



Data Mining.

Extracción de Conocimiento en Grandes Bases de Datos

<http://etsiso2.macc.unican.es/~meteo>



José M. Gutiérrez
*Dpto. de Matemática Aplicada,
Universidad de Cantabria, Santander*

<http://personales.unican.es/gutierjm>

UC

UNIVERSIDAD DE CANTABRIA

El Mundo de la Información y sus Problemas.

- **Cada vez se genera más información** y se hace más fácil el acceso masivo a la misma (existen gran cantidad de bases de datos on-line)
 - ✓ Transacciones bancarias, Internet y la Web, observaciones científicas (biología, altas energías, etc.) "tranNASA's EOS (Earth Observation System)".
- La **tecnología es barata** y los **sistemas de gestión de bases de datos** son capaces de trabajar con cantidades masivas de datos (Terabytes).

Los datos contienen información útil **"CONOCIMIENTO" !!!**

- Necesitamos **extraer** información (**conocimiento**) de estos datos:
 - ✓ **Rapidez y confiabilidad.**
 - ✓ Capacidad de **modelización y escalabilidad.**
 - ✓ **Explicación e Interpretación de los resultados (visualización, ...).**

WalMart captura transacciones de 2900 tiendas en 6 países. Esta información e acumula en una base de datos masiva de 7.5 terabyte. WalMart permite que más de 3500 proveedores accedan a los datos relativos a sus productos para realizar distintos análisis. Así pueden identificar clientes, patrones de compras, etc. En 1995, WalMart computers procesó más de un millón de consultas complejas.

Datos, Información y Conocimiento.

¿Qué diferencias hay entre información, datos y conocimiento?

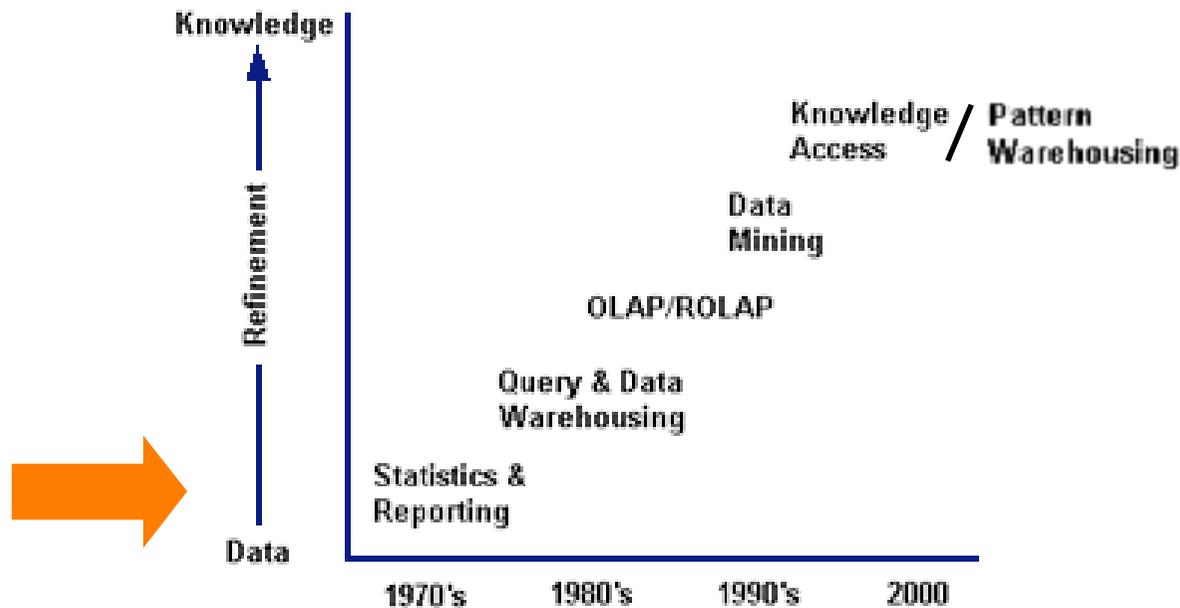
- ✓ Informalmente se utilizan indistintamente, con pequeños matices.
- ✓ **información** y **datos** se pueden referir a cualquier cosa, aunque “Datos” suele referir a la “evidencia”.
- ✓ **Conocimiento** es subjetivo:
 - depende de las intenciones (**objetivo del aprendizaje**).
 - debe ser **inteligible** para el que aprende o el que encarga el **aprendizaje** (usuario).

¿Qué es aprendizaje?

- ✓ (visión genérica, Mitchell 1997) es **mejorar el comportamiento** a partir de la experiencia. Aprendizaje = Inteligencia.
- ✓ (visión más estática) es la **identificación de patrones**, de **regularidades**, existentes en la evidencia.
- ✓ (visión externa) es la **predicción** de observaciones futuras con **plausibilidad**.
- ✓ (visión teórico- informacional, Solomonoff 1966) es **eliminación de redundancia = compresión de información**.

Acceso a los Datos. Evolución histórica.

La necesidad de almacenar información ha motivado históricamente el desarrollo de sistemas más eficientes, con mayor capacidad y más baratos de almacenamiento.



- **Bases de datos relacionales.**
- **DBMS** (Data Base Management Systems) **y repositorios de información:**
 - Bases de datos orientadas a objetos y objeto-relacionales.
 - Bases de datos espaciales (geográficas).
 - Bases de datos de texto y multimedia.
 - WWW.

OLAP (On-Line Analytical Processing)

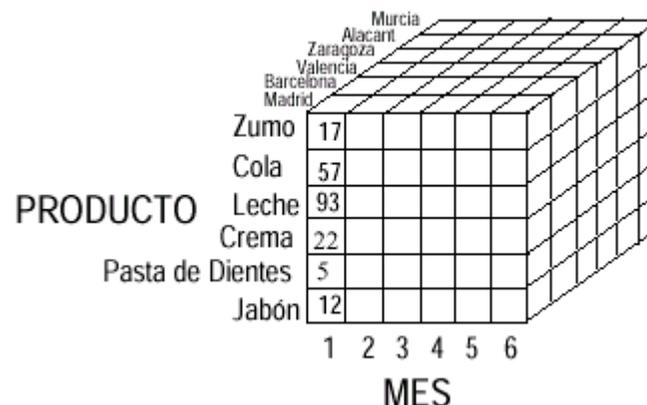
Sobre estas mismas bases de datos de trabajo ya se puede extraer conocimiento (visión tradicional).

- ✓ **Se mantiene el trabajo transaccional** diario de los sistemas de información originales (conocido como **OLTP**, *On-Line Transactional Processing*).
- ✓ Se hace **análisis de los datos en tiempo real** sobre la misma base de datos(conocido como **OLAP**, *On-Line Analytical Processing*),

Según la organización de la información copiada se distingue:

- ✓ **ROLAP** (Relational OLAP): el almacén de datos es relacional.
- ✓ **MOLAP** (Multidim OLAP): el almacén de datos es una matriz multidimensional.

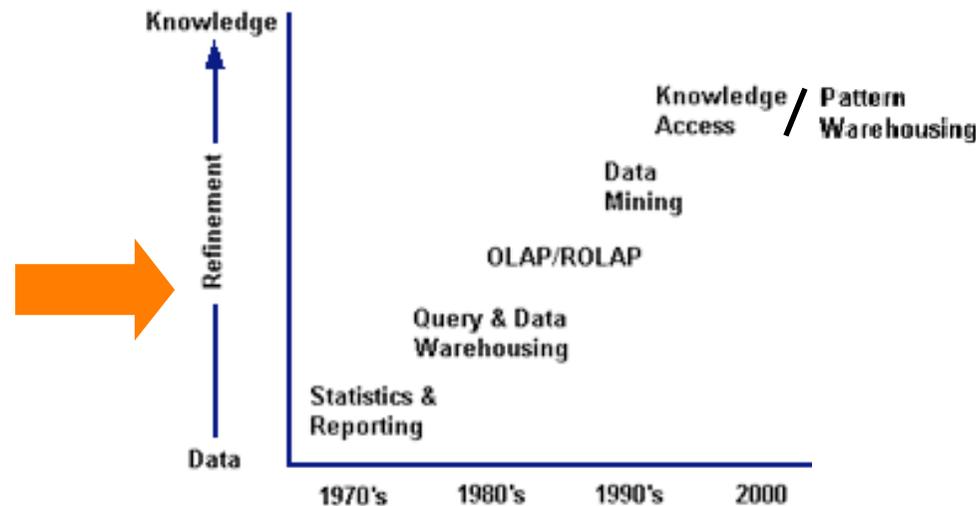
Cada atributo relevante se establece en una dimensión, que se puede agregar o desagregar.



Las dimensiones se agregan:



Data Warehouses. Génesis.



PROBLEMAS:

- ✓ Disturba el trabajo transaccional diario de los sistemas de información originales (“*killer queries*”). Se debe hacer por la noche o en fines de semana.
- ✓ La base de datos está diseñada para el trabajo transaccional, no para el análisis de los datos. Generalmente no puede ser en tiempo real (era AP pero no OLAP).

Para poder operar eficientemente con esos datos y debido a que los costes de almacenamiento masivo y conectividad se han reducido drásticamente en los últimos años, parece razonable recoger (copiar) los datos en un sistema unificado.

Data Warehouses

DATA-WAREHOUSES (Almacenes de Datos): Se separan de los datos a analizar con respecto a sus fuentes transaccionales (se copia/ almacena toda la información histórica).

Existe toda una tecnología creciente de cómo organizarlos y sobretodo de cómo tenerlos actualizados (cargas periódicas) respecto a los datos originales

VENTAJAS:

- ✓ Facilita el análisis de los datos en tiempo real (**OLAP**),
- ✓ No disturba el **OLTP** de las bases de datos originales.

A partir de ahora diferenciaremos entre bases de datos para OLTP (tradicional) y almacenes de datos (KDD sobre data warehouses).

	OLTP	Data Warehouse
Purpose	Run day-to-day operations	Information retrieval and analysis
Structure	RDBMS	RDBMS
Data Model	Normalised	Multi-dimensional
Access	SQL	SQL plus data analysis extensions
Type of Data	Data that runs the business	Data that analyses the business
Condition of Data	Changing, incomplete	Historical, descriptive

Construcción de un Data Warehouse



Limpieza y criba selección de datos:

*Se deben eliminar el mayor número posible de datos erróneos o **inconsistentes** (limpieza) e **irrelevantes** (criba).*

Se aplican métodos estadísticos:

- Histogramas (detección de datos anómalos).*
- Redefinición de atributos (agrupación o separación).*

Muy relacionado con la disciplina de "Calidad de Datos".

Acciones ante datos anómalos (outliers):

- **Ignorar**: algunos algoritmos son robustos a datos anómalos.
- **Filtrar** (eliminar o reemplazar) la columna: solución extrema.
- **Discretizar**: transformar un valor continuo en uno discreto (p. ej. muy alto, alto, etc.) hace que los outliers caigan en 'muy alto' o 'muy bajo' sin mayores problemas.

Acciones ante datos faltantes (missing values):

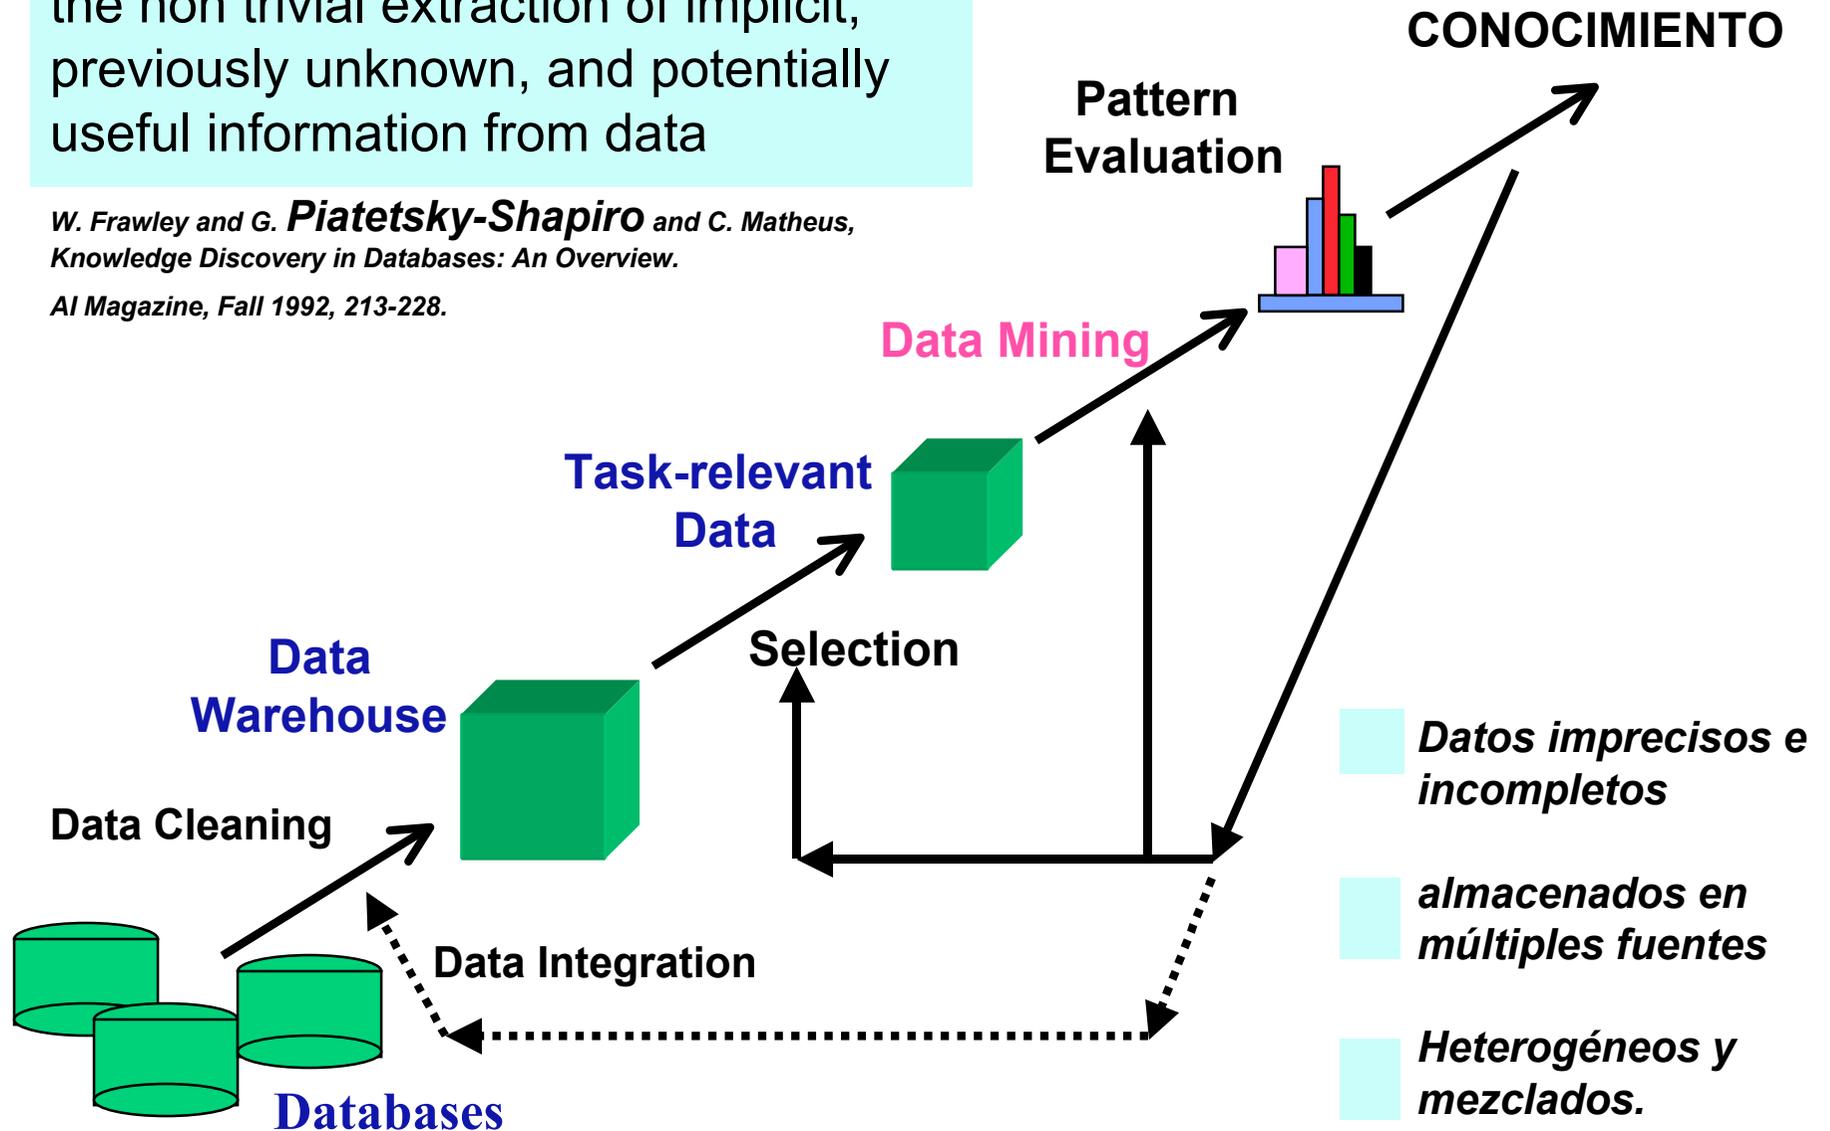
- **Ignorar**: algunos algoritmos son robustos a datos faltantes.
- **Filtrar** (eliminar o reemplazar) la columna
- **Reemplazar** el valor: por medias. A veces se puede *predecir* a partir de otros datos, utilizando cualquier técnica de ML.

¿Qué es Data Mining (minería de datos)?

the non trivial extraction of implicit, previously unknown, and potentially useful information from data

W. Frawley and G. *Piatetsky-Shapiro* and C. Matheus,
Knowledge Discovery in Databases: An Overview.

AI Magazine, Fall 1992, 213-228.



Diferencias entre DBMS y Data Mining

En los sistemas estándar de gestión de bases de datos las consultas se resuelven accediendo a distintos conjuntos de datos almacenados:

- ✓ *Ventas del último mes de un producto.*
- ✓ *Ventas agrupadas por la edad del comprador.*

Los sistemas de data mining infieren conocimiento de la base de datos en forma de estructuras y patrones. Este conocimiento supone un nuevo conjunto de información en base a la cual se responden las consultas:

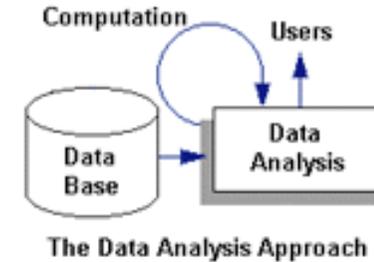
- ✓ *por qué es tan rentable la división Iberoamericana de Telefónica?*
- ✓ *¿qué clientes son potenciales compradores de un producto?*
- ✓ *¿cuál será el beneficio de la compañía el mes próximo?*

Acceso a Datos vs. Acceso a Conocimiento

Paradigma de Acceso a Datos:

El usuario solicita datos y procesa los datos recibidos en busca de "conocimiento".

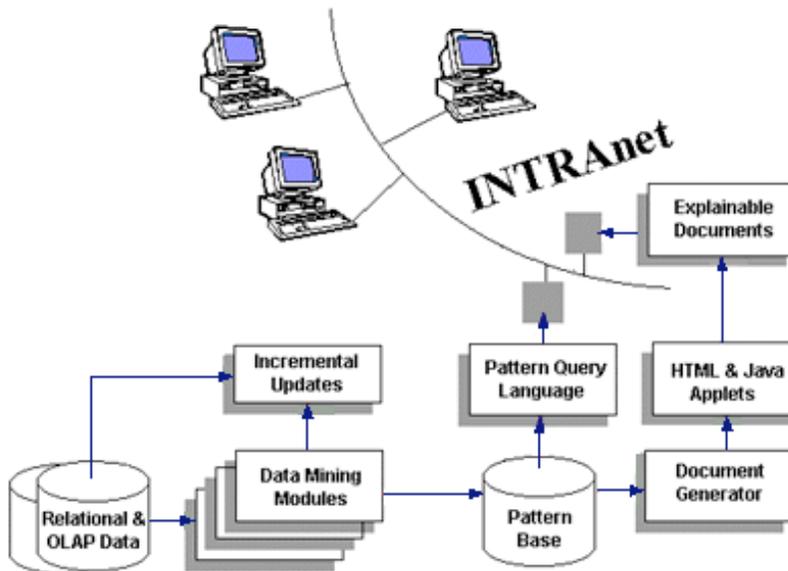
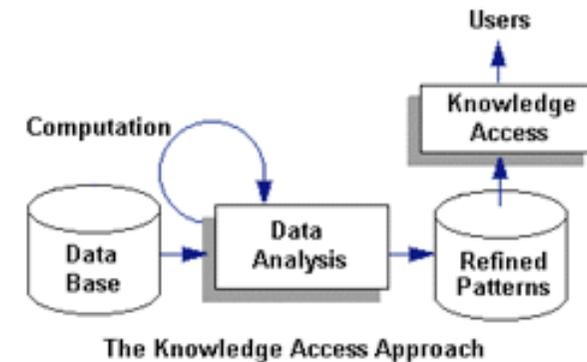
SQL + algoritmos de data mining.



Paradigma de Acceso a Conocimiento:

El sistema genera automáticamente patrones de conocimiento refinados y el usuario accede directamente a los mismos.

PQL = Pattern Query Lenguaje

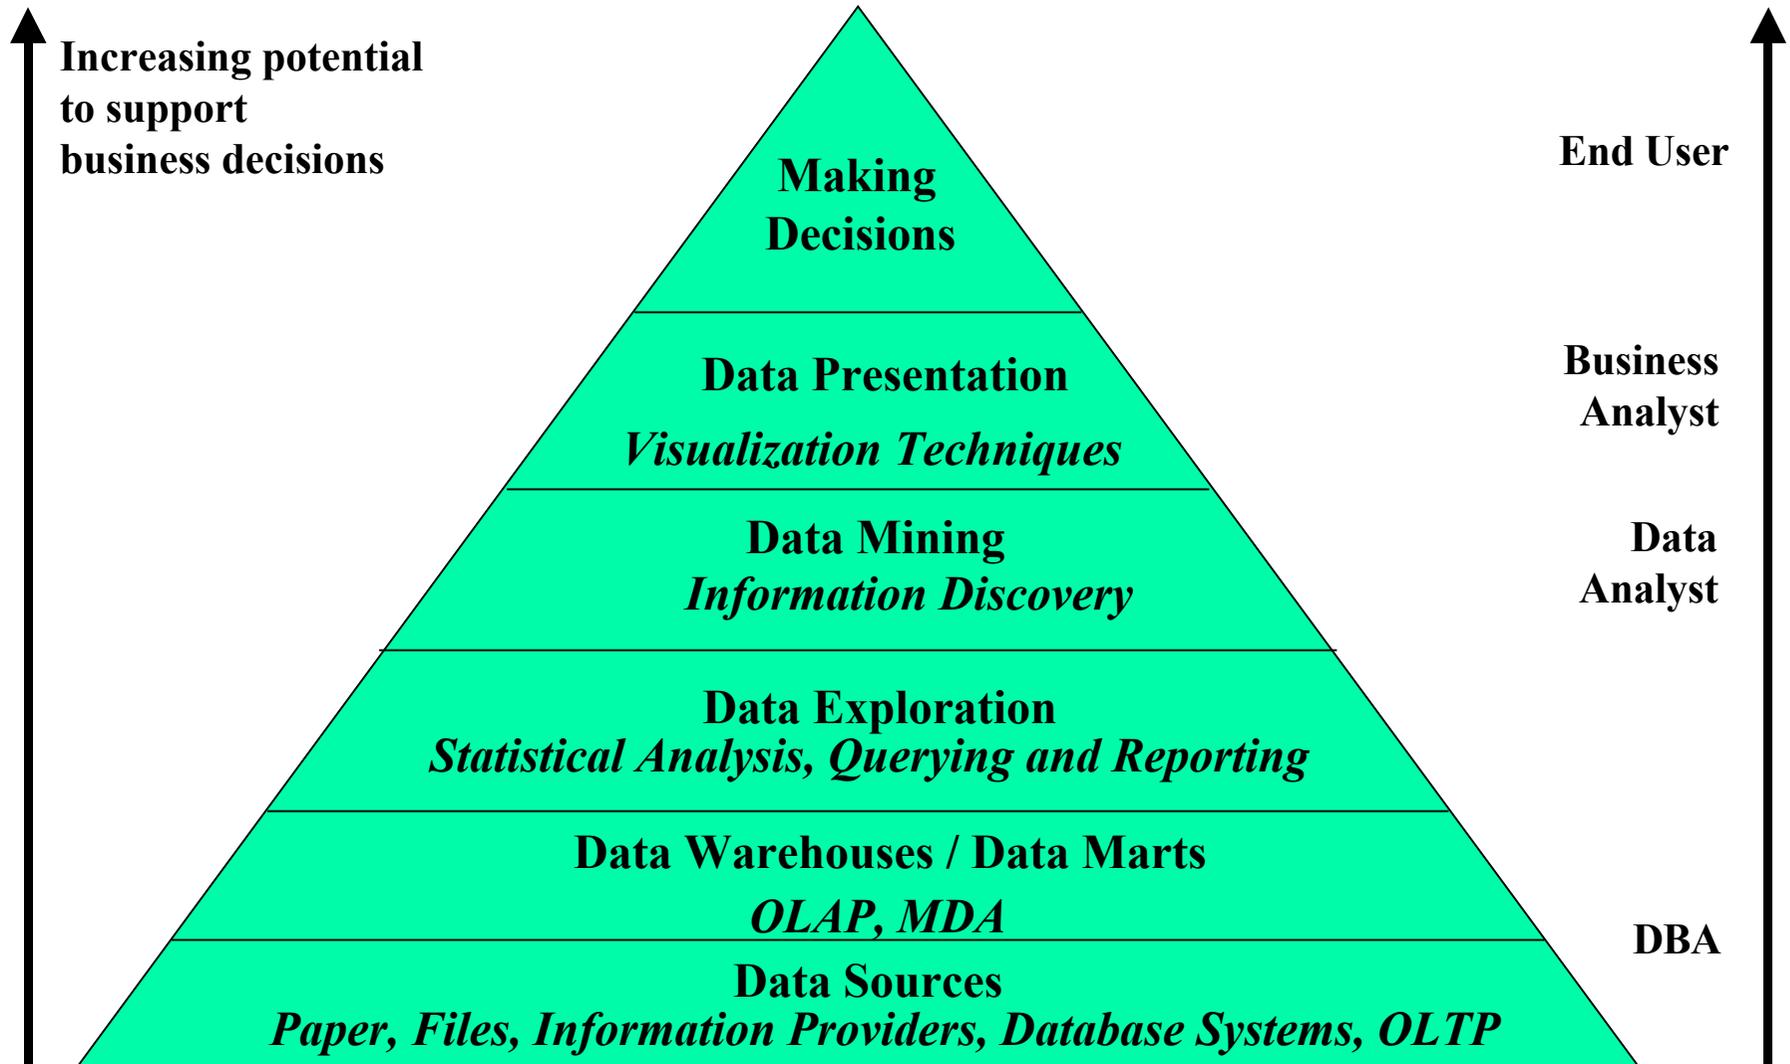


PQL was designed to access patterns just as **SQL was designed to access data**. PQL resembles SQL, works atop existing SQL engines.

