

UNIVERSIDAD DE BUENOS AIRES
FACULTAD DE CIENCIAS EXACTAS Y NATURALES
D.E. - 2001

“Aprendizaje Automático de Estrategias de Inversión que Generen Ganancias”

Tesis de Licenciatura

Setiembre 2001

Gabriel Andrés Bulfón L.U. 328/92

Adrián Sergio Pulvirenti L.U. 227/92

Director: Dr. Jorge Sergio Igor Zwir



Departamento de Computación
Facultad de Ciencias Exactas y Naturales
Universidad de Buenos Aires

2001

Aprendizaje Automático de Estrategias de Inversión que Generen Ganancias

Los mercados financieros han sido objeto de estudio y análisis por parte de los economistas, inversores e investigadores con el fin de establecer *modelos de comportamiento* y descubrir *técnicas de predicción* para poder elaborar *Estrategias de Inversión* que permitan obtener ganancias.

En el presente trabajo se analizan y evalúan las técnicas utilizadas por los inversores de mercados de valores y se estudian los problemas que se presentan en la identificación de Estrategias de Inversión.

Con el fin de encontrar solución a algunos de estos problemas se presenta el diseño e implementación de un Sistema de Clasificación (métodos híbridos) que permite aprender en forma automática y no supervisada, en base a ejemplos de series financieras y por medio de Algoritmos Genéticos, Estrategias de Inversión que generan ganancias. También se plantea una extensión de estos Sistemas Clasificadores aplicados a series financieras, a modelos lingüísticos difusos (Sistemas de Clasificación Basados en Reglas Difusas) con capacidad de agrupar situaciones similares y de establecer soluciones de compromiso entre la interpretabilidad y la precisión de los sistemas aprendidos.

Machine Learning of Investment Strategies That Yield Profit

Stock market has been studied and analyzed by both economists and investors as well as researchers in order to set up *behavior patterns* and discover *forecasting methods* so as to be able to work out *Investment Strategies* that yield profit.

In this thesis, those techniques used by stock market investors are analyzed and evaluated, and the problems that arise in identifying Investment Strategies are studied.

In order to find answers to some of these problems, the design and implementation of a Classifier System (hybrid methods) is proposed. This Classifier System allows learning automatically and in an unsupervised way, based on financial series and by means of Genetic Algorithms, Investment Strategies that yield profit. An extension of these Classifier Systems applied to financial series to fuzzy linguistic models (Classifier Systems based on Fuzzy Rules) is also proposed. This extension has the skill of grouping similar situations and set up committed solutions between the interpretability and the accuracy of the learning systems.

Agradecimientos

En primer lugar, queremos agradecer a nuestro director Jorge Sergio Igor Zwir por su gran paciencia, su predisposición y por prestarnos su computadora portátil.

También queremos agradecer a nuestras familias, amigos y compañeros por su comprensión y apoyo durante el desarrollo de esta memoria.

Agradecemos a José Angel Alvarez por sus recomendaciones iniciales y especialmente por habernos sugerido que nos contactemos con Igor para este trabajo de tesis.

Finalmente agradecemos a los integrantes de ING Barings Sociedad De Bolsa (Argentina) por su aporte teórico financiero.

Y por si nos olvidamos de alguien, Gracias a Todos.

Índice General

Introducción	1
Presentación del problema	1
Objetivos	3
Resumen.....	3
Mercados de Capitales	6
1.1. Introducción.....	6
1.2. Mercados de Capitales	6
1.2.1. El Operador de Mercados	7
1.2.2. Perfiles de inversión	7
1.2.3. Tipos de operaciones	8
1.2.4. Volatilidad de una acción.....	9
1.2.5. Relación entre la cotización y varios indicadores.....	10
1.3. Estrategias de Inversión	11
1.3.1. Técnicas clásicas para la elaboración de Estrategias de Inversión	11
1.3.2. Análisis Fundamental	12
1.3.3. Análisis Técnico	14
1.3.3.1. Racionalidad	14
1.3.3.2. Tendencias	14
1.3.3.3. Instrumentos y Figuras	15
1.3.3.4. Medias móviles	19
1.3.3.5. Otros indicadores utilizados.....	22
1.4. Dificultades que se presentan en el uso de las técnicas tradicionales	24
1.5. Marco de trabajo y Experiencias	24
1.5.1. Estrategias de Inversión	25
1.5.2. Datos.....	26
1.5.3. Tipos de experiencias	28
1.5.4. Restricciones	29
1.6. Observaciones finales.	29
Técnicas de Aprendizaje Automático	31
2.1. Introducción.....	31
2.2. Reseña de trabajos previos con herramientas computacionales.....	32
2.3. Problemas de la aplicación de estas técnicas al problema de identificación de Estrategias de Inversión.....	34
2.4. Utilización de técnicas híbridas de Aprendizaje Automático.....	35
2.4.1. Algoritmos Evolutivos	36
2.4.2. Algoritmos Genéticos	37
2.4.2.1. Definición	37
2.4.2.2. Componentes	39
2.4.2.3. Representación.....	41
2.4.2.4. Inicialización.....	42
2.4.2.5. Evaluación	43
2.4.2.6. Operaciones de cruzamiento y mutación.....	43
2.4.3. Aprendizaje de Sistemas Basados en Reglas mediante Algoritmos Genéticos	44
2.4.4. Sistemas Clasificadores	46
2.4.4.1. Características de un Sistema Clasificador	46
2.4.4.2. Aprendizaje de un Sistema Clasificador.....	48
2.4.5. Sistemas Basados en Reglas Difusas	49
2.4.5.1. Componentes de los Sistemas Basados en Reglas Difusas.....	50

2.4.5.2. Construcción de un Sistema Basado en Reglas Difusas.....	53
2.4.6. Sistemas Difusos Genéticos	55
2.4.7. Sistemas de Clasificación Basados en Reglas Difusas	56
2.4.7.1. Componentes de un SCBRD.....	57
2.4.7.2. Zona de actuación de las reglas difusas.....	57
2.4.7.3. Reglas difusas de clasificación con grados de certeza.....	60
2.4.8. Aprendizaje de la Base de Datos de un SCBRD por medio de técnicas de Clustering	61
2.4.8.1. Clustering por Particiones o Prototipos.....	63
2.4.8.2. Algoritmo para el método de Clustering por Particiones.....	64
2.5. Observaciones finales	65
Utilización de Algoritmos Genéticos para el Aprendizaje de Estrategias de Inversión que Generen Ganancias	67
3.1. Introducción.....	67
3.2. Problemática.....	67
3.3. Una metodología para el aprendizaje de EIs que generen ganancias.....	68
3.3.1. Marco de trabajo: Estrategias de Inversión	69
3.3.2. Algoritmo de aprendizaje de EIs.....	70
3.3.3. Criterios para el aprendizaje y la evaluación de las estrategias aprendidas.....	73
3.4. Experiencias	76
3.4.1. Codificación y parámetros	77
3.4.1.1. Experiencias con una sola especie.....	77
3.4.1.2. Experiencias con un conjunto de especies	80
3.4.1.3. Experiencias con Múltiples Estrategias de Inversión.....	82
3.4.2. Resultados de las experiencias	83
3.4.2.1. Resultados obtenidos en las experiencias con una sola especie.....	83
3.4.2.2. Resultados obtenidos en las experiencias con un conjunto de especies	85
3.4.2.3. Resultados obtenidos en la experiencia con Múltiples Estrategias de Inversión	87
3.5. Análisis de resultados.....	89
3.5.1. Análisis de los resultados obtenidos en las experiencias con una sola especie.....	89
3.5.2. Análisis de los resultados obtenidos en las experiencias con un conjunto de especies	93
3.5.3. Análisis de los resultados obtenidos en la experiencia con Múltiples Estrategias de Inversión.....	97
3.6. Observaciones Finales.....	98
Aprendizaje de Estrategias de Inversión como un Sistema de Clasificación Basado en Reglas Difusas	101
4.1. Introducción.....	101
4.2. Motivación para el uso de Sistemas Clasificadores Basados en Reglas Difusas.....	102
4.3. Aprendizaje de Sistemas de Clasificación Basados en Reglas Difusas	104
4.3.1. Aprendizaje de la Base de Conocimiento de los SCBRDs	104
4.3.1.1. Aprendizaje de la Base de Datos.....	105
4.3.1.2. Aprendizaje de la Base de Reglas Lingüísticas por medio de AGs.....	105
4.4. Una metodología para el aprendizaje de SCBRD que generen ganancias por medio de AGs.....	106
4.5. Experiencias	110
4.5.1. Codificación y parámetros	110
4.5.2. Resultados obtenidos en las experiencias con Múltiples Estrategias de Inversión.....	112
4.5.3. Resultados obtenidos en las experiencias con SCBRDs con BD uniforme	114
4.5.4. Resultados obtenidos en las experiencias con SCBRDs con BD aprendida por Clustering	115
4.5.5. Resultados obtenidos en las experiencias con Técnicas Clásicas de Inversión.....	116
4.6. Análisis de Resultados	119

4.6.1. Comparación de resultados entre SCBRD con BD uniforme y SC clásicos	120
4.6.2. Comparación de resultados entre un SCBRD con BD aprendida mediante técnicas de Clustering y un SCBRD con BD uniforme.....	123
4.6.3. Comparación de resultados entre las Técnicas tradicionales y un SCBRD con BD aprendida mediante técnicas de Clustering.....	127
4.7. Observaciones Finales.....	128
Comentarios Finales.....	130
5.1. Marco de trabajo.....	130
5.2. Resumen.....	131
5.3. Trabajos Futuros.....	134
5.4. Conclusiones.....	135
Apéndice A	137
Apéndice B	141
Apéndice C	145
Apéndice D	149
Apéndice E	150
Bibliografía.....	151

4.6.1. Comparación de resultados entre SCBRD con BD uniforme y SC clásicos	120
4.6.2. Comparación de resultados entre un SCBRD con BD aprendida mediante técnicas de Clustering y un SCBRD con BD uniforme.....	123
4.6.3. Comparación de resultados entre las Técnicas tradicionales y un SCBRD con BD aprendida mediante técnicas de Clustering.....	127
4.7. Observaciones Finales.....	128
Comentarios Finales.....	130
5.1. Marco de trabajo	130
5.2. Resumen.....	131
5.3. Trabajos Futuros	134
5.4. Conclusiones.....	135
Apéndice A	137
Apéndice B	141
Apéndice C	145
Apéndice D	149
Apéndice E	150
Bibliografía.....	151

Tabla de Acrónimos

AC	Análisis de Clusters / Clustering
AE	Algoritmo Evolutivo
AF	Análisis Fundamental
AG	Algoritmo Genético
AT	Análisis Técnico
BC	Base de Conocimiento
BD	Base de Datos
BR	Base de Reglas
BRD	Base de Reglas Difusas
BRL	Base de Reglas Lingüísticas
CE	Computación Evolutiva
DM	Data Mining
EE	Estrategia de Evolución
EI	Estrategia de Inversión
FA	Función de Aptitud
LD	Lógica Difusa
MEI	Múltiples Estrategias de Inversión
MRD	Método de Razonamiento Difuso
MUE	Muestreo Universal Estocástico
PE	Programación Evolutiva
PG	Programación Genética
RD	Reglas Difusas
RN	Redes Neuronales
SAM	Sistema de Asignación de Mérito
SBRD	Sistema Basado en Reglas Difusas
SC	Sistema de Clasificación
SCBRD	Sistema de Clasificación Basado en Reglas Difusas
SDC	Sistema de Descubrimiento de Clasificadores
SDG	Sistema Difuso Genético
SR	Sistema de Rendimiento

Introducción

Presentación del problema

Un *mercado financiero* no existe como lugar físico de negociación, su funcionamiento se encuadra por medio de un marco legal o reglas y un grupo de participantes u *operadores de mercado* (traders, brokers, mutual fund managers, etc.). De una manera sencilla podríamos decir que una *bolsa de comercio* es un mercado donde se realizan operaciones de compra y venta de acciones u obligaciones, donde se fija un precio público que se denomina *cotización* o cambio.

Durante muchos años los mercados financieros han sido estudiados y analizados por economistas, inversores e investigadores con el objetivo de establecer *Modelos de Comportamiento*, descubrir *Técnicas de Predicción* y así poder elaborar *Estrategias de Inversión* (EIs) que permitan obtener ganancias.

Las EIs van desde las puramente subjetivas a las puramente objetivas. En las más subjetivas, el inversor debe tratar con rumores o con su intuición para elegir con qué especies operar. Por otra parte, un inversor puramente objetivo confía plenamente en las recomendaciones que se deducen de fórmulas matemáticas o procesos mecánicos.

Existen al menos dos tipos de información que históricamente han utilizado los inversores para tomar sus decisiones: *Análisis Fundamental* (AF) y *Análisis Técnico* (AT).

- El *Análisis Fundamental* se basa en el estudio de toda la información económico-financiera disponible sobre la empresa (balance, cuenta de resultados, ratios financieros, etc.), así como de la información del sector, de la coyuntura macroeconómica, etc. En definitiva, estudia cualquier información que pueda servir para tratar de predecir el comportamiento futuro de la empresa. Con este análisis se determinan los puntos fuertes y débiles de la empresa.
- En el *Análisis Técnico* se considera que el mercado proporciona la mejor información posible sobre el comportamiento de la acción. Analiza como se ha comportando ésta en el pasado y trata de proyectar su evolución futura.

Se basa en tres premisas:

- La cotización evoluciona siguiendo determinados movimientos o pautas.
- El mercado facilita la información necesaria para poder predecir los posibles cambios de tendencia.
- Lo que ocurrió en el pasado volverá a repetirse en el futuro.

El AT trata de anticipar los cambios de tendencia. Si la acción está subiendo busca determinar en qué momento esta subida va a terminar y va a comenzar la caída, y lo mismo cuando la acción está cayendo. Parte de la idea de que las cotizaciones se mueven por tendencias. Si bien las cotizaciones pueden reflejar muchos movimientos de zig-zag, en el fondo siguen una dirección o tendencia.

Desde que se produjo la aparición de las primeras computadoras y a medida que se han ido desarrollando nuevas herramientas computacionales, éstas han estado presentes aportando soluciones a los distintos problemas de las más diversas disciplinas.

Una computadora puede efectuar cálculos basados en el AT y evaluar de forma fría e imparcial un resultado, mientras que cualquier AF normalmente requerirá mucha mayor interpretación por nuestra parte y contendrá un mayor grado de subjetividad. Si bien gran parte de los datos utilizados por el AF son de dominio público, existen algunos indicadores de suma importancia para evaluar una compañía, los cuales no siempre están disponibles. Estas razones hacen poco viable la utilización de herramientas computacionales basadas en el AF para aprender Els.

La tarea de identificar figuras en los gráficos de precios tiene un fuerte componente subjetivo debido a que a veces los analistas técnicos deben predecir su formación antes de que esté completa. En muchos casos la formación que se va definiendo se puede corresponder con más de una figura conocida por lo que el inversor debe apelar a su 'olfato' para determinar cuál de ellas se va a formar. Otro dato para tener en cuenta es que los inversores pueden detectar estas figuras tanto en períodos cortos como en períodos largos por lo que se deben incluir diferentes escalas de análisis complicando aún más su seguimiento.

Tanto las medias móviles como otros indicadores utilizados en el AT requieren que el inversor posea conocimientos matemáticos y financieros para interpretar las señales de compra o de venta originadas por los mismos.

Las tendencias son otra de las fuentes de información más utilizadas por los analistas técnicos. Teniendo en cuenta que es deseable mantener un alto nivel de interpretabilidad, la tendencia, como parte de las Els, se presenta como un parámetro de mucha utilidad para decidir cuándo operar. El carácter cuantitativo que posee el análisis de las tendencias facilita su tratamiento computacional. Teniendo en cuenta todas estas propiedades, vemos que las tendencias cumplen los requisitos necesarios para formar parte de la elaboración de una solución al problema planteado.

Algunas formas de capturar el conocimiento por parte de un analista técnico y luego utilizarlo para la construcción de herramientas que realicen operaciones exitosas involucran técnicas con origen en la Inteligencia Artificial, la Estadística y la Investigación Operativa, tales como técnicas de Clustering, Machine Learning, Redes Neuronales, Lógica Difusa, Data Mining, Metaheurísticas y Algoritmos Evolutivos, etc. [MIT97, GOO95, BER97, MIC99].

Si bien algunas de las técnicas mencionadas han sido previamente utilizadas para la tarea de búsqueda de patrones financieros de carácter predictivo, muchas de ellas presentan ciertas falencias que impiden su utilización práctica en forma individual. Algunos de los problemas referidos tienen que ver con implementaciones de tipo caja negra, por las cuales el experto se rehusa a emplear reglas que no puede comprender. Por otra parte, no siempre existe información supervisada que permita obtener un conocimiento cierto sobre las estrategias identificadas en base a datos históricos [RUS01]. Finalmente, existe una gran dificultad en la representación del problema, debido a que gran parte de la información manipulada es incierta y los enunciados que describen las estrategias son de carácter impreciso [CUR00].

En el presente trabajo haremos uso de la información proporcionada por expertos en el área del AT y estudiaremos el efecto de algunas de las mencionadas técnicas en la búsqueda de Els que generen ganancias. En este sentido plantearemos una metodología híbrida que permita el aprovechamiento de las técnicas estudiadas, aplicándolas a aquellos subproblemas en los cuales logran un mejor rendimiento e integrando sus resultados en un sistema de cooperación general. Todo esto, con el propósito de solucionar algunos de los problemas anteriormente planteados.

Objetivos

El objetivo propuesto para este trabajo de tesis es encontrar Els que generen ganancias a partir de conceptos que surgen del AT. Dichas estrategias deberán ser lo suficientemente precisas en cuanto al rendimiento y las predicciones que surjan a partir de las mismas como para alentar su uso por parte de los usuarios expertos en finanzas. Por otra parte, las Els identificadas o aprendidas deberán ser lo suficientemente interpretables como para posibilitar su comprensión y utilización por los mencionados expertos. Finalmente, se deberá considerar a la tarea de aprendizaje o identificación de Els como una tarea no estrictamente supervisada, debido a que no se cuenta con un conjunto de ejemplos que indiquen la correctitud o incorrectitud de las mismas. Esto es, sólo se cuenta con información histórica de variables de mercado.

Resumen

La presente memoria está organizada en 4 Capítulos y una Sección de Comentarios Finales. A continuación resumimos brevemente los contenidos de cada uno de ellos:

En el Capítulo 1 presentaremos la problemática que se observa en el estudio de los mercados financieros: la construcción de modelos de comportamiento, la elaboración de técnicas de predicción y el aprendizaje de estrategias de inversión que generen ganancias. Primero estudiaremos varios conceptos asociados tales como: mercados financieros, operadores, tipos de operaciones, cotización, volatilidad, etc. A continuación se describirán las dos técnicas de análisis más utilizadas por los inversores: el AT y el AF. Destacaremos las distintas herramientas que posee el Análisis Técnico, entre ellas las Medias Móviles y otros indicadores ampliamente difundidos entre los expertos.

Finalmente presentaremos algunas críticas y problemas asociados a estos modelos de análisis, y esbozaremos algunas pautas y requerimientos sobre los que se construirán las experiencias que se presentarán en los Capítulos 3 y 4.

En el Capítulo 2, haremos una reseña de herramientas clásicas de aprendizaje utilizadas para los problemas planteados por los mercados financieros: Redes Neuronales, Lógica Difusa, Data Mining, etc. Luego describiremos algunos de los inconvenientes que se presentan al usar las técnicas mencionadas en forma individual y más adelante analizaremos en profundidad algunas de las técnicas de Aprendizaje Automático (AA) que permiten identificar estrategias a partir de ejemplos históricos y predecir comportamientos futuros. Estas técnicas permitirán realizar hibridaciones efectivas, las cuales se implementarán en los restantes capítulos de esta tesis. En pocas palabras, este Capítulo presentará las bases teóricas sobre las que se van a elaborar las experiencias de los Capítulos 3 y 4.

En el Capítulo 3 aprenderemos diferentes representaciones de Els que reflejarán distintos grados de expresividad para las mismas y determinaremos cuáles producen mejores resultados. Primeramente trabajaremos con estrategias que operen con una especie y luego extenderemos las estrategias para que operen con un conjunto de especies. También estudiaremos el uso de múltiples estrategias para cada especie. Para ello emplearemos Sistemas Clasificadores (SCs) para aprender los mencionados tipos de Els. Estudiaremos distintas formas de aprendizaje de Sistemas Basados en Reglas (estrategias) mediante Algoritmos Genéticos (AGs), tales como Michigan y Pittsburgh [COR01, MIC96]. En base a los resultados obtenidos, intentaremos analizar la incidencia de factores tales como la ganancia obtenida, el porcentaje de operaciones realizadas, el porcentaje de operaciones exitosas, etc. Finalmente, a partir del análisis realizado, seleccionaremos aquellas alternativas que resulten más promisorias que nos servirán de basamento para las experiencias del siguiente Capítulo.

En el Capítulo 4 enriqueceremos las mencionadas estrategias agregando la característica de interpretabilidad requerida por los usuarios expertos. En este sentido intentaremos hacer uso de la representación lingüística que permiten realizar los Sistemas de Clasificación Basados en Reglas Difusas (SCBRDs) [ISH93, JES99, COR00]. Esto nos permitirá incorporar en forma descriptiva el análisis de la tendencia de las variables financieras mencionado en el Capítulo 1, típicamente empleado por los inversores.

También intentaremos hacer más flexible la Base de Conocimiento (BC) de los SCBRDs, que contiene las reglas difusas y las particiones donde sus variables toman valores. Para ello incorporaremos técnicas de Clustering sobre las series temporales de precios [ALC00, BEZ98]. Este hecho nos permitirá insertar conocimiento inicial en la tarea de búsqueda llevada a cabo por el AG, estrechar el espacio de búsqueda y mejorar uno de los aspectos críticos del uso de los mencionados algoritmos.

Por último compararemos los resultados obtenidos con técnicas usualmente empleadas por los expertos en sus inversiones tales como Medias Móviles e identificación de Figuras en los gráficos de cotizaciones.

Posteriormente, incluiremos un apartado de Comentarios Finales, que sintetizará los resultados obtenidos en esta memoria y servirá como compendio y conclusión de los aportes realizados en la misma. Finalizaremos la memoria con una serie de Apéndices dedicados a la descripción de algunos métodos de aprendizaje empleados, una presentación más amplia y completa de los resultados obtenidos y una recopilación bibliográfica que recogerá las contribuciones más destacadas en la materia estudiada.

Capítulo 1

Mercados de Capitales

1.1. Introducción

Desde que hicieron su aparición las primeras computadoras, investigadores de las más diversas disciplinas han sabido sacar provecho de las nuevas tecnologías. A medida que ha ido creciendo el poder de cálculo, también ha ido creciendo el interés en resolver ciertos problemas específicos con más exactitud y en un tiempo razonable, dos objetivos que generalmente son difíciles de alcanzar en forma simultánea, motivo por el cual muchas veces es necesario optar por soluciones de compromiso.

El estudio de los mercados financieros no es ajeno a este gran interés. Actualmente existen varios problemas asociados a los mercados financieros para los cuales si bien existen soluciones, éstas presentan ciertas falencias que impiden su utilización práctica o requieren mucho conocimiento por parte de los operadores para poder aplicarlas. Entre otros, podemos mencionar: la selección de una cartera de inversiones que optimice las ganancias totales, la elaboración de una estrategia o conjunto de reglas que permitan seleccionar las mejores operaciones para una o varias especies, la predicción del comportamiento del precio de una especie en el futuro, la obtención de una simulación aproximada del funcionamiento de un mercado, etc. En pocas palabras, más allá de la manera en que se lo presenta, en todos los casos el objetivo subyacente que se persigue es el mismo: operar en un mercado de valores utilizando una estrategia que nos asegure que el resultado va a ser positivo, es decir que vamos a obtener ganancias.

Antes de comenzar con el análisis de la problemática, definamos algunos conceptos para comprender cómo funciona un mercado de capitales y de qué medios se vale un operador para tomar sus decisiones.

1.2. Mercados de Capitales

La expresión *mercado* se refiere al lugar físico acordado por los poseedores de bienes, quienes, con finalidad de intercambio, se reúnen con el objetivo de optimizar los costos del proceso de negociación. En el caso particular de un *mercado financiero* no existe el lugar físico de negociación y su funcionamiento se encuadra por medio de un marco legal o reglas y un grupo de participantes u *operadores de mercado* (traders, brokers, mutual fund managers, etc.). De una manera sencilla podríamos decir que una *bolsa de comercio* es un mercado donde se realizan operaciones de compra y venta de acciones u obligaciones, y donde se fija un precio público que se denomina *cotización* o cambio [APP80].

Dentro de un mercado de valores podemos distinguir dos fases:

- Un *mercado de valores primario* o de emisiones; esta fase se distingue cuando se realiza la oferta y demanda de valores en el momento en que una empresa entra a cotizar en bolsa (por ejemplo cuando una empresa pública es privatizada). Existe una relación directa entre el emisor y el suscriptor de los valores.
- Un *mercado de valores secundario*; aquí se produce la oferta y la demanda de valores que han sido emitidos con anterioridad.

Las funciones principales de una *bolsa de comercio* son:

- *Canalizar el ahorro*, es decir, facilitar el intercambio de fondos entre las entidades que precisan financiación y los inversores. Para ello, las entidades emisoras de títulos/valores han de ser admitidas en la bolsa. Esto se realiza en el mercado primario.
- *Proporcionar liquidez* a los inversores. De esta forma, el inversor puede recuperar su inversión cuando la precise si acude a la bolsa para vender los títulos adquiridos previamente. Este objetivo se consigue a través del mercado secundario.
- *Fijar el precio de los títulos* a través de la ley de la oferta y de la demanda.
- *Dar información a los inversores* sobre las empresas que cotizan en bolsa. Para cumplir con esta función las empresas admitidas en bolsa deben informar periódicamente su evolución económica. Esta información sirve como un método para valorar a las empresas cotizadas.

1.2.1. El Operador de Mercados

Un *operador de mercados* es funcionalmente el responsable instrumental en el proceso de negociación por intercambio de valores en el sistema financiero en representación de una firma o agente de mercado. El operador tiene por finalidad la compra/venta de valores con el fin de obtener un margen de ganancia sobre el capital excedente del flujo de negocios (el dinero que no se aplicó al negocio, o sea, el capital ocioso), en el caso de firmas no agentes, y la colocación del capital operativo (el dinero de sus clientes), en el caso de los agentes de mercado. Si bien el objetivo principal de operar en un mercado es siempre el mismo, no todos invierten de la misma manera y por eso se pueden distinguir al menos dos *perfiles de inversión* distintos.

1.2.2. Perfiles de inversión

La bolsa es un mercado muy útil tanto para el inversor que busca la *máxima rentabilidad* como para el que quiere primar la *seguridad*. Lograr un objetivo u otro depende de la actitud con la que el inversor accede al mercado.

Asomarse a las plazas bursátiles con un perfil netamente *conservador* permitirá encontrar en ellas respuesta a la necesidad de seguridad. Por el contrario,

abordarlas con una *actitud agresiva* abre las puertas a conseguir una magnífica rentabilidad, pero también expone al inversor a un riesgo considerable.

Las *operaciones* realizadas por un inversor permiten reconocer a qué perfil pertenece y en qué medida.

1.2.3. Tipos de operaciones

Cuando se va a realizar una operación de *compra* o *venta* de acciones se le da al intermediario una instrucción determinada:

- *Orden por lo mejor*: no se establece ningún límite de precio a la compra o a la venta, por lo que el intermediario la ejecutará lo antes posible, al precio que en ese momento haya en el mercado. Este tipo de orden tiene la ventaja de que se ejecuta inmediatamente, pero presenta el problema de que puede haber sorpresas desagradables:
Si se compra por lo mejor y el precio de la acción se dispara, puede ocurrir que la compra resulte más cara de lo previsto.
Si se vende por lo mejor y el precio se derrumba puede ser que se reciba menos dinero del estimado.
- *Ordenes limitadas*: se fija un precio que sirve de límite a la hora de realizar la operación:
Si es una operación de compra, se fija el límite máximo al que se está dispuesto a realizar la adquisición.
Si es una operación de venta se fija el límite mínimo al que se está dispuesto a vender las acciones.
Tiene como ventaja que se elimina el factor sorpresa, pero, por el contrario, puede que la orden tarde algún tiempo en ejecutarse, hasta que se de la condición establecida.

Existen dos maneras de realizar las operaciones de compra/venta de acciones:

- *Operación al contado*: en el momento en el que se realiza la transacción, el comprador entrega el dinero y el vendedor entrega las acciones.
- *Operación a plazo*: se caracteriza porque se acuerda que una de las partes aplaza el cumplimiento de su contraprestación:

En las *operaciones a plazo*, una de las partes realiza su contraprestación en un momento futuro determinado:

- *Compras a plazo*: el comprador recibe los títulos adquiridos el día de cierre de la operación, pero no tiene que realizar el pago hasta que se cumpla el plazo acordado. El comprador espera que el precio futuro de la acción suba. Ejemplo: Compra una acción de Telefónica por \$2.000 teniendo que realizar el pago de la operación dentro de 1 mes. El comprador espera que dentro de 1 mes ese título cotice a, por ejemplo, \$2.500, por lo que podría venderlo, pagar los \$2.000 que debe y quedarse con los \$500 restantes. De esta manera ganaría dinero sin haber invertido nada.

- *Venta a plazo*: el vendedor recibe el dinero de la venta el día de cierre de la operación, pero no tiene que realizar la entrega de los títulos hasta que se llegue a la fecha pactada. El vendedor espera que el precio de la acción baje. Ejemplo: Vende a plazo títulos de Telefónica por \$2.000 esperando que dentro de 1 mes sólo se pague por ellos, por ejemplo, \$1.500. El vendedor recibirá ahora \$2.000 y dentro de 1 mes, cuando tenga que entregar las acciones, espera poder comprarlas en el mercado por \$1.500, ganando la diferencia.

En las operaciones a plazo, el inversor (ya sea comprador o vendedor) tendrá que entregar una garantía (hasta un 50% del precio de la operación) para responder por el cumplimiento de su obligación futura.

El riesgo presentado por esta operatoria es la posibilidad de que el precio de la acción evolucione en sentido contrario al que espera el inversor. Existen varios indicadores utilizados por los inversores para anticiparse a estos movimientos como por ejemplo la *volatilidad* de la acción, las *tasas de interés*, el *índice de inflación* y la evolución del *volumen operado*.

1.2.4. Volatilidad de una acción

La *volatilidad* es una medida para determinar el grado de oscilación que tiene una acción en un período determinado de tiempo (véase la Figura 1.1). Esta definición se refiere entonces a la variabilidad que puede asumir una cifra alrededor de su valor promedio, proporcionando una estimación de la inestabilidad en su comportamiento a partir de una muestra de datos históricos.

El grado de oscilación que presenta una acción se mide con un indicador denominado *beta*. Este indicador compara la volatilidad de la acción con la que presenta la bolsa en su conjunto. La *beta* es la covarianza de la cotización de la acción y de un índice representativo del mercado, por ejemplo el NASDAQ, dividida por la varianza de la cotización de la acción.

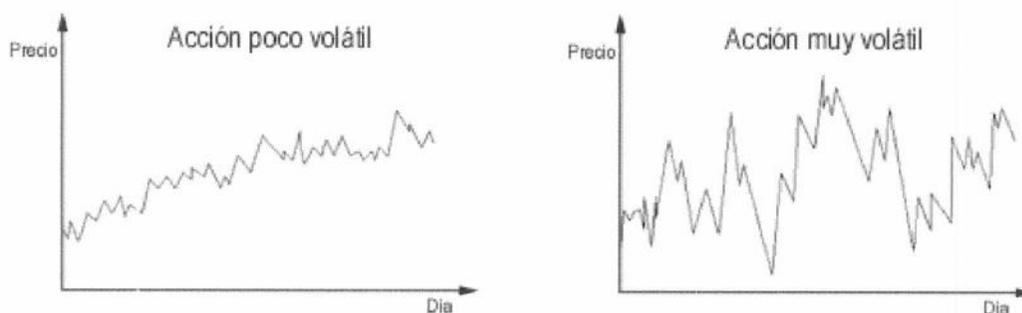


Figura 1.1 – Ejemplos de gráfico de cotización para una acción poco volátil y para una acción muy volátil.

1.2.5. Relación entre la cotización y varios indicadores

La cotización de los valores muestra movimientos relacionados con algunos indicadores financieros, entre ellos: tasa de interés, volumen operado.

- **Cotización vs. Tasa de Interés**

Existe una relación inversa entre las cotizaciones y las tasas de interés:

- Si las tasas de interés suben, las cotizaciones tienden a bajar.
- Si las tasas de interés bajan, las cotizaciones tienden a subir.

Causas y explicaciones:

- El mercado valora una acción descontando al momento actual los dividendos futuros que espera que dicha acción reciba.
- Si suben las tasas de interés, aumenta la rentabilidad de los títulos de renta fija, se hacen más atractivos, por lo que muchos inversores venderán acciones y comprarán renta fija, haciendo caer las cotizaciones.
- Si suben las tasas de interés, aumenta la carga financiera de las empresas, lo que hace disminuir sus beneficios, afectando negativamente a la cotización.

- **Cotización vs. Inflación**

La inflación y las cotizaciones también evolucionan de manera inversa:

- Si la inflación sube las cotizaciones tienden a bajar
- Si la inflación baja las cotizaciones tienden a subir

Hay diversas razones que explican esta relación contraria:

- Si sube la inflación, las autoridades monetarias elevarán las tasas de interés para tratar de controlar esta subida de precios, y ya hemos visto en el punto anterior como el aumento de las tasas de interés afecta negativamente a las cotizaciones.
- El aumento de la inflación repercute en un incremento de los costos de las empresas con el consiguiente impacto negativo en sus beneficios. Esto se traduce en una caída en las cotizaciones.
- Al aumentar la inflación la capacidad adquisitiva de las familias se resiente, por lo que disminuye su ahorro y, por lo tanto, la posibilidad de destinar fondos excedentes a la inversión en bolsa.
- Al elevarse la inflación disminuye la rentabilidad real de las acciones, reduciéndose su atractivo para el inversor.

- **Cotización vs. Volumen**

El volumen de los títulos negociados en cada sesión informa sobre el fortalecimiento o debilitamiento de la tendencia que esté describiendo la cotización del título (sea alcista o bajista). La relación entre volumen y tendencia es la siguiente:

- Tendencia alcista sólida: el volumen sube mientras la cotización sigue subiendo.

- Tendencia alcista débil: la cotización sube pero el volumen va disminuyendo.
- Tendencia bajista fuerte: el volumen sube mientras que la cotización sigue bajando.
- Tendencia bajista débil: la cotización baja pero el volumen se va reduciendo.

Hay distintos indicadores de volúmenes, entre ellos el más utilizado se denomina 'Balance de volúmenes'. Este indicador funciona de la siguiente manera: cada día se suma el volumen de acciones negociadas si el precio cierra en alza, y se resta si el precio baja.

- Si el balance de volumen va subiendo es debido a que la tendencia alcista predomina (señal de compra).
- Si el balance del volumen va bajando es porque predomina la tendencia descendente (señal de venta).

1.3. Estrategias de Inversión

El objetivo fundamental de cualquier *Estrategia de Inversión* (EI) para operar en un mercado es elegir comprar o vender especies que hagan ganar dinero al inversor o al operador. Las EIs van desde las puramente subjetivas a las puramente objetivas. En las más subjetivas, el inversor debe tratar con rumores, o su intuición para elegir las especies. Un inversor excesivamente subjetivo pega en la pared las páginas del mercado de capitales aparecidas en el diario y les arroja un conjunto de dardos, comprando luego las especies seleccionadas por los dardos. Un inversor puramente objetivo confía plenamente en fórmulas matemáticas o mecánicas. Cuando la fórmula o el algoritmo indica que la especie va a subir entonces el inversor compra, y cuando indica que va a bajar entonces vende. El caso más extremo es una computadora que calcula la ganancia potencial y realiza las operaciones directamente sin ninguna intervención del inversor.

1.3.1. Técnicas clásicas para la elaboración de Estrategias de Inversión

En el estudio del comportamiento de las acciones, con vistas a tratar de predecir su evolución futura, se utilizan dos tipos de análisis:

- *Análisis Fundamental* (AF): se basa en el estudio de toda la información económico-financiera disponible sobre la empresa (balance, cuenta de resultados, ratios financieros, etc.), así como de la información del sector, de la coyuntura macroeconómica, etc. En definitiva, se estudia cualquier información que pueda servir para tratar de predecir el comportamiento futuro de la empresa.

Con este análisis se determinan los puntos fuertes y débiles de la empresa, por ejemplo:

- *Solidez financiera* (peso del patrimonio neto dentro del pasivo).
- *Liquidez* (si la empresa dispone de los fondos suficientes con los que ir atendiendo sus pagos).
- *Gastos* (viendo si la empresa es cada vez más eficiente y viene reduciendo sus gastos o si, por el contrario, sus gastos están descontrolados).
- *Rentabilidad* (sobre volumen de venta, sobre fondos propios, etc.)

El AF estudia cómo viene evolucionando la empresa en estos y otros conceptos, y cómo compara con la media del sector. A partir de ahí, estima el comportamiento futuro de los beneficios, lo que determinará la posible evolución de la acción. Si los beneficios van a crecer, incluso más que la media del sector, lo lógico es que la acción se vaya revalorizando, mientras que si los beneficios están estancados o disminuyen, la cotización irá cayendo.

- *Análisis Técnico (AT)*: considera que el mercado proporciona la mejor información posible sobre el comportamiento de la acción. Analiza como se ha comportado ésta en el pasado y trata de proyectar su evolución futura [ACH95].

El AT se basa en tres premisas:

- *La cotización evoluciona siguiendo unos determinados movimientos o pautas.*
- *El mercado facilita la información necesaria para poder predecir los posibles cambios de tendencia.*
- *Lo que ocurrió en el pasado volverá a repetirse en el futuro.*

Trata de anticipar los cambios de tendencia. Si la acción está subiendo busca determinar en qué momento esta subida va a terminar y va a comenzar la caída, y lo mismo cuando la acción está cayendo.

Utiliza charts (gráficos de la evolución de la cotización) y diversos indicadores estadísticos que analizan las tendencias de los valores.

1.3.2. Análisis Fundamental

Como ya lo anticipamos, el *análisis fundamental* se basa en que la cotización de una acción depende de la evolución futura de los resultados de la empresa y de cómo se compararán con los de los competidores. Por lo tanto, habría que estimar cuál puede ser el comportamiento futuro de estos resultados.

Para realizar esta estimación, hay que analizar:

- La trayectoria que viene siguiendo la empresa.
- El comportamiento de los competidores (mejor o peor que el de la empresa)
- La situación económica y política del país, en la medida en que pueda afectar a los resultados de la empresa.

- La situación de otros países que sean mercados relevantes para la empresa.

En este análisis hay que realizar un estudio en profundidad del balance y de la cuenta de resultados.

El *balance* nos dirá:

- Si la empresa está suficientemente capitalizada o no.
- Si su nivel de endeudamiento es elevado o reducido.
- Si su liquidez es holgada o si, por el contrario, podría tener problemas para atender sus pagos.
- Gestión de sus existencias, plazo de pago de los clientes, si la empresa es puntual o se retrasa en el pago a sus proveedores, etc.

La *cuenta de resultados* nos dirá:

- Cómo evolucionan las ventas, si se gana o se pierde una parte del mercado.
- Cómo evolucionan los gastos, si crecen más o menos que las ventas: en definitiva, si la empresa es cada vez más eficiente o no.
- Estructura de la cuenta de resultados: ¿dónde gana dinero la empresa, en su actividad ordinaria o en partidas de carácter extraordinario?
- Beneficios: ¿cómo evolucionan?, ¿cuál es la rentabilidad que obtiene la empresa?

En el estudio de estos aspectos, se utilizan ratios o indicadores financieros. Si bien es posible utilizar cualquier ratio que uno considere conveniente, relacionando las partidas de balance y cuenta de resultados que puedan aportar información sobre la evolución de la empresa, los fundamentales son los que veremos a continuación.

Mientras que algunos manuales de análisis financieros facilitan valores ideales para estos ratios, cada sector económico tiene sus propias particularidades, por lo que varían significativamente de un sector a otro. Lo relevante no es, por tanto, comparar los ratios de la empresa con valores ideales, sino analizar la evolución histórica que vienen presentando, así como compararlos con los ratios medios de la competencia.

Las fuentes de información utilizadas por este tipo de análisis son:

- Información anual que las empresas están obligadas a presentar: auditoría de sus cuentas (incluye balance y cuenta de resultados del ejercicio).
- Información trimestral que toda empresa que cotiza tiene que presentar ante las autoridades bursátiles.
- Noticias en prensa de la empresa, de la competencia, del sector, de la situación económica en general.
- Hechos significativos (ampliaciones de capital, renovación del equipo directivo, cambio en la estructura accionaria, nuevos contratos firmados,

lanzamiento de nuevos productos, etc.) y que la empresa está obligada a comunicar a las autoridades bursátiles.

1.3.3. Análisis Técnico

Una posible definición de AT sería el estudio de los movimientos del mercado con el propósito de pronosticar las futuras tendencias de los precios. La expresión de movimientos de mercado incluye las dos fuentes principales de información disponible para el analista técnico que son: precio y volumen [HEX95, MUR86, PRI91].

El estudio de los gráficos de cotización se orienta a encontrar patrones determinados, que históricamente se han repetido (a veces de manera cíclica) y fundamentarse en ese comportamiento previsible para entrar o salir de una posición.

Mediante el AT es posible obtener grandes rentabilidades en pequeños periodos de tiempo, en una forma objetiva.

1.3.3.1. Racionalidad

Gran parte del éxito o fracaso de las estrategias definidas en base al AT dependen del grado de *disciplina* que tenga el inversor a la hora de implementar la misma.

El AT da la posibilidad de diseñar un método de gestión objetivo, que aplicado de forma sistemática sirve de herramienta de gestión de una cartera de activos financieros. Para ello se aplican métodos cuantitativos que permiten medir y estudiar de forma objetiva el comportamiento del valor. La aplicación de estos métodos pretende además reducir al mínimo la subjetividad y eliminar la componente emocional [FOS92].

1.3.3.2. Tendencias

El AT parte de que las cotizaciones se mueven por tendencias. Si bien las cotizaciones pueden reflejar muchos movimientos de zig-zag, en el fondo siguen una dirección o tendencia (véase la Figura 1.2) [EDW92].

El AT trata de detectar cuál es esta tendencia y busca anticiparse a los posibles cambios de la misma. La Teoría Dow (desarrollada por el analista que lanzó el índice Dow-Jones) habla de tres tipos de tendencias:

- *Tendencia principal*: es la tendencia básica, la que marca la evolución del valor a largo plazo y cuya duración puede superar el año. Para el Análisis Técnico esta tendencia es la que tiene mayor importancia. La tendencia principal puede ser: Alcista (bull market), Bajista (bear market) o *Lateral* u

horizontal. En este último caso se dice que la cotización se mueve sin una tendencia definida. Cuando esto ocurre, el Análisis Técnico aconseja no tomar decisiones hasta que no se manifieste nuevamente una tendencia.

- *Tendencia secundaria*: su duración oscila entre varias semanas y 3-4 meses, y son movimientos que tienen lugar dentro de la tendencia principal.
- *Tendencias menores*: son movimientos a corto plazo, con una duración entre un día y varias semanas. Para el Análisis Técnico tienen menor importancia ya que son más erráticas y difíciles de predecir.

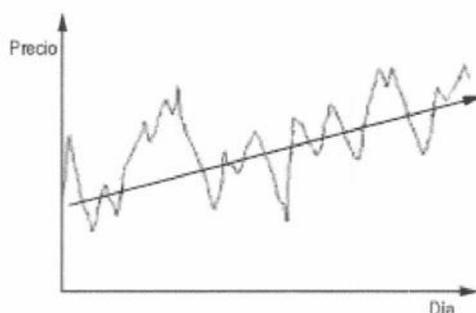


Figura 1.2 – Tendencia de la cotización de una acción (recta superpuesta a la curva de precios).

Las tendencias se desarrollan unas dentro de otras. La cotización sigue una tendencia principal, pero dentro de ella se desarrollan tendencias secundarias, y dentro de éstas hay movimientos a corto plazo. El AT trata de identificar estas distintas tendencias, de manera que permita al inversor estimar la evolución de la acción a largo plazo, así como el momento en que dicha evolución puede cambiar.

Una tendencia indica que existe un desequilibrio entre las fuerzas de la oferta y de la demanda. Ciertas formaciones o figuras, que suelen aparecer reflejadas en los gráficos de precios, pueden ser interpretados como una evolución futura de la tendencia.

1.3.3.3. Instrumentos y Figuras

Una parte importante del AT consiste en el uso de gráficos para descubrir tendencias en el precio de una acción o la dirección del mercado en su conjunto [BRO92, EDW92].

A lo largo del tiempo, el mercado y cada acción en particular tienden a oscilar en un determinado rango. En algunos casos, hay un incremento a un determinado nivel de precio donde se encuentra una presión vendedora muy fuerte. Esto se conoce como *área de resistencia*. Los precios son muy caros

causando que las compras cesen. Los analistas describirán al mercado como sobre-comprado, es decir comprado en exceso.

En otros casos, hay un descenso a un determinado precio que provoca que los inversores lo encuentren muy atractivo y compren a esos precios menores. Estas compras detienen el descenso del precio. Esto se conoce como el *área de soporte*. Los precios se vuelven tan atractivos que las ventas se detienen y comienza la operativa inversa: la compra en serie. Los analistas describirán al mercado como sobre-vendido o vendido en exceso.

Un breakout ocurre cuando el precio de la acción sube por encima del nivel de resistencia o declina por debajo del de soporte. Cuando esto ocurre, un analista técnico considerará que el precio de la acción seguirá su tendencia. Un breakout por encima del nivel de resistencia se considera como una señal alcista.

Las figuras gráficas tienen dos clasificaciones con distintas implicaciones: las *figuras de cambio de tendencia* y las *figuras de continuación de tendencia*. Las figuras de cambio de tendencia, como su propio nombre indica, son las que nos dan señales de debilidad en la tendencia actual y posibilidad de un cambio de tendencia. Las figuras de continuación nos avisan de que la tendencia actual se está tomando una pausa, pero que continuará con fuerza en un plazo corto. Las figuras gráficas suelen tener un valor predictivo importante.

Figuras de Cambio de Tendencia

- Formación de hombro-cabeza-hombro

Un hombro-cabeza-hombro, en rasgos generales, se caracteriza por tres puntos de resistencia y dos puntos de soporte. El primer y el tercer punto de resistencia se encuentran a los mismos niveles y el segundo punto de resistencia, es el máximo tocado en la tendencia alcista. A las formaciones que se producen en la primera y la tercera resistencia, se les llama hombros. A la formación de la segunda resistencia se le llama cabeza. Existe una línea clave, que se llama línea de cuello.

- Formación de hombro-cabeza-hombro invertido

El hombro-cabeza-hombro invertido es una figura gráfica idéntica al hombro-cabeza-hombro normal con la diferencia de que está invertida. Este tipo de formaciones se produce en el suelo en vez de en los techos. Esto implica que las consecuencias de estas formaciones son alcistas en lugar de bajistas.

- Formación de doble techo

Después de la formación del hombro-cabeza-hombro, el doble techo es la formación gráfica más común, con implicaciones de cambio de tendencia. Un doble techo, en rasgos generales, se caracteriza por dos puntos de resistencia y un punto de soporte. Los dos puntos de resistencia están, más

o menos, al mismo nivel. El doble techo tiene un aspecto gráfico muy parecido a una "M" (véase la Figura 1.3).

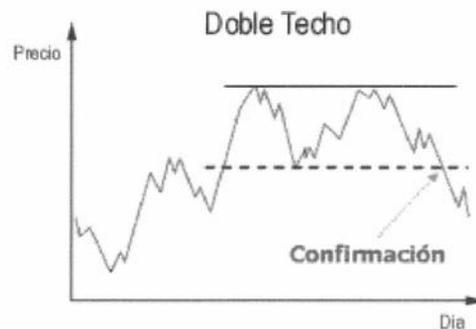


Figura 1.3 – Formación de Doble Techo.

- **Formación de doble suelo**

Se trata de una figura con características invertidas a las de un doble techo. Es decir, que en lugar de tener dos puntos de resistencia, tiene dos puntos de soporte, y en lugar de tener un punto de soporte, tiene un punto de resistencia. En este caso, estamos ante una figura alcista y gráficamente parecida a una "W" (véase la Figura 1.4).



Figura 1.4 – Formación de Doble Suelo.

- **Formación de suelos y techos redondeados**

Estas formaciones se producen en mercados donde hay muy poca volatilidad y el volumen de negocio es pequeño. Los techos y suelos redondeados suelen mostrar cambios progresivos y bastante simétricos en la dirección del activo.

Figuras de Continuación de Tendencia

- Formación de Triángulos simétricos

El triángulo simétrico no indica claramente hacia donde va a continuar la dirección el activo. Normalmente, este tipo de formación implica continuación de tendencia, pero en algunos casos implica un cambio de tendencia. Para la formación de un triángulo simétrico es necesario un mínimo de dos puntos de resistencia y dos puntos de soporte.

- Formación de triángulos rectos ascendentes

El triángulo ascendente se suele producir en tendencias alcistas y representa pausas de la tendencia actual. Al contrario del triángulo simétrico, el triángulo recto ascendente sí avisa hacia dónde se va a mover el activo. Esta formación tiene implicaciones alcistas y por lo tanto, lo que supera el activo es la línea de resistencia y no la línea de soporte. Este triángulo se caracteriza por tener la línea de resistencia plana. Esto es debido a que salen una gran cantidad de ofertas a un mismo nivel. La línea de soporte de este triángulo es ascendente, lo que significa que aparecen compradores cuando el precio está cada vez más arriba.

- Formación de triángulos rectos descendentes

El triángulo recto descendente se produce en las tendencias bajistas. Este tipo de triángulo nos señala pausas en la tendencia actual. A diferencia del ascendente, la línea plana es la de soporte.

- Formación de cuña

Las cuñas son formaciones gráficas muy parecidas a los triángulos. Constan de una línea de soporte y otra de resistencia que convergen. Se necesitan un mínimo de dos puntos de resistencia y dos puntos de soporte. Estas líneas tardan en formarse entre uno y tres meses y el volumen característico es descendente.

Sin embargo, a diferencia de los triángulos, las líneas de soporte y de resistencia que dibujan las cuñas tienen la misma dirección.

- Formación de bandera y gallardete

Suelen aparecer después de que en el mercado se han vivido sesiones muy dinámicas y se ha producido una subida o una bajada fuerte. La causa de que se produzcan estas formaciones suele ser la toma de beneficio por gran parte de los inversores. En el caso de la bandera, la toma de beneficios se produce mediante la formación de un rectángulo. Este rectángulo suele inclinarse en contra de la tendencia. En el caso de los gallardetes, se suele formar un pequeño triángulo simétrico. Como es lógico, en los dos casos es necesario un mínimo de dos puntos de resistencia y dos puntos de soporte.

- **Formación de ensanchamiento**

Aunque estas figuras se pueden considerar de continuación de tendencia, en el 90% de las apariciones tienen consecuencias bajistas, Su formación gráfica es muy parecida a la de los triángulos, pero de una forma invertida. Esto hace que también sean conocidos como triángulos invertidos.

- **Formación de diamante**

El diamante se considera una formación de continuación de tendencia, aunque en ocasiones aparece actuando de cambio de tendencia. Esta figura se basa en la formación de otras dos figuras consecutivas. Se produce primero una formación de ensanchamiento, seguida de un triángulo simétrico.

Otras figuras gráficas

Los huecos o gaps, como su nombre bien indica, son espacios vacíos que se producen en el gráfico de barras. La causa por la cual se producen es que no ha habido cruces a esos niveles. Es decir, que el mínimo (máximo) del día anterior al que se han cruzado precios es mayor (menor) que el máximo (mínimo) del día de hoy si la tendencia es bajista (alcista).

