

Índice general

Prefacio	5
----------------	---

Capítulo 1

Introducción	13
1.1 Introducción.....	13
1.2 Los datos.....	19
1.3 Etapas en los procesos de <i>big data</i>	20
1.4 Minería de datos.....	21
1.5 Estructura de un proyecto de análisis de datos..	22
1.6 Aplicaciones.....	25
1.6.1 <i>Marketing</i>	25
1.6.2 Compañías de seguros.....	26
1.6.3 Banca	26
1.6.4 Telecomunicaciones	27
1.6.5 Medicina	27
1.6.6 Industria farmacéutica.....	27
1.6.7 Biología	28
1.6.8 Minería de textos.....	28
1.6.9 Minería de datos web	29
1.6.10 Redes sociales.....	30
1.7 Modelos y tareas	31
1.7.1 Tareas descriptivas	32
1.7.1.1 Agrupamiento	32
1.7.1.2 Correlaciones y factorizaciones	32
1.7.1.3 Reglas de asociación.....	33
1.7.1.4 Dependencias funcionales.....	33
1.7.2 Tareas predictivas.....	34
1.7.2.1 Clasificación.....	34
1.7.2.2 Clasificación suave	35
1.7.2.3 Categorización	35
1.7.2.4 Preferencias o priorización.....	35
1.7.2.5 Regresión	36
1.8 Métodos y técnicas.....	36
1.8.1 Técnicas algebraicas y estadísticas.....	36
1.8.2 Técnicas bayesianas	37
1.8.3 Técnicas basadas en conteos de frecuencias y tablas de contingencia	37

1.8.4 Técnicas basadas en árboles de decisión y sistemas de aprendizaje de reglas.....	37
1.8.5 Técnicas relacionales, declarativas y estructurales.....	37
1.8.6 Técnicas basadas en redes neuronales artificiales	37
1.8.7 Técnicas basadas en núcleo y máquinas de soporte vectorial	38
1.8.8 Técnicas estocásticas y difusas	38
1.8.9 Técnicas basadas en casos, en densidad o distancia	38

Capítulo 2

Análisis estadístico de datos.....39

2.1 Introducción.....	39
2.2 Análisis de una variable. Estadística descriptiva e inferencia.....	40
2.2.1 Estadísticos de variable continua.....	41
2.2.2 Histograma.....	42
2.2.3 Estadísticos de variables nominales	44
2.3 Contrastes de hipótesis	46
2.3.1 Distribuciones de probabilidad.....	46
2.3.1.1 Distribución normal	47
2.3.2 Inferencia	49
2.3.3 Evaluación de hipótesis.....	51
2.4 Análisis de relaciones entre variables.	
Evaluación de hipótesis.....	54
2.4.1 Relación entre variables nominales-nominales.....	54
2.4.2 Relaciones numéricas-nominales	56
2.4.2.1 Comparación de dos medias.....	56
2.4.2.2 Análisis de la varianza	58
2.4.3 Relaciones numéricas-numéricas.....	61

Capítulo 3

Introducción al lenguaje R. Lectura, procesado y visualización de datos:

<i>data wrangling</i>.....63	
3.1 Carga y transformaciones de datos	63
3.1.1 Estructura básica de datos	64
3.1.2 Lectura de fichero.....	65

3.2 Estadística descriptiva	68
3.2.1 Variables categóricas.....	84
3.2.2 Correlación	88
3.2.2.1 Visualización	88
3.2.3 Test de hipótesis	97
3.2.4 Representación de datos.....	100

Capítulo 4

Predicción y clasificación con técnicas numéricas.....117

4.1 Técnicas numéricas de predicción.....	117
4.1.1 Regresión lineal	117
4.1.1.1 Regresión lineal simple.....	118
4.1.1.2 Regresión lineal múltiple.....	119
4.1.1.3 Regresión lineal ponderada localmente	121
4.1.1.4 Atributos nominales	123
4.1.2 Evaluación del modelo de regresión	124
4.1.2.1 Error de regresión y selección de variables	126
4.1.3 Regresión no lineal.....	130
4.1.3.1 Transformaciones sencillas	131
4.1.3.2 Otras transformaciones.....	133
4.1.4 Ejemplos de regresión lineal.....	133
4.2 Técnicas numéricas de clasificación	136
4.2.1 Clasificación mediante regresión lineal	138
4.2.2 Clasificación mediante regresión logística	139
4.2.3 Clasificación bayesiana.....	141
4.2.3.1 Clasificación bayesiana de atributos numéricos	141
4.2.3.2 Clasificación bayesiana con atributos nominales.....	146
4.2.4 Ejemplos de clasificación bayesiana	147

Capítulo 5

Predicción y clasificación con R153

5.1 Regresión.....	153
5.1.1 Regresión lineal	153
5.1.2 Selección de atributos	165
5.1.3 Regresión no lineal.....	169
5.1.4 Regresión de atributos no continuos	172
5.1.5 Modelos lineales generalizados	179

5.2 Algoritmos de clasificación.....	185
5.2.1 Detección de valores atípicos.....	186
5.2.2 LDA, <i>Linear Discriminant Analysis</i>	195
5.2.3 Clasificadores probabilísticos.....	200
5.2.3.1 <i>Naïve</i> bayesiano.....	201
5.2.3.2 Redes bayesianas	202

