

APPRENDIMENTO SUPERVISIONATO CON ESTRAZIONE QUASI-CASUALE DI DESCRITTORI

Danilo Comminiello, Raffaele Parisi, Simone Scardapane, Michele Scarpiniti, Aurelio Uncini

Dipartimento di Ingegneria dell'Informazione, Elettronica e Telecomunicazioni (DIET)
"Sapienza" Università di Roma
Via Eudossiana 18, 00184 Roma

Parole chiave: Reti neurali, apprendimento supervisionato, extreme learning machine

L'apprendimento supervisionato è un approccio *data-driven* per l'estrazione automatica di modelli a partire da un insieme di dati [1]. Esempi di possibili applicazioni includono il rilevamento delle email indesiderate, la classificazione dei segnali musicali, e la predizione di serie temporali. Con l'espressione "*apprendimento su larga scala*" si denotano tutte le applicazioni in cui la quantità di dati elaborata dal sistema è tale per cui gli algoritmi classici, quali ad esempio le reti neurali allenate tramite algoritmi di discesa al gradiente, incontrano limiti prestazionali in termini di memoria occupata e/o tempo di calcolo [2].

Le due possibili soluzioni a questo problema sono lo sviluppo di algoritmi di apprendimento distribuito, o in alternativa lo sviluppo di modelli che siano specialmente progettati per scalare in maniera adeguata a quantità di dati sempre maggiori. A quest'ultima classe appartengono i modelli che eseguono un passo detto di "*randomized feature extraction*", ovvero sfruttano una procedura di randomizzazione interna che trasforma il problema originale di apprendimento (che si formula tipicamente in termini di un problema di ottimizzazione altamente non-lineare) in un problema più semplice, che possa essere risolto con tecniche maggiormente scalabili (es., un problema di regressione lineare). A questa categoria appartengono i modelli delle *Extreme Learning Machine* (ELM) [3], delle *Echo State Network* (ESN) [4], ed altri. Un esempio di ELM è mostrata in Fig. 1, in cui si può vedere come l'input viene proiettato in uno spazio di rappresentazione intermedio, generato tramite una serie di funzioni denotate come $h_1(x), \dots, h_L(x)$. La particolarità rispetto ad altri modelli di reti neurali, che non viene evidenziata dalla Figura 1, è che i parametri di tali funzioni vengono scelti in maniera pseudo-casuale.




Figura 1. Esempio di architettura di una *Extreme Learning Machine*. Immagine tratta da [5].

La ricerca in corso presso l'Università di Roma "La Sapienza" riguarda lo studio approfondito di tali modelli, sia da un punto di vista teorico che da un punto di vista implementativo, volto allo sviluppo di tecniche che, pur ritenendo la scalabilità descritta precedentemente, possano essere applicate in contesti realistici ed in maniera flessibile. Ad esempio, viene mostrato nella Tabella 1 un sottoinsieme dei risultati presentati in [5], dove una ELM ha mostrato accuratezza e tempi di allenamento significativamente migliori rispetto ad una rete neurale allenata in maniera classica su un diversi problemi di classificazione di segnali audio.

Dataset	Rete Neurale Classica	ELM
Dortmund	48 % (3.59 secs.)	54 % (0.54 secs.)
LMD	60 % (16.05 secs.)	60 % (0.27 secs.)
Decade Recognition (UCI)	61 % (45.74 secs.)	62 % (9.95 secs.)

Tabella 1. Prestazioni (in termini di accuratezza di classificazione e tempo di apprendimento) su tre benchmark di classificazione musicale, estratti da [5].

Altri esempi di tematiche affrontate in questo contesto sono lo sviluppo di modelli “trasduttivi” di apprendimento basati sulle ELM [6], di algoritmi di apprendimento che possano operare su un flusso continuo di dati in maniera efficiente [7], e di implementazioni che sfruttino in maniera ibrida le capacità combinate di CPU/GPU [8]. A tal proposito, viene mostrato in Figura 2 un esempio di guadagno prestazionale (in termini di tempo di allenamento) eseguendo parte dell’algoritmo di apprendimento di una ELM e di una rete neurale su due diversi modelli di GPU.




Figura 2. Prestazioni (in termini di tempo di apprendimento) per implementazioni su CPU e ibride CPU/GPU. L’immagine è tratta da [8].

BIBLIOGRAFIA

1. Alpaydin, E. (2004). *Introduction to machine learning*. MIT press.
2. Bottou, L., & Bousquet, O. (2007). *The Tradeoffs of Large Scale Learning*. In NIPS (Vol. 4, p. 2).
3. Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2012). *Extreme learning machine for regression and multiclass classification*. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 42(2), 513-529.
4. Lukoševičius, M., & Jaeger, H. (2009). *Reservoir computing approaches to recurrent neural network training*. Computer Science Review, 3(3), 127-149.
5. Scardapane, S., Comminiello, D., Scarpiniti, M., & Uncini, A. (2013, September). *Music classification using extreme learning machines*. In 2013 8th International Symposium on Image and Signal Processing and Analysis (ISPA), (pp. 377-381). IEEE.
6. Scardapane, S., Comminiello, D., Scarpiniti, M., & Uncini, A. (2014). *A Preliminary Study on Transductive Extreme Learning Machines*. In Recent Advances of Neural Network Models and Applications (pp. 25-32). Springer International Publishing.
7. Scardapane, S., Comminiello, D., Scarpiniti, M., & Uncini, A. (2014). *Online Sequential Extreme Learning Machine with Kernels*, submitted to IEEE Transactions on Neural Networks and Learning Systems (IEEE).
8. Scardapane, S., Comminiello, D., Scarpiniti, M., & Uncini, A. (2014). *Designing Large Machine Learning Simulations Using the Lynx Toolbox*, submitted to International Journal on Artificial Intelligence Tools (World Scientific).