

Este trabajo ha sido realizado bajo el proyecto de investigación TestEAMos (TIN2016-76956-C3-1-R), financiado por el Ministerio Español de Economía y Competitividad junto con fondos FEDER

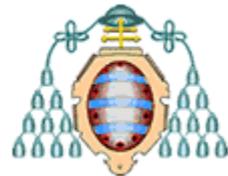
# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

Cristian Augusto, Jesús Morán, Claudio de la Riva and Javier Tuya

**Grupo de Investigación en Ingeniería del Software**

<http://giis.uniovi.es>

**Universidad de Oviedo**



# Dataset del concurso de Netflix (I)



Dataset

			★★★★★ Th 14 June	
	★★★★★ Th 14 June			★★★★★ Sat 3 January
		★★★★★ Mon 16 July		
			★★★★★ Sat 12 September	
	★★★★★ Wed 18 July		★★★★★ Fri 11 October	★★★★★ Mon 22 January
		★★★★★ Wed 22 March		
		★★★★★ Fri 25 May		

- En 2009 Netflix libero un dataset sin identificadores de los usuarios explícitos, para que desarrolladores compitiesen por mejorar su algoritmo de recomendación

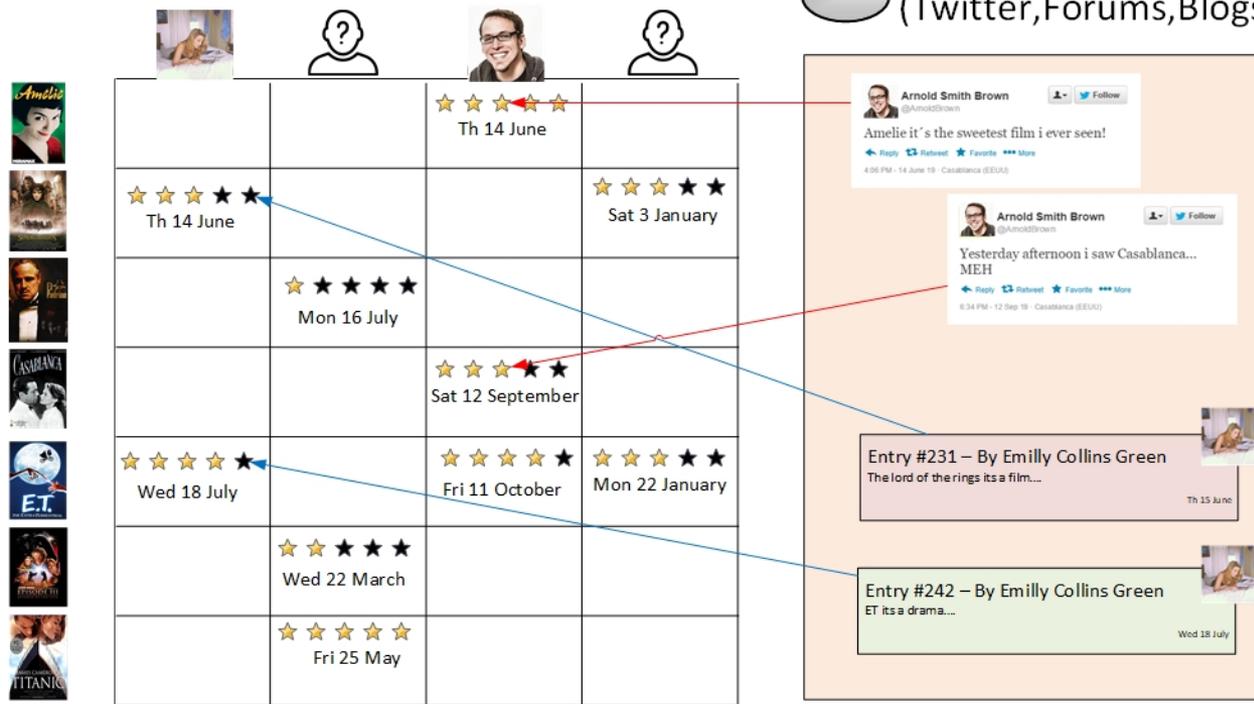
# Dataset del concurso de Netflix (II)



Dataset

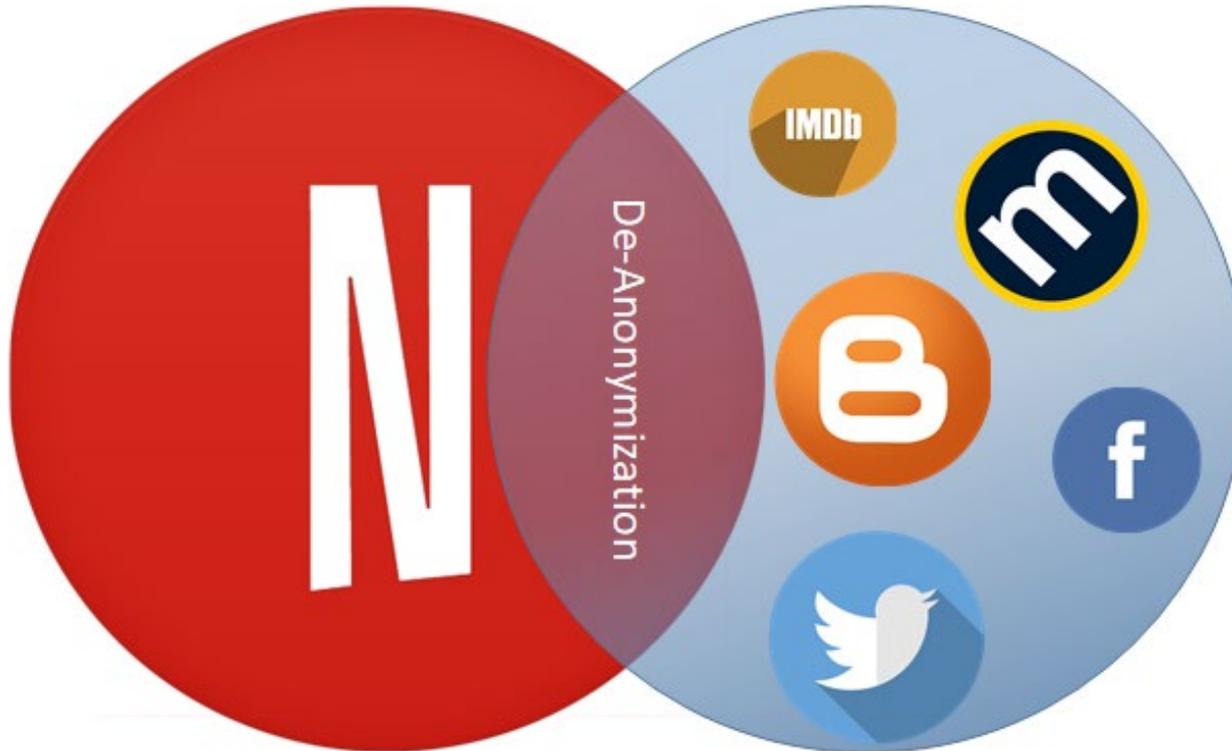


Public Data  
(Twitter, Forums, Blogs...)



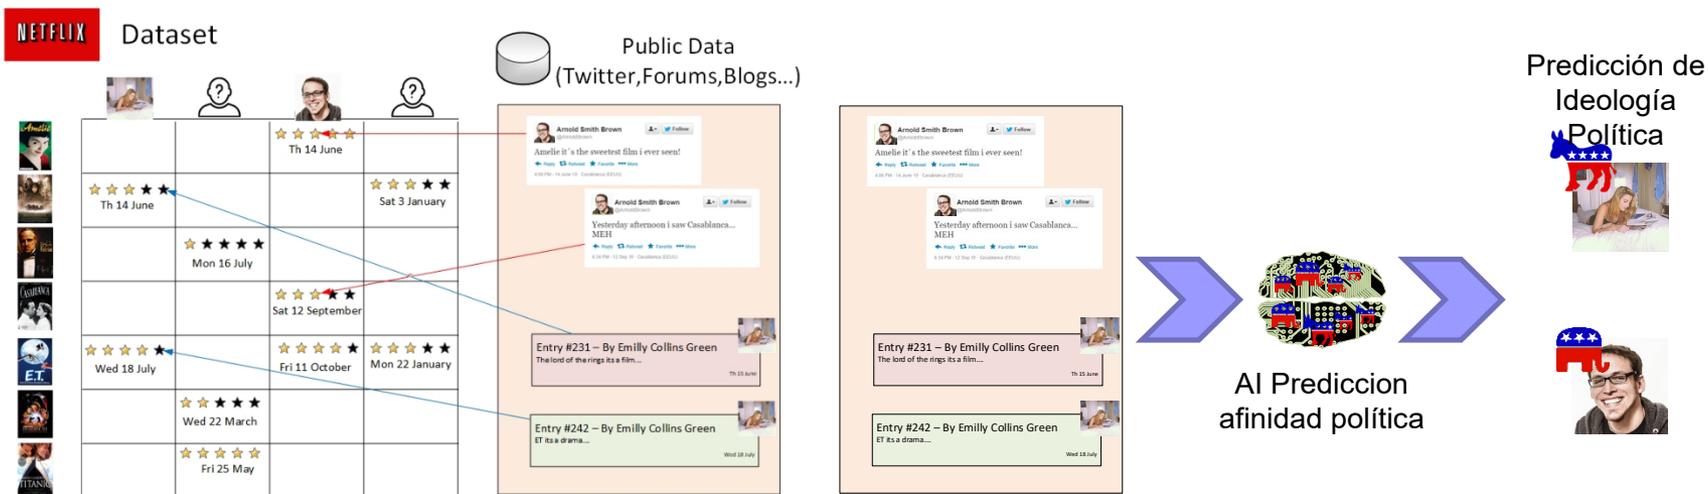
- La información compartida por Netflix cruzada con datos de otras fuentes como Tweets o Posts en Blogs permitía reidentificar a los usuarios

