

Otras aplicaciones de teledetección urbana



UNIVERSITÀ DI PAVIA

Agrupamiento no supervisado para la fusión de sensores heterogéneos para la detección de cambios en áreas urbanas

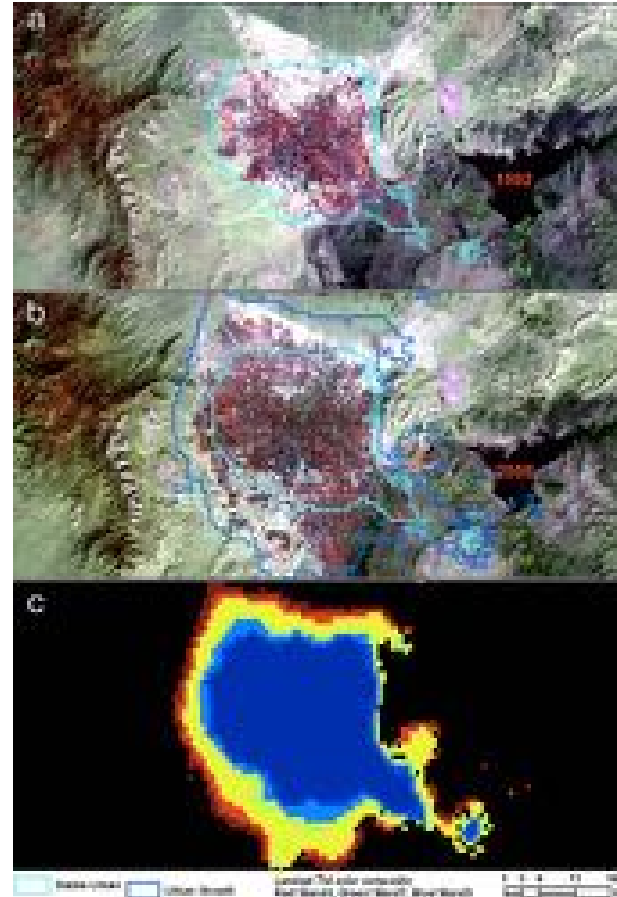
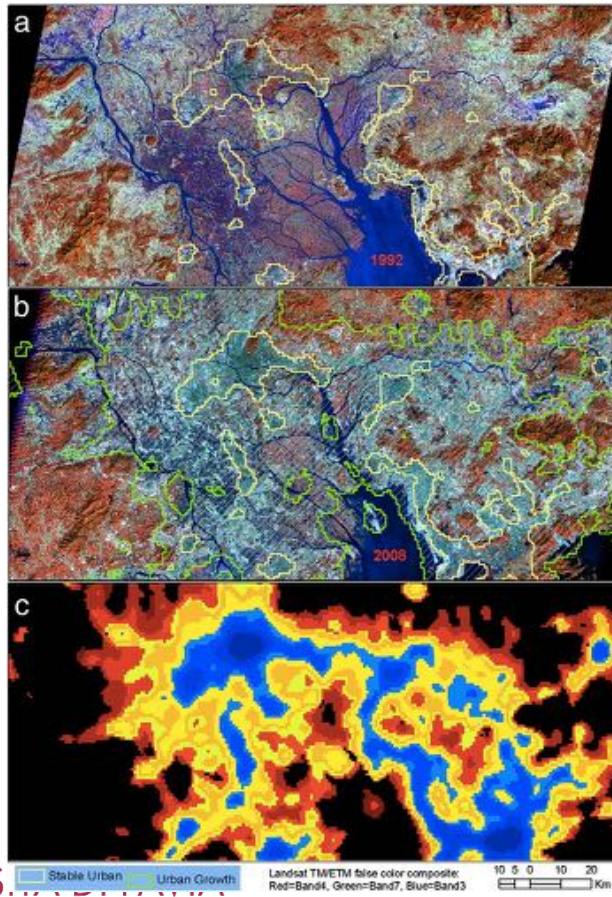


Punto de partida

- Mediante secuencias SAR es posible detectar automáticamente patrones de cambio en zonas urbanas y rurales y en áreas intraurbanas.
- Los datos S1 permiten monitorear cambios 2D/3D en áreas urbanas, pero siempre que se refieran a un cambio físico en la edificación.
- ¿Hay algo más que se pueda agregar para mejorar las posibilidades de monitorear otros tipos de cambios?
- Sí: luces nocturnas, pero ...
 - resolución espacial diferente (10 a 250 m)
 - resolución temporal diferente (no más frecuente que 1 mes)