Se pueden producir en gráficos intradiarios, diarios y semanales, aunque en estos últimos no son tan comunes.

Existe una teoría que dice que siempre que se produce un hueco el mercado tiende a rellenarlo. Esta teoría como después veremos, sólo funciona en algunos casos.

Se pueden distinguir cuatro tipos de huecos: los huecos comunes o temporales, de ruptura, de continuación y de agotamiento.

1.3.3.4. Medias móviles

Las *medias móviles* son gráficas formadas por los valores medios de una cotización durante un período determinado [BRO92]. Ayudan a determinar la tendencia de un valor, eliminando la dificultad que plantea la erraticidad diaria de su cotización (véase la Figura 1.5).

Mientras que los *gráficos de cotización* permiten anticipar un futuro cambio de tendencia, las medias móviles simplemente lo detectan una vez que se ha producido.

Para calcular una media móvil se suman las cotizaciones de todos los días del período considerado y se divide esta suma por el número de días de dicho período. Por ejemplo: para una media móvil de 10 sesiones se suman las cotizaciones de los últimos 10 días y la suma se divide por 10. Cada día se realiza este cálculo y de esta manera se van obteniendo los valores para construir la curva que la representa.

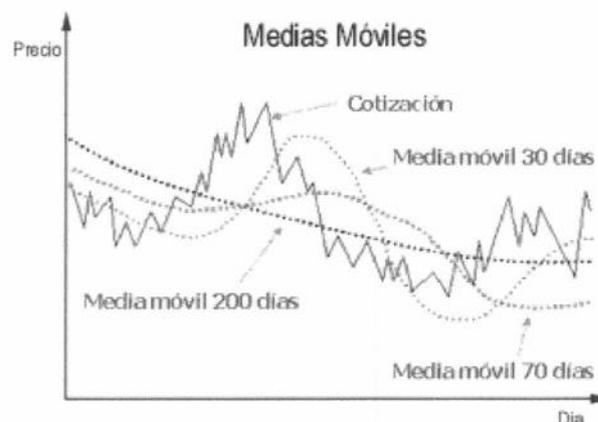


Figura 1.5 – Ejemplo con tres Medias Móviles.

Las *medias móviles* se pueden calcular utilizando distinta longitud de periodo:

- Medias móviles a corto plazo: se calculan para periodos que van entre 5 y 20 días.
- Medias móviles a medio plazo: se calculan para periodos que van entre 20 y 70 días.
- Medias móviles a largo plazo: se calculan para periodos que van entre 70 y 200 días.

Mientras más largo sea el período, más fiable es la información que facilita la media móvil sobre la tendencia de la cotización, pero más tarda en reflejar los cambios de tendencia, pudiendo suceder que cuando recoja dicho cambio ya sea tarde para tomar decisiones.

Las medias móviles avisan de cambios de tendencia que pueden interpretarse como señales de compra o de venta. Cuando la cotización corta una media móvil es un aviso de cambio de tendencia:

- Si la cotización va por encima de la media y la corta hacia abajo es indicio del inicio de una tendencia bajista (señal de venta, véase la Figura 1.6).
- Si la cotización va por debajo de la media y la corta hacia arriba es indicio del inicio de una tendencia alcista (señal de compra, véase la Figura 1.7).

El *corte* debe ser significativo, la cotización debe rebasar hacia arriba o hacia abajo a la media móvil en al menos un 5%. El indicio de cambio de tendencia se verá reforzado si la propia media móvil refleja un cambio de tendencia.

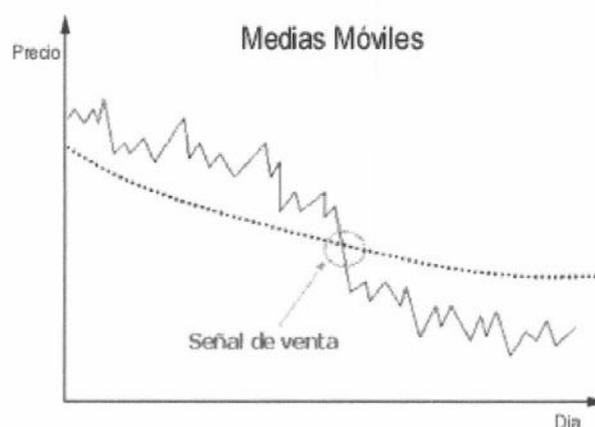


Figura 1.6 –Medias Móviles. Indicio de tendencia bajista.

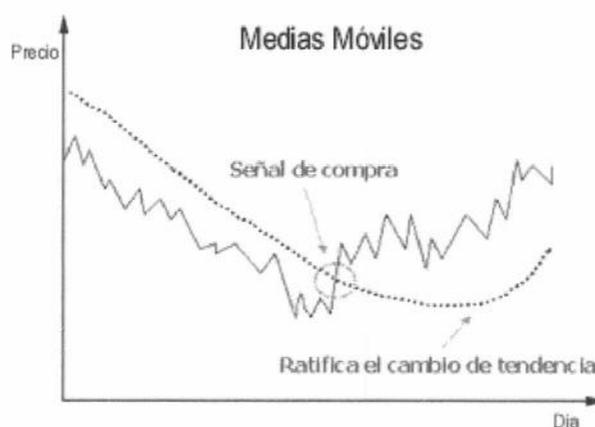


Figura 1.7 –Medias Móviles. Indicio de tendencia alcista

El corte de dos líneas de medias móviles, una de corto plazo y otra de mayor plazo, también anuncia un cambio de tendencia:

- Si la de corto plazo cruza hacia abajo a la de mayor plazo, es indicio del inicio de una tendencia bajista (señal de venta, véase la Figura 1.8).
- Si la de corto plazo cruza hacia arriba a la de mayor plazo, es indicio del inicio de una tendencia alcista (señal de compra, véase la Figura 1.9).

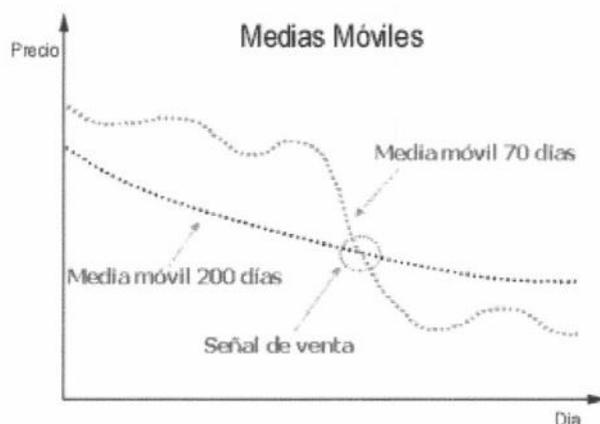


Figura 1.8 –Cruce de Medias Móviles. Indicio de tendencia bajista

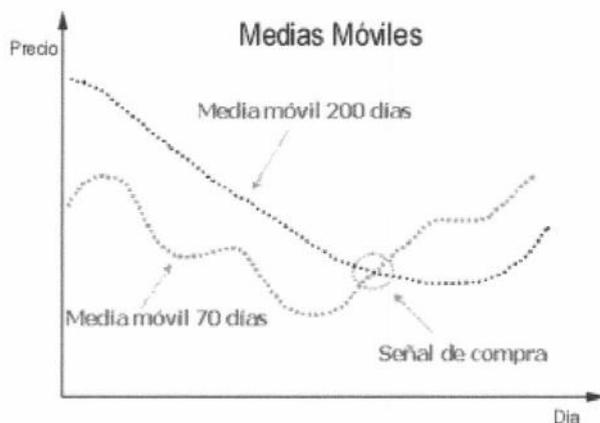


Figura 1.9 –Cruce de Medias Móviles. Indicio de tendencia alcista.

1.3.3.5. Otros indicadores utilizados

Momento

El momento es un *indicador de la velocidad* de subida o bajada de la cotización [CHA96, COL88]:

- Si la velocidad de subida o bajada se va acelerando indica que la tendencia se va fortaleciendo.
- Si esta velocidad se va desacelerando es señal de que la tendencia se está debilitando, por lo que se podría producir en breve un cambio de la misma.

Para su cálculo se utiliza la siguiente fórmula:

$$M(5) = C(n) - C(n - 5)$$

donde:

$M(5)$: momento de orden 5. El número entre paréntesis indica la amplitud del periodo considerado.

$C(n)$: cotización de cierre del último día del periodo

$C(n - 5)$: cotización de cierre de hace 5 sesiones

Se suelen tomar periodos entre 5 y 10 sesiones, aunque cabría utilizar periodos más largos. El valor de este momento se va calculando diariamente, lo que nos permite obtener una gráfica con la evolución de dicho indicador. Como la cotización diaria suele ser volátil, lo que se termina trasladando al momento dificultando su interpretación, se puede sustituir dicha cotización por una media móvil de corto plazo (10 - 15 sesiones), eliminando buena parte de estos movimientos erráticos.

Para su interpretación se deben observar las siguientes reglas:

- Si el valor del momento va creciendo, signo de tendencia alcista, tanto más sólida cuanto mayor sea la pendiente de esta subida. (señal de compra)
- Si va disminuyendo, señal de tendencia bajista, tanto más fuerte cuanto mayor sea la pendiente de caída. (señal de venta)
- Si la pendiente (tanto de subida como de bajada) se va desacelerando, señal de debilitamiento de la tendencia y posible cambio de la misma a corto plazo

Rsi

Este indicador muestra la fuerza interna que tiene cada activo en cada momento, con respecto a su tendencia [CHA94, COL88]. Los resultados que da este indicador fluctúan entre 0 y 100. Las señales más importantes, dadas por el Rsi, son las de sobre-compra y sobre-venta. Cuando el Rsi de un activo supera los niveles de 70, nos indica que este activo se encuentra sobre-comprado y que puede tender a la baja. Por el contrario, cuando el Rsi de un activo se encuentra por debajo del 30, nos indica que este activo se encuentra sobre-vendido, y que puede tender al alza.

Oscilador Estocástico

Este indicador fue introducido por George Lane [COL88]. Está basado en la asunción de que cuando un activo está en tendencia alcista, éste intenta cerrar en los máximos de la sesión. Por el contrario, cuando un activo se encuentra en una tendencia bajista, éste intenta cerrar en los mínimos de la sesión. Basándose en esta teoría, George Lane intentó buscar una relación matemática que estudiase la posición en que se encuentra el precio de cierre con respecto al máximo y mínimo de un período elegido.

El oscilador estocástico está formado por dos líneas, conocidas como %K y %D. La línea %K intenta encontrar la relación que tiene el precio de cierre con respecto a los máximos y a los mínimos. La línea %D es una media de la línea %K. Este indicador al igual que el Rsi, nos señala cuándo un activo puede encontrarse sobre-comprado y cuándo sobre-vendido. Las zonas de sobre-compra y sobre-venta se encuentran en 80 y 20 respectivamente

1.4. Dificultades que se presentan en el uso de las técnicas tradicionales

En la Sección anterior se presentaron dos fuentes principales de análisis utilizadas por los inversores. Si bien existen muchas opiniones en contra de ambas opciones de análisis, hay que destacar que tanto el análisis técnico como el análisis fundamental han sido y son utilizados diariamente por miles de inversores.

Una computadora puede efectuar cálculos basados en AT y evaluar de forma fría e imparcial un resultado, mientras que cualquier AF normalmente requerirá mucha mayor interpretación por nuestra parte y contendrá un mayor grado de subjetividad. Si bien gran parte de los datos utilizados por el AF son de dominio público, existen algunos indicadores que son de suma importancia para evaluar una compañía que no siempre están disponibles [APP80].

La tarea de identificar figuras en los gráficos de precios tiene un fuerte componente subjetivo debido a que los analistas técnicos deben predecir su formación antes de que esté completa. En muchos casos la formación que se va definiendo se puede corresponder con más de una figura conocida por lo que el inversor debe apelar a su olfato para determinar la figura que está por aparecer. Otro dato para tener en cuenta es que los inversores pueden encontrar las figuras tanto en períodos cortos como en períodos largos por lo que debe incluir diferentes escalas de análisis complicando más su seguimiento [ACH95].

Tanto las medias móviles como los indicadores utilizados en el AT requieren que el inversor posea conocimientos matemáticos y financieros para interpretar las señales de compra o de venta originadas por los mismos.

1.5. Marco de trabajo y Experiencias

El objetivo propuesto para este trabajo de tesis es encontrar Els que generen ganancias. Dichas estrategias deberán ser lo suficientemente precisas en cuanto al rendimiento y las predicciones que surjan a partir de las mismas como para alentar su uso por parte de los usuarios expertos en finanzas. Por otra parte, las Els identificadas o aprendidas deberán ser suficientemente interpretables como para posibilitar su comprensión y utilización por los mencionados expertos.

La manera elegida para adentrarnos en el tema fue asistir a un curso [CUR00] introductorio de la operatoria bursátil y la elaboración de Els. El curso cubrió los

siguientes temas: Introducción al Mercado, Acciones, Bonos, Opciones, Futuros, Análisis Técnico, Análisis Fundamental y Mercados internacionales. Durante el mismo se realizó una simulación de operaciones bursátiles con precios de un mercado real (Bolsa de Comercio de Buenos Aires).

Por otro lado, y para tener un mejor acercamiento a las Els utilizadas por los operadores, nos contactamos con profesionales expertos en el área pertenecientes al banco de inversiones ING. Luego de una serie de entrevistas donde se trataron todos los temas inherentes a la operatoria bursátil, llegamos a adquirir el conocimiento necesario para plantear el problema que vamos a tratar y analizar sus posibles soluciones.

En base a toda la información obtenida podemos constatar que el AT se adecua perfectamente a un cálculo computacional. Todos los datos requeridos están disponibles y son de naturaleza cuantitativa lo que permite un tratamiento muy objetivo de la información [COM97].

Todas las bondades reflejadas por estas propiedades hacen a que esta memoria esté basada en los conceptos que surgen del AT.

En esta memoria trataremos de aprender estrategias que realicen operaciones de compra y de venta de acciones. Para el caso de operaciones de venta debemos aclarar que esto se refiere a operaciones de venta a plazo (véase la Sección 1.2.3).

Finalmente, se deberá considerar a esta tarea de aprendizaje o identificación de Els como una tarea no estrictamente supervisada, debido a que no se cuenta con un conjunto de ejemplos que indiquen la correctitud de las mismas. Esto es, sólo se cuenta con información histórica de variables de mercado.

1.5.1. Estrategias de Inversión

Las Els identificadas o aprendidas deberán ser suficientemente interpretables como para posibilitar su comprensión y utilización por los expertos. En base a esta premisa decidimos utilizar Els del tipo comprar-mantener y vender-mantener. Esto es, si la estrategia nos dice comprar-mantener, nos está indicando que debemos realizar una compra y mantener por un determinado período para luego realizar la venta correspondiente. En forma análoga, si dice vender-mantener entonces hay que vender para luego de un período comprar.

Tal como se ha mencionado en la Sección 1.3.3.2, las tendencias son una de las fuentes de información más utilizadas por los analistas técnicos. Continuando con la idea de mantener un alto nivel de interpretabilidad, la aplicación de las estrategias utilizadas en las experiencias va a estar determinada por la tendencia observada en la evolución de la cotización.

Si bien una gran mayoría de los inversores decide sus operaciones basándose en Els que contienen una o dos reglas que involucran pocas especies, existen

inversores que lo hacen mediante Els más complejas. Algunos ejemplos de estas estrategias son: utilizar una regla para un conjunto de especies pertenecientes a un mismo sector comercial, utilizar varias reglas para operar con una sola especie, utilizar un mismo conjunto de reglas para operar con varias especies, operar con varias especies utilizando un conjunto de reglas específico para cada una de ellas.

Para valorar la efectividad de sus Els, los inversores suelen estudiar algunos factores que le dan una idea de su comportamiento. Entre estos factores, los más importantes son: las ganancias o pérdidas obtenidas y el porcentaje de veces que la estrategia le hizo ganar dinero. Cabe destacar que muchas veces es necesario tomar una solución de compromiso cuando se buscan mejoras en estos factores. Esto es, por querer aumentar las ganancias los inversores elaboran estrategias que operan una mayor cantidad de veces, pero producen una disminución de la efectividad de las mismas.

Observemos que en nuestra definición de Estrategia de Inversión no hay ninguna restricción que indique que tiene que ser una estrategia óptima sino que es suficiente con que no produzca pérdidas, y además no es necesario que todas las operaciones sean ganadoras sino que el resultado final sea positivo.

1.5.2. Datos

En todos los casos, nuestra fuente de información será el precio de cierre diario de cotización de las especies. Estos datos, correspondientes a varias especies que cotizan en la Bolsa de Comercio de Buenos Aires, han sido tomados por un período que abarca 1700 días a partir del año 1992. De esos 1700 días, 1200 serán utilizados para aprender las Els y los 500 días restantes para realizar el test de las mejores Els obtenidas. Para tener una idea de la complejidad de las series temporales que se van a utilizar, podemos ver algunos ejemplos en las figuras 1.10, 1.11 y 1.12. En el Apéndice A se encuentran las series temporales de todas las especies utilizadas en las experiencias.

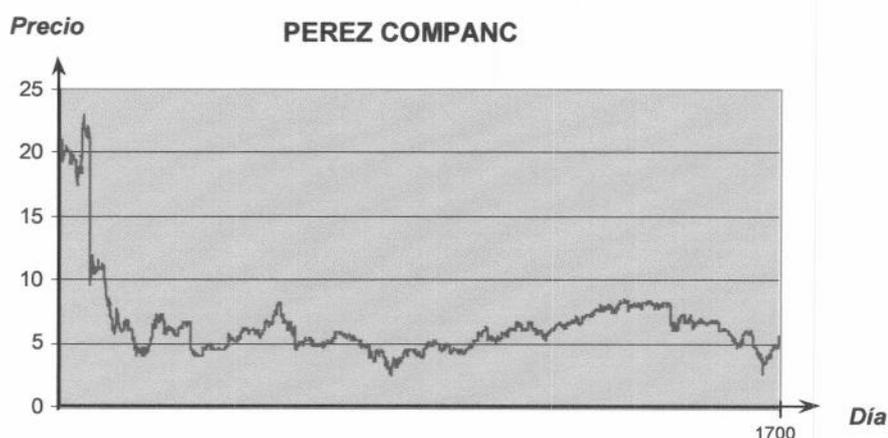


Figura 1.10 – Gráfico de evolución de la cotización de la especie Pérez Companc.

Si la especie Renault presenta una tendencia creciente por 5 días entonces comprar, ó si presenta una tendencia decreciente de 3 días entonces vender.

Por otra parte, consideraremos dos opciones para el proceso de lectura de los datos:

- *Secuencial*: los datos serán analizados en forma cronológica para verificar si se cumple el antecedente de la estrategia.
- *Aleatorio*: para evaluar la estrategia se analizará el conjunto de datos en forma aleatoria.

La inclusión de experiencias realizadas con un muestreo al azar nos va a ser de utilidad para verificar que el procedimiento empleado no es dependiente de la secuencialidad de los datos.

En base a los resultados obtenidos, intentaremos analizar la incidencia de factores tales como la ganancia obtenida, el porcentaje de operaciones realizadas, el porcentaje de operaciones exitosas, etc.

1.5.4. Restricciones

Normalmente, quien desea operar con acciones en una bolsa de comercio, debe hacerlo a través de un agente, el cual cobra al cliente una comisión por cada operación que realiza. Por lo tanto este costo es dependiente de la cantidad de operaciones realizadas. Si bien existe en una operación real, no va a ser tenido en cuenta para el cálculo de la ganancia generada por las estrategias utilizadas en las experiencias. Indirectamente va a estar presente en el análisis de los resultados, ya que el *porcentaje de operaciones* realizadas será uno de los puntos de vista estudiados.

En lo que respecta al monto invertido en cada operación siempre se va a comprar o vender una sola acción de la especie analizada al precio de cierre del día correspondiente.

1.6. Observaciones finales.

En este Capítulo hemos presentado una breve descripción de los Mercados de Capitales y de sus actores principales, los operadores. Se analizaron varios aspectos relacionados con la operatoria bursátil: órdenes, cotizaciones, volatilidad, etc. y se introdujo el concepto de Estrategias de Inversión.

Los inversores utilizan dos fuentes principales de información: el Análisis Técnico y el Análisis Fundamental. Si bien estas dos técnicas han sido y son muy populares entre los operadores de bolsa, presentan algunos inconvenientes asociados principalmente con un exceso de subjetividad y con la complejidad. En particular, el AF además de la subjetividad tiene el

problema de que no siempre todos los datos de las variables analizadas están disponibles. En el AT encontramos problemas de subjetividad en el reconocimiento de las figuras y problemas de complejidad en el cálculo de algunos de los indicadores utilizados por los expertos.

Finalmente se ha establecido el marco de trabajo y se han descrito brevemente las EIs y los conjuntos de datos que serán utilizados en las experiencias que se desarrollarán en Capítulos posteriores.

Capítulo 2

Técnicas de Aprendizaje Automático

2.1. Introducción

Si recordamos las premisas fundamentales del análisis técnico, se puede observar que estas características admiten un tratamiento con técnicas de *Aprendizaje Automático* (AA) [MCK83]. En particular, el hecho de que lo ocurrido en el pasado vuelva a repetirse en el futuro nos invita a pensar seriamente en la utilización de algún sistema de clasificación para aprender las Estrategias de Inversión (EIs).

En este Capítulo estudiaremos varias técnicas computacionales que han sido utilizadas para tareas de aprendizaje, con el objetivo de presentar las bases teóricas para analizar las maneras de realizar hibridaciones efectivas que nos permitan resolver algunos de los problemas planteados.

Para ello, este Capítulo está organizado de la siguiente forma: en la Sección 2.2 haremos una reseña de los trabajos relacionados con el problema planteado en los que se utilizan herramientas computacionales y luego en la Sección 2.3 analizaremos cuáles son los problemas que se presentan en las mismas. En la Sección 2.4 introduciremos varios conceptos de aprendizaje y estudiaremos diversas técnicas utilizadas para el AA como los Algoritmos Evolutivos (AEs) haciendo hincapié en los Algoritmos Genéticos (AGs) detallados en la Sección 2.4.2. En la Sección 2.4.3, se presentarán dos enfoques de aplicación de los AGs al aprendizaje de reglas: Michigan y Pittsburgh y se mencionarán las ventajas y desventajas de cada uno de ellos. En la Sección 2.4.4, se describirán las componentes de los Sistemas Clasificadores (SCs) y se analizarán los procesos de aprendizaje que tienen asociados. En la Sección 2.4.5, estudiaremos las componentes y algunos aspectos de diseño de los Sistemas Basados en Reglas Difusas (SBRDs) como por ejemplo los inconvenientes que presentan las diferentes formas de construir la Base de Datos (BD). En la Sección 2.4.6, mostraremos de qué manera han sido utilizados los Algoritmos Genéticos (AGs) en los procesos de aprendizaje de los SBRDs dando lugar a una familia de sistemas denominada Sistemas Difuso Genéticos (SDGs). En la Sección 2.4.7, se presenta una variante de los SBRD dedicada al modelado de SCs que utilizan como herramienta de representación a las reglas difusas, denominada Sistemas Clasificadores Basados en Reglas Difusas (SCBRDs). En la Sección 2.4.8, analizaremos técnicas de Clustering con el objetivo de poder utilizarlas para realizar un aprendizaje eficiente de la BD del SCBRD. Finalmente, en la Sección 2.5, se brindarán comentarios y algunas observaciones finales.

2.2. Reseña de trabajos previos con herramientas computacionales

Existen varias formas de tratar de capturar el conocimiento para poder utilizarlo en la construcción de herramientas útiles que permitan ayudar a realizar operaciones exitosas, es decir las que generen mayores beneficios económicos. Existe un conjunto de técnicas dentro y fuera de la Inteligencia Artificial que se utilizan para predecir el comportamiento de los precios y en base a éste tomar decisiones.

- Los métodos de aprendizaje basados en redes neuronales (RN) proveen un acercamiento robusto para la aproximación de funciones de valores reales, discretos y vectoriales. Para cierto tipo de problemas tales como aprender a interpretar datos complejos del mundo real, las RN son métodos efectivos de aprendizaje. Por ejemplo, el algoritmo Back-Propagation fue exitoso en muchos problemas prácticos como el aprendizaje o reconocimiento de textos, aprendizaje de reconocimiento del lenguaje y aprendizaje de reconocimiento de rostros [MIT97].

En las finanzas, las RN se pueden utilizar para predecir el valor de un bono y tomar decisiones con respecto a una cartera de especies. Este tipo de modelos difiere de otras aplicaciones en varios aspectos. La primera observación es que estos modelos son cuantitativos. El trabajo se basa en la creencia de que hay algún patrón subyacente o relaciones estocásticas entre varios indicadores del mercado y las ganancias. Si estas relaciones son descubiertas, pueden ser aprovechadas para operar en forma eficiente. Esto está en fuerte contraste con los modelos de agentes o sistemas expertos. Mientras que en éstos se trata de cuantificar lo que ya es conocido sobre el mercado, las RN, en cierto modo redescubren estas relaciones por sí mismas [DEB94, CHE96].

- La Lógica Difusa (LD) puede ser vista como un lenguaje que permite trasladar sentencias sofisticadas en lenguaje natural a un lenguaje matemático formal. La mayoría de los fenómenos que encontramos diariamente son imprecisos, es decir, tienen implícito un cierto grado de difusidad en la descripción de su naturaleza [ZAD65].

La LD ha sido aplicada exitosamente en muchas áreas donde los modelos convencionales son dificultosos o costosos de implementar. Los sistemas desarrollados bajo la LD permiten incluir reglas de operación provistas por los operadores y son capaces de presentar una explicación interpretable de las recomendaciones hechas.

Es apropiado usar LD cuando gran parte de las variables de entrada son continuas, cuando no existen modelos matemáticos para las interacciones entre las entradas y las estrategias de salida deseadas, o cuando la elaboración de sistemas expertos para decisiones de operaciones es compleja o dificultosa de evaluar en tiempo real [DEB94, YE94].

Un modelo difuso de operaciones, consta de una o más entradas difusas (tendencias o medidas de volatilidad), una salida (el patrón de operación deseado) y unas pocas reglas difusas expresando las relaciones entre ellas.

- La madurez alcanzada por ciertas tecnologías para poder procesar gran cantidad de información ha permitido a los investigadores dedicarse a ciertos aspectos del mercado en los que antes no era posible. Las técnicas de data mining (DM), como por ejemplo clasificación y clustering, son utilizadas para descubrir patrones ocultos en las operaciones realizadas por los operadores en un mercado. En [WEI98a] se intenta encontrar respuesta a preguntas como “Qué estilos de operaciones y regularidades ocultas pueden descubrir los métodos estadísticos en bonos futuros?”, “Encontraremos evidencias que sean consistentes con el análisis técnico?”, “Podemos modelar transiciones de un modelo a otro?”, etc., mediante la aplicación de técnicas de clustering a un conjunto de tres años de transacciones. Los resultados obtenidos muestran que algunos estilos se corresponden con las reglas del análisis técnico mientras que otros difieren significativamente en lo que hace a los beneficios y riesgos. Del estudio surgen varios líneas de investigación que incluyen desde el análisis del comportamiento de operadores exitosos y no exitosos hasta el estudio del impacto de eventos de noticias en los precios y en la volatilidad visto desde el micro nivel de operadores individuales.

En muchos casos los datos financieros son modelados con métodos supervisados, donde las dependencias funcionales son estimadas con objetivos específicos (tales como ganancias o beneficios). En contraste, los métodos no supervisados se aplican en casos donde se necesita descubrir estructuras ocultas sin conocimiento de tales objetivos predefinidos. En [WEI98b] se puede ver una comparación de estas dos clases de métodos que muestra sus fortalezas y debilidades. Allí se contrastan métodos basados en árboles de decisión y clustering aplicados a transacciones correspondientes a bonos futuros (3 millones de transacciones). Las comparaciones se realizan en términos del rendimiento en la predicción de las ganancias. En [KEO97] se presenta una representación extendida de series de tiempo que permite realizar clasificaciones y clustering rápidos y precisos. La representación realiza segmentaciones de la serie de tiempo que son modeladas con líneas rectas. De esta manera, se obtiene una secuencia de líneas rectas para modelar la serie de tiempo.

- Los Algoritmos Genéticos (AGs) han sido aplicados exitosamente a una variedad de tareas de aprendizaje y a otros problemas de optimización. Por ejemplo: han sido usados para aprender colecciones de reglas para controlar un robot, para optimizar la topología y los parámetros de aprendizaje en redes neuronales y para detectar Estrategias de Inversión [FRK96, MAH96, WON94, DAC97]. Como ya se ha visto, las redes neuronales tienen la capacidad de aprender los mecanismos subyacentes en las series de tiempo, y específicamente en el caso de las operaciones, la dinámica del mercado. El problema es que muchos de los principios que se manejan son difíciles de entender y la complejidad de los datos los hace inaplicables.

Cuando se quiere optimizar a las redes neuronales en problemas de predicción y clasificación, se pueden aplicar algoritmos genéticos en distintos aspectos, por ejemplo: para buscar la correcta combinación de datos de entrada, el mejor horizonte de predicción, la más óptima interconexión de patrones de redes, los pesos entre las neuronas y los parámetros de control [MCL93].

Como las redes neuronales, los algoritmos genéticos no siempre garantizan la solución perfecta, pero en muchos casos arriban a una solución aceptable sin usar un tiempo extensivo en búsquedas exhaustivas.

2.3. Problemas de la aplicación de estas técnicas al problema de identificación de Estrategias de Inversión

Las técnicas mencionadas en la Sección anterior presentan algunas falencias al ser aplicadas a la clase de problemas financieros que estamos analizando en este trabajo.

En [GIL95], se presenta un análisis crítico respecto de las técnicas de inteligencia artificial que han ido incorporándose como herramientas en la industria financiera, desde simulaciones con agentes hasta RN pasando por sistemas expertos. En general estos sistemas son utilizados como un complemento para el equipo de expertos en lugar de ser los expertos en sí mismo. Esto es, estos sistemas son considerados como una herramienta más dentro del conjunto de factores que determinan las decisiones de los expertos.

Algunas de las desventajas de los sistemas de operaciones basados en RNs son:

- Falta de capacidad explicativa.
Las RNs son implementaciones de tipo caja negra donde el sistema aprende a partir de ejemplos la relación que existe entre las entradas y la salida. Esta característica no permite obtener, acerca de las recomendaciones que genera, una explicación razonable que pueda satisfacer a un experto.
- Dificultad para incluir conocimiento estructurado.
Si bien en muchos casos es posible contar con conocimiento obtenido de los expertos para facilitar y mejorar el aprendizaje, cuando se utilizan RNs no se puede aprovechar este conocimiento.
- Preferencia de datos cuantitativos.

A medida que se incrementa la complejidad del sistema a modelar con LD, las reglas difusas y las funciones usadas para describir el comportamiento del entorno son difíciles de determinar. Además, debido a la naturaleza dinámica de las aplicaciones económicas y financieras, las reglas deben ser capaces de adaptarse a los cambios en el entorno.

La recolección de información asociada a las operaciones realizadas por los inversores es una tarea que presenta varias dificultades. Muchas veces por

políticas del negocio esta información está restringida. Suponiendo que esté disponible, una vez obtenida es necesario anexarle otras fuentes de información, por ejemplo: cotizaciones históricas, volumen operado, etc. Todos estos factores producen una importante complejidad a los estudios realizados con técnicas de Data Mining.

Por otra parte, mantener un buen balance entre la precisión y la interpretabilidad del sistema no es una tarea sencilla. Generalmente, aumentar la precisión del sistema trae como consecuencia una pérdida en la interpretabilidad del modelo, y viceversa.

2.4. Utilización de técnicas híbridas de Aprendizaje Automático

El *Aprendizaje Automático* (AA) [MCK83] puede definirse como la adquisición de *conceptos* mediante la exploración de los datos. Esto es, las similitudes encontradas en los datos de entrada permiten que un programa inductivo aprenda conceptos.

El *método de aprendizaje* puede ser analizado desde dos perspectivas: la disponibilidad de los datos y la existencia de conceptos o resultados asociados a los datos.

- Desde la primer perspectiva, se dice que el aprendizaje es *incremental* cuando los datos están disponibles a lo largo del tiempo y el sistema de aprendizaje debe adaptar lo que ya ha aprendido a medida que recibe y procesa nuevos datos. En el aprendizaje *por lotes*, por otro lado, todos los datos están disponibles al comienzo y el sistema puede formar conceptos analizando todos los datos simultáneamente.
- Desde la segunda perspectiva podemos hablar de aprendizaje *supervisado*, *no supervisado* y *por refuerzo*.
 - El *aprendizaje no supervisado* opera con datos para los que no se conoce un concepto o resultado asociado.
 - En el *aprendizaje supervisado*, junto con los datos el sistema recibe el concepto correspondiente adjudicado por un experto o por experiencias previas comprobadas.
 - El *aprendizaje por refuerzo* difiere del aprendizaje supervisado en varios aspectos. La diferencia más importante es que, al igual que en el aprendizaje no supervisado, el sistema no recibe pares con datos de entrada y salida. El sistema recibe una recompensa o refuerzo cada vez que toma una decisión. Con este refuerzo establece una valoración sobre la decisión tomada que le permite obtener experiencia que posteriormente utilizará para tomar decisiones. Además, un sistema de aprendizaje por refuerzo realiza los procesos de aprendizaje y evaluación en forma concurrente, por lo que hay que considerar sus costos computacionales [KAE95, RUS96].

Una de las técnicas usadas en la actualidad para tareas de aprendizaje son los Algoritmos Evolutivos (AEs). Si bien los AEs no son algoritmos de aprendizaje, ofrecen una metodología de búsqueda potente e independiente del dominio que puede ser aplicada a tareas de aprendizaje. Dentro de los AEs existen dos enfoques de aplicación al aprendizaje de reglas que se describirán en detalle en las próximas secciones: Michigan y Pittsburgh.

2.4.1. Algoritmos Evolutivos

La Computación Evolutiva (CE) está basada en la utilización de modelos de procesos evolutivos para el diseño y la implementación de sistemas computarizados de resolución de problemas. Los modelos computacionales propuestos dentro del marco de esta filosofía generalmente son denominados Algoritmos Evolutivos (AEs) [BÄC96]. De acuerdo a lo expresado en [BÄC97], dentro de los AE podemos mencionar cuatro líneas de trabajo bien definidas que sirven como base a la mayoría de los desarrollos de esta área:

- Algoritmos Genéticos (AGs) [GOL89, HOL75];
- Estrategias de Evolución (EEs) [BÄC95, SCH95];
- Programación Evolutiva (PE) [FOG66, FOG91];
- Programación Genética (PG) [KOZ92].

Desde el punto de vista de la optimización, los AEs son considerados como metaheurísticas. Las metaheurísticas conforman un proceso de generación iterativo que guía a una o más heurísticas subordinadas combinando en forma inteligente diferentes conceptos para explorar y explotar las distintas estrategias de búsqueda usando estrategias de aprendizaje para estructurar información con el fin de encontrar eficientemente soluciones cercanas al óptimo [OSM96].

Los AEs mantienen una población de posibles soluciones para el problema a resolver que se va modificando en cada paso o generación. En la transición de una generación a la siguiente, el algoritmo produce alteraciones sobre las soluciones y mediante un proceso de selección determina cuáles permanecerán en la siguiente y cuáles serán eliminadas. Todos los modelos existentes de AEs comparten la misma estructura general, pero en cada uno de ellos aparecen algunas particularidades en la manera en que se lo implementa:

- *AGs*: están basados en operadores que tratan de modelar las operaciones genéticas naturales que actúan sobre los individuos de la población de soluciones.;
- *EEs* y *PE*: las transformaciones que implementan se basan en la aplicación de operaciones de mutación sobre los individuos para obtener los hijos, de manera que permite que la descendencia mantenga una línea general de comportamiento.
- *PG*: las soluciones al problema son codificadas en forma de programas (generalmente en una estructura de árbol) que luego sufren un proceso de adaptación mediante operadores específicos.

2.4.2. Algoritmos Genéticos

Los AGs son algoritmos de búsqueda de propósito general, basados en principios inspirados en la genética de las poblaciones naturales para llevar a cabo un proceso evolutivo sobre soluciones de problemas (véase la Figura 2.1). Inicialmente fueron propuestos por John Holland [HOL75] y posteriormente han sido estudiados con mayor profundidad por otros autores [GOL89, MIC96]. *“La evolución adaptativa es el motor de la biología. Pero sus mecanismos son tan generales que también deberían ser efectivos dando forma a los sistemas artificiales”*, manifestaba John Holland a comienzos de los 70.

Los AGs han demostrado ser una herramienta óptima que proporciona una búsqueda robusta en espacios complejos, tanto desde un punto de vista teórico como práctico, ofreciendo un enfoque válido para solucionar problemas que requieran que la herramienta sea eficiente y eficaz [GOL98, GRE94].

Genética natural	Algoritmos genéticos
Cromosoma	Cadena de caracteres (String)
Gen	Bit, carácter, propiedad.
Allele	Valor de la propiedad, valor de un gen.
Sitio	Posición
Genotipo	Estructura, solución codificada.
Fenotipo	Comportamiento, conjunto de parámetros, solución alternativa, estructura decodificada, solución decodificada, o un punto en el espacio de soluciones.

Figura 2.1 – Comparación de la terminología de la genética natural y los algoritmos genéticos

Gran parte de este éxito se debe a su habilidad para explotar la información que van acumulando sobre el espacio de búsqueda que manejan. Generalmente este espacio es desconocido al inicio del proceso y a medida que la evolución avanza, la información obtenida permite orientar la búsqueda hacia los subespacios más útiles. Su característica principal es la capacidad de adaptación que presentan, especialmente cuando los espacios de búsqueda son grandes, complejos y con poca información disponible, donde las técnicas clásicas de búsqueda (enumerativas, heurísticas, etc.) no presentan buenos resultados.

2.4.2.1. Definición

Se puede decir que un AG realiza una búsqueda multidireccional al mantener una población de soluciones potenciales y promover la elaboración de información y el intercambio entre esas direcciones. Durante el proceso de búsqueda la población sufre una evolución simulada: en cada generación las

soluciones relativamente buenas se reproducen mientras que las relativamente malas mueren. Para distinguir entre las diferentes soluciones se define el concepto de bondad o aptitud, mediante una función objetivo o de evaluación que usualmente retorna un valor numérico.

Las sucesivas generaciones mejoran la aptitud de los individuos de la población hasta que se alcanza el criterio de convergencia esperado para la optimización (que, como en cualquier técnica de optimización, puede ser una disyunción de varias condiciones de parada, como por ejemplo una cantidad máxima de generaciones o una cantidad máxima de generaciones en las que se repite el valor de aptitud del mejor individuo). A pesar de que por su naturaleza probabilística los algoritmos genéticos tienden a alcanzar un óptimo global, por esa misma característica no pueden garantizar que se llegue a la solución óptima.

Más allá de que las diferentes implementaciones de AGs puedan variar en sus detalles, en líneas generales todas comparten una estructura similar (véase la Figura 2.2). Las sucesivas generaciones se forman como resultado de seleccionar los mejores individuos de la generación actual y aplicarles un conjunto de operaciones genéticas (básicamente cruzamiento y mutación). Luego de haber avanzado a través de una determinada cantidad de generaciones, se espera que esta última contenga la o las mejores soluciones.

Generalmente, cuando se quiere reutilizar un AG para resolver un nuevo problema, sólo es necesario redefinir su función de evaluación. El hecho de que los AGs posean esta fuerte independencia de dominio, si bien es una propiedad muy conveniente, no permite el tratamiento de restricciones no triviales. No obstante, existen varias maneras de implementarlas:

- imponer *grandes penalizaciones* a los individuos que las violan;
- imponer *penas moderadas*;
- construir *filtros* que se aplican en la etapa de creación de nuevos individuos (usados en la creación de la población inicial y en el momento de aplicar los operadores genéticos) que eviten crear individuos que violen las restricciones.

Igualmente, cada una de estas opciones presentan sus inconvenientes por lo que debe evaluarse cuáles conviene utilizar para cada caso en particular:

- Una *alta penalización* en la rutina de evaluación sobre una población en la que es muy probable que se generen individuos que violan restricciones, puede producir un algoritmo genético que pierda demasiado tiempo evaluando individuos ilegales. Además, también puede suceder que estos individuos ilegales generen nuevos individuos ilegales y el algoritmo converja prematuramente sobre los pocos individuos legales reduciendo el espacio de exploración.
- Si se utiliza una *penalización moderada*, el sistema puede evolucionar sobre los individuos ilegales que tienen mejor aptitud.
- Finalmente, al incorporar *filtros* que evitan la generación de individuos ilegales se produce un incremento del costo computacional del algoritmo.

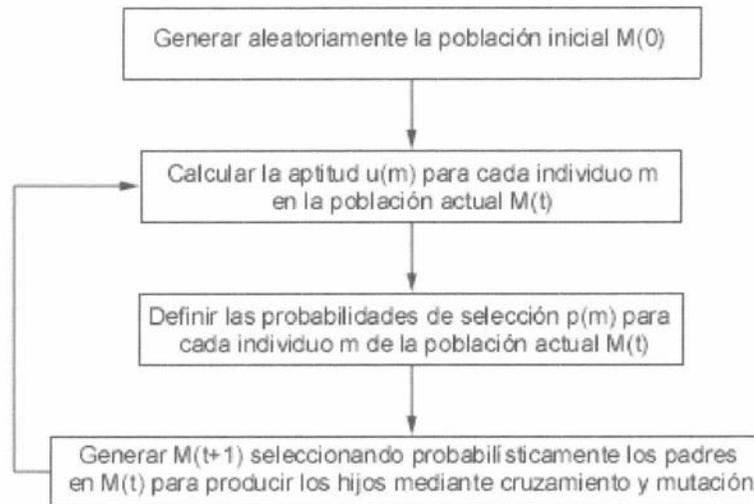


Figura 2.2 – Un algoritmo genético simple.

2.4.2.2. Componentes

Un algoritmo genético para un problema particular debe tener definidos los siguientes componentes [MIC96]:

- Una representación genética para las soluciones potenciales del problema.
- Una manera de crear la población inicial de soluciones potenciales.
- Una función de evaluación que califica las soluciones en términos de sus aptitud.
- Operadores genéticos que alteran la composición de los hijos.
- Valores para los parámetros que utiliza el algoritmo genético (tamaño de población, probabilidad de aplicación de un operador, etc.)

Podemos decir que más allá de tener una estructura general en común (como veremos luego), varios de sus componentes deben ser definidos e implementados analizando el problema particular que se intenta resolver. Los AGs constan de cuatro etapas fundamentales: evaluación, selección, cruzamiento y mutación (véase la Figura 2.3).

- El proceso iterativo de los AGs continúa hasta que se alcanza uno de los posibles criterios de terminación. Los más utilizados son: alcanzar un óptimo conocido o un nivel de solución aceptable, llegar a una cantidad determinada de generaciones, y detectar que no hay mejoras en la aptitud en varias generaciones sucesivas. El hecho de que se cumpla este último criterio no significa que el algoritmo haya encontrado el mejor resultado, ya que puede haberse detenido en un óptimo local.

```
procedimiento algoritmo genético
comienzo
  t = 0
  iniciar P(t)
  evaluar P(t)
  mientras (no se cumple la condición de terminación) hacer
  comienzo
    t = t + 1
    seleccionar P(t) de P(t -1)
    modificar P(t)
    evaluar P(t)
  fin
fin
```

Figura 2.3 – Cuerpo de un algoritmo genético

- *El procedimiento de evaluación* mide la aptitud de cada solución individual en la población y le asigna un valor relativo basado en el criterio de optimización o de búsqueda. Típicamente, en un escenario de programación no lineal, esta medida reflejará el valor de la función objetivo del modelo dado.
- *El procedimiento de selección* elige individuos de la población actual de manera aleatoria para formar la siguiente generación. Hay varias alternativas que han sido propuestas pero todas siguen la idea de que los más aptos tengan una gran chance de sobrevivir [BLI95, MIL95, THI96].
- *El procedimiento de cruzamiento* toma dos individuos y los combina a partir de un punto de cruce generando dos nuevos individuos.
- *En la mutación* se modifican genes de individuos de la población en base al factor de mutación predefinido introduciendo de esta manera una cuota de aleatoriedad en la población.
- Uno de los aspectos más desafiantes del uso de algoritmos genéticos es la elección de los *parámetros de configuración*. La teoría provee pocas especificaciones sobre cómo seleccionar adecuadamente estos valores. El tamaño de la población, probablemente el parámetro más importante, refleja el tamaño y la complejidad del problema. De cualquier manera, la solución de compromiso entre el esfuerzo computacional extra y el aumento de tamaño de la población, es una decisión específica hecha en base al problema en cuestión. Otros parámetros importantes son el número máximo de generaciones, la probabilidad de cruce y de mutación, el método de selección y posiblemente una estrategia elitista donde el mejor pasa automáticamente a la próxima generación de la población. Al contrario que con los métodos de optimización tradicionales, los algoritmos genéticos son mejores tratando variables enteras antes que continuas. Esto se debe a la granularidad inherente a las cadenas de genes dentro de la estructura del modelo de los algoritmos genéticos.

2.4.2.3. Representación

En los AGs, las hipótesis generalmente son representadas por cadenas de bits porque pueden ser manipuladas fácilmente por los operadores genéticos (como la mutación y el cruzamiento). Las hipótesis representadas por estas cadenas de bits pueden llegar a ser bastante complejas. Por ejemplo, los conjuntos de sentencias *SI-ENTONCES* pueden ser representados fácilmente de esta manera: eligiendo una codificación que ubique las subcadenas para cada precondition y postcondición de cada regla. Ejemplos del uso de estas representaciones se pueden ver en [HOL86, GRE88 y DEJ93].

Para ver cómo codificar las reglas *SI-ENTONCES* primero consideremos cómo podríamos usar una cadena de bits para describir una restricción en un atributo [MIT97].

En la Figura 2.4 podemos ver dos formas de representar los valores posibles de un atributo.

Univaluado	Multivaluado
00 Soleado 01 Nublado 10 Lluvioso 11 Ventoso	1000 Soleado 0100 Nublado 0010 Lluvioso 0001 Ventoso
Ejemplo: 01 Nublado	Ejemplo: 0101 Nublado y/o Ventoso

Figura 2.4 – Representación binaria de valores de atributos

- Cuando el atributo puede tomar un único valor a la vez, se puede asignar un valor decimal a cada valor posible del mismo y utilizar su representación binaria. Por ejemplo, si son cuatro los valores posibles para un atributo, podemos utilizar una representación de dos bits. Esta forma de representar las restricciones presenta un inconveniente. Si tenemos una cantidad de valores que no es potencia de dos, para poder representarlos debemos tomar una cantidad de bits que en realidad nos va permitir una cantidad de valores codificados mayor a la que necesitamos. Por ejemplo, si sólo son seis los valores a codificar, vamos a necesitar tres bits ($2^3=8$ valores distintos). Si comenzamos a codificar desde el valor cero, permitiremos las codificaciones 110 y 111 que no representan ningún significado útil.
- La segunda manera de codificar el atributo permite que el mismo pueda tener más de un valor simultáneamente, es decir una conjunción o una disyunción de valores. En este caso necesitamos un bit para cada valor posible del atributo y si no está predefinido, uno más para indicar si los valores deben tratarse como una conjunción o una disyunción.

En muchos casos, para valores numéricos, se utiliza la codificación Gray en lugar de codificación binaria. Esta codificación tiene la propiedad de que dos puntos cercanos en el espacio de búsqueda difieren solamente en un bit en la representación [MIC96].

Hay una gran variedad de opciones para representar las soluciones, aplicables según las características del problema: listas ordenadas, listas de tamaño variable, matrices, etc. Por ejemplo en [MIC96] podemos encontrar un trabajo que compara una representación en punto flotante y una representación binaria. En [WRI91] se definen los operadores de mutación y cruzamiento para una representación con vectores de parámetros reales. Sin embargo, las cadenas de bits de tamaño fijo son la representación de soluciones más difundida.

2.4.2.4. Inicialización

- *La inicialización*, primer etapa del proceso evolutivo, se encarga de construir la población inicial, es decir la primera generación.
- La manera más simple de hacerlo es armar *aleatoriamente* el contenido genético de cada individuo;
- Una opción interesante es aplicar alguna técnica conocida para *aprender algunas soluciones interesantes* que luego son incorporadas a la población inicial. De esta manera se puede facilitar la búsqueda y acelerar la convergencia del proceso a las mejores soluciones. Simplemente, si tenemos conocimiento explícito acerca del sistema a optimizar, este puede ser incluido en la población inicial. Por ejemplo, supongamos que estamos hablando de Els, que son codificadas en los cromosomas y hablan de cuál es el período de tiempo que debe existir entre la compra y la venta de acciones de una determinada especie. Podríamos recibir sugerencias de parte de un operador de bolsa que nos diga en base a su experiencia cuáles son los períodos de tiempo que él considera que producen los mejores resultados. Luego de obtenida esta información estamos en condiciones de elaborar las Els que conformarán nuestra población inicial.
- *El tamaño de la población* indica el número de cromosomas en la población. Una gran población permite tener una gran variedad de individuos pero al precio de requerir mayores recursos (más memoria y mayor procesamiento al aumentar la cantidad de evaluaciones de aptitud). Una buena población de cromosomas es la que contiene una selección diversa de soluciones potenciales, produciendo una mejor exploración. Si la población pierde diversidad se dice que tiene convergencia prematura y se realiza poca exploración. Para cromosomas de gran tamaño en problemas de optimización es necesario mantener la diversidad (que también puede ser alcanzada mediante una tasa alta de mutación y cruce uniforme) y por lo tanto una mejor exploración.

2.4.2.5. Evaluación

Para poder comparar las soluciones contenidas en la población es necesario tener alguna medida que nos diga qué tan buena es una de ellas respecto de las otras. Si lo vemos desde el punto de vista de la genética, esta medida está representada por la aptitud del individuo. Indudablemente, este proceso de evaluación es dependiente de la naturaleza del problema y de la representación de las soluciones [HOR95].

2.4.2.6. Operaciones de cruzamiento y mutación

La exploración en el proceso de búsqueda se realiza en base al uso de los operadores de cruzamiento y mutación.

- Para hacer el *cruzamiento* se seleccionan aleatoriamente dos cromosomas (padres). La probabilidad de que esos cromosomas sean cruzados es un parámetro controlado por el usuario (usualmente se le asigna un valor entre 0.6 y 0.9). Por cada pareja, la probabilidad indica que le corresponde cruzarse, entonces se aplica el operador de cruce que intercambia los genes de los padres para producir dos hijos. En caso contrario, los padres pasan directamente a la siguiente generación. Los dos operadores de cruce más comunes son el método de un punto y el de dos puntos. En el de un punto se elige un punto de los cromosomas y se intercambian los genes de la parte superior. En el de dos puntos, como se ve en la Figura 2.5, se seleccionan dos puntos de cruce y se intercambian los genes que están entre los dos puntos.

