

Pietro Mastro^{*a}, Guido Masiello^a, Antonio Pepe^b, Domenico Cimini^c, Filomena Romano^c, Elisabetta Ricciardelli^c, Carmine Serio^a

^aUniversità degli Studi della Basilicata, Scuola di Ingegneria, Potenza, Italia, 85100;

^bConsiglio Nazionale delle Ricerche, Istituto per il Rilevamento Elettromagnetico dell'Ambiente (CNR-IREA), 80124, Napoli, Italia

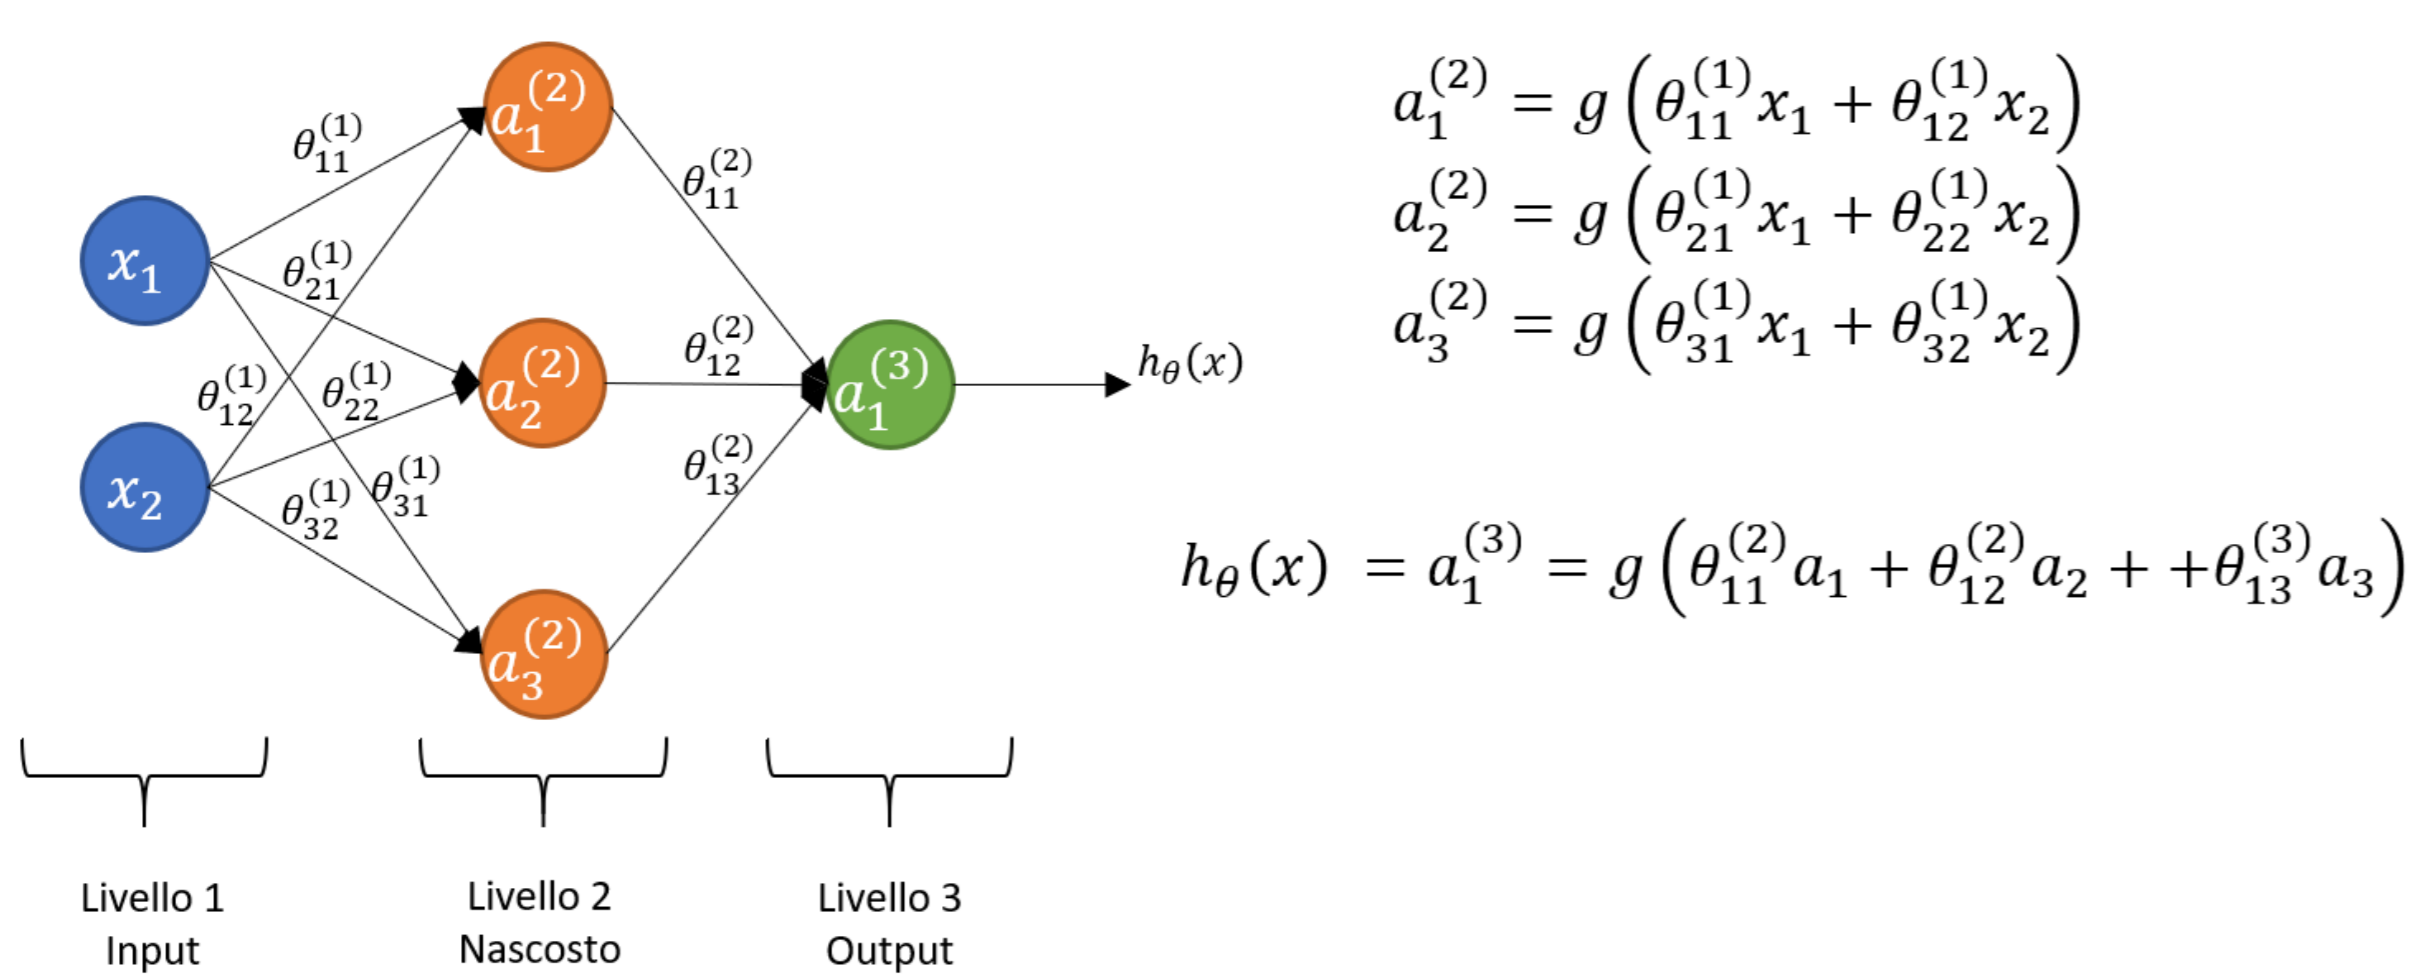
^cConsiglio Nazionale delle Ricerche, Istituto di Metodologie per l'Analisi Ambientale (CNR-IMAA), 85050, Tito, Italia

