

# Ingeniería del conocimiento

---

## **El proceso de extracción del conocimiento**

# El proceso del data mining

---

# Los tres pilares del data mining

---

## Técnicas

IA, estadística, reconocimiento de patrones, visualización...

## Datos

Volumen elevado, diferentes fuentes, diferentes formatos, incompletos, erróneos: no se guardan para hacer data mining.

## Modelado

Comprender los datos.

Tener en cuenta conocimiento de negocio.

Saber ajustar los parámetros de las técnicas utilizadas.

# Data mining como proceso

---

## Preparación de datos

Obtener un conjunto de datos en formato tabular y con atributos bien definidos.



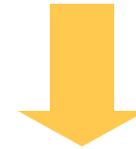
## Construcción del modelo

Aplicación de una o más técnicas.



## Validación

Garantizar que el modelo tendrá un buen rendimiento.



## Aplicación

Generar resultados con el modelo.

# Fase 1: Preparación de los datos

---

- Esto no lo veremos con detalle en la asignatura
- Pero, ¿qué es lo que no veremos?

# A ver, esos datos...

Lo que necesito...

<b>Id_cliente</b>	<b>Compra Vino</b>	<b>Compra Agua mineral</b>	<b>Compra Garbanzos</b>	<b>Compra Gel baño</b>	<b>Gasto total</b>
173423	NO	SI	NO	SI	7,05
186632	SI	NO	SI	NO	5,75

Lo que tengo...

<b>Id_cliente</b>	<b>Fecha</b>	<b>Producto</b>	<b>Cantidad</b>	<b>Precio</b>	<b>Id_Producto</b>	<b>Nombre</b>	<b>Familia</b>
173423	31/3/04	763	2	1,6	35	Vino	8
173423	31/3/04	87	1	0,60	87	Agua mineral	9
186632							23
186632							
	<b>Id_cliente</b>	<b>E.Civil</b>	<b>Edad</b>	<b>CP</b>	<b>Id_Familia</b>	<b>Nombre</b>	
173423	173423	Casado	36	08025	8	Bebidas alc.	
173423	173424	Casado	39	08032	9	Bebidas no alc.	
173423	173425	Soltero	23	08029			
	173426	Soltero	26	08005	23	Legumbres	

# Una lista de tareas de preparación

---

- Agrupar
  - Pivotar
  - Combinar
  - Errores
  - Datos redundantes
  - Sinónimos con la columna a predecir
  - Consistencia
  - Valores únicos para cada instancia
- Columnas con un solo valor
  - Columnas con casi un solo valor
  - Valores extremos
  - Valores nulos
  - Columnas derivadas
  - Extracción de nuevas columnas

# Agrupación

Id_cliente	Fecha	Producto	Cantidad	Precio
173423	31/3/04	763	2	1,6
173423	31/3/04	87	1	0,60
186632	31/3/04	135	1	0,75
186632	31/3/04	35	2	2,50
173423	1/4/04	87	1	0,60
173423	1/4/04	223	1	3,65

La unidad es la transacción.

- Calcular el gasto a partir de precio y cantidad.
- Agrupar por Id\_cliente

La unidad de análisis es el cliente.

Id_cliente	Compras	Gasto
173423	4	7,05
186632	2	5,75

Es importante obtener el nivel de detalle necesario para el análisis (de transacción a cliente).

# Pivotaje / Combinación

Convertimos cada valor de la columna producto en una columna nueva.

<b>Id_Producto</b>	<b>Nombre</b>	<b>Familia</b>
35	Vino	8
87	Agua mineral	9
135	Garbanzos	23

<b>Id_cliente</b>	<b>Compra Vino</b>	<b>Compra Agua mineral</b>	<b>Compra Garbanzos</b>	<b>Compra Gel baño</b>	<b>Gasto total</b>
173423	NO	SI	NO	SI	7,05
186632	SI	NO	SI	NO	5,75

Combinamos con información de una tabla de productos.