Nighttime lights & urban 2D/3D analysis

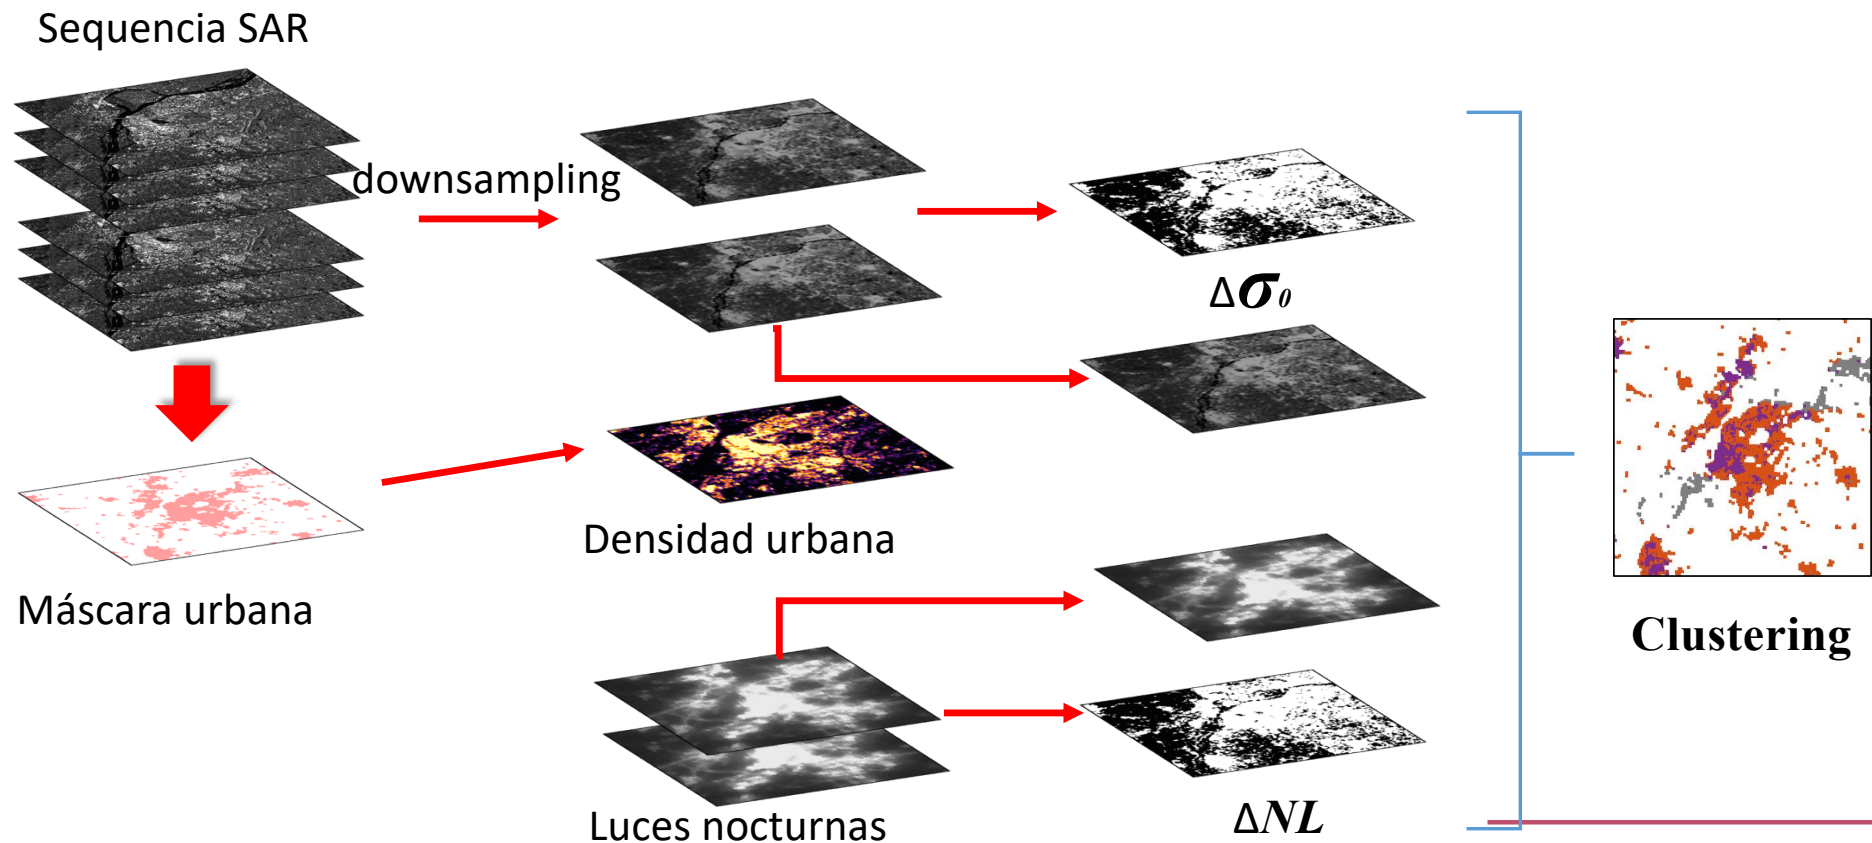


Q. Zhang, K.C. Seto
Remote Sensing of
Environment 115
(2011) 2320–2329





UNIVERSITY OF TOKYO

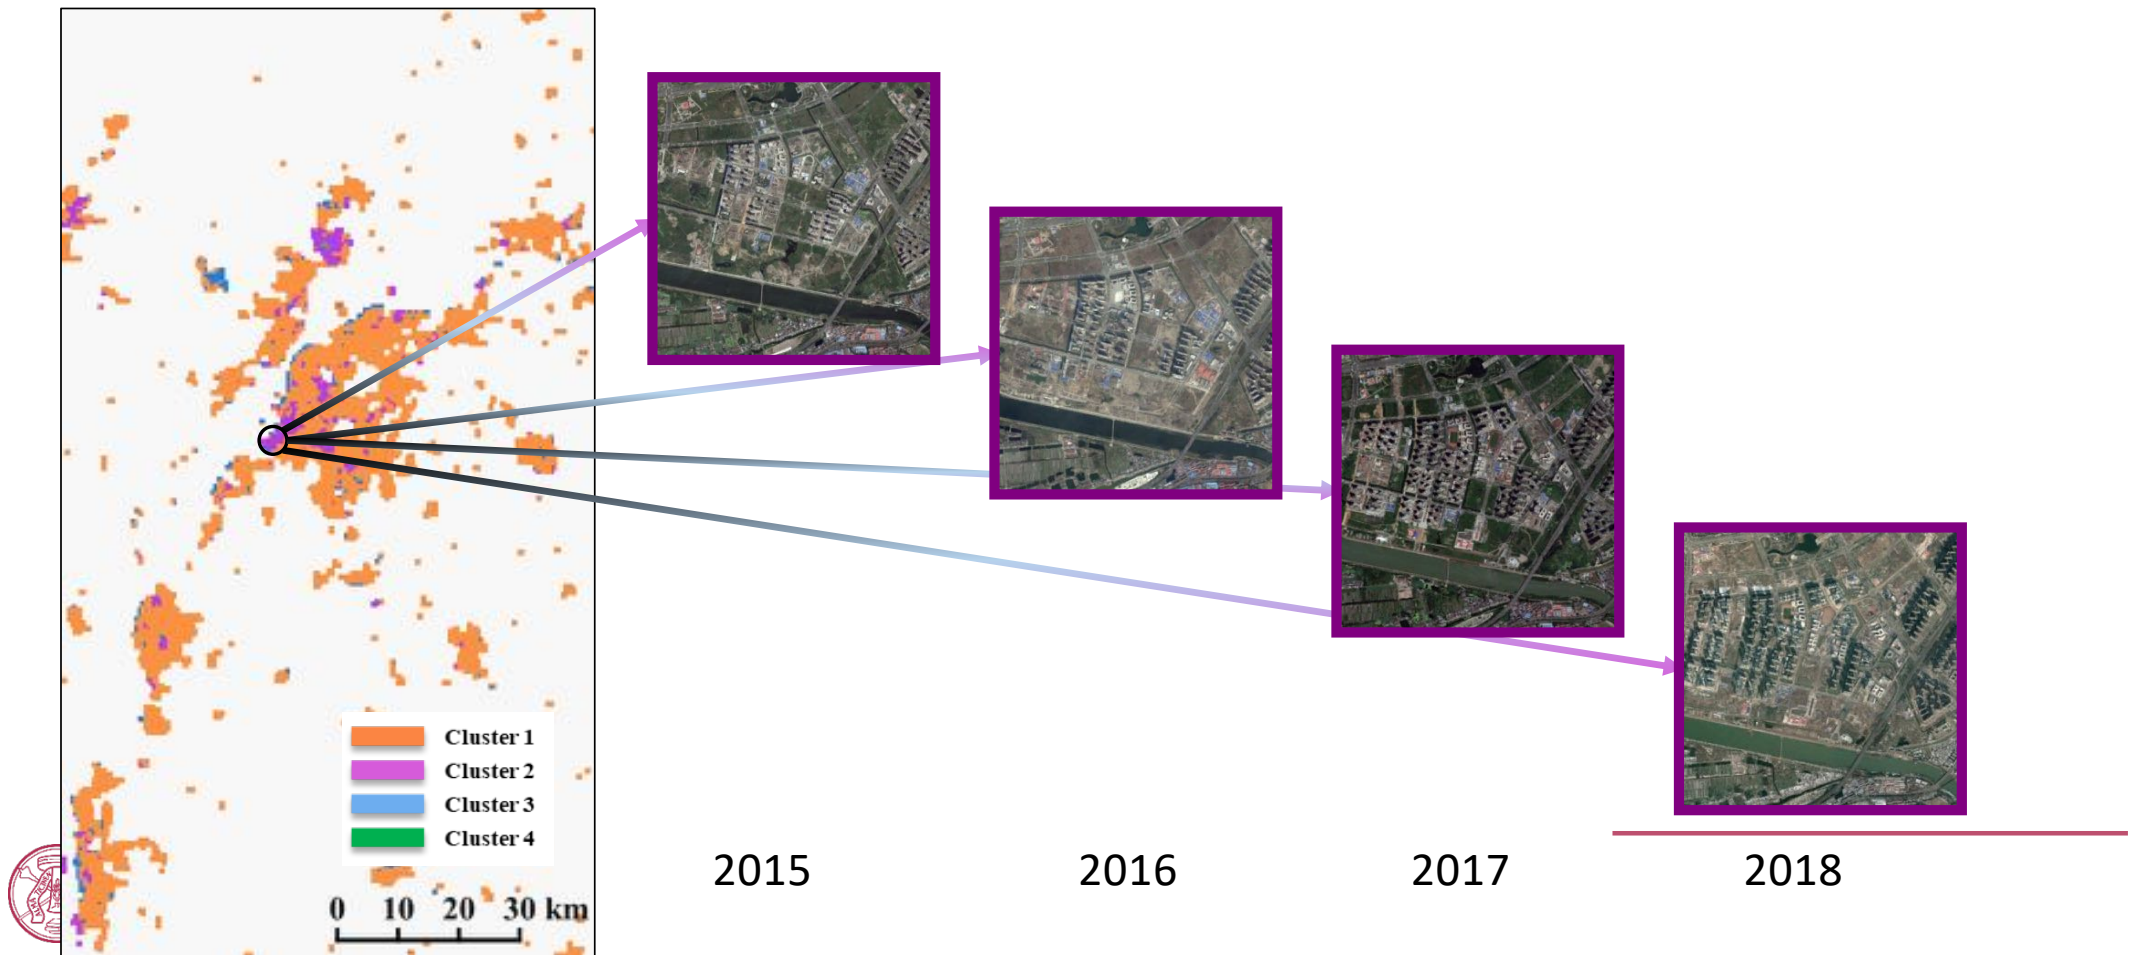
SAR multitemporal y luces nocturnas




Resultados intermedios para Nanjing



Púrpura: cambio volumétrico (3D)

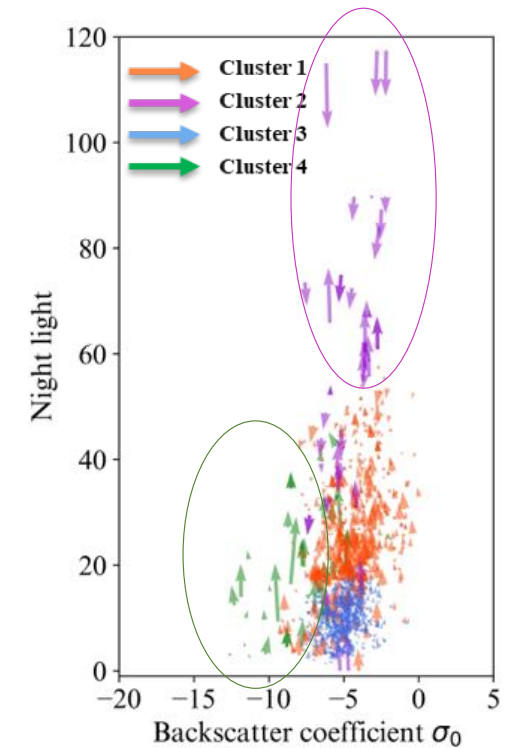




Azul: relleno (cambio 2D)




