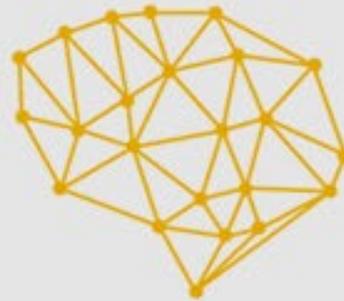


# Minsait Land Classification

Equipo MATRICS



**UNIVERSITYHACK 2020<sup>®</sup>**  
**DATAATHON**



minsait  
by Indra

idealista/data



VIEWNEXT  
AN IBM SUBSIDIARY

**CUNEF**  
COLEGIO UNIVERSITARIO DE  
ESTUDIOS FINANCIEROS

# Cajamar UniversityHack 20 – Reto: Mindsait Land Classification

---



**Juan Villasante Guerrero**  
Graduado en ADE



**Miguel López Garralón**  
Graduado en Periodismo



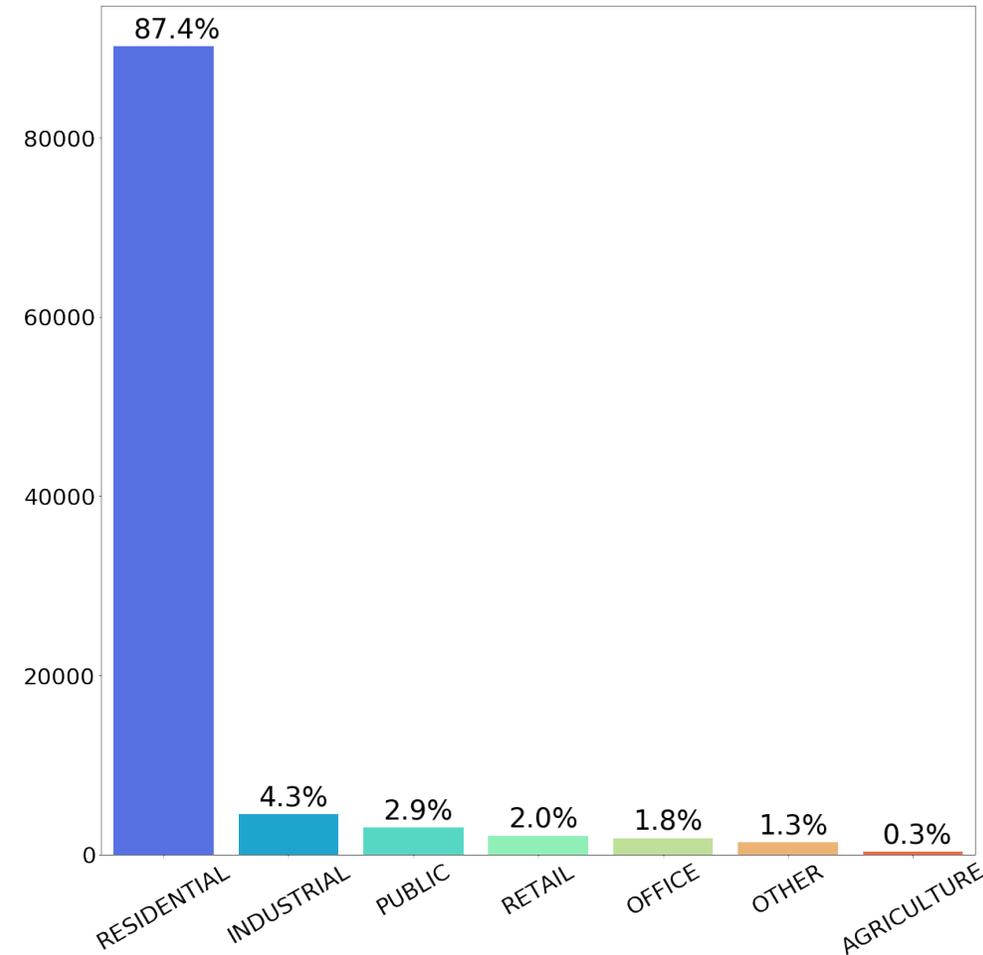
**Beltrán Aller López**  
Graduado en ADE