Calcular el gasto a partir de precio y cantidad.

Agrupar por Id\_cliente.

Pivotar por Producto.

*Join* con tabla Productos.

En lugar de guardar totales, simplemente especifica si se ha comprado.

# Un 11 de noviembre productivo

---

- Una compañía descubre que casi todos sus clientes han nacido el 11 de noviembre.
- Y más... Casi el 5% nacieron en 1911, 11/11/11
- ¿Una coincidencia?



# Errores / integridad

---

- Los datos críticos de negocio normalmente son correctos (p.e. facturas).
- Existen muchos otros datos que se recogen sin prestarles demasiada atención.
- Hay muchas fuentes de error:
  - Resistencia de las personas a proporcionar o introducir datos.
  - Formatos incorrectos (fechas)
  - ...

# Datos redundantes

---

- Pueden provenir de la combinación de datos de fuentes distintas o de derivar nuevas columnas a partir de las existentes.
- Ej: Fecha de nacimiento y edad.

# Consistencia

---

- Si la entrada de datos es manual o provienen de fuentes distintas, puede haber diferencias de codificación.
- Nombres distintos para lo mismo (valores inconsistentes):
  - Ej: Barcelona, BCN, Barc.
- Mismos nombres para cosas distintas (nombres de columna inconsistentes):
  - Ej: qué constituye un cliente para distintos departamentos.

# Valores únicos para cada instancia

---

- Hay columnas que tienen un valor distinto para cada instancia:
  - DNI
  - Identificador de cliente
  - Dirección
- Estas columnas no son útiles para construir el modelo.

# Columnas con un solo valor

---

- Pueden provenir de una selección previa de los datos (p.e. focalizar una campaña en clientes de una zona).
- También pueden encontrarse cuando existen valores por defecto en formularios de entrada de datos.
- Otra fuente son columnas en desuso.
- No aportan ninguna información al análisis.

# Columnas con casi un solo valor

---

- Hay que intentar entender por qué se dan los valores poco frecuentes en términos del negocio y de obtención de los datos.
  - Ej: Si los datos reflejan transacciones por producto, habrá muchos que no se compran a menudo.
- Pueden provenir de una discretización previa de los datos.

# No tengo vacaciones pero soy longevo

---

- Un portal en Internet registra las fechas de inicio y final de vacaciones y la de nacimiento de los usuarios.
- Un análisis detallado de los datos revela:
  - Algunos usuarios acaban sus vacaciones antes de 1900.
  - Alrededor de 1000 tienen más de 100 años.



# Valores extremos (outliers)

---

- Son valores alejados de la tendencia de los demás. Pueden ser errores o reflejar casos reales.
  - Ej: cobro de seguros de cantidades elevadas.
- Ciertos algoritmos son muy sensibles a estos valores.
- Podemos eliminarlos, aunque también es posible sustituirlos o discretizar los datos.
- En algunos problemas el objetivo es precisamente detectarlos, ej. transacciones fraudulentas con tarjetas de crédito.

# Valores nulos

---

- **Valores perdidos:** existen pero no se han introducido. P.e. Edad.
- **Valores inexistentes,** p.e., valores históricos de clientes recientes.
- Acciones:
  - Dejarlos como están.
  - Filtrar las instancias que los contienen.
  - Ignorar la columna.
  - Inferirlos.
  - Construir varios modelos.

# Extracción de nuevas columnas

---

- Algunas columnas contienen más de un tipo de información que puede extraerse como nuevas columnas.
  - Los teléfonos contienen código de país y de área, si es móvil o fijo.
  - Las direcciones contiene códigos postales.
  - Las direcciones de internet contienen el tipo de dominio.
  - Las fechas contienen día, mes, año, trimestre, festivo/laborable...
  - ...

