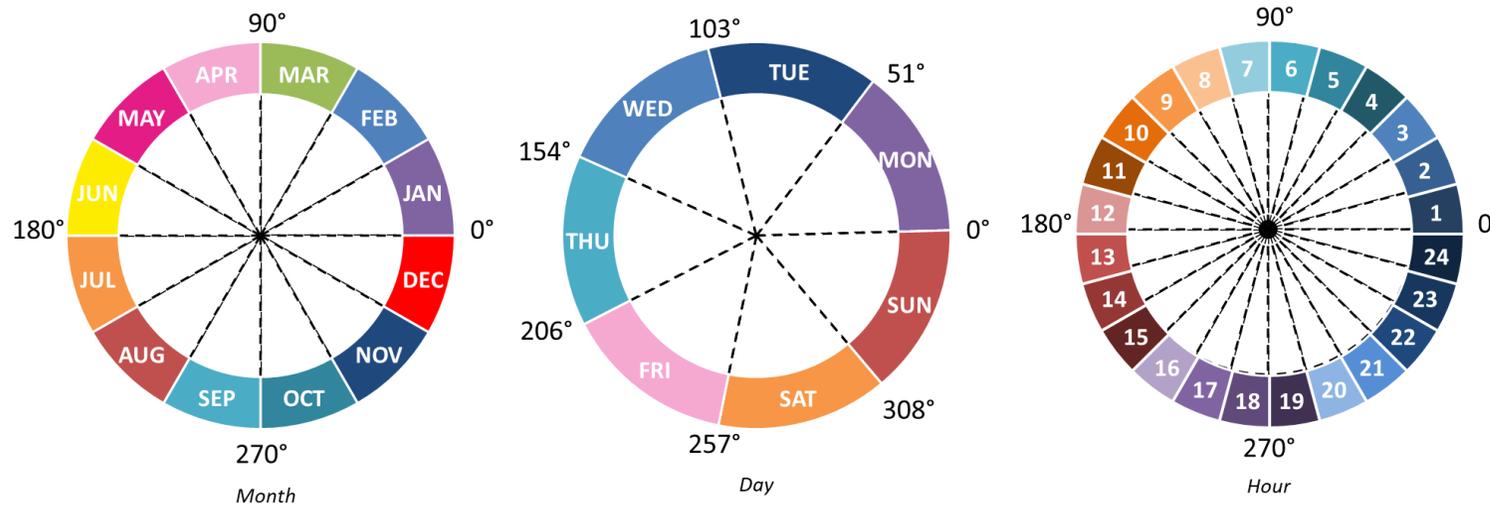
Name	Location	Campus	Granularity	Period
Leonardo_1h	Città Studi	Leonardo	1 h	2019-2023
Leonardo_15min	Città Studi	Leonardo	15 min	2019-2023
Candiani_1h	Bovisa	Candiani	1 h	2020-2023
Candiani_15min	Bovisa	Candiani	15 min	2020-2023
La Masa_1h	Bovisa	La Masa	1 h	2020-2023
La Masa_15min	Bovisa	La Masa	15 min	2020-2023

Feature: Previsioni Meteo + Modellazione dati calendariali

	1h	15min
Temperature (2m) [°C]	✓	✓
Relative humidity (2m) [%]	✓	✓
Rain [mm]	✓	✓
Wind speed (10m) [km/h]	✓	✓
DNI [W/m ²]	✓	✓

- 2019 – 2021 → Storico realizzazioni Meteo (Historical **weather**)
- 2022 – 2023 → Storico previsioni meteo (Historical **forecast**)