Information Discovery uses a *Pattern Warehouse*TM of refined information and PQL works on patterns just as SQL works on a datawarehouse. While SQL relies on the relational algebra, **PQL uses the "pattern algebra"**. PQL allows pattern-based queries just as SQL allows data-based queries. And, PQL uses SQL as part of its operation, i.e. **PQL queries are decomposed into a set of related SQL queries**, the Pattern Warehouse is accessed with these queries and the results are re-combined for display to the user. The user accesses these patterns using a web browser.

Data Mining and Business Intelligence

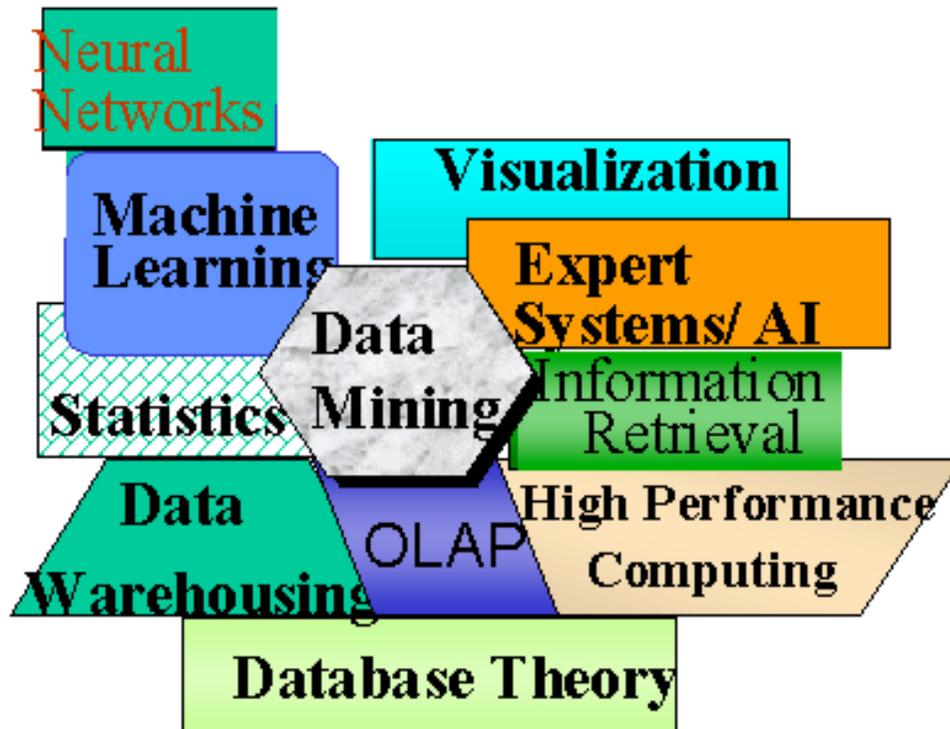
Jiawei Han
Intelligent Database System Research Lab
<http://www.cs.sfu.ca/~han>



Multidisciplinar. Areas y Técnicas Involucradas

variety of techniques to identify nuggets of information or decision-making knowledge in bodies of data, and *extracting* these in such a way that they can be put to use in the areas such as decision support, prediction, forecasting and estimation. The data is often voluminous, but as it stands of low value as no direct use can be made of it; **it is the hidden information in the data that is useful.**

Areas Involucradas



✓ Componentes Principales:

compresión de la información.

✓ Componentes Independientes:

extracción de características.

✓ Modelado de Dependencias:

*hallar asociaciones entre variables.
redes Bayesianas*

✓ Agrupación:

hallar grupos de elementos.

✓ Clasificación:

asignar elementos a clases.

✓ Predicción:

estimación de valores.

✓ Visualización:

representación gráfica.

Redes Neuronales

Estadística y Ciencias de la Computación

- **Estadística**
 - 1970: EDA, estimación Bayesiana, modelos flexibles, EM, etc
 - Conciencia sobre el papel de la computación en el análisis de datos.
- **Reconocimiento de Patrones e Inteligencia Artificial**
 - Atención dirigida a problemas de percepción (e.g., habla, visión)
 - 1960: división en técnicas estadísticas y no estadísticas (gramáticas, etc.)
 - Convergencia de estadística aplicada e ingeniería (análisis imágenes, Geman)
- **Aprendizaje Automático y Redes Neuronales**
 - 1980: fracaso de las técnicas de aprendizaje no estadísticas
 - Aparición de modelos flexibles (árboles, redes)
 - Convergencia de estadística aplicada y aprendizaje
 - e.g., trabajos de Friedman, Spiegelhalter, Jordan, Hinton

IA / Aprendizaje Automático

Extracción automática de conocimiento

1989 KDD workshop

ACM SIGKDD 2000

Bases de Datos

Bases de datos masivas

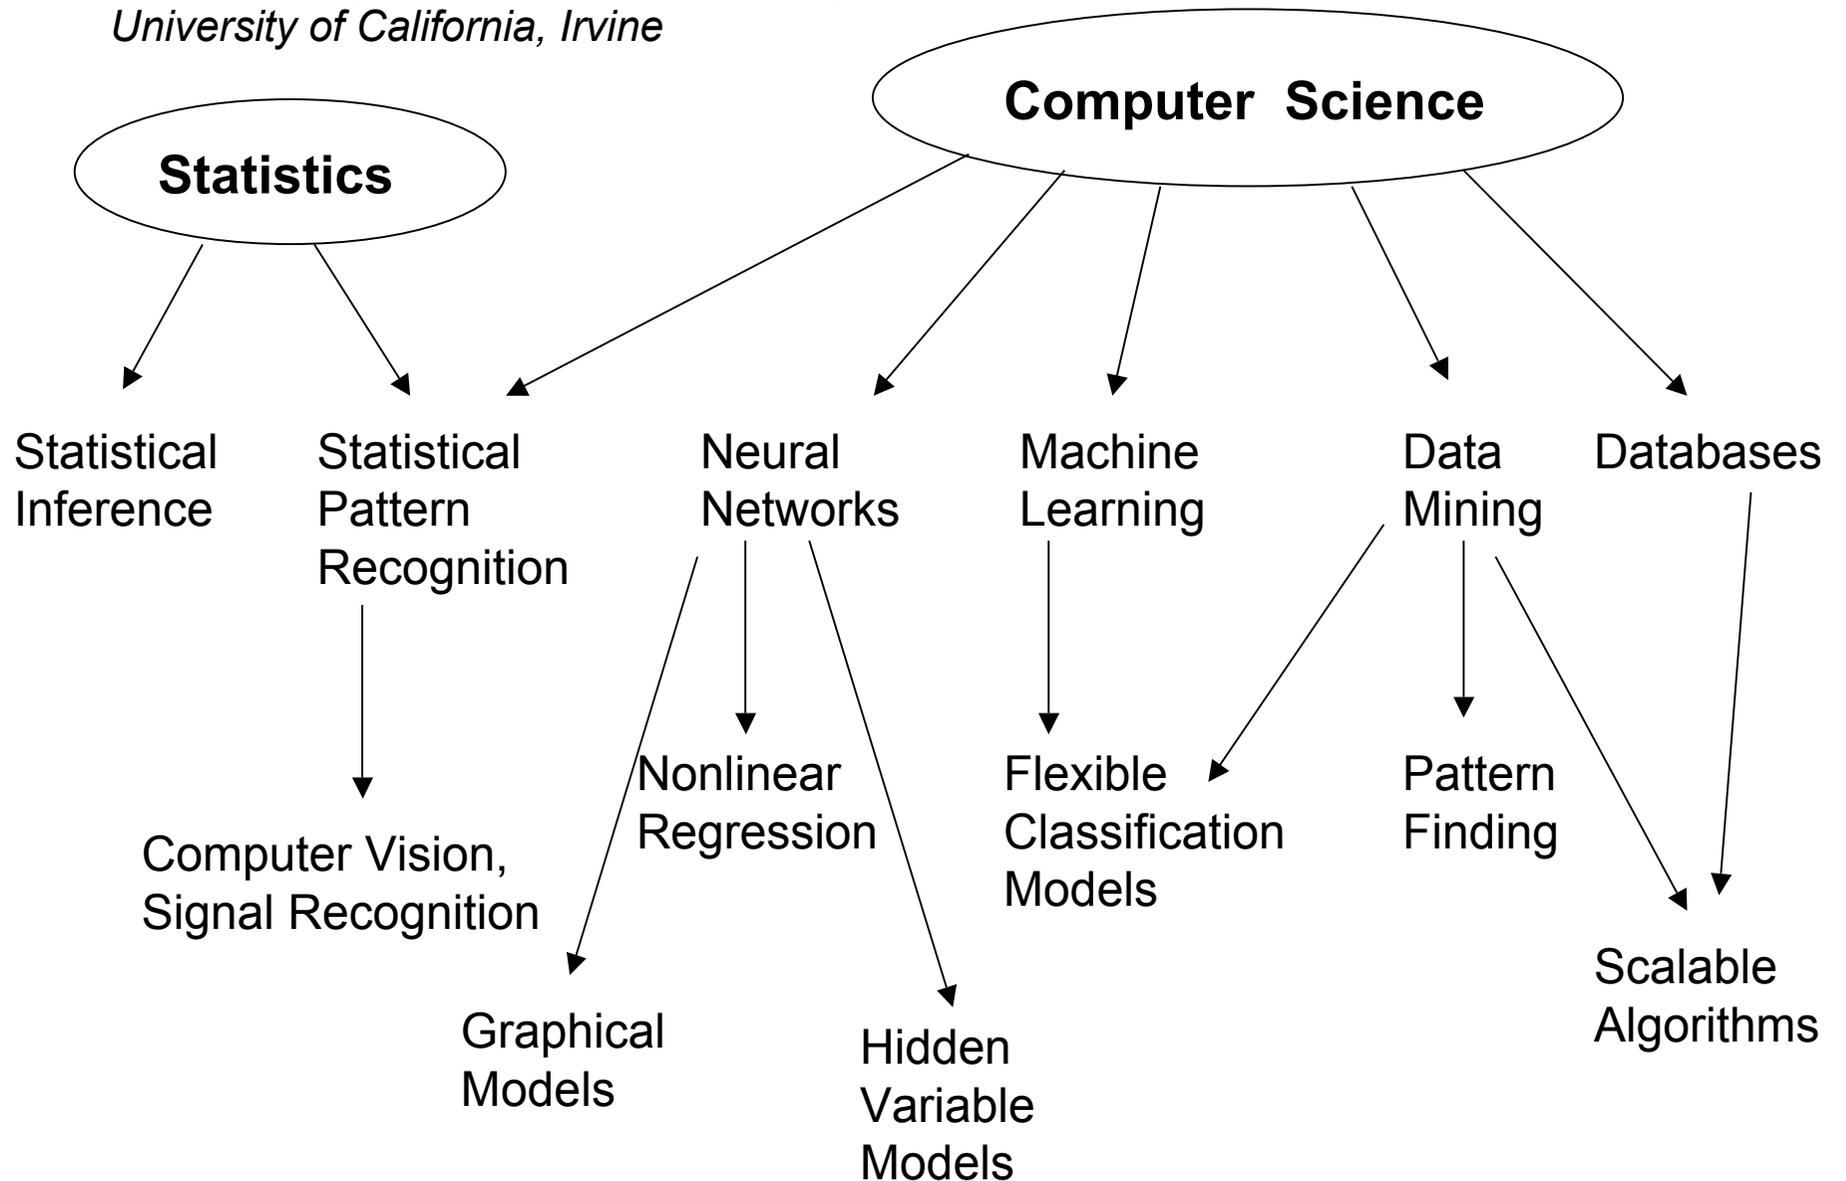
Reglas de asociación

Algoritmos escalables

MINERIA DE DATOS

Focus Areas

*Padhraic Smyth. Information and Computer Science
University of California, Irvine*

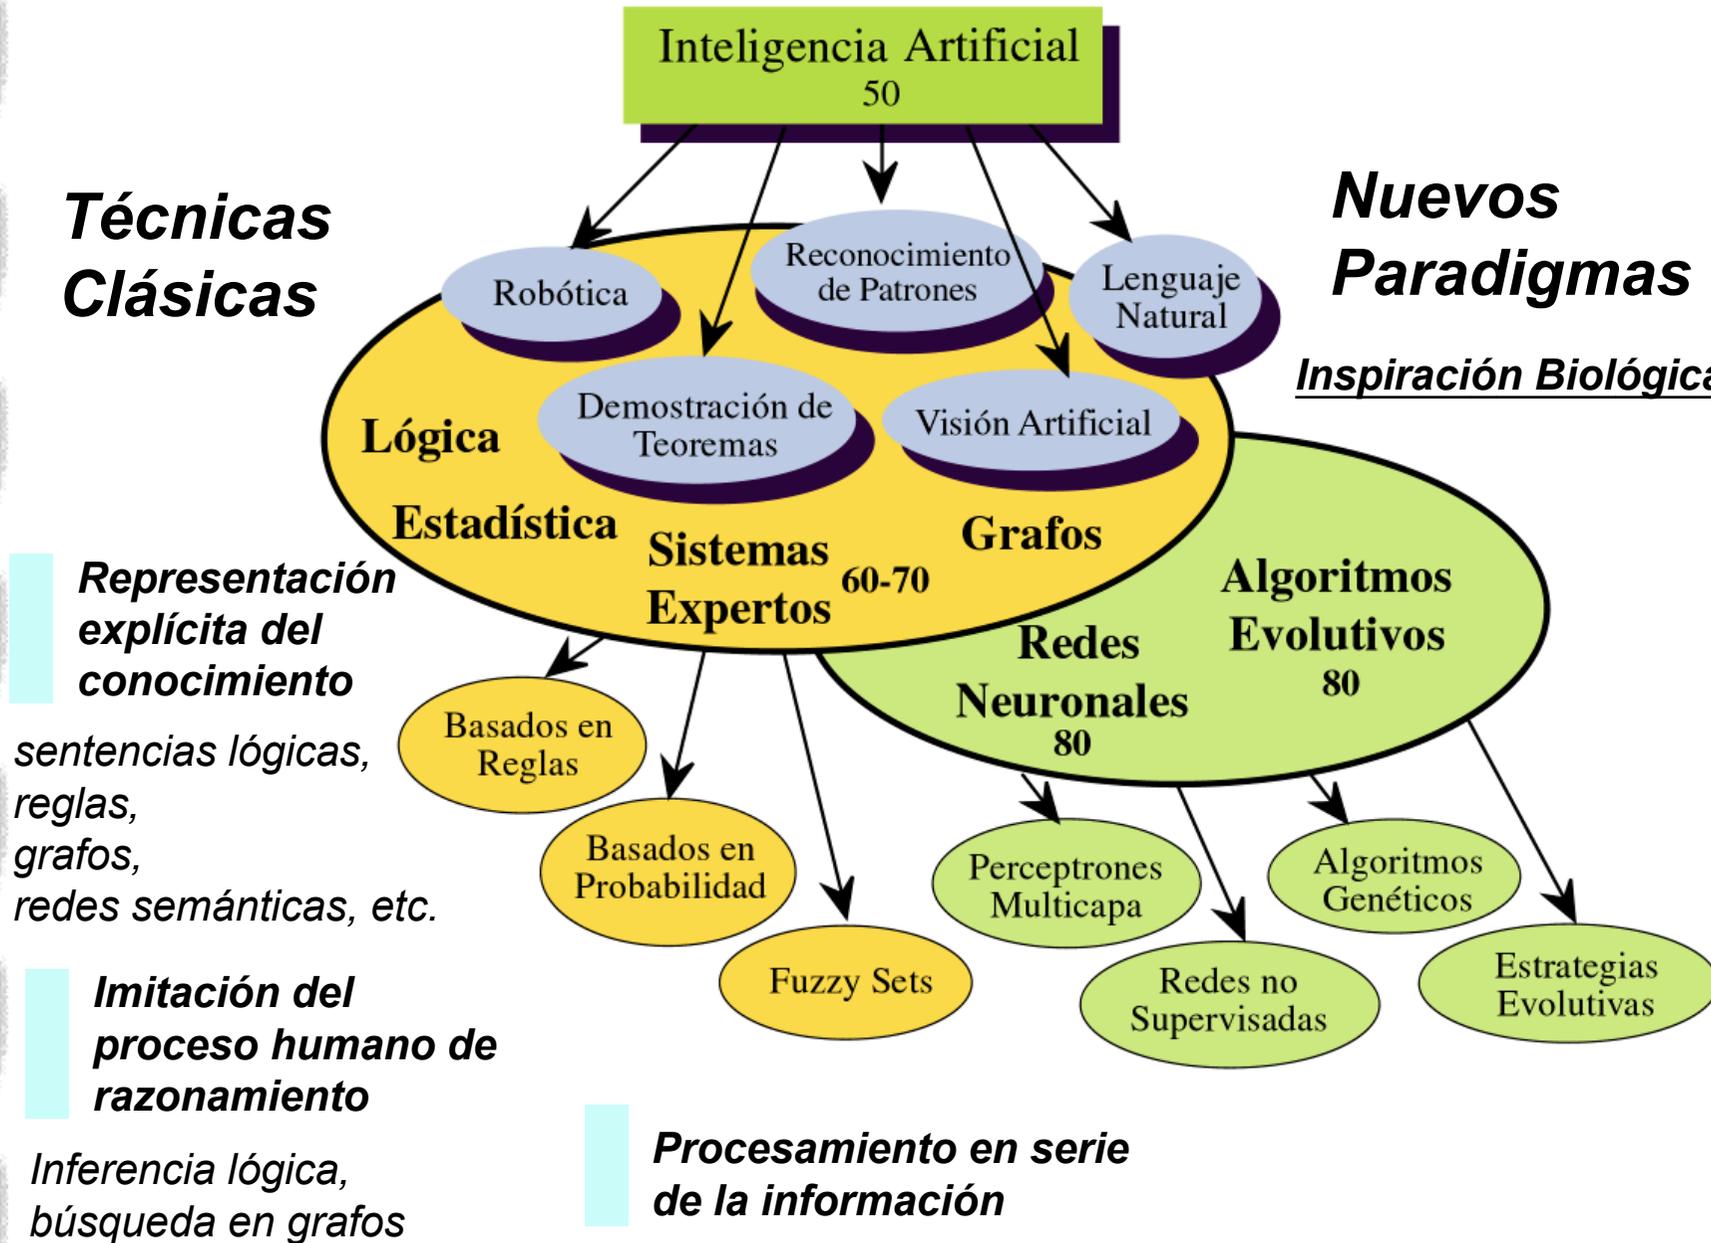


Inteligencia Artificial

Técnicas Clásicas

Nuevos Paradigmas

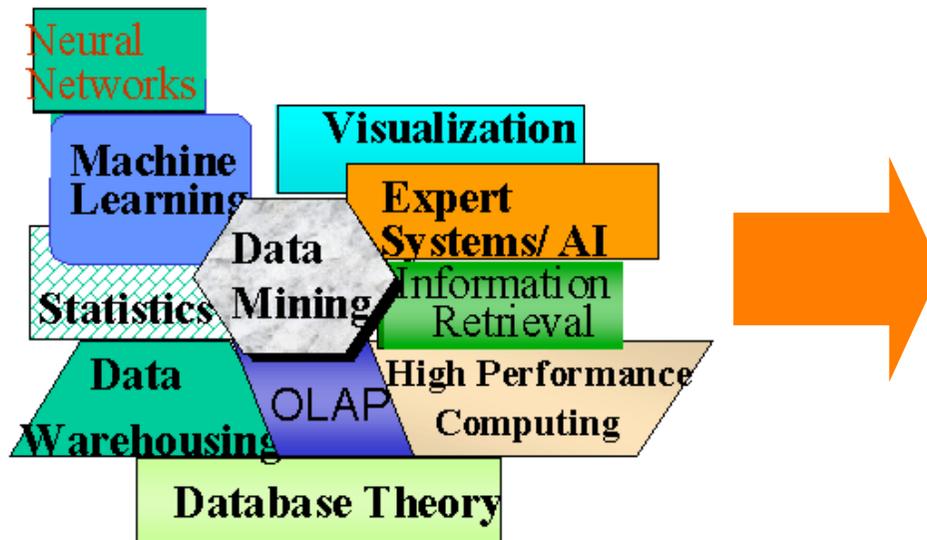
Inspiración Biológica



Areas y Técnicas Involucradas

variety of techniques to identify nuggets of information or decision-making knowledge in bodies of data, and **extracting** these in such a way that they can be put to use in the areas such as decision support, prediction, forecasting and estimation. The data is often voluminous, but as it stands of low value as no direct use can be made of it; **it is the hidden information in the data that is useful.**

Técnicas Involucradas



✓ **Modelado de Dependencias:**

asociaciones entre variables.
reglas y grafos (redes Bayesianas).

✓ **Componentes Principales:**

compresión de la información.

✓ **Componentes Independientes:**

extracción de **características**.

✓ **Agrupación:**

hallar grupos de elementos.

✓ **Clasificación:**

asignar elementos a **clases**.

✓ **Predicción:**

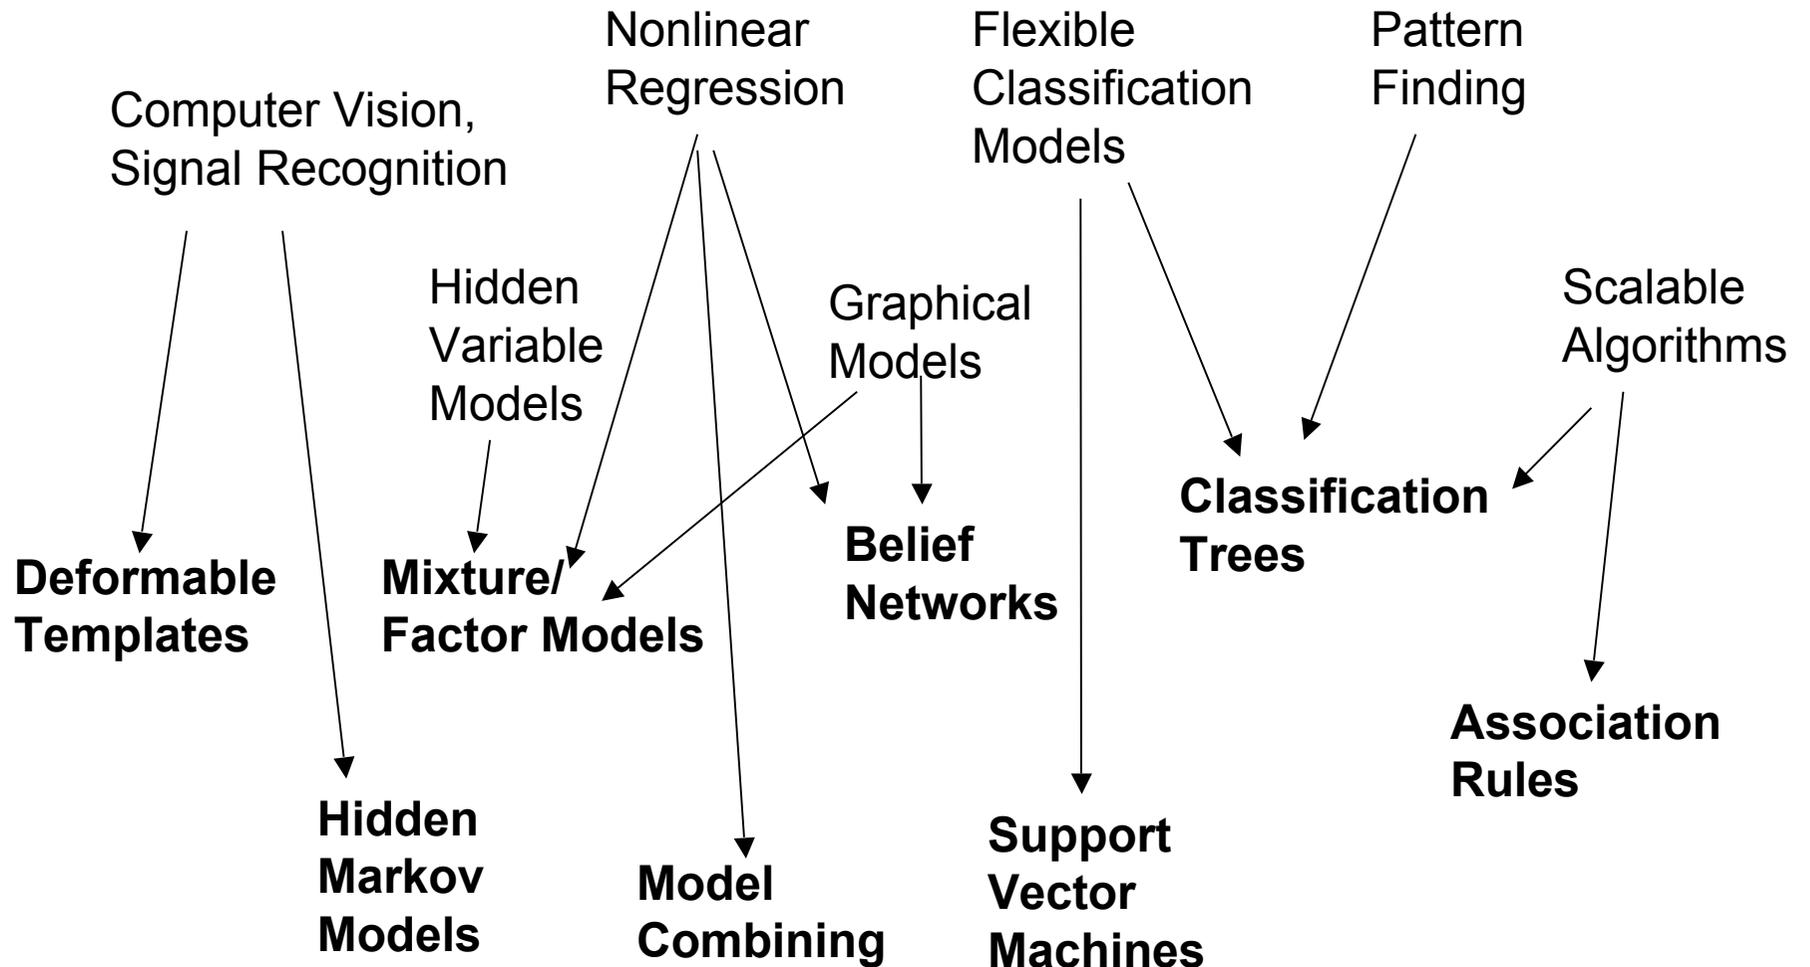
estimación de valores.