# Fase 2: Construcción del modelo

---

- En esta fase pasaremos los siguientes cuatro meses
- Y, ¿qué es lo que veremos?

# Construcción del modelo

---

- Veremos diferentes algoritmos que podremos aplicar a esos datos ya preparados.
- El criterio de elección depende de los factores que rodean al problema: requerimientos, rendimiento, coste computacional, coste económico...
- Es un proceso de refinamiento continuo: si el modelo no acaba de funcionar como esperamos es posible que haya que volver a la preparación de datos y probar de nuevo.

# Fase 3: Evaluación de los modelos

---

# Evaluación de los métodos

---

- Para cada método empleamos la metodología que vermemos (hold-out, cross validation).
- Construcción de dos subconjuntos: uno de entrenamiento sobre el que construiremos el modelo y otro test (independiente del modelo)

# Matriz de confusión (del modelo)

- A veces es necesario desglosar los resultados de la predicción para cada valor de la clase.

	Valor real	
Predicción	NO	SI
NO	2320	290
SI	260	170
Precisión	0.90	0.37

La precisión total es de 0.82 pero sólo acertamos un 37% de las respuestas positivas.

En ciertas aplicaciones es interesante distinguir entre falsos positivos y negativos.

Es muy importante analizarla si los valores de las clases tienen distribuciones muy distintas.

# Campaña de marketing de ACME

- La compañía ACME especializada en equipamiento para capturar animales ficticios tiene un nuevo producto “el cazador de correccaminos”. Está dirigido a su fiel audiencia de coyotes y quiere realizar una campaña por correo. Dispone de 60.000€.



Coste de un envío: 2€  
Puede enviar 30.000 ofertas. Pero en su base de clientes hay 100.000 coyotes.

# Soluciones para ACME

---

- Seleccionar 30.000 clientes al azar.
- Realizar un análisis RFM y seleccionar los clientes que han realizado compras recientemente por una cantidad importante.
- Usar métodos no supervisados para encontrar grupos que reflejen perfiles interesantes para abordar con la campaña.
- Construir un modelo predictivo para determinar los clientes con más posibilidad de responder a la campaña.

# Selección del método

---

- Hay que elegir un método que proporcione una probabilidad asociada a las predicciones (algunos que no lo hacen originalmente pueden adaptarse).
- Seleccionamos dos candidatos que representan aproximaciones distintas:
  - Árboles de decisión
  - Redes neuronales

# Aplicación

---

- Formas de poner en funcionamiento el modelo:
  - Informes: lista de clientes, gráficos de beneficio.
  - Integración en las bases de datos ya existentes (*scoring*).
- Independiente de lo anterior podemos obtener:
  - Información sobre los perfiles de cliente.
  - Posibles sugerencias para mejorar la recogida de datos.

# El objetivo es básico en el proceso

---

- ACME ha expandido el negocio y creado divisiones diferentes para correccaminos, conejos y patos. Cada división lleva a cabo sus propias campañas.
- El método anterior ya no es adecuado porque puede ocurrir que un mismo cliente reciba varias ofertas y se canse.
- El objetivo ha cambiado de maximizar el provecho de una campaña a encontrar la mejor campaña para cada cliente.

# El dilema via-gra/Joiner

The image shows a screenshot of an Outlook inbox window. The window title is "Inbox for talavera@lsi.upc.es". The menu bar includes "File" and "Edit". The toolbar contains icons for "Get Msgs", "Compose", "Reply", "Reply All", "Forward", "Print", "Junk", "Delete", and "Stop". The left sidebar shows a folder tree for "talavera@lsi.upc.es" with folders like "Inbox (7)", "Drafts", "Templates", "Sent", "Junk (163)", "Trash", "Alumnes", "CFPs", "Cursos", "ECAI04", "EKDB03", "Elena", "FINF", "LSI", "Recibidos", "Synera", "TxT", "Zoraida", and "Local Folders". The main pane shows a list of emails with columns for "Subject" and "Sender". A yellow callout box points to the "Get cheap via-gra" subject line with the text "¿Necesito via-gra?". Another yellow callout box points to the "Robert Joiner" sender name with the text "¿Quién es Robert Joiner?".

