



OPENCOURSEWARE

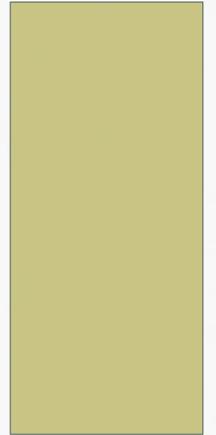
APRENDIZAJE AUTOMÁTICO PARA EL ANÁLISIS DE DATOS

GRADO EN ESTADÍSTICA Y EMPRESA

Ricardo Aler

INTRODUCCIÓN AL APRENDIZAJE AUTOMÁTICO

1. TIPOS DE TAREAS, MODELOS Y ALGORITMOS



TAREAS

- ¿Qué se puede hacer en aprendizaje automático? **Tareas:**
 - Supervisado: clasificación, predicción (regresión), ...
 - No supervisado: asociación, agrupamiento (clustering), ...
 - Semi-supervisado
 - Por refuerzo

TAREAS

- Tareas:
 - **Aprendizaje supervisado:**
 - **Clasificación:**
 - **Discreta**
 - Ranking, scoring, probability estimation
 - Predicción numérica (regresión)
 - Aprendizaje semi-supervisado
 - Aprendizaje no supervisado:
 - Agrupamiento o clustering
 - Asociación
 - Aprendizaje por refuerzo

UN EJEMPLO DE PROBLEMA SUPERVISADO DE CLASIFICACIÓN DISCRETA:

- Concesión de créditos bancarios
 - Un banco por Internet desea obtener reglas para predecir qué personas de las que solicitan un crédito no van a devolverlo.
 - La entidad bancaria cuenta con una gran base de datos correspondientes a los créditos concedidos (o no) a otros clientes con anterioridad.
 - Instancias (de la base de datos del banco):
 - Atributos de entrada: años del crédito, cuantía del crédito, tiene cuentas morosas, tiene casa propia
 - Clase: si/no
 - Modelo que se podría aprender:
 - **SI** (cuentas-morosas > 0) **ENTONCES** Devuelve-crédito = no
 - **SI** (cuentas-morosas = 0) **Y** ((salario > 2500) **O** (años > 10)) **ENTONCES** devuelve-crédito = si

UN EJEMPLO DE PROBLEMA SUPERVISADO DE CLASIFICACIÓN DISCRETA:

Instancia de test

Años	Euros	Salario	Casa propia	Cuentas morosas	Crédito
10	50000	3000	Si	0	??

T = Conjunto de instancias de entrenamiento (o ejemplos, datos, patrones, ...)

Años	Euros	Salario	Casa propia	Cuentas morosas	Crédito
15	60000	2200	Si	2	No
2	30000	3500	Si	0	Si
9	9000	1700	Si	1	No
15	18000	1900	No	0	Si
10	24000	2100	No	0	No
...

Debido a esta columna, la tarea es supervisada

Algoritmo

Modelo

IF CM > 0 THEN NO

IF CM = 0 Y S > 2500 THEN SI

...

Crédito = Si

x: atributos (o características, predictores, variables independientes, variables de entrada, ...)

y: clase (o etiqueta, atributo de salida, variable dependiente, variable respuesta, ...)

