



Terzo Meeting di Progetto



## WP2 - SoA strumenti 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



14/07/2025

M. Gabba

## LEAP – State of Art Strumenti di previsione del carico

### LE CER DI OGGI

- Quali feature? **Meteo** (Radiazione solare, temperatura esterna, velocità del vento, umidità relativa, copertura nuvole, direzione del vento), **Stagionalità** (ora del giorno, giorno della settimana, ecc.), **sensori** (temperatura interna, umidità, occupazione), **varie** (prezzo energia, vacanza, dettagli sull'edificio, abitudini degli utenti) e dati storici sulla grandezza target.
- Quali metodi? Statistici (Linear regression, lasso regression...) sono in calo, Tree-based methods sono molto popolari (soprattutto nelle versioni boosted), ML molto usati (RNN, LSTM, CNN). Focus della ricerca sono gli **ensemble methods**.
- LSTM sembrano essere le più popolari per Federated Learning (FL), come compromesso tra accuratezza e complessità computazionale ai nodi
- Ulteriori spunti: uso di dataset sintetici per agevolare l'addestramento degli strumenti di forecast a inizio vita della CER

### LA SFIDA DELLA FLESSIBILITÀ

- La letteratura si focalizza sul tema di prevedere (e scorporare) i carichi controllabili. Mentre il tema è affrontato per quanto riguarda il singolo consumer, non abbiamo trovato articoli che propongano framework per la previsione della flessibilità aggregata (e.g. FL)

### I SISTEMI MULTI ENERGIA

- La ricerca si sta concentrando anche sulla previsione contemporanea dei diversi carichi in sistemi multi-energia
- FL è stato proposto anche in questo ambito, ma di solito usando in serie CNN e LSTM per ridurre la dimensionalità dei dati

## Proposte per WP3

### Selezione del modello

- LSTM è la scelta più ragionevole, con finestre di 24 ore.
- **Struttura:** 1 o 2 hidden layer, circa 30 <-> 50 celle in totale
- **Iperparametri:** Learning rate = 0.05 <-> 0.0001, dropout= 10%<->20%, n\_epoch = 5 (FL) <-> 50 (centralized)  
 **Personalized FL:** ogni client seleziona il LR ottimale prima di ri-addestrare il modello condiviso!

### Preprocessing / Exploratory Analysis / Feature selection

- Per variabili "rumorose" (e.g. temperatura) si può usare come proxy una clusterizzazione (e.g. ora "fredda" o "calda").
- Una feature interessante da aggiungere potrebbe essere **AVG4D**: la media dei consumi energetici medi alla stessa ora dei quattro giorni precedenti dello stesso tipo (lavorativo vs weekend).
- Alternativa: inserire carico di 1,2,3 settimane prima tra le feature
- Ridurre il numero di feature: non inserire feature tra loro molto correlate (-> verificare matrice correlazioni in exploratory analysis)