# Dataset del concurso de Netflix (III)



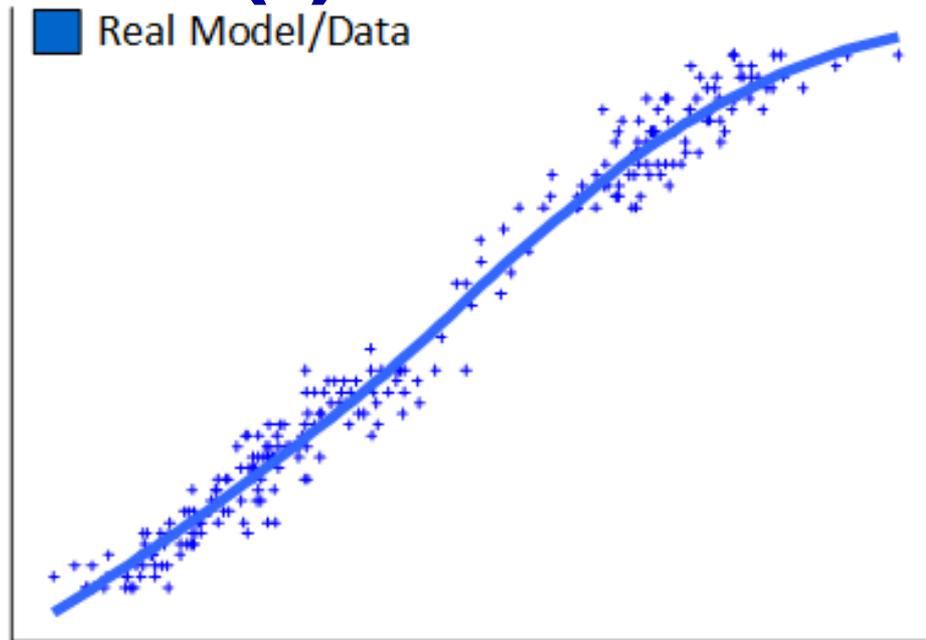
- Cruzando información de múltiples fuentes se puede llegar a adquirir nuevos conocimientos que no se encontraban originalmente

# Dataset del concurso de Netflix (IV)



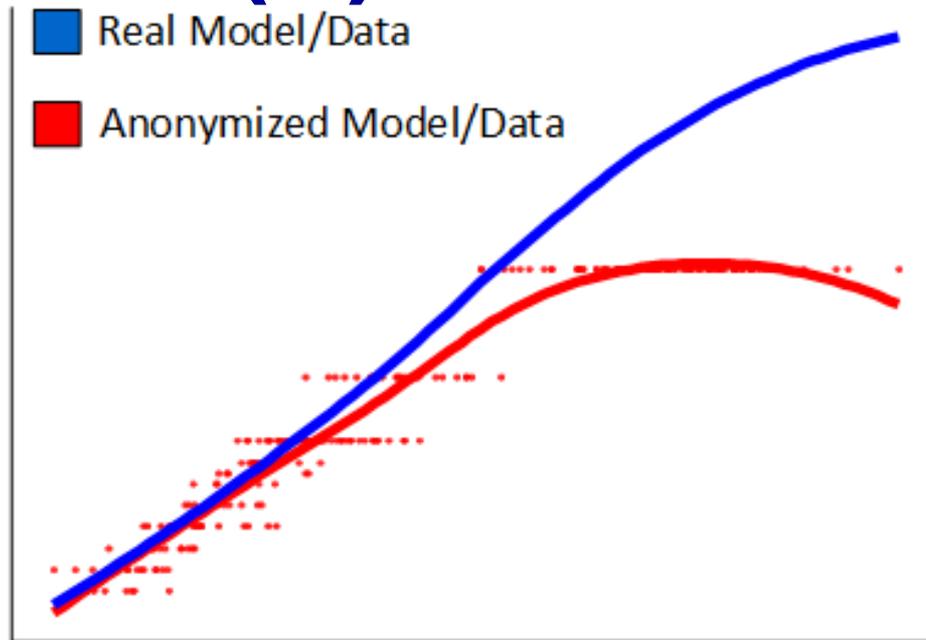
- Algo tan “Inofensivo” puede ser empleado para predecir la ideología política de los usuarios (dato sensible)

# Contexto (I)



- Efectos de la anonimización
  - Mejora la privacidad → Se pierde información
  - Altera los datos afectando a aquellos desarrollos altamente dependientes de los mismos (p.ej. Modelos de inteligencia artificial)

# Contexto (II)

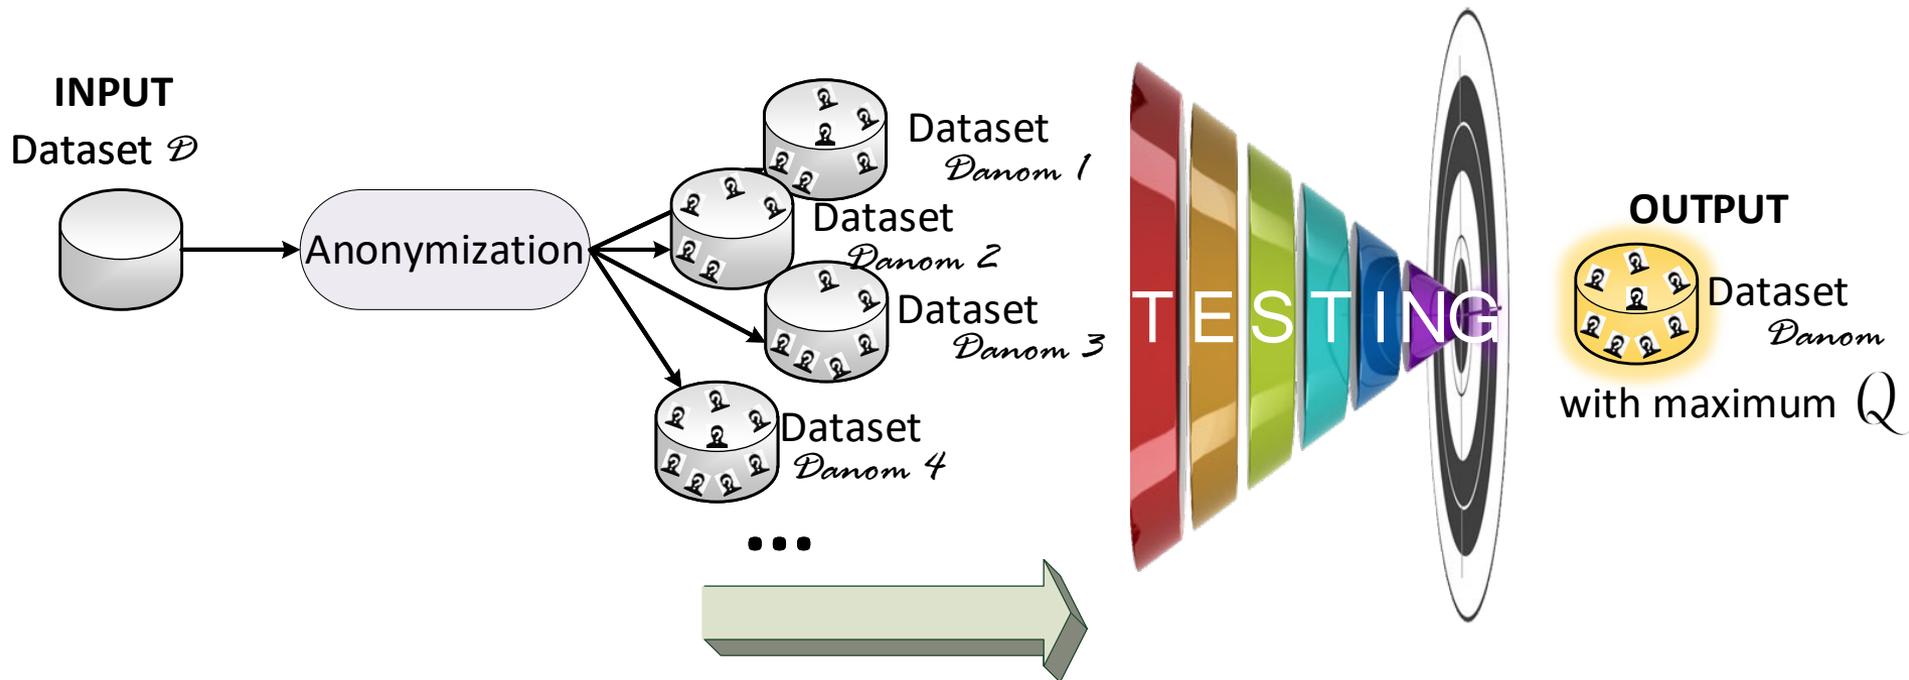


## ■ Enmascaramiento de fallos

- Puede darse el caso de que un modelo de IA que funcione correctamente en desarrollo falle dramáticamente al ser puesto en producción

