



Reconocimiento de cultivos agrícolas en regiones tropicales usando secuencias de imágenes de teledetección de sensores activos y pasivos

Ph.D. Pedro M. Achancaray Diaz

pedro.diaz@puc-rio.br

Outline



1. Introducción

2. CRFs

3. Resultados

4. Conclusiones

Outline



1. Introducción

2. CRFs

3. Resultados

4. Conclusiones

Introducción

- Agricultura
 - Fuente de **sustento**
 - Contribuye a los **ingresos nacionales**
 - Fuente de **materia prima**
 - Suministro de **alimentos y pasto**

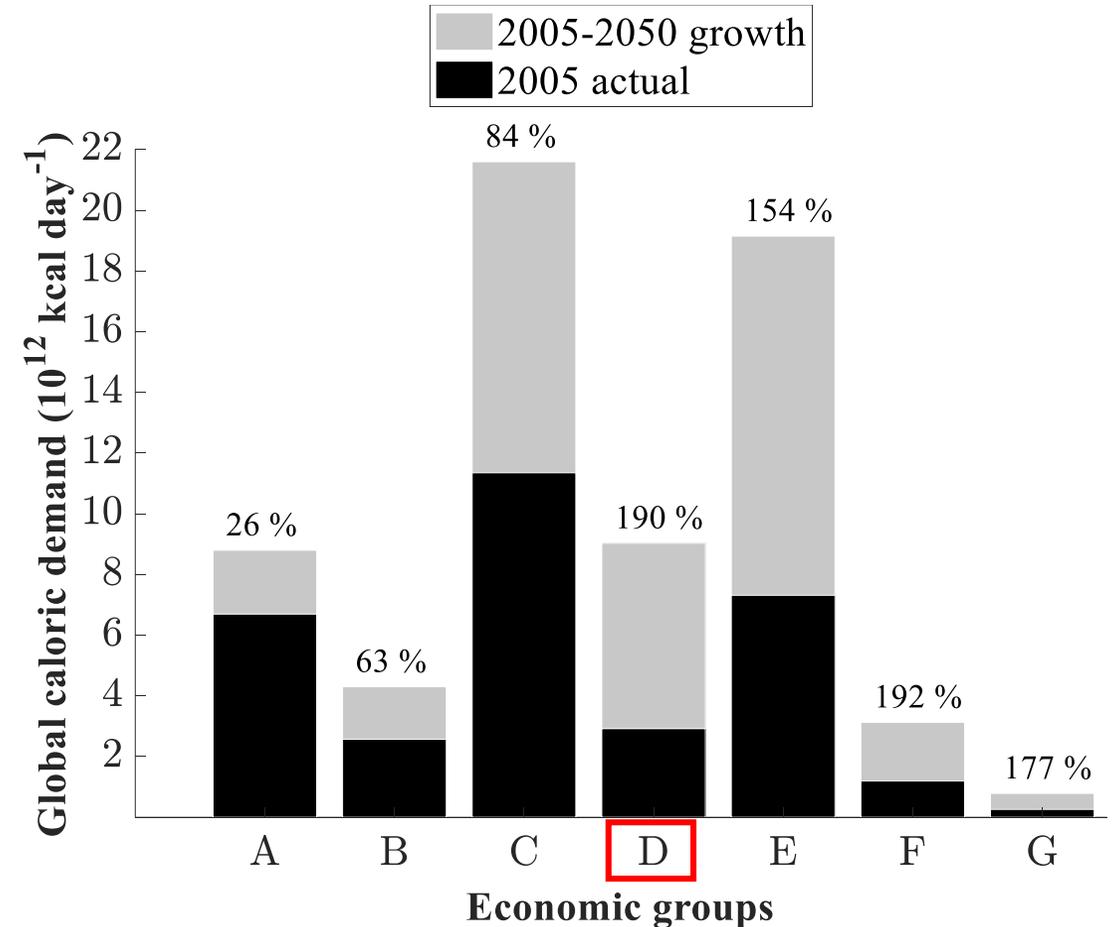


Introducción

- Agricultura – Retos
 - Reducir **impacto ambiental**

Introducción

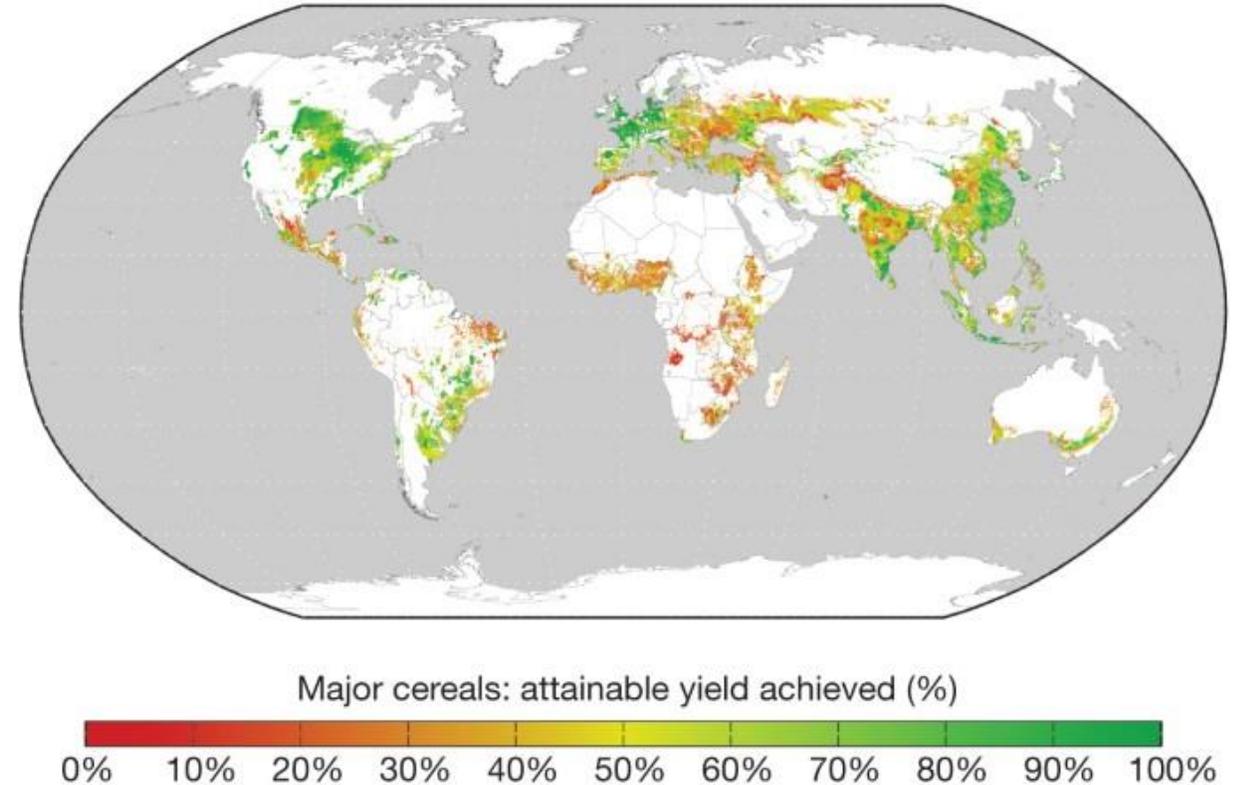
- Agricultura – Retos
 - Reducir impacto ambiental
 - Aumento de la demanda de alimentos



Fuente: FAO – UN (Food and Agriculture Organization of the United Nations)
THENKABAIL, P. S.. Land resources monitoring, modeling, and mapping with remote sensing. CRC Press, 2015.

Introducción

- Agricultura – Retos
 - Reducir **impacto ambiental**
 - Aumento de la **demanda de alimentos**
 - Reducir la brecha de rendimiento (**yield gap**)



Fuente: MUELLER, N. D.; GERBER, J. S.; JOHNSTON, M.; RAY, D. K.; RAMANKUTTY, N. ; FOLEY, J. A.. Closing yield gaps through nutrient and water management. *Nature*, 490(7419):254, 2012.

Introducción



- Agricultura – Soluciones
 - **Mapear tipos de cultivos y área cultivada**
 - Inventarios sobre cultivos
 - Predicción de rendimiento
 - Monitoreo de actividades agrícolas

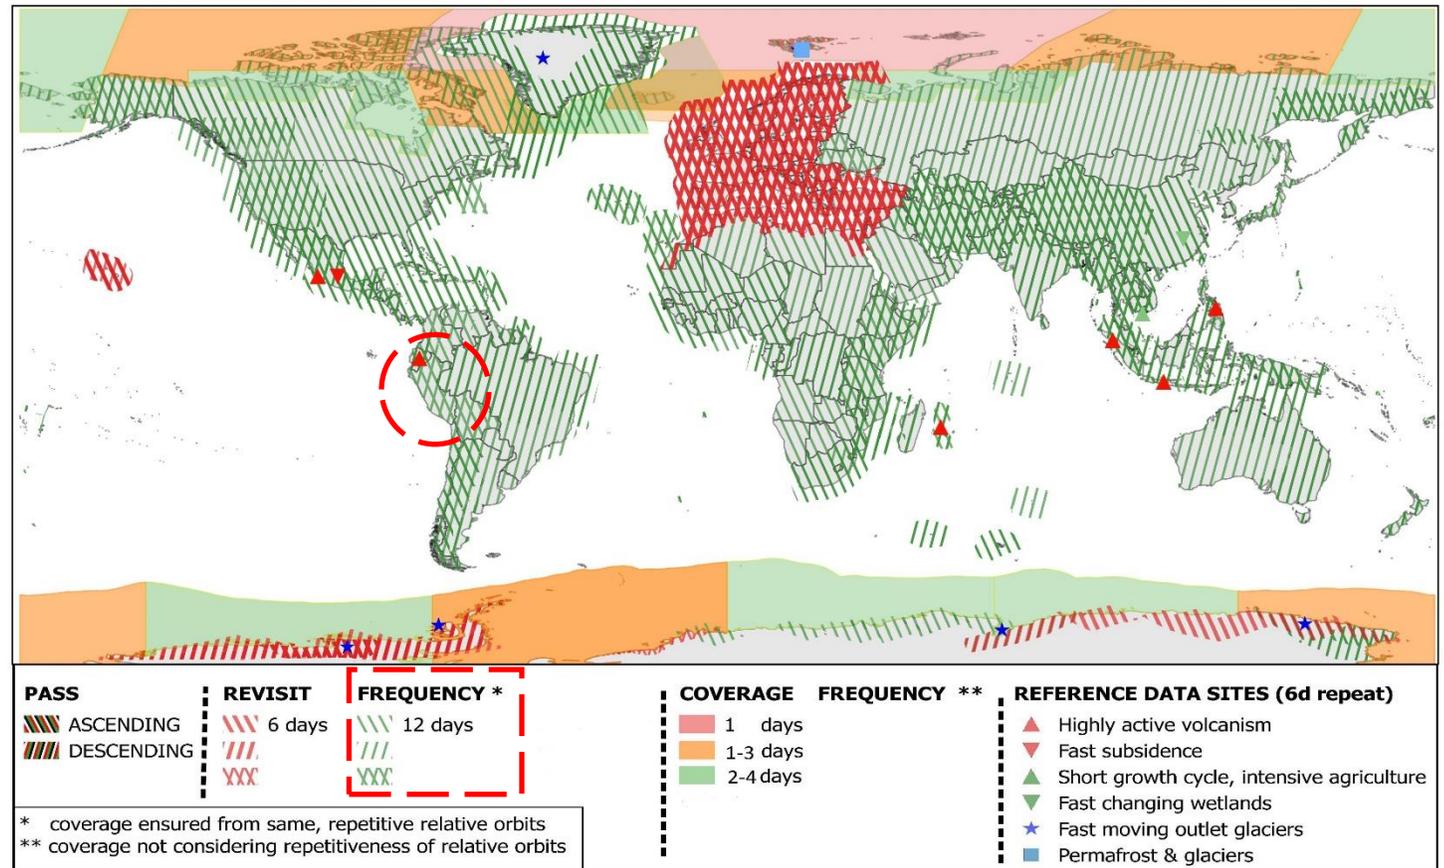
Introducción

- Agricultura – Teledetección (*Remote Sensing*)

Source: European Space Agency – ESA
 (<https://sentinel.esa.int/web/sentinel/missions/sentinel-1/observation-scenario>)

- Gran cobertura
- Alta frecuencia y repetitivo
- Costo relativamente bajo
- Resoluciones espaciales
 - Bajo, medio y alto

Sentinel-1 Constellation Observation Scenario: Revisit & Coverage Frequency



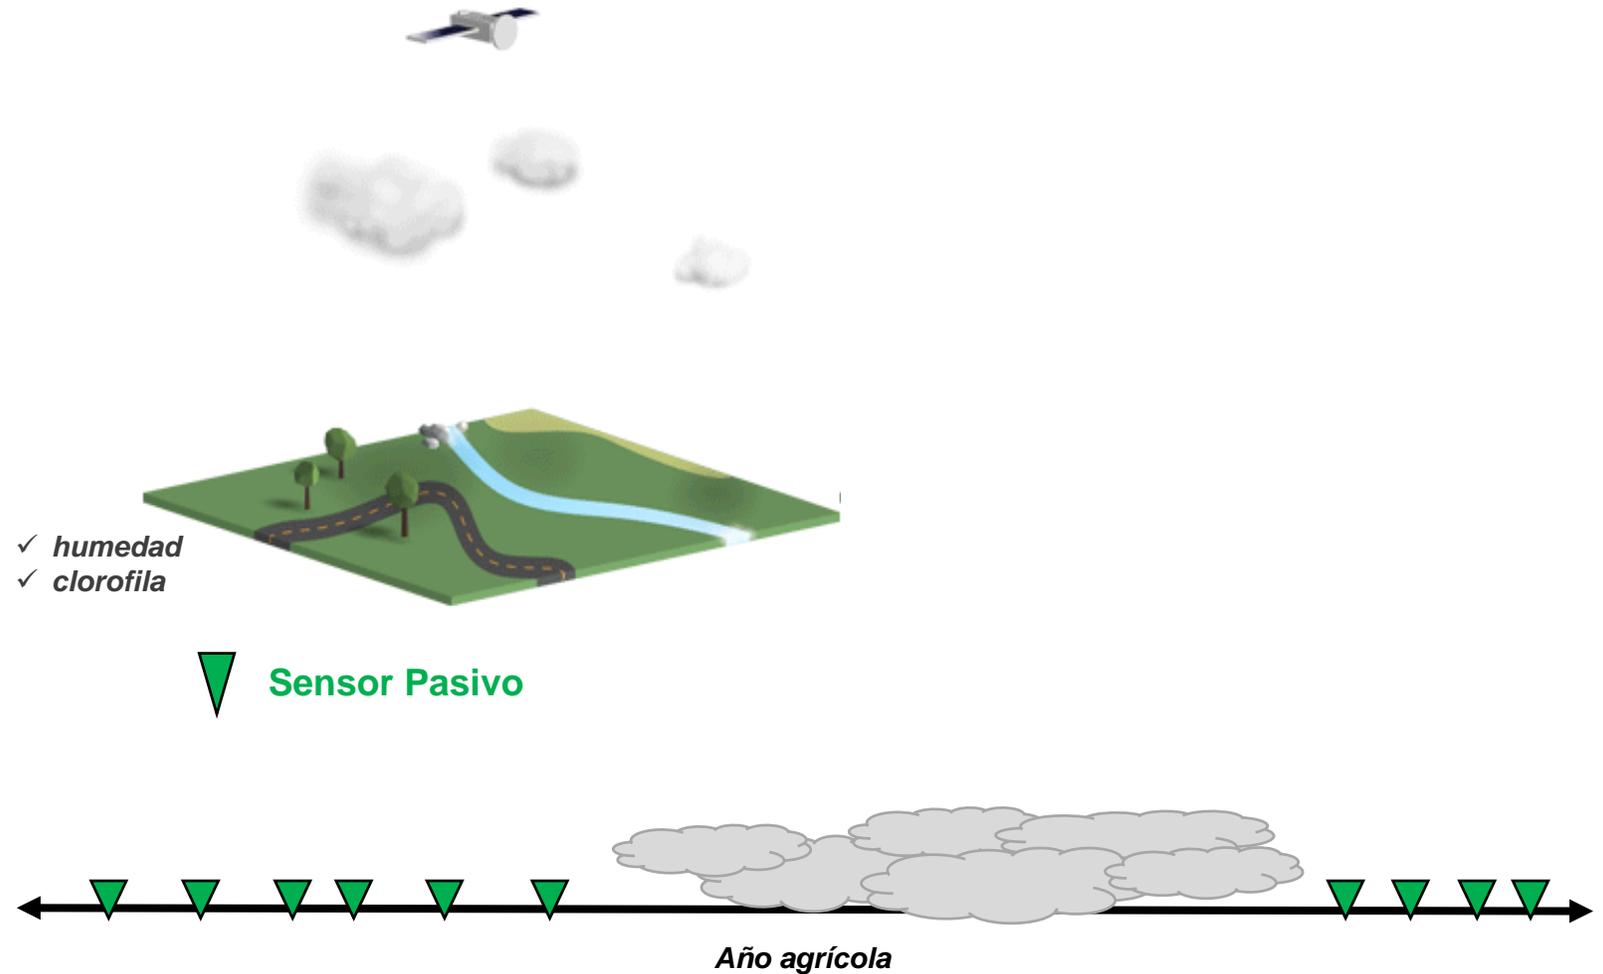
Introducción

- Teledetección (*Remote Sensing*)

Introducción

Source: NASA Earth Observatory (<https://earthobservatory.nasa.gov/features/SoilMoisture>)

- Teledetección (*Remote Sensing*)
 - Sensores pasivos
 - Ópticos



Introducción

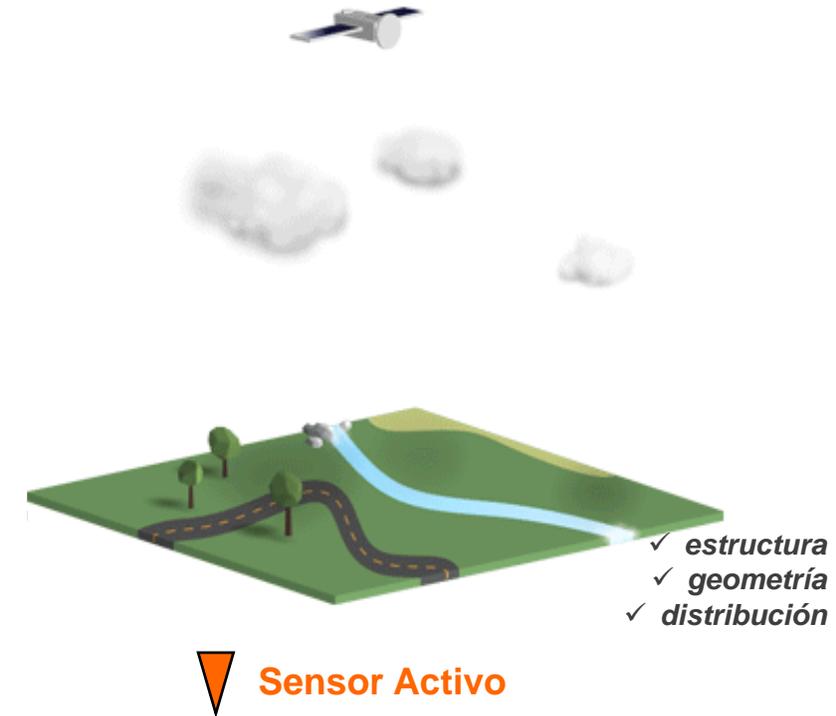
Source: NASA Earth Observatory (<https://earthobservatory.nasa.gov/features/SoilMoisture>)

- Teledetección (*Remote Sensing*)

- **Sensores activos**

- **Radar de abertura**

Sintética (SAR)



Introducción

Source: NASA Earth Observatory (<https://earthobservatory.nasa.gov/features/SoilMoisture>)

- Teledetección (*Remote Sensing*)

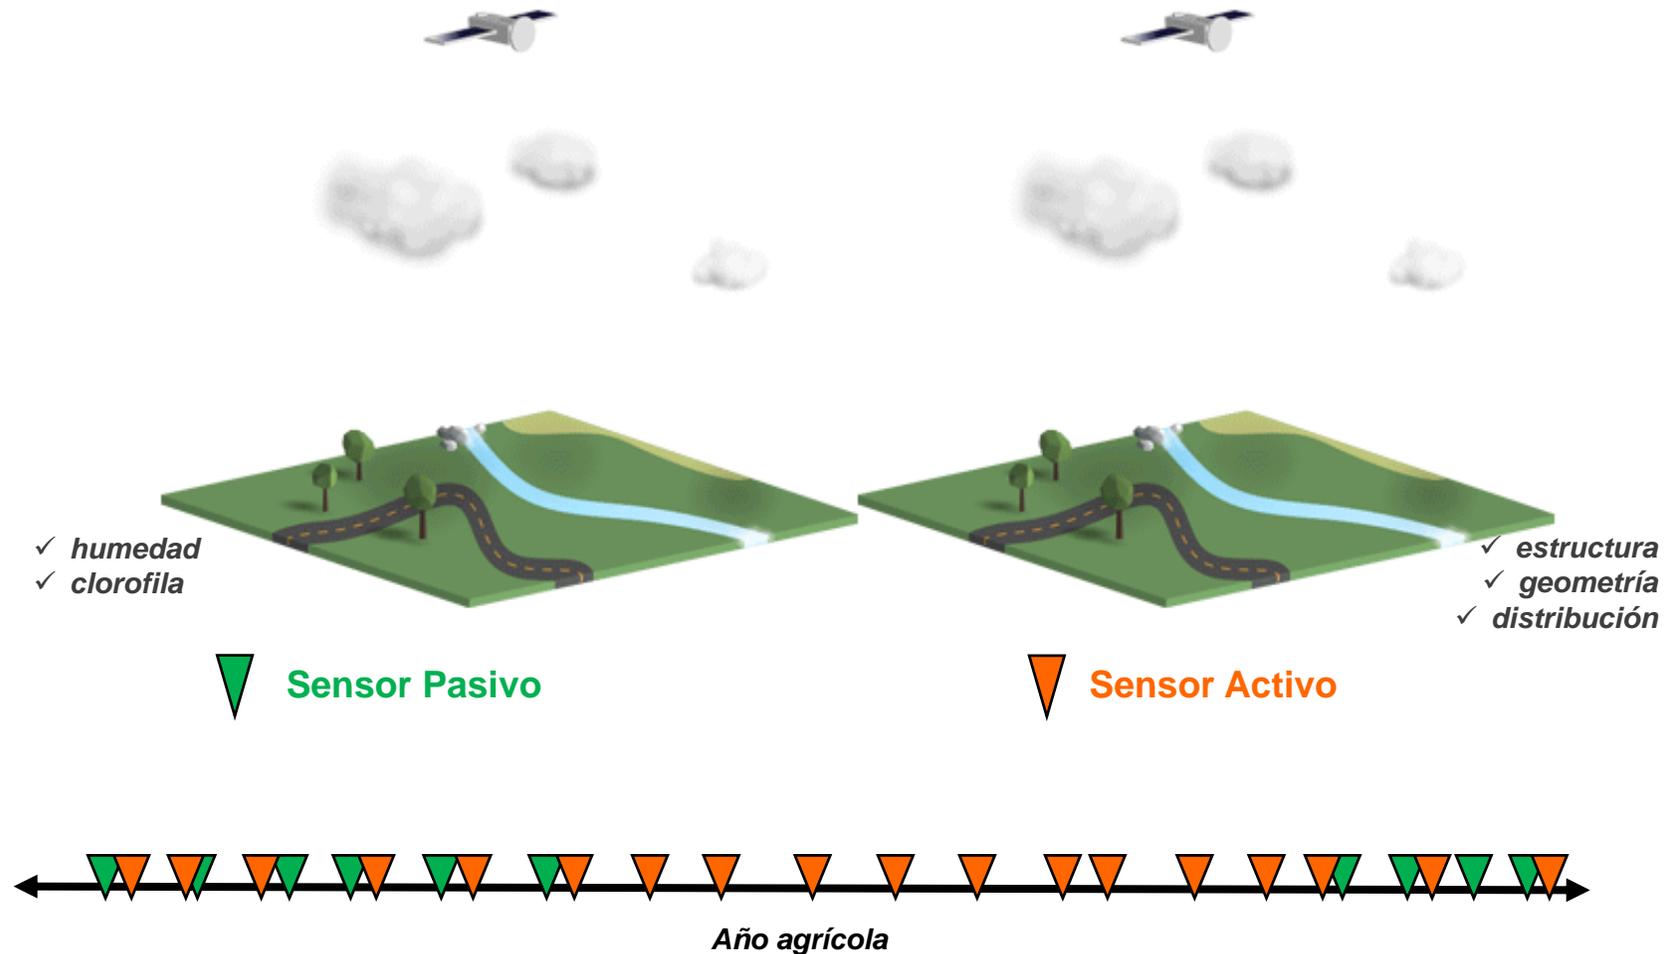
- Sensores pasivos

- Ópticos

- Sensores activos

- Radar de abertura

- Sintética (SAR)



Introducción

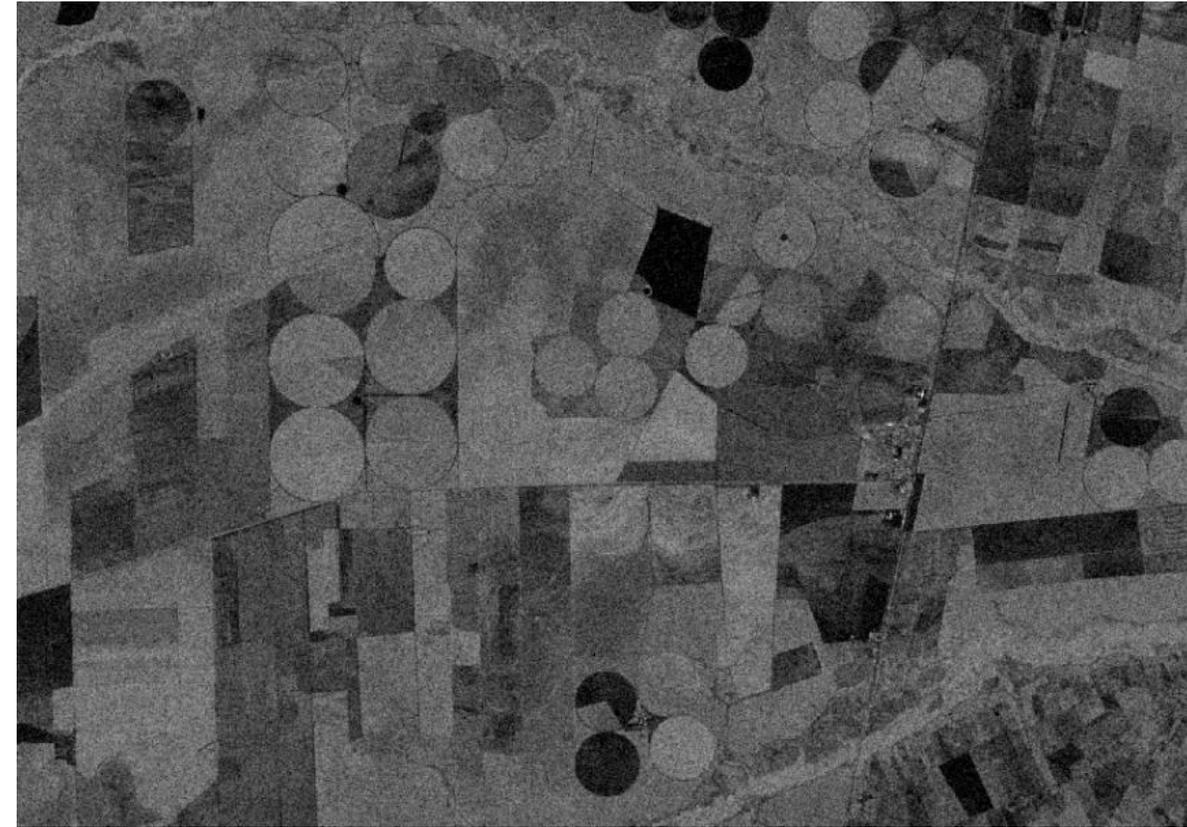
- Teledetección (*Remote Sensing*)

*Composición RGB de imagen Sentinel-2A
adquirida el 19 de Junio, 2018 en Bahía, Brazil*



Sensor Pasivo

*Banda C, SAR, polarización VH, imagen Sentinel-1A
adquirida el 19 de Junio, 2018 en Bahía, Brazil*



Sensor Activo

Introducción



- Características de Cultivos Agrícolas

Introducción



- Características de Cultivos Agrícolas

- Información de contexto

- *“everything is related to everything else, but near things are more related than distant things”– Waldo Tobler. (1st Law of Geography)*

Introducción

- Características de Cultivos Agrícolas

- Información de contexto

- *“everything is related to everything else, but near things are more related than distant things”– Waldo Tobler. (1st Law of Geography)*

- Contexto Espacial



Introducción

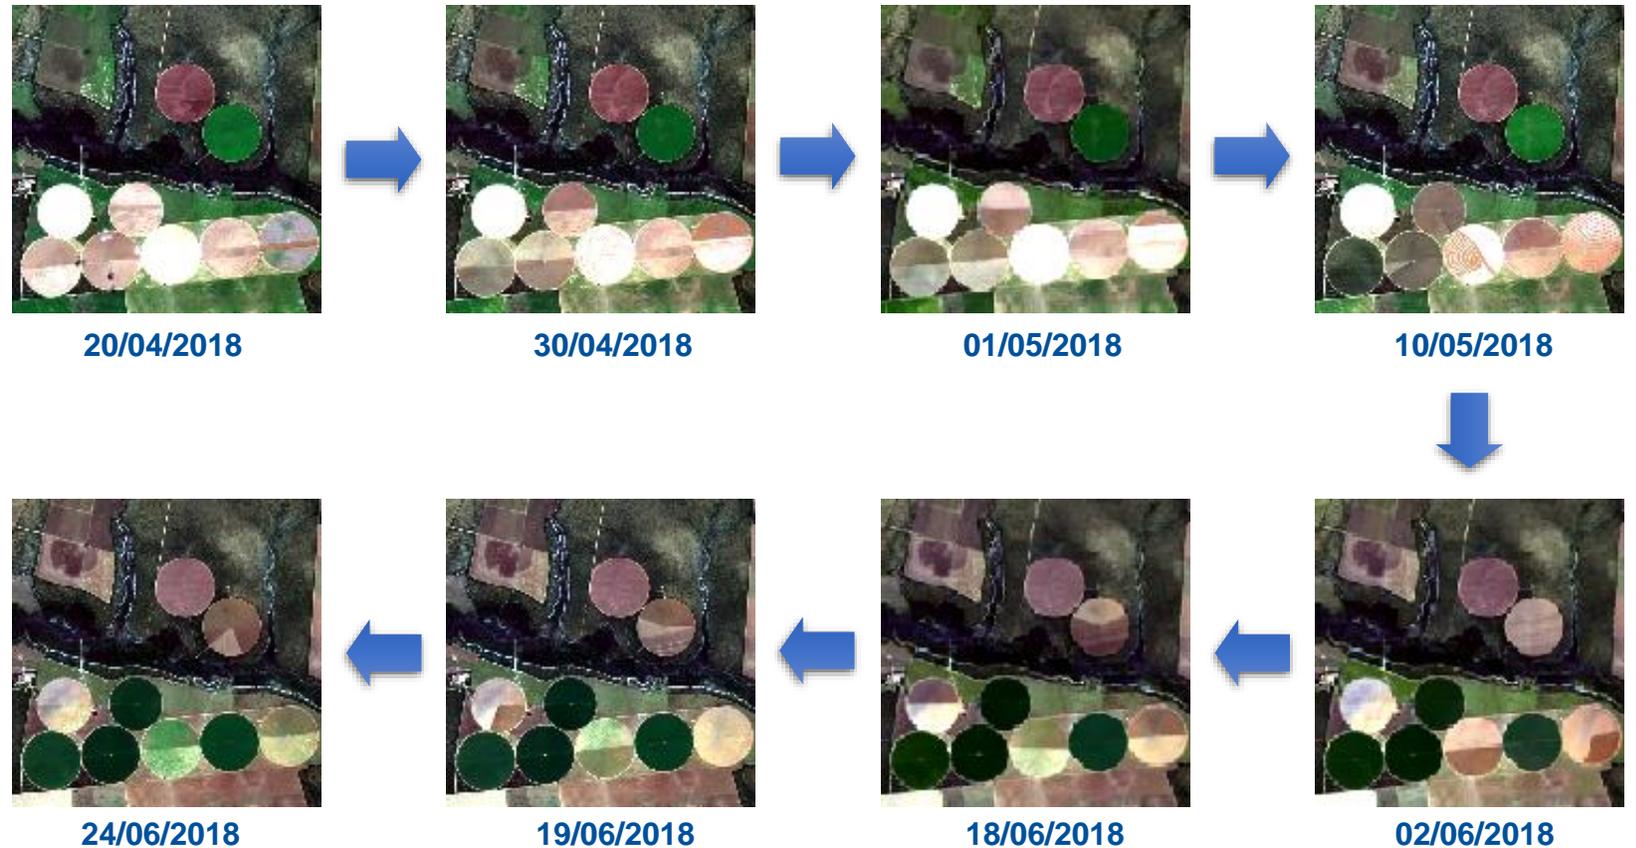
- Características de Cultivos Agrícolas

- Información de contexto

- “everything is related to everything else, but near things are more related than distant things”– Waldo Tobler. (1st Law of Geography)

- Contexto Espacial

- Contexto Temporal



Outline



1. Introducción

2. CRFs

3. Resultados

4. Conclusiones

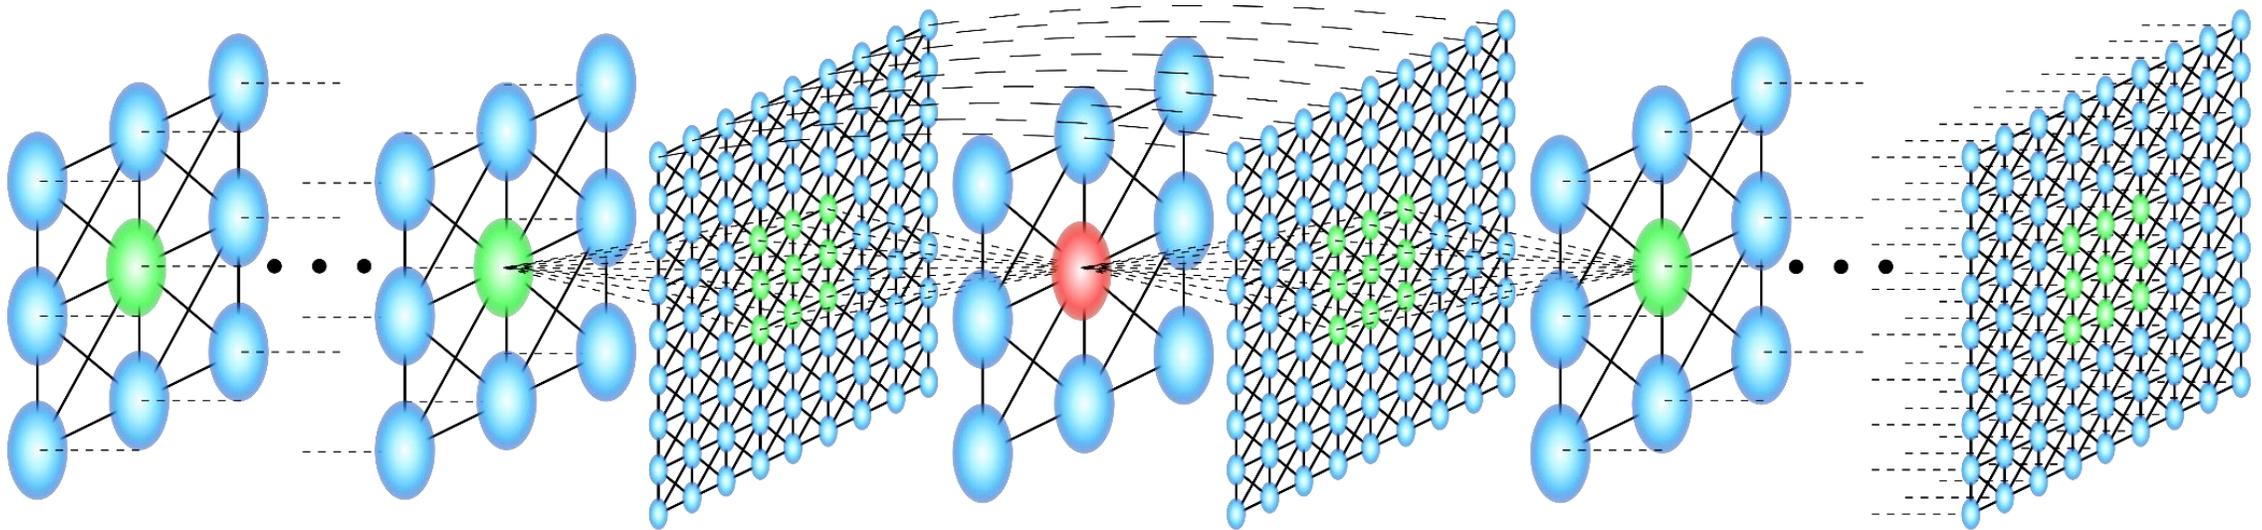
Multi-temporal CRF



- Conditional Random Fields (CRFs)
- Clasificador discriminativo, basado en grafos

Multi-temporal CRF

- Conditional Random Fields (CRFs)
- Clasificador discriminativo, basado en grafos



Multi-temporal CRF



Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label
- Multi-temporal CRF estima la probabilidad posterior $P(\mathbf{y}|\mathbf{x})$ de tener los labels \mathbf{y} dado los datos \mathbf{x}

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label
- Multi-temporal CRF estima la probabilidad posterior $P(\mathbf{y}|\mathbf{x})$ de tener los labels \mathbf{y} dado los datos \mathbf{x}

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label
- Multi-temporal CRF estima la probabilidad posterior $P(\mathbf{y}|\mathbf{x})$ de tener los labels \mathbf{y} dado los datos \mathbf{x}

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

Constante de Normalización

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label
- Multi-temporal CRF estima la probabilidad posterior $P(\mathbf{y}|\mathbf{x})$ de tener los labels \mathbf{y} dado los datos \mathbf{x}

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

Constante de Normalización

Potencial de Asociación: relación entre datos y labels

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label
- Multi-temporal CRF estima la probabilidad posterior $P(\mathbf{y}|\mathbf{x})$ de tener los labels \mathbf{y} dado los datos \mathbf{x}

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

Constante de Normalización

Potencial de Asociación: relación entre datos y labels

Potencial de Interacción Espacial: como un pixel interactúa con sus vecinos espaciales

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label
- Multi-temporal CRF estima la probabilidad posterior $P(\mathbf{y}|\mathbf{x})$ de tener los labels \mathbf{y} dado los datos \mathbf{x}

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

Constante de Normalización

Potencial de Asociación: relación entre datos y labels

Potencial de Interacción Espacial: como un pixel interactúa con sus vecinos espaciales

Potencial de Interacción Temporal: como un pixel interactúa con sus vecinos en el dominio temporal

Multi-temporal CRF

- Dado T imágenes co-registradas $t = 1, \dots, T$
- $i \in S$, representa un área geográfica
- $\mathbf{x} = \{\mathbf{x}_{i,t}\}_{i \in S, t \in T}$: atributo extraído en i y época t , $\mathbf{y} = \{y_{i,t}\}_{i \in S, t \in T}$ su respectivo label
- Multi-temporal CRF estima la probabilidad posterior $P(\mathbf{y}|\mathbf{x})$ de tener los labels \mathbf{y} dado los datos \mathbf{x}

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

Pesos de cada potencial

Constante de Normalización

Potencial de Asociación: relación entre datos y labels

Potencial de Interacción Espacial: como un pixel interactúa con sus vecinos espaciales

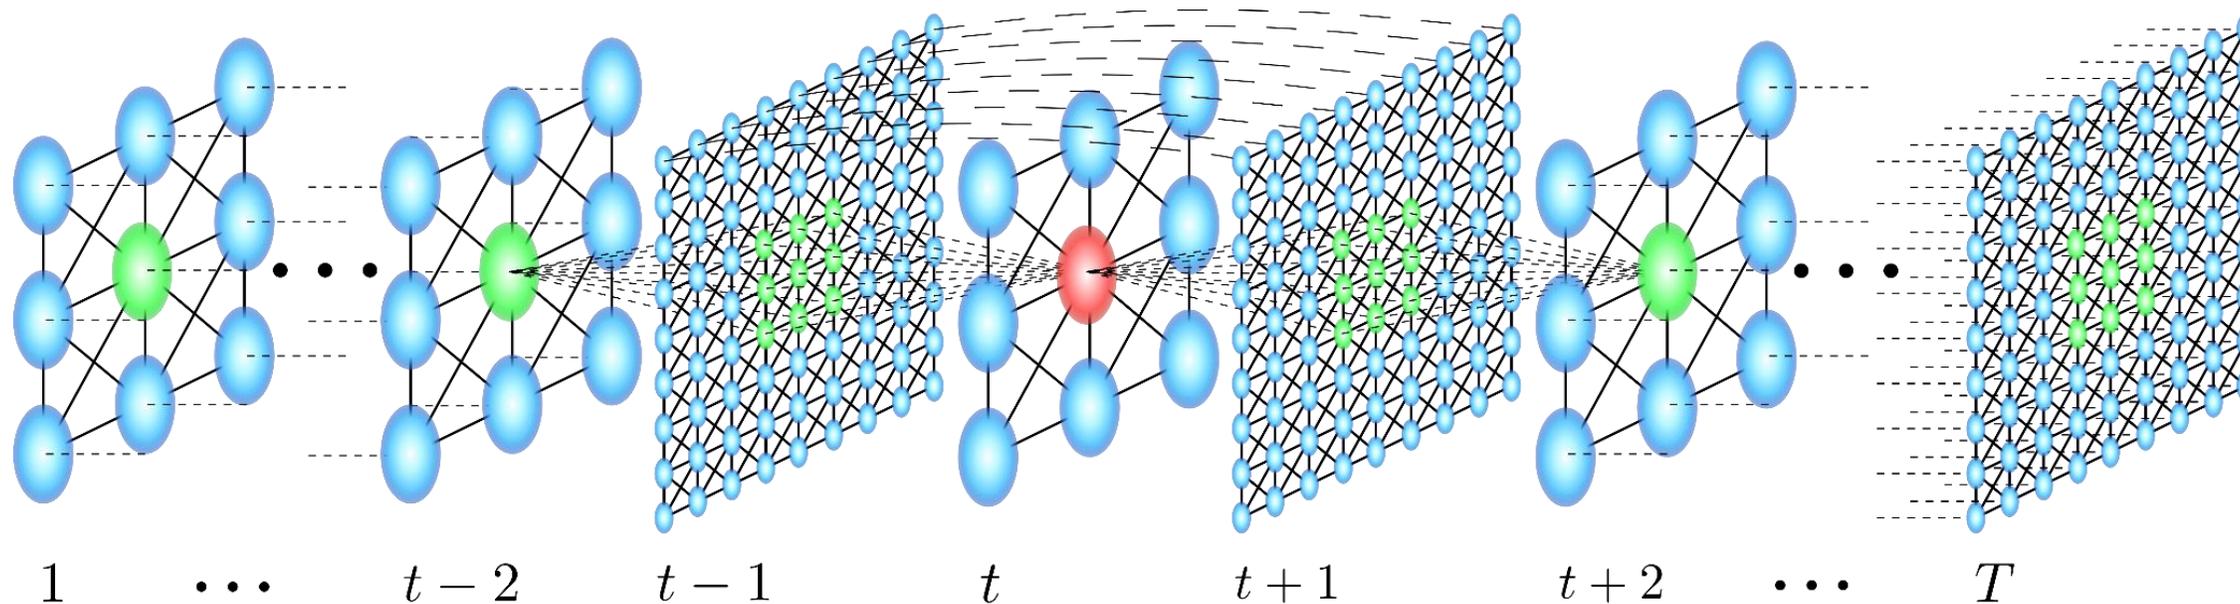
Potencial de Interacción Temporal: como un pixel interactúa con sus vecinos en el dominio temporal