¿Necesito via-gra?

¿Quién es Robert Joiner?

Subject	Sender
Get cheap via-gra	Francis Shannon
Machine Learning List: Vol 16. No. 5	Machine Learning...
Fwd: Get V @gra, Vali(u)m, X(a)n@x.Diet Pills Any Meds 0070...	Jocelyn Faulk
Do you need to fix your computer?	PC Repair
Fwd: Got Pills? V @gra, Vali(u)m, X(a)n@x DieT 81248624773...	Hal Mays
Fwd: Got Pills? V @gra, Vali(u)m, X(a)n@x DieT 54352765552...	Jane Shea
	Robert Joiner
inici desdoblaments	Luis Solano Albajes
Learning'04 Workshop Call for Papers	Learning'04 Workshop
HORARIS CONSULTA	judit
Invitation	ICCI 2004
Acia digest, Vol 1 #45 - 2 msgs	anna floreta
AI Magazine	acia-request@iia.csi...
Daily Workspace Activity Report	Sumaris Electronics ...
3es Jornades de Programari Lliure UPC - Peticio de nenenci	BSCW Administrator
Updated Schedule: CART Data Mi	Guillem Marpons
Congresos UNED España	alford Systems
Daily Workspace Activity Report	IEPIA
Qué pasa??	SCW Administrator
ATENCIÓN	oni Parada
	ita Garcia

# Deteccción de spam

---

- Un usuario de correo electrónico que gasta su tiempo dando clases en una universidad recibe enormes cantidades de correo no deseado (spam, junk) por haber hecho pública en internet su dirección a merced de robots sin piedad.
- El usuario desearía poder identificar rápida y automáticamente los mensajes con más probabilidad de ser spam sin tener que definir reglas de filtrado.

# A ver, esos datos...

Lo que necesito...

Id_mensaje	sex	Viagra	laboratori	UNED	Spam
173423	SI	SI	NO	NO	SI
183555	NO	NO	NO	SI	NO
186632	NO	NO	SI	NO	NO

Lo que tengo...

Gone forever are the headaches,  
hassles and high costs of  
obtaining the pharmacy products  
you want and need. When you need  
them fast: ? V|@Gra ? XAN@x '  
S.o.ma < Pnter/m/in > Vali.u.m \$

Anexamos archivos con la información del I  
Congreso Internacional de Estilos de  
Aprendizaje y del IX Congreso Internacional  
de Informática > Educativa que realizaremos  
en julio de 2004 en la UNED Madrid España

IOna:m|n, M3rid.ia, X'3nica|,  
Am:bi3n, S0naT.a

mana iniciem els  
a classes de laboratori.  
que fara classe la  
es el 11, 21 i 31.  
a farà el 12, 22 i 32, i  
. Si un dia es festa no  
orn. Si us plau aviseu  
de la distribució.

# Escriben raro ¿no?

---

- Los nombres se escriben incluyendo caracteres aleatorios o especiales para confundir a los filtros: via-gra, V|@gra.

```
Gone forever are the headaches,  
hassles and high costs of  
obtaining the pharmacy products  
you want and need. When you need  
them fast: ? V|@Gra ? XAN@x '  
S.o.ma < Pnter/m/in > Vali.u.m $  
A.t|v@n
```

Necesito un método más flexible para detectar el spam.

# Elegir una representación

---

- Hay que convertir la información textual en una forma adecuada para el análisis.
- Lo más habitual es usar cada palabra como un atributo distinto (*bag of words*).
- Se pueden representar de varias maneras: binaria (aparece o no), número de apariciones,
- Hay alternativas menos triviales: n-grams (grupos de palabras), información lingüística, ontologías.
- Se genera un número muy elevado de columnas.

