

Introducción al DataMining

Lluís Garrido
garrido@ecm.ub.es
Universitat de Barcelona

Índice

- ¿Qué es el DataMining?
- ¿Qué puede hacer el DataMining?
- ¿Cómo hacer el DataMining?
Técnicas
- Metodología del DataMining
 - ◆ Ejemplo 1: venta plan de pensiones
 - ◆ Ejemplo 2: predicción de mercado de capitales

¿Qué es el DataMining?

- análisis y exploración automática
- de grandes bases de datos
- para extraer información útil
- y no evidente



¿Qué no es el DataMining?

- Queries/ Informes
- Data Warehouse
- Sistemas Expertos
- Estadística
-



¿Por qué ahora?

- Tenemos grandes bases de datos
- cpu/\$ cada vez mejor
- Productos comerciales para DataMining existen
- Competencia cada vez mayor



¿Qué puede hacer el DataMining?

- **Clasificación**
 - ◆ Credit scoring
 - ◆ Fidelidad: ¿quién se dará de baja?
 - ◆ Mejora de campañas: ¿quién de mis clientes es más propenso a comprar mi producto?
 - ◆ Próximo producto: ¿qué producto ofrecer al cliente X?
- **Estimación**
 - ◆ ¿cuál es la nómina de este cliente?
- **Predicción**
 - ◆ ventas en el próximo mes
 - ◆ ¿cuál será el IBEX35 de la próxima semana?
- **Clusterización**
 - ◆ Como son nuestros clientes
 - ◆ por que compran ciertos productos y como evolucionan



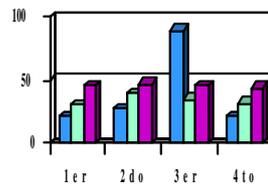
En todos los casos utilizaremos la base de datos histórica para crear los modelos

¿Cómo hacer el DataMining? Técnicas

- Estadísticas
- Clusterización
- Árboles
- Redes neuronales
- Algoritmos genéticos
- (Market Basket Analysis, Memory Based Reasoning, Link Analysis,...)



Estadísticas



■ Útiles en

- ◆ Descripción y visualización simple de datos
- ◆ Test de hipótesis
 - ◆ max, min, medias, sigma, frecuencias,
 - ◆ histogramas 2D
 - ◆ búsqueda de correlaciones
 - ◆ regresiones lineales

■ Dificultades en

- ◆ relaciones no lineales entre variables
- ◆ distribuciones no gaussianas

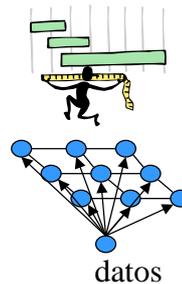
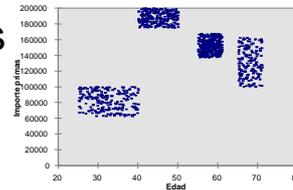
Técnicas de clusterización

- Todas ellas agrupan los clientes pero con distintos métodos y criterios

- Las técnicas más usadas son

- ◆ clásicas: Se agregan registros hasta llegar al número de grupos deseados o a la distancia mínima
- ◆ redes neuronales
 - ✦ Kohonen. Método: el ganador se lo lleva todo
 - ✦ Neural-Gas. Simula un gas formado de moléculas

- Es muy recomendable hacer una Clusterización: Podemos descubrir agradable sorpresas



Árboles

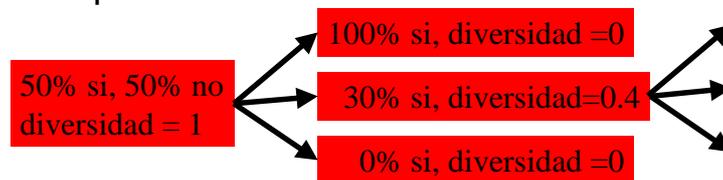


- Herramientas muy populares para clasificación
- Atractivo:
 - ◆ sus resultados pueden expresarse mediante reglas → ejecutables directamente en SQL
- Problemas:
 - ◆ el número de reglas generalmente es enorme
 - ◆ son superadas por las redes (predicción)

Árboles: ¿cómo crecen?