Multi-temporal CRF

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

Multi-temporal CRF

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$



- Spatial Interaction Potential
- Temporal Interaction Potential First Order
- - - Temporal Interaction Potential Higher Order

Multi-temporal CRF

$$P(\mathbf{y}|\mathbf{x}) = \frac{1}{Z} \left[\exp \left(\sum_{t \in T} \sum_{i \in S} AP^t(y_{i,t}, \mathbf{x}) + \theta \sum_{t \in T} \sum_{i \in S} \sum_{j \in N_i} SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}) + \sum_{t \in T} \phi^t \sum_{i \in S} \sum_{k \in C_i} TIP^{tk}(y_{i,t}, y_{i,k}, \mathbf{x}) \right) \right]$$

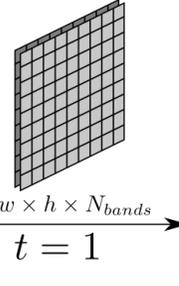
- **Potencial de Asociación**
 - Random Forest + atributos de textura (GLCM)
 - CNN usando cada imagen
 - CNN usando el stack de todas las imágenes
- **Potencial de Interacción Espacial**
 - Modelo Contrast-sensitive Potts
- **Potencial de Interacción Temporal**
 - Información de especialistas sobre transiciones posibles

Potencial de Asociación

Random Forest + atributos de textura (GLCM)

$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{RF^t}(y_{i,t} | \mathbf{f}_{GLCM}(\mathbf{x}_{N_{i,t}}))$$

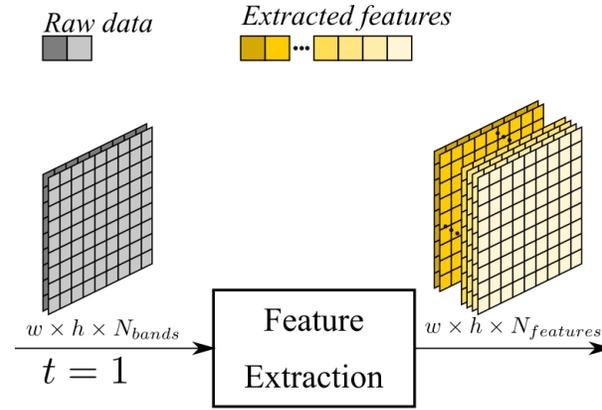
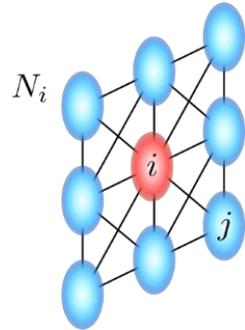
Raw data



Potencial de Asociación

Random Forest + atributos de textura (GLCM)

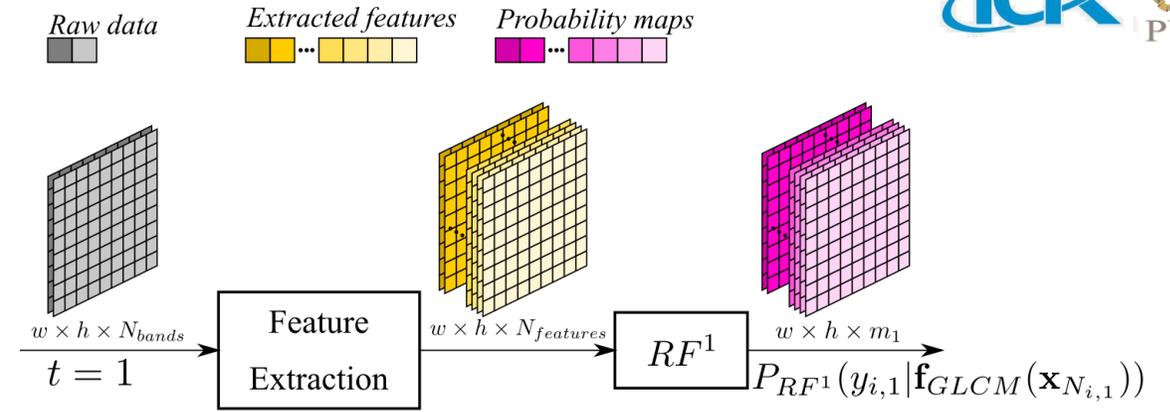
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{RF^t}(y_{i,t} | \mathbf{f}_{GLCM}(\mathbf{x}_{N_i,t}))$$



Potencial de Asociación

Random Forest + atributos de textura (GLCM)

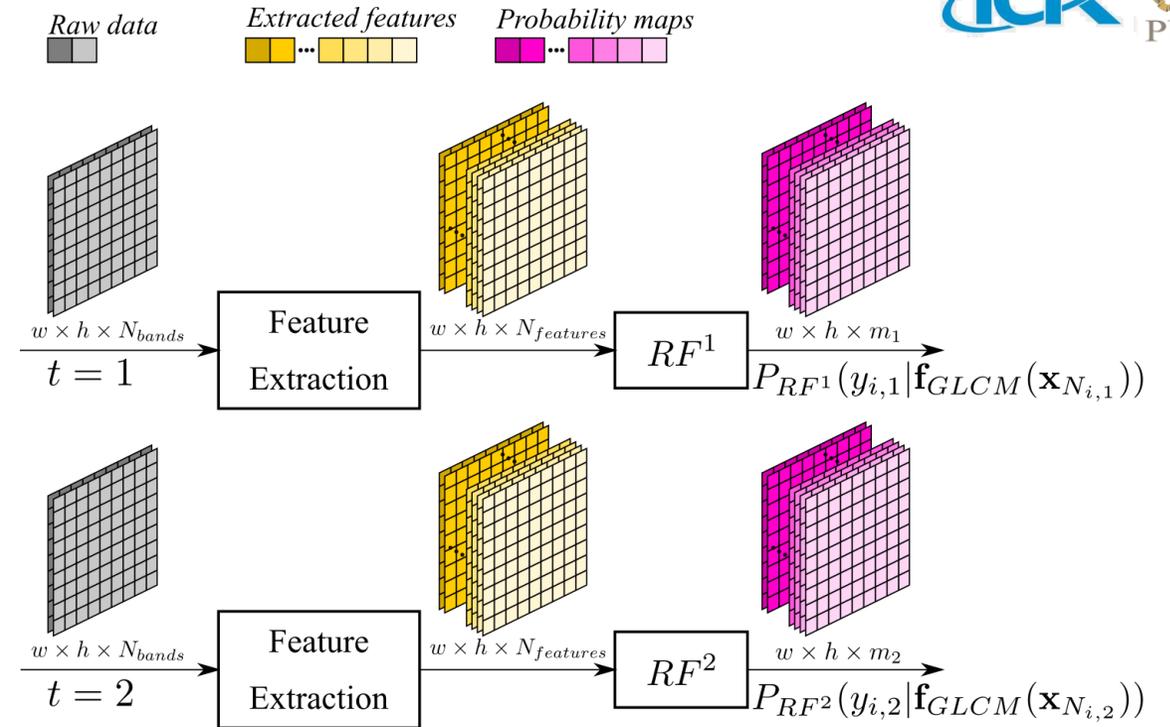
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{RF^t}(y_{i,t} | \mathbf{f}_{GLCM}(\mathbf{x}_{N_{i,t}}))$$



Potencial de Asociación

Random Forest + atributos de textura (GLCM)

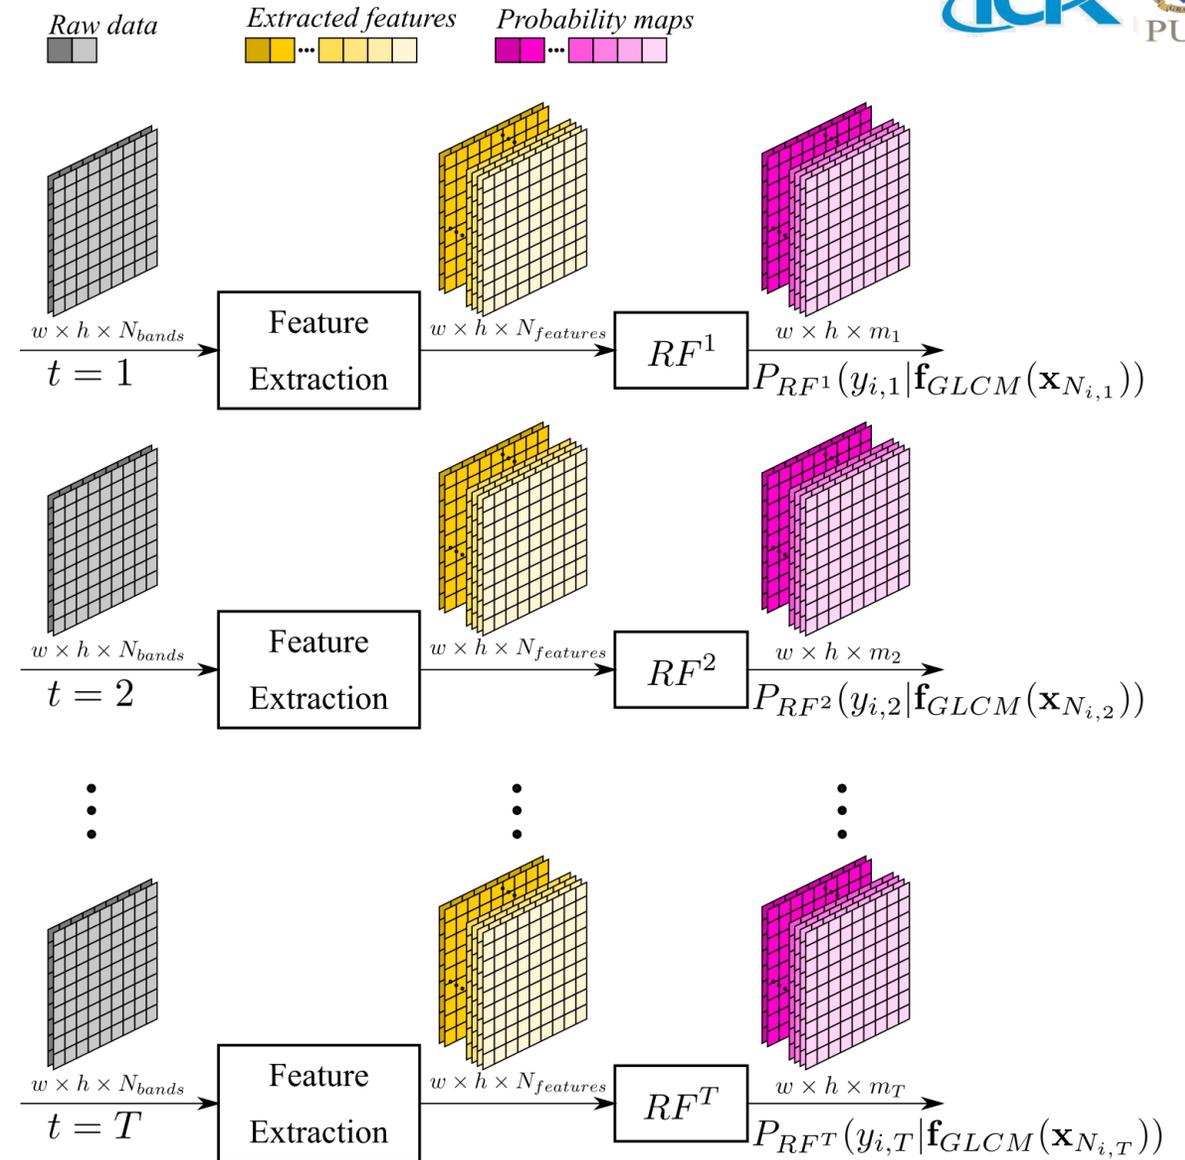
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{RF^t}(y_{i,t} | \mathbf{f}_{GLCM}(\mathbf{x}_{N_{i,t}}))$$



Potencial de Asociación

Random Forest + atributos de textura (GLCM)

$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{RF^t}(y_{i,t} | \mathbf{f}_{GLCM}(\mathbf{x}_{N_{i,t}}))$$

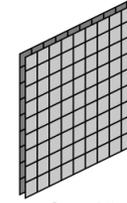


Potencial de Asociación

CNN usando cada imagen

$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,t}})$$

Raw data

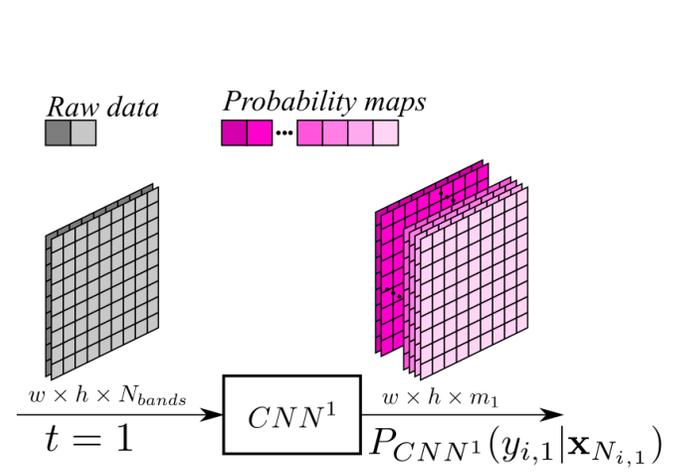
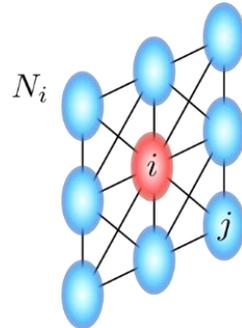


$w \times h \times N_{bands}$
 $t = 1$

Potencial de Asociación

CNN usando cada imagen

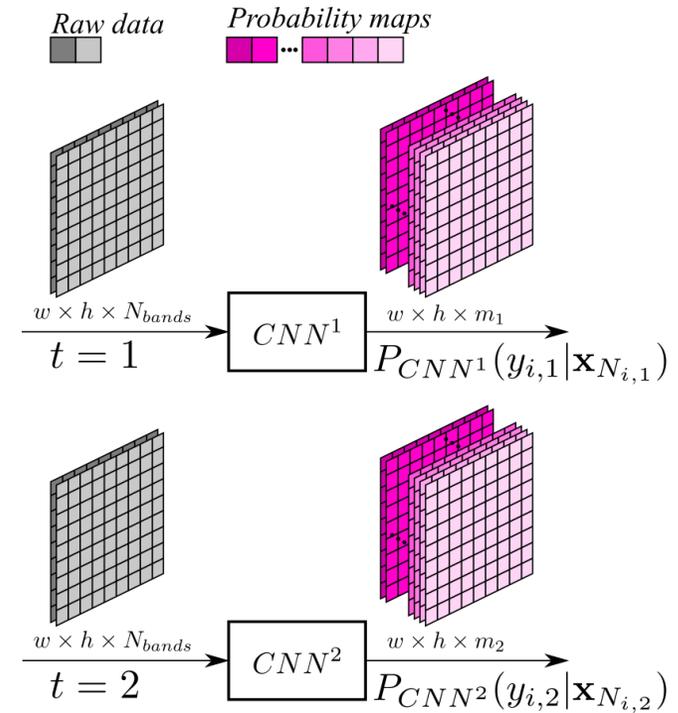
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,t}})$$



Potencial de Asociación

CNN usando cada imagen

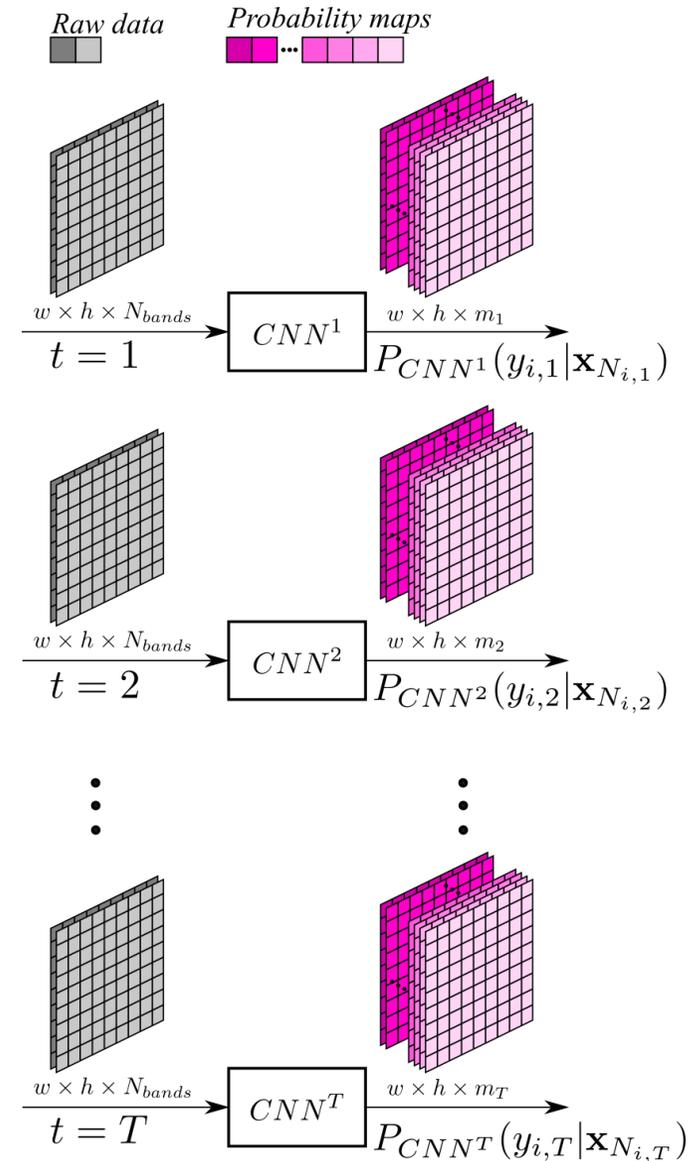
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,t}})$$



Potencial de Asociación

CNN usando cada imagen

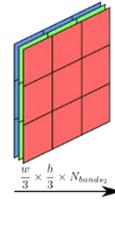
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,t}})$$



Potencial de Asociación

CNN usando el stack de todas las imágenes

$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,1}} : \mathbf{x}_{N_{i,2}} : \dots : \mathbf{x}_{N_{i,T}})$$



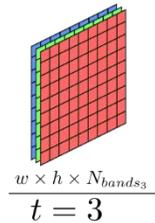
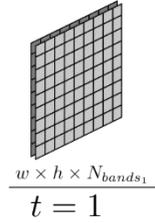
Raw data Sensor 1
(high resolution)



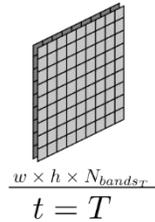
Raw data Sensor 2
(high resolution)



Raw data Sensor 3
(coarse resolution)



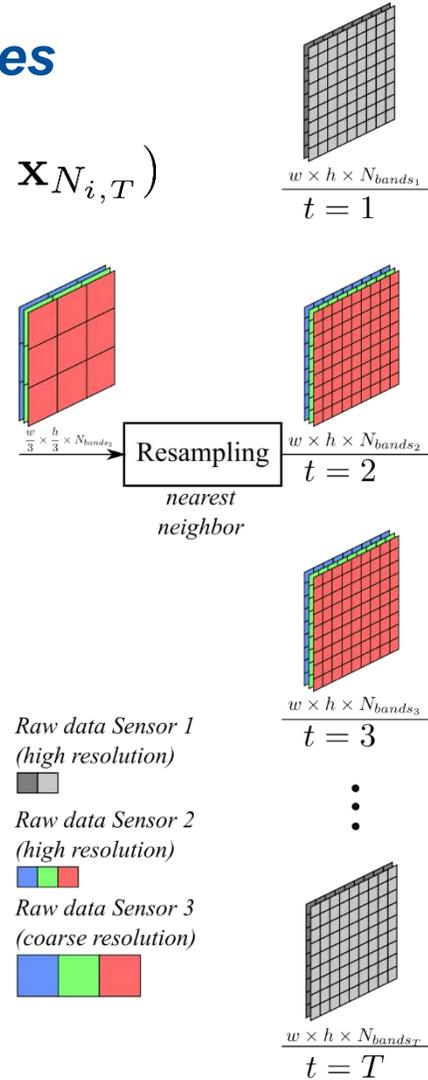
⋮



Potencial de Asociación

CNN usando el stack de todas las imágenes

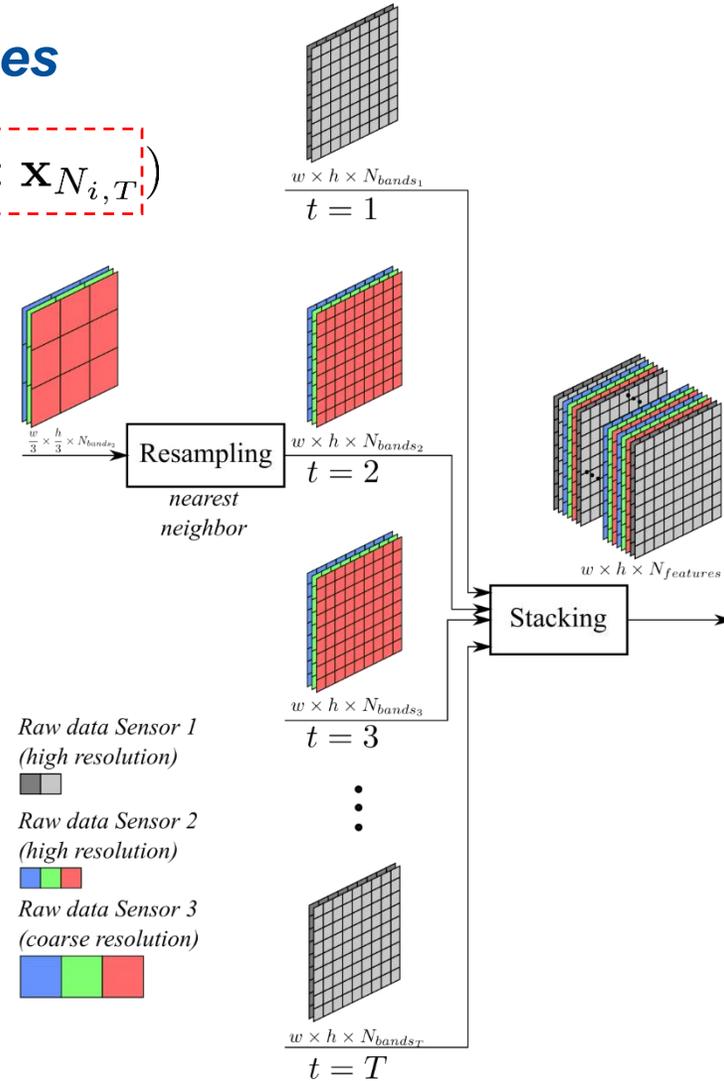
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,1}} : \mathbf{x}_{N_{i,2}} : \dots : \mathbf{x}_{N_{i,T}})$$



Potencial de Asociación

CNN usando el stack de todas las imágenes

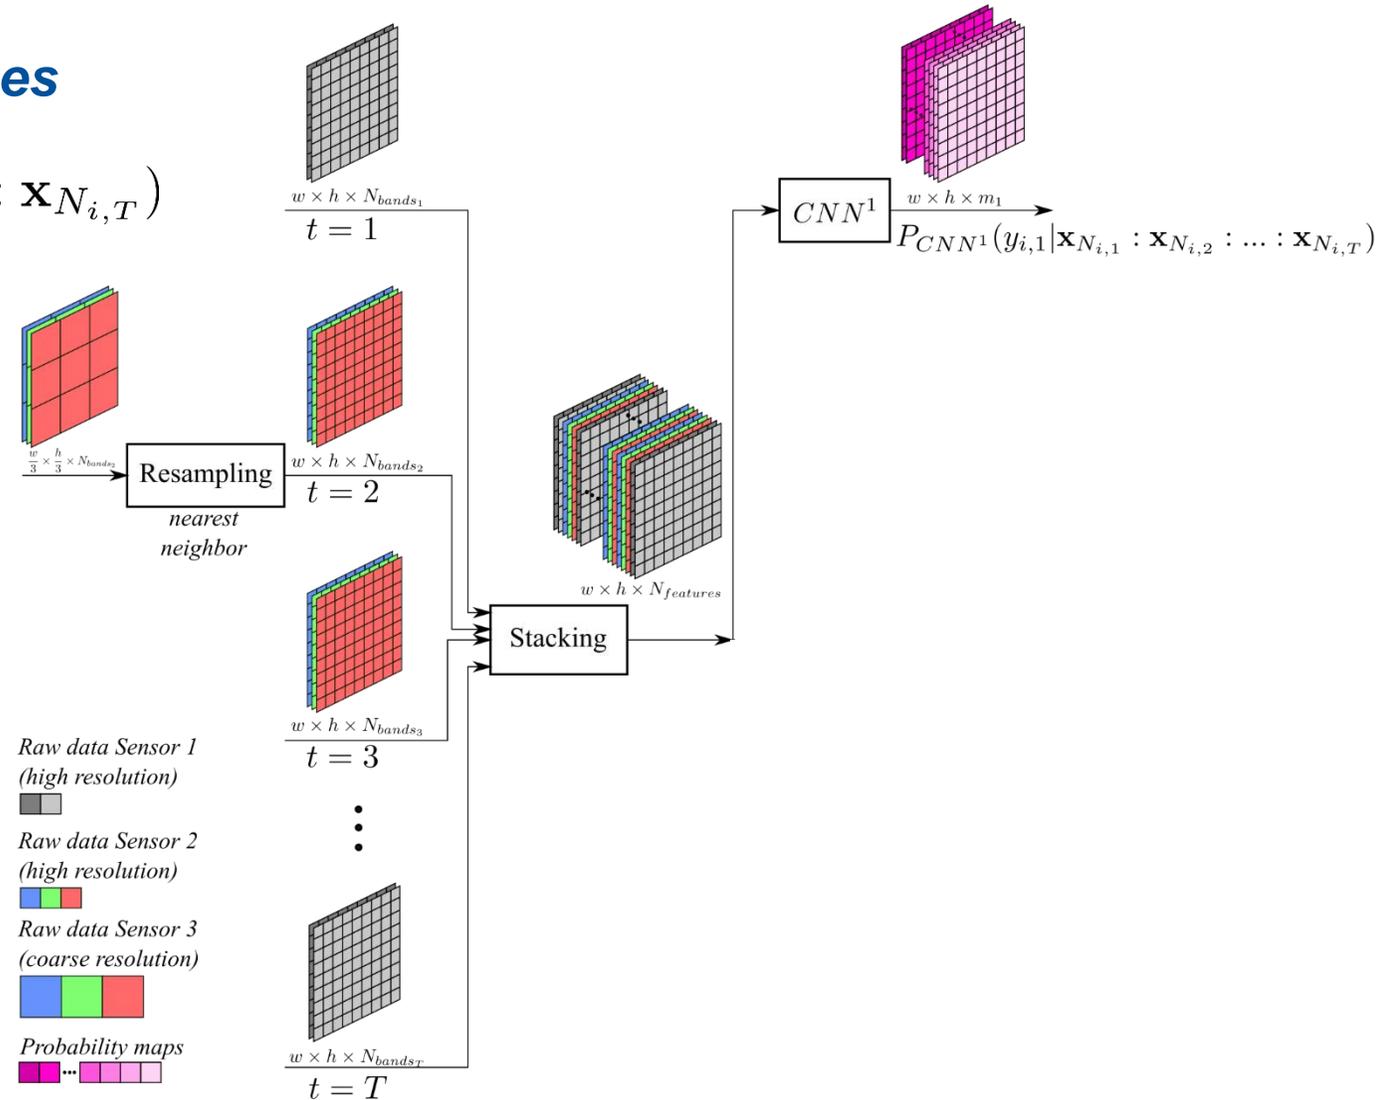
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,1}} : \mathbf{x}_{N_{i,2}} : \dots : \mathbf{x}_{N_{i,T}})$$



Potencial de Asociación

CNN usando el stack de todas las imágenes

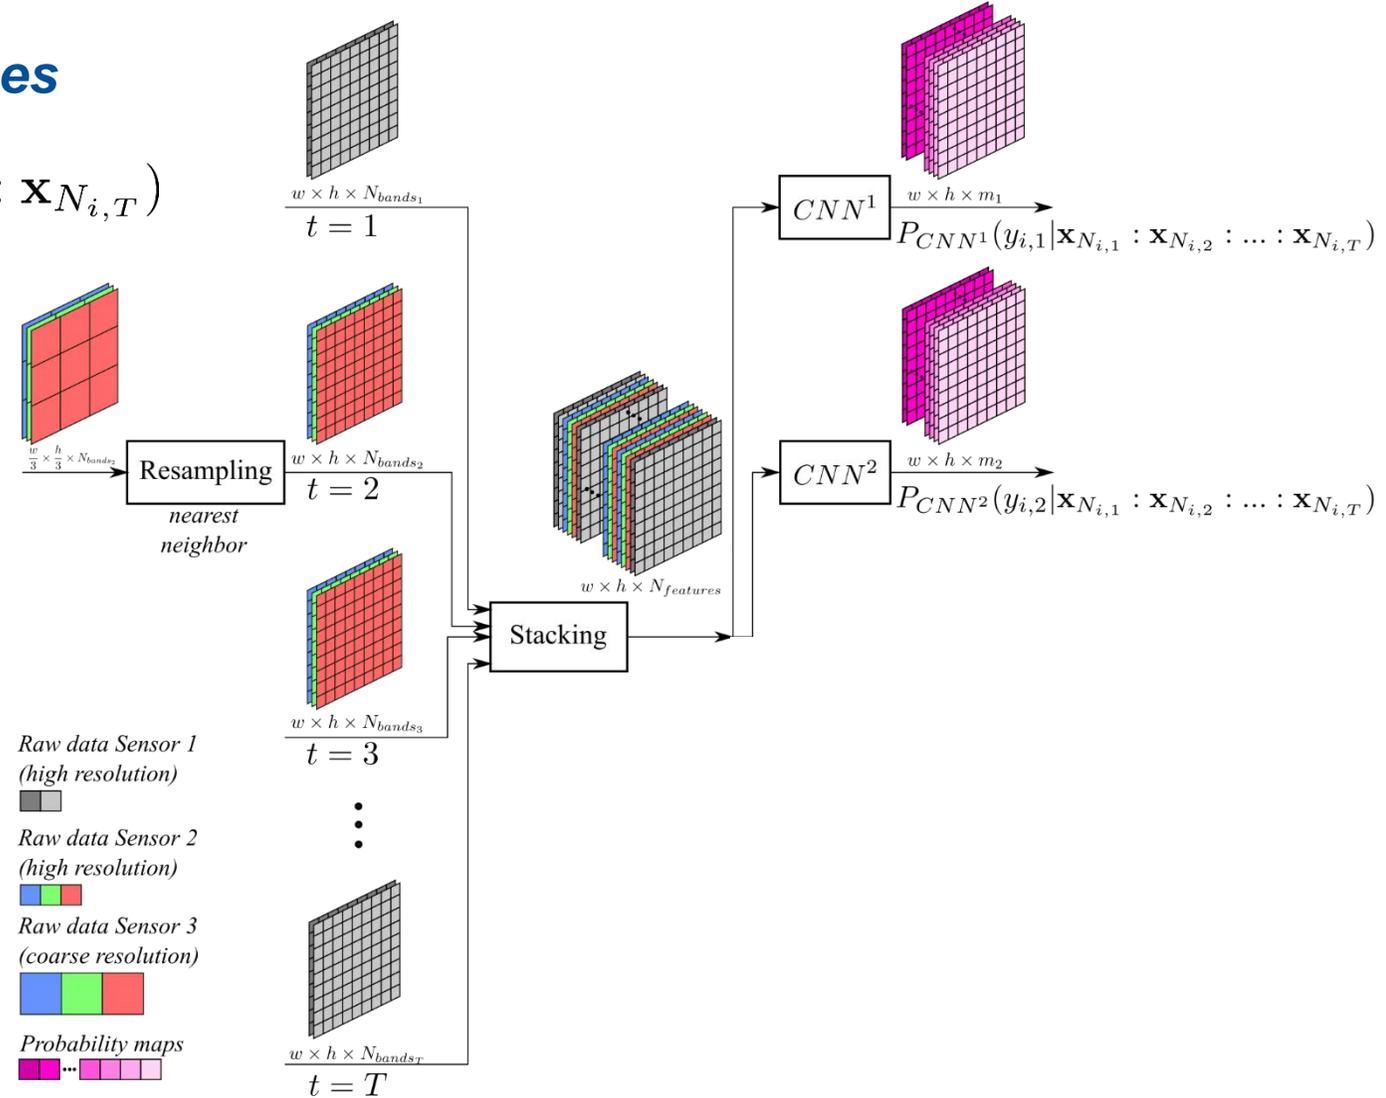
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,1}} : \mathbf{x}_{N_{i,2}} : \dots : \mathbf{x}_{N_{i,T}})$$



Potencial de Asociación

CNN usando el stack de todas las imágenes

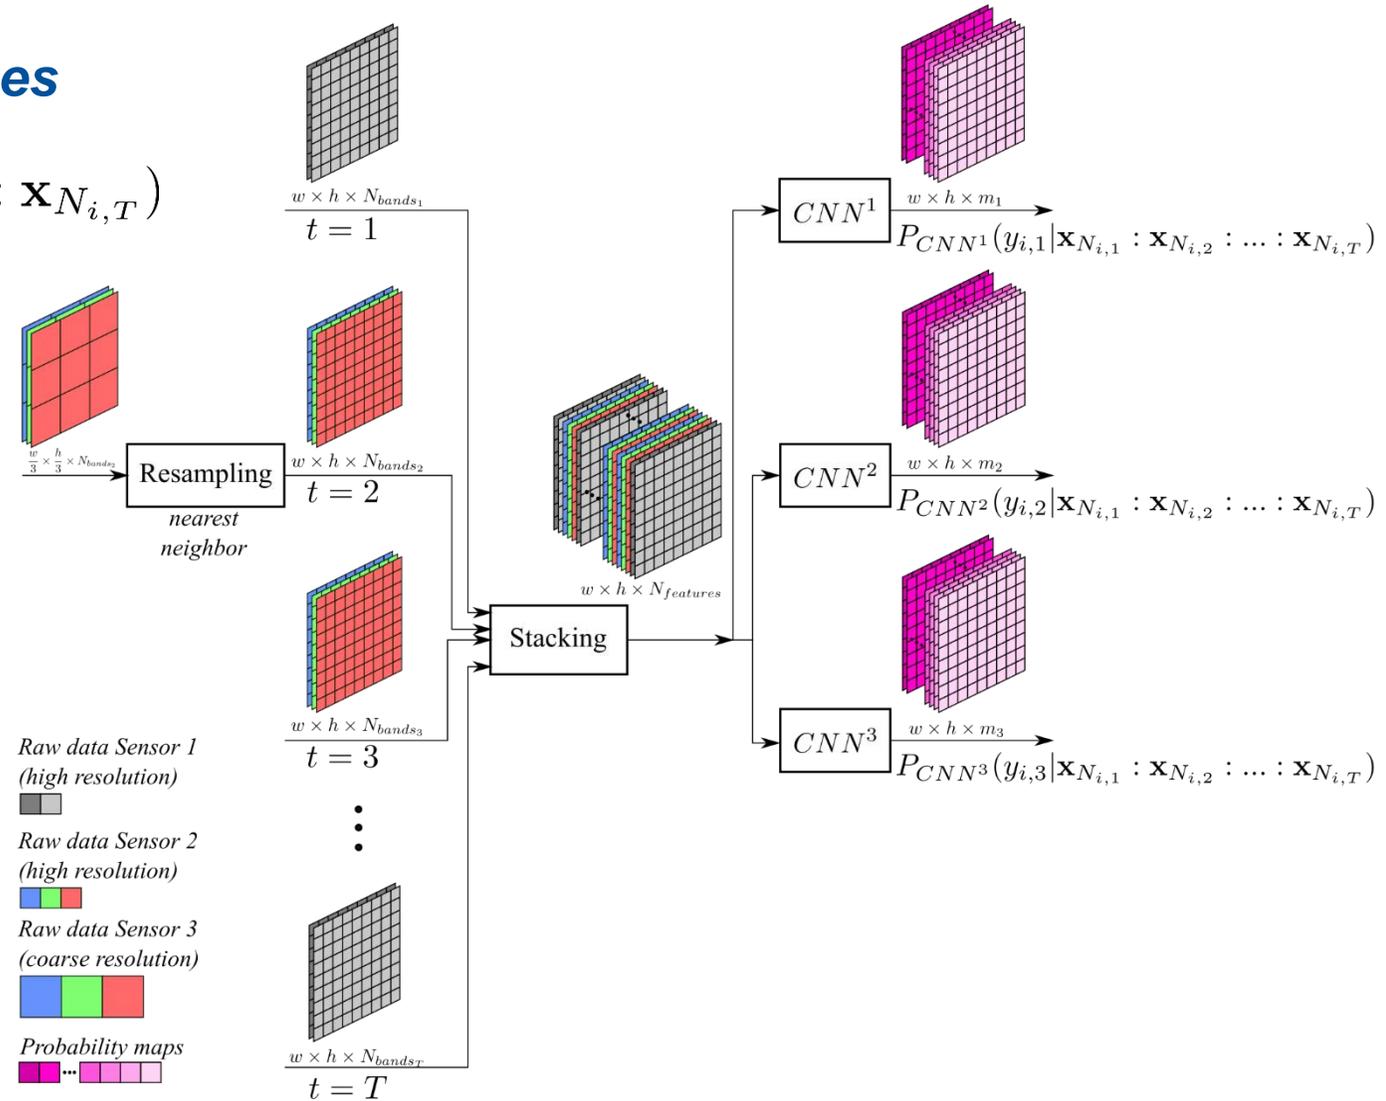
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,1}} : \mathbf{x}_{N_{i,2}} : \dots : \mathbf{x}_{N_{i,T}})$$



Potencial de Asociación

CNN usando el stack de todas las imágenes

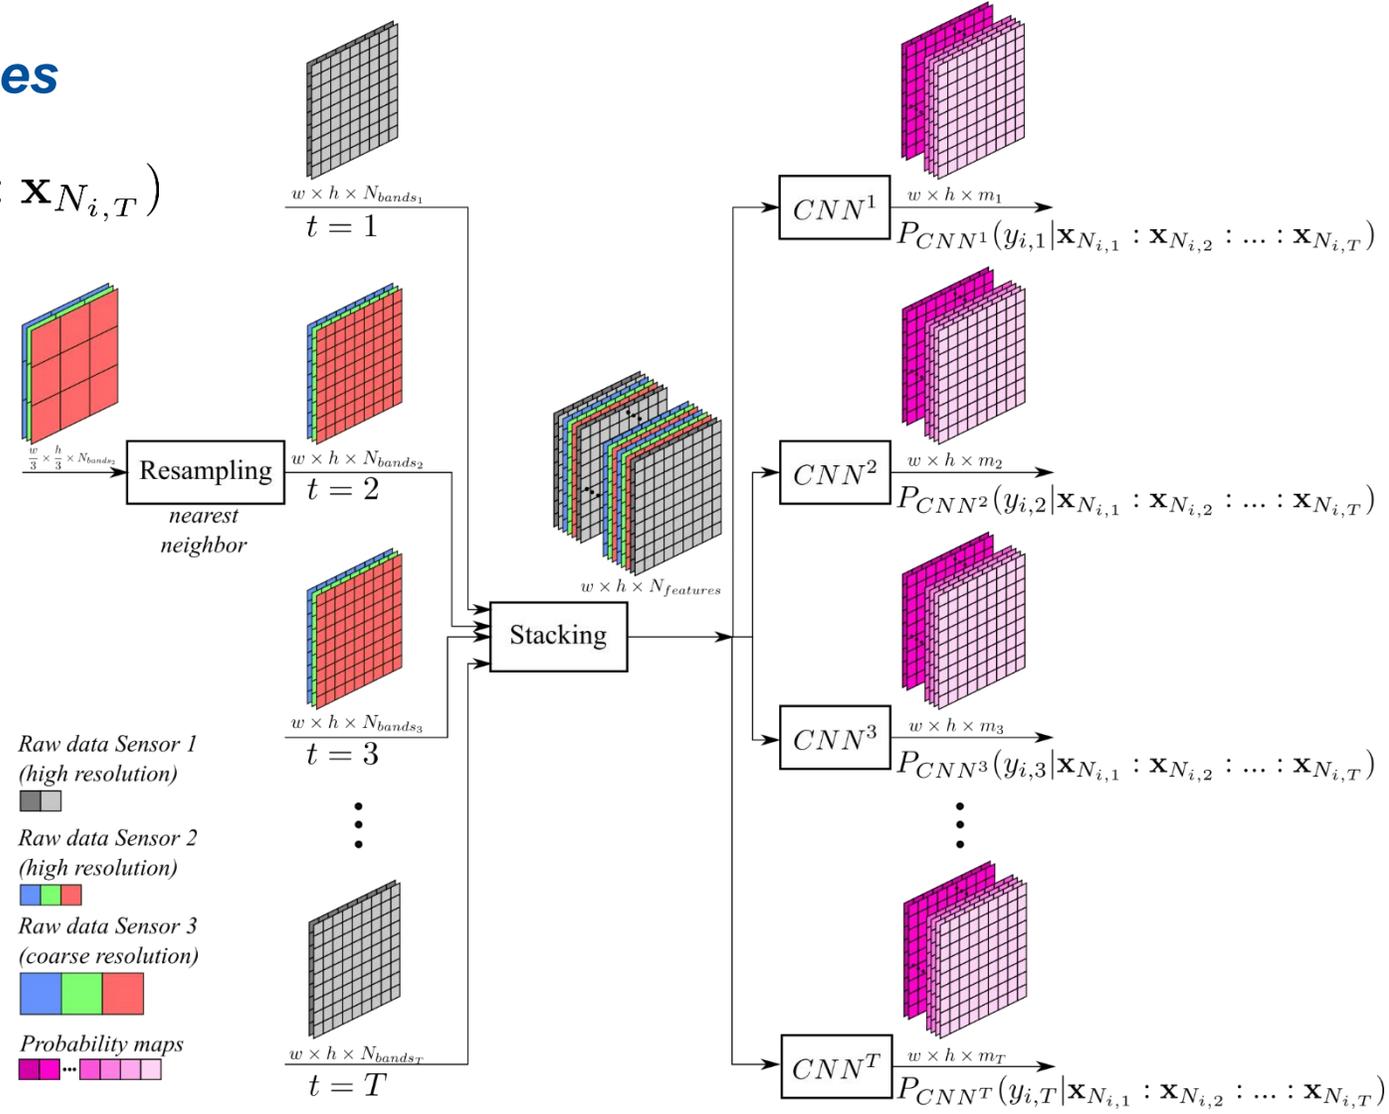
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,1}} : \mathbf{x}_{N_{i,2}} : \dots : \mathbf{x}_{N_{i,T}})$$



Potencial de Asociación

CNN usando el stack de todas las imágenes

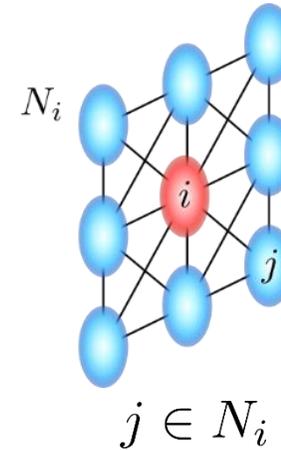
$$AP^t(y_{i,t}, \mathbf{x}) = \log P_{CNN^t}(y_{i,t} | \mathbf{x}_{N_{i,1}} : \mathbf{x}_{N_{i,2}} : \dots : \mathbf{x}_{N_{i,T}})$$



Potencial de Interacción Espacial

Modelo Contrast-sensitive Potts

$$SIP^t(y_{i,t}, y_{j,t}, \mathbf{x}_{i,t}, \mathbf{x}_{j,t}) = \begin{cases} p + (1 - p)e^{-d_{ij,t}^2/2\sigma_t^2} & , y_{i,t} = y_{j,t} \\ 0 & , y_{i,t} \neq y_{j,t} \end{cases}$$



donde: $d_{ij,t} = \|\mathbf{g}_{i,t}(\mathbf{x}_{i,t}) - \mathbf{g}_{j,t}(\mathbf{x}_{j,t})\|$

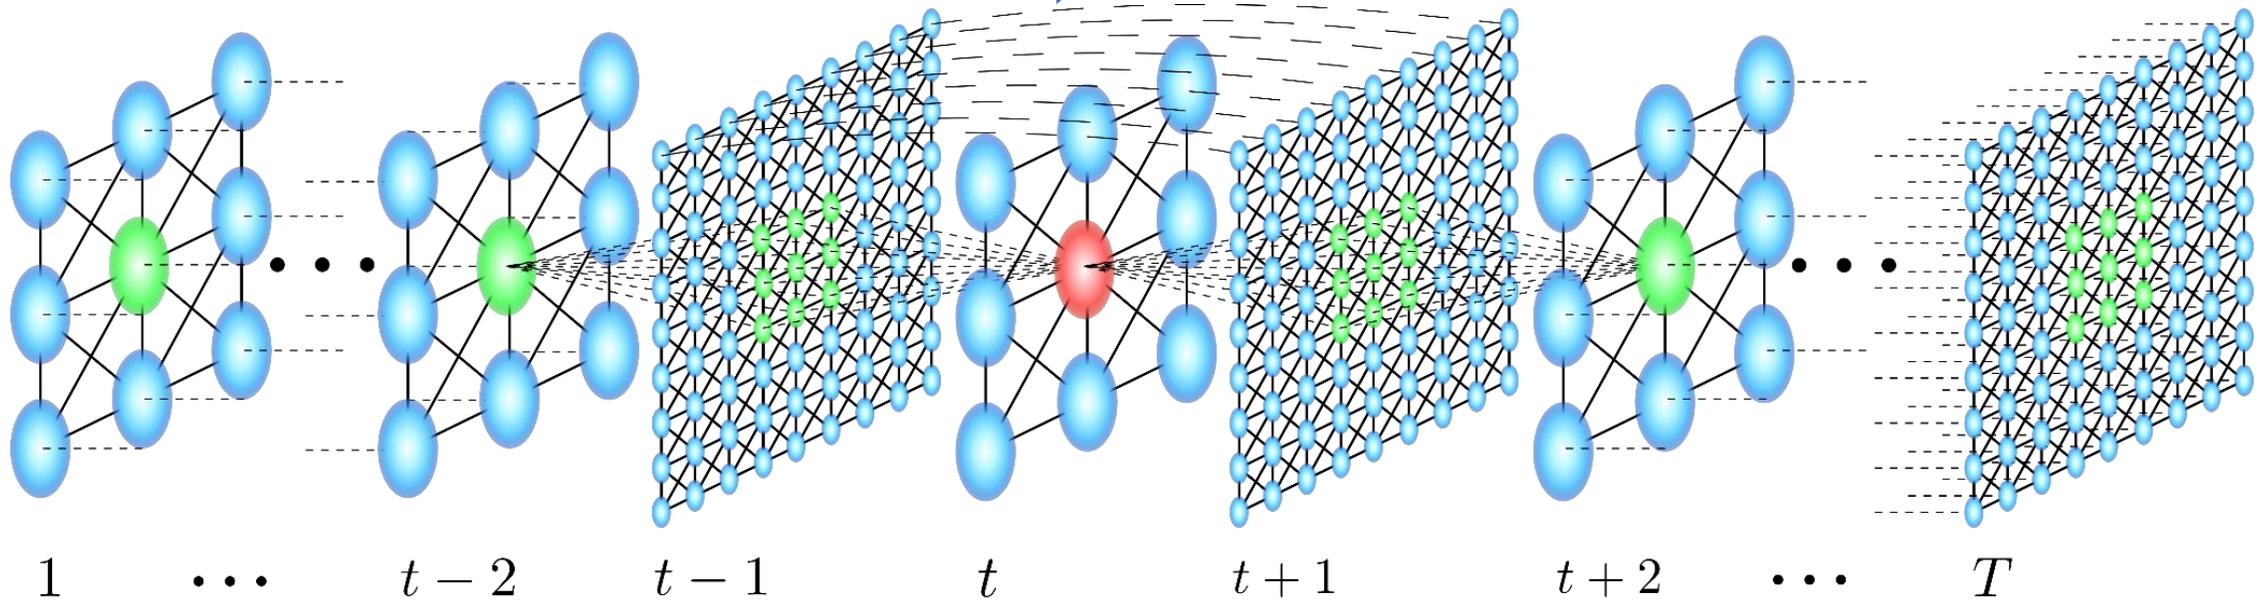
σ^2 valor medio del cuadrado de $d_{ij,t}$

$p \in [0, 1]$ controla la influencia relativa de los términos dependientes e independientes de los datos.