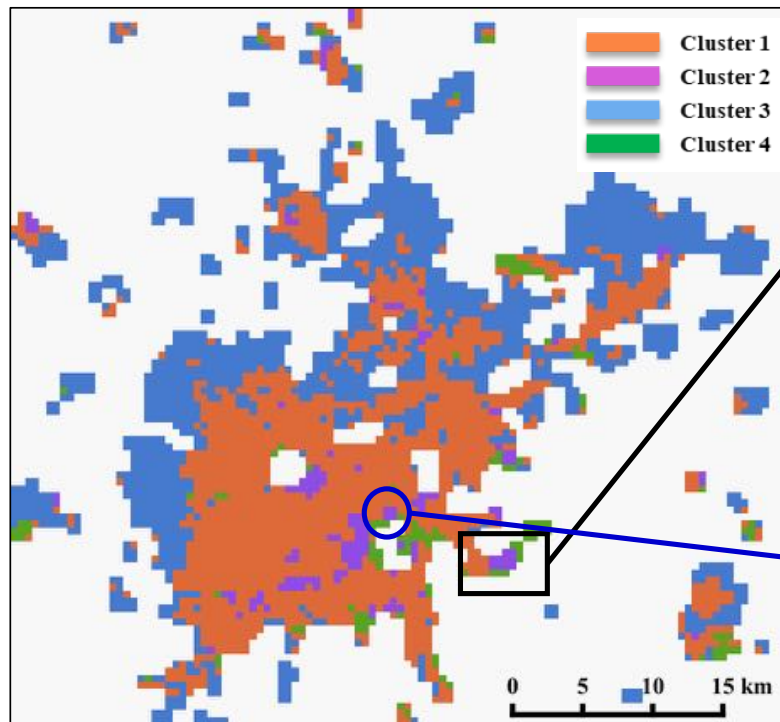
Otro ejemplo: el Gran Saigón

- Cambios detectados como en trabajos anteriores
- Los grandes cambios se refieren a los grupos **morado** y **verde**




Saigón: muestras

- Cluster púrpura: cambios volumétricos



Validación




Class	Green	Purple	White
Green	27	11	27
Purple	18	26	7
White	0	1	38

OA: 59 to 77%


OA: 65%



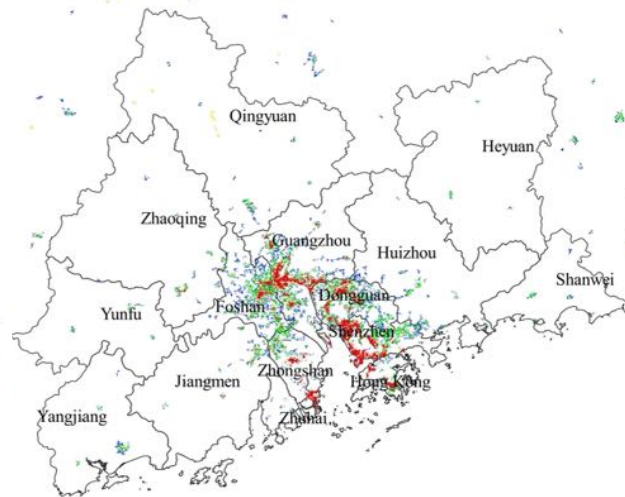
Aplicación a las megaciudades



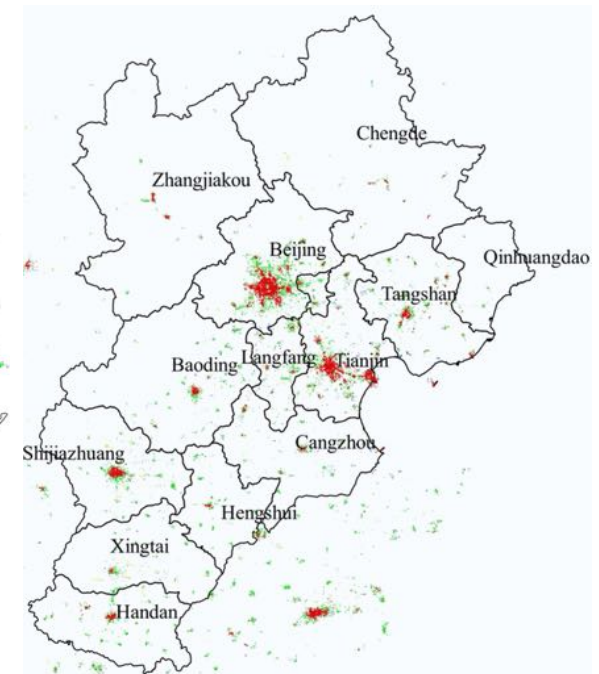
Resultados



Yangtze River Delta Megalopolis





Pearl River Delta Megalopolis



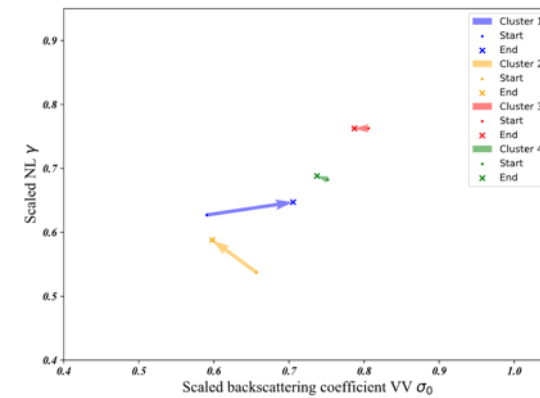
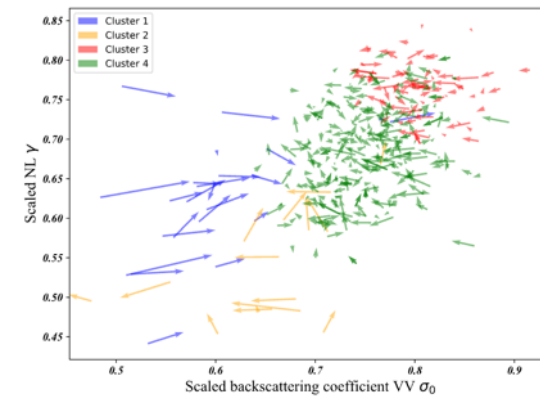
Jingjinji Megalopolis



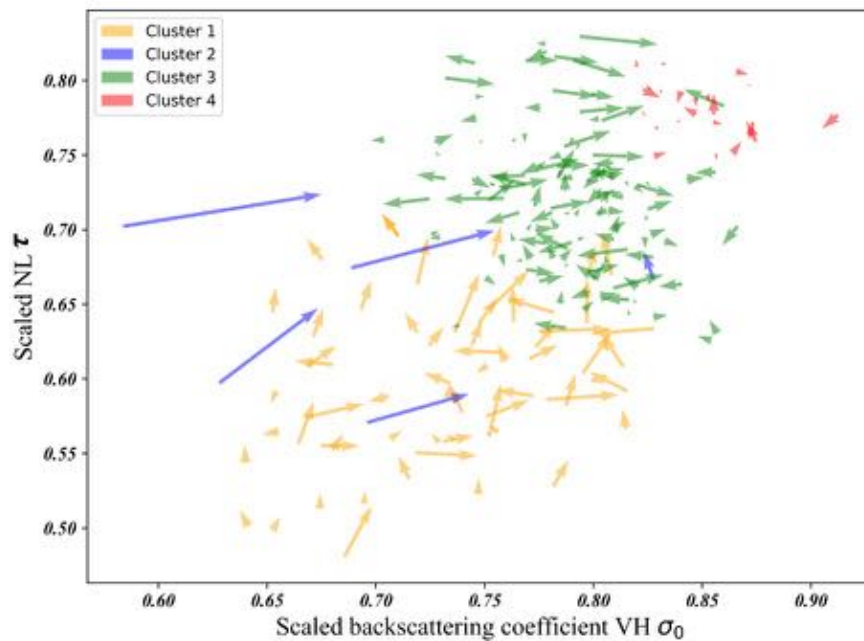
Interpretación SAR y luces nocturnas



Clustering



Change vector analysis



Vectores de cambio bidimensionales

- Representar la magnitud y la dirección (aumento o disminución) de los cambios
- Adecuado para datos de fuentes heterogéneas
- Para discriminar si el cambio depende o no del estado inicial

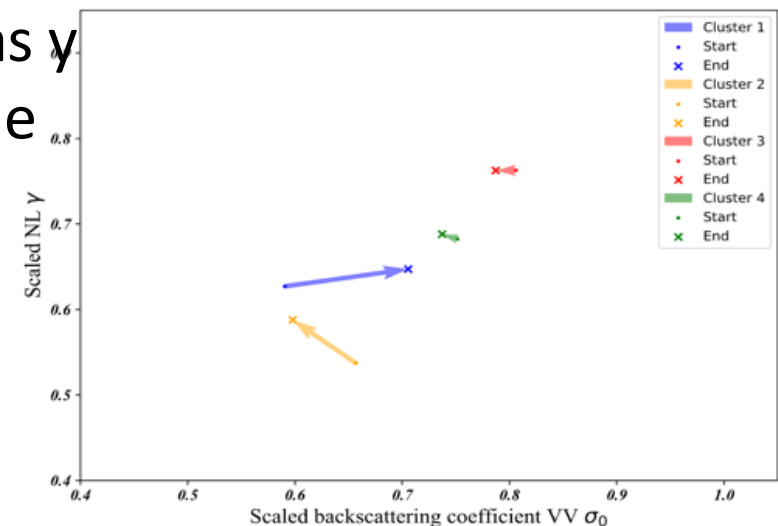
Dirección: cambio de propiedad

Longitud: cambio de magnitud




Interpretación de los clusters


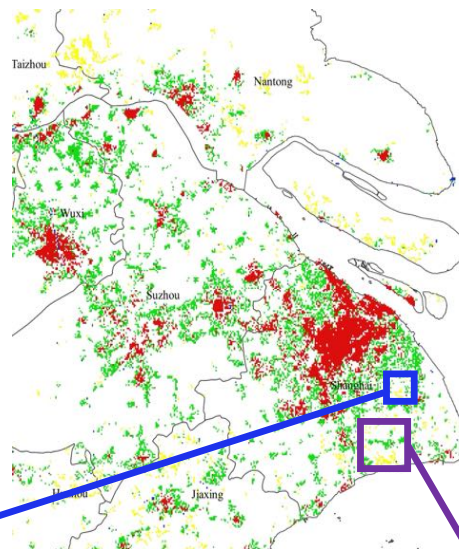
- **Área urbana central:** alta densidad de edificios y alto nivel de urbanización
- **Área suburbana:** la periferia de las áreas urbanas y rurales, baja densidad de edificios y bajo nivel de urbanización
- **Pueblos pequeños y elementos artificiales** (por ejemplo, aeropuertos) sujetos a actividades de construcción (mayor retrodispersión)
- **Fábricas** alejadas del área urbana pero con un fuerte cambio en el nivel de actividad (luz nocturna)



