

Ciclo EAF: applicazioni dell'IA per stimare i consumi energetici

V. Colla, S. Dettori, S. Cateni, M. Vannucci, T. A. Branca, A. Vignali, C. Mocci

La produzione di acciaio attraverso il ciclo elettrico soffre di una bassa diversificazione di fonti d'approvvigionamento energetico e, nell'ottica dell'efficientamento e della diminuzione dei costi, deve essere ottimizzata per diversi aspetti, tra i quali la pianificazione della produzione. Ottimizzare i costi di produzione significa per esempio livellare i consumi di energia elettrica, i cui prezzi possono variare nel breve/medio periodo, prevedere fluttuazioni in funzione dell'orario o se il consumo di picco supera una certa soglia. La pianificazione della produzione può dunque beneficiare di modelli che predicano l'energia consumata in funzione della qualità di acciaio da produrre e la specifica ricetta da seguire; che possano essere utilizzati da sistemi di ottimizzazione intelligente dello scheduling. Questo lavoro presenta un set di modelli basati su reti neurali che permettono di predire con buona precisione il consumo di energia elettrica nel forno elettrico e nel forno siviera in funzione delle principali informazioni sulla produzione. I modelli sono stati addestrati e validati attraverso i dati di produzione e di processo di un impianto in Croazia con risultati incoraggianti.

PAROLE CHIAVE: FORNO AD ARCO ELETTRICO, FORNO SIVIERA, PIANIFICAZIONE DELLA PRODUZIONE, INTELLIGENZA ARTIFICIALE, MODELLI DI CONSUMO DELL'ENERGIA;

INTRODUZIONE

La produzione di acciaio da forni ad arco elettrico (Electric Arc Furnace, EAF), rispetto al ciclo integrale, rappresenta un'alternativa sostenibile e flessibile, giacché il riciclo dei rottami metallici rappresenta una implementazione del concetto di economia circolare. Inoltre, l'energia elettrica utilizzata può essere prodotta da fonti rinnovabili, riducendo così l'impatto ambientale rispetto ai metodi tradizionali basati su combustibili fossili, e permettendo una discreta flessibilità operativa, potendo essere rapidamente accesi e spenti, adattandosi così alle variazioni della domanda di mercato. Tuttavia, il ciclo elettrico presenta delle problematiche tuttora solo parzialmente risolte, quali la dipendenza dalla qualità dei rottami, che varia notevolmente influenzando la qualità finale dell'acciaio prodotto e i consumi elettrici. Inoltre, l'EAF richiede una grande quantità di energia elettrica, il che pone sfide in termini di costi, disponibilità e diversificazione energetica in un mercato sensibile a contesti sociali e mondiali in continua imprevedibile evoluzione. In questo contesto, la pianificazione intelligente del consumo di energia elettrica gioca un ruolo fondamentale sia nella sostenibilità economica del processo, sia in quella ambientale. Tuttavia, risolvere un

Valentina Colla, Stefano Dettori,
Silvia Cateni, Marco Vannucci,
Teresa Annunziata Branca,
Antonella Vignali, Claudio Mocci
Scuola Superiore Sant'Anna, Istituto TeCIP, Pisa, Italy.

