

Gli Autoencoder nel Digital Image Processing

Original

Gli Autoencoder nel Digital Image Processing / Sparavigna, A.C.. - ELETTRONICO. - (2026).
[10.5281/zenodo.18402967]

Availability:

This version is available at: 11583/3007110 since: 2026-01-30T12:13:52Z

Publisher:

Published

DOI:10.5281/zenodo.18402967

Terms of use:

This article is made available under terms and conditions as specified in the corresponding bibliographic description in the repository

Publisher copyright

(Article begins on next page)

Gli Autoencoder nel Digital Image Processing

Amelia Carolina Sparavigna¹ e Gemini (Modello Linguistico di Google)²

¹ DISAT, Politecnico di Torino, ² Gemini AI

DOI: 10.5281/zenodo.18402967

Executive Summary

Obiettivo del Report Il presente documento illustra l'applicazione degli **autoencoder**, una classe di architetture di deep learning non supervisionato, per l'estrazione di pattern complessi e la generazione di modelli archetipici nel campo del *Digital Image Processing*. Il report dimostra la validità del concetto di "**pseudoimmagine**" come evoluzione del metodo già applicato con successo alla spettroscopia Raman (pseudospettro).

Metodologia e Caso di Studio La ricerca si è concentrata sull'analisi di 23 immagini satellitari ad alta risoluzione del territorio statunitense. Sfruttando la regolarità geometrica del *Public Land Survey System* (PLSS) — inteso come una moderna "limitatio" romana — è stato possibile addestrare un autoencoder di tipo *dense* per mappare i dati in uno spazio latente compresso. Attraverso il clustering K-Means applicato a tale spazio, sono stati identificati cinque gruppi morfologici distinti.

Risultati Chiave: La Pseudoimmagine Il risultato principale è la generazione di **pseudoimmagini**, ovvero ricostruzioni visive dei centroidi matematici di ciascun cluster. A differenza del semplice denoising statistico, la pseudoimmagine:

- Funge da **archetipo idealizzato**, rivelando la struttura essenziale (stradale, industriale o agricola) eliminando i dettagli superflui.
- Dimostra la **trasferibilità del metodo** tra domini scientifici diversi (dalla chimica alla geofisica).
- Evidenzia la necessità del **fattore umano** per la validazione semantica, come dimostrato dall'identificazione di pattern visivi trasversali nel Cluster 5.

Conclusioni e Prospettive Il report conclude che l'uso delle pseudoimmagini e degli pseudospettri apre nuove strade per la creazione di **librerie diagnostiche sintetiche**. Questo approccio non solo migliora l'interpretabilità dei modelli di IA, ma fornisce una metodologia robusta per la classificazione non supervisionata di segnali e immagini in contesti di ricerca avanzata.

Abstract

Questo studio esplora l'efficacia degli autoencoder nell'apprendimento non supervisionato applicato al Digital Image Processing, con un focus innovativo sulla generazione di modelli archetipici definiti "pseudoimmagini". Partendo dall'architettura fondamentale encoder-decoder, il report analizza come lo spazio latente possa essere utilizzato non solo per il denoising standard, ma per formalizzare pattern strutturali profondi. La metodologia, originariamente sviluppata per la spettroscopia Raman, viene qui traslata all'analisi di immagini satellitari degli Stati Uniti, sfruttando la regolarità geometrica del Public Land Survey System (PLSS). I risultati dimostrano che l'autoencoder, attraverso il clustering dello spazio latente, è in grado di identificare e ricostruire visivamente i centroidi dei cluster (pseudoimmagini), fornendo rappresentazioni idealizzate di paesaggi rurali, industriali e di transizione. Il lavoro sottolinea la versatilità transdisciplinare del concetto di "pseudospettro" come strumento per la creazione di librerie di riferimento sintetiche e la validazione della logica interna dell'Intelligenza Artificiale.

