



Instituto Nacional de Estadística  
Departamento de Metodologías e Innovación Estadística  
Subdepartamento de Diseño de Marcos y Muestras

# Percepción remota para la producción estadística: avances, desafíos y oportunidades desde la experiencia del LCLU

Caso de estudio en la Macrozona Maule-Ñuble, Chile

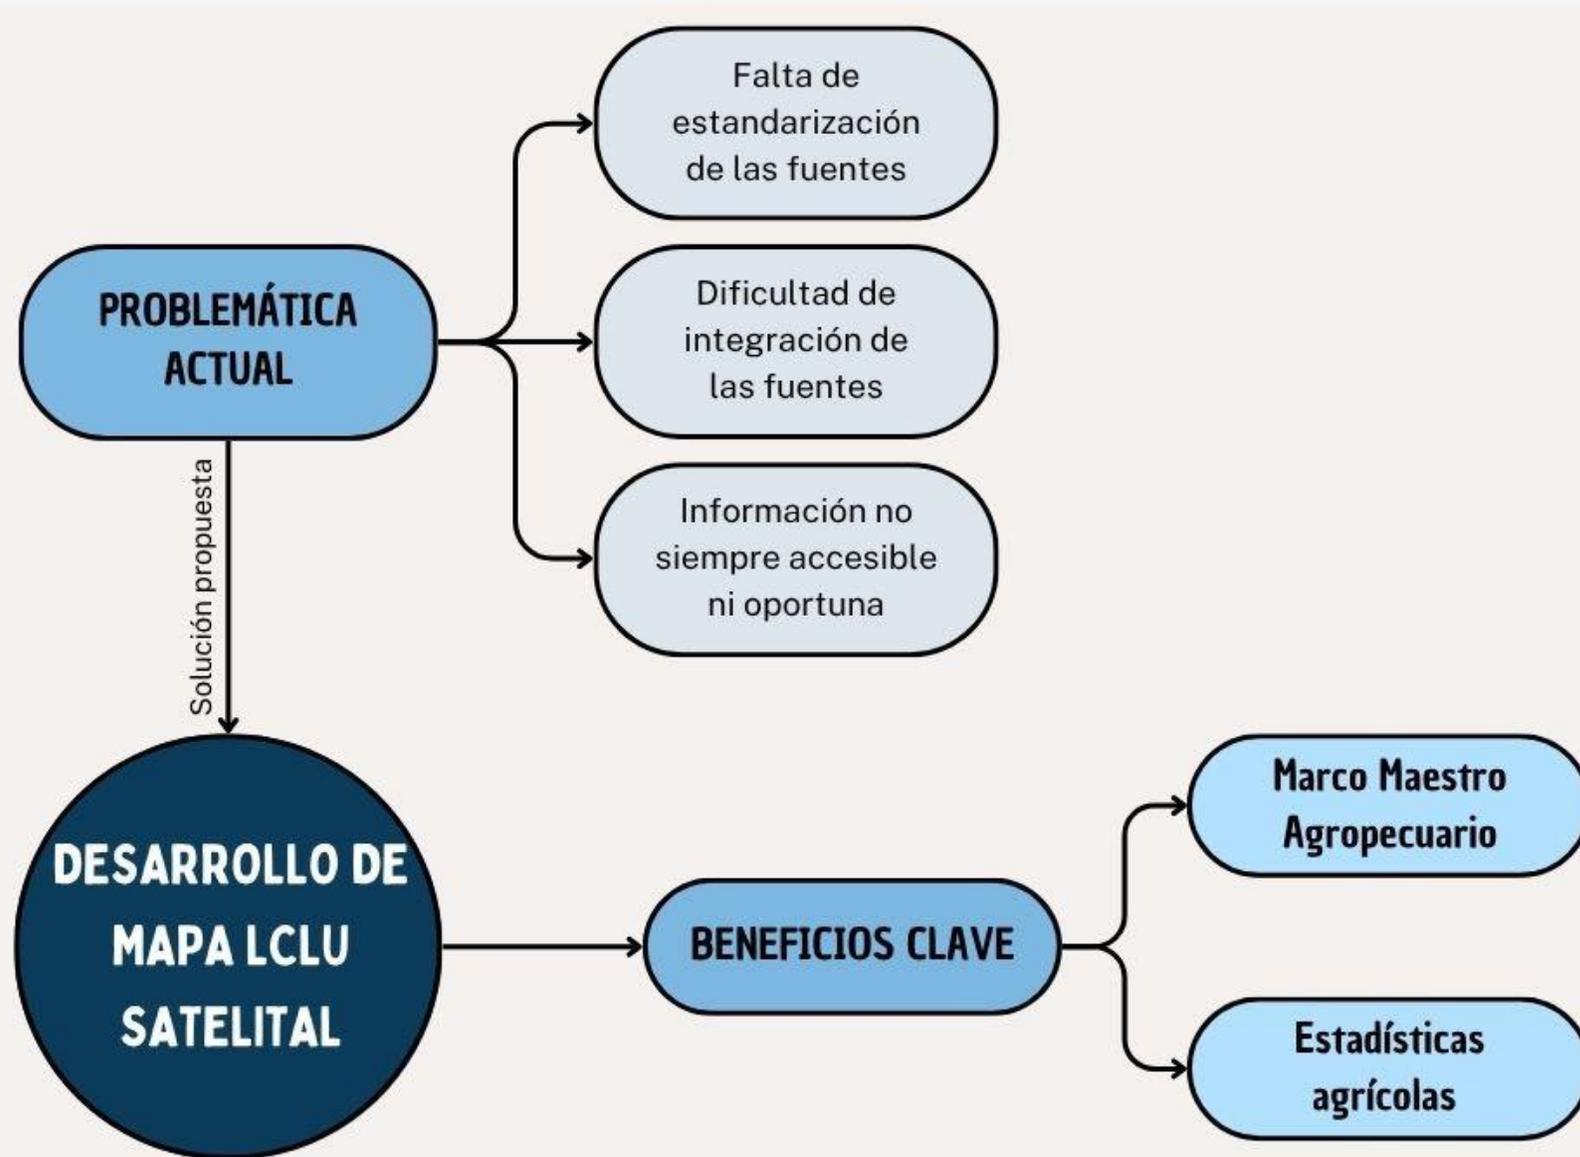
**Estefanía Pizarro Arias**  
**Analista Metodólogo**  
**Ingeniera Agrónoma, Magíster en Ciencias Agropecuarias**

6/26/2025

1. Antecedentes y propósitos del proyecto
2. Enfoque metodológico y avances
3. Desafíos y oportunidades de mejora
4. Próximos pasos
5. Aportes de la percepción remota a la producción de estadísticas oficiales

# 1.

## Antecedentes y propósitos del proyecto



## Junio 2023

### Comienzo proyecto LCLU Satelital

- Revisión bibliográfica
- Desarrollo de método de generación de datos de entrenamiento
- Identificación de posibles predictores
- Búsqueda de algoritmos y códigos en GEE

## Junio 2024

### Primera entrega Odepa

Entregable a Odepa con detalle del método de medias estacionales en GEE y prospecciones del método de series temporales

## Agosto 2024

### Finalización primera parte Piloto Maule

Primer mapa para la Región del Maule. Identificación de posible mejoras en esquema y muestras.



## Noviembre 2023

### Salida a terreno Maule

Visita a la Región del Maule con la finalidad de validar método de generación de muestras de entrenamiento

## Enero 2024

### Comienzo asesoría técnica

- Asesoría técnica respaldada por FAO Roma. Presentación del paquete 'sits' y el uso de series temporales para generación de mapas de LCLU.
- Reuniones con periodicidad semanal.
- Uso de servidor en maquina virtual cedida por el asesor.

## Mayo 2024

### Asesoría técnica presencial

Desarrollo de asesoría técnica en las instalaciones del INE. Asistencia y participación del Banco Central de Chile.

## Septiembre 2024

### Comienzo segunda parte Piloto Maule

Comienzo de nueva versión de modelación haciendo uso esquema ajustado, nuevas muestras y paquete 'sits'

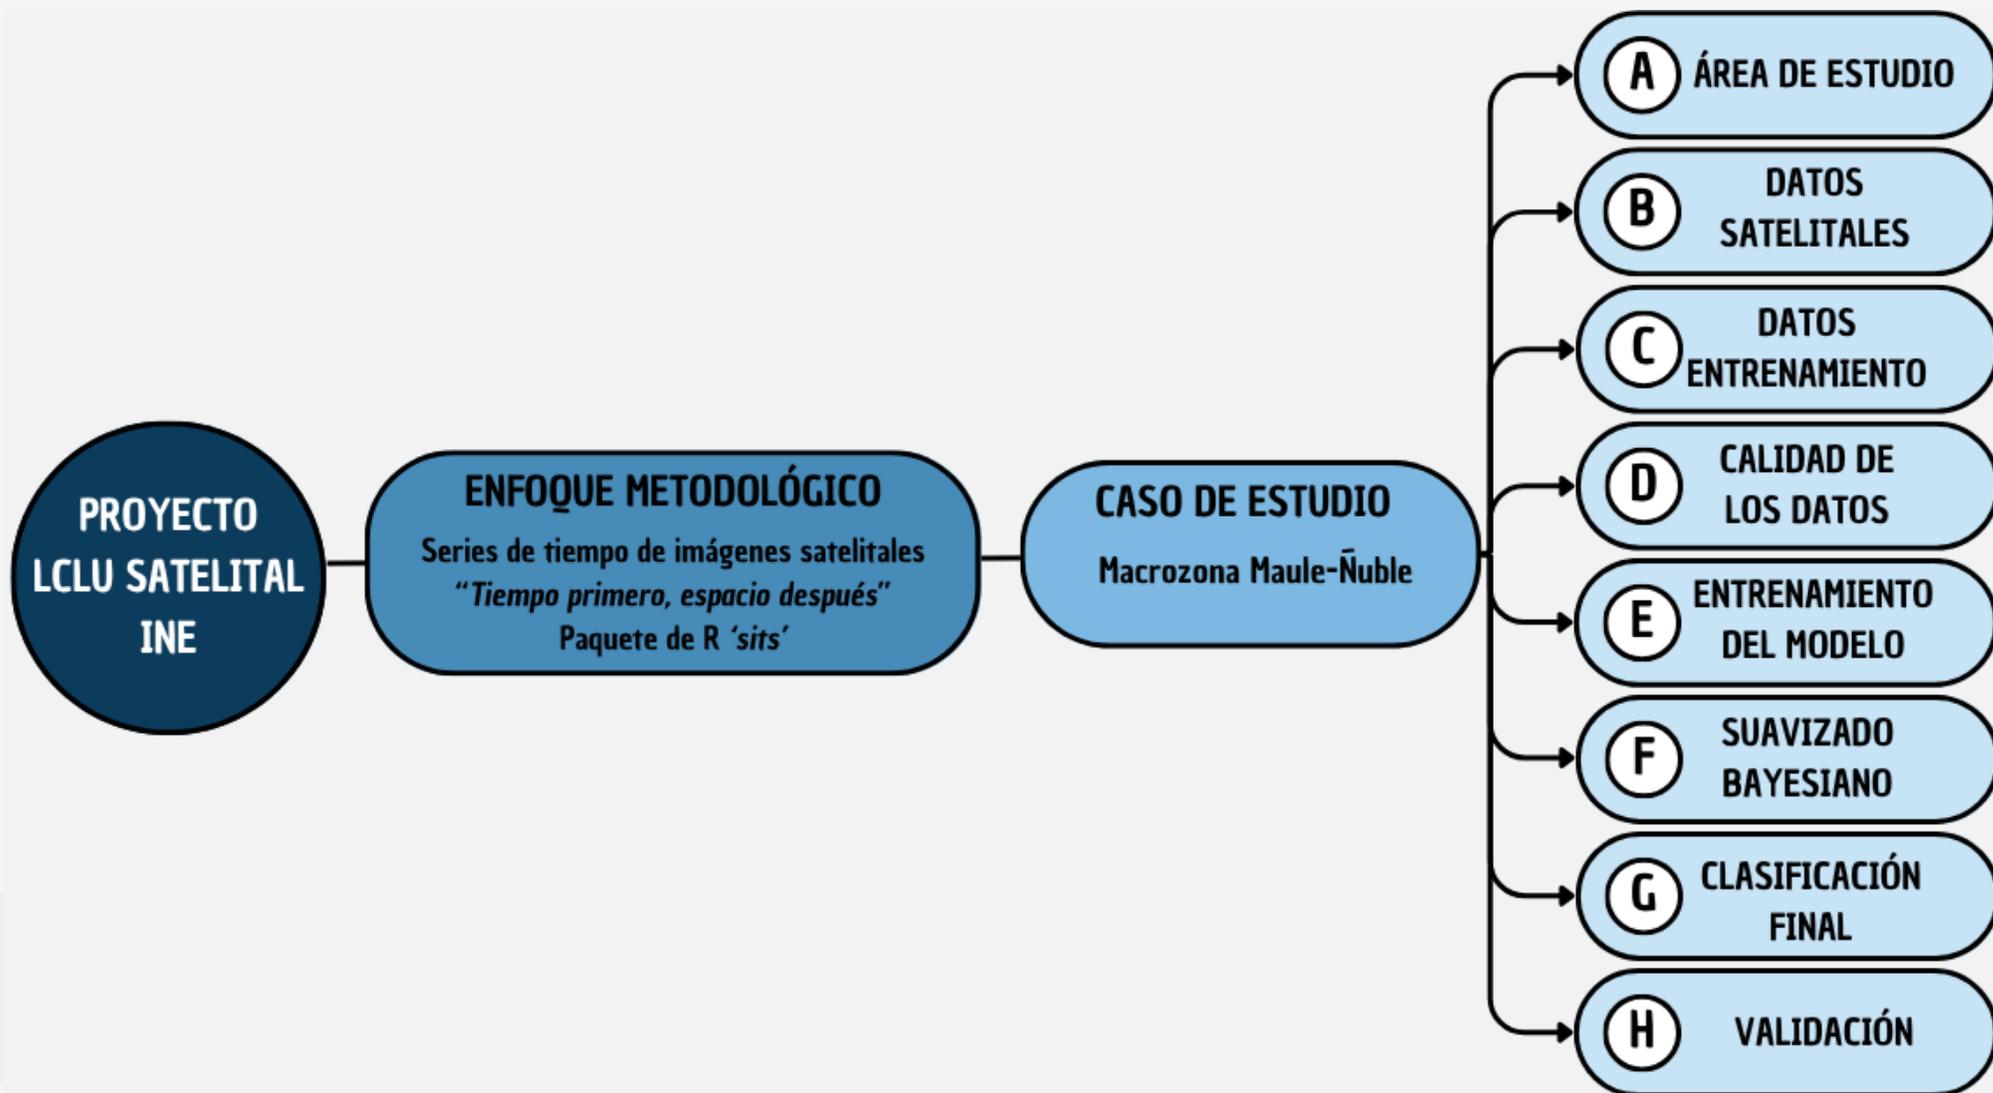
### Comienzo colaboración Paper

Obtención de resultados para colaboración en paper relacionado con Análisis de la calidad de los datos de entrenamiento