problema di schedulazione dei processi è un compito piuttosto arduo per gli operatori, soprattutto quando la sostenibilità economica deve anche essere bilanciata dal rispetto dei normali vincoli operativi degli impianti e dal ritmo di produzione. Ridurre il costo dell'approvvigionamento energetico può significare dover livellare i consumi all'interno di un orizzonte temporale giornaliero, limitandone i picchi, oppure pianificare i lotti di produzione più energivori nei periodi di prezzo inferiore dell'energia elettrica. La pianificazione intelligente richiede dunque strumenti che siano in grado di prevedere il consumo di energia in funzione della qualità d'acciaio da produrre, della disponibilità di rottami, della ricetta di produzione e delle principali misure o informazioni dei processi. Questi strumenti, o modelli, devono inoltre poter bilanciare l'accuratezza delle previsioni numeriche e il loro costo computazionale, motivo per cui i modelli numerici basati su equazioni o principi primi risultano inefficaci per una risposta in tempo reale. In questo contesto, dunque, trainata da diverse applicazioni vincenti, l'intelligenza artificiale (AI) si sta inserendo efficacemente nel set di strumenti necessari per la modellazione di processi produttivi energivori, grazie alla sua capacità di digerire importanti quantità di dati (ora disponibili nei sistemi di acquisizione dati sempre più aggiornati) e di approssimare numericamente comportamenti chimico/fisici di sistemi complessi quali quelli considerati. Questo lavoro presenta dei modelli di intelligenza artificiale basata su reti neurali di tipo Feed Forward Neural Network (FFNN) per la predizione dei principali consumi energetici e della durata dei processi quali l'EAF e i trattamenti in siviera (Ladle Furnace, LF). Questa memoria introduce dunque le metodologie utilizzate durante la fase di modellazione, i risultati ottenuti durante la prototipizzazione dei modelli e le loro principali caratteristiche.

CONTESTO INDUSTRIALE

Caso d'uso e descrizione del processo. Questo lavoro è inquadrato all'interno del progetto EnerMIND, che mira a realizzare un pilota di un sistema di gestione dell'energia di nuova generazione per il monitoraggio del fabbisogno energetico dell'intera catena di produzione dell'acciaio elettrico e per l'ottimizzazione della programmazione dei processi attraverso strumenti di Machine Learning (ML), Industrial Internet of Things e tecnologie di comunicazione sicure, con l'obiettivo di ridurre al minimo il consumo di energia elettrica e diminuire i picchi di consumo. Lo scopo del progetto, dunque, è quello di sviluppare un sistema di supporto alle decisioni (Decision Support System, DSS) che aiuti operatori e manager dell'impianto nella gestione ottimale dei processi e l'ottimizzazione delle problematiche energetiche come il dispacciamento, l'acquisto dell'energia elettrica, la previsione, il monitoraggio e l'analisi dei sistemi. Il dimostratore EnerMIND mira, inoltre, a ridurre l'impronta ambientale del percorso siderurgico elettrico ottimizzando il consumo energetico. Il DSS è stato implementato nell'impianto Acciaierie Bertoli Safau d.o.o. (ABS), Sisak (Croazia), la cui configurazione dell'impianto è stata schematizzata e riportata in figura 1. L'impianto è composto da una linea di fusione basata sulla tecnologia del forno elettrico ad arco (EAF), dei processi di lavorazione in siviera (LF e VD) e infine un sistema di produzione basato sulla colata continua (CCM). Le maggiori variabilità del consumo di energia elettrica si riscontrano naturalmente principalmente nel processo EAF, il principale consumatore, e successivamente nel processo LF durante la lavorazione in siviera.




Fig.1 - Rappresentazione schematica dell'impianto ABS Sisak / *Schematic representation of ABS Sisak.*

MODELLAZIONE TRAMITE INTELLIGENZA ARTIFICIALE

Acquisizione e analisi dei dati. Nel contesto della modellazione attraverso reti neurali, i dati giocano indubbiamente un ruolo chiave. La qualità dei dati, il loro formato e la quantità richiesta sono dunque il primo requisito da prendere in considerazione durante la fase di modellazione dei processi. In questo caso studio, i dati disponibili sono di due tipologie: dati tabulari (dati di programmazione e produzione) e serie temporali (flussi di energia elettrica). I dati tabulari sono organizzati in funzione della colata, e il loro contenuto informativo descrive i flussi di materiali, le fasi di lavorazione e l'utilizzo dell'energia lungo il percorso di produzione, a partire dalla fase di carico del rottame nell'E-AF, passando per la colata dell'acciaio, il percorso della metallurgia secondaria e la fase di colata continua. Questi

dati, caratterizzati in modo *event-driven*¹, devono essere analizzati soprattutto per sincronizzarli con le serie temporali del consumo di energia, per rilevare dati mancanti e identificare valori anomali dovuti a inserimenti manuali o errori di misurazione (come le temperature di colata). L'elaborazione dei dati passa, dunque, attraverso una fase di identificazione e correzione dei cosiddetti *outliers*, attraverso l'analisi della distribuzione dei dati, ma anche utilizzando l'esperienza del personale esperto. Successivamente, per massimizzare l'accuratezza dei modelli, occorre eliminare le variabili ridondanti e selezionare quelle più significative. Il passo finale è quello di addestrare e valutare le prestazioni del modello. La figura 2 rappresenta schematicamente la procedura utilizzata.