- Cada rama se divide en otras para disminuir la diversidad

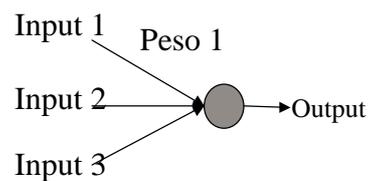
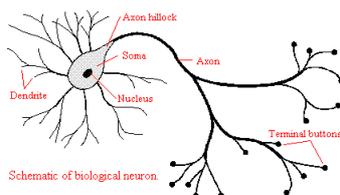
- ◆ diversidad: como más baja es, indica predominio de una clase



- El proceso termina por criterios de
 - ◆ ganancia de información, entropía,...

Redes Neuronales Multicapa

- Inspiradas en la estructura neuronal biológica



- ¿Qué son?

- ◆ Grupo de neuronas (unidad básica de procesamiento) interconectadas con distinta influencia mutua (peso)

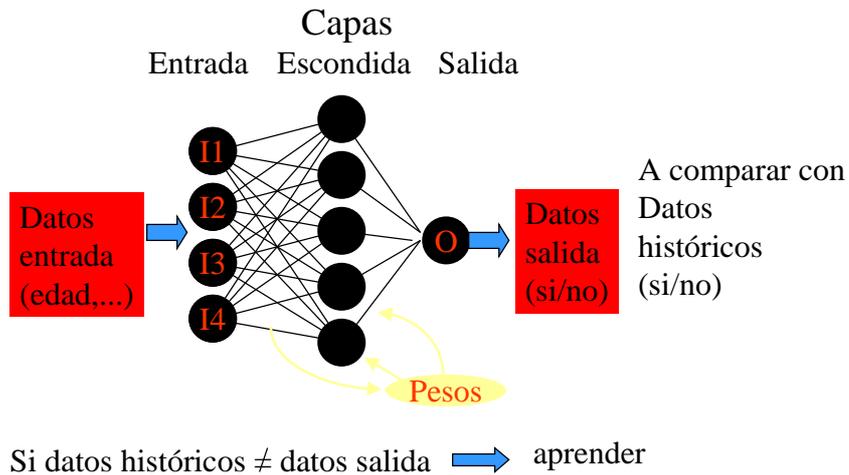
- Aprenden” a partir de ejemplos

- ◆ como nosotros!!!!

- Memoria

- ◆ basada en los pesos

Redes neuronales



¿Para qué son útiles?

■ Son extremadamente útiles en

◆ clasificación

✦ Objetivo: aprender la relación

- datos históricos → si(=1), no(=0)

✦ Para nuevos clientes

- datos nuevo cliente → número entre 0 y 1
- es la **probabilidad** de que este cliente nos diga sí
- esta probabilidad junto a una estimación de beneficios nos permitirá decidir como actuar

■ Son muy útiles en

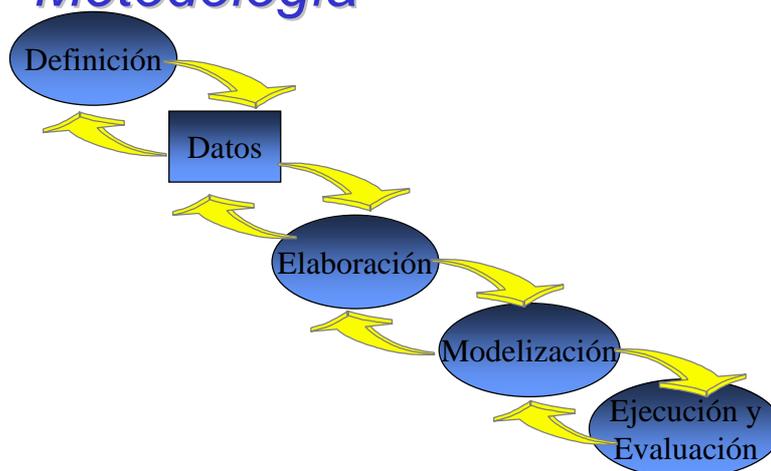
◆ estimación

◆ predicción

Algoritmos genéticos

- **Emulan la naturaleza:**
 - ◆ tenemos una población de individuos (soluciones)
 - ◆ estos individuos sobreviven y se reproducen según sus cualidades
- **Especializados en problemas de optimización con restricciones**
 - ◆ búsqueda de la mejor solución entre muchas

Metodología



Ejemplo 1

■ Problema:

- ◆ Venta de Plan de Pensiones

■ Datos:

- ◆ Datos de cliente
- ◆ Datos de cuentas (selección de productos)
- ◆ Muestra aleatoria de todos los clientes del banco
 - ✦ Clientes sin el producto
 - ✦ Clientes con el producto
 - ✦ varios años de datos por falta de estadística

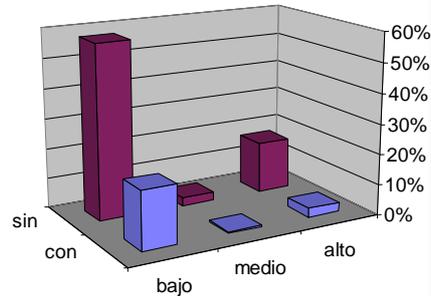
Clustering (Neural Gas)

Variable	1	2	3	4	5	6	7
AF	21	368	81	17	27	103	23
Antiguedad	94	104	81	106	86	144	94
Domiciliacions	65	48	34	96	222	50	411
Edad	64	132	114	90	92	142	83
EstadoCivil_C	0	153	135	153	146	84	85
EstadoCivil_S	336	4	10	2	5	55	133
EstadoCivil_V	0	16	131	10	5	672	32
EstadoCivil_?	41	26	222	74	220	27	220
Finversion	48	28	30	48	191	386	113
Hipoteca	29	6	18	47	39	2	1255
IPF	46	67	57	40	132	402	45
Jubilacion	86	15	73	198	182	36	193
NivelCultural	120	67	82	118	115	77	126
NivelSE	102	88	93	110	104	102	107
Nomina	123	8	15	64	353	8	240
Pension	8	303	69	13	4	275	32
Pensiones	9	4	10	103	508	50	258
PrestamoP	82	21	37	71	250	13	483
Sexo_H	97	124	56	87	155	62	142
Sexo_M	104	67	161	118	24	153	42
Tarjeta_0	89	135	134	79	45	135	55
Tarjeta_1	122	26	29	145	217	25	196
Vista	77	105	51	63	130	210	124

Visualización simple (correlaciones)

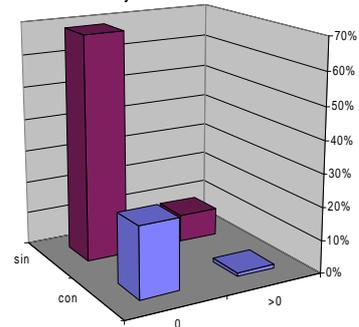
SALDO CUENTA	bajo	medio	alto
con	19,1%	0,6%	3,0%
sin	57,6%	2,7%	17,0%

Factor 1/4 1/6 1/7



IPF	0	>0
con	21,5%	1,1%
sin	68,8%	8,6%

Factor 1/4 1/9



Competencia entre IPF y Plan de Pensiones

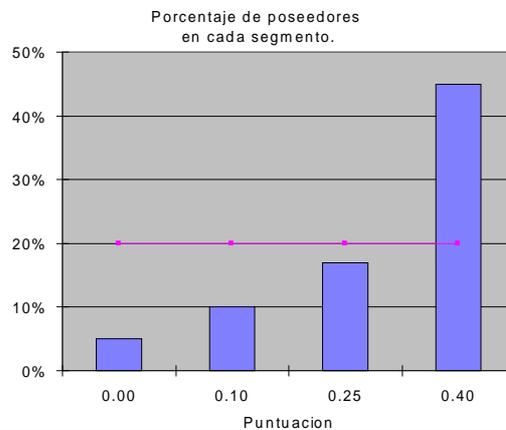
Resultados modelo neuronal

Objetivo: aprender la relación

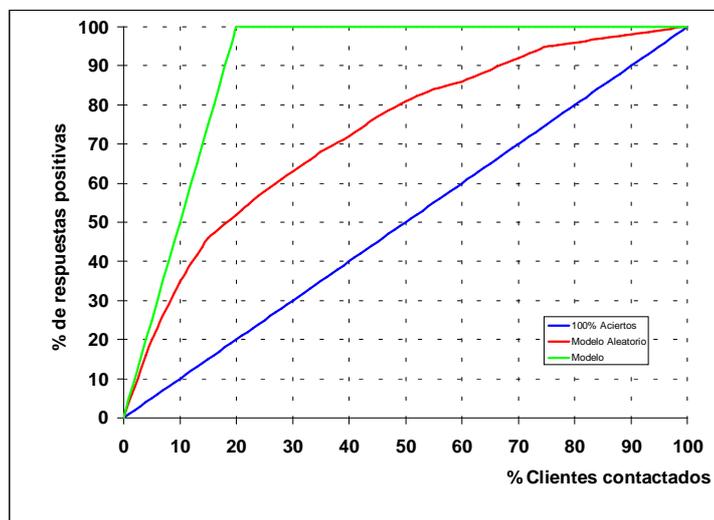
datos cliente → posee Plan Pensiones (=1), no posee (=0)