Potencial de Interacción Temporal

Conecciones de orden mayor

$$TIP^{tk}(y_{i,t}, y_{i,k}) = \begin{bmatrix} ()_{11} & ()_{12} & \dots & ()_{1m_k} \\ ()_{21} & ()_{22} & \dots & ()_{2m_k} \\ \vdots & \vdots & \ddots & \vdots \\ ()_{m_t1} & ()_{m_t2} & \dots & ()_{m_t m_k} \end{bmatrix}_{m_t \times m_k}$$



- Spatial Interaction Potential
- - - - Temporal Interaction Potential First Order
- · · · Temporal Interaction Potential Higher Order

Outline



1. Introducción

2. CRFs

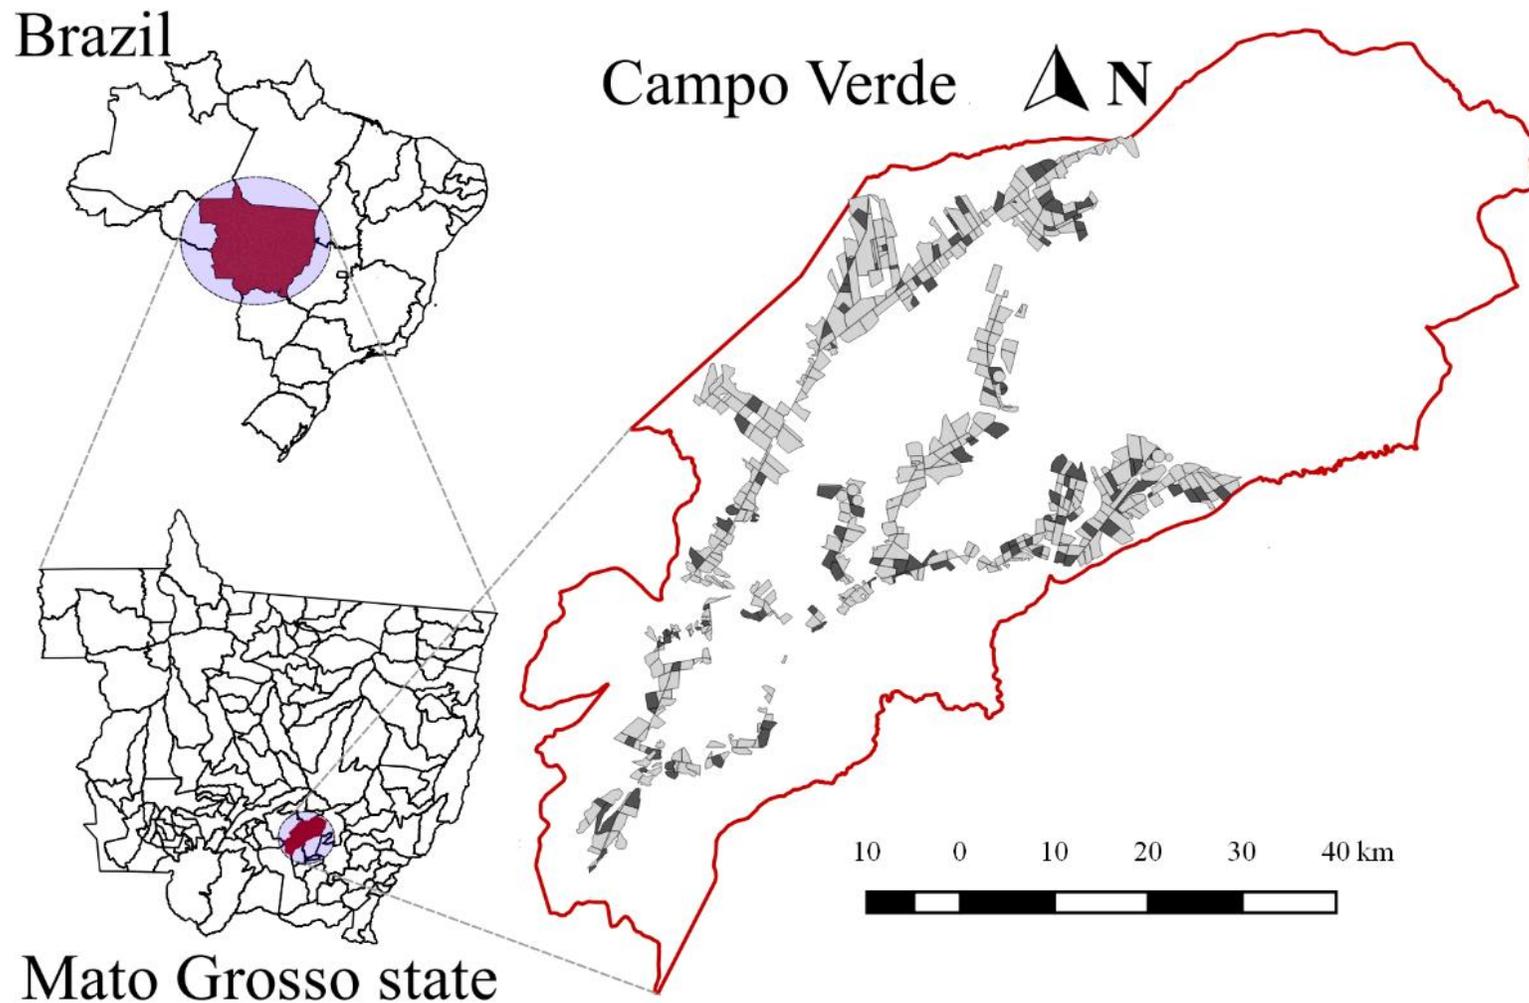
3. Resultados

4. Conclusiones

Dataset

Campo Verde

- Mato Grosso, Brasil



Dataset

Campo Verde

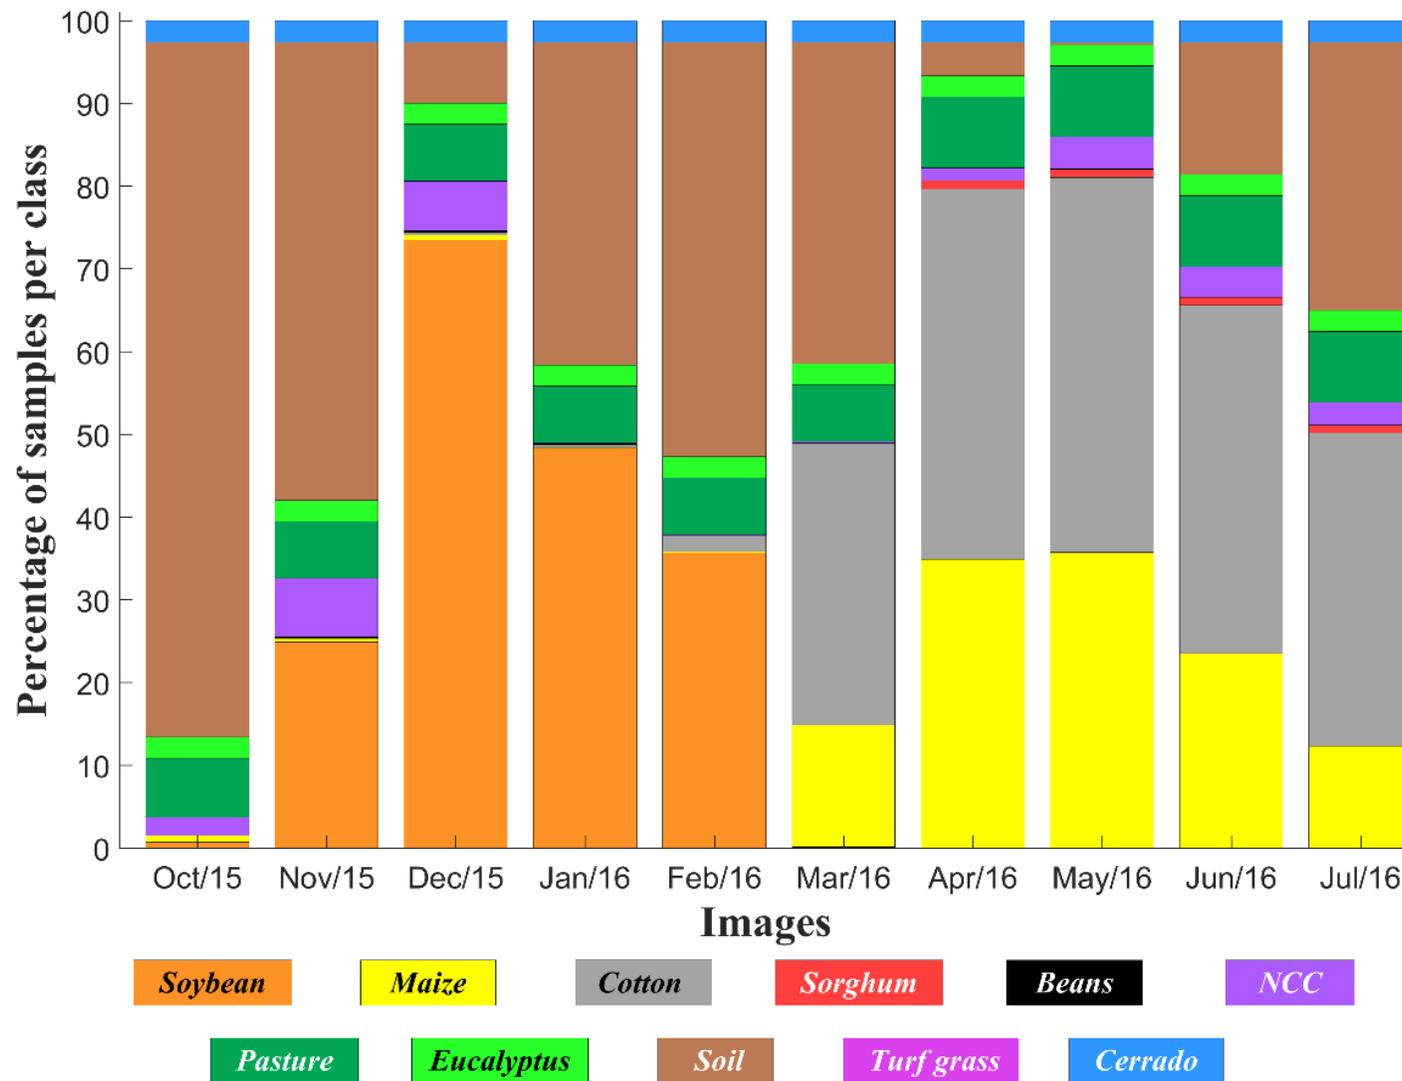
- Mato Grosso, Brasil
- **14** Sentinel-1A / **5** Landsat 8

Year	Month	Date	
		Sentinel-1A	Landsat 8
2015	October	29	-
	November	10, 22	11
	December	04, 16	-
2016	January	21	-
	February	14	-
	March	09, 21	-
	April	-	19
	May	08, 20	05
	June	13	
	July	07, 31	08, 24

Dataset

Campo Verde

- Mato Grosso, Brasil
- 14 Sentinel-1A / 5 Landsat 8
- Desde Octubre 2015 hasta Julio 2016



Dataset



Campo Verde

- Mato Grosso, Brasil
- **14** Sentinel-1A / **5** Landsat 8
- Desde Octubre 2015 hasta Julio 2016
- Train/Test: **20%** / **80%**

Dataset

Campo Verde

- Mato Grosso, Brasil
- 14 Sentinel-1A / 5 Landsat 8
- Desde Octubre 2015 hasta Julio 20
- Train/Test: 20% / 80%

Disponibile en:

<http://www.obt.inpe.br/agricultural-database/campoverde/>



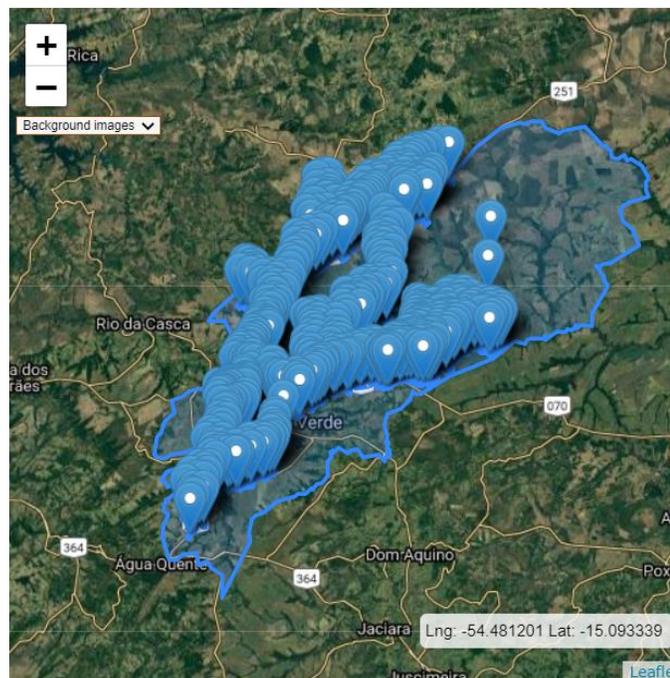
Campo Verde Database

[Data Field 58](#) [Reference data \(download\)](#) [Sentinel-1 data \(download\)](#) [Landsat-8/OLI data \(download\)](#) [Photos](#) [Reference paper](#) [People involved](#) [Financial support](#)

These photographs were taken during two field campaigns conducted in Campo Verde municipality between 14th-18th December 2015 and 9th-13th May 2016.



< Prev Next >



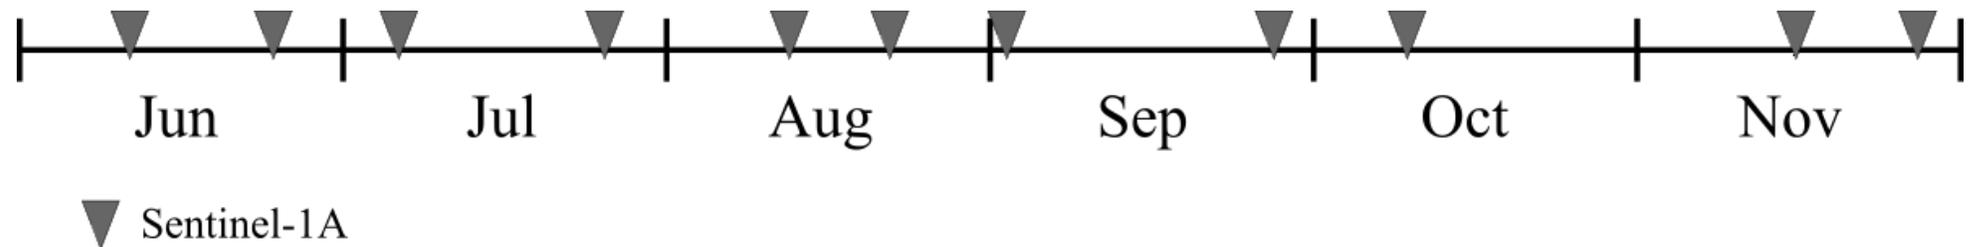
specific Id (0 to 481)?

Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR** (Sentinel-1A)
 - **Múltiples sensores: SAR** (Sentinel-1A) + **Óptico** (Landsat 8)

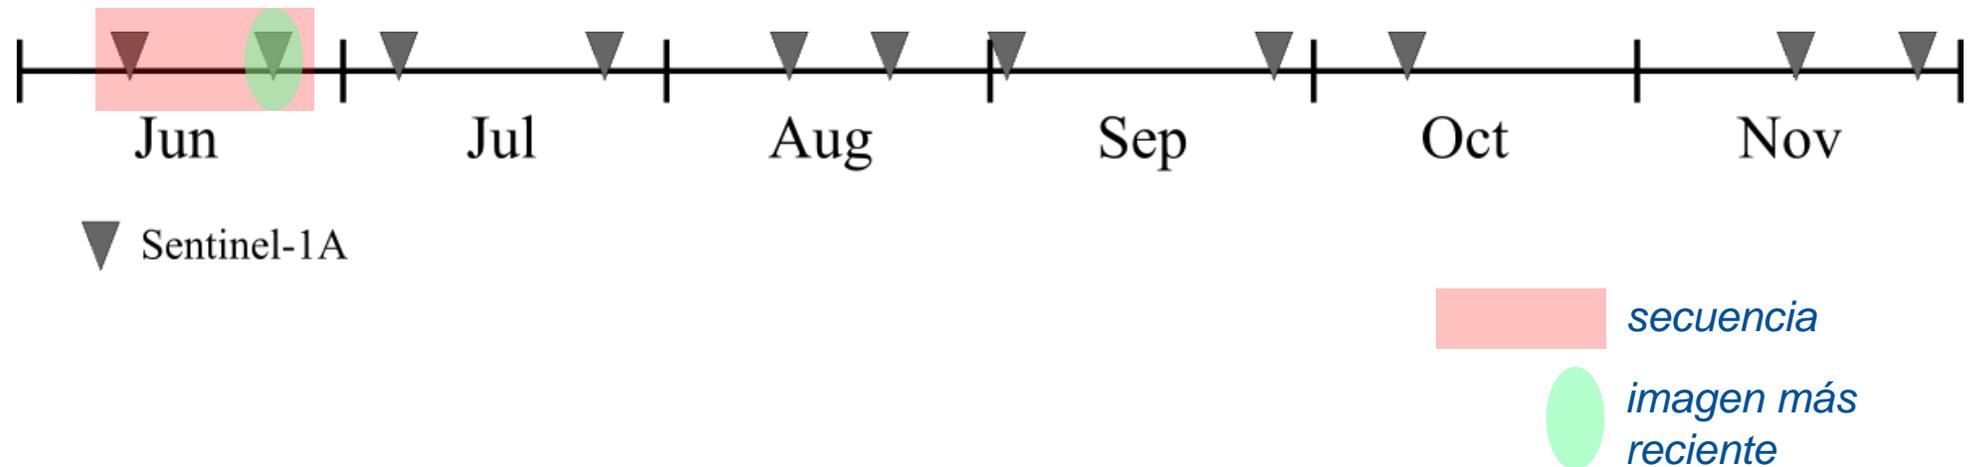
Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR** (Sentinel-1A)
 - **Múltiples sensores: SAR** (Sentinel-1A) + **Óptico** (Landsat 8)



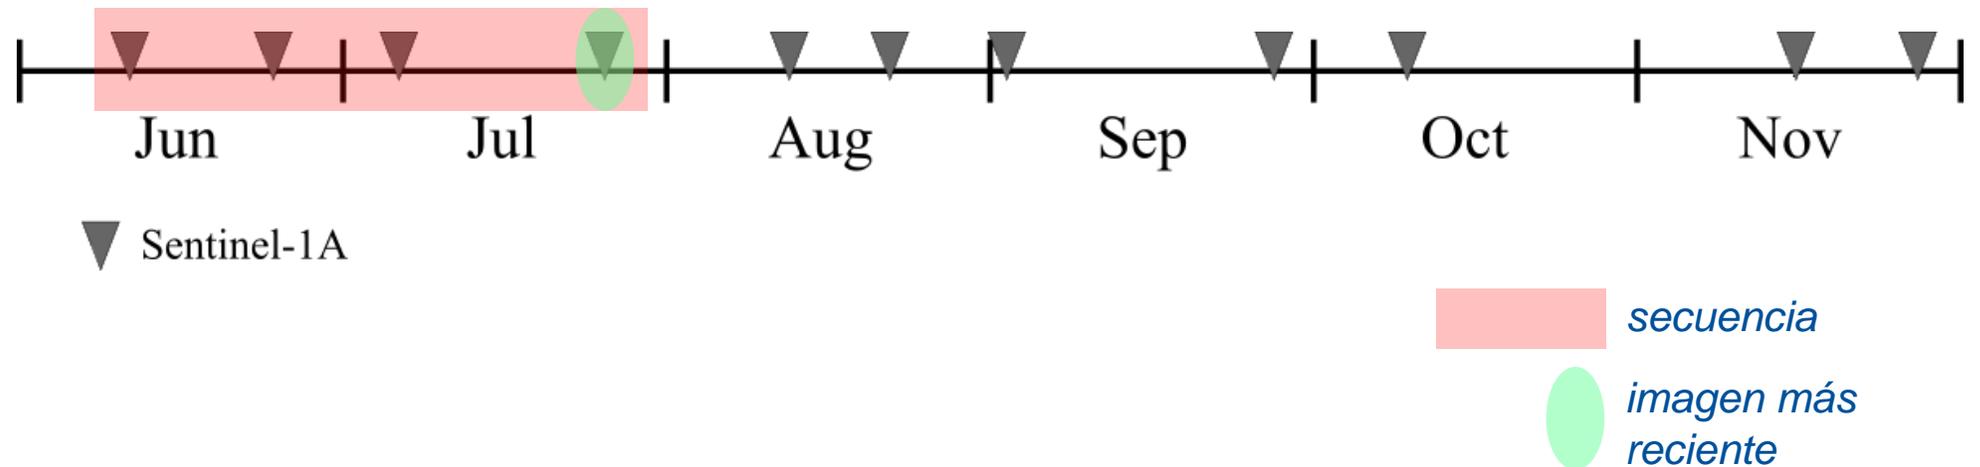
Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR** (Sentinel-1A)
 - **Múltiples sensores: SAR** (Sentinel-1A) + **Óptico** (Landsat 8)



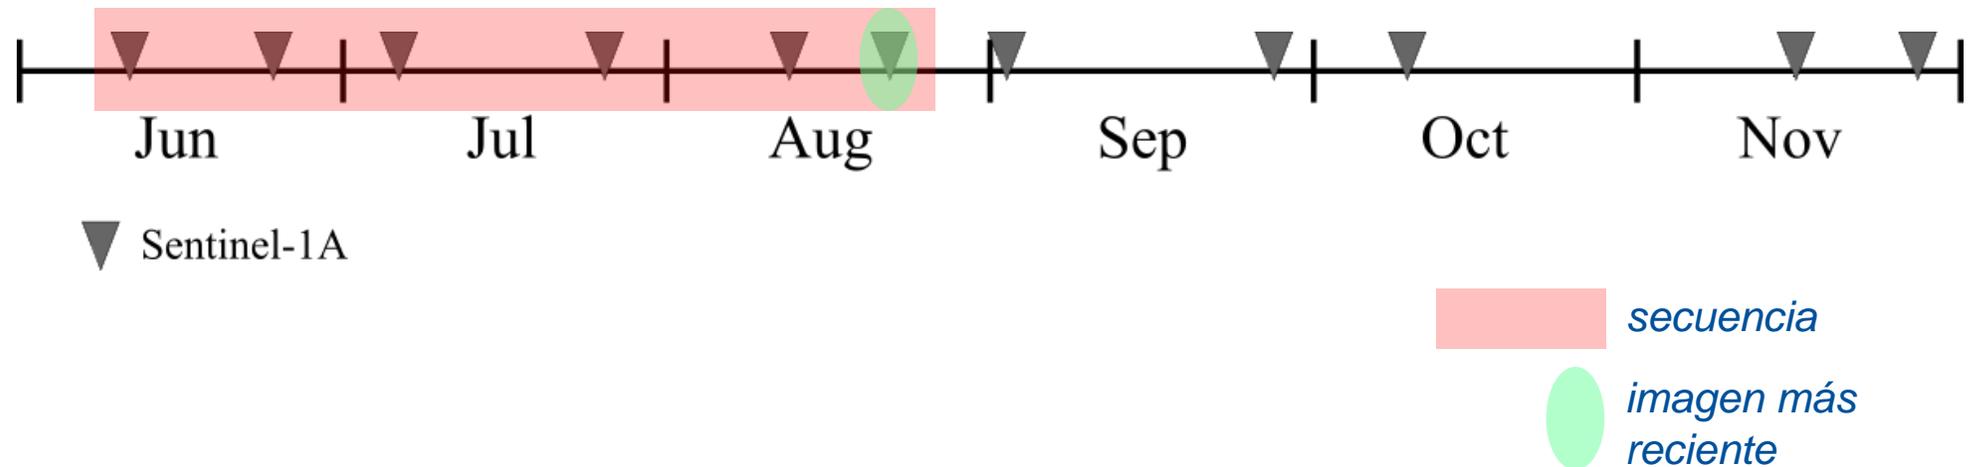
Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR** (Sentinel-1A)
 - **Múltiples sensores: SAR** (Sentinel-1A) + **Óptico** (Landsat 8)



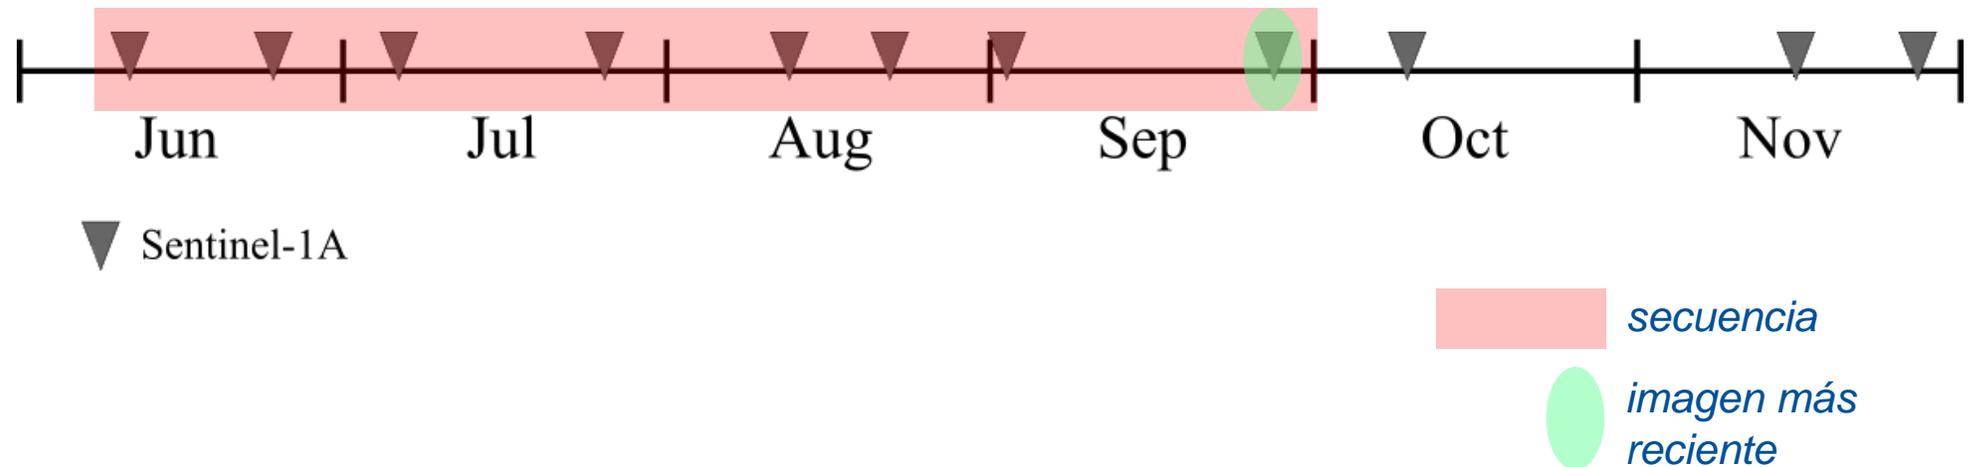
Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR (Sentinel-1A)**
 - **Múltiples sensores: SAR (Sentinel-1A) + Óptico (Landsat 8)**



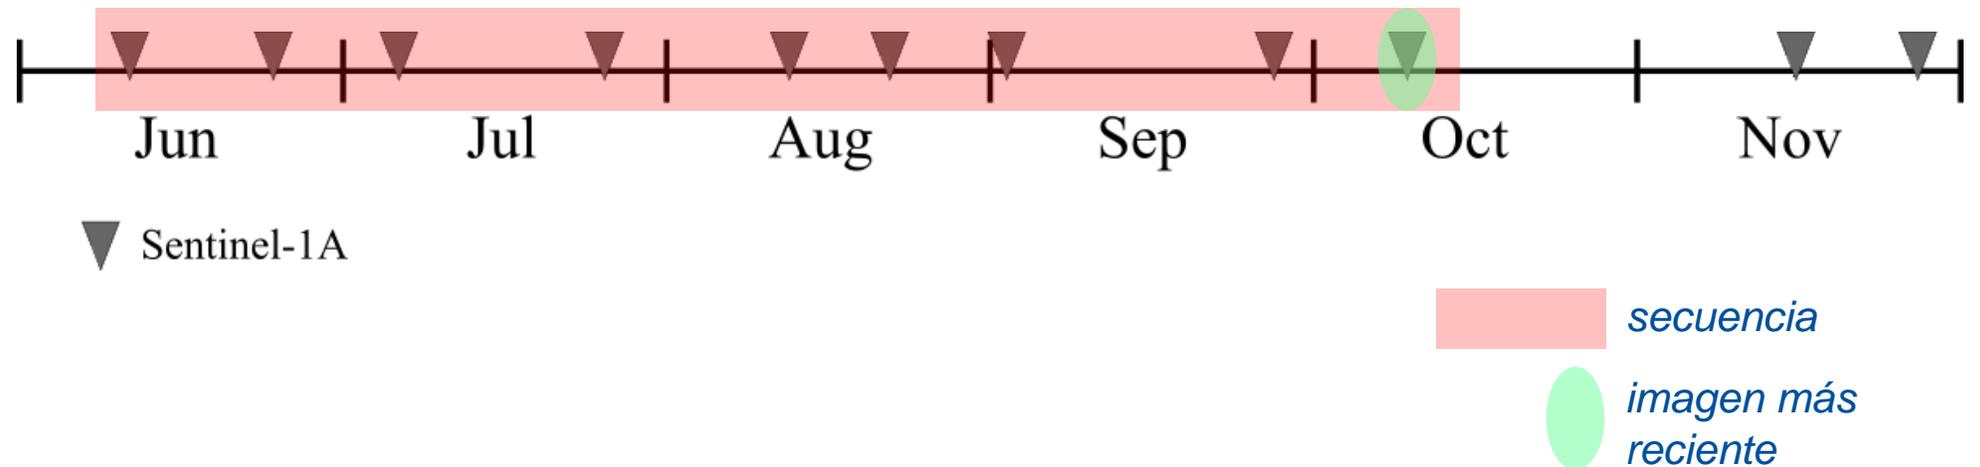
Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR** (Sentinel-1A)
 - **Múltiples sensores: SAR** (Sentinel-1A) + **Óptico** (Landsat 8)



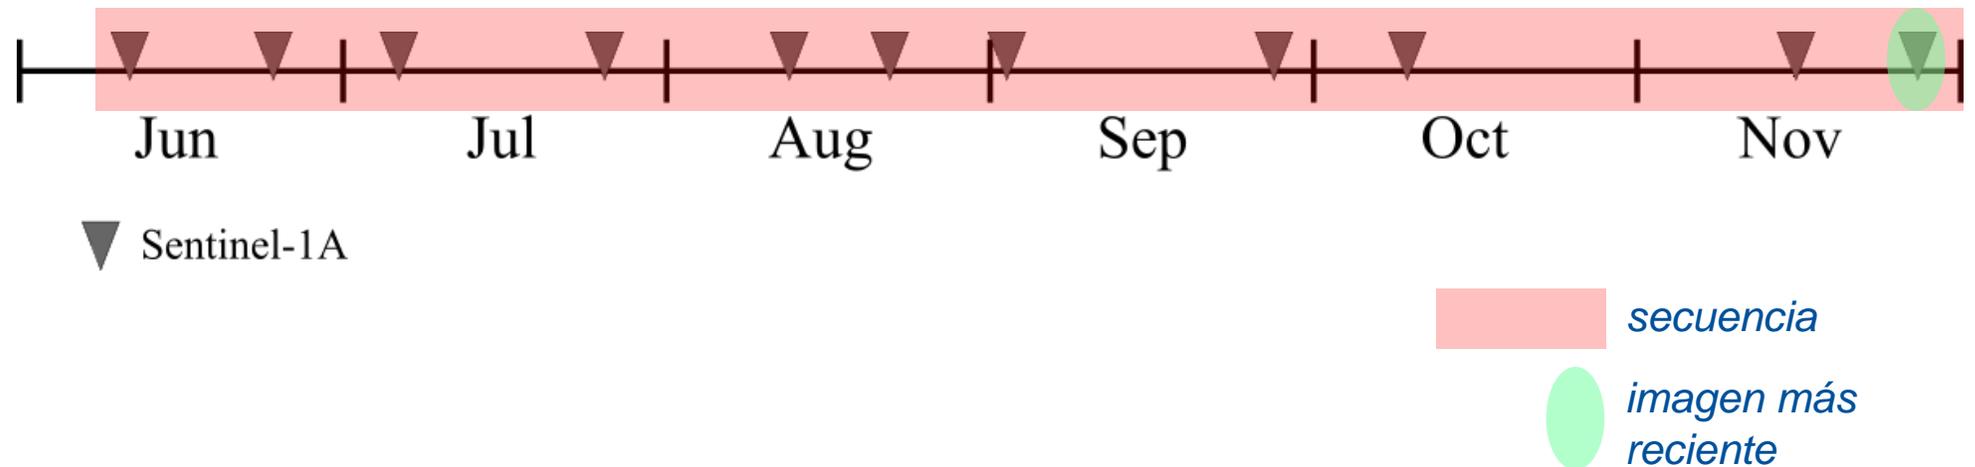
Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR (Sentinel-1A)**
 - **Múltiples sensores: SAR (Sentinel-1A) + Óptico (Landsat 8)**



Protocolo Experimental

- 2 tipos de secuencias de imágenes:
 - **1 sensor: SAR** (Sentinel-1A)
 - **Múltiples sensores: SAR** (Sentinel-1A) + **Óptico** (Landsat 8)



Configuración Experimental

- **Random Forest (RF):** 250 arboles, profundidad máxima 25
 - **Sentinel-1A (SAR)**
 - *Correlación, homogeneidad, media y varianza (GLCM)*
 - Direcciones: 0°, 45°, 90° y 135°, ventanas de 3 × 3
 - 2 polarizaciones: VV y VH
 - Dimensión de vector de atributos: **32**
 - **Landsat 8 (Optical)**
 - Bandas: 1, 2, 3, 4, 5, 6 y 7
 - NDVI
 - Dimensión de vector de atributos: **8**

Configuración Experimental

- Convolutional Neural Network (CNN):

Layer	Output Size
- Input	$9 \times 9 \times N_{features}$
- Convolutional Block (3×3 Conv., B.N. ⁷ , <i>Leaky ReLU</i>)	$9 \times 9 \times 80$
- Max Pooling (2×2)	$5 \times 5 \times 80$
- Convolutional Block (1×1 Conv., B.N., <i>Leaky ReLU</i>)	$5 \times 5 \times 80$
- Convolutional Block (3×3 Conv., B.N., <i>Leaky ReLU</i>)	$5 \times 5 \times 96$
- Max Pooling (2×2)	$3 \times 3 \times 96$
- Fully Connected	256
- B.N.	256
- <i>Leaky ReLU</i>	256
- Dropout	256
- <i>Softmax</i>	m_t