Fig.2 - Algoritmo di selezione delle variabili significative / *Variable selection Algorithm*.

Le variabili ridondanti sono identificate utilizzando l'algoritmo Dominating Set (DSA) [1], un metodo derivato dalla teoria dei grafi. Due variabili sono considerate ridondanti se il loro coefficiente di correlazione lineare ρ è superiore a 0.95 e il p-value associato è inferiore a 0.05, secondo la teoria della correlazione di Pearson. Il DSA estrae il set dominante minimo del grafo: le variabili che non fanno parte di questo set sono considerate ridondanti. Successivamente,

sono state utilizzate e comparate tre diverse metodologie per la selezione delle variabili: *filter*, *wrapper* e *embedded* [2]. In particolare, nell'approccio *filter*, è stata utilizzata una combinazione tra correlazione lineare e l'algoritmo Relief [3]. Per il metodo *wrapper*, è stata eseguita la Sequential Forward Selection [4], mentre per il metodo *embedded* è stato sviluppato un albero decisionale [5]. La selezione finale delle variabili è stata effettuata

¹ Questo termine si riferisce a un modello di gestione dei dati che sottolinea l'importanza degli eventi specifici nel processo produttivo, in questo contesto, ogni azione significativa che avviene durante la produzione di acciaio. Questi dati aiutano a monitorare e coordinare le attività produttive, essenziali per l'analisi e l'ottimizzazione del processo.

identificando il set più efficace nel descrivere numericamente i processi. Per il processo EAF, le principali misure e grandezze di input acquisite sono presentate nella tabella 1. Per quanto riguarda l'LF, i dati raccolti, correlati con l'evoluzione energetica del processo, sono decisamente più

limitati: (I) peso iniziale della carica liquida, (II) la temperatura iniziale, (III) la qualità obiettivo dell'acciaio, e (IV) la quantità di ferroleghie totali da aggiungere. In questo caso specifico, i modelli non hanno richiesto alcuna selezione delle variabili.

Tab. 1 - Dati disponibili per l'EAF / Available data for the EAF.

	Nome Variabile		Nome Variabile		Nome Variabile
1	Qualità obiettivo di acciaio da produrre	9	Peso rottame caricato tipo "Demolizioni Speciali 8M"	17	Peso rottame caricato tipo "Recuperi NCD"
2	Consumo totale di gas	10	Peso rottame caricato tipo "Demolizione 6mm"	18	Peso rottame caricato tipo "Rottame Ghisa"
3	Consumo totale di O ₂	11	Peso rottame caricato tipo "Macinato"	19	Peso rottame caricato tipo "Ghisa"
4	Consumo totale di C	12	Peso rottame caricato tipo "Lingotti da recupero"	20	Peso rottame caricato tipo "Demolizione navale"
5	Peso totale del rottame caricato	13	Peso rottame caricato tipo "Demolizione leggero"	21	Peso rottame caricato tipo "Rottame fine nuovo"
6	Peso Carbone caricato in pani	14	Peso rottame caricato tipo "Tornitura"	22	Peso rottame caricato tipo "Profondo stampaggio sciolto"
7	Peso rottame caricato tipo "Fogli"	15	Peso rottame caricato tipo "Colaticci"	23	Peso rottame caricato tipo "Peridotto"
8	Peso rottame caricato tipo "Correttivo"	16	Peso rottame caricato tipo "Recuperi CD"	24	Peso ferroleghie aggiunte

