



**El futuro  
es de todos**

**DNP**  
Departamento  
Nacional de Planeación



El futuro  
es de todos

DNP  
Departamento  
Nacional de Planeación

# Clasificación de documentos del Diario Oficial

**Unidad de Científicos de Datos**  
Dirección de Desarrollo Digital

Junio, 2019



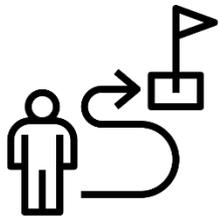
# Descripción del proyecto

Es necesario cuantificar las regulaciones impuestas para cada uno de los sectores productivos del país



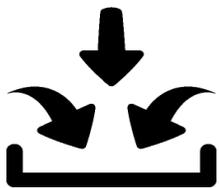
## Objetivo

Implementar técnicas de procesamiento de texto para clasificar normativas dentro de 9 sectores productivos.



## Metodología

1. Procesamiento y limpieza de los documentos
2. Distinguir el tipo de palabras asociadas entre sectores
3. Proponer modelos de clasificación

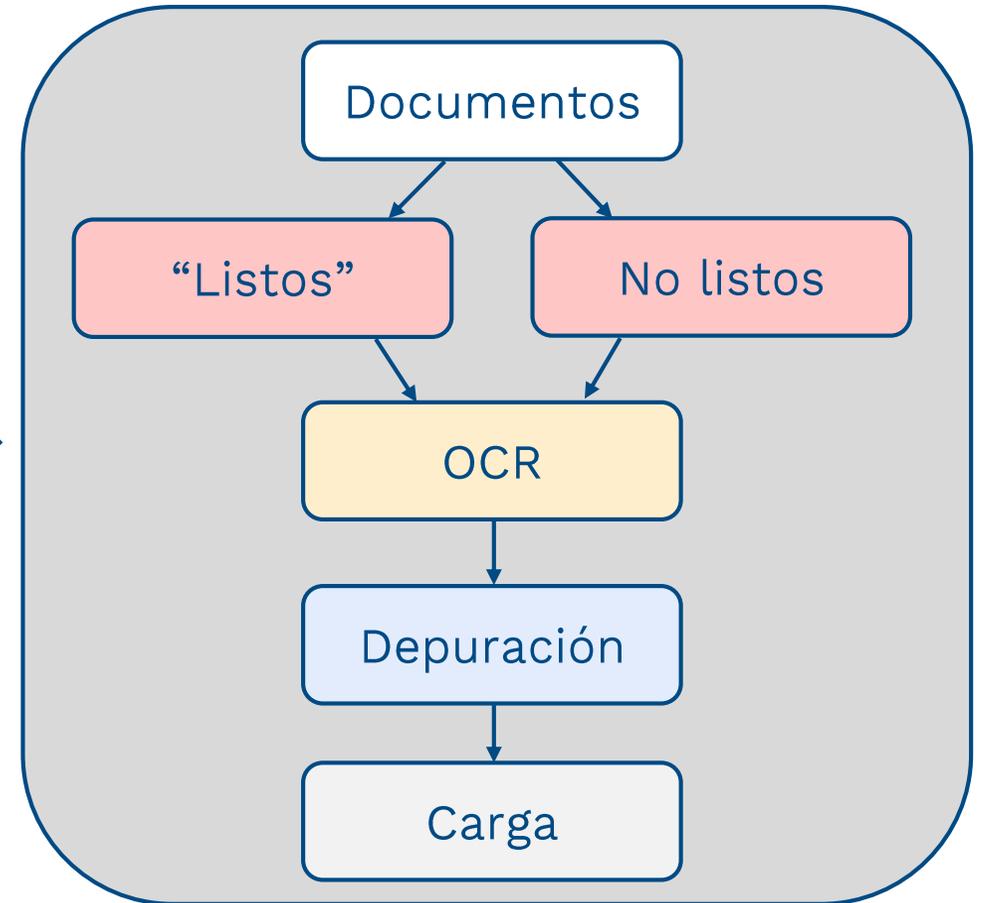
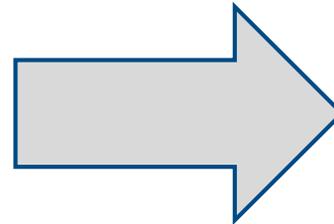
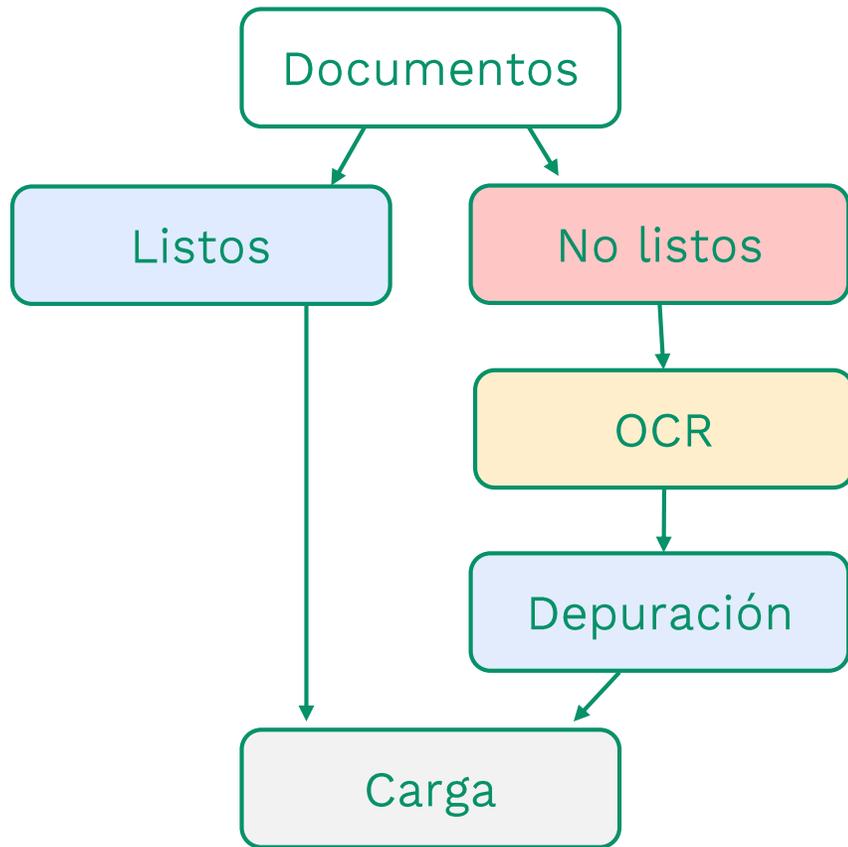