APRENDIZAJE SUPERVISADO. CLASIFICACIÓN CON CLASES DISCRETAS

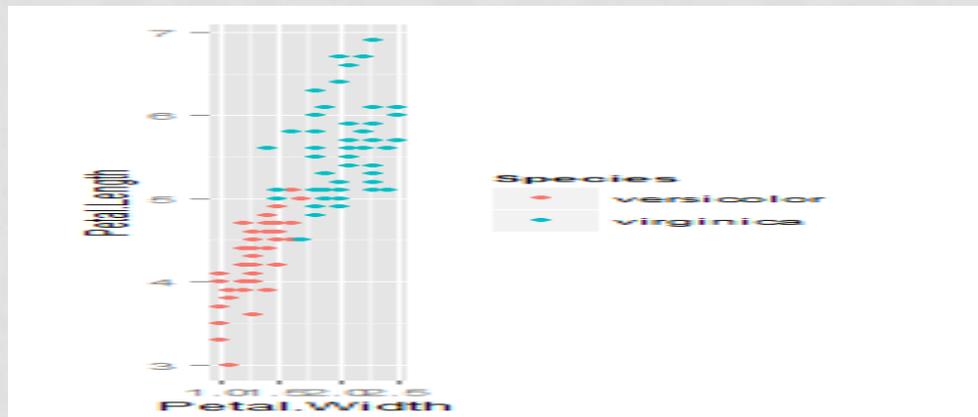
- Tipos de atributos:
 - Nominales / categóricos: verde, rojo, amarillo
 - Ordinales: frío, templado, caliente
 - Reales / enteros: 1.3, 7.9, 10.798, ...
- $Y = \{c_1, c_2, \dots, c_k\}$ son las clases.
 - Si $k=2$, problema de clasificación binaria: cáncer / no-cáncer
 - Si $K>2$, problema de clasificación multi-clase: peligroso / normal / inofensivo

DEFINICIÓN: FEATURE SPACE (ESPACIO DE INSTANCIAS)

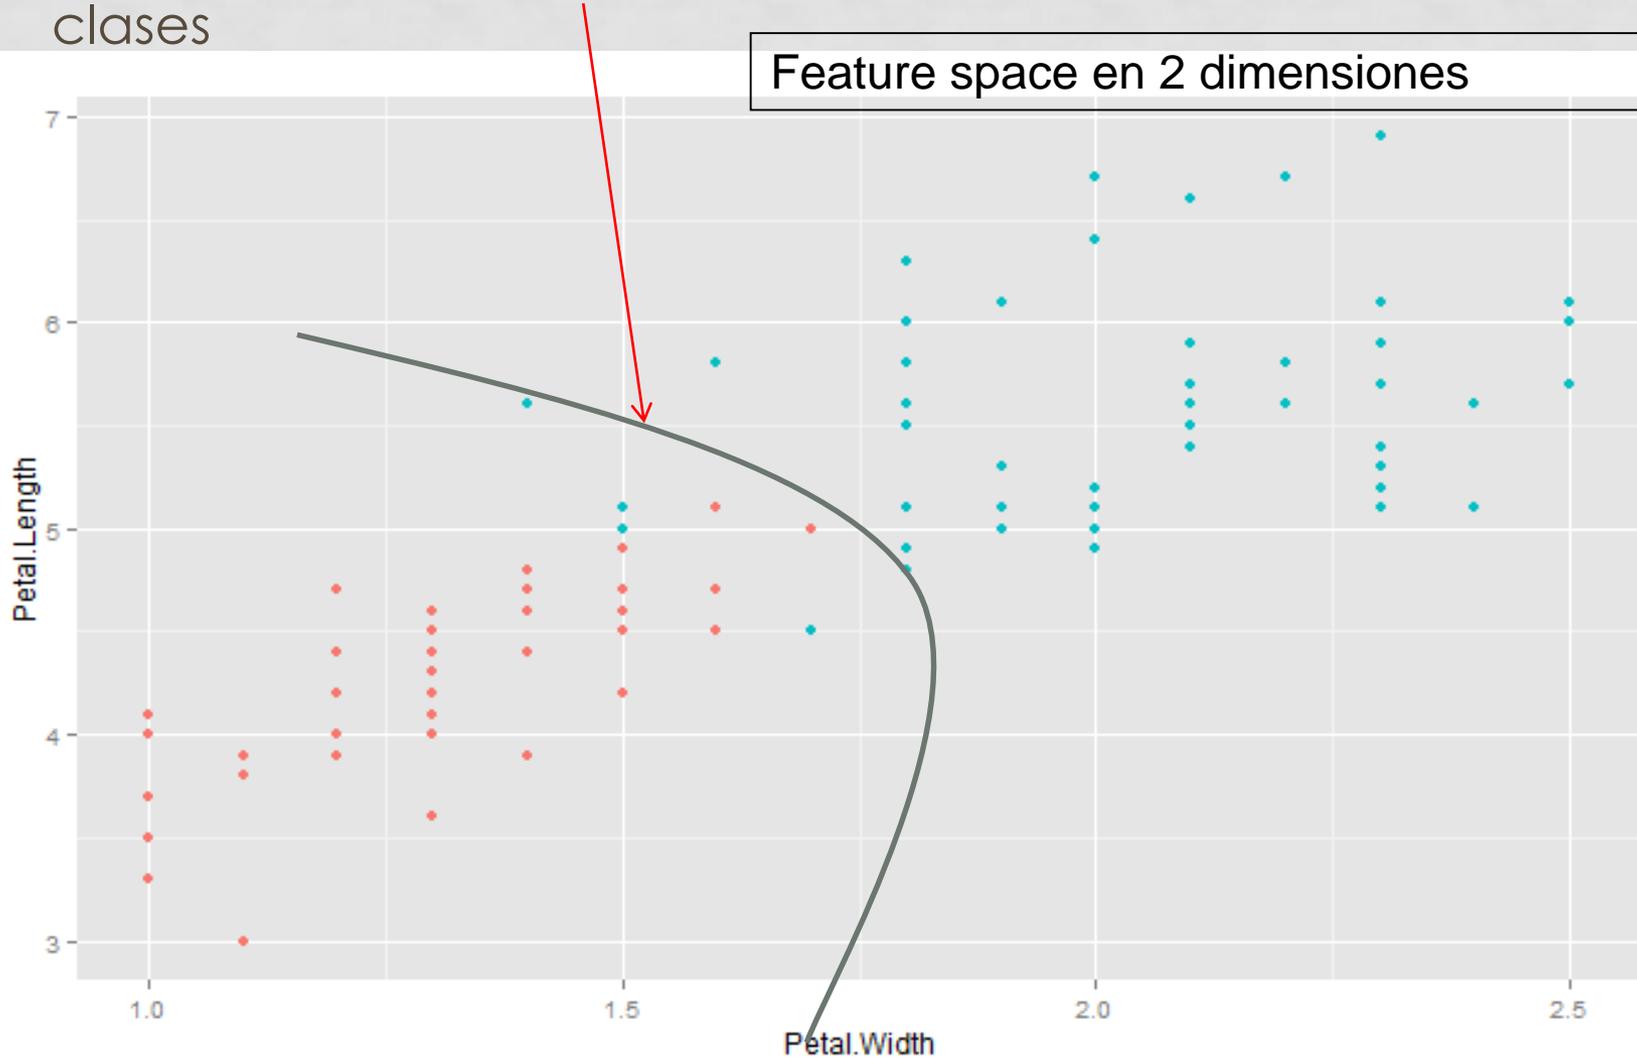
- Las instancias posibles “habitan” un espacio d -dimensional (donde d es el número de atributos de entrada)
 - Esta instancia tiene 5 atributos de entrada y 1 de salida

