



Jesús García Herrero

INTRODUCCIÓN

En esta clase introducimos la materia del Análisis de Datos, con una motivación general a estas técnicas, dominios más relevantes de aplicación, áreas de conocimiento y panorámica de los tipos de técnicas empleadas.

Se revisan los aspectos de infraestructura, metodología y elementos necesarios para abordar cualquier estudio de análisis de datos, para a continuación explicar los conceptos clave que se desarrollarán durante el resto del curso: tipos de modelos de aprendizaje (supervisado y no supervisado), preparación de datos, instancias y atributos y transformaciones más relevantes

Se detallan los principales tipos de modelos de aprendizaje (numérico, reglas, agrupamiento, asociación), y operaciones más frecuentes de limpieza y preparación de datos: eliminación de datos ruidosos, tratamiento de datos incompletos, normalización y proyecciones.

Finalmente se presentan los principales problemas abiertos en el análisis de datos, problemas técnicos dados por las limitaciones de los modelos utilizados, y problemas no técnicos según la información que se precise acceder y explotación de los modelos resultantes.

Análisis de Datos

Introducción y visión general

Jesús García Herrero
Universidad Carlos III de Madrid



Universidad
Carlos III de Madrid




Introducción

- La sociedad de la información e Internet han generado una explosión de datos
 - No hay suficiente gente que pueda analizar tal cantidad de datos
 - Potencia de computación disponible
 - El desarrollo de software es un cuello de botella
- Extraer conocimiento a través de ejemplos es atractivo
 - Aprendizaje de la experiencia para tomar decisiones
 - Servicios comerciales, financieros, etc. tienden hacia la personalización: adaptación al individuo
- Es muy importante la comprensibilidad de la salida

Extracción de conocimiento

- Descubrimiento de patrones, relaciones y tendencias mediante análisis de gran cantidad de datos



Ejemplos de aplicaciones

- Toma de decisiones
 - Cuándo concedo un crédito hipotecario? por cuánto? Qué tipo de solicitante no devolverá el crédito?
 - Un cliente de tarjeta de crédito está realizando una compra, pagará? se la han robado?
- Diagnósticos
 - Determinación de enfermedades
 - Fallos en procesos industriales
- Marketing y ventas
 - Hábitos y fidelidad de clientes. Cuál es el perfil de los clientes que se gastan al mes más de 100.000 pts?
 - Análisis de compras. Qué productos de nuestra empresa es el que compran los clientes junto al detergente?
 - Análisis de perfil más adecuado para publicidad directa.


Ejemplos de aplicaciones

- Predicción
 - Cuánta energía se va a consumir en los próximos días?
- Agencia tributaria
 - Cuál es el perfil de los “defraudadores”?
 - Se puede subdividir en grupos homogéneos y caracterizar los diferentes tipos de contribuyentes?
 - Cuáles están más alejados de cada grupo?
- Herramienta de investigación. Ej.: imágenes:
 - Dada una imagen tomada por un telescopio, soy capaz de detectar y clasificar objetos interesantes?
 - Alerta de fuegos, fugas de combustible, militares, etc.?
- Mejora de procesos industriales
- ...


Análisis de datos en Internet

- Web Mining: análisis de páginas para extraer automáticamente información
- e-Mining: análisis de las interacciones de los clientes con mis páginas
- Web para extraer información
- Tipo de información que busco:
 - Qué tipo de clientes tengo
 - Cómo interacciona cada tipo de cliente con las páginas Web
 - Qué banners son los que siguen mis clientes (publicidad)
 - Descubrimiento de patrones de compra/navegación
- Herramientas de gestión automática del correo

Data Warehouse



Data Warehouse y Data Marts




Introducción al Análisis de Datos

¿Qué es un CUBO de información?

Un “cubo” es una estructura para almacenar información que permite realizar análisis multidimensional y se basa en métricas y dimensiones.

Métrica: Medición matemática de una variable del negocio.
Qué quiero medir.




- cantidad de ventas
- unidades vendidas
- % desecho
- # productos en almacén
- etc.

¿Qué es un CUBO de información?

Un “cubo” es una estructura para almacenar información que permite realizar análisis multidimensional y se basa en métricas y dimensiones.


Dimensión. Contra qué quiero medir.



- sucursales
- zona
- clientes
- vendedores
- etc.