## Insumos

386 documentos compuestos por: Leyes, reformas y decretos, con su correspondiente clasificación (etiqueta).

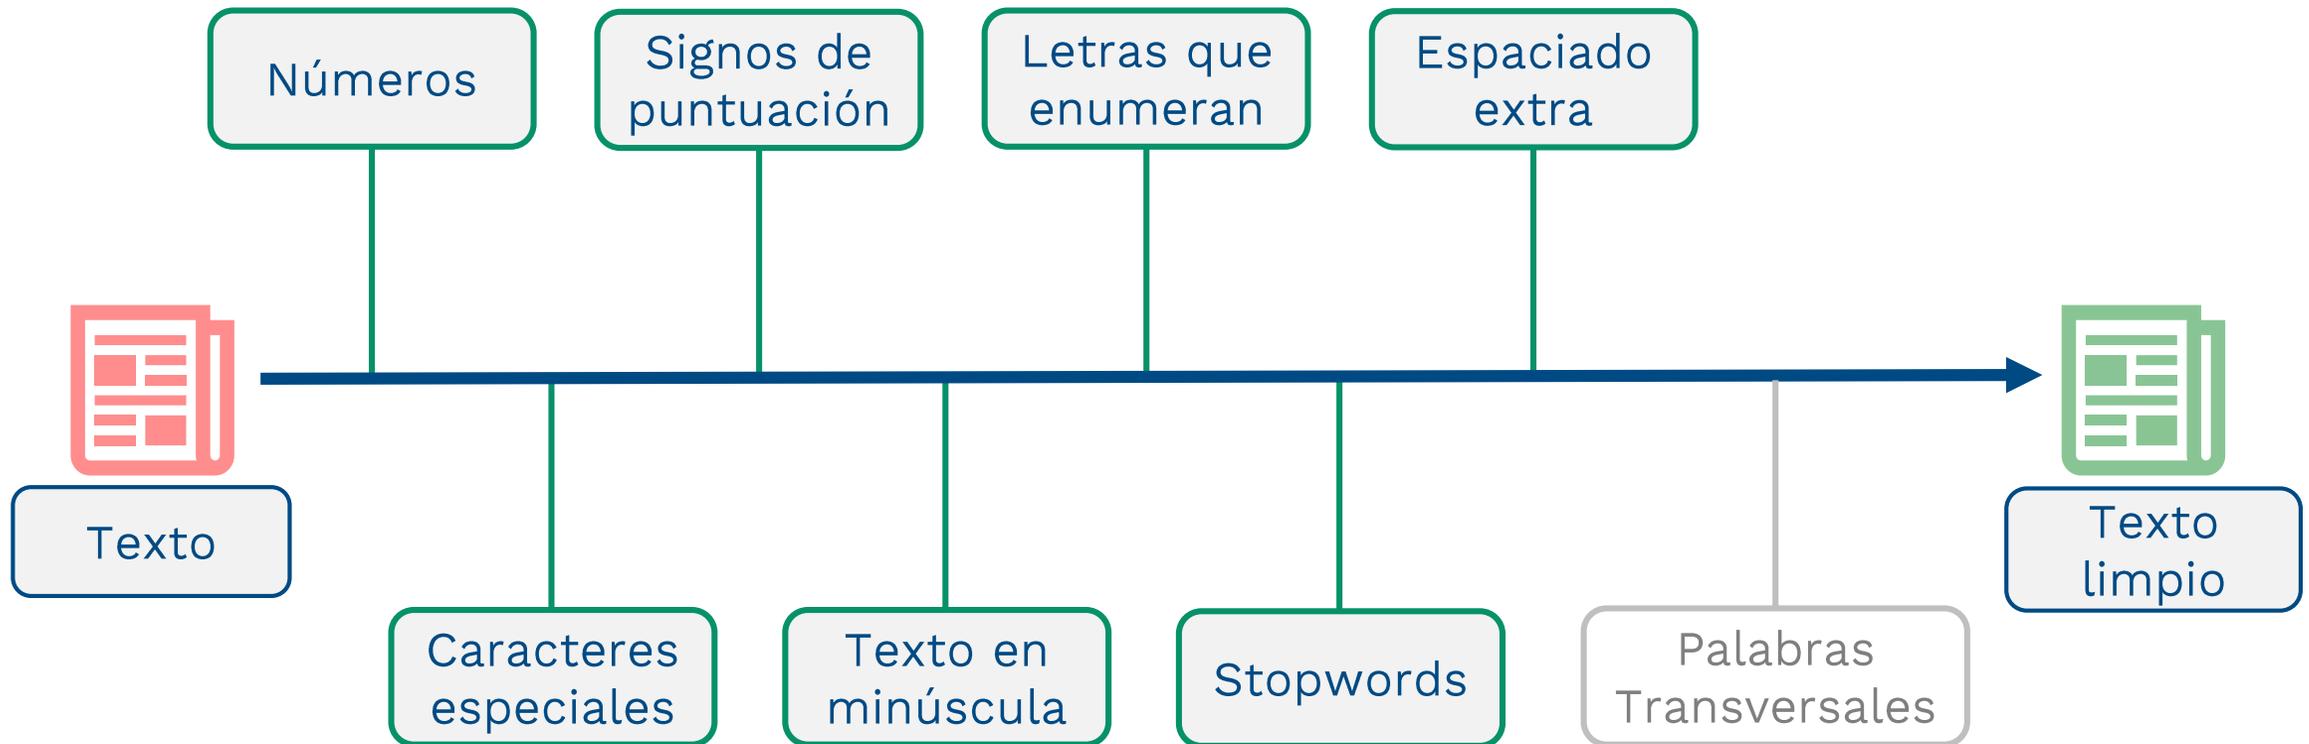
# Carga de los documentos

Uso de un algoritmo de OCR (*tesseract*)



# Limpieza del texto

Se prepararon los documentos para aumentar la calidad de los insumos