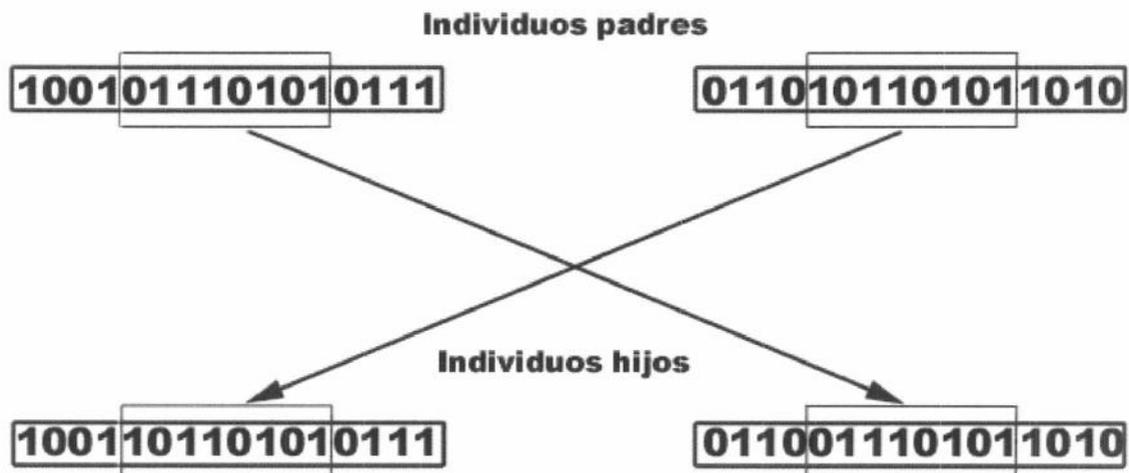


Figura 2.5 – Operación de cruzamiento de dos puntos

- La probabilidad de que ocurra una *mutación* es otro de los parámetros controlados por el usuario y usualmente recibe un valor pequeño (ej. 0.01) para que los cromosomas buenos no sean destruidos. Una mutación

simplemente cambia el valor de algún gen en particular (véase la Figura 2.6). Luego del paso de exploración, la población ya tiene los nuevos cromosomas (hijos) creados.

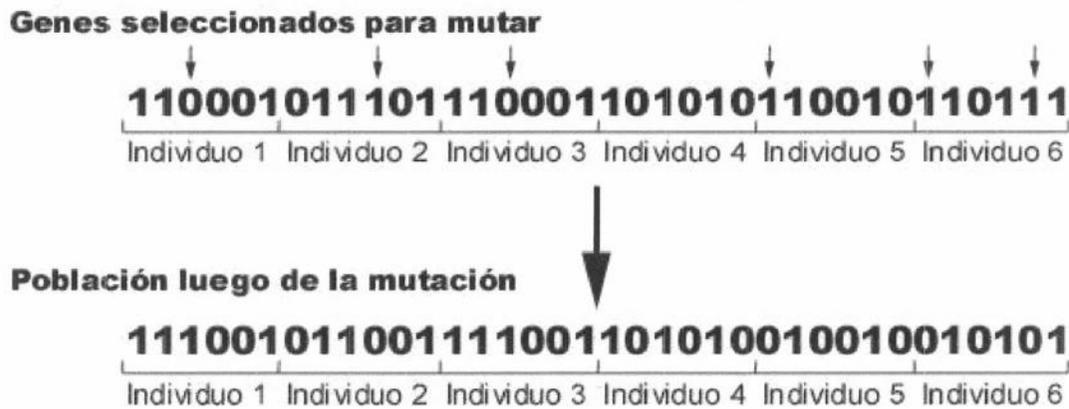


Figura 2.6 – Operación de mutación

La tasa de mutación determina la probabilidad de que se produzca una mutación. La mutación se emplea para dar nueva información a la población y además prevenir que se sature con cromosomas similares (convergencia prematura). Valores grandes de tasa de mutación incrementan la probabilidad de que un buen esquema sea destruido, pero incrementan la diversidad de la población. La mejor tasa de mutación es dependiente de cada caso, pero la experiencia dice que para la mayoría de las aplicaciones se puede tomar un valor entre 0.001 y 0.1.

Algunos investigadores han publicado algunas reglas empíricas para seleccionar la mejor tasa en base a la longitud del cromosoma y al tamaño de la población. DeJong sugirió que la tasa de mutación sea inversamente proporcional al tamaño de la población. Hessner y Manner sugirieron que la tasa óptima de mutación sea aproximadamente $(M * L / 2) - 1$ donde M es el tamaño de la población y L es la longitud del cromosoma. Wright, en [WRI91] define valores para las tasas de mutación y cruzamiento para los casos en los que se utiliza una representación con valores reales.

2.4.3. Aprendizaje de Sistemas Basados en Reglas mediante Algoritmos Genéticos

Los *Sistemas Basados en Reglas* (SBR) son sistemas que utilizan reglas lógicas del tipo *SI-ENTONCES*. Están formados por una Base de Conocimiento (BC), que comprende una Base de Datos (BD) y una Base de Reglas (BR), y un Mecanismo de Inferencia. Existen varias maneras de construir una Base de Reglas para estos sistemas, una de ellas es utilizar AGs.

Si bien los AGs no son algoritmos de aprendizaje, ofrecen una metodología de búsqueda potente e independiente del dominio que puede ser aplicada a tareas de aprendizaje.

Existen dos enfoques de aplicación de los AGs al aprendizaje de reglas, que han sido muy usados a lo largo de los últimos años: Michigan y Pittsburgh. Estos enfoques fueron propuestos en [BOO82, HOL78 y SMI80] respectivamente. La principal diferencia entre ellos es el esquema de representación utilizado.

- En el *enfoque Michigan* cada cromosoma codifica una única regla y la solución final al problema está formada por la última población. Este conjunto de reglas es adaptado a lo largo de las distintas generaciones mediante su interacción con el entorno gracias a la acción de una serie de operadores evolutivos que trabajan a nivel de regla, y de otra serie de módulos como los de asignación de mérito y descubrimiento de reglas. Este tipo de Sistemas Basados en Reglas presentan mecanismos capaces de procesar reglas en paralelo, generar nuevas reglas mediante procesos adaptativos y probar la eficiencia de reglas existentes [MIC96].

Las dos ventajas principales de este enfoque son el menor tiempo de procesamiento y los menores requerimientos de memoria. El inconveniente potencial en este enfoque es que debe diseñarse mecanismos para mantener un juego de reglas diverso y cooperativo dentro de la población, para ocuparse de la asignación de créditos (decidir en cuánto contribuye una regla en la actuación de la población), y resolver conflictos (decidir qué regla recibe mayor prioridad en caso de que más de una cubra un caso).

- En el *enfoque Pittsburgh* los cromosomas corresponden a bases de reglas completas, por lo que la solución al problema de aprendizaje está compuesta finalmente por el mejor cromosoma de la última población. La recompensa o crédito, siguiendo la nomenclatura empleada en el enfoque Michigan, es asociada al conjunto completo de reglas de acuerdo a su interacción con el entorno.

En el caso de emplear un AG para el aprendizaje automático del sistema, el operador de cruce suele ser el encargado de obtener nuevas combinaciones de reglas y el de mutación, de generar reglas distintas a las anteriores. En algunos casos, se trabaja con cromosomas de longitud variable, lo que conlleva la necesidad de emplear operadores genéticos modificados capaces de manejar este tipo de cromosomas.

Este enfoque ofrece las ventajas de que la asignación del crédito está simplificada y la resolución de conflictos es más fácil. Sus inconvenientes son la redundancia y el aumento del tiempo de proceso asociado.

2.4.4. Sistemas Clasificadores

Los Sistemas Clasificadores (SCs) son sistemas de producción que generan poblaciones de reglas que cooperan entre sí para cumplir una determinada tarea en forma automática. Operan típicamente en ambientes que comparten determinadas características, algunas de las cuales se presentan en el problema planteado en esta memoria, como por ejemplo: objetivos implícitos o definidos en forma inexacta, y grandes cantidades de datos irrelevantes o ruidosos.

Los SCs fueron inspirados por el enfoque Michigan cuyas bases fueron propuestas por Holland [HOL75]. Usan AGs como un operador de descubrimiento para generar clasificadores, en contraste con los sistemas expertos tradicionales donde las reglas son creadas artesanalmente por el conocimiento de los expertos. Cada clasificador es una regla *SI-ENTONCES* con una parte de condición y otra de acción, y tiene asociado un peso representado por un valor numérico [COR01].

En la siguiente Sección analizaremos con detalle los elementos que componen un SC.

2.4.4.1. Características de un Sistema Clasificador

Este modelo mantiene la población de clasificadores con asignación de créditos, descubrimiento de reglas y operaciones genéticas aplicadas a cada regla. Hay una gran variedad en lo que respecta a los detalles funcionales y estructurales de este modelo, pero se puede decir que básicamente está compuesto por tres partes (véase la Figura 2.7) [HER97, COR01]:

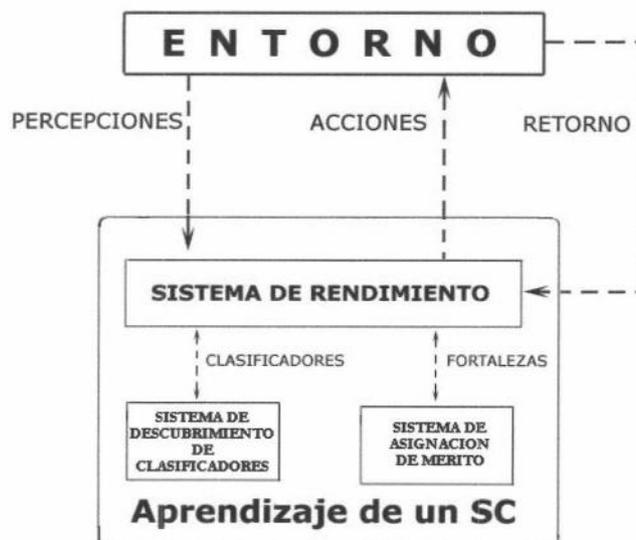


Figura 2.7 – Sistema de Clasificación

- El *sistema de rendimiento (SR)*.

El SR es la parte encargada de interactuar con el entorno y está compuesto por seis elementos básicos:

- Una interface de entrada

Está formada por detectores (al menos uno) que se encargan de captar el estado actual del entorno y codificarlo en mensajes estándar (mensajes de entrada). Normalmente, todos los mensajes tienen la misma longitud y se representan mediante cadenas binarias de longitud fija.

- Una interface de salida

Está formada por efectores (al menos uno) que se encargan de convertir los mensajes de acción o salida en acciones que actúan modificando el estado del entorno.

- Un conjunto de clasificadores

Es un conjunto de clasificadores o reglas que representa el conocimiento que posee el sistema de aprendizaje. Cada clasificador se representa como una cadena formada por símbolos del alfabeto $\{0, 1, \#\}$ con el formato condición/acción de modo que la parte condición especifica los mensajes que satisfacen o activan al clasificador (mensajes externos) y la parte acción especifica los mensajes (mensajes internos) que son enviados cuando el clasificador es satisfecho. Normalmente, en cada ciclo de acción del SC, se produce el disparo en paralelo de un número indeterminado de clasificadores.

- Un sistema de emparejamiento de patrones

Es el encargado de emparejar los mensajes con las condiciones de los clasificadores e identificar qué clasificadores se satisfacen o los cubren.

- Una lista de mensajes

Contiene todos los mensajes que existen en cada momento circulando en el SC, tanto los generados en la interface de entrada como los generados por los clasificadores que se disparan.

- Un resolutor de conflictos

Es el encargado de resolver los conflictos que pueden surgir entre los clasificadores en un ciclo de funcionamiento del SC. Se pueden presentar dos situaciones conflictivas:

- Cuando el número de clasificadores satisfechos es mayor que el número que puede albergar la lista de mensajes.

- Cuando las acciones propuestas por los clasificadores a los efectores, a través de los mensajes de acción, son inconsistentes, por ejemplo si sugieren 'comprar' y a la vez 'vender'.

En ambos casos el sistema RC decide qué clasificadores considera tomando como base alguna medida de utilidad asociada a los mismos, como por ejemplo, la adecuación a la situación y el peso asociado o utilidad pasada.

- El *sistema de asignación de mérito (SAM)*.

La tarea principal del SAM incluye la actividad de aprender mediante la modificación y el ajuste de los parámetros de resolución de conflictos del conjunto de clasificadores, por ejemplo sus pesos o fortalezas [HER97].

- El *sistema de descubrimiento de clasificadores (SDC)*.

El SDC genera nuevos clasificadores individuales a partir de la base global mediante el uso de AGs [COR01].

2.4.4.2. Aprendizaje de un Sistema Clasificador

El proceso aprendizaje en el desarrollo de un SC se divide en dos procesos:

- El *sistema de asignación de mérito*.
- El *sistema de descubrimiento de clasificadores*.

En el primero, el proceso consiste en aprender el uso del conjunto dado de clasificadores mediante las respuestas que se obtienen del entorno. En el segundo, se hace uso de las experiencias pasadas para crear nuevos clasificadores que quizás sean útiles. Para la tarea de descubrimiento de clasificadores en un SC se utilizan AGs. Esto es, el sistema desarrolla su proceso de aprendizaje de nuevos clasificadores por medio de AGs.

Como vimos anteriormente, un AG selecciona los clasificadores con buena aptitud como padres para formar hijos a través de la operación de cruzamiento. La aptitud de los clasificadores es determinada por su utilidad o peso calculado con el SAM en lugar de utilizar una función de aptitud. En una implementación típica de SC la población del AG suele ser una porción del total de los clasificadores (generalmente los de mayor peso). Para preservar el rendimiento del sistema, el AG sólo puede reemplazar un subconjunto del total de clasificadores, es decir que se reemplazan los peores clasificadores.

El SDC entra en funcionamiento cuando el SAM entra en un estado de equilibrio, esto es, un estado en el que cada clasificador refleja realmente su utilidad.

Los únicos requerimientos que hace el AG sobre el SC son que exista una población de reglas, que las reglas se presenten en una sintaxis que permita

manipularlas mediante operadores genéticos, y que esté disponible una medida de aptitud para cada regla. Una medida simple tradicionalmente utilizada como base para resolver conflictos y como medida de aptitud para el AG, es la denominada *peso del clasificador*.

Un ejemplo típico de clasificadores está dado por el enfoque Michigan. Este enfoque se caracteriza porque los cromosomas son reglas individuales y toda la población representa a un conjunto de reglas. La colección de reglas es modificada a través del tiempo por la interacción con el ambiente.

2.4.5. Sistemas Basados en Reglas Difusas

En la actualidad, una de las áreas de aplicación más importantes de la Teoría de Conjuntos Difusos y de la Lógica Difusa, enunciadas por Zadeh en 1965 [ZAD65], es la de los Sistemas Basados en Reglas Difusas (SBRDs). Este tipo de sistemas constituye una extensión de los sistemas basados en reglas de la Lógica Clásica puesto que emplean reglas de tipo *SI-ENTONCES* en las que los antecedentes y consecuentes están compuestos por proposiciones difusas en lugar de proposiciones booleanas clásicas.

En un sentido muy general, un SBRD es un Sistema Basado en Reglas en el que la LD puede ser empleada tanto como herramienta para representar distintas formas de conocimiento sobre el problema a resolver, como para modelar las iteraciones y relaciones existentes entre las variables del mismo. Los SBRDs se han aplicado con éxito a una gran cantidad de problemas reales a lo largo de los últimos años [BAR95, GOO95, HIR93, PED96, WAN94].

El modelado difuso de sistemas se puede considerar como una vía para modelar un sistema haciendo uso de un lenguaje de descripción basado en la LD con predicados difusos [SUG93]. Empleando distintos tipos de SBRDs es posible llevar a cabo distintos tipos de modelado, dependiendo del grado de descripción y precisión que deseemos que presente el modelo obtenido. Estos dos requisitos, el grado en el cual es interpretable el modelo por el ser humano y el grado en que ese modelo aproxima al sistema real, suelen estar enfrentados. Como ya indicaba Zadeh en su *principio de incompatibilidad* [ZAD73], *cuando la complejidad de un problema aumenta, nuestra capacidad para describirlo en términos precisos disminuye*. De este modo, aunque el uso de técnicas basadas en LD, concretamente los SBRDs, nos permiten afrontar el modelado de sistemas que están envueltos en una cierta imprecisión, obteniendo un modelo cualitativo claramente interpretable por el ser humano, muchas veces el rendimiento del modelo obtenido no es el deseado y preferimos perder en la claridad de descripción para ganar en el rendimiento global del modelo. La decisión entre cuán interpretable y cuán preciso debe ser el modelo a obtener suele depender de las necesidades que se tengan para el problema concreto.

La LD posee herramientas que permiten obtener distintos tipos de modelos difusos según deseemos que en los mismos predomine la interpretabilidad o la precisión. De esta forma, cuando se trabaja en este campo, es posible

distinguir dos tipos de modelado: *Modelado Lingüístico* y *Modelado Difuso* [ZWI00]:

- El Modelado Lingüístico se realiza mediante los SBRDs descriptivos. Estos emplean reglas difusas con variables lingüísticas que toman valores en un conjunto de términos con un significado real. El modelo cualitativo finalmente obtenido forma un modelo difuso generalizado que consiste en una serie de descripciones lingüísticas sobre el comportamiento del sistema que está siendo modelado. En este tipo de modelado, la interpretabilidad del modelo es la nota predominante. Como se indica en [SUG93], las ideas básicas de este tipo de modelado ya aparecían en los primeros trabajos de Zadeh [ZAD73].
- El Modelado Difuso, en cambio, se lleva a cabo mediante los SBRDs aproximativos. En este tipo de sistemas, las reglas difusas están compuestas por predicados difusos sin ninguna interpretación lingüística, es decir, las variables que componen las reglas no toman como valores una serie de términos lingüísticos con una semántica asociada en forma de conjunto difuso, sino directamente un conjunto difuso. En este tipo de modelado basado en reglas difusas, se asume que la meta principal es la exactitud en el modelado del comportamiento del sistema real; se hace uso de la potencialidad de los SBRDs como aproximadores universales [BUC93, CAS95, COR96, KOS92, WAN92] y no tanto de su capacidad para representar el conocimiento en forma de reglas lingüísticas. Aún así, el modelo obtenido seguirá presentando un cierto nivel de interpretabilidad que provendrá del hecho de estar compuesto por un SBRD; siempre será posible determinar qué reglas han actuado ante una determinada entrada y, gracias a ello, se podrá estudiar localmente el comportamiento del modelo.

2.4.5.1. Componentes de los Sistemas Basados en Reglas Difusas

Básicamente, todos los tipos de SBRDs están formados al menos por dos componentes principales:

- Una *Base de Conocimiento o de Reglas Difusas*, que contiene las reglas lingüísticas o difusas - según el sistema sea descriptivo o aproximativo - las cuales guían el comportamiento del mismo.
- Un *Sistema de Inferencia*, que emplea estos valores y la información contenida en la base para llevar a cabo dicho proceso.

Además, debido a que los SBRDs pueden tener conjuntos de entrada o de salida difusos en lugar de reales, se puede contar con dos componentes más:

- Una *Interfaz de Fuzzificación*, que se encarga de transformar los datos de entrada precisos en valores manejables en el proceso de razonamiento difuso, es decir, en algún tipo de conjunto difuso. O sea, existe un operador *F* de fuzzificación que hace corresponder cada valor preciso del espacio de

entrada con un conjunto difuso definido en el universo de discurso de dicha entrada.

- Una *Interfaz de Defuzzificación*, que transforma la acción difusa resultante en una acción precisa que constituye la salida global del SBRD.

La *Base de Conocimiento o de Reglas Difusas* es la parte esencial del SBRD debido a que las componentes restantes del sistema se ocupan de interpretar las reglas contenidas en ella y hacerlas manejables en problemas concretos. Tal y como comentábamos en la sección anterior, la componente que almacena estas reglas se denomina Base de Conocimiento (BC) o Base de Reglas Difusas (BRD) según el SBRD sea descriptivo o aproximativo [COR97].

En el primero de los casos, es decir, en los SBRDs descriptivos, la BC está formada a su vez por dos componentes distintos: la Base de Reglas Lingüísticas y la Base de Datos:

- La *Base de Reglas Lingüísticas (BRL)* está formada por un conjunto de reglas lingüísticas de tipo *SI-ENTONCES* que, en el caso de SBRDs con múltiples entradas y una única salida, presentan la siguiente estructura:

Si X_1 es A_{11} y ... y X_n es A_{1n} entonces Y es B_1 ,
 además
 Si X_1 es A_{21} y ... y X_n es A_{2n} entonces Y es B_2 ,
 además
 ...
 además
 Si X_1 es A_{m1} y ... y X_n es A_{mn} entonces Y es B_m ,

donde X_i e Y son variables lingüísticas de entrada y salida respectivamente, y los A_{ij} y B_i son etiquetas lingüísticas asociadas con conjuntos difusos que determinan su semántica en cada una de las reglas. La BRL está compuesta por una serie de reglas de este tipo unidas por el operador *además*, lo que indica que todas ellas pueden dispararse ante una entrada concreta.

La estructura de una regla lingüística puede ser más general si para relacionar las variables de entrada en el antecedente se emplea otro conectivo, en lugar del *y*, pero en trabajos como [WAN94] se demuestra que la estructura de la regla mostrada es lo suficientemente general como para incluir otras. Debido a este hecho y a su simplicidad, este tipo de reglas son las más empleadas en la literatura especializada.

- La *Base de Datos (BD)* contiene la definición de los conjuntos difusos asociados a los términos lingüísticos empleados en las reglas de la BRL. Además contiene los valores de los factores de escala necesarios para efectuar las transformaciones entre los universos de discurso de los conjuntos difusos y los que definen las variables de entrada y salida del sistema.

En los sistemas aproximativos, sin embargo, la BD no es necesaria puesto que las variables que se emplean en las reglas no son lingüísticas sino difusas. La razón es obvia puesto que, al tomar cada variable como valor un conjunto difuso distinto para cada regla y no una etiqueta lingüística, no tiene sentido establecer una relación entre etiquetas y conjuntos difusos. En este tipo de sistemas, la BC queda reducida a una Base de Reglas Difusas (BRD) compuesta por un conjunto de reglas difusas aproximativas conectadas entre sí mediante el operador *además* [COR97].

El *Sistema de Inferencia* es la componente encargada de llevar a cabo el proceso de inferencia difuso. Para ello hace uso de los principios de la Lógica Difusa para establecer una aplicación entre conjuntos difusos definidos en $U = U_1 \times U_2 \dots \times U_n$ y conjuntos difusos definidos en V (donde U_1, \dots, U_n y V son los dominios en los que están definidas las variables de entrada X_1, \dots, X_n y la salida Y , respectivamente)

El proceso de inferencia difuso está basado en la aplicación del Modus Ponens Generalizado, extensión del Modus Ponens de la Lógica Clásica, propuesto por Zadeh [ZAD73] según la siguiente expresión:

$$\frac{\begin{array}{l} \text{Si } X \text{ es } A \text{ entonces } Y \text{ es } B \\ X \text{ es } A' \end{array}}{Y \text{ es } B'}$$

Para llevar a la práctica esta expresión, primero es necesario interpretar el tipo de regla que emplea el SBRD. Una regla con la forma *Si X es A entonces Y es B*, puede ser representada como una relación difusa entre A y B definida entre $U \times V$. Dicha relación se expresa mediante el conjunto difuso R cuya función de pertenencia $\mu_R(X, Y)$ presenta la siguiente forma:

$$\mu_R(X, Y) = I(\mu_A(X), \mu_B(Y)), \quad \forall X \in U, Y \in V$$

donde $\mu_A(X)$ y $\mu_B(Y)$ son funciones de pertenencia de los conjuntos difusos A y B respectivamente, e I es un operador de implicación difuso que modela la relación difusa existente.

Dada una relación R, la función de pertenencia del conjunto difuso B' , resultante de la aplicación del Modus Ponens Generalizado, se obtiene a partir de la Regla Composicional de la Inferencia introducida por Zadeh [ZAD73] del siguiente modo: "Si R es una relación difusa definida de U a V y A' es un conjunto difuso definido en U, entonces el conjunto difuso B' , inducido por A' viene dado por la composición de R y A' , esto es:

$$B' = A' \circ R$$

donde A' juega el papel de una relación unaria" [DRI93]

2.4.5.2. Construcción de un Sistema Basado en Reglas Difusas

El buen comportamiento de un SBRD depende directamente de dos factores: la forma en que realiza el proceso de inferencia y la composición de la BC (BR y BD) que maneja. Por lo tanto, el proceso de diseño de los SBRDs engloba las siguientes tareas principales:

- Diseño del *Mecanismo de Inferencia*, es decir, la elección de los distintos operadores difusos que se emplearán para realizar el proceso de inferencia. Entre las principales tareas de diseño para el mecanismo de inferencia se encuentran:
 - Definir la implicación difusa existente en las reglas lingüísticas o difusas del tipo *SI-ENTONCES* contenidas en la base de reglas difusas, o sea, elegir el operador difuso que se empleará para modelar la implicación
 - Definir el conectivo *y*, o sea, definir el operador de conjunción en caso de que la base presente más de una variable de entrada
 - Definir el operador de composición. Este operador se modela habitualmente empleando una t-norma y las elecciones más habituales son el mínimo o el producto, los cuales están descritos en [LEE90], donde también se analizan sus propiedades en detalle.
 - Definir el operador de agregación cuya función será la de agregar todos los conjuntos difusos individuales resultantes de la inferencia en un único conjunto difuso global. Para este propósito se usa normalmente la t-norma o t-conorma del mínimo o máximo, debido a su sencillez, pero en [BD95] se propone un análisis de operadores de agregación más sofisticados.
- Obtención de una BRDs que contenga información adecuada con respecto al problema que se pretende resolver.

Las tareas principales son las siguientes:

- Selección de las variables relevantes de entrada y salida del sistema
- Si se emplea un SBRD con matices descriptivos, definición de la estructura de la BD que contendrá la semántica de los términos que pueden tomar como valor las variables lingüísticas de entrada y salida. Esto conlleva la ejecución de nuevas subtareas:
 - Definición de los factores de escala.
 - Elección de los conjuntos posibles de términos para cada variable lingüística los que permiten determinar la granularidad deseada en el sistema.
 - Elección del tipo de función de pertenencia a emplear: triangular, trapezoidal, gaussiana o exponencial, principalmente [DR193]. Las dos últimas presentan la ventaja de proporcionar una transición más suave, mientras que las dos primeras la de su simplicidad a la hora de efectuar cálculos computacionales.

- Definición de la función de pertenencia del conjunto difuso concreto asociado a cada etiqueta lingüística.
- Derivación de las reglas lingüísticas que compondrán la base de reglas difusas del sistema. Para ello será necesario determinar el número de éstas así como su composición, mediante la definición del antecedente y el consecuente.
- Obtención de la BD de un SBRD

Una manera para crear la BD de un SBRD [WAN94] es la derivación a partir de los expertos. En este método, la composición de la BD se efectúa empleando la información experta disponible. Los expertos humanos especifican las etiquetas asociadas a cada variable lingüística y la semántica asociada a cada etiqueta. Este método es uno de los más sencillos de aplicar en el caso de que los expertos sean capaces de poner su conocimiento en forma de términos lingüísticos. Aunque esta vía de definición es la ideal en algunos problemas, en la mayoría de los casos prácticos el experto no es capaz de expresar su conocimiento sobre el problema en forma de reglas lingüísticas o, simplemente, no existe un experto que pueda aportar información sobre el problema que tratamos de resolver.

Este último problema se resuelve generalmente definiendo una partición difusa primaria de cada variable mediante un proceso de normalización [DRI93, HAR93, LEE90]. Este proceso consiste en discretizar el dominio de la variable, particionándolo en un número de intervalos igual al número de etiquetas lingüísticas que se consideren, y asociando a cada intervalo un nombre de etiqueta y un conjunto difuso que defina la semántica de ésta. Al no existir conocimiento disponible sobre la forma que deberían presentar dichos conjuntos, lo que se suele hacer es definir una serie de particiones difusas uniformes en las que todos los conjuntos difusos son simétricos y presentan la misma forma.

Si bien el uso de equiparticiones para definir las BD está muy difundido y es útil en la mayoría de los casos, suele presentar una serie de problemas que se mencionan a continuación.

La falta de precisión de los Modelos Lingüísticos se debe a ciertos problemas relacionados con la estructura de la regla lingüística, los cuales son a su vez consecuencia de la inflexibilidad del concepto de variable lingüística [ZAD75]. Algunos de estos problemas son [ALC99, BAS94, CAR96]:

- Falta flexibilidad en los SBRDs debido al rígido particionamiento de los espacios de entrada-salida.
- Los espacios de entrada son complejos de particionar cuando hay dependencia de variables.
- El particionamiento homogéneo de los espacios de entrada-salida, cuando la correspondencia entre entrada-salida varía en complejidad

con el espacio, es ineficiente y no puede hacerse escalable a espacios de grandes dimensiones.

- La obtención de un SBRD preciso requiere de una suma considerable de granularidad, lo que provoca el aumento significativo del número de reglas, hecho que produce la pérdida de la capacidad de ser interpretadas por un ser humano.

En resumen, se puede decir que esta manera de definir la semántica de las variables lingüísticas no siempre conduce a un buen comportamiento del SBRD finalmente obtenido [VIL94, LEE90]. Para resolver los problemas comentados anteriormente una solución que se plantea se basa en la derivación de la BD del SBRD a partir de métodos de aprendizaje automático basados en la información numérica existente.

2.4.6. Sistemas Difusos Genéticos

La idea de un Sistema Difuso Genético es incorporar técnicas genéticas en el proceso de diseño de un SBRD para crear o modificar automáticamente su Base de Conocimiento (o una parte de ella). Esta tarea usualmente involucra un proceso de aprendizaje y en consecuencia este proceso juega un rol central en los Sistemas Difusos Genéticos (SDGs). Como en todo proceso donde participa un AG, el objetivo de este proceso de aprendizaje es la optimización de una función que representa o describe el comportamiento del sistema. En nuestro caso, en el proceso de aprendizaje se buscará obtener EIs cercanas a las óptimas.

Podemos distinguir tres grupos diferentes de SDGs de acuerdo a los componentes de la BC que se incluyen en el proceso de aprendizaje genético:

- optimización genética de las funciones de pertenencia a los conjuntos difusos.

Se han propuesto varios métodos para llevar a cabo la definición de la BD empleando AGs. En todos ellos, cada cromosoma manejado en el proceso evolutivo representa una definición diferente del conjunto completo de funciones de pertenencia consideradas en las reglas difusas de la base. Existen dos posibilidades, según la naturaleza del SBRD sea descriptiva o aproximativa: o bien codificar la partición difusa de cada variable lingüística manteniendo el nivel de descripción del sistema, o codificar las funciones de pertenencia empleadas en cada regla difusa, ajustando los parámetros de las mismas de un modo local para cada conjunto difuso, con lo que se obtiene un SBRD aproximativo, aún en el caso en el que el sistema inicial fuese descriptivo [COR97].

- aprendizaje genético de la BR.

Todos los enfoques existentes en este grupo suponen la existencia de una definición previa de la BD, es decir, de un conjunto de funciones de pertenencia que definen la semántica de los términos lingüísticos

existentes. Esta definición puede haber sido obtenida a partir de conocimiento experto o mediante una equipartición difusa de los espacios de entrada y salida. De este modo, la tarea del AG en estos procesos automáticos de diseño es la de generar una base de reglas difusas adecuada para el problema a resolver. Los primeros enfoques que se realizaron se limitaban a codificar la base de reglas en forma de tabla de decisión en el cromosoma, por lo que el proceso evolutivo sólo se llevaba a cabo sobre los consecuentes de las reglas, siguiendo un enfoque Pittsburgh. Posteriormente se desarrollaron otros SBRD evolutivos más refinados. En [BON93], Bonarini presenta un proceso evolutivo de diseño basado en una variante del enfoque Michigan para el aprendizaje de la BRL, por lo que no codifica tablas de decisión, sino reglas individuales en cada individuo de la población.

- aprendizaje genético de la BC completa (BR y BD)

Este último grupo ha sido el más prolífico en el número de contribuciones desarrolladas en los últimos años. Podemos encontrar aproximaciones muy diversas para la definición completa de la base de reglas difusas. Dentro de este gran grupo de trabajos, hay procesos que presentan cromosomas de longitud variable, algunos que hacen uso de una gran cantidad de conocimiento experto con objeto de mejorar el proceso de aprendizaje, mientras que otros fijan el número de reglas a priori [COR97].

Como se verá en el Capítulo 4, en este trabajo se utilizará un AG para el proceso de aprendizaje de la BR de un SBRD.

Una variante de los SBRD son los Sistemas de Clasificación Basados en Reglas Difusas. Dado que nuestro problema es un problema de clasificación vamos a estudiar la posibilidad de utilizar esta clase de sistemas en las experiencias mencionadas en la Sección 1.5.3.

2.4.7. Sistemas de Clasificación Basados en Reglas Difusas

El diseño de un Sistema de Clasificación (SC) consiste en el establecimiento de una regla de decisión que permita determinar la clase a la que pertenece un nuevo ejemplo dentro de un conjunto de clases conocido. Cuando este proceso de extracción del conocimiento utiliza como herramienta de representación las reglas difusas, el Sistema de Clasificación obtenido se denomina *Sistema de Clasificación Basado en Reglas Difusas* (SCBRD) [JES99].

De acuerdo a lo visto en la Sección anterior, se puede decir que un SCBRD puede ser aprendido a partir de un SBRD en base a un SDG.

En un SCBRD se pueden usar distintos tipos de Reglas Difusas (RD):

- Tipo I: RD con un identificador de clase en el consecuente

- Tipo II: RD con un identificador de clase y un grado de certeza en el consecuente
- Tipo III: RD con información en el consecuente sobre el grado de certeza para la clasificación en cada una de las clases

2.4.7.1. Componentes de un SCBRD

En un SCBRD se distinguen dos componentes principales (véase Figura 2.8):

- La *Base de Conocimiento* (BC), formada por:
 - La *Base de Datos* (BD): Contiene la definición de los conjuntos difusos utilizados en las reglas difusas, es decir, las particiones difusas.
 - La *Base de Reglas* (BR): Conjunto de reglas difusas de clasificación. Su estructura es:

R_k : Si X_1 es A_1^k y y X_N es A_N^k entonces Y es C_j

donde X_1, \dots, X_N son las variables consideradas en el sistema de clasificación, A_1^k, \dots, A_N^k son las etiquetas utilizadas para discretizar los dominios continuos de las variables, e Y es la variable que indica la clase C_j a la cual pertenece el patrón.

- El *Método de Razonamiento Difuso* (MRD):
 - Es el procedimiento de inferencia que combina la información brindada por las reglas difusas compatibles con el ejemplo a clasificar para poder predecir su clase. El método más usado debido a su sencillez es el del máximo (llamado MRD clásico o regla ganadora) que clasifica en la regla más compatible con el ejemplo [JES99, COR99]. Existen otras funciones de agregación más sofisticadas, en [BAR95] se presenta un análisis de sus propiedades y un estudio comparativo de su comportamiento.

En la Figura 2.8 se pueden observar los componentes de un SCBRD y los procesos de aprendizaje e inferencia o clasificación. Como vimos en la Sección 2.4.7 este proceso puede aprender la BRD, la BD o la BC completa. Cuando la etapa de diseño del SCBRD ha finalizado, ya se lo puede utilizar en el *proceso de clasificación* para clasificar nuevos ejemplos.

2.4.7.2. Zona de actuación de las reglas difusas

Un ejemplo de una BR completa para un problema de clasificación con dos variables para las que se utilizan dos y tres etiquetas respectivamente, sería el siguiente:

R1: Si X_1 es Bajo y X_2 es Alto ENTONCES C_1

R2: Si X_1 es Bajo y X_2 es Medio ENTONCES C_1

R3: Si X1 es Bajo y X2 es Bajo ENTONCES C_2
 R4: Si X1 es Alto y X2 es Alto ENTONCES C_2
 R5: Si X1 es Alto y X2 es Medio ENTONCES C_1
 R6: Si X1 es Alto y X2 es Bajo ENTONCES C_1

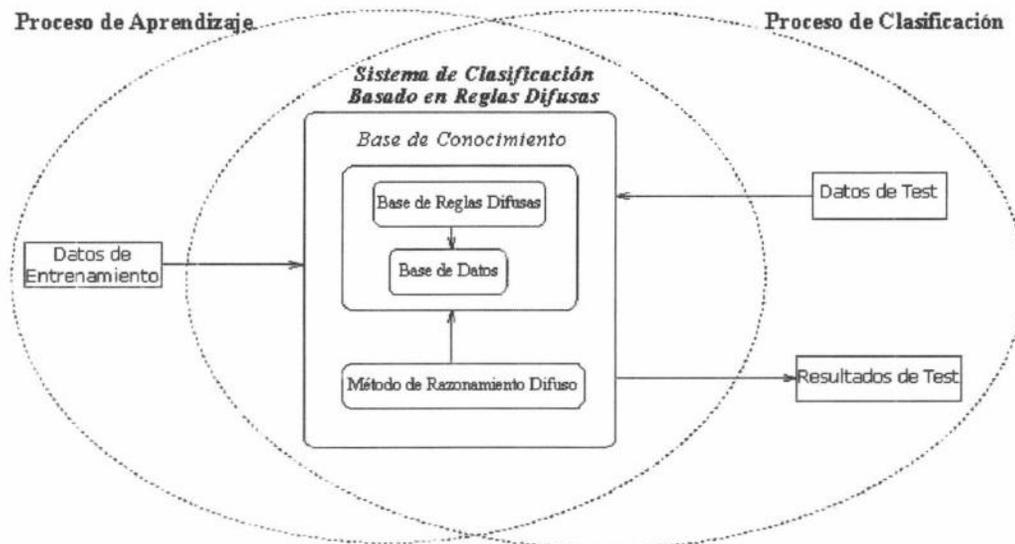


Figura 2.8 – Sistema de Clasificación Basado en Reglas Difusas

Si con esta BR se utilizan conjuntos difusos normalizados y con funciones de pertenencia triangulares, la t-norma mínimo para el cálculo del grado de compatibilidad de una regla con un ejemplo y el MRD de la regla con máximo grado de compatibilidad, se verifica que el grado de actuación de cada regla es el representado en la Figura 2.9

Aquí se puede observar una partición del espacio de patrones equivalente a la que se obtendría con un conjunto de reglas intervalares [JES99]. O sea, cada regla difusa representa un rectángulo del espacio y la región de decisión de cada clase es un subconjunto del conjunto de rectángulos determinados por el producto cartesiano de los intervalos que discretizan las variables implicadas. Esta afirmación no es válida en SCBRDs en los que la BR no sea completa, o se use una t-norma distinta al mínimo para el cálculo de grado de compatibilidad o un MRD distinto al máximo.

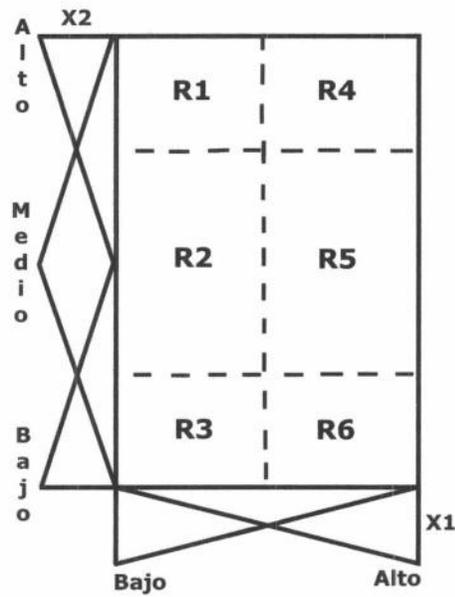


Figura 2.9 – Zonas de actuación para una BR completa

Como ejemplo veamos la figura 2.10. En este caso, las reglas serían:

R1: Si X1 es Bajo y X2 es Alto ENTONCES C_1

R2: Si X1 es Alto y X2 es Alto ENTONCES C_2

R3: Si X2 es Bajo ENTONCES C_1

Aquí podemos ver la diferencia con el caso anterior (que se podía pensar como casos intervalares). Ahora con las reglas difusas, obtenemos regiones de clasificación no rectangulares.

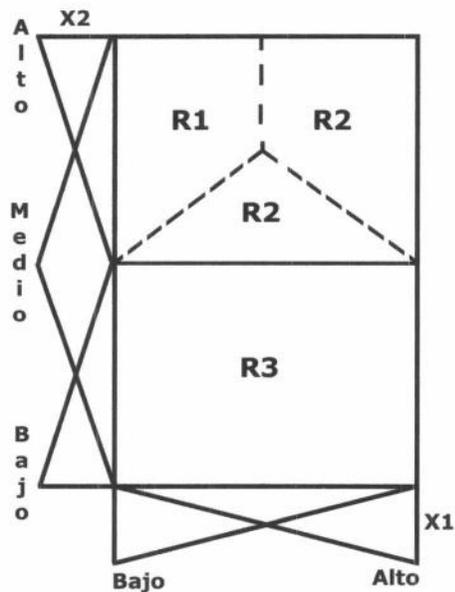


Figura 2.10 – Zonas de actuación para una BR incompleta

Al usar la t-norma mínimo, la zona triangular central es influenciada por ambas reglas (R1 y R2), es decir que un ejemplo de esa zona será clasificado si ambas reglas tienen en el consecuente la misma clase, y quedará sin clasificar en caso contrario.

2.4.7.3. Reglas difusas de clasificación con grados de certeza

La incorporación en una regla difusa de un grado de certeza es una manera de ajustar el conocimiento que representa la regla sobre la zona del espacio de ejemplos con la que se identifica.

Las reglas difusas tienen la siguiente estructura:

$$\text{Si } X_1 \text{ es } A_1^k \text{ y } \dots \text{ y } X_N \text{ es } A_N^k \text{ entonces } Y \text{ es } C_j \text{ con grado } r^k$$

donde X_i es una variable lingüística, A_i es un término lingüístico y r^k es el grado de certeza asociado a la clasificación en la clase C_j para los ejemplos pertenecientes al subespacio difuso delimitado por el antecedente de la regla. El grado de certeza puede considerarse como un peso asociado al grado de compatibilidad del ejemplo con la regla.

El proceso de clasificación con reglas de este tipo, utiliza el operador producto para combinar el grado de compatibilidad de la regla con un ejemplo y el grado de certeza de la regla. De esta forma se obtiene el grado de disparo de la regla [JES99]. Otras maneras de obtener el valor del grado de certeza fueron descritas en [ISH92, ISH95]. En particular, en este trabajo se utilizará el MRD clásico que clasifica con la regla para la cual el grado de certeza es mayor.

Si incluimos grados de certeza en el ejemplo de BR incompleta quedaría:

R1: Si X1 es Bajo y X2 es Alto ENTONCES C_1, gc = 0.5
 R2: Si X1 es Alto y X2 es Alto ENTONCES C_2, gc = 0.7
 R3: Si X2 es Bajo ENTONCES C_1, gc = 0.9

En la figura 2.11 observamos que se modifica la influencia de las reglas difusas, eliminando o reduciendo indecisión en el proceso de clasificación.

En definitiva, cualquier proceso de aprendizaje de SCBRD que incluya grados de certeza en su definición tiene una mayor flexibilidad para determinar las regiones de decisión en el espacio de patrones (o sea, una capacidad mayor de predicción del SCBRD resultante).

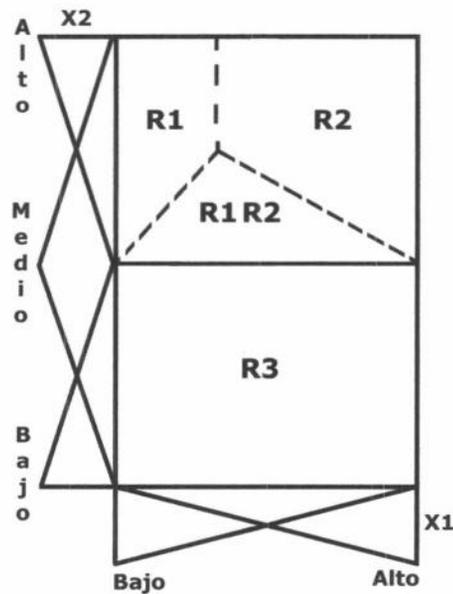


Figura 2.11 – Efecto de la inclusión de los grados de certeza

2.4.8. Aprendizaje de la Base de Datos de un SCBRD por medio de técnicas de Clustering

Como vimos en la Sección 2.4.5.2, la construcción de la BD de un SCBRD se puede realizar principalmente de dos maneras: con la asistencia de un experto que nos ayude a definir las variables lingüísticas y los conjuntos difusos asociados a los términos lingüísticos, o con la utilización de alguna técnica de aprendizaje. La manera más simple de construir la BD cuando no contamos con la información de un experto es realizar una equipartición de los conjuntos asociados a las variables lingüísticas. Otra forma es construir la BD con ayuda de algún método de aprendizaje. Entre los métodos empleados para aprender automáticamente la BD de un SCBRD se encuentran las técnicas de Clustering. La Figura 2.12 muestra un ejemplo de una BD aprendida mediante técnicas de Clustering a partir de una serie de datos históricos.

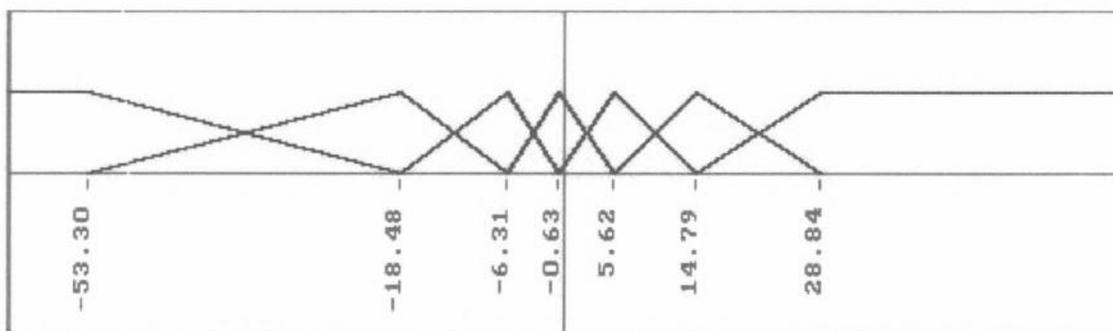


Figura 2.12 Base de Datos aprendida con técnicas de Clustering

Clustering es el nombre genérico usado para definir una variedad de procedimientos diseñados con el fin de encontrar agrupamientos naturales o *clusters* en series de datos, en base a la similitud percibida o medida entre los datos [JAI98, JAI00]

Hacer Clustering de un conjunto de datos constituye un problema difícil de tratar ya que estos pueden tener clusters de diferentes formas o tamaños (véase la Figura 2.13)

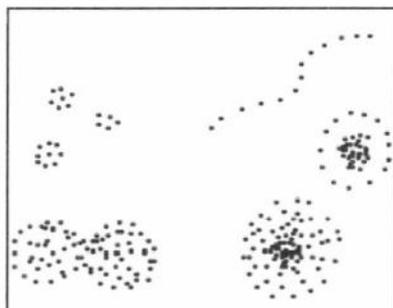


Figura 2.13 Diferentes formas de Clusters

Entre las definiciones funcionales que se han dado para un cluster se incluyen [JAI00]:

- Los datos pertenecientes a un cluster son más parecidos entre sí que los datos pertenecientes a clusters diferentes.
- Un cluster consiste en una densidad relativamente alta de puntos, y la separación entre clusters está dada por una densidad relativamente baja de puntos.

Aún contando con estas definiciones funcionales, un desafío importante es seleccionar una medida de similitud apropiada para definir los clusters. Esta medida depende en general, tanto de los datos como del contexto.

El análisis de clusters es una técnica muy importante y útil. La velocidad, confiabilidad y consistencia con la cual un algoritmo de clustering puede organizar grandes cantidades de información ha sido la razón para utilizar esta técnica en aplicaciones como data mining [JUD98], segmentación de imágenes [FRI99], codificación y compresión de señales [ABB94], machine learning [CAP96] entre otras. Como consecuencia, se han propuesto cientos de algoritmos de clustering. No obstante, la mayoría de estos algoritmos se basan en una de las siguientes técnicas:

- *Clustering por Particiones o Prototipos*: Intenta obtener la partición que minimice la dispersión dentro de un cluster o maximice la dispersión entre clusters. Esta técnica se detalla en la Sección 2.4.9.1.

- *Clustering Jerárquico*: Organiza datos en una secuencia anidada de clusters que luego puede ser mostrada en forma de árbol. Para producir la estructura jerárquica, existen básicamente dos métodos:
 - El primero y más comúnmente utilizado se denomina *aglomerativo*. Comienza con clusters de un solo dato cada uno y posteriormente los combina iterativamente hasta llegar a tener un único cluster del que forman parte todos los datos del conjunto de datos.
 - El segundo método, llamado *derivativo*, comienza con un único cluster que incluye a todos los datos. Luego divide los clusters iterativamente hasta obtener tantos clusters como datos haya en el conjunto.

La mayoría de las técnicas de *clustering por particiones* implícitamente asumen que los datos tienen valores continuos. En cambio, los métodos de *clustering jerárquico* se aplican normalmente cuando no es éste el caso [JAI00].

En virtud de estas características restringimos nuestro trabajo a las técnicas de *clustering por particiones*.

2.4.8.1. Clustering por Particiones o Prototipos

Formalmente, se puede definir el *clustering por particiones* de la siguiente manera: Dados n datos en un espacio d -dimensional, el *clustering por particiones* consiste en determinar una partición de los datos en K clusters, tal que los datos en un cluster son más similares entre sí que los datos pertenecientes a clusters diferentes. El valor de K puede o no haber sido especificado con anterioridad. Asimismo para la definición de los clusters es necesario adoptar un criterio de similitud. Uno de los criterios más comúnmente utilizado en el *clustering por particiones* es el *criterio de Error Cuadrático* entre el posible prototipo y los datos.

El objetivo general de este criterio es obtener una partición que, para un número de clusters fijo, minimice el error cuadrado. Supongamos que el conjunto de datos tiene n datos en d dimensiones y ha sido particionado de alguna manera en K clusters $\{C_1, C_2, \dots, C_k\}$ tal que el cluster C_k tiene n_k datos y cada dato está exactamente en un cluster, de modo que:

$$\sum_{k=1}^K n_k = n$$

El centro del cluster C_k al que notamos $m^{(k)}$, se define como el *centroide* del cluster:

$$m^{(k)} = \left(\frac{1}{n_k} \right) \sum_{i=1}^{n_k} x_i^{(k)}$$

donde $x_i^{(k)}$ es el i -ésimo dato perteneciente al cluster C_k . El error cuadrado para el cluster C_k es la suma de las distancias cuadradas entre cada dato en C_k y su centro $m^{(k)}$:

$$e_k^2 = \sum_{i=1}^{n_k} (x_i^{(k)} - m^{(k)})^T (x_i^{(k)} - m^{(k)})$$

El error cuadrado para el clustering incluyendo los K clusters es la suma de los errores cuadrados correspondientes a cada cluster:

$$E_k^2 = \sum_{k=1}^K e_k^2$$

El objetivo de un método de clustering de error cuadrado es encontrar una partición con K clusters que minimice

$$E_k^2$$

para un K fijo. La partición resultante se conoce también como *partición de varianza mínima* [JAI98].

2.4.8.2. Algoritmo para el método de Clustering por Particiones

El siguiente es un algoritmo general, iterativo, para el método de *clustering por particiones* [JAI00]:

- *Paso 1:* Seleccionar una partición inicial con K clusters con algún criterio (que bien podría ser aleatorio). Repetir los pasos 2 a 5 hasta que la pertenencia de los datos a los clusters se estabilice.
- *Paso 2:* Generar una nueva partición asignando cada dato al centro de cluster más cercano, utilizando algún criterio definido, como por ejemplo el *criterio de Error Cuadrático*, explicado en la sección anterior.
- *Paso 3:* Computar los centros de los nuevos clusters (como se explicó en la sección anterior).
- *Paso 4:* Repetir los pasos 2 y 3 hasta encontrar un valor óptimo de la función de criterio. *Por ejemplo: En el caso del criterio de Error Cuadrático el valor óptimo es el que minimiza el error cuadrado.*
Para garantizar que se ha encontrado la solución óptima habría que examinar todas las posibles particiones de los n datos en K clusters (para un K dado), lo cual no es computacionalmente viable. Por lo tanto, si bien no hay garantía de obtener la mejor solución, es necesario proponer criterios para detener la búsqueda de los clusters en algún punto.

El algoritmo anterior es conocido como *algoritmo K-means*. Los detalles de los pasos del algoritmo deben ser provistos como parámetros o estar implícitos en

el programa que lo resuelve. En cualquiera de los casos, estos detalles son cruciales para el éxito del programa.