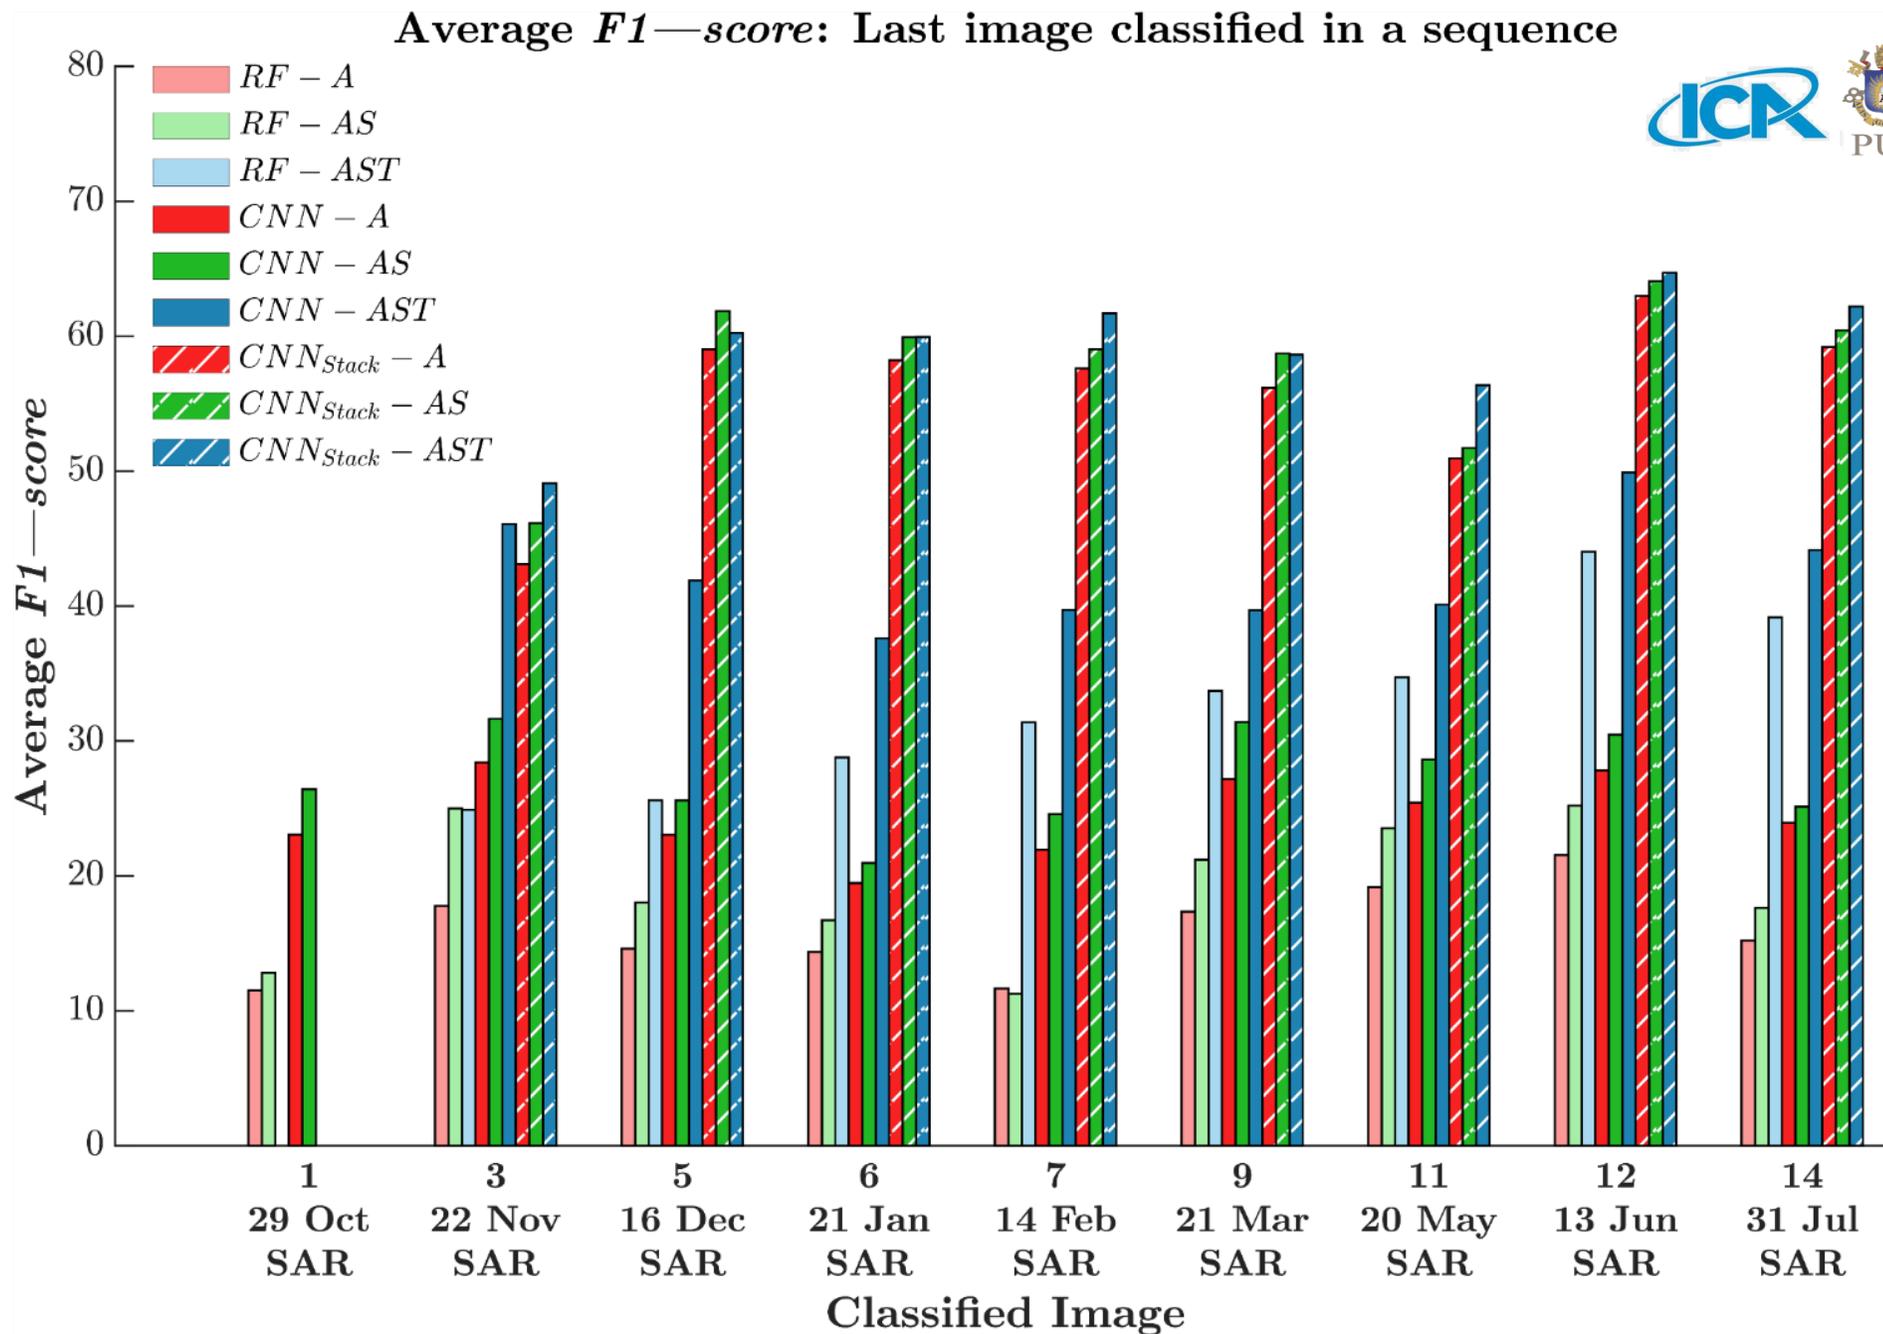
Configuración Experimental

- Para el CRF
 - **Inferencia**
 - Óptimo \hat{y} que maximiza $P(\mathbf{y}|\mathbf{x})$
 - Sum-product Loopy Belief Propagation (LBP)
 - **Métricas**
 - *Overall Accuracy (OA) y average F1-score*