# Identificación de palabras

Comparación de palabras frecuentes entre normativas (sector-sector ó subsector-subsector)



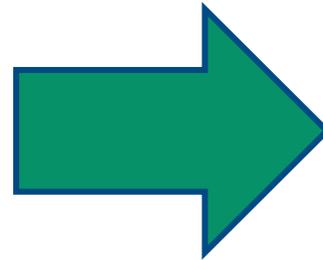
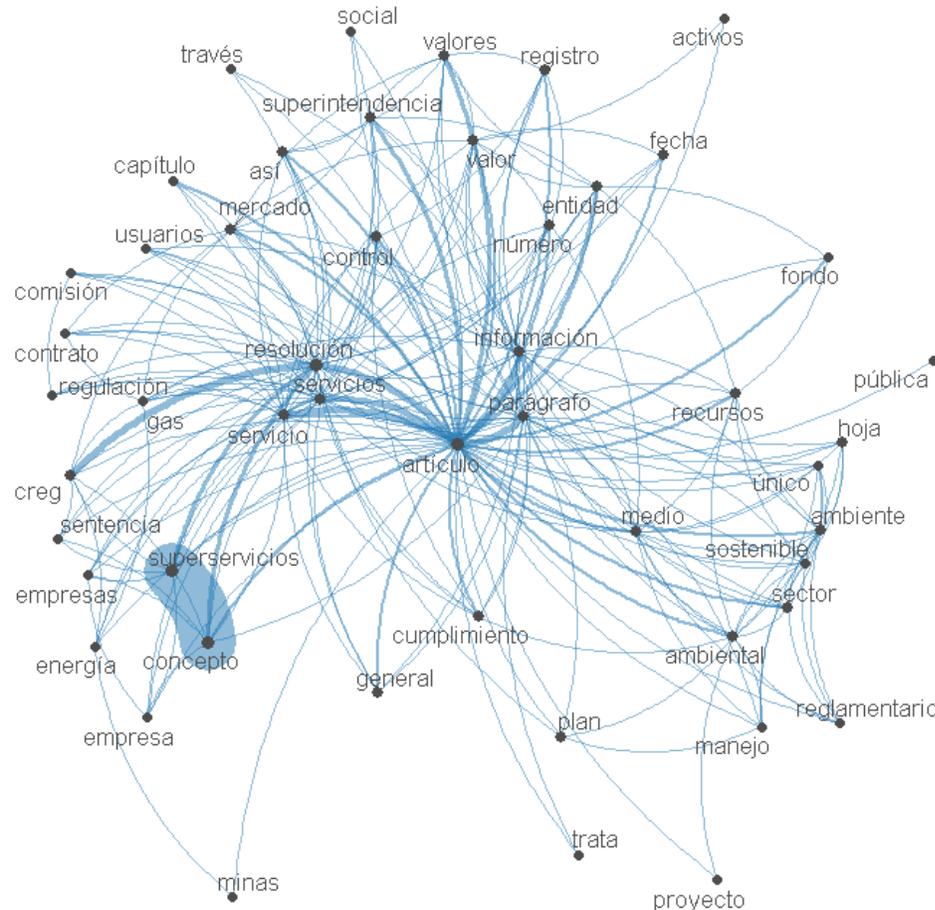
Palabras en común



Palabras discriminantes

# Identificación de *stopwords*

Conformación de red de conexiones entre palabras para identificar aquellas que son transversales