✓ **Visualización:**

representación gráfica.

Hot Topics (Statistics and Machine Learning)

Padhraic Smyth
Information and Computer Science
University of California, Irvine



Objetivos. Un Primer Ejemplo

Asociación:

Interesa obtener automáticamente reglas que relacionen unos atributos de la base de datos con otros, en base a alguna asociación:

Ejemplo - Base de datos de clientes de un banco.

Regla de Asociación:

**if STATUS = married and INCOME > 10000 and HOUSE_OWNER = yes
then INVESTMENT_TYPE = good**

Clasificación:

Un sistema de minería de datos aprende de los datos cómo particionar o calificar los mismos en base a reglas de clasificación:

Ejemplo - Base de datos de clientes de un banco.

Pregunta - *Un cliente que solicita un préstamo, es una buena inversión?*

Regla típica formulada:

**if STATUS = married and INCOME > 10000 and HOUSE_OWNER = yes
then INVESTMENT_TYPE = good**

Aplicaciones de la Minería de Datos.

**Ambiente
dinámico**

En Internet

*Gran cantidad de información (financiera, servicios, empresas, universidades, libros y hobbies), con complejas interrelaciones.
El 99% de la información no le interesa al 99% de la gente.*

- ✓ **E-bussines.** Perfiles de clientes, publicidad dirigida, fraude.
- ✓ **Buscadores "inteligentes".** Generación de jerarquías, bases de conocimiento web.
- ✓ **Gestión del tráfico de la red.** Control de eficiencia y errores.

➤ **Reglas de asociación:**

El 60% de las personas que esquían viajan frecuentemente a Europa.

➤ **Clasificación:**

Personas menores de 40 años y salario superior a 2000\$ compran on-line frecuentemente.

➤ **Clustering:**

Los usuarios A y B tienen gustos parecidos (acceden URLs similares).

➤ **Detección de "outliers"**

El usuario A navega en Internet más del doble del tiempo promedio.

La publicidad en Internet es uno de los tópicos más actuales de Data Mining.

Los data warehouse de las empresas contienen enormes cantidades de información sobre sus clientes y gestiones.

El Mundo de los Negocios

- ✓ **Banca.** Grupos de clientes, préstamos, oferta de productos.
- ✓ **Compañías de seguros.** Detección de fraude, administración de recursos.
- ✓ **Marketing.** Publicidad dirigida, estudios de competencia.

La cantidad de información generada en proyectos científicos ha sido enorme: Genoma Humano, datos geofísicos, altas energías, etc.

En Biología, Meteorología, etc.

- ✓ **Bio-Informática.** Búsqueda de patrones en ADN, consultas inteligentes.
- ✓ **Meteorología.** Teleconexiones (asociaciones espaciales), predicción.
- ✓ **Física (altas energías).** Datos de colisiones de partículas (búsqueda de patrones).



crossgrid

WP4: TESTBED

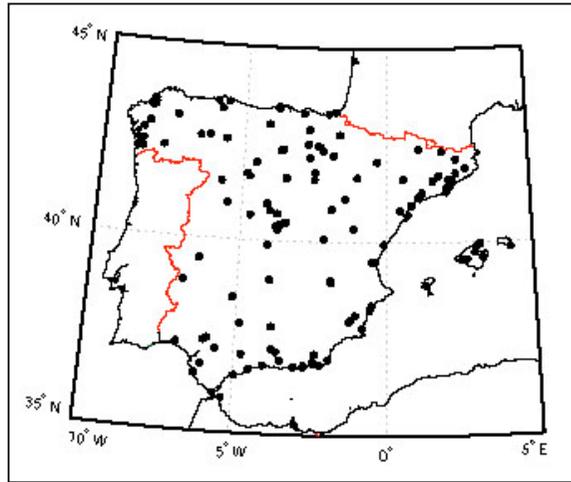
<http://www.ifca.unican.es/crossgrid/>

EJEMPLO !!!!!!!!!!!!!!!!!!!!!!!

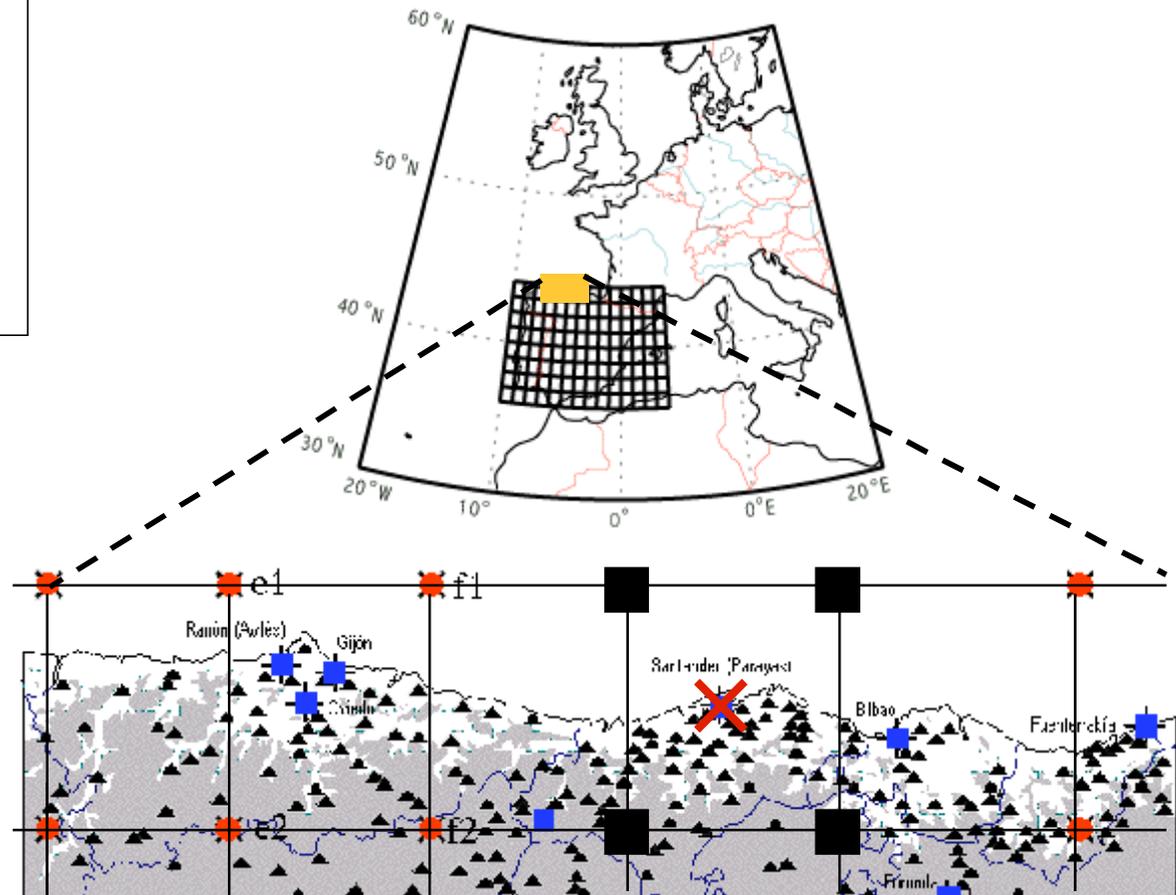
Ejemplo. Meteorología.

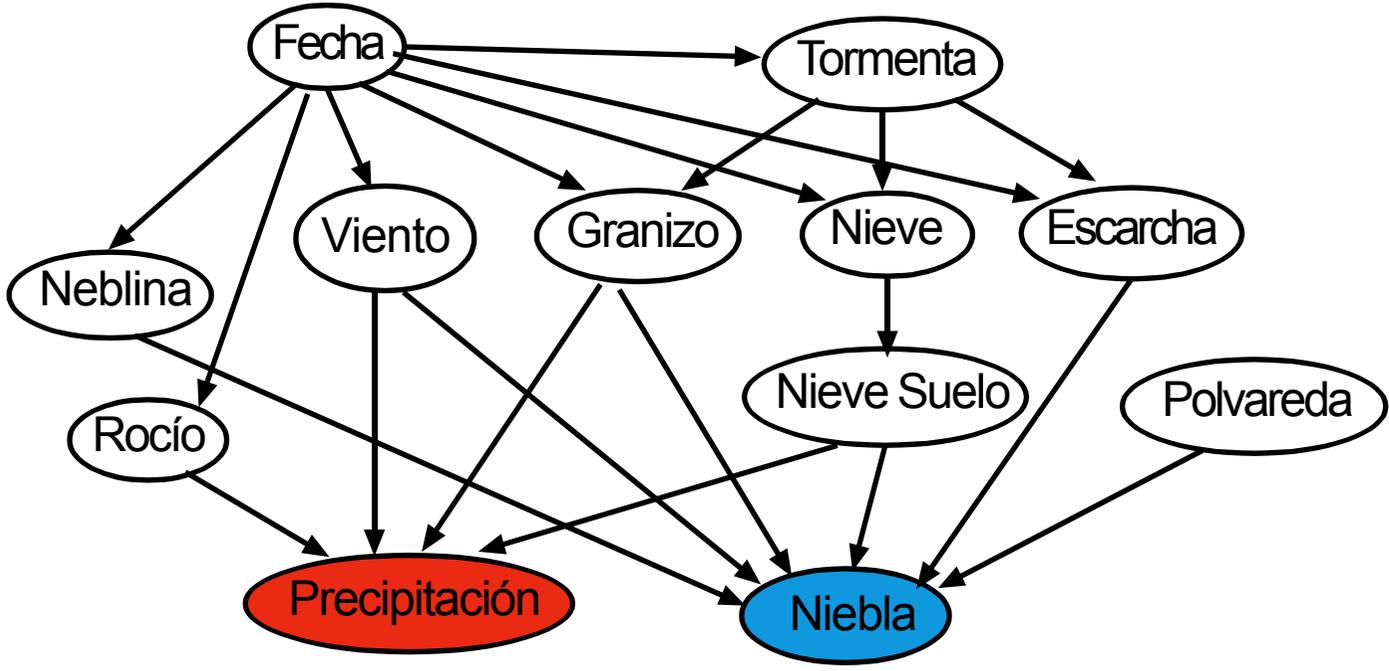
✓ **Meteorología.** *Teleconexiones (asociaciones espaciales), predicción.*

Existen bases de datos con simulaciones de los campos atmosféricos en rejillas dadas.



Se dispone de gran cantidad de información en observatorios locales: Precipitación, temperatura, Viento, etc.





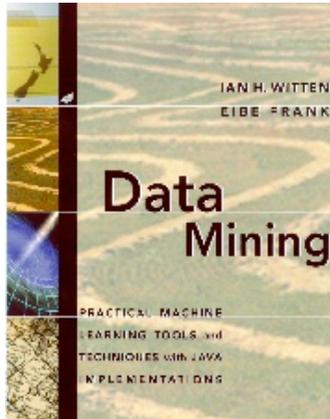
860101500000000010
 860102100000000010
 860103500100000010
 860104500000000010
 860105101100000010
 860106101100000010
 860107300100000010
 860108500000000010
 860109500000001000
 860110000001001100
 860111001000000000

	Fecha	Granizo		Calima
			Rocío	
Precipitación		Escarcha		Neblina
			Tormenta	
	Niebla			Nieve Suelo
	Nieve	Polvareda	Viento	

Libros y Material de Consulta

José Manuel Gutiérrez, Universidad de Cantabria. (2001)

<http://personales.unican.es/gutierjm>



Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations

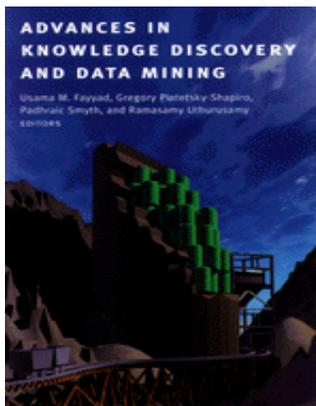
[Ian H. Witten](#), [Eibe Frank](#)



WEKA
The University
of Waikato

**Machine Learning and Data Mining
Open Source Tools in Java**

<http://www.cs.waikato.ac.nz/~ml/weka/>



Advances in Knowledge Discovery and Data Mining

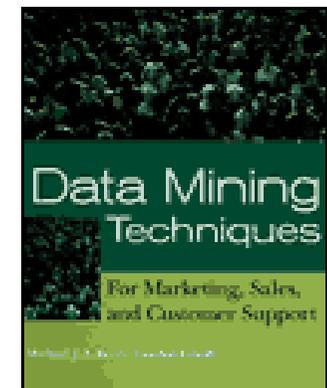
Edited by U.M. Fayyad, G. Piatetsky-Shapiro, P. Smyth, and R. Uthurusamy

The AAAI Press

*Data Mining Techniques: For Marketing,
Sales, and Customer Support*

By Michael J. Berry, Gordon Linoff

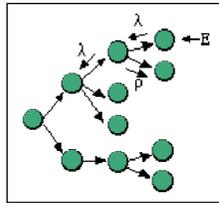
Wiley, John & Sons,



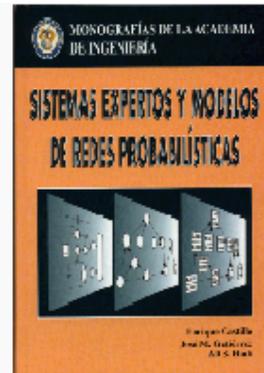
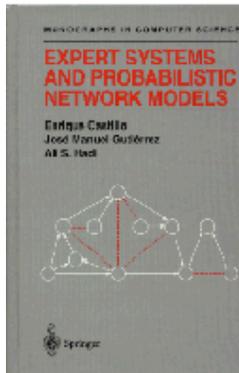
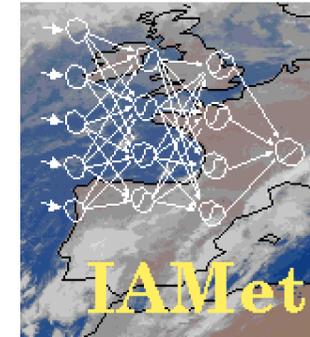
<http://www1.fatbrain.com/FindItNow/Services/home.cl?from=cbs169&store=1>

Libros disponibles en Internet

Artificial Intelligence Research Group

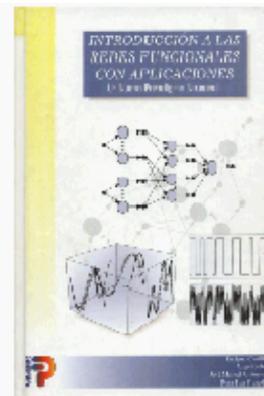
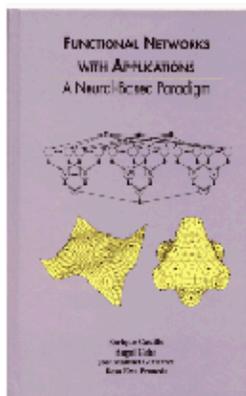


Bayesian and Neural-Based Networks



Expert Systems and Probabilistic Network Models.
E. Castillo, J.M. Gutiérrez, y A.S. Hadi
Springer-Verlag, New York.

Monografías de la Academia Española de Ingeniería



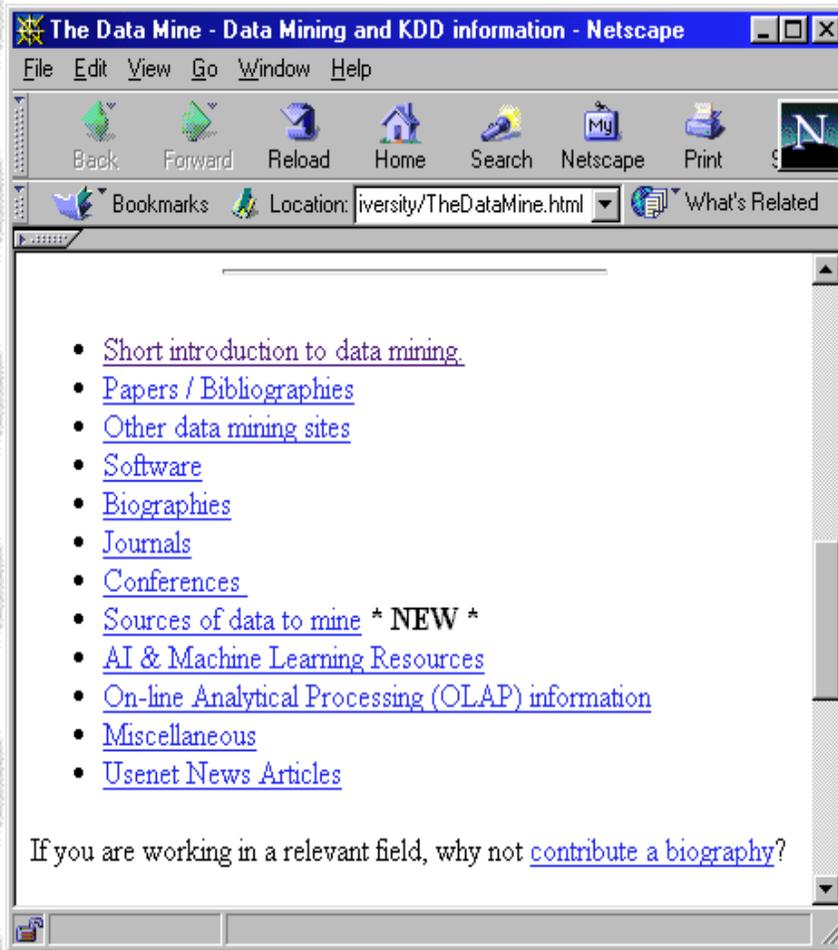
An Introduction to Functional Networks
E. Castillo, A. Cobo, J.M. Gutiérrez and E. Pruneda
Kluwer Academic Publishers (1999).

Paraninfo/International Thomson Publishing

Enlaces Interesantes y Revistas

The Data Mine provides information about Data Mining and Knowledge Discovery in Databases (KDD).

<http://www.cs.bham.ac.uk/~anp/TheDataMine.html>



<http://www.data-miners.com/>

http://www.kdcentral.com/Software/Data_Mining/

<http://www.andypryke.com/university/software.html>

<http://www.galaxy.gmu.edu/stats/syllabi/DMLIST.html>

Journals

Data Mining and Knowledge Discovery.

<http://www.wkap.nl/journalhome.htm/1384-5810>

Intelligent Data Analysis

<http://www.iospress.nl/site/html/1088467x.html>

IEEE Trans. on Knowledge and Data Engineering

<http://www.iospress.nl/site/html/1088467x.html>

Related Journals (from IDA)

<http://www.ida-society.org/journals.html>

El Portal KDnuggets: <http://www.kdnuggets.com/>

Portal dedicado a Data Mining, Web Mining y Búsqueda de Conocimiento.

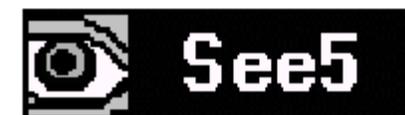
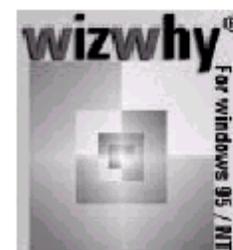
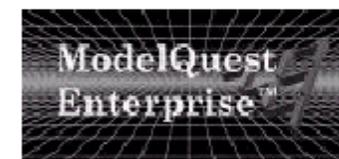
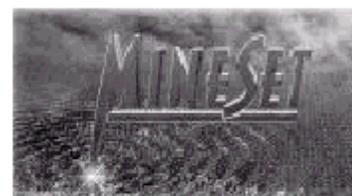
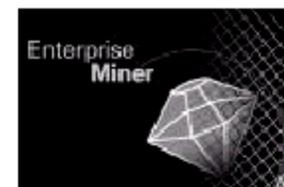
The screenshot shows the KDnuggets website homepage. At the top, there is a logo for "KDnuggets" and the text "Data Mining, Web Mining & News, Consulting, and...". Below the logo, there is a navigation menu with links for "KDnuggets News", "Latest", "Archive", "Submissions", and "Subscribe!". A search bar is located in the center, with a dropdown menu for "Section:" set to "All sections, News 2000-1", a text input field for "keywords", and a "Search!" button. Below the search bar, there are several categories of links: "Software: Visualization, Classification, Suites, Web ...", "Solutions: CRM, Bio, Personalization, Web...", "Companies: ASP, Products, Consulting...", "Websites: AI, Bio, DB/OLAP, Privacy ...", "ACM SIGKDD: Data Mining Professional Society", "Jobs: Industry, Academic", "Courses: Sep | Oct | Nov Meetings, Education", "Publications: Books, Surveys, Business, Tech ...", "Past Polls: ...", and "Datasets: Competitions, KDD Cup". The browser's address bar shows "http://www.kdnuggets.com/polls/index.html".

The screenshot shows the search results page in a Netscape browser window. The title bar reads "Results of Search - Netscape". The browser's address bar shows "Location: hannel1.com". The search results are displayed in a list format, with the following items:

- [Knowledge Discovery in Databases: 10 years after ...Association Rules; OLAP; and Data Visualization.](#)
From General Tools to Domain Specific SolutionsIn 1989 there
- [Knowledge Discovery in Databases: 10 years after ...Association Rules; OLAP; and Data Visualization.](#)
>From General Tools to Domain Specific SolutionsIn 1989 ther
- [KDD-98 Exhibitors](#)
...**association rules** algorithm. WizWhy reveals all the if-then r
relate to the dependent variable, and uses these rules in order
- [KDD-98 Poster Sessions](#)
...Online Generation of Profile **Association Rules**
Charu C. Aggarwal, T. J. Watson Research Center, Zheng Sur
- [KDD-98 Program](#)
...Interestingness-based Interval Merger for Numeric **Associat**
Gautam Das, Heikki Mannila, and Pirjo Ronkainen
- [KDnuggets News 00:02, item 2, News](#)
...detection of **association rules** in transactional
data, and classification to multiple categories.
- [KDnuggets News 00:02, item 3, Software](#)
...Subject: Magnum Opus finds optimal **association rules**
Date: Thu, 6 Jan 2000 22:41:13 -0500 (EST)

The browser's status bar at the bottom shows "Connect: Host www.kdnuggets.com contacted. Waitin".

Productos Comerciales



Un Ejemplo: DBMiner. <http://www.dbminer.com>

The screenshot displays the DBMiner software interface. On the left, a tree view shows 'Data Sources' including 'Database Servers' (vivaldi) and 'OLAP Servers' (strauss). The 'Mining Task: Association Rules' window shows the task settings and progress, indicating that 96 rules were found. Below this, a table lists the discovered association rules.