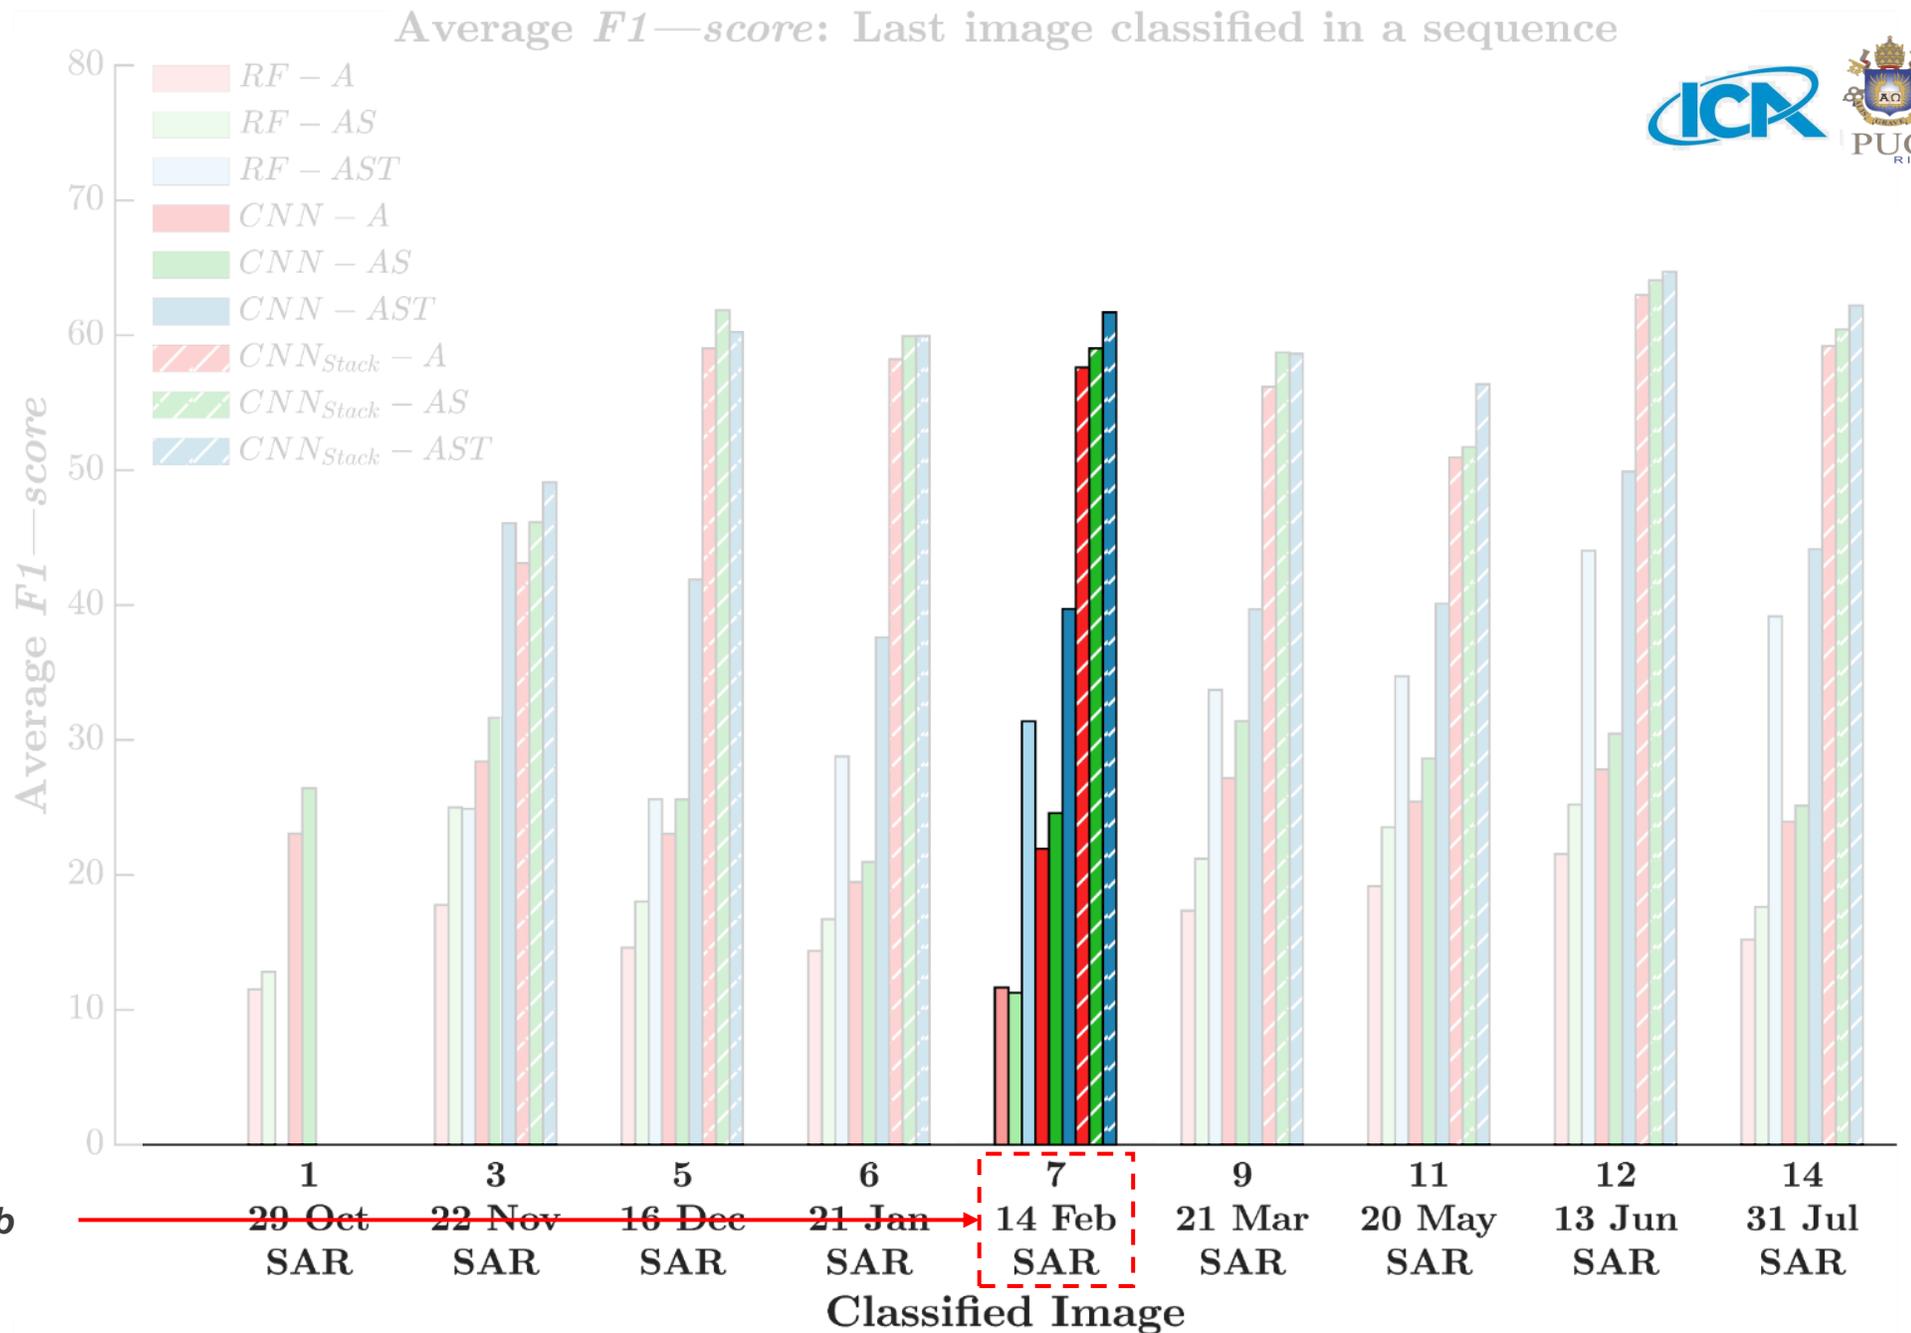
Resultados 1 sensor



Resultados 1 sensor



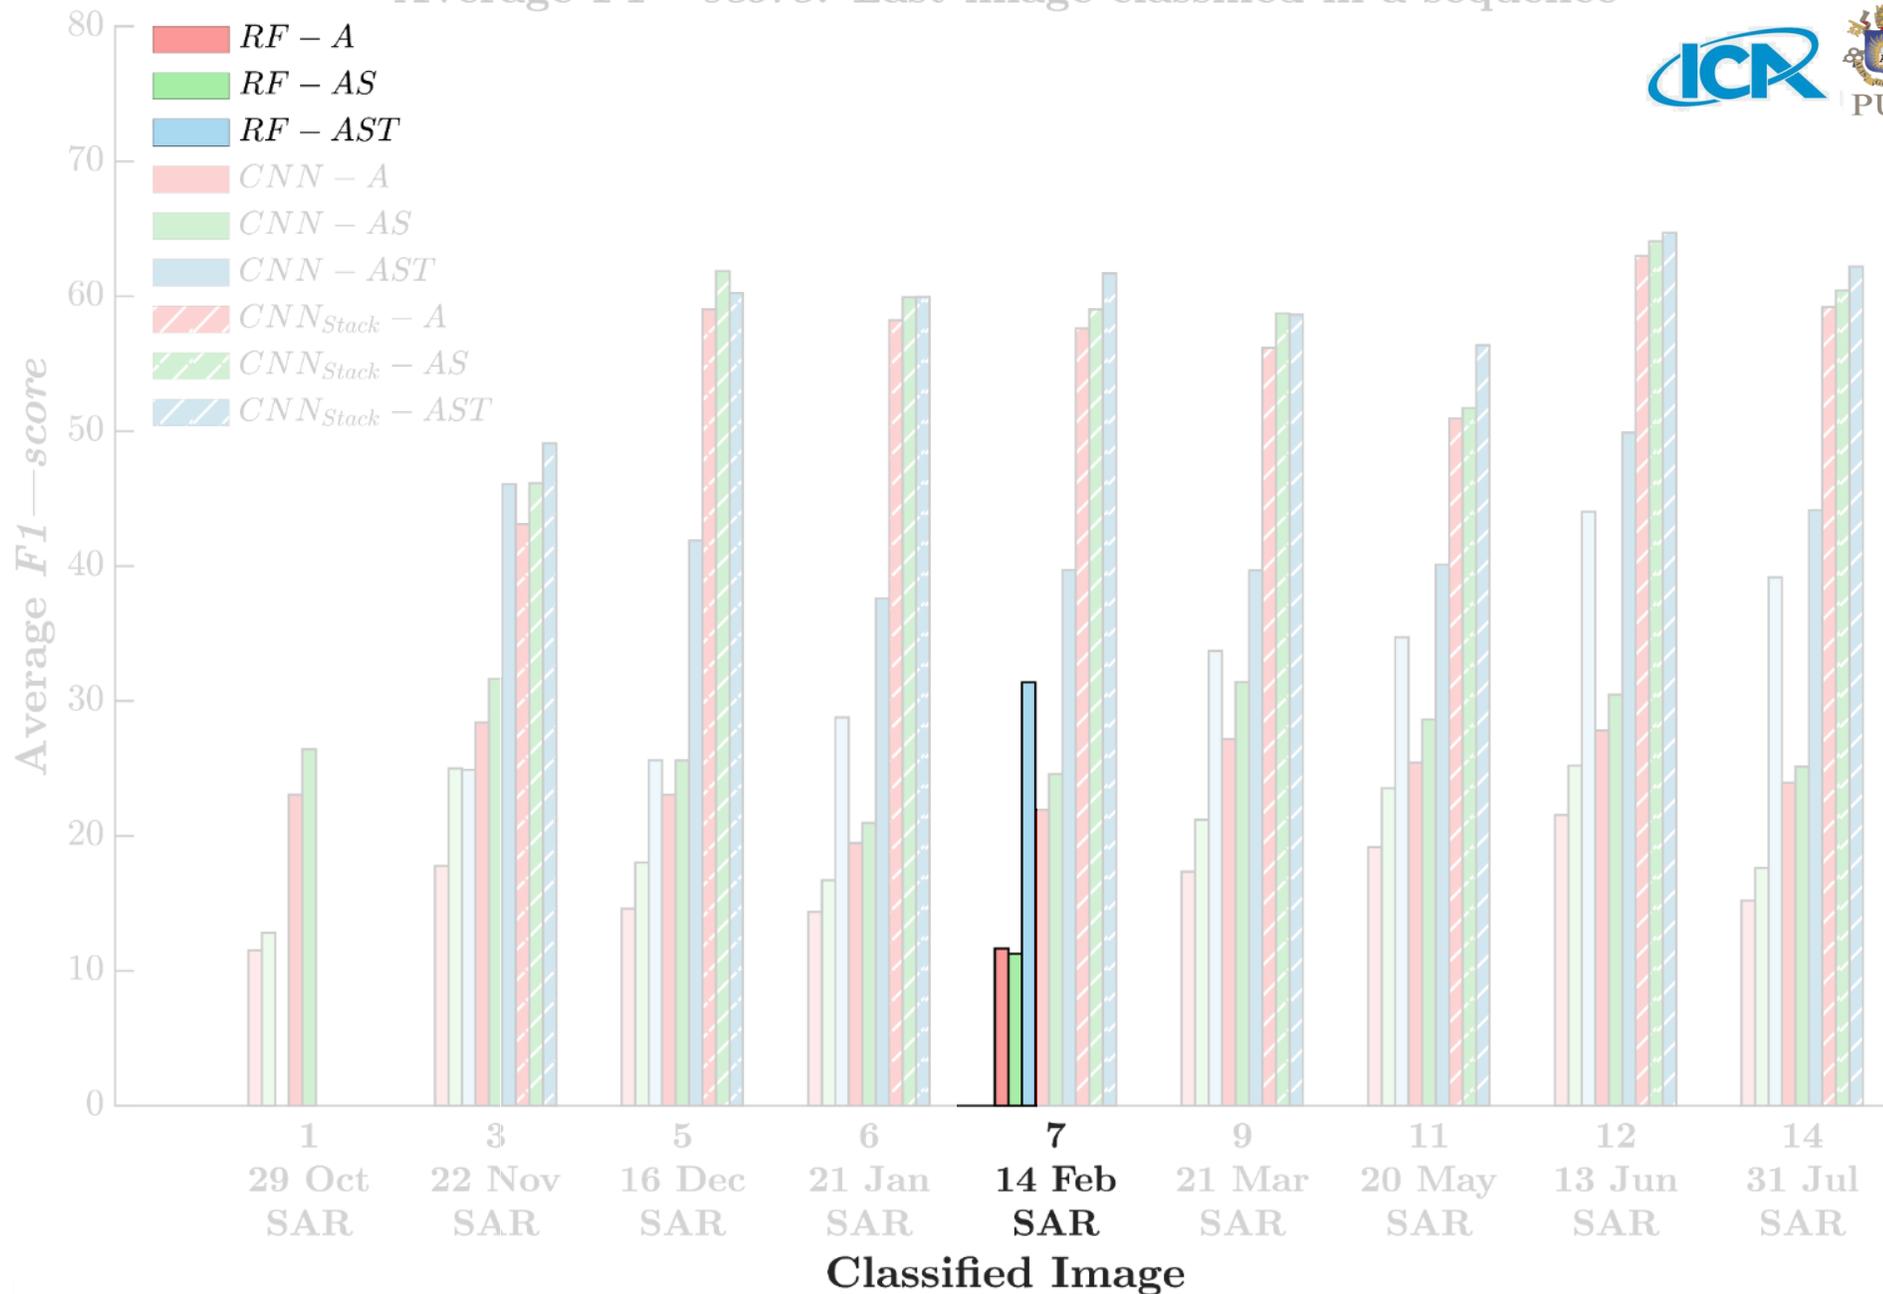
Resultados 1 sensor



Resultados 1 sensor

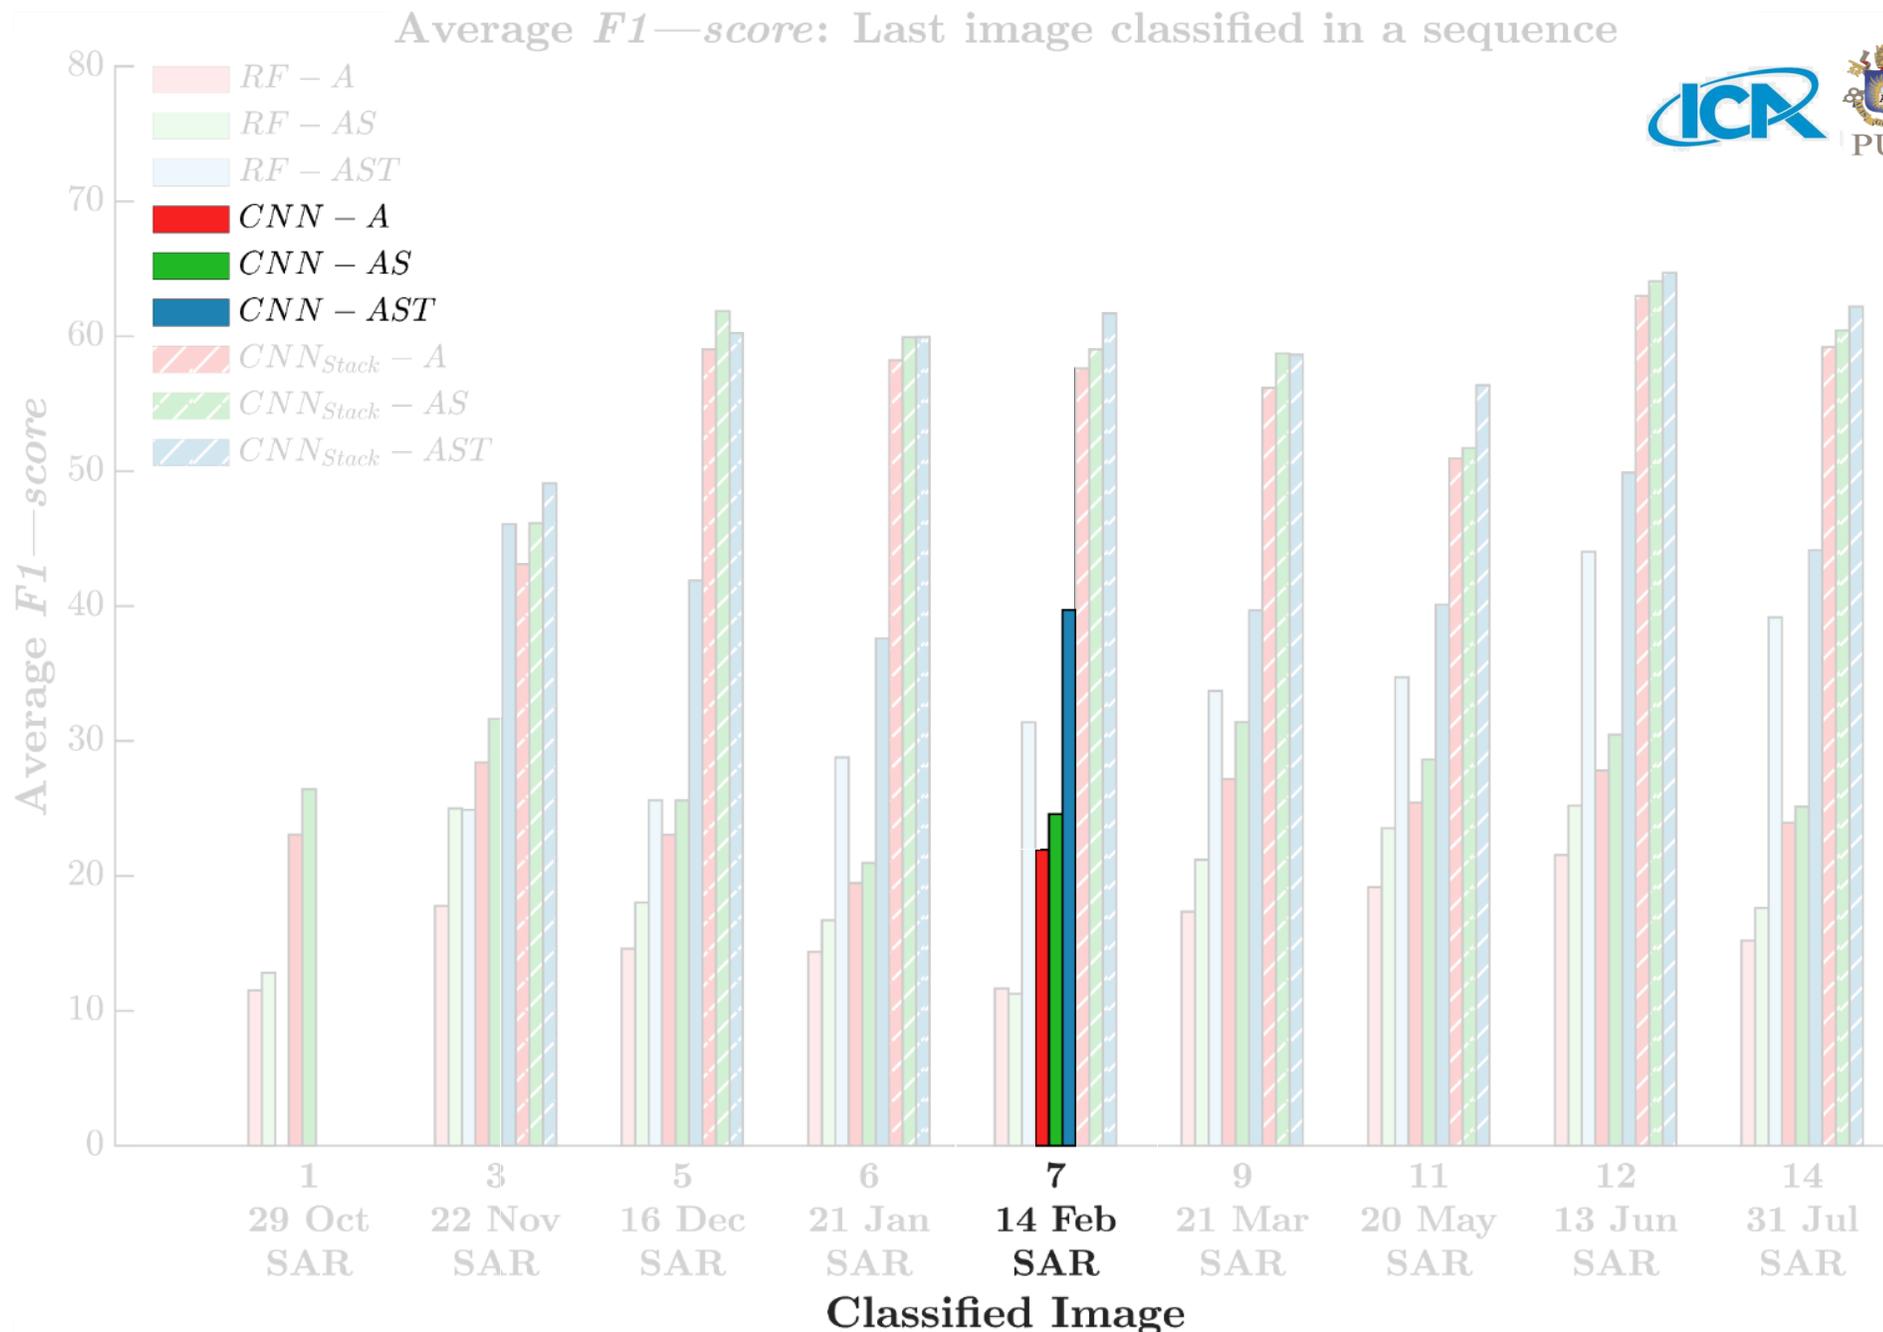
Random Forest + GLCM

Average $F1$ —score: Last image classified in a sequence



Resultados 1 sensor

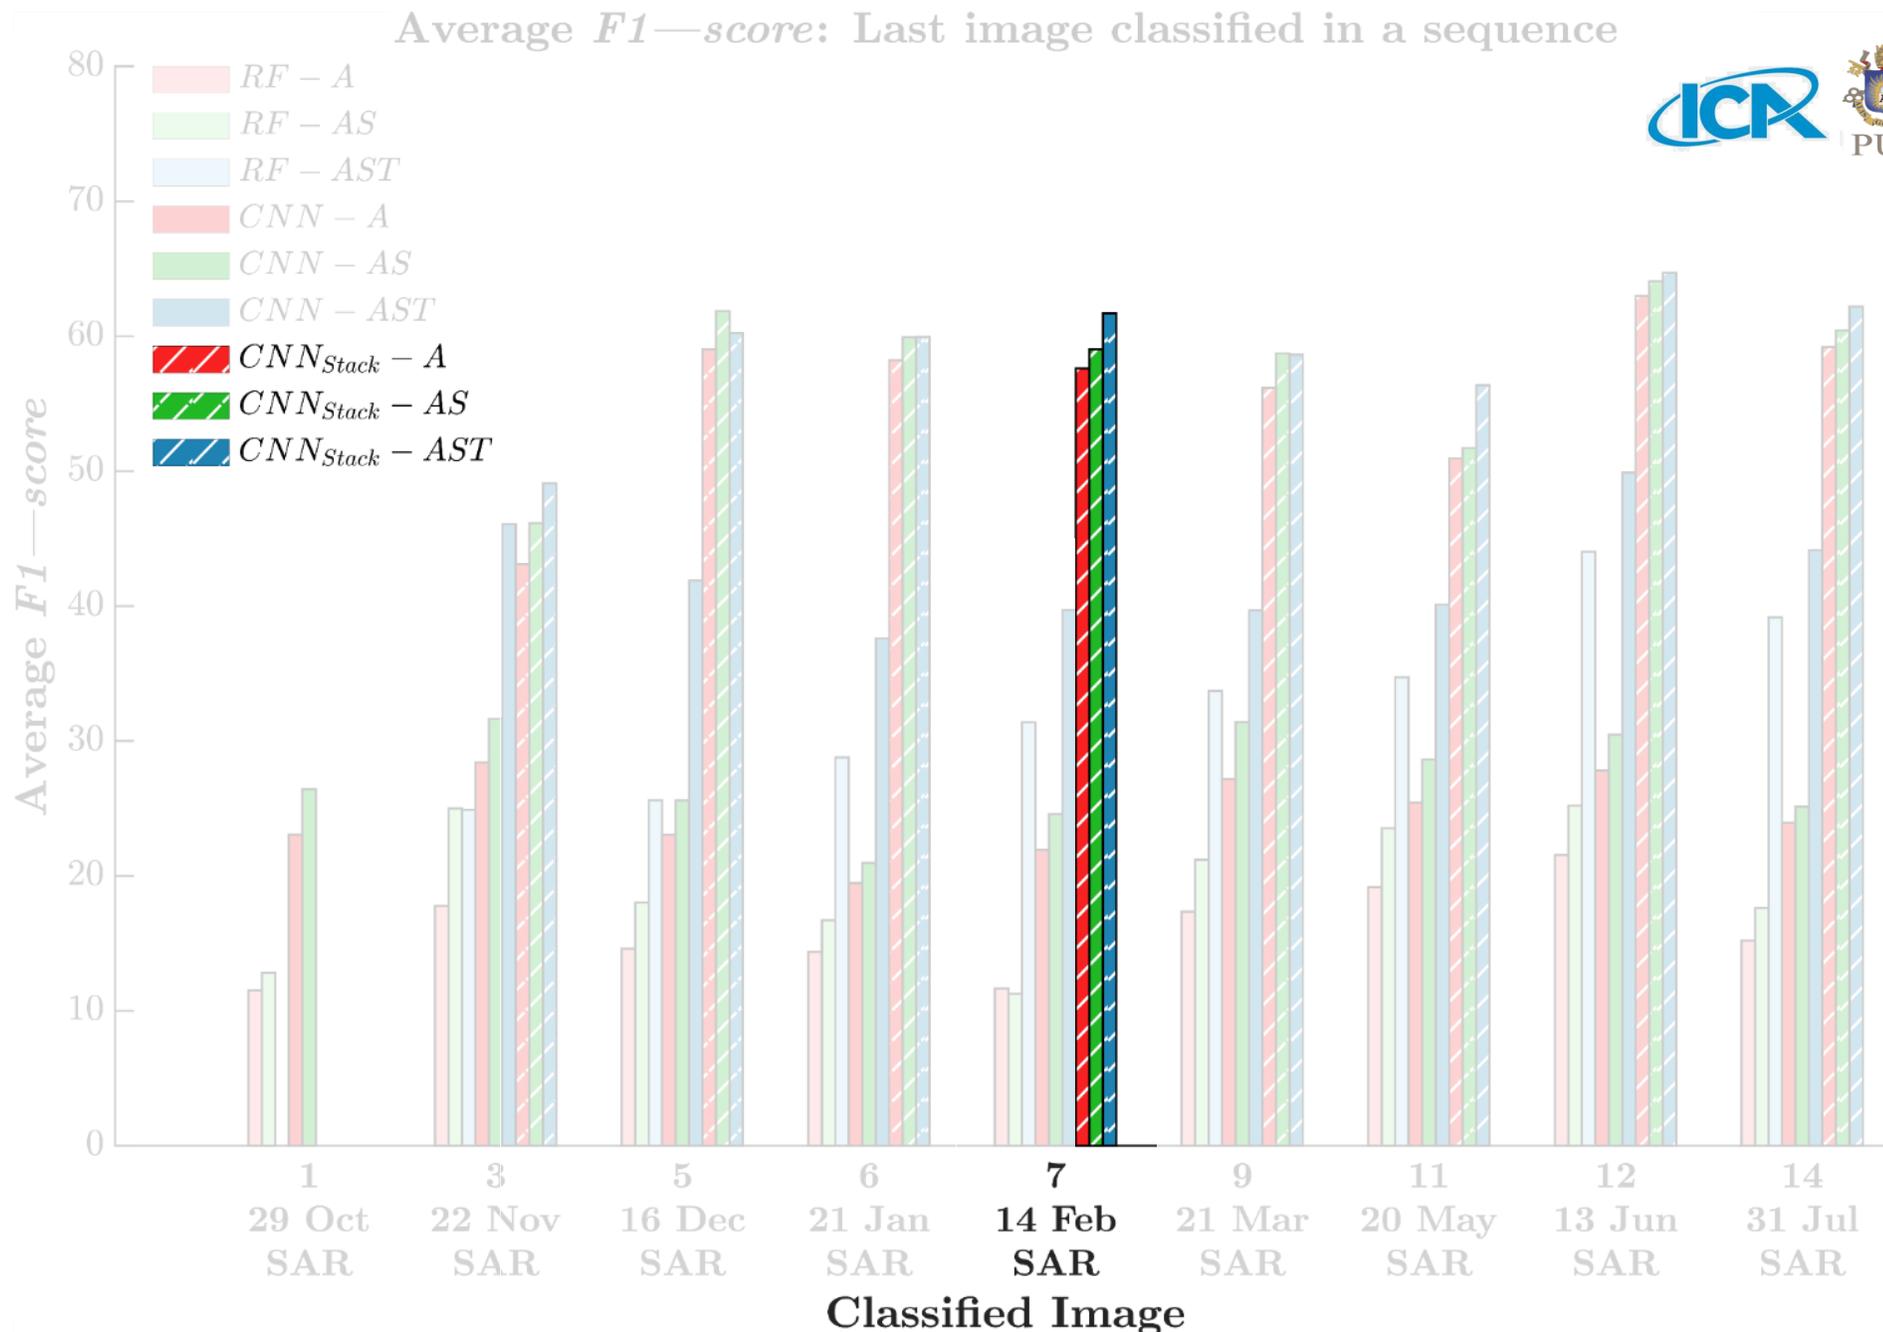
CNN single image



Classified Image

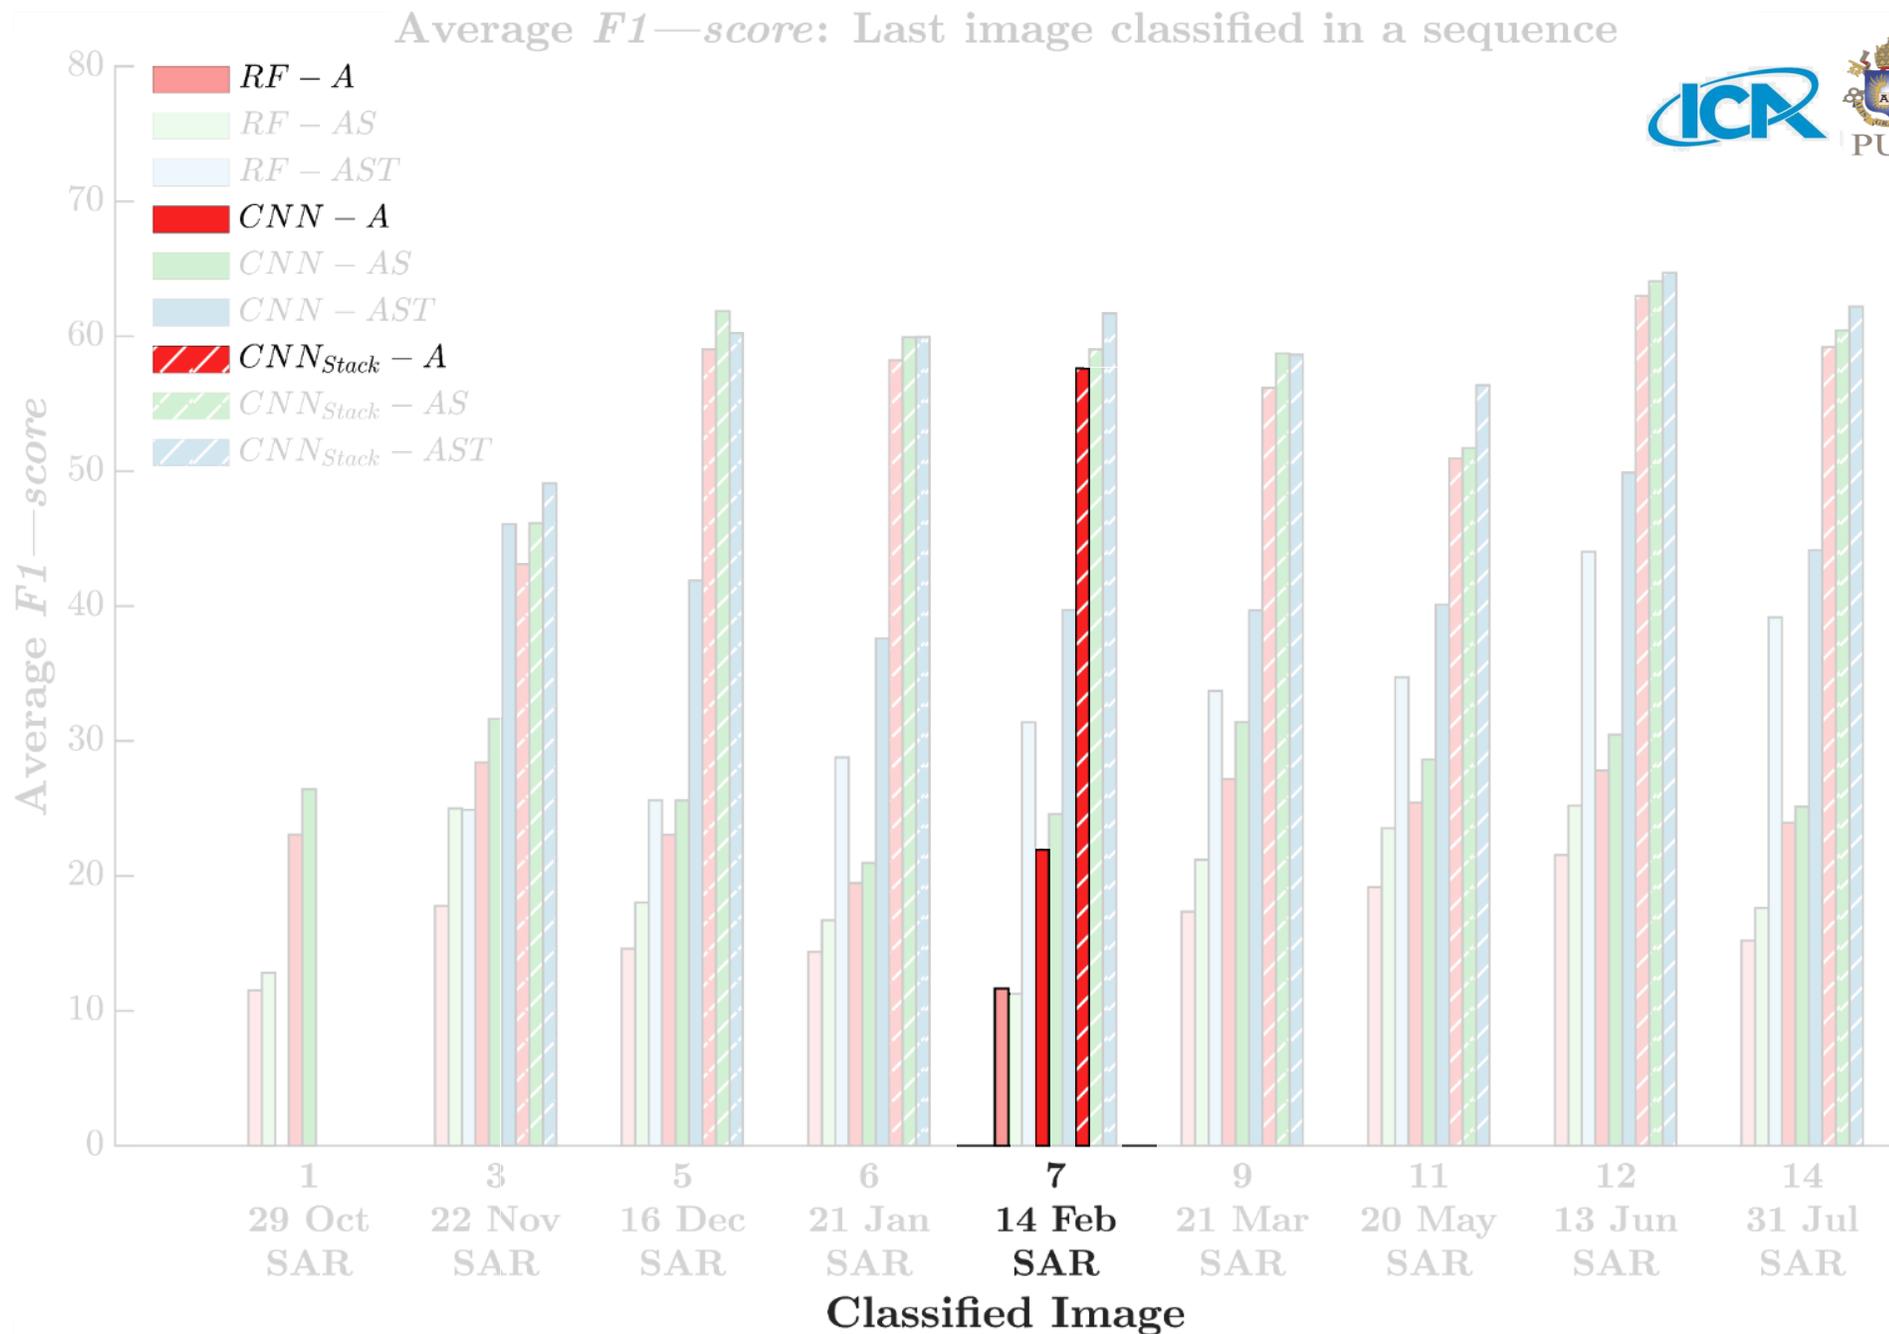
Resultados 1 sensor

CNN image stack



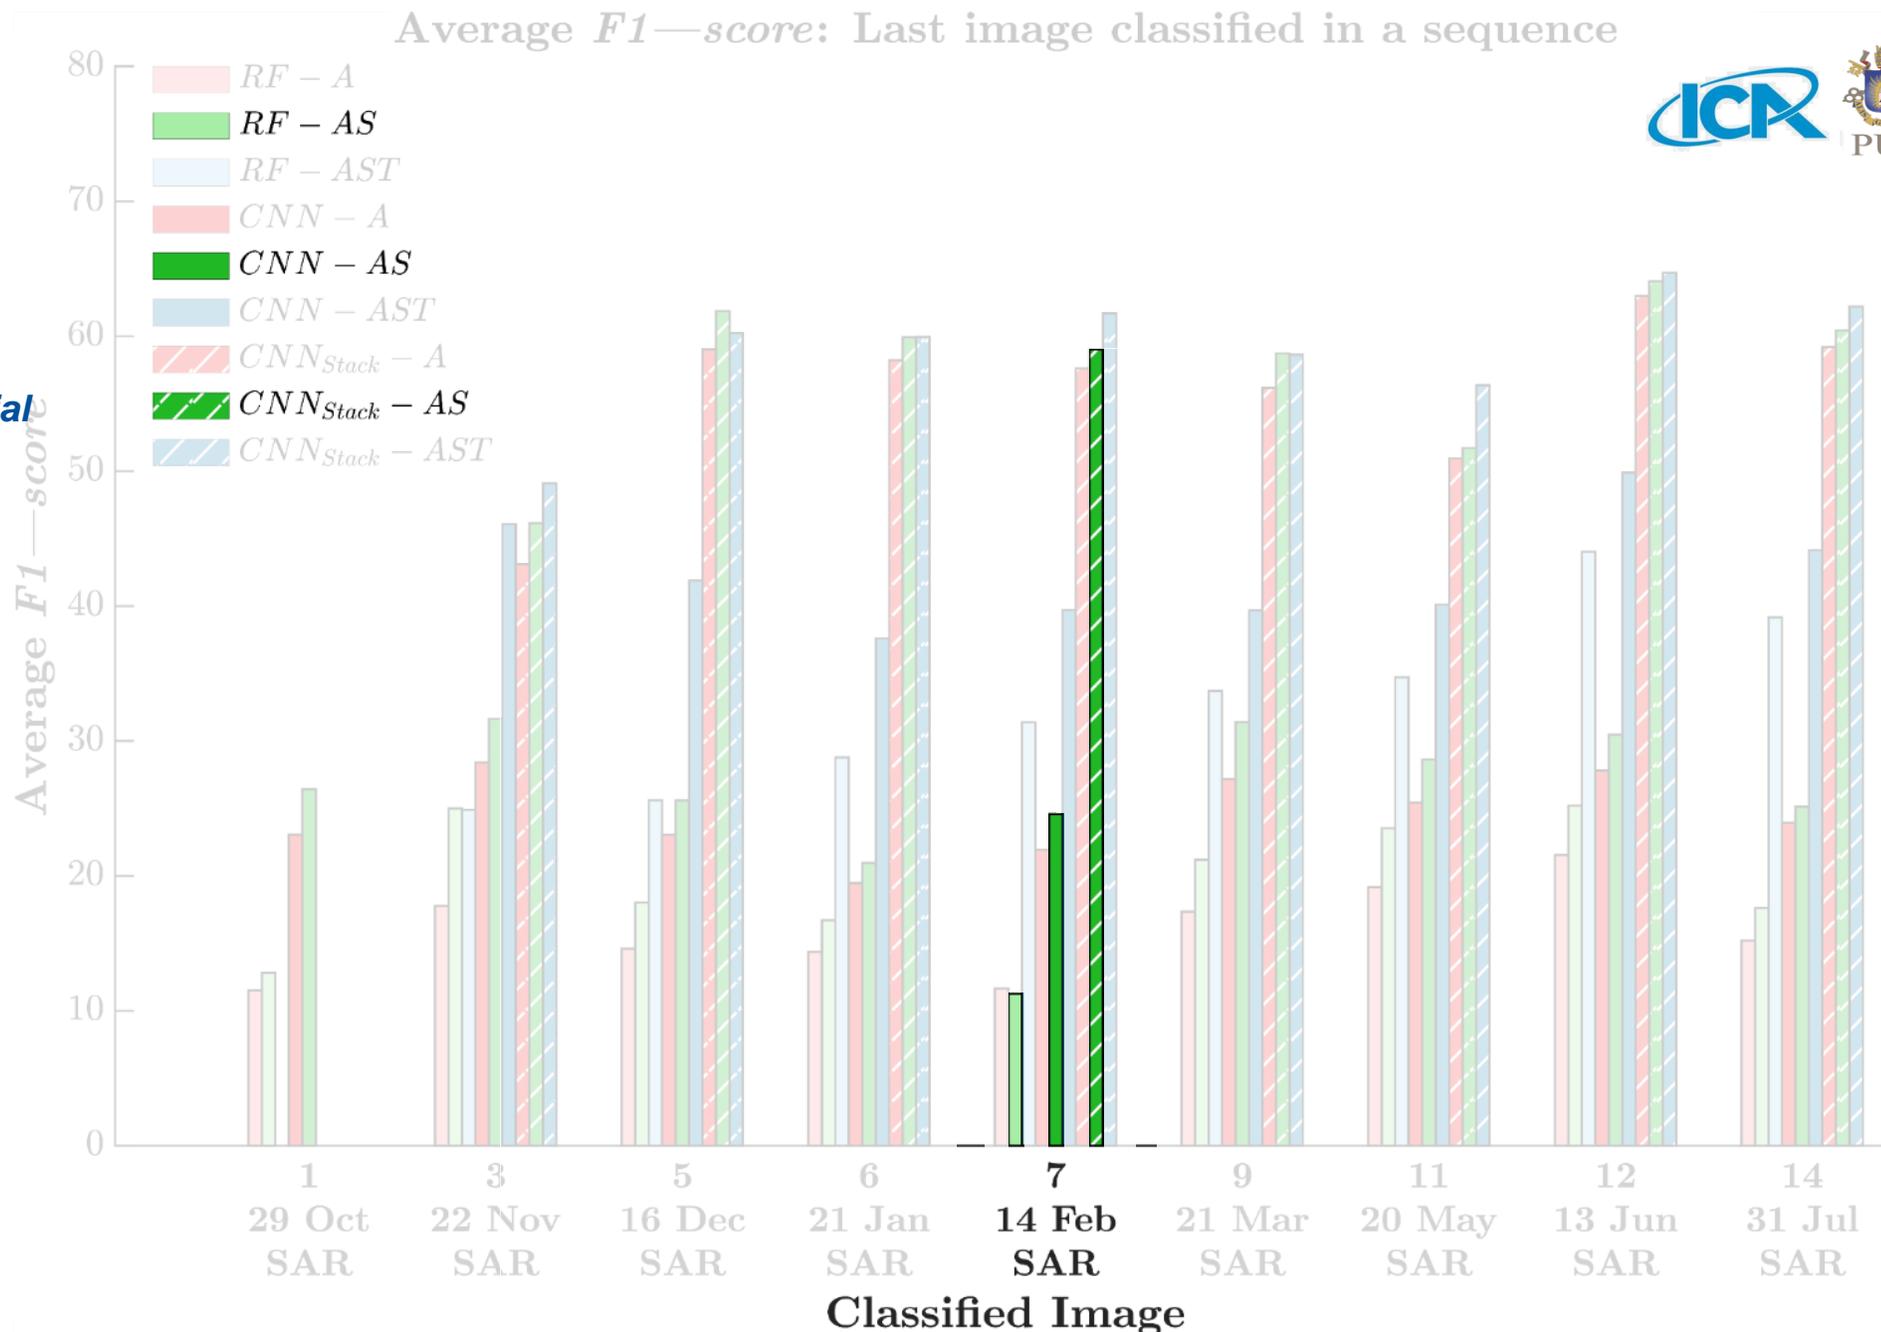
Resultados 1 sensor

A: association potential



Resultados 1 sensor

A: association potential
S: spatial interaction potential

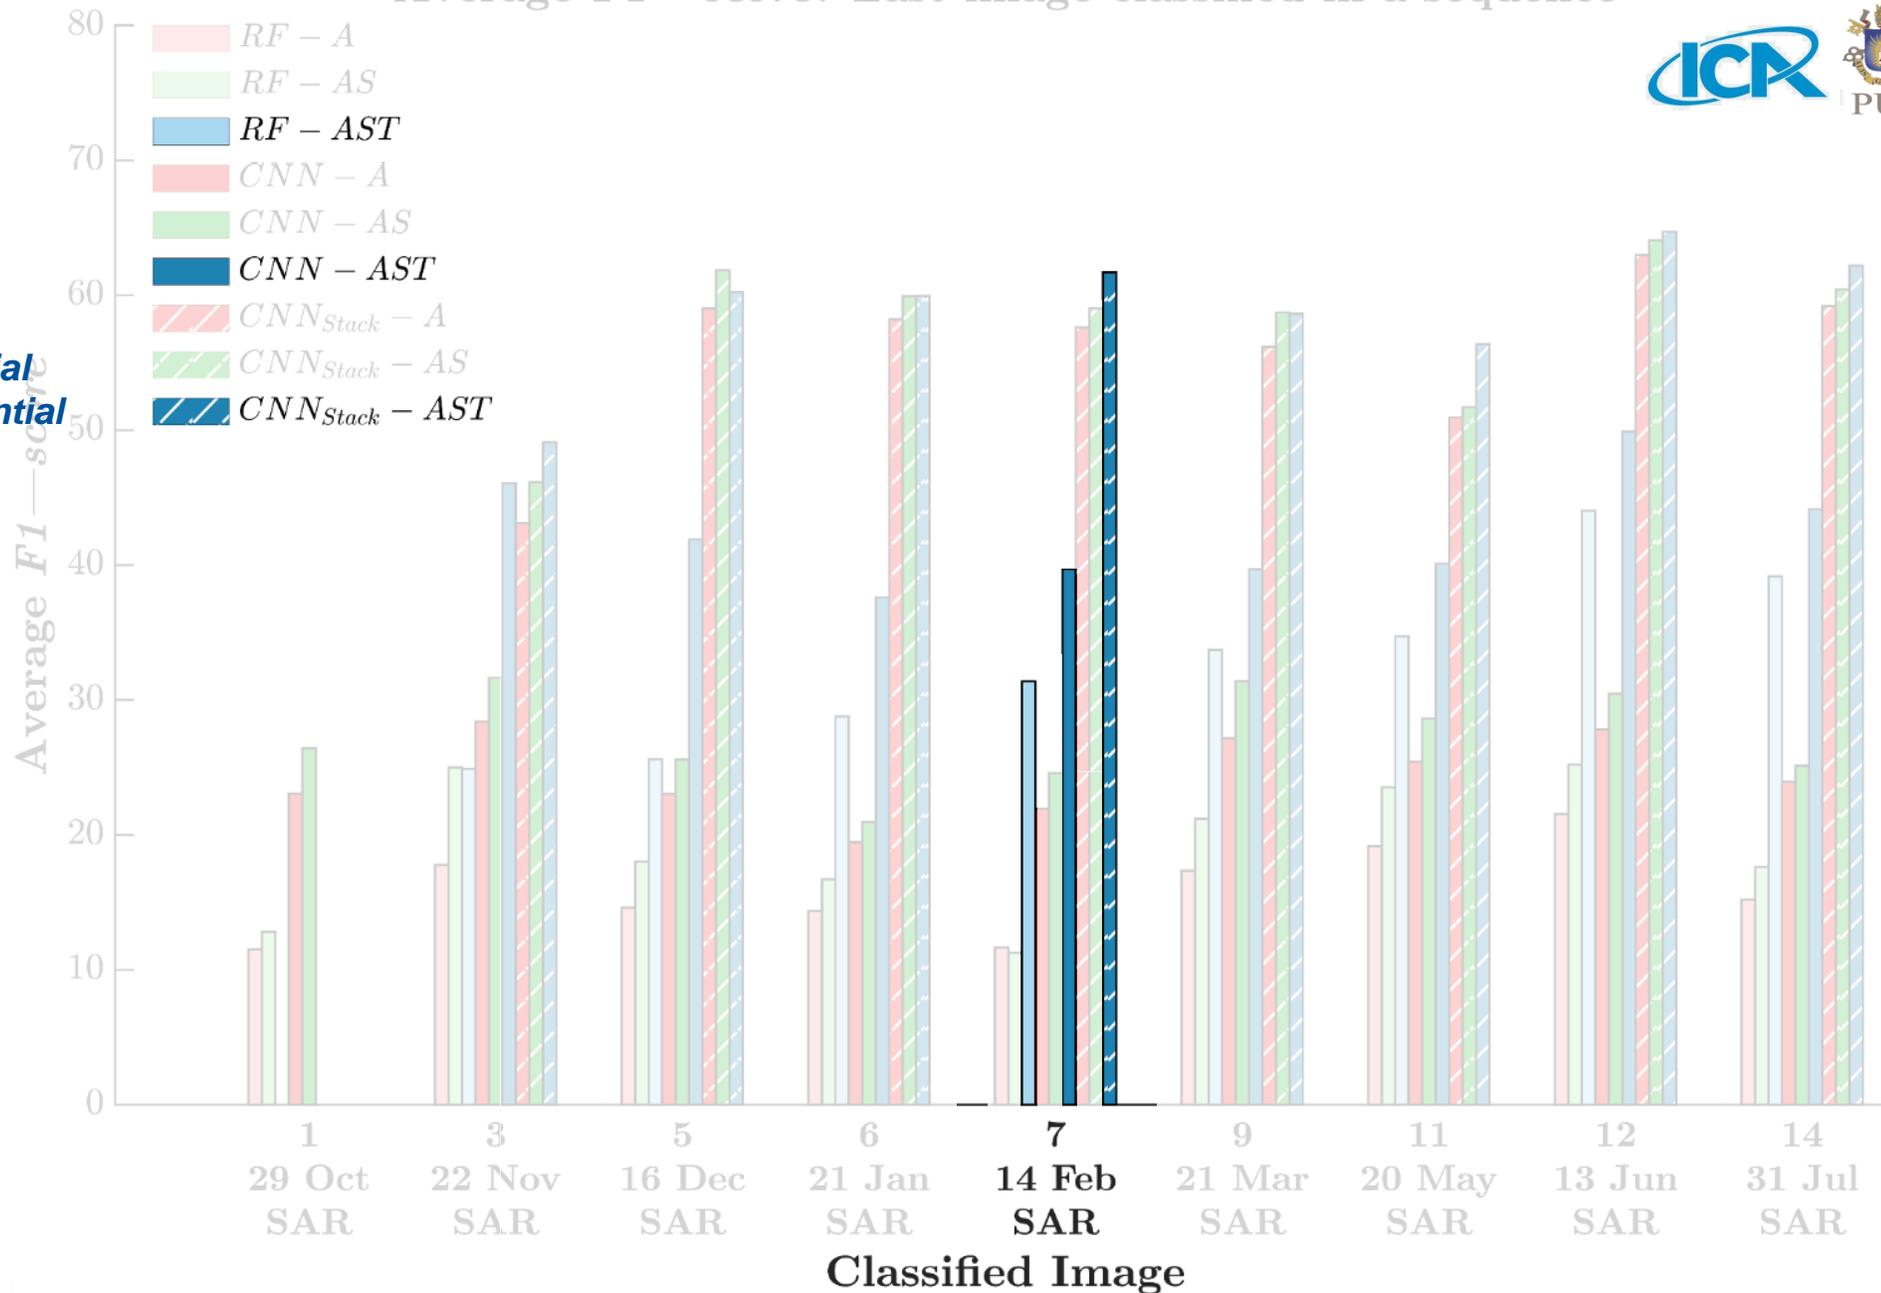


Classified Image

Resultados 1 sensor

A: association potential
S: spatial interaction potential
T: temporal interaction potential