Introduzione e obiettivi

I parametri microfisici delle nubi influenzano direttamente il bilancio radiativo del sistema terrestre ed influiscono sulla stima indiretta di altri parametri geofisici come i gas serra, gli aerosol e la temperatura superficiale da misure acquisite da sensori per il telerilevamento ambientale. Per tale motivo, sin dai primi anni della meteorologia satellitare, l'analisi e lo studio delle caratteristiche delle nubi mediante dati di tipo ambientale rappresenta un passo significativo, soprattutto nel caso di misurazioni acquisite da sensori operanti nelle bande delle microonde e dell'infrarosso. La nuova generazione di sensori satellitari ad alta risoluzione spaziale e spettrale quali ad esempio i) l'Infrared Atmospheric Sounding Interferometer-New Generation (IASI-NG) e ii) il Microwave Sounder (MWS) promuovono stime più accurate dei parametri microfisici delle nubi, permettendo di indagare in maniera più rilevante il modo in cui le nubi influenzano il ciclo idrologico e le componenti radiative del sistema climatico terrestre. A tal proposito, questo lavoro indaga la capacità di stimatori statistici, implementati attraverso l'utilizzo di reti neurali "feed-forward" multistrato, di ricavare, a partire dalla combinazione di simulazioni dei sensori IASI-NG e MWS alcune tra le seguenti variabili chiave delle nubi, quali: i) i profili verticali del contenuto di acqua liquida ("cloud liquid water content" (CLWC)) e ghiacciata ("cloud ice water content" (CIWC)) delle nubi, ii) i loro valori integrati nelle colonne d'aria ("cloud liquid water path" (CLWP) e "cloud ice water path" (CLWP)), nonché il raggio effettivo di rilascio della nube ("cloud drop effective radius" r_e).