Años	Euros	Salario	Casa propia	Cuentas morosas	Crédito
10	50000	3000	Si	0	Si

- En 2 dimensiones (2 atributos), cada instancia es un punto en el feature space



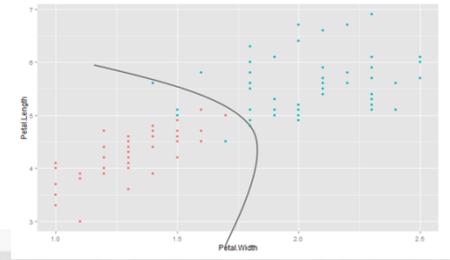
- Ejemplo: clasificar plantas en dos clases ("versicolor" / roja vs. "virginica" / azul)
- 2 atributos = (Petal.Width, Petal.Length) = 2 dimensiones
- Clasificación = encontrar una función $g: \mathbf{X} \rightarrow \mathbf{Y}$ frontera entre las clases



TAREAS

- Tareas:
 - **Aprendizaje supervisado:**
 - **Clasificación:**
 - Discrete
 - **Ranking, scoring, probability estimation**
 - Predicción (regresión)
 - Aprendizaje semi-supervisado
 - Aprendizaje no supervisado:
 - Agrupamiento o clustering
 - Asociación
 - Aprendizaje por refuerzo