Sin una correcta elección de los siguientes ítems, el algoritmo de clustering puede fracasar completamente [BAC95]:

- el número K ,
- la partición inicial,
- el criterio de similitud,
- la puesta a punto del número de clusters, y
- el criterio que indica cuándo terminar la iteración.

2.5. Observaciones finales

En el primer Capítulo hemos visto que los analistas técnicos se ocupan de descubrir Els. Se puede decir que estas Els se comportan como clasificadores ya que están formadas por reglas *SI-ENTONCES* aprendidas a partir de la experiencia, que luego son utilizadas para clasificar nuevos casos.

En este Capítulo estudiamos varias técnicas computacionales utilizadas para tareas de aprendizaje. Por un lado, se han presentado varios ejemplos donde algunas de estas técnicas han sido empleadas para el tratamiento de algunos de los problemas del área financiera.

Si bien estas técnicas han demostrado que con ellas se obtienen buenos resultados, se presentan algunos inconvenientes cuando la información que generan debe ser utilizada por un experto. El problema principal que se presenta es que generalmente el experto sólo acepta Els que pueda comprender. Eso significa que las Els deben ser suficientemente interpretables para facilitar la comprensión y utilización por parte del experto, pero todo esto sin perder precisión en los resultados. Otro problema no menos importante es la falta de información supervisada que permita obtener un conocimiento cierto sobre las estrategias identificadas en base a los datos históricos. Finalmente, existe una gran dificultad en la representación del problema, debido a que gran parte de la información manipulada es incierta y los enunciados que describen las estrategias son de carácter impreciso.

Algunas de las técnicas de AA estudiadas pueden ser complementadas entre sí permitiendo la formación de técnicas híbridas. En los siguientes Capítulos de nuestra tesis implementaremos este tipo de hibridaciones con el propósito de solucionar algunas de los problemas anteriormente planteados.

En lo sucesivo consideraremos hibridaciones de Algoritmos Evolutivos, Sistemas Basados en Reglas Difusas y Sistemas Clasificadores donde trataremos al aprendizaje o identificación de Els como una tarea no estrictamente supervisada ya que sólo se cuenta con información histórica de variables de mercado. Estas Els deberán ser precisas en sus resultados y lo suficientemente interpretables como para facilitar su comprensión y utilización por los expertos. En este sentido, las estrategias utilizadas en las experiencias

van a estar determinadas por la tendencia observada en la evolución de la cotización.

Capítulo 3

Utilización de Algoritmos Genéticos para el Aprendizaje de Estrategias de Inversión que Generen Ganancias

3.1. Introducción

Tal como se ha mencionado en los Capítulos anteriores, desde hace muchos años se han venido realizando diferentes estudios que intentan esclarecer y buscar soluciones aceptables para la problemática de predecir el comportamiento del precio de los papeles que cotizan en bolsa.

En este Capítulo propondremos una metodología para el aprendizaje de clasificadores que describen Els que generan ganancias que solucione algunos de los problemas de las técnicas tradicionales observadas en la Sección 1.4 y de las técnicas estudiadas en la Sección 2.3 cuando se utilizan individualmente. Para ello emplearemos AGs y un mecanismo de aprendizaje por refuerzo en base al cálculo de ganancias obtenidas, que nos permita aprender la mejor estrategia o bien un conjunto de estrategias que al ser aplicadas verifiquen cumplimentar el mencionado objetivo. Definiremos un marco de trabajo con diferentes tipos de Els sobre las que estarán basadas las experiencias presentadas y analizadas a lo largo de esta tesis.

Para ello, este Capítulo está organizado de la siguiente manera. En la Sección 3.2, analizaremos brevemente los diferentes tipos de problemas que surgen de la utilización de las técnicas tradicionales y de las técnicas de Aprendizaje Automático (AA). Más adelante, plantearemos la posibilidad de construir metodologías híbridas que hagan uso algunas de estas técnicas para aplicarlas en los subproblemas donde se aproveche lo mejor de ellas. En la Sección 3.3, presentaremos una metodología de aprendizaje de Els que implementa un Sistema Clasificador (SC) que utiliza un Algoritmo Genético (AG) para el aprendizaje de los clasificadores (véase la Sección 2.4.4.2). En las Secciones 3.4 y 3.5 se describen los grupos de experiencias realizadas con el SC y se analizan los resultados respectivamente y, finalmente, en la Sección 3.6 se vierten algunos comentarios en carácter de conclusiones.

3.2. Problemática

Desde hace muchos años los inversores han estado utilizando dos fuentes principales de información para tomar sus decisiones: el Análisis Técnico y el Análisis Fundamental. Si bien están ampliamente difundidas en el ámbito financiero, la utilización de estas técnicas presenta algunas dificultades.

El AF normalmente requiere mucha mayor interpretación por nuestra parte que el AT y por ello contiene un mayor grado de subjetividad. Además, los datos

correspondientes a las variables que utilizan los analistas fundamentales no siempre se encuentran disponibles al público en general.

Como se mencionó en la Sección 1.3.3, el AT se basa en el reconocimiento de figuras en gráficos de precios y en el análisis de algunos indicadores que estudian la evolución de las cotizaciones.

La tarea de identificar figuras en los gráficos de precios tienen un fuerte componente subjetivo debido a que los analistas técnicos deben poseer mucha experiencia para reconocer que una secuencia de cotizaciones está describiendo una formación determinada.

Por otra parte, los indicadores utilizados por los expertos requieren que el inversor posea determinados conocimientos matemáticos y financieros para interpretar las señales de compra o de venta originadas por los mismos.

En lo que respecta a la aplicación de algunas técnicas computacionales al problema de identificación de Els, cabe resaltar los inconvenientes mencionados en la Sección 2.3:

- Las Redes Neuronales carecen de capacidad explicativa, presentan dificultades para incluir conocimiento estructurado y se recomiendan para el tratamiento de datos cuantitativos.
- Cuando se modela con Lógica Difusa, a medida que se incrementa la complejidad del sistema, las reglas difusas y las funciones usadas para describir el comportamiento del entorno son difíciles de determinar.
- Mantener un buen balance entre la precisión y la interpretabilidad del sistema no es una tarea sencilla. Generalmente aumentar la precisión del sistema trae como consecuencia una pérdida en la interpretabilidad del modelo, y viceversa.

Si bien éstas y otras técnicas computacionales pueden presentar algunos inconvenientes en determinadas aplicaciones, lo más conveniente es utilizarlas donde muestran un mejor desempeño. En este sentido, intentaremos plantear una metodología híbrida que permita el aprovechamiento de las técnicas estudiadas, aplicándolas a aquellos subproblemas en los cuales logran un mejor rendimiento e integrando sus resultados en un sistema de cooperación general. Todo esto, con el propósito de solucionar algunos de los problemas anteriormente planteados

3.3. Una metodología para el aprendizaje de Els que generen ganancias

En esta Sección propondremos una metodología para aprender clasificadores que describen Els que generan ganancias. Para ello emplearemos AGs y un mecanismo de aprendizaje por refuerzo en base al cálculo de ganancias obtenidas que nos permita aprender la mejor estrategia o bien un conjunto de estrategias que al ser aplicadas verifiquen cumplimentar el mencionado objetivo.

Esto es, aprenderemos clasificadores que determinen la mejor estrategia a seguir en una determinada especie; estrategias que contengan las distintas especies y finalmente múltiples estrategias.

Primero presentaremos los diferentes tipos de Els comúnmente empleadas por los inversores que luego serán utilizadas para las experiencias. Describiremos la metodología que se propone para el aprendizaje de los clasificadores y finalmente estudiaremos algunos criterios empleados para el aprendizaje y la evaluación de los clasificadores.

3.3.1. Marco de trabajo: Estrategias de Inversión

En esta tesis nuestra unidad de representación, tal cual se especificó en la Sección 1.5.1, es la estrategia. Una estrategia puede contener una o más reglas de acuerdo al contexto donde ésta sea aplicada. Cada una de estas reglas presenta la siguiente configuración:

- *El antecedente de las reglas* representa características observadas en la evolución del precio de la especie en días previos. Cuando esta evolución es estrictamente creciente decimos que estamos frente a una *tendencia* creciente, y cuando es estrictamente decreciente decimos que la tendencia es decreciente. En este caso vamos a utilizar el precio registrado en el momento del cierre de operaciones.
- *El consecuente de las reglas* representa la operación a realizar por un determinado período de tiempo, por ejemplo comprar y después de cuatro días vender.

Tal como se ha visto en la Sección 1.5.3, existen al menos tres tipos diferentes de representaciones de Els que pueden ser tenidas en cuenta por los expertos en finanzas.

- *Estrategias de Tipo I:* Estas Els poseen una sola regla fija que se aplica a una especie fija. Ejemplo:

El: "Si la especie Acindar comienza a subir de precio entonces comprar"

- *Estrategias de Tipo II:* En este caso las Els contienen una sola regla fija que puede ser aplicada a un conjunto variable de especies o una regla fija para cada una de las especies de un conjunto variable. Ejemplos:

El: "Si alguna especie comienza a subir de precio entonces comprar"

El: "Si el precio de la especie Acindar baja por dos días entonces vender o Si el precio de la especie Renault baja por dos días entonces vender"

- *Estrategias de Tipo III:* Este tipo de Els contienen un conjunto fijo de reglas que pueden ser aplicadas a un conjunto fijo de especies. Ejemplo:

El: "Si el precio de la especie Acindar baja por dos días entonces vender o

*Si el precio de la especie Acindar sube por tres días entonces comprar o
Si el precio de la especie Renault baja por dos días entonces vender o
Si el precio de la especie Renault sube por tres días entonces comprar”*

Para cumplimentar el objetivo planteado de aprender las Els, más adelante se realizarán distintas experiencias que considerarán a cada uno de estos tipos de estrategias.

3.3.2. Algoritmo de aprendizaje de Els

En el Capítulo 2 hemos mencionado que el aprendizaje de clasificadores se realiza por medio de AGs. La forma de realizar el aprendizaje en esta clase de Algoritmos Evolutivos (AE) puede ser al menos de dos tipos: Michigan y Pittsburgh. En la metodología que proponemos a continuación implementaremos ambos tipos de aprendizaje de acuerdo al tipo de estrategia considerado (Tipo I, Tipo II y Tipo III).

El cuerpo principal de la metodología planteada para el aprendizaje de un Sistema Clasificador (véase 2.4.4.2) se resume en la Figura 3.1 y se detalla a continuación:

-
- Paso 0:** Selección del tipo de estrategia a aprender
 - Paso 1:** Creación de la población inicial
 - Paso 2:** Evaluación de la efectividad de los clasificadores de la población frente a los ejemplos de entrenamiento asignándoles un mérito
 - Paso 3:** Mientras no se cumpla la condición de parada hacer
 - Paso 4:** Selección de clasificadores
 - Paso 5:** Aplicación del operador de cruzamiento
 - Paso 6:** Aplicación del operador de mutación
 - Paso 7:** Evaluación de la efectividad de los clasificadores de la población frente a los ejemplos de entrenamiento asignándoles un mérito
 - Paso 8:** Selección de los clasificadores más representativos
 - Paso 9:** Proceso de clasificación
-

Figura 3.1 – Metodología para el aprendizaje de un Sistema Clasificador

PASO 0. *Selección del tipo de estrategia a aprender:* Si la estrategia a aprender es del Tipo I, el tipo de aprendizaje empleado será Michigan. Si se desea aprender estrategias del Tipo II ó III, el aprendizaje empleado será Pittsburgh. En el primer caso las estrategias están formadas por una sola regla mientras que para el segundo una estrategia está compuesta por varias reglas codificadas en el cromosoma.

PASO 1. Creación de la población inicial: Construye la población de la primera generación. En nuestro caso las estrategias o clasificadores son generados aleatoriamente (véase Sección 2.4.2.4).

PASO 2 y 7. Evaluación de la población: La evaluación de la efectividad de los clasificadores se realiza mediante el cálculo de la función de aptitud del cromosoma que codifica a la estrategia. Esta función debe tener un criterio adecuado para evaluar a los cromosomas, de manera que permita una evolución satisfactoria del aprendizaje de los clasificadores.

En la Figura 3.2 podemos observar el algoritmo general para el Sistema de Asignación de Mérito (SAM) del SC utilizado por el AG para determinar la aptitud de los clasificadores. En la siguiente Sección se presentará un ejemplo donde se describen varios de los criterios utilizados para la evaluación de las Els aprendidas en las experiencias. Varios de ellos utilizan los resultados producidos por el SAM (véase la Sección 2.4.4.1).

Paso E1:	Para cada ejemplo (obtenido secuencial o aleatoriamente según sea el caso)
Paso E2:	Si se cumplen la/s condición/es de la estrategia
Paso E3:	Aplicar la operación del consecuente, calcular la ganancia y acumular el resultado
Paso E4:	Si la estrategia ganó dinero en la operación
Paso E5:	Incrementar la cantidad de aciertos
Paso E6:	Sino
Paso E7:	Incrementar la cantidad de fracasos
Paso E8:	Asignar un mérito a la estrategia según el resultado acumulado y la cantidad de aciertos y de fracasos

Figura 3.2 – Algoritmo general del Sistema de Asignación de Mérito

A partir de la información obtenida luego de evaluar al cromosoma, podemos identificar varias maneras de asignar el mérito a los clasificadores de manera que nos permita distinguir cuándo cuando una estrategia es mejor que otra (véase la Sección 2.4.2.5). Algunas de ellas son:

- Contabilizar la cantidad de aciertos (número de veces que ganó);
- Contabilizar la cantidad de fracasos (número de veces que perdió);
- Computar el porcentaje de aciertos (proporción entre aciertos y fracasos);
- Computar el resultado en cuanto a las ganancias obtenidas;
- Computar el resultado ponderado (producto entre el resultado y el porcentaje de aciertos);

En nuestro trabajo consideramos que es conveniente utilizar como función de aptitud el resultado de ganancia ponderada. Esta función nos da un buen balance entre el porcentaje de aciertos y el resultado de ganancia obtenido.

PASO 1. Creación de la población inicial: Construye la población de la primera generación. En nuestro caso las estrategias o clasificadores son generados aleatoriamente (véase Sección 2.4.2.4).

PASO 2 y 7. Evaluación de la población: La evaluación de la efectividad de los clasificadores se realiza mediante el cálculo de la función de aptitud del cromosoma que codifica a la estrategia. Esta función debe tener un criterio adecuado para evaluar a los cromosomas, de manera que permita una evolución satisfactoria del aprendizaje de los clasificadores.

En la Figura 3.2 podemos observar el algoritmo general para el Sistema de Asignación de Mérito (SAM) del SC utilizado por el AG para determinar la aptitud de los clasificadores. En la siguiente Sección se presentará un ejemplo donde se describen varios de los criterios utilizados para la evaluación de las Els aprendidas en las experiencias. Varios de ellos utilizan los resultados producidos por el SAM (véase la Sección 2.4.4.1).

Paso E1: Para cada ejemplo (obtenido secuencial o aleatoriamente según sea el caso)

Paso E2: Si se cumplen la/s condición/es de la estrategia

Paso E3: Aplicar la operación del consecuente, calcular la ganancia y acumular el resultado

Paso E4: Si la estrategia ganó dinero en la operación

Paso E5: Incrementar la cantidad de aciertos

Paso E6: Sino

Paso E7: Incrementar la cantidad de fracasos

Paso E8: Asignar un mérito a la estrategia según el resultado acumulado y la cantidad de aciertos y de fracasos

Figura 3.2 – Algoritmo general del Sistema de Asignación de Mérito

A partir de la información obtenida luego de evaluar al cromosoma, podemos identificar varias maneras de asignar el mérito a los clasificadores de manera que nos permita distinguir cuándo cuando una estrategia es mejor que otra (véase la Sección 2.4.2.5). Algunas de ellas son:

- Contabilizar la cantidad de aciertos (número de veces que ganó);
- Contabilizar la cantidad de fracasos (número de veces que perdió);
- Computar el porcentaje de aciertos (proporción entre aciertos y fracasos);
- Computar el resultado en cuanto a las ganancias obtenidas;
- Computar el resultado ponderado (producto entre el resultado y el porcentaje de aciertos);

En nuestro trabajo consideramos que es conveniente utilizar como función de aptitud el resultado de ganancia ponderada. Esta función nos da un buen balance entre el porcentaje de aciertos y el resultado de ganancia obtenido.

Cabe recordar que el proceso de aprendizaje llevado a cabo por esta metodología no es supervisado. El sistema recibe ejemplos provenientes de datos históricos que no incluyen una clasificación realizada por un experto. Los únicos datos con los que cuenta el sistema para asignarle un mérito a los clasificadores durante el aprendizaje son el refuerzo recibido cada vez que realiza una acción, esto es cada vez que opera con la estrategia, y la valoración global de la efectividad de la misma.

PASO 4. Selección de clasificadores: Para este procedimiento se implementa el Muestreo Universal Estocástico de Baker (MUE) [BAK87]. Básicamente, este método de selección plantea un esquema de selección proporcional [MILL95]. Además, se emplea elitismo para garantizar la preservación del mejor individuo de una generación a la siguiente.

PASO 5 y 6. Aplicación de operadores de cruzamiento y de mutación: Al momento del cruzamiento se realiza un cruce multipunto del cromosoma (en particular el cruce se realiza en dos puntos). El procedimiento de mutación utilizado produce una mutación uniforme sobre el conjunto de individuos (véase la Sección 2.4.2.6). Para el proceso se toma una secuencia formada por los cromosomas y se selecciona un conjunto de genes distribuidos uniformemente (la cantidad está determinada por la tasa de mutación utilizada) para modificarles luego su valor (es decir se le asigna un 0 si tiene un 1 y viceversa).

PASO 8. Selección de los clasificadores más representativos: Los criterios empleados para realizar la selección de estrategias son los siguientes:

- selección de la estrategia óptima: se selecciona una estrategia que presente la máxima función de aptitud.
- selección de las k estrategias óptimas: se seleccionan las k mejores estrategias que cumplan los siguientes requisitos:
 - No puede haber Els repetidas.
 - No puede haber Els que hayan obtenido un valor de aptitud negativo durante el aprendizaje.
 - Las Els que lo forman son las que obtuvieron los mayores valores de aptitud.

PASO 9. Proceso de clasificación: El procedimiento de inferencia que se lleva a cabo en este proceso debe estar adecuado a los distintos tipos de estrategias.

- Estrategias de Tipo I:

R: Si condición(E) entonces acción(E)

donde R es una regla y E es una especie.

- Estrategias de Tipo II:

- Tipo IIa:

Sea $Q = \{ E_1, \dots, E_k \}$ un conjunto fijo de especies.

$\forall E_i \in Q$: Si condición(E_i) entonces acción(E_i)

- Tipo IIb:

Sea $L = \{ E_1, \dots, E_t \}$ donde $L \subseteq Q$ y están codificadas en el cromosoma que representa al clasificador:

$\forall E_j \in L$: Si condición(E_j) entonces acción(E_j)

- Tipo IIc:

Sea $Q = \{ E_1, \dots, E_k \}$ un conjunto fijo de especies.

$\forall E_i \in Q$: Si condición _{i} (E_i) entonces acción _{i} (E_i)

- Estrategias de Tipo III:

Dados

$$El_1 = \{ R_{1,1}, R_{1,2}, \dots, R_{1,j} \}$$

$$El_2 = \{ R_{2,1}, R_{2,2}, \dots, R_{2,j} \}$$

...

$$El_k = \{ R_{k,1}, R_{k,2}, \dots, R_{k,j} \}$$

donde El_i es una Estrategia de Inversión y $R_{i,j}$: Si condición _{i} (E_i) entonces acción _{i} (E_i)

$$\forall E_i \in Q: \text{Máx} \{ R_{1,i}, R_{2,i}, \dots, R_{k,i} \}$$

3.3.3. Criterios para el aprendizaje y la evaluación de las estrategias aprendidas

Antes de enunciar las distintas experiencias que se realizarán a lo largo de este capítulo es conveniente definir una serie de criterios empleados para evaluar las estrategias aprendidas. Luego de la definición de estos conceptos se presenta un ejemplo donde se evalúa la aptitud de una estrategia en base a los méritos recibidos durante su aprendizaje.

- *Porcentaje de operaciones realizadas*: cada vez que se cumple el antecedente de la estrategia, se realiza la operación indicada en el consecuente. Para cada especie, la cantidad máxima de operaciones posibles es 1200 en el aprendizaje y 500 en el test.

$$\%Op = \frac{Op \times 100}{OP}$$

Donde:

%Op: porcentaje de operaciones realizadas;
Op: cantidad de operaciones realizadas;
OP: cantidad de operaciones posibles.

- *Porcentaje de éxito*: se considera que una operación ha sido exitosa cuando la misma produce una ganancia (su resultado es positivo). Este porcentaje se obtiene con el cociente entre la cantidad de operaciones exitosas y la cantidad de operaciones realizadas.

$$\%Ex = \frac{OE \times 100}{Op}$$

Donde:

%Ex: porcentaje de operaciones exitosas;
OE: cantidad de operaciones exitosas.

- *Ganancia de una operación*: por cada operación que se realiza se invierte el monto equivalente al precio de una acción. Se obtiene una ganancia si el precio al vender es mayor que al comprar. El resultado obtenido por una estrategia es la suma de los resultados obtenidos en cada una de las operaciones realizadas (ya sean éstos ganancias o pérdidas).

Donde:

$$GO_i = Pv - Pc$$

GO_i: ganancia obtenida en la operación i;
Pv: precio al momento de la venta;
Pc: precio al momento de la compra.

- *Ganancia de la estrategia*: es la ganancia acumulada obtenida en cada una de las operaciones realizadas.

$$GE = \sum_{i=1}^{Op} GO_i$$

Donde:

GE: ganancia de la estrategia.

- *Ganancia ponderada*: es el producto entre la ganancia de la estrategia y el porcentaje de operaciones exitosas realizadas. Este es el valor utilizado como función de aptitud del AG.

$$GP = \frac{\%Ex \times GE}{100}$$

Donde:

GP: ganancia ponderada.

Ejemplo del cálculo de los conceptos previamente definidos sobre una estrategia que opera sobre la especie Acindar durante 100 días:

$$OP = 100$$

- Operación 1: Compramos una acción de Acindar a 1.2\$ (día 6) y vendemos a 0.9\$ (a los tres días)
 - $Op = 1$
 - $GO_1 = 0.9 - 1.2 = - 0.3$
 - $GE = - 0.3$
 - $OE = 0$

- Operación 2: Compramos una acción de Acindar a 0.8\$ (día 24) y vendemos a 0.9\$ (a los tres días)
 - $Op = 2$
 - $GO_2 = 0.9 - 0.8 = 0.1$
 - $GE = - 0.2$
 - $OE = 1$

- Operación 3: Compramos una acción de Acindar a 0.8\$ (día 25) y vendemos a 1.3\$ (a los tres días)
 - $Op = 3$
 - $GO_3 = 1.3 - 0.8 = 0.5$
 - $GE = 0.3$
 - $OE = 2$

- Operación 4: Compramos una acción de Acindar a 1.2\$ (día 53) y vendemos a 1.1\$ (a los tres días)
 - $Op = 4$
 - $GO_4 = 1.1 - 1.2 = - 0.1$
 - $GE = 0.2$
 - $OE = 2$

- Operación 5: Compramos una acción de Acindar a 0.5\$ (día 89) y vendemos a 1.4\$ (a los tres días)

- $Op = 5$
- $GO_5 = 1.4 - 0.5 = 0.9$
- $GE = 1.1$
- $OE = 3$

Resultados finales

- $\%Op = 5 / 100 * 100 = 5\%$
- $\%Ex = 3 / 5 * 100 = 60\%$
- $GP = 1.1 * 60\% = 0.66$

3.4. Experiencias

Las experiencias que se van a estudiar en este capítulo han sido divididas en tres grupos según el tipo de Els consideradas:

- *Experiencias de aprendizaje de una estrategia que se aplica a una sola especie:* se realizaron tres experiencias con diferentes Els sobre distintas especies en forma individual (Perez Companc, Galicia, Acindar) utilizando Els de Tipo I.
- *Experiencias de aprendizaje de una estrategia que se aplica a un conjunto de especies:* Una vez definido un tipo de estrategia, realizamos tres experiencias sobre conjuntos de especies. Estas experiencias serán realizadas sobre un conjunto de tres especies pertenecientes a un sector específico (Bancos: Bansud, Galicia y Francés) y también sobre un conjunto de diez especies seleccionadas al azar (Bansud, Galicia, Francés, Astra, Atanor, Comercial del Plata, Siderca, Perez Companc, Acindar y Renault). En las experiencias se emplearán los tres casos de Els de Tipo II (véase el paso 9 de la metodología descrita en la Sección 3.3.2).
- *Una experiencia para utilizar MEI que se aplican a un conjunto de especies:* esta experiencia nos mostrará cómo utilizar MEI. Esta modificación persigue el objetivo de aumentar las ganancias, ampliando las posibilidades de operar a través de varias Els. La experiencia se realiza sobre los mismos conjuntos de especies usados para el grupo anterior y en ella se emplean Els de Tipo III.

Con respecto a los ejemplos que serán utilizados para las experiencias, tal como se lo anticipó en la Sección 1.5.3, consideraremos dos opciones para el proceso de lectura de los datos:

- *Secuencial:* en este caso la función de evaluación recorre 1200 días (son 500 días cuando se realiza el test) en forma cronológica observando si se cumple el antecedente de la estrategia.
- *Aleatorio:* en este caso, para evaluar la estrategia la función de evaluación toma en forma aleatoria 1200 días del conjunto de datos de la serie temporal (son 500 días cuando se realiza el test).

La inclusión de experiencias realizados con un muestreo al azar nos va a ser de utilidad para verificar que el procedimiento empleado no es dependiente de la secuencialidad de los datos.

La decisión de aprender una única estrategia en los dos primeros grupos de experiencias se fundamenta en que los operadores tienden a mantener una o muy pocas Els simples a lo largo del tiempo en forma análoga a los jugadores de lotería que apuestan a un mismo número durante muchos años. Por el mismo motivo, y dado que incorporar nuevas Els cuando el conjunto alcanzó una determinada cantidad no produce cambios significativos que justifiquen el mayor costo de procesamiento (véase el Apéndice E), en la experiencia con MEI la cantidad de Els está limitada a tres.

3.4.1. Codificación y parámetros

En la Tabla 3.1 pueden observarse los valores que se han seleccionado para la cantidad de generaciones, las tasas de cruce y las tasas de mutación, los cuales se encuentran dentro de los mencionados en la Sección 2.4.2.6.

Parámetros generales	
Probabilidad de cruce	0.6
Probabilidad de mutación	0.1
Número de generaciones	3000

Tabla 3.1 – Parámetros generales

Definiremos a continuación las Els que se van a utilizar en cada experiencia, su representación binaria en el cromosoma y los parámetros específicos para cada uno.

3.4.1.1. Experiencias con una sola especie

Tal como se ha mencionado, estas experiencias tienen como objetivo encontrar el tipo de Els aplicadas a una única especie que produzca mejores rendimientos.

Los distintos formatos de las Els se muestran a continuación. En los mismos tanto la especie considerada como la estrategia empleada, son fijos (véase la Sección 3.3.1).

Los resultados de la aplicación de este tipo de experiencias se presentan en la Sección 3.4.2.1 y son analizados en la Sección 3.5.1.

- *Experiencia 1-A: Incremento de precio en un día con operación fija*
 - *Estrategia:* Esta experiencia permite obtener estrategias del siguiente tipo:

Si [precio de hoy > precio de ayer] entonces [comprar y mantener por n días]

- *Codificación del cromosoma:* Está formado por 2 genes que representan los días a mantener la operación de compra. Por ejemplo: "01" significa: "Si el precio de hoy es mayor al precio de ayer entonces comprar y mantener por 1 día". El antecedente está construido con una condición muy simple que a priori no parece ser demasiado prometedora. El consecuente es bastante restrictivo: sólo da lugar a operaciones de compra por una determinada cantidad de días cuando ha habido un incremento de precio con respecto al día anterior. La cantidad de días puede tomar valores de uno, dos o tres días (véase Figura 3.3).

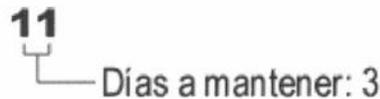


Figura 3.3 – Cromosoma que representa una estrategia para la experiencia 1-A (Si la tendencia es estrictamente creciente por 1 día entonces comprar y mantener por 3 días)

- *Parámetros:* Los parámetros empleados para la experiencia 1-A pueden observarse en la Tabla 3.2

Parámetros para la experiencia 1-A	
Tamaño del cromosoma	2 genes
Cantidad de individuos distintos	$2^2 = 4$
Tamaño de la población inicial	4 individuos

Tabla 3.2 – Parámetros para la experiencia 1-A

- *Experiencia 1-B: Variación de precio en tres días con operación fija*
 - *Estrategia:* En esta experiencia vamos a introducir una modificación en el antecedente produciendo una estrategia aún más restrictiva. En este caso vamos a exigir que la tendencia estrictamente creciente se mantenga por tres días. Las estrategias obtenidas serán del siguiente tipo:
Si [precio de hoy > precio de ayer y precio de ayer > precio de anteayer] entonces [comprar y mantener por n días]
 - *Codificación del cromosoma:* Está formado por 2 genes que representan los días a mantener la operación. Por ejemplo "10" significa "Si precio de hoy es mayor al precio de ayer y el precio de ayer es mayor al precio de anteayer entonces comprar y mantener por 2 días" (véase Figura 3.4).



Figura 3.4 – Cromosoma que representa una estrategia para la experiencia 1-B (Si la tendencia es estrictamente creciente por 3 días consecutivos entonces comprar y mantener por 2 días)

- *Parámetros:* Los parámetros empleados para la experiencia 1-B pueden observarse en la tabla 3.3

Parámetros para la experiencia 1-B	
Tamaño del cromosoma	2 genes
Cantidad de individuos distintos	$2^2 = 4$
Tamaño de la población inicial	4 individuos

Tabla 3.3 – Parámetros para la experiencia 1-B

- *Experiencia 1-C: Variación de precios hasta siete días con operación variable*

- *Estrategia:* Finalmente, en la última experiencia de este primer grupo hacemos cuatro cambios importantes:

Incrementamos la cantidad de días de tendencia: ahora puede ser desde uno hasta siete
 no nos limitamos a tendencias crecientes sino que también tenemos en cuenta las tendencias decrecientes
 la operación que se realiza puede ser tanto de compra como de venta.
 luego de realizada la operación, se mantiene durante un período que puede ser desde uno a siete días

Las estrategias obtenidas serán del siguiente tipo:

Si [tendencia estrictamente creciente/decreciente por n días] entonces [comprar/vender y mantener por m días]

- *Codificación del cromosoma:* Está formado por 1 gen que representa el tipo de tendencia (creciente o decreciente), 3 genes que representan los días de tendencia, 1 gen que representa la operación a realizar (compra o venta) y 3 genes que representan los días a mantener la operación. Por ejemplo "01100011" significa "Si tendencia estrictamente creciente por 6 días entonces comprar y mantener por 3 días". En la Figura 3.5 se puede observar la ubicación de los genes que representan a la estrategia en el cromosoma.

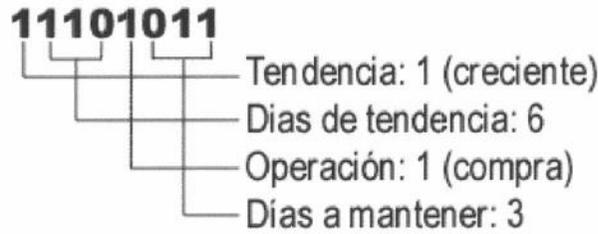


Figura 3.5 – Cromosoma que representa una estrategia para la experiencia 1-C (Si la tendencia es estrictamente creciente por 6 días entonces comprar y mantener por 3 días)

- *Parámetros*: Los parámetros empleados para la experiencia 1-C pueden observarse en la Tabla 3.4

Parámetros para la experiencia 1-C	
Tamaño del cromosoma	8 genes
Cantidad de individuos distintos	$2^8 = 256$
Tamaño de la población inicial	200 individuos

Tabla 3.4 – Parámetros para la experiencia 1-C

3.4.1.2. Experiencias con un conjunto de especies

Los parámetros que emplearemos en el SC utilizado para este conjunto de experiencias son los mismos que se usaron anteriormente. Utilizaremos Els que están formadas por reglas como las aprendidas en la experiencia 1-C, dado que demuestran tener un mejor comportamiento que las restantes (véase la Sección 3.5.1)

Como se mencionó al comienzo de la Sección 3.4, las siguientes experiencias se realizarán tomando dos conjuntos diferentes de datos de especies:

- *Bancos*: un conjunto de tres especies que pertenecen a un mismo sector de negocios.
- *Especies varias*: un conjunto de diez especies seleccionadas al azar.

Como se verá a continuación, en este grupo de experiencias se va a trabajar con Els de Tipo II, que están compuestas por varias reglas, con el fin de obtener mayores ganancias.

- *Experiencia 2-A: Identificación de la estrategia que mejor se aplica a varias especies a la vez*
 - *Estrategia*: Para este primer caso emplearemos estrategias de Tipo Ila que incluyen reglas similares a las utilizadas en la experiencia 1-C del

grupo anterior. La diferencia principal es que ahora en vez de aplicar la estrategia a una única especie, ésta se aplicará al conjunto de especies analizadas. Como resultado obtendremos la mejor estrategia que se aplica a las tres o a las diez especies simultáneamente.

- *Codificación del cromosoma:* En este primer cromosoma, la estrategia que codifica es igual a la utilizada en la experiencia 1-C y se aplica a cada especie (véase Figura 3.6).

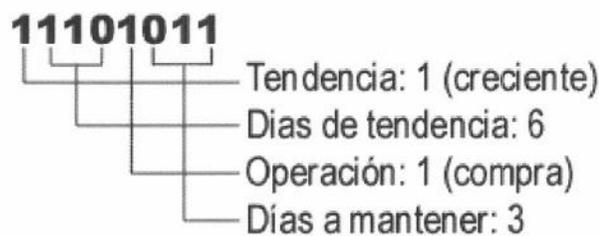


Figura 3.6 – Cromosoma que representa una estrategia para la experiencia 2-A (Si la tendencia es estrictamente creciente por 6 días entonces comprar y mantener por 3 días)

- *Parámetros:* Los parámetros empleados para la experiencia 2-A pueden observarse en la Tabla 3.5

Parámetros para la experiencia 2-A	
Tamaño del cromosoma	8 genes
Cantidad de individuos distintos	$2^8 = 256$
Tamaño de la población inicial	200 individuos

Tabla 3.5 – Parámetros para la experiencia 2-A

- *Experiencia 2-B: Identificación de una estrategia que se aplica a un subconjunto de especies (estrategias de Tipo IIb)*
 - *Estrategia:* En esta experiencia se introduce el siguiente cambio: la estrategia ahora además nos dice a cuáles de las especies consideradas debe ser aplicada.
 - *Codificación del cromosoma:* El cromosoma aumenta de tamaño tantos genes como especies se estén considerando (1 gen por especie). Véase Figura 3.7
 - *Parámetros:* Los parámetros empleados para la experiencia 2-B pueden observarse en la Tabla 3.6

Parámetros para la experiencia 2-B	
Tamaño del cromosoma	8+3 u 8+10 genes
Cantidad de individuos distintos	$2^{(8+3)}$ ó $2^{(8+10)}$
Tamaño de la población inicial	200 individuos

Tabla 3.6 – Parámetros para la experiencia 2-B

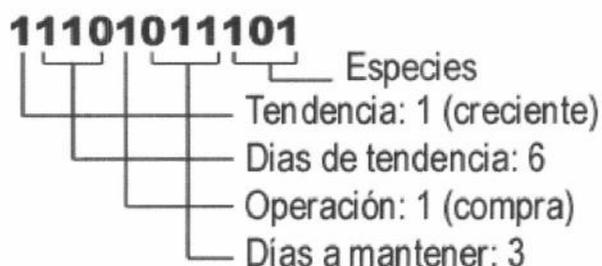


Figura 3.7 – Cromosoma que representa una estrategia para la experiencia 2-B tres especies (Si la tendencia es estrictamente creciente por 6 días entonces comprar y mantener por 3 días, aplicar a Bansud y a Galicia)

- *Experiencia 2-C: Identificación de la mejor estrategia que contiene una regla fija para cada especie*
 - *Estrategia:* En esta tercer experiencia permitiremos que una estrategia contenga una regla por cada especie analizada.
 - *Codificación del cromosoma:* Necesitamos ocho genes para representar la regla de una especie, y esto para cada especie a analizar. Por ejemplo para el sector de tres especies el tamaño es de 24 genes y para el de las diez especies aleatorias el tamaño es de 80 genes. Por lo tanto deberemos ajustar los parámetros del algoritmo tal como se muestra en la tabla 3.7.
 - *Parámetros:* Los parámetros empleados para la experiencia 2-C pueden observarse en la Tabla 3.7

Parámetros para la experiencia 2-C	
Tamaño del cromosoma	24 ú 80 genes
Cantidad de individuos distintos	2^{24} ó 2^{80}
Tamaño de la población inicial	200 individuos

Tabla 3.7 – Parámetros para la experiencia 2-C

3.4.1.3. Experiencias con Múltiples Estrategias de Inversión

La codificación del cromosoma, los parámetros para el AG utilizados en esta experiencia son iguales a los que ya se usaron para la experiencia 2-C. Esta elección se debe a los buenos resultados obtenidos con la misma (véase Sección 3.3.3.2). Las Els empleadas en esta experiencia son las del Tipo III.

3.4.2. Resultados de las experiencias

Los resultados de las experiencias que se presentan a continuación nos van a aportar varios datos que luego serán analizados en la Sección 3.5 desde varios puntos de vista: la ganancia obtenida, el porcentaje de operaciones realizadas y el porcentaje de éxito alcanzado por las Els aprendidas.

En las tablas que muestran los resultados se pueden ver varias referencias abreviadas cuyo significado se describe en la Tabla 3.8.

Abreviatura	Significado
Est	Estrategia aprendida, es una referencia a las tablas 3.12, 3.16 y 3.18
%Op	Porcentaje de operaciones realizadas respecto al total de operaciones posibles.
%Ex	Porcentaje de éxito obtenido en las operaciones
Ga	Ganancia acumulada de las operaciones realizadas (Ganancia de la estrategia)
Gp	Ganancia ponderada de la estrategia (producto entre %Ex y Ga)

Tabla 3.8 – Descripción de las abreviaturas utilizadas.

A continuación se presentan los tres grupos de experiencias y sus resultados.

3.4.2.1. Resultados obtenidos en las experiencias con una sola especie

Los resultados obtenidos en las experiencias se observan en las Tablas 3.9, 3.10 y 3.11. La explicación correspondiente a las estrategias utilizadas (y los cromosomas seleccionados) se puede ver en la Tabla 3.12

Experiencia 1-A

Secuencial		Entrenamiento					Test				(a)
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp		
Pérez Companc	(1)	59,91	52,29	1,75	0,92	47,60	45,80	0,74	0,34		
Galicia	(2)	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00		
Acindar	(3)	59,41	49,51	2,52	1,25	45,40	51,10	1,28	0,65		
Aleatorio		Entrenamiento					Test				(b)
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp		
Pérez Companc	(4)	61,58	55,20	13,63	7,52	46,00	46,09	-1,86	-0,86		
Galicia	(5)	59,66	54,47	71,37	38,87	43,00	51,16	7,51	3,84		
Acindar	(6)	59,91	48,96	4,36	2,13	43,20	49,07	0,55	0,27		

Tabla 3.9 – Incremento de precio en un día con operación fija (a) con datos secuenciales y (b) con datos aleatorios

Experiencia 1-B

Secuencial		Entrenamiento				Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp
Pérez Companc	(7)	13,91	53,30	4,02	2,14	9,60	50,00	-0,16	-0,08
Galicia	(8)	15,41	54,59	48,50	26,48	13,00	47,69	0,97	0,46
Acindar	(9)	14,33	52,90	1,42	0,75	13,20	59,09	1,04	0,61

(a)

Aleatorio		Entrenamiento				Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp
Pérez Companc	(10)	16,40	56,85	8,12	4,61	7,00	54,29	0,24	0,13
Galicia	(11)	15,08	59,67	66,61	39,75	12,00	46,67	2,31	1,08
Acindar	(12)	16,58	60,80	2,74	1,66	12,20	60,66	1,07	0,65

(b)

Tabla 3.10 – Variación de precio en tres días con operación fija (a) con datos secuenciales y (b) con datos aleatorios

Experiencia 1-C

Secuencial		Entrenamiento				Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp
Pérez Companc	(13)	57,75	49,78	55,61	27,69	49,00	48,98	5,21	2,55
Galicia	(14)	56,25	49,04	149,63	73,38	47,80	48,95	11,31	5,54
Acindar	(15)	57,42	49,06	31,78	15,59	44,40	50,00	4,04	2,02

(a)

Aleatorio		Entrenamiento				Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp
Pérez Companc	(16)	59,42	52,45	112,23	58,87	48,20	50,21	-1,43	-0,72
Galicia	(17)	8,00	66,67	266,92	177,95	5,40	46,43	-1,25	-0,58
Acindar	(18)	58,92	53,18	59,98	31,90	43,00	54,42	8,11	4,42

(b)

Tabla 3.11 – Variación de precio hasta siete días con operación variable (a) con datos secuenciales y (b) con datos aleatorios

Descripción de las estrategias aprendidas en las experiencias
(1) Si el precio de hoy es mayor al de ayer, comprar y vender mañana (01)
(2) No operar (00)
(3) Si el precio de hoy es mayor al de ayer, comprar y vender mañana (01)
(4) Si el precio de hoy es mayor al de ayer, comprar y vender pasado mañana (10)
(5) Si el precio de hoy es mayor al de ayer, comprar y vender pasado mañana (10)
(6) Si el precio de hoy es mayor al de ayer, comprar y vender mañana (01)
(7) Si el precio fue creciente por 3 días, comprar y vender al día siguiente (01)
(8) Si el precio fue creciente por 3 días, comprar y vender los 3 días (11)
(9) Si el precio fue creciente por 3 días, comprar y vender al día siguiente (01)
(10) Si el precio fue creciente por 3 días, comprar y vender al día siguiente (01)
(11) Si el precio fue creciente por 3 días, comprar y vender los 3 días (11)
(12) Si el precio fue creciente por 3 días, comprar y vender los 3 días (11)
(13) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)
(14) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)
(15) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)
(16) Si la tendencia fue decreciente por 1 día, vender y mantener por 6 días (00010110)
(17) Si la tendencia fue creciente por 4 días, comprar y mantener por 7 días (11001111)
(18) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)

(13) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)
(14) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)
(15) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)
(16) Si la tendencia fue decreciente por 1 día, vender y mantener por 6 días (00010110)
(17) Si la tendencia fue creciente por 4 días, comprar y mantener por 7 días (11001111)
(18) Si la tendencia fue decreciente por 1 día, vender y mantener por 7 días (00010111)

Tabla 3.12 – Descripción de las estrategias utilizadas

3.4.2.2. Resultados obtenidos en las experiencias con un conjunto de especies

Los resultados obtenidos en las experiencias se observan en las Tablas 3.13, 3.14 y 3.15. La explicación correspondiente a las estrategias utilizadas (y los cromosomas seleccionados) se puede ver en la Tabla 3.16

Experiencia 2-A

Secuencial		Entrenamiento					Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp	
Bancos	(19)	44,83	52,73	119,95	63,25	47,67	50,91	11,40	5,80	
Especies varias	(20)	44,89	51,01	236,09	120,43	45,38	52,00	35,88	18,67	

(a)

Aleatorio		Entrenamiento					Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp	
Bancos	(21)	44,14	56,07	201,83	113,17	47,53	52,59	6,23	3,28	
Especies varias	(22)	45,26	52,64	413,33	217,59	45,26	52,41	34,56	18,11	

(b)

Tabla 3.13 – Identificación de la estrategia que mejor se aplica a varias especies la vez (a) con datos secuenciales y (b) con datos aleatorios

Experiencia 2-B

Secuencial		Entrenamiento					Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp	
Bancos	(23)	44,86	52,73	119,95	63,25	47,67	50,91	11,40	5,80	
Especies varias	(24)	44,89	51,01	236,09	120,43	45,38	52,01	35,88	18,66	

(a)

Aleatorio		Entrenamiento					Test			
Especie	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp	
Bancos	(25)	43,72	54,26	181,16	98,29	47,53	52,59	6,23	3,28	
Especies varias	(26)	36,17	52,41	404,55	212,01	36,60	50,44	18,24	9,20	

(b)

Tabla 3.14 – Identificación de la estrategia aplicada a un subconjunto de especies (a) con datos secuenciales y (b) con datos aleatorios

Experiencia 2-C

Secuencial	Entrenamiento					Test				(a)
	Espece	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	
Bancos	(27)	44,86	53,56	121,63	65,14	47,73	52,23	16,81	8,78	
Especies varias	(28)	40,89	51,72	310,56	160,63	40,90	52,18	37,69	19,66	
Aleatorio	Entrenamiento					Test				(b)
	Espece	Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	
Bancos	(29)	44,83	54,83	180,07	98,73	48,93	52,45	0,14	0,08	
Especies varias	(30)	30,60	53,65	409,48	219,68	31,84	50,82	24,02	12,21	

Tabla 3.15 – Identificación de la mejor estrategia para cada especie (a) con datos secuenciales y (b) con datos aleatorios

Descripción de las estrategias aprendidas en las experiencias
(19) Si la tendencia fue decreciente por 1 día, vender y mantener por 4 días las 3 especies (00010100)
(20) Si la tendencia fue decreciente por 1 día, vender y mantener por 5 días las 10 especies (00010101)
(21) Si la tendencia fue decreciente por 1 día, vender y mantener por 4 días las 3 especies (00010101)
(22) Si la tendencia fue decreciente por 1 día, vender y mantener por 5 días las 10 especies (00010101)
(23) Si la tendencia fue decreciente por 1 día, vender y mantener por 4 días las 3 especies (00010100111)
(24) Si la tendencia fue decreciente por 1 día, vender y mantener por 5 días las 10 especies (000101011111111111)
(25) Si la tendencia fue decreciente por 3 días, vender BANSUD y mantener por 3 días (00010101111)
(26) Si la tendencia fue decreciente por 1 día, vender y mantener por 5 días todas especies excepto ASTRA y ATANOR (000101011110011111)
(27) Si BANSUD baja por 1 días, vender y mantener por 4 días; Si GALICIA baja por 1 días, vender y mantener por 5 días; Si FRANCES baja por 1 días, vender y mantener por 2 días. (000101000001010100010010)
(28) Si BANSUD baja por 1 días, vender y mantener por 4 días; Si GALICIA baja por 1 días, vender y mantener por 5 días; Si FRANCES baja por 1 días, vender y mantener por 2 días; Si ASTRA sube por 1 días, vender y mantener por 7 días; Si ATANOR baja por 1 días, vender y mantener por 5 días; Si COMERCIAL DEL PLATA baja por 1 días, vender y mantener por 5 días; Si SIDERCA baja por 1 días, vender y mantener por 6 días; Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días; Si ACINDAR baja por 1 días, vender y mantener por 7 días; Si RENAULT sube por 4 días, comprar y mantener por 5 días. (00010100000101010001001010010111000101010001010001011000010111000101111001101)
(29) Si BANSUD baja por 1 días, vender y mantener por 4 días; Si GALICIA baja por 1 días, vender y mantener por 5 días; Si FRANCES baja por 1 días, vender y mantener por 7 días. (000101000001010100010111)
(30) Si BANSUD baja por 1 días, vender y mantener por 4 días; Si GALICIA baja por 1 días, vender y mantener por 4 días; Si FRANCES baja por 1 días, vender y mantener por 2 días; Si ASTRA sube por 2 días, vender y mantener por 7 días; Si ATANOR sube por 7 días, vender y mantener por 4 días; Si COMERCIAL DEL PLATA baja por 1 días, vender y mantener por 5 días; Si SIDERCA sube por 4 días, comprar y mantener por 6 días; Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días; Si ACINDAR baja por 1 días, vender y mantener por 7 días; Si RENAULT sube por 4 días, comprar y mantener por 7 días. (000101000001010000010010101001111110100000101011100111000010111000101111001111)

Tabla 3.16 – Descripción de las estrategias utilizadas

3.4.2.3. Resultados obtenidos en la experiencia con Múltiples Estrategias de Inversión

Los resultados obtenidos en las experiencias se observan en la Tabla 3.17. La explicación correspondiente a las estrategias utilizadas (y los cromosomas seleccionados) se puede ver en la Tabla 3.18.

Experiencia con Múltiples Estrategias de Inversión

Secuencial		Entrenamiento				Testeo				
Especie		Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp
Bancos	(1)		44.86	53.56	121.63	65.14	47.73	52.23	16.81	8.78
Especies varias	(2)		43.45	51.96	366.17	190.26	40.90	52.18	37.69	19.66
Aleatorio		Entrenamiento				Testeo				
Especie		Est	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp
Bancos	(3)		44.25	53.11	123.20	65.43	41.80	56.30	61.95	34.88
Especies varias	(4)		31.59	53.15	233.45	124.08	30.24	52.58	74.35	39.09

Tabla 3.17 – Resultados de la experiencia con MEI (a) con datos secuenciales y (b) con datos aleatorios

Descripción de las estrategias aprendidas en la experiencia con MEI
(Si GALICIA baja por 1 días, vender y mantener por 5 días) ó (Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 2 días) (000101010001010000010010)
(Si GALICIA baja por 1 días, vender y mantener por 5 días) ó (Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 3 días) (000101010001010000010011)
(Si GALICIA baja por 1 días, vender y mantener por 4 días) ó (Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 2 días) (000101000001010000010010)
(Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si GALICIA baja por 1 días, vender y mantener por 5 días) ó (Si FRANCES baja por 1 días, vender y mantener por 2 días) ó (Si ASTRA sube por 1 días, vender y mantener por 7 días) ó (Si ATANOR baja por 1 días, vender y mantener por 5 días) ó (Si COMERCIAL DEL PLATA baja por 1 días, vender y mantener por 5 días) ó (Si SIDERCA baja por 1 días, vender y mantener por 6 días) ó (Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días) ó (Si ACINDAR baja por 1 días, vender y mantener por 7 días) ó (Si RENAULT sube por 4 días, comprar y mantener por 5 días) (0001010000010101000100101001011100010101000101010001011000010111000101111001101)

(Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si GALICIA baja por 1 días, vender y mantener por 5 días) ó (Si FRANCES baja por 1 días, vender y mantener por 2 días) ó (Si ASTRA sube por 1 días, vender y mantener por 7 días) ó (Si ATANOR baja por 1 días, vender y mantener por 5 días) ó (Si COM.PLATA sube por 2 días, comprar y mantener por 7 días) ó (Si SIDERCA baja por 1 días, vender y mantener por 6 días) ó (Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días) ó (Si ACINDAR baja por 1 días, vender y mantener por 6 días) ó (Si RENAULT baja por 3 días, comprar y mantener por 7 días)(000101000001010100010010100101110001010110101110001011000010111000101100011111)

(Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si GALICIA baja por 1 días, vender y mantener por 5 días) ó (Si FRANCES baja por 1 días, vender y mantener por 3 días) ó (Si ASTRA sube por 1 días, vender y mantener por 7 días) ó (Si ATANOR baja por 1 días, vender y mantener por 5 días) ó (Si COM.PLATA sube por 2 días, comprar y mantener por 7 días) ó (Si SIDERCA baja por 1 días, vender y mantener por 6 días) ó (Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días) ó (Si ACINDAR baja por 1 días, vender y mantener por 7 días) ó (Si RENAULT baja por 3 días, comprar y mantener por 7 días)
(000101000001010100010011100101110001010110101110001011000010111000101110011111)

(Si GALICIA baja por 1 días, vender y mantener por 5 días) ó (Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 5 días)
(000101010001010000010101)

(Si GALICIA baja por 1 días, vender y mantener por 4 días) ó (Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 6 días)
(000101000001010000010110)

(Si GALICIA baja por 1 días, vender y mantener por 4 días) ó (Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 5 días)
(000101000001010000010101)

(Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si GALICIA baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 2 días) ó (Si ASTRA sube por 7 días, vender y mantener por 7 días) ó (Si ATANOR sube por 5 días, vender y mantener por 4 días) ó (Si COM.PLATA sube por 2 días, comprar y mantener por 7 días) ó (Si SIDERCA baja por 5 días, vender y mantener por 3 días) ó (Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días) ó (Si ACINDAR baja por 1 días, vender y mantener por 7 días) ó (Si RENAULT baja por 1 días, vender y mantener por 5 días)
(00010100000101000001001011110111110101001010111101010011000101110001011100010101)

(Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si GALICIA baja por 1 días, vender y mantener por 5 días) ó (Si FRANCES baja por 1 días, vender y mantener por 2 días) ó (Si ASTRA baja por 7 días, comprar y mantener por 7 días) ó (Si ATANOR sube por 3 días, vender y mantener por 5 días) ó (Si COM.PLATA sube por 6 días, comprar y mantener por 5 días) ó (Si SIDERCA sube por 5 días, comprar y mantener por 4 días) ó (Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días) ó (Si ACINDAR baja por 1 días, vender y mantener por 7 días) ó (Si RENAULT baja por 1 días, vender y mantener por 5 días)
(0001010000010101000100100111111101101011110110111011100000101110001011100010101)

(Si BANSUD baja por 1 días, vender y mantener por 4 días) ó (Si GALICIA baja por 1 días, vender y mantener por 4 días) ó (Si FRANCES baja por 1 días, vender y mantener por 6 días) ó (Si ASTRA baja por 7 días, vender y mantener por 4 días) ó (Si ATANOR baja por 4 días, comprar y mantener por 4 días) ó (Si COM.PLATA sube por 2 días, comprar y mantener por 5 días) ó (Si SIDERCA baja por 5 días, comprar y mantener por 3 días) ó (Si PEREZ COMPANC baja por 1 días, vender y mantener por 7 días) ó (Si ACINDAR baja por 1 días, vender y mantener por 6 días) ó (Si RENAULT baja por 1 días, vender y mantener por 4 días)
(00010100000101000001011001110100010011001010110101011011000101110001011000010100)

Tabla 3.18 – Descripciones de las EIs aprendidas en la experiencia con MEI

3.5. Análisis de resultados

En las Secciones 3.4.2.1, 3.4.2.2 y 3.4.2.3 se han presentado los resultados obtenidos con cada uno de los tres grupos de experiencias. Estos serán estudiados y comparados en las siguientes subsecciones con el fin de verificar si los diferentes cambios planteados en cada experiencia han producido mejoras significativas en los mismos. Analizaremos las experiencias de cada grupo entre sí y con respecto a las del grupo anterior.