	A	B	C	D	E
1	Body	==>	Head	Confidence	support
2	Customers = [Albany]	==>	Education Level = [Bachelors Degree]	91.17647059	91.17647059
3	Education Level = [Bachelors Degree]	==>	Customers = [Albany]	91.17647059	91.17647059
4	Customers = [Albany]	==>	Education Level = [High School Degree]	95.09803922	95.09803922
5	Education Level = [High School Degree]	==>	Customers = [Albany]	95.09803922	95.09803922
6	Customers = [Beaverton]	==>	Education Level = [Partial College]	91.17647059	91.17647059
7	Education Level = [Partial College]	==>	Customers = [Beaverton]	91.17647059	91.17647059
8	Customers = [Corvallis]	==>	Education Level = [Bachelors Degree]	91.17647059	91.17647059
9	Education Level = [Bachelors Degree]	==>	Customers = [Corvallis]	91.17647059	91.17647059
10	Customers = [Corvallis]	==>	Education Level = [Graduate Degree]	93.1372549	93.1372549
11	Education Level = [Graduate Degree]	==>	Customers = [Corvallis]	93.1372549	93.1372549
12	Customers = [Corvallis]	==>	Education Level = [High School Degree]	98.03921569	98.03921569
13	Education Level = [High School Degree]	==>	Customers = [Corvallis]	98.03921569	98.03921569
14	Customers = [Corvallis]	==>	Education Level = [Partial College]	97.05882353	97.05882353
15	Education Level = [Partial College]	==>	Customers = [Corvallis]	97.05882353	97.05882353
16	Customers = [Lebanon]	==>	Education Level = [Bachelors Degree]	99.01960784	99.01960784
17	Education Level = [Bachelors Degree]	==>	Customers = [Lebanon]	99.01960784	99.01960784
18	Customers = [Lebanon]	==>	Education Level = [Graduate Degree]	93.1372549	93.1372549
19	Education Level = [Graduate Degree]	==>	Customers = [Lebanon]	93.1372549	93.1372549
20	Customers = [Lebanon]	==>	Education Level = [High School Degree]	97.05882353	97.05882353
21	Education Level = [High School Degree]	==>	Customers = [Lebanon]	97.05882353	97.05882353
22	Customers = [Lebanon]	==>	Education Level = [Partial College]	98.03921569	98.03921569

IBM DB2 Intelligent Miner

José Manuel Gutiérrez, Universidad de Cantabria. (2001)
<http://personales.unican.es/gutierjm>



The screenshot shows the IBM website for the DB2 Intelligent Miner for Data product. The page features a navigation menu with links for Home, Products & services, Support & downloads, and My account. A search bar is located in the top right corner. The main heading is "DB2 Intelligent Miner for Data". Below the heading, there is a "Buy now" button and a graphic of a person standing on a globe with data points. The page also includes a "Features at a glance" section with a list of bullet points, a "Related links" section with several links, and a "More resources" section with links to external articles and a webcast.

IBM

Home | Products & services | Support & downloads | My account

→ Select a country

Products & services > Software > Database and Data Management > Business Intelligence Solutions

DB2 Intelligent Miner for Data

Use the DB2 Intelligent Miner for Data to gain new business insights and to harvest valuable business intelligence from your enterprise data. You can even mine high-volume transaction data generated by point-of-sale, ATM, credit card, call center, or e-commerce activities. With the Intelligent Miner for Data, you are better equipped to make insightful decisions, whether the problem is how to develop more precisely targeted marketing campaigns, reduce customer attrition, or increase revenue generated by Internet shopping.

Buy now



Buy other versions

→ [DB2 Intelligent Miner for Data](#)

Operating systems

DB2 Intelligent Miner for Data runs on **AIX, OS/390, OS/400, Solaris, Windows 2000, Windows NT and z/OS.**

More resources

→ [IT Sharpens Data Mining's Focus](#) HCW

→ [DB2 Magazine Online: Operation Data Mining](#) HCW

→ [View IBM Webcast - Enhancing](#)

Related links:

- [DB2 Intelligent Miner Scoring](#)
- [DB2 Product Family](#)
- [DB2 Developer Domain](#)
- [Business Intelligence Solutions](#)
- [The data mining group](#)
- [IBM Data Mining Research](#)

Features at a glance

Scalable and with support for multiple platforms, the Intelligent Miner for Data provides a single framework for database mining using proven, parallel mining techniques. Business applications for this technology vary widely, and a variety of mining algorithms is provided. Here are some typical examples of how mining algorithms available in the Intelligent Miner for Data are applied:

- You can use clustering for market segmentation, store profiling, and to reveal buying behavior.
- Associations enable you to discover product associations in a market basket analysis, site visit patterns for an e-commerce site, and combinations of financial offerings purchased in different geographical areas.
- Sequential patterns reveal buying patterns in a series of purchases made on multiple Web site visits over time.
- Classification algorithms enable you to profile customers based on a desired outcome, such as propensity, to buy high-end electronics.
- You can use predictive algorithms to score customers by factors such as likelihood of fraud, credit risk, or propensity to buy.

IBM Advanced Scout. <http://www.research.ibm.com/scout>



Using data mining software called Advanced Scout to prepare for a game, a coach can quickly review countless stats: shots attempted, shots blocked, assists made, personal fouls. But Advanced Scout can also detect patterns in these statistics that a coach may not have known about. So during a game, a coach can know exactly which plays are most effective with which players and under what circumstances.

“attribute focusing” finds conditional ranges on attributes where the distributions differ from the norm.



An analysis of the data from a game played between the New York Knicks and the Charlotte Hornets revealed that when "Glenn Rice played the shooting guard position, he shot 5/6 (83%) on jump shots."

Through data mining, Advanced Scout identified a certain player (Rice), playing a certain position (shooting guard), shooting at a certain rate (83%), on a certain type of shot (jump shots). Advanced Scout not only finds this pattern, but points out that it is interesting because it differs considerably from the average shooting percentage of 54% for the Charlotte Hornets during that game.

The Toolbox "MeteoLab" Data Mining in Meteorology

<http://etsiso2.macc.unican.es/~meteo>

José Manuel Gutiérrez, Universidad de Cantabria. (2001)
<http://personales.unican.es/gutierjm>

MeteoLab

Atmospheric Grid DB

Area and pattern config
D:\Prometeo\WreaPat ...
Stored CPs: 500
Build Pattern DB

Gridded Forecast

D:\Prometeo\ECMWF ...
Forecast Day: 1
Build Forecast Patterns

Downscaling

Number of CPs: 50

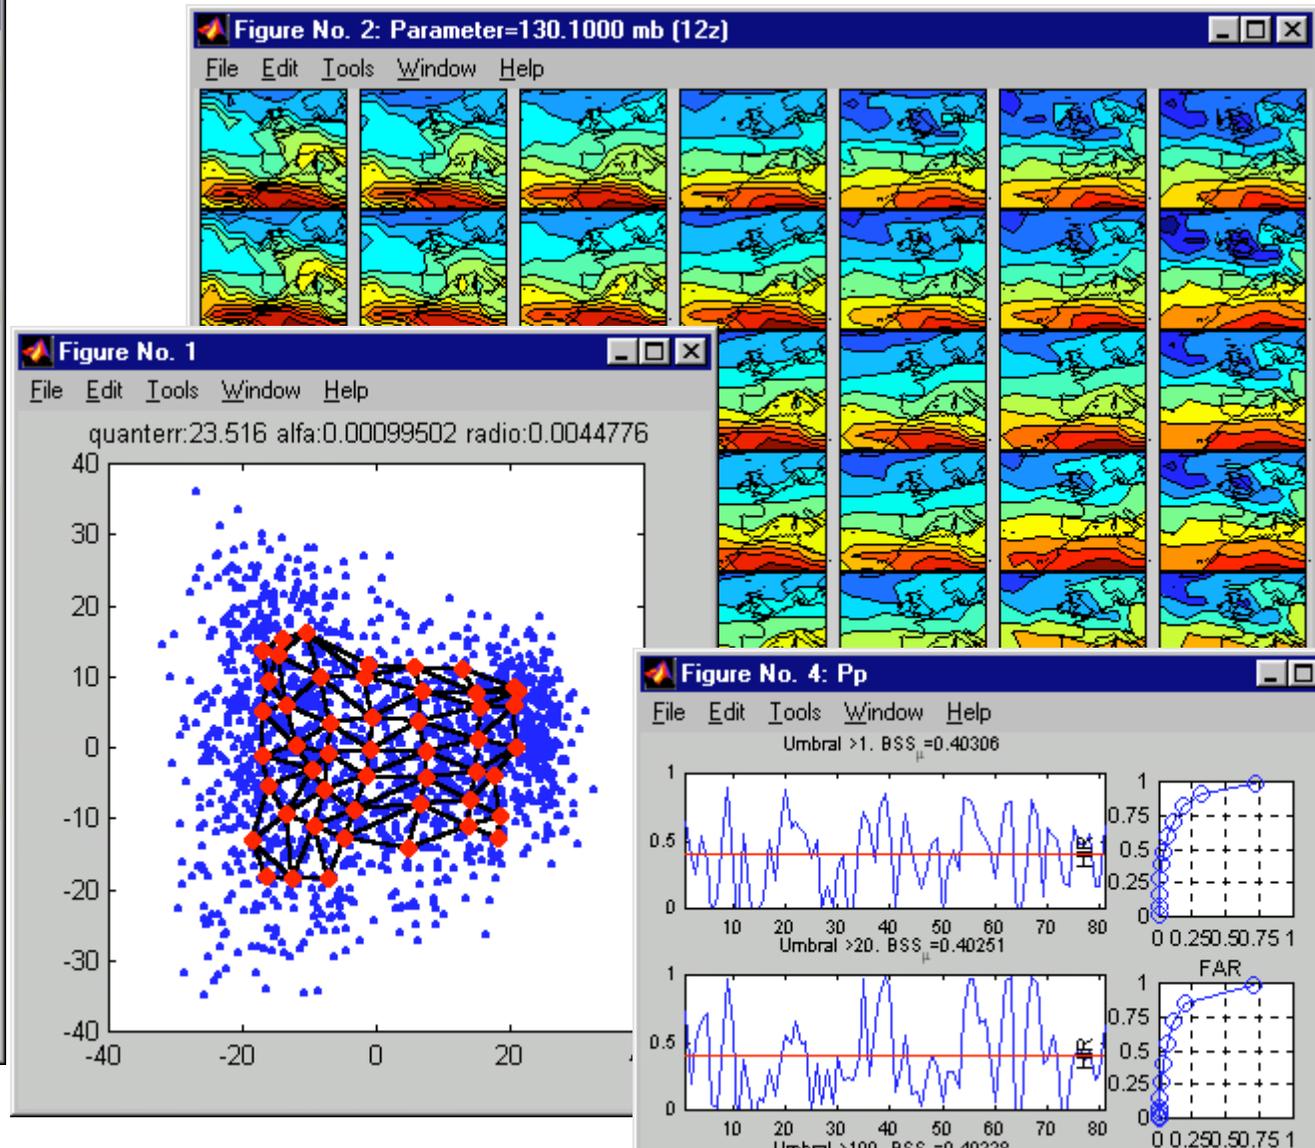
- Climatic
- Global Regression
- k-nn Analog 50
- k-means Analog 125
- SOM Analog 15 15

Stations & Variables

D:\Prometeo\WreaSta ...

- T Min
- T Max
- Rain
- Cloud
- Wind

Make Local Predictions



Modelado de Dep. (reglas de asociación)



✓ **Modelado de Dependencias:**
*asociaciones entre variables.
reglas y grafos.*

✓ **Componentes Principales:**
compresión de la información.

✓ **Componentes Independientes:**
extracción de características.

✓ **Agrupación:**
hallar grupos de elementos.

✓ **Clasificación:**
asignar elementos a clases.

✓ **Predicción:**
estimación de valores.

✓ **Visualización:**
representación gráfica.

Relaciones entre atributos. Fórmulas y Reglas.

Una de las técnicas más habituales en data mining consiste en **extraer las relaciones relevantes** que existan entre conjuntos de variables (**itemsets**) de la base de datos.

De esta forma se pueden detectar **errores**, **fraudes**, e **inconsistencias** fácilmente.

En el caso de **bases de datos relacionales** trabajaríamos con **conjuntos** formados por **pares (atributo # valor)** utilizando los registros de la base de datos.

{**Cliente = Pepe**, **Precio > 10\$**}

{**Producto = Café**}

Estas relaciones de asociación se pueden establecer en distintas formas:

✓ **Reglas if-then "reglas de asociación"**

Son implicaciones de la forma **$X \Rightarrow Y$**
if (X1= a, X3= c, X5= d) then (X4= b, X2= a)

La **fiabilidad** [confidence] es la proporción de Aquellos registros con X que también contienen también a Y.

La **relevancia** [support] es la proporción de registros que contienen tanto X como Y.

**If Cliente is Pepe
and Precio is lower than 10\$
Then
Producto = Café**

confidence: 0.98
The rule exists in 102 records
Significance level: error prob < 0.001

✓ Asociaciones

Se buscan asociaciones de la forma:

$$(X1 = a) \Leftrightarrow (X4 = b)$$

De los n registros de la tabla, las dos igualdades

Son verdaderas o falsas simultáneamente

en rc casos:

$$\text{fiabilidad de la asociación} = rc / n$$

The value **Pepe** in the **Cliente** field is associated with the value **Café** in the **Producto** field

Rule's **fiab**: 0.8

Ejemplo:

DNI	Renta Familiar	Ciudad	Profesion	Edad	Hijos	Obeso	Casado
11251545	5.000.000	Barcelona	Ejecutivo	45	3	S	S
30512526	1.000.000	Melilla	Abogado	25	0	S	N
22451616	3.000.000	Len	Ejecutivo	35	2	S	S
25152516	2.000.000	Valencia	Camarero	30	0	S	S
23525251	1.500.000	Benidorm	Animador Parque Temático	30	0	N	N

Reglas de Asociación:

(Hijos > 0) => Casado (100%, 2 casos).

Casado => Obeso (100%, 3 casos).

Asociaciones:

Casado e (Hijos > 0) están asociados (80%, 4 casos).

Obeso y casado están asociados (80%, 4 casos)

✓ Fórmulas

Relaciones matemáticas $X=f(Y,Z)=Y*Z$

La **fiabilidad** denota el cociente entre el número de casos en que se cumple la fórmula (suponiendo un cierto error de redondeo) y el número total de casos.

$$A = B * C$$

Where: A = Total

B = Cantidad

C = Precio

Rule's Accuracy Level: **0.99**

The rule exists in **1890** records

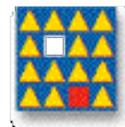
✓ Reglas de ortografía.

Estas reglas permiten detectar errores de ortografía. Un nombre es similar a otro pero la frecuencia en que aparecen ambos es muy diferente.

(Text Mining)

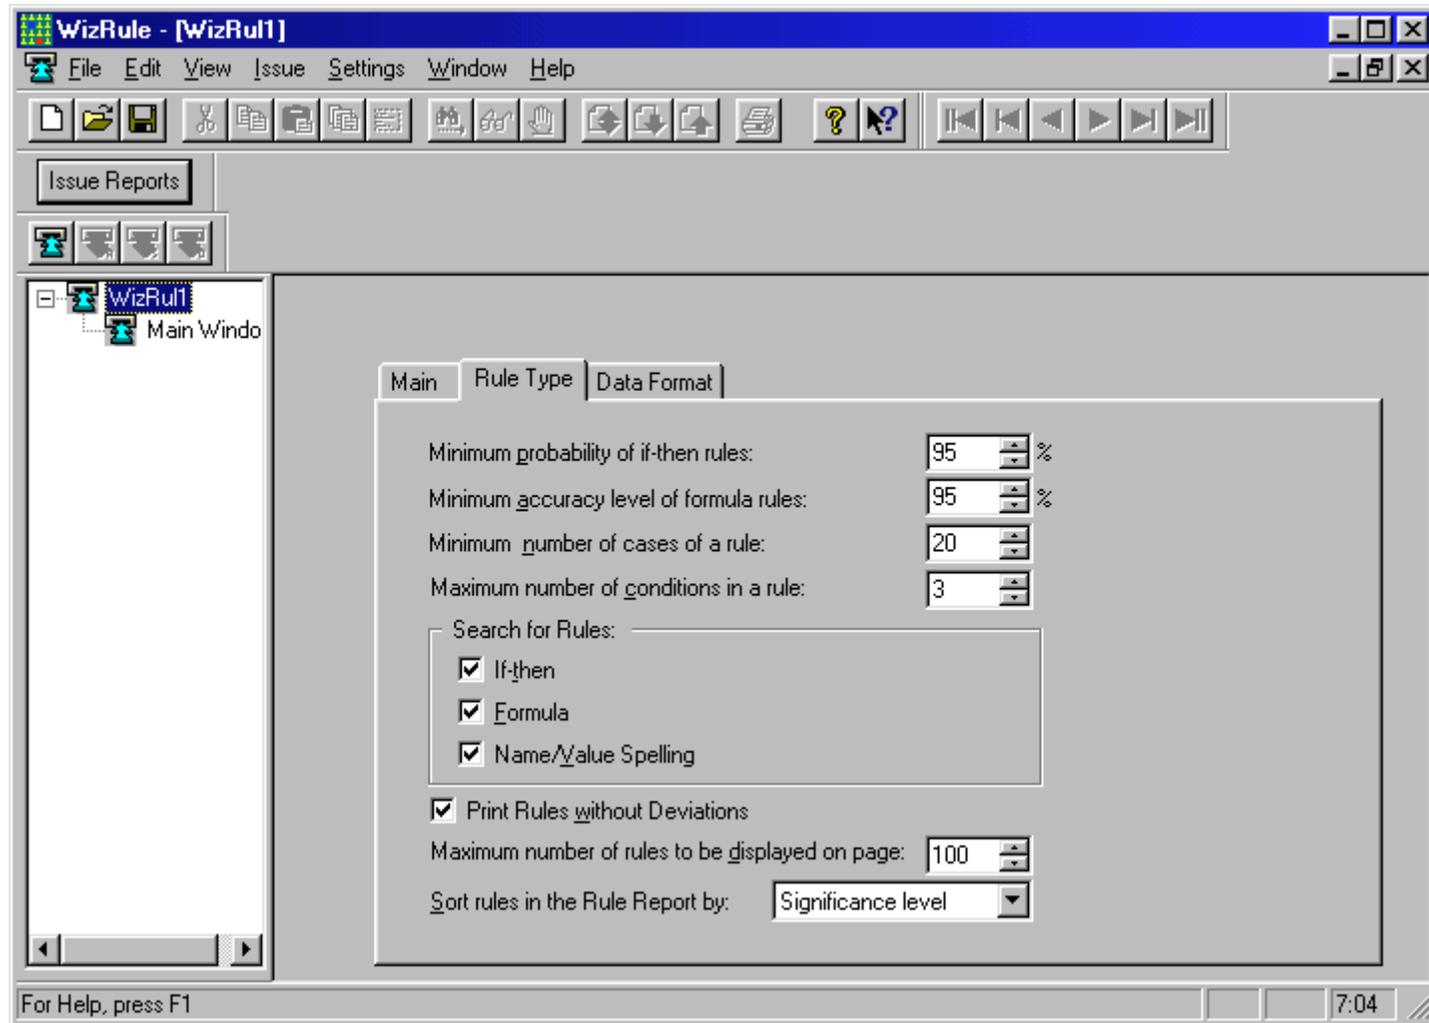
The value **Pepe** appears **52** times in the **Cliente** field.

There are **2** case(s) containing similar value(s)
{Pepr, Repe}



WizRule / Features and Benefits

Ejemplo



Búsqueda de Reglas de Asociación

La mayoría se basa en descomponer el problema en dos fases:

- **FASE A: BÚSQUEDA DE GRANDES CONJUNTOS DE ATRIBUTOS.**

*Se buscan conjuntos de atributos con **relevancia** \geq **umbral**. De momento no se busca separarlos en parte izquierda y parte derecha.*

- **FASE B: ESCLARECIMIENTO DE DEPENDENCIAS (REGLAS).**

*Se hacen particiones binarias y disjuntas de los conjuntos hallados y se calcula la confianza de cada uno. Se retienen aquellas reglas que tienen **confianza** \geq **umbral***

Propiedad: cualquier subconjunto de un conjunto grande es también grande.

AIS es el primer algoritmo que se desarrolló para obtener reglas de asociación.

$X \Rightarrow Y [s,c]$ donde

- ✓ **Y** es un único atributo,
- ✓ **s** es la relevancia y
- ✓ **c** su fiabilidad.

AIS [Agrawal, Imielinski & Swami]
R. Agrawal, T. Imielinsky & A. Swami
IBM Almaden Research Center, 1993

Fase A: Selección Grandes de Atributos

Dada una relevancia mínima R_{min} :

1. $i = 1$ (tamaño de los conjuntos)
2. Generar un conjunto unitario en S_1 para cada atributo.
3. Comprobar la relevancia de todos los conjuntos en S_i .
Eliminar aquellos cuya relevancia $< R_{min}$.
4. Combinar los conjuntos en S_i
creando conjuntos de tamaño $i+1$ en S_{i+1} .

Este paso se lleva a cabo secuencialmente, recorriendo los registros de la base de datos siguiendo el contador i . Tras leer un registro de la base de datos, se hallan los conjuntos relevantes S_i contenidos en el mismo. S_{i+1} se genera extendiendo los conjuntos hallados con otros atributos del registro.

5. Si S_i no es vacío entonces $i := i + 1$. Ir a 3.
6. Si no, retornar $S_2 \sqcup S_3 \sqcup \dots \sqcup S_i$

Dados n registros y m atributos $o(m \cdot 2^{m-1})$ reglas posibles.

Complejidad computacional $o(n \cdot m \cdot 2^m)$

Ejemplo

Fila	1	2	3	4	5
1	x		x	x	
2		x	x		x
3	x	x	x		x
4		x			x

relevancia = 2

confianza = 0.75

FASE A:

$$S1 = \{\{1\}, \{2\}, \{3\}, \{4\}, \{5\}\}$$

$$S'1:rel = \{\{1\}:2, \{2\}:3, \{3\}:3, \{5\}:3\}$$

$$S2 = \{\{1,2\}, \{1,3\}, \{1,5\}, \{2,3\}, \{2,5\}, \{3,5\}\}$$

$$S'2:rel = \{\{1,3\}:2, \{2,3\}:2, \{2,5\}:3, \{3,5\}:2\}$$

$$S3 = \{\{1,2,3\}, \{1,2,5\}, \{1,3,5\}, \{2,3,5\}\}$$

$$S'3:rel = \{\{2,3,5\}:2\}$$

$$S_{final} = S'2 \sqcap S'3 = \{\{1,3\}, \{2,3\}, \{2,5\}, \{3,5\}, \{2,3,5\}\}$$

FASE B:

$$\{1\} \sqcap \{3\} : 1$$

$$\{3\} \sqcap \{1\} : 0.67$$

$$\{2\} \sqcap \{3\} : 0.67$$

$$\{3\} \sqcap \{2\} : 0.67$$

$$\{2\} \sqcap \{5\} : 1$$

$$\{5\} \sqcap \{2\} : 1$$

$$\{3\} \sqcap \{5\} : 0.67$$

$$\{5\} \sqcap \{3\} : 0.67$$

$$\{2,3\} \sqcap \{5\} : 1$$

$$\{2,5\} \sqcap \{3\} : 0.67$$

$$\{3,5\} \sqcap \{2\} : 1$$

El Algoritmo APRIORI

- **F_k** : Set of frequent itemsets of size k
- **C_k** : Set of candidate itemsets of size k

F₁ = {single attribute sets} with minimum support

for (k=2; F_k != 0; k++) do {

 C_{k+1} = *New candidates generated from F_k*

 foreach entry t in the database do

 Increment the count of all candidates in C_{k+1} contained in t

 F_{k+1} = Candidates in C_{k+1} with minimum support

 }

Answer = **U_k F_k**

- Every subset of a frequent itemset is also frequent

=> a candidate itemset in C_{k+1} can be pruned if even one of its subsets is not contained in F_k

Fase de Combinación

Este algoritmo realizan múltiples pasadas sobre la base de datos para obtener los conjuntos de atributos relevantes.

En la primera pasada, se obtienen los items individuales cuya relevancia alcanza el umbral mínimo preestablecido: $L[1]$ de conjuntos relevante.

En las siguientes iteraciones, se utiliza el último conjunto $L[k]$ obtenido para generar un conjunto de $(k+1)$ atributos potencialmente relevantes (el conjunto de candidatos $C[k+1]$) y se obtiene la relevancia de estos candidatos para quedarnos sólo con aquéllos que son relevantes, que incluimos en el conjunto $L[k+1]$. Este proceso se repite hasta que no se encuentran más itemsets relevantes.

En el algoritmo AIS, los candidatos se generaban sobre la marcha, conforme se iban leyendo registros de la base de datos. Se generan innecesariamente conjuntos candidatos que de por sí nunca pueden llegar a ser relevantes.

Por su parte, en Apriori los candidatos se generan a partir de los conjuntos relevantes encontrados en la iteración anterior, única y exclusivamente. La idea subyacente es que, dado un itemset relevante, cualquier subconjunto suyo también es relevante.

Por lo tanto, los conjuntos de k atributos candidatos del conjunto $C[k]$ pueden generarse a partir del conjunto $L[k-1]$.

Ejemplo

Database D

TID	Items
1	{1, 3, 4}
2	{2, 3, 5}
3	{1, 2, 3, 5}
4	{2, 5}

Scan D →

C₁

Itemset	Sup.
{1}	2
{2}	3
{3}	3
{4}	1
{5}	3

F₁

Itemset	Sup.
{2}	3
{3}	3
{5}	3

C₂

Itemset
{2, 3}
{2, 5}
{3, 5}

Scan D →

C₂

Itemset	Sup.
{2, 3}	2
{2, 5}	3
{3, 5}	2

F₂

Itemset	Sup.
{2, 5}	3

Lógica

La lógica proporciona un entorno para representar conocimiento en el que es fácil razonar.

eg1. John is a human
every human are mortals
therefore
John is mortal.

In logic:

human(John)

$\square h(\text{human}(h) \square \text{mortal}(h))$

therefore: human(John) \square mortal(John)

\square elim. rule

therefore: mortal(John)

\square elim. rule

Las expresiones lógicas se construyen en base a un conjunto reducido de símbolos y cuantificadores.