## Índice

1. Objetivo
2. Algoritmos
3. Métrica
4. Reducción de la dimensión
5. Construcción de variables
6. Equilibrio
7. Conclusiones

## Objetivo

- Objetivo: clasificación de parcelas
- Problema **multiclase** con fuerte **desequilibrio**
- Existencia de valores extremos en la variable área
- Muy pocos valores ausentes
- Modelos basados en **ensembles**



# Algoritmos

## ALGORITMOS PROBADOS

Lightgbm  
Catboost  
Xgboost  
Random Forest  
Votingclassifier  
SVM  
Logistic regression  
Redes neuronales

## MEJORES ALGORITMOS

XGBoost  
Lightgbm  
Catboost

## ALGORITMO ELEGIDO

XGBoost

- Mejor equilibrio entre precisión y cómputo requerido

# Métrica

## ¿Cuál es la métrica adecuada?



## Weighted - Recall

- Información a posteriori
- Distinta distribución del target en datos a modelar y a estimar
- Mayor peso de clases minoritarias
- **Mejorar *recall*** de las clases minoritarias para aumentar la precisión en test
- **Verificar resultados** con menor incertidumbre

Aplicamos un peso 4 veces mayor



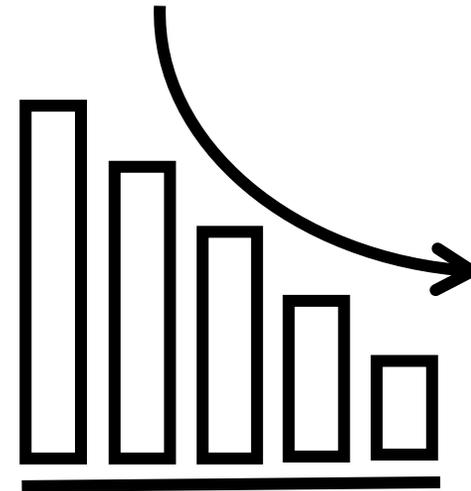
Reducción de peso de la clase mayoritaria



# Reducción de la dimensión

---


- **Análisis PCA**
  - Variables de canales de color
  - **Kernel lineal**
  - De 44 variables a **5 componentes**
  - Mantenemos el **98,7% de la varianza explicada**
  - **Ganancia en rendimiento**, aunque con pérdida de explicabilidad



# Construcción de nuevas variables

---

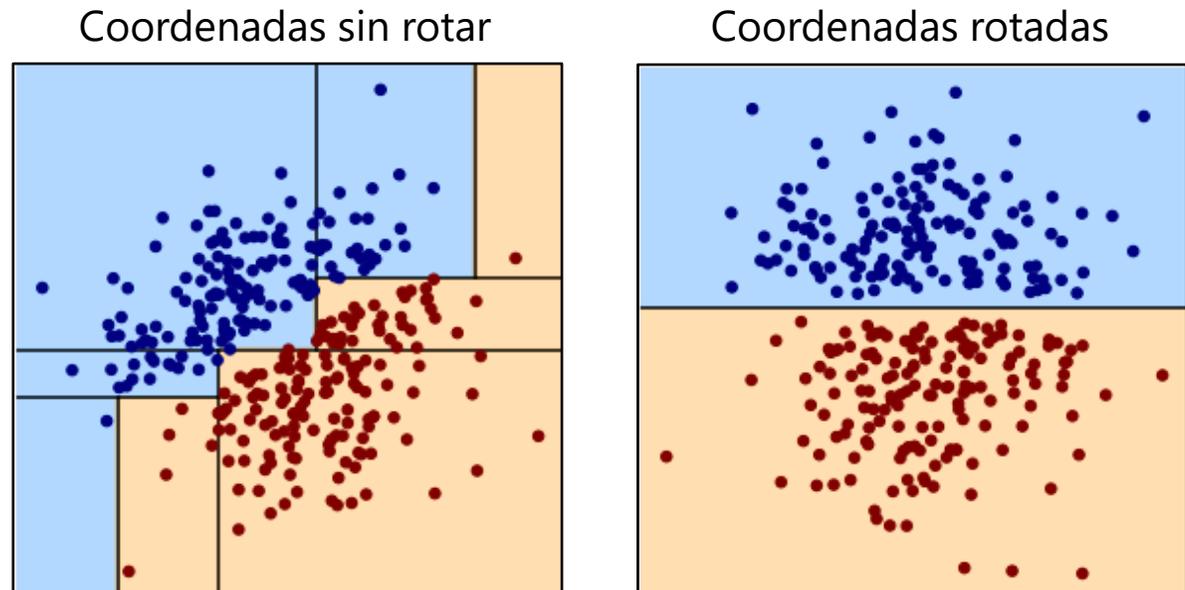
- **Distancia al centro**
  - Estandarización de las coordenadas
  - Diferente distribución de clases entre centro y periferia