# 2.

## Enfoque metodológico y avances

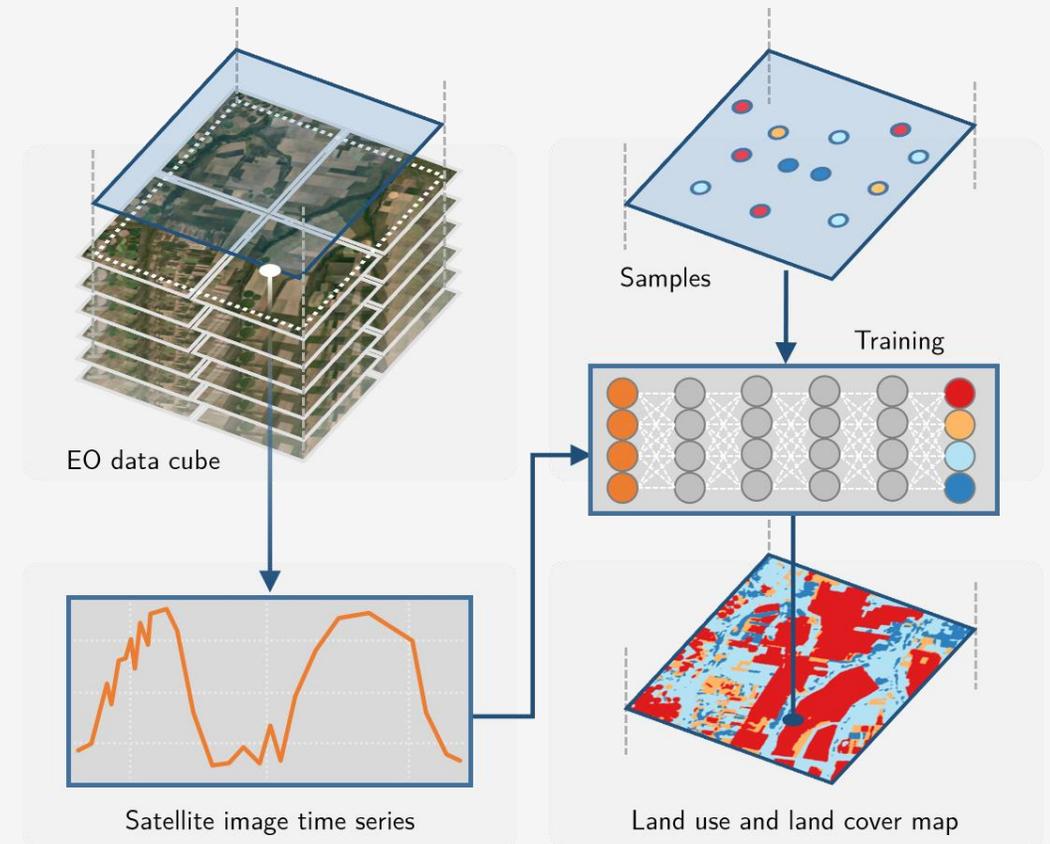


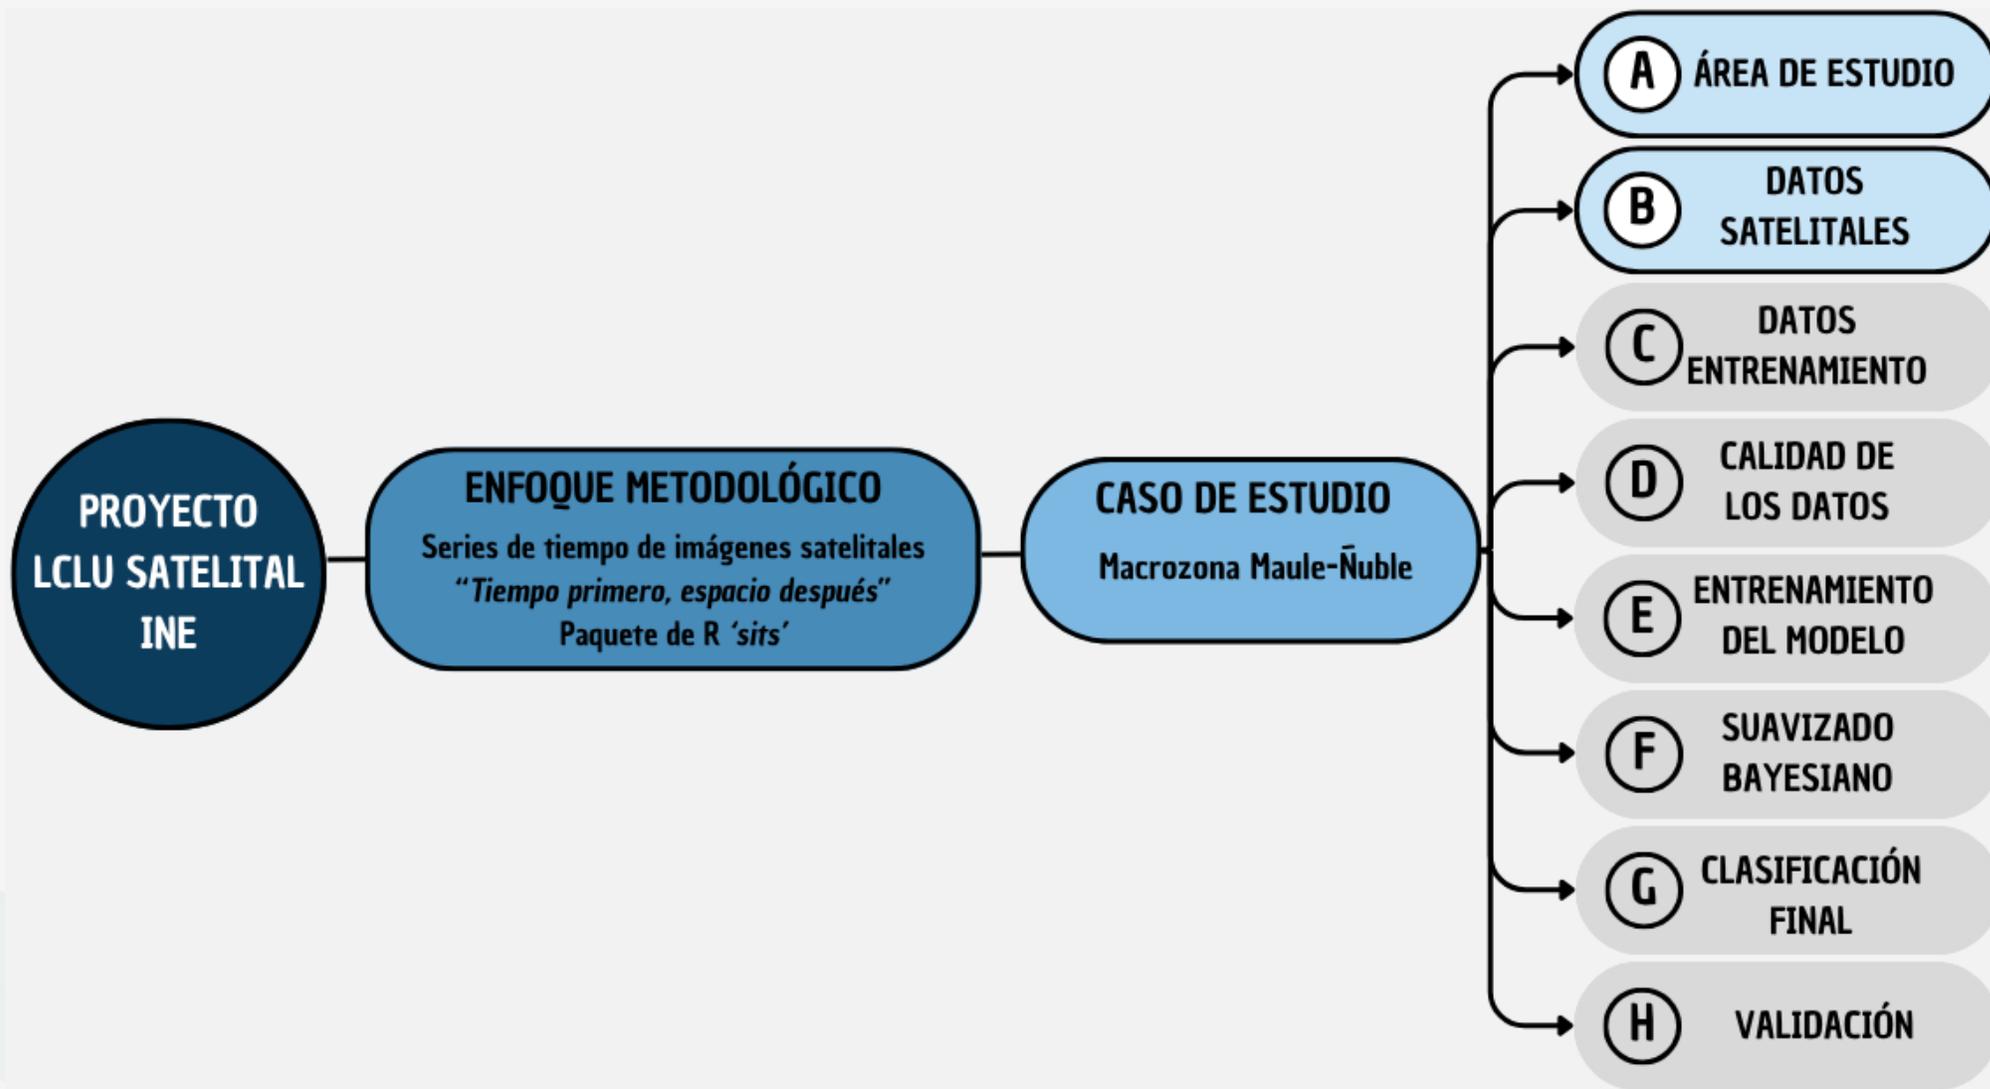


## Enfoque “Time First, Space Later”

- **Time first:** se entrena el modelo a partir de la **serie temporal completa** de cada píxel (curvas de bandas o índices como NDVI/EVI), capturando su comportamiento fenológico.
- **Space later:** una vez clasificados todos los píxeles individualmente, se aplica una **etapa espacial**, donde se suavizan los resultados considerando la vecindad de cada píxel.

Figura: Uso de series temporales para la clasificación de uso y cobertura





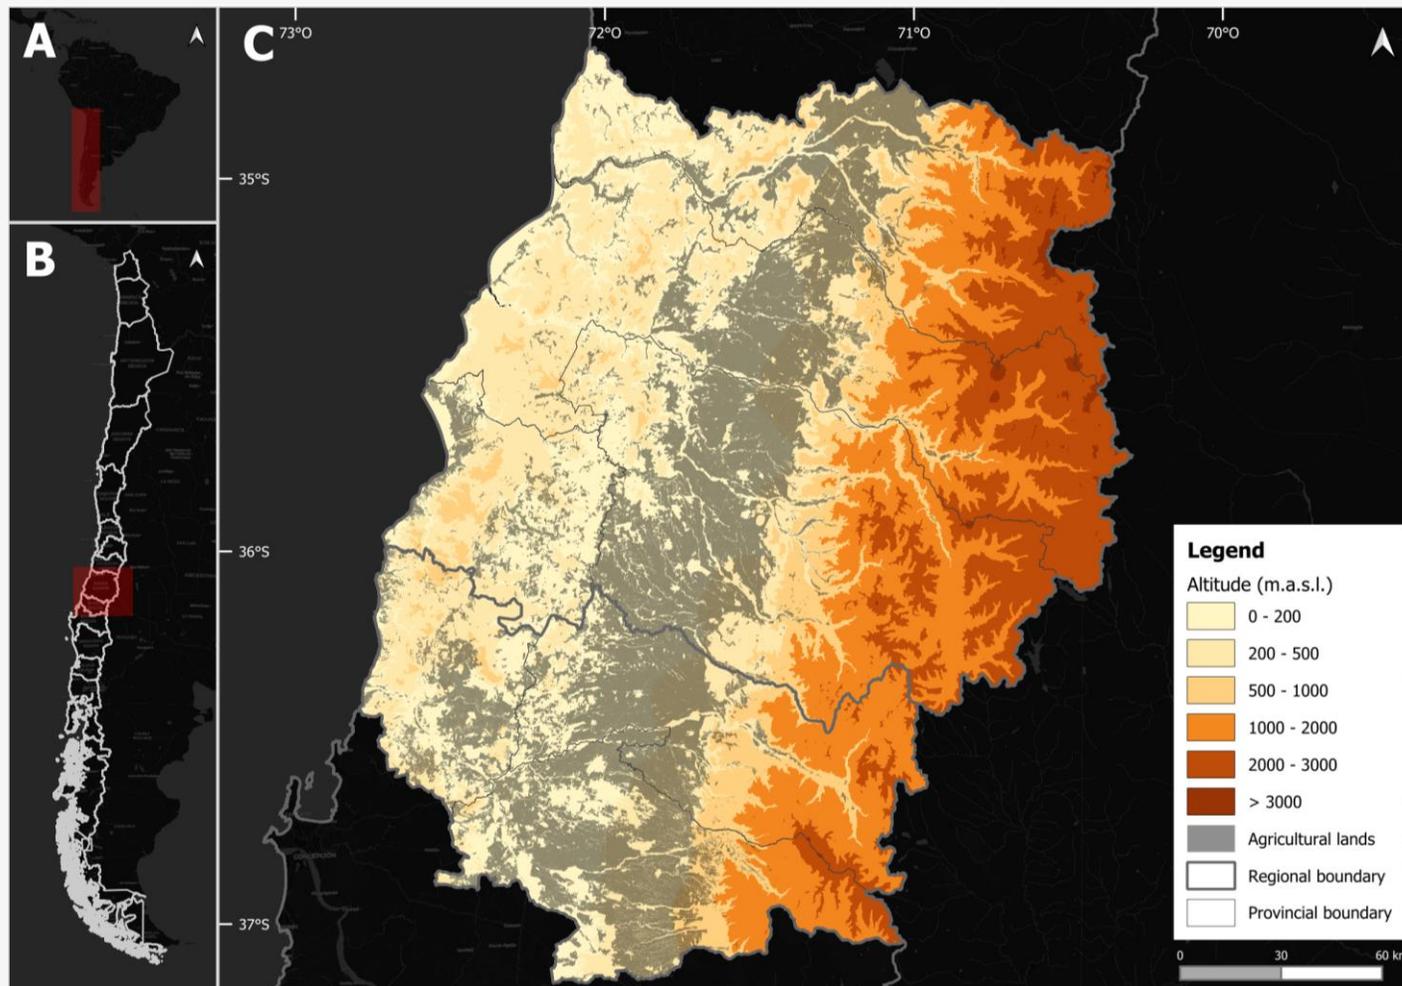
# A. Área de estudio

Figura: División de Macrozonas



Fuente: Instituto Nacional de Estadísticas

Figura: Macrozona de estudio Maule-Ñuble (MZ4)



Fuente: Instituto Nacional de Estadísticas

# B. Datos satelitales



Sentinel-2

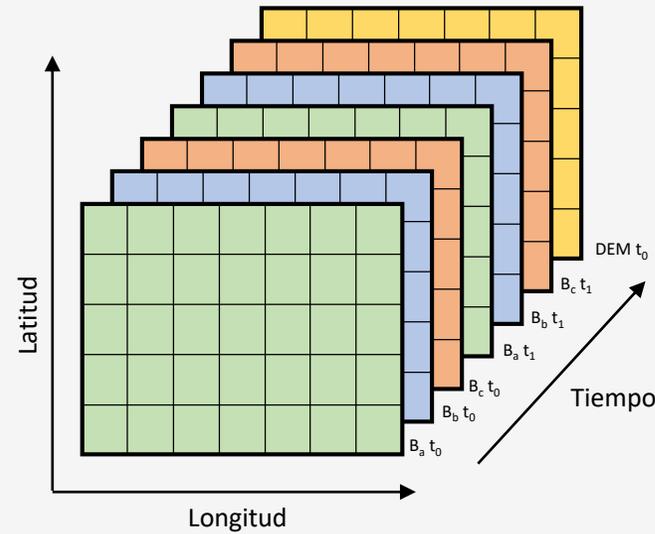
Agencia Espacial Europea (ESA)



TanDEM-X

Centro Aeroespacial Alemán (DLR)

Figura: Vista conceptual de un cubo de datos satelital

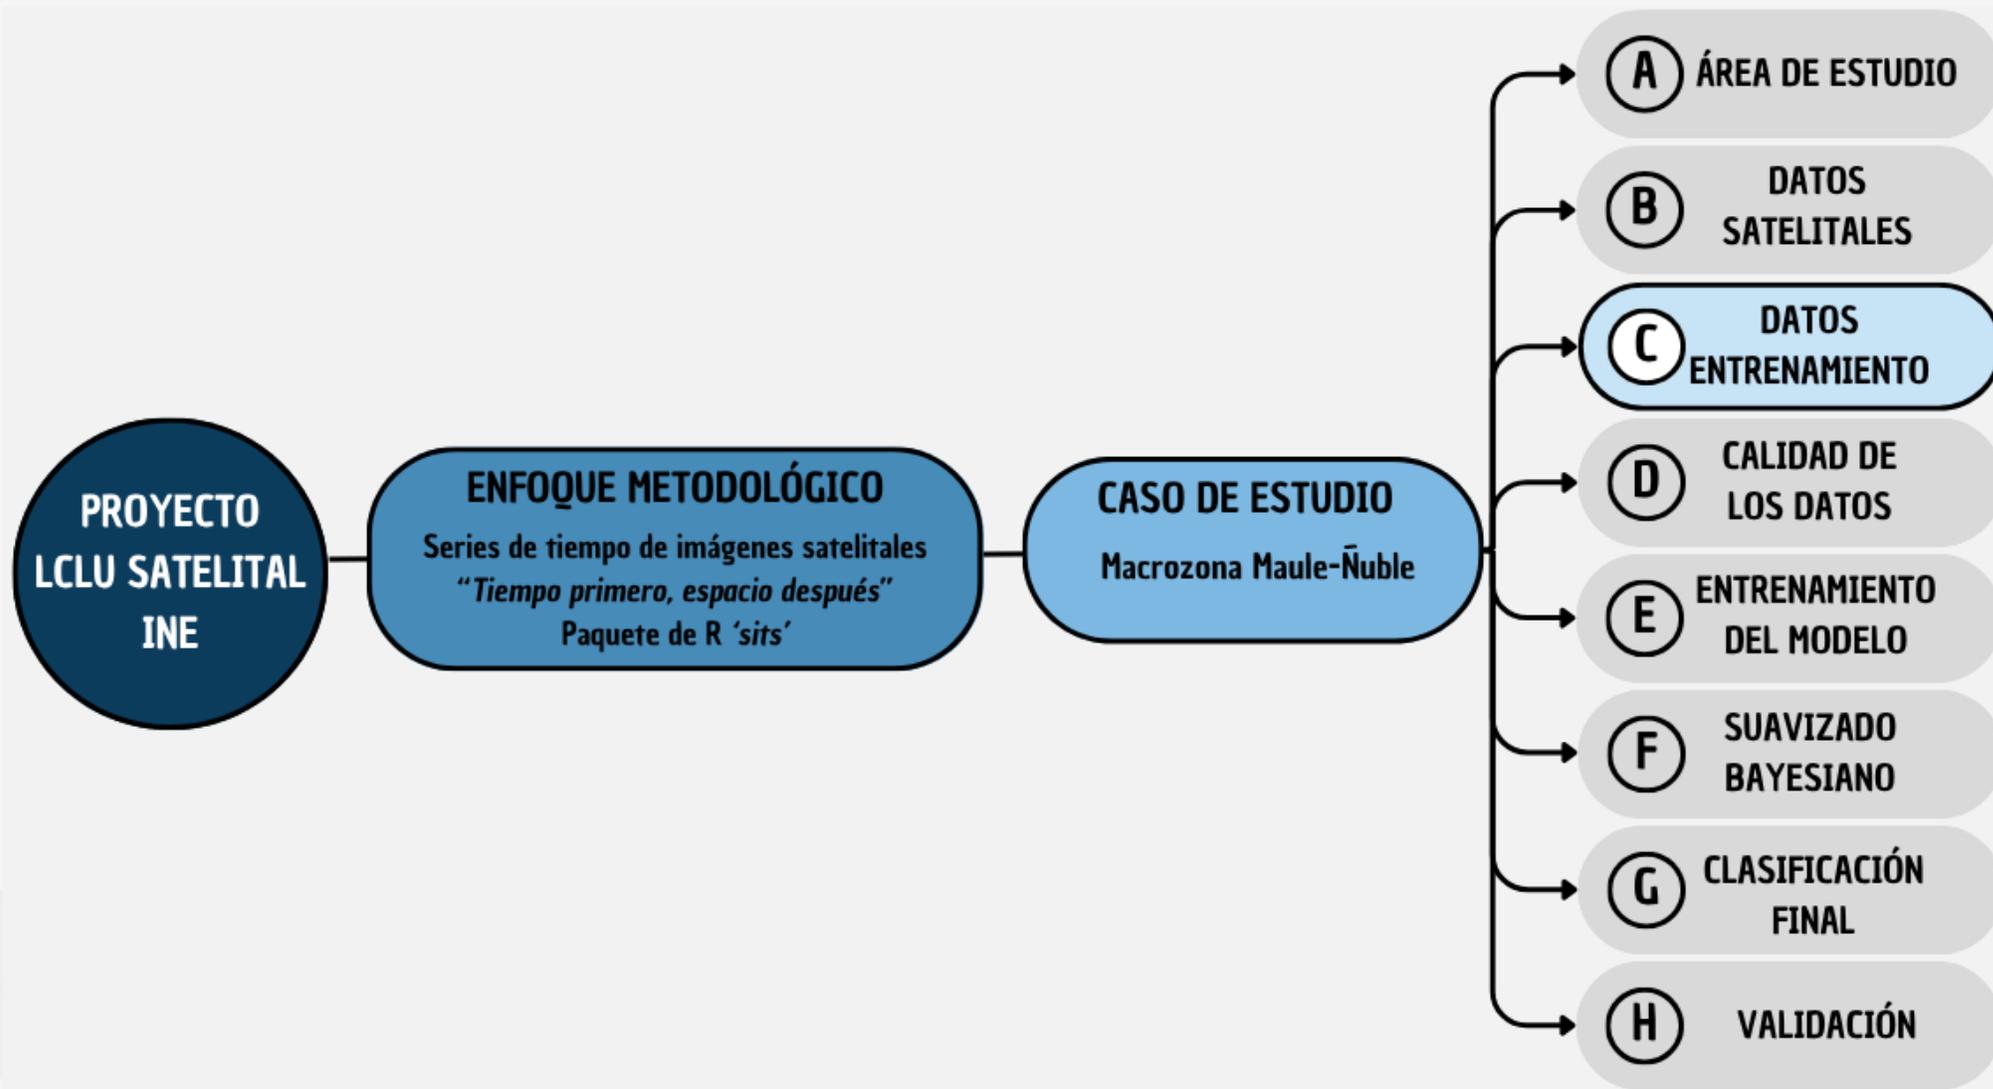


Fuente: Instituto Nacional de Estadísticas

Cubo de datos satelital (regular) con información de Sentinel-2 y TanDEM-X:

- Cobertura espacial: 14 tiles\*
- Cobertura temporal: 05/2020 – 05/2021
- Resolución espacial 10 m
- Resolución temporal 16 días
- 15 bandas en total:
  - 10 bandas ópticas
  - 3 índices espectrales (NDVI, EVI, NDWI)
  - Bandas de Elevación y Pendiente

\*Tile: unidad espacial de 100 km × 100 km en proyección UTM/MGRS, usada para organizar y distribuir imágenes satelitales