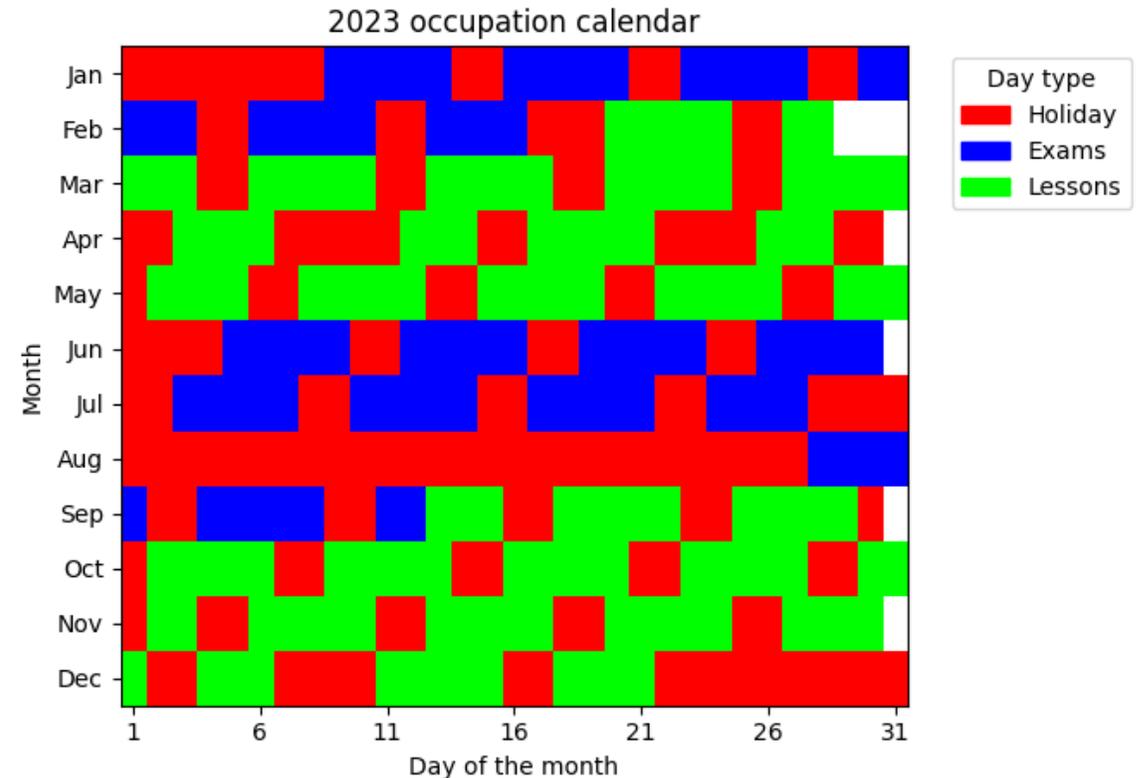
Source: OpenMeteo Historical Weather API, OpenMeteo Forecast API



Mese dell'anno, giorno della settimana, ora del giorno sono modellati come angoli di una circonferenza per tenere conto della circolarità del set (e.g., domenica e lunedì sono giorni consecutivi)

Feature: Occupazione edifici

	Lesson	Exam	Holiday
Sunday			✓
Saturday			✓
Bank holidays			✓
Sandwich days			✓
Christmas holidays			✓
Easter holidays			✓
Summer holidays			✓
Exams periods		✓	
“Parziali” week	✓		
Graduation days	✓		
Lesson periods	✓		