Crear una lista de palabras no necesarias:

ej: decreto, artículo, parágrafo, resolución

# Mejora de los insumos

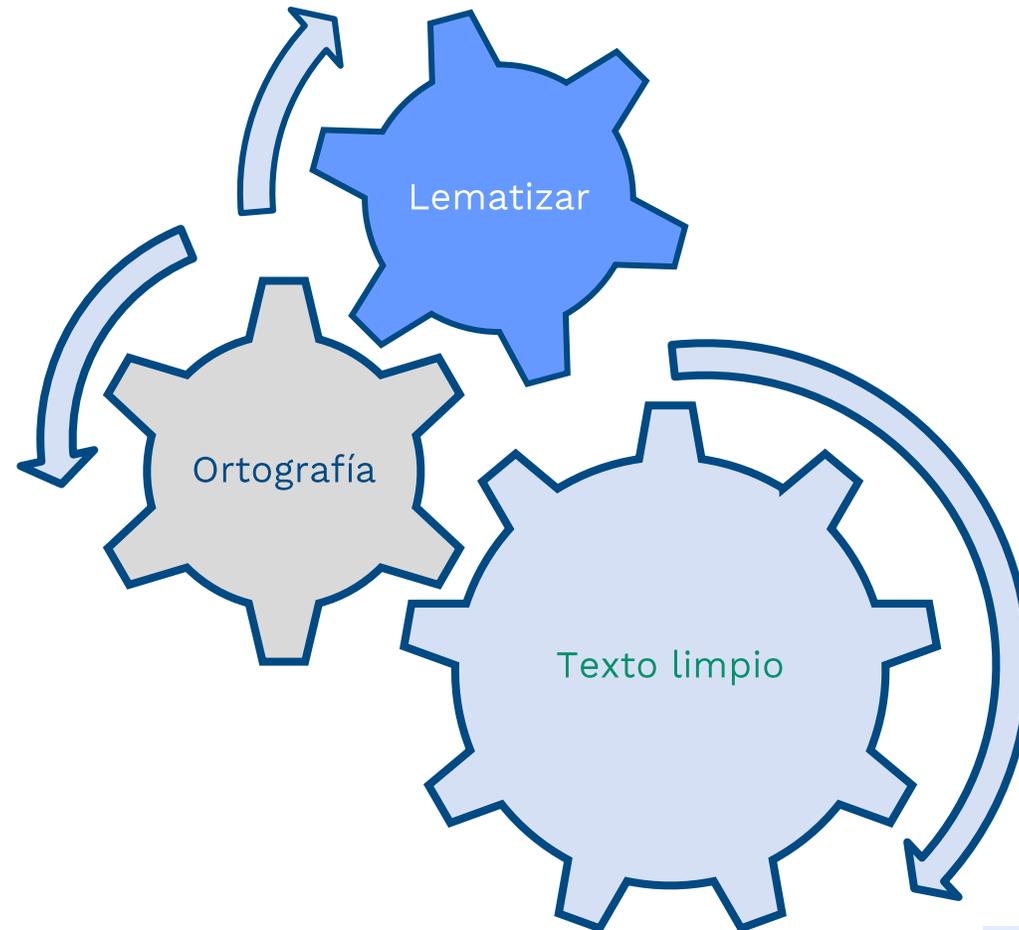
Se está trabajando en mejorar la calidad de los insumos