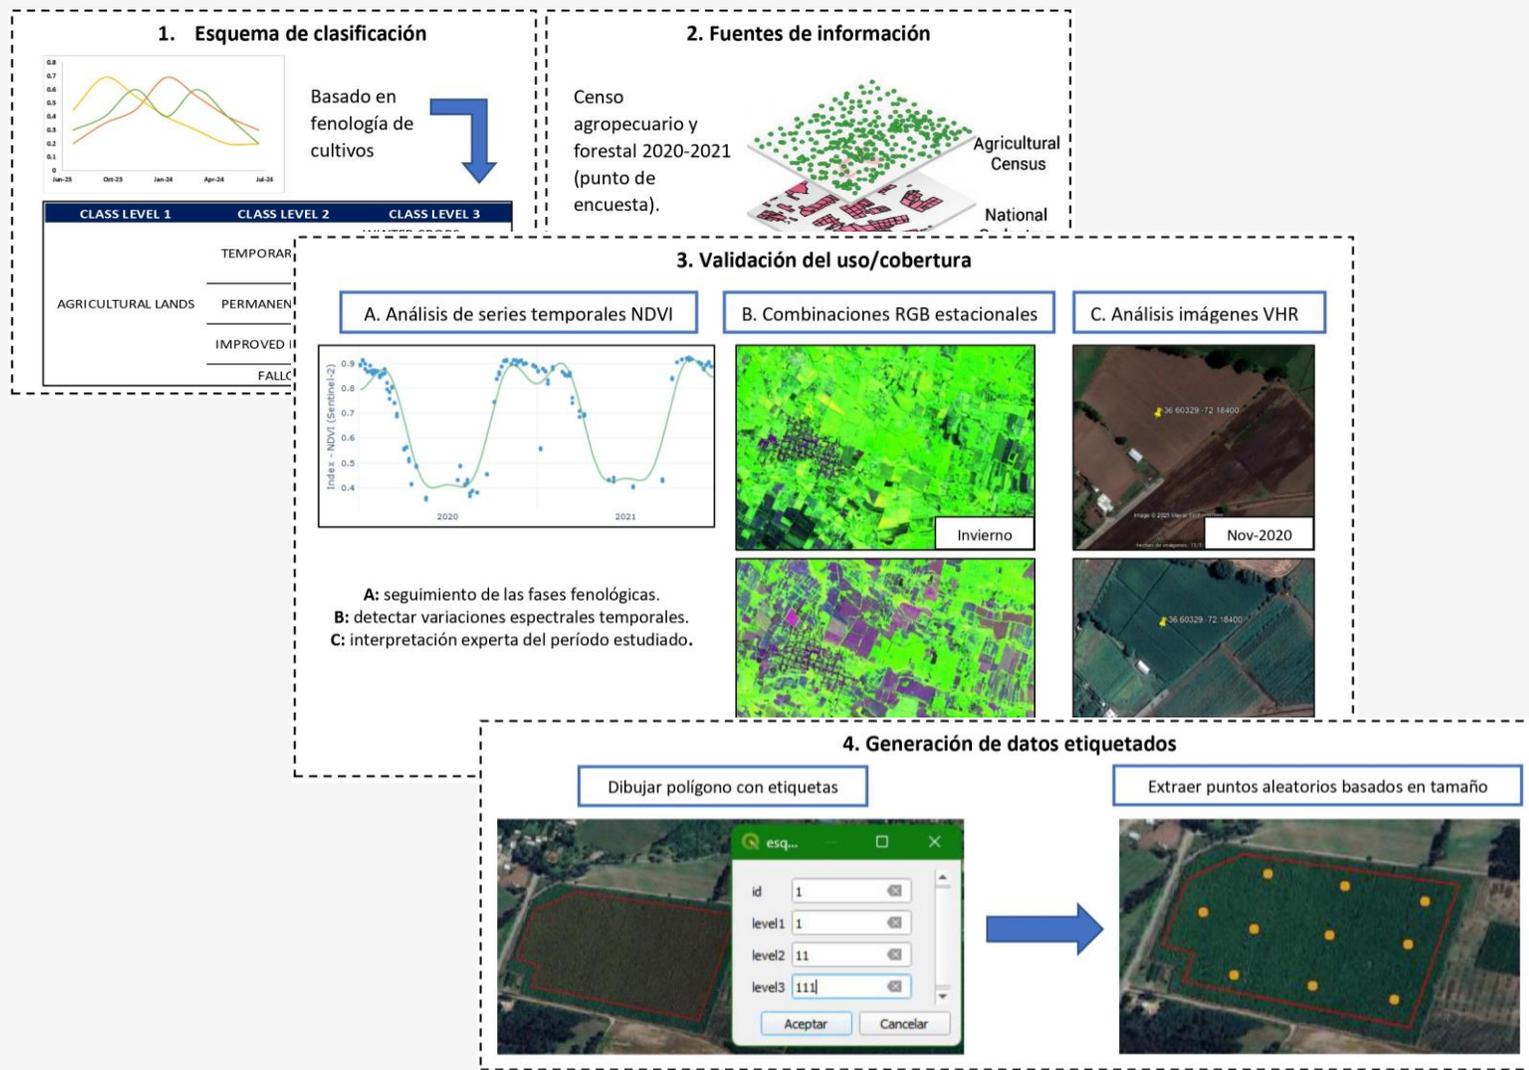
# C. Datos de entrenamiento

Cuadro: Clasificación jerárquica del LCLU satelital en tres niveles

Nivel 1	Nivel 2	Nivel 3
1 Superficies artificiales	11 Superficies artificiales	111 Superficies artificiales
2 Terrenos agrícolas	21 Cultivos temporales	211 Cultivos invierno
		212 Cultivos primavera
		213 Cultivos sucesivos
	22 Cultivos permanentes	221 Frutal caducifolio
		222 Frutal perennifolio
		23 Pasturas
	24 Barbecho	231 Pastura anual
		232 Pastura perenne
241 Barbecho	241 Barbecho	
3 Plantaciones forestales	31 Plantaciones forestales	311 Plantación adulta
		312 Plantación cosecha
		313 Plantación joven
4 Cuerpos de agua	41 Cuerpos de agua	411 Cuerpos de agua
5 Humedales	51 Humedales	511 Humedales
6 Bosque nativo	61 Bosque nativo	611 Bosque caducifolio
		612 Bosque perennifolio
7 Praderas y matorrales	71 Pradera	711 Pradera
	72 Matorrales	721 Matorrales
8 Áreas desprovistas de vegetación	81 Áreas no vegetadas	811 Afloramiento rocoso
		812 Arenas y dunas
		813 Suelos desnudos
		814 Área no vegetada con nieve
82 Nieves y glaciares	821 Nieves y glaciares	

Fuente: Instituto Nacional de Estadísticas

Figura: Diagrama del flujo propuesto para la generación de datos de entrenamiento

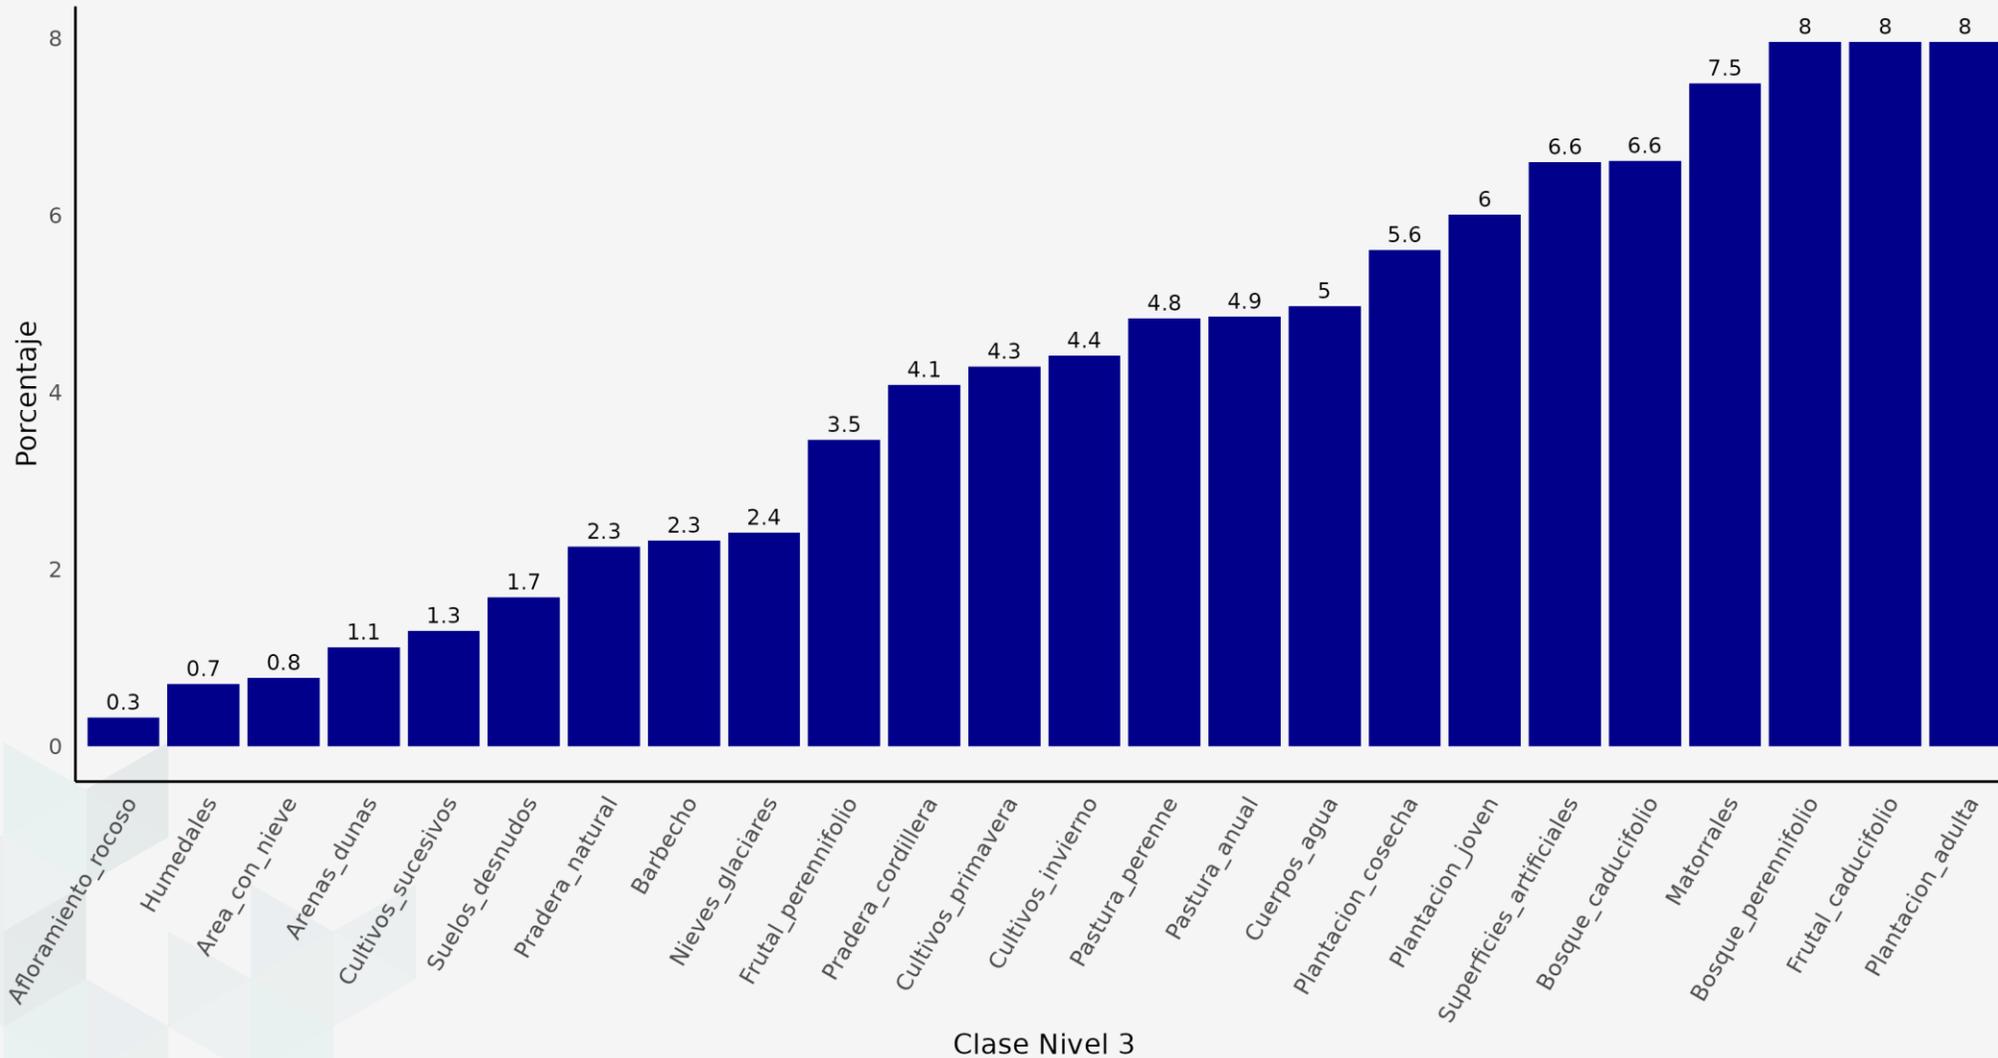


Fuente: Instituto Nacional de Estadísticas

# C. Datos de entrenamiento

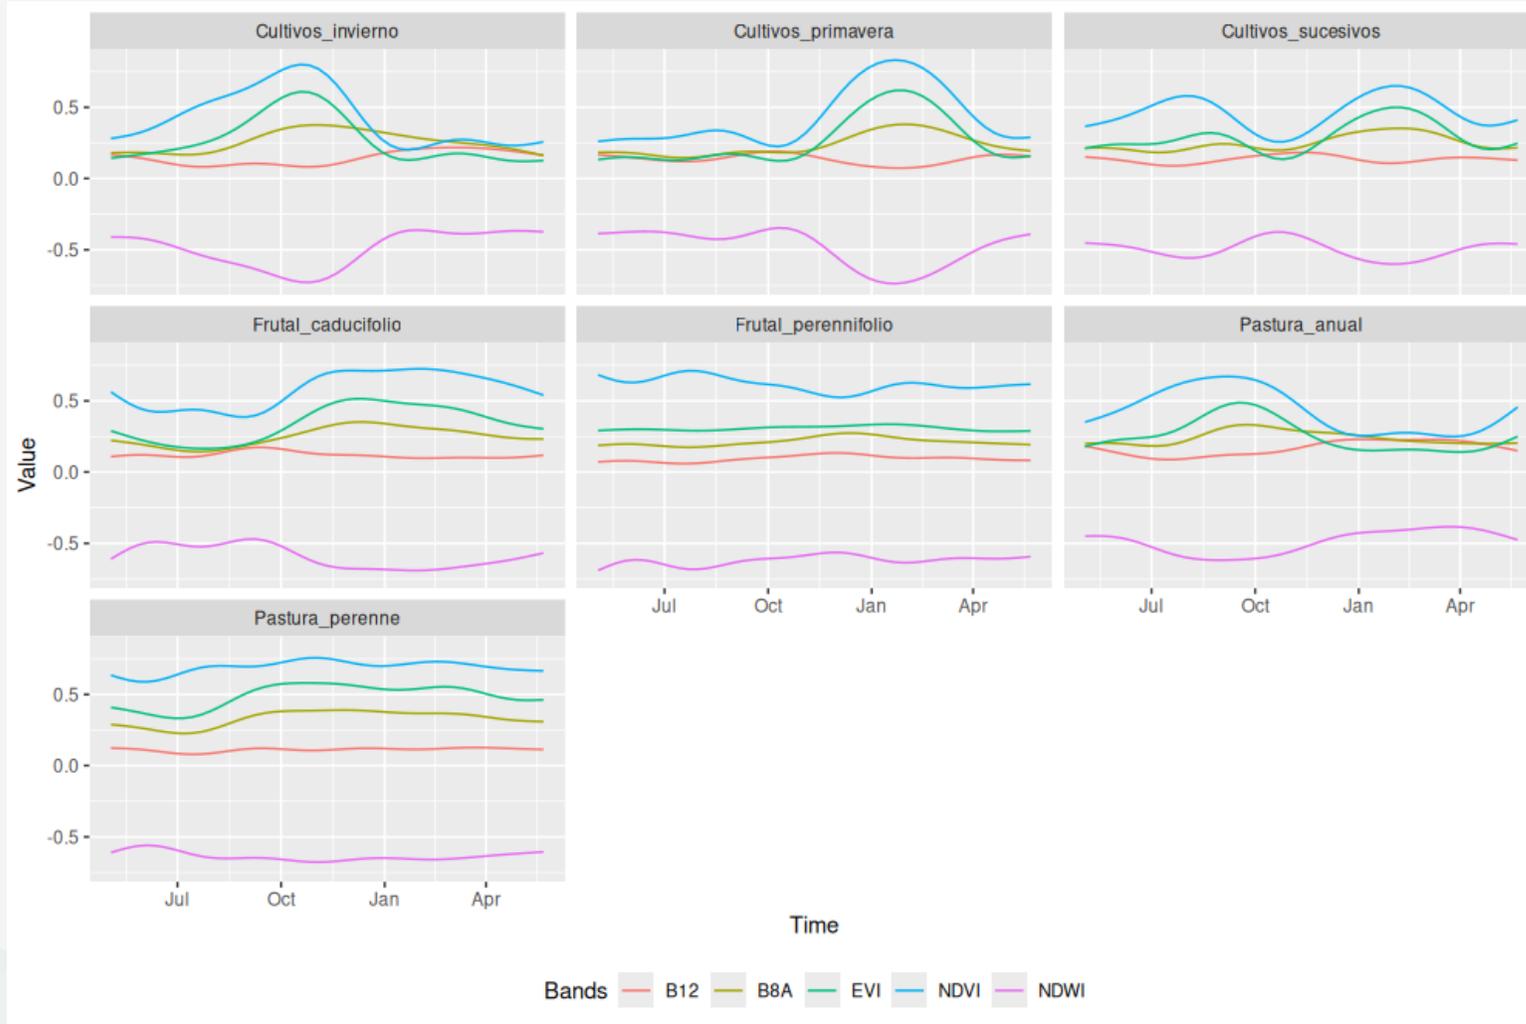
Figura: Distribución de datos de entrenamiento por clases de uso y cobertura del suelo