Average $F1$ —score: Last image classified in a sequence

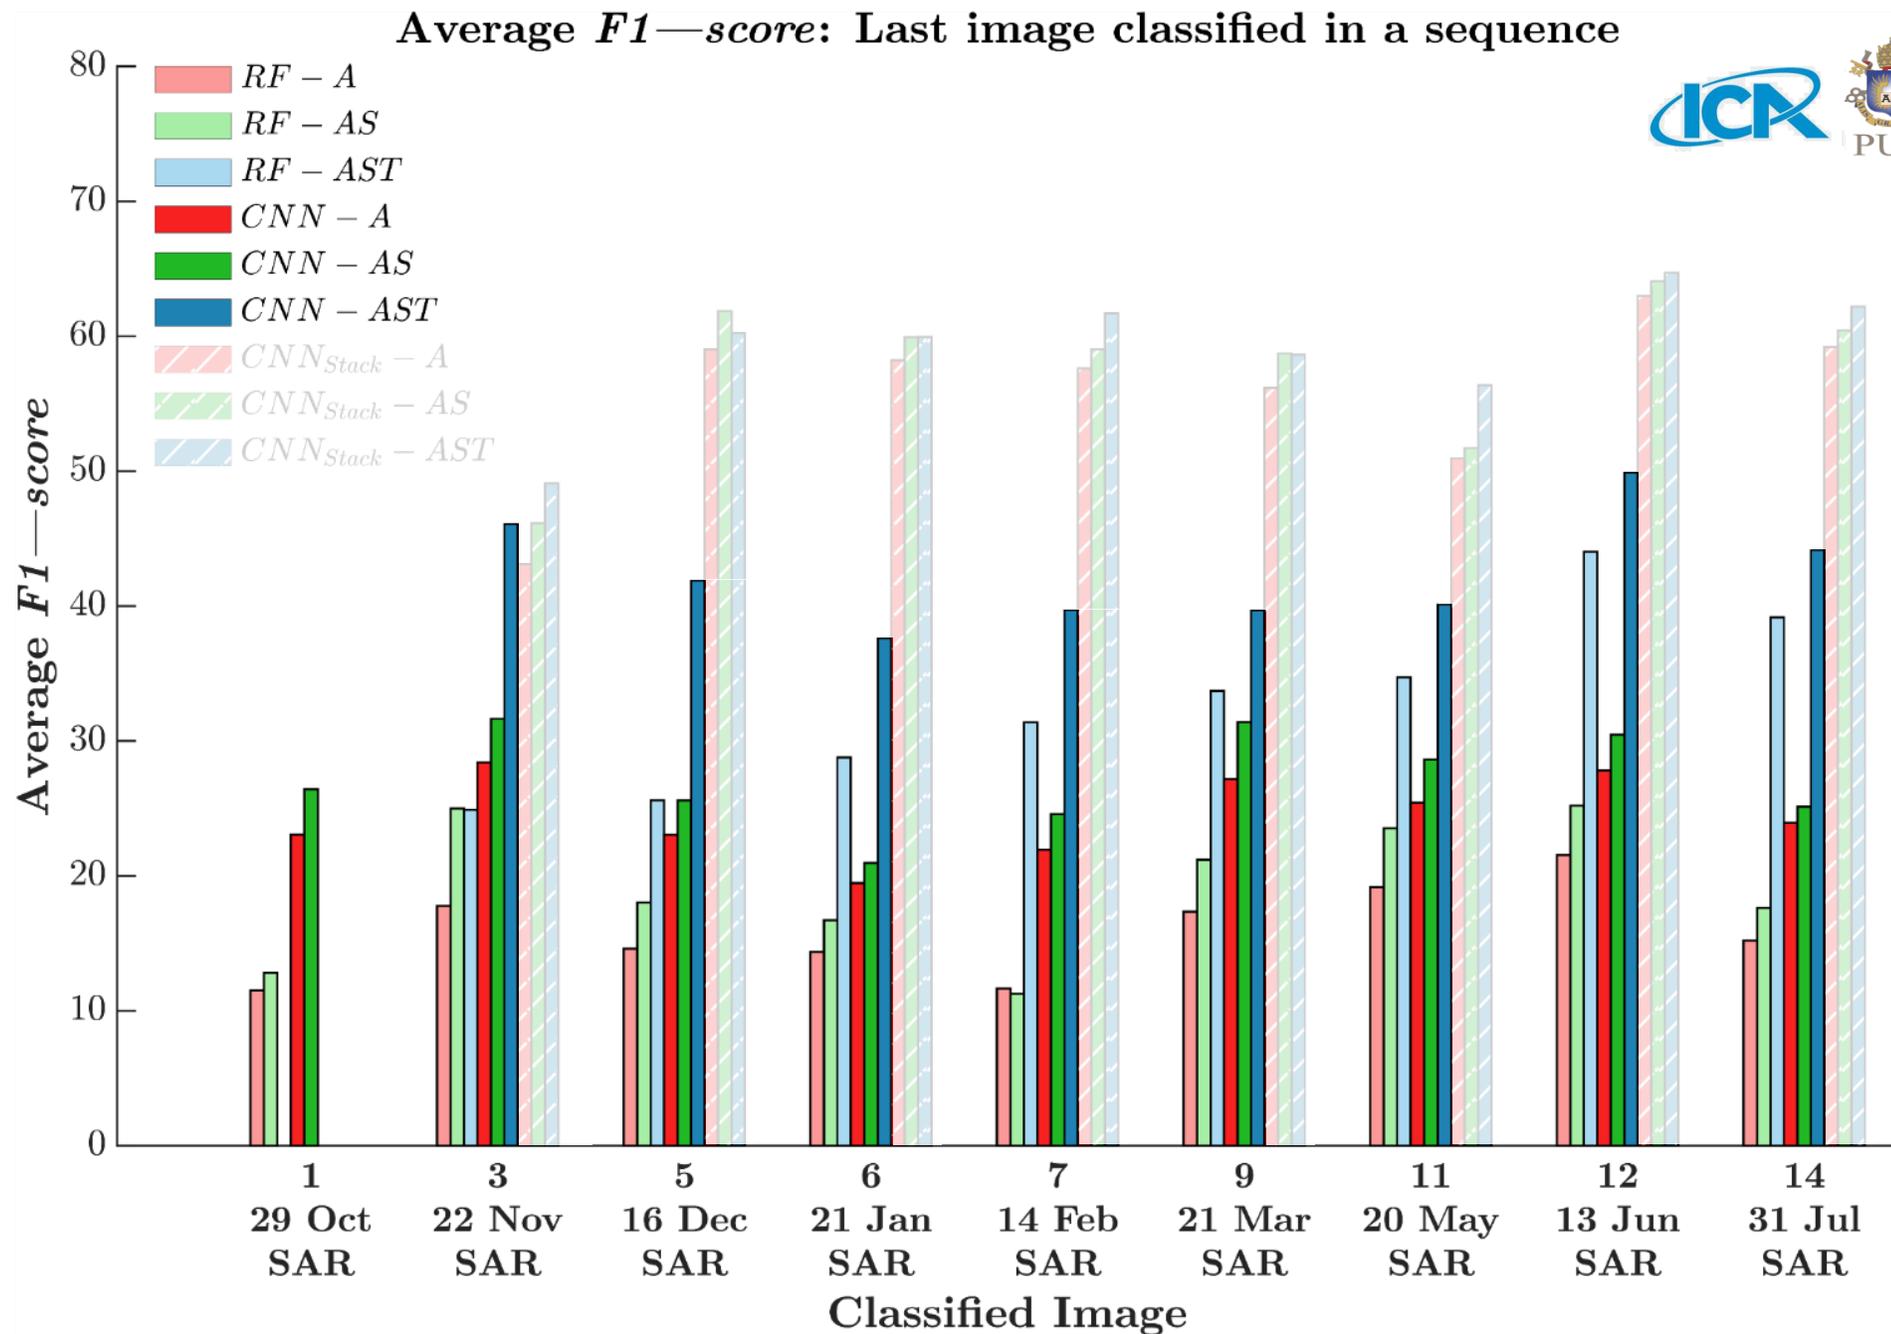


Classified Image

Resultados 1 sensor

RF + GLCM

CNN single image

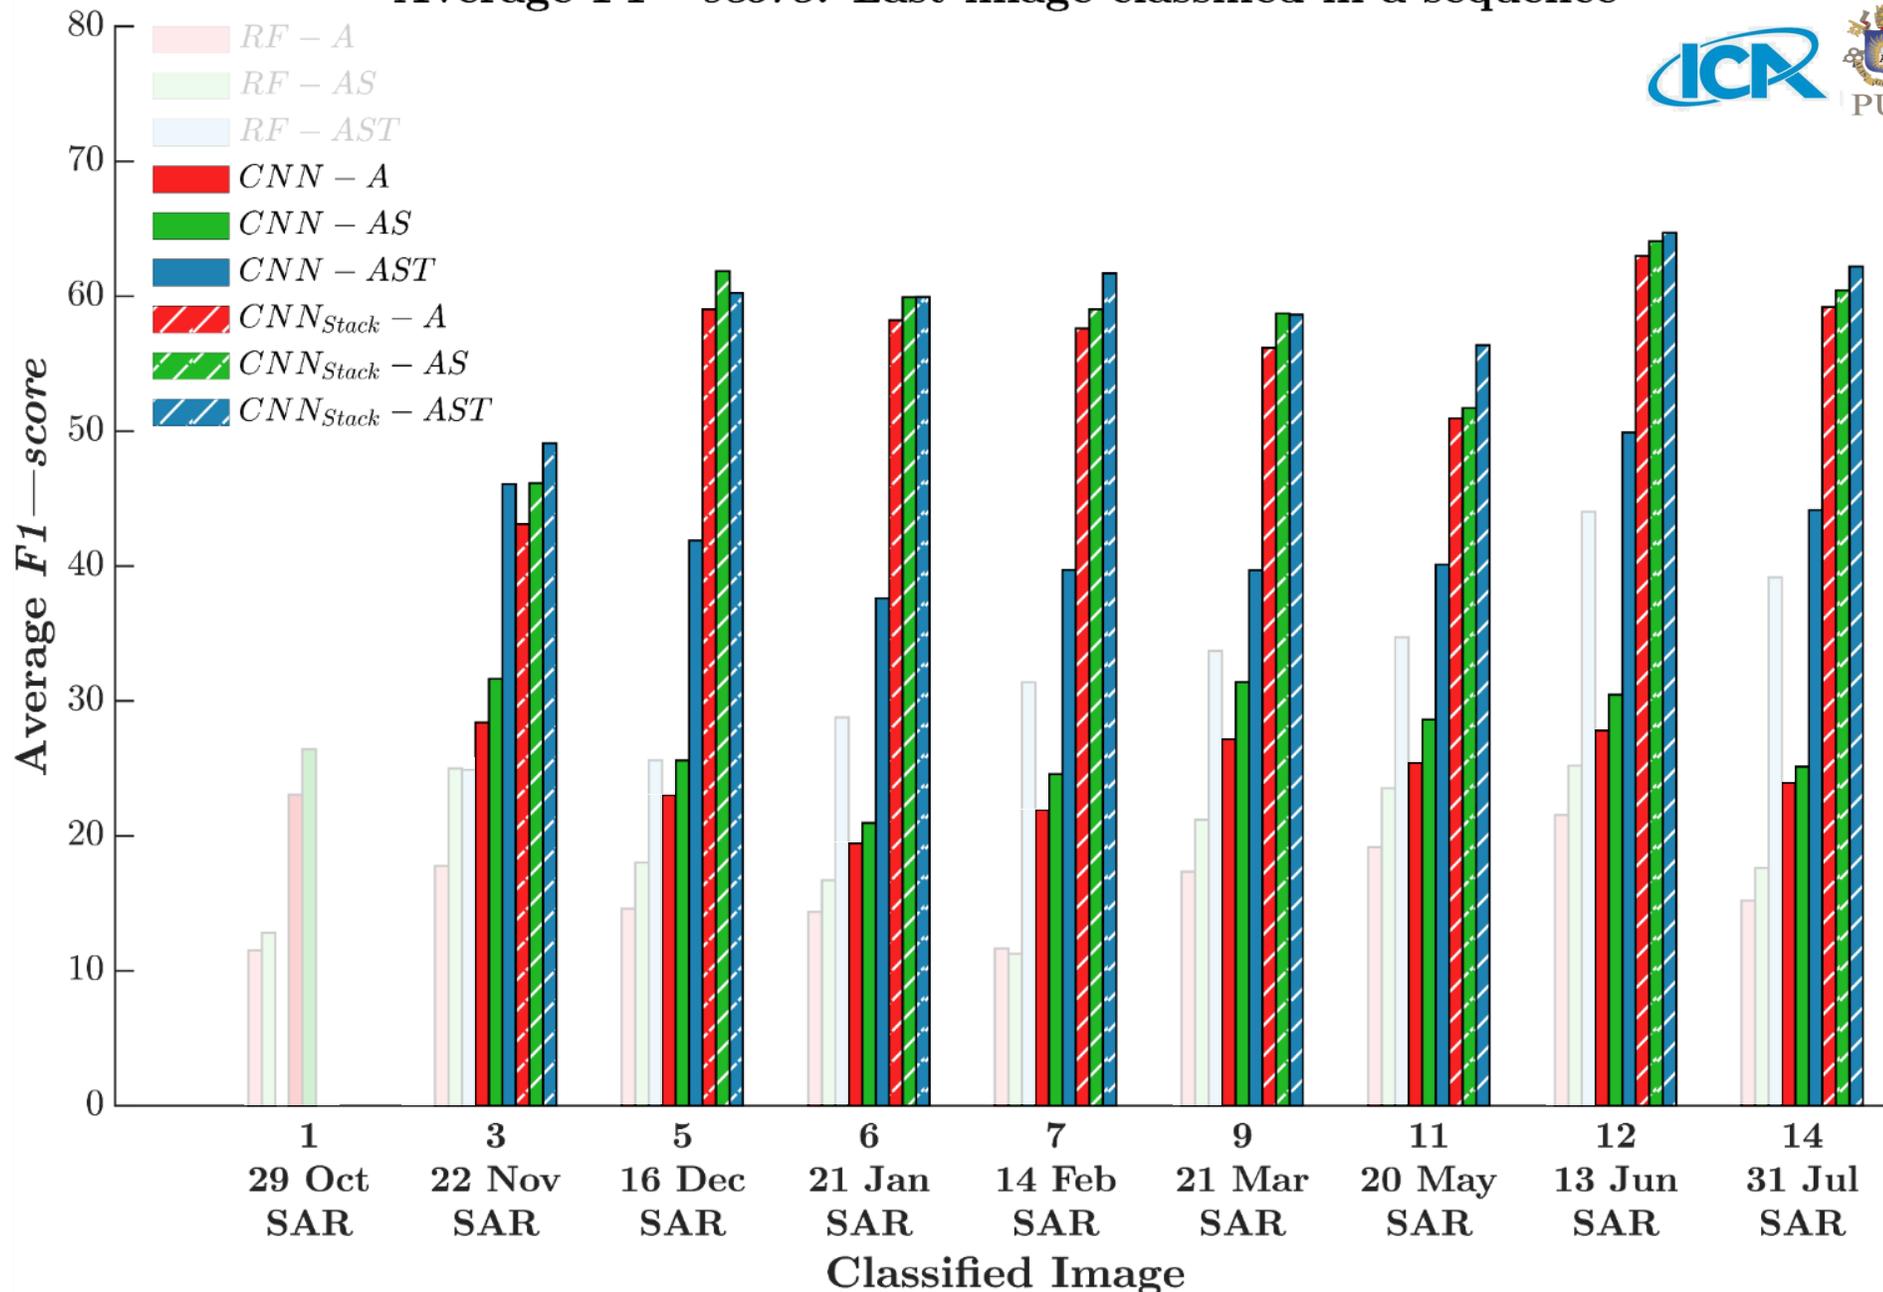


Resultados 1 sensor

CNN single image

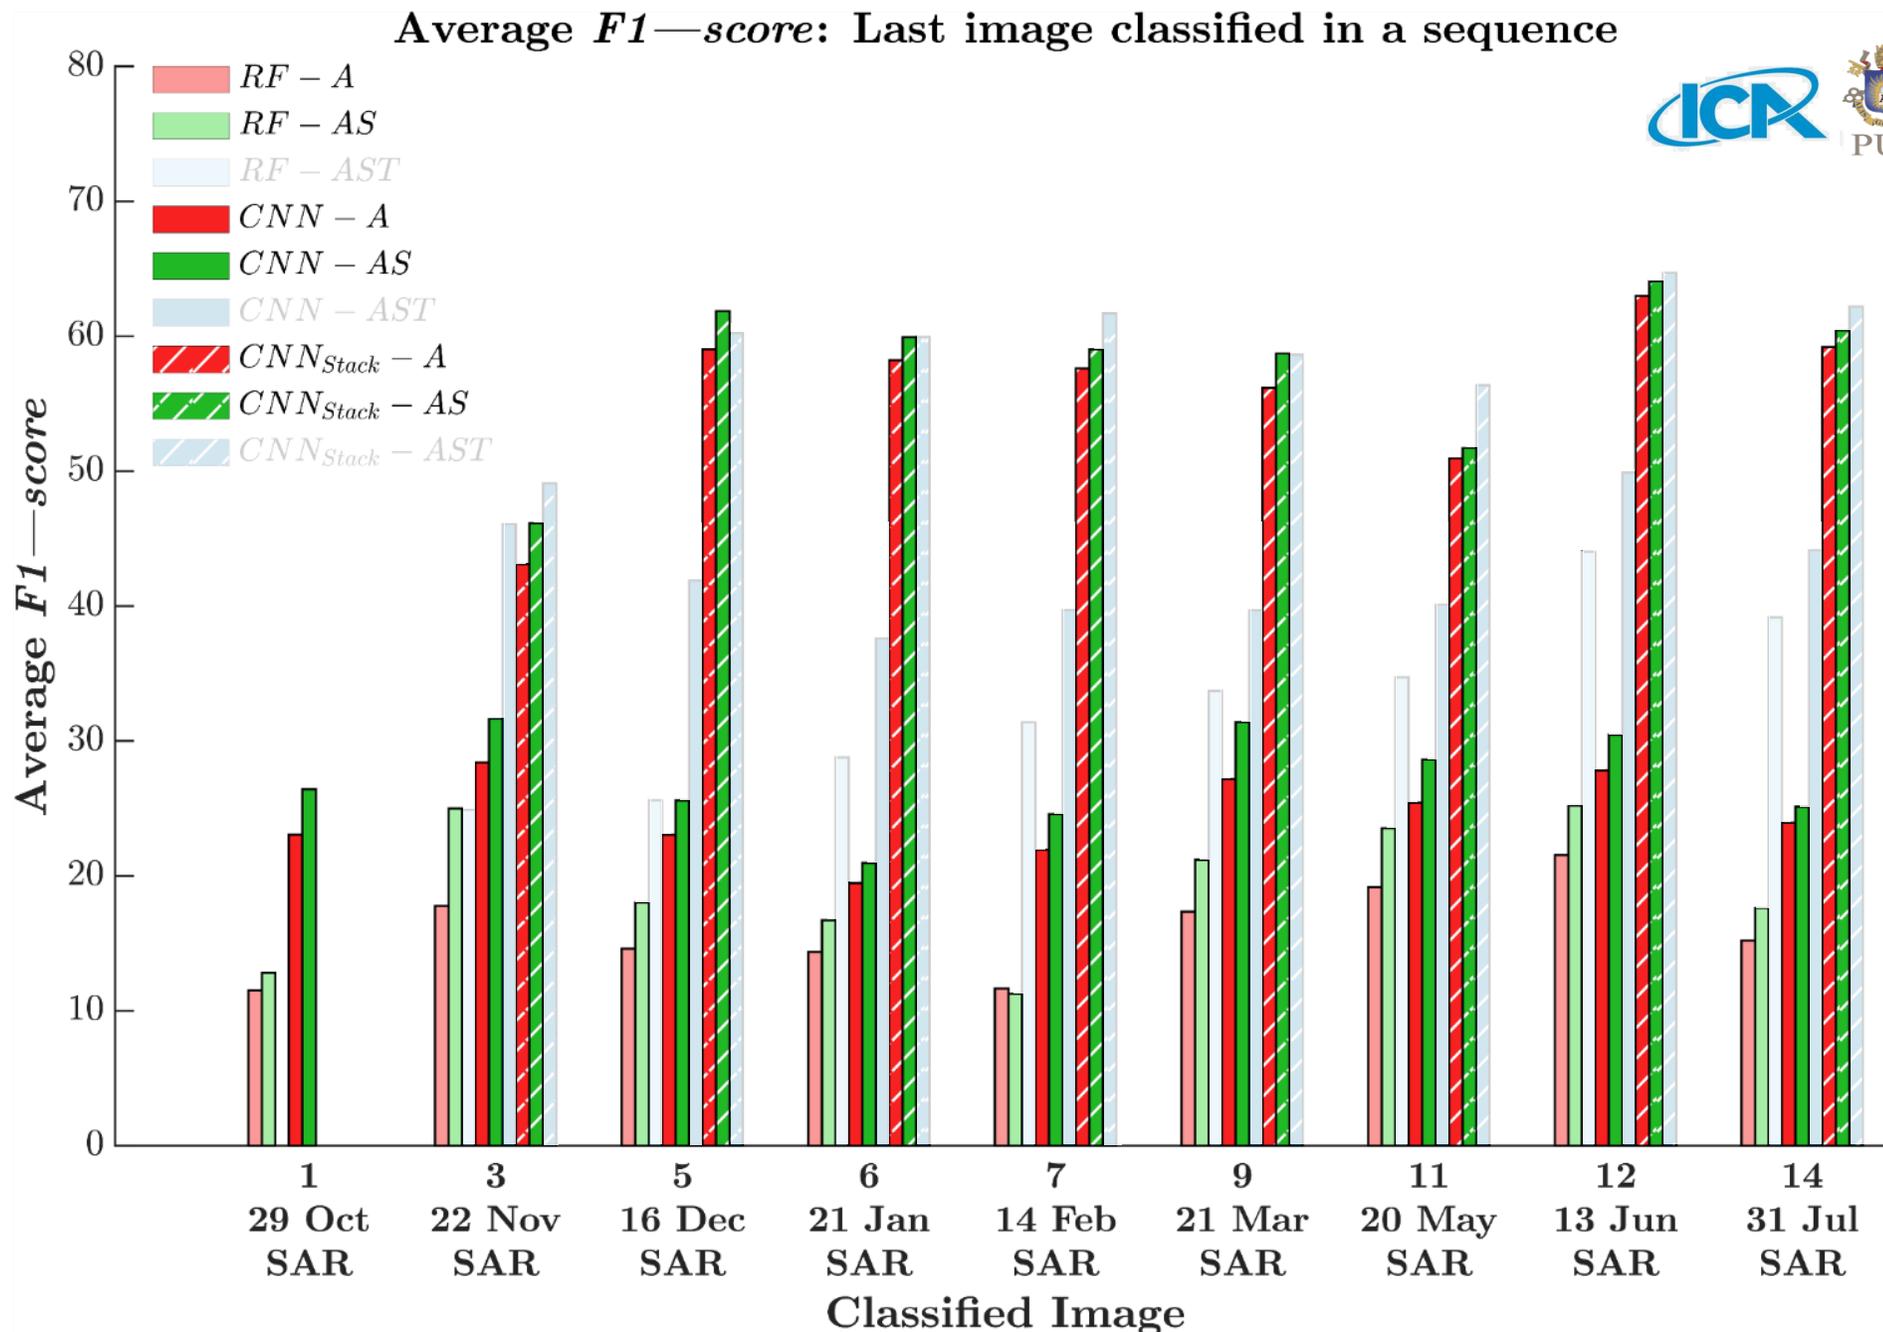
CNN image stack

Average $F1$ —score: Last image classified in a sequence



Resultados 1 sensor

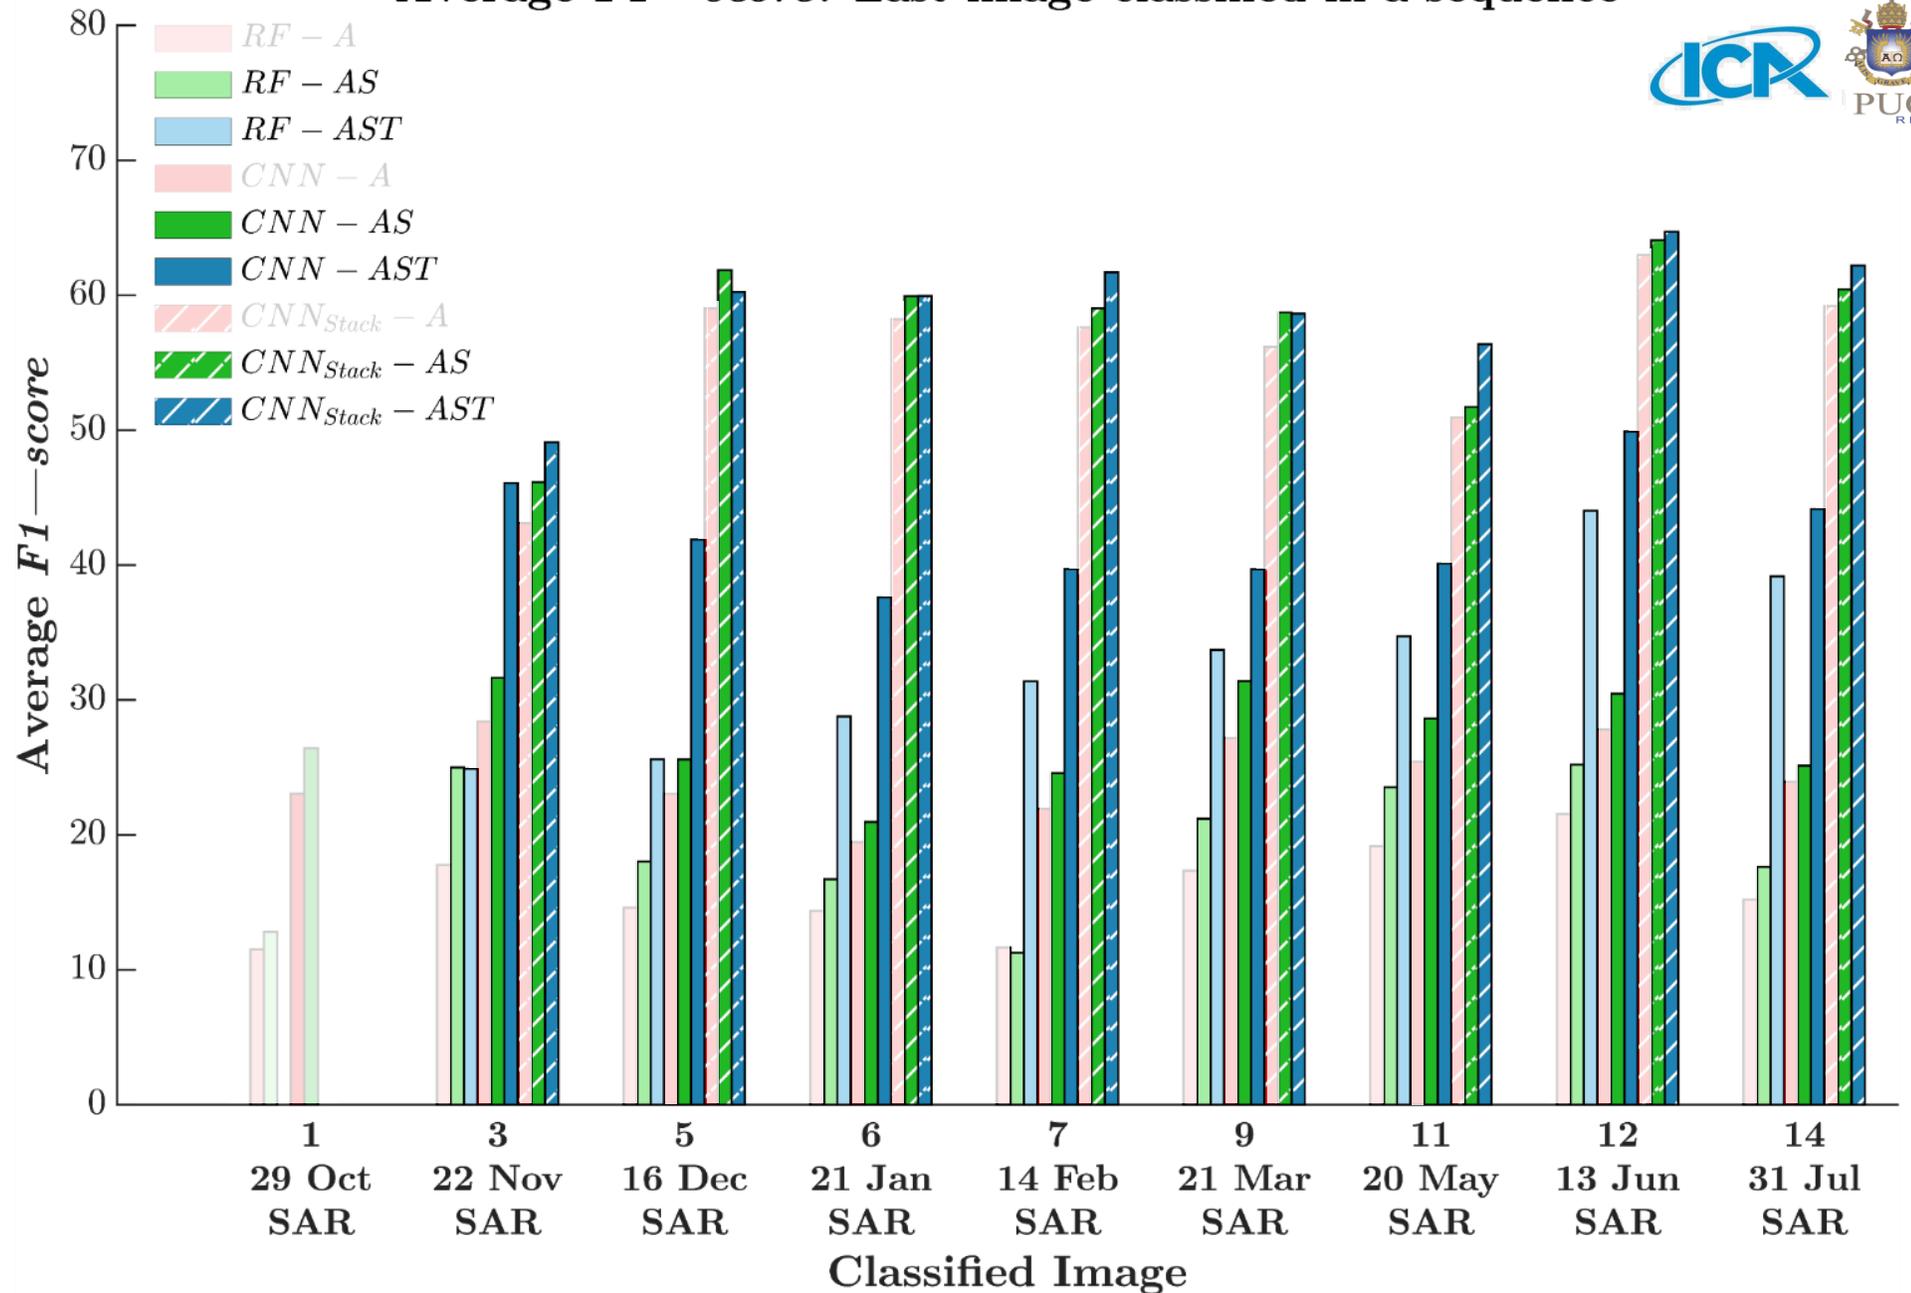
Introduction of the SIP



Resultados 1 sensor

Introduction of the TIP

Average $F1$ —score: Last image classified in a sequence



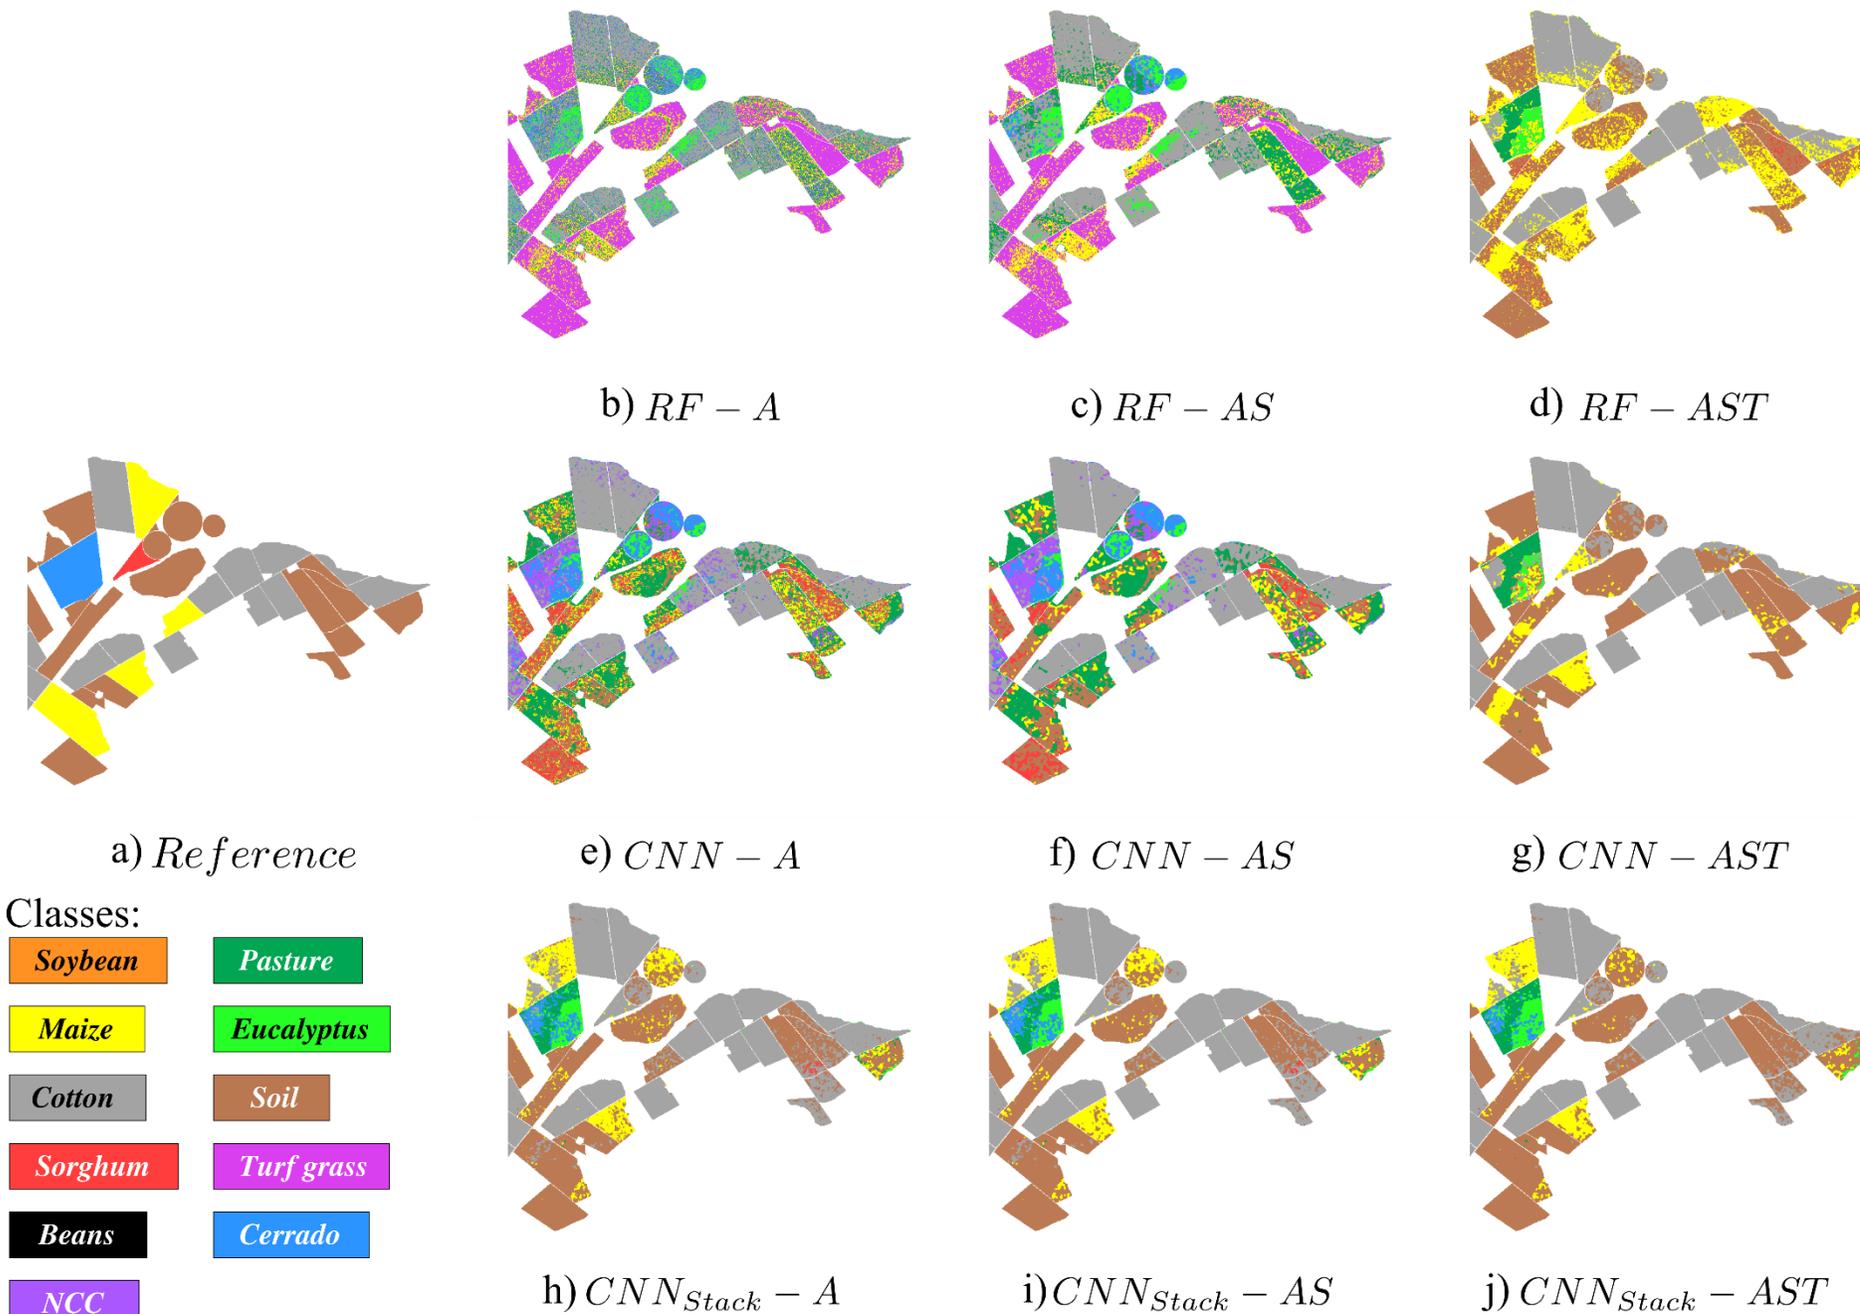
Resultados 1 sensor

Classification Maps

Sequence length: 14

Date: July 31st

Sensor: SAR



Classes:

Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	

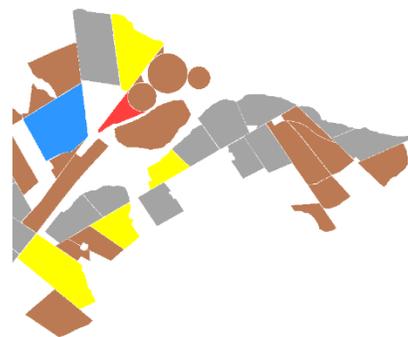
Resultados 1 sensor

Classification Maps

Sequence length: 14

Date: July 31st

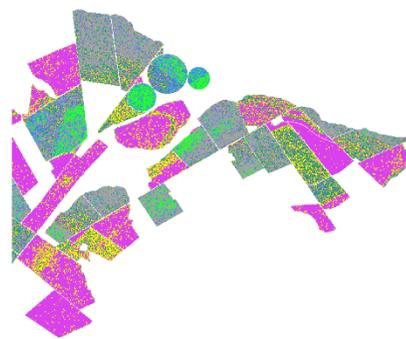
Sensor: SAR



a) Reference

Classes:

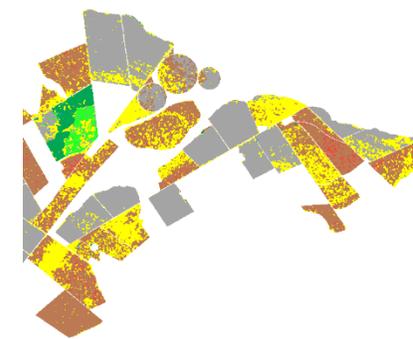
Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



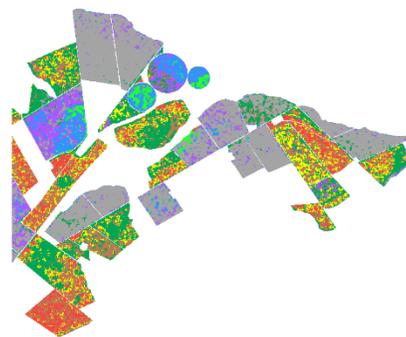
b) RF - A



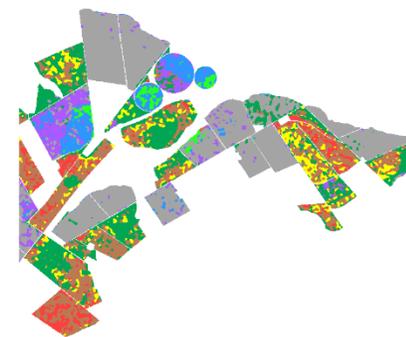
c) RF - AS



d) RF - AST



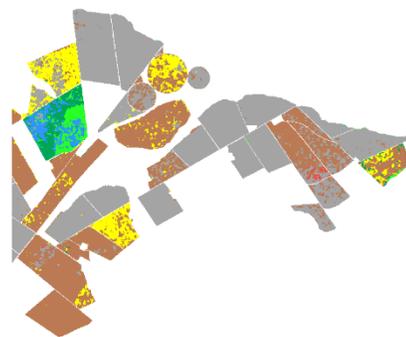
e) CNN - A



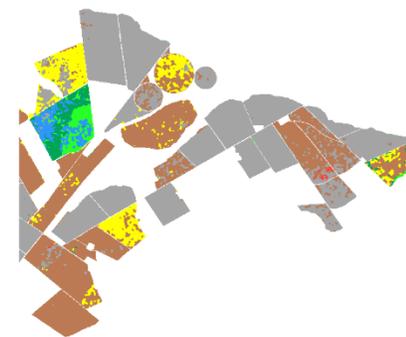
f) CNN - AS



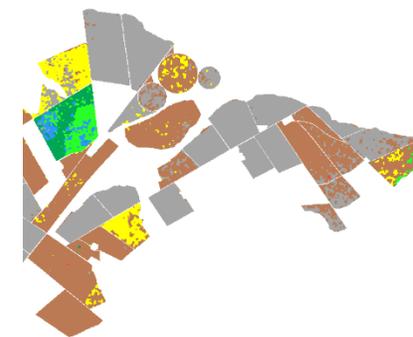
g) CNN - AST



h) CNN_{Stack} - A



i) CNN_{Stack} - AS



j) CNN_{Stack} - AST

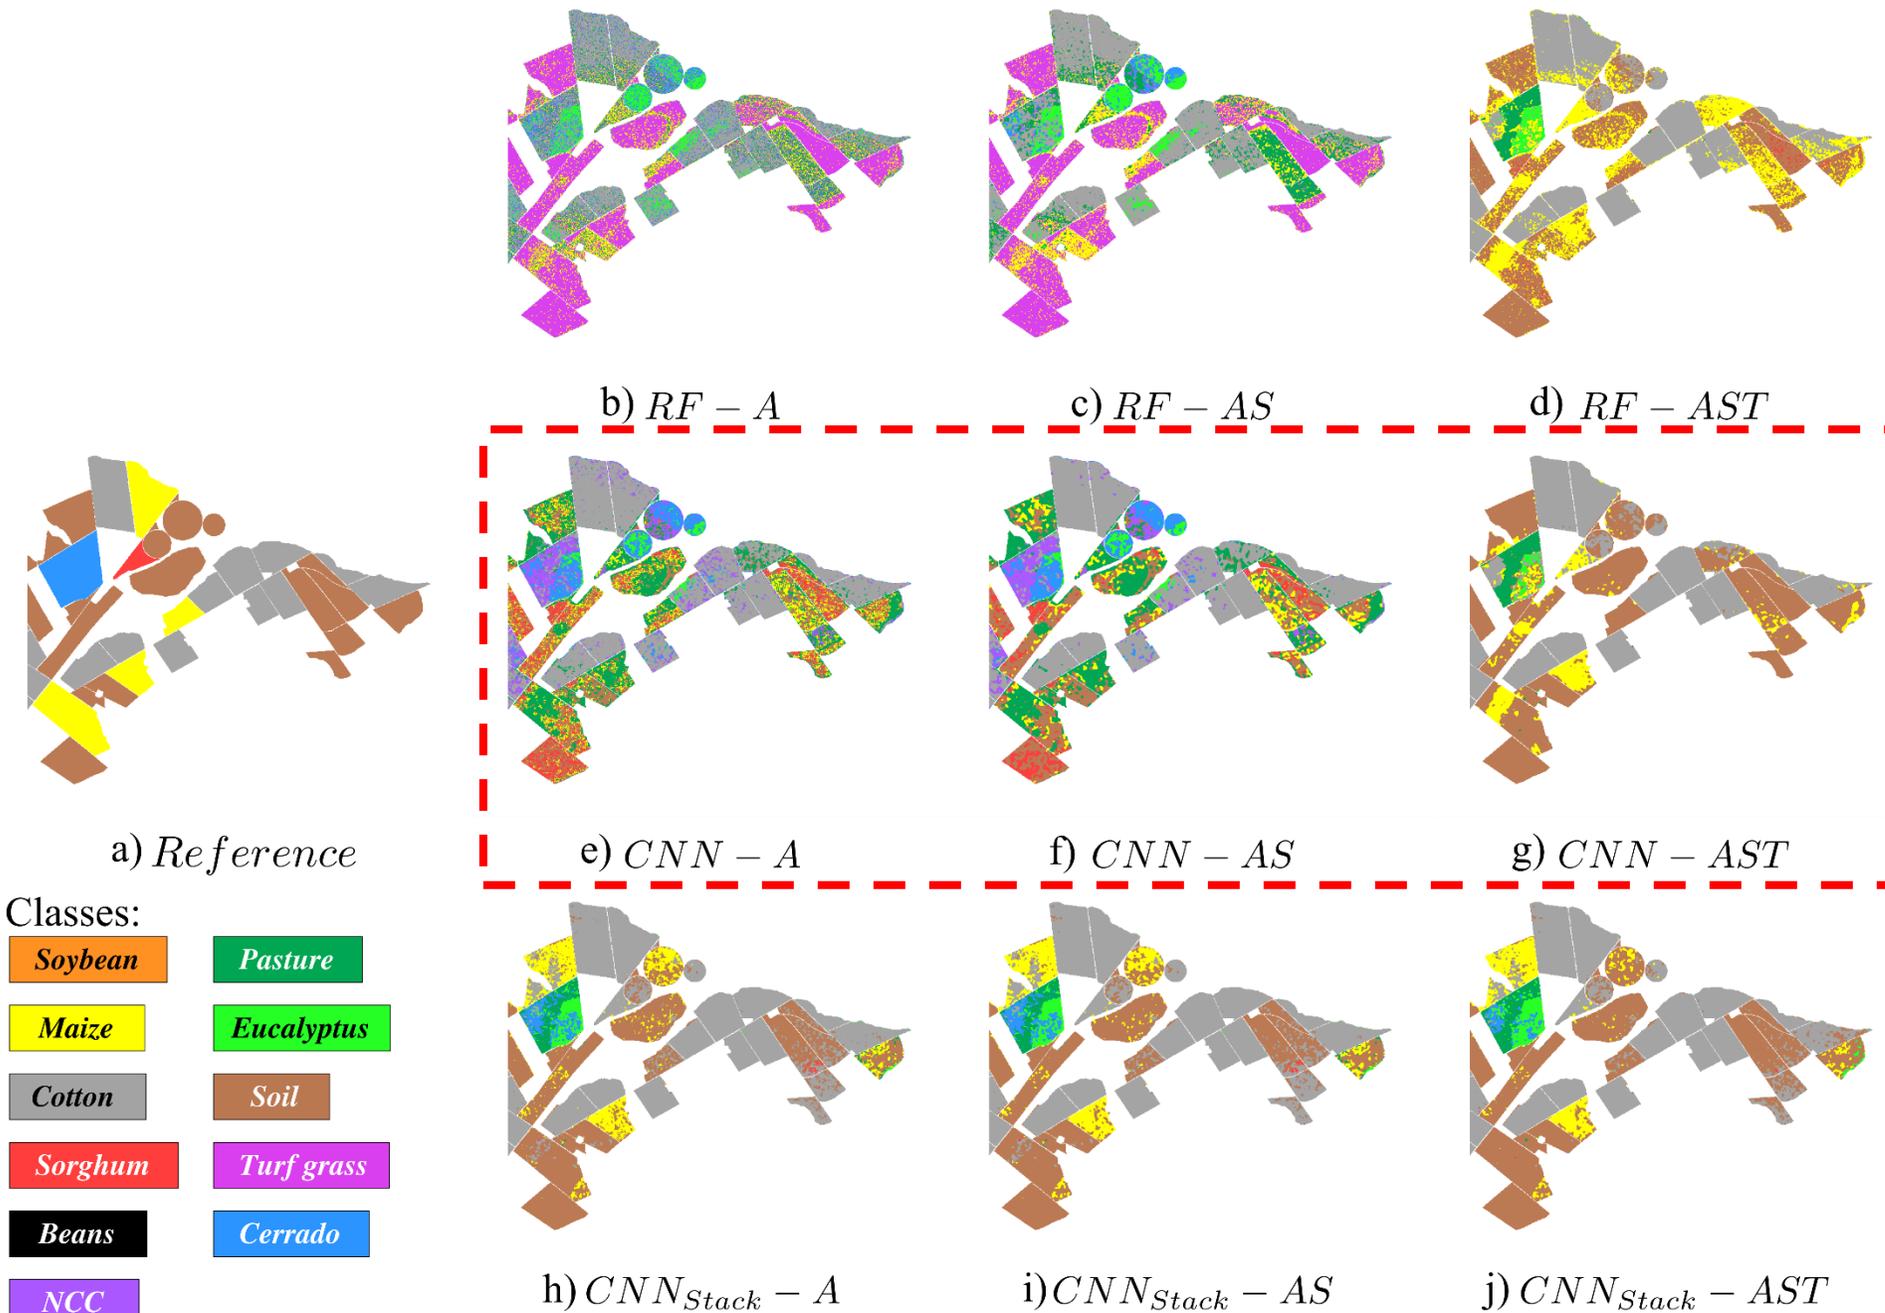
Resultados 1 sensor

Classification Maps

Sequence length: 14

Date: July 31st

Sensor: SAR



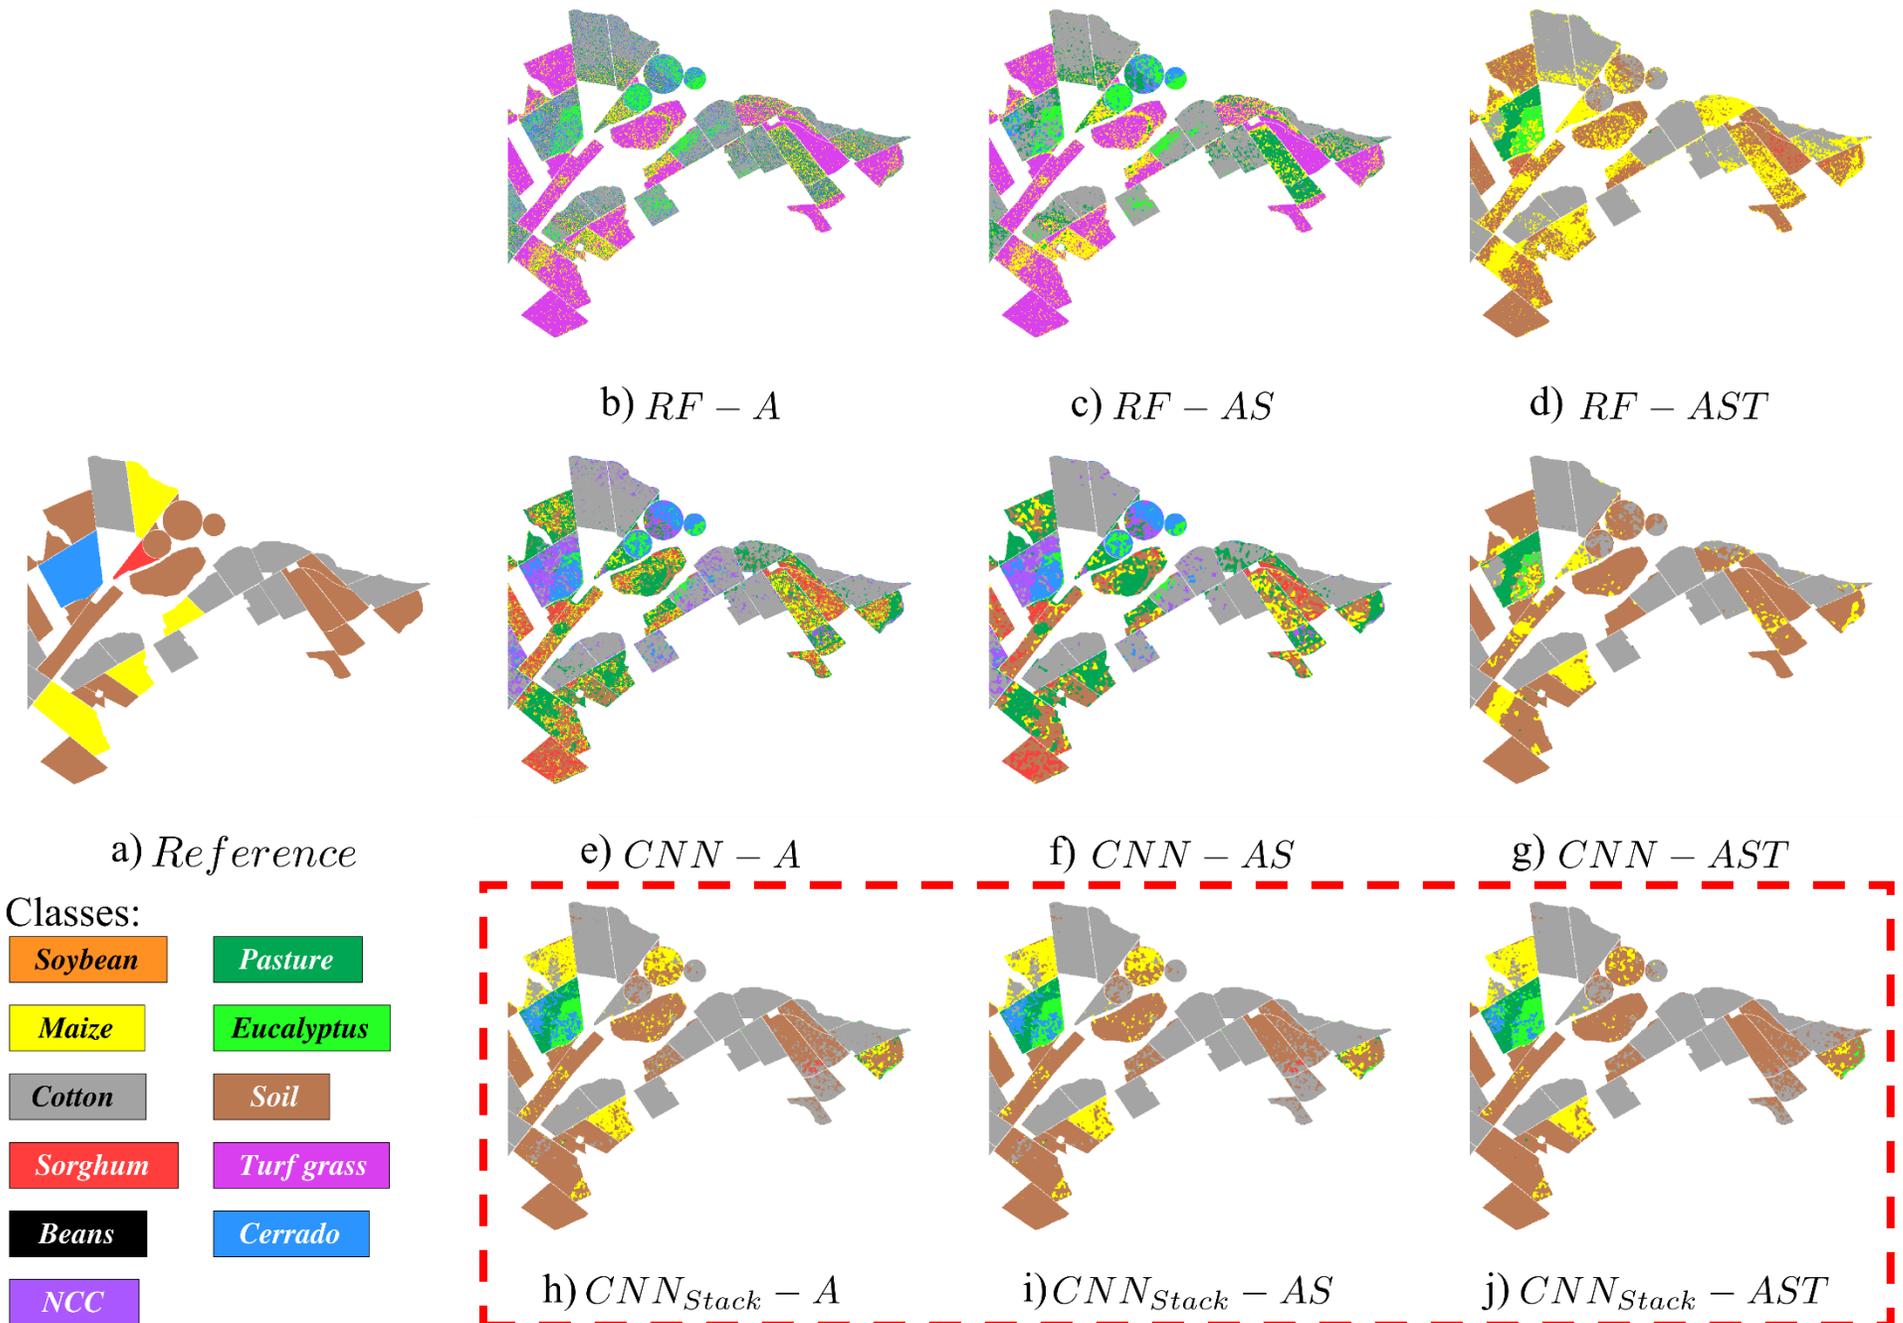
Resultados 1 sensor

Classification Maps

Sequence length: 14

Date: July 31st

Sensor: SAR



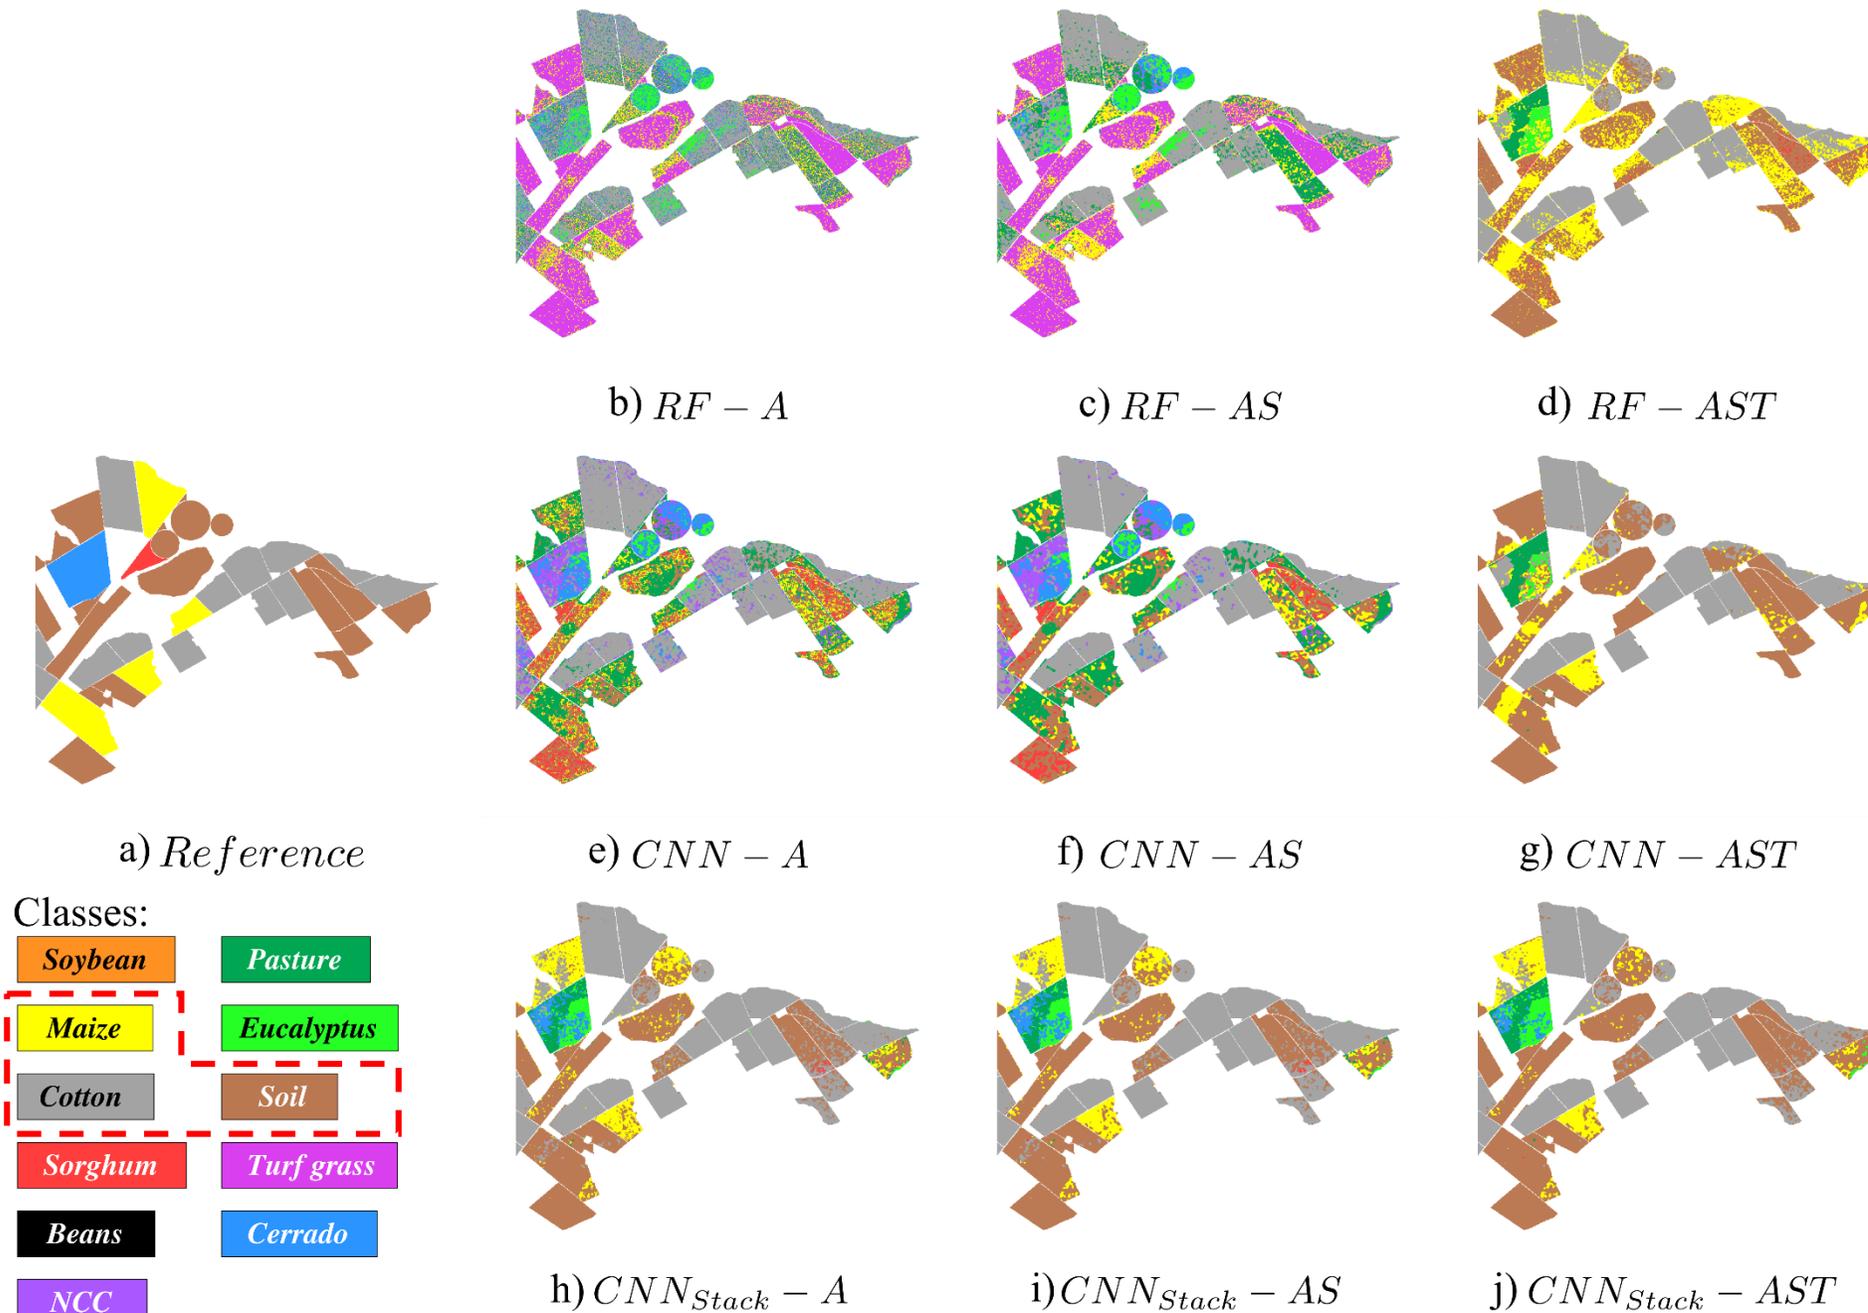
Resultados 1 sensor

Classification Maps

Sequence length: 14

Date: July 31st

Sensor: SAR



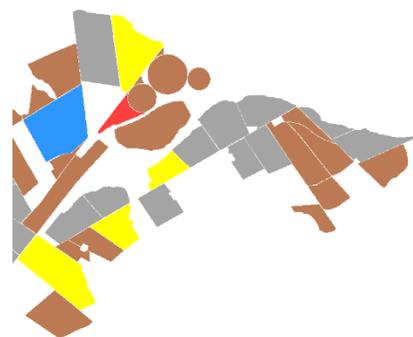
Resultados 1 sensor

Classification Maps

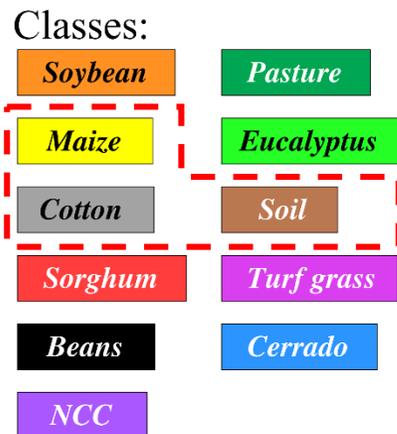
Sequence length: 14

Date: July 31st

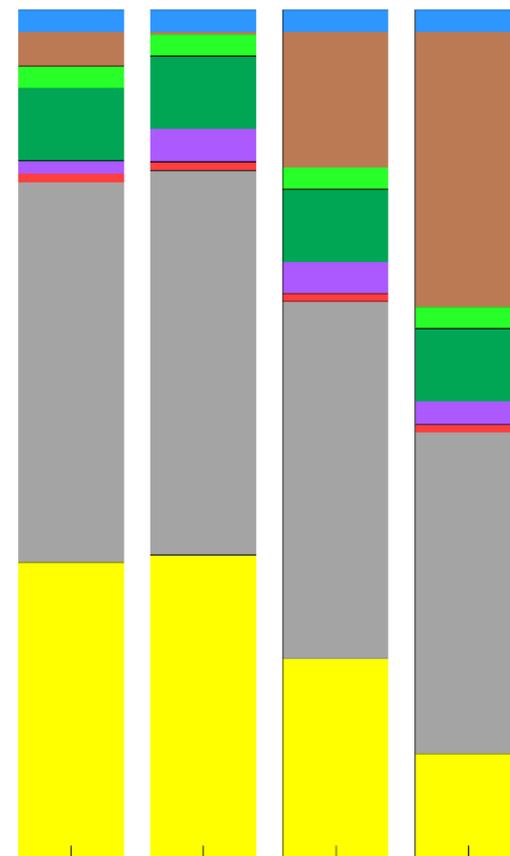
Sensor: SAR



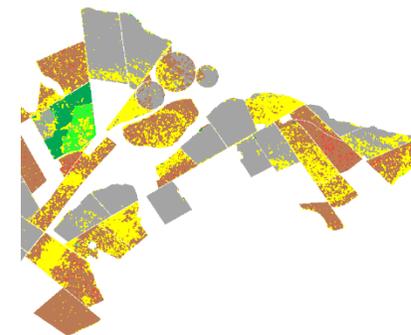
a) Reference



e)



