

Un Metodo Adattivo per il Monitoraggio Non-Intrusivo della Potenza Attiva in Presenza di Impianti Fotovoltaici

Muhammad Affan Khan, Giulia Tanoni, Paolo Vitulli, Enrik Xhani, Emanuele Principi e Stefano Squartini

Dipartimento di Ingegneria dell'Informazione, Università Politecnica delle Marche
Via Brezze Bianche 12, 60131, Ancona, e-mail: m.a.khan@pm.univpm.it

L'incremento del fabbisogno energetico e la necessità di diminuire le emissioni di gas serra hanno mostrato quanto sia cruciale migliorare l'efficienza energetica in diversi settori. Nello specifico, si è osservato che quando gli utenti sono informati sui propri consumi energetici, questi possono ridursi fino al 15% [1]. Una metodologia innovativa in questo campo è il "monitoraggio non intrusivo dei carichi elettrici" (NILM) [1], che permette di rilevare e tenere traccia dei consumi energetici dei singoli dispositivi in un edificio utilizzando un solo strumento di misurazione.

Gli approcci NILM più avanzati si basano su Deep Neural Networks, e nonostante i recenti progressi sia nella ricerca che nell'industria, la loro applicazione in contesti reali presenta ancora numerose sfide. Sempre più spesso, ad esempio, gli edifici sono dotati di fonti di energia rinnovabile, come gli impianti fotovoltaici. Nei punti di misura, però, viene rilevata solo la potenza netta relativa all'intero impianto elettrico, che comprende sia la potenza attiva assorbita dai carichi che quella generata dalla fonte rinnovabile [2]. Questo rende più difficoltosa la distinzione dei profili di consumo dei carichi, riducendo, così, le prestazioni degli algoritmi di disaggregazione. Studi recenti hanno mostrato che la presenza di un impianto fotovoltaico impatta sull'accuratezza per circa il 25% [2]. Oltre a questo, la maggior parte degli approcci recenti non considera ambienti dinamici, ovvero nei quali i profili di potenza cambiano nel tempo ed in cui nuovi sistemi, macchinari, o dispositivi vengono aggiunti o rimossi [3].

Per affrontare tali criticità, in questo articolo proponiamo AIPLD (*Adaptive Appliance-Incremental and Photovoltaic-Aware Load Disaggregation*), un metodo in grado di disaggregare sia i carichi elettrici sia la potenza generata da un sistema fotovoltaico e di adattarsi continuamente a scenari dinamici (Fig. 1). A differenza delle tecniche NILM tradizionali, che assumono un flusso unidirezionale di energia, AIPLD è in grado di gestire un flusso bidirezionale e di separare la potenza generata da un sistema fotovoltaico dalla potenza aggregata netta. Questo viene effettuato a partire da un modello addestrato inizialmente per disaggregare i soli consumi dei carichi elettrici, ed adattandolo successivamente per disaggregare anche la potenza generata dal sistema fotovoltaico. AIPLD è basato sul paradigma Teacher-Student (Fig. 1), in cui il modello Teacher viene addestrato esclusivamente sui profili di consumo dei carichi, mentre il modello Student viene adattato tramite *knowledge distillation* [4] a partire dal modello Teacher per stimare anche la potenza generata dal sistema fotovoltaico, in questo modo gestendo uno scenario dinamico. L'addestramento del modello Student avviene utilizzando anche la tecnica di regolarizzazione *Learning without Forgetting* (LwF) [5] e un meccanismo di *Dynamic Layer Distillation* (DLD) [3].

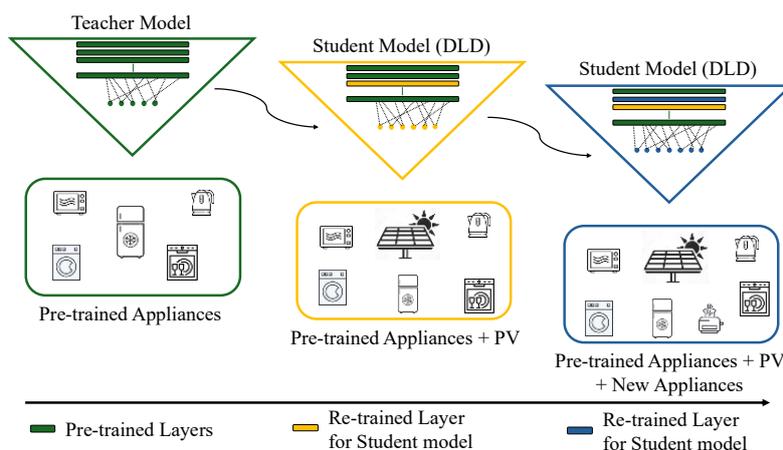


Figura 1: Schema a blocchi dell'approccio proposto.

Tabella 1: Confronto delle prestazioni dei modelli NILM sul set di dati UK-DALE.

Modello	MAE (W)
Baseline CRNN	26.82
AIPLD	26.85

Per validare il metodo proposto, sono stati effettuati esperimenti utilizzando il dataset pubblico, UK-DALE, al quale è stata aggiunta la potenza attiva simulata di un tipico sistema fotovoltaico. Gli elettrodomestici considerati sono i seguenti: Bollitore, Microonde, Lavastoviglie, Lavatrice, Tostapane e Lavasciuga. Le prestazioni di disaggregazione vengono valutate utilizzando la metrica *Mean Absolute Error* (MAE) del consumo energetico stimato.

La Tabella 1 mostra i risultati ottenuti, confrontando le prestazioni di AIPLD con un modello Convolutional Recurrent Neural Network (Baseline CRNN). Tale modello è stato addestrato da zero utilizzando come ground-truth sia i profili di consumo degli elettrodomestici che la potenza attiva prodotta dal sistema fotovoltaico. Sebbene entrambi i modelli raggiungano livelli di accuratezza comparabili, AIPLD dimostra un vantaggio significativo consentendo l'aggiunta incrementale di un impianto fotovoltaico dopo l'installazione nell'edificio, senza richiedere un riaddestramento completo della rete. Questa adattabilità consente ad AIPLD di mantenere prestazioni elevate in contesti domestici dinamici, mentre i modelli statici richiederebbero un riaddestramento completo ogni volta che vengono introdotti nuovi segnali o modelli energetici.

BIBLIOGRAFIA

- [1] G. Tanoni, E. Principi, S. Squartini, "Non-Intrusive Load Monitoring in Industrial Settings: A systematic Review," *Renewable and Sustainable Energy Reviews*, vol. 202, 2024.
- [2] Y. Yoo, G. Jang, J. Lee e S. Jung, "Stochastic forecast error estimation of high PV penetration system considering net-load/PV decoupling for microgrid operation," *IET Renewable Power Generation*, vol. 16, n. 10, 2022.
- [3] G. Tanoni, E. Principi, L. Mandolini e S. Squartini, "Appliance-Incremental Learning for Non-Intrusive Load Monitoring," in Proc. of *SmartGridComm*, Glasgow, 2023.
- [4] G. Hinton, O. Vinyals e J. Dean, "Distilling the knowledge in a neural network," in Proc. of *NIPS*, 2015.
- [5] Z. Li e D. Hoiem, "Learning without Forgetting," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 40, n. 12, pp. 2935-2947, 2018.