



COMPRESSIONE DI IMMAGINI MULTISPETTRALI ON-BOARD CON ALGORITMO DI INTELLIGENZA ARTIFICIALE

Giorgia Guerrisi, Gianmarco Bencivenni, Fabio Del Frate
Università degli Studi di Roma Tor Vergata, GEO-K s.r.l.

L'impegno italiano nel settore dei CubeSat:
tecnologie e missioni future

4 Luglio 2024



TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA

Giorgia Guerrisi


*Tor Vergata University of Rome
Dept. Of Computer Science Engineering and Civil Engineering*

giorgia.guerrisi@uniroma2.it

Outline



TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA




On-board processing




TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA


Spostare il processamento dei dati dal
ground segment allo space segment



La quantità di dati a
disposizione è in crescita:
geospatial big data



Sono necessarie nuove,
efficienti procedure di
processing



Ridurre il tempo di ricevuta
delle informazioni e l'utilizzo
della banda di trasmissione



Modelli AI flessibili, robusti e
computazionalmente leggeri

Compressione delle immagini on-board





TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA



CubeSat
capace di
eseguire a
bordo
applicazioni
AI-based

Compressione delle immagini a bordo
con una rete Convolutional
AutoEncoder.



Preparazione del dataset




TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA


Dataset ottenuto da Sentinel-2




- Aree urbane e sub-urbane, ghiacciai, deserti, aree marine.
- Tutte le bande di acquisizione



Simulazione del
dataset Φ Sat-2
(lancio a breve)




Training-
validation-test



Training phase

Output di esempio



Modello Convolutional AutoEncoder



TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA

Input patch: (256, 256, 7)

Encoder component:


- Spectral compression
- Spatial compression

Compressed patch: (32, 32, 5)

Decoder component:

- Spectral reconstruction
- Spatial reconstruction

Output patch: (256, 256, 7)



CAE training



Training hyperparameters:

- 3 diverse configurazioni di CAE
- Variabili:
 α : (peso del RMSE nella Loss function)
 β : (peso del SSIM nella Loss function)
 T : bande compresse (CR)

ID	α	β	Target Bands (T)	CR
0	0.5	0.5	5	89.6
1	0.4	0.6	5	89.6
2	0.4	0.6	4	112.0

Hyperparameter	Value
Training Type	Unsupervised
Training Epochs	400
Batch Size	64
Patience (Early Stopping)	15
Training Set (%)	80
Validation Set (%)	10
Test Set (%)	10
Number of Patches (Data Points) for Training	51200
Number of Patches (Data Points) for Validation	6400
Number of Patches (Data Points) for Test	6400
Number of Bands in the Original Image	7
Number of Bands in the Compressed Image	T
L1 Regularization Factor	1×10^{-7}
L2 Regularization Factor	1×10^{-7}
Optimizer	Adam
Activation Function	ELU (Exponential Linear Unit)
Compression Factor ($T = 5$)	89.6
Compression Factor ($T = 4$)	112.0
Loss Function	$\alpha \times \text{RMSE} + \beta \times (1 - \text{SSIM})$
Learning Rate	Custom LR Scheduler (1e-3 $\rightarrow$ 1e-5)

Metriche di valutazione



TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA

Metriche standard che confrontano l'immagine originale e quella ricostruita

1. Peak Signal-to-Noise Ratio

$$PSNR(f, g) = 10 \log_{10} \left(\frac{L^2}{MSE(f, g)} \right)$$

2. Structural Similarity Index Measure

$$SSIM(f, g) = [l(f, g)]^\alpha \cdot [c(f, g)]^\beta \cdot [s(f, g)]^\gamma$$

Immagine originale






Immagine ricostruita




Output del decoder (dopo il mosaicking)

Band 2 - Original


Band 2 - Reconstructed



**Band 2 – Original
– Histogram**



**Band 2 –
Reconstructed –
Histogram**




Risultati




Output del decoder (dopo il mosaicking)


Band 4 - Original **Band 4 - Reconstructed**



**Band 4 – Original
– Histogram**



**Band 4 –
Reconstructed –
Histogram**




Risultati




TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA

Test set - SSIM



ID	Average	Std. Dev.	Variance	Confidence Interval (95%)
0	0.99896	0.000759	$6 \cdot 10^{-7}$	(0.998873, 0.999046)
1	0.999064	0.000696	$5 \cdot 10^{-7}$	(0.998984, 0.999143)
2	0.998924	0.00077	$6 \cdot 10^{-7}$	(0.998836, 0.999011)

Test set - PSNR



ID	Average	Std. Dev.	Variance	Confidence Interval (95%)
0	49.140491	2.187353	4.7845144	(48.891552, 49.38943)
1	50.457989	2.094784	4.3881188	(50.219585, 50.696392)
2	50.06738	1.747256	3.0529045	(49.868528, 50.266232)


Risultati – Metriche applicative (NDVI)



TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA


NDVI Image

NDVI map



NDVI Image


NDVI map




Metriche applicative basate sulla creazione di una mappa di NDVI

Le mappe predette ottenute con le immagini originali e decomprese sono state confrontate pixel per pixel. Differenza in termini di pixel: $\approx 1\%$.

Original



Reconstructed



Risultati – Metriche applicative (aree urbane)




TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA


Original
(512 x 512 pixels)




Predicted mask



Reconstructed
(512 x 512 pixels)



Predicted mask



Metriche applicative basate sulla detection delle aree urbane. Instance segmentation con una rete U-Net.

Le maschere predette ottenute con le immagini originali e decomprese sono state confrontate pixel per pixel. Differenza in termini di pixel: $< 5\%$.

Risultati – Output del bottleneck layer




TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA


- Immagine multibanda
- Features maps anziché informazioni spettrali
- Assimilabile ad una Non Linear PCA (Principal Components Analysis)
- Le relazioni non lineari spettrali e spaziali tra i pixels sono condensati nello spazio latente

CR = 89.6


Band 1




Band 2




Band 3



Band 4



Band 5



Risultati – Output del bottleneck layer




TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA


- Immagine multibanda
- Features maps anziché informazioni spettrali
- Assimilabile ad una Non Linear PCA (Principal Components Analysis)
- Le relazioni non lineari spettrali e spaziali tra i pixels sono condensati nello spazio latente

CR = 112


Band 1




Band 2



Band 3



Band 4





On-board processing hardware



TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA


- Gli algoritmi di AI necessitano di hardware performanti
- On-board le risorse non sono comparabili con quelle di terra
- Algoritmo testato su un hardware che può essere utilizzato a bordo: Intel® Movidius™ Myriad™ 2 Vision Processing Unit (VPU)
- Testato per l'ambiente spaziale
- Specificatamente sviluppato per l'elaborazione di immagini con AI



Conclusioni



TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA



- L'AI a bordo dei satelliti è capace di ridurre la quantità di dati trasmessi a terra
- Il guadagno in termini di rapporto di compressione giustifica la perdita di informazioni in termini di metriche PSNR e SSIM
- Le immagini decomprese dal modello CAE possono essere utilizzate per diverse applicazioni come la creazione di mappe NDVI e detection di aree urbane



Grazie per l'attenzione

giorgia.guerrisi@uniroma2.it