Architettura Feed Forward Neural Network. In questa sezione vengono riportate e brevemente descritte le principali metodologie utilizzate durante la fase di modellazione. Lo scopo dei modelli è quello di prevedere il consumo di energia elettrica e le principali tempistiche dei processi principali, ovvero EAF e LF. Questi processi possono essere schedati in modo da livellare i picchi di consumo elettrico, diminuendo l'impatto economico della gestione della produzione. Per far ciò, in questo lavoro viene utilizzata una metodologia che mira a bilanciare l'accuratezza della simulazione del processo e il relativo costo computazionale, aspetti che spesso contrastano tra di loro. In aggiunta, la metodologia deve essere efficace nella modellazione di sistemi particolarmente comples-

si, spesso caratterizzati da comportamenti non lineari, e che spesso sono parzialmente inaccessibili e osservabili dal punto di vista delle misure dello stato. In questo contesto, l'architettura di modellazione scelta è basata sulle reti neurali di tipo Feed Forward (FFNN), che risulta una scelta efficace [6]. Per ciascun processo è stato addestrato un modello specializzato su una singola variabile obiettivo. In particolare, in questo lavoro vengono presentati 4 modelli, le cui variabili obiettivo sono riportate nella tabella 2. Ciascun modello è stato addestrato attraverso un insieme di misure e informazioni, risultato del processo di selezione delle variabili descritto nella sezione precedente e riportato nella stessa tabella.

Tab. 2 - Modelli di processo e variabili selezionate come ingressi dei modelli EAF / Process models and variables selected as inputs to the EAF models.

Processo	Modello	Variabile obiettivo	Variabili Selezionate
EAF	Modello 1	Potenza media consumata	1, 2, 3, 5, 8, 9, 11, 12, 17, 18, 22
	Modello 2	Durata processo di fusione	1, 2, 3, 4, 5, 9, 18, 23, 24
LF	Modello 3	Potenza media consumata	Tutte le variabili disponibili
	Modello 4	Durata processo	Tutte le variabili disponibili

L'addestramento delle FFNN può essere eseguito attraverso diversi algoritmi di ottimizzazione; tuttavia, l'attuale stato dell'arte per l'apprendimento supervisionato è l'algoritmo ADAM (Adaptive Moment Estimation) [7], che migliora lo standard degli algoritmi di *backpropagation* attraverso un'ottimizzazione stocastica e l'adattamento dei parametri dell'algoritmo in funzione dell'epoca di addestramento. Per tale ragione, questo algoritmo è stato scelto per la fase di apprendimento. In generale, l'accuratezza dei modelli numerici dipende dal rapporto tra il numero dei campioni di dati disponibili per l'apprendimento e il numero di parametri liberi del modello, oggetto dell'apprendimento. Il numero di parametri liberi di un modello FFNN dipende dal numero di strati nascosti del modello, e dal numero di neuroni presenti in ciascuno strato. Queste due caratteristiche del modello sono i principali iper-parametri del modello, che devono essere ottimizzati per ottenere il miglior compromesso tra complessità computazionale e accuratezza. Al momento, non esistono euristiche che permettano di identificare numericamente il miglior set di iper-parametri, e la loro ottimizzazione viene effettuata attraverso algoritmi *bayesiani*, oppure attraverso *grid* o *random search*. In questo lavoro, è stata utilizzata una ricerca basata su *grid search*, che ottimizza il

valore degli iperparametri minimizzando un indice di performance valutato sul dataset di validazione.