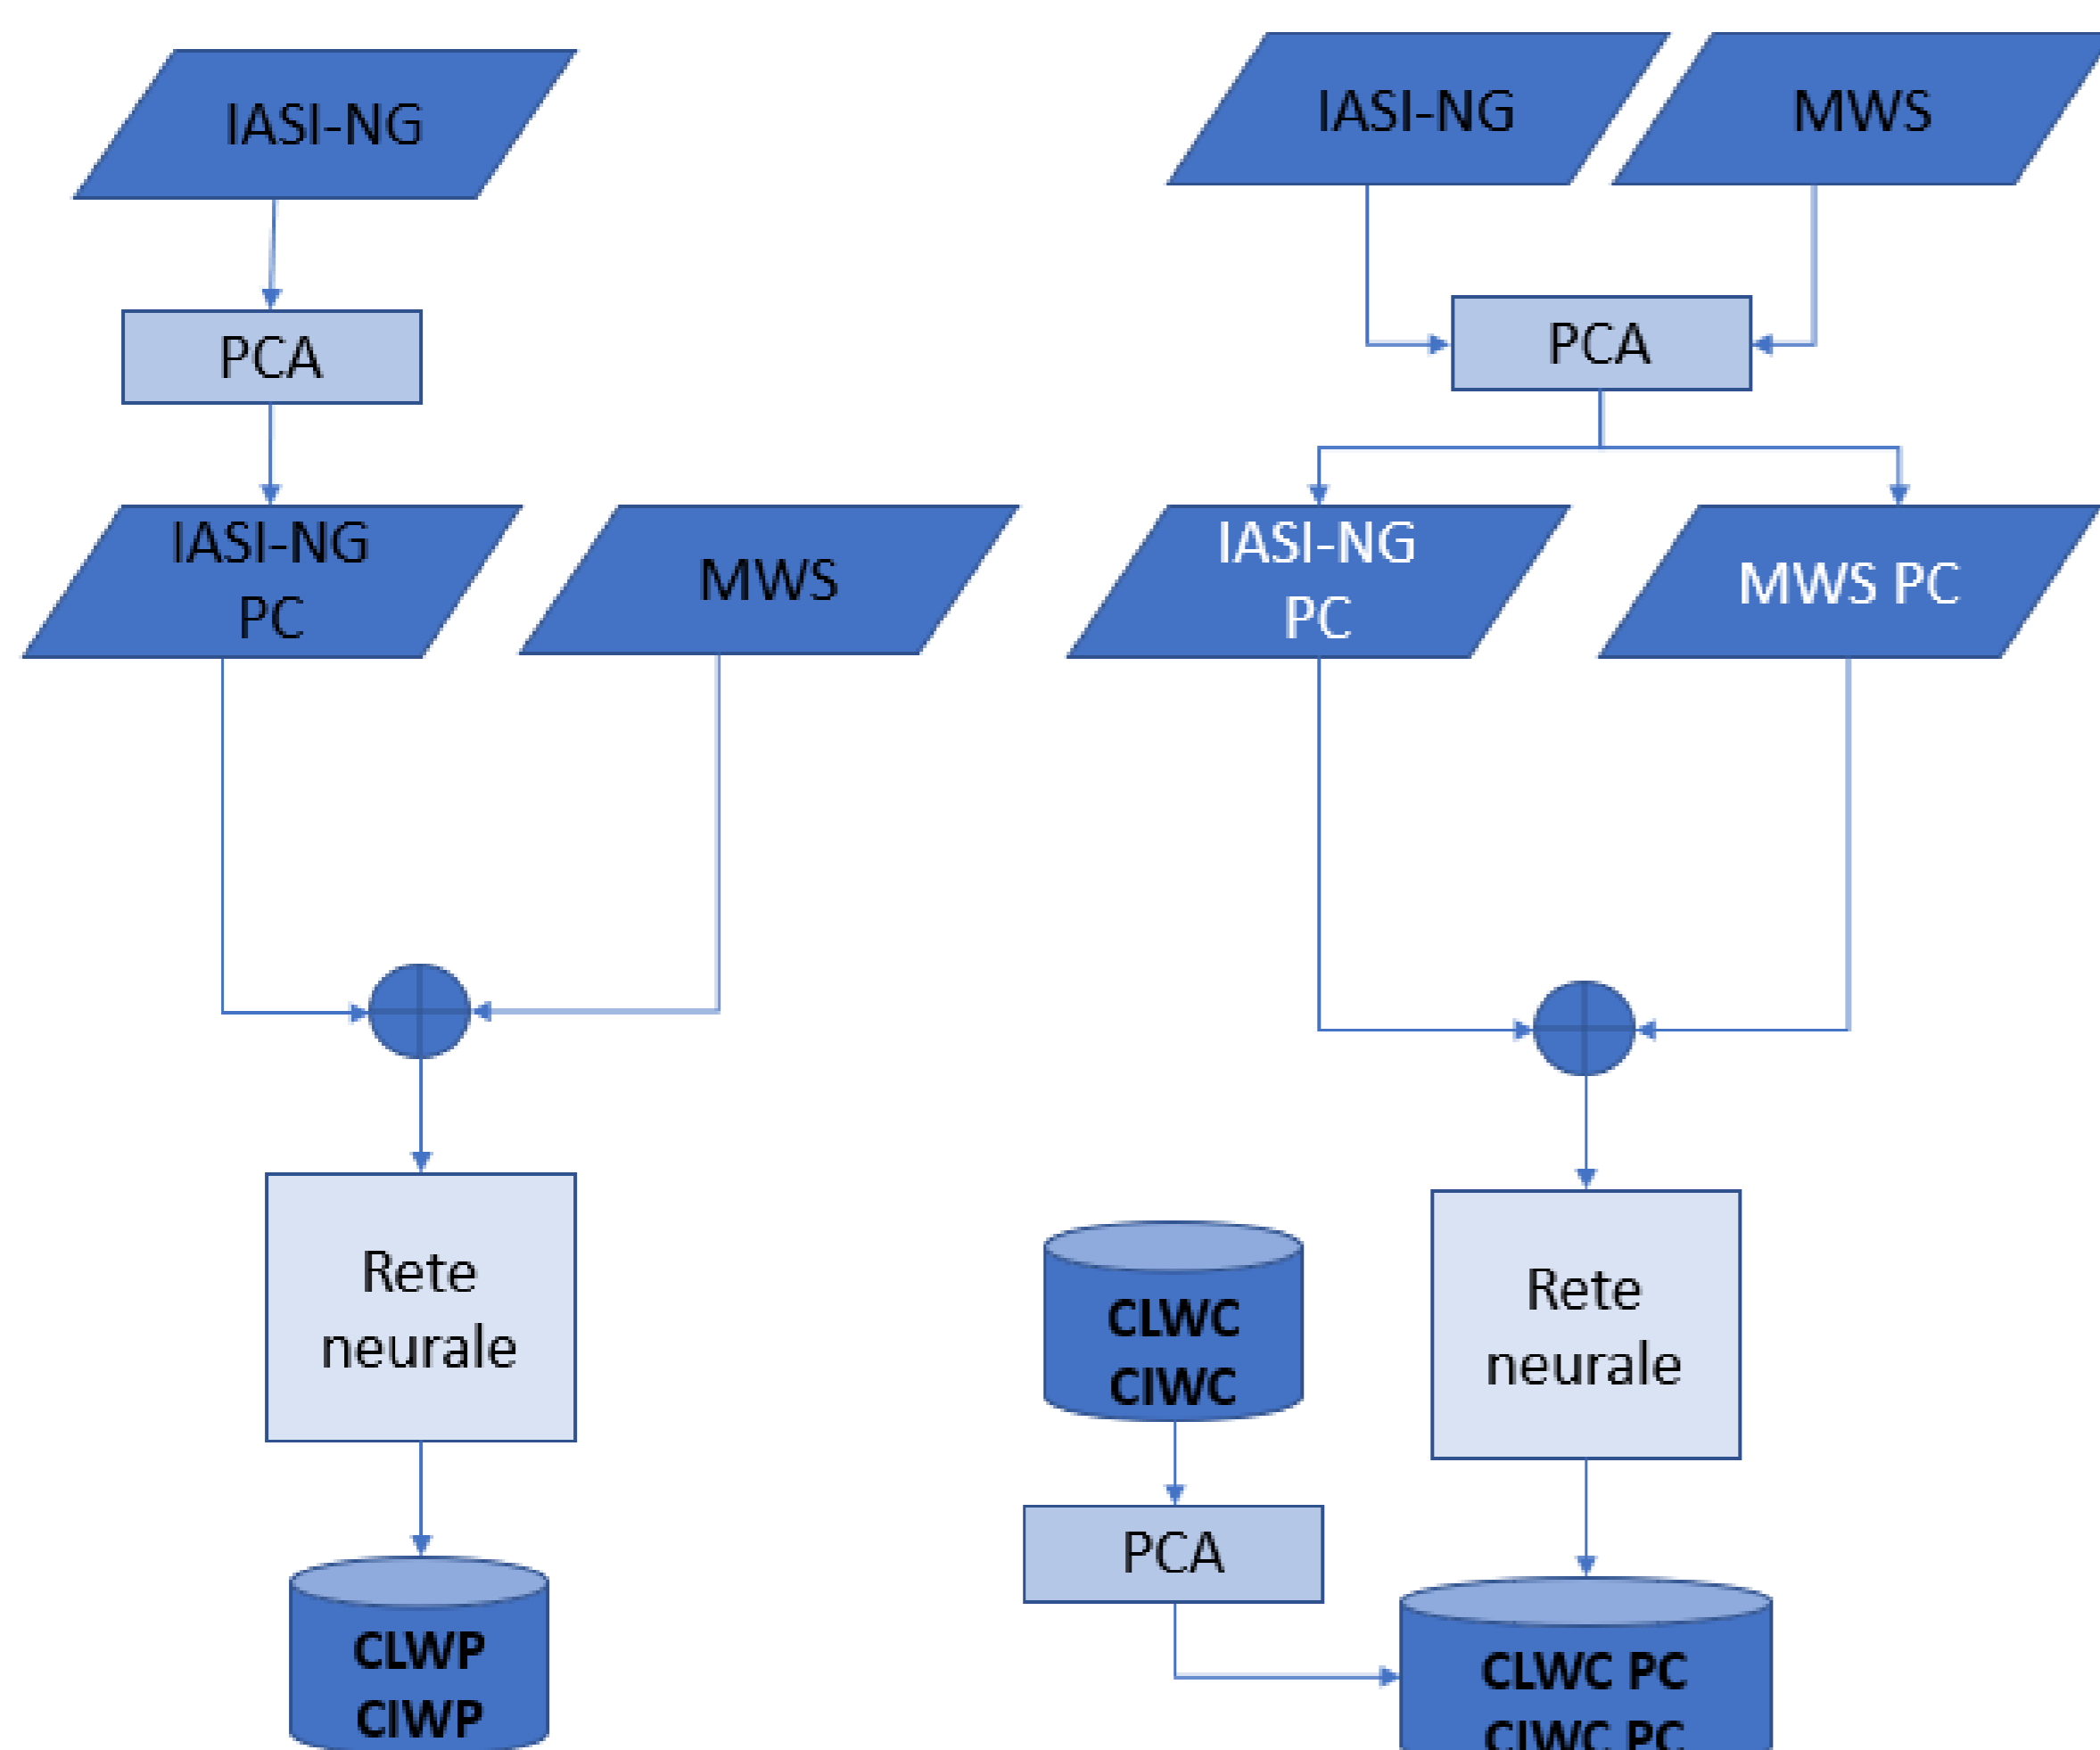
Reti neurali «feed-forward»