Mejor conteo de las palabras  
frecuentes en los sectores

Ej: “hablamos y habló el hablador”  
> hablar y hablar el hablar

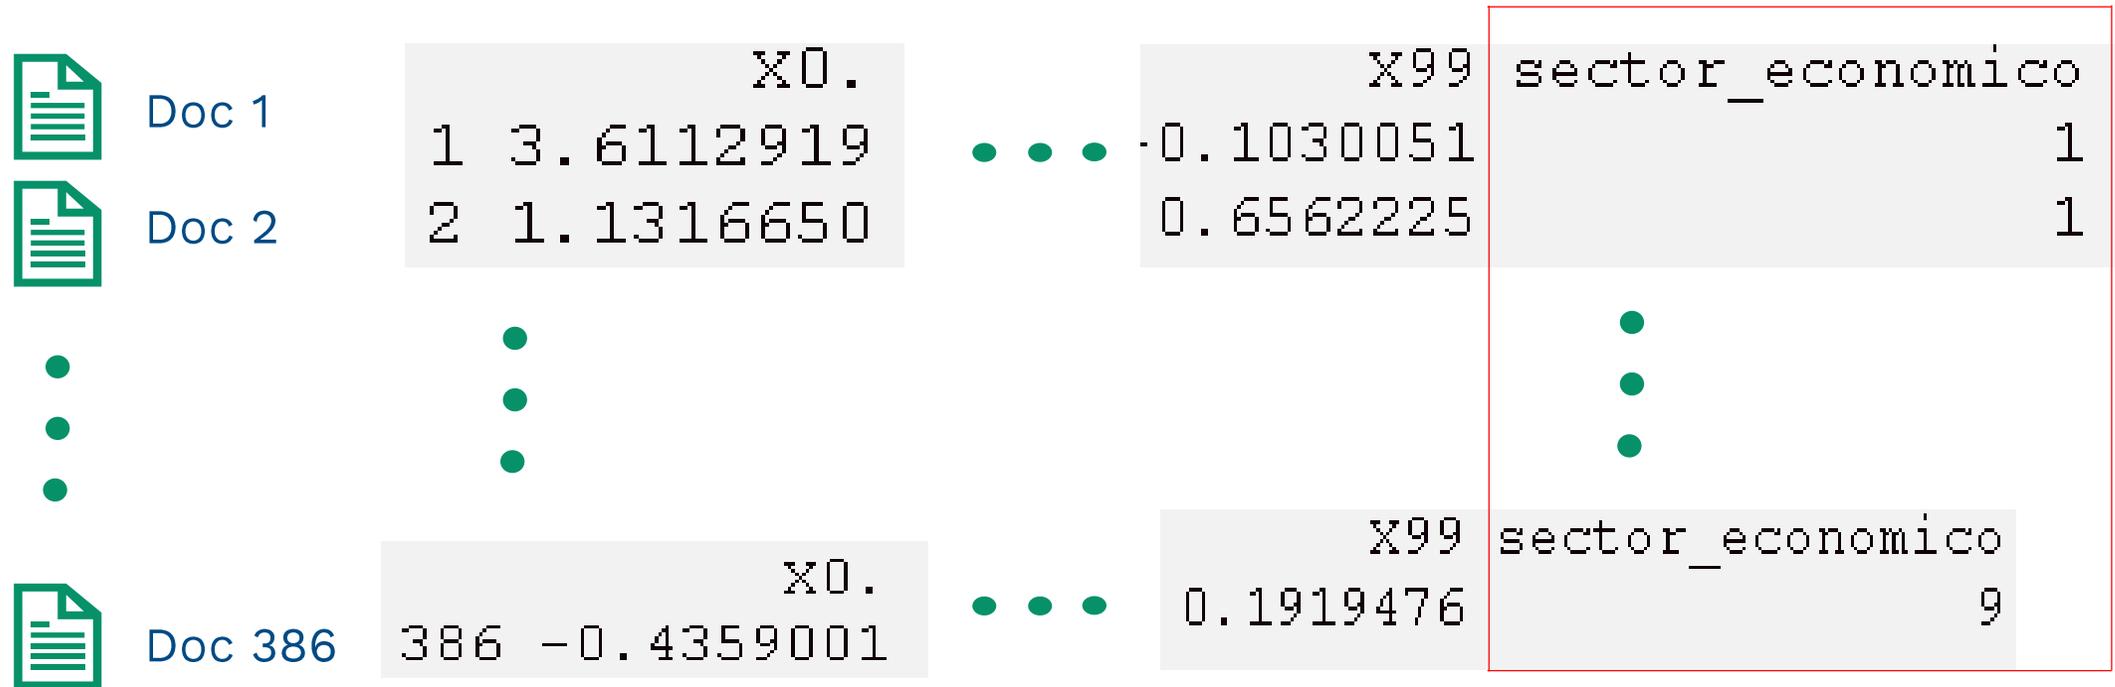
Corregir errores de ortografía o del  
OCR

Ej: “ambiental”, “alimenfo”  
> ambiental, alimento



# Vectorización

Representación numérica del texto contenido en los documentos



# Primeros modelos

Se empezó la clasificación con dos tipos de modelos supervisados

Nombre	Precisión
Gradient Boosting Model	55,88%
Super Vector Machine	61,76%



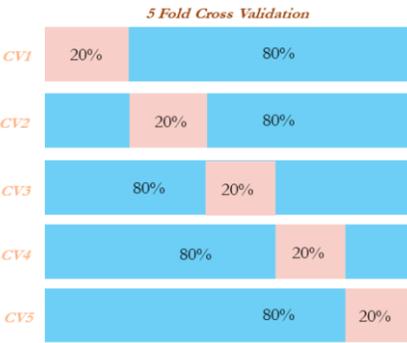
# Búsqueda del modelo

Diferentes algoritmos para modelos supervisados

Modelo	Precisión
Gradient Boosting Model	55,88%
Naive Bayes	36,24%
Neural Network	45,76%
Random Trees	54,12%
Extreme Gradient Boosting	63,20%
Super Vector Machine	61,74%
★ Random Forest	65,88%
Lineal Discriminant Analysis	52,37%

# Hiperparámetros

Conjunto de parámetros que exploran las combinaciones posibles en la configuración inicial del modelo



*5 Fold Cross Validation*

CV1: 20% (red), 80% (blue)

CV2: 20% (red), 80% (blue)

CV3: 80% (blue), 20% (red)

CV4: 80% (blue), 20% (red)

CV5: 80% (blue), 20% (red)

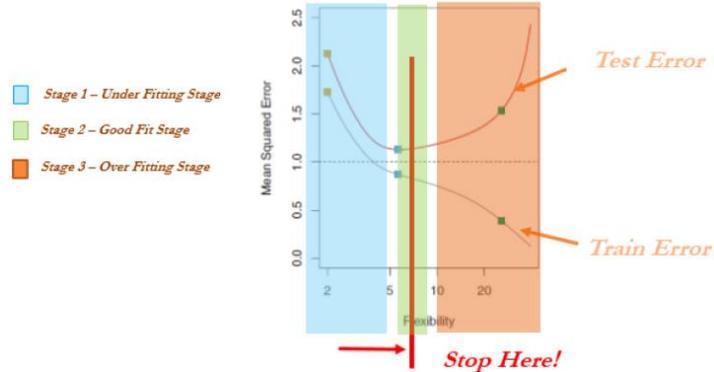
Validación cruzada

17 repeticiones

sector_economico	n
1	56
2	23
3	108
4	78
5	22
6	14
7	36
8	23
9	26

Balanceo de clases

Upsampling



Stage 1 – Under Fitting Stage

Stage 2 – Good Fit Stage

Stage 3 – Over Fitting Stage

Mean Squared Error

Train Error

Test Error

Flexibility

Stop Here!