RISULTATI ADDESTRAMENTO RETI

In questa sezione vengono riportati i modelli sviluppati per i principali processi del caso di studio. Come precedentemente detto, ogni modello si concentra su un processo specifico e una specifica variabile obiettivo. La fase di addestramento di ciascun modello parte dai risultati della selezione delle variabili precedentemente riportati e si concentra sulla ricerca della migliore architettura, ottimizzando gli iperparametri di ciascun modello. Come precedentemente detto, la metodologia di ottimizzazione della struttura di ciascun modello si basa sulla *grid search*, con l'obiettivo di ottimizzare solo il numero di neuroni di una rete neurale con un singolo strato nascosto. Vista la natura stocastica dell'apprendimento, in cui ogni sessione di addestramento dipende dalla inizializzazione casuale dei pesi della rete, la *grid search* per una data griglia di neuroni, calcola 100 addestramenti per ogni architettura con l'obiettivo di minimizzare l'errore quadratico medio normalizzato (NRMSE) calcolato sul dataset di validazione, definito come:

$$NRMSE = 100 \cdot \frac{\sqrt{\frac{1}{N_c} \sum_{k=1}^{N_c} (y_p(k) - y_r(k))^2}}{std(y_r)} \quad (1)$$

dove N_c è il numero di campioni del dataset di validazione, y_p è l'uscita predetta dal modello, y_r è la variabile reale e $std(y_r)$ è la deviazione standard dell'intero dataset della variabile obiettivo.

Una volta addestrate 100 reti per ogni architettura, vengono calcolati i seguenti indici per identificare l'andamento medio e mediano delle prestazioni in funzione del numero di neuroni: errore assoluto medio (Mean Absolute Error, MAE), NRMSE, Massimo Errore Assoluto e Deviazione Standard.

I dati acquisiti per la modellazione, una volta ripuliti da *outliers* [8], vengono suddivisi in tre sottoinsiemi: il 60% per l'addestramento, il 20% per la validazione e il restante 20% per il test. Questa suddivisione viene effettuata utilizzando un metodo di clustering per garantire che i campio-

ni rari siano presenti in tutti i sottoinsiemi, considerando la distribuzione dei diversi target e mantenendo la stessa percentuale di dati in ciascun cluster. Per ciascun modello, i principali risultati in termini di MAE e deviazione standard sono riportati nelle figure 3, 4, 5 e 6 che rispettivamente riportano i due indici di performance valutati sul dataset di test, in funzione del numero di neuroni della rete per il modello 1, 2, 3 e 4. La rete ottima è stata selezionata per minimizzare la mediana del MAE e della deviazione standard. I risultati mostrati in figura mostrano alcuni comportamenti salienti. In primo luogo, la complessità ottima delle reti neurali (in termini di numero di neuroni) è sempre piuttosto limitata. Per ciascun modello, il numero di neuroni ottimo si attesta intorno alla decina di unità, ottime relativamente alla numerosità dei dataset utilizzati

nella fase di addestramento. L'accuratezza dei modelli è piuttosto soddisfacente ed è da considerarsi buona per il loro utilizzo all'interno del DSS sviluppato.




Fig.3 - Modello EAF, potenza media: (a) MAE in funzione del numero di neuroni, (b) Deviazione standard in funzione del numero di neuroni / *EAF model, mean power: (a) MAE in function of the number of neurons, (b) Standard deviation in function of the number of neurons.*




Fig.4 - Modello EAF, durata del processo di fusione. (a) MAE in funzione del numero di neuroni, (b) Deviazione standard in funzione del numero di neuroni / *EAF model, process duration. (a) MAE in function of the number of neurons, (b) Standard deviation in function of the number of neurons.*

CONCLUSIONI E SVILUPPI FUTURI

Sono stati presentati dei modelli per la predizione dei consumi di energia elettrica nei principali processi del ciclo elettrico di produzione dell'acciaio, progettati attraverso tecniche di AI, ossia reti neurali che, durante l'apprendimento, sfruttano in maniera efficace il contenuto informativo dei dati storici del processo. Questi modelli predico-

no l'energia elettrica media consumata per una specifica colata e la durata della colata a ogni passo della produzione. I modelli sono alimentati da dati relativi alla qualità obiettivo dell'acciaio, dalla ricetta dell'acciaio in termini di peso e della tipologia dei rottami utilizzati, e le temperature obiettivo a ciascun passo di produzione. I modelli vengono utilizzati all'interno di un sistema di ottimizza-

zione che permette di minimizzare l'impatto economico della produzione attraverso il livellamento del consumo di energia elettrica. I prossimi passi della sperimentazione prevedono i test dei modelli e del sistema di ottimizzazione sul campo e l'addestramento degli operatori per il loro utilizzo. Inoltre, al fine di migliorare le prestazioni

dell'intero sistema, si prevede di migliorare l'accuratezza dei modelli attraverso una più ampia raccolta di dati, sia in termini di quantità, sia in termini di numero di punti di misura utilizzati. Inoltre, si analizzerà la possibilità di ibridizzare le tecniche di modellazione basati sui dati attraverso considerazioni ed equazioni chimico/fisiche del sistema.