1. Introduzione

Gli **Autoencoder** sono una classe di reti neurali artificiali appartenenti al paradigma dell'apprendimento non supervisionato. Il loro obiettivo primario è quello di apprendere una rappresentazione compressa (encoding) dei dati di input, per poi ricostruirli (decoding) il più fedelmente possibile. Nell'immagine processing, questo processo permette di estrarre le caratteristiche salienti di un'immagine, eliminando il "rumore" o le informazioni ridondanti.

2. Architettura Fondamentale

Un autoencoder è composto da tre componenti chiave:

1. **Encoder:** Contrae l'input in una rappresentazione a bassa dimensione.
2. **Bottleneck (Latent Space):** Il "cuore" della rete, dove risiede la conoscenza compressa. È qui che avviene la magia: la rete deve decidere quali "ingredienti" dell'immagine sono essenziali.
3. **Decoder:** Espande la rappresentazione compressa per tornare alla dimensione originale.

3. Applicazioni Principali nell'Image Processing

Applicazione	Descrizione
Denoising	Rimuove il rumore casuale. La rete impara a ignorare le variazioni isolate per concentrarsi sulle strutture coerenti.
Compressione	Riduce il peso dei file mantenendo le caratteristiche visive fondamentali.
Inpainting	Ricostruisce parti mancanti o danneggiate di un'immagine basandosi sul contesto appreso.

Applicazione	Descrizione
Generazione	Attraverso i <i>Variational Autoencoders</i> (VAE), è possibile generare nuove immagini simili a quelle del dataset di addestramento.

In particolare, gli autoencoder usati sono i seguenti.

Applicazione	Modello di Autoencoder Utilizzato	Caratteristiche Tecniche
Denoising	Denoising Autoencoder (DAE)	Durante l'addestramento, viene introdotto del rumore artificiale nell'input. La rete non deve solo ricostruire l'immagine, ma deve imparare a "mappare" i pixel corrotti verso quelli corretti, ignorando le variazioni isolate.
Compressione	Undercomplete Autoencoder	Utilizza un collo di bottiglia (<i>bottleneck</i>) estremamente stretto. Poiché lo spazio latente ha una dimensione molto inferiore all'input, la rete è costretta a scartare tutto ciò che non è essenziale, mantenendo solo le caratteristiche visive fondamentali. Gli strati sono densi.
Inpainting	Convolutional Autoencoder (CAE)	Utilizza strati convoluzionali invece di strati densi. Questo permette alla rete di comprendere la coerenza spaziale e il contesto delle zone circostanti per "indovinare" e ricostruire le parti mancanti o danneggiate.
Generazione	Variational Autoencoder (VAE)	A differenza degli AE tradizionali, il VAE non mappa l'input in un singolo punto dello spazio latente, ma in una distribuzione di probabilità. Questo permette di campionare nuovi punti e generare immagini inedite ma coerenti con il dataset originale.

Ed ora i gruppi di ricerca relativi.

Modello di Autoencoder	Gruppo di Ricerca / Autore Principale	Contributo Fondamentale
Denoising (DAE)	Yoshua Bengio (MILA, Università di Montréal)	Hanno introdotto il concetto di addestramento su dati corrotti per forzare

Modello di Autoencoder	Gruppo di Ricerca / Autore Principale	Contributo Fondamentale
		la rete ad apprendere rappresentazioni più robuste (Vincent et al., 2008).
Undercomplete (AE)	Geoffrey Hinton (Università di Toronto / Google Brain)	Il lavoro seminale del 2006 sulla riduzione della dimensionalità ha dato il via al moderno Deep Learning e alla compressione tramite bottleneck.
Convolutional (CAE)	Jonathan Masci (IDSIA, Svizzera)	Hanno formalizzato l'uso dei filtri convoluzionali negli autoencoder (2011), permettendo all'architettura di gestire la struttura spaziale delle immagini.
Variational (VAE)	Diederik Kingma (Google Brain) & Max Welling (Università di Amsterdam)	Nel 2013 hanno introdotto il framework probabilistico che permette agli autoencoder di diventare modelli generativi (Auto-Encoding Variational Bayes).