Pre-processamento dei dati

Armonizzazione della time-zone

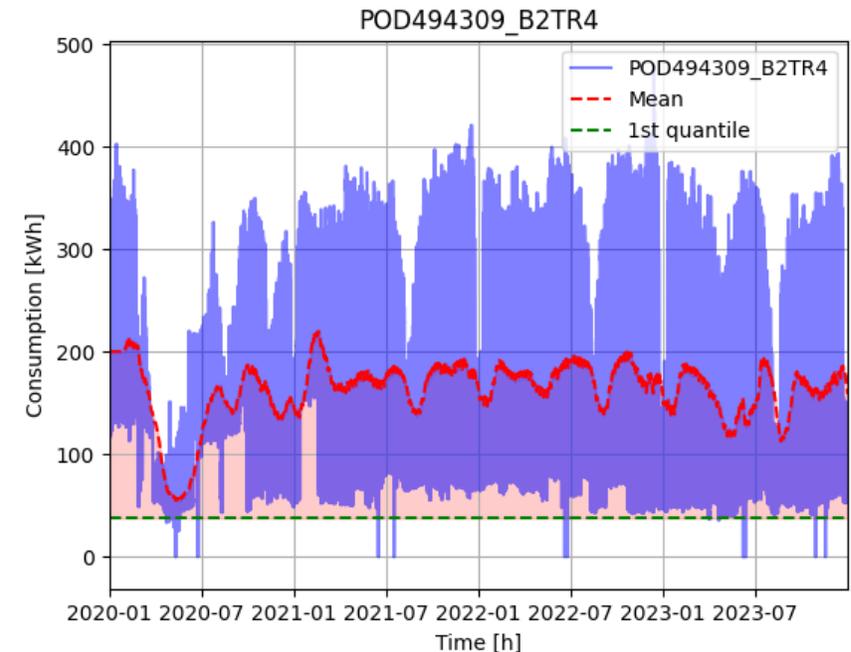
I dataset sono indicizzati utilizzando timestamp localizzati UTC+0

datetime	POD494309_B2TR1	POD494309_B2TR2	POD494309_B2TR4	POD489352
2019-12-31 23:00:00+00:00	35.2284	34.33759	122.11347	0
2020-01-01 00:00:00+00:00	34.92063	34.0418	123.25239	0
2020-01-01 01:00:00+00:00	35.0303	34.15118	123.43733	0
2020-01-01 02:00:00+00:00	35.05357	34.16607	124.23001	0
2020-01-01 03:00:00+00:00	35.15368	34.27053	122.74253	0
2020-01-01 04:00:00+00:00	34.96239	34.08267	122.75035	0
2020-01-01 05:00:00+00:00	43.15441	42.20275	122.23232	0
2020-01-01 06:00:00+00:00	47.1605	46.20887	121.08261	0
2020-01-01 07:00:00+00:00	47.81406	46.86873	120.41708	0
2020-01-01 08:00:00+00:00	47.84303	46.89641	121.59378	0
2020-01-01 09:00:00+00:00	44.89913	43.9556	119.93657	0
2020-01-01 10:00:00+00:00	45.42877	44.48064	120.31773	0
2020-01-01 11:00:00+00:00	50.91034	49.95211	119.39654	0
2020-01-01 12:00:00+00:00	53.45304	52.49851	117.34839	0

Example of Candiani_1h dataset index

Identificazione anomalie

Per ciascuna unità di consumo, i valori inferiori al primo percentile sono considerati outlier