SCORING-CLASSIFIERS / ESTIMACIÓN DE PROBABILIDADES



- *Scoring*: en caso de que la función g nos devuelva una medida de pertenencia de una instancia a una clase:
 - $g : X \rightarrow \mathbf{R}$ (en caso de clasificación binaria)
 - Por ejemplo, $g(x) = \text{distancia de } x \text{ a la frontera de separación}$
- Estimación de probabilidades / densidades:
 - Un “score” no es una probabilidad (no cumple las leyes de las probabilidades)
 - $g(x) = p(y | x)$
 - $p(y = \text{si} | x)$
 - $p(y = \text{no} | x)$

TAREAS

- Tareas:
 - **Aprendizaje supervisado:**
 - Clasificación:
 - Discrete
 - Ranking, scoring, probability estimation
 - **Predicción numérica (regresión): la “clase” es continua**
 - Aprendizaje semi-supervisado
 - Aprendizaje no supervisado:
 - Agrupamiento o clustering
 - Asociación
 - Aprendizaje por refuerzo

PREDICCIÓN (REGRESIÓN)

- Si la clase a predecir es continua el problema es de **predicción** (o **regresión**)
- Los modelos que se aprenden son funciones matemáticas $y=g(x)$
 - Lineal: $y = ax+b$
 - No lineal: $y = a*x^2+bx+c$ / $y = \log(\sin(x))$

TAREAS

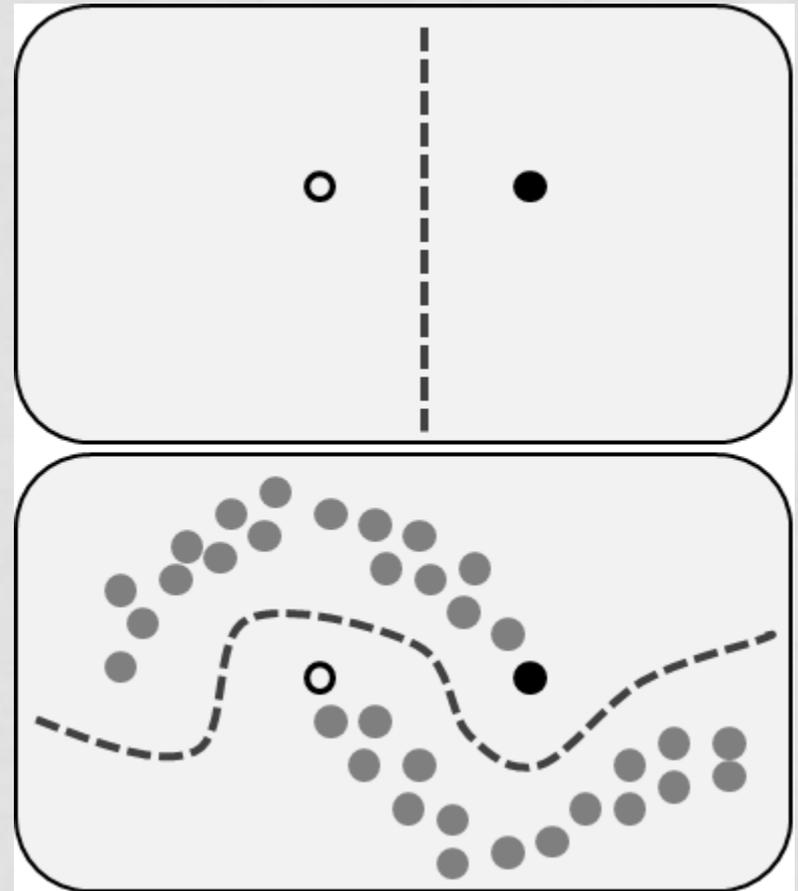
- Tareas:
 - **Aprendizaje supervisado:**
 - Clasificación:
 - Discrete
 - Ranking, scoring, probability estimation
 - Predicción numérica (regresión)
 - Aprendizaje semi-supervisado
 - Aprendizaje no supervisado:
 - Agrupamiento o clustering
 - Asociación
 - Aprendizaje por refuerzo

TAREAS

- Tareas:
 - Aprendizaje supervisado:
 - Clasificación
 - Predicción (regresión)
 - **Aprendizaje semi-supervisado**
 - Aprendizaje no supervisado:
 - Agrupamiento o clustering
 - Asociación
 - Aprendizaje por refuerzo