4. Il Ruolo della Funzione Sigmoidale

Come abbiamo discusso in passato, la **funzione sigmoide** gioca un ruolo cruciale nella fase finale del decoder. Poiché i valori dei pixel sono solitamente normalizzati tra 0 e 1, la sigmoide è perfetta per mappare l'output della rete in questo intervallo specifico: $f(x) = \frac{1}{1 + e^{-x}}$

Questo garantisce che l'immagine ricostruita mantenga una coerenza fisica e statistica, rendendola ideale per segnali puliti e definiti.

Si noti che la **funzione sigmoide non è utilizzata in tutti gli autoencoder**. La scelta della funzione di attivazione nell'ultimo strato del decoder dipende strettamente dalla natura dei dati di input e da come sono stati normalizzati.

Ecco i casi principali in cui si usano alternative alla sigmoide:

- **Dati non limitati tra 0 e 1:** Se i dati (come nel caso di alcuni spettri Raman non normalizzati o dati fisici grezzi) hanno valori che superano 1 o sono negativi, si preferisce una funzione **Lineare** o una **ReLU** (Rectified Linear Unit), poiché la sigmoide "schiafferebbe" forzatamente tutti i valori in un intervallo ristretto, perdendo l'informazione originale.
- **Problemi di "Vanishing Gradient":** In reti molto profonde, l'uso ripetuto di funzioni come la sigmoide può rallentare l'addestramento. Per questo motivo, negli strati interni (non l'ultimo) si usano quasi sempre funzioni come la **ReLU** o le sue varianti.
- **Output centrati sullo zero:** Se le immagini o i segnali sono normalizzati tra -1 e 1, si utilizza la **Tangente Iperbolica (tanh)** invece della sigmoide, poiché mappa l'output esattamente in quell'intervallo simmetrico.

Perché nel nostro caso è ideale? Nel nostro lavoro sulle immagini satellitari e sugli spettri normalizzati, la sigmoide è perfetta perché i pixel e le intensità scalate sono rigorosamente compresi tra 0 e 1. In questo contesto, garantisce che l'autoencoder non generi valori "impossibili" (come un

pixel più luminoso del bianco o un'intensità negativa), mantenendo quella **coerenza fisica e statistica** che rende lo pseudo-spettro o la pseudo-immagine così definiti.

5. Connessione con la Spettroscopia (Riflessione Critica)

La vera potenza degli autoencoder emerge quando li applichiamo alla nostra ricerca. Invece di limitarci al denoising standard, la nostra strategia di usare lo **pseudo-spettro** trasforma l'autoencoder in un critico 'gastronomico': non si limita a pulire il piatto, ma valuta quanto la "ricetta" rumorosa sia vicina alla perfezione del modello teorico (cluster di materiali). Si veda la nostra discussione in <https://zenodo.org/records/18339887> in merito agli spettri Raman.

Ampliamo questa sezione aggiungendo il cuore della nostra innovazione che ha introdotto il concetto di pseudo-spettro. Parliamo quindi della natura dello **pseudo-spettro** e il motivo per cui rappresenta un cambio di paradigma rispetto al semplice denoising.

5.1. Cos'è lo Pseudo-Spettro?

Lo pseudo-spettro non è semplicemente lo spettro originale ripulito dal rumore, ma è la **ricostruzione visiva del centroide matematico** dello spazio latente identificato per un determinato cluster.

- **L'Archetipo Ideale:** Rappresenta la forma "ideale" o l'archetipo di una categoria di segnali (ad esempio, un particolare minerale o un tipo di suolo).
- **Sintesi dello Spazio Latente:** Deriva dalla compressione dei dati operata dall'Encoder, che trattiene solo le caratteristiche essenziali scartando le fluttuazioni casuali.
- **Versatilità:** È un concetto trasferibile che abbiamo applicato con successo sia alla spettroscopia Raman che alle immagini satellitari, dove prende il nome di **pseudo-immagine**.