#### Guardiamo ancora più avanti!

### Indicatori di accuratezza

- RMSE: 0.133 <-> 0.70; MAPE: 15% - 20%



Terzo Meeting di Progetto



## WP3 – Federated Learning

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



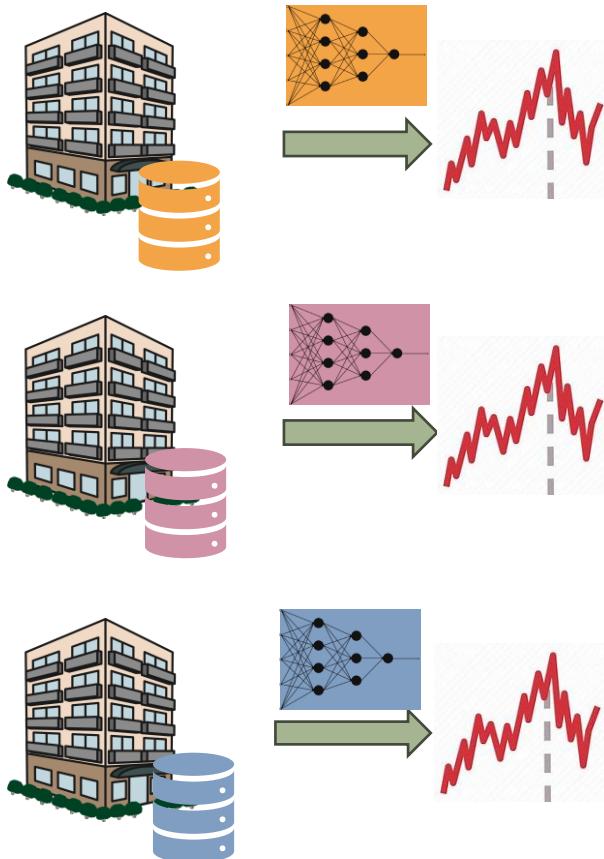
14/07/2025

G. Taromboli

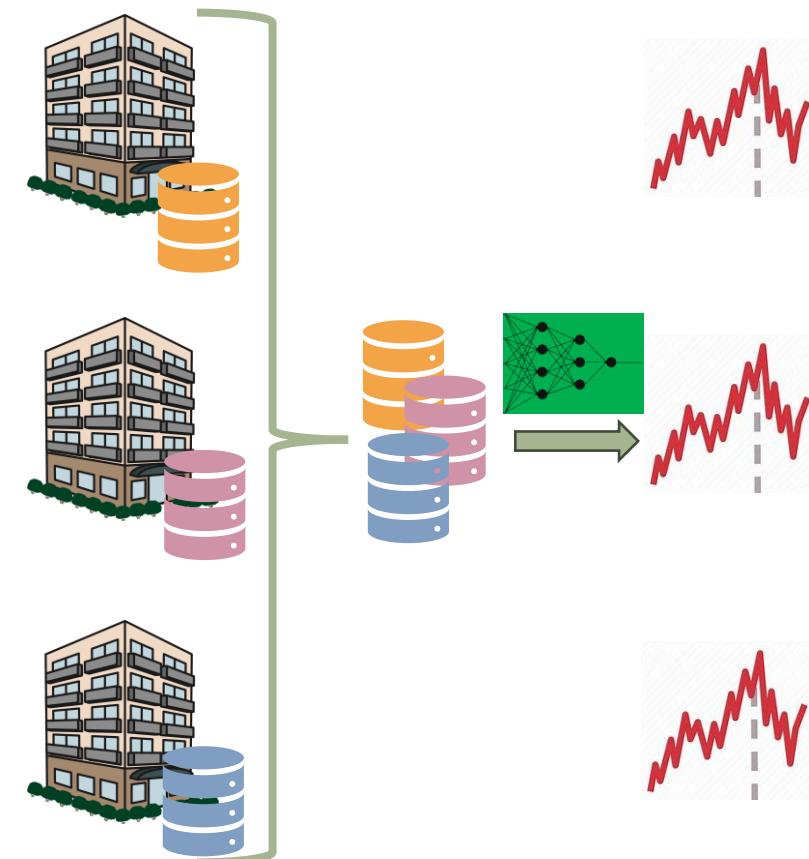
- Costruzione di un **dataset di consumi** per ogni campus del Politecnico di Milano con granularità di 1h e 15 min
- Costruzione di un **dataset di feature** con granularità di 1h e 15 min: dati meteo e calendariali, profili di occupazione semplificati
- Data preprocessing
- Costruzione di un modello **LSTM centralizzato** per la previsione dei consumi elettrici