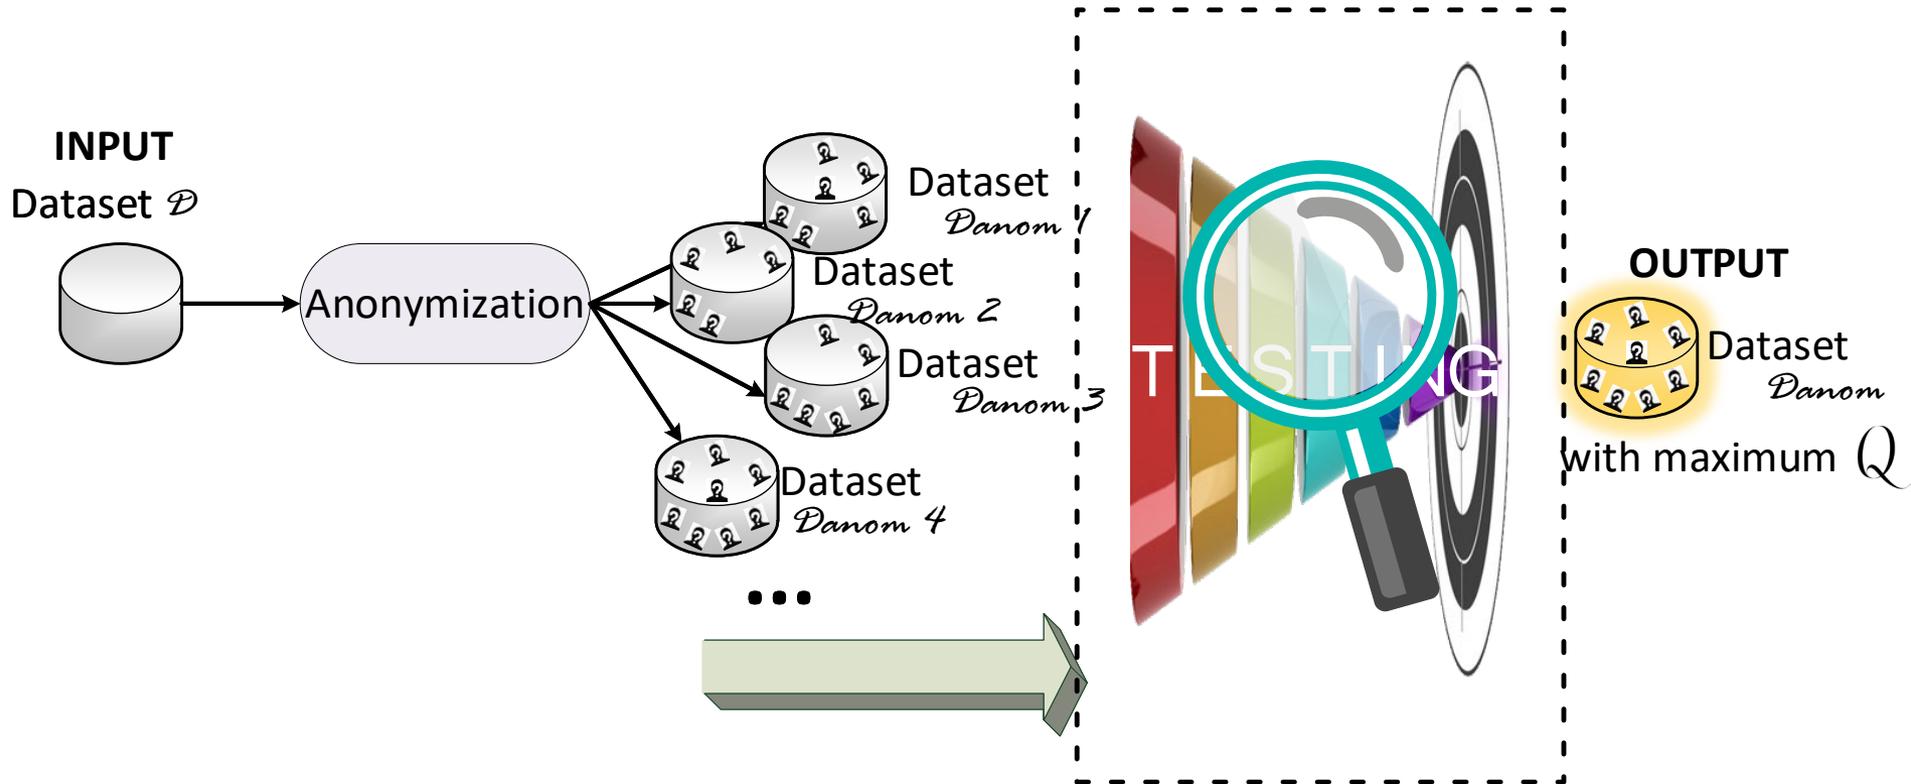
# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

## Plano general



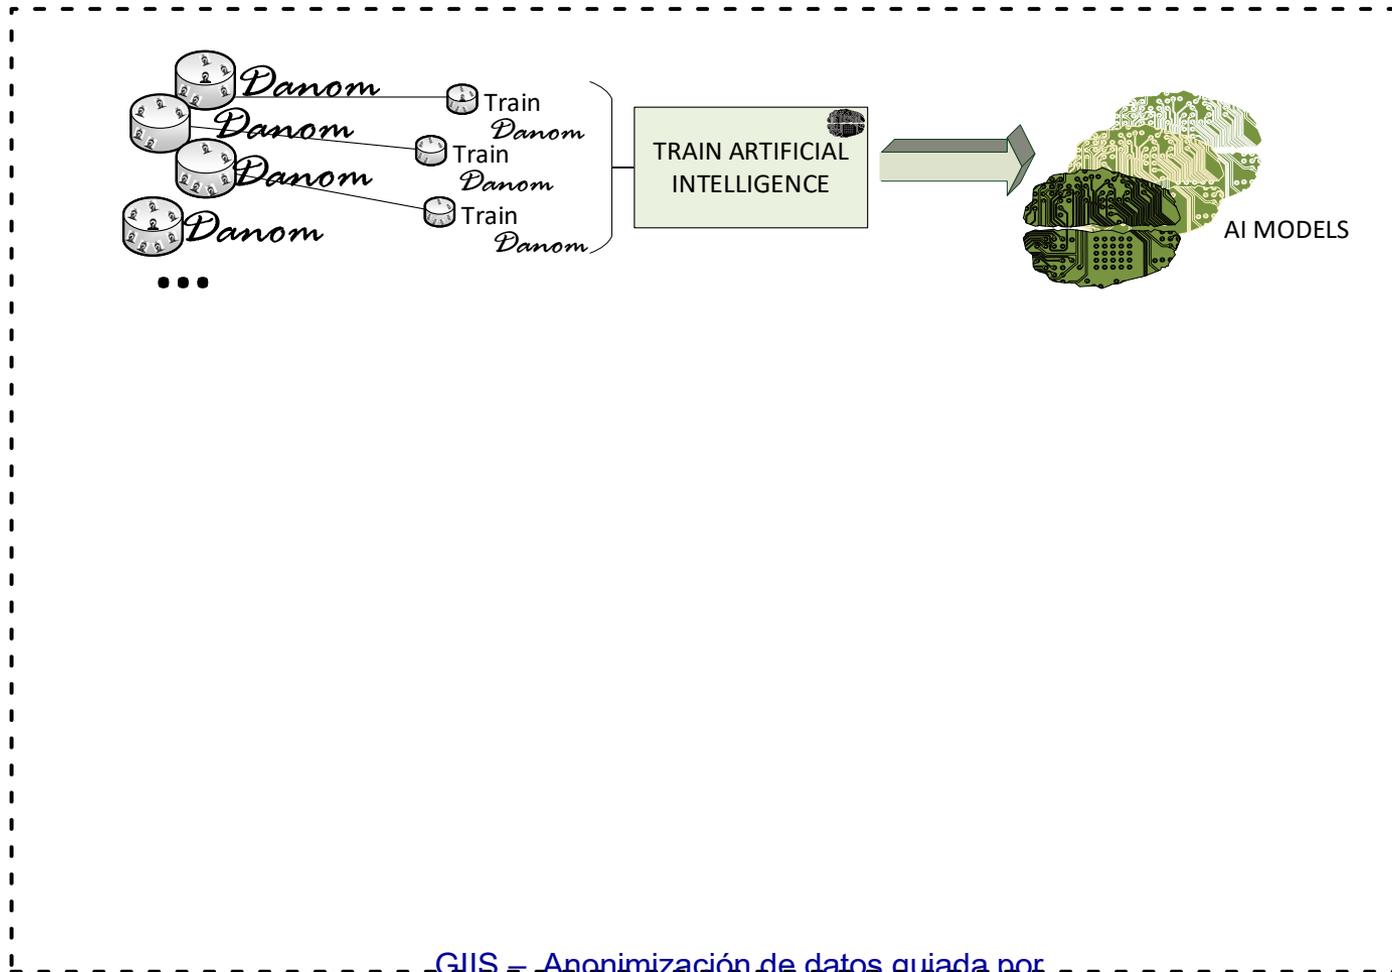
# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

## Plano general



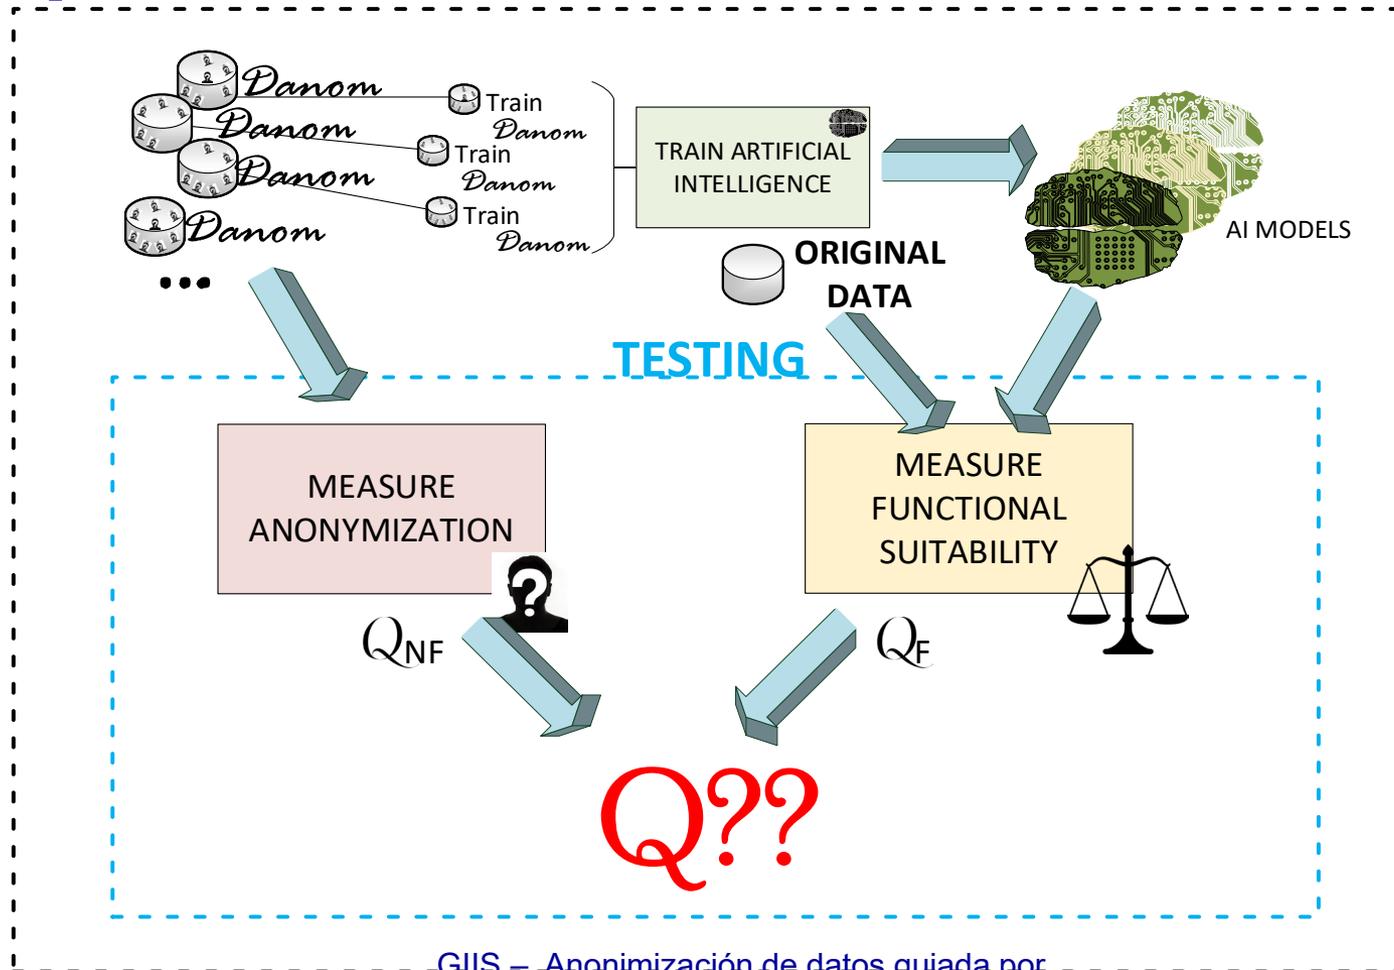
# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

