

PROBABILISTIC FORECAST OF EV CHARGING DEMAND USING QUANTILE REGRESSION AND LSTM WITH ATTENTION

S. Matrone, M. Wood, R. Zich, M. Mussetta, S. Leva, E. Ogliari

Politecnico di Milano, Dipartimento di Energia, Sezione Elettrica
Via Lambruschini, 4, 20156 Milano (MI)

Con la crescente domanda di energia dalle stazioni di ricarica dei veicoli elettrici, la previsione accurata del carico è fondamentale per bilanciare domanda e offerta, garantendo stabilità ed efficienza della rete. In uno studio precedente, abbiamo sviluppato un modello di Deep Learning basato su una struttura LSTM encoder-decoder, integrata con un meccanismo di attenzione [1]. Un aspetto cruciale nella gestione dei sistemi energetici distribuiti, come le microreti, è la valutazione delle incertezze. Le tecniche di previsione puntuale non sempre catturano adeguatamente la variabilità della previsione. Pochi studi hanno esplorato la previsione probabilistica per la domanda di ricarica dei veicoli elettrici. I modelli probabilistici forniscono stime delle distribuzioni, dei quantili [2], o utilizzano tecniche bayesiane [3]. In questo studio, proponiamo l'applicazione della Quantile Regression (QR) al

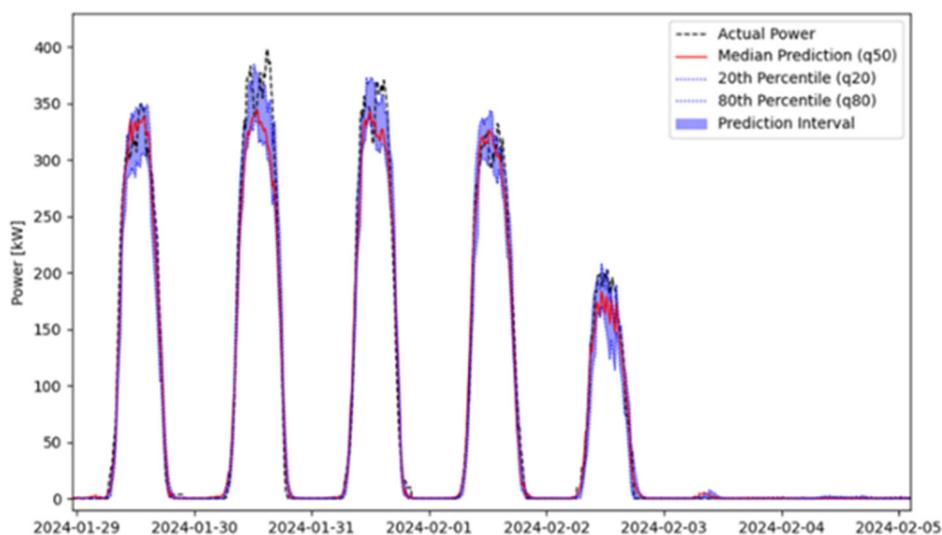
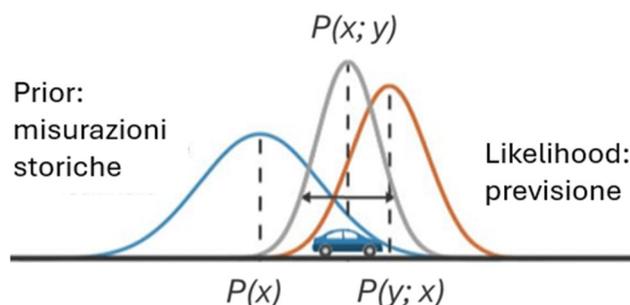


Figura 1 Risultati del modello QR su una settimana di esempio.

modello LSTM encoder-decoder con attenzione, applicato a un nuovo dataset olandese. La previsione puntuale è effettuata tramite LSTM, mentre la previsione probabilistica è ottenuta mediante QR. L'Encoder, composto da più strati di LSTM, estrae un contesto che alimenta il Decoder, il quale genera le previsioni. Il meccanismo di attenzione migliora il contesto tramite la somma ponderata degli stati nascosti, aumentando l'allineamento tra input e output. Per stimare i quantili, abbiamo addestrato tre modelli LSTM con attenzione: uno per la mediana (quantile 50°), uno per il 20° quantile e uno per l'80° quantile, minimizzando la "pinball loss", una funzione di errore asimmetrica.

Per valutare l'accuratezza, abbiamo utilizzato il Continuous Ranked Probability Score (CRPS), che misura la differenza tra la funzione di distribuzione cumulativa prevista e

l'osservazione effettiva. Il modello è stato valutato per diverse configurazioni degli iperparametri (numero di strati LSTM, unità per strato), con risultati che indicano un compromesso tra complessità e prestazioni. I modelli con 48 e 64 unità hanno generalmente mostrato migliori performance, con il modello a 2 strati e 48 unità che ha ottenuto il CRPS più basso (6.111). I risultati su una settimana di esempio sono mostrati in Figura 2. Il benchmark di riferimento è un modello di persistenza settimanale con intervalli di previsione



a ampiezza fissa. Rispetto al benchmark, il nostro modello ha mostrato miglioramenti significativi: una riduzione della pinball loss del 81,39% per il 20° quantile, del 62,09% per il 50°, e del 68,04% per l'80°, con una riduzione del CRPS medio del 67,70%. Questi risultati confermano che il nostro modello è significativamente più preciso. Nel modello di Bayes Ensemble [4] si utilizza l'inferenza bayesiana per combinare previsioni da LSTM con informazioni a priori basate su dati storici. Invece di mediare le previsioni, il metodo considera le previsioni ed i loro errori come variabili casuali applicando il teorema di Bayes per ottenere stime più robuste e centrate, come mostrato in Figura 2. Questo approccio agisce come un filtro di post-elaborazione, senza richiedere modifiche all'architettura dei modelli né il riaddestramento, risultando flessibile e facilmente integrabile. La versione che combina più LSTM ha mostrato prestazioni superiori in termini di accuratezza e numero di giorni con skill score positivo, confermando l'efficacia del metodo¹.

Bibliografia

- [1] S. Matrone, E. Ogliari, A. Nespoli, and S. Leva, "Electric vehicle supply equipment day-ahead power forecast based on deep learning and the attention mechanism," *IEEE Transactions on Intelligent Transportation Systems*, 2024.
- [2] M. S. Islam, N. Mithulanathan, and D. Q. Hung, "A day-ahead forecasting model for probabilistic EV charging loads at business premises," *IEEE Transactions on Sustainable Energy*, vol. 9, 2018.
- [3] J. Huber, D. Dann, and C. Weinhardt, "Probabilistic forecasts of time and energy flexibility in battery electric vehicle charging," *Applied Energy*, vol. 262, Mar. 2020.
- [4] D. Zhou, Z. Guo, Y. Xie, Y. Hu, D. Jiang, Y. Feng, and D. Liu, "Using Bayesian deep learning for electric vehicle charging station load forecasting," *Energies*, vol. 15, no. 17, 2022.

¹ This study was carried out within the MOST — Sustainable Mobility Center and received funding from the European Union Next-GenerationEU (PIANO NAZIONALE DI RIPRESA E RESILIENZA (PNRR) – MISSIONE 4 COMPONENTE 2, INVESTIMENTO 1.4 – D.D. 1033 17/06/2022, CN00000023). This manuscript reflects only the authors' views and opinions, neither the European Union nor the European Commission can be considered responsible for them