

FORECASTING ENERGETICO OTTIMIZZATO PER LE SMART GRID: MODELLI DI DEEP LEARNING CON INTEGRAZIONE DI INFORMAZIONI RELAZIONALI E OBIETTIVI DECISIONALI

Antonello Rizzi, Enrico De Santis, Gianluca Ferro, Sabereh Taghdisi Rastkar
Dipartimento di Ingegneria dell'Informazione, Elettronica e Telecomunicazioni

Università di Roma "La Sapienza"
Via Eudossiana 18, 00184 Roma

L'affidabilità e la resilienza dei sistemi energetici distribuiti dipendono in misura crescente dalla capacità di anticipare in modo accurato i profili di carico, produzione da fonti rinnovabili e andamento dei prezzi. Questo contesto richiede modelli previsionali non solo precisi, ma anche capaci di incorporare informazione strutturale e obiettivi operativi all'interno del processo di apprendimento. Il nostro gruppo ha investigato, in tale direzione, due direttrici convergenti: l'arricchimento semantico dell'input tramite strutture relazionali e l'integrazione end-to-end tra previsione e ottimizzazione mediante tecniche di *Decision Focused Learning* (DFL).

Il lavoro di ricerca ha affrontato una delle limitazioni strutturali dei modelli di *deep learning* sequenziali tradizionali tipo LSTM, ovvero l'indipendenza tra le feature in ingresso. Variabili come temperatura, giorno della settimana, umidità o storici di consumo sono tipicamente considerate disgiunte, ignorando il loro intreccio semantico e statistico. L'introduzione di una rappresentazione a grafo delle correlazioni tra le feature consente di modellare esplicitamente tali interdipendenze. Un modulo basato su *Graph Attention Network* (GAT) apprende una rappresentazione contestualizzata per ciascuna variabile, che viene poi integrata nel flusso temporale della rete LSTM. Il grafo è costruito in base a correlazioni Pearson tra le feature, e consente al modello di modulare dinamicamente l'importanza di ciascun nodo, con un impatto positivo sulla capacità di generalizzazione. Parallelamente, si è introdotta una funzione di perdita ponderata (*Weighted MSE*) che penalizza maggiormente gli errori nei periodi di picco, ritenuti critici per l'affidabilità operativa dei sistemi. Tale scelta risponde all'esigenza, emersa anche in letteratura [3][4], di bilanciare la priorità delle previsioni in base al rischio operativo, superando l'approccio uniforme implicito nelle metriche standard come il MSE. I risultati sperimentali su dataset reali mostrano una riduzione significativa dell'errore sia globale che localizzato nei picchi, e confermano la validità dell'approccio rispetto a modelli LSTM standard, XGBoost e altri metodi regressivi [1].

Il secondo asse metodologico esplora un cambio di paradigma più profondo: l'abbandono dell'approccio a due stadi (previsione seguita da ottimizzazione) a favore di un apprendimento congiunto tra predizione e decisione. Il framework di *Decision Focused Learning* permette di addestrare modelli previsionali in modo che massimizzino direttamente la qualità delle decisioni derivate, piuttosto che la semplice accuratezza predittiva [5][6]. Nell'ambito degli Energy Management Systems (EMS) per microgrid, dove le decisioni riguardano l'accumulo, il consumo e lo scambio di energia con la rete, si è implementato un modello LSTM il cui output viene utilizzato come input parametrico per un problema di programmazione lineare. Questo problema, che modella la minimizzazione dei costi operativi della microgrid, viene risolto all'interno di una *optimization layer* differenziabile, realizzata mediante la libreria

cvxpylayers [7]. Tale architettura consente di calcolare la derivata del costo operativo rispetto alle previsioni e quindi aggiornare i pesi della rete LSTM in funzione dell'impatto effettivo che la previsione ha sulle decisioni. La funzione di perdita utilizzata è una versione differenziabile del *regret*, ovvero la differenza tra il costo ottenuto con previsioni imperfette e il costo ottimale derivante dai dati reali. Questa strategia mostra benefici concreti: su un dataset reale fornito da Schneider Electric [2], si è osservata una riduzione dell'11% dei costi operativi rispetto all'approccio standard, pur con un lieve peggioramento delle metriche di errore predittivo. Tale risultato conferma quanto sottolineato da altri studi recenti [8]: minimizzare l'errore predittivo non equivale a massimizzare la qualità delle decisioni, e il passaggio a una loss basata sull'obiettivo finale può condurre a sistemi più efficaci nella pratica.

Un ulteriore vantaggio di questi approcci è la loro compatibilità con architetture modulari. Nel caso del DFL, ogni serie temporale (consumo, produzione fotovoltaica, prezzo) è modellata da una LSTM distinta, permettendo una specializzazione adattiva. Allo stesso modo, la rappresentazione a grafo può essere appresa su insiemi eterogenei di variabili e aggiornata dinamicamente. Questa modularità apre la strada all'integrazione dei due approcci: l'adozione di strutture a grafo all'interno di modelli *decision-focused* rappresenta una prospettiva promettente per il futuro, particolarmente rilevante in contesti multi-microgrid o comunità energetiche, dove la complessità delle relazioni tra agenti sul mercato dell'energia cresce notevolmente.

Infine, è opportuno sottolineare come il contributo metodologico si accompagni a una visione più ampia in cui l'intelligenza predittiva nei sistemi energetici non può prescindere da una consapevolezza strutturale (modello del dominio) e da un'integrazione stretta con gli obiettivi decisionali. I modelli di *deep learning*, per quanto potenti, devono essere orientati e regolati da vincoli e strutture che riflettano la natura del sistema. Solo così l'apprendimento automatico può davvero contribuire alla transizione energetica e alla costruzione di infrastrutture resilienti, flessibili e sostenibili.

- [1] S. T. Rastkar, S. Jamili, E. De Santis, and A. Rizzi, «Graph-Augmented LSTM with Weighted Loss for Enhanced Energy Forecasting», in *Proc. IEEE Int. Joint Conf. on Neural Networks. (IJCNN)*, Rome, Italy, Jun. 30–Jul. 5, 2025.
- [2] G. Ferro, E. De Santis, and A. Rizzi, «Decision Focused Forecasting for Smart Grid Energy Management Systems», in *Proc. IEEE Int. Joint Conf. on Neural Networks. (IJCNN)*, Rome, Italy, Jun. 30–Jul. 5, 2025.
- [3] N. L. M. Jailani et al., «Investigating the Power of LSTM-Based Models in Solar Energy Forecasting», *Processes*, vol. 11, p. 1382, 2023.
- [4] U. Ugurlu, I. Oksuz, and O. Tas, «Electricity Price Forecasting Using Recurrent Neural Networks», *Energies*, vol. 11, no. 5, p. 1255, 2018.
- [5] A. N. Elmachetoub and P. Grigas, «Smart 'Predict, then Optimize'», *Management Science*, vol. 68, no. 1, pp. 9–26, 2021.
- [6] C. Cameron et al., «The Perils of Learning Before Optimizing», in *Proc. AAAI Conf. Artificial Intelligence*, vol. 36, no. 4, pp. 3708–3715, 2022.
- [7] A. Agrawal et al., «Differentiable Convex Optimization Layers», in *Proc. NeurIPS*, pp. 9562–9574, 2019.
- [8] D. Wahdany et al., «More than Accuracy: End-to-End Wind Power Forecasting that Optimises the Energy System», *Electr. Power Syst. Res.*, vol. 221, p. 109384, 2023.