3.5.1. Análisis de los resultados obtenidos en las experiencias con una sola especie

El análisis de los resultados será realizado teniendo en cuenta varios aspectos: ganancia obtenida, porcentaje de operaciones realizadas y porcentaje de éxito obtenido.

- *Desde el punto de vista de la ganancia obtenida:*
 - Como puede observarse en la Figura 3.8 (véanse las Tablas 3.9a, 3.10a y 3.11a), las ganancias obtenidas por el caso 1-C son claramente superiores a las de los casos 1-A y 1-B para las tres especies analizadas, tanto para el entrenamiento como para el test cuando trabajamos con una selección de instancias en forma secuencial. Esto se debe a que en los dos primeros casos (1-A y 1-B), las estrategias utilizadas tienen poca expresividad ya que sólo se refieren a operaciones de compra, tienen fija la cantidad de días de tendencia y sólo pueden ser mantenidas hasta tres días. Por el contrario, en el caso 1-C aumenta la expresividad al agregarse la posibilidad de que la estrategia realice operaciones de venta a plazo y que los días de tendencia y de mantenimiento de la acción puedan llegar a ser siete.
 - Si bien se nota un importante incremento en las ganancias cuando se toman los datos en forma aleatoria (véase la Figura 3.9a), la estrategia

encontrada muestra una acción con considerables ganancias respecto del conjunto de test: la especie Acindar. Existe sobreaprendizaje en las restantes acciones (véanse la Tabla 3.11b y la Figura 3.9b). Esto se debe a un sobreajuste de la estrategia identificada con respecto al conjunto de entrenamiento, posiblemente debido a la elección aleatoria de los datos. Existen varias formas de tratar con el problema de sobreaprendizaje [MIT97]. Una de estas formas es realizando una pre-pruning sobre los datos de entrenamiento, esto es disminuyendo el tamaño de dicho conjunto. Otra forma es aplicando diferentes mecanismos de re-muestreo (cross validation, bootstrap, one leave-out) [FRI01] o de multiclasificación (Boosting, Bagging) [BAU99]

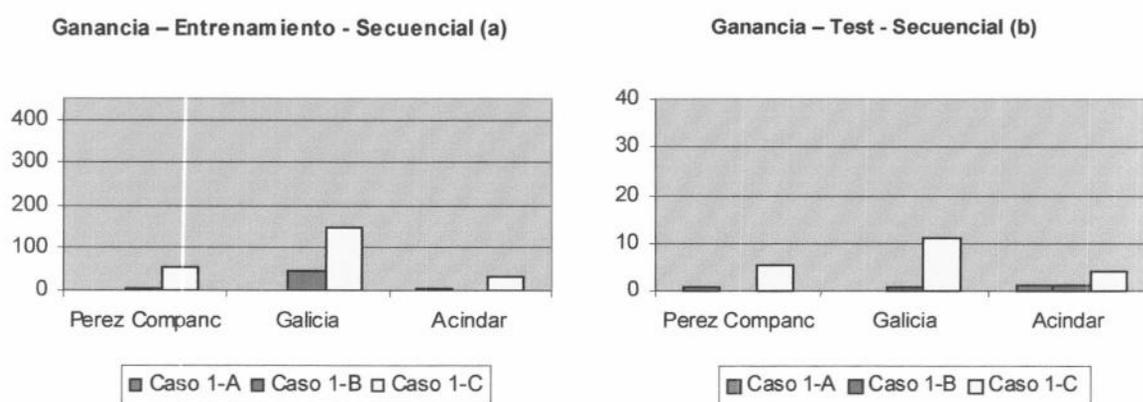


Figura 3.8 – Ganancia con conjunto de datos secuencial en el entrenamiento (a) y en el test (b)

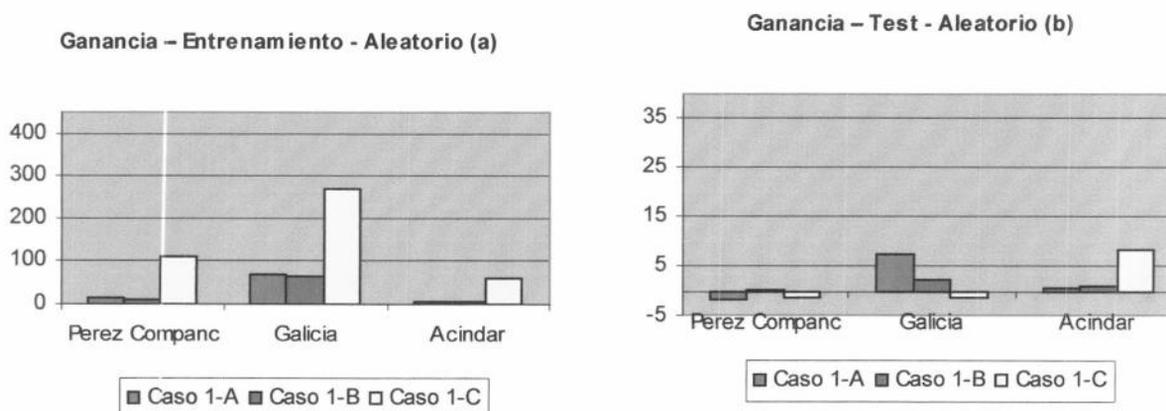


Figura 3.9 – Ganancia con conjunto de datos aleatorio en el entrenamiento (a) y en el test (b)

- Desde el punto de vista de la cantidad operaciones y del porcentaje de éxito:
 - Como puede observarse en las Figuras 3.10 y 3.11 (véanse las Tablas 3.9, 3.10 y 3.11), el porcentaje de operaciones realizadas por el caso 1-

B es mucho menor al que se obtuvo con los casos 1-A y 1-C (menos que la cuarta parte). Lo que provoca estos resultados es que la estrategia utilizada en este caso es más restrictiva que en los otros casos (exige que la tendencia sea estrictamente creciente por tres días) y son pocas las veces en las que se cumple el antecedente de la estrategia empleada. Comparando los porcentajes de operaciones realizadas en los tres casos (véase las Figuras 3.10 y 3.11), podemos ver que la estrategia 1-B realiza una menor cantidad de operaciones tanto en el entrenamiento como en el test: en el entrenamiento los valores son de aproximadamente un 15% para el caso 1-B contra un 60% para los casos 1-A y 1-C. Por otro lado, también se observa que la estrategia 1-B registra menores ganancias que la estrategia 1-C. Como hemos visto anteriormente, si se tiene en cuenta el costo que implica realizar una operación, el porcentaje de operaciones realizadas es un dato que tiene incidencia en la ganancia real. Por lo tanto, para poder evaluar cuál estrategia es más conveniente es necesario tomar una solución de compromiso entre el porcentaje de operaciones realizadas y la ganancia, teniendo en cuenta el costo por operación.

- Como se puede observar en varios de los ejemplos, los porcentajes de éxito no siempre superan el 50% de efectividad, sin embargo estas estrategias igualmente generan ganancias. Esto se debe a que el algoritmo acumula un fracaso al hecho de *“vender a un precio más barato que al momento de comprar”* sin tener en cuenta la magnitud de la diferencia de precios entre ambos momentos. En estos casos particulares sucede que cuando se produce un fracaso, la diferencia de precios es muy poca, pero cuando se producen éxitos la diferencia a favor es mucho mayor.

Por ejemplo, veamos las siguientes 3 operaciones:

Comparamos en Acindar a 1\$ y vendemos a 0.9\$

Comparamos en Acindar a 1\$ y vendemos a 0.8\$

Comparamos en Acindar a 1\$ y vendemos a 1.5\$

En este ejemplo, el porcentaje de éxito es muy bajo (tan solo 33% de éxito), pero la ganancia es positiva (0.2\$)

- Con respecto a la forma en que se toman los datos, secuencial o aleatoria, se puede observar que los porcentajes de éxito obtenidos son mayores cuando se aplica un muestreo aleatorio que cuando se toma uno secuencial, generalmente en el entrenamiento y varias veces en el test (véanse las Tablas 3.9, 3.10 y 3.11 y las Figuras 3.12 y 3.13). Esto se debe al comportamiento no estacionario y altamente no lineal de las series modeladas. Si el objetivo de la predicción se reduce a tener un número importante de aciertos, independientemente de la ganancia, la selección aleatoria parece promisoría. Si bien en las anteriores experiencias mostramos una única ejecución que valida los resultados obtenidos, se podría lograr un análisis exhaustivo empleando otras técnicas de re-muestreo como las mencionadas anteriormente.

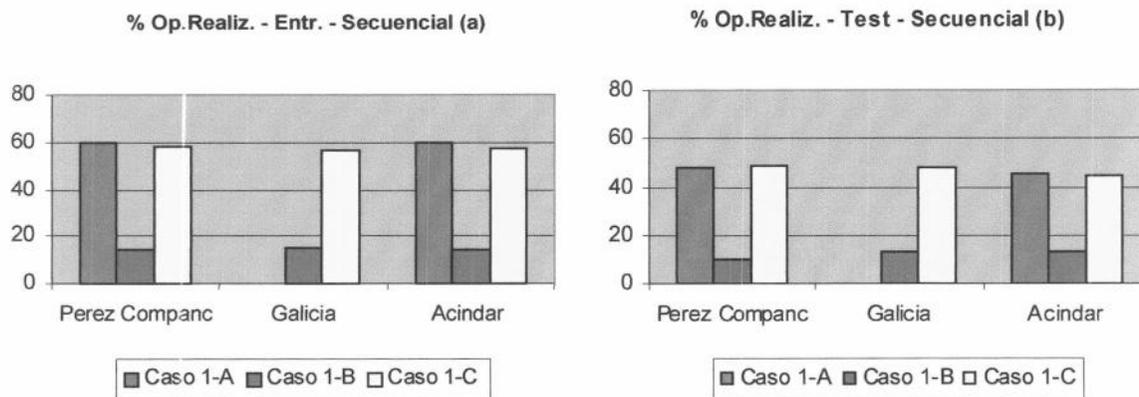


Figura 3.10 – Porcentaje de operaciones realizadas con conjunto de datos secuencial en el entrenamiento (a) y en el test (b)

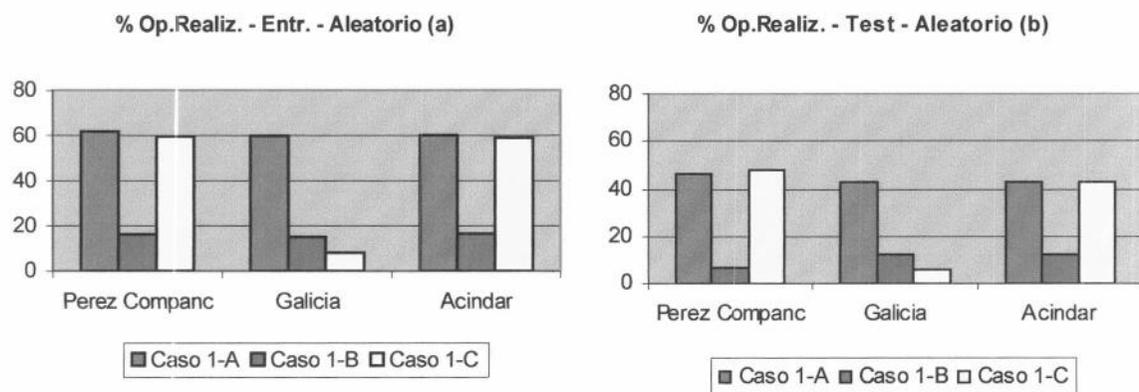


Figura 3.11 – Porcentaje de operaciones realizadas con conjunto de datos aleatorio en el entrenamiento (a) y en el test (b)

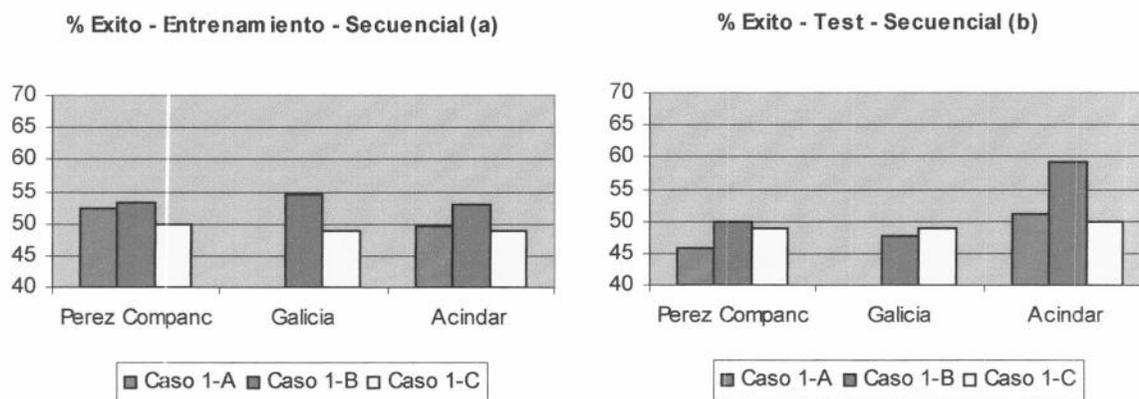


Figura 3.12 – Porcentaje de éxito obtenido con conjunto de datos secuencial en el entrenamiento (a) y en el test (b)

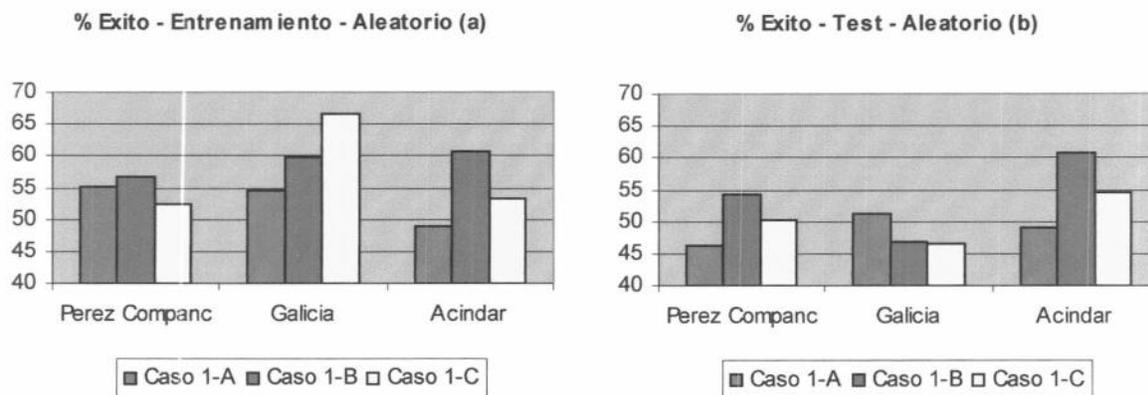


Figura 3.13 – Porcentaje de éxito obtenido con conjunto de datos aleatorio en el entrenamiento (a) y en el test (b)

En base a los resultados obtenidos en estas tres experiencias podemos decir que las estrategias del caso 1-C son las más promisorias, especialmente desde el punto de vista de la obtención de una representación inicial en base a un conjunto de entrenamiento, adecuada para memorizar e identificar. Es capaz de obtener ganancias a partir de ejemplos. Por este motivo han sido utilizadas como base para el segundo grupo de experiencias.

3.5.2. Análisis de los resultados obtenidos en las experiencias con un conjunto de especies

El análisis de los resultados será realizado teniendo en cuenta varios aspectos: ganancia obtenida, porcentaje de operaciones realizadas y porcentaje de éxito obtenido.

- Desde el punto de vista de la ganancia obtenida :
 - Las ganancias obtenidas en este grupo de experiencias con conjuntos de especies, son muy superiores a las que se obtuvieron con el primer grupo de experiencias. Una medida que podemos utilizar para poder hacer una comparación es el promedio de las ganancias obtenidas en las experiencias, tanto en las etapas de entrenamiento como en las de test. Para el primer grupo, los promedios de ganancia obtenida son de 50,06 para el entrenamiento y 2,20 para el test, mientras que para el segundo grupo los valores los superan notablemente: 244,56 y 19,87 respectivamente.
 - El objetivo del caso 2-C es encontrar la mejor estrategia para todas las especies juntas como en los casos anteriores, pero la diferencia es que ahora permite tener reglas distintas para cada especie en particular. Sería equivalente a buscar la mejor estrategia para cada especie. Como

consecuencia de ello, para el muestreo secuencial se obtienen mejores resultados de ganancias que en los casos 2-A y 2-B (Véanse la Figura 3.14 y las Tablas 3.13a, 3.14a y 3.15a). Cuando se utilizó un muestreo aleatorio, las ganancias obtenidas en el test no han sido las mejores (véase la Figura 3.15). Aquí también se podría realizar un análisis más exhaustivo aplicando las técnicas de re-muestreo ya mencionadas.

- Cabe destacar que para los casos 2-A y 2-B secuenciales (véanse la Figura 3.14 y las Tablas 3.13a y 3.14a) los resultados fueron iguales debido a que la estrategia del caso 2-B incluye a la del caso 2-A y el algoritmo eligió para ambos casos los mismos individuos.

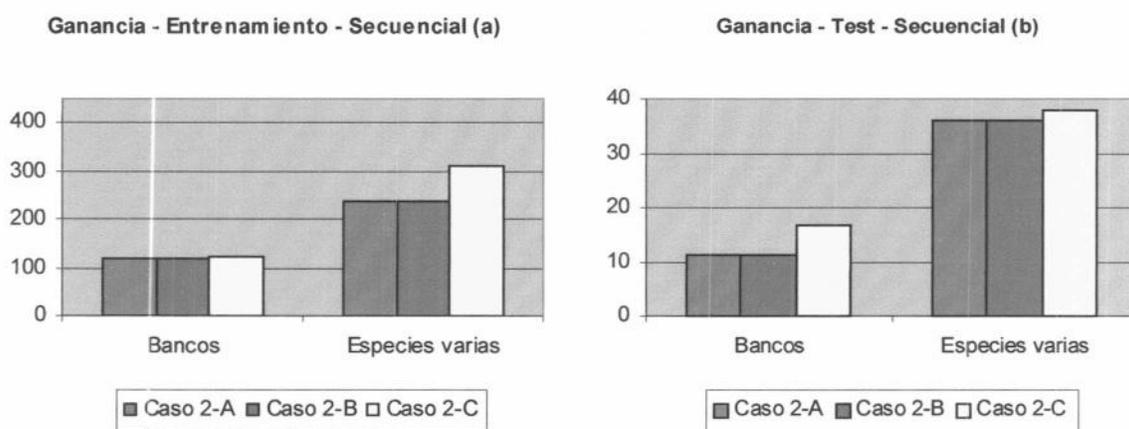


Figura 3.14 – Ganancia con conjunto de datos secuencial en el entrenamiento (a) y en el test (b)

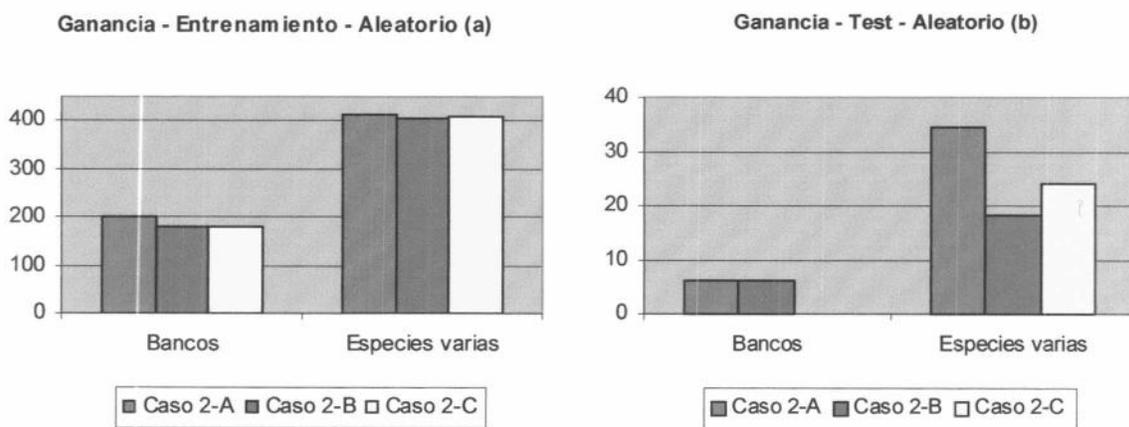


Figura 3.15 – Ganancia con conjunto de datos aleatorio en el entrenamiento (a) y en el test (b)

- Desde el punto de vista de la cantidad de operaciones y del porcentaje de éxito:
 - Como se ve en las Figuras 3.16 y 3.17 (véanse las Tablas 3.13, 3.14 y 3.15), los porcentajes de operaciones realizadas son muy similares para todos los casos. En los entrenamientos rondan el 50% y para los tests son del 45%. Sólo en el caso 2-C se observa una cantidad algo menor de operaciones realizadas. Tal como se vio anteriormente esto es importante ya que no debemos olvidar que *las operaciones en un mercado son realizadas a través de un agente que cobra un porcentaje de comisión tanto al entrar como al salir*. Cuanto menor sea la cantidad de operaciones menor será el costo extra.
 - Es importante destacar que en todos los casos analizados en este grupo, siempre el porcentaje de éxito fue mayor al 50% (recordemos que en el grupo anterior se presentaron casos en los que el porcentaje de éxito era menor al 50%), esto quiere decir que la cantidad de operaciones que dieron ganancia fue mayor a la cantidad de las que dieron pérdida.
 - En particular en el caso 2-C secuencial se logra mayor porcentaje de acierto que en los casos 2-A y 2-B (véanse la Figura 3.18 y las Tablas 3.13a, 3.14a y 3.15a), lo cual es coherente con la evolución de la estrategia. En los casos anteriores la estrategia constaba de una única regla que se usaba para todas las especies; esta regla podía ser muy buena con una especie en particular, pero perder muchas veces con otra especie. Por ello, al permitir que se busquen distintas reglas en el caso 2-C (la mejor para cada especie) logramos aumentar el nivel de efectividad.

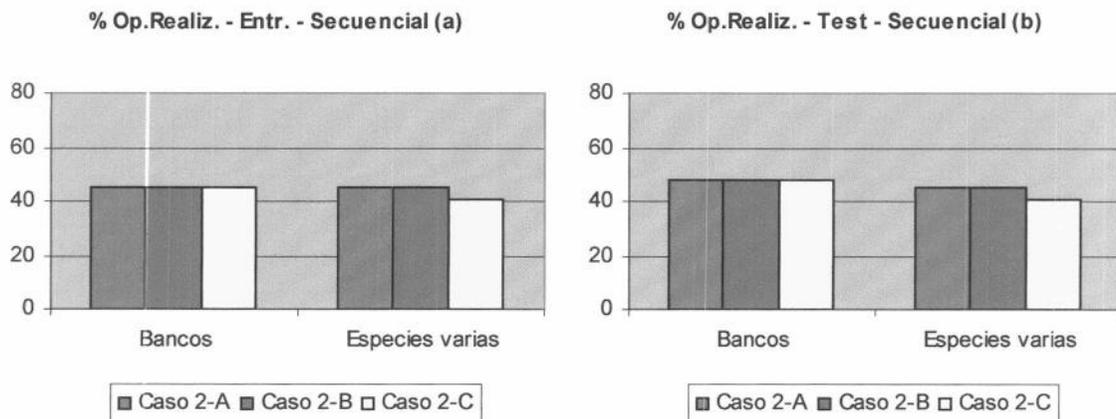


Figura 3.16 – Porcentaje de operaciones realizadas con conjunto de datos secuencial en el entrenamiento (a) y en el test (b)

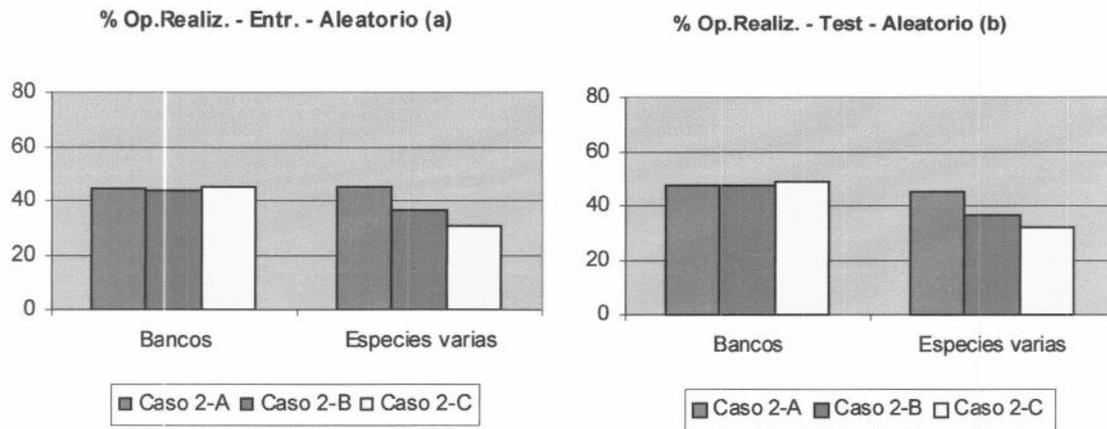


Figura 3.17 – Porcentaje de operaciones realizadas con conjunto de datos aleatorio en el entrenamiento (a) y en el testeo (b)

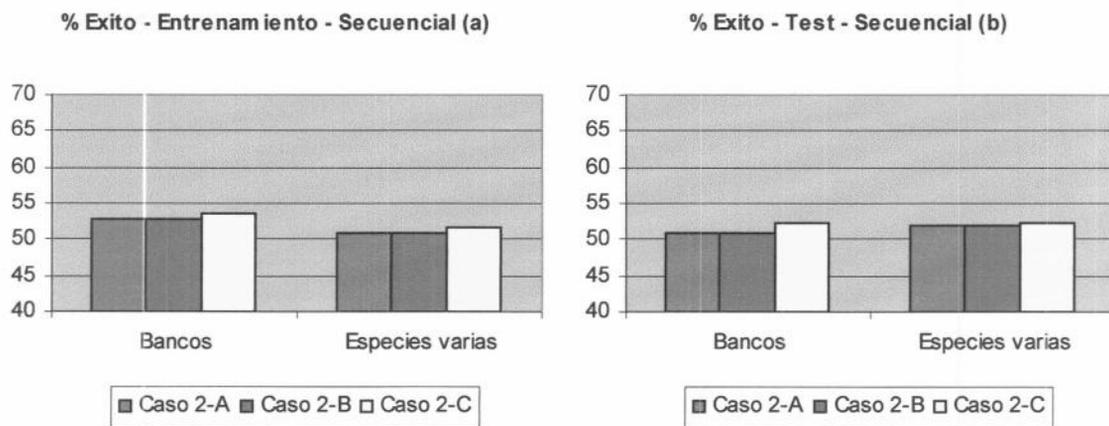


Figura 3.18 – Porcentaje de éxito obtenido con conjunto de datos secuencial en el entrenamiento (a) y en el testeo (b)

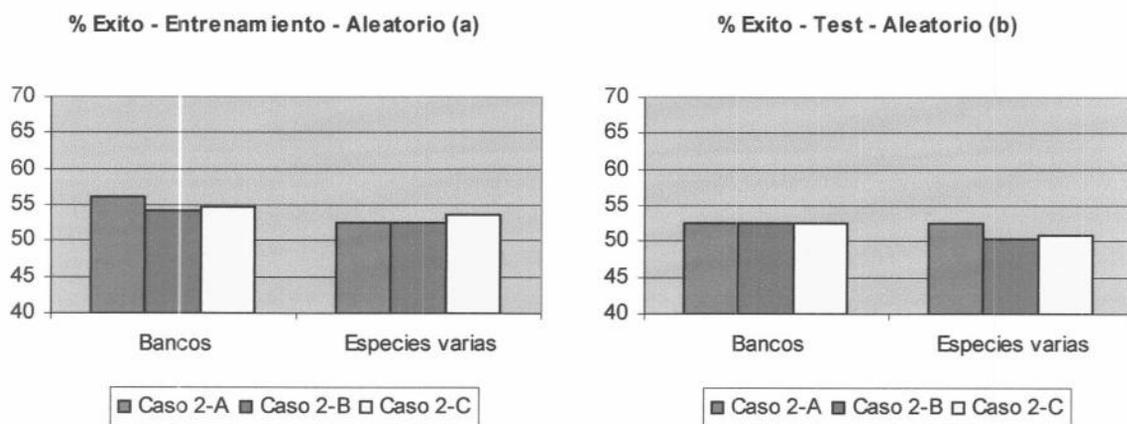


Figura 3.19 – Porcentaje de éxito obtenido con conjunto de datos aleatorio en el entrenamiento (a) y en el testeo (b)

3.5.3. Análisis de los resultados obtenidos en la experiencia con Múltiples Estrategias de Inversión

El análisis de los resultados será realizado teniendo en cuenta varios aspectos: ganancia obtenida, porcentaje de operaciones realizadas, porcentaje de éxito obtenido.

- *Desde el punto de vista de la ganancia obtenida:*
 - En los resultados obtenidos en esta experiencia (véase la Tabla 3.17a y la Figura 3.20) se observa que cuando se utilizó un muestreo secuencial de datos no hubo grandes diferencias con respecto al caso 2-C. Para comprender por qué ocurre esto, hay que considerar que la estrategia aprendida en el caso 2-C está incluida en el conjunto de estrategias aprendidas en esta experiencia (véanse las Tablas 3.16 y 3.18). Esto es porque ambas experiencias coinciden en el procedimiento de aprendizaje empleado. Como se mencionó en la Sección 3.4.1.3, esta experiencia difiere de las anteriores en su mecanismo de inferencia. Esta modificación permite obtener un Sistema de Clasificación formado por varios clasificadores o estrategias y requiere un cuidado especial en la resolución de los conflictos o colisiones que se presentan entre las mismas. De la observación de los resultados se pueden deducir dos hipótesis: la segunda y tercera estrategia nunca fueron aplicadas o si se dieron las condiciones para la aplicación de alguna de ellas se produjo una colisión con la primer estrategia y el mecanismo de resolución determinó que ésta era la mejor.
 - Esto no ocurre de la misma manera para el caso en el que se utilizó muestreo aleatorio (véanse las Tablas 3.15b y 3.17b), donde las ganancias de esta experiencia son mayores a las del caso 2-C en el test pero menores en el entrenamiento. La diferencia de ganancia que existe en la etapa de entrenamiento es producida por las características del muestreo utilizado, como fue observado en el capítulo anterior. En el test, la participación de varias estrategias permite que las ganancias sean mayores en más de un 200%. Esto se debe a que los cambios realizados en el mecanismo de inferencia permiten trabajar con un conjunto de estrategias más complejo que las estrategias individuales utilizadas en las experiencias anteriores, que reconoce una mayor cantidad de situaciones y logra una captación más clara de la función de inversión.

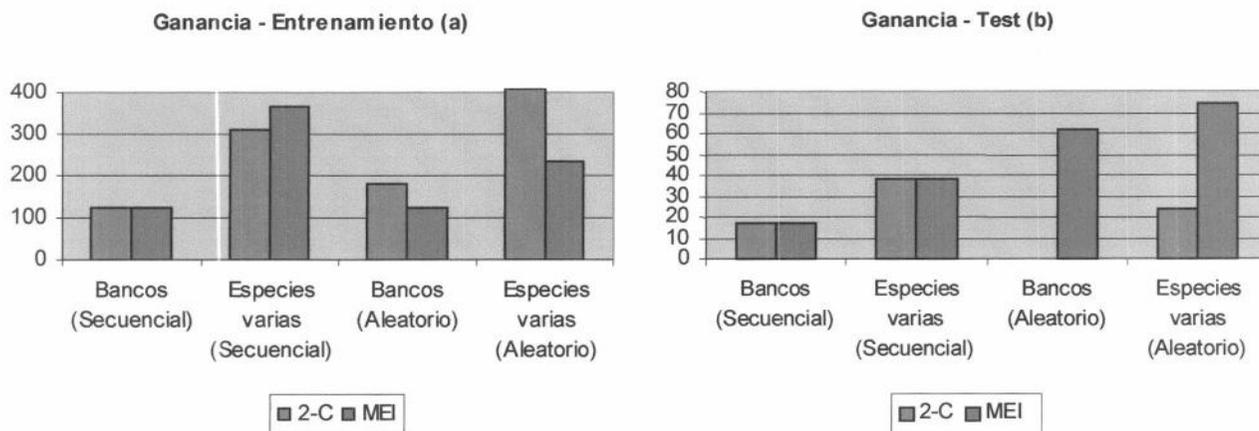


Figura 3.20 – Comparación de la ganancia obtenida entre la experiencia 2-C y la experiencia con MEI

- Desde el punto de vista de la cantidad de operaciones y del porcentaje de éxito:
 - Si se comparan los resultados obtenidos en esta experiencia con los del caso 2-C, podemos ver que el primero sólo realiza una mayor cantidad de operaciones en el caso de entrenamiento de Especies Varias con muestreo aleatorio. En todos los demás casos la cantidad es menor o igual (véanse las Tablas 3.15 y 3.17 y la Figura 3.21).
 - Puede observarse que en esta experiencia los porcentajes de éxito han mejorado o igualado los valores obtenidos en el caso 2-C para el test (véase las Tablas 3.15 y 3.17 y las Figuras 3.12, 2.13 y 3.22). La utilización de MEI con su mecanismo de resolución de colisiones para la inferencia mejora la efectividad en la aplicación de las Els. Esto se debe a que al considerar más Els se logra un mayor cubrimiento de las mejores situaciones de compra y de venta, y a que en los casos en que varias de ellas cumplen las condiciones para su aplicación, el sistema elige la que tuvo mejor comportamiento durante el aprendizaje.

3.6. Observaciones Finales

En este Capítulo hemos planteado como objetivo determinar Els que generen ganancias y propusimos la utilización de AGs como herramienta para lograr ese objetivo. Hemos comprobado las bondades de esta técnica para la identificación de diferentes Els.

Las experiencias sobre las que se trabajó fueron divididas en tres grupos. En el primero se trabajó con Els de Tipo I que consideran especies individuales, lo cual nos permitió definir el tipo de estrategia a utilizar en las experiencias posteriores. La estrategia que hemos elegido está formada por una regla

simple de tipo *comprar-mantener o vender-mantener* (véase la Sección 1.5.1) que clasifica tendencias en operaciones de compra o de venta: Si BANSUD baja por 1 días, vender y mantener por 4 días. El tipo de representación de reglas *SI-ENTONCES* permite una mayor interpretabilidad que otros métodos y un fácil manejo por parte de los expertos que puedan comprender la dinámica del proceso de inversión. Estas primeras experiencias muestran la posibilidad de aprender una estrategia óptima en un ambiente no supervisado y generalizar su aplicación a circunstancias no observadas. El segundo grupo, que utiliza Els de Tipo II, combina reglas en estrategias compuestas que en forma conjunta obtengan un mejor rendimiento. En el tercero se utilizan MEI que permiten capturar situaciones complejas dentro de las series temporales con el objetivo de maximizar las ganancias observadas.

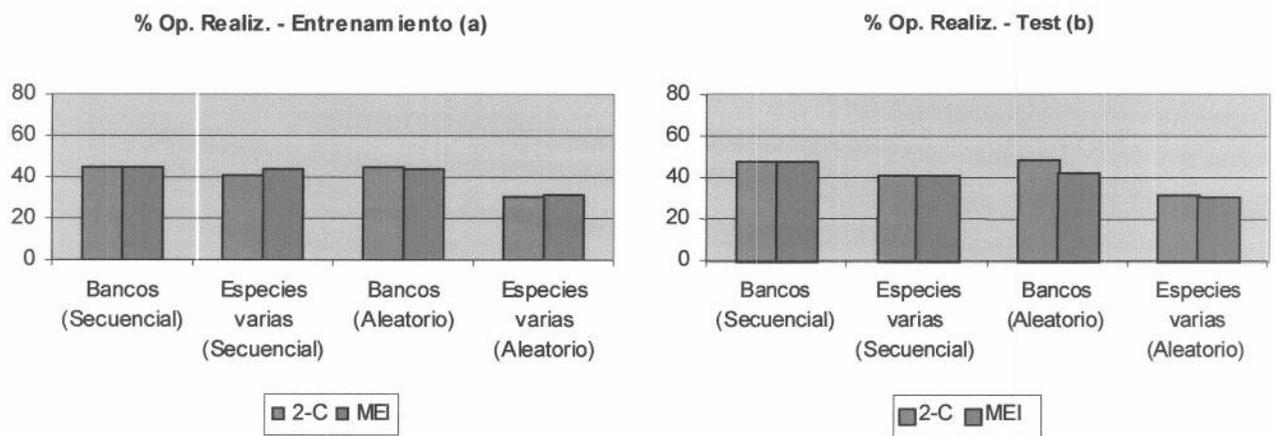


Figura 3.21 – Comparación del porcentaje de operaciones realizadas entre la experiencia 2-C y la experiencia con MEI

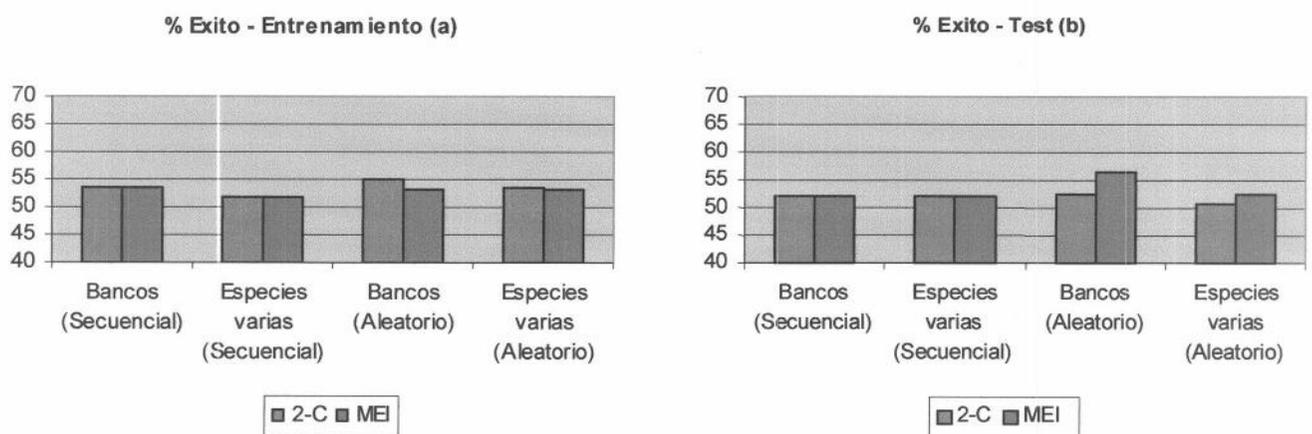


Figura 3.22 – Comparación del porcentaje de éxito obtenida entre la experiencia 2-C y la experiencia con MEI

Como se manifestó en la Sección 1.5.4, en el análisis de las ganancias obtenidas por las diferentes experiencias no se ha tenido en cuenta el costo asociado a la inversión, esto es, la comisión que se debe pagar al agente de bolsa. De todos modos, ha estado presente en el análisis de resultados ya que este costo es directamente proporcional a la cantidad de operaciones realizadas que sí formaron parte de los aspectos estudiados.

El aumento en la capacidad de representación de las estrategias nos ha permitido seleccionar aquellas que resultan más promisorias teniendo en cuenta los distintos factores analizados: ganancia, porcentaje de éxito y porcentaje de operaciones realizadas. Este incremento se ve reflejado en los grupos de experiencias. En el primer grupo se incorporaron otros parámetros: tipo de operación, cantidad de días observación de la tendencia y tipo de tendencia. En el segundo grupo de experiencias, las estrategias pasaron a estar formadas por más de una regla. En el tercer grupo se utilizó un mecanismo de inferencia que soporta un esquema con MEIs.

Finalmente, las estrategias aprendidas parecen ser un tanto restrictivas en lo que se refiere a su capacidad de representación. Esta observación se refiere al concepto de tendencia utilizado: sólo se admiten tendencias estrictamente crecientes o decrecientes. En el siguiente Capítulo, la flexibilización de las nociones de tendencia nos permitirá tratar con los problemas de sobreaprendizaje detectados en el uso del clasificador empleado.

Para ello emplearemos hibridaciones más complejas de acuerdo a las técnicas mencionadas en las Secciones 2.4.6, 2.4.7 y 2.4.8, esto es, SDG, SCBRD y Clustering.

Capítulo 4

Aprendizaje de Estrategias de Inversión como un Sistema de Clasificación Basado en Reglas Difusas

4.1. Introducción

Las experiencias realizadas previamente mediante la utilización del Sistema Clasificador (SC) nos han permitido tener una visión general de la problemática de la operatoria en los mercados.

La utilización de conjuntos difusos como posibles valores de las variables contenidas en las reglas de los SCBRDs permiten agrupar situaciones ambiguas y de esta manera asignarles a dichas situaciones las acciones más convenientes. Este agrupamiento está dado por medio de un criterio de similitud difusa y se corresponde con la elaboración de un clustering sobre la serie temporal [ZWI00] que mapea situaciones, acciones y refuerzos o penalidades similares.

En este Capítulo presentaremos una metodología para el aprendizaje de un Sistema Clasificador Basado en Reglas Difusas (SCBRD) que generen ganancias por medio de Algoritmos Genéticos (AGs). En particular intentaremos solucionar algunos problemas que tienen que ver con la interpretabilidad y la precisión del sistema obtenido. Para ello también estudiaremos dos maneras de aprender la Base de Datos del SCBRD: por medio de equiparticiones y aprendiéndola mediante técnicas de Clustering.

Este Capítulo se encuentra organizado de la siguiente manera. En la Sección 4.2 estudiaremos las motivaciones para la utilización de SCBRDs presentando una clase de ejemplos que no son clasificados adecuadamente por el Sistema Clasificador (SC) clásico del Capítulo anterior. En la Sección 4.3 estudiaremos algunas maneras de aprender los distintos componentes de un SCBRD: la Base de Datos (BD) y la Base de Reglas Lingüísticas (BRL). En la Sección 4.4 describiremos la metodología para el aprendizaje de SCBRD que se utilizará en las experiencias, detallando como se desarrollan cada uno sus pasos. En las Secciones 4.5 y 4.6 presentaremos y analizaremos los resultados obtenidos por las experiencias realizadas respectivamente. Además de las experiencias con el SCBRD también se presentarán resultados obtenidos con SCs clásicos y con técnicas clásicas de inversión utilizadas por los expertos. Finalmente, en la Sección 4.7, se vierten algunos comentarios a modo de conclusión.

4.2. Motivación para el uso de Sistemas Clasificadores Basados en Reglas Difusas

En el Capítulo 3 de esta tesis hemos estado trabajando con Els con el siguiente formato:

Si tendencia es creciente por n días, entonces comprar y mantener por m días

donde la condición es *creciente por n días* es verdadera sólo cuando todos los valores de precio de cierre (VC) son estrictamente crecientes, esto es:

$$\forall i: 2 \leq i \leq 6: VC_i > VC_{i-1}$$

En otras palabras, la operación se realiza sólo si el precio de cierre se ha ido incrementando durante n días.

En este Capítulo proponemos modificar la definición de tendencia que hemos estado utilizando, permitiendo una mayor flexibilidad. Decir que una tendencia es creciente ya no va a significar que el precio de la especie tenga que crecer estrictamente para todos los días involucrados en la estrategia.

Para comprender la necesidad de realizar esta modificación analicemos el siguiente ejemplo (véanse las Figuras 4.1 y 4.2). En el primer gráfico de cotizaciones observamos que los precios se incrementan día a día produciéndose una tendencia que cumple la especificación de *tendencia estrictamente creciente*. No ocurre lo mismo para el caso planteado en el segundo gráfico dado que presenta una secuencia de precios que decrece en el tercer día. Si bien este caso no representa una tendencia estrictamente creciente, cualquier inversor reconocería que representa una buena oportunidad para operar.

Esto requiere una medida que nos indique el crecimiento/decrecimiento de la curva de valores de cotización durante un determinado período de tiempo. Una manera de obtener esta información es utilizando una recta que aproxime la curva (véase Figura 4.3).

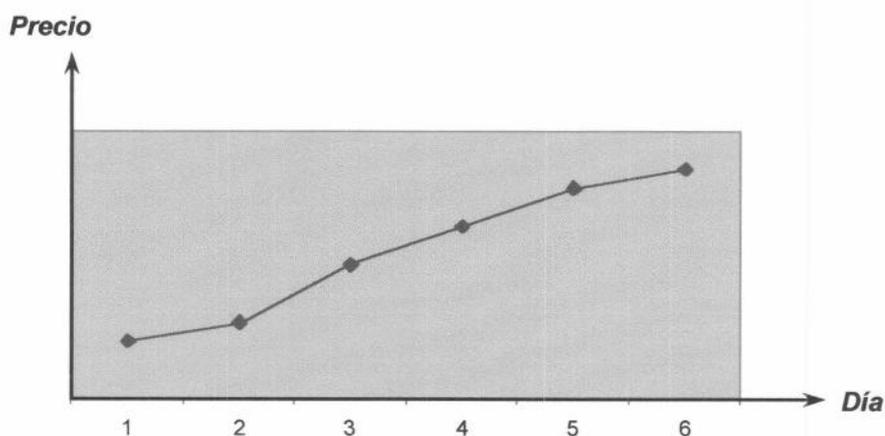


Figura 4.1 – Tendencia estrictamente creciente

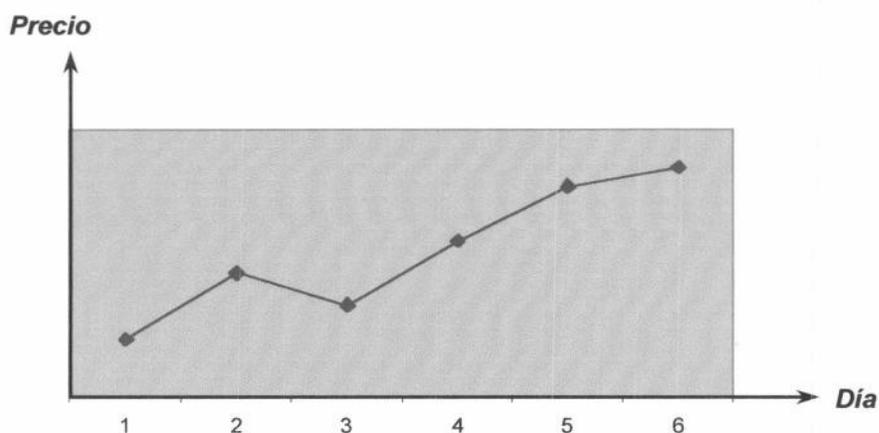


Figura 4.2 – Tendencia no estrictamente creciente

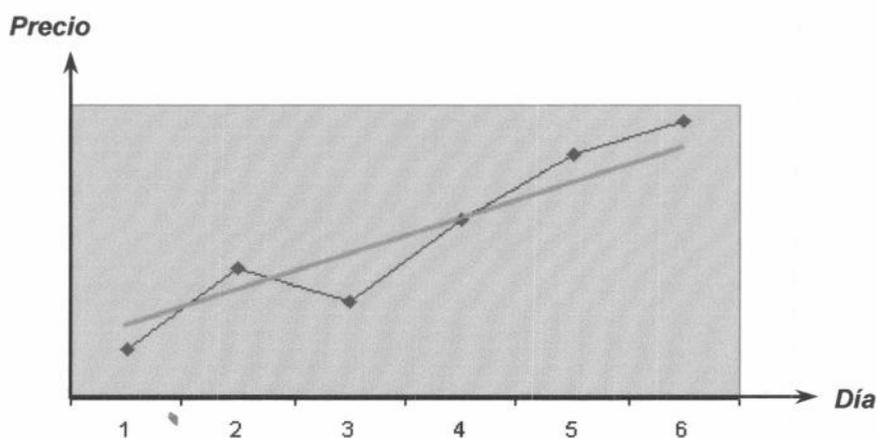


Figura 4.3 – Tendencia creciente determinada por su recta de aproximación

En base a esta recta, y en particular a su pendiente, podremos utilizar valores numéricos que nos permitan realizar una clasificación más flexible que tenga una mejor adaptación a los términos empleados por los inversores y así mejorar su interpretabilidad, como por ejemplo: muy creciente, poco decreciente, etc.

Dado que la pendiente de la recta de aproximación es una variable real y que de acuerdo a lo planteado resulta conveniente utilizar términos lingüísticos en la representación de la tendencia, podemos analizar la posibilidad de usar clasificadores basados en Lógica Difusa (véase la Sección 2.4.7), es decir, SCBRDs.

Los Sistemas Basados en Reglas Difusas (SBRDs) pueden llevar a cabo distintos tipos de modelado, dependiendo del grado de descripción y precisión que deseemos que presente el modelo. Estos dos requisitos, el grado en el

cual es interpretable el modelo por el ser humano y el grado en que ese modelo aproxima al sistema real, suelen estar enfrentados. Por un lado, con información incierta y predicados impreciso, el uso de técnicas basadas en LD, concretamente los SBRDs, nos permiten afrontar el modelado de sistemas, y obtener un modelo cualitativo interpretable por el ser humano. Por otro lado, muchas veces ocurre que el rendimiento del modelo obtenido no es el deseado y preferimos perder en el rendimiento global del modelo para ganar en la claridad de descripción. La decisión entre cuán interpretable y cuán preciso debe ser el modelo a obtener suele depender de las necesidades que se tengan para el problema concreto (véase la Sección 2.4.5).

