

OTTIMIZZAZIONE PERSONALIZZATA DELLA STIMOLAZIONE MAGNETICA TRANSCRANICA MEDIANTE MOR E FRAMEWORK CVAE-CNN

M. Tucci¹, S. Barmada¹, S. Dodge¹, N. Fontana (Vice PI)¹, L. Di Rienzo², L. Codecasa², A. Pichiecchio³, G. Cosentino³, M. E. Mognaschi (PI)⁴

¹DESTEC Dipartimento di Ingegneria dell'Energia, dei Sistemi, del Territorio e delle Costruzioni, Università di Pisa, Largo Lucio Lazzarino 1, 56122 Pisa

²Dipartimento di Elettronica, Informazione e Bioingegneria – Sezione Elettrica, Politecnico di Milano
Piazza Leonardo da Vinci 32, 20133 Milano

³Department of Brain and Behavioral Sciences, University of Pavia, Pavia, Italy
IRCCS Mondino Foundation, Pavia, Italy

⁴Dipartimento di Ingegneria Industriale e dell'Informazione, Università degli Studi di Pavia
Via Ferrata 5, 27100 Pavia

Nel progetto PRIN “STEM-DEEP” collaboriamo con la Fondazione Mondino per ottimizzare la stimolazione magnetica transcranica (TMS) dell’area motoria che controlla la mano sinistra (regione “omega”). Su **27 pazienti** sottoposti a risonanza magnetica (MRI) puntiamo a evocare, in modo riproducibile, la contrazione del muscolo del pollice tramite un posizionamento preciso del coil. A partire dalle MRI craniche costruiamo, in collaborazione con l’Unità di Milano, un **modello elettromagnetico di ordine ridotto** (MOR) con un’accuratezza paragonabile al FEM e tempi di calcolo drasticamente inferiori. Il MOR serve a simulare la distribuzione del campo elettrico per **migliaia di configurazioni** del coil (passo 2 mm / 5°) in una mesh che comprende tutto il cervello, per una data posizione e orientamento del coil. Da queste simulazioni viene interpolata una griglia di punti centrata sulla regione “omega” del cervello, ottenendo immagini 2D (50 × 50 px) dell’intensità del campo elettrico nella corteccia, utilizzate per addestrare il framework di Deep Learning.

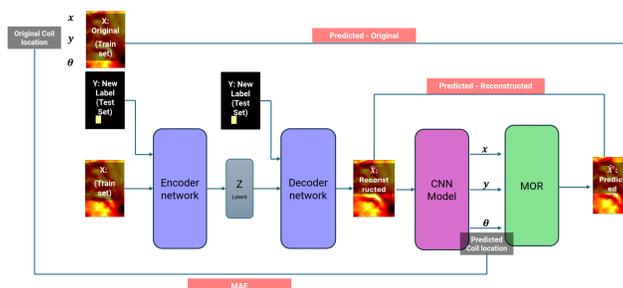


Figura 1. Configurazione di test, l’uscita viene verificata applicando nuovamente il MOR.

Il **framework di Deep Learning CVAE-CNN** opera in due stadi: 1. un **Conditional Variational Autoencoder (CVAE)** come modello generativo che sintetizza campi a partire dal valore in una specifica regione di interesse. Esso viene alimentato in ingresso con le coordinate della posizione desiderata (nell’area della regione “omega”) di massima eccitazione; 2. una **Convolutional Neural Network (CNN)** come modello discriminativo che risolve il problema inverso. Essa viene addestrata sul dataset simulato con il MOR e restituisce posizione (x, y, z) e orientamento (α) del coil, data la distribuzione di campo elettrico indotto. Nella fase di inferenza è alimentata dall’uscita del CVAE. Stiamo valutando la

robustezza della pipeline con diversi split dei dati, che sono stati generati con il MOR sia su una griglia random che uniforme di posizioni del coil. La tabella 1 mostra alcuni risultati preliminari per uno dei pazienti. Le tabelle successive mostrano i modelli del CVAE e della CNN. Il framework **ROM-CVAE-CNN** promette di fornire in tempo reale parametri di stimolazione personalizzati, riducendo il trial-and-error clinico.

Tabella 1

Modalità train set	Modalità test set	MAE x	MAE y	MAE α	MAPE(P-O) %	MAPE(P-R) %
Random	Random	1.58	5.22	3.71	3.49	2.70
Uniforme	Random	1.49	4.36	3.64	2.85	1.79
Random	Uniforme	1.40	5.45	4.34	2.86	1.94

Modello della CNN

Layer No.	Layer Type	Parameters
1	Input Layer	Input size: $[50 \times 50 \times 1]$
2	Conv2D	Filter size: 3×3 , Filters: 8, Padding: same
3	Batch Normalization	–
4	ReLU Activation	–
5	Max Pooling	Pool size: 2×2 , Stride: 2
6	Conv2D	Filter size: 3×3 , Filters: 16, Padding: same
7	Batch Normalization	–
8	ReLU Activation	–
9	Max Pooling	Pool size: 2×2 , Stride: 2
10	Dropout	Dropout rate: 0.3
11	Global Avg Pooling 2D	–
12	Fully Connected Layer	Output size: 3
13	Regression Layer	–

Encoder del CVAE

Layer Type	Details
Image Input Layer	
Label Input Layer	
Concatenation Layer	concatenationLayer(3, 2, 'Name', 'cat')
Conv Layer 1	6×6 , 16 filters, stride 1, padding 'same'
Batch Normalization	
ReLU Activation	
Max Pooling 1	2×2 , stride 2
Conv Layer 2	3×3 , 32 filters, stride 1, padding 'same'
Batch Normalization	
ReLU Activation	
Max Pooling 2	2×2 , stride 2
Conv Layer 3	3×3 , 64 filters, stride 1, padding 'same'
Batch Normalization	
ReLU Activation	
Fully Connected Layer	Outputs $2 \times \text{latentDim}$ values

Decoder del CVAE

Layer Type	Details
Latent Input Layer	imageInputLayer([1 1 latentDim], 'z')
Label Input Layer	imageInputLayer([1 1 prod(imageSize)], 'labels')
Concatenation Layer	concatenationLayer(3, 2, 'Name', 'cat')
Transposed Conv Layer 1	3×3 , 64 filters, stride 2, cropping 'same'
ReLU Activation	
Transposed Conv Layer 2	5×5 , 32 filters, stride 5, cropping 'same'
ReLU Activation	
Transposed Conv Layer 3	10×10 , 16 filters, stride 5, cropping 'same'
ReLU Activation	
Transposed Conv Layer 4	3×3 , 8 filters, stride 1, cropping 'same'
ReLU Activation	
Output Conv Layer	3×3 , 1 filter, stride 1, cropping 'same'

[1] Barmada, S., Barba, P.D., Fontana, N., Mognaschi, M.E. and Tucci, M., 2023. Electromagnetic Field Reconstruction and Source Identification Using Conditional Variational Autoencoder and CNN. IEEE Journal on Multiscale and Multiphysics Computational Techniques, 8, pp.322-331.

Ringraziamenti: This work is supported by the European Union’s Next Generation EU program through the Italian PRIN 2022 - Missione 4 Component 2, Investment 1.1 - grant n. 2022P8YKIJ - CUP F53D23000660006 - project “STEM-DEEP Stochastic electromagnetic modeling and deep learning for an effective and personalized transcranial magnetic stimulation”.