Operaciones con cubos OLAP

Drill Down. Desglosar una métrica de lo general a lo particular por la jerarquía de sus dimensiones




Operaciones con cubos OLAP

Drill Up. Agregar una métrica de lo particular a lo general por la jerarquía ascendente de sus dimensiones




Operaciones con cubos OLAP

Slice. Obtener un sub-cubo fijando una de sus dimensiones



Operaciones con cubos OLAP

Dice. Obtener un sub-cubo fijando dos o mas de sus dimensiones



Tiempo = Ene. **or** Feb
Geografía = Norte **or** Este
Ventas del Producto = C **or** B

Obtenemos un cubo 2 x 2

Tiempo = Ene. **or** Feb
Geografía = Norte **or** Este

Obtenemos un cubo 2 x 3

El Proceso de KDD

INTERPRETACIÓN Y EVALUACIÓN



Conocimiento

MINERÍA DE DATOS

Modelos

TRANSFORMACIÓN

Datos Transformados






LIMPIEZA

Datos Procesados

SELECCIÓN

Datos objetivo


Datos



Introducción al Análisis de Datos

El Proceso de KDD

- Contexto de un aplicación con Análisis de Datos.
 - Proceso interactivo e iterativo. Ensayo y error




METODOLOGÍA


1. Formular el problema
2. Determinar la representación (atributos y clases)
 - directamente
 - hablando con expertos
 - a partir de otras técnicas (filtros)
3. Identificar y recolectar datos de entrenamiento (bases de datos, ficheros, ...)
4. Preparar datos para análisis
5. Selección de modelo, construcción y entrenamiento
6. Evaluar lo aprendido
 - validación cruzada, expertos
7. Integrar la base de conocimiento a la espera de nuevos datos tras acciones

TÉCNICAS MD

Supervisada



No Supervisada



Clasificación

Predicción

Agrupamiento

Asociación

Tabla de Decisión
Árboles de Decisión
Reglas
Bayesiana
Basado en Ejemplares
Redes de Neuronas

Regresión
Árboles de Predicción
Estimador de Núcleos

Numérico K-MEDIAS
Conceptual
Probabilístico

A Priori

Técnica

Tipos de técnicas

- Paramétricas, no paramétricas
- Grado de supervisión
 - Supervisadas, no supervisadas, por refuerzo
- Tipo de información resultante
 - Simbólica, subsimbólica/numérica, mixta
- Número de técnicas empleadas
 - Sencillos, meta-clasificadores
- Tipo de clases
 - Discretas, continuas, desconocidas

Estadística vs. aprendizaje automático

- Técnicas estadísticas
 - asumen una determinada estructura/ distribución
 - tienen que determinar los parámetros (técnicas paramétricas)
 - pueden funcionar con pocos datos. Verificación de hipótesis
 - basadas fundamentalmente en la estadística
- Técnicas no-paramétricas (aprendizaje automático)
 - están dirigidas por los datos. Realizan un mínimo de suposiciones
 - pueden capturar cambios estructurales en los datos
 - determinan los parámetros y además la estructura del modelo
 - admiten formulación genérica como búsqueda.
 - basadas fundamentalmente en la computación (algoritmos).

Elementos básicos de entrada

- **Concepto:** qué se quiere aprender (estructura inteligible y útil para cada tipo de problema). Salida: descripción del concepto
 - Clasificación
 - Predicción/Estimación
 - Asociación
 - Agrupamiento
- **Atributo:** qué características (variables) se van a utilizar para describir el concepto
 - Ej.: salario, crédito solicitado, categoría a la que pertenece, ...
 - Tipos: continuos, nominales/categóricos
- **Clase:** diferentes valores (etiquetas) del concepto aprendido
 - Ej.: sí, no, necesita-aval, etc.
- **Instancia** o ejemplo: cada muestra a partir de la cual se extrae el concepto

TABLA DE DATOS

Entrada: Instancias (o ejemplos):

SALARIO	CLIENTE	EDAD	...	HIJOS	CRÉDITO
Poco	Sí	Joven	...	Uno	NO
Mucho	No	Adulto	...	Dos	SI
Mucho	No	Adulto	...	Dos	SI
Medio	Sí	Mayor	...	Tres	NO
⋮	⋮	⋮	⋮	⋮	⋮

Salida: Árboles, tablas de decisión, reglas, clusters, modelos regresión, etc.

Introducción al Análisis de Datos

Salida. Estructuras de conocimiento

- Árboles, tablas de decisión, reglas, clusters, modelos regresión, etc.
- Instancias:


SALARIO	CLIENTE	EDAD	...	HIJOS	CRÉDITO
Poco	Sí	Joven	...	Uno	NO
Mucho	No	Adulto	...	Dos	SI
Mucho	No	Adulto	...	Dos	SI
Medio	Sí	Mayor	...	Tres	NO
:	:	:	⋮	:	:

TÉCNICAS MD

Supervisado


Clasificación

Separar instancias de cada categoría (aprender fronteras de clases)



Predicción

Predecir valores numéricos (aprender funciones de interpolación)