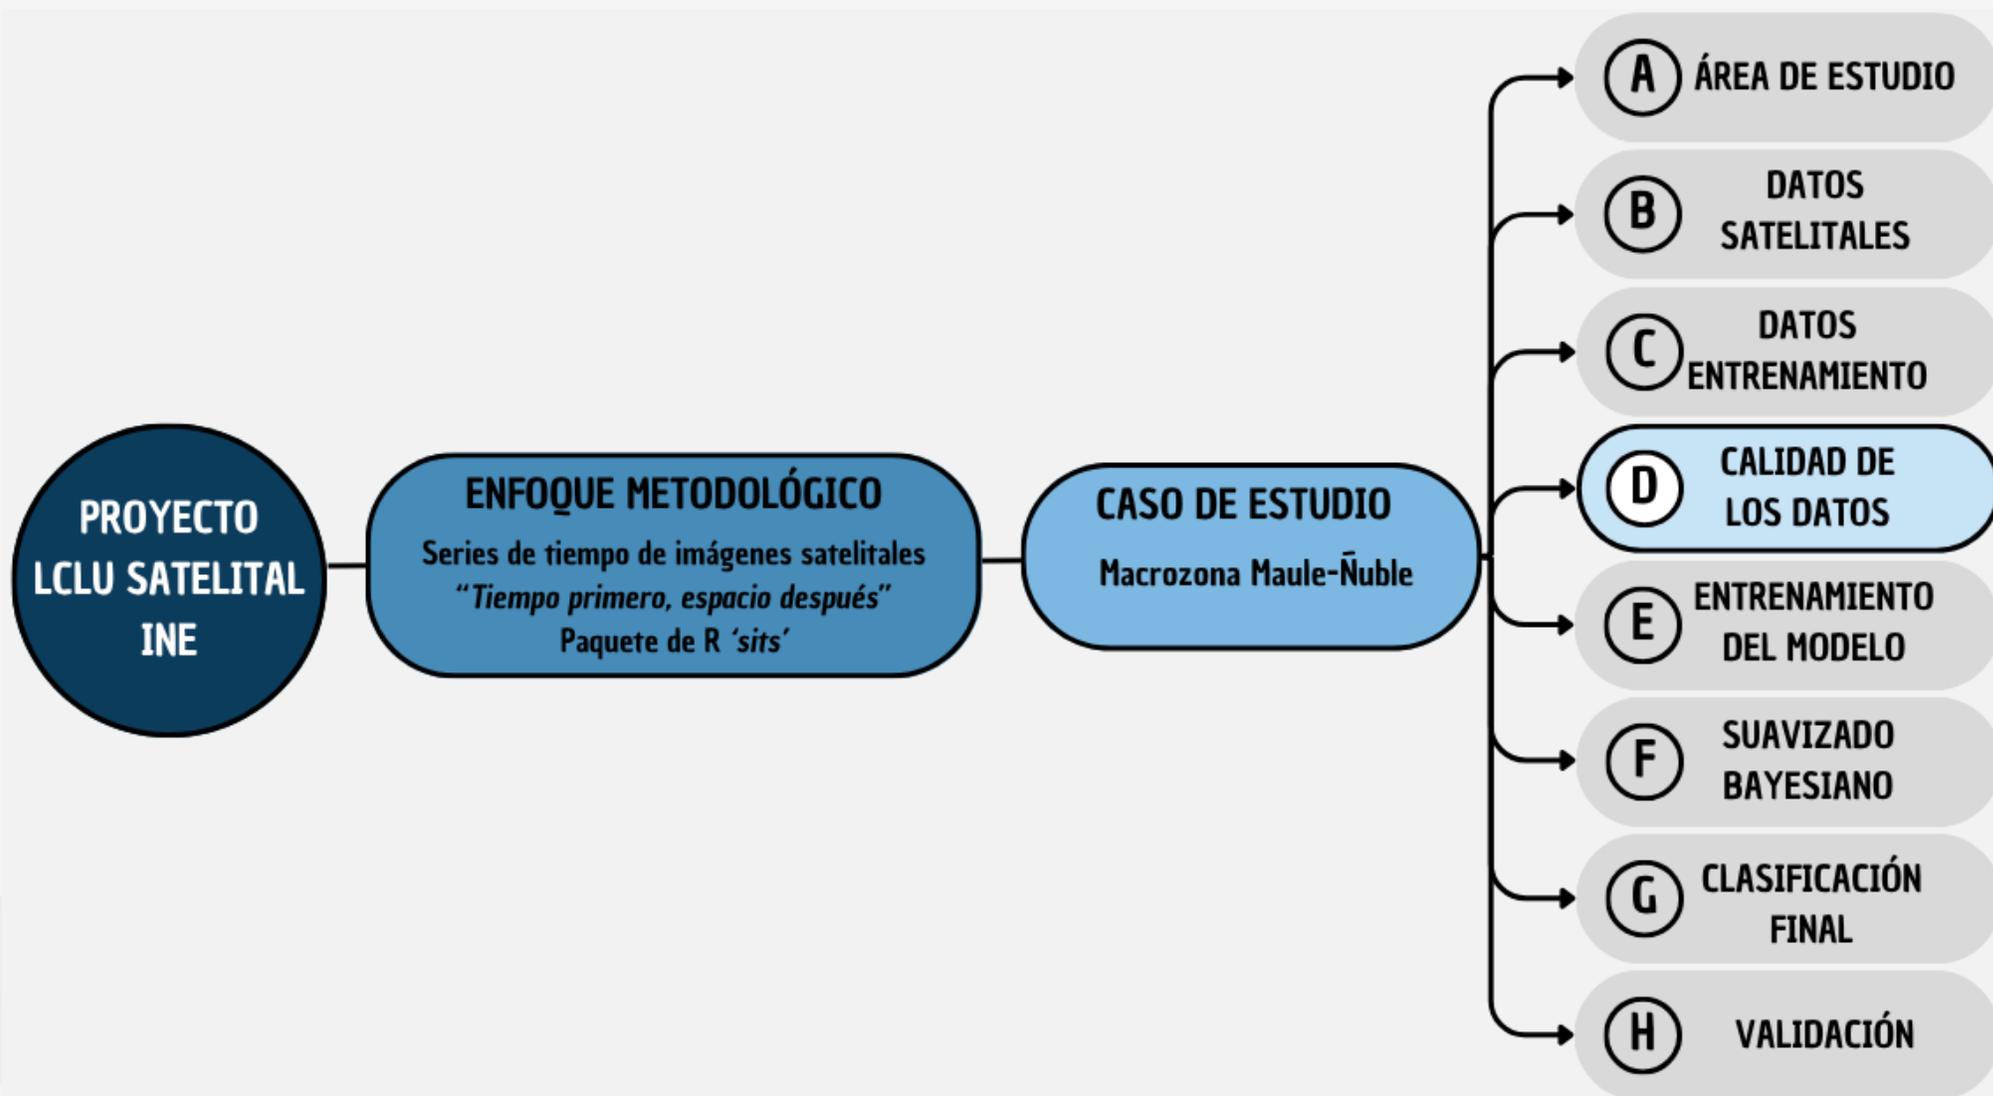
Cantidad datos  
entrenamiento:  
62.823



# C. Datos de entrenamiento

Figura: Patrones de las clases agrícolas de la Macrozona en estudio

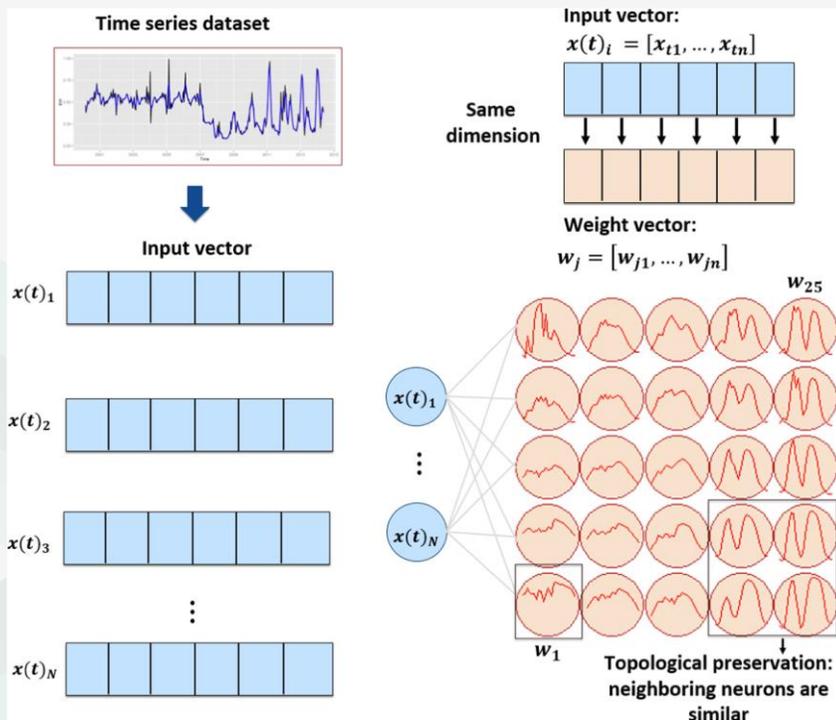




# D. Calidad de los datos

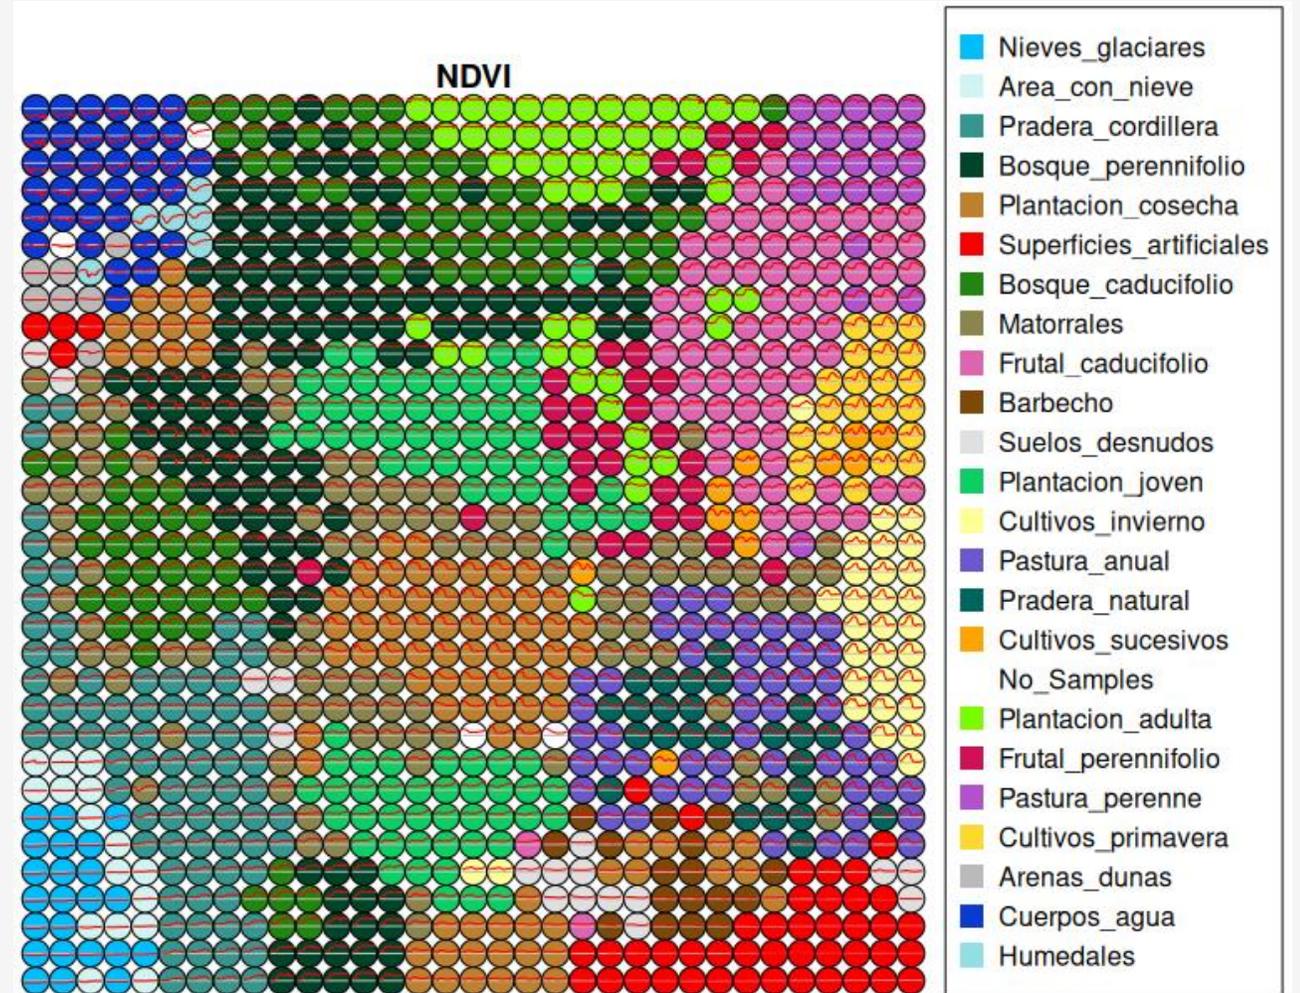
La calidad de las muestras de entrenamiento es clave para lograr buenos resultados en clasificación con percepción remota y machine learning, especialmente cuando las fuentes de información **no fueron diseñadas originalmente para este fin**.

Figura: Estructura de los Mapas Autoorganizados (Self Organized Maps)



Fuente: Santos et al., 2021

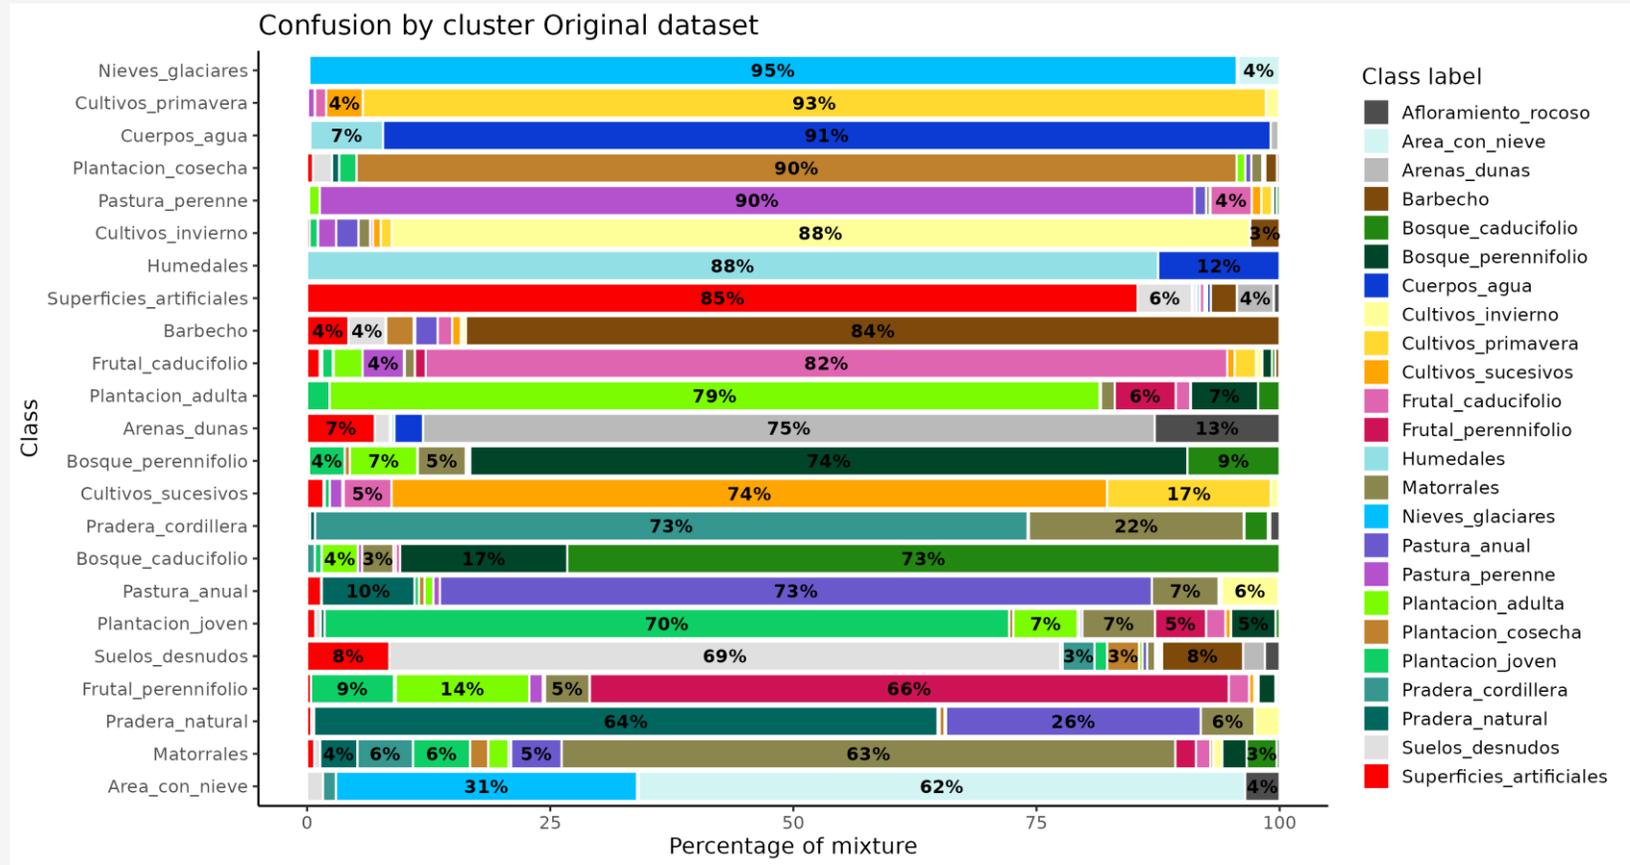
Figura: Mapa SOM de los datos de entrenamiento de la Macrozona Maule-Ñuble



Fuente: Instituto Nacional de Estadísticas

# D. Calidad de los datos

Figura: Confusión por clase de los datos de la Macrozona Maule-Ñuble

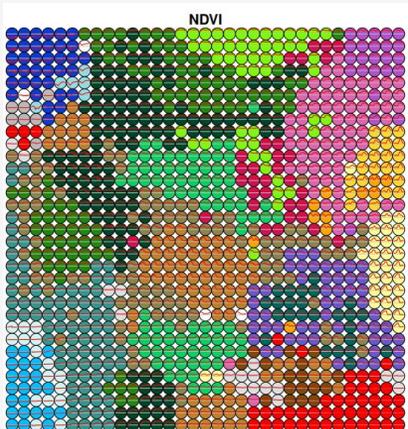


Fuente: Instituto Nacional de Estadísticas

Accuracy 0,954  
 Kappa 0,951  
 F1-Score 0,83 – 0,99

## Confusión entre clases

Evaluación de los clústeres generados en el mapa SOM



CLÚSTER DE REFERENCIA

CLÚSTERES ASIGNADOS

MATRIZ DE CONFUSIÓN

PUREZA DE CLUSTER  
 Porcentaje de participación de clases dentro de cada clúster

## Reducción del desbalance de clases

Reducir el desbalance entre clases en el set de muestras de entrenamiento de un modelo

**A** OVERSAMPLING

**SMOTE**

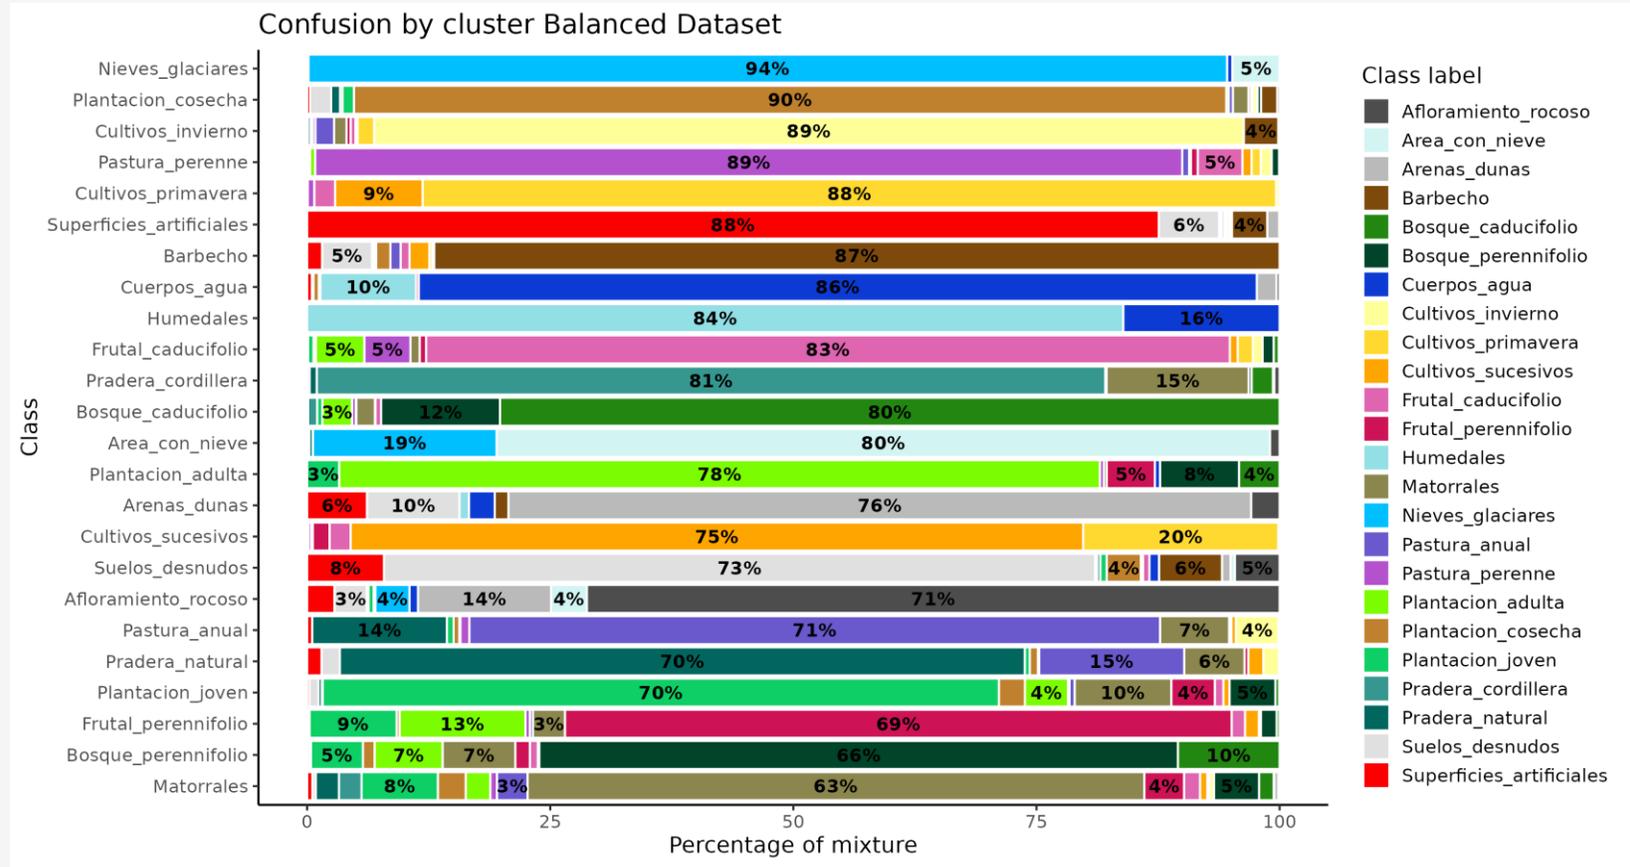
- Se generan muestras sintéticas de cada banda
- Evita el oversampling basado en duplicación simple (más diversidad en el set generado)