# Simulazioni LSTM: Modelli Utilizzati

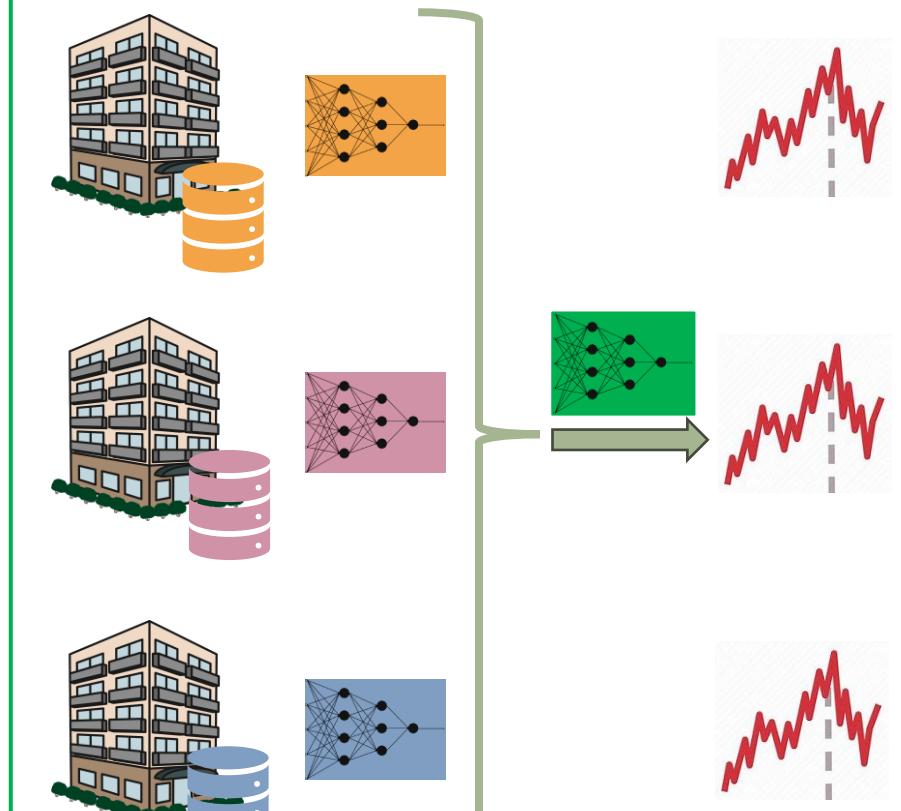
**One building, One model**



**Centralised model**



**Federated model**



**Modello Adottato:** Long-Short Term Memory (LSTM)

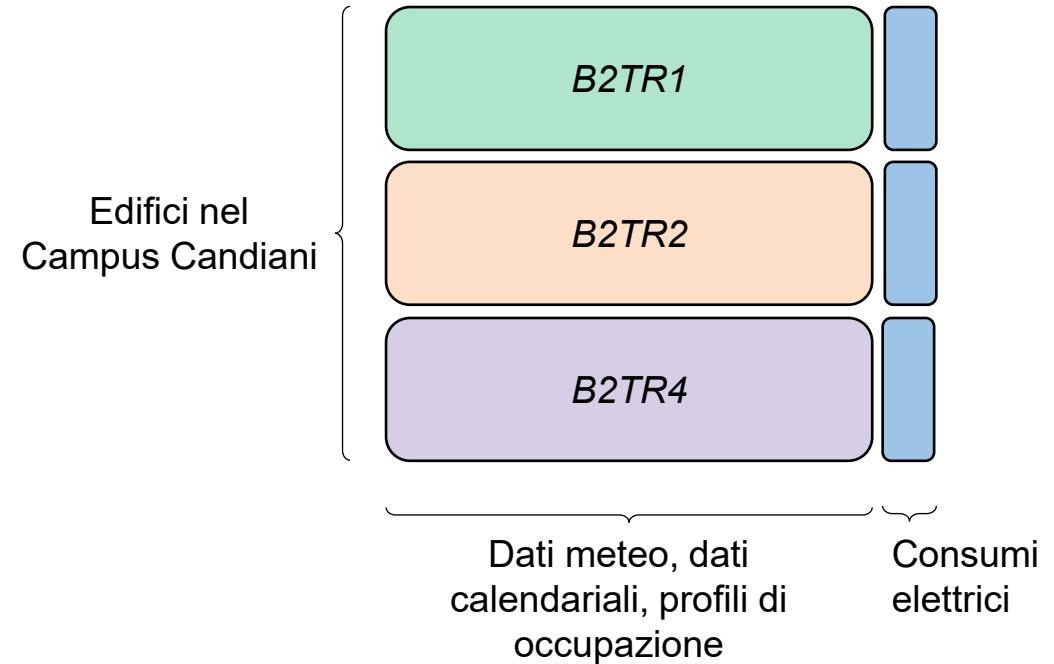