Finalizado el aprendizaje la red da una puntuación (de 0 a 1) para cada cliente que puede interpretarse como la **propensión** de que dicho cliente tenga un plan de pensiones.

Resultados sobre clientes no utilizados durante el aprendizaje:



Lift Chart



Sensibilidad

Variable	Sens.	Dirección	Desv. Rango		
			Stan.	Bajo	Alto
Cuentas	6,32	Negativa	2,16	-5,52	2,95
FIAMM	4,41	Negativa	1,87	-4,62	2,72
Fim1	3,06	Negativa	1,52	-3,85	2,13
Hipoteca	1,85	Positiva	1,10	-1,35	2,95
IPF	1,69	Negativa	1,12	-2,86	1,52
CuentaDep	0,95	Negativa	0,90	-2,14	1,39
CtaAhorro	0,77	Negativa	0,76	-1,92	1,06
SaldoCuentas	0,50	Negativa	0,62	-1,55	0,86
Tarjeta	0,48	Positiva	0,42	-0,27	1,37
DepFinanc	0,42	Negativa	0,59	-1,43	0,88
Fim2	0,40	Negativa	0,57	-1,39	0,85

Resultados

- Para desarrollar la campaña,
 - ◆ clientes con score máximo
 - ◆ clientes con score mínimo

Posibilidad de medición

- Resultados finales mostraban claramente mayor respuesta en segmento de alto score (factor 2)

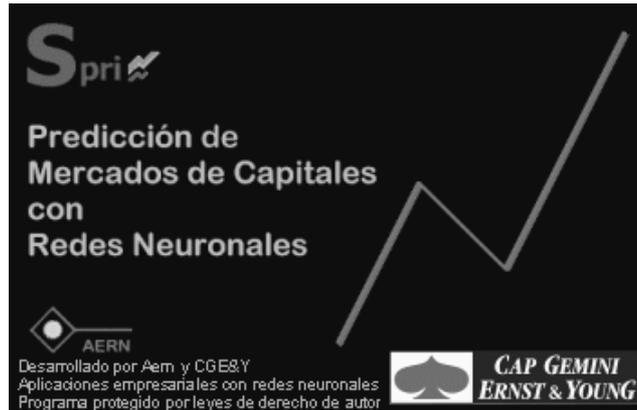
herramientas

<u><i>Nombre</i></u>	<u><i>Compañía</i></u>
Model1	Group1
Marksman	HNC
Enterprise Miner	SAS
Intelligent Miner	IBM
Clementine	SPSS
Sprinn	AERN & CAP GEMINI

La diferencia se centra en sus objetivos, la automatización, la cantidad de datos que puede utilizar, su integración en la base de datos,...

Predicción de Mercados de Capitales

AERN conjuntamente con Cap Gemini Ernst & Young y en colaboración de 10 personas del sector, ha desarrollado un aplicativo orientado a la predicción en el ámbito de Mercados Financieros



¿Qué es Sprinn Institucional?

- Herramienta de predicción de series financieras.
- Se basa en redes neuronales
- Esta herramienta otorga flexibilidad al analista financiero
 - ◆ permite crear y evaluar sus propios modelos de predicción
 - ◆ permite ajustar el nivel de riesgo
 - ◆ permite utilizar series no financieras (opinión,...)
 - ◆ permite evaluar influencias
- Sprinn genera evaluaciones de riesgo y muestra oportunidades de inversión.