**B** UNDERSAMPLING

**SOM (SELF-ORGANIZING MAP)**

- Se construye un mapa SOM
- Se seleccionan muestras diversas → se toman 4 por cada neurona del SOM
- No se queda solo con puntos redundantes o similares

Figura: Confusión por clase de los datos balanceados de la Macrozona Maule-Ñuble



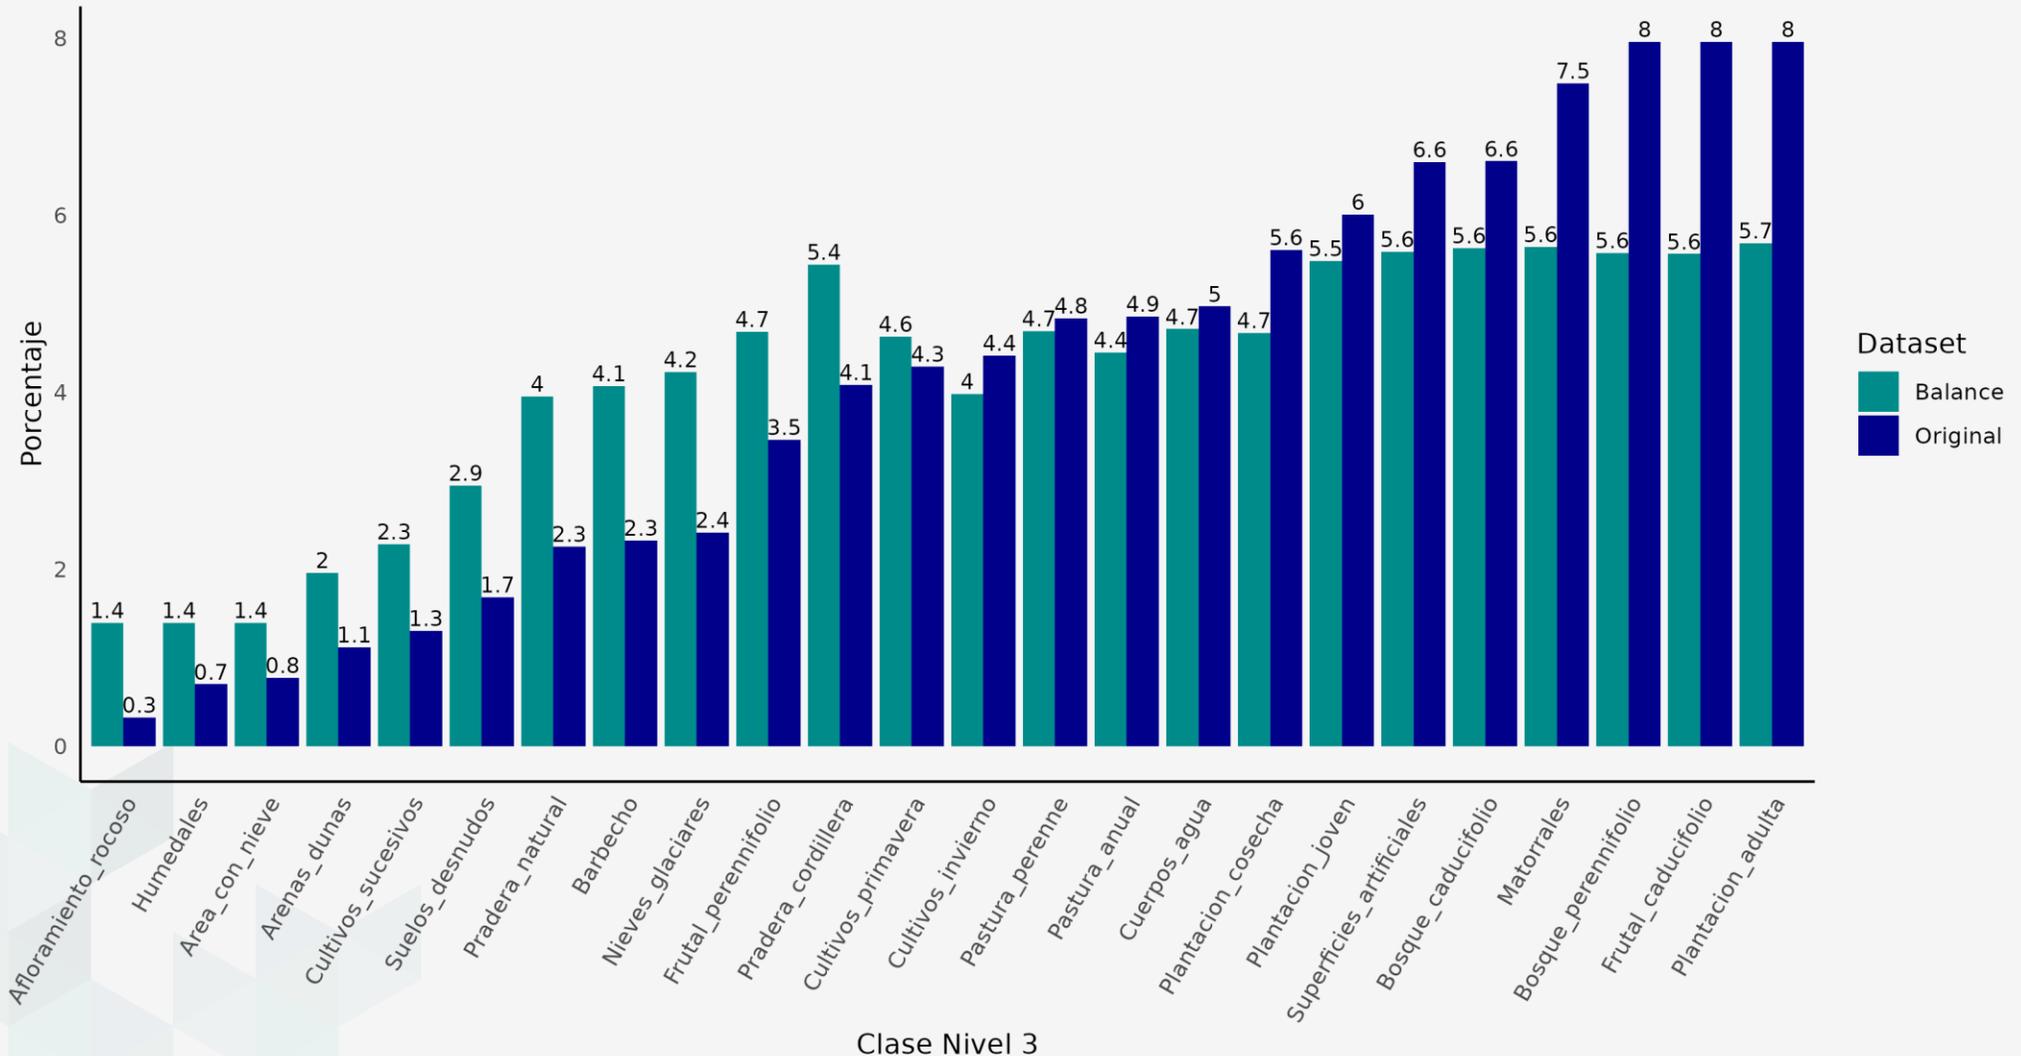
Fuente: Instituto Nacional de Estadísticas

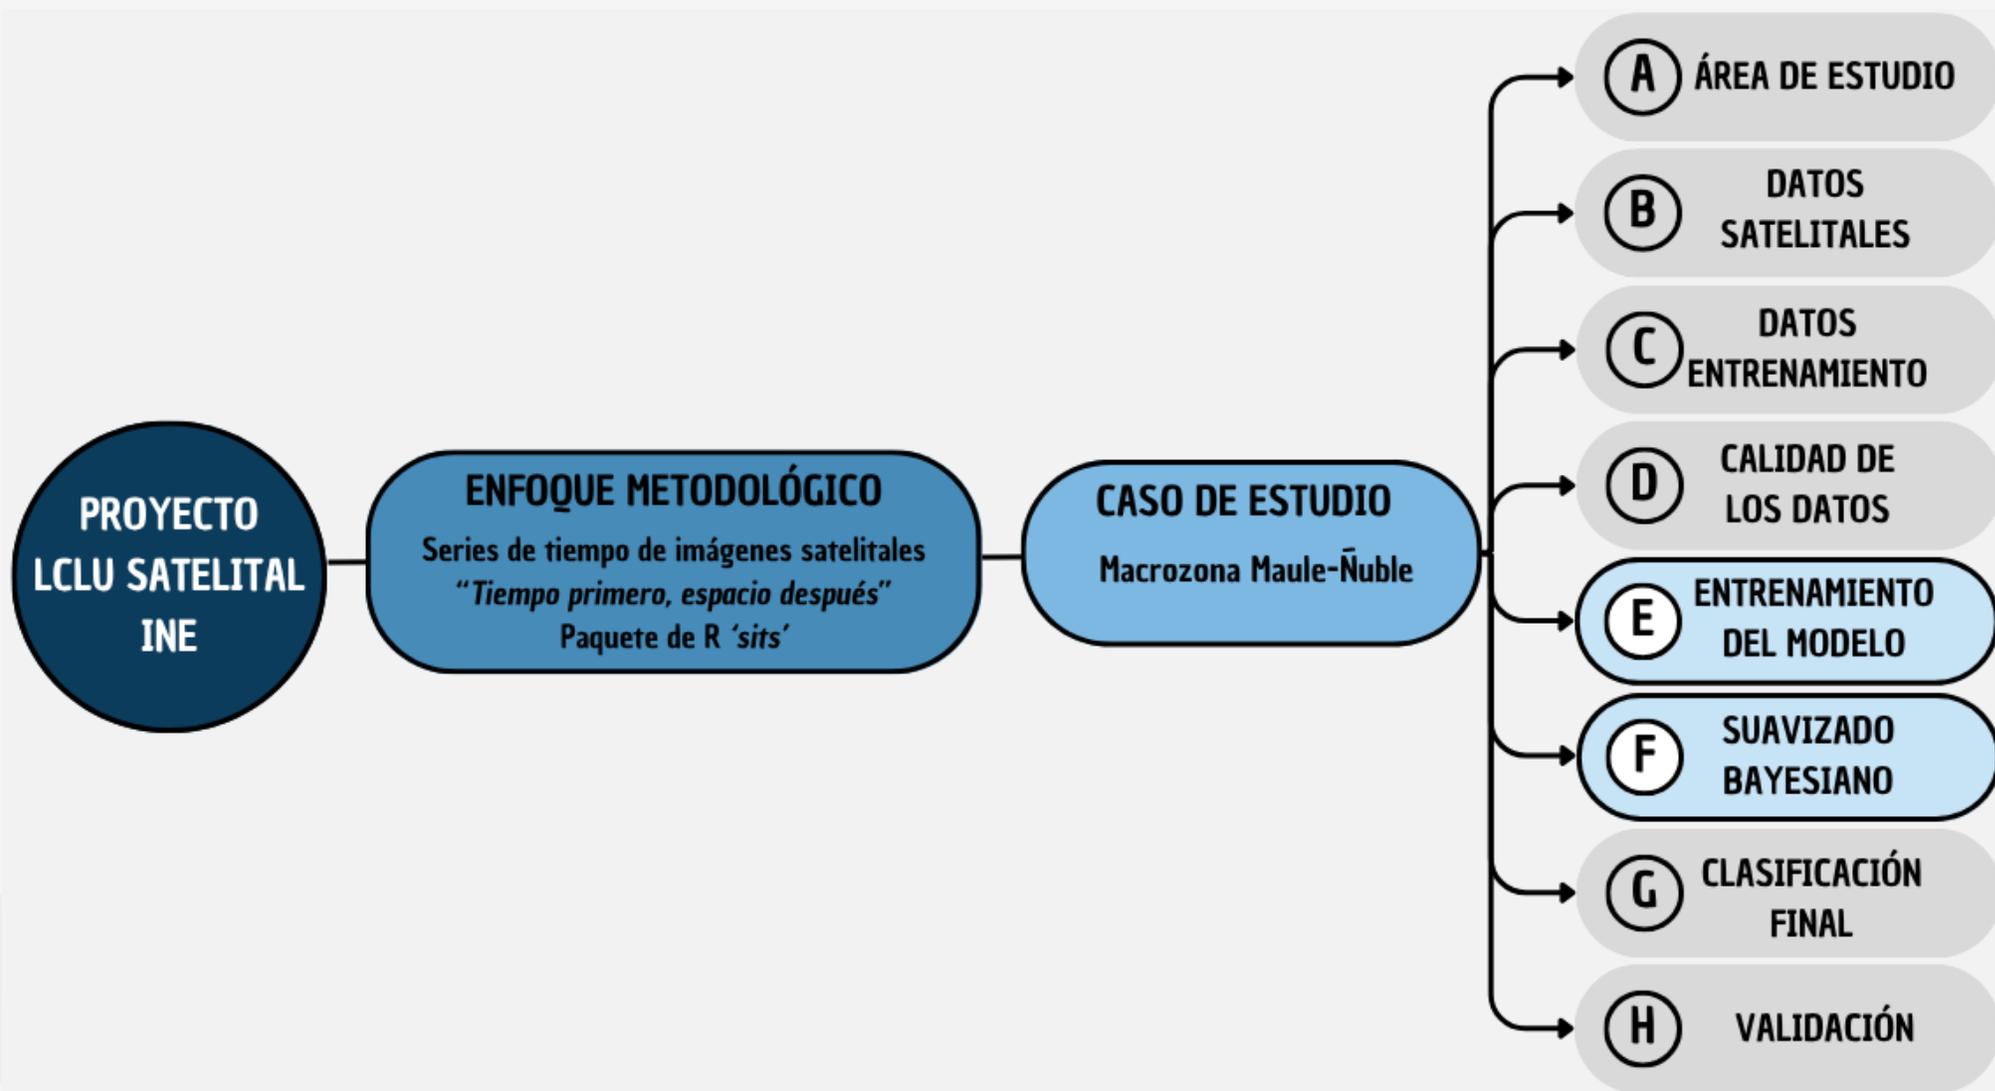
Accuracy 0,963  
 Kappa 0,961  
 F1-Score 0,89 – 0,99

Cantidad datos  
 entrenamiento: 35.896

# D. Calidad de los datos

Figura: Distribución de datos de entrenamiento por clases de uso y cobertura del suelo para Dataset original y balanceado





# E. Entrenamiento

# F. Suavizado bayesiano

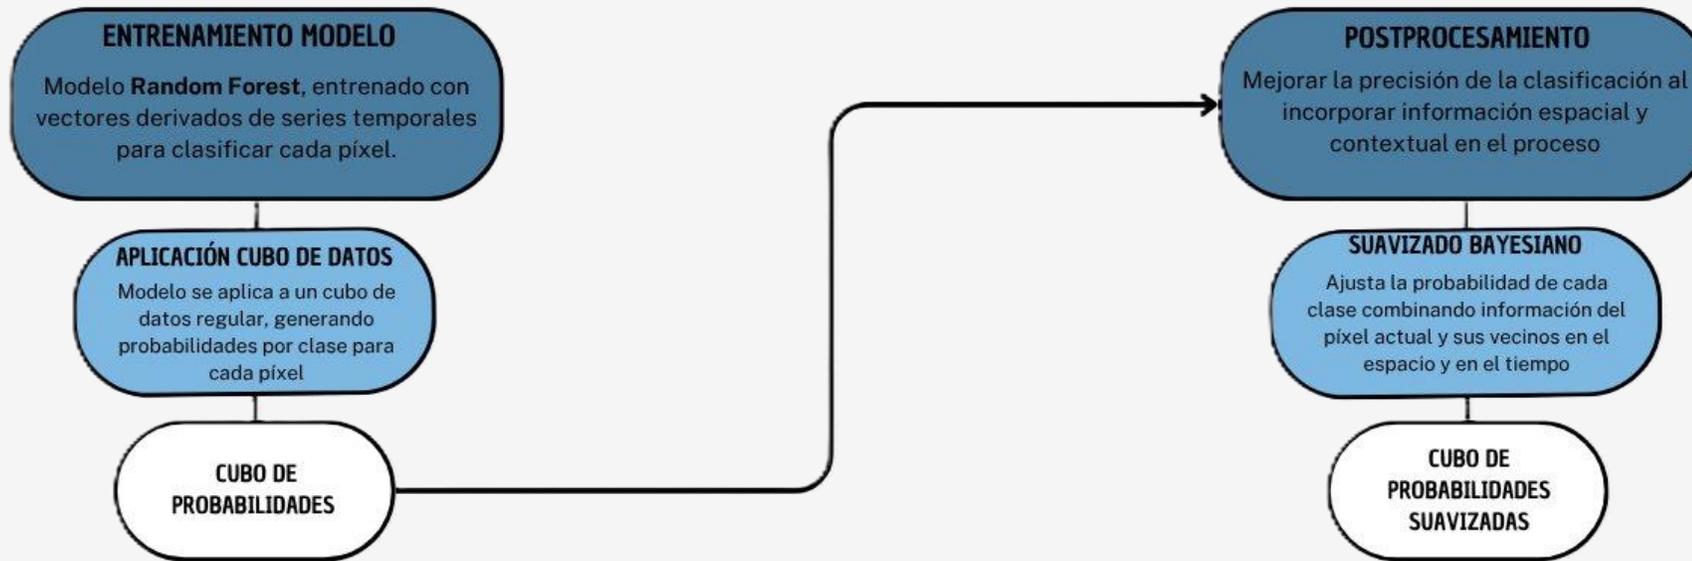
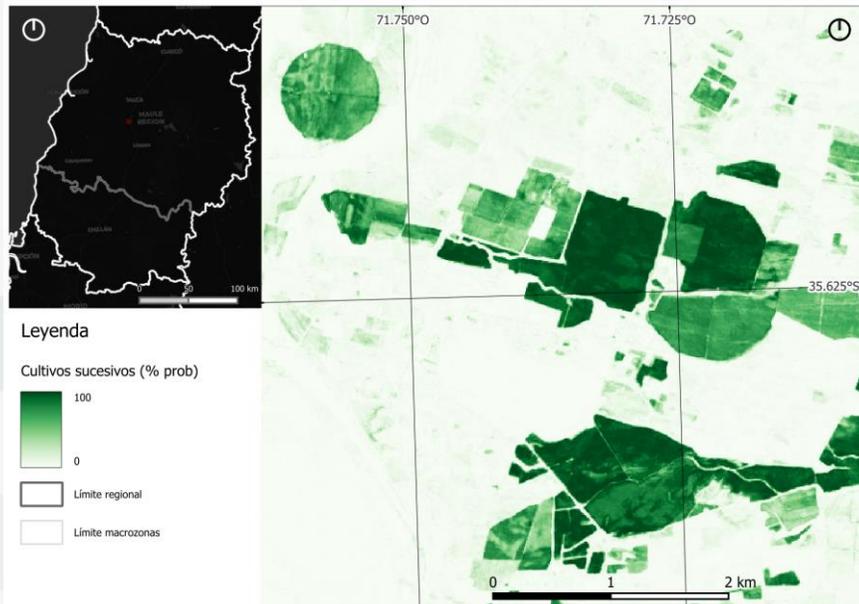
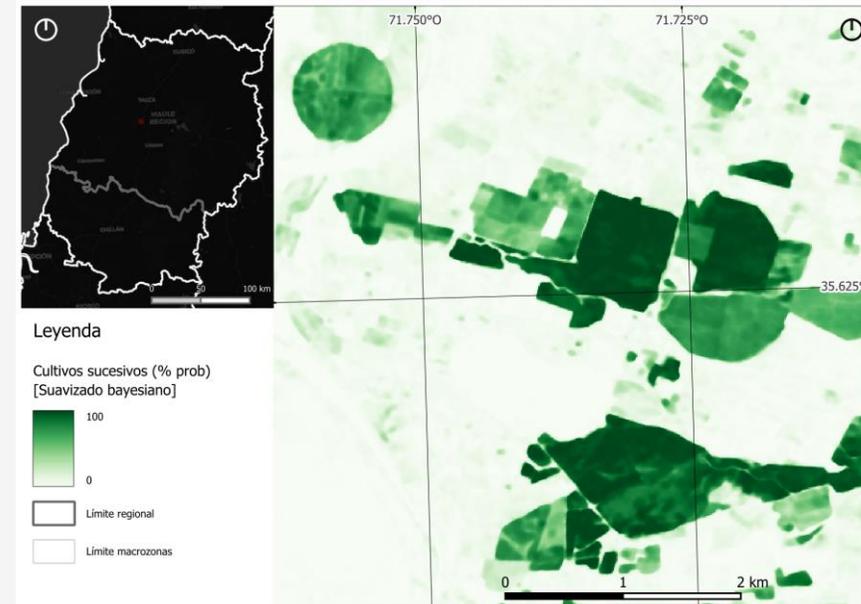