5.2. Perché è così importante?

L'importanza dello pseudo-spettro risiede nella sua capacità di **formalizzare pattern nascosti** in dataset complessi e non etichettati.

1. **Denoising "Intelligente":** A differenza dei filtri classici, lo pseudo-spettro non si limita a mediare i valori, ma "ricostruisce" ciò che il segnale dovrebbe essere in base alla logica del cluster di appartenenza.
2. **Modello per Librerie Future:** Uno pseudo-spettro generato da un autoencoder può essere inserito in una libreria di riferimento per fungere da modello in lavori futuri, facilitando l'identificazione di materiali sconosciuti.
3. **Validazione della Logica AI:** Funge da "finestra" sulla logica interna dell'autoencoder, permettendo al ricercatore umano di verificare se la rete ha raggruppato i dati correttamente in base a caratteristiche fisiche o chimiche reali.

6. Caso di Studio sulle Immagini Satellitari

In questo caso di studio ci riferiamo al nostro lavoro: Sparavigna, A. C., & Gemini (Modello Linguistico di Google). (2025). Identification of Geospatial Patterns using Autoencoders and Clustering. Zenodo. <https://doi.org/10.5281/zenodo.17164172>, intitolato "Identification of Geospatial Patterns using Autoencoders and Clustering":

6.1. Estensione del Concetto di Denoising: La "Pseudoimmagine"

Oltre alla rimozione del rumore statistico, abbiamo dimostrato che l'autoencoder può essere utilizzato per generare una **pseudoimmagine**.

- **Definizione:** La pseudoimmagine è la ricostruzione visiva del centroide matematico calcolato nello spazio latente di un cluster.

- **Funzione:** Agisce come un "archetipo idealizzato", eliminando i dettagli superflui (noise) per rivelare la struttura geometrica e morfologica essenziale del territorio.

6.2. Metodologia: Dalla Spettroscopia alla Geofisica


Il report ora include la prova della **trasferibilità concettuale** del metodo:

- **Dataset:** Sono state analizzate 23 immagini satellitari ad alta risoluzione degli Stati Uniti.
- **Sinergia con la Storia:** La regolarità del *Public Land Survey System* (PLSS) americano, definita come una versione moderna della "limitatio" romana, ha fornito la griglia ideale (256x256 pixel) per l'addestramento non supervisionato.

6.3. Risultati e Classificazione Unsupervised

L'integrazione mostra come il modello abbia identificato 5 pattern geospaziali distinti (<https://doi.org/10.5281/zenodo.17164172>):

- **Pattern Rurali (Cluster 1):** Pseudoimmagini che rappresentano l'archetipo dei campi agricoli e delle strade rurali.
- **Pattern Urbani/Industriali (Cluster 2, 4, 5):** Identificazione di strutture artificiali, magazzini e reti stradali complesse.
- **Pattern di Transizione (Cluster 3):** Un mix visivo che cattura il passaggio tra l'uso del suolo rurale e quello urbano.



Esempio di pseudoimmagine nel caso del cluster 5. <https://zenodo.org/records/17164172>

6.4. Il Ruolo Critico dell'Analisi Umana

Un punto essenziale da aggiungere al report è l'importanza della validazione umana. Ad esempio, l'inclusione di una cava nel Cluster 5 insieme a edifici industriali evidenzia come l'AI si concentri su **pattern visivi di alto livello** (forme e riflettanza), rendendo necessaria l'interpretazione esperta per definire il contesto semantico.

Conclusioni

Il presente lavoro evidenzia che gli autoencoder rappresentano una tecnologia d'avanguardia per la scoperta e la formalizzazione di pattern nascosti in dataset complessi e privi di etichettatura umana. Il passaggio concettuale dallo **pseudospettro** alla **pseudoimmagine** dimostra una solida trasferibilità metodologica: in entrambi i domini, l'autoencoder funge da "filtro intelligente" capace di estrarre l'essenza morfologica o chimica del dato, superando i limiti dei filtri statistici tradizionali.