4.3. Aprendizaje de Sistemas de Clasificación Basados en Reglas Difusas

Como vimos en las secciones anteriores, el objetivo planteado para las experiencias de este capítulo es flexibilizar las nociones de tendencia y con ello mejorar la respuesta en el aprendizaje del AG. Para ello, vamos a construir una partición difusa de la variable *tendencia* que es usada en las EIs. Estas estrategias equivalen a los clasificadores que forman parte de los SCs que se describieron en la Sección 2.4.4

Los procesos de aprendizaje del SC se desarrollarán de la siguiente manera:

- *Sistema de asignación de mérito*: cada vez que una EI o clasificador sea utilizado obtendremos como respuesta una ganancia que nos indicará su fortaleza y nos permitirá determinar el mérito que le corresponde al mismo.
- *Sistema de descubrimiento de clasificadores*: el AG se encargará de descubrir nuevos clasificadores en base a operaciones de cruzamiento en dos puntos y mutación uniforme. La selección de los mejores clasificadores se realizará teniendo en cuenta a los que tengan mayor mérito asignado

Estos procesos de aprendizaje también se utilizan en los SCBRDs cuando se utilizan AGs para la construcción de su Base de Conocimiento (véase la Sección 2.4.6).

4.3.1. Aprendizaje de la Base de Conocimiento de los SCBRDs

La Base de Conocimiento (BC) es la parte esencial de los SCBRDs debido a que las componentes restantes del sistema se ocupan de interpretar las reglas contenidas en ella y hacerlas manejables en problemas concretos. En los SBRDs descriptivos como el que vamos a utilizar para las experiencias, la BC está formada a su vez por dos componentes distintos: la Base de Datos (BD) y la Base de Reglas Lingüísticas (BRL). La BRL está formada por un conjunto de reglas lingüísticas de tipo *SI-ENTONCES* y la BD contiene la definición de los conjuntos difusos asociados a los términos lingüísticos empleados en las reglas de la BRL (véase la Sección 2.4.5.1).

4.3.1.1. Aprendizaje de la Base de Datos

La BD de los SCBRDs sirve de soporte a la BRL dado que contiene la semántica que se asocia a los términos lingüísticos que se emplean en las reglas. Para construir la BD se deben llevar a cabo las siguientes tareas: definir los conjuntos posibles de términos para cada variable lingüística según la granularidad deseada en el sistema, elegir el tipo de función de pertenencia a emplear: triangular, trapezoidal, gaussiana o exponencial y definir la función de pertenencia del conjunto difuso concreto asociado a cada etiqueta lingüística.

Existen dos vías principales para la derivación de la BD: a partir de expertos o a partir de métodos de aprendizaje automático basados en la información numérica existente.

La primer vía a priori parece ser la más adecuada, pero existen varias razones que no permiten llevarla a la práctica: el experto humano no siempre es capaz de expresar su conocimiento sobre el problema en forma de reglas lingüísticas o, simplemente, no existe un experto que pueda aportar información sobre el problema que tratamos de resolver.

Este problema se resuelve generalmente discretizando el dominio de la variable, particionándolo en un número de intervalos uniformes igual al número de etiquetas lingüísticas que se consideren, y asociando a cada intervalo un nombre de etiqueta y un conjunto difuso que defina la semántica de ésta. Otra manera de tratarlo es utilizando alguna técnica de Aprendizaje Automático (AA) para aprender los conjuntos difusos asociados a los términos lingüísticos ya definidos o no a partir del análisis de datos históricos (véase la Sección 2.4.5.2).

4.3.1.2. Aprendizaje de la Base de Reglas Lingüísticas por medio de AGs

La BRL de un SCBRDs está formada por un conjunto de reglas lingüísticas de tipo *SI-ENTONCES* que, en el caso de los SBRDs con múltiples entradas y una única salida, presentan la siguiente estructura:

$$\text{Si } X_1 \text{ es } A_1 \text{ y } \dots \text{ y } X_n \text{ es } A_n \text{ entonces } Y \text{ es } B,$$

donde X_i e Y son variables lingüísticas de entrada y salida respectivamente, y los A_i y B son etiquetas lingüísticas asociadas a dichas variables. La BRL está compuesta por una serie de reglas de este tipo unidas por el operador *además*, lo que indica que todas ellas pueden dispararse ante una entrada concreta.

En un SCBRD se pueden usar distintos tipos de Reglas Difusas (RD): con un identificador de clase en el consecuente, con un identificador de clase y un grado de certeza en el consecuente y con información en el consecuente sobre

el grado de certeza para la clasificación en cada una de las clases (véase la Sección 2.4.7).

La BRL es utilizada por el Método de Razonamiento Difuso (MRD). Este procedimiento de inferencia combina la información brindada por las reglas difusas compatibles con el ejemplo a clasificar para poder predecir su clase. El método más usado es el del máximo (llamado MRD clásico o regla ganadora) que clasifica en la regla más compatible con el ejemplo (véase la Sección 2.4.7.1).

Todos los enfoques existentes para el aprendizaje de la BRL suponen la existencia de una definición previa de la BD, es decir, de un conjunto de funciones de pertenencia que definen la semántica de los términos lingüísticos existentes. De este modo, la tarea del AG en estos procesos automáticos de diseño es la de generar una BRL adecuada para el problema a resolver.

4.4. Una metodología para el aprendizaje de SCBRD que generen ganancias por medio de AGs

El algoritmo del SCBRD utilizado para las experiencias se define en la Figura 4.4.

Paso 1:	Aprendizaje de la Base de Datos
Paso 2:	Aprendizaje de la Base de Reglas Lingüísticas mediante el Sistema de Clasificación que utiliza Algoritmos Genéticos
Paso 3:	Utilización de los clasificadores obtenidos para inferir sobre nuevos ejemplos

Figura 4.4 – Metodología para el aprendizaje de SCBRD

Los distintos pasos representan procesos de aprendizaje e inferencia necesarios para utilizar un SCBRDs.

PASO 1. Aprendizaje de la BD: Como se mencionó en la Sección 4.3.1.1, la BD de un SCBRDs puede ser creada al menos de dos maneras: discretizando el dominio de la variable y construyendo una equipartición con cantidad de intervalos igual al número de etiquetas lingüísticas o utilizando alguna técnica de AA. En este sentido, en la Figura 4.5 se presenta un algoritmo para construir una BD con equiparticiones y en la Figura 4.6 otro algoritmo para construirla mediante la utilización de técnicas de Clustering.

Comencemos por definir cuáles son los valores posibles para nuestra variable de entrada: el ángulo que define la recta que mejor se aproxima a los precios de cierre. Estos valores se encuentran en el rango $[-90^\circ, 90^\circ]$. De todos modos, es necesario obtener una mejor cota para el rango dado que el precio de las distintas especies no varía de la misma manera. Mientras que para algunas sube o baja suavemente, produciendo tendencias con poca pendiente,

en otras los cambios son más bruscos, generando tendencias con una mayor pendiente.

En el caso en el que se utiliza una BD con equiparticiones, para definir este rango se realiza un pre-procesamiento de la serie de precios para aprender el máximo y el mínimo valor de pendiente (Paso BE1). Este rango [pendiente mínima, pendiente máxima] se dividirá en partes iguales según la cantidad definida de términos lingüísticos (Paso BE3).

Para el caso de usar BD aprendidas con técnicas de Clustering la definición de este rango se encuentra implícita en el proceso de descubrimiento de los centroides.

El dominio de la variable lingüística *tendencia* en ambos casos va a estar formado por los siguientes términos comúnmente utilizados por los expertos: *muy decreciente*, *decreciente*, *poco decreciente*, *constante*, *poco creciente*, *creciente* y *muy creciente* (Pasos BE2 y BC1), y la función de pertenencia será triangular.

-
- Paso BE1:** Aprender las pendientes máxima y mínima a partir de los datos históricos
- Paso BE2:** Definir los términos lingüísticos para las variables
- Paso BE3:** Construir equiparticiones del espacio definido por las pendientes máxima y mínima
- Paso BE4:** Asociar cada una de las equiparticiones a los términos lingüísticos definidos previamente
-

Figura 4.5 – Algoritmo para la creación de una Base de Datos con equiparticiones

-
- Paso BC1:** Definir los términos lingüísticos para las variables
- Paso BC2:** Aprender los centroides para los conjuntos difusos asociados a los términos lingüísticos a partir de los datos históricos mediante técnicas de Clustering
- Paso BC3:** Asociar cada una de los centroides a los términos lingüísticos definidos previamente
-

Figura 4.6 – Algoritmo para la creación de una Base de Datos mediante técnicas de Clustering

En las Figuras 4.7 y 4.8 se pueden ver las BD difusas definidas para cada uno de los términos lingüísticos de la variable de entrada creados por equipartición y mediante técnicas de Clustering sobre un mismo conjunto de ejemplos (véase en los Apéndices B y C las BD difusas aprendidas para las especies utilizadas en las experiencias por equipartición y mediante técnicas de Clustering respectivamente).

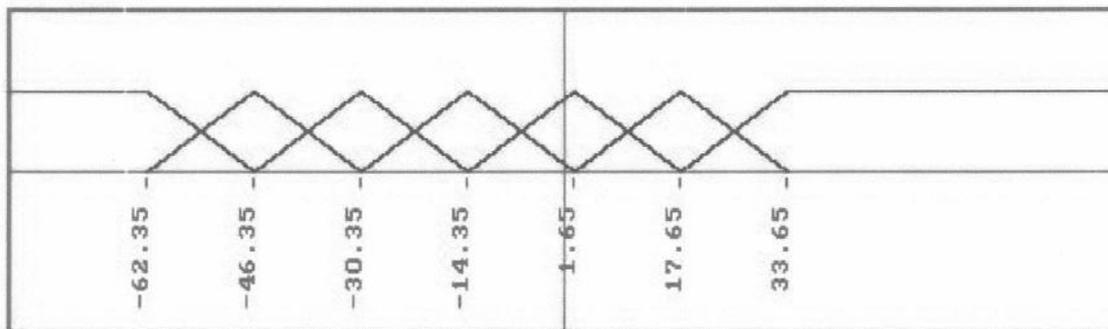


Figura 4.7 – Base de Datos difusa definida por equipartición

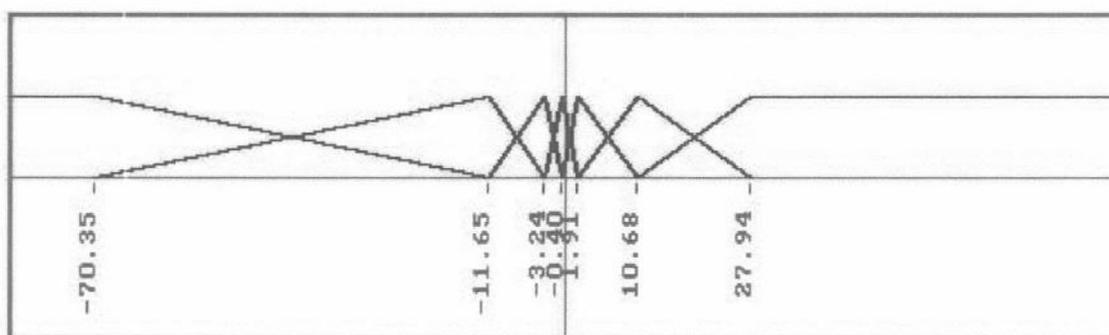


Figura 4.8 – Base de Datos difusa aprendida mediante técnicas de Clustering

PASO 2. Aprendizaje de la BRL: Como vimos en la Sección 2.4.6, existen varios grupos de Sistemas Difuso Genéticos (SDG) según los componentes de la BC que se incluyen en el proceso de aprendizaje genético. En esta metodología haremos uso de los AGs para el aprendizaje de la BRL del SCBRD. La BRL estará compuesta por reglas difusas de Tipo II, es decir EIs que en el consecuente tienen un identificador de clase y un *grado de certeza* (véase Sección 2.4.6).

Dado que los datos utilizados como entrada durante el período de aprendizaje no incluyen información que nos indique a qué clase pertenece un periodo de cotizaciones (compra o venta), el aprendizaje podría considerarse como *no supervisado*. Si bien se recibe una respuesta por la aplicación de la estrategia o clasificador, ésta no proviene de la opinión de un experto y en todo caso sólo puede ser usada para otorgarle un mérito a la estrategia. Como vimos en la Sección 2.4, cuando el clasificador recibe algún tipo de recompensa que le indique qué tan bien está clasificando se dice que el sistema utiliza *aprendizaje por refuerzo*.

Durante el proceso de aprendizaje obtenemos la BRL mediante el uso del AG. En esta etapa, se analizan las EIs para ver si cubren los ejemplos. Para ello se calcula el grado de pertenencia de la pendiente de las cotizaciones del ejemplo a todos los conjuntos difusos asociados con los términos lingüísticos. Luego, mediante la función máximo se determina para cuál etiqueta lingüística el

ejemplo registra un mayor grado de pertenencia. Finalmente, si la etiqueta lingüística codificada en la estrategia coincide con la del ejemplo entonces este ejemplo está cubierto por ella y el AG le asigna un mérito en función de la ganancia obtenida. Una vez finalizado el proceso de aprendizaje se le aplica un factor a los méritos obtenidos por la estrategia, que representa la efectividad alcanzada por el clasificador, es decir, el porcentaje de veces que tuvo éxito en la clasificación. El resultado de este producto se denomina *ganancia ponderada* y es utilizado junto con el máximo grado de pertenencia de un nuevo ejemplo a los conjuntos difusos para determinar el *grado de certeza* de la estrategia que es utilizado por el mecanismo de inferencia (véase el Paso 3).

La construcción de la BRL del SCBRD está inspirada en el Método de Generación de Reglas para Clasificación de Wang y Mendel [WAN92], si bien no contempla todas las etapas definidas en el mismo (véase el Apéndice D).

PASO 3. *Utilización de los clasificadores obtenidos para inferir sobre nuevos ejemplos:* Una vez construida la BRL podemos utilizar el SCBRD para clasificar nuevos casos. El mecanismo de inferencia utilizado debe contemplar la posibilidad de que un ejemplo puede ser cubierto por más de una de las EIs presentes en la BRL. Cuando se presentan estas situaciones decimos que hay un conflicto y el mecanismo de inferencia es el encargado de elegir, mediante algún criterio establecido, la EI que mejor cubre al ejemplo. En nuestra metodología utilizamos el Método de Razonamiento Difuso (MRD) clásico, que elige la regla que tiene asociado el máximo valor de grado de certeza (véase la Sección 2.4.7.3).

Ejemplo:

El siguiente ejemplo muestra cómo se resuelven los conflictos que se presentan cuando puede aplicarse más de una regla para la inferencia sobre un nuevo caso.

Supongamos que nuestra BRL incluye las siguientes estrategias:

- EI_1 : *Si la tendencia es creciente por 3 días, entonces comprar y mantener por 5 días (mérito=1.6)*
- EI_2 : *Si la tendencia es muy creciente por 2 días, entonces comprar y mantener por 3 días (mérito=0.4)*
- EI_3 : *Si la tendencia es creciente por 6 días, entonces comprar y mantener por 2 días (mérito=1.4)*

Tomemos como ejemplo dos días diferentes para analizar el grado de pertenencia a los conjuntos difusos definidos para los términos creciente y muy creciente, que aparecen en nuestra BR:

- Día A:
El conjunto difuso que presenta mayor grado de pertenencia es *muy creciente* (con pertenencia 0.7 para 2 días). Por lo tanto la única estrategia aplicable es EI_2 :

Si la tendencia es muy creciente por 2 días (0.7), entonces comprar y mantener por 3 días (0.4)

- Día B:
El conjunto difuso que presenta mayor grado de pertenencia es *creciente* (con pertenencia 0.5 para 3 días y pertenencia 0.8 para 6 días).

Si la tendencia es creciente por 3 días (0.5), entonces comprar y mantener por 5 días (1.6)

Si la tendencia es creciente por 6 días (0.8), entonces comprar y mantener por 2 días (1.4)

En este caso, estamos frente a un conflicto por lo que debemos calcular los grados de certeza asociados a las estrategias:

$$Gc(EI_1) = 0.5 \times 1.6 = 0.8$$

$$Gc(EI_3) = 0.8 \times 1.4 = 1.12$$

Por lo tanto, dado que nuestro método de razonamiento difuso emplea el MRD clásico, se elige la estrategia que tiene el mayor Gc para el día B que resulta ser EI_3 .

4.5. Experiencias

Los conjuntos de datos utilizados en las experiencias y los criterios de evaluación de las EI s de este Capítulo son los mismos que se han empleado para las experiencias del Capítulo anterior. Para estudiar el comportamiento del SCBRD, el algoritmo se ejecutó sobre las siguientes especies en forma individual: ACINDAR, ASTRA, BANSUD, SIDERCA, RENAULT y COMERCIAL DEL PLATA. En la Sección 4.5.2, se encuentran las experiencias realizadas con SC clásicos. En la Sección 4.5.3, podemos observar los resultados de las experiencias realizadas con un SCBRD con BD uniforme. En la Sección 4.5.4, se presentan los resultados de las experiencias realizadas con un SCBRD con BD aprendida con técnicas de Clustering. Finalmente, en la Sección 4.5.5 se encuentran los resultados obtenidos mediante la utilización de técnicas clásicas de inversión utilizadas por los expertos.

4.5.1. Codificación y parámetros

Las experiencias con el SC clásico serán realizadas con la misma estrategia y codificación para el cromosoma que se han utilizado para la experiencia con

Múltiples Estrategias de Inversión (MEI) de la Sección 3.4.1.3 aplicadas a especies individuales.

Definiremos a continuación las Els que se van a emplear en las dos experiencias en las que se utilizará el SCBRD, su representación binaria en el cromosoma y los parámetros específicos para cada una.

- *Estrategia:* Para estas experiencias hemos modificado la condición del antecedente flexibilizando la definición de tendencia. Ahora podemos representarla mediante distintos términos lingüísticos (muy decreciente, decreciente, poco decreciente, constante, poco creciente, creciente, muy creciente).

Las estrategias son del tipo: Si [tendencia *poco creciente* por n días] entonces [comprar/vender y mantener por m días]

- *Codificación del cromosoma:* La nueva estructura del cromosoma está conformada por 10 bits (véase la Figura 4.9). De izquierda a derecha:

- Posiciones 1, 2 y 3) Estos 3 primeros bits representan a la variable lingüística tendencia de la estrategia que se está evaluando. Los posibles valores y sus significados son los siguientes:
 - 001: Muy Decreciente
 - 010: Decreciente
 - 011: Poco Decreciente
 - 100: Constante
 - 101: Poco Creciente
 - 110: Constante
 - 111: Muy Creciente
 - 000: No se evalúa
- Posiciones 4, 5 y 6) Representan los días durante los cuales se evalúa la tendencia.
- Posición 7) Indica si se va a operar una compra o una venta (1 y 0 respectivamente)
- Posiciones 8, 9 y 10) Representan los días durante los cuales se mantiene las especias compradas o vendidas antes de vender o comprar (respectivamente)

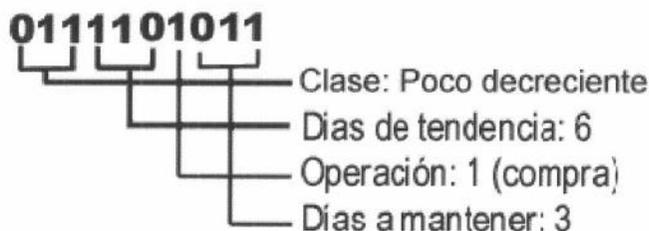


Figura 4.9 – Ejemplo de cromosoma (estrategia: si la especie es poco decreciente por 6 días, comprar y mantener por 3 días)

- *Parámetros*: Los parámetros empleados pueden observarse en la Tabla 4.1

Parámetros	
Tamaño del cromosoma	10 genes
Cantidad de individuos distintos	$2^{10} = 512$
Tamaño de la población inicial	200 individuos
Cantidad de Generaciones	3000

Tabla 4.1 – Parámetros utilizados

La descripción de las abreviaturas utilizadas puede observarse en la tabla 4.2

Abreviatura	Significado
Est	Estrategia aprendida, es una referencia a la tabla 3.8
%Op	Porcentaje de operaciones realizadas respecto al total de operaciones posibles.
%Ex	Porcentaje de éxito obtenido en las operaciones
Ga	Ganancia acumulada en las operaciones realizadas (Ganancia de la estrategia)
Gp	Ganancia ponderada de la estrategia (producto entre %Ex y Ga)

Tabla 4.2 – Descripción de las abreviaturas utilizadas.

La información que presentan las tablas muestran los resultados obtenidos luego de ejecutar el proceso sobre el conjunto de entrenamiento y sobre el conjunto de test usando la mejor estrategia y las 3 mejores estrategias obtenidas en la última población del aprendizaje.

En las Tablas 4.4, 4.6 y 4.8 pueden verse las descripciones de los 3 cromosomas (estrategias) seleccionados para cada especie.

4.5.2. Resultados obtenidos en las experiencias con Múltiples Estrategias de Inversión

Los resultados obtenidos en las experiencias se observan en la Tabla 4.3. La explicación correspondiente a las estrategias utilizadas (y los cromosomas seleccionados) se puede ver en la Tabla 4.4.

Entrenamiento mejor estrategia						Testeo mejor estrategia				
Especie	Est	%Op	%Ex	Ga	Gp	Est	%Op	%Ex	Ga	Gp
Acindar	(1)	38.00	51.75	18.38	9.51	(1)	41.40	46.38	0.90	0.42
Astra	(4)	16.67	50.80	2.41	1.22	(4)	22.40	57.14	1.67	0.95
Bansud	(7)	33.13	53.52	28.31	15.15	(7)	46.60	51.07	3.50	1.79
Siderca	(10)	8.93	54.48	0.62	0.34	(10)	11.00	49.09	-3.11	-1.53
Renault	(13)	4.27	53.13	30.98	16.46	(13)	3.00	53.33	-0.67	-0.36
Com. Plata	(16)	35.33	51.70	9.28	4.80	(16)	46.20	52.81	5.22	2.76
Entren. 3 mejores estrategias						Testeo 3 mejores estrategias				
Especie	Est	%Op	%Ex	Ga	Gp	Est	%Op	%Ex	Ga	Gp
Acindar	(1-3)	46.75	52.41	38.61	20.23	(1-3)	41.40	46.38	0.90	0.42
Astra	(4-6)	28.92	51.58	7.11	3.67	(4-6)	32.80	52.44	1.44	0.75
Bansud	(7-9)	40.25	53.21	52.66	28.02	(7-9)	46.60	51.07	3.50	1.79
Siderca	(10-12)	13.67	54.88	1.74	0.96	(10-12)	15.00	50.67	-2.95	-1.50
Renault	(13-15)	4.83	51.72	57.65	29.82	(13-15)	3.00	53.33	-0.67	-0.36
Com. Plata	(16-18)	65.75	53.11	33.13	17.59	(16-18)	62.40	47.12	0.18	0.08

Tabla 4.3 – Resultados obtenidos sin utilizar SCBRD

Descripción de las estrategias aprendidas en las experiencias
(1) Si ACINDAR baja por 1 días, vender y mantener por 7 días (00010111)
(2) Si ACINDAR baja por 1 días, vender y mantener por 6 días (00010110)
(3) Si ACINDAR baja por 1 días, vender y mantener por 5 días (00010101)
(4) Si ASTRA sube por 2 días, vender y mantener por 7 días (10100111)
(5) Si ASTRA sube por 2 días, vender y mantener por 5 días (10100101)
(6) Si ASTRA baja por 3 días, vender y mantener por 7 días (00110111)
(7) Si BANSUD baja por 1 días, vender y mantener por 4 días (00010100)
(8) Si BANSUD baja por 1 días, vender y mantener por 5 días (00010101)
(9) Si BANSUD baja por 1 días, vender y mantener por 1 días (00010001)
(10) Si SIDERCA sube por 3 días, comprar y mantener por 6 días (10111110)
(11) Si SIDERCA baja por 4 días, comprar y mantener por 6 días (01001110)
(12) Si SIDERCA sube por 4 días, comprar y mantener por 7 días (11001111)
(13) Si RENAULT sube por 4 días, comprar y mantener por 5 días (11001101)
(14) Si RENAULT sube por 4 días, comprar y mantener por 4 días (11001100)
(15) Si RENAULT sube por 5 días, comprar y mantener por 5 días (11011101)
(16) Si COM.DEL PLATA baja por 1 días, vender y mantener por 5 días (00010101)
(17) Si COM.DEL PLATA sube por 2 días, comprar y mantener por 7 días (10101111)
(18) Si COM.DEL PLATA sube por 2 días, comprar y mantener por 4 días (10101100)

Tabla 4.4 – Descripciones de las estrategias

4.5.3. Resultados obtenidos en las experiencias con SCBRDs con BD uniforme

Los resultados obtenidos en las experiencias se observan en la Tabla 4.5. La explicación correspondiente a las estrategias utilizadas (y los cromosomas seleccionados) se puede ver en la Tabla 4.6.

Especie	Entrenamiento mejor estrategia					Testeo mejor estrategia				
	Est	%Op	%Ex	Ga	Gp	Est	%Op	%Ex	Ga	Gp
Acindar	(1)	4.60	76.81	31.91	24.51	(1)	7.40	59.46	2.26	1.34
Astra	(4)	22.13	50.30	3.30	1.66	(4)	24.00	63.33	3.68	2.33
Bansud	(7)	64.47	51.71	45.15	23.35	(7)	85.40	55.97	14.32	8.02
Siderca	(10)	22.93	52.91	3.19	1.69	(10)	38.60	52.85	2.51	1.33
Renault	(13)	26.33	51.14	75.08	38.40	(13)	29.00	53.10	6.78	3.60
Com. Plata	(16)	14.53	50.92	5.98	3.04	(16)	4.40	63.64	3.69	2.35
Especie	Entren. 3 mejores estrategias					Testeo 3 mejores estrategias				
	Est	%Op	%Ex	Ga	Gp	Est	%Op	%Ex	Ga	Gp
Acindar	(1-3)	6.67	75	42.88	32.16	(1-3)	8.60	60.47	2.84	1.17
Astra	(4-6)	47.08	50.97	10.30	5.25	(4-6)	40.00	60.00	4.77	2.86
Bansud	(7-9)	89.17	51.42	77.88	40.05	(7-9)	91.80	54.90	13.06	7.17
Siderca	(10-12)	28.75	53.04	7.25	3.85	(10-12)	39.60	54.04	3.59	1.94
Renault	(13-15)	34	51.47	225.20	115.91	(13-15)	29.00	53.10	6.78	3.60
Com. Plata	(16-18)	23.5	52.83	17.85	9.43	(16-18)	5.00	64	4.16	2.66

Tabla 4.5 – Resultados obtenidos utilizando SCBRD

Descripción de las estrategias aprendidas en las experiencias
(1) Si ACINDAR es constante por 6 días, vender y mantener por 7 días (1001100111)
(2) Si ACINDAR es constante por 5 días, vender y mantener por 7 días (1001010111)
(3) Si ACINDAR es constante por 6 días, vender y mantener por 6 días (1001100110)
(4) Si ASTRA es poco creciente por 2 días, vender y mantener por 7 días (1010100111)
(5) Si ASTRA es poco creciente por 4 días, vender y mantener por 6 días (1011000110)
(6) Si ASTRA es poco creciente por 3 días, vender y mantener por 6 días (1010110110)
(7) Si BANSUD es constante por 2 días, vender y mantener por 7 días (1000100111)
(8) Si BANSUD es constante por 7 días, vender y mantener por 7 días (1001110111)
(9) Si BANSUD es constante por 6 días, vender y mantener por 7 días (1001100111)
(10) Si SIDERCA es poco creciente por 5 días, vender y mantener por 4 días (1011010100)
(11) Si SIDERCA es muy creciente por 4 días, vender y mantener por 7 días (1111000111)
(12) Si SIDERCA es muy creciente por 7 días, vender y mantener por 6 días (1111110110)
(13) Si RENAULT es poco creciente por 5 días, vender y mantener por 7 días (1011010111)
(14) Si RENAULT es creciente por 7 días, comprar y mantener por 6 días (1101111110)
(15) Si RENAULT es creciente por 7 días, comprar y mantener por 7 días (1101111111)
(16) Si COM.DEL PLATA es constante por 7 días, vender y mantener por 7 días (1001110111)
(17) Si COM.DEL PLATA es constante por 3 días, vender y mantener por 7 días (1000110111)
(18) Si COM.DEL PLATA es constante por 3 días, vender y mantener por 5 días (1000110101)

Tabla 4.6 – Descripciones de las estrategias

4.5.4. Resultados obtenidos en las experiencias con SCBRDs con BD aprendida por Clustering

Los resultados obtenidos en las experiencias se observan en la Tabla 4.7. La explicación correspondiente a las estrategias utilizadas (y los cromosomas seleccionados) se puede ver en la Tabla 4.8.

Entrenamiento mejor estrategia						Test mejor estrategia				
Especie	Est	%Op	%Ex	Ga	Gp	Est	%Op	%Ex	Ga	Gp
Acindar	(1)	2.20	81.82	29.95	24.50	(1)	1.80	55.56	0.09	0.052
Astra	(4)	5.80	66.67	3.06	2.04	(4)	2.80	85.71	0.64	0.55
Bansud	(7)	40.27	52.15	33.03	17.23	(7)	44.40	58.11	5.38	3.12
Siderca	(10)	2.93	72.73	4.15	3.02	(10)	14.60	43.84	1.63	0.72
Renault	(13)	17.20	53.10	99.13	52.64	(13)	21.80	55.05	6.08	3.35
Com. Plata	(16)	33.00	50.30	9.68	4.87	(16)	66.40	57.53	8.89	5.12
Entren. 3 mejores estrategias						Test 3 mejores estrategias				
Especie	Est	%Op	%Ex	Ga	Gp	Est	%Op	%Ex	Ga	Gp
Acindar	(1-3)	3.17	73.68	35.49	26.15	(1-3)	2.00	60.00	0.11	0.07
Astra	(4-6)	10.25	65.04	6.59	4.29	(4-6)	3.60	88.89	0.93	0.83
Bansud	(7-9)	61	50.68	65.07	32.98	(7-9)	59.40	58.59	8.47	4.96
Siderca	(10-12)	5.58	67.16	7.18	4.82	(10-12)	23.20	45.69	2.44	1.12
Renault	(13-15)	26.92	52.01	160.00	83.21	(13-15)	27.00	57.78	7.92	4.58
Com. Plata	(16-18)	55.92	51.71	37.48	19.38	(16-18)	67.60	57.40	9.01	5.17

Tabla 4.7 – Resultados

Descripción de las estrategias aprendidas en los experiencias
(1) Si ACINDAR es decreciente por 7 días, vender y mantener por 7 días (0101110111)
(2) Si ACINDAR es decreciente por 7 días, vender y mantener por 5 días (0101110101)
(3) Si ACINDAR es decreciente por 6 días, vender y mantener por 7 días (0101100111)
(4) Si ASTRA es creciente por 7 días, vender y mantener por 7 días (1101110111)
(5) Si ASTRA es creciente por 3 días, vender y mantener por 5 días (1100110101)
(6) Si ASTRA es creciente por 7 días, vender y mantener por 6 días (1101110110)
(7) Si BANSUD es constante por 2 días, vender y mantener por 6 días (1000100110)
(8) Si BANSUD es constante por 2 días, vender y mantener por 5 días (1000100101)
(9) Si BANSUD es constante por 7 días, vender y mantener por 7 días (1001110111)
(10) Si SIDERCA es creciente por 4 días, vender y mantener por 7 días (1101000111)
(11) Si SIDERCA es muy creciente por 6 días, vender y mantener por 7 días (1111100111)
(12) Si SIDERCA es creciente por 5 días, vender y mantener por 7 días (1101010111)
(13) Si RENAULT es poco creciente por 5 días, vender y mantener por 6 días (1011010110)
(14) Si RENAULT es poco creciente por 4 días, vender y mantener por 6 días (1011000110)
(15) Si RENAULT es poco creciente por 4 días, vender y mantener por 7 días (1011000111)
(16) Si COM.DEL PLATA es constante por 5 días, vender y mantener por 6 días (1001010110)
(17) Si COM.DEL PLATA es creciente por 5 días, comprar y mantener por 7 días (1101011111)
(18) Si COM.DEL PLATA es poco decreciente por 3 días, vender y mantener por 7 días (0110110111)

Tabla 4.8 – Descripciones de las estrategias

4.5.5. Resultados obtenidos en las experiencias con Técnicas Clásicas de Inversión

Si bien la serie de experiencias realizadas muestran una evolución muy positiva en sus resultados, un buen parámetro para contrastar con ellos es desarrollar experiencias de la manera en la que lo hacen los expertos.

En la Sección 1.3.1 hemos visto cómo los expertos deciden qué operación realizar y cuándo llevarla a cabo, en base a dos fuentes principales de información: el Análisis Fundamental y el Análisis Técnico. Primero recordaremos cómo se aplican estas técnicas, para poder determinar cuáles de ellas pueden ser utilizadas para construir experiencias razonables que se puedan comparar con los resultados obtenidos por nuestro sistema clasificador.

Los analistas fundamentales basan sus decisiones en el estudio del comportamiento de un conjunto de variables que en su gran mayoría son de naturaleza cualitativa. Los procedimientos empleados por los expertos en el Análisis Fundamental presentan un alto grado de subjetividad. Esto se convierte en un obstáculo para implementar herramientas computarizadas como también lo es para aplicar técnicas de aprendizaje. Además, se agrega la complejidad que presenta la tarea de recopilar todos los valores de estas variables correspondientes al período que se quiere analizar. Por lo tanto, descartamos estas técnicas ya que observamos que no es posible elaborar una buena predicción de las ganancias que obtendría un analista fundamental.

Por otra parte, el análisis técnico estudia el comportamiento de indicadores y el reconocimiento de un conjunto de figuras en los gráficos de cotización. Para el caso de las figuras, si bien se observa cierta subjetividad en cuanto al reconocimiento de las mismas, la técnica se basa en reglas suficientemente claras que permiten hacer una mecanización del proceso. Por ello, el reconocimiento de figuras será uno de los tipos de experiencias a realizar (véanse las Figuras 4.10, 4.11 y 4.12).

Figuras de Bansud

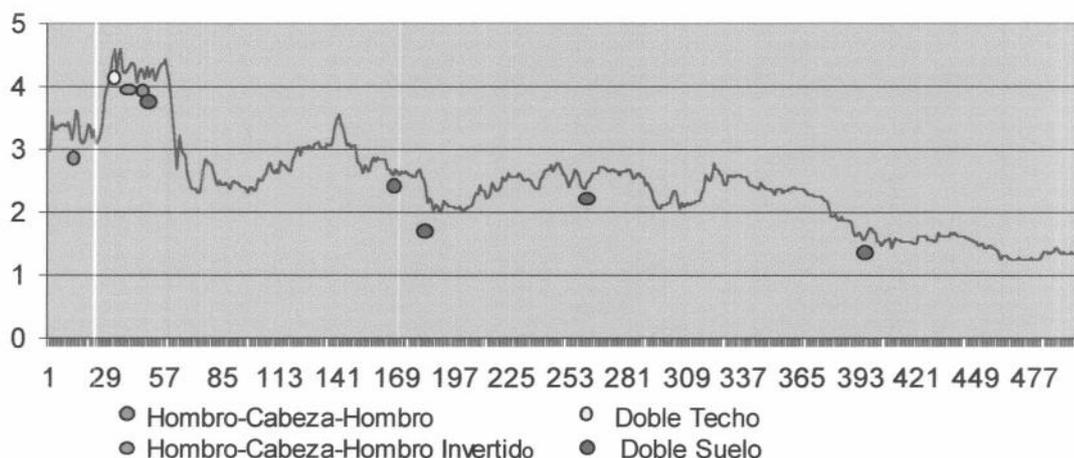


Figura 4.10 – Gráfico de Figuras para Bansud

Figuras de Comercial del Plata

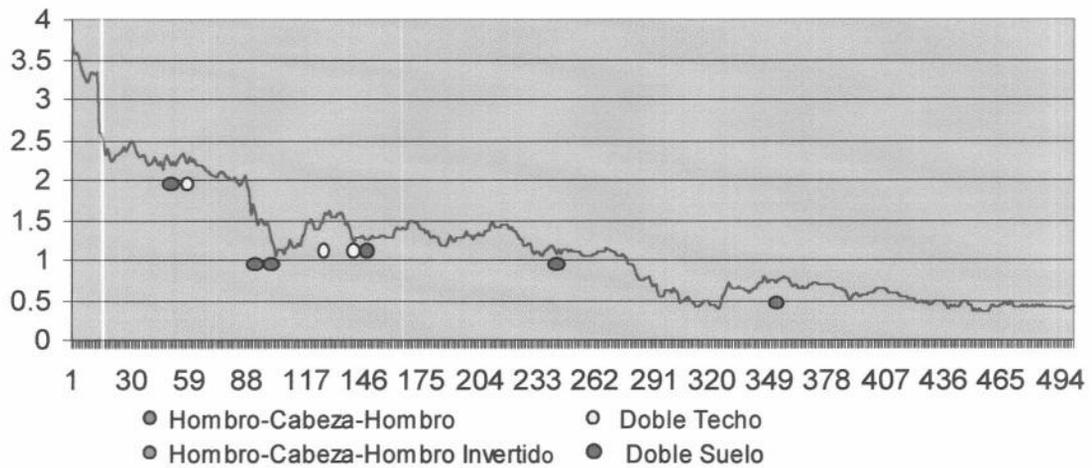


Figura 4.11 – Gráfico de Figuras para Comercial del Plata

Figuras de Renault

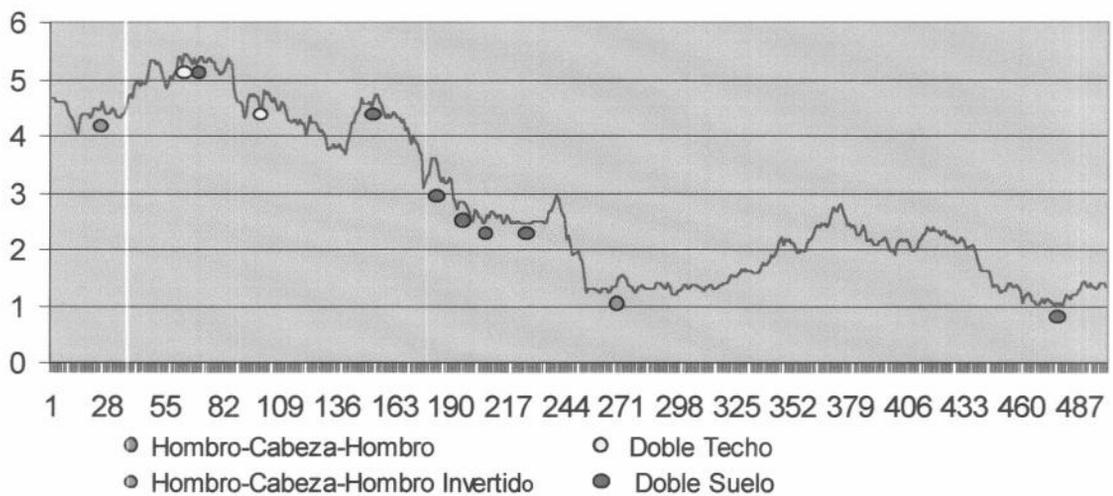


Figura 4.12 – Gráfico de Figuras para Renault

Para estas experiencias utilizaremos las figuras más comúnmente usadas por los expertos: formación de hombro-cabeza-hombro, formación de doble techo, formación de hombro-cabeza-hombro invertido y formación de doble suelo. Las dos primeras predicen una tendencia bajista, mientras que las dos últimas una tendencia alcista. O sea, si nos encontramos con una formación hombro-cabeza-hombro o una formación de doble techo realizamos una venta; y en el

caso de formaciones hombro-cabeza-hombro invertido o formaciones de doble suelo realizamos una compra.

Los indicadores más populares entre los expertos son las Medias Móviles. Este indicador permite detectar señales de compra o de venta con mucha objetividad. Los fundamentos para el uso de este indicador también son bastante simples: se trazan curvas de promedios de cotización y mediante algunas reglas se determinan los puntos significativos.

En la experiencia con Medias Móviles (véase las Figuras 4.13, 4.14 y 4.15) se empleará una media móvil de 20 días. Recordemos que se considera que estamos frente a una señal de compra cuando la curva de la cotización corta en forma ascendente a la curva de la media y frente a una señal de venta cuando la corta en forma descendente.

Medias Móviles de Bansud

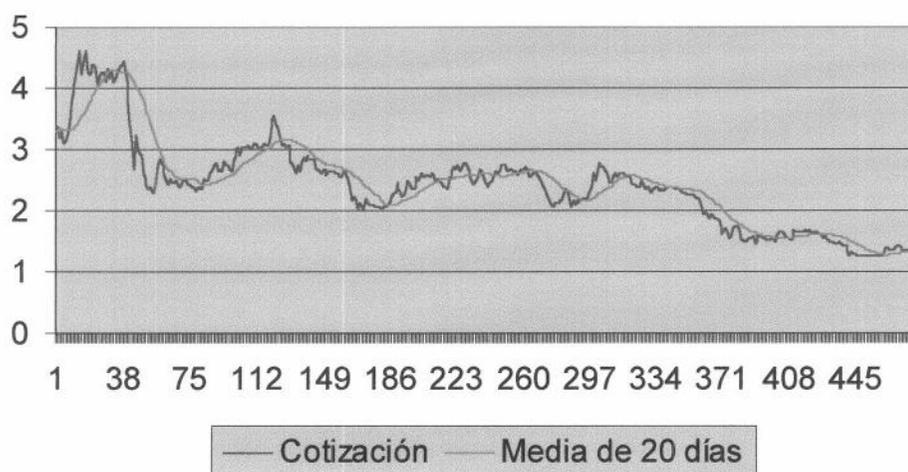


Figura 4.13 – Gráfico de Medias Móviles de 20 y 50 días para Bansud

Medias Móviles de Comercial del Plata

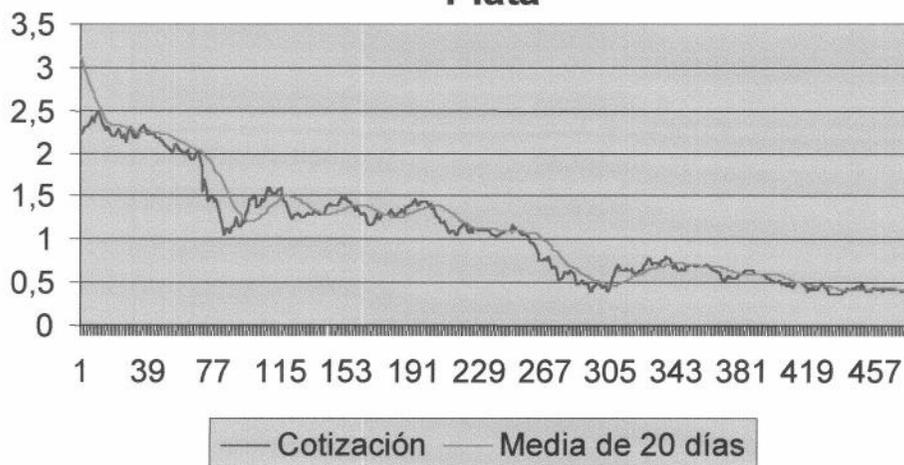


Figura 4.14 – Gráfico de Medias Móviles de 20 y 50 días para Comercial del Plata

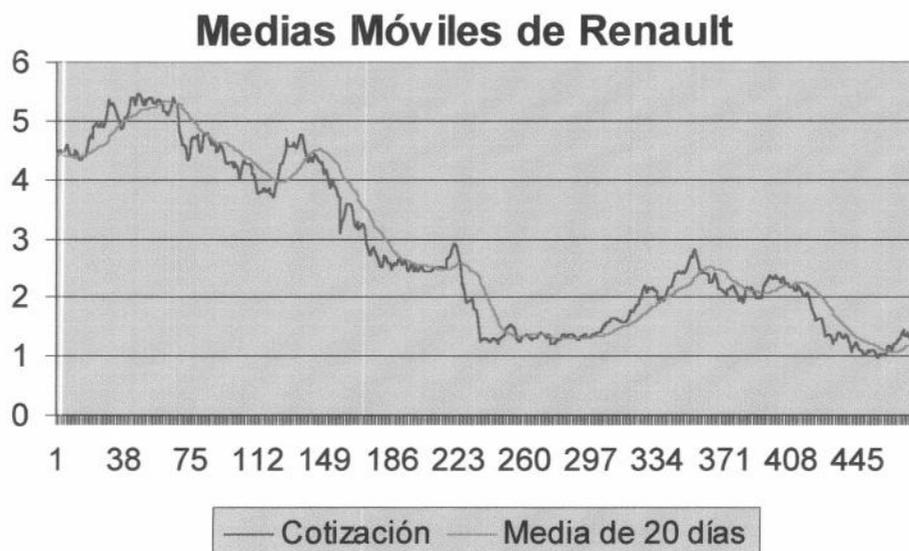


Figura 4.15 – Gráfico de Medias Móviles de 20 y 50 días para Renault

Todas las experiencias fueron realizadas sobre las especies Bansud, Comercial del Plata y Renault y sus resultados se pueden ver en la Tabla 4.9. El período utilizado de 500 días es el mismo que se usó para los tests de las experiencias realizadas previamente.

Identificación de Figuras	%Op	%Ex	Ga	Gp	a)
Bansud	1,40	57,14	0,43	0,24	
Comercial del Plata	2,40	66,70	0,13	0,08	
Renault	3,60	55,60	0,04	0,02	
Cruce de media de 20 días y cotización	%Op	%Ex	Ga	Gp	b)
Bansud	5,21	69,44	2,08	1,44	
Comercial del Plata	5,00	51,06	-0,09	-0,05	
Renault	4,58	47,83	1,48	0,71	
SCBRD mediante técnicas de Clustering	%Op	%Ex	Ga	Gp	c)
Bansud	59.40	58.59	8.47	4.96	
Comercial del Plata	67.60	57.40	9.01	5.17	
Renault	27.00	57.78	7.92	4.58	

Tabla 4.9 – Resultados obtenidos con las técnicas tradicionales a) Figuras, b) Medias Móviles y c) con nuestro SCBRD

4.6. Análisis de Resultados

En las Secciones 4.4.2, 4.4.3, 4.4.4 y 4.4.5 se han presentado los resultados obtenidos para las experiencias realizadas con cada uno de los algoritmos

presentados. Todas las experiencias, excepto con las técnicas tradicionales, han sido realizadas con una y con tres estrategias para destacar los beneficios obtenidos mediante la utilización de MEI. Los resultados muestran que la utilización de tres estrategias genera mayores ganancias debido a que realiza más operaciones porque entre todas cubren una mayor cantidad de ejemplos. Por esto, las comparaciones entre las distintas metodologías serán realizadas en base a los resultados obtenidos por la experiencias con tres estrategias.

4.6.1. Comparación de resultados entre SCBRD con BD uniforme y SC clásicos

El análisis de los resultados será realizado teniendo en cuenta varios aspectos: ganancia obtenida, porcentaje de operaciones realizadas y porcentaje de éxito obtenido.

- Desde el punto de vista de la ganancia obtenida:
 - En las Figuras 4.16 y 4.17 pueden observarse claramente las grandes diferencias a favor de la nueva técnica en cuanto a la ganancia, tanto para el entrenamiento como para el test. Incluso existe un par de especies (Siderca y Renault) que producía pérdida en el test usando el enfoque anterior y que con este nuevo método produce ganancias. (véase Tabla 4.5). Este logro se debe al haber incorporado en esta etapa una nueva manera de tratar las tendencias con el objetivo de poder clasificarlas más correctamente y así poder obtener estrategias mejor especializadas.
 - La nueva clasificación empleada produce ventajas al momento de los test. En los casos anteriores se producían estrategias que solo se expresaban en función de tendencia creciente o decreciente, pero ahora gracias a la clasificación en distintos grupos podemos obtener de la última población del entrenamiento distintas estrategias que usen distintas clases de tendencia, y por lo tanto que generen más ganancias cuando operamos simultáneamente con varias de ellas. Por ejemplo en la especie SIDERCA (véase Tabla 4.5) , cuando se trabaja con tres estrategias, además de operar con las tendencias *poco crecientes* también se operará con las tendencias *muy crecientes*. El conjunto de estrategias consigue un mejor cubrimiento de los ejemplos, por consiguiente aumenta la cantidad de operaciones exitosas realizadas y la ganancia obtenida.
 - Puede observarse que con esta nueva forma de clasificación, a medida que agregamos más estrategias para operar en la fase de test, se incrementa siempre la ganancia, o por lo menos se mantiene igual en algunos casos. Cuando se presenta una igualdad en los valores se debe a que varias de las mejores estrategias obtenidas (y por lo tanto, las estrategias) para cada especie, son similares y tienden a producir conflictos en el test en los que siempre gana la primer estrategia. Es por ello que en algunos casos cuando agregamos una estrategia más

para tenerla en cuenta al momento de operar, ésta no produce cambios en los resultados.