# Construcción de nuevas variables

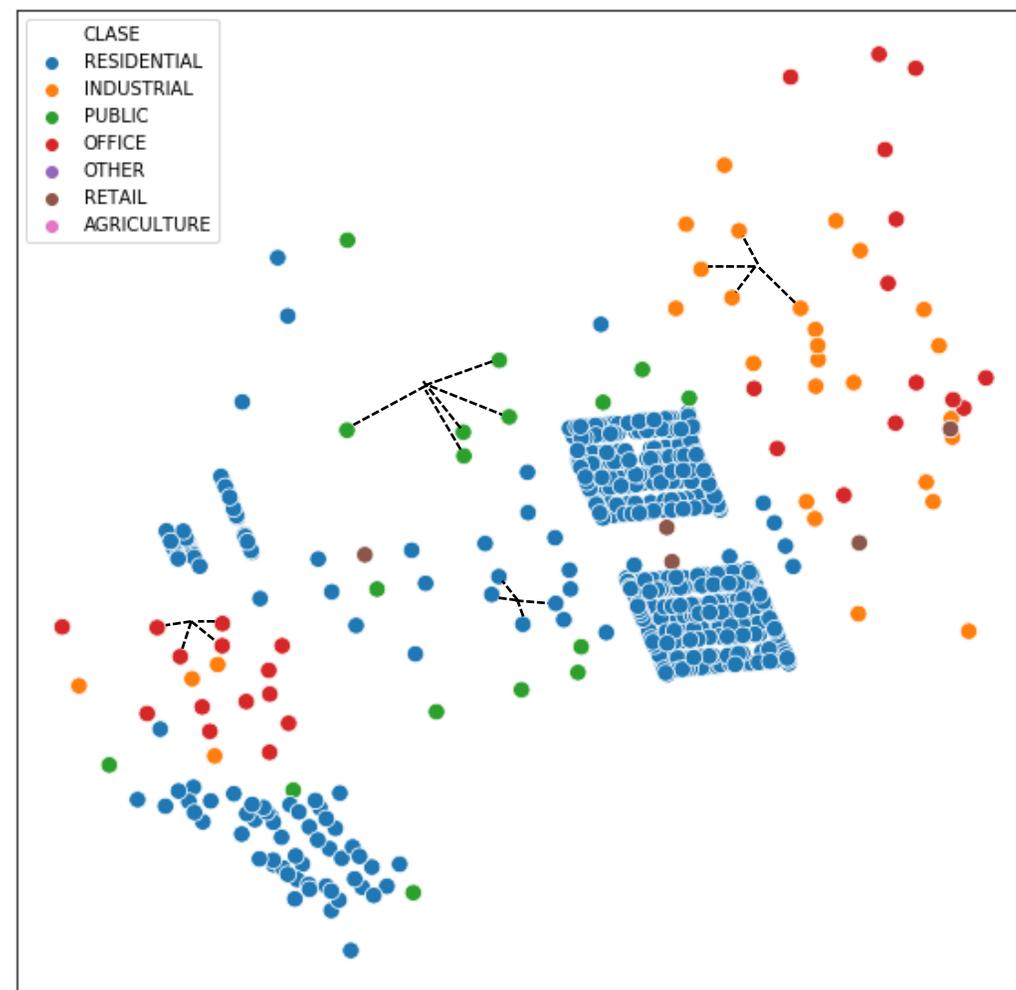
## ▪ Rotación de coordenadas

- Algoritmos basados en árboles de decisión (XGBoost)
- Mejor división de las variables espaciales

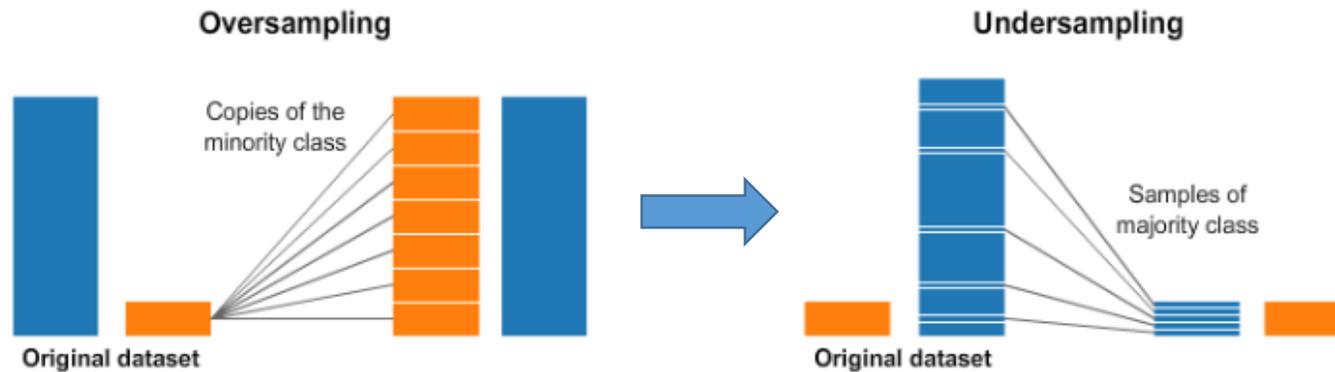


# Construcción de nuevas variables – Posición relativa

- **Densidad**
  - Distancia media a los 5 vecinos
  - Diferentes concentraciones según la clase
- **Moda de la altura**
  - Altura más frecuente de los 15 vecinos
  - Las clases tienden a agruparse
  - Difiere mucho entre clases