- *Símbolos lógicos*

~ NOT

\square AND

OR

\square IMPLIES

- *Cuantificadores*

\square FOR ALL

\square THERE EXISTS

Lógica. Representación de Conocimiento con

L_{PC}

A language of PC, call it L_{PC} is defined by the following rules:

1. Variables p, q, r, \dots are in L_{PC} . We call the above variables: ***undeterminate statements***.
2. If a statement A is in L_{PC} and a statement B is in L_{PC} , then the statement **$(A \& B)$** is in L_{PC} . Similarly for the symbols: \vee, \square .
3. If a statement A is in L_{PC} , then the statement **$\sim A$** is in L_{PC} .

L_{PC} is a set of statements which represent useful logical expressions for a given problem

- $(\sim A \square B)$
- $((A \square B) \& (A \square B) \square B)$

Using the above rules and some other logical inference techniques it is easy to reason on a given problem.

Inferencia Lógica. Deducción natural.

Natural deduction uses the definition of logical symbols for eliminating, or introducing, knowledge on a given expression.

Elimination Rules	Introduction Rules	A B A B A B	[A] [B]
$\frac{\boxed{}}{}$	$\frac{}{\boxed{}}$	$\frac{ }{\boxed{ }}$	$\boxed{}$
$\frac{}{}$	$\frac{}{}$	$\frac{ }{ }$	
$\frac{\boxed{}}{}$	$\frac{}{\boxed{}}$	$\frac{ }{\boxed{ }}$	$\boxed{}$
$\frac{}{}$	$\frac{}{}$	$\frac{ }{ }$	

Tablas de Verdad y Leyes Lógicas

- $\sim(\sim P) = P$
- $(P \supset Q) = (\sim P \sqcup Q)$ [or $(\sim P \supset Q) = (P \sqcup Q)$]

P	Q	$\sim P$	$\sim P \vee Q$	$P \rightarrow Q$	$(\sim P \vee Q) = (P \rightarrow Q)$
T	T	F	T	T	T
T	F	T	T	F	F
F	T	F	T	T	T
F	F	T	F	T	T

- De Morgan's laws:
 - $\sim(P \supset Q) = (\sim P \sqcup \sim Q)$
 - $\sim(P \sqcup Q) = (\sim P \supset \sim Q)$
- Distributive laws:
 - $P \supset (Q \sqcup R) = (P \supset Q) \sqcup (P \supset R)$
 - $P \sqcup (Q \supset R) = (P \sqcup Q) \supset (P \sqcup R)$



Reglas de Inferencia Lógica.

- Modus ponens

If P is true and $P \rightarrow Q$ is true
then Q is true

- Modus tolens

if $P \rightarrow Q$ is true and Q is false or $\sim Q$ is true
then $\sim P$ is true

e. g., $\text{sick}(\text{student}) \rightarrow \text{not_attend_lecture}(\text{student})$
 $\sim \text{not_attend_lecture}(\text{student})$
produces: $\sim \text{sick}(\text{student})$

- Elimination

if $P \rightarrow Q$ is true
then P is true and Q is true

Modelado de Dep. (redes Bayesianas)

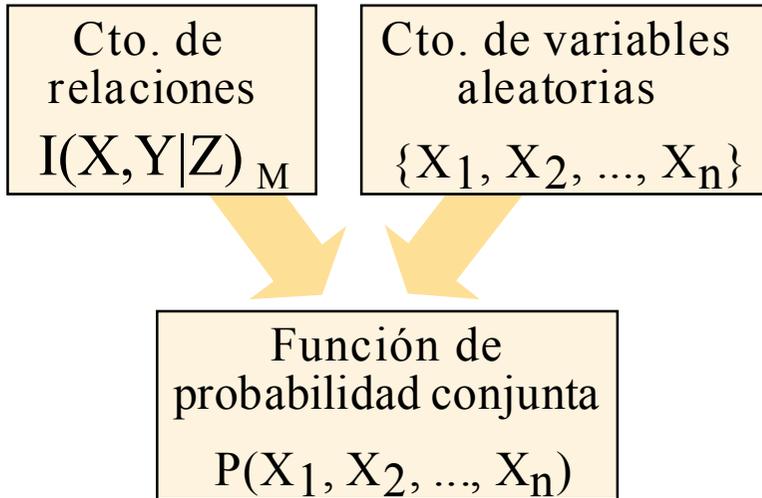


- ✓ **Componentes Principales:**
compresión de la información.
- ✓ **Componentes Independientes:**
extracción de características.
- ✓ **Modelado de Dependencias:**
hallar asociaciones entre variables
redes Bayesianas
- ✓ **Agrupamiento:**
hallar grupos de elementos
- ✓ **Clasificación:**
asignar elementos a clases
- ✓ **Predicción:**
estimación de valores
- ✓ **Visualización:**
representación gráfica.
Redes Neuronales

Redes Probabilísticas. Redes Bayesianas

Algunos problemas involucran gran número de variables y se conocen ciertas relaciones de independencia entre ellas.

Obtener un modelo probabilístico



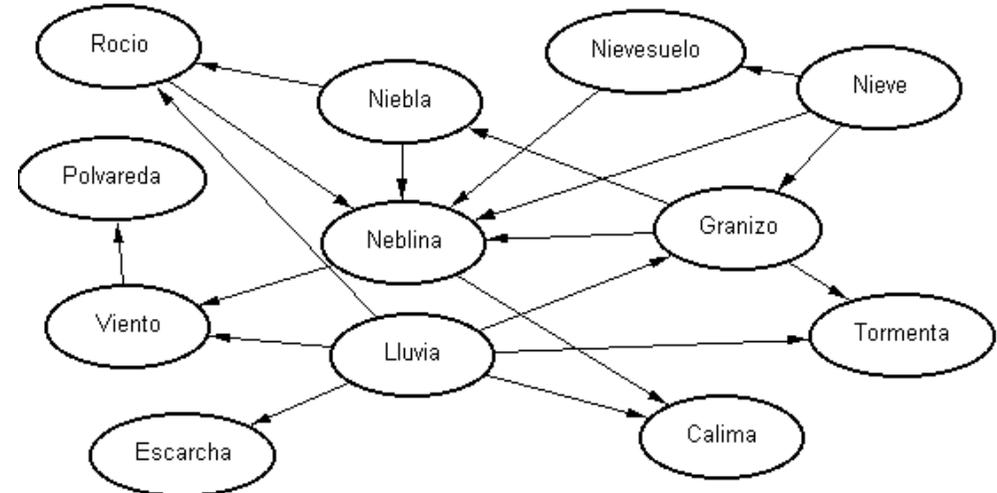
Factorización de la probabilidad !!

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P_i(x_i | \pi_i)$$

Lluvia	Nieve	Granizo	Tormenta	Niebla ...
5	0	0	0	0 ...
1	0	0	0	0 ...
5	0	0	1	0 ...

Relaciones de dependencia

Mediante un grafo dirigido donde cada variable tiene sus antecedentes.



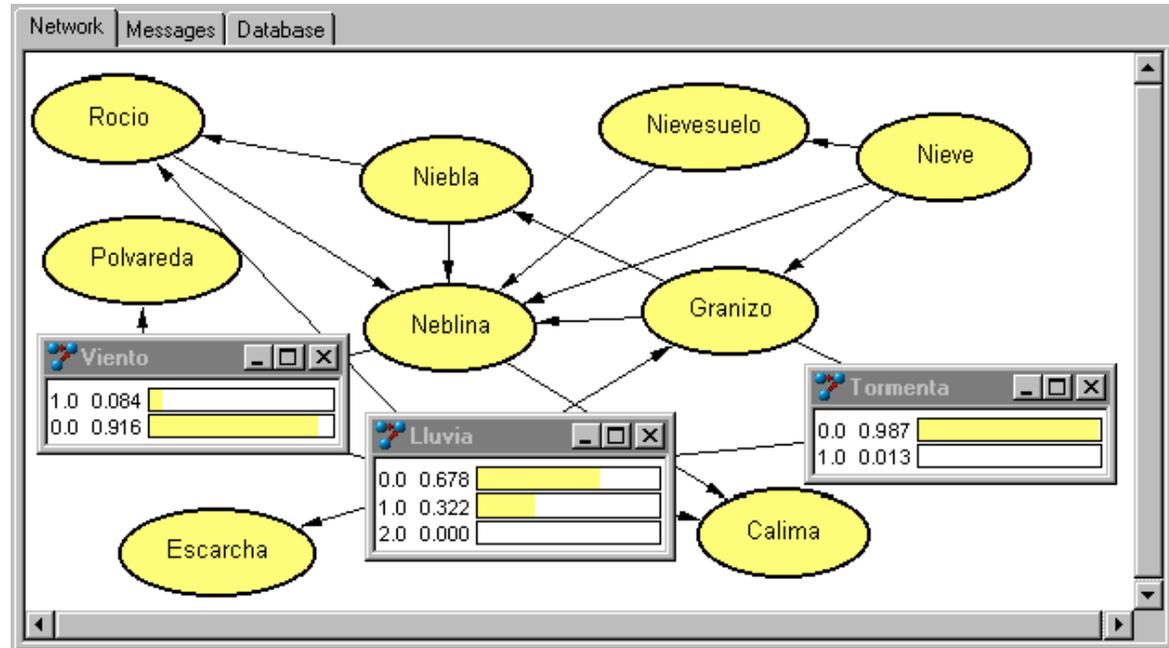
Lluvia	0.0	1.0
5.0	0.998	0.002
1.0	0.996	0.004
3.0	0.990	0.010
0.0	0.963	0.037
4.0	0.917	0.083

Cuantificación

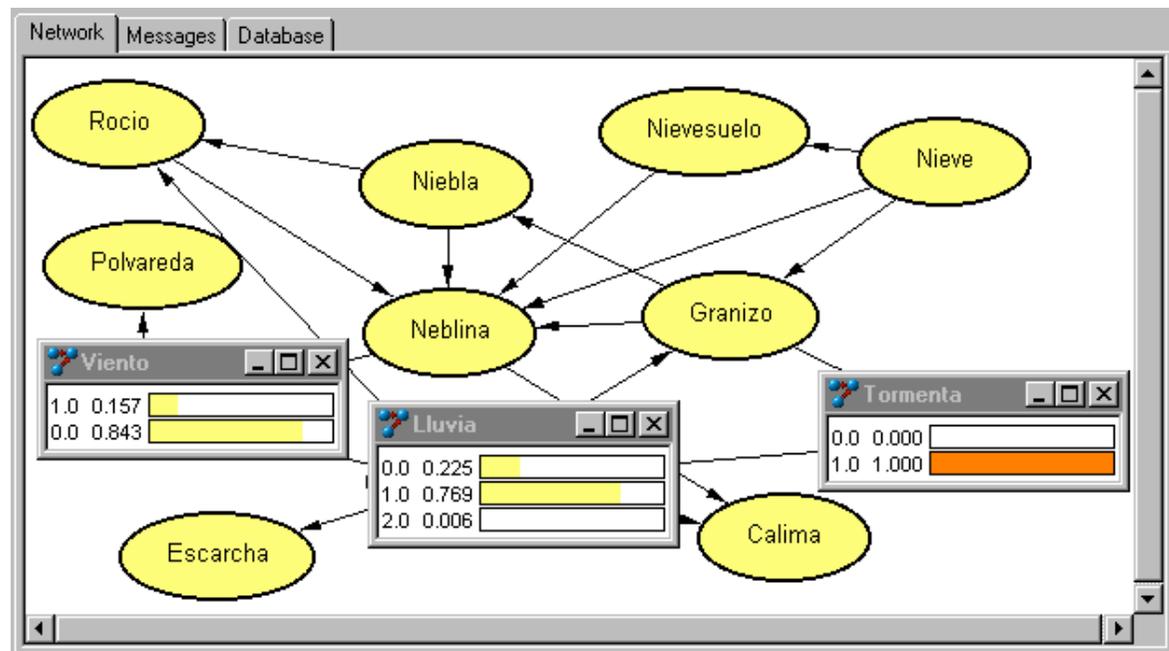
Funciones de prob. condicionada.

Cálculo de probabilidades

Inicialmente los distintos estados de las variables de la red tienen probabilidades que corresponden al estado de conocimiento inicial (**sin evidencia**).



Cuando se tiene alguna evidencia, las nuevas probabilidades condicionadas dan la influencia de esta información en el resto de variables
Tormenta = 1



Componentes Principales e Independientes



✓ **Modelado de Dependencias:**
*asociaciones entre variables.
reglas y grafos.*

✓ **Componentes Principales:**
compresión de la información.

✓ **Componentes Independientes:**
extracción de características.

✓ **Agrupación:**
hallar grupos de elementos.

✓ **Clasificación:**
asignar elementos a clases.

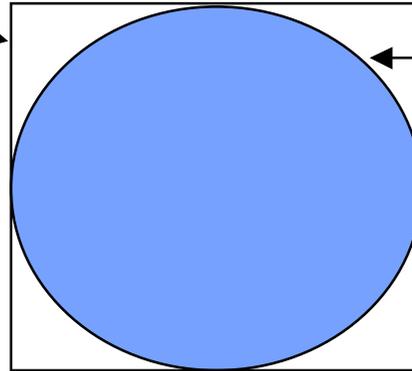
✓ **Predicción:**
estimación de valores.

✓ **Visualización:**
representación gráfica.

Problemas con datos de alta dimensionalidad

(David Scott, *Multivariate Density Estimation*, Wiley, 1992)

Hypercube
in d dimensions



Hypersphere
in d dimensions

Volume of sphere relative to cube in d dimensions?

Dimension	2	3	4	5	6	7
Rel. Volume	0.79	0.53	0.31	0.16	0.08	0.04

- *high-d, uniform \Rightarrow most data points will be “out” at the corners*
- ***high-d space is sparse: and non-intuitive***

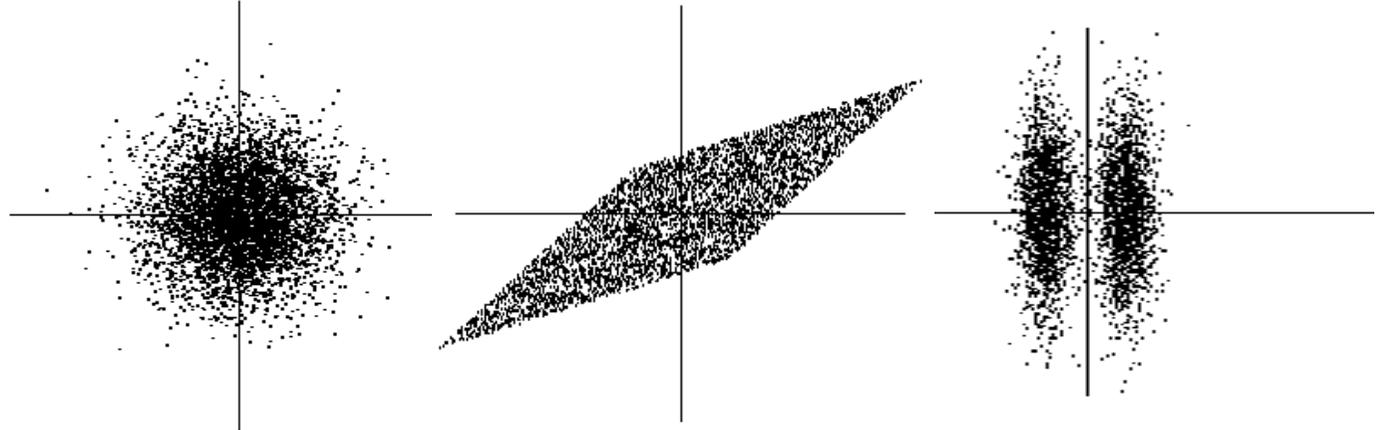
Ejemplos y casos a estudiar

$$Y^k = M X^k$$

Datos Aleatorios Gaussianos Análisis de Componentes Principales

$$X^k = \begin{bmatrix} d \\ \vdots \\ x_i^k \\ \vdots \end{bmatrix} E_i$$

$$\begin{bmatrix} r \\ \vdots \\ c_i^k \\ \vdots \end{bmatrix} V_i,$$



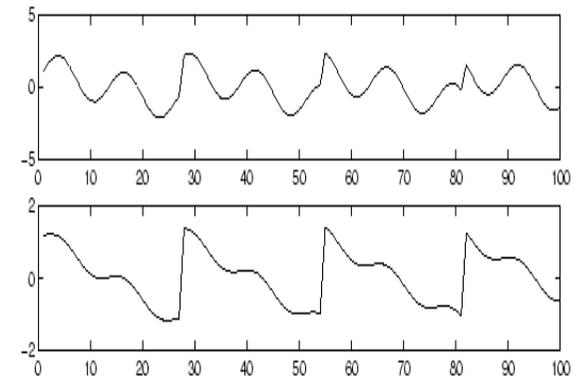
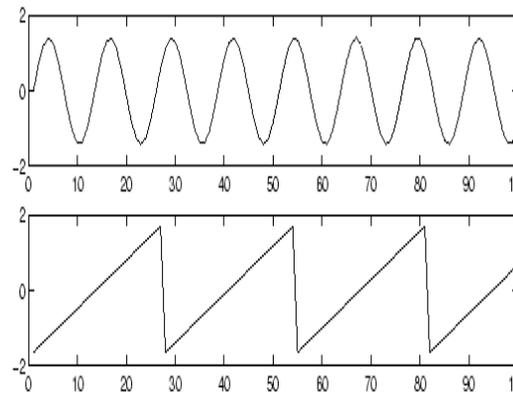
**Maximizar
varianza**

Datos Aleatorios NO-Gaussianos Análisis de Componentes Independientes

$$X^k = M S^k$$

X es la mezcla de m señales S Independientes. Dada X:

$$y_i^k = w_i^T X^k \quad \text{Indep.}$$



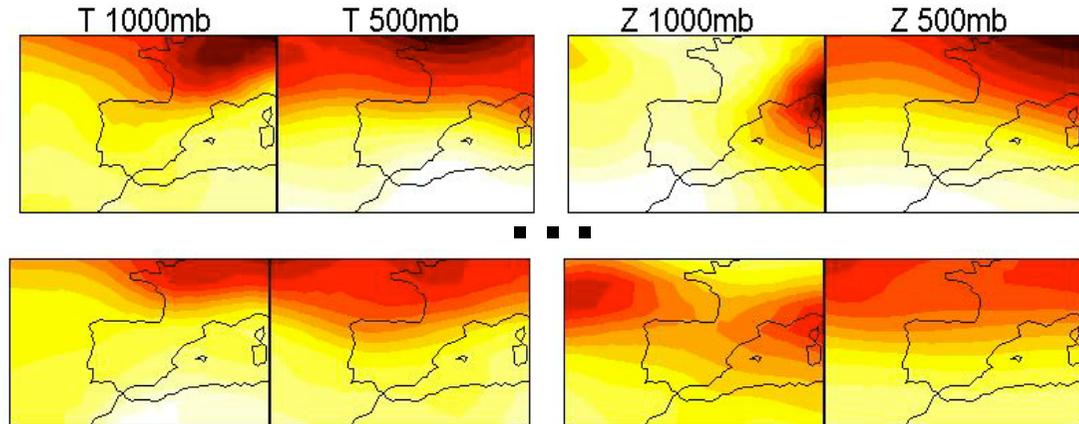
**Maximizar
independencia**

Ejemplos y casos a estudiar

$$Y^k = M X^k$$

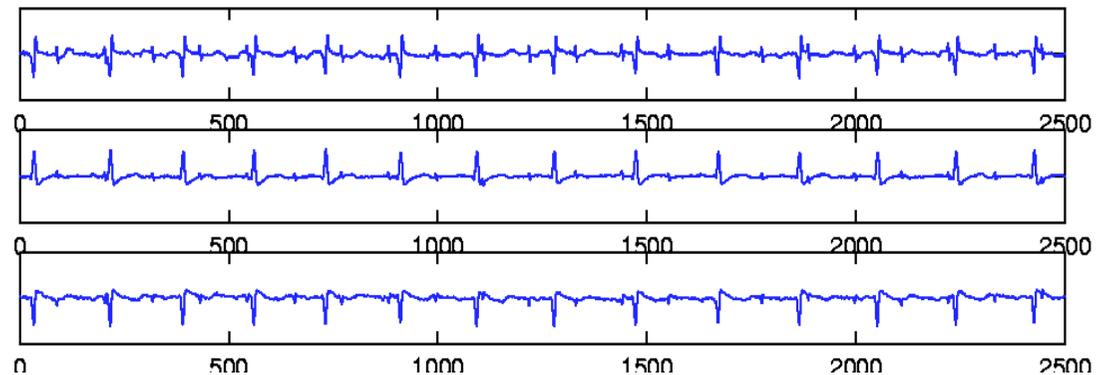
Datos Aleatorios Gaussianos Análisis de Componentes Principales

Maximizar
varianza



Datos Aleatorios NO-Gaussianos Análisis de Componentes Independientes

Maximizar
independencia



Sistemas Deterministas (Caos determinista) Estimación No-Paramétrica

$$Y^k = F(X^k)$$

Estimar **F**

Base de Datos de Re-Análisis del Centro Europeo

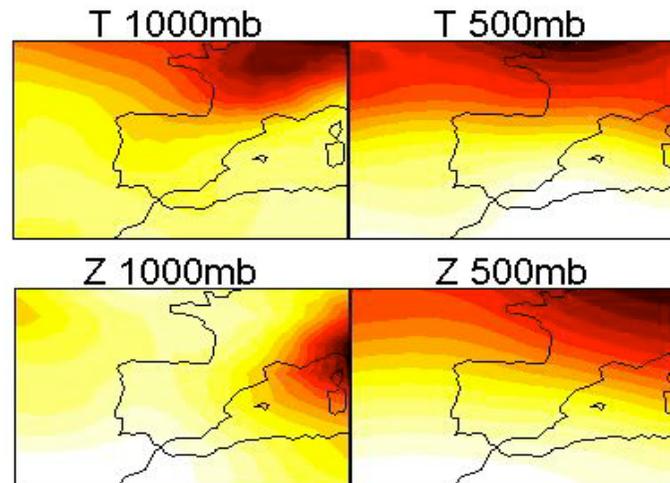
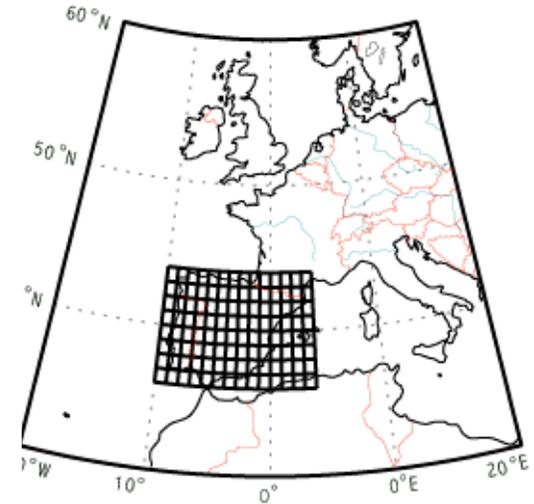
El Reanálisis del ECMWF

proporciona una base de datos de salidas del modelo numérico.

Serie diaria **1979-1993**
 a las **0, 6, 12 y 18** horas.