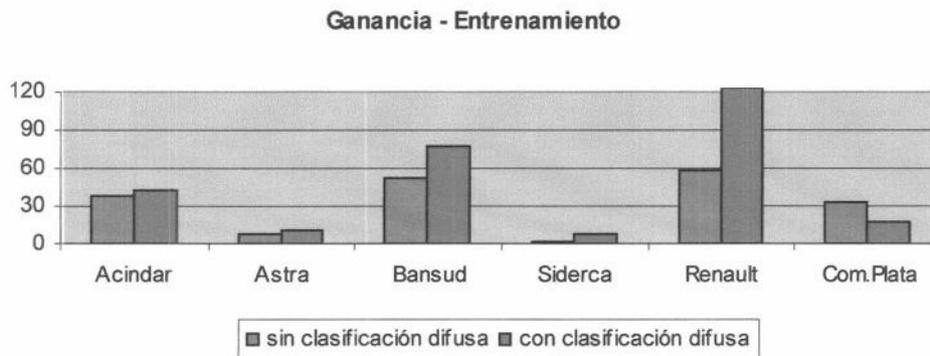


Figura 4.16 – Comparación de ganancia en el entrenamiento

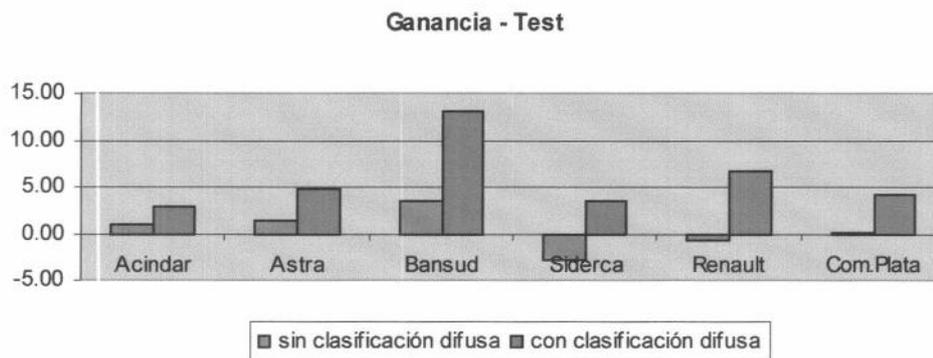


Figura 4.17 – Comparación de la ganancia en el test

- Desde el punto de vista de la cantidad de operaciones y del porcentaje de éxito:
 - En cuanto al porcentaje de operaciones, se puede ver en las Figuras 4.18 y 4.19 (véase Tabla 4.5) que la mayoría de las especies produce un mayor porcentaje de operaciones con este nuevo método. Si observamos las estrategias seleccionadas (véase Tabla 4.6), vemos que la mayoría de ellas se aplica a las clases donde se concentran casi todas las tendencias de los conjuntos de datos (tal como vimos anteriormente, las clases de menor pendiente ya sea positiva o negativa, o, lo que es lo mismo, tendencia creciente o decreciente, son las que concentran la mayor parte de las tendencias). Debido a esto, es razonable que estas estrategias operen una mayor cantidad de veces.
 - En las Figuras 4.20 y 4.21 (véase Tablas 4.3 y 4.5) puede observarse la comparación del porcentaje de éxito entre ambas técnicas, en el entrenamiento y en el test respectivamente. Los resultados obtenidos en el entrenamiento son muy similares, pero al ser evaluadas en el conjunto de test, pueden observarse mejores resultados a favor de la

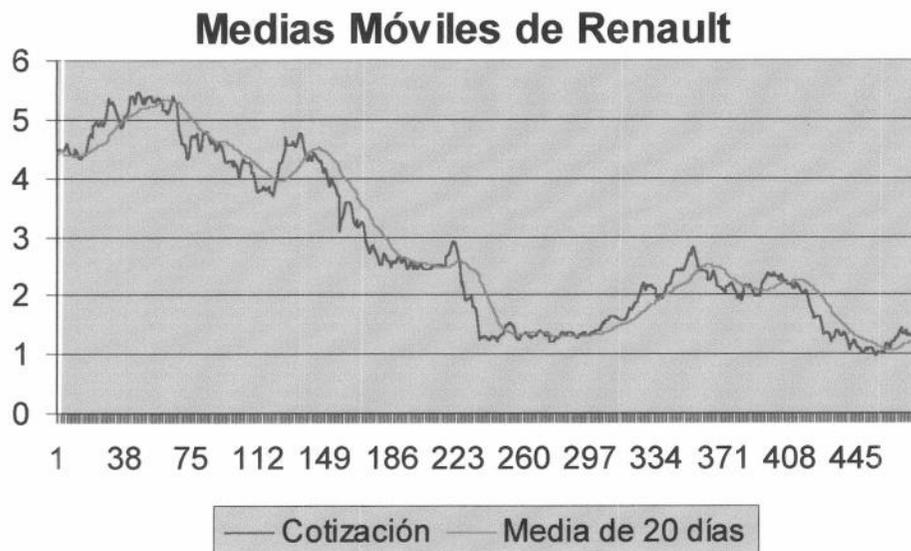


Figura 4.15 – Gráfico de Medias Móviles de 20 y 50 días para Renault

Todas las experiencias fueron realizadas sobre las especies Bansud, Comercial del Plata y Renault y sus resultados se pueden ver en la Tabla 4.9. El período utilizado de 500 días es el mismo que se usó para los tests de las experiencias realizadas previamente.

Identificación de Figuras	%Op	%Ex	Ga	Gp	a)
Bansud	1,40	57,14	0,43	0,24	
Comercial del Plata	2,40	66,70	0,13	0,08	
Renault	3,60	55,60	0,04	0,02	
Cruce de media de 20 días y cotización	%Op	%Ex	Ga	Gp	b)
Bansud	5,21	69,44	2,08	1,44	
Comercial del Plata	5,00	51,06	-0,09	-0,05	
Renault	4,58	47,83	1,48	0,71	
SCBRD mediante técnicas de Clustering	%Op	%Ex	Ga	Gp	c)
Bansud	59.40	58.59	8.47	4.96	
Comercial del Plata	67.60	57.40	9.01	5.17	
Renault	27.00	57.78	7.92	4.58	

Tabla 4.9 – Resultados obtenidos con las técnicas tradicionales a) Figuras, b) Medias Móviles y c) con nuestro SCBRD

4.6. Análisis de Resultados

En las Secciones 4.4.2, 4.4.3, 4.4.4 y 4.4.5 se han presentado los resultados obtenidos para las experiencias realizadas con cada uno de los algoritmos

presentados. Todas las experiencias, excepto con las técnicas tradicionales, han sido realizadas con una y con tres estrategias para destacar los beneficios obtenidos mediante la utilización de MEI. Los resultados muestran que la utilización de tres estrategias genera mayores ganancias debido a que realiza más operaciones porque entre todas cubren una mayor cantidad de ejemplos. Por esto, las comparaciones entre las distintas metodologías serán realizadas en base a los resultados obtenidos por la experiencias con tres estrategias.

4.6.1. Comparación de resultados entre SCBRD con BD uniforme y SC clásicos

El análisis de los resultados será realizado teniendo en cuenta varios aspectos: ganancia obtenida, porcentaje de operaciones realizadas y porcentaje de éxito obtenido.

- *Desde el punto de vista de la ganancia obtenida:*
 - En las Figuras 4.16 y 4.17 pueden observarse claramente las grandes diferencias a favor de la nueva técnica en cuanto a la ganancia, tanto para el entrenamiento como para el test. Incluso existe un par de especies (Siderca y Renault) que producía pérdida en el test usando el enfoque anterior y que con este nuevo método produce ganancias. (véase Tabla 4.5). Este logro se debe al haber incorporado en esta etapa una nueva manera de tratar las tendencias con el objetivo de poder clasificarlas más correctamente y así poder obtener estrategias mejor especializadas.
 - La nueva clasificación empleada produce ventajas al momento de los test. En los casos anteriores se producían estrategias que solo se expresaban en función de tendencia creciente o decreciente, pero ahora gracias a la clasificación en distintos grupos podemos obtener de la última población del entrenamiento distintas estrategias que usen distintas clases de tendencia, y por lo tanto que generen más ganancias cuando operamos simultáneamente con varias de ellas. Por ejemplo en la especie SIDERCA (véase Tabla 4.5) , cuando se trabaja con tres estrategias, además de operar con las tendencias *poco crecientes* también se operará con las tendencias *muy crecientes*. El conjunto de estrategias consigue un mejor cubrimiento de los ejemplos, por consiguiente aumenta la cantidad de operaciones exitosas realizadas y la ganancia obtenida.
 - Puede observarse que con esta nueva forma de clasificación, a medida que agregamos más estrategias para operar en la fase de test, se incrementa siempre la ganancia, o por lo menos se mantiene igual en algunos casos. Cuando se presenta una igualdad en los valores se debe a que varias de las mejores estrategias obtenidas (y por lo tanto, las estrategias) para cada especie, son similares y tienden a producir conflictos en el test en los que siempre gana la primer estrategia. Es por ello que en algunos casos cuando agregamos una estrategia más

para tenerla en cuenta al momento de operar, ésta no produce cambios en los resultados.

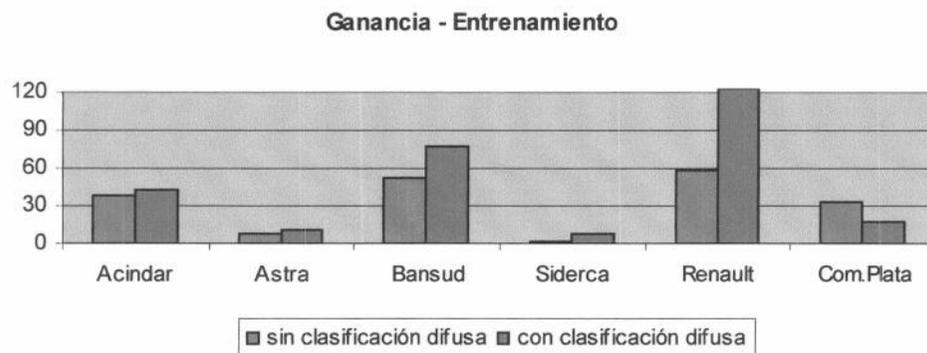


Figura 4.16 – Comparación de ganancia en el entrenamiento

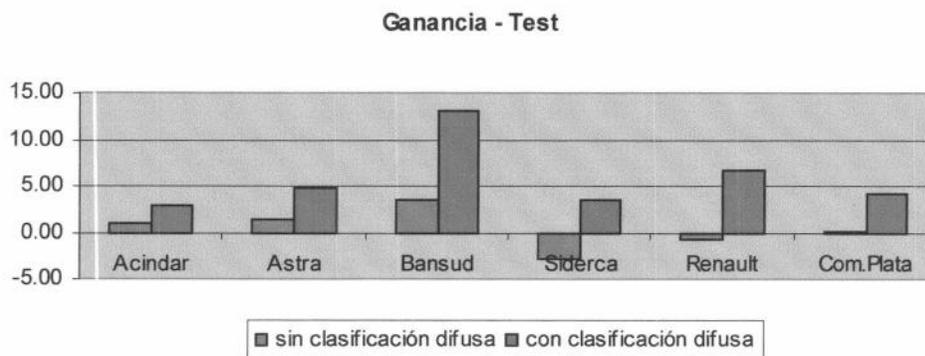


Figura 4.17 – Comparación de la ganancia en el test

- Desde el punto de vista de la cantidad de operaciones y del porcentaje de éxito:
 - En cuanto al porcentaje de operaciones, se puede ver en las Figuras 4.18 y 4.19 (véase Tabla 4.5) que la mayoría de las especies produce un mayor porcentaje de operaciones con este nuevo método. Si observamos las estrategias seleccionadas (véase Tabla 4.6), vemos que la mayoría de ellas se aplica a las clases donde se concentran casi todas las tendencias de los conjuntos de datos (tal como vimos anteriormente, las clases de menor pendiente ya sea positiva o negativa, o, lo que es lo mismo, tendencia creciente o decreciente, son las que concentran la mayor parte de las tendencias). Debido a esto, es razonable que estas estrategias operen una mayor cantidad de veces.
 - En las Figuras 4.20 y 4.21 (véase Tablas 4.3 y 4.5) puede observarse la comparación del porcentaje de éxito entre ambas técnicas, en el entrenamiento y en el test respectivamente. Los resultados obtenidos en el entrenamiento son muy similares, pero al ser evaluadas en el conjunto de test, pueden observarse mejores resultados a favor de la

nueva técnica. Esto se debe a que con esta nueva manera de tratar las tendencias se obtienen estrategias mejor definidas.

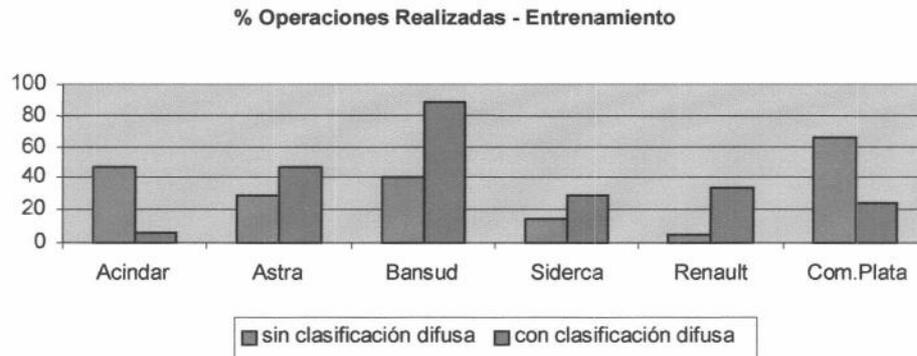


Figura 4.18 – Comparación del porcentaje de operaciones en el entrenamiento

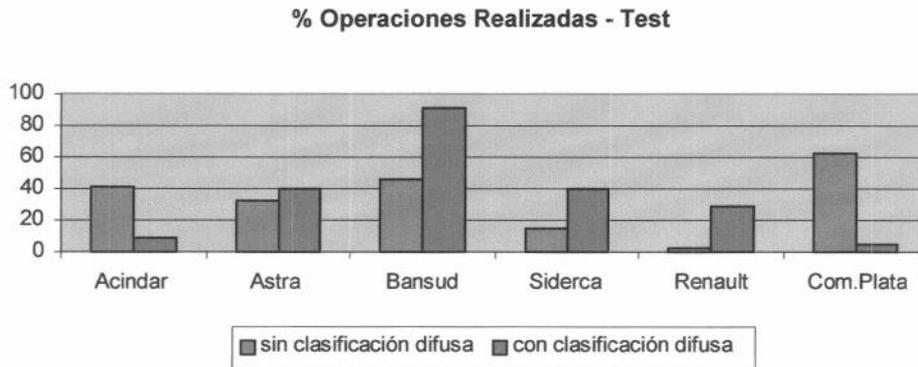


Figura 4.19 – Comparación del porcentaje de operaciones en el test

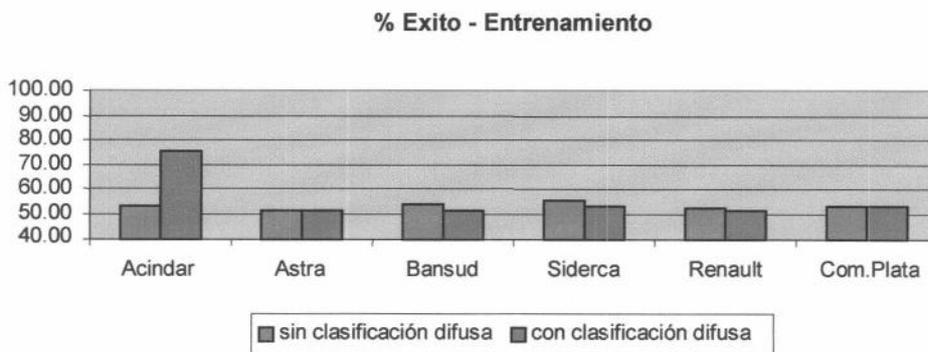


Figura 4.20 – Comparación del porcentaje de éxito en el entrenamiento

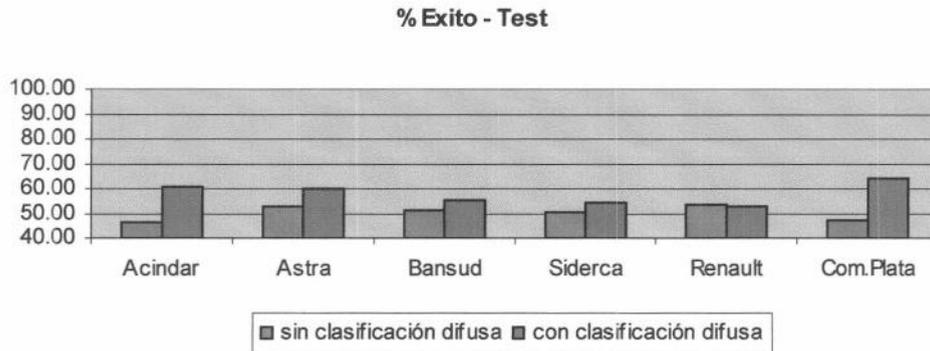


Figura 4.21 – Comparación del porcentaje de éxito en el test

4.6.2. Comparación de resultados entre un SCBRD con BD aprendida mediante técnicas de Clustering y un SCBRD con BD uniforme

El análisis de los resultados será realizado teniendo en cuenta varios aspectos: ganancia obtenida, porcentaje de operaciones realizadas y porcentaje de éxito obtenido.

- *Desde el punto de vista de la ganancia obtenida:*
 - Puede verse en las Figuras 4.24 y 4.25 (Véase Tabla 4.7) que aunque en la mayoría de las especies evaluadas no se produjeron grandes diferencias con respecto a la ganancia (y tampoco al porcentaje de éxito), en algunos casos se observaron mejores resultados. Si bien en algunos casos resulta más conveniente tener una BD ajustada de acuerdo a los datos, en otros casos una definición con mayor fuzziness (como la de la BD equiparticionada) remite una mayor generalización.
 - Para algunos de los casos que presentan similitudes se observa que la nueva construcción de las BD difusas difiere poco de la utilizada en las experiencias anteriores, o sea, para determinadas especies las estrategias que resultaron seleccionadas son similares. Por ejemplo, para la especie BANSUD se pueden ver las Figuras 4.22 y 4.23, donde se muestran las BD difusas obtenidas mediante ambos métodos.

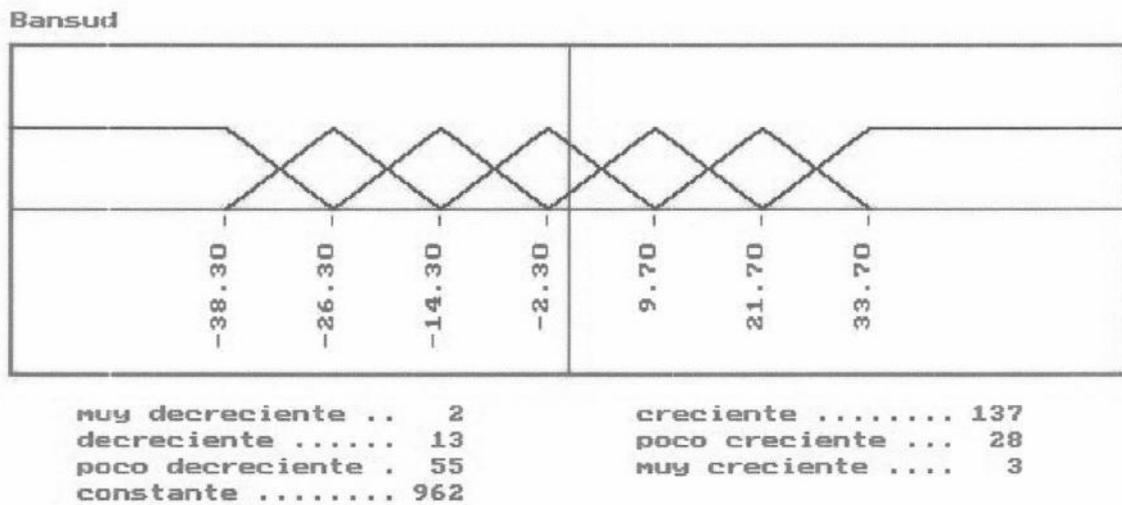


Figura 4.22 – Base de Datos para Bansud

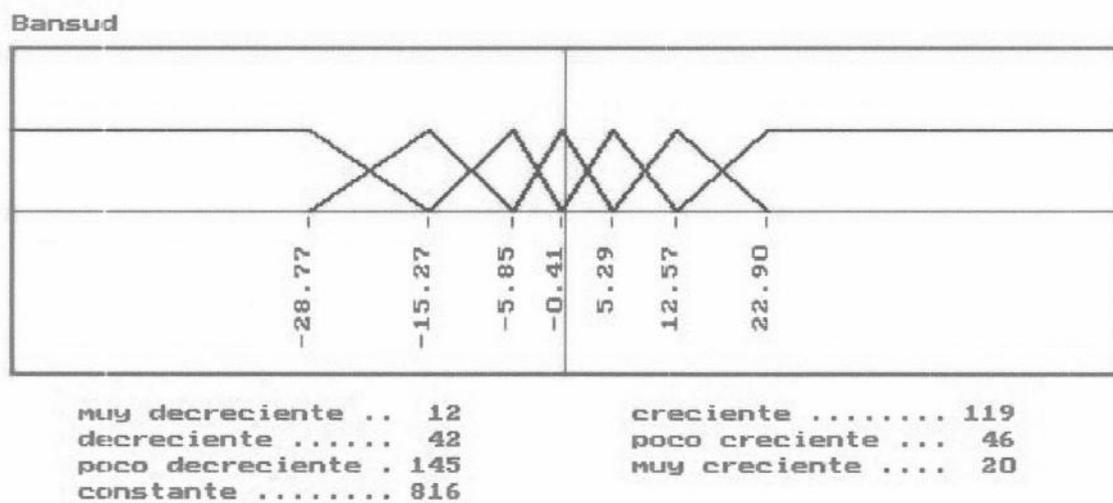


Figura 4.23 – Base de Datos para Bansud construida con K-Means

Observemos las similitudes de las tres mejores estrategias obtenidas para la especie Bansud sin utilizar Clustering y usando Clustering:

- Estrategias generadas para la especie Bansud con BD difusa creada sin Clustering:
 - Estrategia 1: Si BANSUD se mantiene constante por 2 días, vender y mantener por 7 días (1000100111)
 - Estrategia 2: Si BANSUD se mantiene constante por 7 días, vender y mantener por 7 días (1001110111)
 - Estrategia 3: Si BANSUD se mantiene constante por 6 días, vender y mantener por 7 días (1001100111)

- Estrategias generadas para la especie Bansud con BD difusa creada usando Clustering:
 - Estrategia 1: Si BANSUD se mantiene constante por 2 días, vender y mantener por 6 días (1000100110)
 - Estrategia 2: Si BANSUD se mantiene constante por 2 días, vender y mantener por 5 días (1000100101)
 - Estrategia 3: Si BANSUD se mantiene constante por 7 días, vender y mantener por 7 días (1001110111)

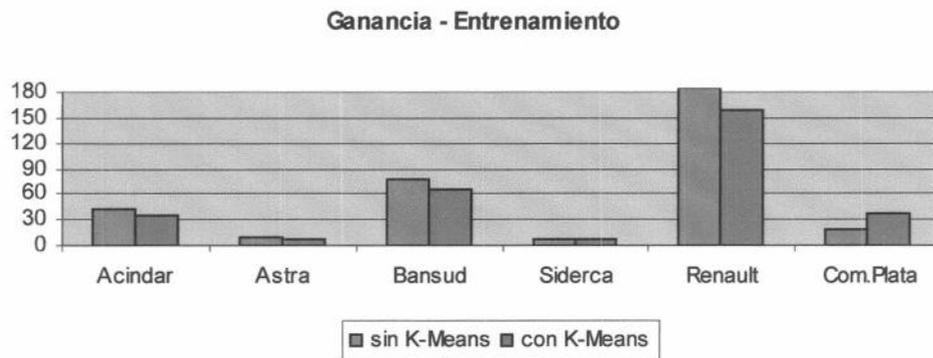


Figura 4.24 – Comparación de ganancia en el entrenamiento

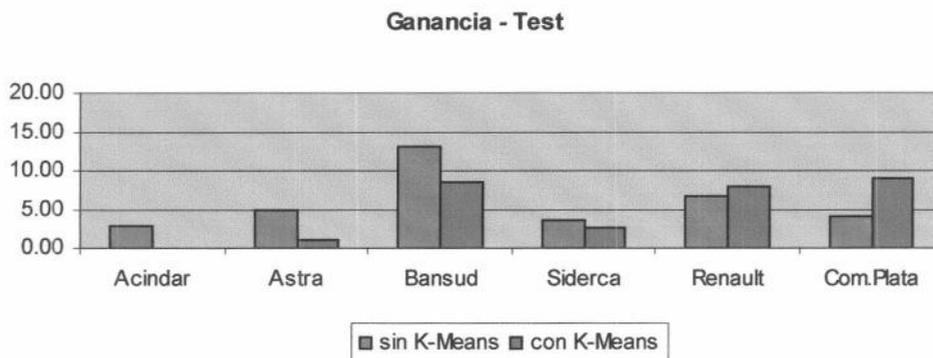


Figura 4.25 – Comparación de ganancia en el test

- Desde el punto de vista de la cantidad operaciones y del porcentaje de éxito:
 - La gran ventaja lograda con la incorporación de la técnica de Clustering para definir la BD difusa se refleja en la cantidad de operaciones realizadas. Se puede observar que en la mayoría de las especies con la que se ha probado el algoritmo, se opera muchas menos veces que las que operaba con el método anterior (véase la Tabla 4.7 y las Figuras 4.26 y 4.27). Este logro es bastante importante, hay que tener en cuenta que las operaciones en un mercado son realizadas a través de un

agente que cobra un porcentaje de comisión tanto al entrar como al salir. Cuanto menor sea la cantidad de operaciones menor será el costo extra. En la Tabla 4.10 se detalla esta comparación donde se observa que con la utilización de técnicas de Clustering se opera 952 veces menos con las especies evaluadas (se realiza un 28.80% de operaciones respecto del 36.93% de operaciones realizadas con el método anterior). Esta disminución en la cantidad de operaciones significa que la partición lingüística construida con técnicas de Clustering produce conjuntos mejor definidos de acuerdo al tipo de datos empleado.

Especie		Cant. Oper. sin Clustering				Cant. Oper. con Clustering			
		Exitos	Fracasos	Total	% Op	Exitos	Fracasos	Total	% Op
Acindar	Entren.	60	20	80	6.67	28	10	38	3.16
	Test	26	17	43	8.60	6	4	10	2.00
Astra	Entren.	288	277	565	47.08	80	43	123	10.25
	Test	120	80	200	40.00	16	2	18	3.60
Bansud	Entren.	550	520	1070	89.17	371	361	732	61.00
	Test	252	207	459	91.80	174	123	297	59.40
Siderca	Entren.	183	162	345	28.75	45	22	67	5.58
	Test	107	91	198	39.60	53	63	116	23.20
Renault	Entren.	210	198	408	34.00	168	155	323	26.91
	Test	77	68	145	29.00	78	57	135	27.00
Com. Del Plata	Entren.	149	133	282	23.50	347	324	671	55.91
	Test	16	9	25	5.00	194	144	338	67.60
TOTALES		2038	1782	3820	36.93	1560	1308	2868	28.80

Tabla 4.10 – Comparación de cantidad de operaciones realizadas

- En cuanto a los porcentajes de éxitos, los valores alcanzados por el SCBRD con BD aprendida mediante Clustering han sido superiores en la mitad de las experiencias (véanse las Figuras 4.28 y 4.29 y la Tabla 4.7). Los resultados obtenidos no muestran que una de las metodologías sea mejor que la otra. Por lo tanto este último método se presenta como una alternativa que conserva la semántica global de las variables lingüísticas difusas.

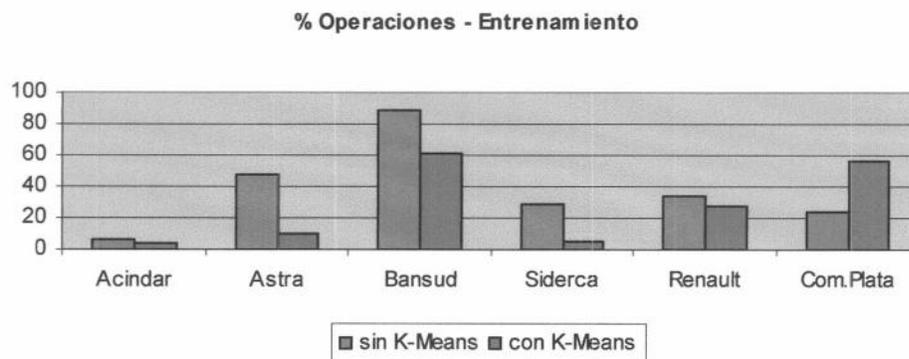


Figura 4.26 – Comparación del porcentaje de operaciones realizadas en el entrenamiento

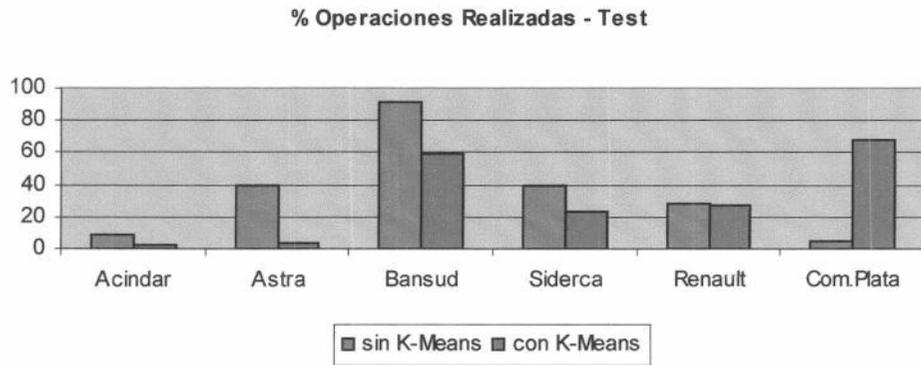


Figura 4.27– Comparación del porcentaje de operaciones realizadas en el test

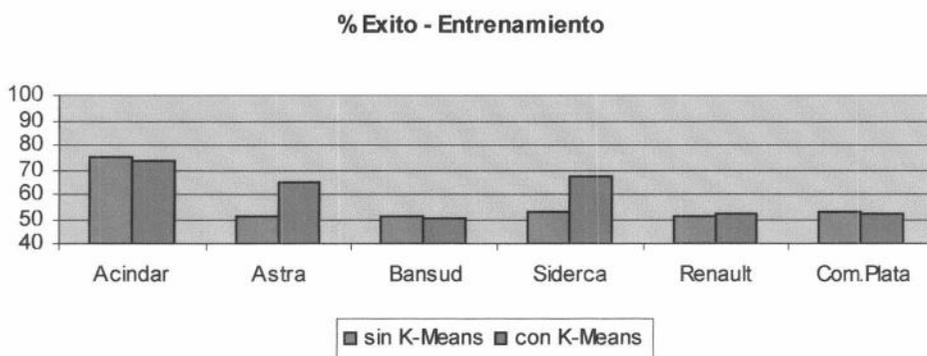


Figura 4.28 – Comparación del porcentaje de éxito en el entrenamiento

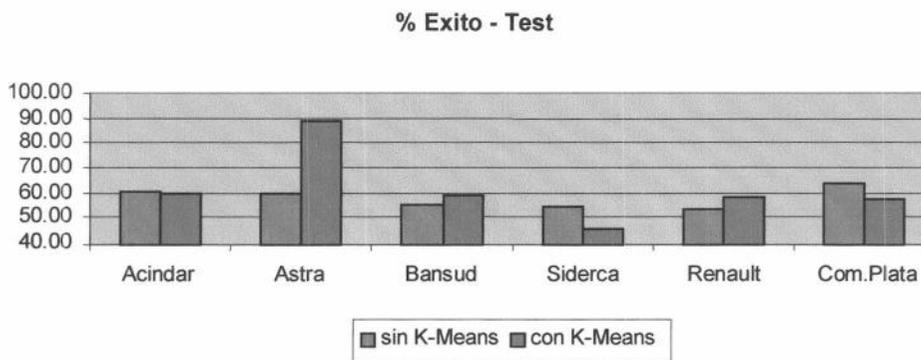


Figura 4.29 – Comparación del porcentaje de éxito en el test

4.6.3. Comparación de resultados entre las Técnicas tradicionales y un SCBRD con BD aprendida mediante técnicas de Clustering

A continuación analizaremos los resultados obtenidos comparándolos con los producidos por nuestro Sistema Clasificador.

- *Desde el punto de vista de la ganancia obtenida*

Las ganancias obtenidas en ambas experiencias han sido menores a las observadas en las experiencias realizadas con nuestro SCBRD (véanse las Tablas 4.7 y 4.9). En particular, para el caso en el que se analizó Comercial del Plata utilizando Medias Móviles se han registrado pérdidas.

- *Desde el punto de vista de la cantidad de operaciones realizadas y del porcentaje de éxito*

Como se ve en las Tablas 4.7 y 4.9, los porcentajes de operaciones realizadas para las tres especies son mucho menores a los registrados por nuestro SCBRD, tanto para el caso de la Identificación de Figuras como para el estudio de Medias Móviles.

En cuanto a los porcentajes de éxito podemos observar que en general han sido menores. Sólo en dos casos se ha registrado un porcentaje de éxito más alto: Comercial del Plata analizado con Figuras y Bansud analizado con Medias Móviles.

Para el caso de las figuras, el porcentaje de operaciones realizadas podría ser mayor si no exigiéramos demasiada rigurosidad en el reconocimiento de las formaciones, pero esto afectaría a la precisión de los resultados obtenidos disminuyendo tanto la ganancia como el porcentaje de éxito.

4.7. Observaciones Finales

Los Sistemas Clasificadores Basados en Reglas Difusas (SCBRDs) han demostrado ser una herramienta eficaz para aprender las mejores Estrategias de Inversión sin descuidar la interpretabilidad requerida por los expertos para poder emplearlas. Fundamentalmente nos han permitido representar conceptos ambiguos y mantener una interpretabilidad lingüística.

En este Capítulo hemos planteado dos algoritmos con diferentes definiciones para la creación de la Base de Datos (BD) difusa que contiene la definición de las funciones de pertenencia asociadas a los términos lingüísticos.

El primero nos permitió utilizar BD por equipartición. En el segundo aprendimos la BD por medio de técnicas de Clustering. Este método fue presentado como una alternativa que conserva la semántica global de las variables lingüísticas difusas.

El SCBRD con BD uniforme produjo mejores ganancias que el SC clásico y que las técnicas tradicionalmente usadas por los expertos. Si bien operó una mayor cantidad de veces, las ganancias fueron mucho mayores.

Desde el punto de vista de la cantidad de operaciones realizadas observamos que las experiencias en las que se utilizaron técnicas de Clustering, se

registraron valores notablemente menores. Este aspecto es muy importante, ya que si se tiene en cuenta el costo por operación, este puede ser bastante significativo frente a la ganancia obtenida.

Si bien en algunos casos resulta más conveniente tener una BD ajustada de acuerdo a los datos, en otros casos una definición con mayor fuzziness (como la de la BD equiparticionada) remite una mayor generalización.

En muchos casos, la integración de varias técnicas se presenta como una buena opción para la resolución de problemas. Sin embargo, a veces no es una tarea tan sencilla como una simple combinación y en este proceso se requiere mucha atención tal como fue expresado por Goldberg en [GOL00]. En este sentido, hemos comprobado en este Capítulo que los Sistemas Difusos Genéticos son una muy buena manera de aprender SCBRDs si se tiene especial cuidado en la integración de las distintas técnicas utilizadas.

Capítulo 5

Comentarios Finales

En este apartado final presentaremos una serie de conclusiones que surgen del trabajo realizado en esta memoria. En la Sección 5.1 describiremos los problemas asociados con la tarea de aprender Estrategias de Inversión que generen ganancias y detallaremos las técnicas de Aprendizaje Automático que han sido estudiadas para elaborar una metodología híbrida eficaz. En la Sección 5.2 describiremos un resumen de la memoria. En la Sección 5.3 comentaremos los trabajos futuros y finalmente en la Sección 5.4 brindaremos las conclusiones finales.

5.1. Marco de trabajo

Como hemos presentado en la Sección 1.1, desde hace muchos años los mercados financieros han sido estudiados y analizados por economistas, inversores e investigadores con el objetivo de establecer Modelos de Comportamiento, descubrir Técnicas de Predicción y así poder elaborar Estrategias de Inversión (EIs) que permitan obtener ganancias.

Si bien se han desarrollado varias técnicas de análisis para poder comprender y predecir el comportamiento de los mercados, estos métodos aún no logran satisfacer los requerimientos de muchos inversores.

Las dos técnicas que históricamente han sido utilizadas por los inversores para tomar sus decisiones son: Análisis Fundamental (AF) y Análisis Técnico (AT).

El Análisis fundamental (AF) se basa en el estudio de toda la información económico-financiera disponible sobre la empresa (balance, cuenta de resultados, ratios financieros, etc.), así como de la información del sector, de la coyuntura macroeconómica, etc. En definitiva, se estudia cualquier información que pueda servir para tratar de predecir el comportamiento futuro de la empresa.

En el Análisis técnico (AT) se considera que el mercado proporciona la mejor información posible sobre el comportamiento de la acción. Analiza como se ha comportado ésta en el pasado y trata de proyectar su evolución futura.

En la Sección 1.4 comentamos las principales dificultades que se presentan al utilizar cada una de estas técnicas.

Los inversores que emplean AF para evaluar las especies y tomar decisiones encuentran que esta tarea requiere mucha interpretación por parte de ellos, de los datos de las compañías. Dado que este tipo de análisis contiene un alto grado de subjetividad, mecanizar el proceso de aprendizaje incorporando metodologías computacionales se convierte en una tarea muy difícil. Por

otro lado, si bien gran parte de los datos utilizados por el AF son de dominio público, existen algunos indicadores de suma importancia para evaluar una compañía que no siempre están disponibles.

Como vimos en la Sección 1.3.3, los analistas técnicos basan sus decisiones en la utilización de gráficos de cotización para reconocer determinadas figuras o predecir la tendencia, en la utilización de medias móviles y en el cálculo de otros indicadores. Todos estos presentan un carácter cuantitativo dado que tienen origen en el valor de cotización de las especies. La naturaleza cuantitativa del AT posibilita la construcción de una herramienta computacional para el tratamiento de esta problemática.

La tarea de identificar figuras en los gráficos de precios tiene un fuerte componente subjetivo debido a que los analistas técnicos deben predecir su formación antes de que esté completa. En muchos casos la formación que se va definiendo se puede corresponder con más de una figura conocida por lo que el inversor debe apelar a su olfato para determinar cuál de ellas cree que se formará. Otro dato para tener en cuenta es que los inversores pueden encontrar las figuras tanto en períodos cortos como en períodos largos por lo que debe incluir diferentes escalas de análisis complicándose aún más su seguimiento.

Tanto las medias móviles como los otros indicadores utilizados en el AT requieren que el inversor posea conocimientos matemáticos y financieros para interpretar las señales de compra o de venta originadas por los mismos.

Las tendencias son una de las fuentes de información más utilizadas por los analistas técnicos. Teniendo en cuenta la necesidad de mantener un alto nivel de interpretabilidad, la tendencia, como parte de las Estrategias de Inversión, se presenta como un parámetro de mucha utilidad para decidir cuándo operar. Si a esto le agregamos el carácter cuantitativo del análisis de las tendencias que facilita un tratamiento computacional, vemos que el uso de tendencias en el AT cumple con los requisitos necesarios para formar parte de la elaboración de una solución al problema planteado.

5.2. Resumen

En esta Sección resumiremos lo realizado en el presente trabajo sobre a la elaboración de Estrategias de Inversión que generen ganancias mediante la utilización de Sistemas Clasificadores clásicos y basados en Lógica Difusa con modelos lingüísticos. Finalmente destacaremos los aportes de este trabajo.

- *Elaboración de la Estrategia de Inversión*

El objetivo deseado de las EIs es que sean lo suficientemente interpretables sin perder precisión. Esta solución de compromiso nos posibilita su comprensión y utilización por parte de los expertos. En base a esta premisa se decidió utilizar EIs del tipo comprar-mantener y vender-mantener. Por otro lado, y pensando en este requisito, la aplicación de las estrategias utilizadas en las experiencias

ha estado determinada por la tendencia observada en la evolución de la cotización.

Una característica de las Estrategias de Inversión obtenidas es que para su aprendizaje no se plantearon restricciones que indiquen que tengan que ser óptimas sino que ha sido suficiente con que no produzcan pérdidas. Además, no necesariamente todas las operaciones debieron ser exitosas sino que se ha buscado que el resultado final sea positivo.

- *Sistemas de Clasificación (SC)*

El SC empleado como primer enfoque de aprendizaje en el Capítulo 3 está basado en la utilización de un Algoritmo Genético (AG). Las Els fueron representadas en los cromosomas mediante codificación binaria dada la naturaleza de los datos que las componen.

Las experiencias realizadas con este SC fueron divididas en tres grupos:

Experiencias con una única especie

Experiencias con un conjunto de especies

Experiencias con Múltiples Estrategias de Inversión

En base a los resultados obtenidos, hemos analizado la incidencia observada en factores tales como la ganancia obtenida, el porcentaje de operaciones realizadas, el porcentaje de operaciones exitosas, etc.

Con el primer grupo se logró establecer el tipo de Estrategia de Inversión que se utilizó para las siguientes experiencias de la memoria.

En los otros dos grupos se verificó que la utilización de más de una especie y más de una estrategia en operaciones bursátiles permite obtener una mayor eficiencia en los aspectos analizados.

- *Sistemas de Clasificación Basados en Reglas Difusas (SCBRDs)*

La incorporación de variables lingüísticas en la definición de las Els para utilizar un SCBRD nos ha permitido flexibilizar las nociones de tendencia, mejorar la respuesta en el aprendizaje del AG y obtener Els con una mayor interpretabilidad, que facilita la comprensión y el uso de las mismas por parte de los expertos.

El AG ha sido empleado nuevamente para el aprendizaje de la Base de Reglas, que en el caso de las experiencias del Capítulo 4 se compone de reglas lingüísticas. Las reglas lingüísticas pueden conjugar precisión con interpretabilidad.

En las experiencias realizadas con el SCBRD se aprendieron Els que mostraron importantes mejoras, principalmente desde el punto de vista de la ganancia y del porcentaje de éxito para los tests, con respecto a las Els que fueron aprendidas por el Sistema Clasificador clásico.

El uso de estas hibridaciones se basa en el área conocida como Computación Flexible (Soft-Computing) o en otros sectores como Inteligencia Computacional. Goldberg [GOL00] destaca la gran importancia de integrar cuidadosamente los distintos métodos para aprovechar sus cualidades individuales: “*el futuro de nuestro campo está en la integración de lo mejor de cada uno de sus exponentes*”.

- *Mejoras en la definición de la Base de Datos mediante técnicas de Clustering*

Si bien los resultados obtenidos por el SCBRD fueron exitosos, la definición de la BD por equipartición para los términos lingüísticos puede no ser lo suficientemente precisa en algunos casos. Por este motivo, se utilizaron técnicas de Clustering para su aprendizaje.

La incorporación del algoritmo de Clustering en el aprendizaje de la BD produce resultados que muestran algunas diferencias con respecto a los de las experiencias previas de acuerdo al tipo de problema modelado. Si bien en algunos casos resulta más conveniente tener una BD ajustada de acuerdo a los datos, en otros casos una definición con mayor fuzziness (como la de la BD equiparticionada) remite una mayor generalización. Los porcentajes de éxito en la BD aprendida a priori han sido superiores en la mitad de las experiencias y desde el punto de vista de la cantidad de operaciones realizadas observamos que con la aplicación de esta técnica se produce una notable disminución. Este aspecto es muy importante, ya que si se tiene en cuenta el costo por operación puede ser bastante significativo frente a la ganancia obtenida. En definitiva, el método de aprendizaje de la BD se presenta como una alternativa que conserva la semántica global de las variables lingüísticas difusas.

En resumen, este trabajo realiza los siguientes aportes:

- Análisis, evaluación y detección de problemas en la identificación de Estrategias de Inversión utilizadas por los inversores del mercado de valores.
- Diseño e implementación de Sistemas de Clasificación (métodos híbridos) que permitan aprender en forma automática y no supervisada, en base a ejemplos de series financieras y por medio de Algoritmos Genéticos, Estrategias de Inversión que generen ganancias. Caracterización y evaluación del método propuesto y comparación con técnicas tradicionales empleadas por los inversores.
- Extensión de los Sistemas Clasificadores, aplicados a series financieras, a modelos lingüísticos difusos (Sistemas de Clasificación Basados en Reglas Difusas) con capacidad de agrupar situaciones similares y de establecer soluciones de compromiso entre la interpretabilidad y la precisión de los sistemas aprendidos. Diseño de un método de aprendizaje en base a Sistemas Difusos Genéticos. Evaluación y comparación de resultados obtenidos.

5.3. Trabajos Futuros

Las Els aprendidas y utilizadas en las experiencias presentadas en esta memoria han mostrado muy buenos rendimientos y un buen grado de interpretabilidad. Pero aún es posible continuar explorando la problemática y extender las soluciones aquí presentadas en trabajos futuros. A continuación mencionaremos posibles extensiones:

- *Modificaciones en las Els*

Ampliación de la cantidad de días de tendencia o mantenimiento

Como vimos en la Sección 1.3.3.2, existen tres tipos de tendencias: principal, secundaria y menor. En esta memoria, las Els que hemos utilizado sólo hablan de tendencias menores. Estas tendencias registran movimientos a corto plazo. Para poder trabajar con tendencias de mayor duración sólo es necesario modificar la representación de las Els ampliando la cantidad de días de tendencia. Por otro lado, de la misma manera también es posible ampliar el rango de días que puede durar la operación.

Incorporación de relaciones entre la cotización y otras variables

Otra extensión posible para las Els es utilizar las relaciones entre la cotización y las variables mencionadas en la Sección 1.2.5.

Para esto es necesario conseguir toda la información histórica requerida (tasa de interés, índice de inflación o volumen operado) y hacer las modificaciones necesarias al Sistema de Asignación de Mérito del Sistema Clasificador.

Utilización de Medias Móviles

Al igual que en el caso anterior, las Medias Móviles descritas en la Sección 1.3.3.4 también podrían ser incorporadas a las Els como complemento al análisis de la tendencia o en forma individual. En cualquiera de los dos casos, los cambios necesarios involucran modificaciones en el Sistema de Asignación de Mérito.

- *Modificaciones en el Sistema de Clasificación*

Incorporación de estrategias promisorias obtenidas de un experto al comienzo del proceso

En algunos casos es posible que un experto nos provea ciertas estrategias básicas. Estas estrategias pueden ser incorporadas a la Base de Reglas inicial estrechando el espacio de búsqueda y en consecuencia mejorando el tiempo de procesamiento.

Adaptación a un ambiente de aprendizaje incremental

Como se definió en la Sección 2.4, existen dos tipos de aprendizaje según la disponibilidad de los datos: aprendizaje incremental o aprendizaje por lotes.

Todas las experiencias desarrolladas en esta memoria han sido realizadas utilizando aprendizaje por lotes, es decir que la totalidad de los datos estaban disponibles al comienzo del procesamiento. Si bien la granularidad de la cotización de las especies empleada en este trabajo es diaria, existen inversores que realizan operaciones intradiarias para lo cual observan los precios con una frecuencia de minutos. En estos casos, la posibilidad de utilizar herramientas como la presentada en este trabajo exige dar una respuesta en un lapso muy breve. Otra posible extensión sería modificar este sistema para que pueda recibir nueva información en línea y que su sistema de aprendizaje adapte las reglas ya aprendidas.

5.4. Conclusiones

En esta memoria, hemos estudiado las técnicas más difundidas entre los inversores para elaborar *Estrategias de Inversión* que generen ganancias. De todas las técnicas analizadas, el *Análisis Técnico* en general y el seguimiento de las *tendencias* en las cotizaciones en particular, son las que mejor se prestan para un manejo computacional debido a su naturaleza cuantitativa.

En este sentido, hemos estudiado las características y propiedades de los SC con el fin de construir experiencias que nos han permitido obtener estrategias interpretables por los expertos. También fueron utilizados para elaborar estrategias múltiples que permitan conseguir un mejor cubrimiento de las posibles operaciones de compra y de venta.

Los AGs, como el empleado en el SC, permiten aprender clasificadores en base a conjuntos de datos históricos. Hemos empleado dos modelos de aprendizaje, los cuales han sido utilizados en nuestras experiencias: Michigan y Pittsburgh. En cuanto a la naturaleza de los problemas tratados, el tipo de aprendizaje empleado no fue supervisado y estuvo caracterizado por el refuerzo recibido.

Los SCBRDs han mostrado ser una herramienta eficaz para aprender las mejores Estrategias de Inversión sin descuidar la interpretabilidad requerida por los expertos para poder emplearlas. Fundamentalmente permiten representar conceptos ambiguos y mantener una interpretabilidad lingüística. Gran parte del éxito de los SCBRDs se basa en el aprendizaje de la BD que contiene la definición de las funciones de pertenencia asociadas a los términos lingüísticos

Es importante destacar el gran auge que han alcanzado las inversiones bursátiles. En muchos países, especialmente en EEUU, se ha producido un fuerte acercamiento de la población en general a este tipo de inversiones. Ya no es un ámbito restringido a los expertos, por lo que la solución de compromiso entre la interpretabilidad y la precisión de las estrategias es indispensable en esta clase de herramientas.

En muchos casos, la integración de varias técnicas se presenta como una buena opción para la resolución de problemas. Sin embargo, a veces no es una tarea tan sencilla como una simple combinación y en este proceso se requiere

mucha atención. En este sentido, los SDG conforman un integración adecuada para aprender SCBRDs si se tiene especial cuidado en la hibridación de las distintas técnicas utilizadas [GOL00].

En esta memoria hemos abordado estos temas con especial cuidado y hemos abierto una línea de trabajo que podrá continuar través de las mencionadas extensiones futuras.

Apéndice A

Gráficos de Cotizaciones

Los datos utilizados en nuestro análisis han sido tomados de varias especies que cotizan en la Bolsa de Comercio de Buenos Aires por un período que abarca 1700 días. A continuación se mostrarán los gráficos que representan la cotización diaria (evolución de los precios de cierre) para todas las especies utilizadas en nuestros ejemplos.