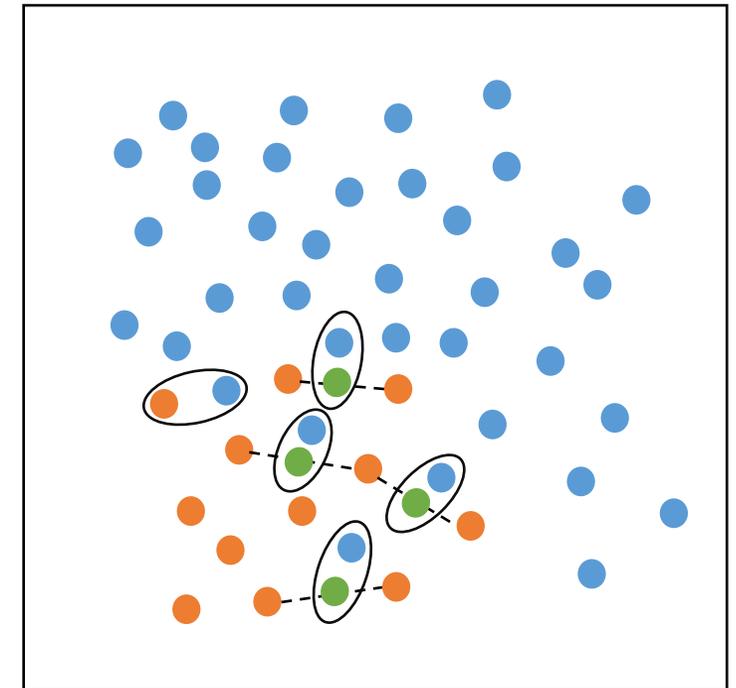


# Equilibrio



- Combinación de **oversampling (SMOTE)** y **undersampling (Tomek's links)**
- Mayor **distanciamiento** entre clases
- Mejor identificación de clases minoritarias

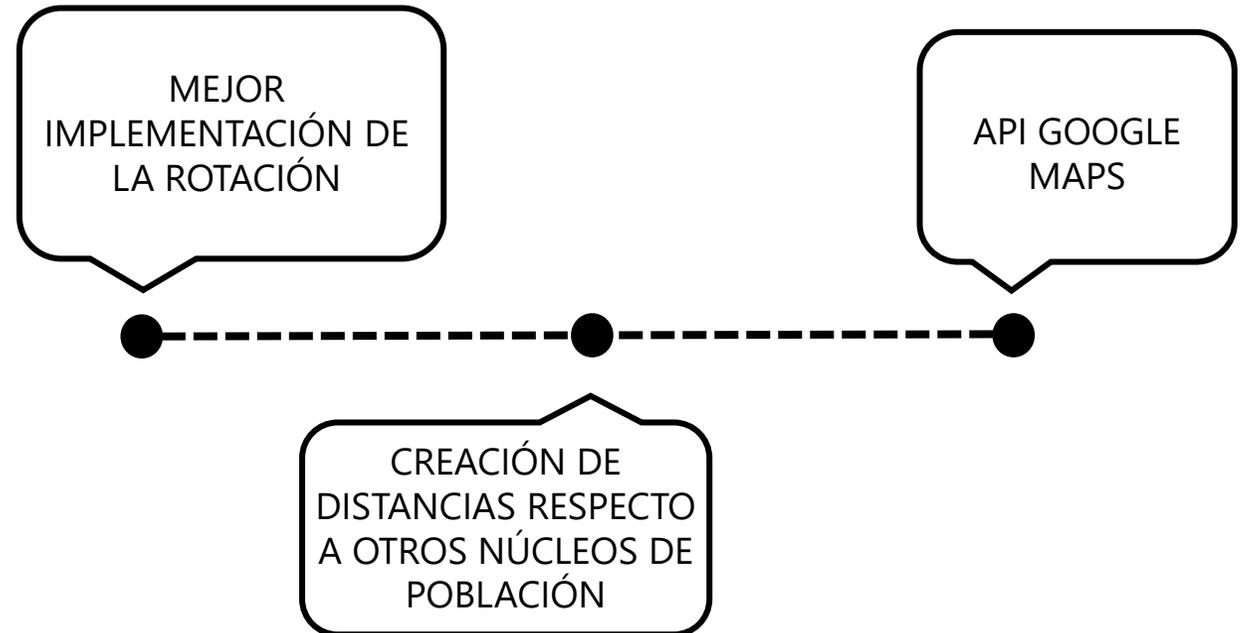
## TOMEK'S LINKS



## Conclusiones

- **Modelo XGBoost**
- Generación de **nueva métrica**
- Creación de **nuevas variables**:
  - Distancia al centro
  - Rotación de las coordenadas
  - Moda de la altura
  - Densidad
- Equilibrio de clases: *SmoteTomek*
- Optimización bayesiana
- Validación cruzada: 4 *Folds*
- **Métrica final: 73%**

## Posibles Mejoras





UNIVERSITYHACK 2020®  
DATAATHON

La competición de analítica de datos  
más grande de España.

Muchas gracias.