En cada uno de los nodos
 • **5 variables** Z, T, U, V y H
 • **7 niveles** de presión

$$\left\{ \begin{array}{l} \frac{\partial u}{\partial t} = -u \frac{\partial u}{\partial x} - v \frac{\partial u}{\partial y} - \omega \frac{\partial u}{\partial p} - \frac{\partial \Phi}{\partial x} + fv + F_x \\ \frac{\partial v}{\partial t} = -u \frac{\partial v}{\partial x} - v \frac{\partial v}{\partial y} - \omega \frac{\partial v}{\partial p} - \frac{\partial \Phi}{\partial y} - fu + F_y \\ \frac{\partial \Phi}{\partial p} = -\frac{RT}{p} \\ \frac{\partial T}{\partial t} = -u \frac{\partial T}{\partial x} - v \frac{\partial T}{\partial y} + \omega \left(\frac{\kappa T}{p} - \frac{\partial T}{\partial p} \right) + \frac{\dot{H}}{c_p} \\ \frac{\partial \omega}{\partial p} = -\left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right) \end{array} \right.$$

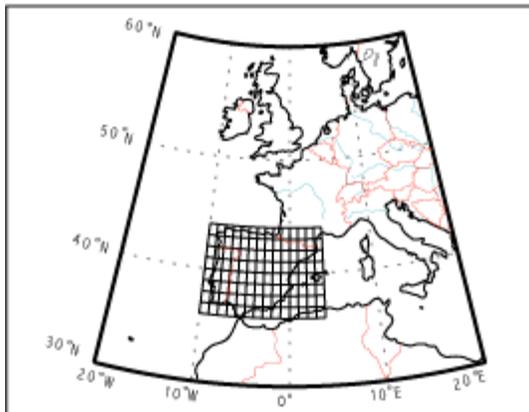


Componentes Principales. Primera Opción

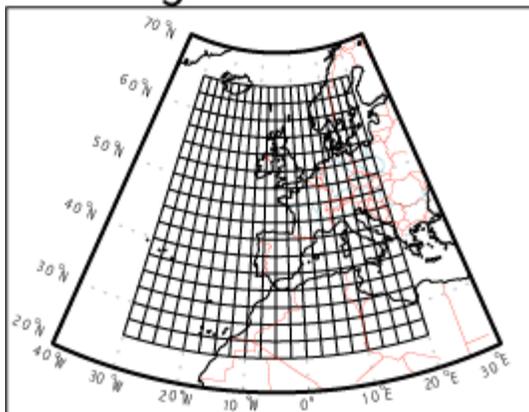
We used atmospheric circulation patterns at 1200 UTC of ERA-15 (1979-1993) reanalysis data

$$P = (T(1000 \text{ mb}), \dots, T(500 \text{ mb}); Z(1000 \text{ mb}), \dots, Z(500 \text{ mb}); \dots; H(1000 \text{ mb}), \dots, H(500 \text{ mb}))$$

Limited Area Grid

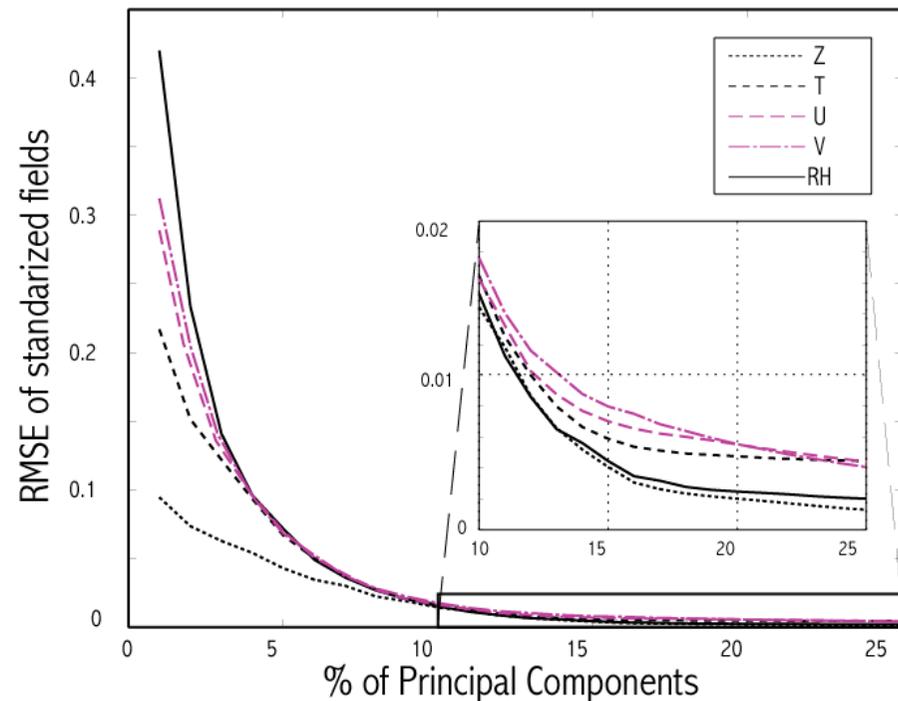


Large Scale Grid



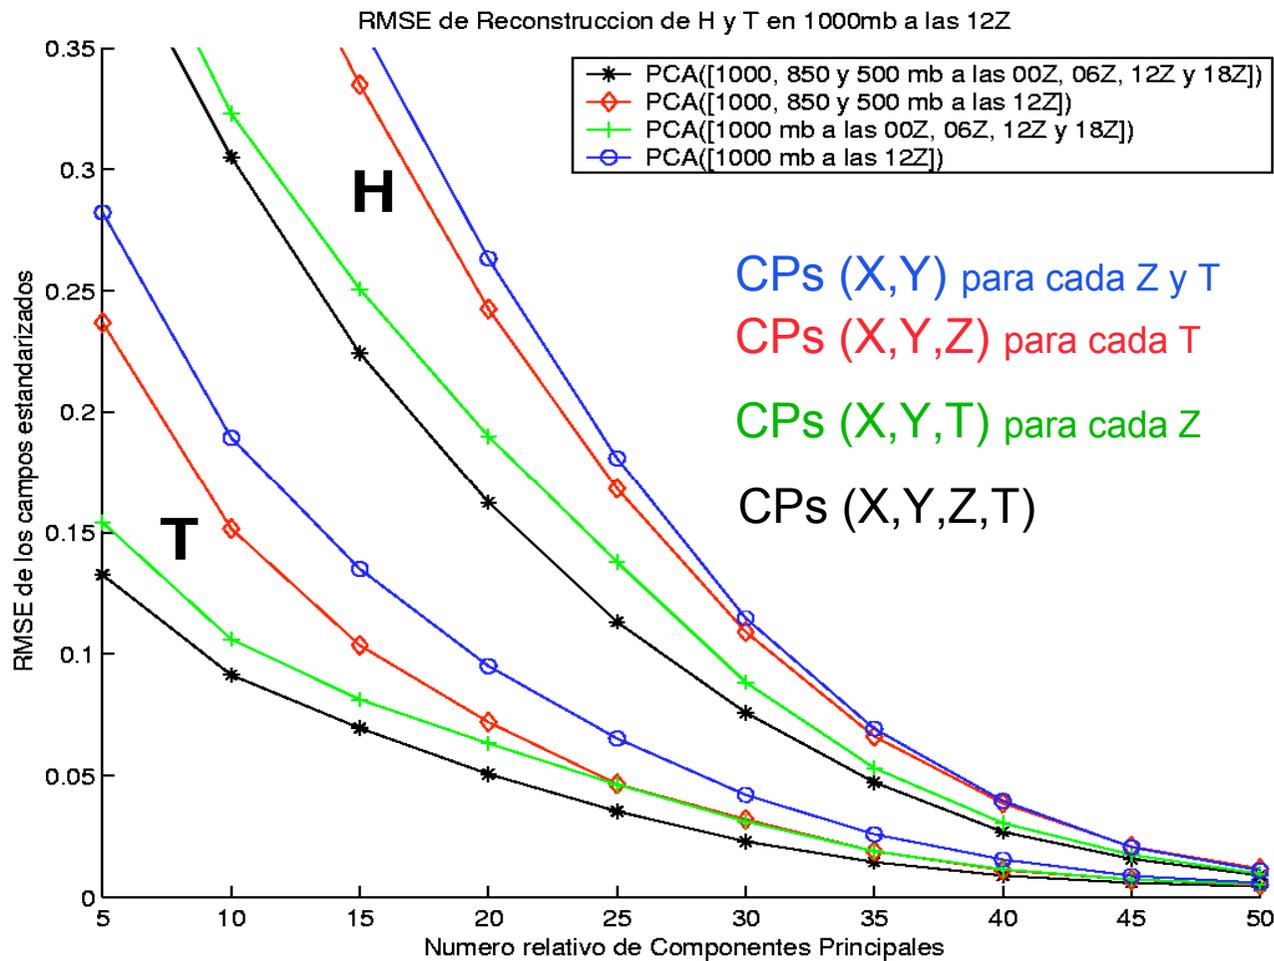
→ P is **6000 dimensional !!!**

Using Principal Components the dimension can be reduced to **500 – 600**.



Componentes Principales. Alternativas

La configuración atmosférica de un día concreto viene dada por un campo (X,Y,Z) para cada $T=0, 6, 12$ y 18 horas



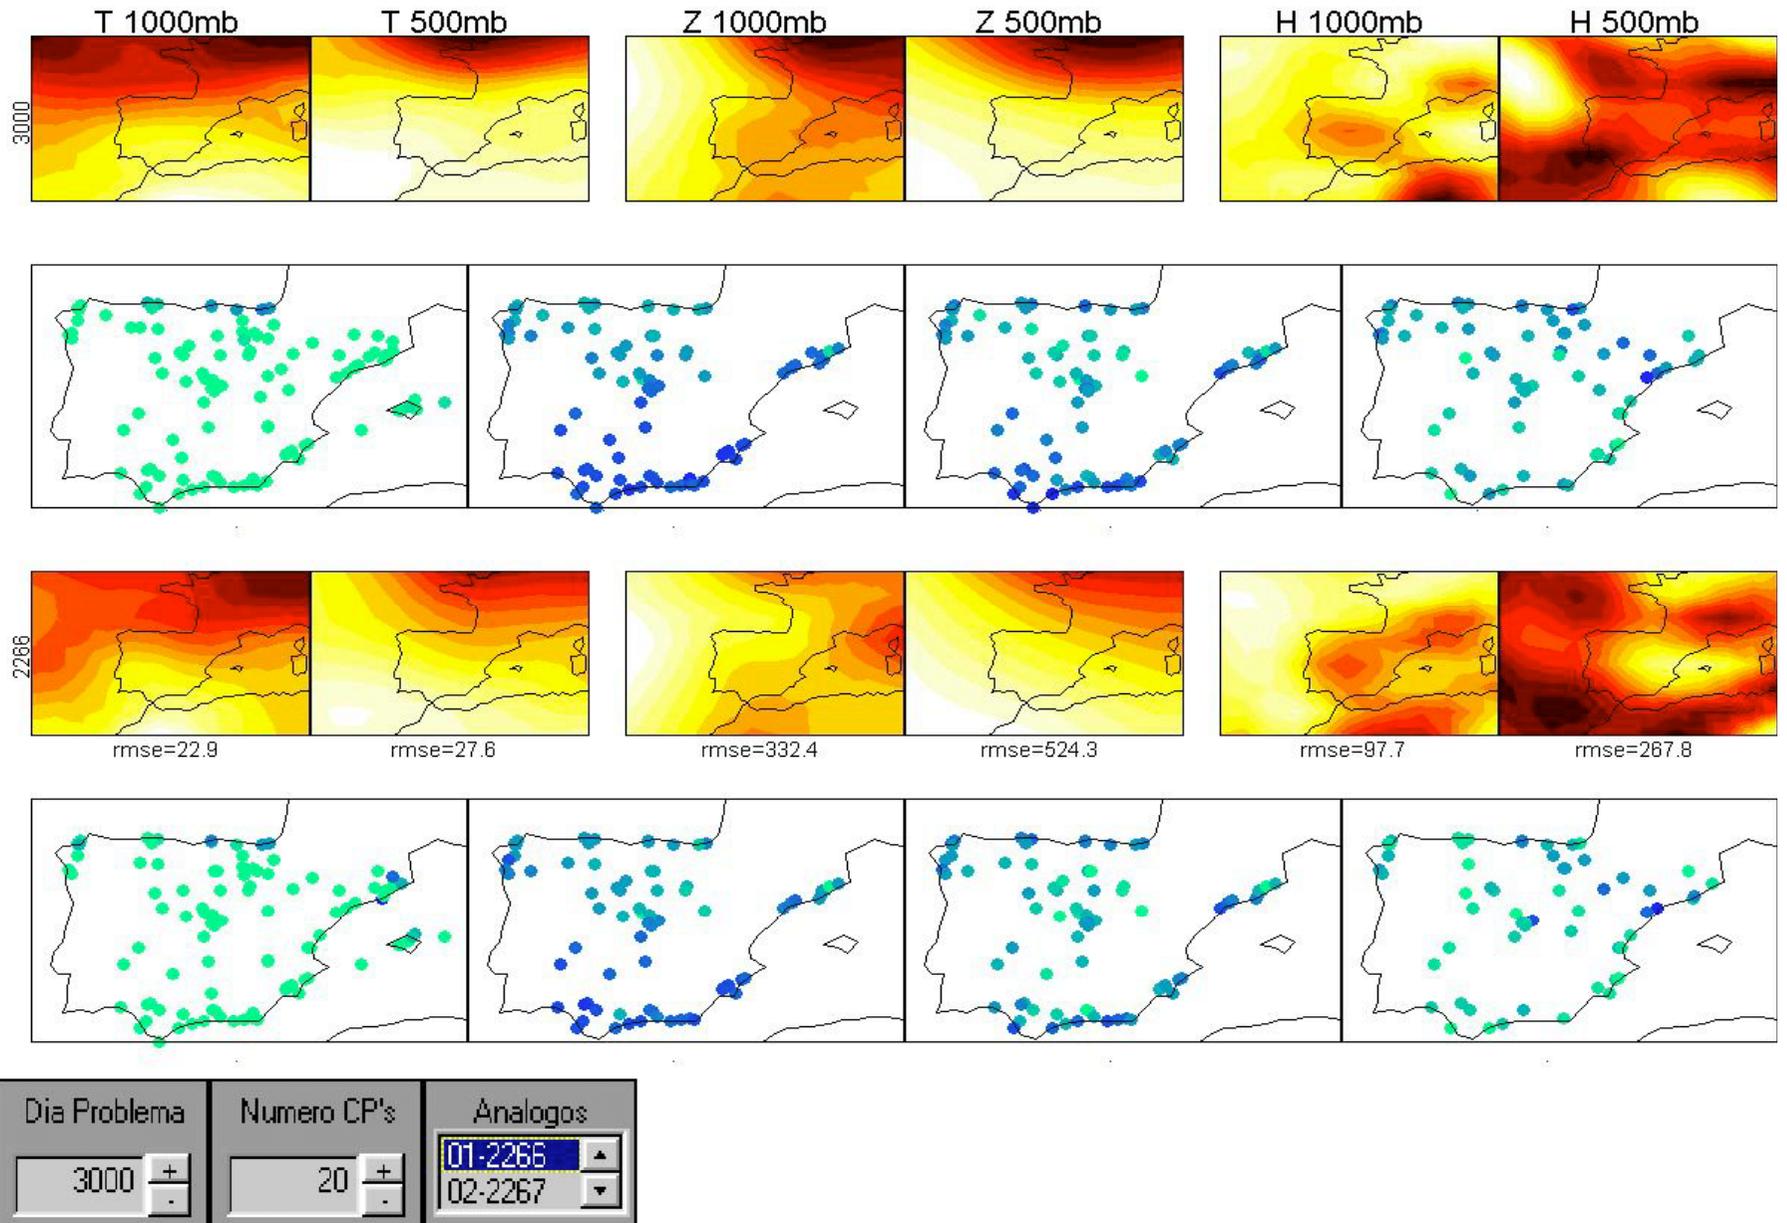
$$X^k = \prod_{i=1}^d v_i^k E_i$$

$$\prod_{i=1}^r c_i^k V_i,$$

$$k = 1, 2, \dots, n$$

Si los vectores X^k son realizaciones de una variable Gaussiana, los V_i óptimos son los autovectores de la matrix de covarianza.

Componentes Principales con MeteoLab



Agrupación y Clasificación



- ✓ **Componentes Principales:**
compresión de la información.
- ✓ **Componentes Independientes:**
extracción de características.
- ✓ **Modelado de Dependencias:**
hallar asociaciones entre variables
redes Bayesianas
- ✓ **Agrupación:**
hallar grupos de elementos
- ✓ **Clasificación:**
asignar elementos a clases
- ✓ **Predicción:**
estimación de valores
- ✓ **Visualización:**
representación gráfica.
Redes Neuronales

Técnicas de Aprendizaje Automático

Predictivas

- **Interpolación**: una función continua sobre varias dimensiones
- **Predicción secuencial**: las observaciones están ordenadas secuencialmente. Se predice el siguiente valor de la secuencia. Caso particular de interpol. con 2 dim., una discreta y regular.
- **Aprendizaje supervisado**: cada observación incluye un valor de la clase a la que corresponde. Se aprende un clasificador. Caso particular de interpolación: la clase (imag. función) es discreta.

Deductivas

- **Aprendizaje no supervisado**: el conjunto de observaciones no tienen clases asociadas. El objetivo es detectar regularidades en los datos de cualquier tipo: agrupaciones, contornos, asociaciones, valores anómalos.

Aprendizaje Automático. Ejemplos

Ejemplos:

Predictivos

- *Interpolacion:*



$$f(2.2)=?$$

- *Prediccion secuencial:* 1, 2, 3, 5, 7, 11, 13, 17, 19, ... ?

- *Aprendizaje supervisado:*

$$1\ 3 \rightarrow 4.$$

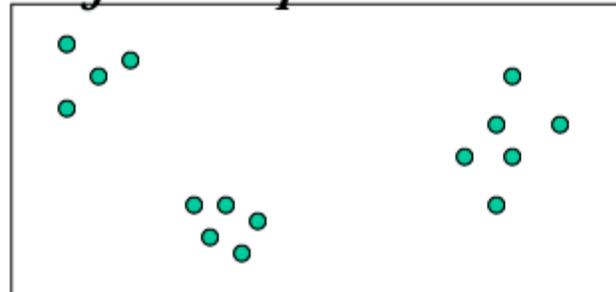
$$3\ 5 \rightarrow 8.$$

$$7\ 2 \rightarrow 9.$$

$$4\ 2 \rightarrow ?$$

Descriptivos

- *Aprendizaje no supervisado:*



¿Cuántos grupos hay?

Clasificación. Planteamiento del Problema

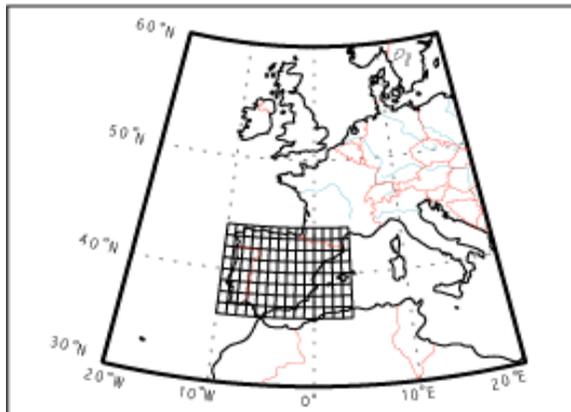
- Classification is an important problem in artificial intelligence
- We have a special discrete-valued variable called the Class, C
 - C takes values in $\{c_1, c_2, \dots, c_m\}$
 - for now assume $m=2$, i.e., 2 classes: $c_1 = 1, c_2 = 2$
- Problem is to decide what class an object is
 - i.e., what value the class variable C is for a given object
 - given measurements on the object, e.g., X, Y, \dots
 - These measurements are called “features”
 - **we wish to learn a mapping from Features \rightarrow Class**
- Notation:
 - C is the class
 - X, Y , etc (the measurements) are called the “features” (sometimes also called “attributes”)

Clustering ERA-15 Data for **Selecting Analogues Ensembles**

We used atmospheric circulation patterns at 1200 UTC of ERA-15 (1979-1993) reanalysis data

$$P = (T(1000 \text{ mb}), \dots, T(500 \text{ mb}); Z(1000 \text{ mb}), \dots, Z(500 \text{ mb}); \dots; H(1000 \text{ mb}), \dots, H(500 \text{ mb}))$$

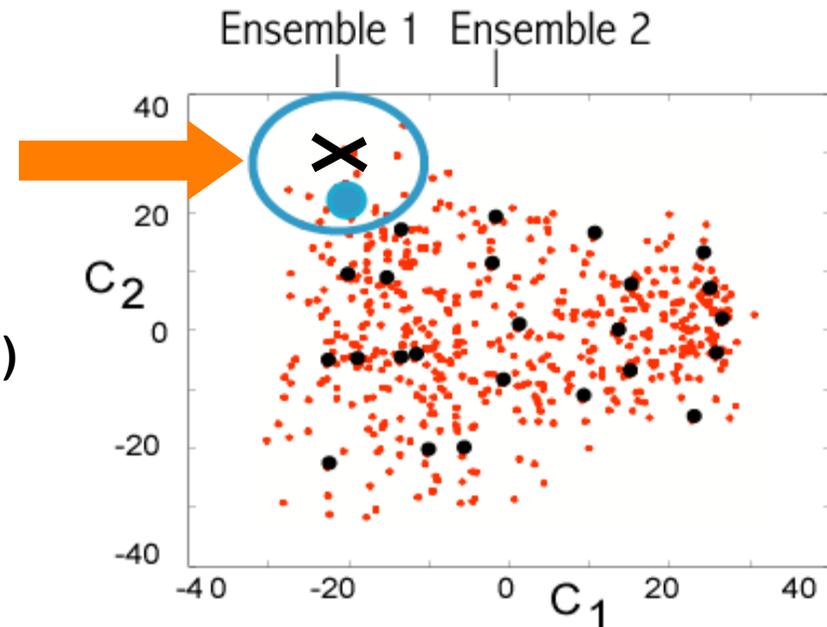
Limited Area Grid



→ P is **6000 dimensional** !!!

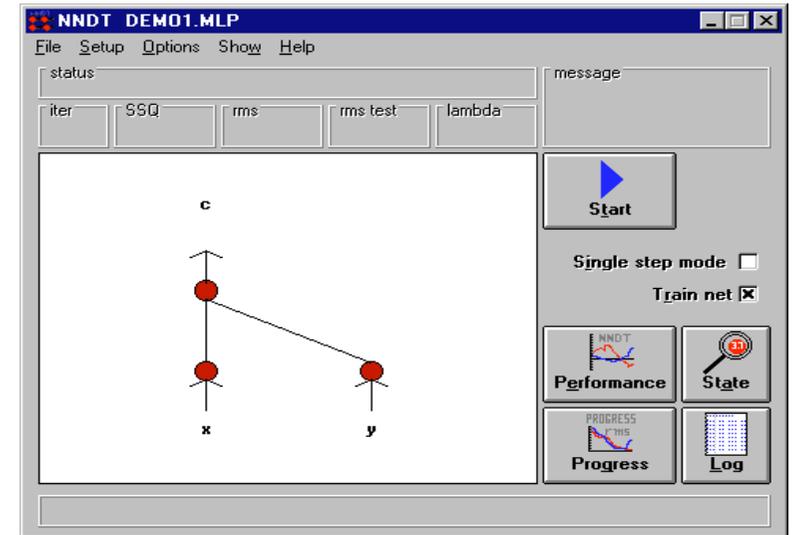
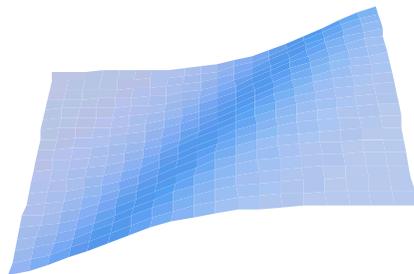
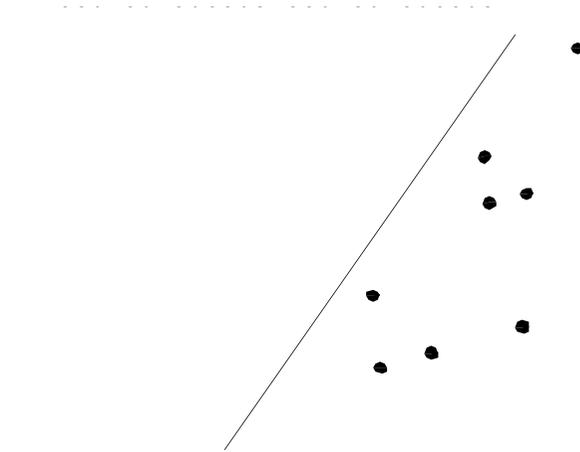
Using Principal Components the dimension can be reduced to **500 – 600**.

- Projection of ERA-15 using the first 2 PCs
- Cluster centers (prototypes)
- ✕ Predicted pattern to be downscaled



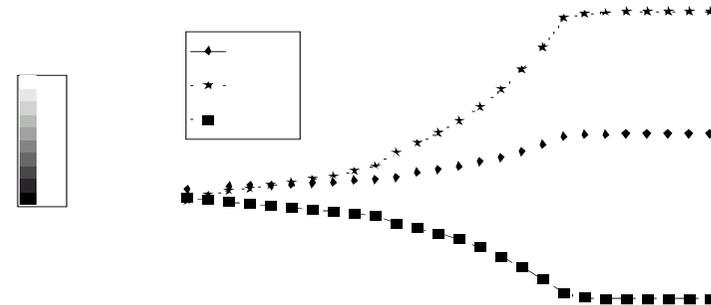
Clasificación con Redes Neuronales

Dada una nube de puntos en el plano correspondientes a dos clases distintas, se quiere obtener un criterio de clasificación automático, que extrapole la información de estos puntos.



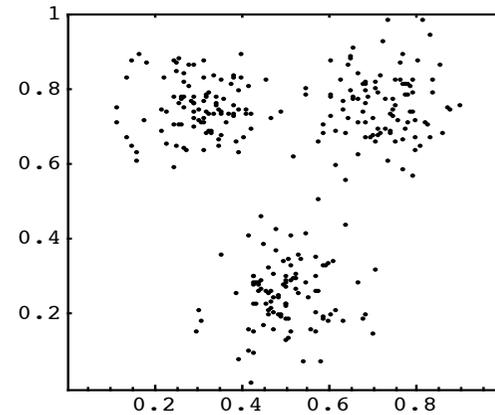
ERROR

PESOS

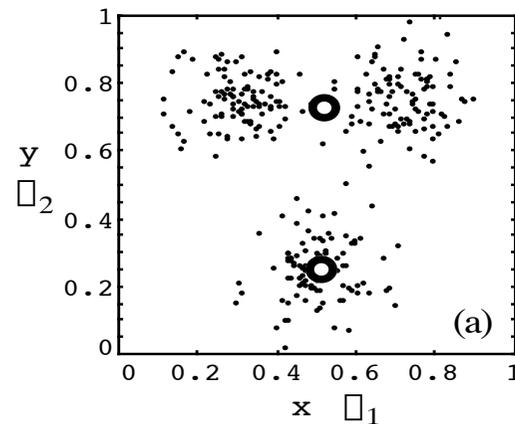
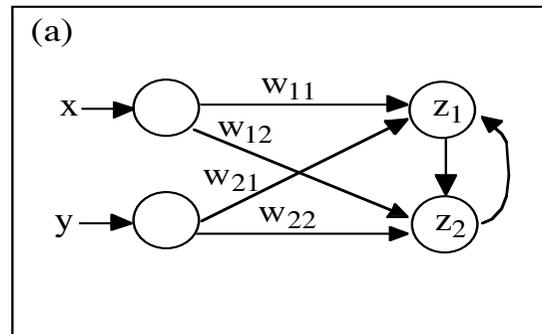


Clasificación no supervisada

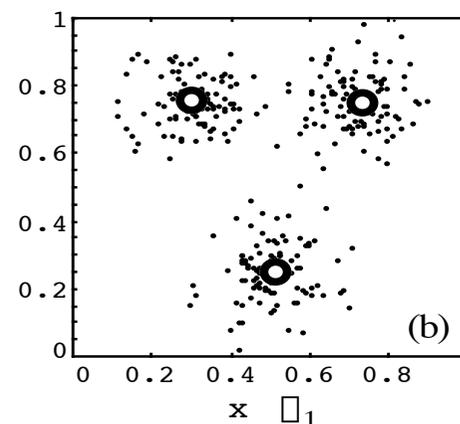
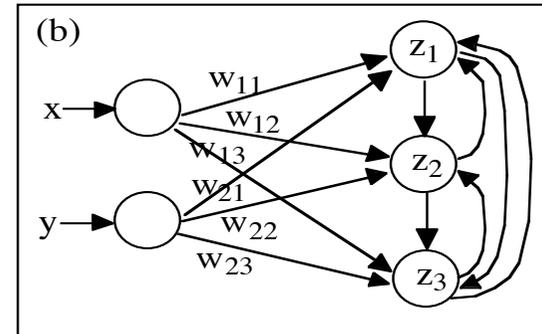
Las redes competitivas permiten obtener criterios de clasificación no supervisados (el usuario no especifica el número de clases).



