

Desarrollo de Técnicas de Aprendizaje y Aplicaciones en el Grupo de Sistema Inteligentes del Dpto. de Informática de la Universidad de Valladolid.*

Carlos J. Alonso González¹, Teodoro Calonge Cano¹, Quiliano I. Moro Sancho¹, Juan José Rodríguez Díez², and M^a Aranzazu Simón Hurtado¹

¹ GSI: Grupo de Sistemas Inteligentes
Departamento de Informática
Universidad de Valladolid
{calonso,teodoro,isaac,arancha}@infor.uva.es
² Lenguajes y Sistemas Informáticos
Universidad de Burgos
jjrodriguez@ubu.es

Resumen Este informe resume las actividades realizadas por el Grupo de Sistemas Inteligentes del Dpto. de Informática de la Universidad de Valladolid en el área del aprendizaje automático y sus aplicaciones durante los últimos cinco años. El grupo ha trabajado en el desarrollo de nuevas técnicas de aprendizaje y en la aplicación del aprendizaje automático a la resolución de problemas. En relación con el desarrollo de técnicas de aprendizaje, destaca su aportación a la clasificación de series temporales y su trabajo en el área de la combinación de clasificadores. Las principales aplicaciones están relacionadas con la diagnosis de sistemas físicos y la biomedicina.

1. Introducción

Este trabajo presenta la actividad del Grupo de Sistemas Inteligentes, grupo de investigación del Dpto. de Informática de la Universidad de Valladolid, que también integra investigadores de la universidad de Burgos, en la línea de aprendizaje automático. El grupo ha desarrollado su actividad en dos direcciones: el desarrollo de técnicas de aprendizaje y la aplicación de técnicas de aprendizaje a la resolución de problemas. Referente al desarrollo de técnicas de aprendizaje, se ha trabajado en el desarrollo de técnicas para la clasificación de series temporales y en el uso de técnicas de combinación de clasificadores. Las principales aportaciones en este área se concretan en el desarrollo de métodos de inducción de reglas de primer orden y clasificadores mediante boosting de literales, basados en intervalos o en distancias, todos ellos para la clasificación de series temporales;

* Este trabajo ha sido financiado por el proyecto de la CICYT TAP 99-0344 y el proyecto de la Junta de Castilla y León VA101/01

en esta misma línea se está trabajando en la propuesta de un método alternativo para la obtención de redes de funciones de base radial (RBF), cuya aplicación no se limita a las series temporales. Desde la perspectiva de la aplicación de técnicas de aprendizaje a la resolución de problemas, se trabaja, principalmente, en la aplicación de técnicas de aprendizaje a la diagnosis de dispositivos físicos dinámicos continuos y en aplicaciones biomédicas. En relación con la diagnosis de dispositivos físicos se están estudiando métodos para la integración de las técnicas de aprendizaje mencionadas en el contexto de la diagnosis basada en modelos, manteniendo las propiedades de solidez de este tipo de técnicas. Referente a las aplicaciones biomédicas, se ha desarrollado un software de diagnosis del Glaucoma mediante un sistema híbrido simbólico-conexionista, que utiliza redes neuronales para integrar información sobre distintos datos clínicos en un sistema de reglas borrosas. Por último, destacar el trabajo para el desarrollo de herramientas de ayuda al tratamiento y diagnosis de la Retinopatía Diabética, que utiliza un sistema modular cuyos nodos son redes neuronales para la clasificación de los distintos casos. Este trabajo ha sido realizado en colaboración con el IOBA (Instituto de Oftalmobiología Aplicada) de la Universidad de Valladolid en colaboración con la Consejería de Sanidad y Bienestar Social de la Junta de Castilla y León; el software desarrollado ha sido cedido a las autoridades regionales sanitarias, con el que se elaboró una tirada de 700 CD's bajo el título de "Programa de Prevención de la Ceguera por Retinopatía Diabética" para su distribución y posterior implantación en los centros de atención primaria competencia del gobierno regional.

El resto del trabajo presenta, con mayor detalle, las técnicas y aplicaciones que se han bosquejado en esta introducción.

2. Técnicas de Aprendizaje desarrolladas en el Grupo

2.1. Clasificación de Series Temporales

La *Programación Lógica Inductiva* (ILP) [8] combina los principios del aprendizaje automático inductivo con la representación de la programación lógica. Las técnicas desarrolladas para la clasificación de series temporales se basan en aplicar ILP sobre predicados adecuados para la descripción de series. De esta manera es posible obtener clasificadores simbólicos (reglas de primer orden) de series. A continuación se presentan los literales utilizados.