Negli ultimi decenni, grazie alla presenza di sistemi di calcolo più potenti, le reti neurali sono state utilizzate sempre più come strumento per l'analisi e la soluzione di problemi in diversi ambiti della scienza [1], tra questi anche quello del telerilevamento ambientale. Generalmente, una rete neurale può essere intesa come una struttura non lineare di dati statistici il cui modello di calcolo è basato sulle reti neurali biologiche [1]. Analogamente a queste ultime, una rete neurale artificiale riceve segnali esterni su uno strato di nodi di input x , ciascuno dei quali è collegato a sua volta con numerosi nodi interni a , organizzati su uno o più livelli. Ogni nodo interno delle reti neurali elabora i segnali ricevuti mediante una funzione di attivazione g , trasmettendo il risultato ai nodi successivi. L'addestramento della rete neurale avviene attraverso l'utilizzo di un algoritmo di ottimizzazione di «forward-/back-propagation» [1-2] che mediante la minimizzazione di una funzione di costo permette di aggiornare iterativamente, man mano che la rete viene sollecitata da nuovi input, i parametri liberi θ del modello neurale, permettendo di ottenere risultati di output sempre più accurati.



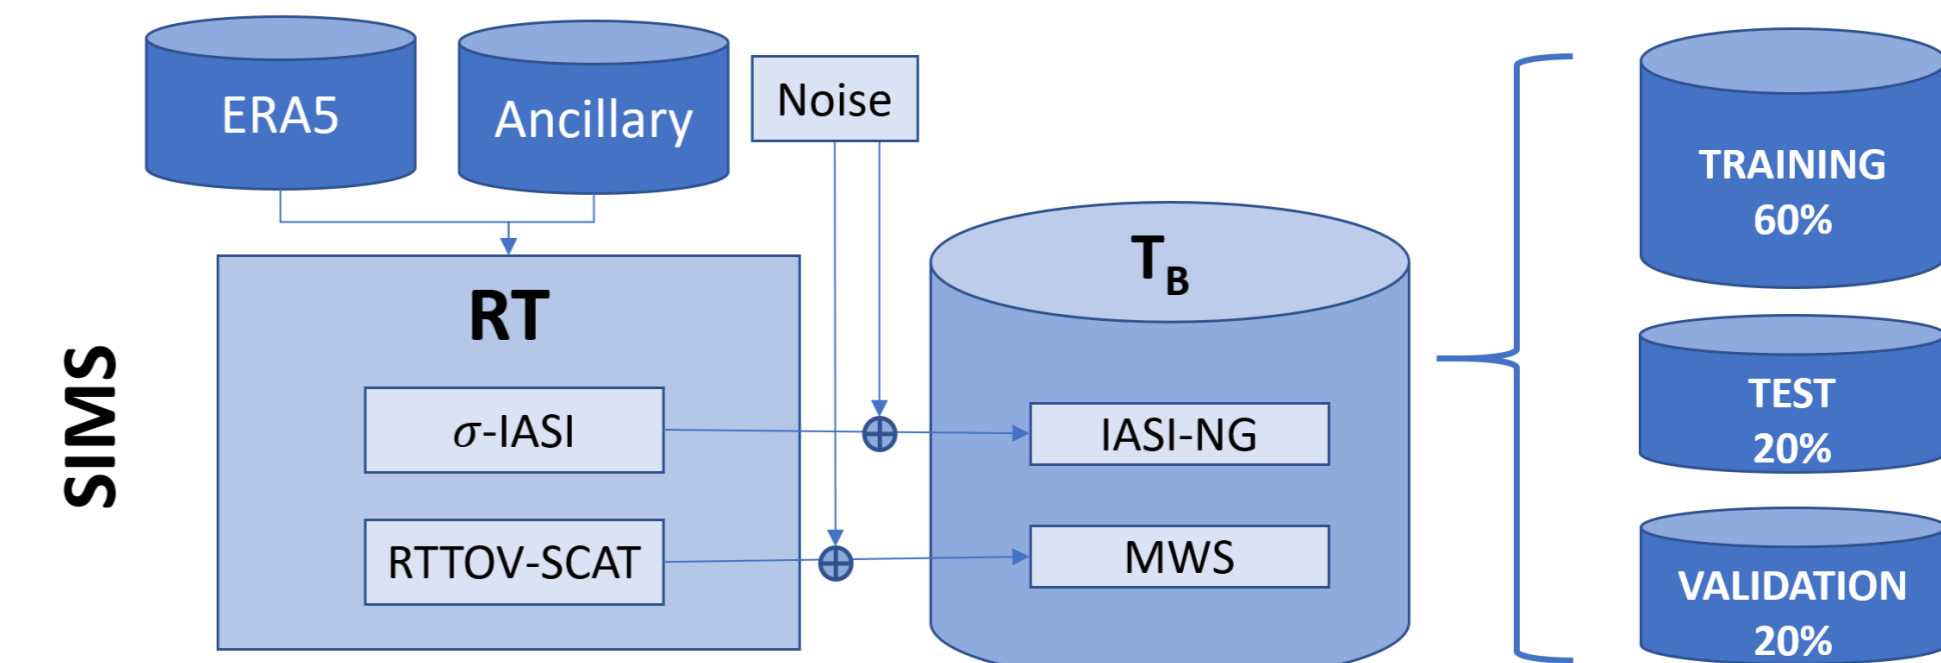
Metodologia di regressione

In questo lavoro, in aggiunta all'utilizzo dei modelli neurali, lo schema di regressione è stato basato sull'analisi delle componenti principali [3] degli input e degli output utilizzati dalle reti con il duplice obiettivo di estrarre da essi le informazioni più significative e di ridurre la complessità delle predizioni da effettuare. Nello specifico, ciò ha portato alla determinazione di due distinti modelli di regressione dei contenuti integrati e colonnari di acqua liquida e ghiacciata delle nubi. Nel primo caso, l'analisi delle componenti principali è stata effettuata soltanto sugli input della rete, ovvero sulla combinazione dei canali di MWS e di IASI-NG. Nel secondo caso, l'analisi delle componenti principali è stata effettuata anche sugli output, ovvero sono state determinate le componenti principali più significative dei contenuti colonnari di acqua liquida e ghiacciata delle nubi.