APRENDIZAJE SEMISUPERVISADO

- Se dispone de algunas instancias de entrenamiento etiquetadas y de otras muchas sin etiquetar (sólo los atributos de entrada)
- Justificación: etiquetar datos puede resultar costoso (ej: hacer una biopsia para saber si una persona tiene cáncer)



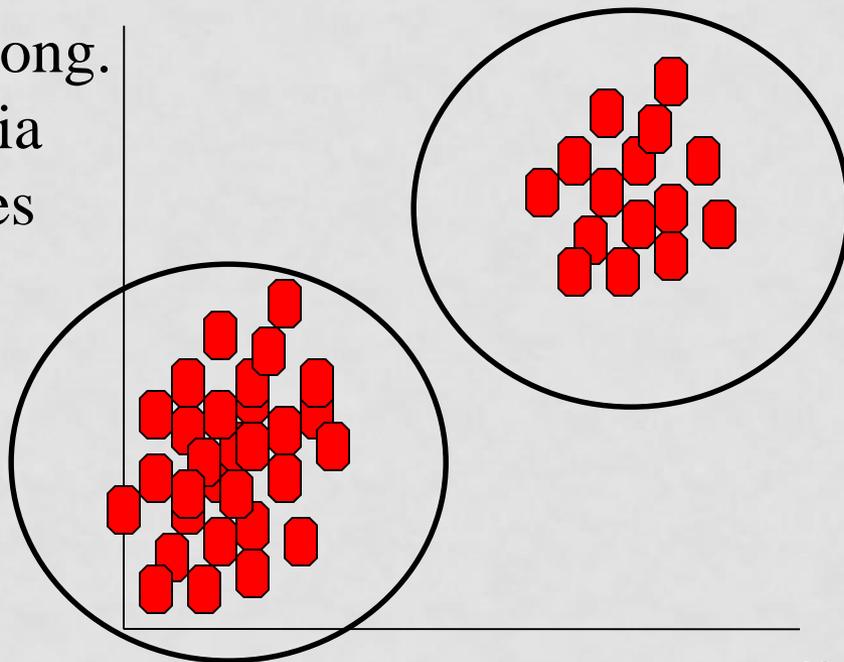
TAREAS

- Tareas:
 - Aprendizaje inductivo (a partir de ejemplos)
 - Aprendizaje supervisado:
 - Clasificación
 - Predicción (regresión)
 - Aprendizaje semi-supervisado
 - **Aprendizaje no supervisado:**
 - **Agrupamiento o clustering**
 - Asociación
 - Aprendizaje por refuerzo

IDEA GENERAL DE AGRUPACIÓN

- Detectar agrupaciones naturales en los datos
- Agrupación (o “clustering”) = aprendizaje no supervisado: se parte de una tabla, como en clasificación, pero sin la clase

Y: Long.
media
frases



X: Longitud ¹⁸media de palabras

Ejemplo: clustering de libros. 2 grupos:

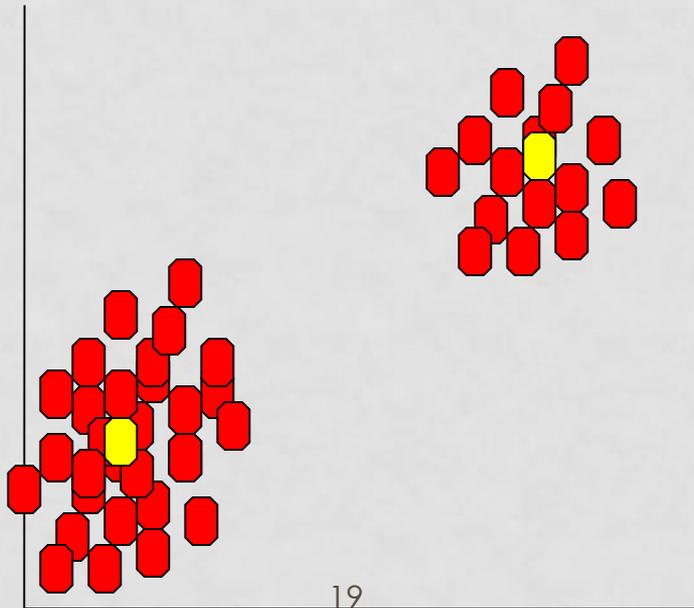
* Palabras y frases largas (¿filosofía?)