Capítulo 6

Técnicas de minería de datos.....	205
6.1 Técnicas de minería de datos	205
6.2 <i>Clustering</i>	207
6.2.1 <i>Clustering</i> numérico (k-medias).....	209
6.2.2 <i>Clustering</i> conceptual (COBWEB)	210
6.2.3 <i>Clustering</i> probabilístico (EM)	214
6.3 Reglas de asociación	217
6.4 Predicción numérica	220
6.4.1 Predicción no lineal con árboles de regresión.....	220
6.4.2 Estimador de núcleos.....	225
6.4.2.1 Aplicación a problemas multivariantes.....	228
6.4.2.2 Aplicación a problemas de clasificación.....	229
6.5 Clasificación	231
6.5.1 Tabla de decisión	231
6.5.2 Árboles de decisión.....	233
6.5.3 Reglas de clasificación	245
6.5.4 Clasificación bayesiana.....	251
6.5.5 Aprendizaje basado en ejemplares	257
6.5.5.1 Algoritmo de los k-vecinos más próximos.....	258
6.5.5.2 Algoritmo k-estrella.....	260
6.5.5.3 Probabilidad de transformación para los atributos permitidos.....	261
6.5.5.4 Combinación de atributos	262
6.5.5.5 Selección de los parámetros aleatorios	262
6.5.5.6 Clasificación de un ejemplo	264
6.5.6 Máquinas de vectores de soporte (SVM)	265
6.5.6.1 SVM lineal.....	266
6.5.6.2 SVM lineal de margen blando (<i>soft margin</i>)	270
6.5.6.3 SVM no lineal. Funciones <i>kernel</i>	272
6.5.6.4 Clasificación multiclase	276
6.5.7 Redes de neuronas	277
6.5.7.1 Estructura de las redes de neuronas.....	278
6.5.7.2 Proceso de entrenamiento (retropropagación).....	279
6.5.8 Lógica borrosa (<i>fuzzy logic</i>)	281
6.5.9 Técnicas genéticas: algoritmos genéticos (<i>genetic algorithms</i>)	282

Capítulo 7

Técnicas de minería de datos en R.....285

7.1 Agrupamiento. <i>Clustering</i>	285
7.1.1 Agrupamiento jerárquico.....	286
7.1.2 Número óptimo de agrupaciones.....	289
7.1.3 Agrupamiento por particionamiento	299
7.1.4 Agrupamiento basado en modelos.....	305
7.1.5 Agrupamiento borroso (<i>fuzzy</i>).....	312
7.1.6 Otras técnicas de agrupamiento.....	314
7.1.7 Representación y análisis de las clases.....	323
7.1.8 Validación de resultados	326
7.2 Clasificación	329
7.2.1 Selección de atributos	329
7.2.2 Reducción de la dimensionalidad.....	340
7.2.3 Árboles de decisión.....	347
7.2.3.1 RPART (<i>Recursive Partitioning and Regression Trees</i>).....	347
7.2.3.2 Árboles de inferencia condicional, CTREE.....	350
7.2.3.3 C5.0	351
7.2.4 Metaalgoritmos.....	354
7.2.4.1 AdaBoost (<i>ADaptive BOOSTing</i>).....	355
7.2.4.2 GBM (<i>Gradient Boosting Machine</i>)	356
7.2.4.3 <i>Random forest</i>	358
7.2.5 SVM, máquinas de vectores de soporte	359
7.2.6 K vecinos próximos. k-NN (<i>k-Nearest Neighbors</i>).....	361
7.2.7 Redes de neuronas artificiales	363

Capítulo 8

Internet de las cosas y análisis de series temporales.....369

8.1 Internet de las cosas	369
8.2 Thingier.io IoT	371
8.2.1 <i>Hardware</i>	372
8.2.2 Configuración de la plataforma	374
8.2.3 <i>Software</i> del dispositivo	376
8.2.4 Visualización y exportación de la información.....	379
8.3 Series temporales	381
8.3.1 Predicción con series temporales	382
8.3.1.1 Predicción lineal (autorregresión).....	382
8.3.1.2 Error de predicción.....	384
8.3.1.3 Predicción no lineal	385
8.3.2 Análisis y descomposición de series.....	386
8.3.2.1 Tendencia y estacionalidad.....	386
8.3.2.2 Modelos ARMA/ARIMA.....	389

8.4 Análisis de series con R	390
8.4.1 Componentes de la serie temporal	392
8.4.2 Modelos de predicción	400
8.4.3 Detección de anomalías.....	408

Capítulo 9

Análisis de datos espaciales.....**411**

9.1 Introducción.....	411
9.1.1 Datos de tipo espacial	412
9.1.2 Latitud, longitud	413
9.1.3 La clase de datos Spatial en RStudio	414
9.1.4 Datos	414
9.2 Tipos de datos.....	416
9.2.1 Creación de objetos SpatialPoints	416
9.2.2 Creación de objetos SpatialGrid.....	420
9.3 Visualización de datos espaciales	421
9.4 Análisis estadístico (interpolación).....	423
9.4.1 Análisis exploratorio de datos.....	424
9.4.1.1 Crear <i>grid</i> Ávila-Madrid	424
9.4.2 Interpolación IDW (<i>Inverse Distance Weighted</i>).....	427
9.4.2.1 Presentación de resultados IDW	428
9.4.3 Correlación espacial (variograma).....	428
9.4.3.1 Selección modelo de variograma.....	428
9.4.3.2 Presentación de resultados.....	430

Bibliografía.....**431**