## Enfoque



# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

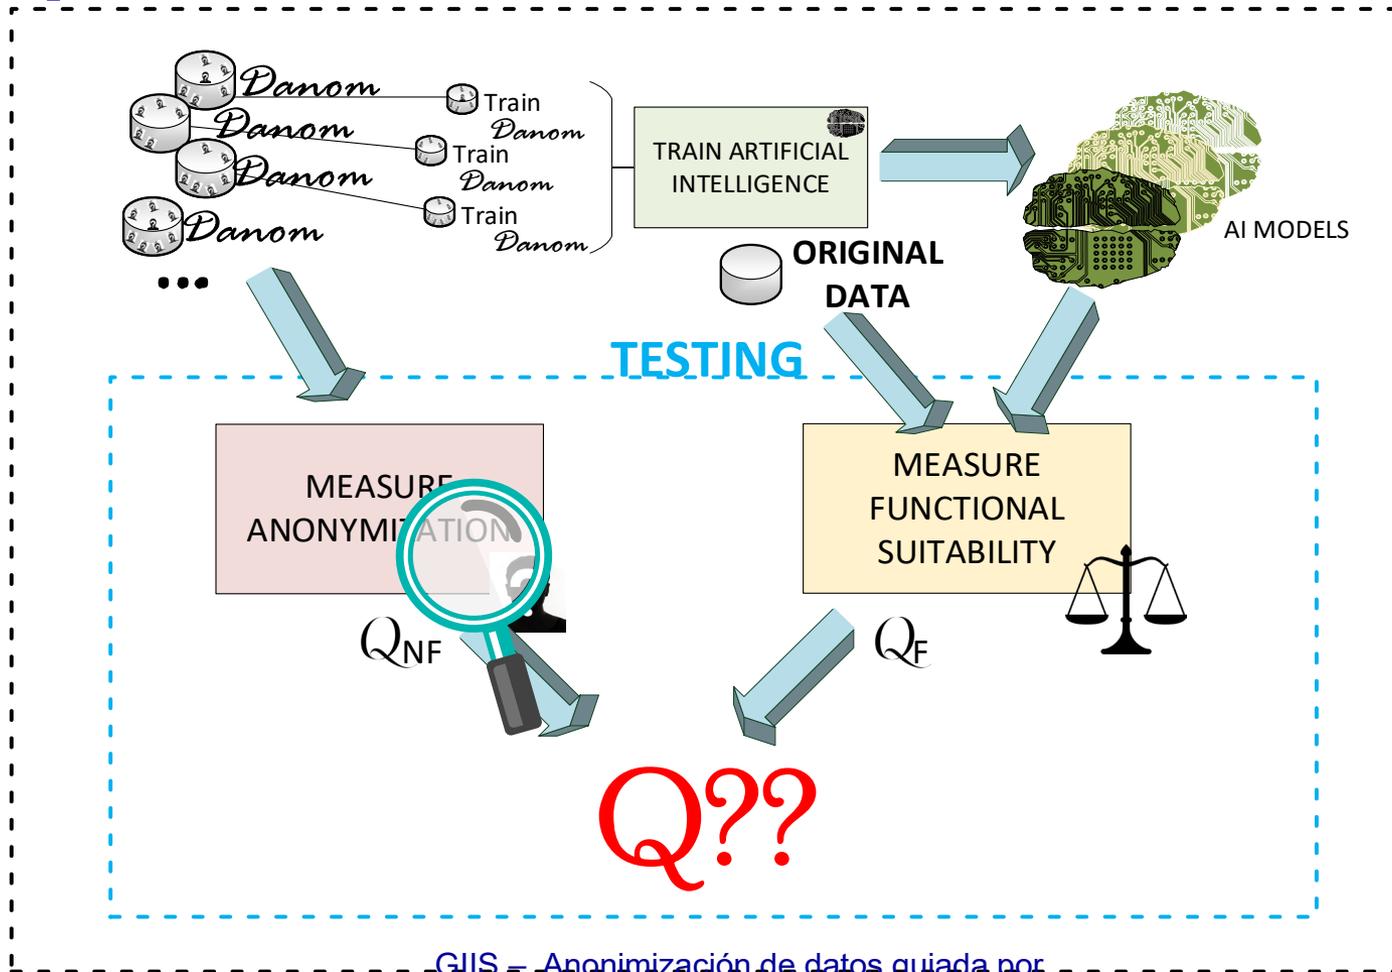
## Enfoque



GIS – Anonimización de datos guiada por pruebas para aplicaciones inteligentes

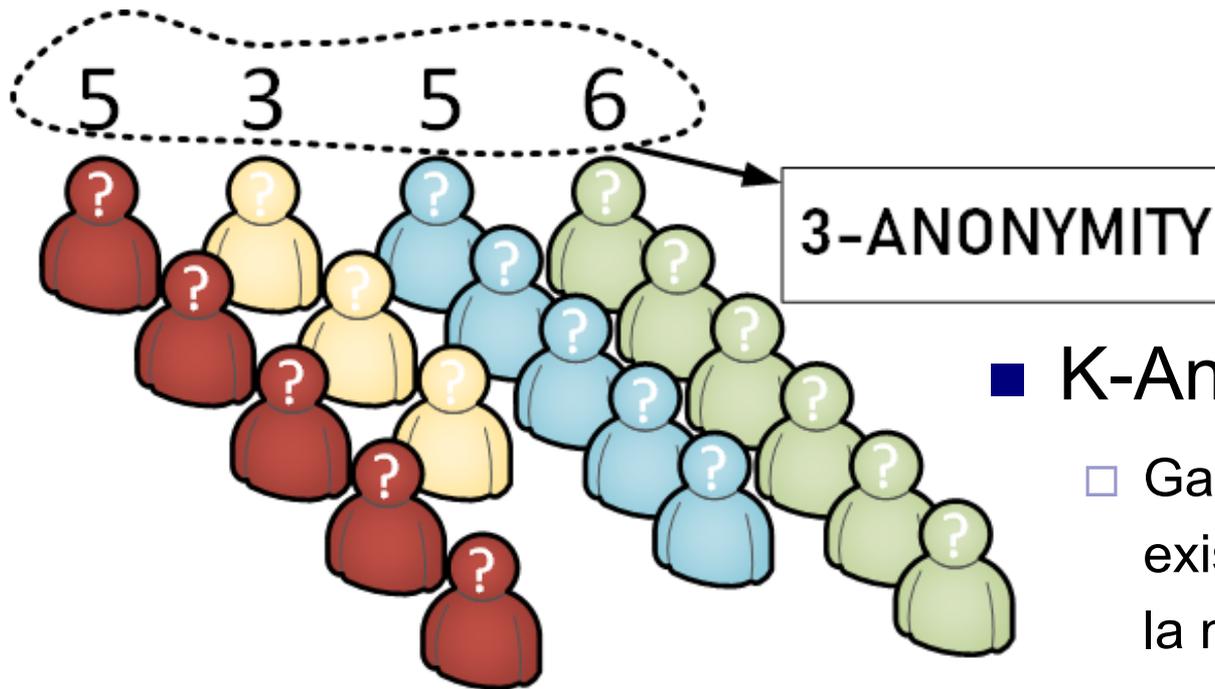
# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