Aprender-Memorizar

70% entrenamiento – 30% prueba



Objetivo: Obtener un mejor rendimiento en la clasificación

# Resultados de clasificación

Conjunto de prueba con el algoritmo Random Forest

Funciones objetivo:

- **Precision (P):**  $TP/(TP+FP)$
- **Recall (R)/sensitivity:**  $TP/(TP+FN)$



88,23% de precisión  
91,83% de sensibilidad

	Truth								
Prediction	1	2	3	4	5	6	7	8	9
1	12	0	4	0	0	0	0	0	1
2	0	2	0	0	1	0	0	0	0
3	4	4	28	0	0	1	1	0	1
4	0	0	0	23	1	1	0	1	0
5	0	0	0	0	4	0	0	0	0
6	0	0	0	0	0	2	0	0	0
7	0	0	0	0	0	0	9	0	0
8	0	0	0	0	0	0	0	5	0
9	0	0	0	0	0	0	0	0	5

Sectores

1. Agricultura
2. Minería
3. Manufacturas
4. Electricidad
5. Construcción
6. Comercio
7. Transporte
8. Finanzas
9. Servicios

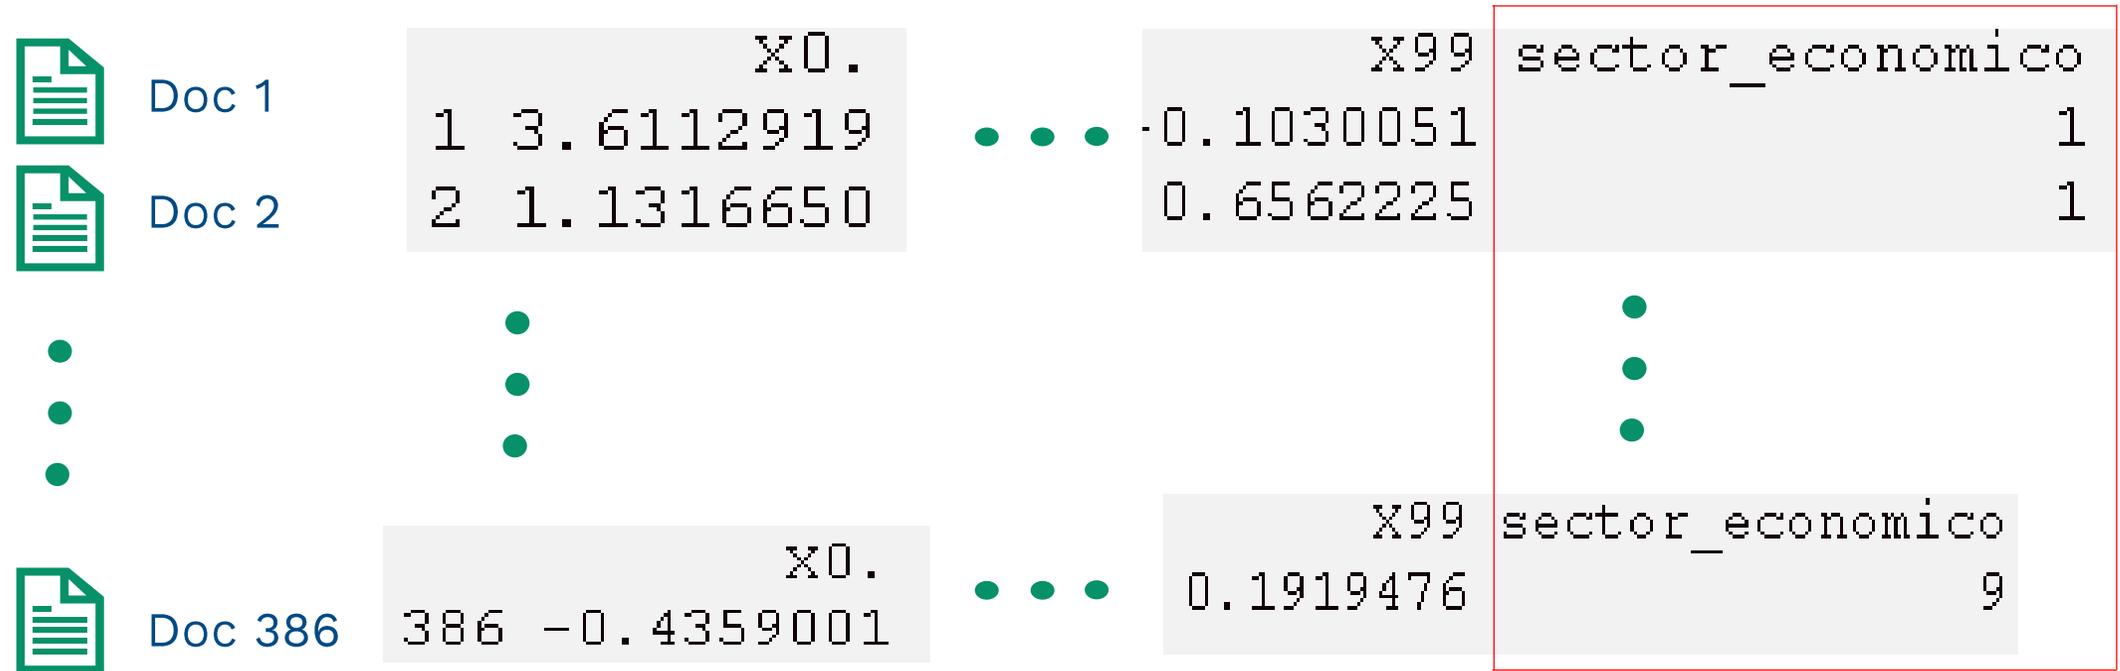
Falso Positivo: Es clasificado en el sector cuando en realidad no pertenece a él. (12)