Literales sobre Intervalos. Los predicados basados en intervalos consideran todo un rango de puntos. Hay dos variantes: relativos y basados en regiones. Los predicados relativos consideran las diferencias entre los valores del intervalos. Los basados en regiones tienen en cuenta la presencia de los valores de la variable en una región durante un intervalo. Este sección sólo introduce los predicados, en [12] se proporciona una descripción más detallada, incluyendo como seleccionarles de manera eficiente.

Un modo natural de describir series es indicar cuando incrementan, decrecientan o permanecen estables. Los *predicados relativos* contemplan estos conceptos:

- **incrementa**(Ejemplo, Variable, Inicio, Fin, Valor). Es cierto si para el Ejemplo, la diferencia entre los valores de la Variable para Fin e Inicio es mayor o igual que el Valor.
- **decrementa**(Ejemplo, Variable, Inicio, Fin, Valor).
- **permanece**(Ejemplo, Variable, Inicio, Fin, Valor). Es cierto, para el Ejemplo, si el rango de valores de la Variable en el intervalo es menor o igual que Valor.

Normalmente, las series con las que se trabaja tienen ruido, y en consecuencia una definición estricta de **incrementa** y **decrementa** en un intervalo (i.e., la relación se mantiene para todos los puntos del intervalo) no es útil. Por supuesto, es posible filtrar la serie antes del proceso de aprendizaje, pero consideramos que un sistema de clasificación de series no debería apoyarse en la suposición de que los datos no tienen ruido. Por tanto, para estos dos predicados sólo se consideran los extremos del intervalo. El parámetro **Valor** es necesario para indicar la magnitud del cambio.

Para el predicado **permanece** tampoco es útil considerar una definición estricta. En este caso se consideran todos los puntos del intervalo. El parámetro **Valor** se utiliza para indicar la diferencia máxima permitida entre los valores del intervalo.

Los predicados anteriores sólo consideraban la relación entre los distintos valores de una serie. No obstante, hay aplicaciones en las que sí que importan los valores absolutos, y no sólo las tendencias. Para este tipo de situaciones se utilizan los *predicados basados en regiones*:

- **siempre**(Ejemplo, Variable, Región, Inicio, Fin). Es cierto, para el Ejemplo, si la Variable está siempre en la región Región en el intervalo entre Inicio y Fin.
- **alguna_vez**(Ejemplo, Variable, Región, Inicio, Fin).
- **porcentaje_cierto**(Ejemplo, Variable, Región, Inicio, Fin, Porcentaje). Es cierto, para el Ejemplo, si el porcentaje del tiempo entre Inicio y Fin en el que la variable está en la Región es mayor o igual que Porcentaje.

Una vez que se ha decidido trabajar con intervalos temporales, el uso y la definición de los predicados **siempre** y **alguna_vez** es natural, debido a que son la extensión de la conjunción y la disyunción a intervalos. Dado que ambos representan situaciones muy extremas, y parecen muy sensibles al ruido, se introduce un tercer predicado **porcentaje_cierto**. Es un “siempre relajado” (o un “alguna vez restringido”). El parámetro adicional indica el grado de flexibilidad.

Las regiones que aparecen en los predicados previos son intervalos en el dominio de los valores de la variable. En algunos casos las definiciones de estas regiones pueden obtenerse de un experto, como conocimiento básico. En otro caso, se pueden obtener mediante un preproceso de discretización.

Literales sobre Distancias. Otra forma intuitiva de describir series es indicando si se parece o no (mucho o poco) a otras series. El formato de los predicados basados en distancias es el siguiente:

$\text{distancia}_{\leq}(\text{Ejemplo}, \text{Referencia}, \text{Variable}, \text{Umbral})$

El predicado es cierto si la distancia entre **Ejemplo** considerado y un ejemplo de **Referencia**, restringida a la **Variable**, es menor o igual que el **Umbral**.

Las distancias consideradas son la euclídea y la proporcionada por el *Alineamiento Dinámico Temporal* (DTW).

Boosting de Literales. La agrupación de varios clasificadores, obtenidos utilizando un mismo método, es una manera natural de incrementar la precisión, con respecto a la obtenida con la utilización aislada de dichos clasificadores. Uno de los métodos más populares para crear estas agrupaciones de clasificadores es el *boosting* [14]. Este término engloba toda una familia de métodos, de la que ADABOOST es la variante más conocida.