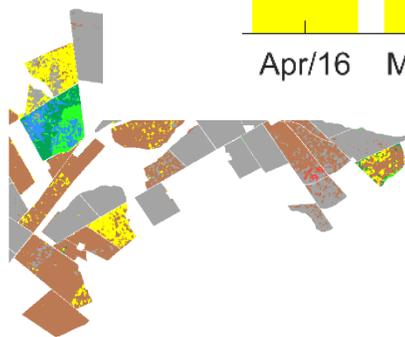
Apr/16 May/16 Jun/16 Jul/16



d) RF – AST



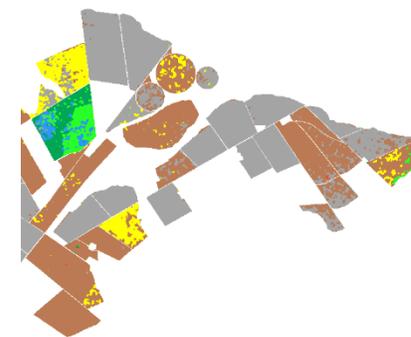
g) CNN – AST



h) $CNN_{Stack} - A$



i) $CNN_{Stack} - AS$



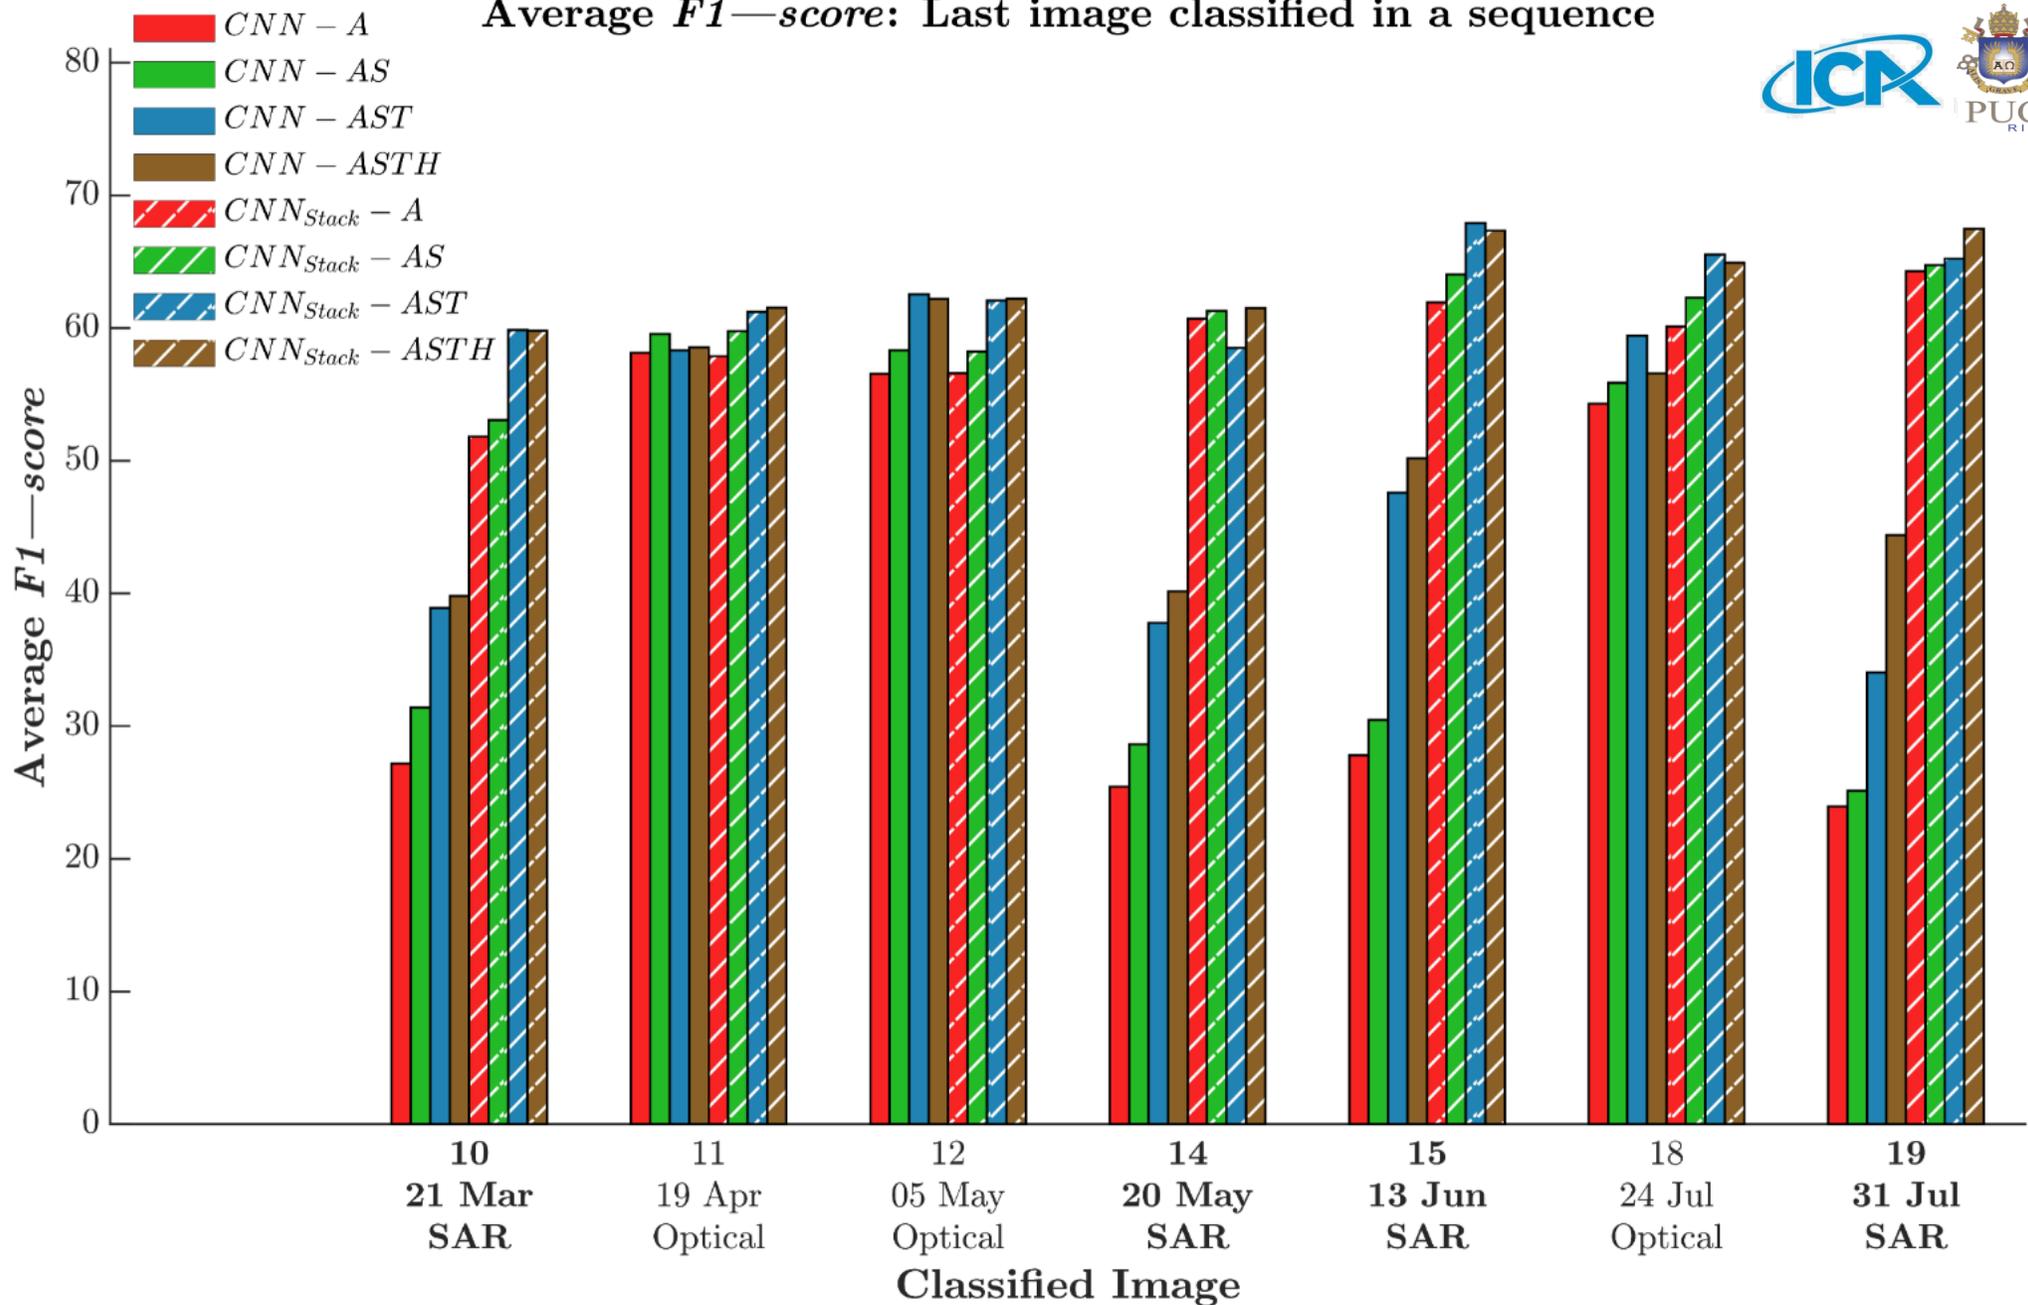
j) $CNN_{Stack} - AST$

Resultados Múltiples sensores



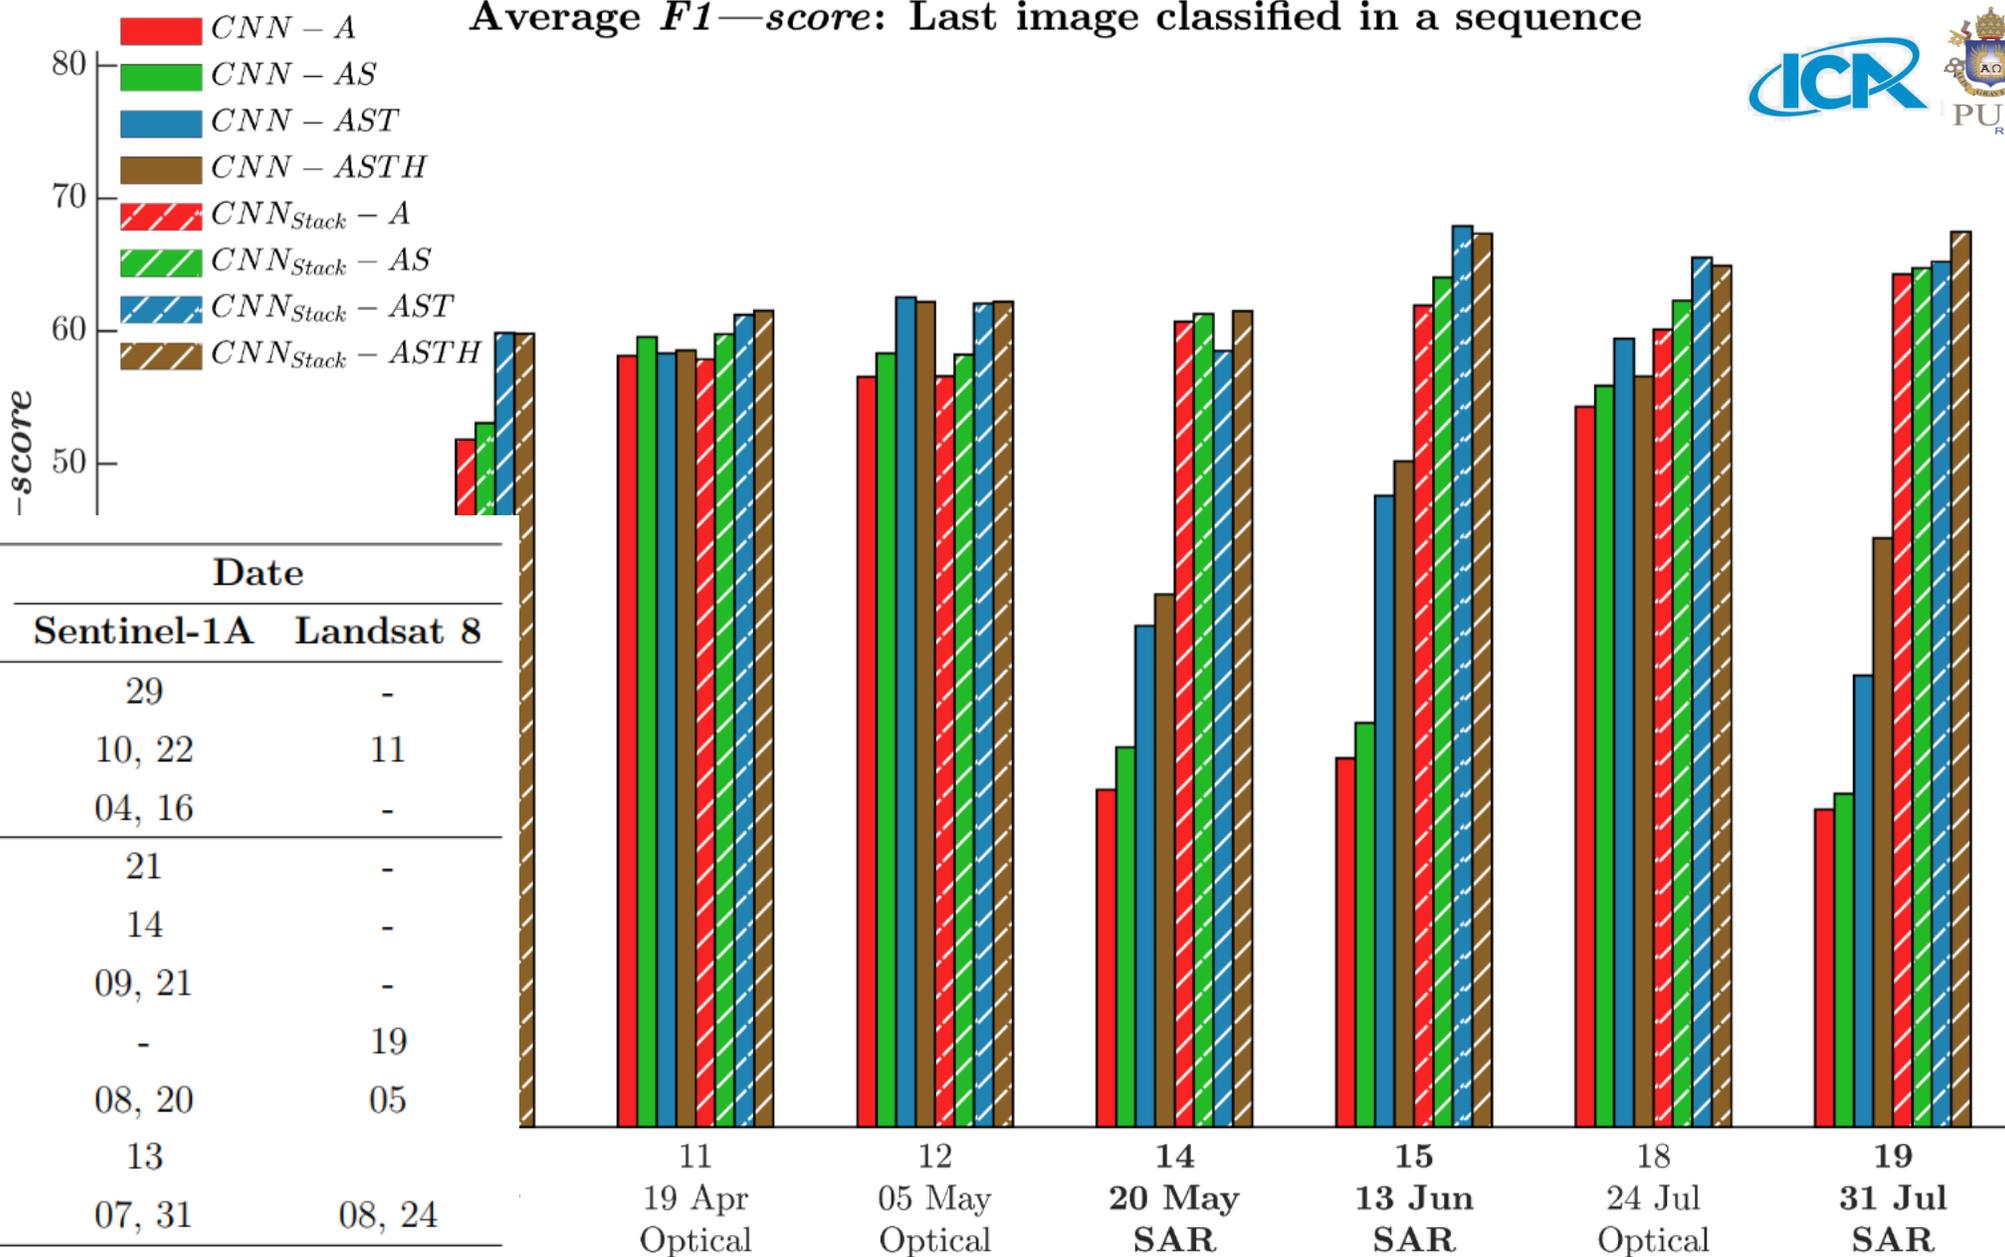
Resultados Múltiples sensores

Average $F1$ —score: Last image classified in a sequence

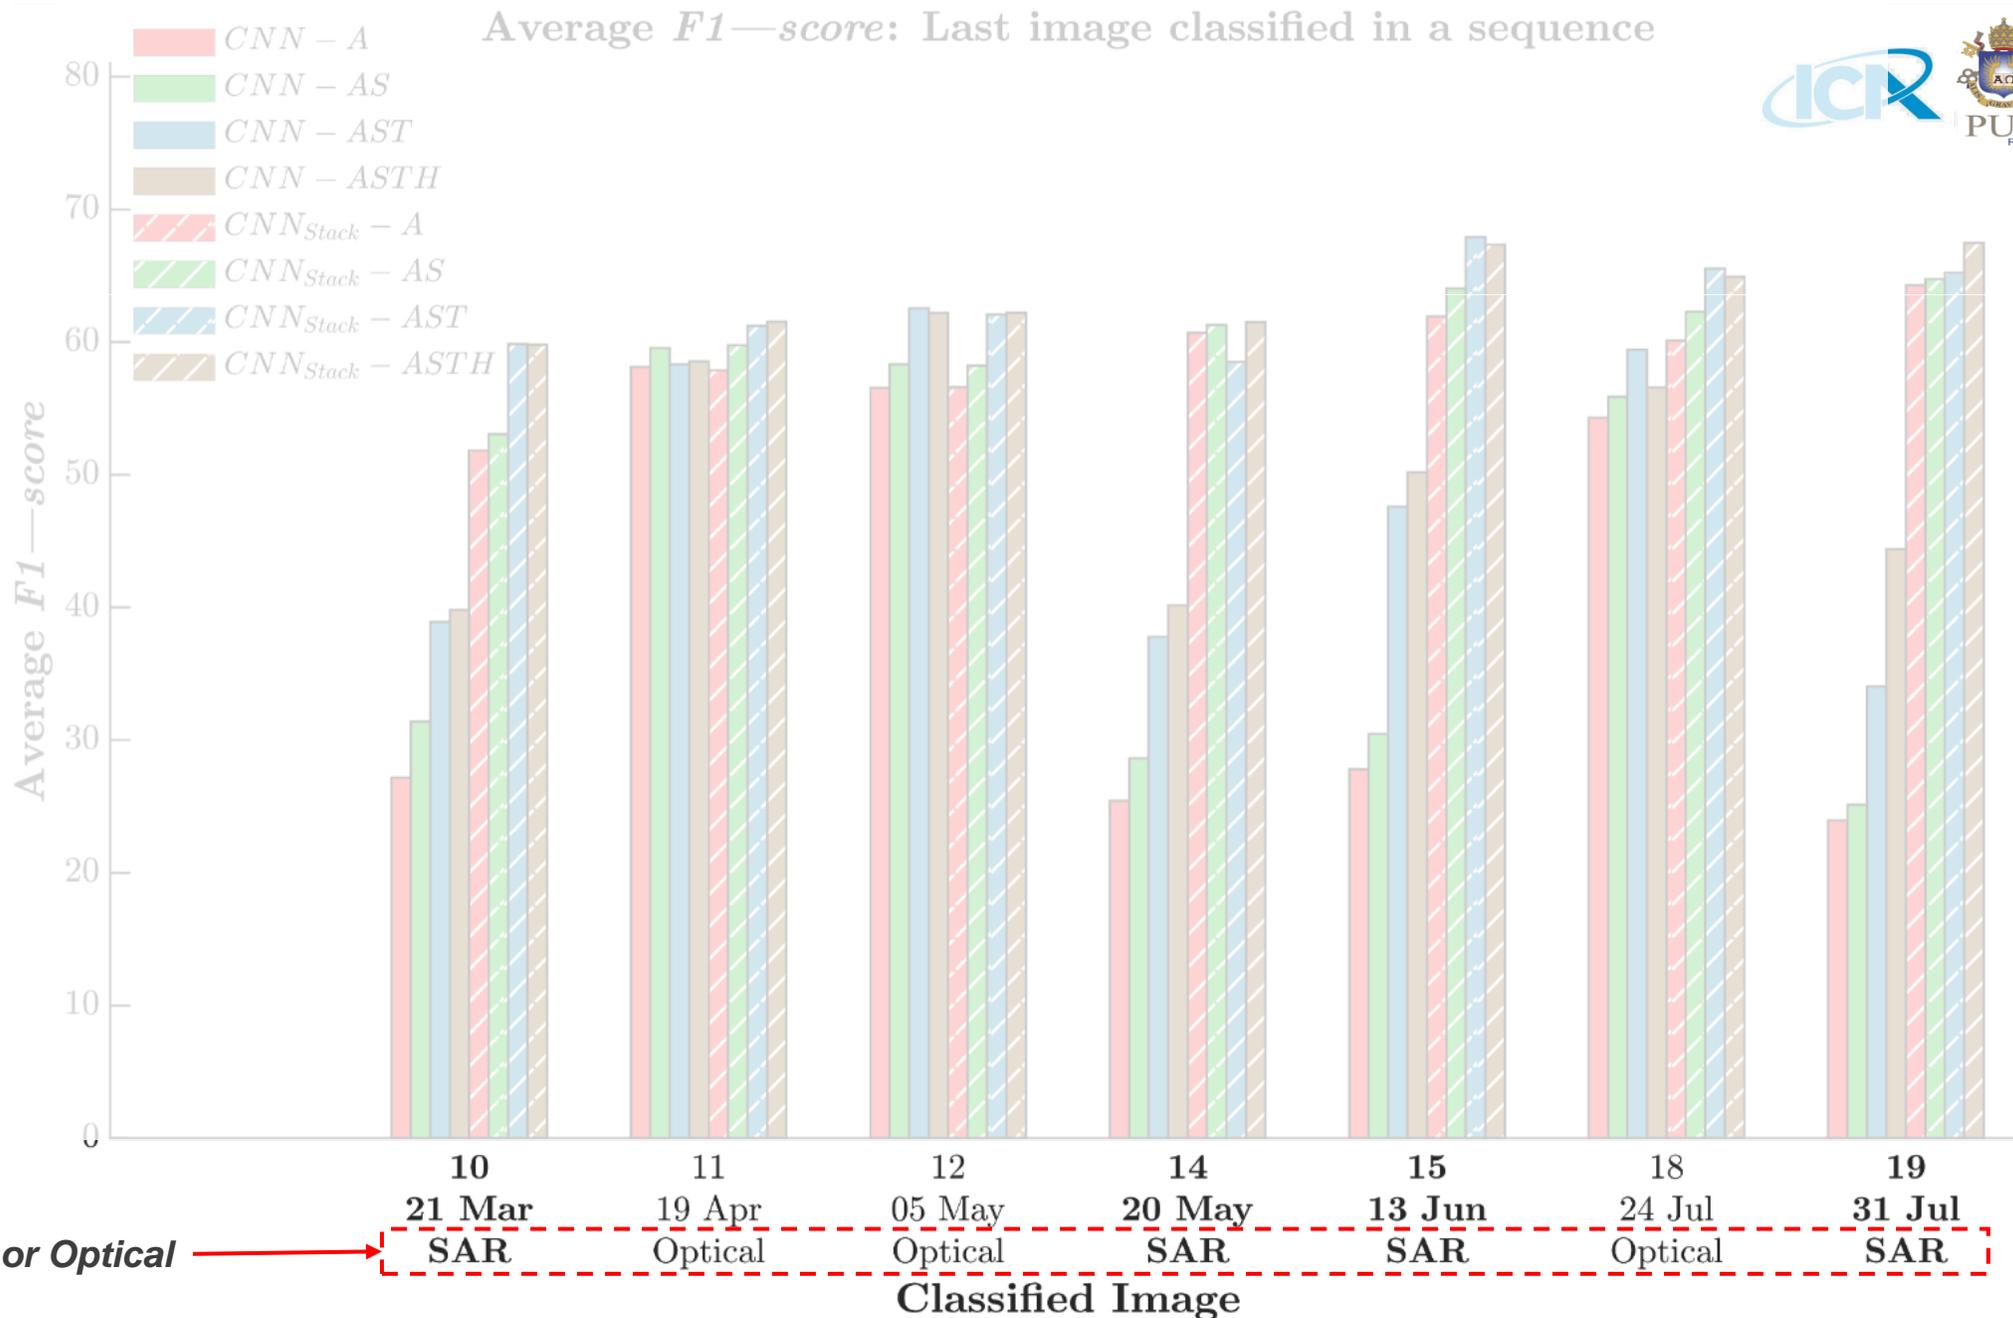


Resultados Múltiples sensores

Average $F1$ -score: Last image classified in a sequence

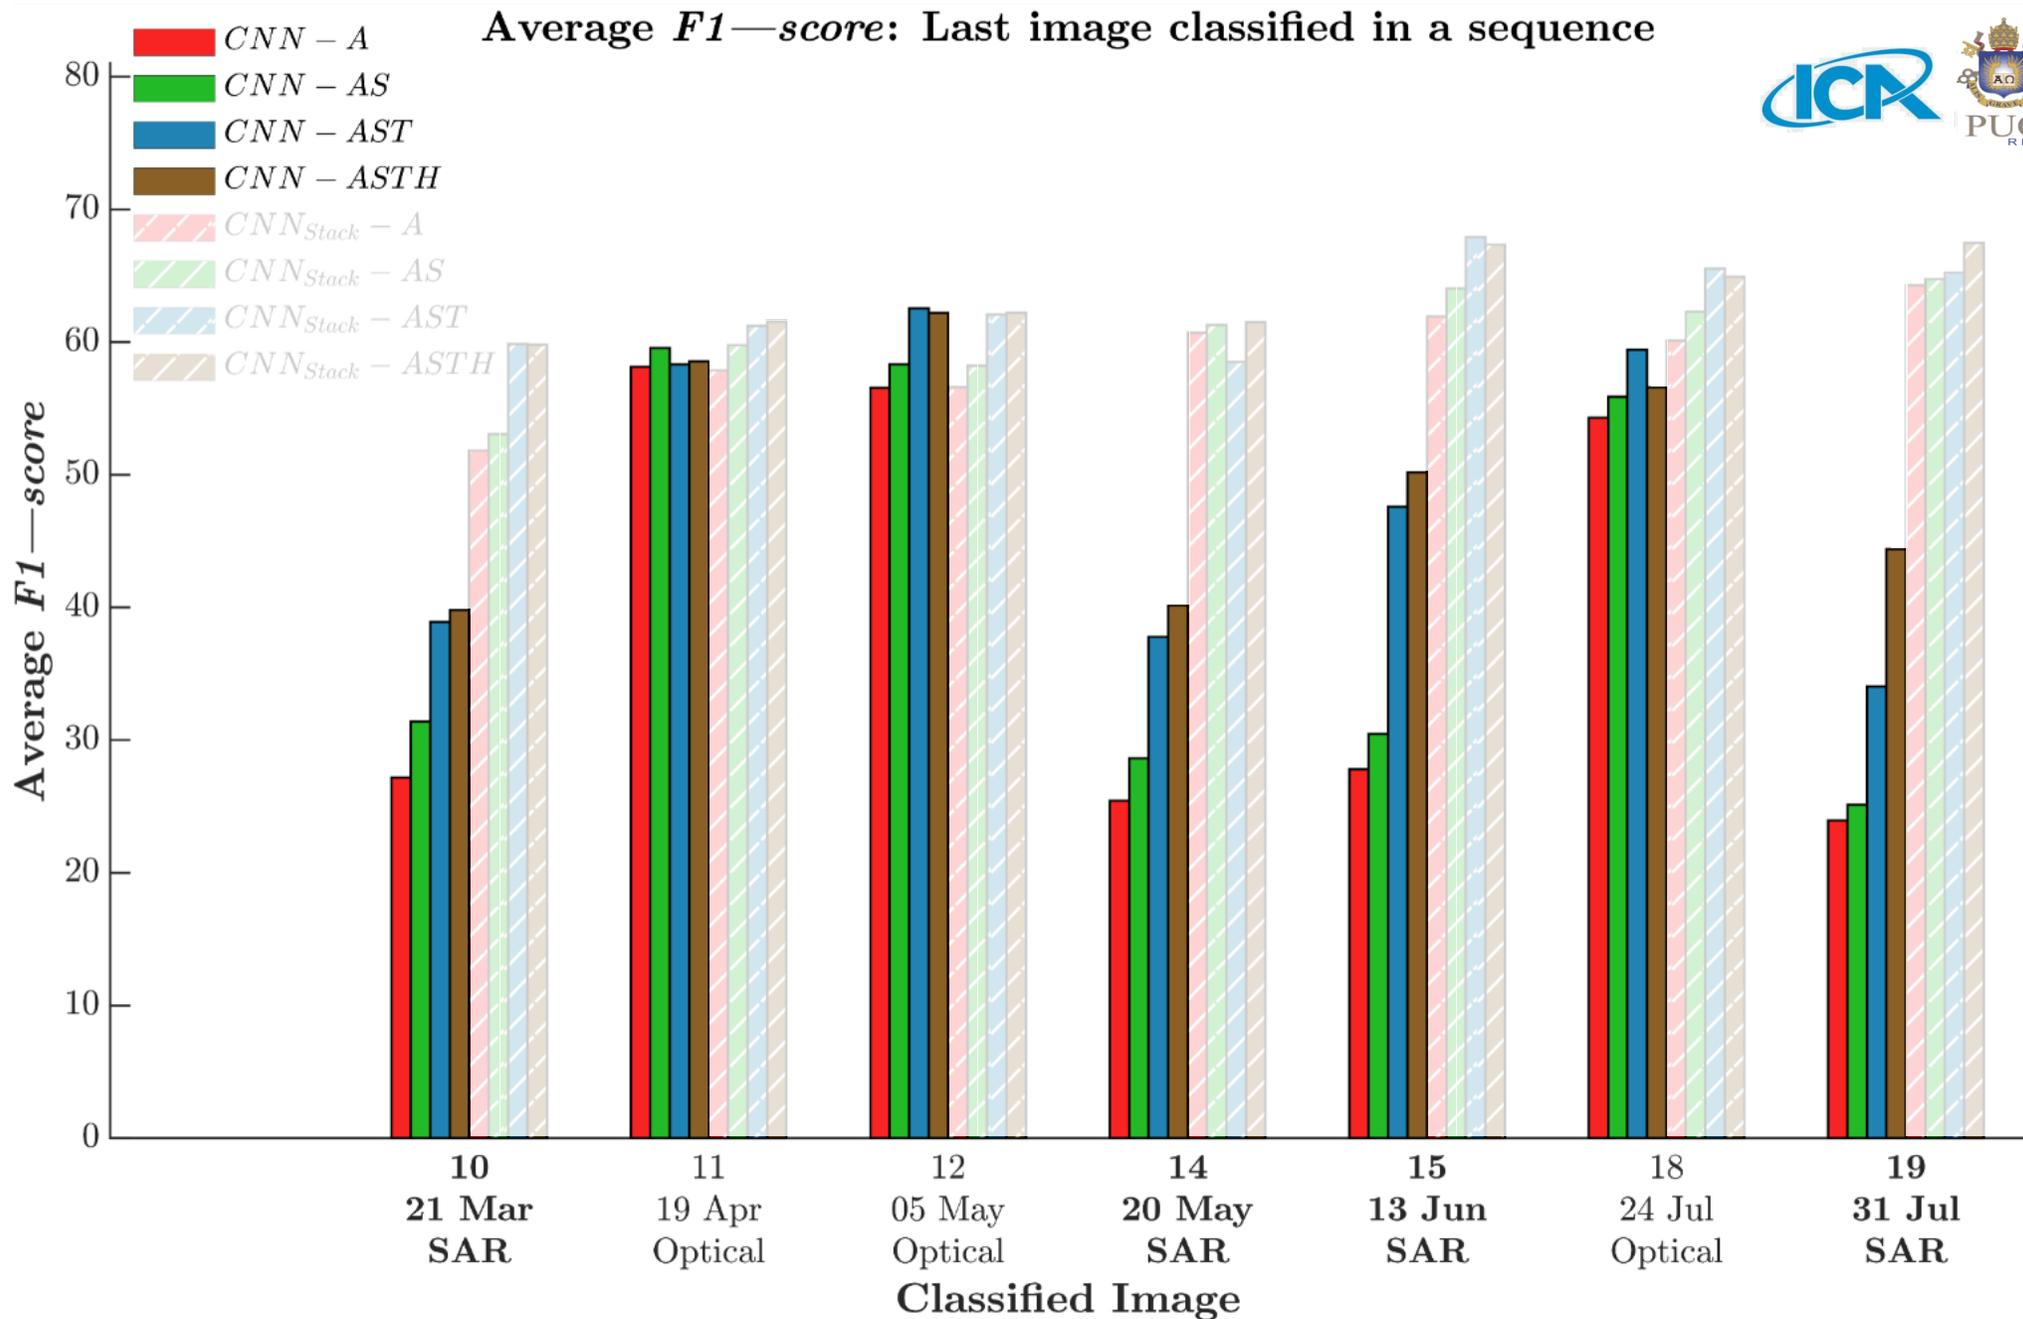


Resultados Múltiples sensores



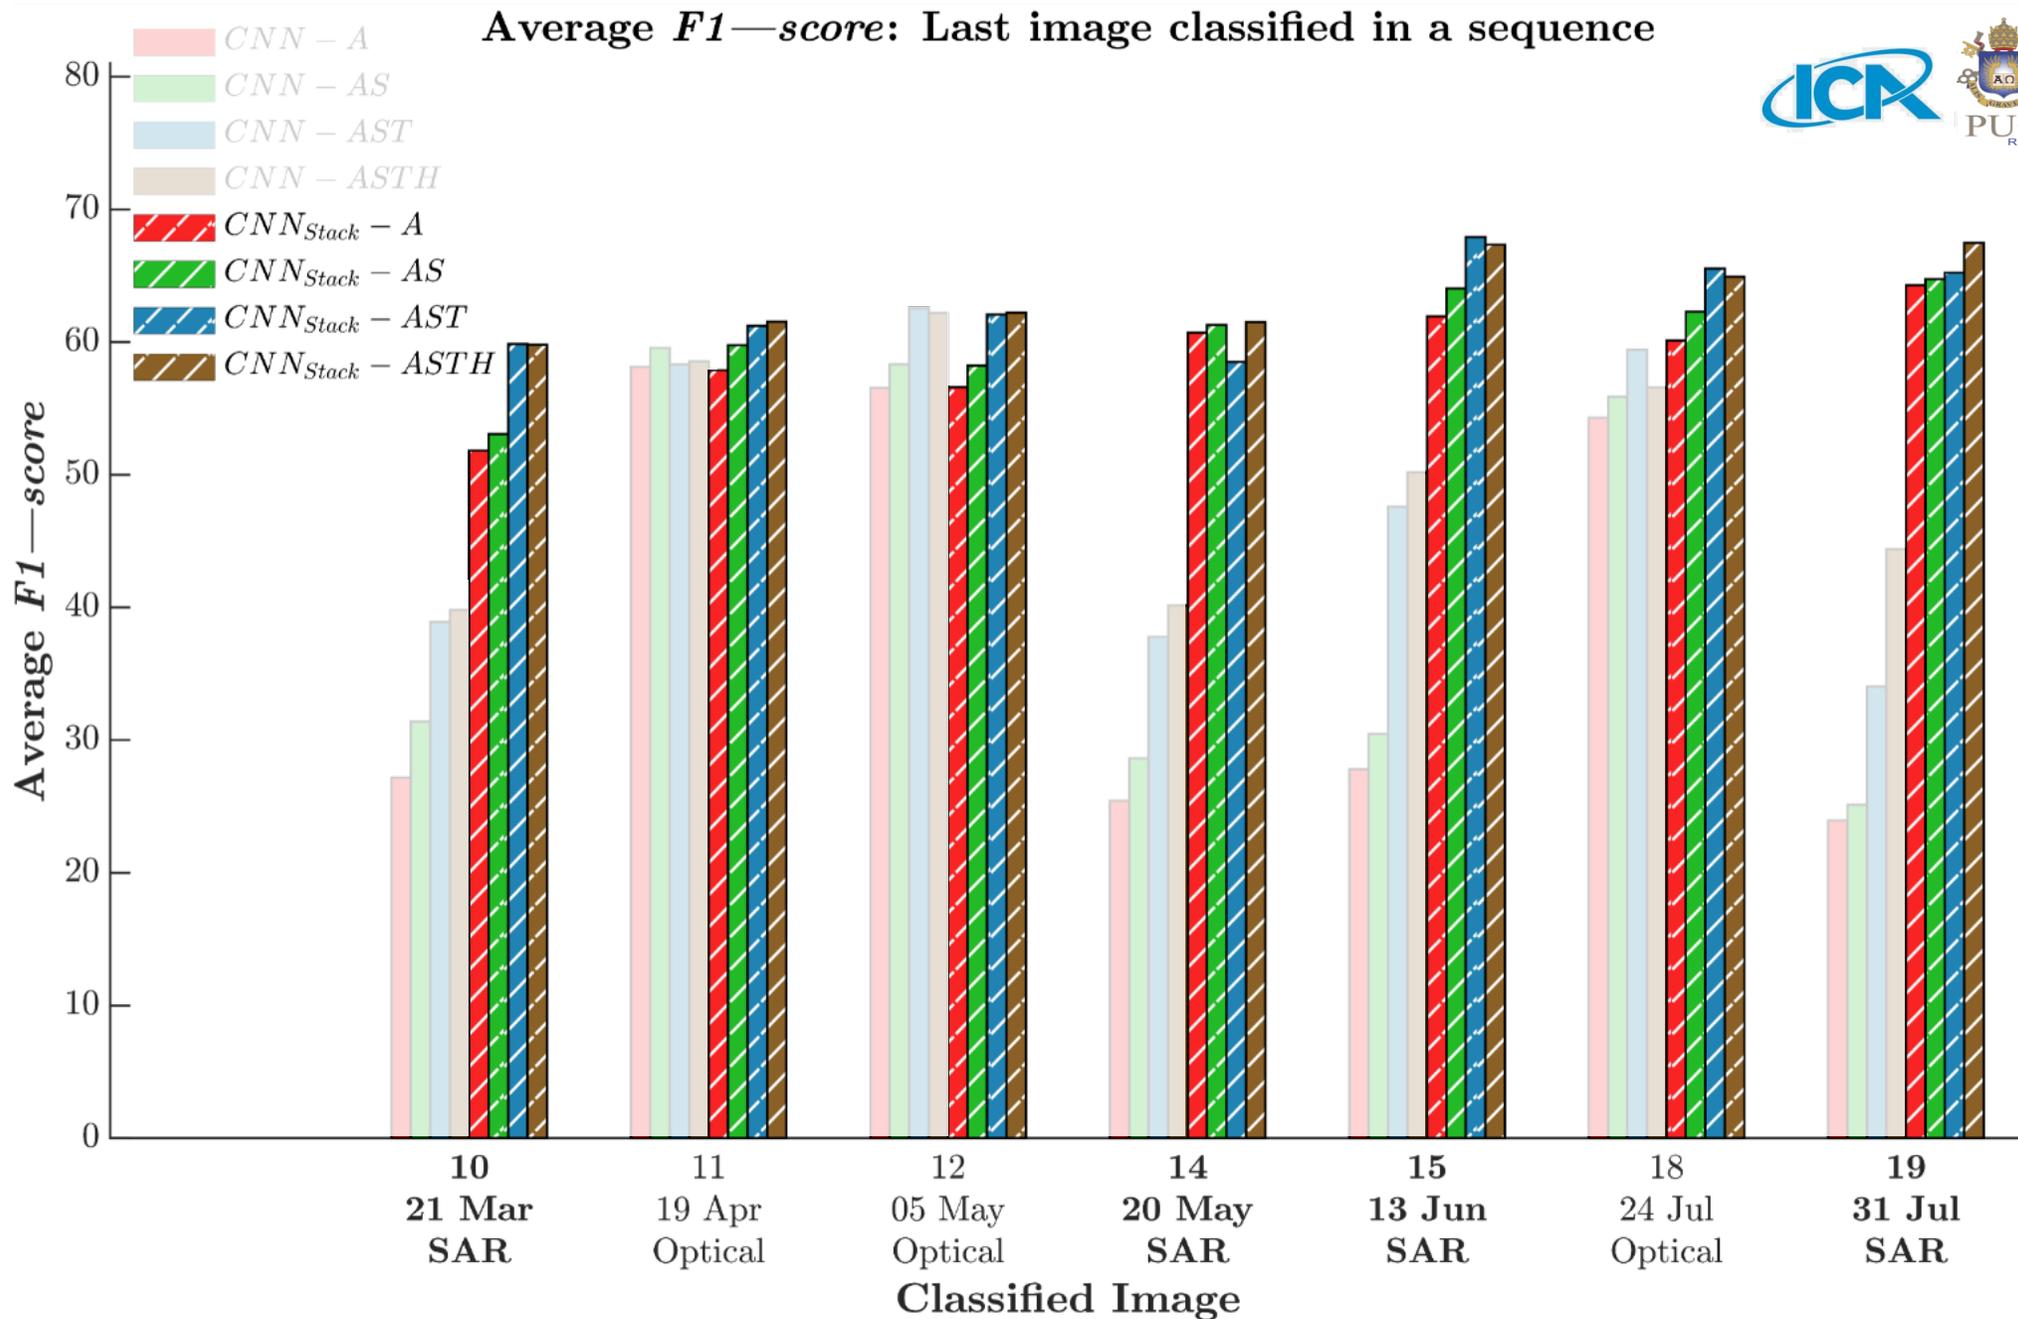
Resultados Múltiples sensores

CNN single image



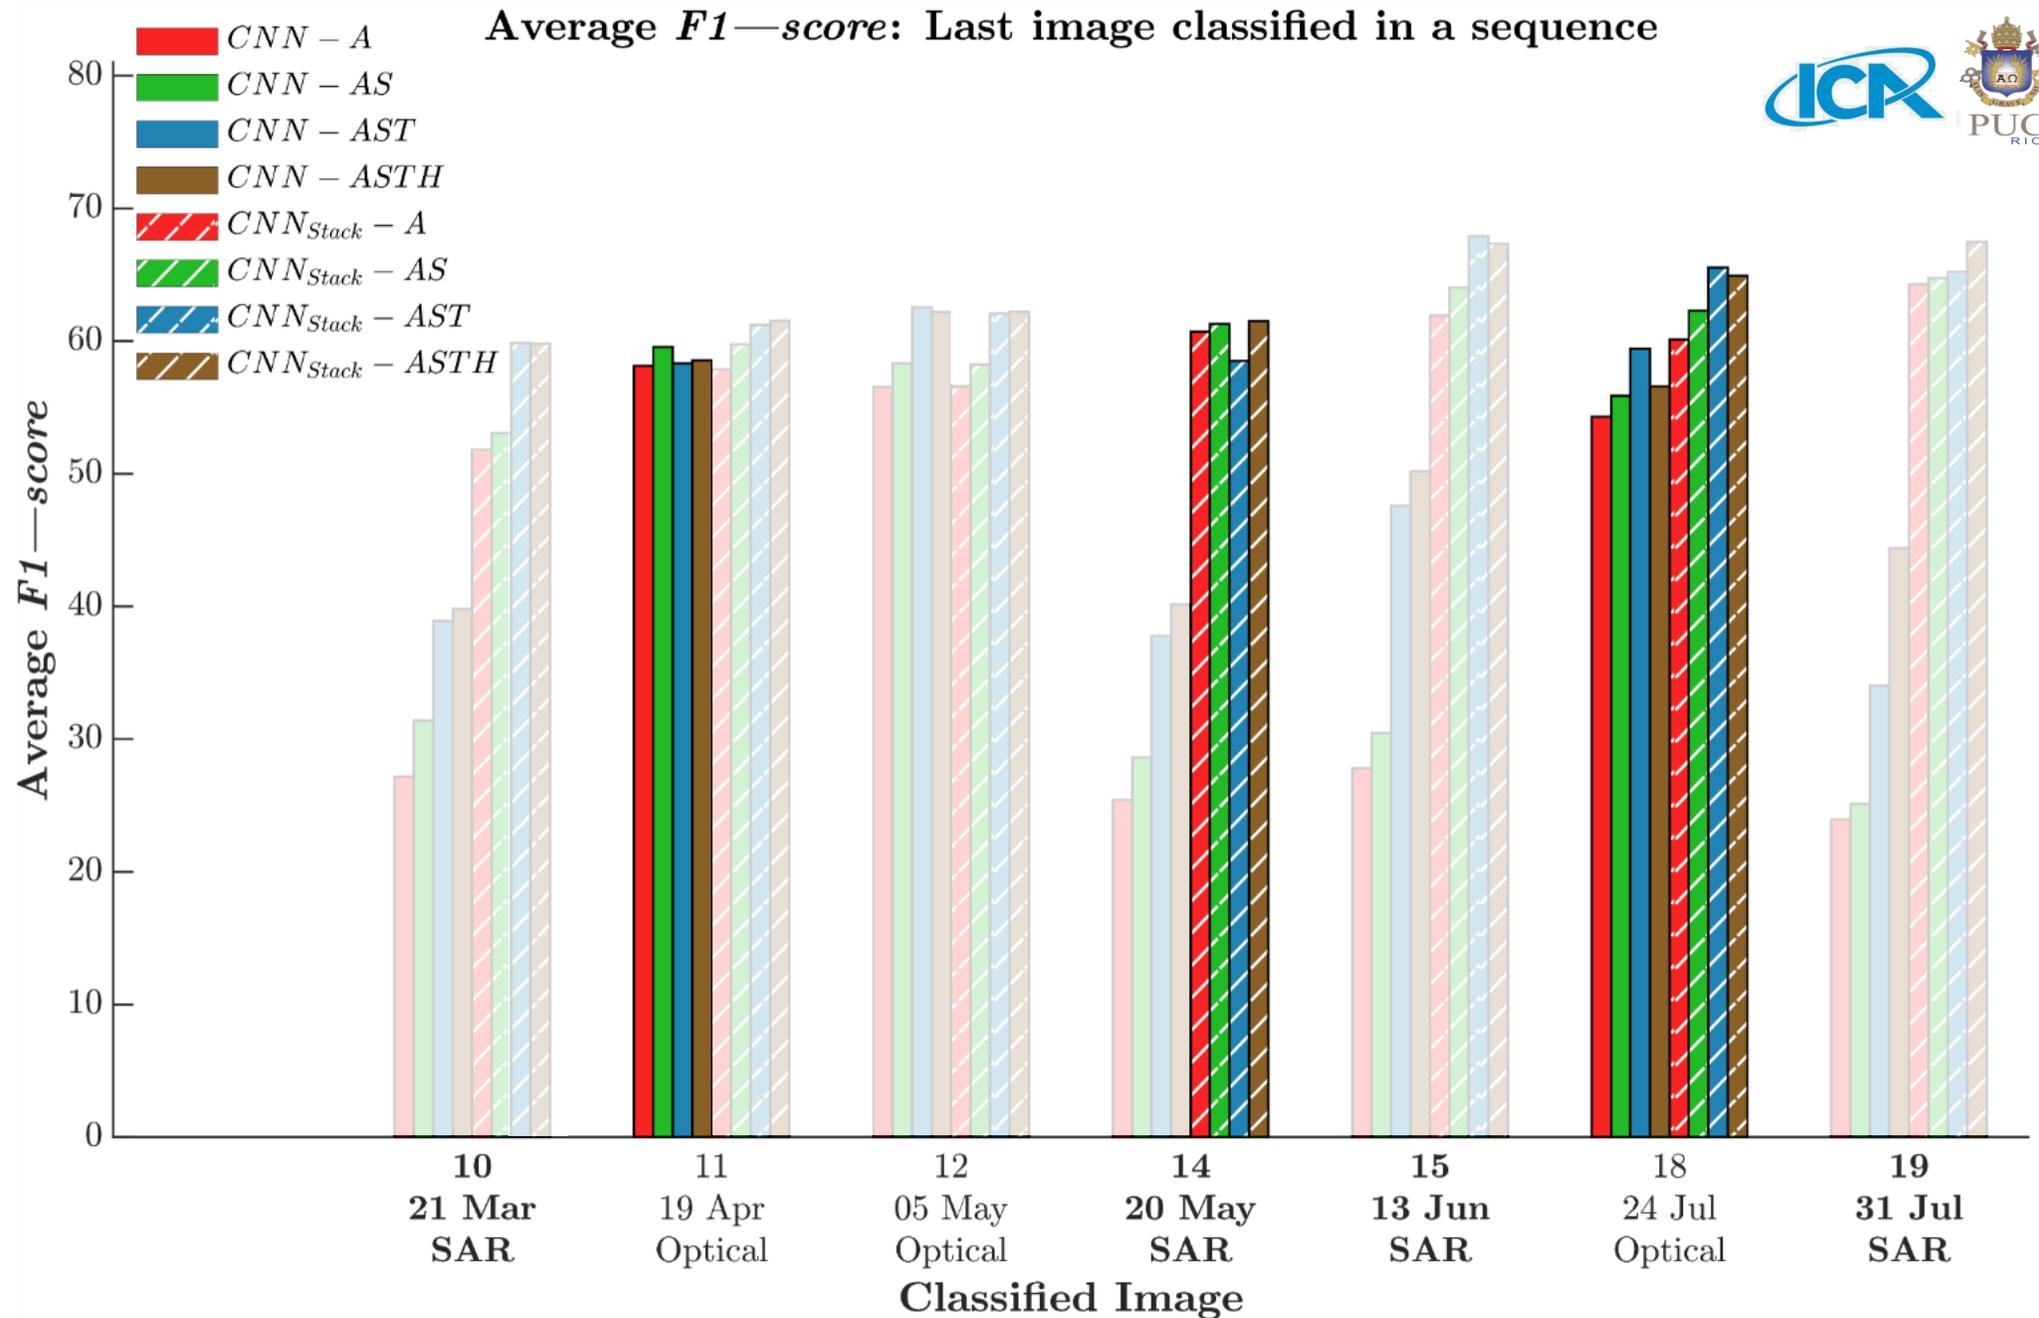
Resultados Múltiples sensores

CNN image stack



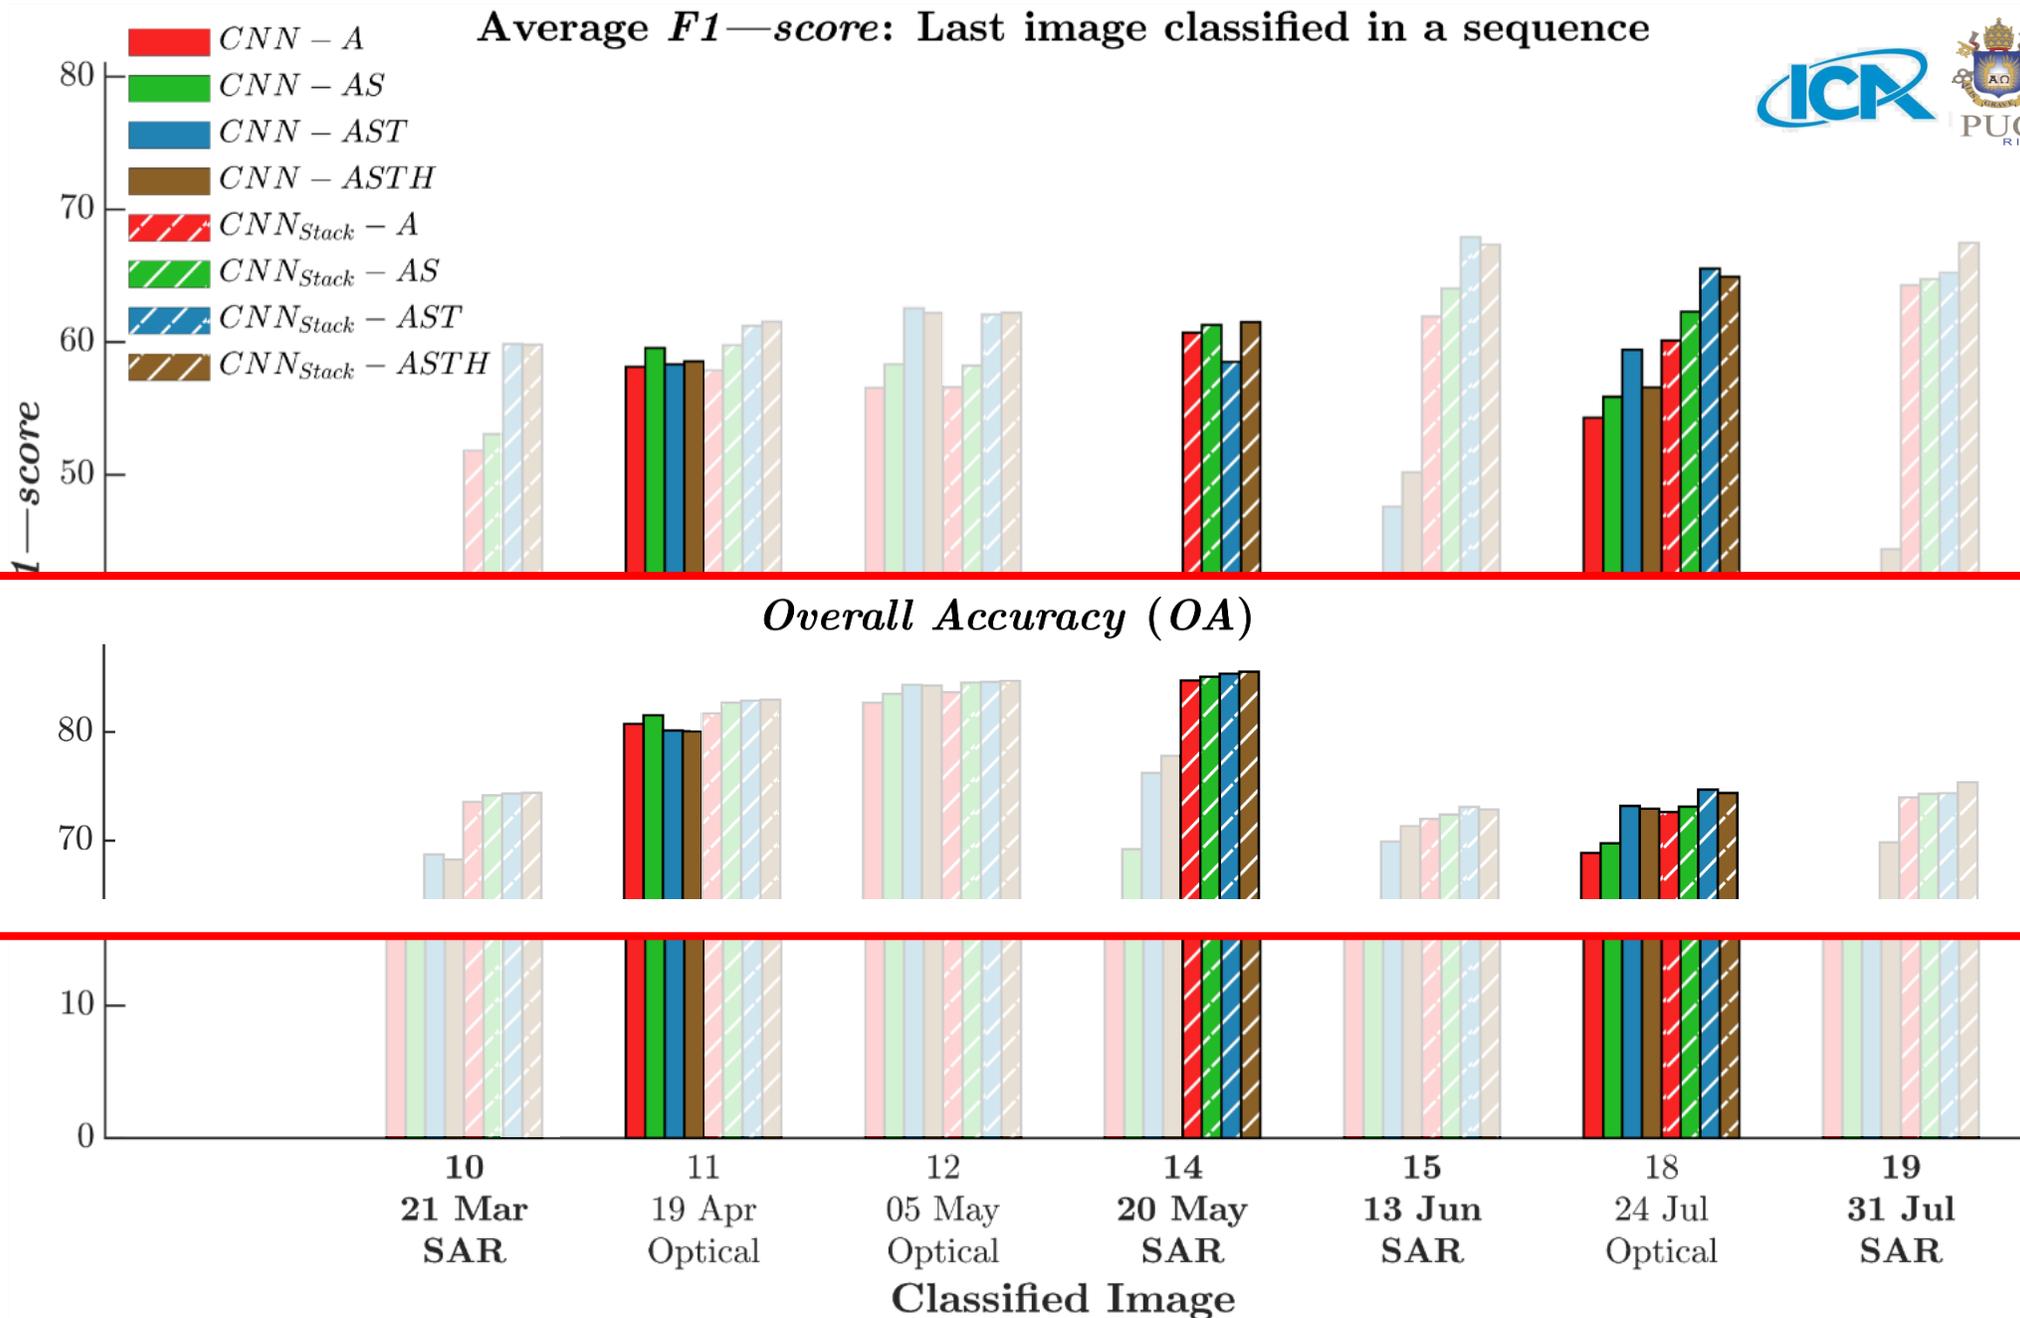
Resultados Múltiples sensores

Epochs 11, 14 and 18



Resultados Múltiples sensores

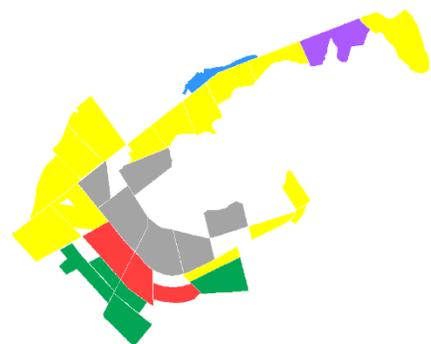
Epochs 11, 14 and 18



Resultados Múltiples sensores

Classification Maps

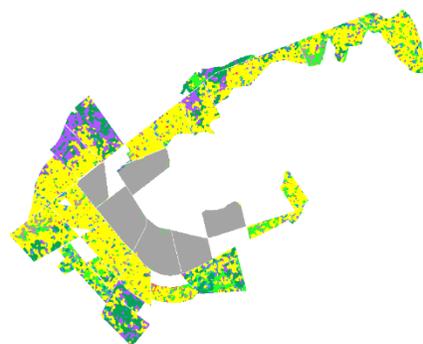
Sequence length: 14
Date: May 20th
Sensor: SAR



a) *Reference*



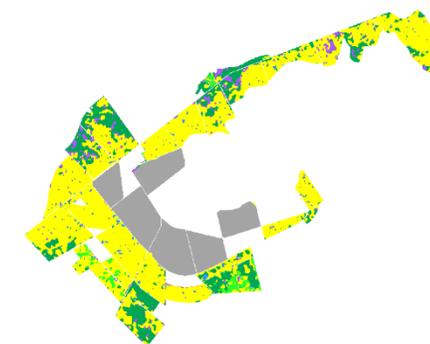
b) *CNN - A*



d) *CNN - AS*



f) *CNN - AST*



h) *CNN - ASTH*

Classes:

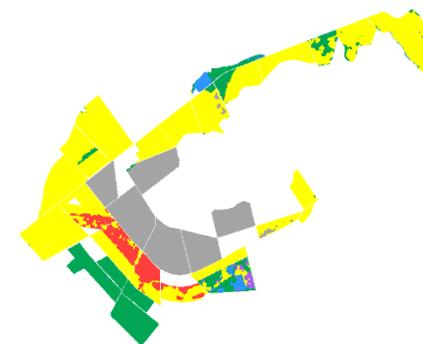
Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



c) *CNN_{Stack} - A*



e) *CNN_{Stack} - AS*



g) *CNN_{Stack} - AST*



i) *CNN_{Stack} - ASTH*

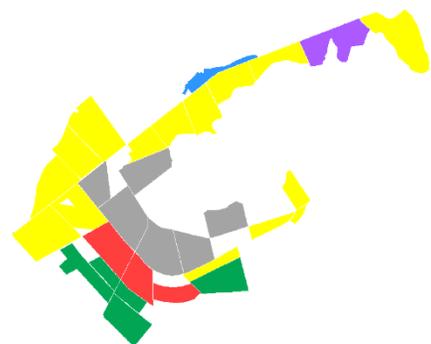
Resultados Múltiples sensores

Classification Maps

Sequence length: 14

Date: May 20th

Sensor: SAR



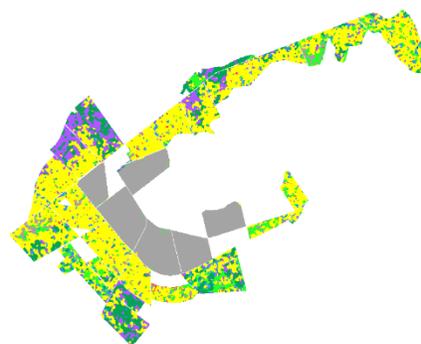
a) *Reference*

Classes:

Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



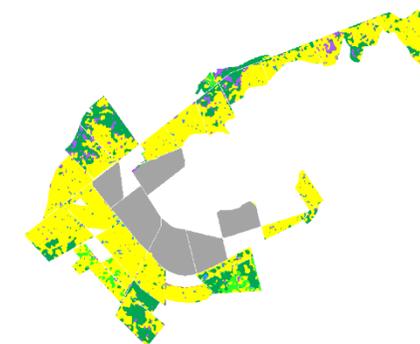
b) *CNN - A*



d) *CNN - AS*



f) *CNN - AST*



h) *CNN - ASTH*



c) *CNN_{Stack} - A*



e) *CNN_{Stack} - AS*



g) *CNN_{Stack} - AST*



i) *CNN_{Stack} - ASTH*

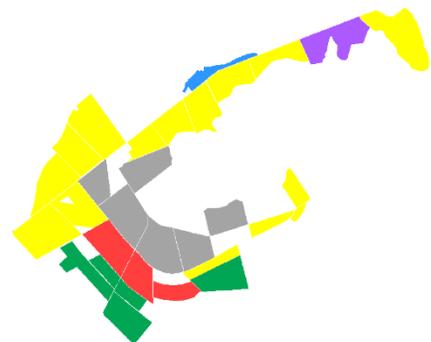
Resultados Múltiples sensores

Classification Maps

Sequence length: 14

Date: May 20th

Sensor: SAR



a) *Reference*

Classes:

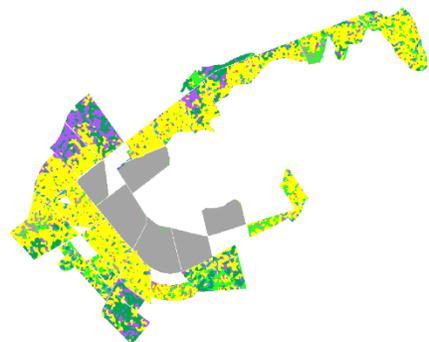
Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



b) *CNN - A*



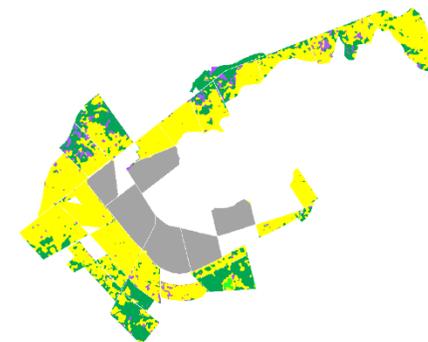
c) *CNN_{Stack} - A*



d) *CNN - AS*



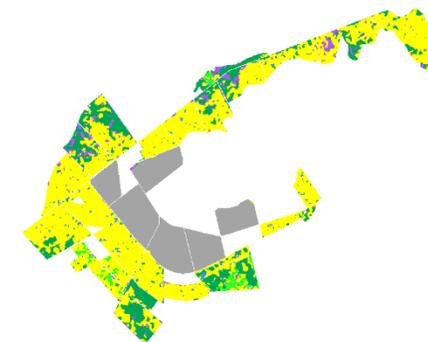
e) *CNN_{Stack} - AS*



f) *CNN - AST*



g) *CNN_{Stack} - AST*



h) *CNN - ASTH*

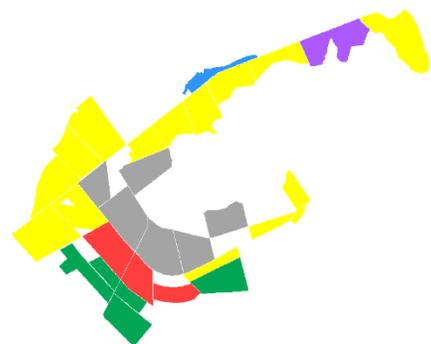


i) *CNN_{Stack} - ASTH*

Resultados Múltiples sensores

Classification Maps

Sequence length: 14
Date: May 20th
Sensor: SAR



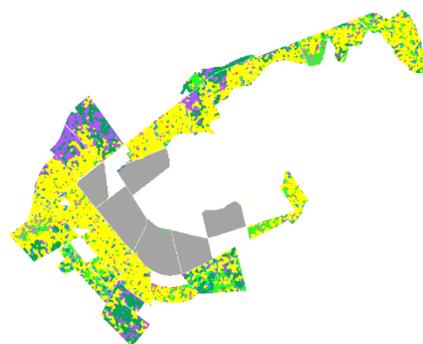
a) Reference

Classes:

Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



b) $CNN - A$



d) $CNN - AS$



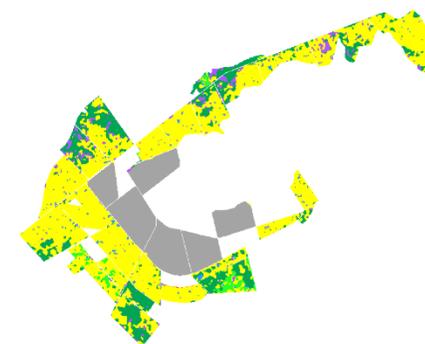
c) $CNN_{Stack} - A$



e) $CNN_{Stack} - AS$



f) $CNN - AST$



h) $CNN - ASTH$



g) $CNN_{Stack} - AST$



i) $CNN_{Stack} - ASTH$

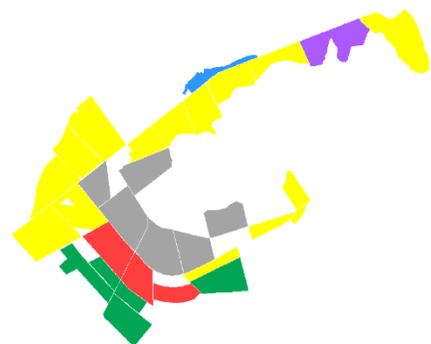
Resultados Múltiples sensores

Classification Maps

Sequence length: 14

Date: May 20th

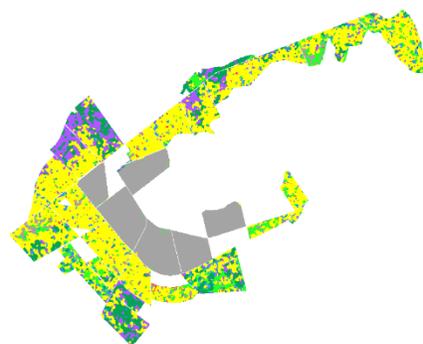
Sensor: SAR



a) Reference



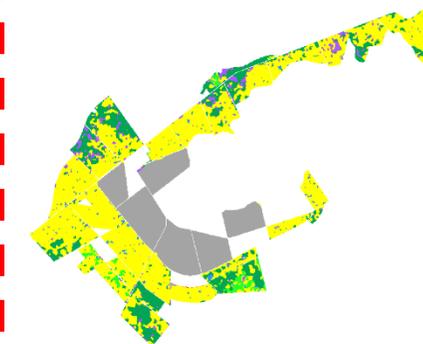
b) $CNN - A$



d) $CNN - AS$



f) $CNN - AST$



h) $CNN - ASTH$

Classes:

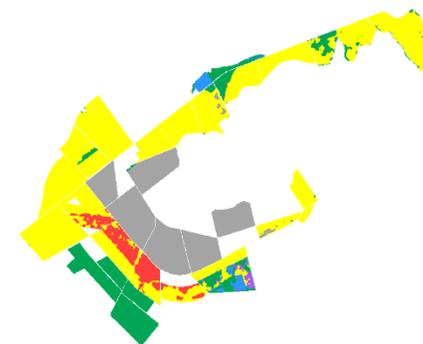
Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



c) $CNN_{Stack} - A$



e) $CNN_{Stack} - AS$



g) $CNN_{Stack} - AST$

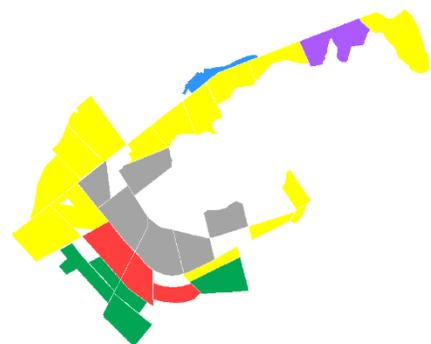


i) $CNN_{Stack} - ASTH$

Resultados Múltiples sensores

Classification Maps

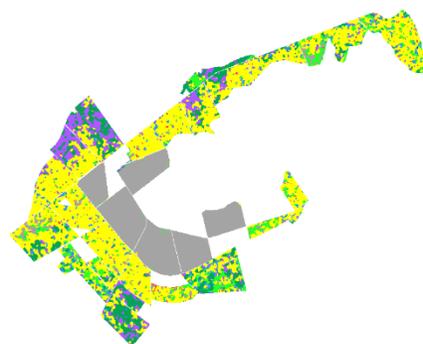