Funcionalidades

(I) Definición de la estructura de datos de cada serie

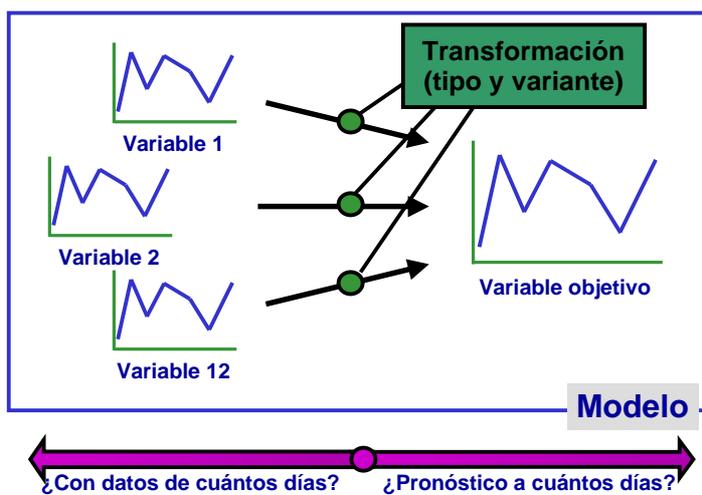
(II) Carga de datos según estructura

(III) Definición del modelo predictivo

(IV) Entrenamiento del modelo con Redes Neuronales

(V) Visualización de los resultados y recomendaciones

Definición del modelo predictivo



SprINN - [ibex11_inc2.nnp]

Archivo Datos Proyecto Ventana Ayuda

Edición del proyecto

Serie: Elemento: Tipo:

Variante:

Objetivo Variable Limpiar

Estructura del proyecto

Descripción:

	Serie	Elemento	Tipo	Variante	Parámetro 1	Parámetro 2	Pa
Objetivo	IBEX35	Cierre	Total	Incremento	2		

Predicción a: con los datos de:

	Serie	Elemento	Tipo	Variante	Parámetro 1	Parámetro 2
Variable 3	IBEX35	Cierre	Total	Media móvil exponencial	5	
Variable 4	IBEX35	Cierre	Total	Incremento a media móvil expc	5	
Variable 5	IBEX35	Cierre	Total	Volatilidad	5	
Variable 6	Telefonica	Cierre	Total	Propia Serie		
Variable 7	DowJones	Cierre	Total	Propia Serie		
Variable 8	NASDAQ100	Cierre	Total	Propia Serie		
Variable 9	Petroleo	Cierre	Total	Propia Serie		
Variable 10	IBEX35	Cierre	Total	Momento	5	

Editar Entrenar Resultados Informe

Variables del proyecto d:\aern\sprinn institucional 2.0-esp\proyectos\ibex11_inc2.nnp

Entrenamiento, test y predicción



Una vez realizado el entrenamiento el análisis gráfico nos permite validar el modelo según su capacidad de predicción: 1) en el periodo de entrenamiento, y 2) en el intervalo ex-post. Todo esto con el objetivo de poder predecir ex-ante.

SprINN - [ibex11_inc2.nnp]

Archivo Datos Proyecto Ventana Ayuda

Información de entrenamiento

	Desde	Días
Objetivo	4/1/95	1520
Variable 1	2/1/95	1522
Variable 2	6/1/95	1518
Variable 3	6/1/95	1518
Variable 4	6/1/95	1518
Variable 5	6/1/95	1518

Proyecto: ibex11_inc2.nnp
 Último patrón disponible: 31/10/00
 Predicción para el día: 2/11/00
 Patrones de entrenamiento: 498
 Último entrenamiento realizado: 20/10/00 con datos desde 29/6/98 hasta 1/6/00
 Ciclos de entrenamiento acumulados: 20

Entrenamiento

Período: Intervalo móvil Desde: 08/07/98 Hasta: 12/06/00

Número de ciclos: 20

Guardar Entrenar Mejorar Parar Deshacer

Editar Entrenar Resultados Informe

d:\aern\sprinn institucional 2.0-esp\proyectos\ibex11_inc2.nnp

SprINN - [ibex11_inc2.nnp]

Archivo Datos Proyecto Ventana Ayuda

Resultados

Predicir tendencia: Eje derecho Margen proporcional
 Puntos Todos los datos
 Grid Tabla de resultados

Puntos por página: 610
 Margen del 10.00% Ninguna variable

Página 1 de 2

	23/10/00	24/10/00	25/10/00	26/10/00	27/10/00	30/10/00	31/10/00	1/11/00	2/11/00
Predicción	10374.36	10448.70	10331.72	10667.92	10516.34	10324.09	10396.12	10310.39	10367.93
Objetivo	10329.90	10667.00	10518.00	10325.00	10396.00	10308.00	10364.00		