## Enfoque



# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

## Calidad no-funcional

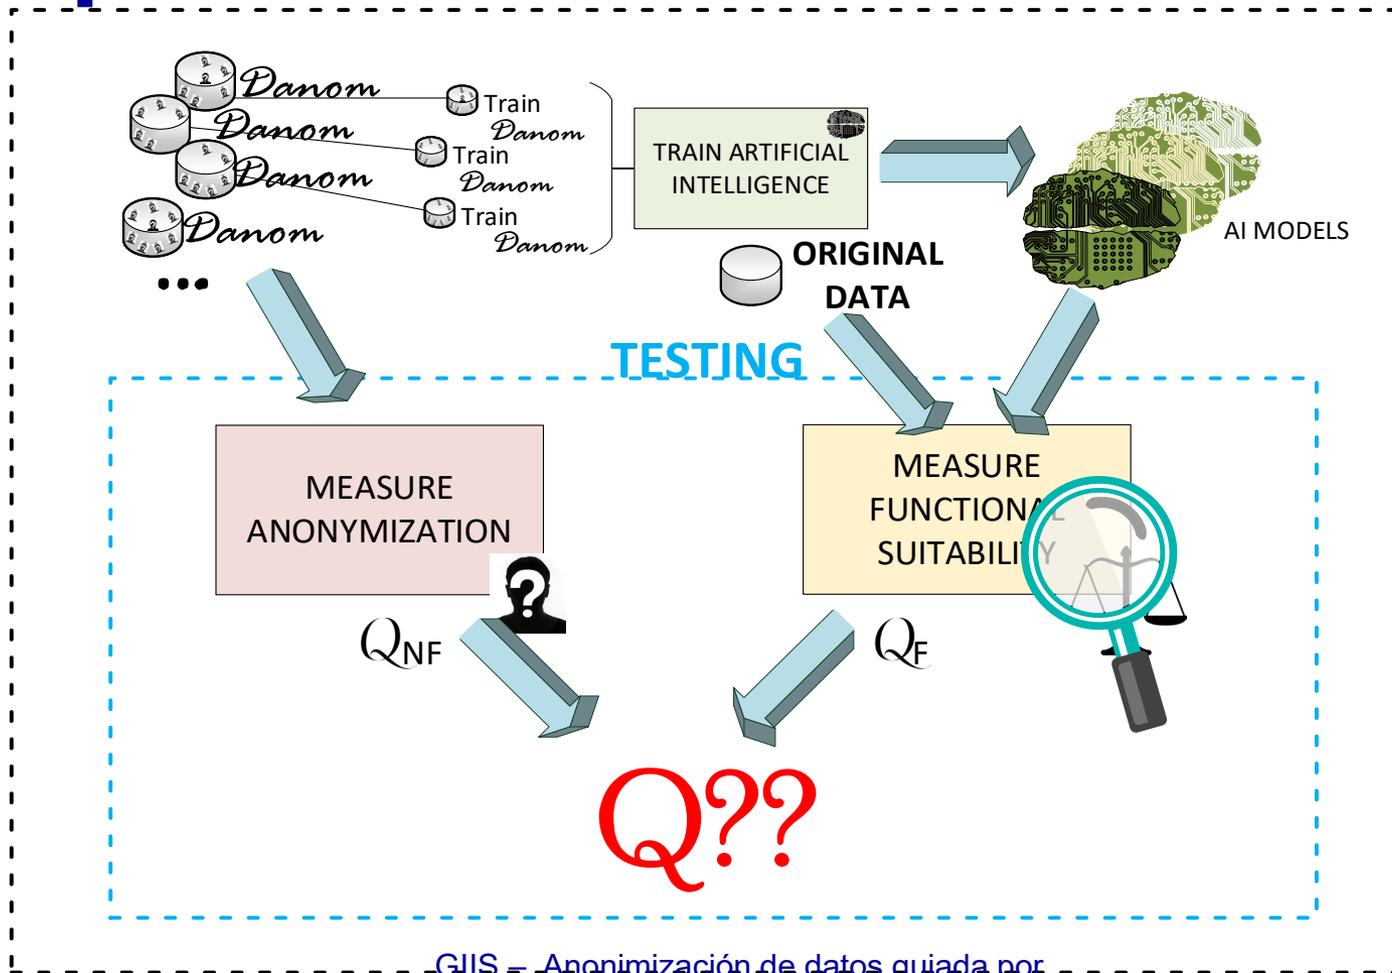


### ■ K-Anonimidad:

- Garantiza que al menos existen K-Individuales con la misma combinación de pseudo-identificadores

# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

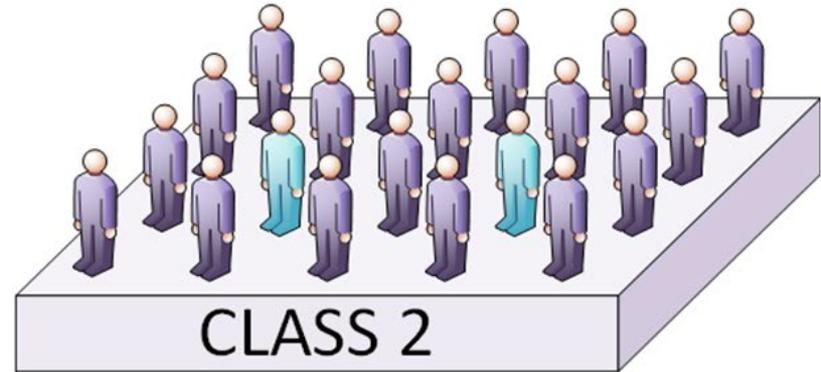
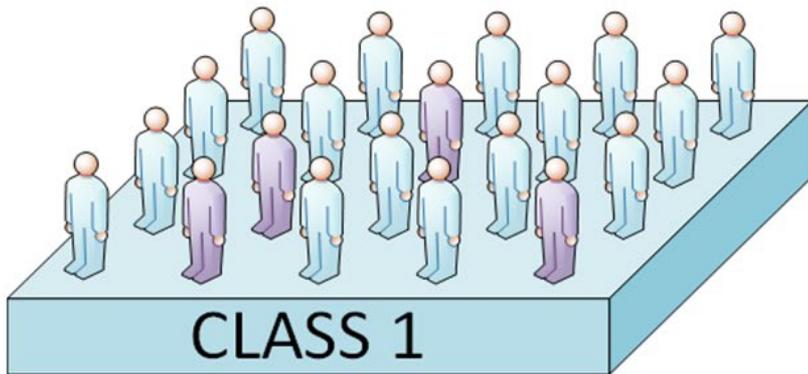
## Enfoque



GIS – Anonimización de datos guiada por pruebas para aplicaciones inteligentes

# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

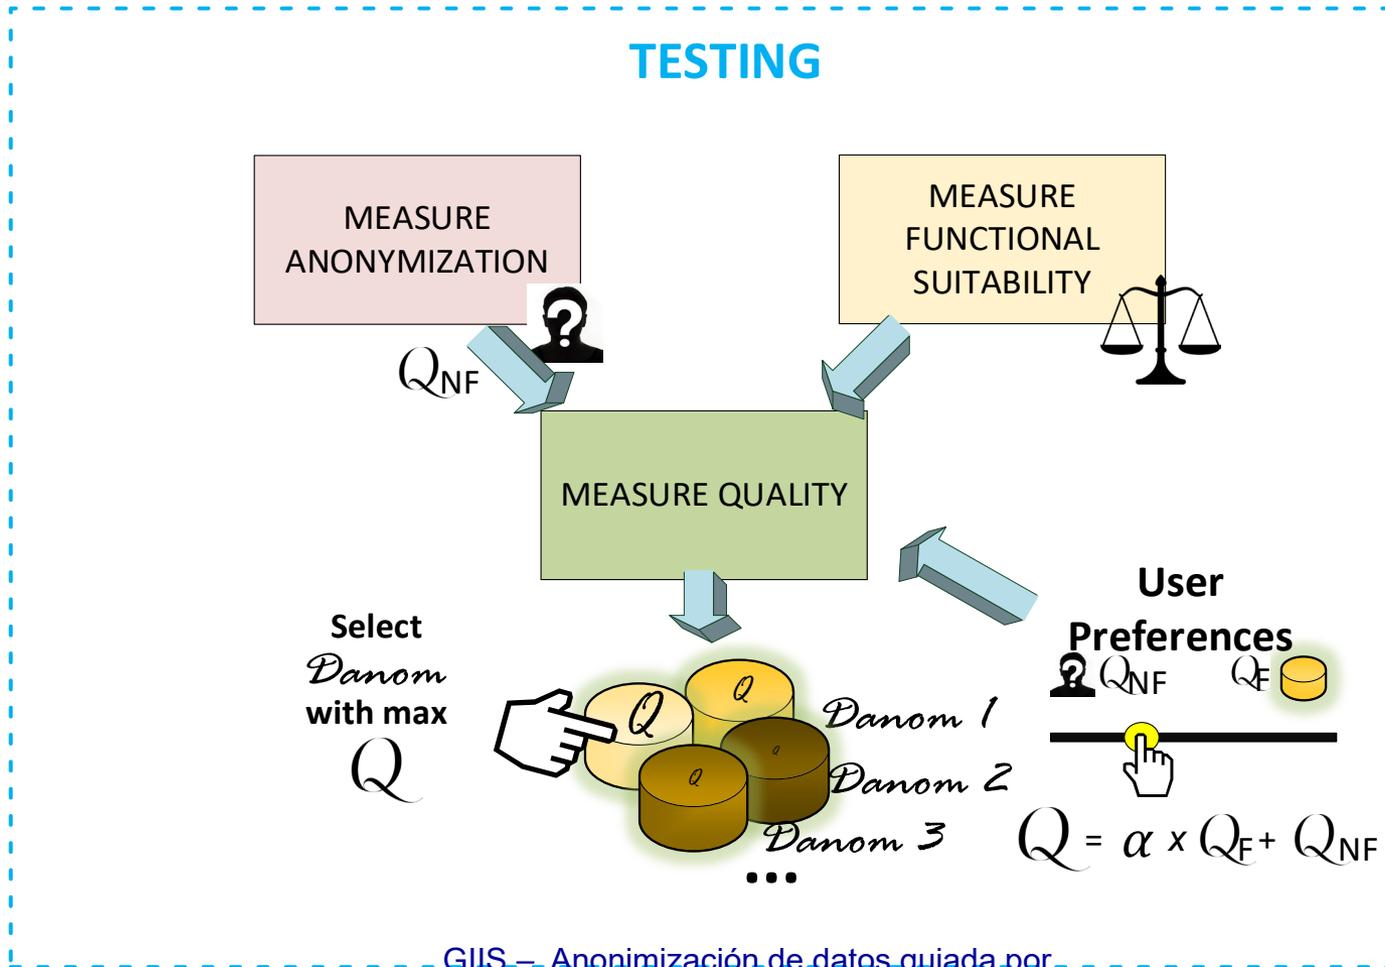
## Adecuación funcional



$$Accur = \frac{N^a_{\text{correct}} + N^a_{\text{incorrect}}}{N^a_{\text{total}}}$$

# Anonimización de datos guiada por pruebas para aplicaciones inteligentes

## Metrica de calidad



# Conclusiones y trabajo futuro

## ■ Conclusiones

- Nuestro enfoque logra un punto de compromiso entre la privacidad y la adecuación funcional de los datos.
- Nuestro enfoque permite a las terceras partes la liberación de datos seguros a la vez de útiles

## ■ Trabajo Futuro

- Evaluar la técnica en varios conjuntos de datos
- Automatizar el enfoque
- Evaluar la dependencia entre el enfoque y los diferentes algoritmos de IA

Este trabajo ha sido realizado bajo el proyecto de investigación TestEAMos (TIN2016-76956-C3-1-R), financiado por el Ministerio Español de Economía y Competitividad junto con fondos FEDER

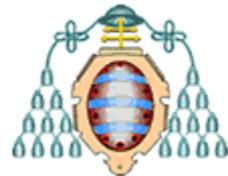
# Preguntas?