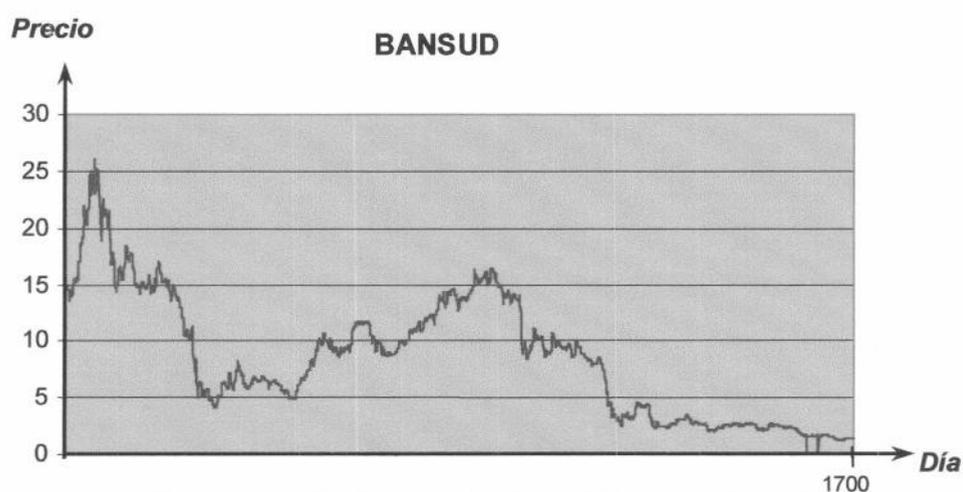


Figura A.1 – Gráfico de cotizaciones de la especie Bansud

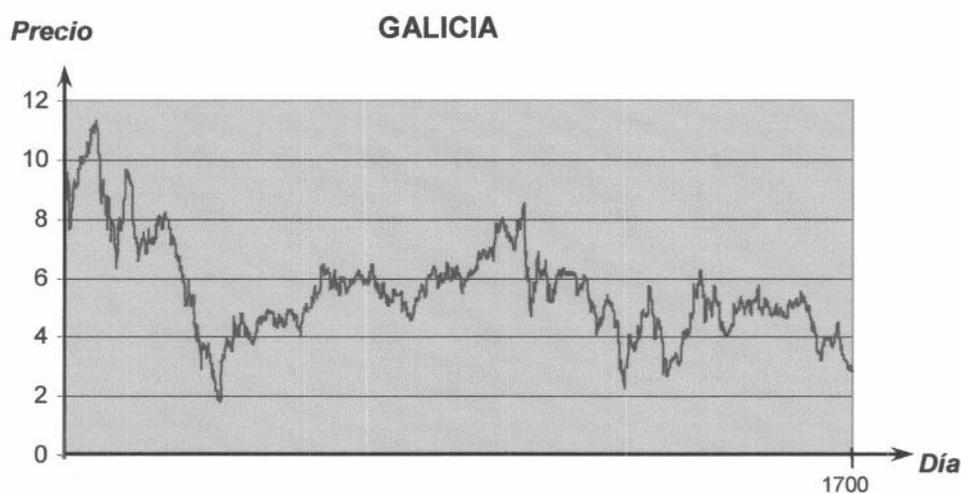


Figura A.2 – Gráfico de cotizaciones de la especie Galicia

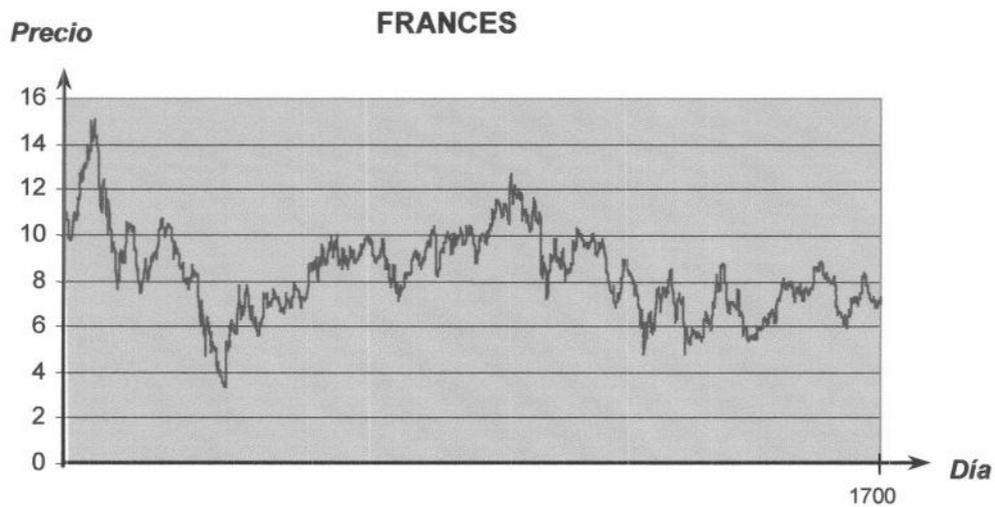


Figura A.3 – Gráfico de cotizaciones de la especie Francés

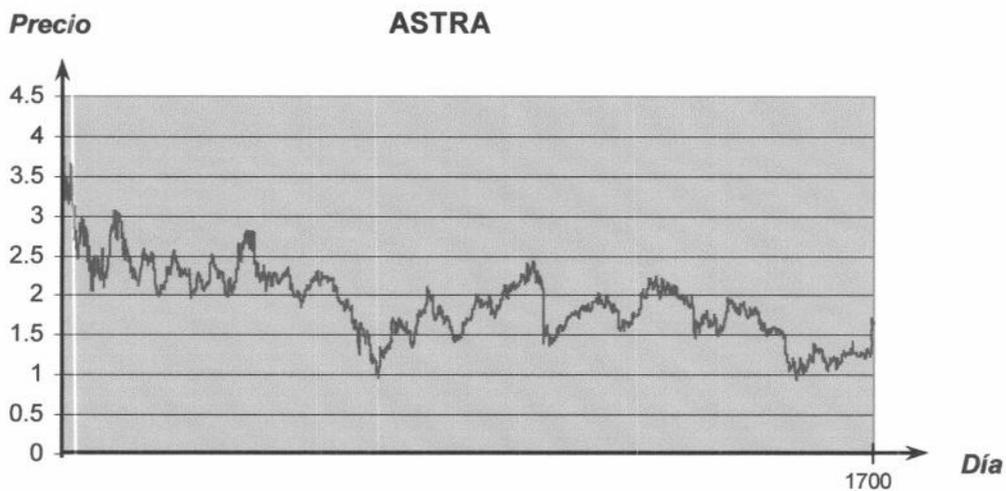


Figura A.4 – Gráfico de cotizaciones de la especie Astra

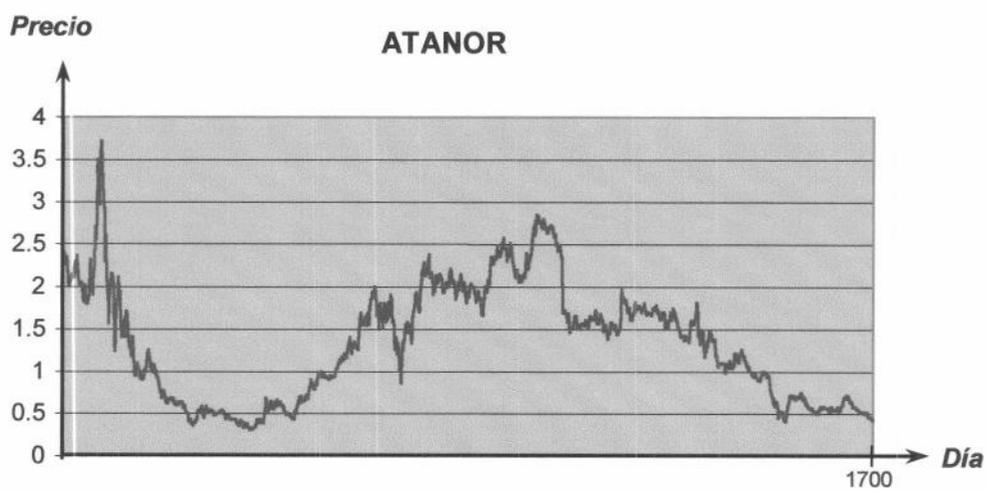


Figura A.5 – Gráfico de cotizaciones de la especie Atanor

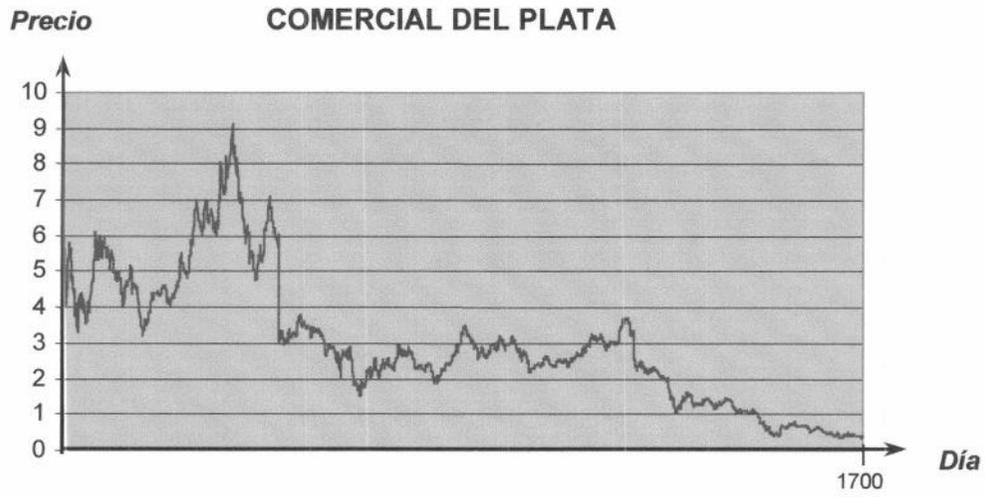


Figura A.6 – Gráfico de cotizaciones de la especie Comercial del Plata



Figura A.7 – Gráfico de cotizaciones de la especie Siderca

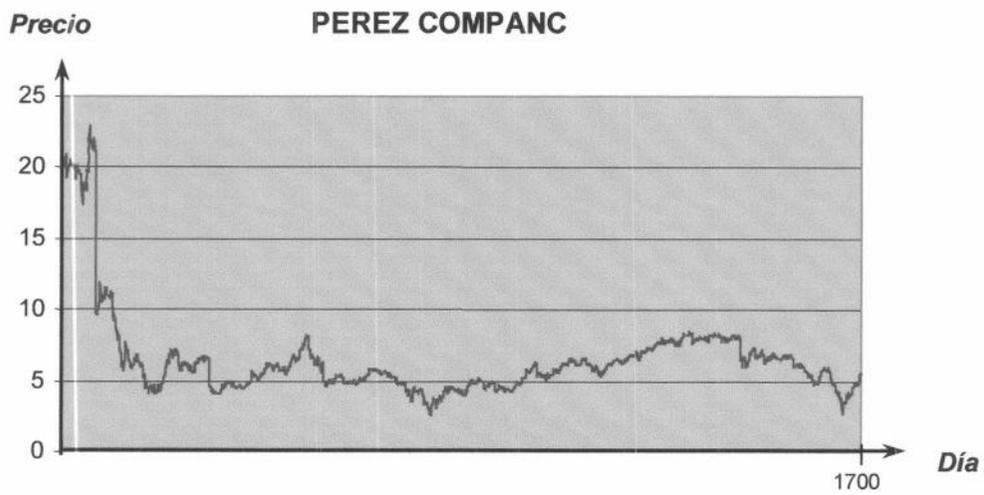


Figura A.8 – Gráfico de cotizaciones de la especie Pérez Companc

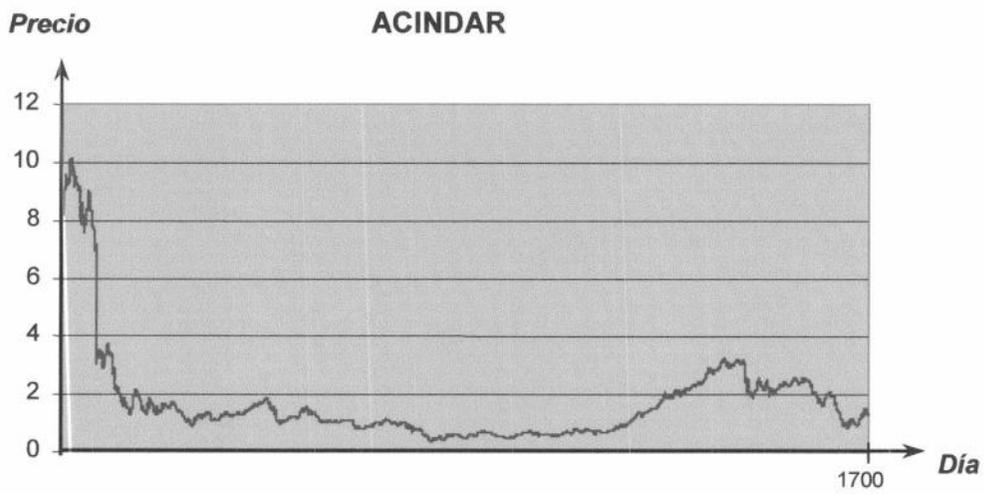


Figura A.9 – Gráfico de cotizaciones de la especie Acindar

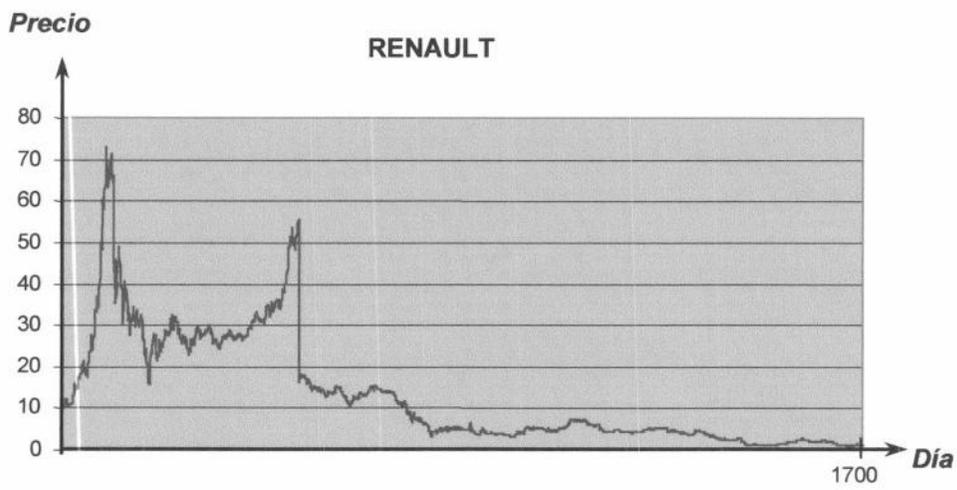


Figura A.10 – Gráfico de cotizaciones de la especie Renault

Apéndice B

Bases de Datos Difusas

A continuación se presentan los gráficos en donde se identifican las bases de datos difusas para las especies utilizadas en las experiencias del Capítulo 4.

Los datos utilizados corresponden a una período de cotizaciones de 1200 días para las siguientes especies: ACINDAR – ASTRA – BANSUD – SIDERCA – RENAULT – COMERCIAL DEL PLATA.

Cada gráfico presenta la siguiente información:

- *ESPECIE*: Nombre de la especie
- *GRAFICO*: En el gráfico pueden distinguirse los siete conjuntos difusos. De izquierda a derecha, éstos son:
 - muy decreciente
 - decreciente
 - poco decreciente
 - constante
 - poco creciente
 - creciente
 - muy creciente
- *CANTIDAD*: Debajo de cada gráfico se encuentra la información de la distribución de las 1200 tendencias en los siete conjuntos.

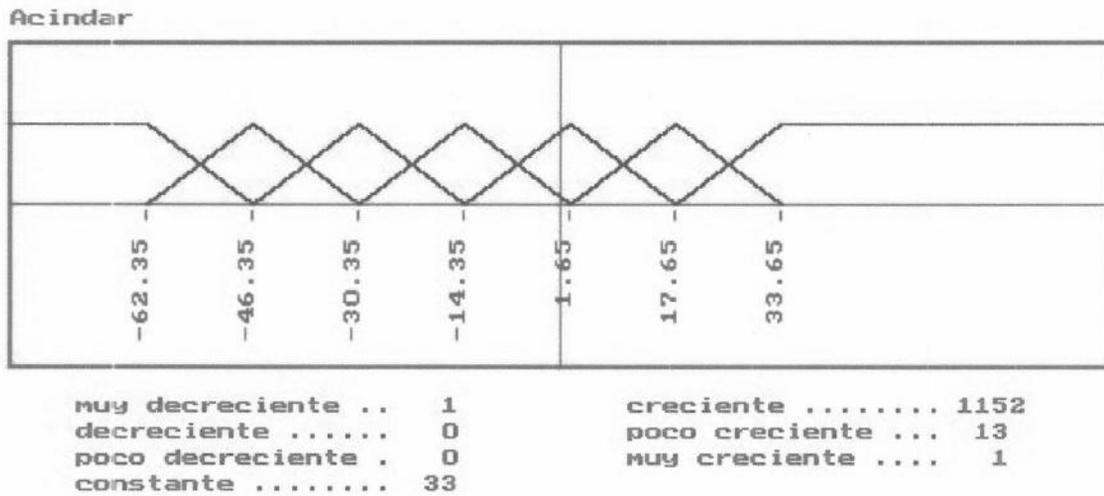


Figura B.1 – Base de Datos para la especie Acindar

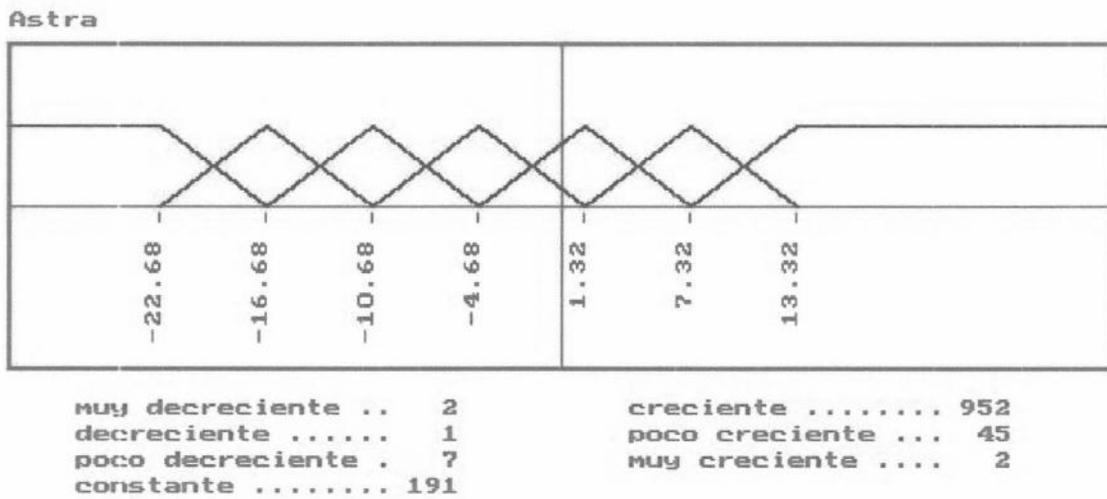


Figura B.2 – Base de Datos para la especie Astra

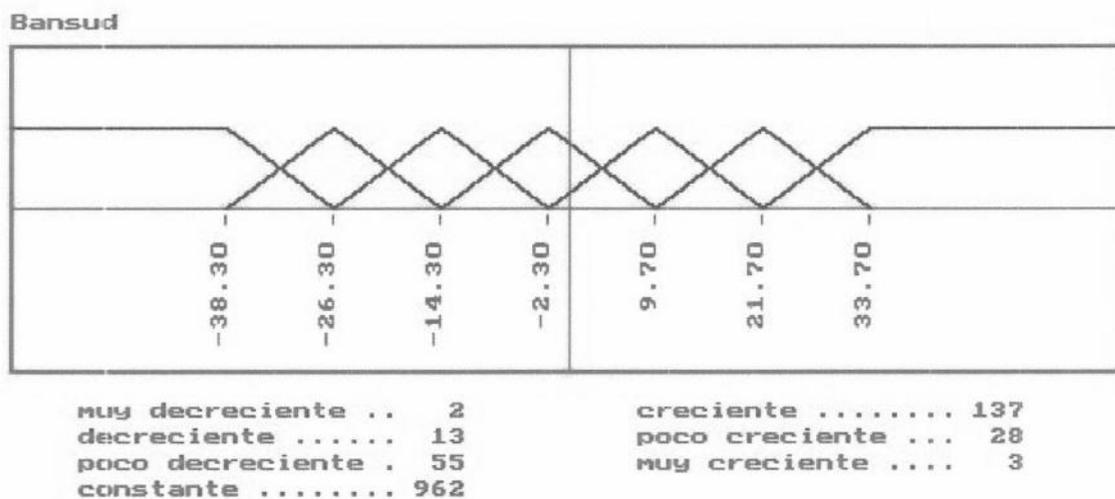


Figura B.3 – Base de Datos para la especie Bansud

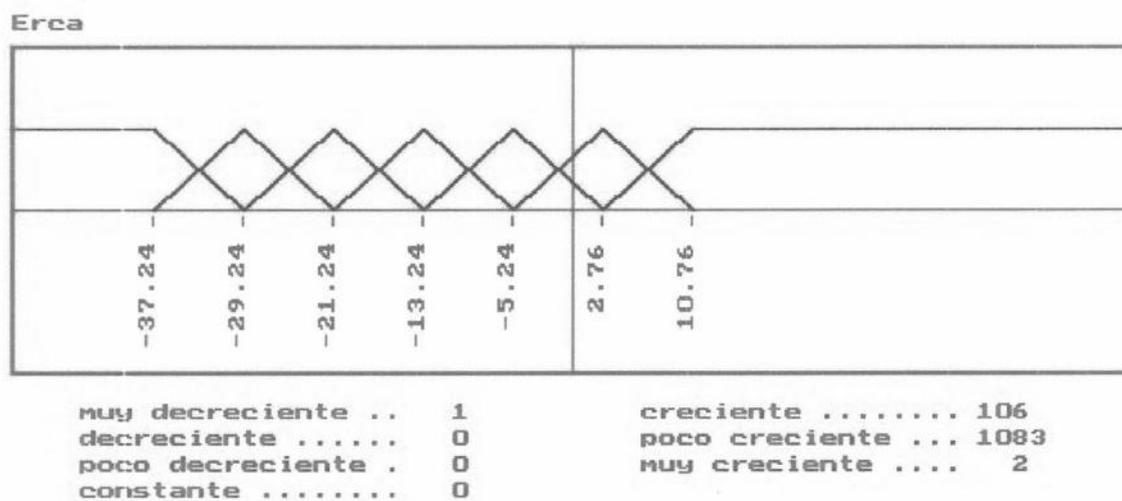
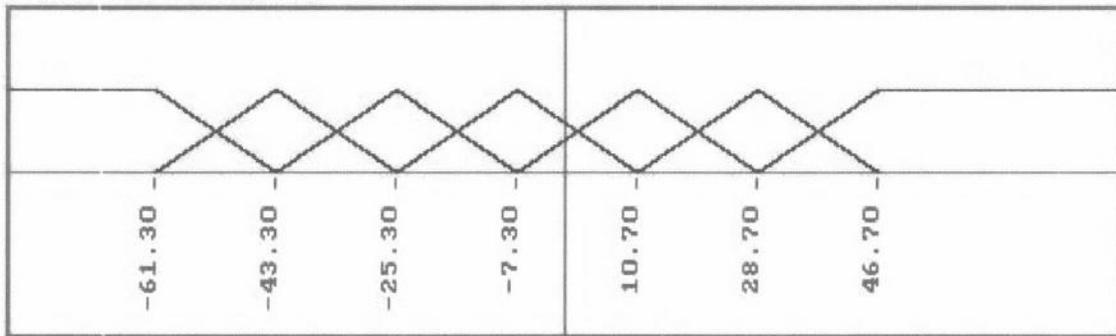


Figura B.4 – Base de Datos para la especie Siderca

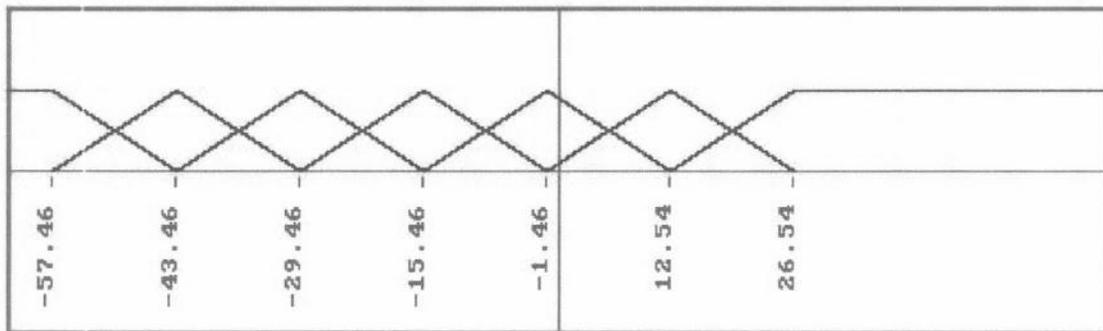
Renault_Arentina



muy decreciente ..	1	creciente	362
decreciente	2	poco creciente ...	9
poco decreciente .	19	muy creciente	1
constante	806		

Figura B.5 – Base de Datos para la especie Renault

Comercial_del_Plata



muy decreciente ..	1	creciente	1024
decreciente	1	poco creciente ...	120
poco decreciente .	2	muy creciente	4
constante	48		

Figura B.6 – Base de Datos para la especie Comercial del Plata

Apéndice C

Conjuntos Difusos construidos con técnicas de Clustering

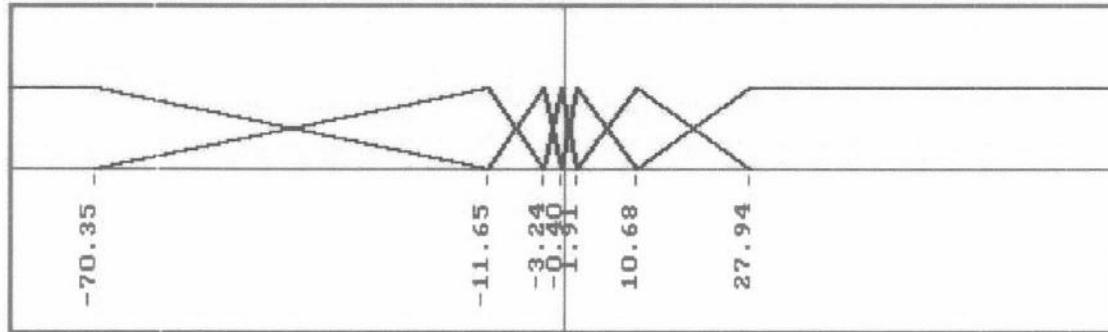
A continuación se presentan los gráficos en donde se identifican los conjuntos difusos que se construyeron usando el algoritmo de K-Means para las especies utilizadas en las experiencias del Capítulo 4.

Igual que en apéndice anterior, los datos utilizados corresponden a una período de cotizaciones de 1200 días para las siguientes especies: ACINDAR – ASTRA – BANSUD – SIDERCA – RENAULT – COMERCIAL DEL PLATA.

Cada gráfico presenta la siguiente información:

- *ESPECIE*: Nombre de la especie
- *GRAFICO*: En el gráfico pueden distinguirse los siete conjuntos difusos. De izquierda a derecha, éstos son:
 - muy decreciente
 - decreciente
 - poco decreciente
 - constante
 - poco creciente
 - creciente
 - muy creciente
- *CANTIDAD*: Debajo de cada gráfico se encuentra la información de la distribución de las 1200 tendencias en los siete conjuntos.

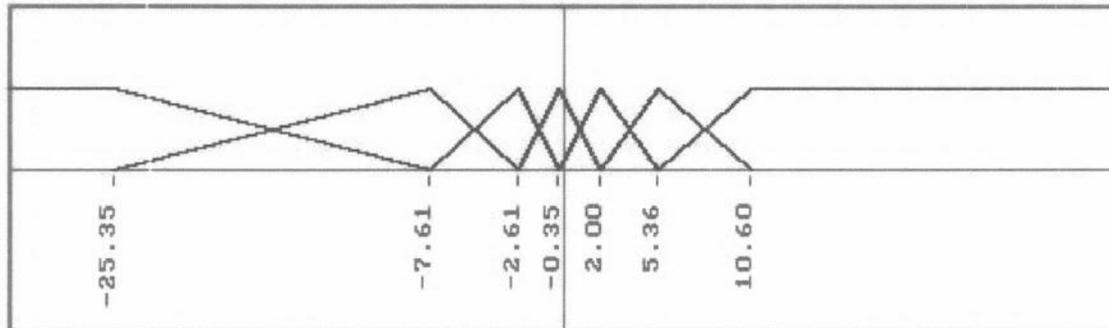
Acindar



muy decreciente ..	1	creciente	282
decreciente	30	poco creciente ...	24
poco decreciente .	134	muy creciente	1
constante	728		

Figura C.1 – Base de Datos para la especie Acindar construida con K-Means

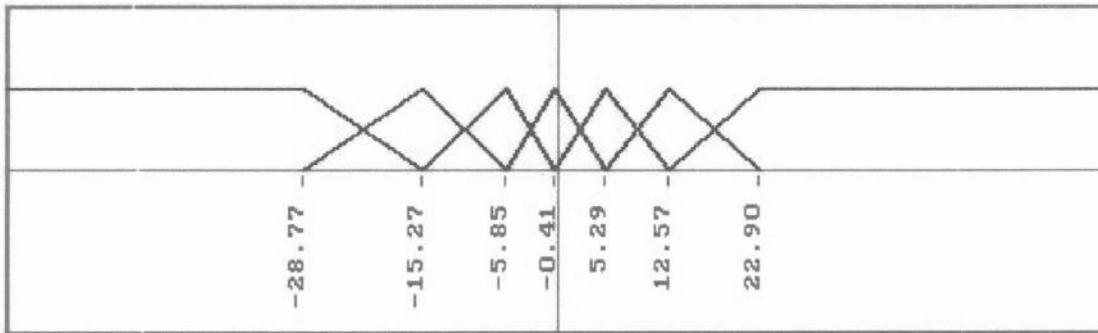
Astra



muy decreciente ..	2	creciente	288
decreciente	32	poco creciente ...	49
poco decreciente .	229	muy creciente	6
constante	594		

Figura C.2 – Base de Datos para la especie Astra construida con K-Means

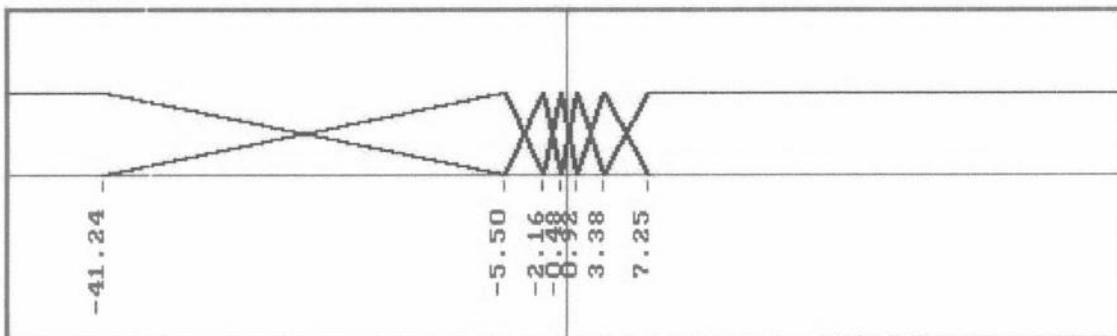
Bansud



muy decreciente ..	12	creciente	119
decreciente	42	poco creciente ...	46
poco decreciente .	145	muy creciente	20
constante	816		

Figura C.3 – Base de Datos para la especie Bansud construida con K-Means

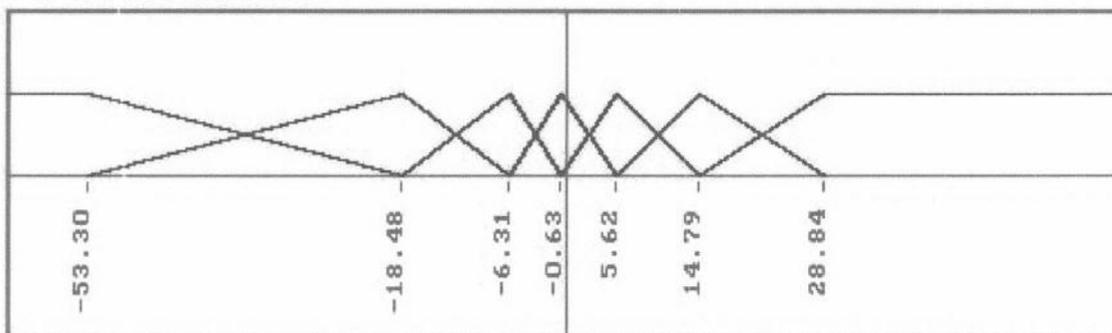
Siderca



muy decreciente ..	1	creciente	85
decreciente	19	poco creciente ...	26
poco decreciente .	38	muy creciente	2
constante	129		

Figura C.4 – Base de Datos para la especie Siderca construida con K-Means

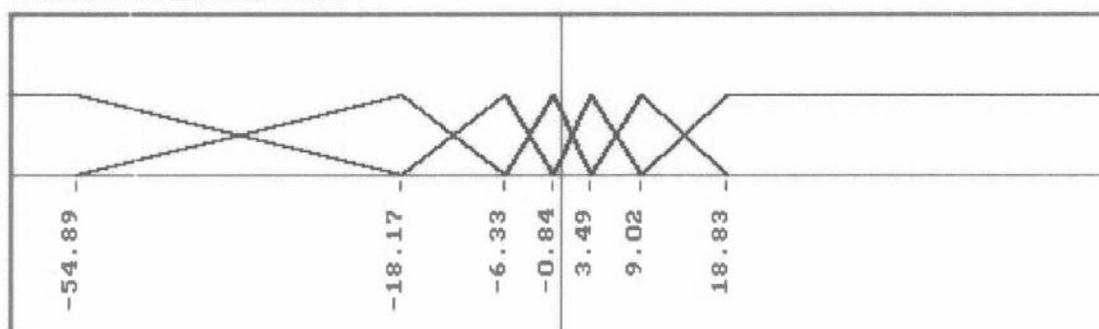
Renault_Argentina



muy decreciente ..	3	creciente	225
decreciente	36	poco creciente ...	39
poco decreciente .	206	muy creciente	8
constante	683		

Figura C.5 – Base de Datos para la especie Renault construida con K-Means

Comercial_del_Plata



muy decreciente ..	2	creciente	294
decreciente	16	poco creciente ...	77
poco decreciente .	198	muy creciente	13
constante	600		

Figura C.6 – Base de Datos para la especie Comercial del Plata construida con K-Means

Apéndice D

Método de Generación de Reglas Wang y Mendel

El Método de Generación de BR de Wang y Mendel (método WM) es uno de los métodos de diseño LM más simples y conocidos. En este método inductivo, la generación de las BR se lleva a cabo por medio de los siguientes pasos:

1. Considerar una partición difusa de los espacios de variables de entrada: Puede obtenerse de la información de expertos (si se dispone de ella) o mediante un proceso de normalización. En este último caso, realizar una partición difusa de los espacios de variables de entrada dividiendo cada universo de discurso en un número de particiones iguales o distintas, seleccionar una clase de función de pertenencia y asignar un conjunto difuso a cada subespacio.
2. Generar un conjunto de reglas lingüísticas preliminar: Este conjunto estará compuesto por la regla que mejor cubra cada ejemplo (par de datos de entrada-salida) contenido en el conjunto de datos de entrenamiento. La estructura de estas reglas se obtiene tomando un ejemplo específico, por ejemplo, un arreglo real $n+1$ -dimensional (n valores de entrada y un valor de salida) y fijando a cada una de las variables de la regla la etiqueta lingüística asociada al conjunto difuso que mejor cubre cada componente del arreglo.
3. Asignar a cada regla un grado de importancia: Sea $R_i = \text{IF } x_1 \text{ es } A_1 \text{ y } \dots \text{ y } x_n \text{ es } A_n \text{ THEN } y \text{ es } B$ la regla lingüística generada a partir del ejemplo $e_i = (x_1^i, \dots, x_n^i, y^i)$. El grado de importancia asociado a la regla se obtendrá de la siguiente manera:

$$G(R_i) = \mu_{A_1}(x_1^i) \cdot \dots \cdot \mu_{A_n}(x_n^i) \cdot \mu_B(y^i)$$

4. Obtener una RB final a partir del conjunto de reglas difusas preliminar: Para cada combinación de antecedentes, seleccionar la regla con el mayor grado de importancia.

Apéndice E

Resultados con Múltiples Estrategias de Inversión (10 estrategias)

La siguiente Tabla presenta los resultados obtenidos para la experiencia con Múltiples Estrategias de Inversión (MEI) utilizando estrategias de Tipo III con un conjunto de diez estrategias.

Secuencial	Entrenamiento				Testeo				(a)
Especie	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp	
Bancos	48.24	53.24	129.14	68.75	47.73	52.23	16.81	8.78	
Especies varias	53.26	52.19	382.42	199.58	49.61	51.58	37.69	19.44	
Aleatorio	Entrenamiento				Testeo				(b)
Especie	%Op	%Ex	Ga	Gp	%Op	%Ex	Ga	Gp	
Bancos	49.64	52.27	116.25	60.76	43.80	55.63	63.41	35.27	
Especies varias	56.76	52.03	241.72	125.77	46.91	50.98	75.62	38.55	

Tabla E.1 – Resultados de la experiencia con MEI utilizando 10 EIs (a) con datos secuenciales y (b) con datos aleatorios

Bibliografía

- [ABB94] H. M. Abbas y M.M. Fahmy. "Neural Networks for Maximum Likelihood Clustering". *Signal Processing*, vol. 36, 1:111-126. (1994)
- [ACH95] S. B. Achelis. "Technical Analysis From A To Z". McGraw-Hill Professional Publishing. (1995)
- [ALC99] R. Alcalá, J. Casillas, O. Cordon y F. Herrera. "Approximate Mamdani-Type Fuzzy Rule Based System: Features and Taxonomy of Learning Methods". Informe Técnico #DECSAI-990117. Departamento de Ciencias de la Computación e Inteligencia Artificial. E.T.S. de Ingeniería Informática. Universidad de Granada. España. (1999)
- [APP80] G. Appel y F. Hitschler. "Stock Market Trading Systems. Traders Pr. (1980)
- [BAC95] E. Backer. "Computer-Assisted Reasoning in Cluster Analysis". Prentice Hall. (1995)
- [BÄC95] Th. Bäck, H. P. Schwefel. "Evolution Strategies I: Variants and their computational implementation", "Evolution Strategies II: Theoretical aspects and implementation". *Genetic Algorithms in Engineering and Computer Science*, Ed. G. Winter, J. Perieaux, M. Gala, P. Cuesta. 111-126, 127-140. John Wiley & Sons. (1995)
- [BÄC96] Th. Bäck. "Evolutionary Algorithms in Theory and Practice". Oxford University Press. (1996)
- [BÄC97] Th. Bäck (ed.), D. B. Fogel (ed.), Z. Michalewicz (ed.). "Handbook of Evolutionary Computation". Institute of Physics Publishing. (1997)
- [BAR95] A. Bardossy y L. Duckstein. "Fuzzy Rule-Based Modeling with Application to Geophysical, Biological and Engineering Systems". CRC Press. (1995)
- [BAS94] A. Bastian. "How to Handle the Flexibility of Linguistic Variables with Applications". *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems* 2:4 463-484. (1994)
- [BAU99] E. Bauer y R. Kohavi. "An Empirical Comparison of Voting Classification Algorithms: Bagging, Boosting and Variants". *Machine Learning*, 36, 105-139. University of California. (1999)
- [BLI95] T. Blickle y L. Thiele. "A Comparison of Selection Schemes used in Genetic Algorithms". Reporte Técnico #11. Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology (ETH) Zurich, Gloriastrasse 35, CH-8092 Zurich. (1995)

- [BON93] A. Bonarini. "Learning Incomplete Fuzzy Rule Sets for an Autonomous Robot". En Proc. First European Congress on Fuzzy and Intelligent Technologies (EUFIT'93). 69-75. Aachen. (1993)
- [BOO82] L. B. Booker. "Intelligent Behavior as an Adaptation to the Task Environment". Tesis doctoral. Reporte Técnico. University of Michigan. (1982)
- [BRO92] W. Brock, J. Lakonishok y B. LeBaron. "Simple Technical Trading Rules and the Stochastic Properties of Stock Returns". The Journal of Finance. (1992)
- [BUC93] J. J. Buckley. "Sugeno Type Controllers are Universal Approximators". Fuzzy Sets and Systems 53:299-304. (1993)
- [CAP96] C. Carpineto y G. Romano. "A Lattice Conceptual Clustering System and Its Application to Browsing Retrieval". Machine Learning. 24(2):95-122. (1996)
- [CAR96] B. Carse, T. C. Fogarty y A. Munro. "Evolving Fuzzy Rule Based Controllers usind Genetic Algorithms". Fuzzy Sets and Systems. 80 273-294. (1996)
- [CAS95] J. L. Castro. "Fuzzy Logic Controlers are Universal Approximators". En IEEE Transactions on Systems, Man, and Cybernetics 25 (4): 629-635. (1995)
- [CHA94] T. S. Chande y S. Kroll. "The New Technical Trader: Boost Your Profit by Plugging Into the Latest Indicators". John Wiley & Sons. (1994)
- [CHA96] L. K. C. Chan, N. Jegadeesh y J. Lakonishok. "Momentum Strategies". The Journal of Finance. (1996)
- [CHE96] U. Cherubini y A. Sironi. "Bond Trading, Market Anomalies and Neural Networks: An analysis with Kohonen Nets". Banca Commerciale Italiana. Economic Research Department. (1996)
- [COL88] R. W. Colby y Th. A. Meyers. "The Encyclopedia of Technical Market Indicators". McGraw-Hill Professional Publishing. (1988)
- [COM97] D. Compton y T. Hill. "Technical Stock Trading Rules Engine using a GA". Department of General Engineering. University of Illinois, at Urbana-Champaign. (1997)
- [COR96] O. Cerdón, M. J. del Jesús y F. Herrera. "Sistema de Clasificación con Reglas Difusas utilizando Algoritmos Genéticos". En Proc. VI Congreso Español sobre Tecnologías y Lógica Fuzzy (ESTYLF'96). 95-100. Oviedo. (1996)

- [COR97] O. Cordón. "Una Metodología para el Diseño Automático de Sistemas Basados en Reglas Difusas mediante Algoritmos Evolutivos". Tesis Doctoral. Departamento de Ciencias de la Computación e Inteligencia Artificial. E.T.S. de Ingeniería Informática. Universidad de Granada. España. (1997)
- [COR99] O. Cordón, M.J. del Jesus y F. Herrera. "A proposal on reasoning methods in fuzzy rule/based classification systems". Reporte Técnico #DECSAI-970126. Departamento de Ciencias de la Computación e Inteligencia Artificial. E.T.S. de Ingeniería Informática. Universidad de Granada. España. 1999
- [COR01] O. Cordón. "Genetic Fuzzy Systems". World Scientific Pub Co.(2001)
- [CUR00] "Curso de Simulación Bursátil". Facultad de Ciencias Económicas. Universidad de Buenos Aires. (2000)
- [DAC97] M. Dacorogna. "The Main Ingredients of Simple Trading Models for Use in Genetic Algorithm Optimization". Olsen and Associates. (1997)
- [DEB94] G. J. Deboeck. "Trading on the Edge: Neural, Genetic, and Fuzzy Systems for Chaotic Financial Markets". John Wiley & Sons. (1994)
- [DEJ93] K. A. DeJong, W. M. Spears y D. F. Gordon. "Using Genetic Algorithms for Concept Learning". Machine Learning. 13:161-188. (1993)
- [DRI93] D. Driankov, H. Hellendoorn y M. Reinfrank. "An Introduction to Fuzzy Control". Springer-Verlag. (1993)
- [EDW92] R. D. Edwards y J. Magee. "Technical Analysis of Stock Trends". Prentice Hall Press. (1992)
- [FOG66] L. J. Fogel y M. J. Walsh. "Artificial Intelligence through Simulated Evolution". John Wiley & Sons. (1966)
- [FOG91] D. B. Fogel. "System Identification through Simulated Evolution, A Machine Learning Approach". Ginn Press. (1991)
- [FOS92] N. G. Fosback. "Stock Market Logic". Inst for Econometric Research. (1992)
- [FRI99] H. Frigui y R. Krishnapuram. "A Robust Competitive Clustering Algorithm with Aplications in Computer Vision". En IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 21, no. 5, 450-465. (1999)
- [FRI01] H. Friedl y E. Stampfer. "Cross-Validation". A ser publicado en: Encyclopedia of Environmetrics. John Wiley & Sons. (2001)

- [FRK96] A. Frick, R. Herrmann, M. Kreidler, A. Narr y D. Seese. "A Genetic-Base Approach for the Derivation of Trading Strategies on the German Stock Market". Institute for Decision Theory and Enterprise Research. Department of Economic Sciences. University of Karlsruhe/Germany. (1996)
- [GIL95] J. Gilbert. "Artificial Intelligence on Wall Street: An Overview and Critique of Applications in the Finance Industry". Material for the COSI 35 course. (1995)
- [GOL89] D. E. Goldberg. "Genetic Algorithms in Search, Optimization, and Machine Learning". Addison Wesley. (1989)
- [GOL98] D. E. Goldberg. "A Meditation on the Application of Genetic Algorithms". IlliGAL Reporte técnico #98003. Department of General Engineering. University of Illinois, at Urbana-Champaign. (1998)
- [GOL00] D. E. Goldberg. "A Meditation on the Computational Intelligence and Its Future". IlliGAL Reporte técnico #2000019. Department of General Engineering. University of Illinois, at Urbana-Champaign. (2000)
- [GOO95] S. Goonatilake y P. Treleaven. "Intelligent Systems for Finance and Bussiness". John Wiley & Sons. (1995)
- [GRE88] J.J. Grefenstette. "Credit Assignment in Rule Discovery Systems Based on Genetic Algorithms". Machine Learning, Vol. 3. 225-245. (1988)
- [GRE94] J.J. Grefenstette (ed.). "Genetic Algorithms for Machine Learning". Kluwer Academic. (1994)
- [HAR93] C. J. Harris, C. G. Moore y M. Brown. "Intelligent Control. Aspects of Fuzzy Logic and Neural Networks". World Scientific. (1993)
- [HER97] F. Herrera y L. Magdalena. "Genetic Fuzzy System: A Tutorial". Departamento de Ciencias de la Computación e Inteligencia Artificial. E.T.S. de Ingeniería Informática. Universidad de Granada. España. (1997)
- [HEX95] R. Hexton. "Technical Analysis in the Options Market: The Effective Use of Computerized Trading Systems". John Wiley & Sons. (1995)
- [HIR93] K. Hirota. "Industrial Applications of Fuzzy Technology". Springer-Verlag. (1993)
- [HOL75] A. Arbor y J. H. Holland. "Adaptation in Natural and Artificial Systems". The MIT Press. (1975)

- [HOL78] J. H. Holland y J. S. Reitman. "Cognitive Systems Based on Adaptive Algorithms". En Waterman D. A. y Hayes-Roth F. (Eds.) *Pattern-Directed Inference Systems*. Academic Press. (1978)
- [HOL86] J. H. Holland. "Escaping brittleness: The Possibilities of General Purpose Learning Algorithms Applied to Parallel Rule-Based Systems". En Michalski R., Carbonell J. y Michel T. (Eds.), *Machine Learning: An AI approach, Vol II*, 593-623, Morgan-Kaufmann. (1986)
- [HOR95] J. Horn. "Genetic Algorithms, Problem Difficulty, and the Modality of Fitness Landscapes". *IlliGAL Reporte técnico #95004*. Department of General Engineering. University of Illinois, at Urbana-Champaign. (1995)
- [ISH92] H. Ishibuchi , K. Nozaki y H. Tanaka. "Distributed Representation of Fuzzy Rules and Its Applications to Pattern Classification". *Fuzzy Sets and Systems*. 52 21-32. (1992)
- [ISH93] H. Ishibuchi , K. Nozaki y H. Tanaka. "Efficient Fuzzy Partition of Pattern Spaces for Classification Problems". *Fuzzy Sets and Systems*. 59 295-304. (1993)
- [ISH95] H. Ishibuchi , K. Nozaki, N. Yamamoto y H. Tanaka. "Selected Fuzzy If-Then Rules for Classification Problems Using Genetic Algorithms". En *IEEE Transactions on Fuzzy Systems* 3:3 260-270. (1995)
- [JAI98] A. K. Jain y R. C. Dubes. "Algorithms for Clustering Data". Prentice Hall. (1988)
- [JAI00] A.K. Jain y R.P.W. Duin. "Statistical pattern recognition: a review". En *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1):4-37. (2000)
- [JES99] Ma. J. del Jesús y Francisco Herrera. "Influencia del uso de Modificadores Lingüísticos y Grados de Certeza en un Sistema de Clasificación Basado en Reglas Difusas". Departamento de Ciencias de la Computación e Inteligencia Artificial. E.T.S. de Ingeniería Informática. Universidad de Granada. España . (1999)
- [JUD98] D. Judd, P. Mckinley y A. K. Jain. "Large-Scale Parallel Data Clustering". En *Proc. Int'l Conference on Pattern Recognition*. (1998)
- [KAE95] L. P. Kaelbling, M. L. Littman y A. W. Moore. "Reinforcement Learning: A Survey". *Journal of Artificial Intelligence Research*, vol. 4, 237-285. (1995)
- [KEO97] E. J. Keogh y M. J. Pazzani. "An Enhanced Representation of Time Series which Allows Fast and Accurate Classification, Clustering and Relevance Feedback". En *Fourth conference on Knowledge Discovery in Databases and Data Mining*. New York. (1997)

- [KOS92] B. Kosko. "Neural Networks and Fuzzy Systems". Prentice Hall. (1992)
- [KOZ92] J. Koza. "Genetic Programming. On the Programming of Computers by Means of Natural Selection". The MIT Press. (1992)
- [LEE90] C. C. Lee. "Fuzzy Logic in Control Systems: Fuzzy Logic Controller" – parts I and II. En IEEE Transactions on Systems, Man and Cybernetics, 20(2):404-418, 419-435. (1990)
- [MAH96] S. Mahfoud y G. Mani. "Financial Forecasting using Genetic Algorithms". Applied Artificial Intelligence, 10:543-565 Taylor & Francis. (1996)
- [MCK83] R. S. Michalski. "A Theory and Methodology of Inductive Learning". En Machine Learning: An Artificial Intelligence Approach eds. R. S. Michalski, J. G. Carbonell y T. M. Mitchell, 83-134 Palo Alto, Calif: Tioga. (1983)
- [MCL93] P. C. McCluskey. "Feedforward and Recurrent Neural Networks and Genetic Programs for Stock Market and Time Series Forecasting". Department of Computer Science. Brown University. Providence. Rhode Island 02912 CS-93-36. (1993)
- [MIC96] Z. Michalewicz. "Genetic Algorithms + Data Structures = Evolution Programs". Springer-Verlag. (1996)
- [MIL95] B. L. Miller y D. E. Goldberg. "Genetic Algorithms, Selection Schemes, and the Varying Effects of Noise". IlliGAL Informe técnico #95009, Department of General Engineering, University of Illinois, at Urbana-Champaign. (1995)
- [MIT97] T. Mitchell. "Machine Learning". McGraw-Hill Professional Publishing. (1997)
- [MUR86] J. Murphy. "Technical Analysis of the Futures Markets". Prentice Hall Press. (1986)
- [OSM96] I. H. Osman (ed.), J. P. Kelly (ed.). "Metaheuristics: Theory and Applications". Kluwer Academic Press. (1996)
- [PED96] W. Pedrycz. "Fuzzy Modeling: Paradigms and Practice". Kluwer Academic Press. (1996)
- [PRI91] M. J. Pring. "Technical Analysis Explained: The Successful Investor's Guide to Spotting Investment Trends and Turning Points". John Wiley & Sons. (1991)
- [RUS96] S. Russell y P. Norvig. "Inteligencia Artificial. Un enfoque moderno". Prentice Hall. (1996)

- [SCH95] H. P. Schwefel. "Evolution and Optimum seeking". McGraw-Hill Professional Publishing. (1995)
- [SMI80] S. F. Smith. "A Learning System Based on Genetic Adaptive Algorithms". Tesis doctoral. University of Pittsburgh. Pittsburgh. (1980)
- [SUG93] M. Sugeno y T. Yasukawa. "A Fuzzy-Logic-Based Approach to Qualitative Modeling". En IEEE Transactions on Fuzzy Systems, 1 (1):7-31. (1993)
- [THI96] D. Thierens. "Selection Schemes. Elitist Recombination and Selection Intensity". En Th. Bäck, ed., Proceedings of the 7th International Conference on Genetic Algorithms, 152-159. Morgan Kaufmann. San Mateo. (1996)
- [VIL94] P. Villar, O. Cordón y F. Herrera. "Analysis and Guidelines to Obtain a Good Uniform Fuzzy Partition Granularity for Fuzzy Rule-Based Systems Using Simulated Annealing". International Journal of Approximate Reasoning 11:1-158. Elsevier Science Inc. (1994)
- [WAN92] L. X. Wang. "Fuzzy Systems are Universal Approximators". En Proc. First IEEE International Conference on Fuzzy Systems (FUZZYEEE'92) 1163-1170. San Diego. (1992)
- [WAN94] L. X. Wang. "Adaptive Fuzzy Systems and Control". Prentice Hall. (1994)
- [WEI98a] A. S. Weigend, F. Chen, S. Figlewski y L. N. Stern. "Discovering Technical Traders in the T-bond Futures Market". Leonar N. Stern School of Bussiness. New York University. (1998)
- [WEI98b] F. Chen, S. Figlewski, A. S. Weigend y L. N. Stern. "Modeling financial data using clustering and tree-based approaches". En International Conference on Data Mining, Southampton, UK.: Computational Mechanics Publications. (1998)
- [WON94] F. Wong y C. Tan. "Hybrid Neural, Genetic and Fuzzy Systems". En Trading on the Edge: Neural, Genetic, and Fuzzy Systems for Chaotic Financial Markets. John Wiley & Sons. (1994)
- [WRI91] A. H. Wright. "Genetic Algorithms for Real Parameter Optimization". G. J. E. Rawlins (Ed.), Foundations of Genetic Algorithms, 205-218. (1991)
- [YE94] Z. Ye y L. Gu. "A Fuzzy System for Trading the Shanghai Stock Market". En Trading on the Edge: Neural, Genetic, and Fuzzy Systems for Chaotic Financial Markets. John Wiley & Sons. (1994)
- [ZAD65] L. A. Zadeh. "Fuzzy Sets". Information and Control. 8:338-353. (1965)

- [ZAD73] L. A. Zadeh. "Outline of a New Approach to the Analysis of Complex Systems and Decision Processes". En IEEE Transactions on Systems, Man and Cybernetics, 3:28-44. (1973)
- [ZAD75] L. A. Zadeh. "The Concept of Linguistic Variable and its Application to Approximate Reasoning". Information Science Parte I: 8 199-249, Parte II: 8 301-357, Parte III: 9 43-80. (1975)
- [ZWI00] J. S. I. Zwir. "Sistemas Jerárquicos de Reglas Difusas y sus Metodologías de Aprendizaje Asociadas". Tesis Doctoral. Departamento de Ciencias de la Computación e Inteligencia Artificial. E.T.S. de Ingeniería Informática. Universidad de Granada. España. (2000)