

## Progetto di ricerca: Learning Networks

Le tecniche di apprendimento automatico si sono sviluppate negli ultimi anni ad una velocità vertiginosa. La versatilità delle reti neurali è risultata determinante in un numero elevato di applicazioni scientifiche che vanno dallo studio del linguaggio [1] fino alla classificazione delle galassie [2]. Emergono, inoltre, sempre più evidenze che il funzionamento delle Neural Network sia governato da principi simili a quelli che regolano l'apprendimento umano [3]. Ciò nonostante, il numero elevatissimo di parametri necessario per un efficiente addestramento ne ostacola l'applicabilità.

### Lavoro di Tesi

L'indagine dei principi che sottendono al funzionamento delle reti neurali è una sfida interdisciplinare ed è stata il punto di partenza per il mio lavoro di tesi. Mi sono in particolare concentrato sul funzionamento e sullo sviluppo di reti neurali capaci di categorizzare i dati in ingresso.

È stata sviluppata un'innovativa tecnica di addestramento delle Neural Network che permette di raggiungere un'accuracy nel riconoscimento delle cifre da 0 a 9 (database *MNIST*) scritte a mano di circa 98%. Questo risultato, confrontabile con quello che è lo stato dell'arte delle reti feedforward (connessioni unidirezionali da un layer di nodi sconnessi verso il successivo), è il risultato di una procedura di apprendimento che agisce sullo spettro della matrice di trasferimento fra layer adiacenti. Ottimizzando lo spettro dell'operatore di trasferimento, ovvero gli autovalori e autovettori ad esso associati, è possibile addestrare simultaneamente più connessioni fra quelle implicate nel passaggio da un layer verso il successivo fino ai nodi di riconoscimento finali.

Iterando l'applicazione di questi operatori si hanno, quindi, tante matrici di trasferimento quanti layer nella Neural Network. Applicando una funzione non lineare ad ogni trasferimento fra un layer e il successivo si ottiene una composizione di operatori che opera nella stessa modalità di una Neural Network feedforward. Il dato in ingresso diviene un vettore le cui componenti, che variano con la progressiva applicazione degli operatori, costituiscono l'attivazione dei vari nodi in sinergia con il flusso dell'informazione verso i nodi di riconoscimento.

La base degli autovettori utilizzata è strutturata in modo che, grazie alla non ortogonalità dei propri elementi, favorisca un progressivo embedding dei dati dallo spazio di ingresso verso quello dei nodi di riconoscimento. Questa tecnica è stata testata nel contesto descritto e ha prodotto una significativa riduzione dei parametri di apprendimento, a fronte di performance sostanzialmente analoghe dell'algorithm di riconoscimento. Chiamiamo, infatti,  $\rho$  il rapporto fra i parametri liberi nel nostro schema di ragionamento e quelli utilizzati con una NN (equivalente) addestrata con le usuali tecniche di apprendimento. In Fig1 il rapporto fra le performance delle rete neurali allenate con i due approcci sopra ricordati (spettrale vs. ordinario) è rappresentato in funzione di  $\rho$ . Con  $\rho=0.1$ , ovvero con il 10% dei parametri utilizzati negli schemi ordinari si ottengono, con l'approccio spettrale, reti che hanno capacità di classificazioni sostanzialmente analoghe a quelle ottenute con i metodi classici.

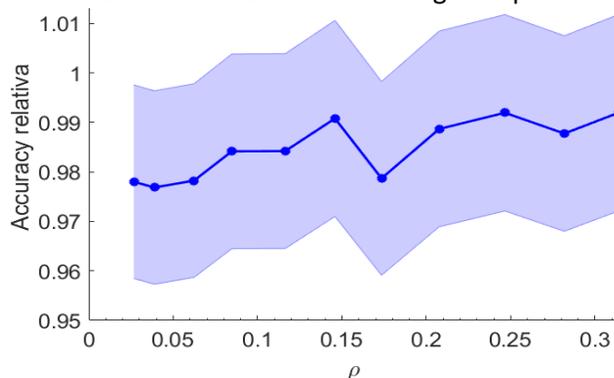


Fig1. Rapporto fra l'accuracy ottenuta con l'addestramento della rete neurale standard e quello basato sullo spazio reciproco. Figura presa da : L. Giambagli et al. "Machine learning in spectral domain" (2020) [4]

Come ulteriore direzione di indagine siamo partiti dal precedente schema di ragionamento, ed abbiamo inserito una dinamica di tipo attivatore inibitore in ogni nodo. Lavorando in approssimazione lineare si ottiene un operatore di trasferimento, che, agendo nello spazio dei modi della rete, è capace di trasferire l'attività dai nodi di ingresso verso quelli di riconoscimento. È stato possibile integrare nel processo di learning il suddetto operatore addestrando simultaneamente la struttura della rete sulla quale fluisce la dinamica e i parametri di reazione. Anche per questo caso i risultati sono stati promettenti. Abbiamo, infatti, ottenuto reti dinamiche (e non più statiche come negli schemi ordinari) che riconoscono le cifre del database MNIST con un accuracy di poco inferiore a quella realizzata dalla rete neurale.

## Sviluppi

Durante il lavoro di tesi sono state gettate le basi per un percorso di dottorato che sarà strutturato secondo le seguenti direttrici:

- Utilizzo di **dataset di complessità superiore** rispetto a quello MNIST.  
I promettenti risultati nel riconoscimento hanno un'estensione naturale nell'utilizzo del metodo di apprendimento per la discriminazione di dati come immagini o dati numerici più complessi.
- Lo sviluppo della tecnica di **learning spettrale all'interno di topologie non feedforward** della rete neurale.  
Si integreranno connessioni ricorrenti all'interno dei vari layer lavorando sulla decomposizione spettrale dell'operatore di trasferimento. L'indagine delle caratteristiche delle reti al termine dell'addestramento offre la possibilità di indagare la specificità dell'efficacia delle varie strutture (a imbuto, a rombo ecc...) di connessione.
- L'integrazione di **effetti di memoria** a breve termine nel processo.  
Intervallando agli operatori di trasferimento moduli capaci di memorizzare lo stato di attivazione dei propri nodi sarà possibile categorizzare dati costituiti da serie temporali. Per assolvere questo compito si farà uso dei moduli sviluppati nell'ambito delle reti neurali ricorrenti (LSTM) che saranno testati su un dataset costituito da serie temporali di un random walk classico e quantistico su reticolo .
- L'estensione della tecnica in ambito quantistico (in collaborazione con il gruppo di F. Caruso).
- Indagine e sfruttamento del **regime non lineare** del processo di apprendimento che fa uso **della dinamica** attivatore inibitore.  
Nel lavoro di tesi si è discusso un approccio generalizzato all'apprendimento che tiene conto della dinamica temporale su ogni nodo della rete. Lo studio ed i conseguenti algoritmi di apprendimento operano però nel regime lineare della dinamica. Estendere la dinamica nel regime non lineare sarà una direzione capace di aprire nuovi e interessanti scenari come l'utilizzo di tutte le regioni della rete nella fase di riconoscimento.

## References

- [1] Y. Goldberg, Neural Network Methods for Language Processing, 2017.
- [2] N. Khalifa, M. Taha et al, "Deep Galaxy: Classification of Galaxies based on," 2019.
- [3] A.Santoro, P. T. Lillicrap et al., "Backpropagation and the brain," *Nature Reviews Neuroscience*, 2020.
- [4] L.Giambagli, D.Fanelli et al., "Machine Learning in spectral domain".<https://arxiv.org/abs/2005.14436>.