Estos métodos trabajan asignando un peso a cada ejemplo. Inicialmente, todos los ejemplos tienen el mismo peso. En cada iteración, se construye un clasificador, denominado *base* o *débil*, utilizando algún método de aprendizaje, y teniendo en cuenta la distribución de pesos. A continuación, el peso de cada ejemplo se reajusta, en función de si el clasificador base le asigna la clase correcta o no. El resultado final se obtiene mediante voto ponderado de los clasificadores base.

El método de boosting aplicado sobre literales, tanto sobre intervalos como sobre distancias, permite obtener clasificadores de series muy competitivos con otras técnicas de clasificación [12,13].

2.2. Aprendizaje de Redes RBF mediante Boosting

Tomando como partida el sistema de clasificación de series basado en boosting de literales sobre distancias, se propone un método alternativo para la construcción de redes RBF [13]. Dado un literal, sobre un ejemplo podemos tener dos resultados, cierto o falso, que para el algoritmo de boosting se consideran +1 y -1. No obstante, el método de boosting puede trabajar con clasificadores base que devuelven valores reales, denominados grados de confianza. En este caso, la cantidad de información intercambiada entre el algoritmo de aprendizaje base y el algoritmo de boosting es mayor, puesto que la salida del clasificador base no está limitada a positivo o negativo, sino que es un número real que indica el grado de confianza.

El método seguido para obtener grados de confianza continuos a partir de literales consiste en transformar estos en funciones de base radial, RBF. Dado un literal $\text{distancia}_{\leq}(\text{Ejemplo}, \text{Referencia}, \text{Umbral})$, la función de base radial seleccionada es

$$h(x) = 2 \exp \left(- \left(\frac{d(x, c)}{u} \right)^2 \ln 2 \right) - 1$$

donde x es el Ejemplo, c el ejemplo de Referencia, u el Umbral y $d()$ la funcion de distancia.

Esta función tiene las siguientes propiedades:

- $h(c) = 1$
- $h(x) = 0$ if $d(x, c) = t$
- $-1 \leq h(x) \leq 1$, supuesto que $d(x, c) \geq 0$
- Esta función desciende monótonamente con respecto a $d(x, c)$

Estas funciones son funciones de base radial [9], y su combinación lineal es un red de funciones de base radial.

3. Aplicaciones

3.1. Diagnósis de Dispositivos Físicos

En [1] se propone un marco para integrar conocimiento extraído mediante un sistema de aprendizaje en el ciclo de diagnosis basada en consistencia con modos de fallos. Dicho sistema utiliza el concepto de posible conflicto [10] para realizar la detección y localización del fallo en el contexto de la diagnosis basada en consistencia [3]. La identificación del fallo se aborda suponiendo que se conoce como se comportan los dispositivos cuando fallan, esto es, con la aproximación de modos de fallo [2]. Uno de los inconvenientes de esta aproximación es que el número de simulaciones necesarias para determinar los modos de funcionamiento consistentes con las observaciones crece exponencialmente con el número de modos de funcionamiento. Para reducir al mínimo el número de simulaciones necesarias, sin perder la solidez del sistema de diagnóstico, se recurre al concepto de diagnosis preferida [2], modificando dinámicamente las preferencias de las diagnosis en función de la información aportada por un sistema de aprendizaje. El sistema de diagnóstico se limitaría a simular primero los modos con mayor preferencia, hasta encontrar alguno consistente con las observaciones, con un cierto grado de tolerancia.

La utilidad de un sistema de aprendizaje en este contexto se ve incrementada si el sistema es capaz de proporcionar una clasificación de los fallos tan pronto como sea posible. A esta capacidad se le denomina *clasificación temprana*. Para que el sistema de aprendizaje pueda clasificar con gran precisión es necesario que los patrones temporales con los que se le entrena tengan una longitud suficiente como para que estén presentes las dinámicas de todos los fallos. No obstante, cuando se quiere determinar que fallo es el que está presente, el patrón a clasificar se está generando, y si se espera a tener un patrón completo, la determinación del fallo puede llegar demasiado tarde. Por tanto, es necesario que el sistema de clasificación pueda funcionar con patrones incompletos.