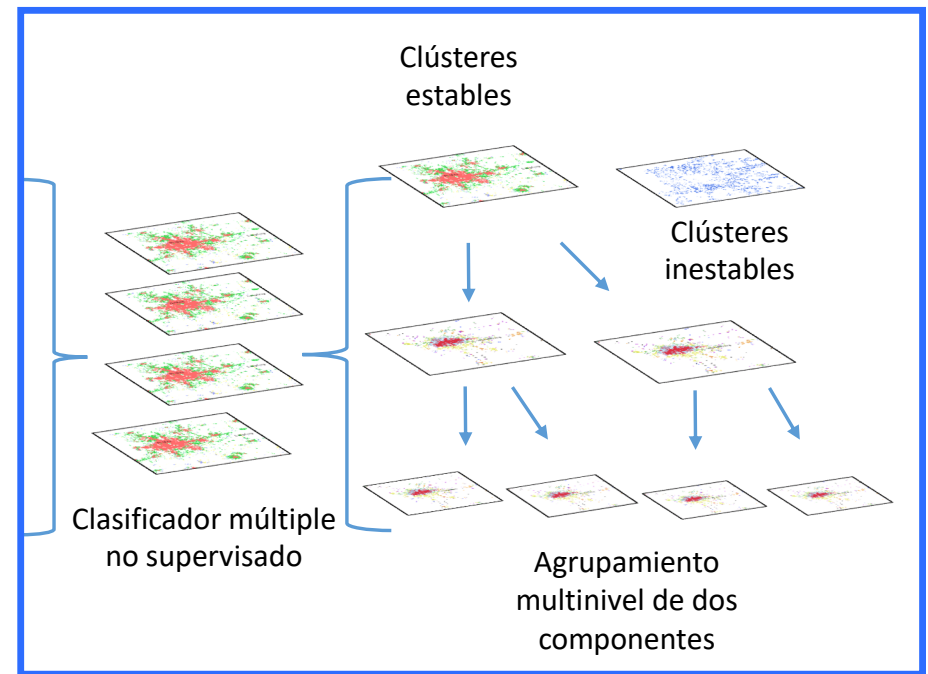
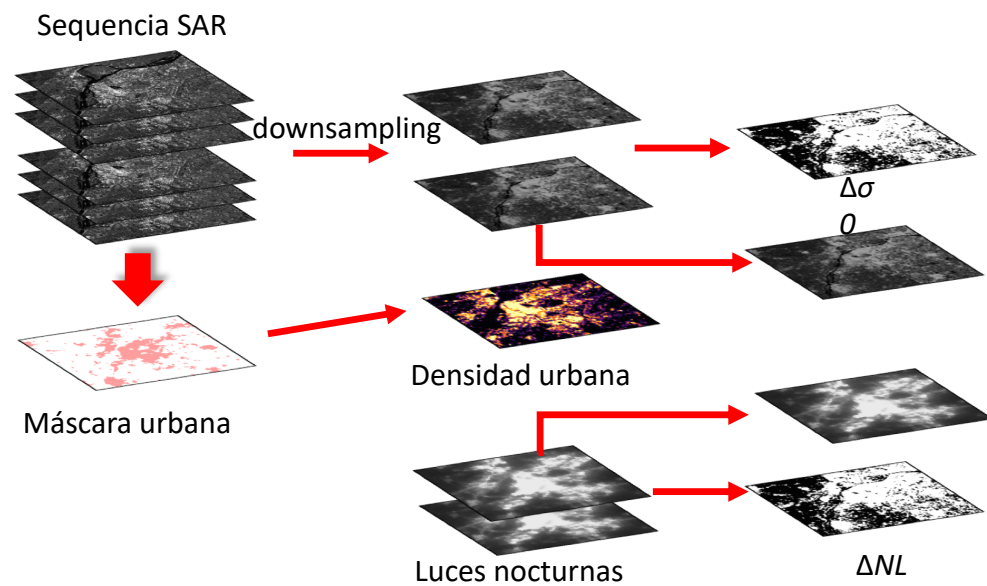
Ciudad pequeña



Aumento de la actividades

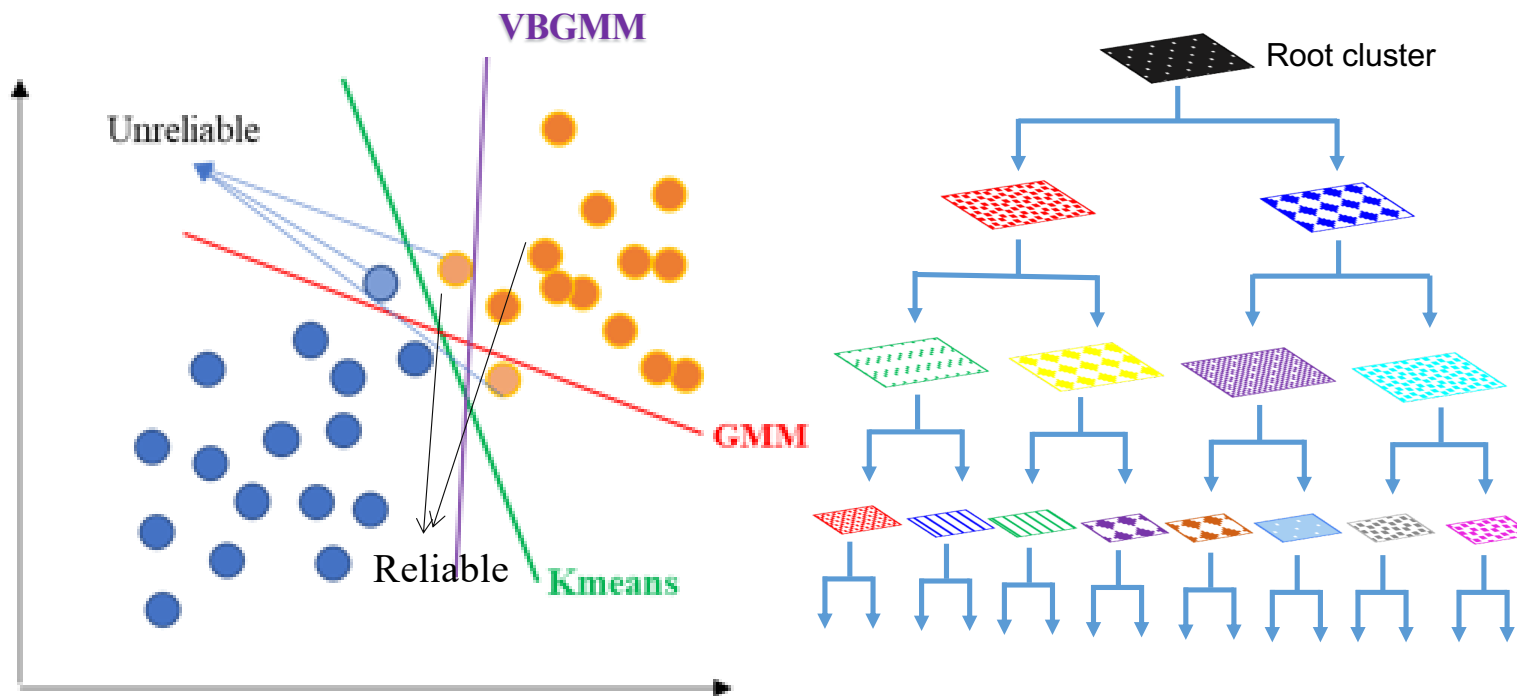


Metodología mejorada



Metodología: bi-clustering jerárquico


Para resolver la incertidumbre del número de clúster




Uso de clasificadores múltiples para extraer grupos confiables de baja incertidumbre