Cristian Augusto, Jesús Morán, Claudio de la Riva and Javier Tuya

**Grupo de Investigación en Ingeniería del Software**

<http://giis.uniovi.es>

**Universidad de Oviedo**

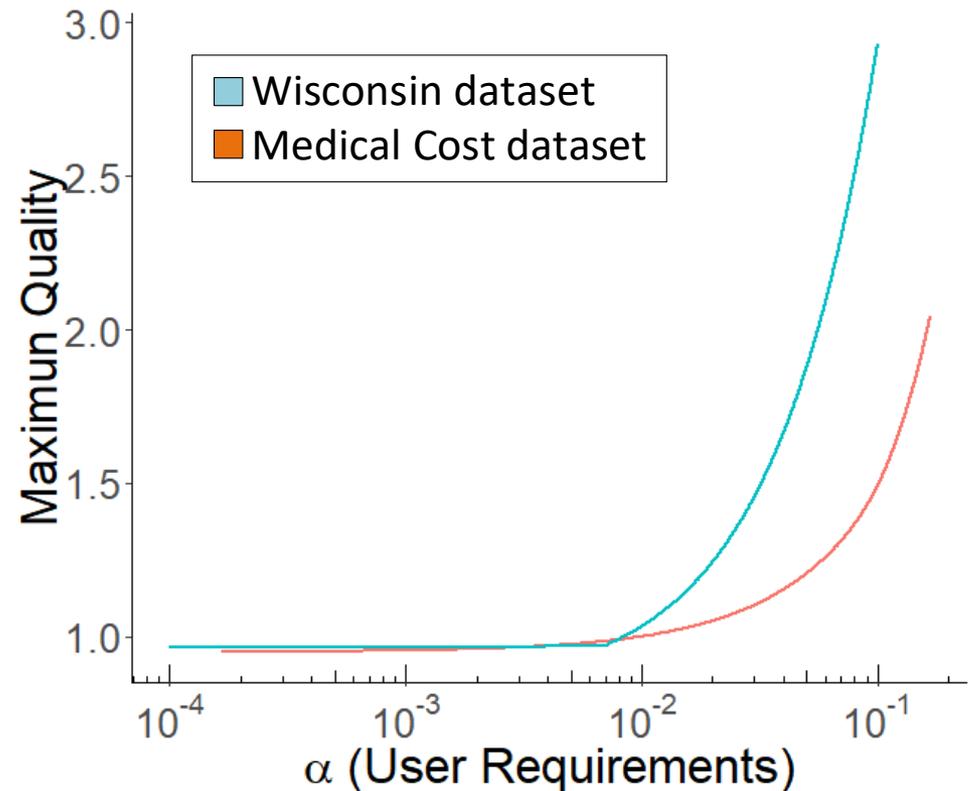


# Preferencias del usuario

- Representadas por un valor  $\alpha$ 
  - Prioriza la utilidad de los datos o la privacidad
- Nuestra metrica de calidad:
  - $Q = QF + \alpha \cdot QNF$

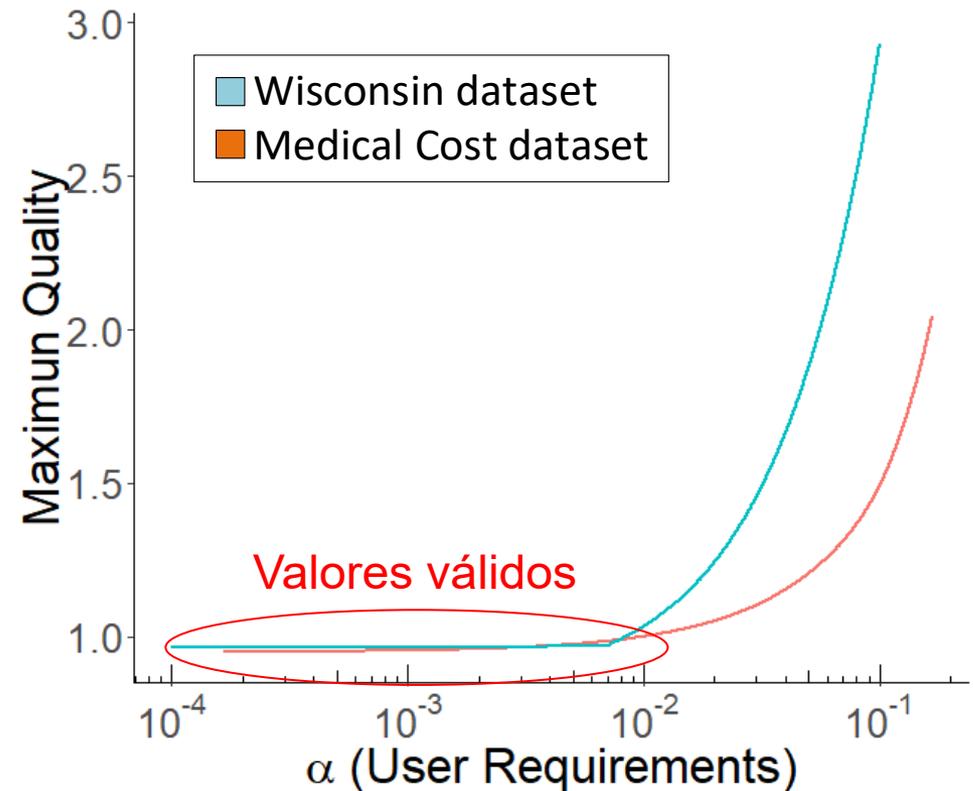
# Preferencias del usuario

- Eligiendo el valor :



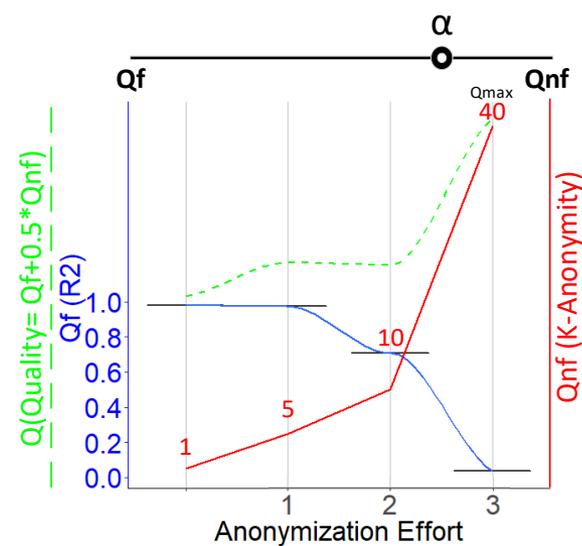
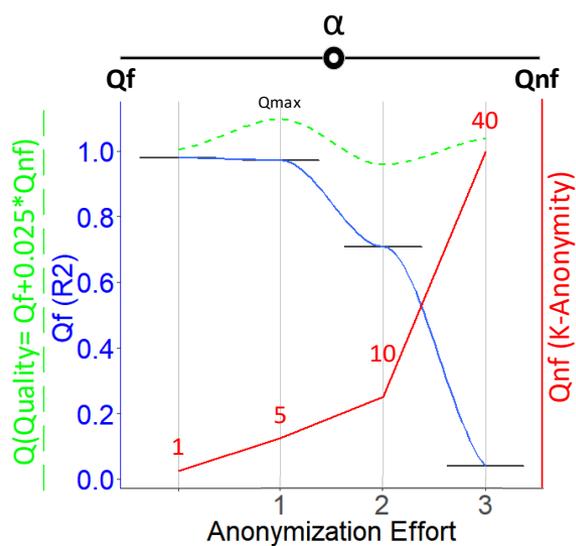
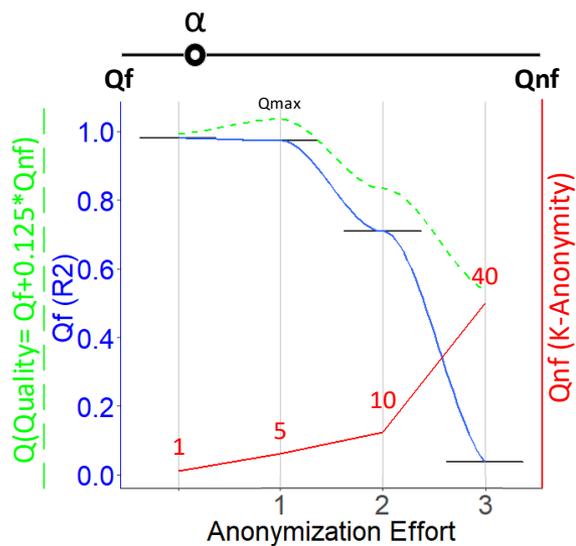
# Preferencias del usuario

- Eligiendo el valor :