Figura: Probabilidad es para la clase Cultivos sucesivos

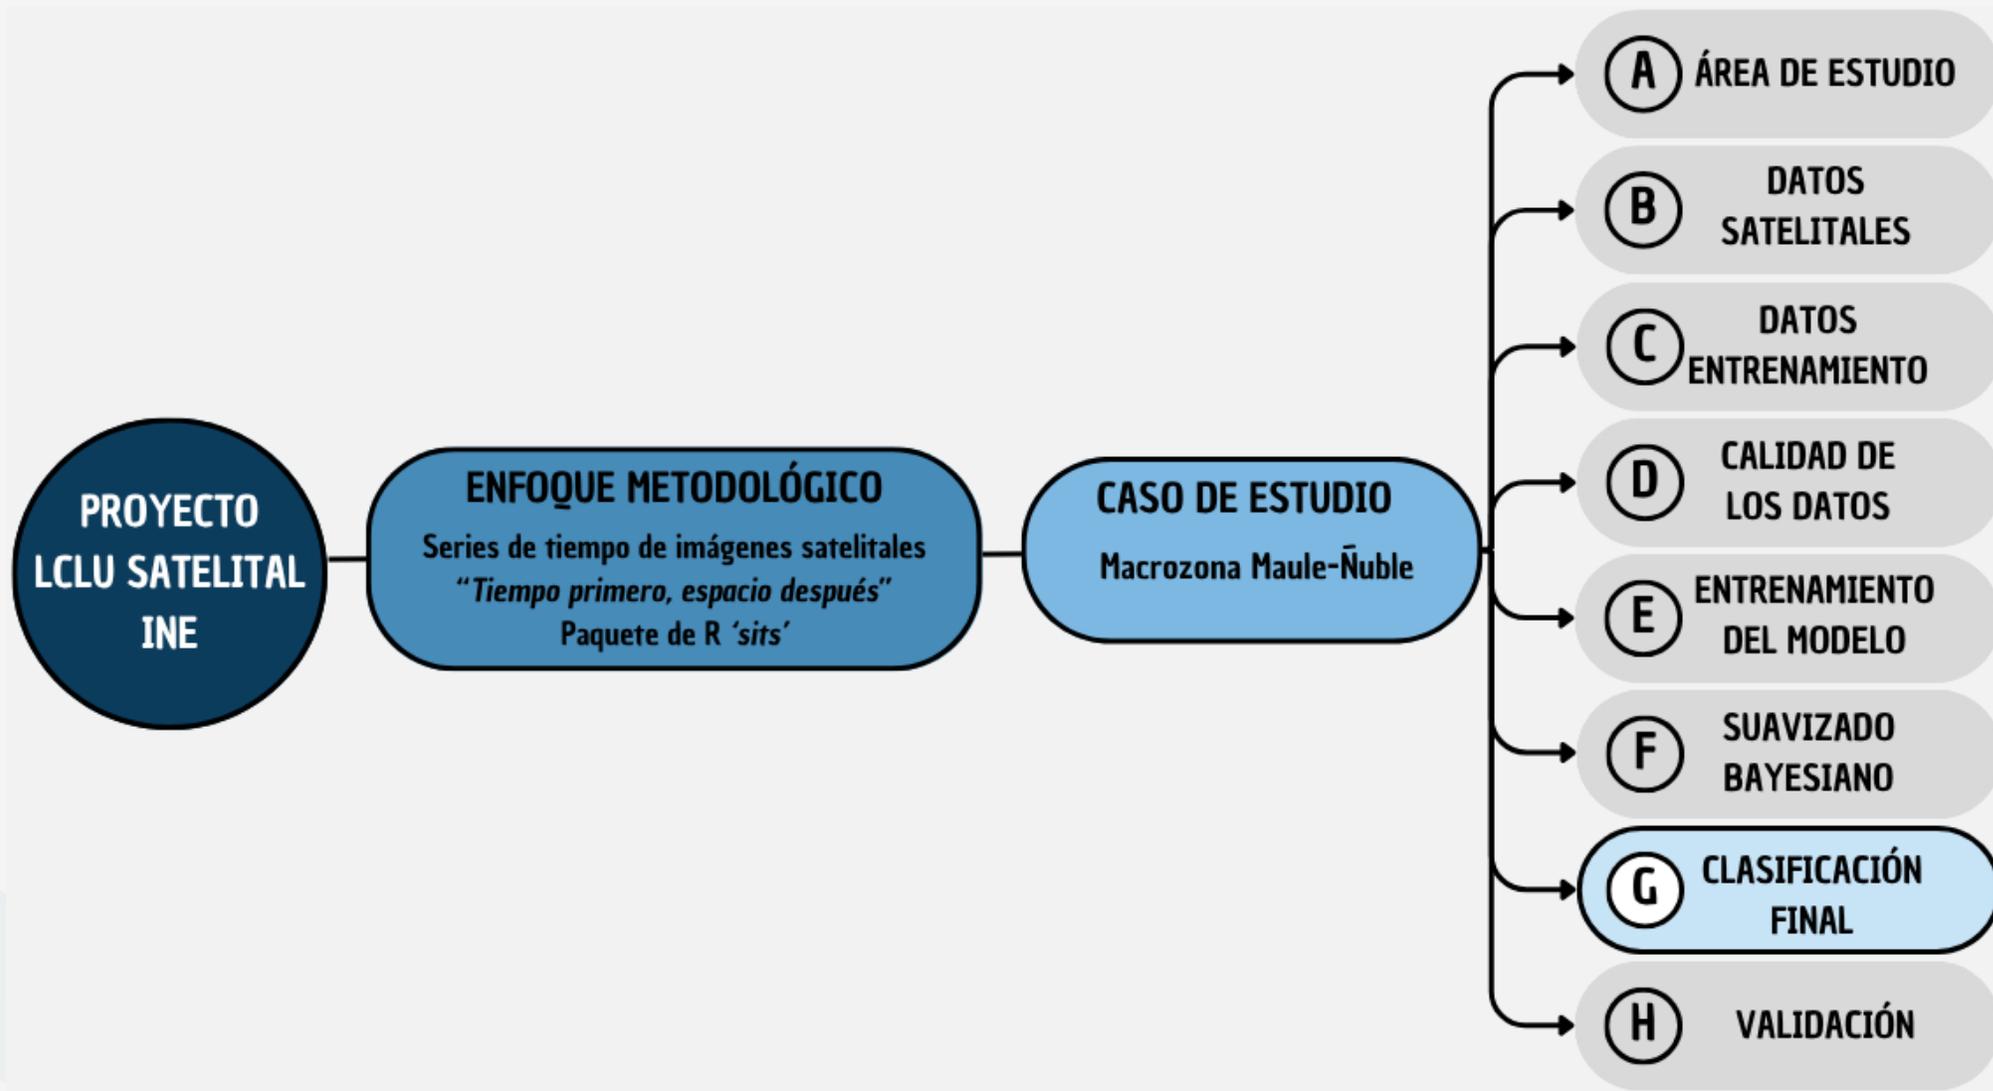


Fuente: Instituto Nacional de Estadísticas

Figura: Probabilidades suavizadas para la clase Cultivos sucesivos

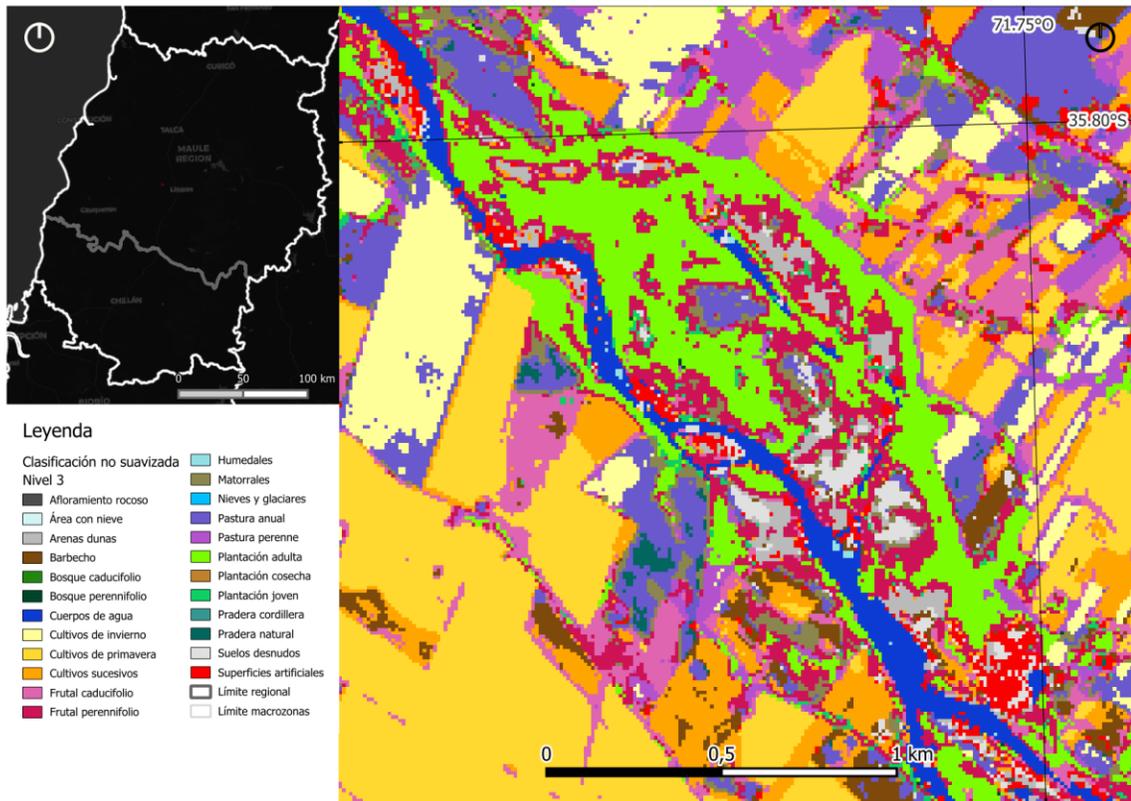


Fuente: Instituto Nacional de Estadísticas



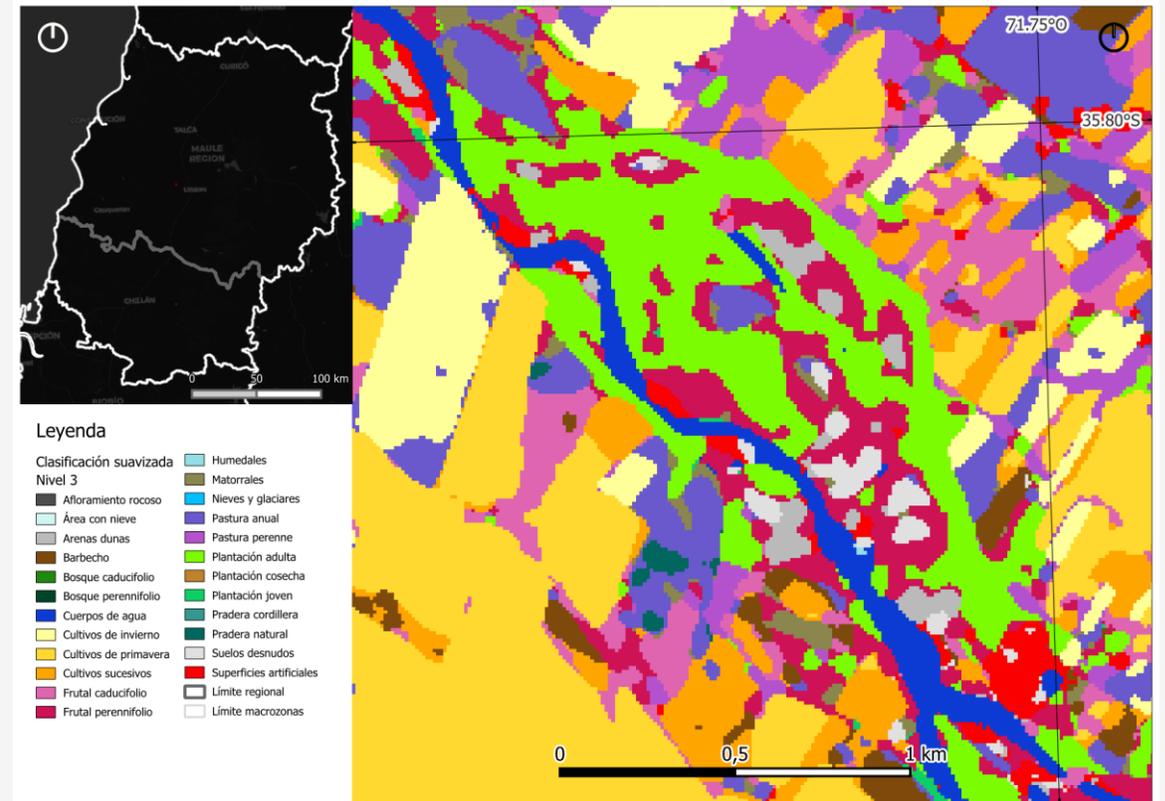
# G. Clasificación final

Figura: Detalle de mapa producido mediante un RF basado en píxeles sin suavizado



Fuente: Instituto Nacional de Estadísticas

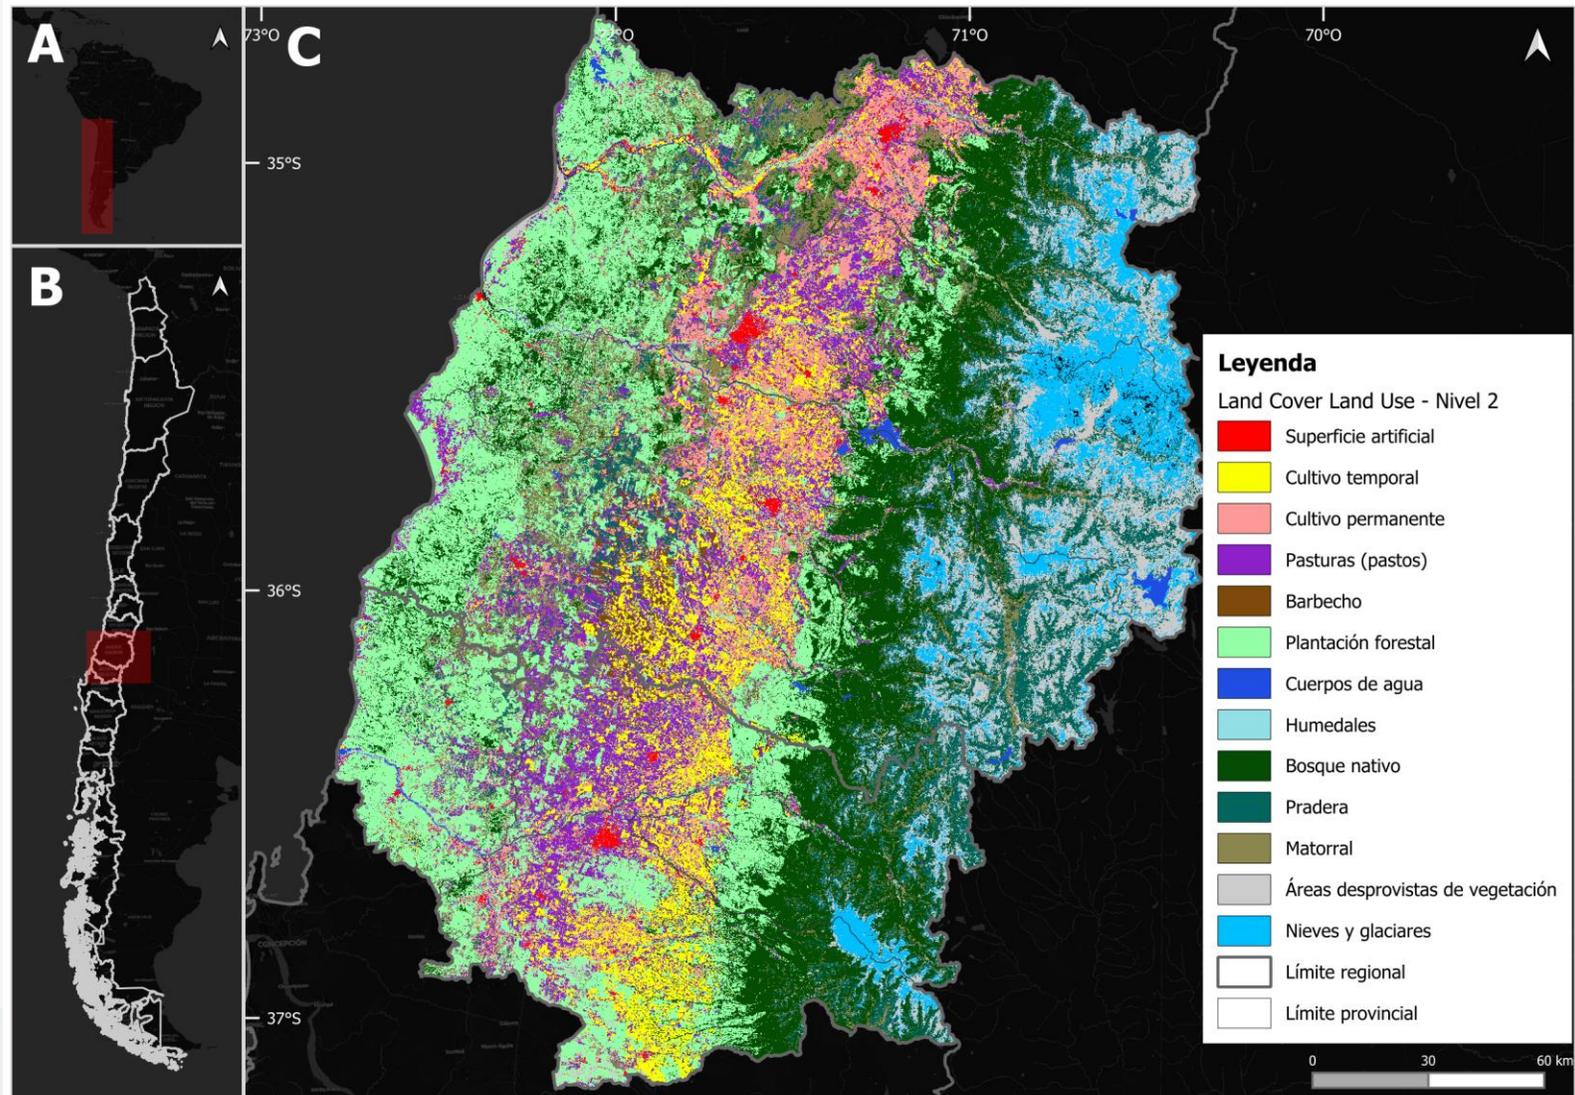
Figura: Detalle de mapa producido mediante un RF basado en píxeles con suavizado



