

MODELLAZIONE SURROGATA DI DISPOSITIVI ELETTROMAGNETICI

*Matteo Zorzetto, Giulio Poggiana, Francesco Lucchini, Riccardo Torchio, Michele Forzan,
Fabrizio Dughiero*

Università di Padova, Dipartimento di Ingegneria Industriale
Via Gradenigo 6/A, 35131 Padova, Italia

I modelli numerici rappresentano uno strumento essenziale per l'analisi e la progettazione di dispositivi elettromagnetici. Essi permettono di stimare grandezze fisiche che sarebbero altrimenti difficili, se non impossibili, da misurare sperimentalmente. Inoltre, consentono di evitare la realizzazione di prototipi fisici nelle fasi preliminari del progetto, con un conseguente risparmio significativo sia in termini di tempo che di costi. Tuttavia, quando tali simulazioni devono essere utilizzate in contesti che richiedono tempi di risposta rapidi, come nel caso di applicazioni in tempo reale o di ottimizzazioni parametriche, il costo computazionale può diventare estremamente elevato, fino a rappresentare un serio ostacolo alla loro applicabilità pratica.

Per superare queste limitazioni, sono state sviluppate tecniche di riduzione dell'ordine del modello (Model Order Reduction, MOR). Questi metodi permettono di semplificare drasticamente i modelli originali, pur mantenendo un livello di accuratezza sufficiente elevato. Le tecniche MOR si basano principalmente su trasformazioni e operazioni algebriche applicate alle matrici che descrivono il sistema fisico, come ad esempio la proiezione su spazi a bassa dimensionalità [1]. Negli ultimi anni, tali approcci stanno trovando un complemento sempre più efficace nell'impiego di tecniche di machine learning, che consentono di apprendere rappresentazioni surrogate del comportamento del sistema [2].

Queste tecniche possono essere impiegate per ricostruire il campo magnetico all'interno di un dispositivo, considerando la variazione di parametri di progetto, come la geometria o le condizioni di alimentazione, quali corrente e frequenza. L'approccio si articola in due fasi. Nella prima, viene utilizzato un modello ad alta fedeltà, come ad esempio un modello agli elementi finiti, per simulare il comportamento del sistema in corrispondenza di un insieme selezionato di configurazioni parametriche. Questa fase consente di acquisire una base di dati che descrive il sistema in modo dettagliato. Successivamente, nella seconda fase, vengono applicate tecniche di riduzione della dimensionalità, come la Proper Orthogonal Decomposition (POD), per proiettare i dati ottenuti in uno spazio a bassa dimensionalità, mantenendo solo le componenti essenziali del comportamento del sistema. Infine, modelli di machine learning vengono addestrati su questo spazio ridotto per interpolare in modo efficiente il campo magnetico anche per configurazioni parametriche non simulate esplicitamente, garantendo una ricostruzione rapida con un notevole risparmio computazionale.

Questa tecnica è stata applicata al modello del levitatore magnetico longitudinale in Figura 1. Il dispositivo è composto da due avvolgimenti collegati in parallelo che inducono correnti all'interno di una billetta di alluminio [3].




Fig 1: Linee di flusso del campo magnetico nella sezione dell'induttore longitudinale.

Il modello è stato simulato per un insieme di combinazioni parametriche composte da posizione e frequenza, monitorando la distribuzione della densità di corrente e del campo magnetico in direzione x ed y all'interno della billetta. Successivamente, la dimensionalità dei dati è stata ridotta ricostruendo con 30 variabili il valore della parte reale ed immaginaria delle tre quantità. La tecnica di Gaussian Process Regression (GPR) è stata impiegata per trovare una relazione fra le 30 variabili ed i tre parametri (frequenza, posizione x e posizione y), ottenendo un modello in grado di riprodurre con sufficiente fedeltà i campi di interesse come presentato in Figura 2. Da questi campi è poi stato possibile ottenere quantità macroscopiche quali la forza media agente sulla billetta.




Fig 2: Stima dell'induzione magnetica nella billetta e corrispettivo errore.

Bibliografia:

- [1] P. Benner *et al.*, *Model Order Reduction. Volume 1, System- and Data-Driven Methods and Algorithms*. in *Model Order Reduction* ; Volume 1. Berlin ; De Gruyter, 2021. doi: 10.1515/9783110498967.
- [2] R. Swischuk, L. Mainini, B. Peherstorfer, and K. Willcox, "Projection-based model reduction: Formulations for physics-based machine learning," *Computers & Fluids*, vol. 179, pp. 704–717, Jan. 2019, doi: 10.1016/j.compfluid.2018.07.021.
- [3] M. Zorzetto, R. Torchio, F. Lucchini, M. Forzan, and F. Dughiero, "Proper Orthogonal Decomposition for Parameterized Macromodeling of a Longitudinal Electromagnetic Levitator," *IEEE Transactions on Magnetics*, vol. 61, no. 4, pp. 1–7, Apr. 2025, doi: 10.1109/TMAG.2025.3542131.