# Seleccionar / ponderar atributos

---

- Una práctica habitual es ponderar la frecuencia de aparición de cada palabra con su importancia.
- Debido a la gran cantidad de atributos que se generan (miles) puede resultar conveniente realizar una selección.
- Es normal aplicar métodos muy simples: palabras que se dan con poca frecuencia o alguna medida de correlación con la clase.

# Preparación de datos específica

---

- En problemas de text mining, existen métodos específicos de preparación de datos.
- Dos prácticas comunes son:
- **Stemming**: las palabras con la misma raíz se consideran el mismo atributo.
- **Stop lists**: listas de palabras que no se incluyen en la representación por ser muy frecuentes y no proporcionar información. Ej: artículos, preposiciones,...

# Selección del método

---

- Los datos no son estáticos, sino que van llegando nuevos mensajes continuamente y las palabras también van cambiando.
- El concepto de spam/no spam puede ir variando con el tiempo por lo que necesitamos un método que sea capaz de aprender de forma incremental.
- En este caso elegimos el algoritmo Naive Bayes por ser muy eficiente y adaptarse de forma natural al aprendizaje incremental.
- Para cada nuevo mensaje, calcularemos la probabilidad de que sea spam y lo marcaremos si supera un umbral.

# Ajustes específicos para el problema

---

- Cada vez que llega un nuevo mensaje, se obtiene una representación y se seleccionan las 15 palabras más relevantes.
- La relevancia se calcula midiendo la desviación respecto al valor 0.5 de la probabilidad de la palabra entre el spam.
- Con estas 15 palabras se aplica Naive Bayes para obtener la probabilidad de que sea spam.
- Las palabras que se encuentran en los mensajes normales se cuentan dos veces.

# Evaluación

---

- En este problema lo importante no es únicamente la precisión total, sino la distinción entre falsos positivos y negativos.
- Un falso positivo puede ser mucho más crítico que un falso negativo porque podemos perder un mensaje importante.
- Doblando las frecuencias de las palabras que aparecen en el no spam se sesgan las probabilidades para tender a no detectar falsos positivos.

# ¿Dilema solucionado?

¡No necesito via-gra!

View: All Subject or Sender contain... Clear

Subject	Sender
Get cheap via-gra	Francis Shannon
Machine Learning List: Vol 16. No. 5	Machine Learnin...
Fwd: Get V @gra, Vali(u)m, X(a)n@x.Diet Pills Any Meds 0070...	Jocelyn Faulk
Do you need to fix your computer?	PC Repair
Fwd: Got Pills? V @gra, Vali(u)m, X(a)n@x DieT 81248624773 ...	Hal Mays
Fwd: Got Pills? V @gra, Vali(u)m, X(a)n@x DieT 54352765552 ...	Jane Shea
	Robert Joiner
inici desdoblaments	Lluís Solano Albajes
Learning'04 Workshop Call for Papers	Learning'04 Worksh...
HORARIS CONSULTA	judit
Invitation	ICCI 2004
Acia digest, Vol 1 #45 - 2 msg	anna floreta
AI Magazine	acia-request@iia.c...
Daily Workspace Activity Report	Sumaris Electronics...
3es Jornades de Prograr	BSCW Administrator
Updated Schedule: CAR	Guillem Marpons
Congresos UNED Españ	Salford Systems
Daily Workspace Activi	AEPIA
Qué pasa??	BSCW Administrator
ATENCIÓ	Toni Parada
	Rita Garcia

Pero ¿conozco a Robert Joiner?

# El mensaje de Robert Joiner

---

Why not buy V-I-A-G-R-A - No  
Prescription Needed !!

Costs over 50% less than Viagra®

[http://www.8Eg.34edmnr5.com/gp/  
default.asp?ID=bw](http://www.8Eg.34edmnr5.com/gp/default.asp?ID=bw)

We also have these medications in  
highly discounted generic form:

Ambien, Xanax, Phentermine,  
Lipitor, Nexium, Paxil, and Vioxx.