* Palabras y frases cortas (¿novela?)

REPRESENTACIÓN DE CLUSTERS

- Por sus centroides (ej: algoritmo k-medias)

K-MEDIAS / K-MEANS: <http://www.youtube.com/watch?v=74rv4snLI70>



$$\arg \min_{\mathbf{S}} \sum_{i=1}^k \sum_{\mathbf{x}_j \in \mathcal{S}_i} \|\mathbf{x}_j - \boldsymbol{\mu}_i\|^2$$

AGRUPACIÓN DE EMPLEADOS ("CLUSTERING")

- El departamento de RRHH de una empresa desea categorizar a sus empleados en distintos grupos con el objetivo de entender mejor su comportamiento y tratarlos de manera adecuada

EJEMPLO DE CLUSTERING

Id	Sueldo	Casado	Coche	Hijos	Alq/Prop	Sindicado	Bajas	Antigüedad	Sexo
1	1000	Si	No	0	Alq	No	7	15	H
2	2000	No	Si	1	Alq	Si	3	3	M
3	1500	Si	Si	2	Prop	Si	5	10	H
4	3000	Si	Si	1	Alq	No	15	7	M
5	1000	Si	Si	0	Prop	Si	1	6	H
...

MODELO

	GRUPO 1	GRUPO 2	GRUPO 3
Sueldo	1535	1428	1233
Casado (No/Si)	77%/22%	98%/2%	0%/100%
Coche	82%/18%	1%/99%	5%/95%
Hijos	0.05	0.3	2.3
Alq/Prop	99%/1%	75%/25%	17%/83%
Sindicado	80%/20%	0%/100%	67%/33%
Bajas	8.3	2.3	5.1
Antigüedad	8.7	8	8.1
Sexo (H/M)	61%/39%	25%/75%	83%/17%

- Grupo 1: sin hijos y con vivienda de alquiler. Poco sindicados. Muchas bajas
- Grupo 2: sin hijos y con coche. Muy sindicados. Pocas bajas. Normalmente son mujeres y viven en alquiler
- Grupo 3: con hijos, casados y con coche. Mayoritariamente hombres propietarios. Poco sindicados.

TAREAS

- Tareas:
 - Aprendizaje supervisado:
 - Clasificación
 - Predicción (regresión)
 - Aprendizaje semi-supervisado
 - **Aprendizaje no supervisado:**
 - Agrupamiento o clustering
 - **Asociación**
 - Aprendizaje por refuerzo

ANÁLISIS DE LA CESTA DE LA COMPRA (ASOCIACIÓN)

- Un supermercado quiere obtener información sobre el comportamiento de compra de sus clientes.
 - Si compra este producto también compra este otro producto
- Se piensa que de esta manera se puede mejorar el servicio, colocando ciertos productos juntos, etc.

INSTANCIAS DE LAS CESTAS

Id	Huevos	Aceite	Pañales	Vino	Leche	Mantequilla	Salmón	Lechugas	...
1	Si	No	No	Si	No	Si	Si	Si	...
2	No	Si	No	No	Si	No	No	Si	...
3	No	No	Si	No	Si	No	No	No	...
4	No	Si	Si	No	Si	No	No	No	...
5	Si	Si	No	No	No	Si	No	Si	...
6	Si	No	No	Si	Si	Si	Si	No	...
7	No	No	No	No	No	No	No	No	...
8	Si	Si	Si	Si	Si	Si	Si	No	...
...