Por otro lado, es también necesario que el sistema de clasificación proporcione una ordenación de las posibles clases, en vez de sugerir una única clase. La tarea del sistema de aprendizaje no se limita a seleccionar uno de los fallos, sino a establecer una preferencia entre los distintos modos, de manera que se simulen los modos de fallos según el orden establecido por el sistema de aprendizaje.

En [11] se presenta la integración del sistema de clasificación de series descrito en la sección 2.1 con la diagnosis basada en consistencia. Dicha integración se basa en considerar que el resultado del método de aprendizaje es una combinación lineal de literales. Al intentar clasificar un ejemplo incompleto, algunos literales no podrán ser evaluados. Si de la combinación lineal se excluyen dichos literales, el resultado sigue siendo un clasificador, aunque seguramente menos preciso. Según se va generando el ejemplo correspondiente a la situación actual, la clasificación será más precisa.

3.2. Sistema Híbrido de Ayuda al Diagnóstico del Glaucoma

Primeramente se plantea el problema del diagnóstico del glaucoma para poder valorar la importancia que tiene el desarrollo de herramientas que ayuden a la detección precoz de esa enfermedad. El glaucoma puede definirse como una enfermedad ocular crónica, que se caracteriza por presentar una degeneración progresiva del nervio óptico que en un 60 — 70 % de los casos cursa con elevación de la presión ocular. La pérdida de células ganglionares de la retina provoca alteraciones típicas en la función visual y en la papila del nervio óptico.

Su importancia radica en dos hechos: Por un lado su frecuencia, ya que aparece en aproximadamente un 2 % de la población de más de 40 años y su prevalencia aumenta con la edad; y por otro lado el glaucoma crónico, el más frecuente, es en general una enfermedad asintomática hasta estadios terminales y, no tratada adecuadamente, puede llevar a la ceguera. De hecho el glaucoma es la segunda causa de ceguera en los países desarrollados.

Su diagnóstico en estadios avanzados no resulta difícil para el oftalmólogo general, ya que normalmente va a encontrarse con una presión ocular elevada, una excavación papilar claramente glaucomatosa, y unas lesiones campimétricas típicas, que confirmarán el diagnóstico. Sin embargo, es en las fases iniciales del glaucoma, cuando suelen presentarse las dificultades diagnósticas, debido a que ninguna de las exploraciones que se realizan gozan de la sensibilidad y especificidad suficiente como para confirmar por sí mismas y de forma indudable el diagnóstico [4].

La integración de todos los datos recogidos en una consulta por un oftalmólogo experto, que aplique su experiencia adquirida, es el mejor método para el diagnóstico de la enfermedad.

Se ha desarrollado un sistema de ayuda al diagnóstico precoz del Glaucoma Crónico Simple, que recoge y maneja gran parte de la experiencia del experto. Este sistema será una ayuda importante en centros hospitalarios que no dispongan de especialistas, para el oftalmólogo general al que se le brinda la experiencia adquirida por una Sección de Glaucoma de un hospital Universitario, y para el aprendizaje de aquellos oftalmólogos que estén especializándose en el tema.

La herramienta implementada no sólo recoge experiencia y conocimiento que proviene directamente del experto, sino que incluye el conocimiento extraído a partir de los datos. Por este motivo, se han usado técnicas conexionistas además de simbólicas.

Las técnicas de aprendizaje y diagnóstico de IA que se han aplicado son: sistemas basados en conocimiento, sistemas basados en lógica borrosa y clasificación mediante redes neuronales artificiales.

El sistema transforma los parámetros que usa el oftalmólogo para realizar su diagnóstico en conjuntos borrosos, y recoge la información de uno de ellos, el campo visual, a partir de un sistema de clasificación basado en redes neuronales artificiales, en particular mapas autoorganizados de Kohonen [15].

Los datos de pacientes utilizados han sido recogidos a partir del estudio de 1491 historias clínicas del Hospital Clínico Universitario de Valladolid teniendo en cuenta unos criterios establecidos por el oftalmólogo experto.

En cuanto a los resultados obtenidos podemos distinguir por un lado la capacidad de los mapas autoorganizados para clasificar campos visuales y por otro la concordancia del diagnóstico del sistema híbrido desarrollado con el del experto. Hemos logrado clasificar campos visuales en dos categorías, glaucoma y no glaucoma, con sensibilidad y especificidad de 95 y 92,86 % respectivamente [16], y una precisión diagnóstica de 93,75 %. El sistema híbrido de ayuda al diagnóstico ofrece una concordancia del 90 % con el experto, detectando antes los casos patológicos. Además, hemos comprobado que con esta mezcla de clasificadores de distinta naturaleza se logramos mejorar la precisión de los resultados de cada uno por separado.