Sequence length: 14
Date: May 20th
Sensor: SAR



a) Reference



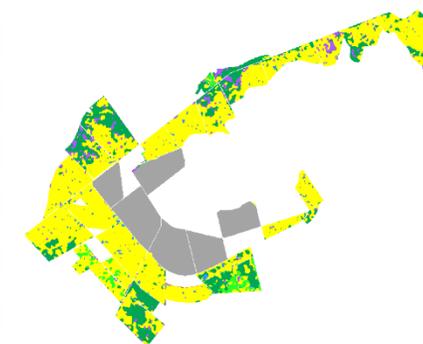
b) $CNN - A$



d) $CNN - AS$



f) $CNN - AST$



h) $CNN - ASTH$

Classes:

Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



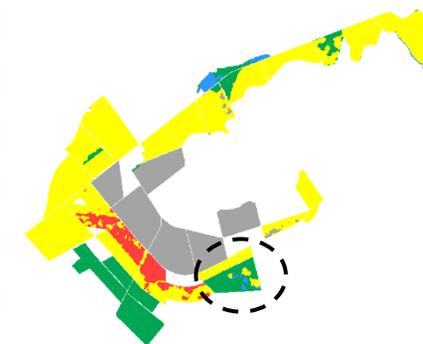
c) $CNN_{Stack} - A$



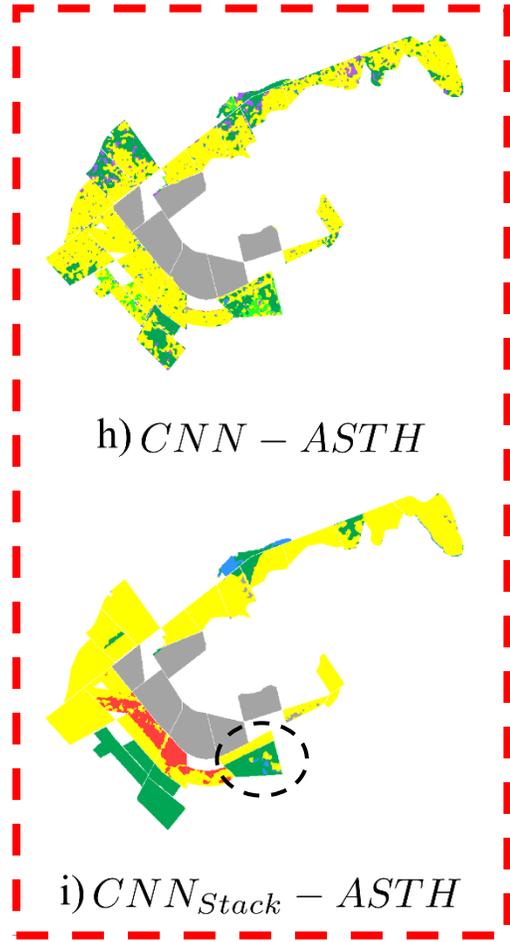
e) $CNN_{Stack} - AS$



g) $CNN_{Stack} - AST$



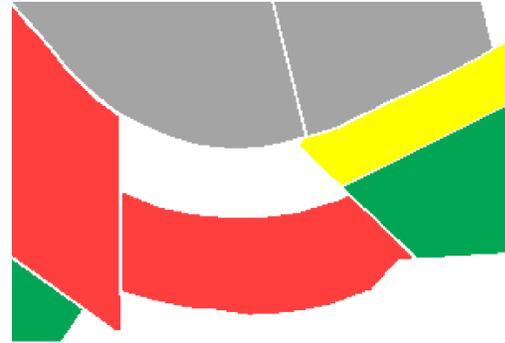
i) $CNN_{Stack} - ASTH$



Resultados Múltiples sensores

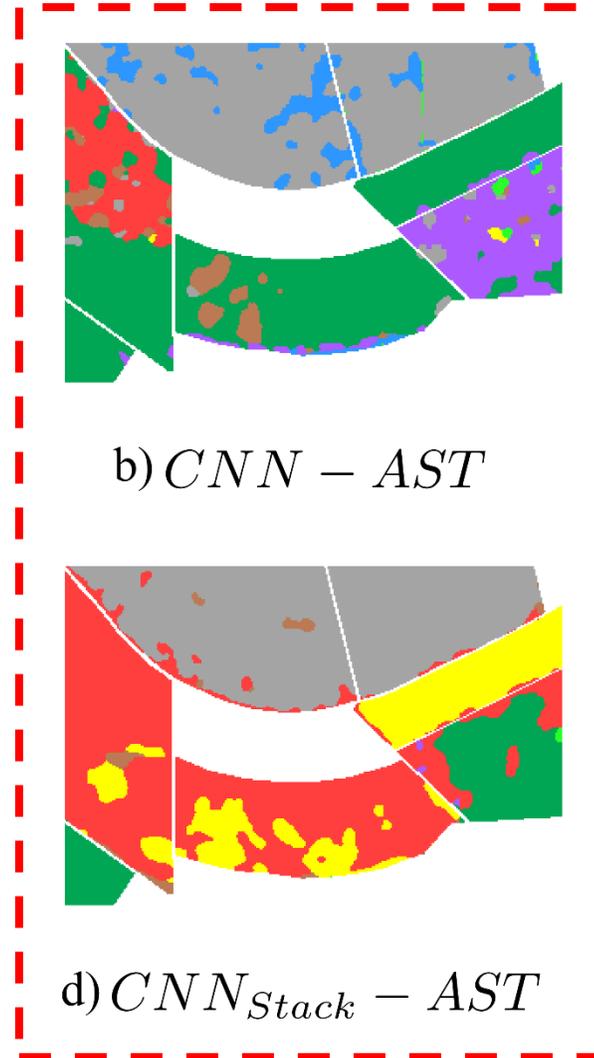
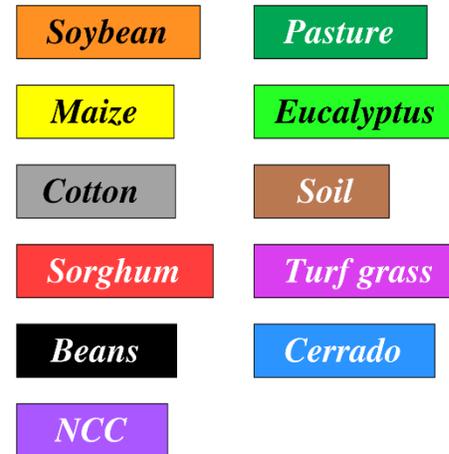
Classification Maps

Sequence length: 19
Date: July 31st
Sensor: SAR



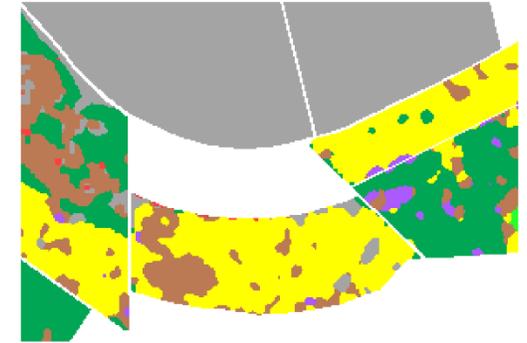
a) *Reference*

Classes:

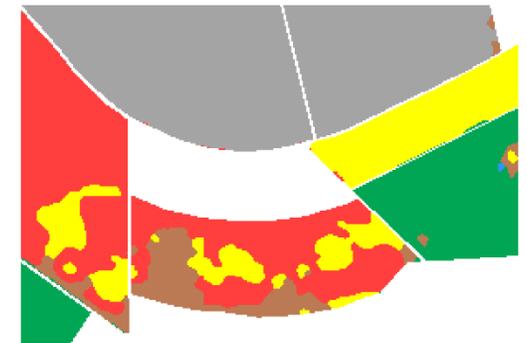


b) *CNN – AST*

d) *CNN_{Stack} – AST*



c) *CNN – ASTH*

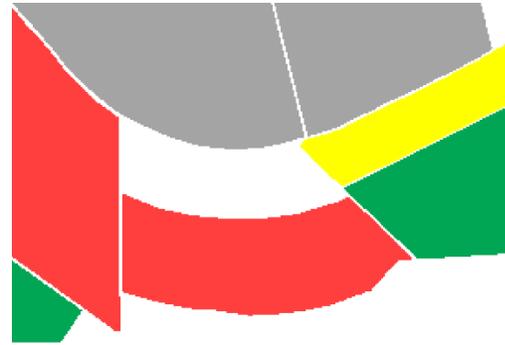


e) *CNN_{Stack} – ASTH*

Resultados Múltiples sensores

Classification Maps

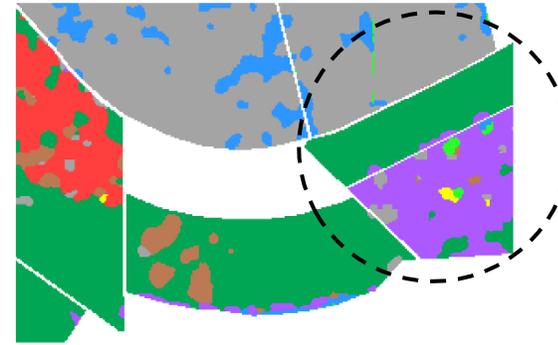
Sequence length: 19
Date: July 31st
Sensor: SAR



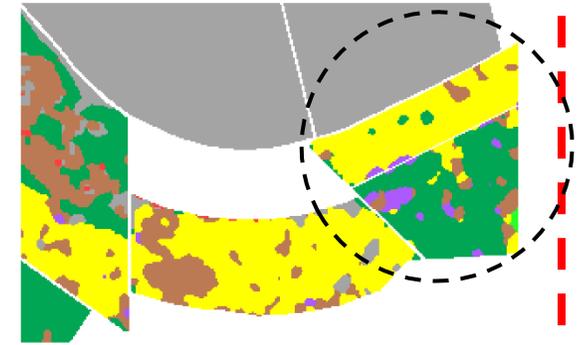
a) *Reference*

Classes:

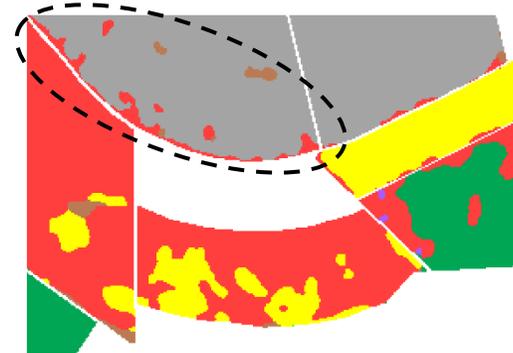
Soybean	Pasture
Maize	Eucalyptus
Cotton	Soil
Sorghum	Turf grass
Beans	Cerrado
NCC	



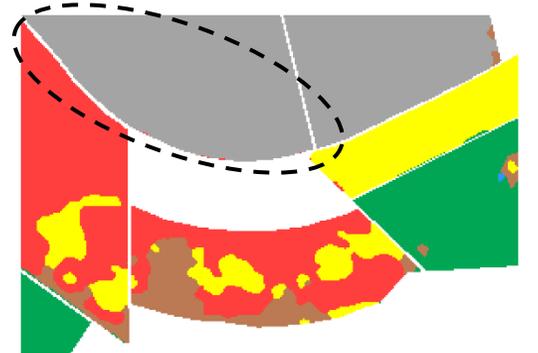
b) *CNN – AST*



c) *CNN – ASTH*



d) *CNN_{Stack} – AST*



e) *CNN_{Stack} – ASTH*

Outline



1. Introducción

2. CRFs

3. Resultados

4. Conclusiones

Conclusiones

- Campo Verde: **85% Overall Accuracy** y **68% average F1-score**.
- Variantes basadas en CNN (**single image** y **image stack**) obtuvieron mejores resultados que sus correspondientes usando **Random Forest** y **atributos de textura (GLCM)**.
- Cada **potencial** del CRF adicionó mayor información de contexto: **espacial** y **temporal**, mejorando la clasificación
- La adición de conexiones de mayor orden ayudó a corregir algunas parcelas que fueron erróneamente clasificadas.

Conclusiones

- Campo Verde: **85% Overall Accuracy** y **68% average F1-score**.
- Variantes basadas en CNN (**single image** y **image stack**) obtuvieron mejores resultados que sus correspondientes usando **Random Forest** y **atributos de textura (GLCM)**.
- Cada **potencial** del CRF adicionó mayor información de contexto: **espacial** y **temporal**, mejorando la clasificación
- La adición de conexiones de mayor orden ayudó a corregir algunas parcelas que fueron erróneamente clasificadas.

Conclusiones

- Campo Verde: **85% Overall Accuracy** y **68% average F1-score**.
- Variantes basadas en CNN (**single image** y **image stack**) obtuvieron mejores resultados que sus correspondientes usando **Random Forest** y **atributos de textura (GLCM)**.
- Cada **potencial** del CRF adicionó mayor información de contexto: **espacial y temporal**, mejorando la clasificación
- La adición de conexiones de mayor orden ayudó a corregir algunas parcelas que fueron erróneamente clasificadas.

Conclusiones

- Campo Verde: **85% Overall Accuracy** y **68% average F1-score**.
- Variantes basadas en CNN (**single image** y **image stack**) obtuvieron mejores resultados que sus correspondientes usando **Random Forest** y **atributos de textura (GLCM)**.
- Cada **potencial** del CRF adicionó mayor información de contexto: **espacial** y **temporal**, mejorando la clasificación
- La adición de conexiones de mayor orden ayudó a corregir algunas parcelas que fueron erróneamente clasificadas.



Reconocimiento de cultivos agrícolas en regiones tropicales usando secuencias de imágenes de teledetección de sensores activos y pasivos

Ph.D. Pedro M. Achancaray Diaz

pedro.diaz@puc-rio.br