Red con **dos** procesadores de salida (dos clases)



Red con **tres** procesadores de salida (tres clases)

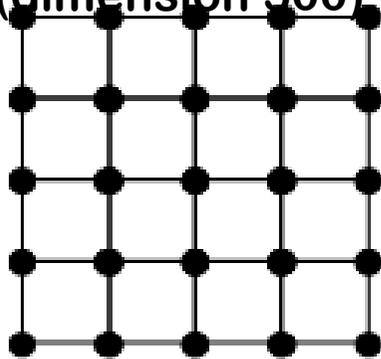


Self-Organizing Maps. Preserving Data Topology

*For medium and seasonal weather forecast, we need a measure of the **dispersion of the forecast ensemble members.***

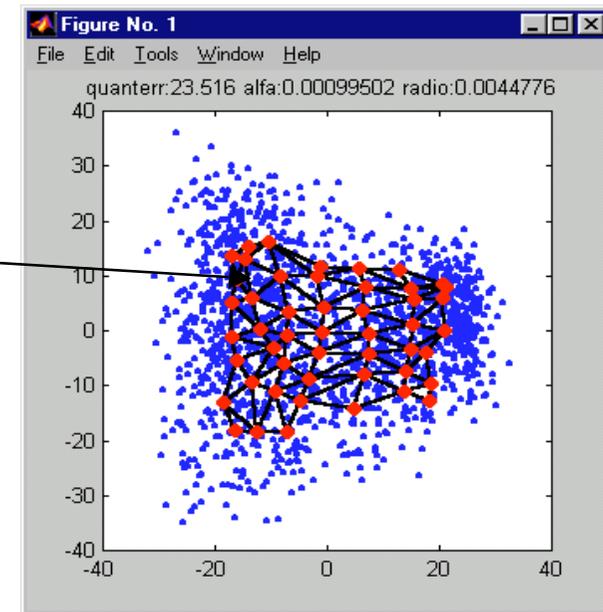
Therefore, we also need a measure of Cluster Dispersion.

Cluster units are located on a 2D lattice, each one associate with a pattern prototype (dimension 500)



**Adaptive
Competitive
Learning**

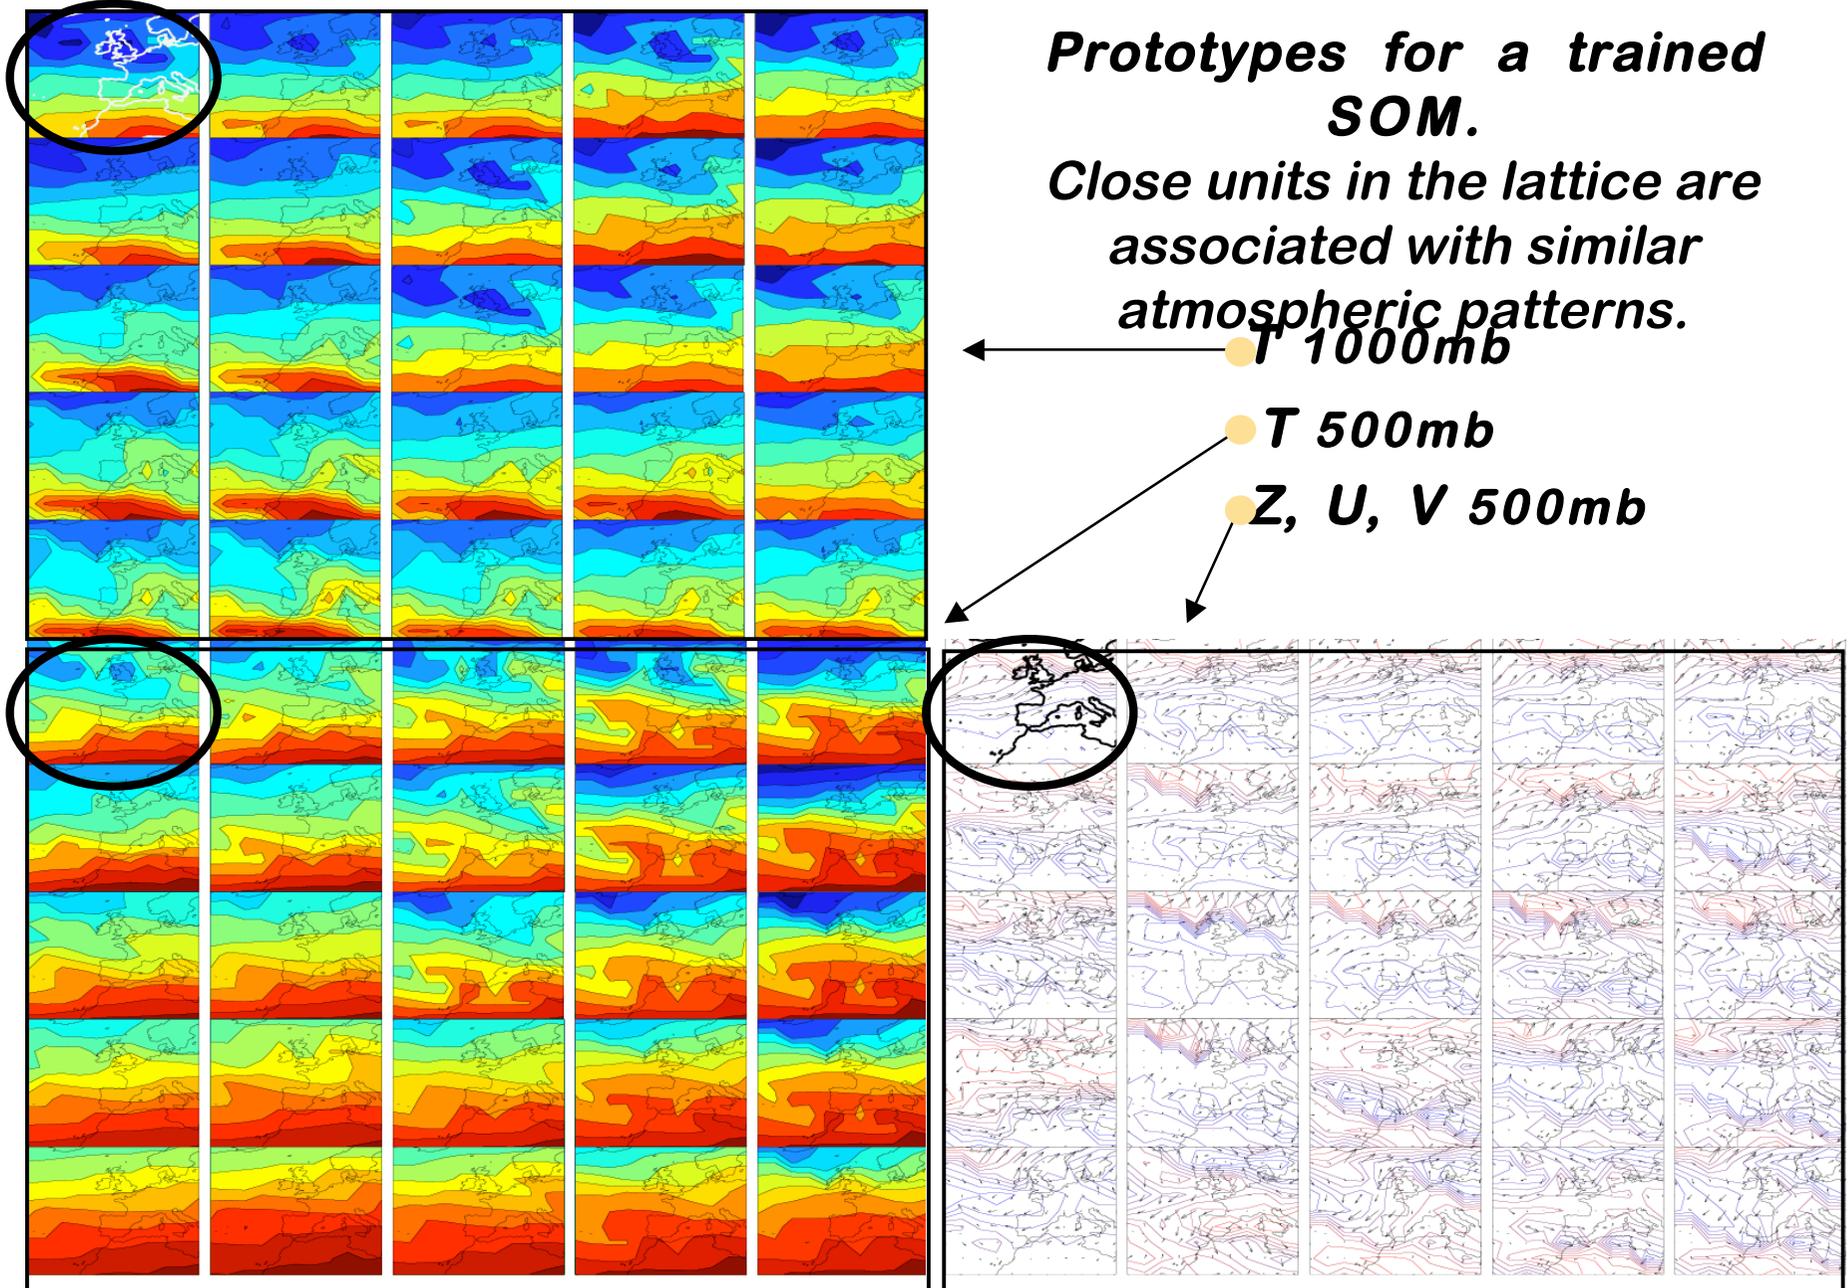
Dimension 500



Topology preserving transformation.

Close clusters in the lattice correspond to close prototypes in the high dimensional data space.

T 1000mb, T 500 mb Z,U,V 500mb patterns for a 5X5 SOM



Predicción. Regresión y Redes Neuronales

José Manuel Gutiérrez, Universidad de Cantabria. (2001)

<http://personales.unican.es/gutierjm>

VII Congreso Argentino de Ciencias de la Computación
V Escuela Internacional de Informática
Octubre del 2001, Calafate (Argentina)

Data Mining.

Extracción de Conocimiento
en Grandes Bases de Datos

JAVA UC UNIVERSIDAD DE CANTABRIA

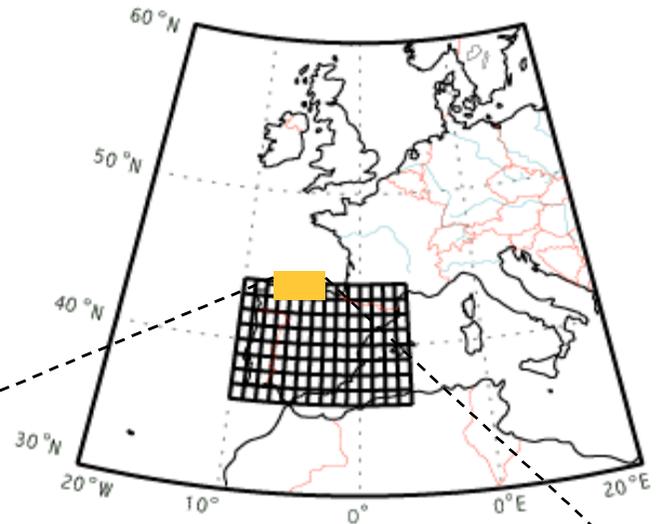
- ✓ **Componentes Principales:**
compresión de la información.
- ✓ **Componentes Independientes:**
extracción de características.
- ✓ **Modelado de Dependencias:**
hallar asociaciones entre variables
redes Bayesianas
- ✓ **Agrupación:**
hallar grupos de elementos
- ✓ **Clasificación:**
asignar elementos a clases
- ✓ **Predicción:**
estimación de valores
- ✓ **Visualización:**
representación gráfica.
Redes Neuronales

Weather Forecasting (Downscaling)

Numeric atmospheric models are the basic tools for operative forecasting.



$$\left\{ \begin{array}{l} \frac{\partial u}{\partial t} = -u \frac{\partial u}{\partial x} - v \frac{\partial u}{\partial y} - \omega \frac{\partial u}{\partial p} - \frac{\partial \Phi}{\partial x} + fv + F_x \\ \frac{\partial v}{\partial t} = -u \frac{\partial v}{\partial x} - v \frac{\partial v}{\partial y} - \omega \frac{\partial v}{\partial p} - \frac{\partial \Phi}{\partial y} - fu + F_y \\ \frac{\partial \Phi}{\partial p} = -\frac{RT}{p} \\ \frac{\partial T}{\partial t} = -u \frac{\partial T}{\partial x} - v \frac{\partial T}{\partial y} + \omega \left(\frac{\kappa T}{p} - \frac{\partial T}{\partial p} \right) + \frac{\dot{H}}{c_p} \\ \frac{\partial \omega}{\partial p} = -\left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right) \end{array} \right.$$

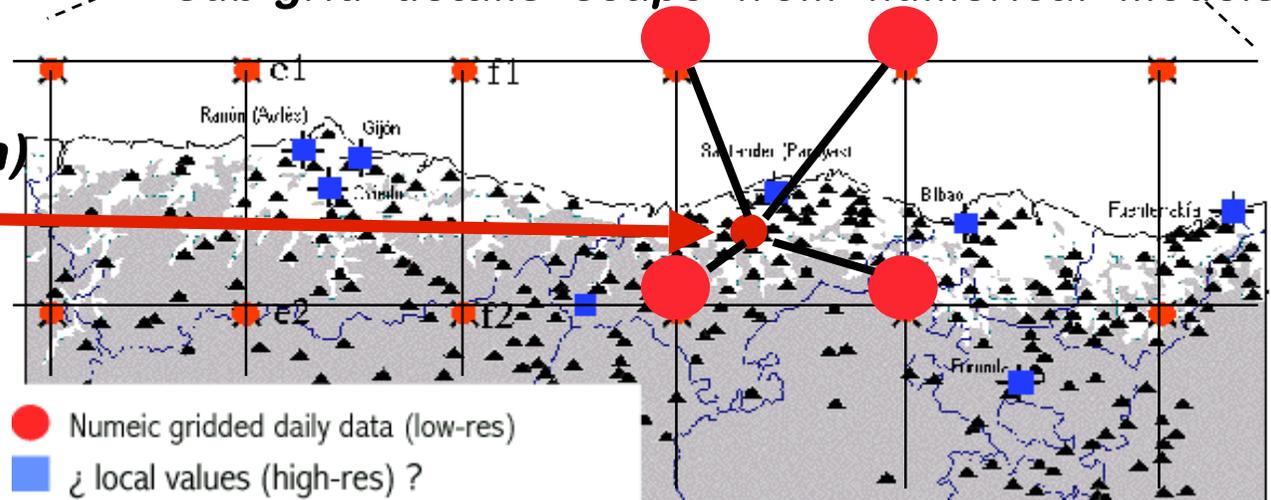


Sub-grid details scape from numerical models

How can we get a prediction for a local point (station) of interest

- Interpolating the gridded predictions.
- Applying statistics to station historical records:

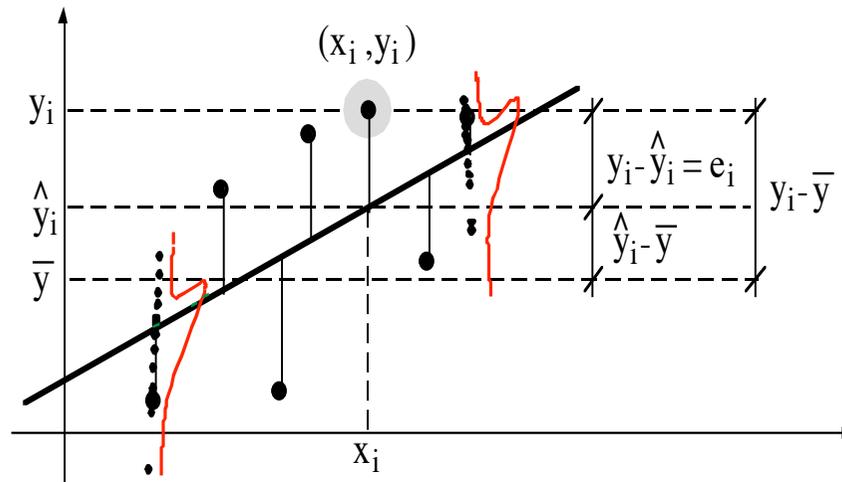
X_1, X_2, X_3, \dots



STATISTICAL DOWNSCALING

Técnicas Clásicas de Predicción

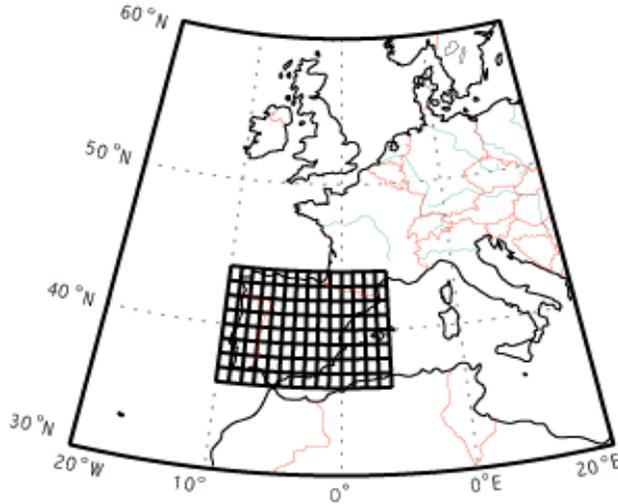
- **Regresión Lineal:** $Y = a + b X$
 - Los parámetros **a** y **b** definen la línea recta que más se ajusta al conjunto de datos disponible; estos parámetros se estiman **directamente** de los datos utilizando el criterio de mínimos cuadrados con los valores conocidos de $Y_1, Y_2, \dots, X_1, X_2, \dots$



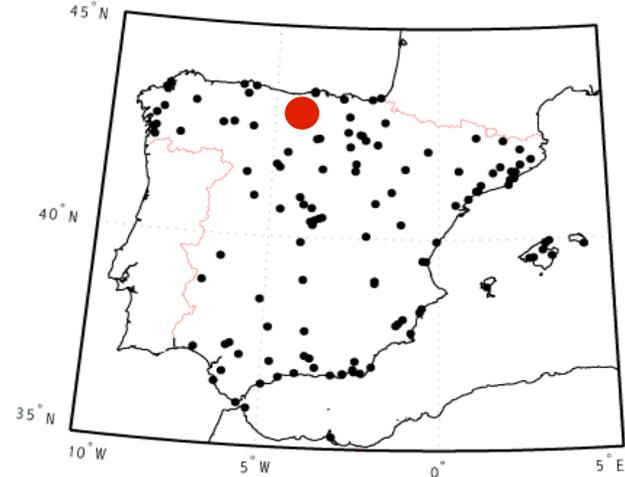
- **Regresión Múltiple:** una extensión de la regresión lineal para tratar vectores:
 $Y = b_0 + b_1 X_1 + b_2 X_2.$
Numerosas funciones no lineales pueden transformarse en este tipo de ecuación.

Regresión Lineal

Gridded atmospheric circulation patterns for day n



Observations at 122 stations for day n



$$\left. \begin{array}{l} (T(1000 \text{ mb}), \dots, T(500 \text{ mb}); \\ Z(1000 \text{ mb}), \dots, Z(500 \text{ mb}); \\ \dots; \\ H(1000 \text{ mb}), \dots, H(500 \text{ mb})) = \mathbf{X}_n \end{array} \right\}$$

$$\mathbf{Y}_n = F(\mathbf{x}_n)$$

Precipitation
Maximum wind speed
Sun light, ...
 \mathbf{Y}_n

A linear model $\mathbf{Y}_n = \mathbf{W}^T \mathbf{X}_n$ can be obtained by estimating the coefficients $\mathbf{W} = (w_1, \dots, w_p)$ from historical records from a period $i=1, \dots, N$ where both \mathbf{X}_i and \mathbf{Y}_i are available.

Given a gridded forecast \mathbf{X}_{n+1} an estimation is obtained as:

$$\hat{\mathbf{Y}}_{n+1} = \mathbf{W}^T \mathbf{X}_{n+1}$$

Nonlinearities in the relationship $Y_n = f(X_n)$

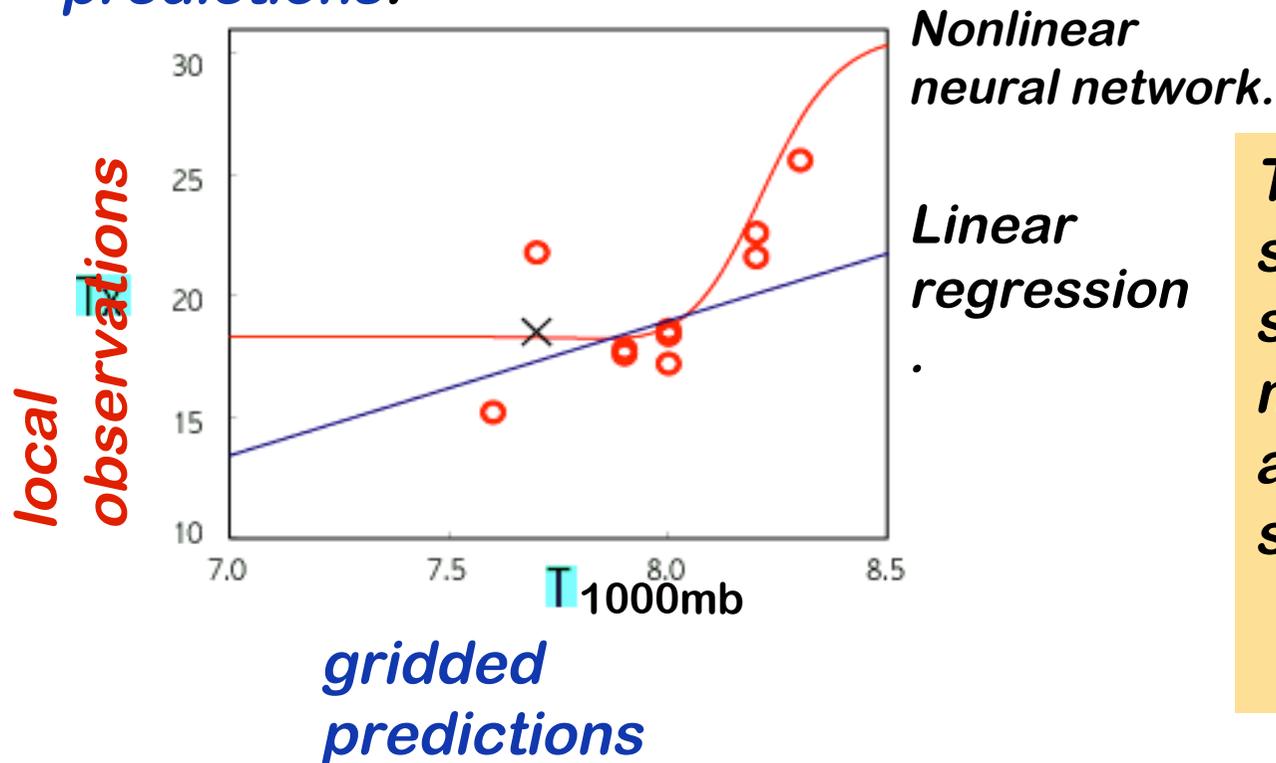
Let us consider a simple case:

$(T(1000\text{ mb}), \dots, T(500\text{ mb}); Z(1000\text{ mb}), \dots, Z(500\text{ mb}); \dots; H(1000\text{ mb}), \dots, H(500\text{ mb})) = X_n$

$TMax_n = w T1000_n$ is the simplest case for the relationship

$$TMax_n = f(T1000mb_n),$$

if any, between *local observations* and *gridded predictions*.



This example shows how a simple linear model is not appropriate in some cases:

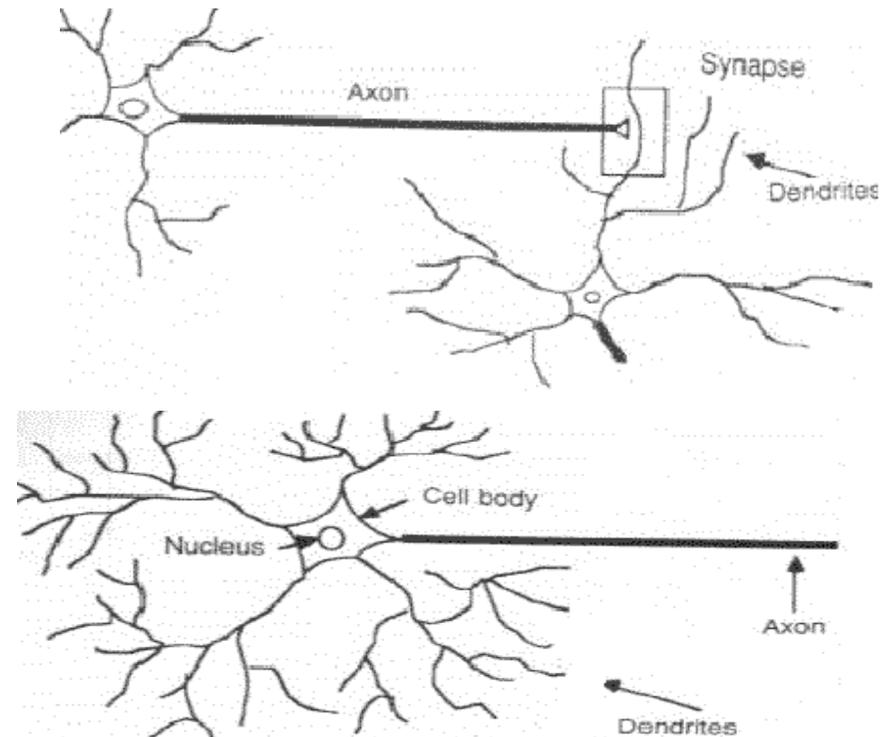
~~$TMax_n = a T_n$~~

$TMax_n = f(T_n)$

Redes Neuronales. Inspiración en la Neurofisiología

El cerebro humano está formado por un gran número de neuronas (más de 100000 millones) conectadas entre sí de forma masivamente paralela

La actividad de cada neurona se basa en descargas electroquímicas, a partir de los estímulos recibidos por neuronas vecinas a las que esté conectada.