Fuente: Instituto Nacional de Estadísticas

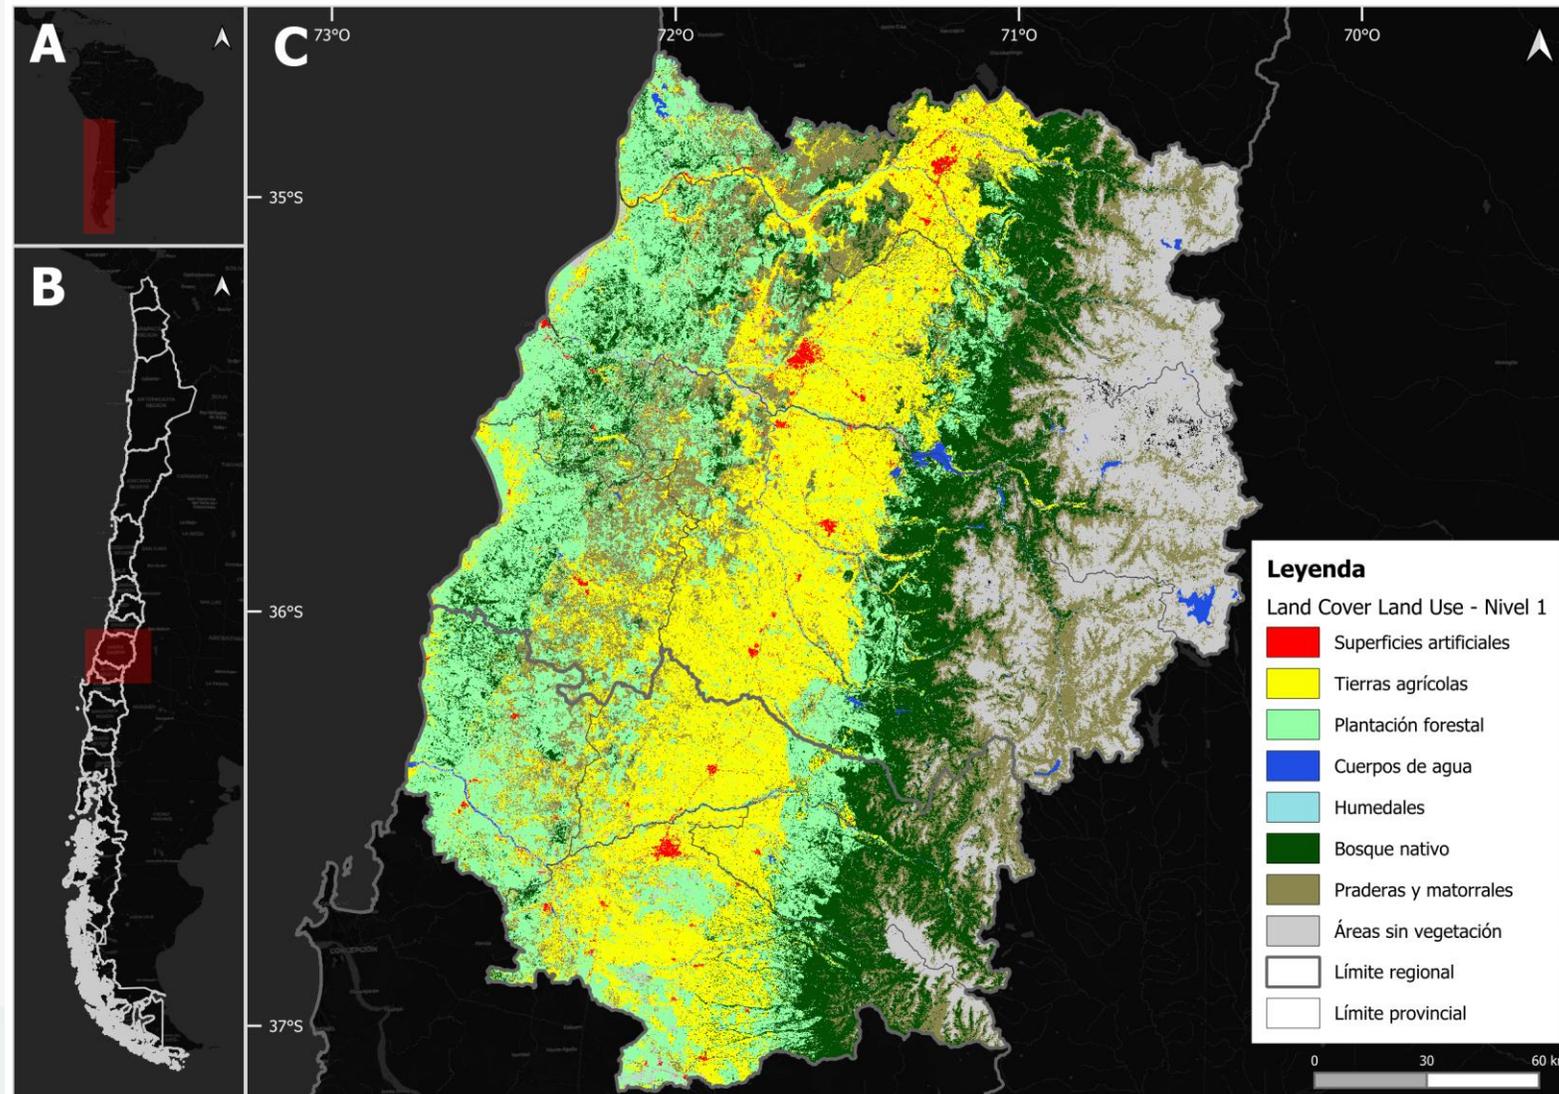
# G. Clasificación final

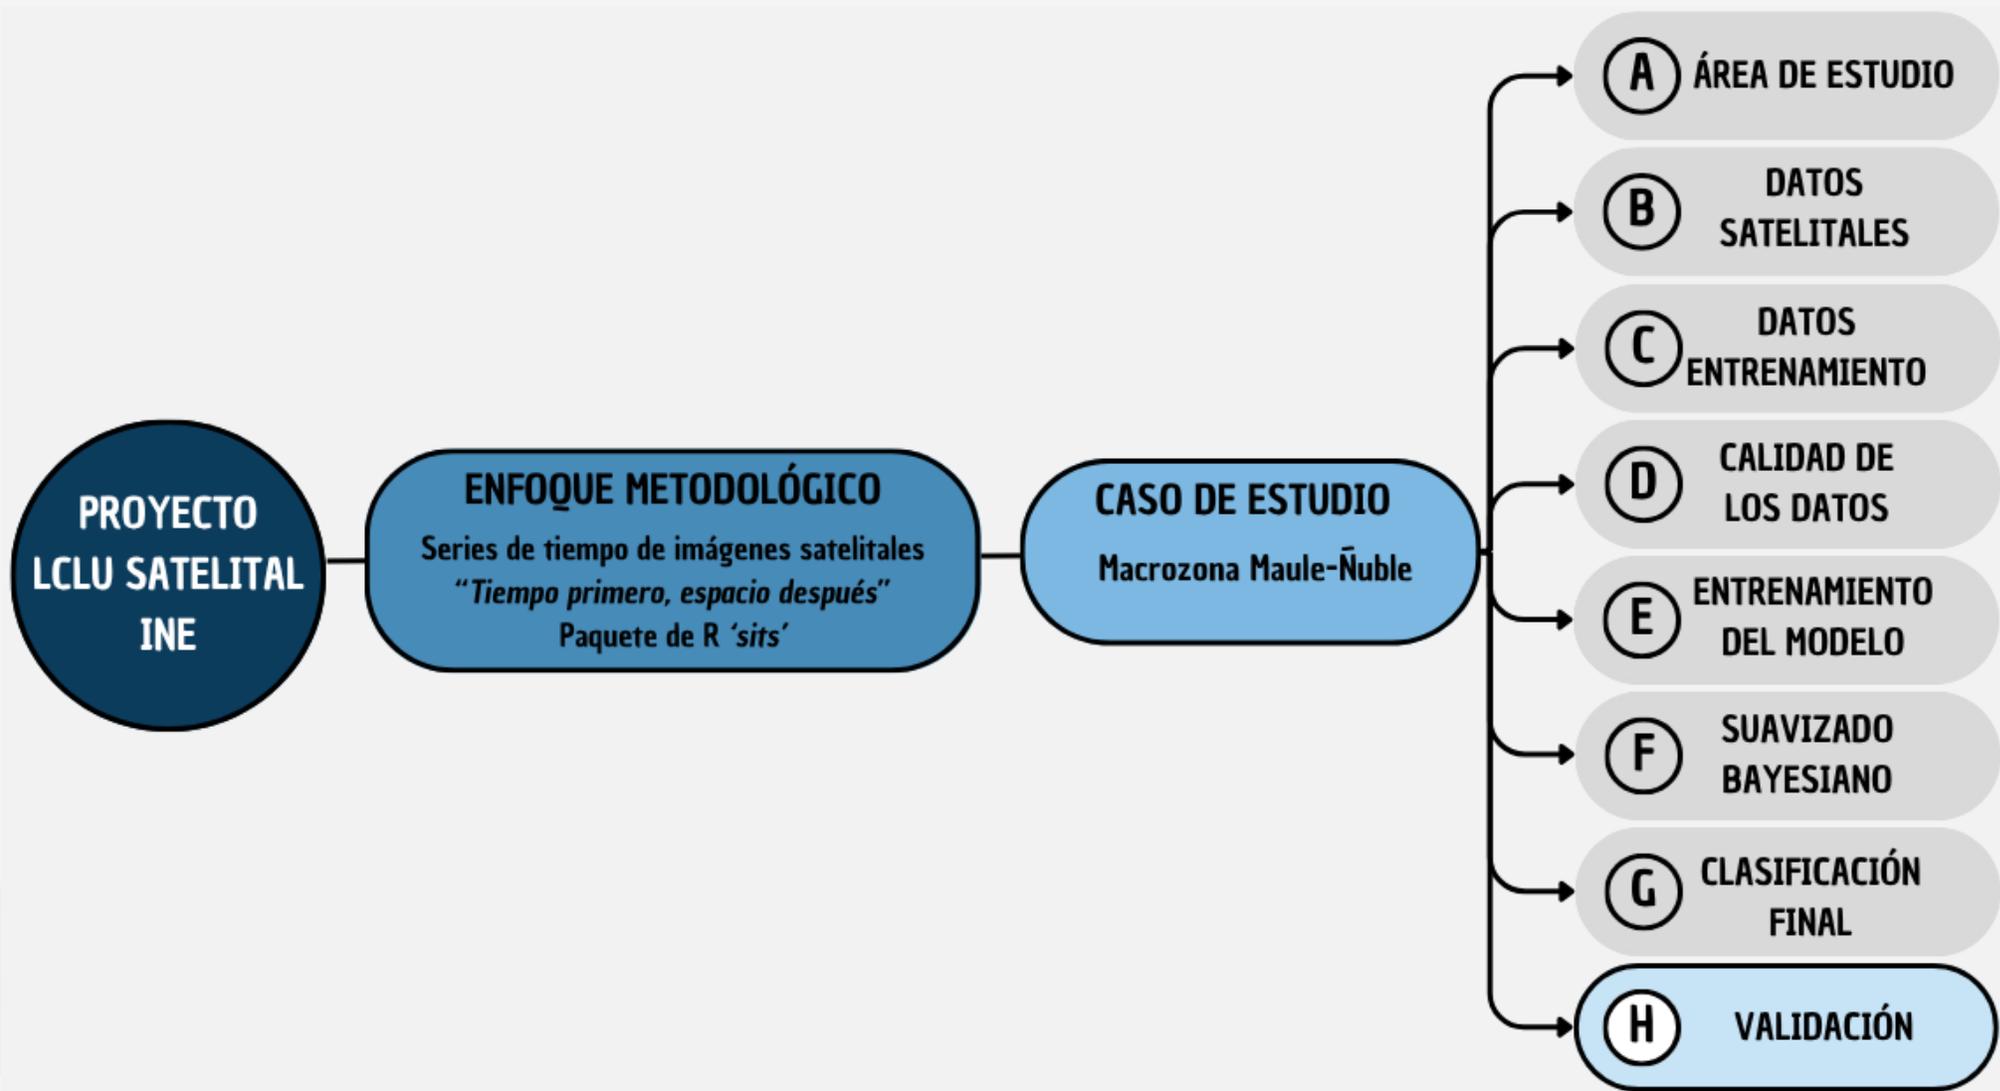
Figura: Mapa LCLU Satelital Nivel 2 Macrozona Maule-Ñuble



# G. Clasificación final

Figura: Mapa LCLU Satelital Nivel 1 Macrozona Maule-Ñuble





Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation

Pontus Olofsson <sup>a,\*</sup>, Giles M. Foody <sup>b</sup>, Stephen V. Stehman <sup>c</sup>, Curtis E. Woodcock <sup>a</sup>

2013

Good practices for estimating area and assessing accuracy of land change

Pontus Olofsson <sup>a,\*</sup>, Giles M. Foody <sup>b</sup>, Martin Herold <sup>c</sup>, Stephen V. Stehman <sup>d</sup>,  
Curtis E. Woodcock <sup>a</sup>, Michael A. Wulder <sup>e</sup>

2014

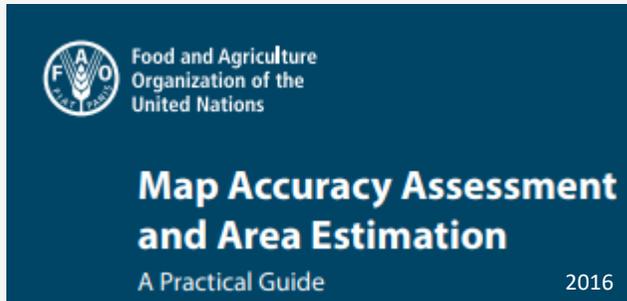
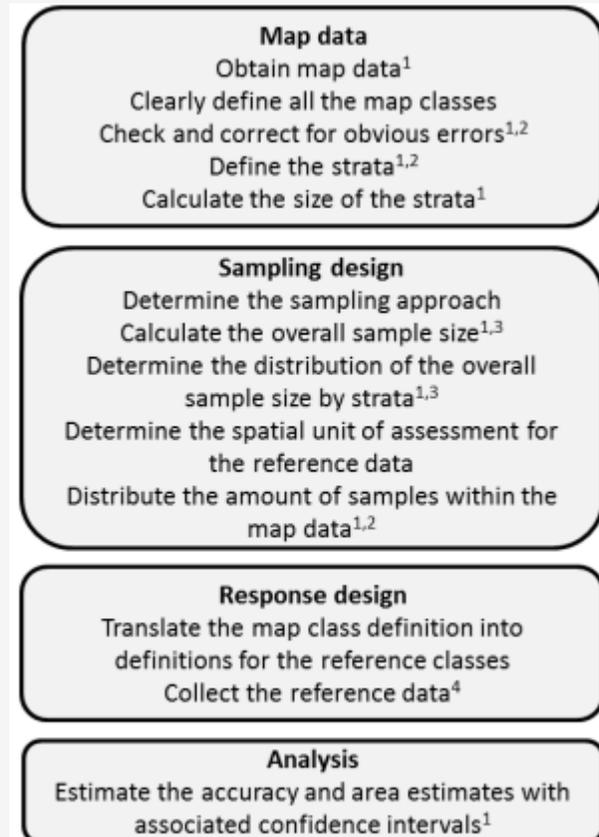


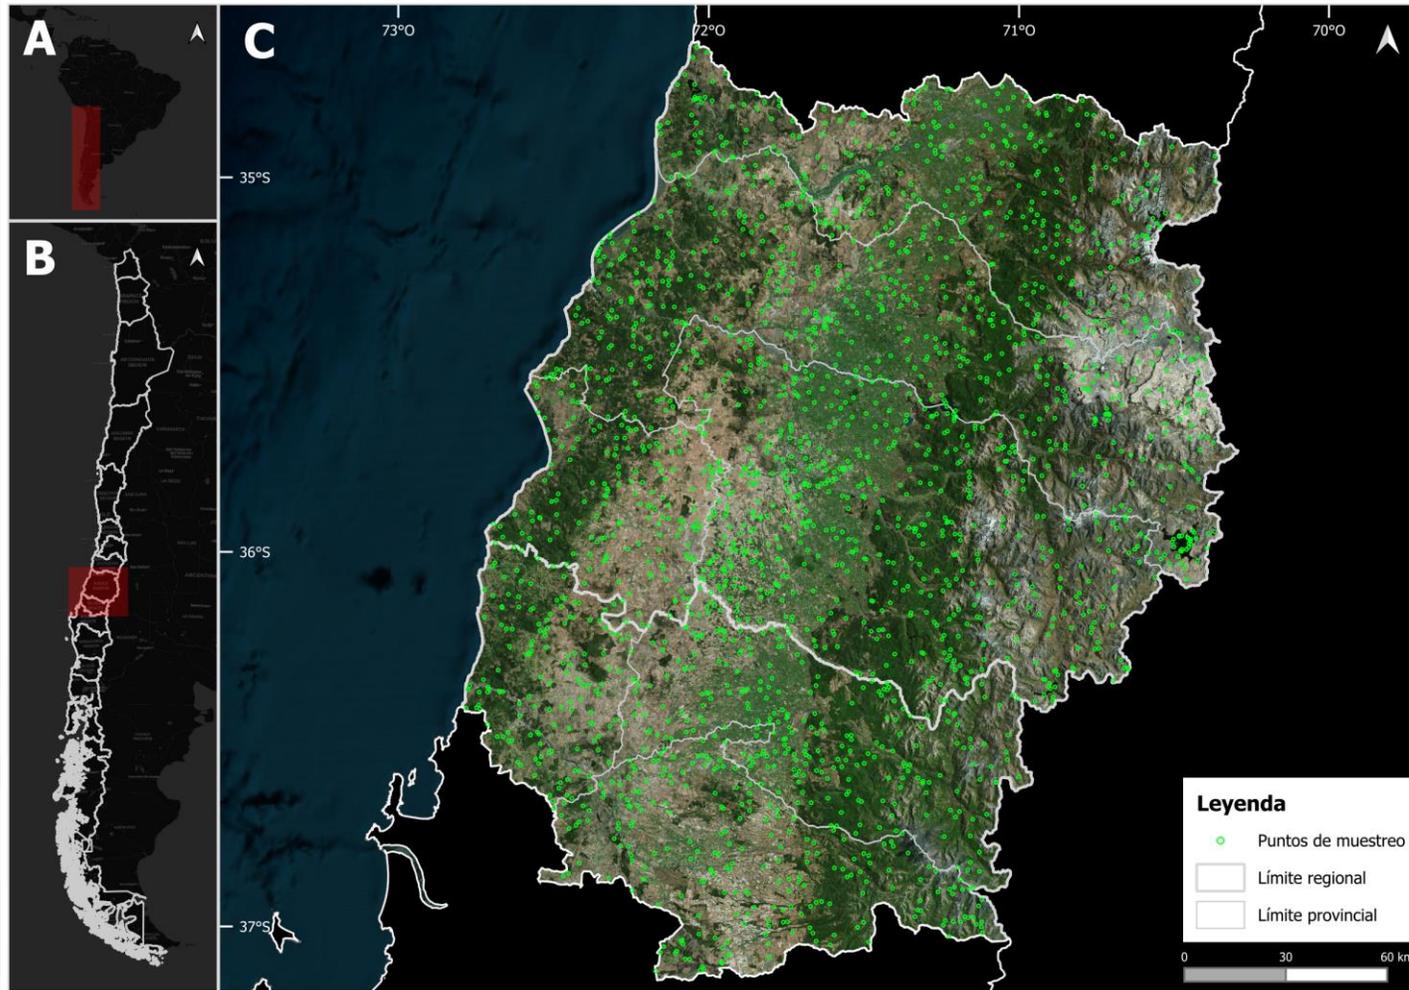
Figura: Los cuatro pasos principales para la estimación de precisión