Mentre il modello si è dimostrato estremamente efficace nell'isolare caratteristiche visive di alto livello — come le griglie stradali o le volumetrie industriali — l'analisi del caso di studio (in particolare il raggruppamento di cave e fabbriche nel Cluster 5) ribadisce il ruolo insostituibile del ricercatore umano nella validazione semantica dei risultati. In conclusione, la generazione di modelli archetipici basati sui centroidi dello spazio latente non solo facilita l'arricchimento di librerie diagnostiche per la ricerca futura, ma apre nuove prospettive per un'IA interpretabile, capace di offrire una "finestra" chiara sulla propria logica di classificazione.

Lavori di Riferimento (Sparavigna & Gemini)

Sparavigna, A. C., & Gemini (Modello Linguistico di Google). (2025). Identification of Geospatial Patterns using Autoencoders and Clustering. Zenodo. <https://doi.org/10.5281/zenodo.17164172>

Sparavigna, A. C., & Gemini (Modello Linguistico di Google). (2025). Dense Autoencoder-Generated Pseudospectra for Unsupervised Raman Classification of Carbonaceous Materials. Zenodo. <https://doi.org/10.5281/zenodo.16935868>

Sparavigna, A. C., & Gemini (Modello Linguistico di Google). (2025). Beyond the Spectrum: How an AI Autoencoder Deciphers the Chemical Fingerprint in SERS Data. Zenodo. <https://doi.org/10.5281/zenodo.16895315>

Sparavigna, A. C., & Gemini (Modello Linguistico di Google). (2025). A Novel Unsupervised Approach to Stellar Spectra Analysis. Zenodo. <https://doi.org/10.5281/zenodo.17144409>

Sparavigna, A. C. (2020). La Limitatio Romana: Alcune Definizioni. Zenodo. <https://doi.org/10.5281/zenodo.3733048>

Letteratura sull'Analisi Satellitare via AI

Alabidi, S. A., & Al-Zubaidi, E. A. (2024). Satellite Image Classification Using Unsupervised Machine Learning. *Al-Furat Journal of Innovations in Electronics and Computer Engineering*, 3(2), 276-298.

Basu, S., Ganguly, S., Mukhopadhyay, S., DiBiano, R., Karki, M., & Nemani, R. (2015). Deepsat: a learning framework for satellite imagery. In *Proceedings of the 23rd SIGSPATIAL international conference on advances in geographic information systems* (pp. 1-10).

Block, J., Yazdani, M., Nguyen, M., Crawl, D., Jankowska, M., Graham, J., DeFanti, T., & Altintas, I. (2017). An unsupervised deep learning approach for satellite image analysis with applications in demographic analysis. In *2017 IEEE 13th International Conference on e-Science (e-Science)* (pp. 9-18). IEEE.

Shafaey, M. A., Salem, M. A. M., Ebied, H. M., Al-Berry, M. N., & Tolba, M. F. (2018). Deep learning for satellite image classification. In *International Conference on Advanced Intelligent Systems and Informatics* (pp. 383-391). Cham: Springer International Publishing.

Certamente, Amelia. Ecco la bibliografia completa del report aggiornata secondo lo stile **APA (7^a edizione)***, includendo i pionieri dell'AI, i nostri lavori e i riferimenti sulla limitatio e le immagini satellitari:

Pionieri e Fondamenti degli Autoencoder

- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313 (5786), 504–507. <https://doi.org/10.1126/science.1127647>
- Kingma, D. P., & Welling, M. (2013). Auto-encoding variational bayes. arXiv. <https://doi.org/10.48550/arXiv.1312.6114>
- Masci, J., Meier, U., Cireşan, D., & Schmidhuber, J. (2011). Stacked convolutional auto-encoders for hierarchical feature extraction. In *Artificial Neural Networks and Machine Learning – ICANN 2011* (pp. 52–59). Springer.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., & Manzagol, P. A. (2010). Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11(110), 3371–3408.