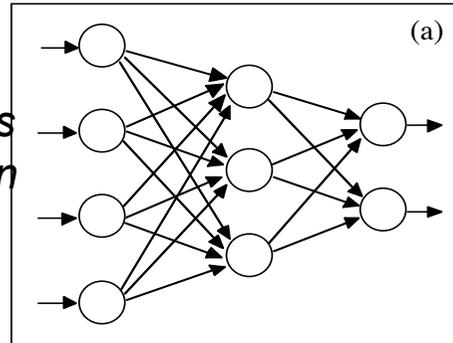
Neural Network Study (1988, AFCEA International Press, p. 60):
... a neural network is a system composed of many simple processing elements operating in parallel whose function is determined by network structure, connection strengths, and the processing performed at computing elements or nodes.

Redes Neuronales Artificiales

Siguiendo esta metodología se desarrollaron diversas topologías de red, para organizar la conexión de los procesadores.

Redes Multicapa.

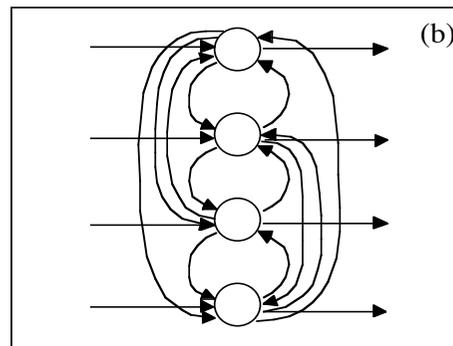
Con varias capas conectadas en serie con procesadores en paralelo.



Reconocimiento de patrones
OCR
Proc. lenguaje natural
Interpolación y extrapolación
Ajuste de funciones

Redes de Hopfield.

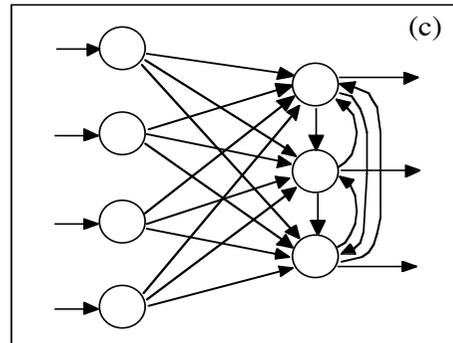
Una sólo capa totalmente interconectada y paralela.



Reconocimiento de patrones
OCR
Almacenamiento con recuperación robusta al ruido

Redes competitivas.

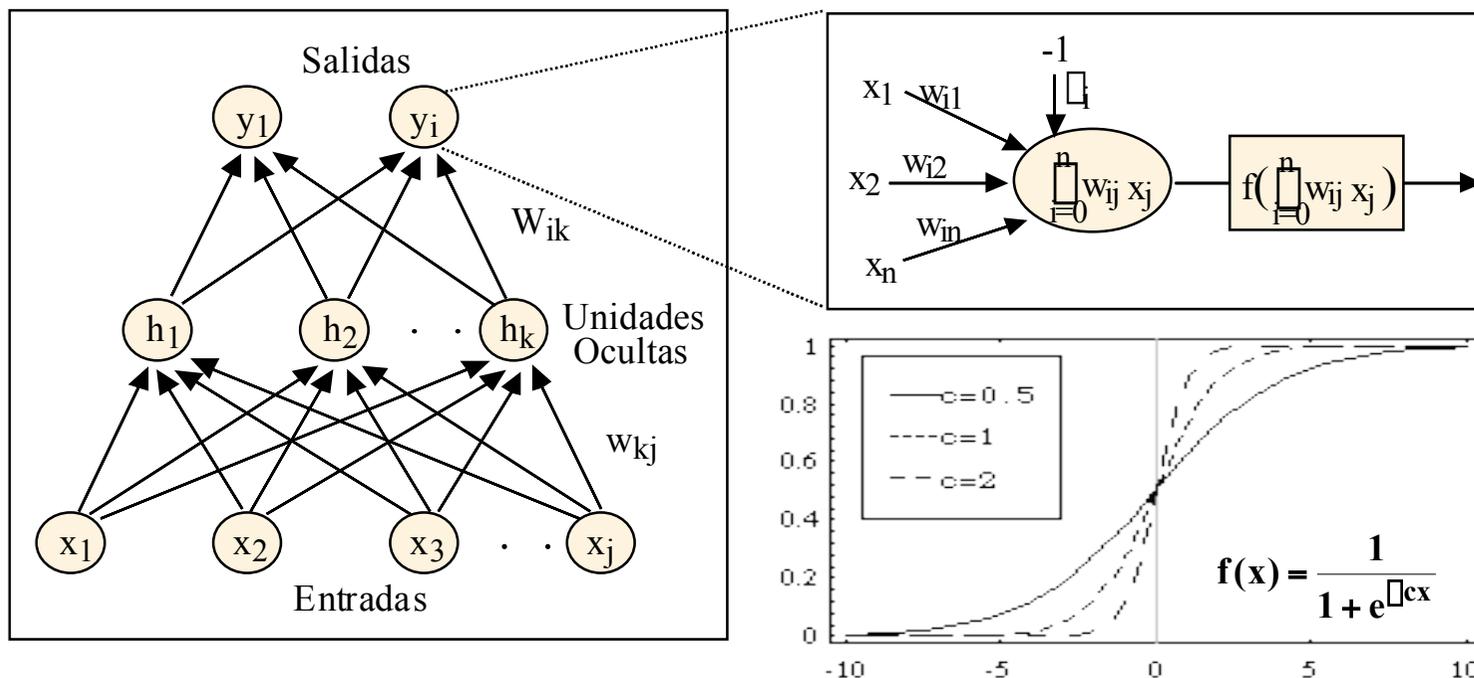
Redes multicapa con conexiones laterales en la última capa.



Clasificación autoorganizada
Reconstrucción topológica
Extracción de variables características

Redes Multicapa (Perceptrones)

Las **redes neuronales** permiten obtener una aproximación funcional de un modelo dado en base a un conjunto de datos y a operadores sigmoidales.



Cada procesador realiza una actividad muy simple: **combinación lineal** de las actividades recibidas por la neurona **activación * peso**.

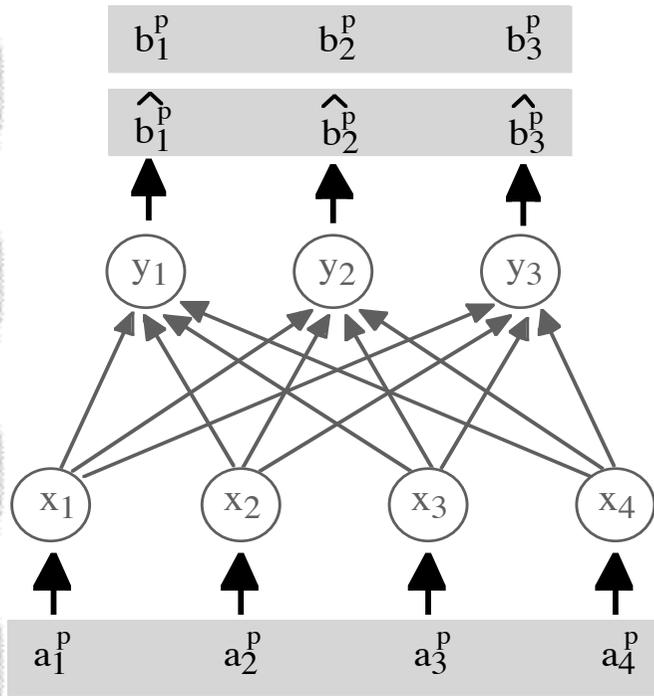
A continuación, se calcula su actividad aplicando una **función de activación no lineal**. La salida final es un **ajuste no lineal** de las entradas.

Estimar de los datos

$$y_i = f\left(\sum_k W_{ik} f\left(\sum_j w_{kj} x_j\right)\right)$$

El Aprendizaje

¿Cómo se pueden hallar los pesos para que una red obtenga las salidas correctas a partir de las entradas de un conjunto de entradas-salidas dado?



Inicialmente se eligen valores aleatorios para los pesos.

Aprendizaje Hebbiano: Se modifican los pesos acorde a la correlación entre las unidades.

Se eligen los patrones (a^p, b^p) de uno en uno y se modifican los pesos w_{ij} de los procesadores con salidas incorrectas:

$$\Delta w_{ij} = (b_i^p - \hat{b}_i^p) a_j^p$$

Descenso de gradiente: Se modifican los pesos acorde a la dirección del gradiente de una función de error.

$$E(w_{ij}) = \sum_{i,p} (b_i^p - \hat{b}_i^p)^2$$

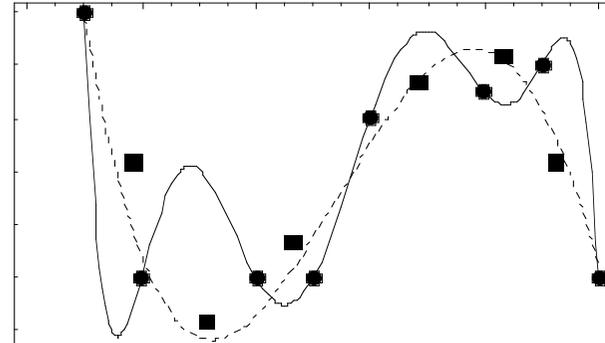
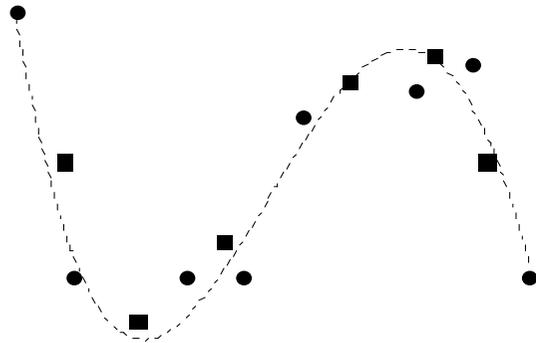
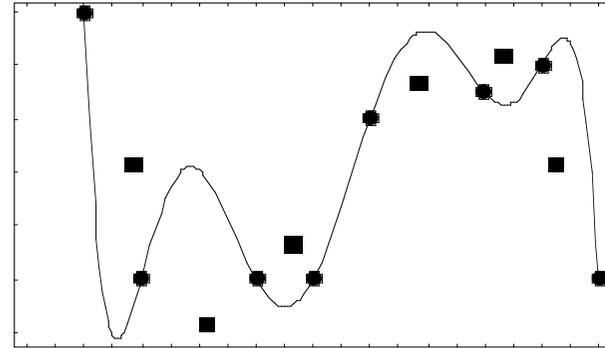
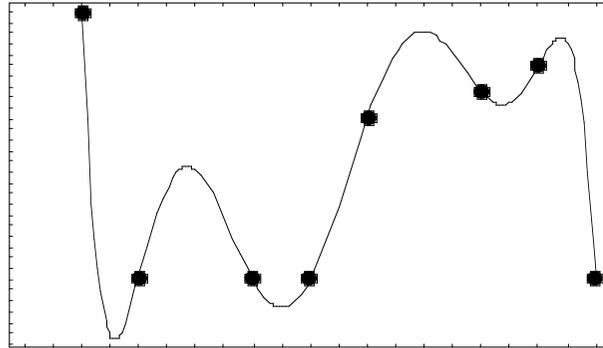
$$\Delta w_{ij} = - \frac{\partial E(w_{ij})}{\partial w_{ij}} = \sum_p (b_i^p - \hat{b}_i^p) a_j^p$$

Regularización →

$$E(w_{ij}) = \sum_{i,p} (b_i^p - \hat{b}_i^p)^2 + \sum_{i,j} w_{ij}^2$$

Sobreajuste (balance incorrecto de parámetros y datos)

*En estadística es bien conocido que cuando se utiliza un modelo con **muchos parámetros** para ajustar un conjunto de datos procedente de proceso con **pocos grados de libertad**, el modelo obtenido puede no descubrir las tendencias reales del proceso original, aunque pueda presentar un error pequeño.*

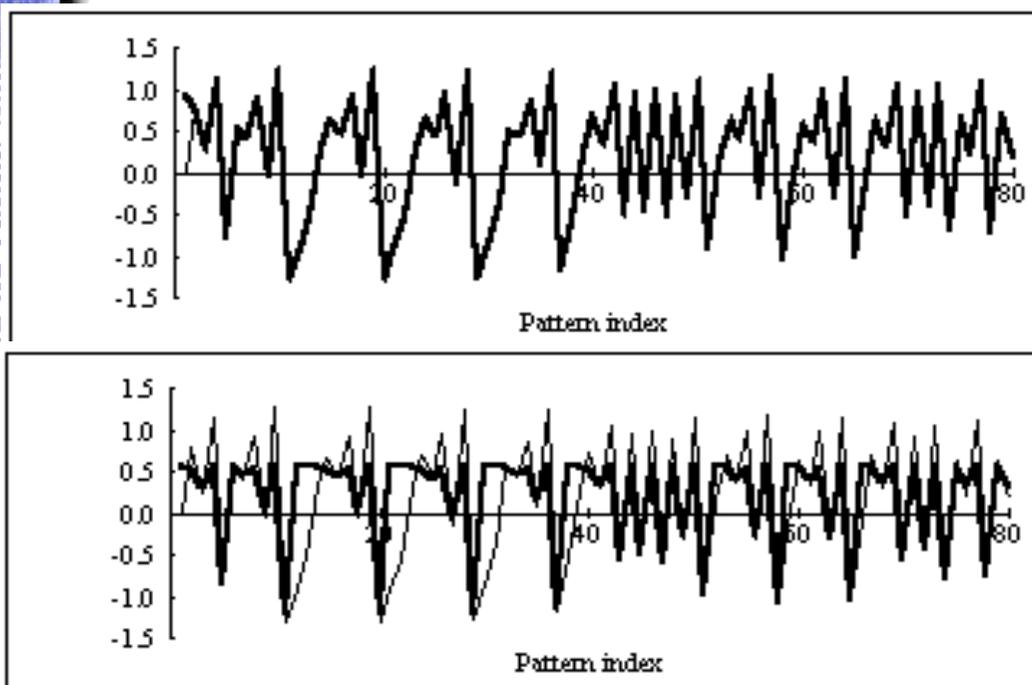
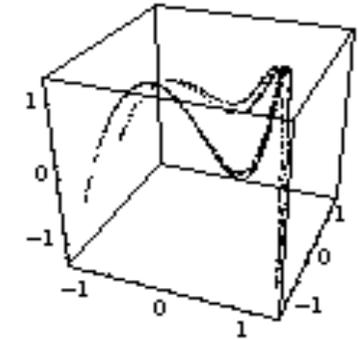
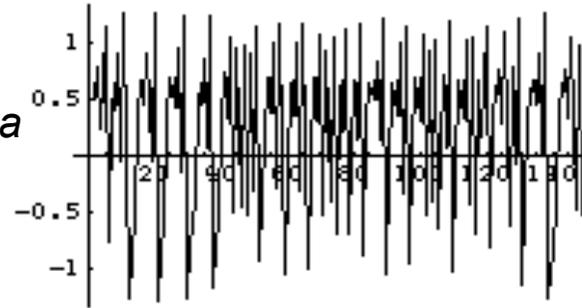


Ejemplo: Predicción No Lineal

En ocasiones es necesario tratar con series temporales caóticas, que tienen apariencia estocástica y difícilmente predecible.

Un ejemplo es la serie de Henon:

$$x_{n+1} = 1 - 1.4 x_n^2 + 0.3 x_{n-1}$$



NNDT D:\NEURAL\1\NNDT\NNDT\HENON.MLP

File Setup Options Show Help

status

message
13 variables not conv.

iter	SSQ	rms	rms test	lambda
97	9.161e-1	1.070e-1	2.943e-2	1e-4

Out

In in2

Start

Single step mode

Train net

Performance

State

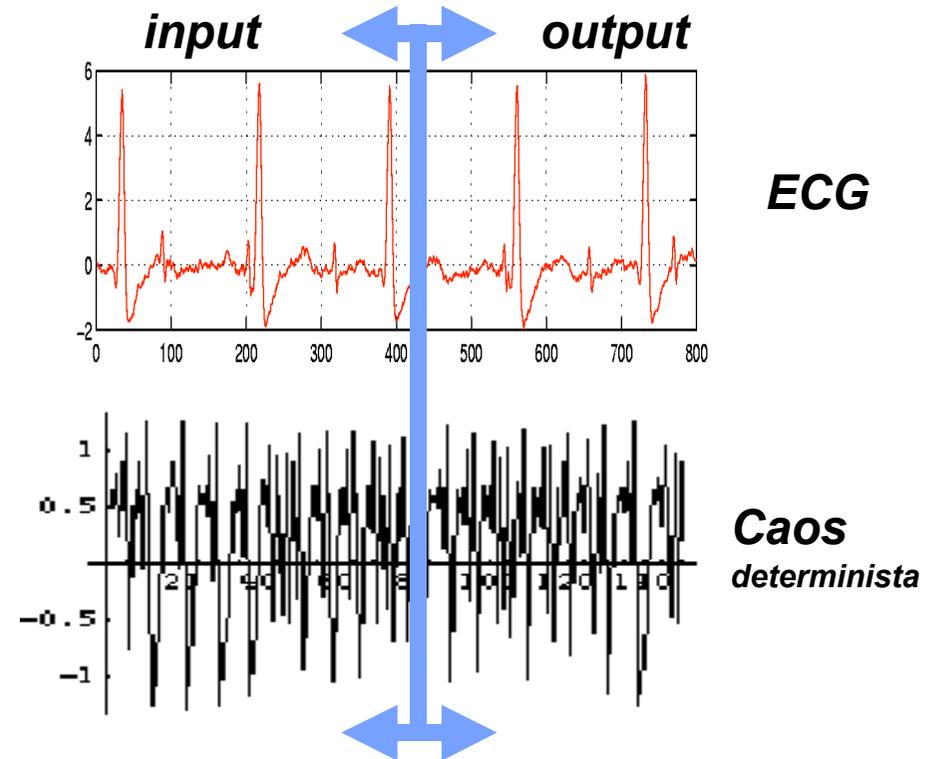
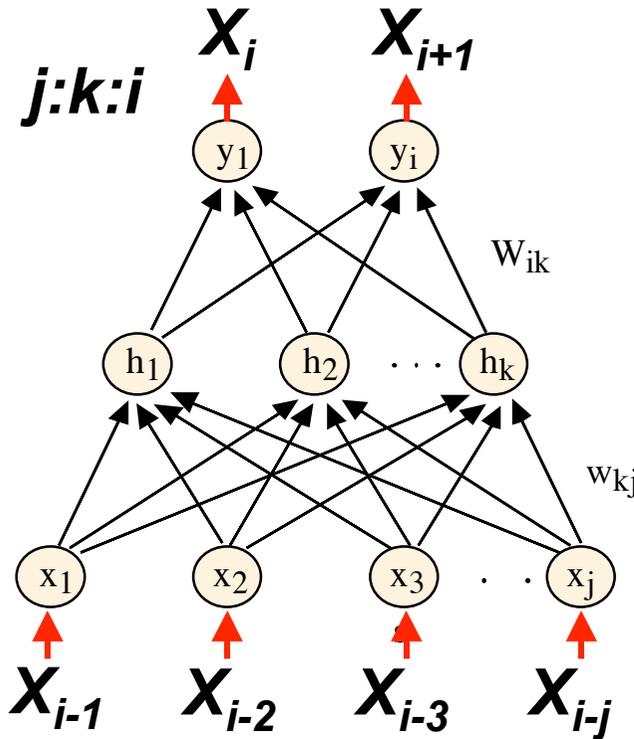
Progress

Log

Show plot of training progress

Modelización de Series Temporales

Las **redes neuronales** permiten obtener una aproximación funcional de un modelo dado en base a un conjunto de datos y a operadores sigmoidales.



Cada procesador realiza una actividad muy simple: combinación lineal de las actividades recibidas por la neurona.

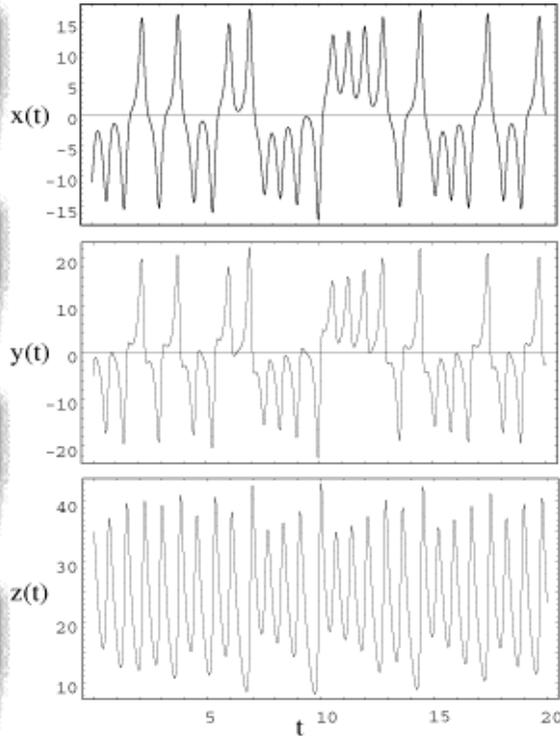
A continuación, se calcula su actividad aplicando una función de activación al valor obtenido (simula el potencial de membrana de una neurona).

Finalmente, dados los valores de entrada, se obtienen las salidas de la red:

$$y_i = f\left(\sum_k W_{ik} f\left(\sum_j w_{kj} x_j\right)\right)$$

Modelos de Lorenz Aproximados

Dada una serie temporal de 2000 puntos ($t=20$), se prueban distintos modelos de red para comprobar el poder modelizador.



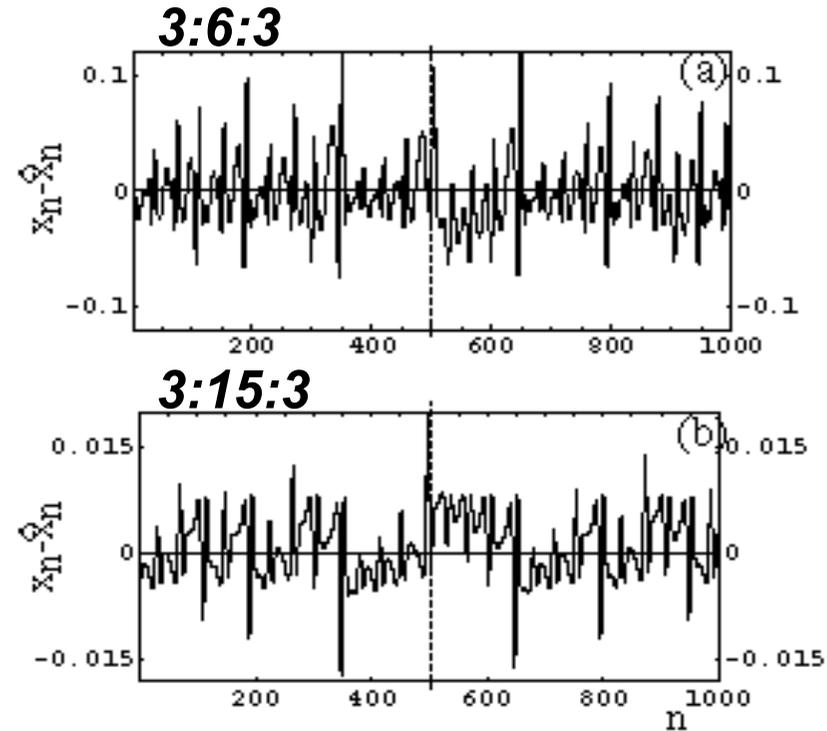
Tres variables
(x, y, z)

(x_n, y_n, z_n)



($x_{n+1}, y_{n+1}, z_{n+1}$)

Sistema continuo
Red neuronal
3:k:3



$$\hat{x}_{n+1} = -3768.18 - \frac{0.34}{1 + e^{9.31+0.53x_n-0.68y_n-0.21z_n}} + \frac{0.92}{1 + e^{7.64-0.121x_n-0.149y_n-0.13z_n}} - \frac{1}{1 + e^{6.19+0.15x_n+0.0451y_n-0.09z_n}} - \frac{1}{1 + e^{1.13+0.06x_n+0.0119y_n-0.06z_n}} + \frac{1}{1 + e^{-0.12+0.00021x_n-0.0002y_n+0.000021z_n}} - \frac{1}{1 + e^{-0.24+0.08x_n-0.016y_n+0.0049z_n}}$$

Comportamiento Dinámico

Un **modelo simple** no captura de forma completa la estructura funcional y, por tanto, no reproduce la dinámica del sistema.

Un **modelo muy complicado** se sobreajusta al modelo y no reproduce la dinámica del sistema.

Sólo un **modelo intermedio**, con el número apropiado de parámetros puede ajustar apropiadamente la estructura funcional del sistema y, por tanto su dinámica.