Fuente: FAO, 2016

# H. Validación

Figura: Distribución espacial de los puntos de muestreo para validación MZ4



Fuente: Instituto Nacional de Estadísticas

Figura: Estimación de área y área ajustada por clase (Prueba piloto Maule)

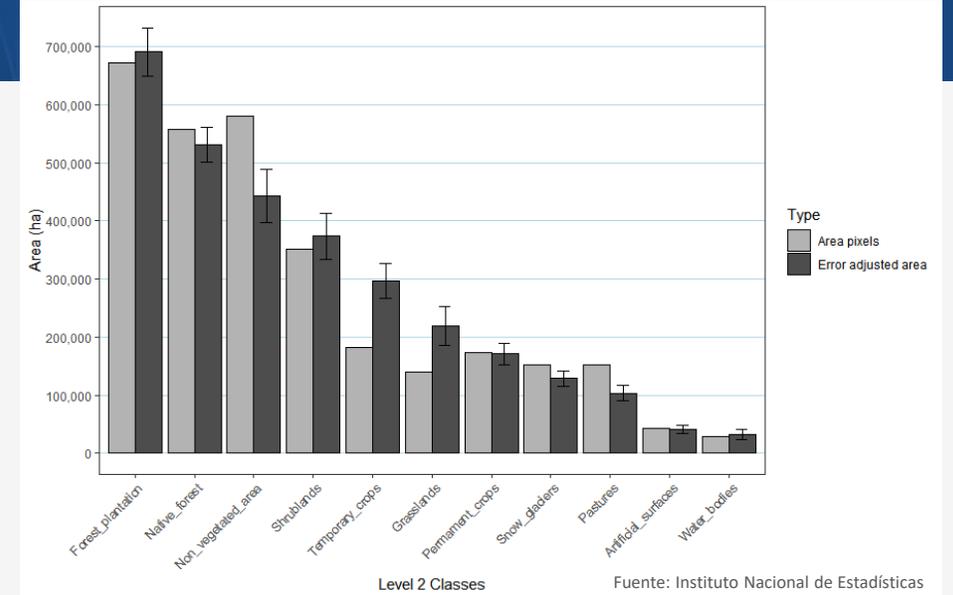
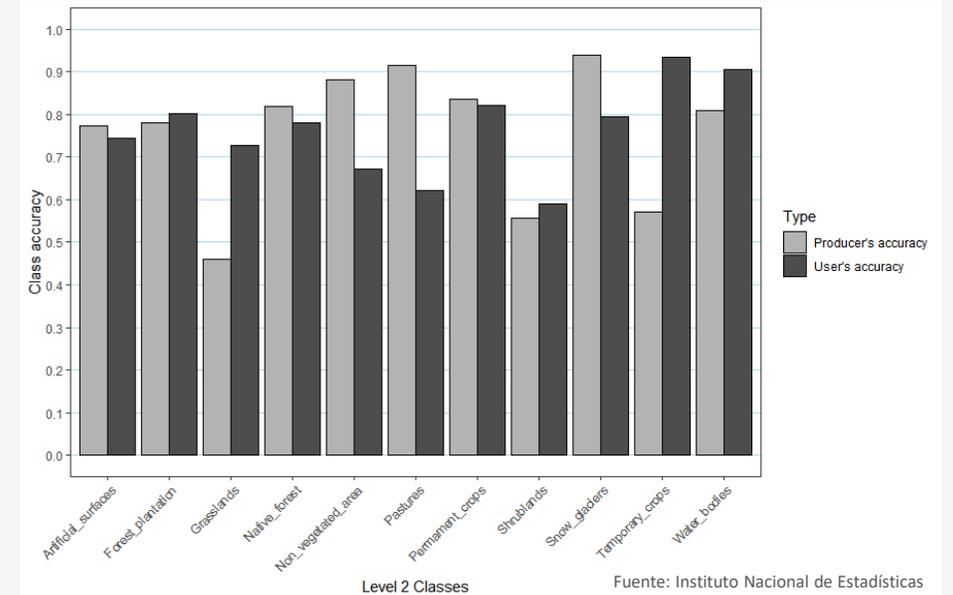
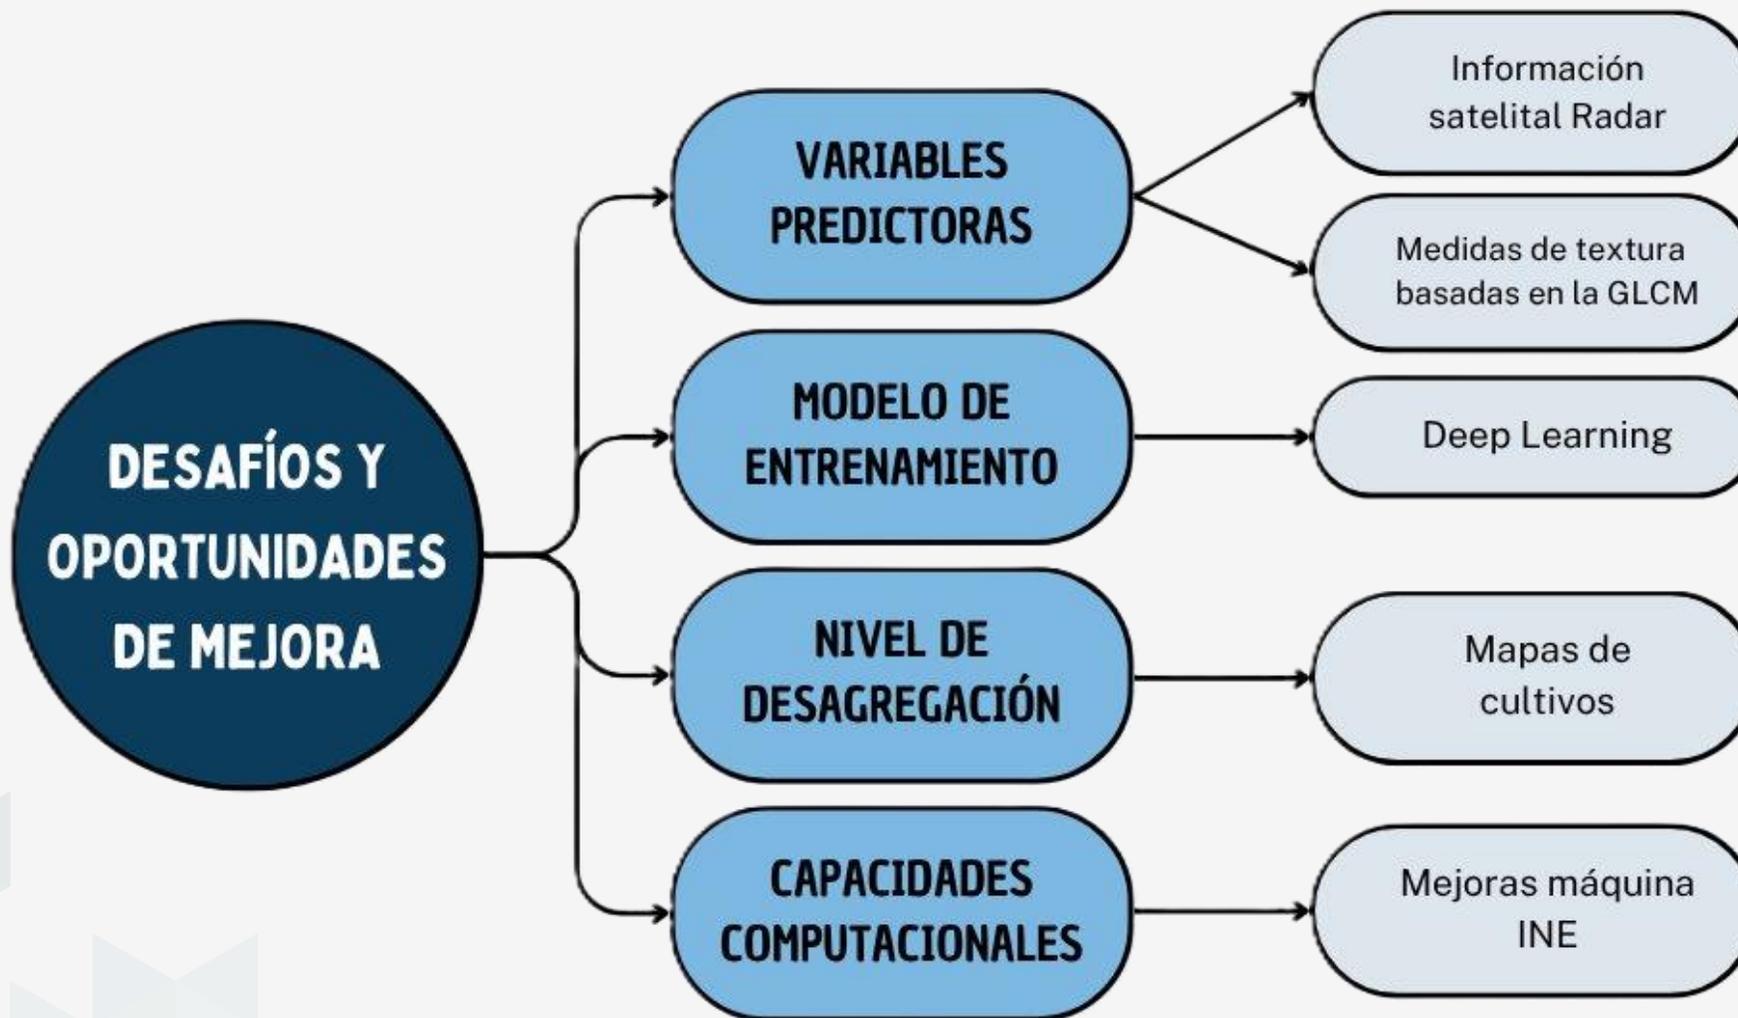


Figura: Métricas de precisión ajustada por clase (prueba piloto Maule)



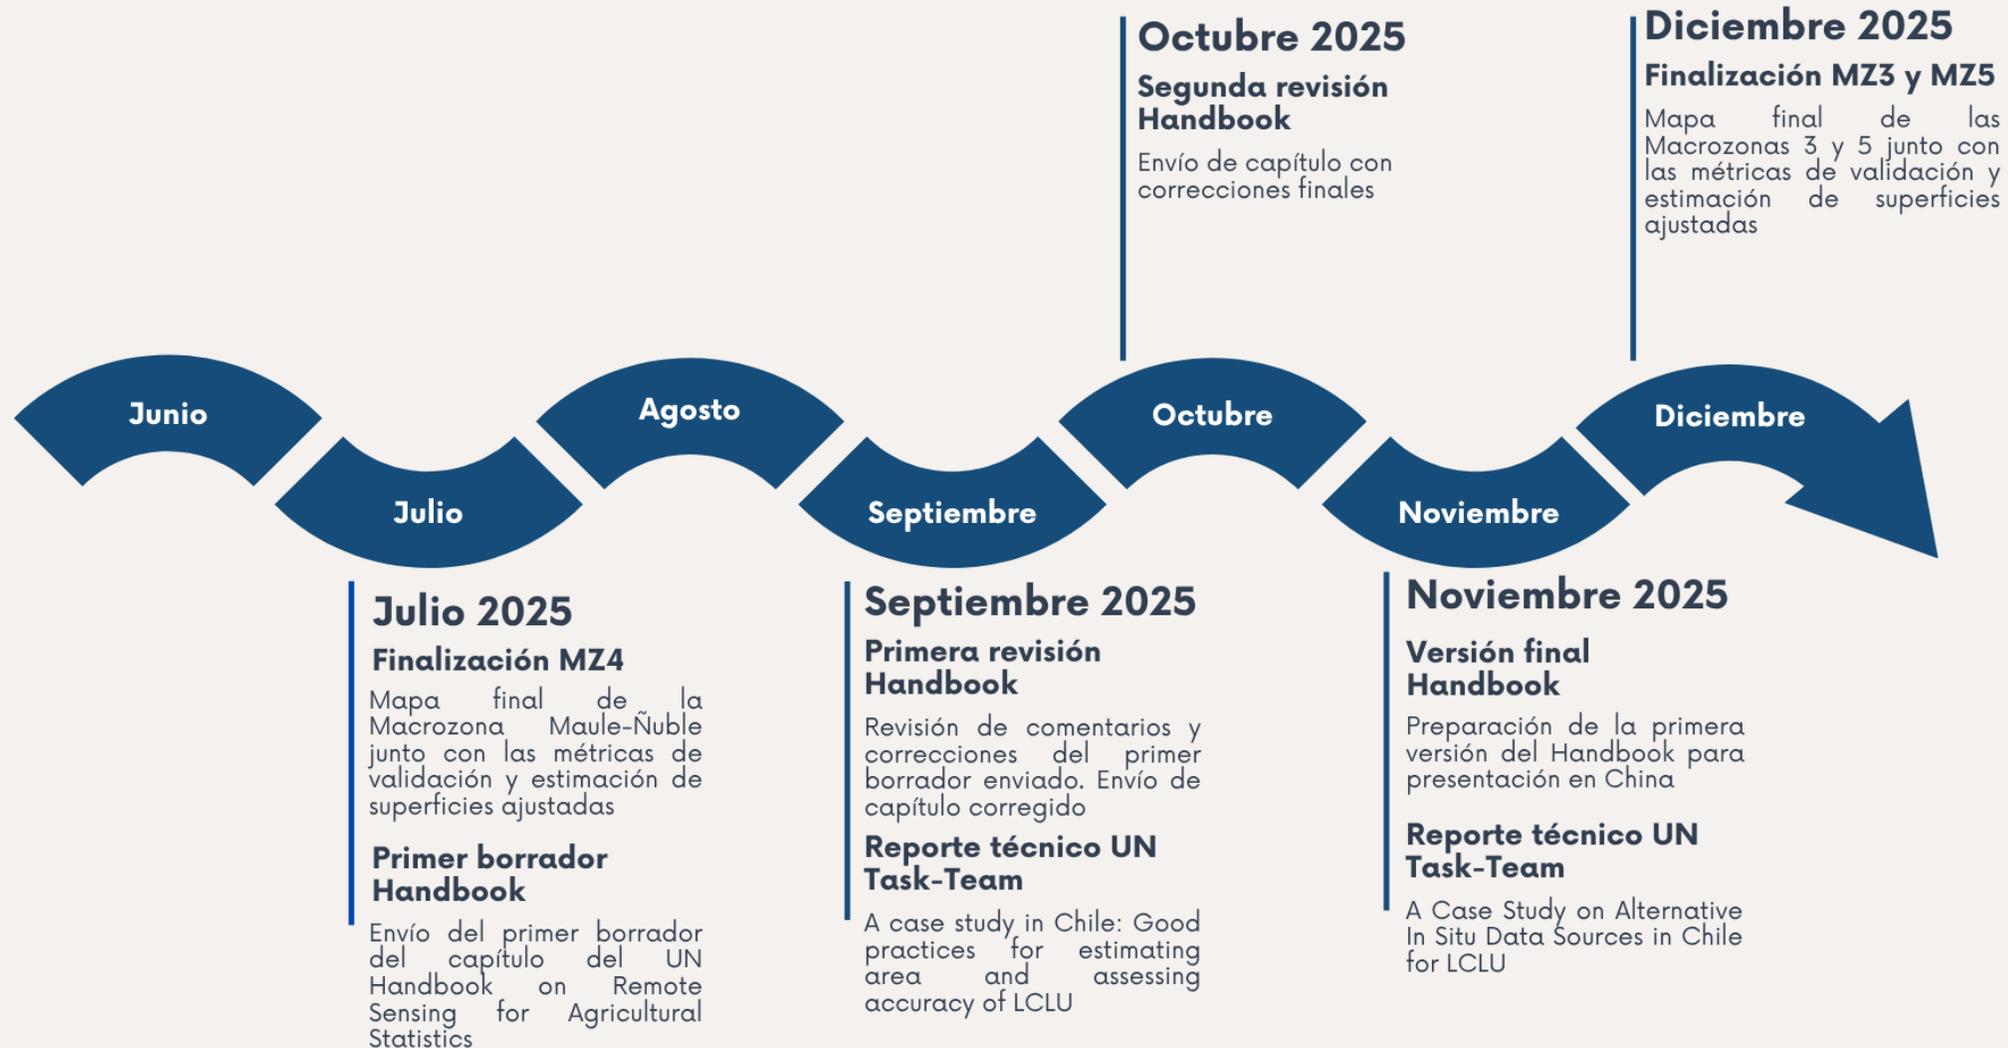
# 3.

## Desafíos y oportunidades de mejora



# 4.

## Próximos pasos



## Primer semestre 2026

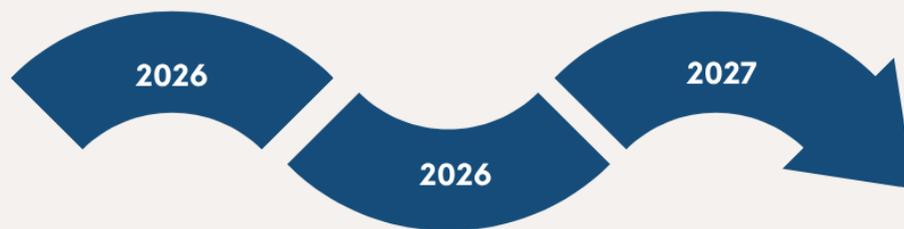
### Finalización 4<sup>ta</sup> y 5<sup>ta</sup> Macrozona

Mapa final de la cuarta y quinta macrozona junto con las métricas de validación y estimación de superficies ajustadas

## Primer semestre 2027

### Finalización 8<sup>va</sup> y 9<sup>na</sup> Macrozona

Mapa final de la octava y novena macrozona junto con las métricas de validación y estimación de superficies ajustadas



## Segundo semestre 2026

### Finalización 6<sup>ta</sup> y 7<sup>ma</sup> Macrozona

Mapa final de la sexta y séptima macrozona junto con las métricas de validación y estimación de superficies ajustadas

# 5.

## Aportes de la Percepción Remota a la producción de estadísticas oficiales



## Mapeo de límites de parcelas

- Facilita proceso de registro de agricultores y vinculación de la identificación del agricultor a las parcelas
- Acelera las operaciones de censos y encuestas agrícolas

01



## Mapeo de tipos de cultivos

- Estadísticas de la superficie de cultivo
- Mayor precisión (reducción del coeficiente de variación)
- Mejor diseño de encuestas agrícolas
- Detección de cambios intra e inter anuales

02



## Estimación de rendimiento

- Estimación de producción agrícola
- Mejora en estimaciones indirectas de rendimiento en zonas sin encuesta
- Complemento de encuestas tradicionales; uso de estimadores de regresión

03



## Diseño muestral

- Actualización eficiente de marcos de área
- Estratificación temática y espacial
- Selección de UPM con criterios geoespaciales
- Estimación áreas pequeñas

04



## Predicción y cartografía de desastres socionaturales

- Identificación de zonas afectadas por sequías, inundaciones, heladas
- Evento de pronóstico
- Evaluación de impactos (daños en superficie cultivada)

05



## Producción de estadísticas ambientales y climáticas

- Indicadores de sostenibilidad (uso de suelo, degradación, emisiones)
- Reportes vinculados a los ODS (Objetivos de Desarrollo Sostenible)

06



## Desarrollo de estadísticas urbanas

- Delimitación de áreas urbanas y expansión del tejido construido
- Cálculo de indicadores como densidad, acceso a servicios, crecimiento urbano

07



## Aumento de eficiencia operativa

- Monitoreo remoto de grandes extensiones de territorio
- Mayor frecuencia de actualización con menor presupuesto
- Control de calidad de los datos

08



Gracias por su atención

ine.gob