Fig.5 - Modello LF, potenza media: (a) MAE in funzione del numero di neuroni, (b) Deviazione standard in funzione del numero di neuroni / LF model, mean power: (a) MAE in function of the number of neurons, (b) Standard deviation in function of the number of neurons.




Fig.6 - Modello LF, durata del processo: (a) MAE in funzione del numero di neuroni, (b) Deviazione standard in funzione del numero di neuroni / EAF model, process duration: (a) MAE in function of the number of neurons, (b) Standard deviation in function of the number of neurons.

RINGRAZIAMENTI

Il lavoro descritto nel presente lavoro è stato sviluppato nell'ambito del progetto dal titolo "*Energy Management in the Era of Industry 4.0*" (EnerMIND GA 899345), finanziato dall'Unione Europea tramite il "Research Fund for Coal and Steel (RFCS)", che gli Autori ringraziano. La re-

sponsabilità esclusiva delle questioni trattate nel presente lavoro è degli autori; l'Unione Europea non è responsabile per l'uso che può essere fatto delle informazioni ivi contenute.

BIBLIOGRAFIA

- [1] J.A. Bondy, U. Murty, Graph Theory, ISBN 978-1-84628-969-9. Springer, 2008.
- [2] S. Cateni, V. Colla, M. Vannucci, A genetic algorithm-based approach for selecting input variables and setting relevant network parameters of a SOM-based classifier, International Journal of Simulation: Systems, Science and Technology, 12 (2), 30-37, 2011.
- [3] M. Robnik-Sikonja, I. Kononenko, Theoretical and empirical analysis of ReliefF and RReliefF. Machine Learning 53(1-2):23-69, 2003.
- [4] D. Ververidis, C. Kotropoulos, Sequential forward feature selection with low computational cost. 13th IEEE European Signal Processing Conference, 2005.
- [5] L. Breiman, J.H. Friedman, R.A. Olshen, C.J. Stone, Classification and Regression Trees. Wadsworth and Brooks, 1984.
- [6] H. Yu, B.M. Wilamowski, Levenberg-Marquardt training. In Intelligent system CRC Press, 2018.
- [7] D.P. Kingma, J. Ba Adam, A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.
- [8] S. Cateni, V. Colla, M. Vannucci, A fuzzy logic-based method for outliers detection, Proceedings of the IASTED International Conference on Artificial Intelligence and Applications, AIA 2007, 561-566, 2007.

EAF Steelmaking: AI applications for estimating energy consumption

Steel production through the electric cycle suffers from low diversification of energy supply sources and, with a view to efficiency and cost reduction, needs to be optimized on several aspects, among which production planning. Optimizing production costs means, for example, leveling out the electricity consumption along the day, whose prices may fluctuate in the short/medium term (varying on hour/daily basis) or if peak consumption exceeds a certain threshold. Production planning can, therefore, benefit from models predicting the energy consumed as a function of the quality of steel to be produced and the specific production recipe. These models can be effectively used by intelligent scheduling optimization systems. This paper presents a set of models based on neural networks that can predict with good accuracy the power consumption in the electric arc and ladle furnaces as a function of main production information. The models were trained and validated through real production and process data from a plant in Croatia with encouraging results.

KEYWORDS: EAF, LADLE FURNACE, PRODUCTION PLANNING, ARTIFICIAL INTELLIGENCE, ENERGY CONSUMPTION MODELS;

[TORNA ALL'INDICE >](#)