Exportar

Editar Entrenar Resultados Informe

Gráfico de objetivo, variables y predicciones

d:\aern\sprinn institucional 2.0-esp\proyectos\ibex11_inc2.nnp

Sprinn - [Ibex1_inc2.nnp]

Archivo Datos Proyecto Ventana Ayuda

Informe de resultados

Tipo de predicción: Predecir tendencia Serie de actuación: IBEX35 Retardo: 0 Desde: 01/06/00 Hasta: 31/10/00

Margen del 10.00% Cierre Operaciones: Alzas y Bajas Comisión fija: 0.000 Comisión %: 0.000

Diario Diario invertido Gráfico del saldo

Resumen

Posición actual: 30/10/00 C a 10308.00
 Última cotización: 31/10/00 a 10364.00
 Recomendación inmediata: **Mantener**
 Valor patrimonial: 1209.51 = 1202.97 + 6.54 - 0.00

Rentabilidades

Rentabilidad acumulada: 20.30% Rentabilidad anual: **48.42%**

Indices

Indice de eficacia: 79.58% Indice de seguridad: 100.00%

Estadística de operaciones

Número de operaciones cerradas	15	Número de operaciones abiertas	1
Número de operaciones positivas	11	Número de operaciones negativas	4
Días invertido	101	Días desinvertido	52
Máximo recorrido positivo	209.35	Máximo recorrido negativo	0.00
Total ganancias	248.53	Total pérdidas	45.56

Días al alza: 81 Días a la baja: 35
 Número de operaciones al alza: 10 Número de operaciones a la baja: 6
 Número de alzas positivas: 8 Número de bajas positivas: 3
 Número de alzas negativas: 1 Número de bajas negativas: 3
 Beneficio total al alza: **131.70** Beneficio total a la baja: **116.83**
 Beneficio máximo al alza: 44.00 Beneficio máximo a la baja: 54.15

AFRN <http://www.sprinn.com> CAP GEMINI ERNST & YOUNG

Análisis de las recomendaciones de C/V

Diario de operaciones

C = Abrir Alza, V = Cerrar Alza, W = Abrir Baja, Z = Cerrar Baja

Tipo	Operación	Días	Beneficio
	Capital inicial el 1/6/00		
Baja	2/6/00 W a 11142.00 y 7/6/00 Z a 10688.90	6	40.67
Alza	13/6/00 C a 10806.00 y 14/6/00 V a 10881.00	2	7.22
Alza	16/6/00 C a 10724.00 y 5/7/00 V a 10758.00	20	3.32
Baja	10/7/00 W a 10829.00 y 11/7/00 Z a 10875.00	2	-4.47
Alza	13/7/00 C a 10849.00 y 17/7/00 V a 10950.00	5	9.74
Alza	18/7/00 C a 10792.00 y 21/7/00 V a 10880.00	4	8.61
Alza	25/7/00 C a 10715.00 y 8/8/00 V a 10868.00	15	15.21
Baja	10/8/00 W a 11111.00 y 17/8/00 Z a 11156.00	8	-4.38
Alza	21/8/00 C a 11094.00 y 22/8/00 V a 10935.00	2	-15.42
Alza	23/8/00 C a 10799.00 y 4/9/00 V a 11247.00	13	44.00
Baja	15/9/00 W a 11464.00 y 20/9/00 Z a 10902.00	6	54.15
Alza	21/9/00 C a 10804.00 y 25/9/00 V a 11160.00	5	38.18
Baja	27/9/00 W a 10958.00 y 2/10/00 Z a 11153.00	6	-21.30
Baja	4/10/00 W a 11160.00 y 10/10/00 Z a 10951.00	7	22.02
Alza	12/10/00 C a 10619.00 y 24/10/00 V a 10667.00	13	5.41
Alza	30/10/00 C a 10308.00 abierta		
	Ultima cotización el 31/10/00 a 10364.00	2	6.54

Resultados reales (1 año)

Estrategia	5 sesiones	20 sesiones	40 sesiones	60 sesiones
Agresiva	63%(219)	62%(229)	58%(228)	48%(236)
Media	63%(145)	66%(61)	74%(131)	56%(143)
Conservadora	60%(72)		89%(80)	100%(44)