Extracción de objetos

- Objetos de cada clúster mediante análisis de componentes conectados



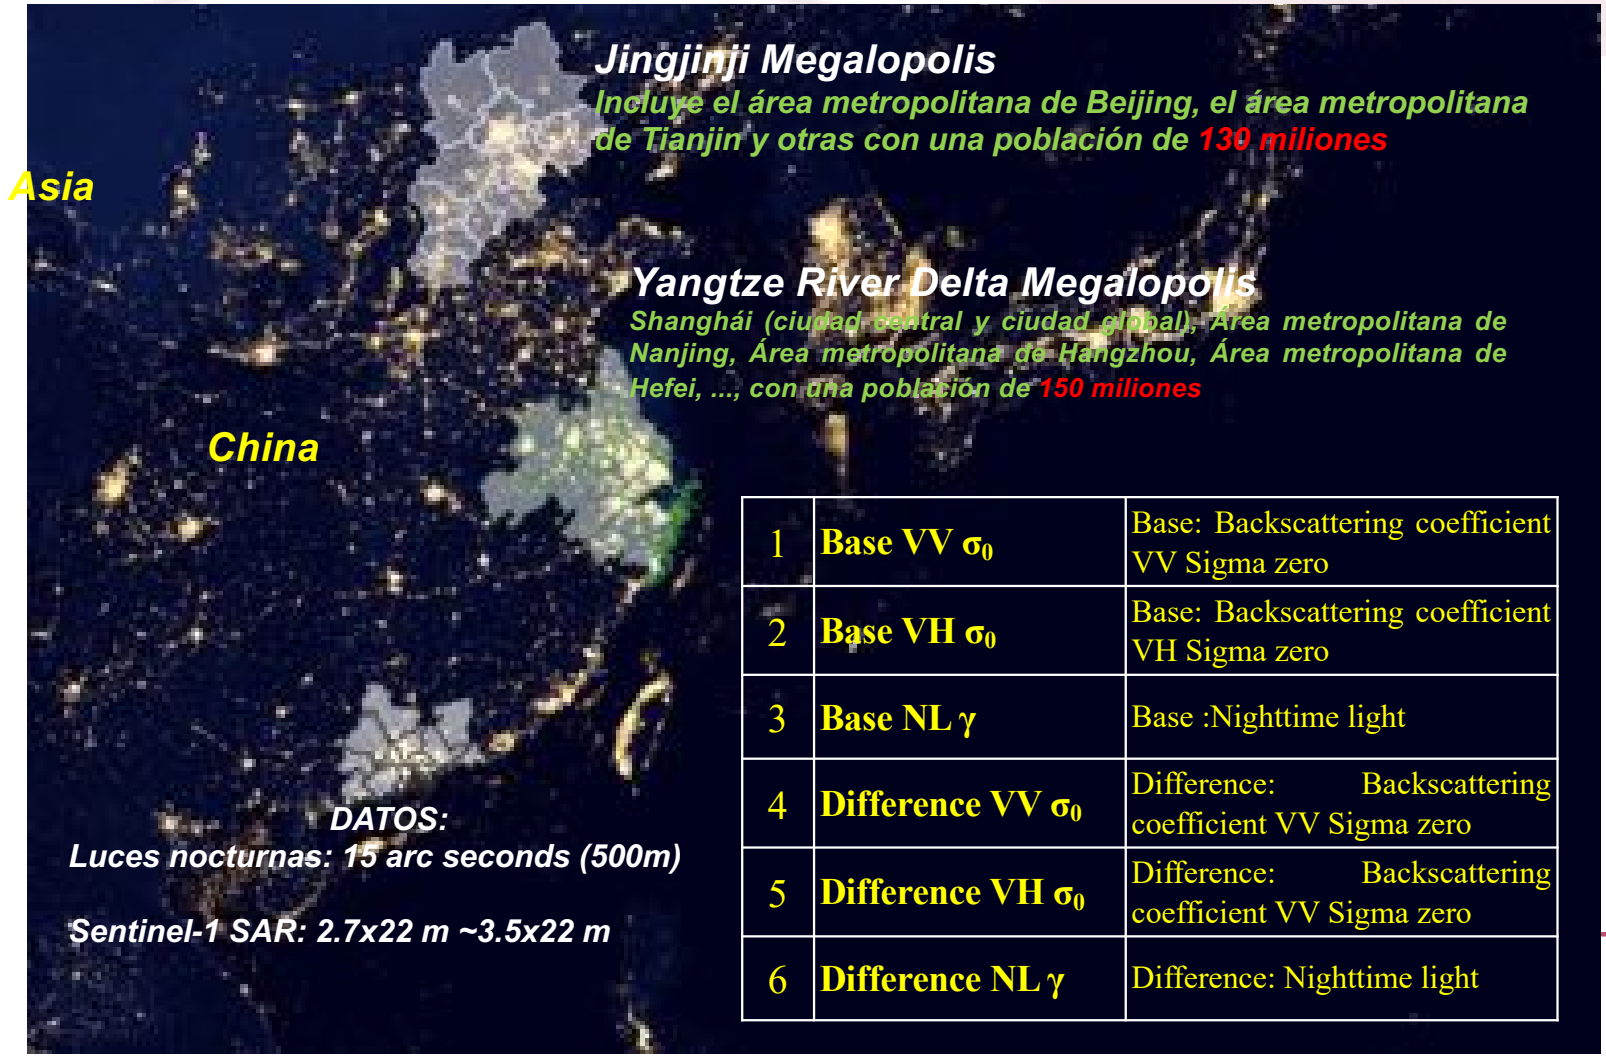
4 cluster en rojo, verde, azul y amarillo





Objetos (componentes conectados)
en diferentes colores






Áreas de estudio



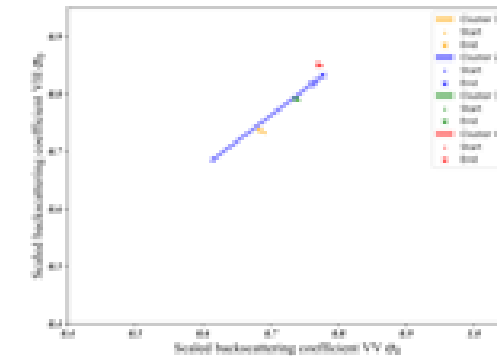
Análisis de vector de cambio para mapeo de cambio de 4 patrones