Dati MWS e IASI-NG

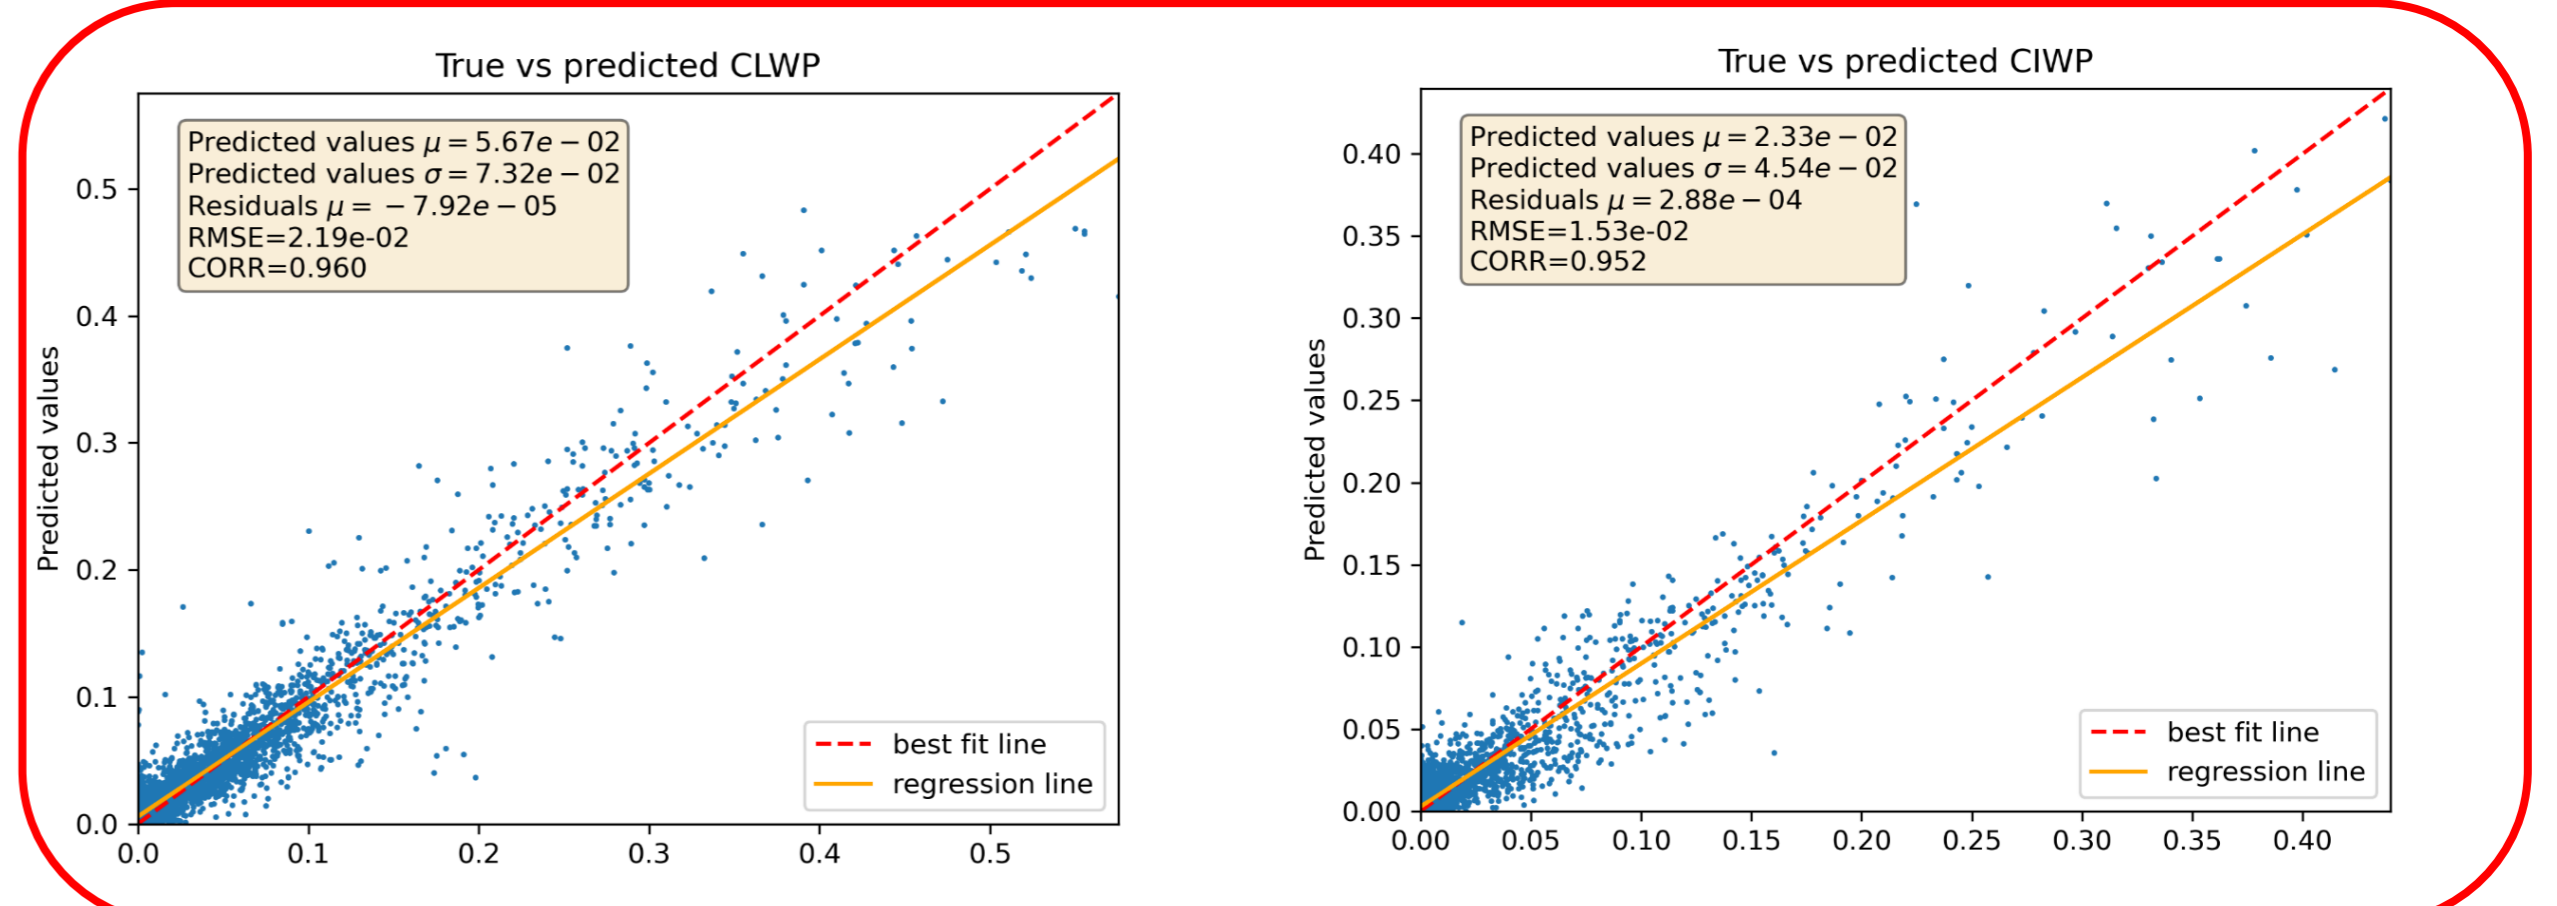
I dataset di misurazioni MWS e IASI-NG sono stati simulati mediante l'utilizzo degli algoritmi stato dell'arte RTTOV [4] e σ -IASI [5], e di informazioni ancillari da parte dell'ECMWF riguardanti il «vettore di stato» dell'atmosfera terrestre. Nello specifico, per entrambi i sensori l'angolo di acquisizione è stato posto al Nadir e al fine di avere una copertura ottimale e rappresentativa della variabilità dei dati, le misurazioni MWS e IASI-NG sono state simulate spazialmente su una griglia regolare di risoluzione $0.125^\circ \times 0.125^\circ$ su tutte le latitudini e longitudini e temporalmente su quattro orari di acquisizione (00:00,06:00,12:00,18:00), relativi al primo giorno dei mesi di Gennaio, Aprile, Luglio e Ottobre del 2019. Successivamente, sono state estratte le misure acquisite soltanto su mare. Infine, per un addestramento ottimale dei modelli neurali, i dataset generati sono stati suddivisi in tre dataset distinti. Il 60% è stato utilizzato per la fase di apprendimento, mentre il restante 40% per le fasi di validazione e test.