**Ambienti di Lavoro:** python

**Librerie:** PyTorch, Flower

## LSTM iperparametri

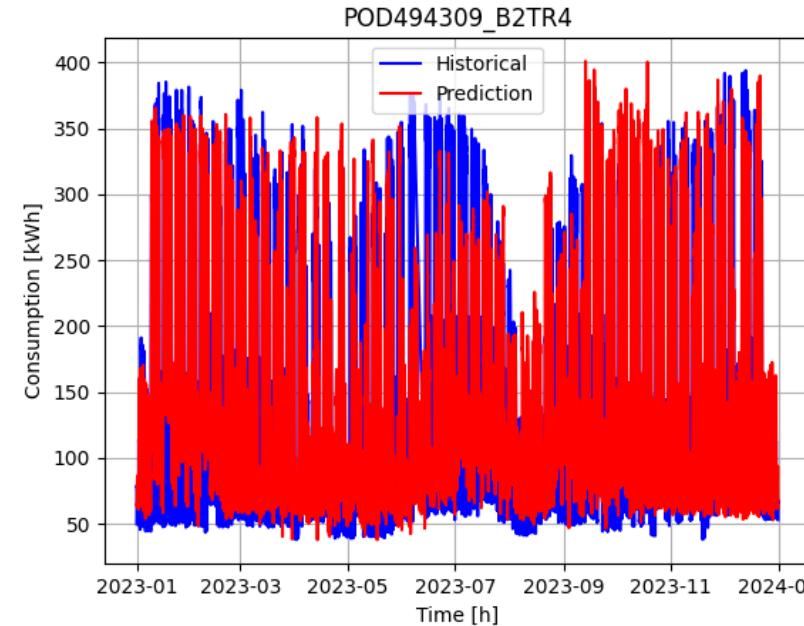
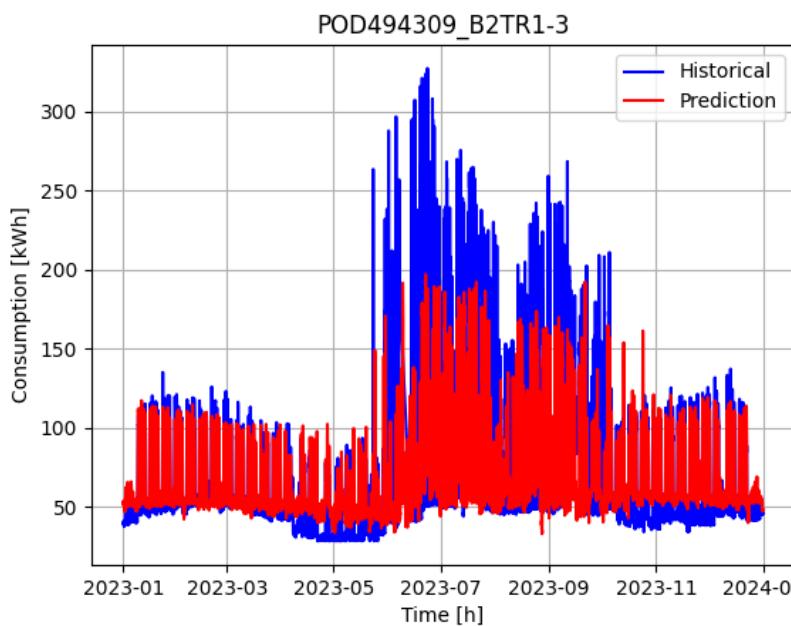
```
time_steps = 24
batch_size = 30
n_epochs = 10
n_neurons = 70
n_layers = 2
```

Train set → Dal 01-01-2020 al 31-12-2022  
Test set → Dal 01-01-2023 al 31-12-2023