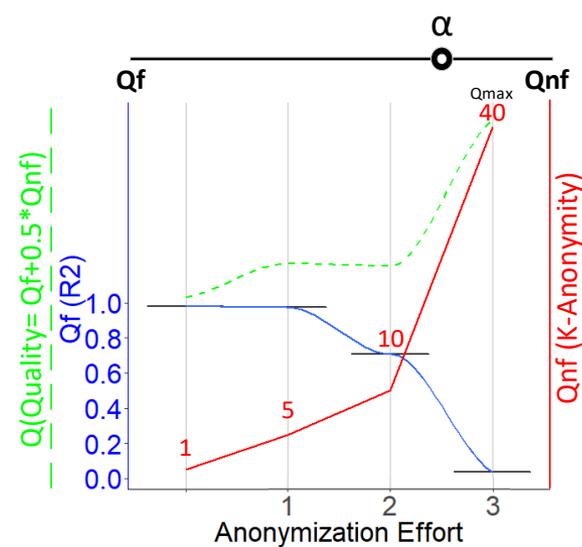
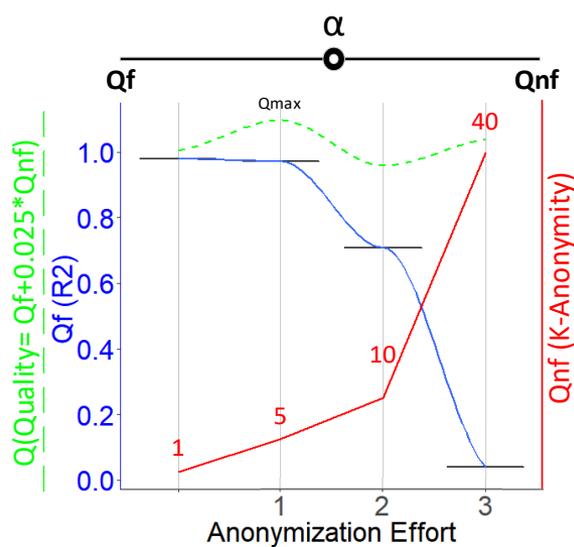
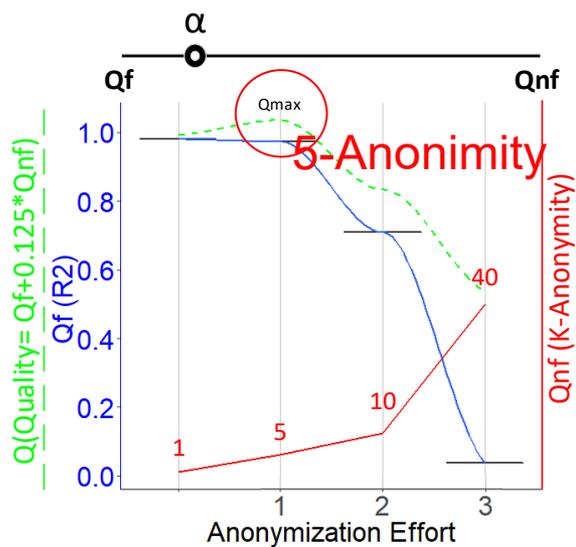
# Preferencias del usuario

## ■ Diferentes ponderaciones:



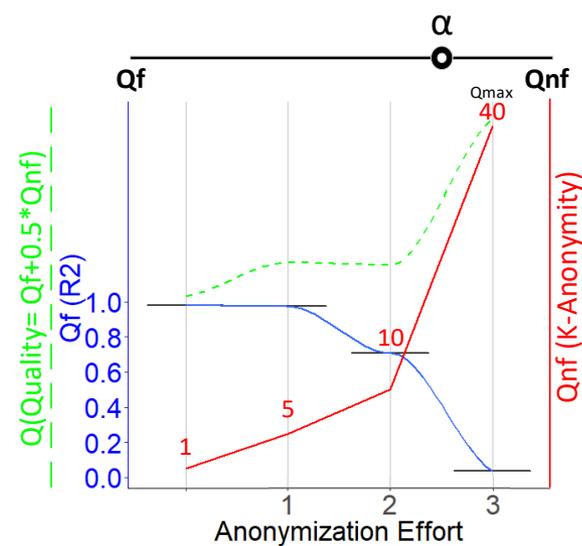
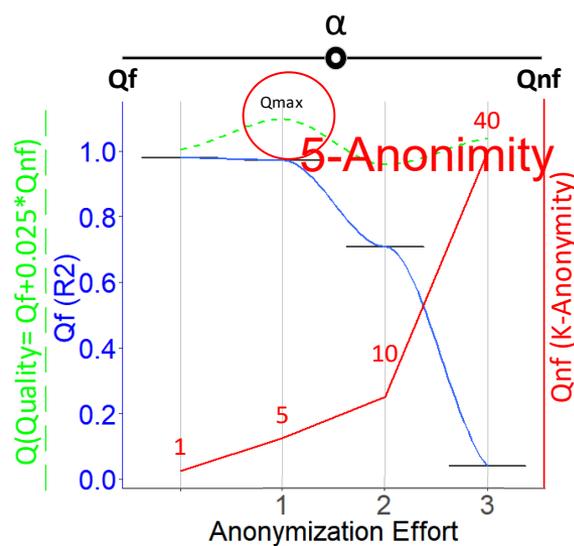
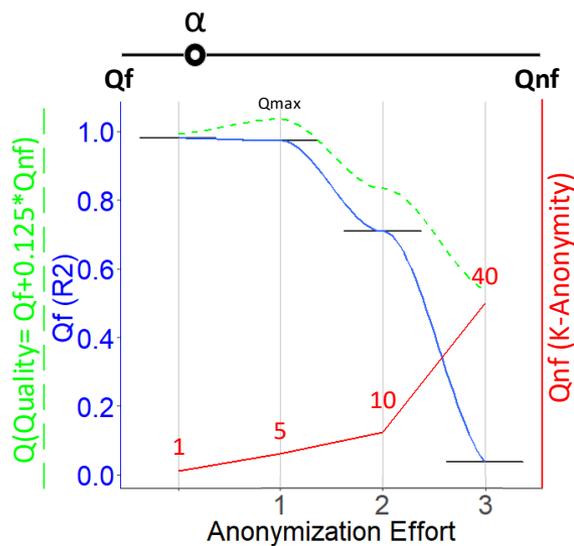
# Preferencias del usuario

## ■ Diferentes ponderaciones:



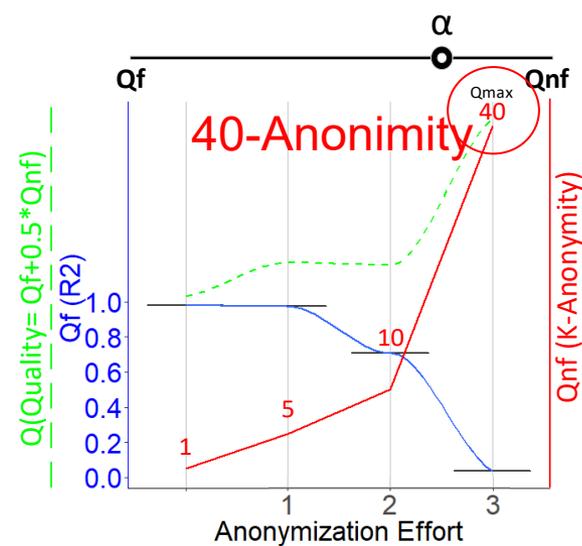
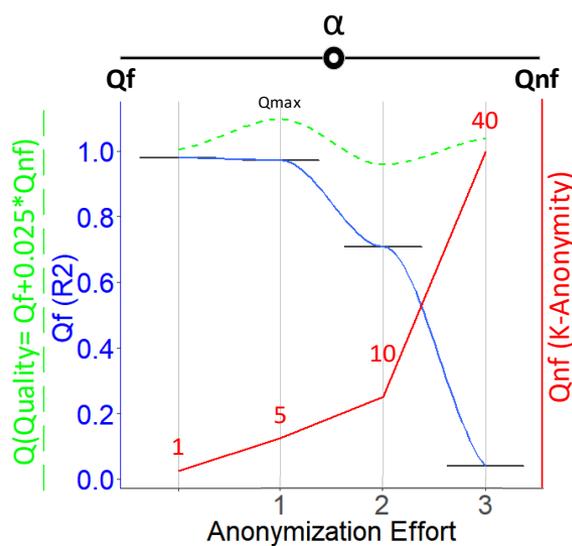
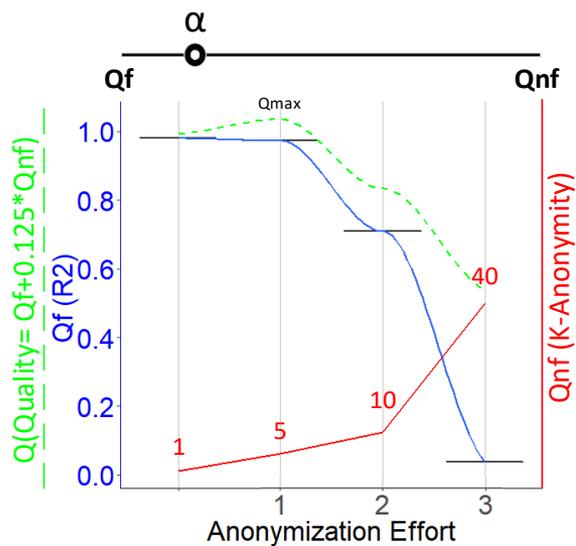
# Preferencias del usuario