Risultati

Per la predizione dei contenuti integrati CLWP e CIWP è stato sviluppato un modello neurale composto da 5 livelli. Nel livello di input la rete utilizza le informazioni combinate di 24 canali MWS e delle prime 15 componenti principali dei canali IASI-NG mentre nel livello di output la rete fornisce mediante due unità le predizioni sui due contenuti integrati. Nei tre strati nascosti ogni unità utilizza una funzione di attivazione **tangente iperbolica**, mentre la funzione di costo utilizzata dalla rete è l'errore quadratico medio (**MSE**). Per le predizioni dei contenuti colonnari di acqua liquida e ghiacciata delle nubi, sono state sviluppati due modelli neurali. Entrambe le reti sono composte da una decina di strati nascosti in cui ogni unità utilizza la funzione di attivazione **ReLU**. Nel caso delle predizioni di CLWC, il modello neurale prende in input le prime 10 componenti principali dei canali MWS, mentre nel caso delle predizioni di CIWC la rete prende in input una combinazione di 10 componenti principali dei canali di MWS e 15 dei canali di IASI-NG. Infine come output in entrambi i modelli sono state predette le prime 5 componenti principali dei due contenuti colonnari. Quest'ultime vengono successivamente utilizzate per ricostruire i due profili su una griglia di pressione atmosferica composta da 60 livelli. La funzione di costo utilizzata dalle reti è l'errore assoluto medio (**MAE**). Infine, l'algoritmo **ADAM** [6] è stato utilizzato per l'ottimizzazione della fase di apprendimento di tutti i modelli neurali sviluppati.

Predizioni CLWP e CIWP



Predizioni CLWC e CIWC



Conclusioni

L'analisi dei risultati prodotti dalle reti neurali per la predizione dei contenuti integrati di acqua liquida e ghiacciata delle nubi, evidenzia delle regressioni soddisfacenti e in accordo con la fisica del problema, permettendo di ottenere correlazioni di circa il 96%. Nel caso dei contenuti colonnari di ghiaccio e acqua anche qui le reti mostrano di essere in accordo con la fisica dei due contenuti perché le predizioni ottenute permettono di ricostruire dei profili in grado di seguire bene il loro andamento nell'atmosfera, permettendo inoltre di individuare lo strato di concentrazione massimo. Naturalmente, analisi e studi aggiuntivi sono necessari per confermare la validità della metodologia, per esempio utilizzare le reti su dataset di misurazioni MWS e IASI-NG acquisite con angoli diversi dal Nadir e su aree di terra.

Contatti

Pietro Mastro
Università degli studi della Basilicata
Email: pietro.mastro@unibas.it
Phone: 3398974787

Riferimenti

- [1] Goodfellow I., Bengio Y., Courville A., "Deep Learning". The MIT Press, 2016
- [2] LeCun Y.A., Bottou L., Orr G.B., Müller K.R., "Efficient BackProp". Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science, vol. 7700. Springer, Berlin, Heidelberg, 2012, https://doi.org/10.1007/978-3-642-35289-8_3
- [3] Serio C., Masiello G., Giuseppe G., "EOF regression analytical model with applications to the retrieval of atmospheric temperature and gas constituents concentration from high spectral resolution infrared observations," Environmental Modelling: New Research, 2008.
- [4] Saunders, R. et al., "An update on the RTTOV fast radiative transfer model." Geosci. Model Dev., vol. 11, pp. 2717-2737, 2018, <https://doi.org/10.5194/gmd-11-2717-2018>
- [5] Amato U., Masiello G., Serio C., Viggiano M., "The σ -IASI code for the calculation of infrared atmospheric radiance and its derivatives," Environmental Modelling & Software, vol. 17, issue 7, pp. 651-667, 2002, [https://doi.org/10.1016/S1364-8152\(02\)00027-0](https://doi.org/10.1016/S1364-8152(02)00027-0)
- [6] Kingma D., Ba J., "Adam: A method for Stochastic Optimization". International Conference on Learning Representations (ICLR), 2015, <https://arxiv.org/pdf/1412.6980.pdf>