MODELO

- Reglas **Si** $At_1=a$ y $At_2=b$ y ... **Entonces** $At_n=c$
 - **Si** pañales=si, **entonces** leche=si
- Las reglas también pueden ser:
 - **Si** $At_1=a$ y $At_2=b$ **Entonces** $At_n=c$, **$At_4=D$**
 - **Si** huevos = si **Y** vino = si **Entonces** Mantequilla = si **Y** Salmón = si

ASOCIACIÓN: OTROS EJEMPLOS



*Provides a thorough grounding in machine learning concepts as well as practical advice on applying the tools and techniques to your data mining projects *Offers concrete tips and techniques for performance improvement that work by transforming the input or output in machine learning methods *Includes downloadable Weka software toolkit, a collection of machine learning algorithms for data mining tasks-in an updated, interactive interface. Algorithms in toolkit cover: data pre-processing, classification, regression, clustering,

[Show More](#)

Special Offers and Product Promotions

- Buy \$25 or more in Textbooks, get a \$5 Amazon MP3 Credit. [Here's how](#) (restrictions apply)
- FREE One-Day Shipping if you purchase this item using your Discover Card. Enter code DSCVRFSP at checkout. [Here's how](#) (restrictions apply)

Frequently Bought Together



+



Price For Both: **\$94.07**

[Add both to Cart](#) [Add both to Wish List](#)

[Show availability and shipping details](#)

- This item:** Data Mining: Practical Machine Learning Tools and Techniques, Third Edition (The Morgan Kaufmann Series in Data Management Systems) by Ian H. Witten Paperback **\$40.88**
- Data Mining: Concepts and Techniques, Third Edition (The Morgan Kaufmann Series in Data Management Systems) by Jiawei Han Hardcover **\$53.19**

Customers Who Bought This Item Also Bought

Page 1 of 17



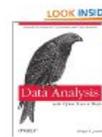
Data Mining: Concepts and Techniques, Third ...
> Jiawei Han
★★★★☆ (11)
Hardcover
\$53.19



Programming Collective Intelligence: Building ...
> Toby Segaran
★★★★☆ (83)
Paperback
\$26.39



Mining the Social Web: Analyzing Data from ...
> Matthew A. Russell
★★★★☆ (18)
Paperback
\$26.36



Data Analysis with Open Source Tools
> Philipp K. Janert
★★★★☆ (27)
Paperback
\$24.05



Data Mining with R: Learning with Case ...
> Luis Torgo
★★★★☆ (5)
Hardcover
\$67.50



The Elements of Statistical Learning: Data Mining, ...
> Trevor Hastie
★★★★☆ (46)
Hardcover
\$63.05

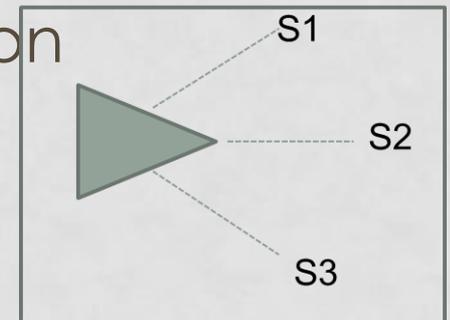
Editorial Reviews

TAREAS

- Tareas:
 - Aprendizaje inductivo (a partir de ejemplos)
 - Aprendizaje supervisado:
 - Clasificación
 - Predicción (regresión)
 - Aprendizaje semi-supervisado
 - Aprendizaje no supervisado:
 - Agrupamiento o clustering
 - Asociación
 - **Aprendizaje por refuerzo**

APRENDIZAJE POR REFUERZO

- El agente tiene que aprender la “política” (policy) o estrategia π para saber que acción tomar en cada situación s
- Sea un robot que:
 - Tiene 3 sensores de distancia $S1, S2, S3$
 - Acciones: girar hacia la izquierda, hacia la derecha, avanzar
- Objetivo: aprender estrategia (policy) π para saber que acción tomar en cada situación s , para por ejemplo, moverse por una habitación con obstáculos sin chocar
 - $\pi(s1, s2, s3) = \text{acción}$



APRENDIZAJE POR REFUERZO

- No puede ser un problema supervisado, porque en principio, no podemos decirle al robot que acción realizar en cada posible situación.

S1	S2	S3	π
1.3	0.5	7	?
10	8.7	5	?
0.5	0.5	0.6	?
...

- La política es aprendida dejando que el robot explore un espacio simulado, recibiendo refuerzos positivos (de vez en cuando) al hacer algo bien, y negativos en caso contrario (ej: chocar).