Falso Negativo: No se clasifica en el sector cuando en realidad sí pertenece a él. (8)



# Vectorización

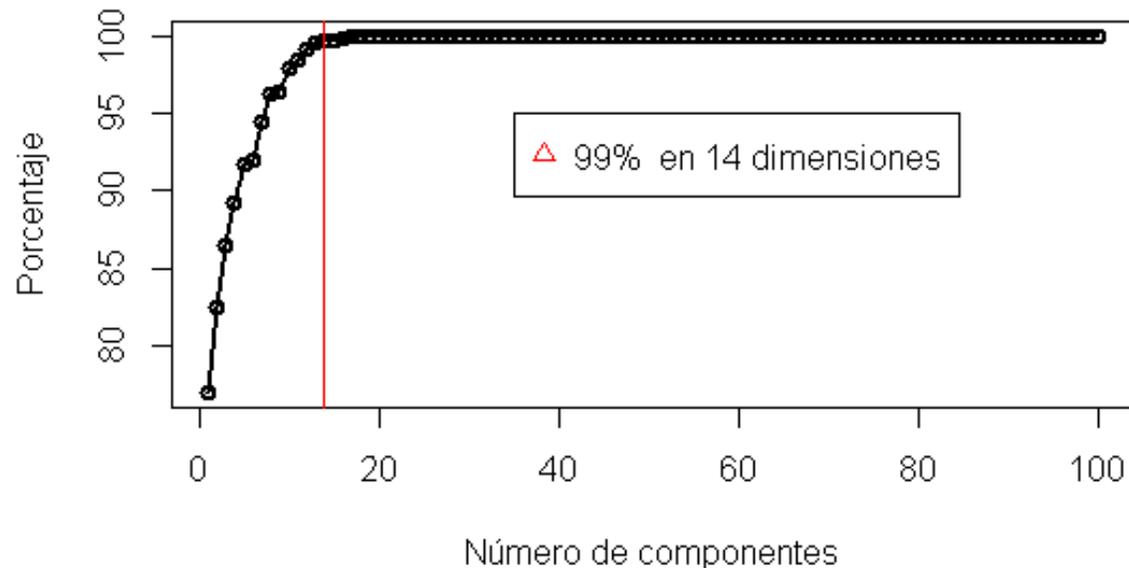
Representación numérica del texto contenido en los documentos



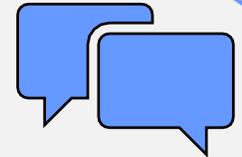
# Componentes principales

Explora el número de dimensiones necesarias para reunir la información a partir del proceso de vectorización con el algoritmo Doc2Vec

**Información contenida por los componentes principales**



Nuevos escenarios:



1. Resumir el 99% de las proyecciones hechas por la vectorización en 14 componentes y luego clasificar
2. Hacer una proyección en el proceso de vectorización con menos dimensiones

# Escenarios

Escenarios:

1. Resumir el 99% de las proyecciones hechas por la vectorización en 14 componentes y luego clasificar

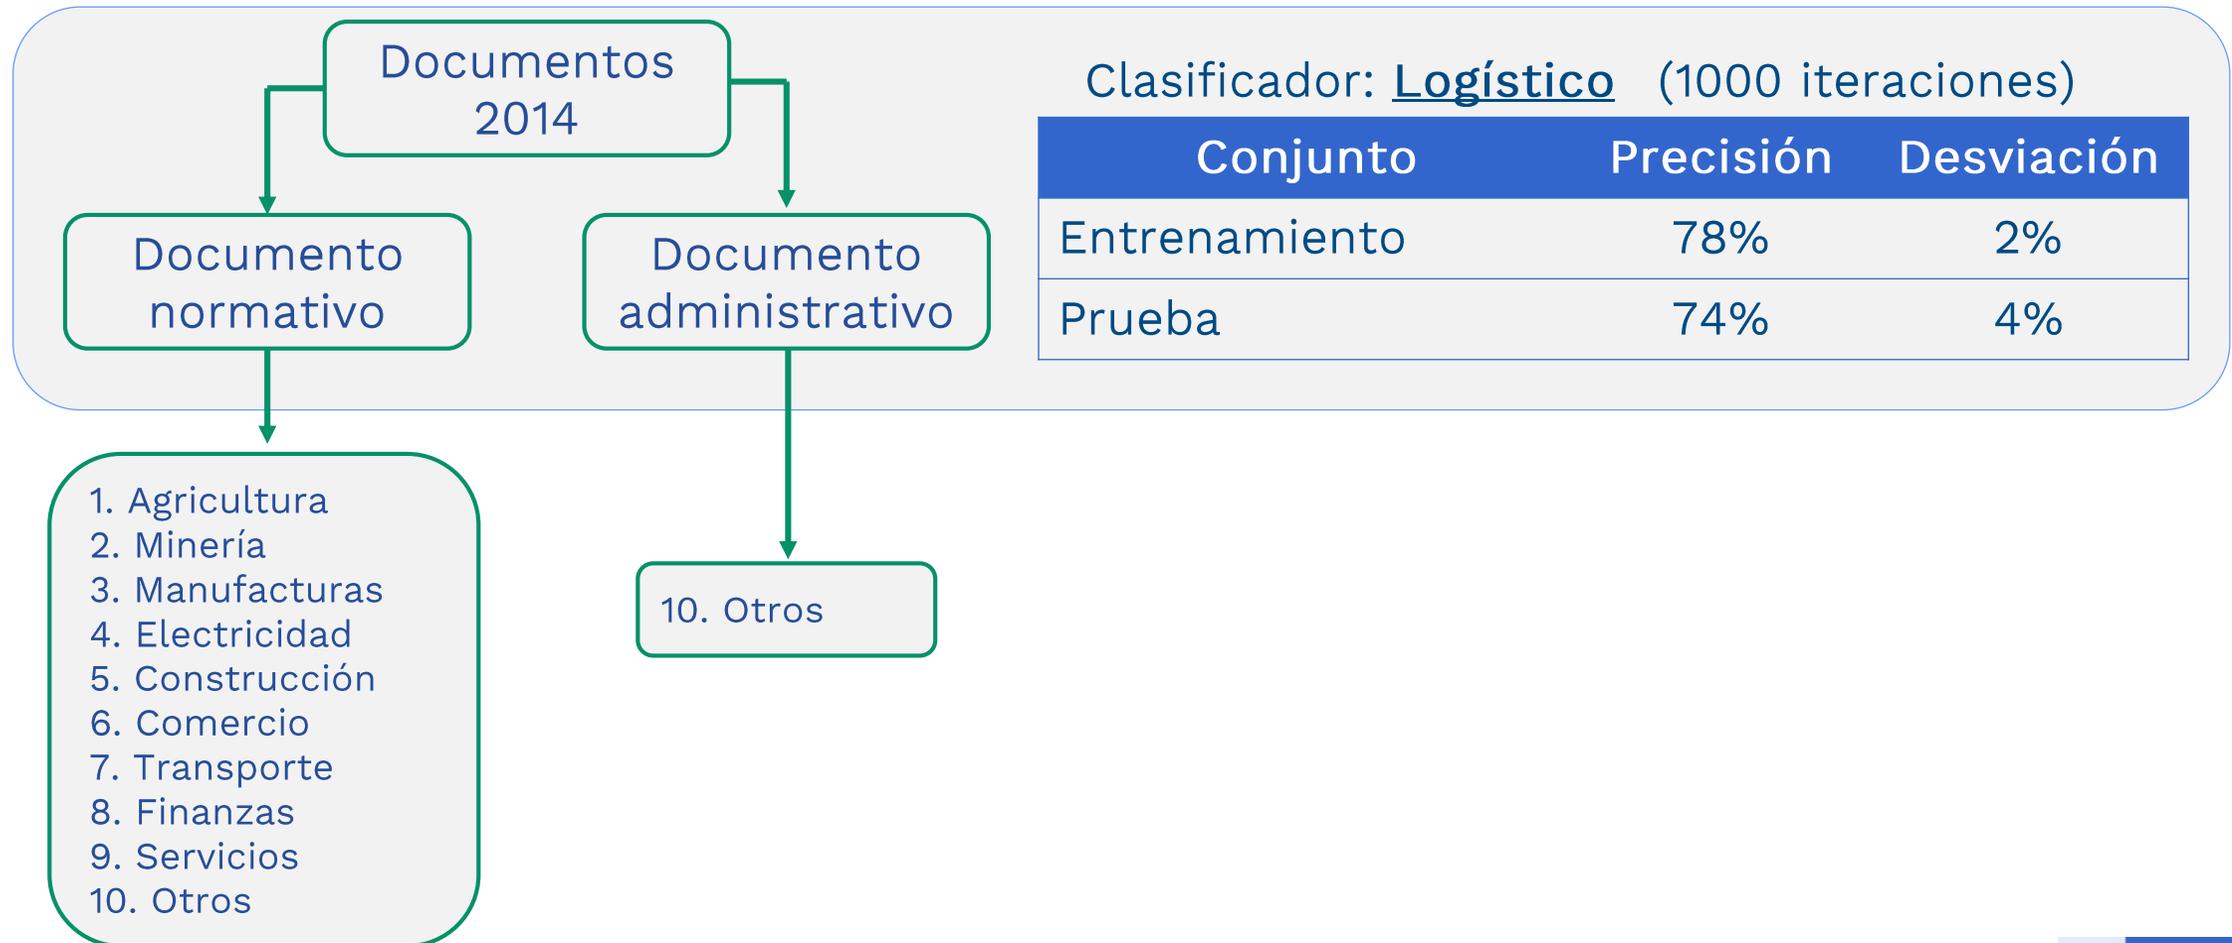


2. Hacer una proyección en el proceso de vectorización con menos dimensiones



# Diagrama del proceso

Resultados obtenidos para el clasificador sustancial





**El futuro  
es de todos**

**DNP**  
Departamento  
Nacional de Planeación