cluster vectors



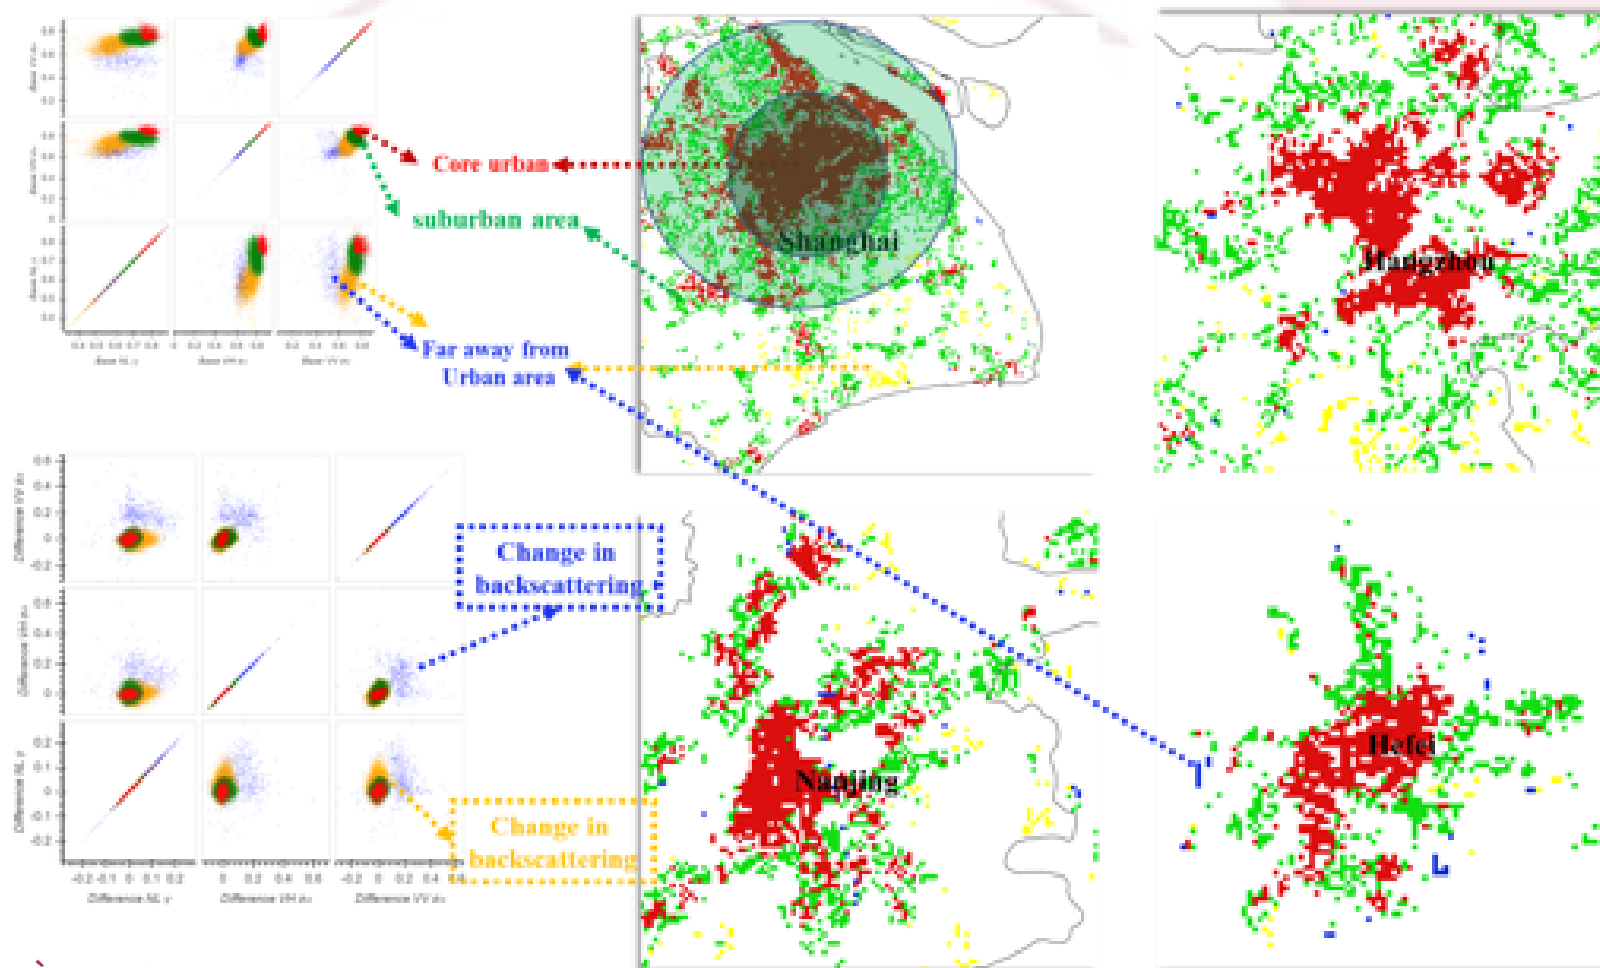
Cluster average vectors



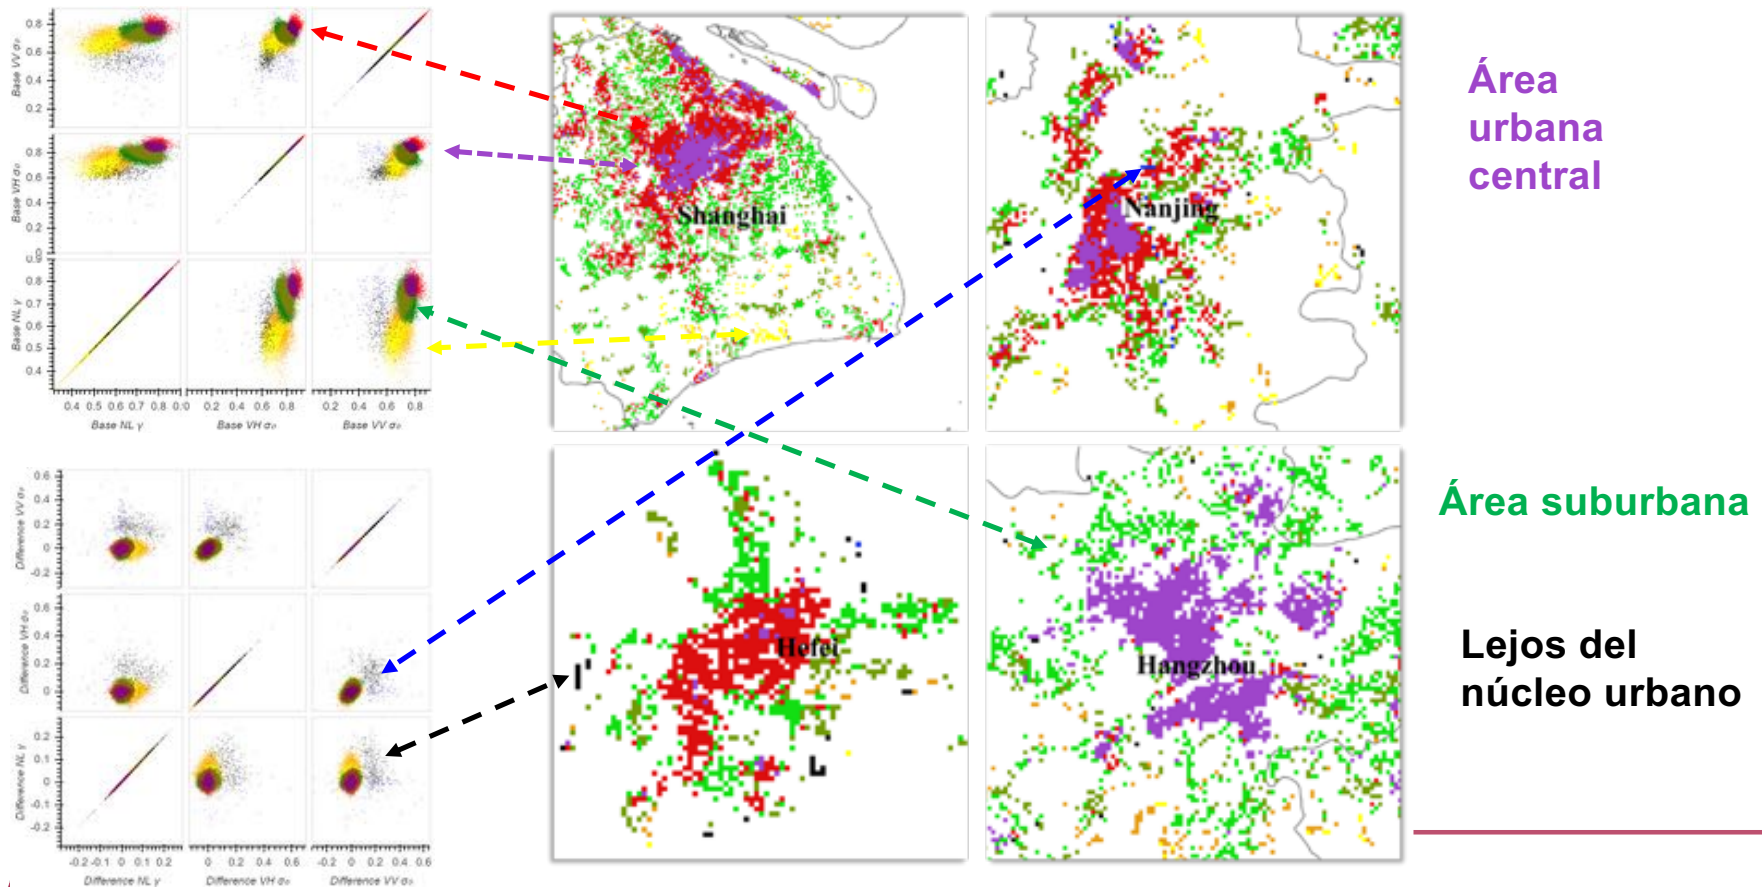
Pequeñas localidades, fábricas y aeropuertos alejados del núcleo urbano, pero con fuerte actividad de construcción (incremento de valores de sentinel-1 y luz nocturna)

El aumento de la iluminación indica una actividad económica más fuerte

Resultados




Mapeo de patrones de 8 componentes




UNIVERSITÀ DI PAVIA

Purple cluster: core urban areas, with high building density and high urbanization level. **Red cluster:** core urban areas with a lower building density.

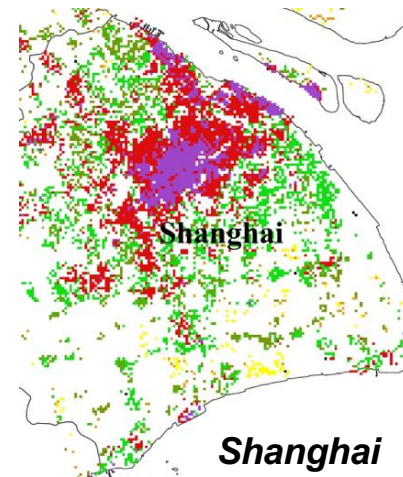
Validación




Beijing



Tianjin



Shanghai



Nanjing

Megalopolis	Urban extents		Change detection	
	OA(/100%)	<i>Kappa</i>	Cluster	Detected Rate (/100%)
YTZ	98.61	0.9289	3/4	86.67
JJJ	96.51	0.8645	1/2/4	83.33



Lecciones aprendidas

- Podemos aprovechar la resolución espacial y temporal más fina de los datos SAR existentes (más allá de la interferometría) y obtener un análisis bastante preciso de los cambios en el “paisaje urbano” 2D/3D.
- La combinación de SAR de resolución fina y datos nocturnos más burdos ayuda a centrar el análisis y a hacer una interpretación más interesante de los cambios intraurbanos.
- Todavía hay margen de mejora, por ejemplo, una mejor identificación automática de los cambios 3D o el uso de índices urbanos multispectrales (NDBI, NBI, etc.)



Datos multispectrales en lugar de luces nocturnas



UNIVERSITÀ DI PAVIA

Índices urbanos (S2)


- Se evaluaron varios índices
 - en cuanto a la extracción de lo urbano;
 - en cuanto a la caracterización de los cambios.