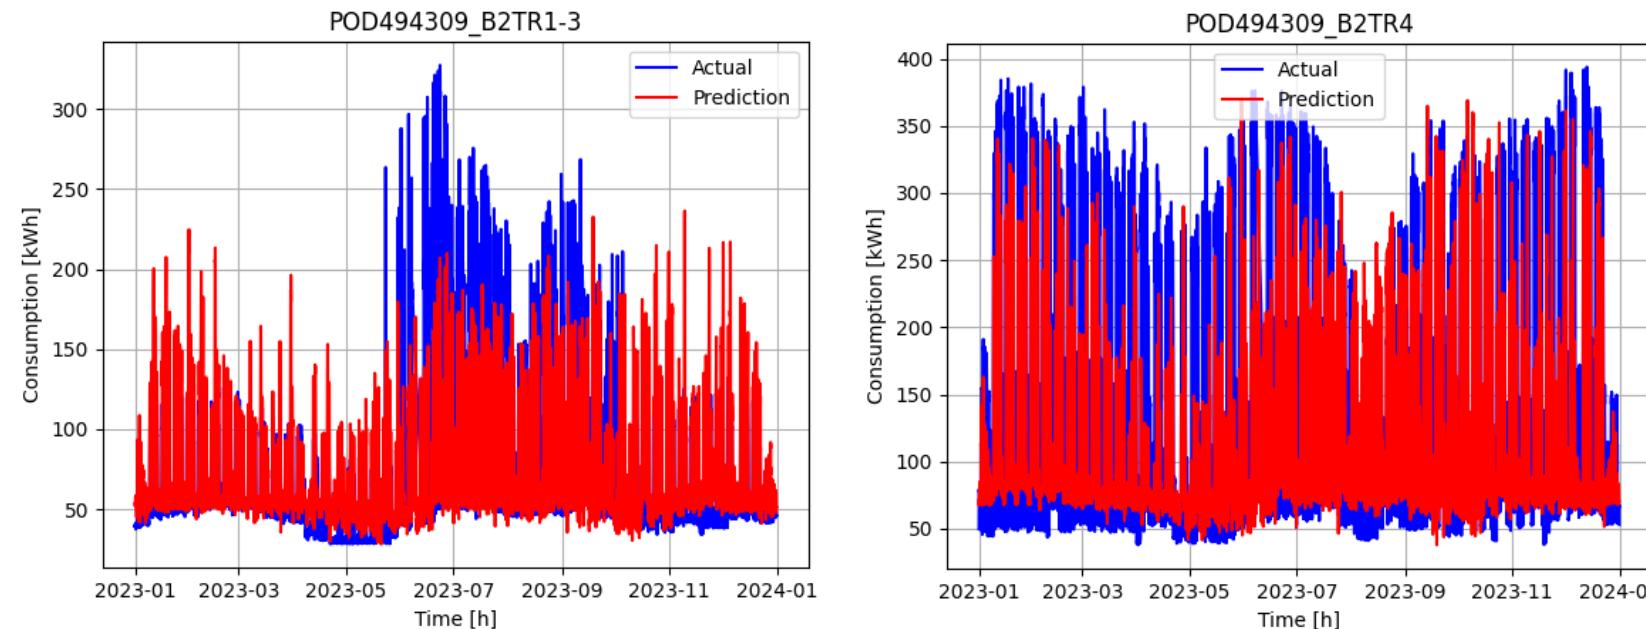
# Bovisa Candiani: Single-output Local LSTM

	POD494309_B2TR1	POD494309_B2TR2	POD494309_B2TR4
MAPE [%]	24.84	25.26	27.55
R <sup>2</sup>	0.64	0.59	0.69



# Bovisa Candiani: Single-output Centralised LSTM

	POD494309_B2TR1	POD494309_B2TR2	POD494309_B2TR4
MAPE [%]	29.68	31.95	31.54
R <sup>2</sup>	0.45	0.48	0.47