## ■ Diferentes ponderaciones:



# Preferencias del usuario

## ■ Diferentes ponderaciones:

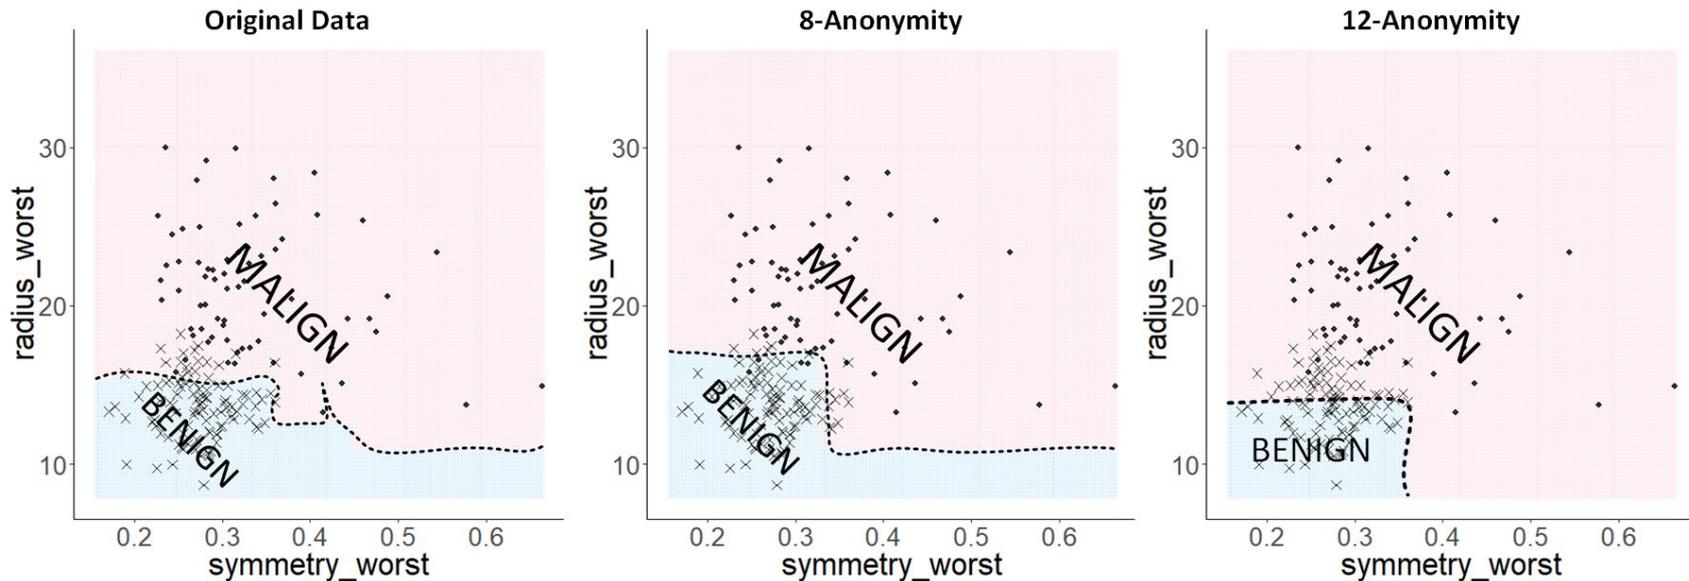


# Experimentación (I)

Id	diagnosis	radius_mean	texture_mean	perimeter_mean	area_mean	...
1	M	17.99	10.38	122.8	1001	...
2	M	<b>20.57</b>	<b>17.77</b>	<b>132.9</b>	<b>1326</b>	...
3	M	19.69	21.25	130	1203	...
4	M	<b>11.42</b>	<b>20.38</b>	<b>77.58</b>	<b>386.1</b>	...
5	M	20.29	14.34	135.1	1297	...
6	M	<b>12.45</b>	<b>15.7</b>	<b>82.57</b>	<b>477.1</b>	...
7	M	18.25	19.98	119.6	1040	...
8	M	<b>13.71</b>	<b>20.83</b>	<b>90.2</b>	<b>577.9</b>	...
9	M	13	21.82	87.5	519.8	...
10	M	<b>12.46</b>	<b>24.04</b>	<b>83.97</b>	<b>475.9</b>	...
11	M	16.02	23.24	102.7	797.8	...
12	M	<b>15.78</b>	<b>17.89</b>	<b>103.6</b>	<b>781</b>	...
13	M	19.17	24.8	132.4	1123	...
14	M	<b>15.85</b>	<b>23.95</b>	<b>103.7</b>	<b>782.7</b>	...
15	M	13.73	22.61	93.6	578.3	...

- Dos datasets de dominio publico referents a temas medicos
  - Breast-Cancer(Wisconsin) Dataset
  - Medical Cost Personal Dataset
- Usando tecnicas de generalizacion sobre los pseudo-identificadores numericos

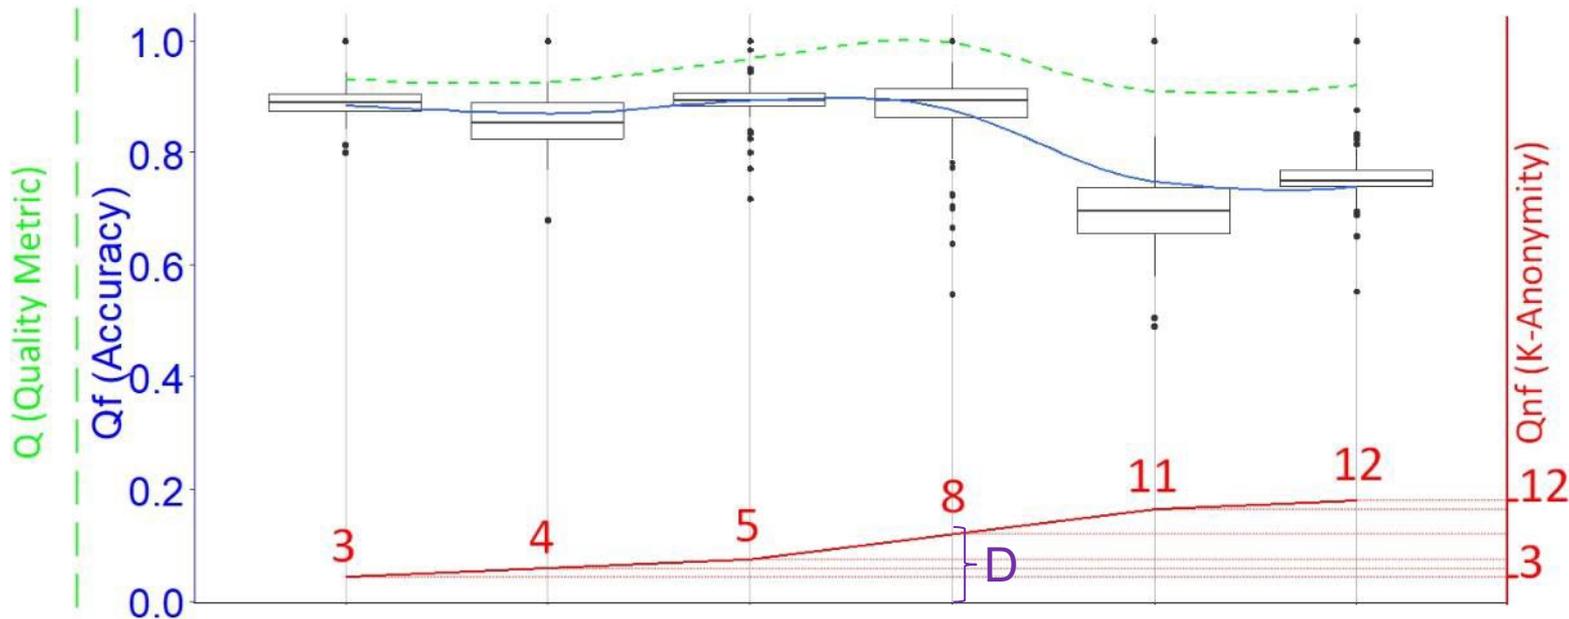
# Experimentacion(II)



## ■ Wisconsin Dataset:

- Usa un algoritmo RandomForest Algorithm para clasificar empleando dos metricas de los tumores
- Trata de predecir la clase del tumor(malign o benigno)

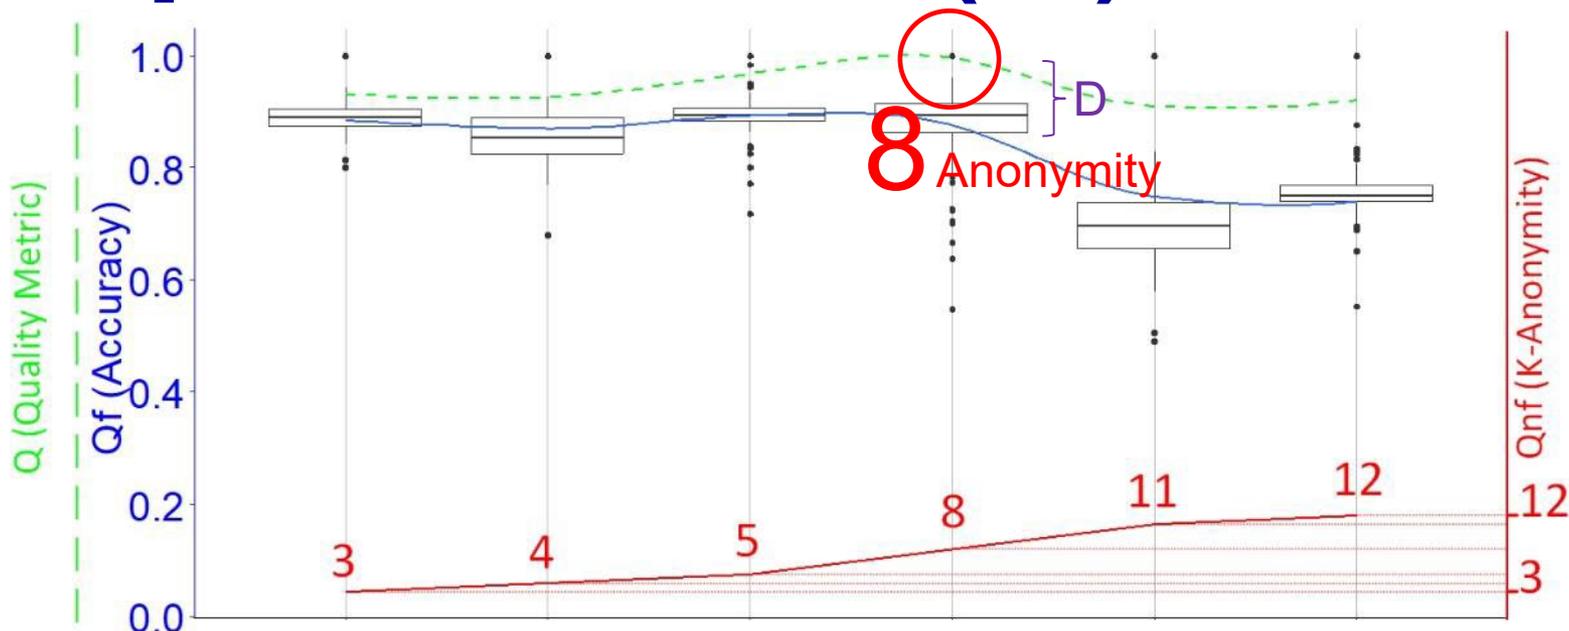
# Experimentacion(III)



## ■ Wisconsin Dataset:

- Alcanza el punto de compromiso entre calidad funcional y no funcional en 8-Anonimidad

# Experimentación (IV)



## ■ Wisconsin Dataset:

- Alcanza el punto de compromiso entre calidad funcional y no funcional en 8-Anonimidad