Built-up Index	Symbol	Formula
Normalized Difference Built-up Index	NDBI	$\frac{SWIR2 - NIR}{SWIR2 + NIR}$
New Built-up Index	NBI	$\frac{RED * SWIR2}{NIR}$
Normalized Built-up Area Index	NBAI	$\frac{SWIR2 - SWIR1/GREEN}{SWIR2 + SWIR1/GREEN}$
Perpendicular Impervious Surface	PISI	$0.8192 * Blue - 0.5735 * NIR + 0.0750$
Built-up land features extraction index	BLFEI	$\frac{(GREEN + RED + SWIR2)/3 - SWIR1}{(GREEN + RED + SWIR2)/3 + SWIR1}$



Análisis de los índices (cuantitativo)

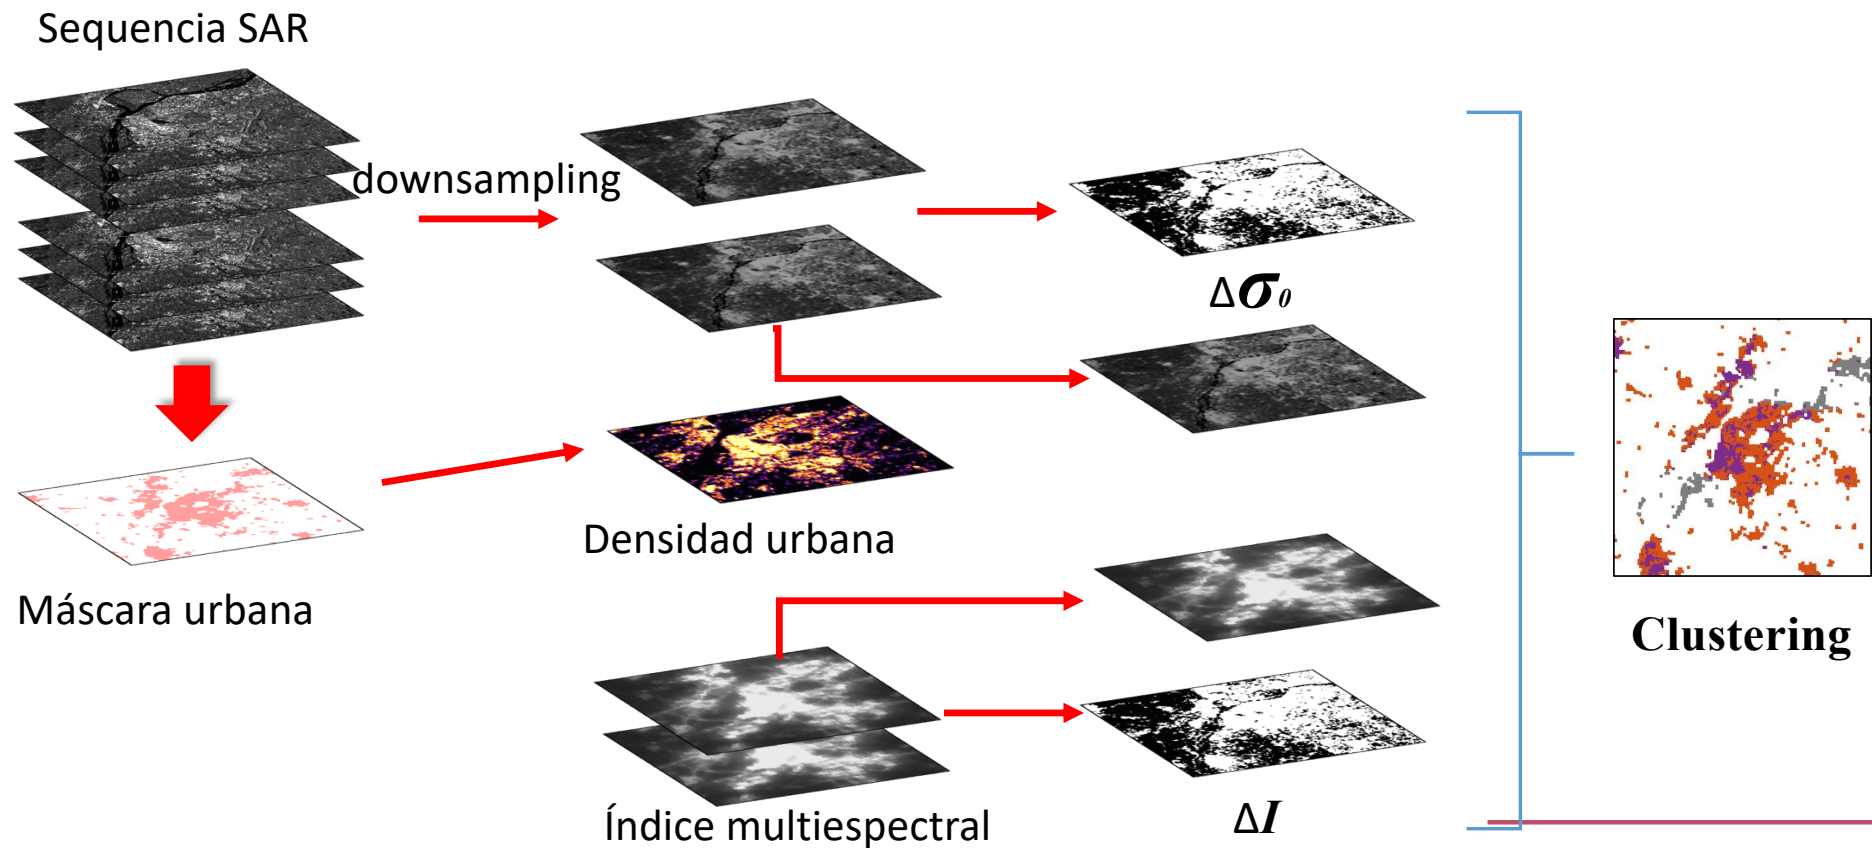
- Utilizando los datos de Planet a 3 m en 2017, 2019 y 2022 como referencia





	2017*		2019		2022	
	OA	K	OA	K	OA	K
NDBI	0,88	0,76	0,90	0,79	0,83	0,65
NBI	0,90	0,71	0,92	0,84	0,99	0,98
NBAI	0,86	0,73	0,88	0,77	0,91	0,83
PISI	0,93	0,87	0,85	0,70	0,95	0,91
BLFEI	0,97	0,93	0,92	0,84	0,99	0,99




SAR multitemporal y datos multispectrales



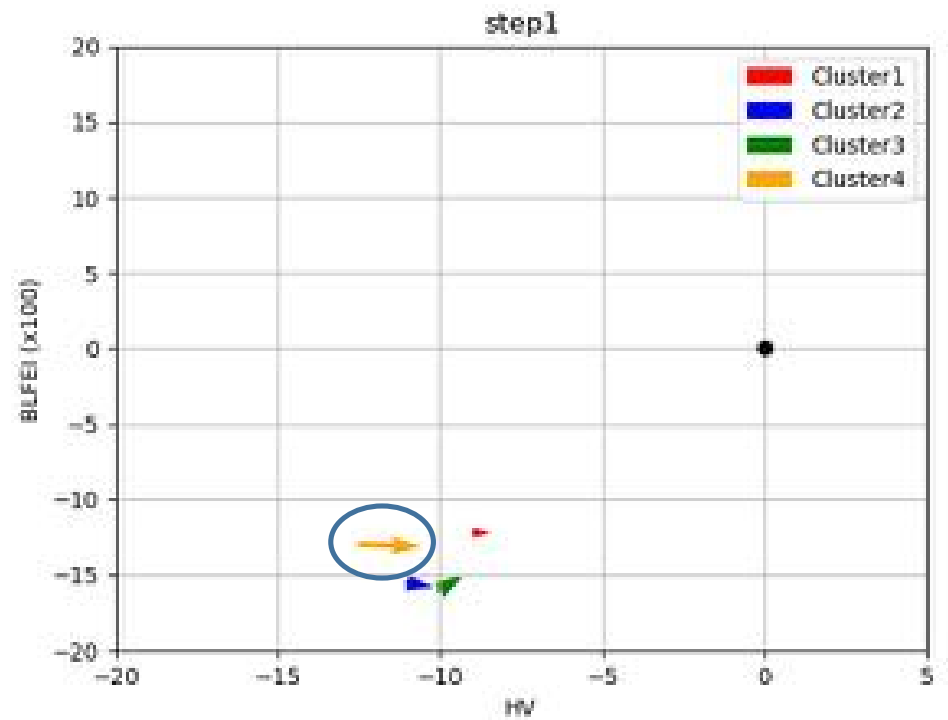

SAOCOM + VIIRS: Cordoba 2020-2021





ΔI



Cluster en el periodo 2017-2019 (500 m)



Cluster en el periodo 2017-2019 (30 m)



Ej. 1 del grupo 4 (amarillo a 500 m, verde a 30m)




Basemap



2017



2019



@ 200 m



@ 30 m



Ejemplo 2



2017



2019

2019



@ 200 m

@ 30 m



2 →



References

- M. Che and P. Gamba, "Change Pattern Exploration with Hierarchical Bi-Clustering on Sentinel-1 SAR and Nighttime Light Data," Proc. of the 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS), Santiago, Chile, 2020, pp. 48-53, doi: 10.1109/LAGIRS48042.2020.9165612.
- M. Che, P. Gamba, "Intra-urban change analysis using Sentinel-1 and nighttime light data", IEEE J. of Selected Topics in Applied Earth Observation and Remote Sensing, doi: 10.1109/JSTARS.2019.2899881, vol. 12, no. 4, pp. 1134-1142, April 2019.
- M. Che, A. Vizziello, P. Gamba, "Urban Change Pattern Exploration for Megacities using Multi-Temporal Nighttime Light and Sentinel-1 SAR Data," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, doi: 10.1109/JSTARS.2021.3119419, vol. 14, pp. 10681-10690, 2021.
- ...