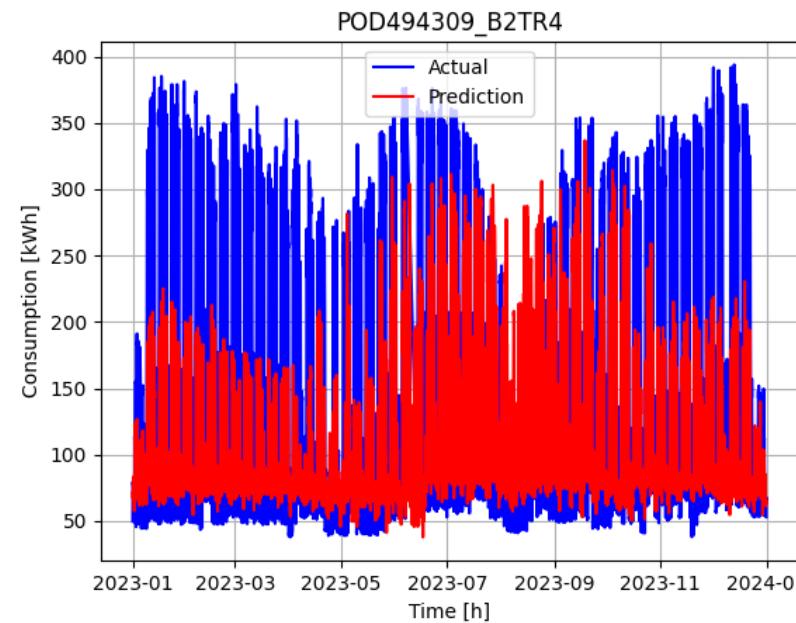
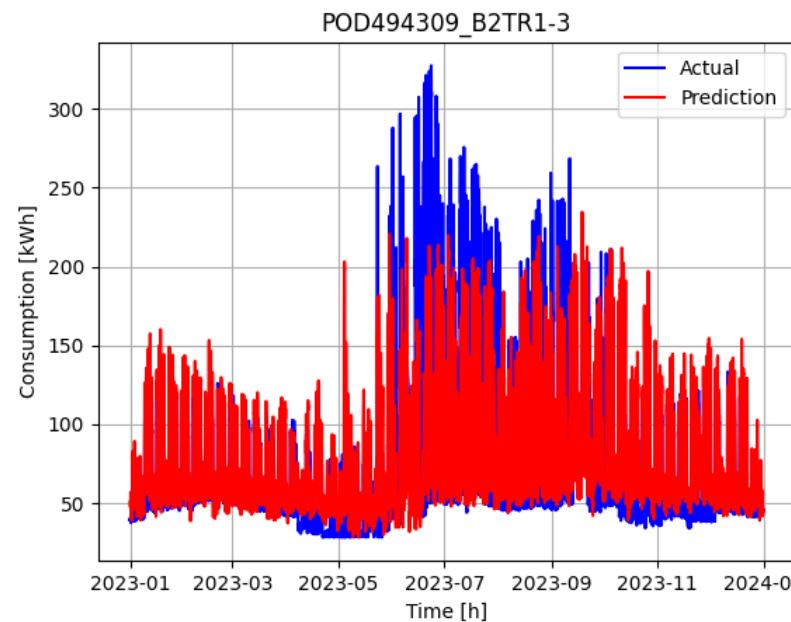


# Bovisa Candiani: Single-output Federated LSTM

	POD494309_B2TR1	POD494309_B2TR2	POD494309_B2TR4
MAPE [%]	30.87	29.32	34.65
R <sup>2</sup>	0.54	0.55	0.32

3 round

34 min



## Confronto con altri modelli

- Esplorare modelli di ML alternativi
- Ottimizzazione degli iperparametri di ogni modelli

## Profili di occupazione

- Introdurre profili di occupazione più complessi, tenendo conto della destinazione d'uso specifica degli edifici

## Espansioni future

- Aumentare il numero di POD
- FL Transfer Learning
- FL con clustering



*Grazie per l'attenzione!*

M. Gabba 