No Supervisado

Clasificadores bayesianos

- Tablas de prob. condicionales

SALARIO	CLIENTE	EDAD	...	HIJOS	CRÉDITO
Poco	Sí	Joven	...	Uno	NO
Mucho	No	Adulto	...	Dos	SI
Mucho	No	Adulto	...	Dos	SI
Medio	Sí	Mayor	...	Tres	NO
⋮	⋮	⋮	⋮	⋮	⋮



	Crédito	No	Sí
Salario			
Poco		0.4	0.2
Mucho		0.3	0.6
Medio		0.3	0.2

	Crédito	No	Sí
Cliente			
Sí		0.4	0.3
No		0.6	0.7

	Crédito	No	Sí
Hijos			
Uno		0.2	0.1
Dos		0.3	0.0
Tres		0.5	0.9

	Crédito	No	Sí
Edad			
Joven		0.4	0.2
Adulto		0.4	0.6
Mayor		0.2	0.2


...

$$p(\text{SI}) = 0.63$$


$$p(\text{NO}) = 0.37$$

Árboles de decisión

SALARIO	CLIENTE	EDAD	...	HIJOS	CRÉDITO
Poco	Sí	Joven	...	Uno	NO
Mucho	No	Adulto	...	Dos	SI
Mucho	No	Adulto	...	Dos	SI
Medio	Sí	Mayor	...	Tres	NO
⋮	⋮	⋮	⋮	⋮	⋮




Árboles de regresión



Reglas de decisión

SALARIO	CLIENTE	EDAD	...	HIJOS	CRÉDITO
Poco	Sí	Joven	...	Uno	NO
Mucho	No	Adulto	...	Dos	SI
Mucho	No	Adulto	...	Dos	SI
Medio	Sí	Mayor	...	Tres	NO
⋮	⋮	⋮	⋮	⋮	⋮




Si (Cliente=No) Y (Edad=Joven) Entonces NO
Si (Cliente=No) Y (Edad=Adulto) Entonces SI
Si (Cliente=Sí) Y (Salario=Ninguno) Entonces NO
Si (Cliente=Si) Y (Salario=Medio) Entonces SI
...

- Reglas proposicionales y relacionales
- Convertibilidad de árboles en reglas
- Tablas secuenciales y no secuenciales


Aprendizaje vago

- Se almacena toda la tabla de instancias:




- Caso particular: *tabla de decisión*
- Poca eficiencia de cómputo
- Ausencia de análisis de información

Propiedades (discutible)



TÉCNICAS MD



REGLAS DE ASOCIACIÓN

Búsqueda general de relaciones significativas entre atributos

No supervisado

Mayor número de grados de libertad para búsqueda (subconjuntos)

SALARIO	CLIENTE	EDAD	...	HIJOS	CRÉDITO
Poco	Sí	Joven	...	Uno	NO
Mucho	No	Adulto	...	Dos	SI
Mucho	No	Adulto	...	Dos	SI
Medio	Sí	Mayor	...	Tres	NO
⋮	⋮	⋮	⋮	⋮	⋮


A dashed line points from the first row of the table to the first rule in the list below. A vertical dashed line with a downward arrow is positioned to the left of the table.

Si (Edad=Joven) Entonces Hijos < Tres
Si (Residencia=X) Entonces (Salario=Medio) Y (Hijos>2)
Si (Salario=NO) Entonces (Salario=Bajo) O (Salario=Mucho)
Si (Crédito=Si) Entonces (Cliente=Si)
...

Algoritmo
“A priori”

Agrupación (clustering)

	SALARIO	CLIENTE	EDAD	...	HIJOS	CRÉDITO
(a)	Poco	Sí	Joven	...	Uno	NO
(b)	Mucho	No	Adulto	...	Dos	SI
(c)	Mucho	No	Adulto	...	Dos	SI
(d)	Medio	Sí	Mayor	...	Tres	NO
⋮	⋮	⋮	⋮	⋮	⋮	⋮




PREPARACIÓN DE DATOS


- La preparación de datos puede suponer 60-90% del tiempo
 - objetivo: única tabla de datos (instancias, atributos)
 - ensamblar, integrar formatos, agregar, ...
- **Filas:** Agregación: selección de dato unitario
 - asociar datos, calcular resúmenes, ...
- **Columnas:** Selección de atributos
 - eliminar campos redundantes o inapropiados (ID)
 - crear atributos de interés de campos textuales
 - fecha/hora->edad, estación, vacaciones, mañana/tarde/noche,
 - dirección/código postal-> lugar geográfico, área, ciudad
 - transformar atributos

PREPARACIÓN DE DATOS

- Integración
 - Múltiples fuentes (bases de datos, ficheros, ...)