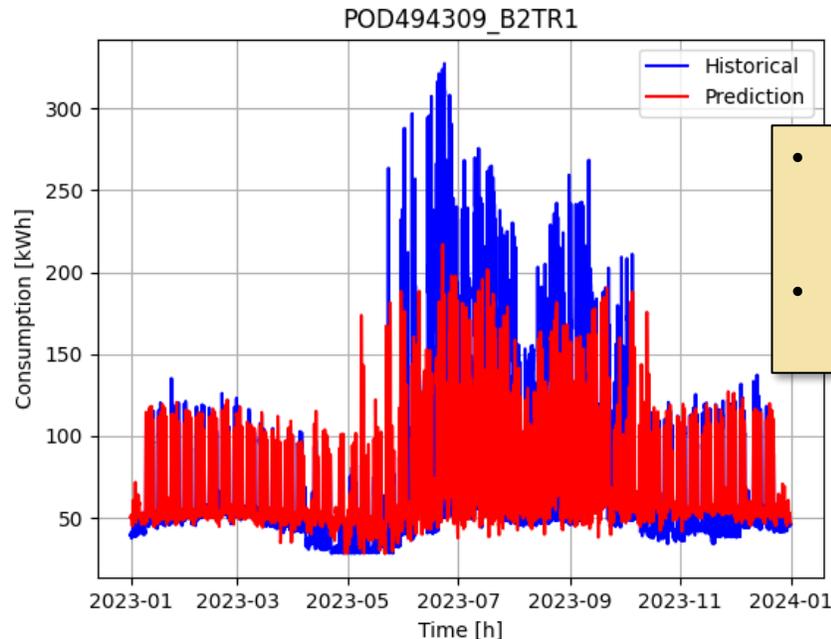


Example of consumption unit B2TR4 outliers in Candiani_1h dataset

LSTM – Modello centralizzato – Risultati preliminari Campus Bovisa Candiani

time_steps = 24
 batch_size = 30
 n_epochs = 10
 n_neurons = 70
 n_layers = 2

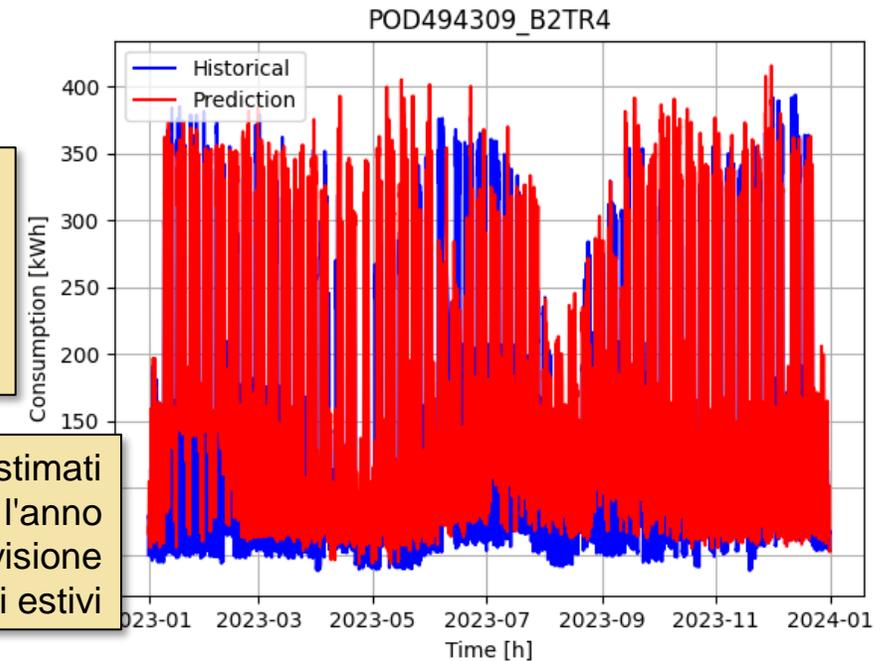
	Overall	POD494309_B2TR1	POD494309_B2TR2	POD494309_B2TR4
MAPE [%]	24.74	23.27	23.44	27.51
R ²	0.68	0.63	0.63	0.77



Consumo reale e previsto per l'unità B2TR1 (anno 2023)

- Previsioni più accurate nel periodo invernale e nelle mezze stagioni
- Errori maggiori nella previsione dei picchi estivi