Caracterización urbana 3D

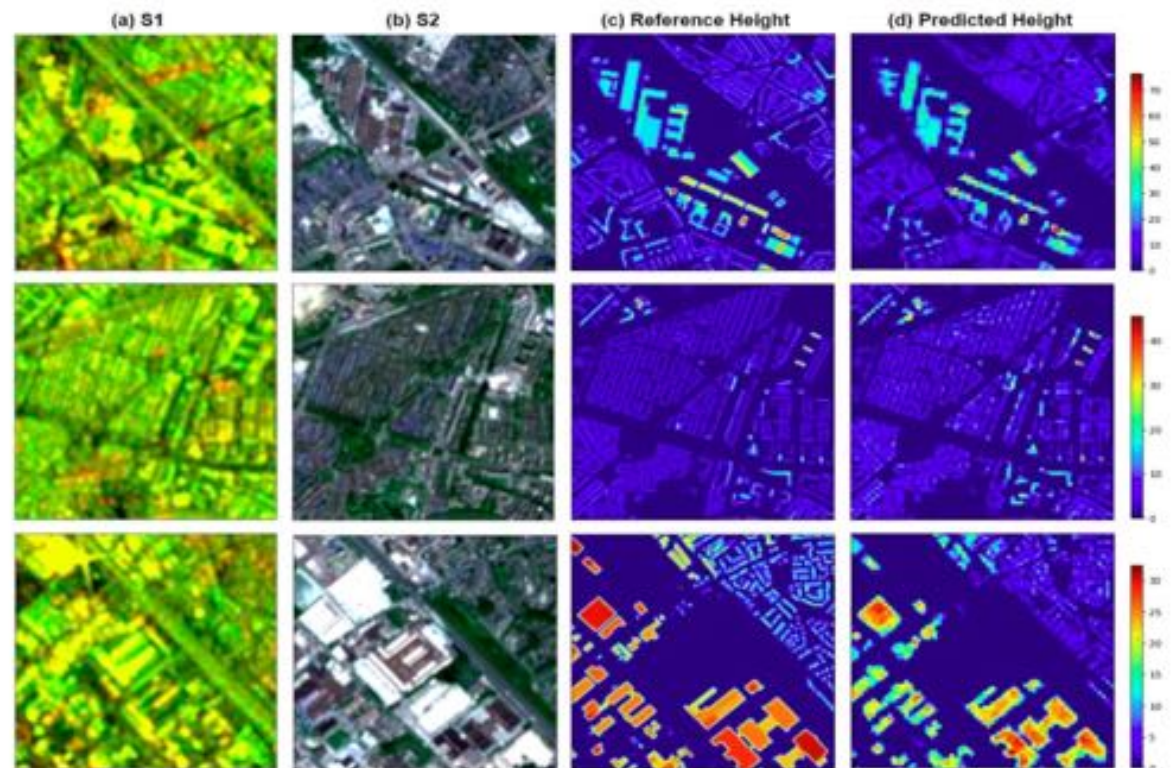


UNIVERSITÀ DI PAVIA

Regresión de altura de BU

- ❖ Los resultados alentadores en la localización 2D de las áreas de BU impulsaron una mayor exploración del análisis de altura 3D utilizando imágenes satelitales.
- ❖ Existen varios enfoques de vanguardia para modelar la recuperación de altura de los edificios como un problema de regresión.
- ❖ [1] propone una red de regresión de altura de edificios multimodal supervisada (MBHR-Net) para estimar las alturas de los edificios con una resolución espacial de 10 m utilizando datos satelitales Sen-1 y Sen-2.

[1] Yadav, R., Nascetti, A., & Ban, Y. (2023). A CNN regression model to estimate buildings height maps using Sentinel-1 SAR and Sentinel-2 MSI time series. ArXiv preprint arXiv:2307.01378.



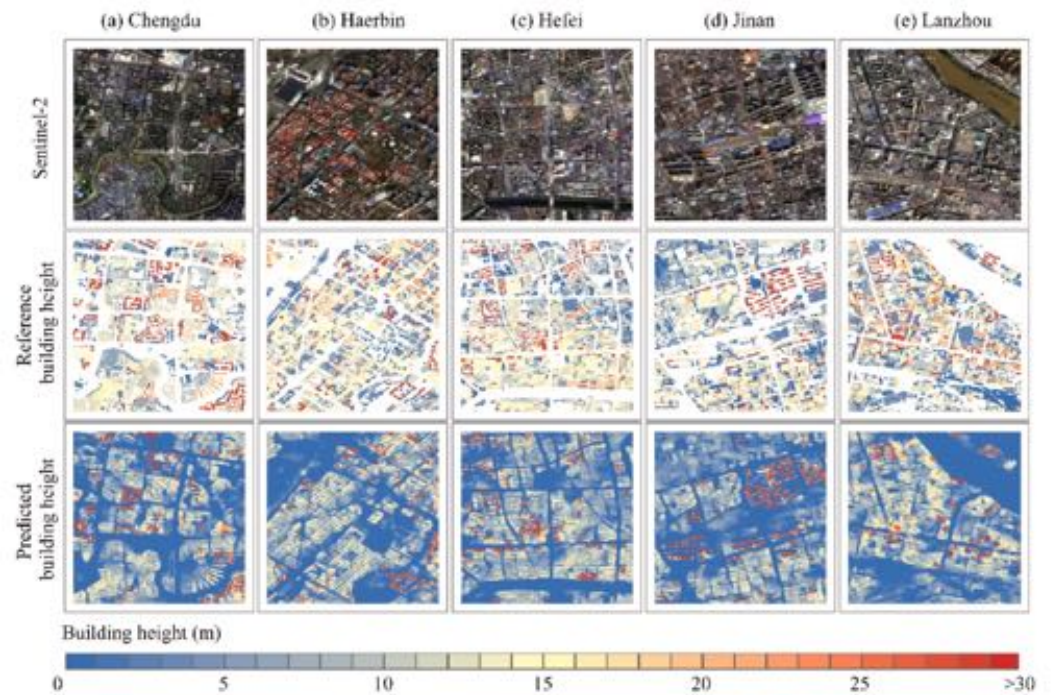
Qualitative visual comparison of the results obtained from the methodology implemented in [1].

Regresión de altura de BU (continuación)

- ❖ [2] introduce una red de estimación de altura de edificios con estructura de doble rama (BHE-NET) y un módulo multimodal Selective-Kernel (MSK) mejorado para fusionar características ópticas y SAR.
- ❖ [3] introduce un método que utiliza imágenes multispectrales y multivista HR ZY-3 para estimar la altura de los edificios con una resolución espacial de 2,5 m, empleando una red profunda de aprendizaje multitarea (M3Net).

[2] Bowen Cai, Zhenfeng Shao, Xiao Huang, Xuechao Zhou, Shenghui Fang, Deep learning-based building height mapping using Sentinel-1 and Sentinel-2 data, International Journal of Applied Earth Observation and Geoinformation, Volume 122, 2023, 103399, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2023.103399>.



[3] Yinxia Cao, Xin Huang, A deep learning method for building height estimation using high-resolution multi-view imagery over urban areas: A case study of 42 Chinese cities, Remote Sensing of Environment, Volume 264, 2021, 112590, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2021.112590>.



Comparison of predicted and reference building heights on the validation dataset from [2].



Attention U(Regression)-Net





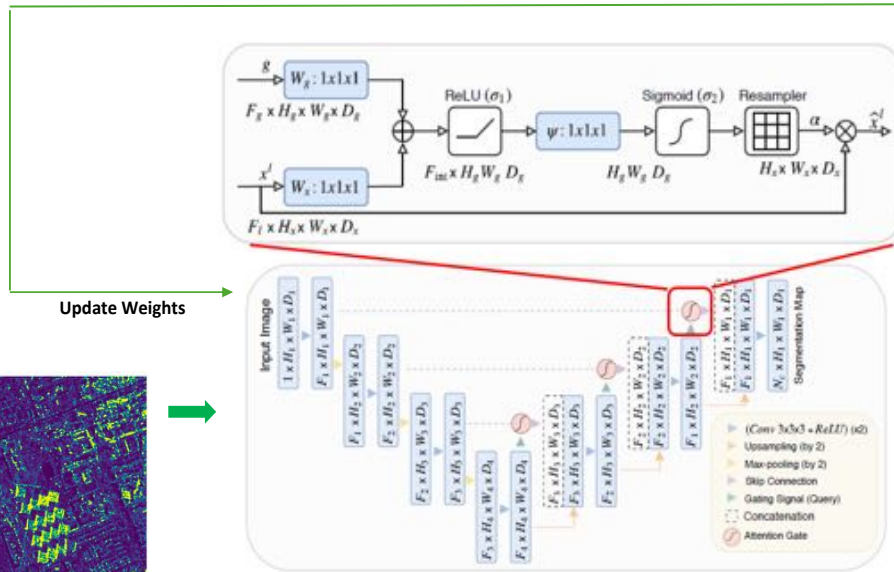
OSM Binary Footprint Mask

Ground Truth (nDSM)

$nDSM = DSM - DTM$



$nDSM = DSM - DTM$
Normalized DSM



Input - CSK

Resultados

- ❖ Se muestran comparaciones visuales (Pred vs. GT) en el conjunto de validación para el enfoque propuesto para varias muestras.
- ❖ Nuestro modelo demuestra un rendimiento sólido en términos de RMSE, logrando un valor de error promedio final de 1,095 (m) en la regresión de altura de BU.
- ❖ Esto se logra aprovechando solo la información de radar pura proporcionada por los datos VHR COSMO-SkyMed.

	RMSE (m)	Source
Ref. [1]	3.73	Optical + Radar
Ref. [2]	4.6502	Optical + Radar
Ref. [3]	0.847	Optical
OURS	1.095	Radar