- Limpieza
 - Valores faltantes, outliers, inconsistencias
- Transformación
 - Normalizar, proyectar, discretizar
- Reducción
 - Representación reducida




LIMPIEZA: DATOS RUIDOSOS

- **Outliers** : detección y eliminación (o tratamiento individual)
 - Analisis de clusters



Regresión



LIMPIEZA: DATOS INCOMPLETOS, REDUNDANTES

- **Datos Redundantes:** detectar relaciones causales o funcionales en datos
 - Frecuente al integrar múltiples bases de datos
 - El mismo atributo con diferente nombre
 - Relaciones directas: atributo “calculado”
 - Se detecta con análisis de correlación
- **Datos incompletos:** faltan atributos en algunos ejemplos
 - Relleno manual: tedioso o no posible
 - Ignorar ejemplo: cuando son pocos casos
 - Nuevo valor “desconocido”
 - Valor medio, valor más probable según resto, ...

TRANSFORMACION DE DATOS


- Agregación: resumen, cubos de datos
- Normalización: re-escalar las variables (para distancias)
 - normalización min-max $v' = \frac{v - \mathit{min}_A}{\mathit{max}_A - \mathit{min}_A}$
 - normalización estadística (tipificar) $v' = \frac{v - \mathit{media}_A}{\mathit{stand_dev}_A}$
- Selección/transformación de atributos
 - Discretizar
 - Quitar atributos redundantes
 - Proyectar a espacios reducidos: PCA

TRANSFORMACIÓN: DISCRETIZACION


- Discretización
 - Reducir número de valores, o poner intervalos a variables continuas.
Ej.: edad->(joven, adulto, mayor)
 - Reduce el tamaño de datos y mejora precisión
 - Misma amplitud:
 - Cajas: $W = (\text{Max}-\text{min})/N$.
 - El más directo. Problemas de escala y con outliers
 - Misma frecuencia:
 - Cada caja el mismo numero de muestras
 - Métodos supervisados

TRANSFORMACIÓN: PROYECCIÓN PCA

- Dados vectores k -dimensionales, buscar vectores ortogonales de dimensión $c \leq k$
- Aplicable a datos numéricos de muchas dimensiones




$$C = \frac{1}{n} X^t X = U \Lambda U^t = \begin{pmatrix} u_{11} & u_{21} \\ u_{12} & u_{22} \end{pmatrix} \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} \begin{pmatrix} u_{11} & u_{12} \\ u_{21} & u_{22} \end{pmatrix}$$



Otros aspectos de preparación

- Formulación problema, atributos, representación...



persona1	persona2	hermana?
Peter	Peggy	No
Peter	Steven	No
⋮	⋮	⋮
Brian	Pam	Sí
⋮	⋮	⋮

persona1	persona2	abuelo?
Peter	Peggy	No
Peter	Steven	No
⋮	⋮	⋮
Anna	Peter	Sí
⋮	⋮	⋮

Desnormalización de relaciones

persona1	género	padre	madre	persona2	género	padre	madre	hermana?
Brian	V	Ray	Grace	Pam	M	Ray	Grace	Sí
Pippa	M	Ray	Grace	Pam	M	Ray	Grace	Sí
⋮				⋮				⋮
Nikki	M	Ian	Pam	Anna	M	Ian	Pam	Sí
Resto								No

Si (género persona2=M) Y (padre persona 1=padre persona 2) Entonces Si


Si (género persona2=M) Y (madre persona 1=madre persona 2) Entonces Si

Resto: NO

- Abuelo? Más atributos
- Descendiente? Programación lógica inductiva

Reglas proposicionales y relacionales

- A veces se precisan reglas con relaciones entre atributos para aprender un tipo de problema



Proposicional

Si $(\text{ancho} \geq 4)$ y $(\text{alto} < 3) \Rightarrow$ tumbado

Si $(\text{alto} > 6) \Rightarrow$ levantado

...

Relacional

Si $(\text{ancho} > \text{alto}) \Rightarrow$ tumbado

Si $(\text{ancho} < \text{alto}) \Rightarrow$ levantado

Problemas técnicos

- Relaciones espúreas, casuales o coincidencias
- Datos incorrectos o incompletos
- Datos distribuidos
- Conceptos que cambian con el tiempo
- Datos que llegan en el tiempo
- Datos o formulación del problema sesgados
- Conceptos en varios niveles de generalización
- Integración de información cualitativa y cuantitativa

Problemas no técnicos

- Las máquinas no son responsables de las predicciones o clasificaciones
- Los humanos no se fían de los resultados
- La salida no es entendible por el humano
- Hay que proporcionar al sistema los valores de los atributos
- Miedo de los humanos a la pérdida de control
- Cuestiones legales y éticas: privacidad, discriminación, etc.