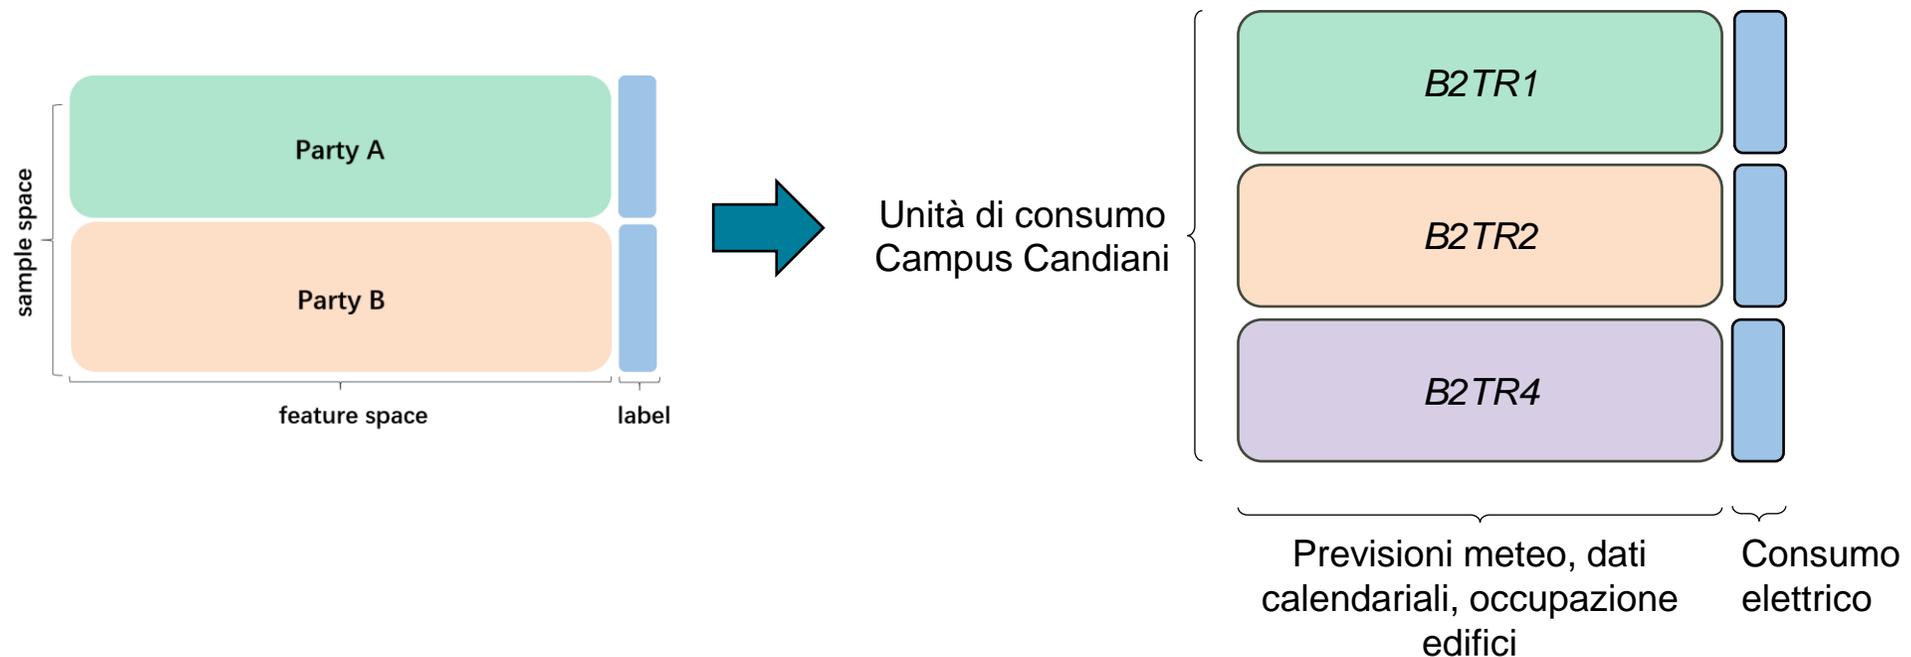
- Consumi minimi sovrastimati lungo tutto l'anno
- Errori maggior nella previsione dei picchi estivi



Consumo reale e previsto per l'unità B2TR4 (anno 2023)

LSTM – Modello federato – Prossimi passi

L'obiettivo del prossimo semestre sarà iniziare l'implementazione del framework per federare il modello LSTM mostrato precedentemente



Grazie per l'attenzione!

M. Zatti, M. Gabba, G. Martoriello, L. Saguatti