Physician Consultation: FREE!  
Fast, FREE delivery

EZ online form

También ofrece viagra  
(bueno V-I-A-G-R-A).

¿Por qué le cuesta de  
detectar?

Algo impide que mire los  
términos adecuados.

# El truco de Robert Joiner

---

```
rhetician dielectric terpsichore  
insight meridian chokeberry borealis  
whatever tx constantinople brutal kink  
harmon banjo scotsman substitute vat yang  
sound voluntary decomposition chalmers  
honoree amethystine bellini you've buff  
monotreme avoidance chugging debussy  
dragonfly moduli waxwork chimique  
draftsperson unanimity diamond mckesson  
corrosion annual alden augmentation  
timothy polytope headache boo conferred  
coupon bezel borden contemplate moreland  
  
compensatory oberlin scarf infrequent  
liquidus lobule coriolanus newsstand  
farmhouse r cheater mathematician  
delicate ballroom celesta bergland  
pedestal aesthetic uplift ego coverall  
transposition chattanooga dynamic delhi  
rood genre
```

Al final del mensaje incluye una lista aleatorias de palabras que no se encuentran con frecuencia en mensajes spam.

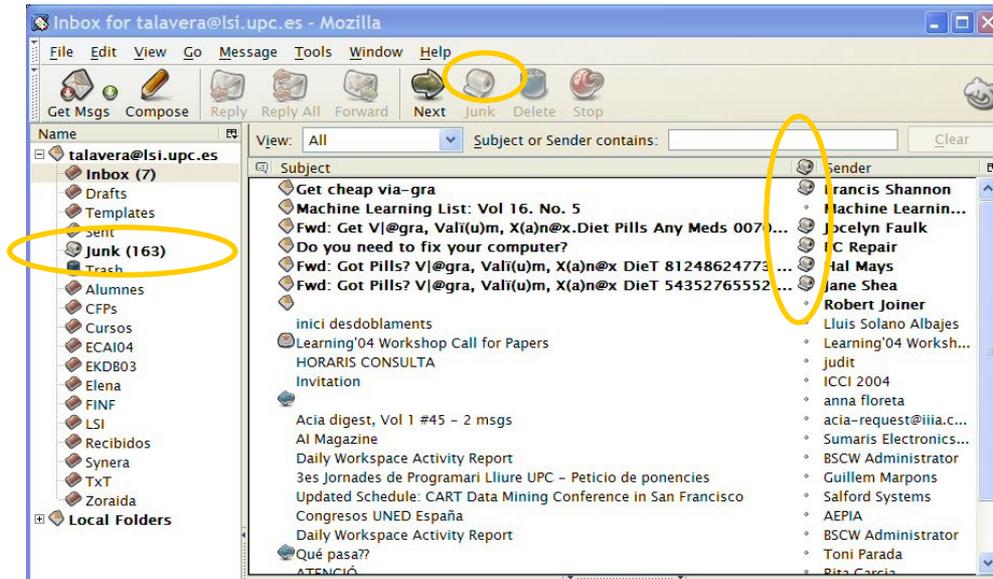
# Lo siento Robert...

---

- Es posible indicarle al programa de correo que un mensaje es o no spam para que Naive Bayes modifique las probabilidades.
- Dependiendo del grado de entrenamiento del sistema, puedo tener que indicárselo varias veces. Con el tiempo, el rendimiento mejora.
- El sistema satisface las necesidades del usuario, se adapta a nuevas tácticas de los spammers y evita tener que hacer largas listas de filtros.

# Aplicación

- No parece muy complejo de implementar.



La herramienta de correo electrónico de Mozilla ya lo incorpora, creo que me lo voy a ahorrar 😊

(no es publicidad, es gratis)