3.3. Ayuda al Tratamiento y Diagnóstico de la Retinopatía Diabética

Esta línea de investigación persigue la aplicación de técnicas de Inteligencia Artificial al tratamiento y diagnóstico de la Retinopatía Diabética, enfermedad ocular derivada de la diabetes, que es la mayor causa de ceguera en los países industrializados. En los actuales sistemas sanitarios españoles, los diabéticos son controlados por los médicos de atención primaria (MAP), que son los responsables de enviarlos a los diferentes especialistas (nefrólogos, oftalmólogos, endocrinólogos, etc.) y recabar todos los datos provenientes de estas visitas.

En este punto surge la principal disfunción del servicio asistencial, porque los MAP tienen una formación generalista, que carecen de criterio, por ejemplo, a la hora de determinar el periodo de revisión oftalmológica. En casos puntuales como este último, la Inteligencia Artificial puede aportar soluciones para paliar estos inconvenientes creando sistemas eficientes para la transferencia de conocimiento entre un especialista en diabetes ocular y un MAP. Bajo esta idea surge una aplicación informática para determinar la frecuencia personalizada de la visitas al oftalmólogo para cada diabético. El programa está destinado a los MAP, aunque bien podría ser de utilidad a endocrinólogos y educadores en diabetes.

Para su construcción se ensayaron diferentes sistemas modulares, en cada uno de sus nodos se colocaron clasificadores conexionistas basadas en redes neuronales. El motivo de optar por este tipo de técnicas se debió a la existencia de una gran base de conocimiento materializada en numerosos casos (3543) perfectamente estudiados y catalogados provenientes de una campaña de prevención de ceguera para diabéticos realizada en el área rural de la provincia de Valladolid.

Este trabajo de campo fue llevado a cabo por la Unidad de Diabetes del Instituto de Oftalmobiología Aplicada (IOBA) de la Universidad de Valladolid en colaboración con la Consejería de Sanidad y Bienestar Social de la Junta de Castilla y León. Su eficiencia se resume en una tasa de aciertos media superior al 99 %. Ha sido cedido a las autoridades regionales sanitarias, con el que se elaboró una tirada de 700 CD's bajo el título de "Programa de Prevención de la Ceguera por Retinopatía Diabética" para su distribución y posterior implantación en los centros de atención primaria competencia del gobierno regional.

La utilidad práctica de este programa está incompleta, porque una parte de sus entradas proviene del análisis del fondo de ojo. La valoración de esta prueba no puede realizarla un MAP y se debe recurrir a un oftalmólogo. Por este motivo, este proyecto se enmarca dentro de otro más ambicioso de teleoftalmología, en donde estaría definida una red de centros de referencia, en los que el MAP obtendría, a vuelta de correo electrónico, los resultados de este examen. La obtención de las imágenes correspondientes en los centros de atención primaria, hoy por hoy, es factible mediante retinógrafos digitales no midriáticos y perfectamente manejables por los MAP o ATS tras un pequeño curso de formación. En esta fase, se encuentra actualmente el proyecto. Pero los objetivos son mucho más ambiciosos, puesto que se están iniciando trabajos encaminados al análisis automático de estas imágenes de fondo de ojo. Con ello, se evitaría, en parte; la dependencia con los mencionados centros de referencia; de conseguirse esta meta, se habría cubierto la parte de diagnosis.

3.4. Predicción Meteorológica mediante Mezcla de Expertos y Sistemas Modulares

Los sistemas conexionistas (también conocidos como Redes Neuronales Artificiales) aparecen a mediados del siglo XX como una posible solución para procesar información de la misma manera en que lo hace el cerebro en los animales. A pesar de que este nuevo paradigma de computación inició su existencia con un gran entusiasmo, en la década de los 70 cayeron en desuso para volver a renacer a mediados de los 80, con nuevos algoritmos de aprendizaje más potentes. Esto hizo que su aplicación se extendiera en el mundo real. Muchos de las tareas en las que las RNA's han demostrado su aplicación de forma exitosa están íntimamente relacionadas con la clasificación de patrones. Pero, al igual que ocurre con cualquier otro tipo de clasificador, se puede mejorar el rendimiento del sistema de clasificación mediante la combinación de varios de estos clasificadores base. La combinación de clasificadores base se puede realizar de muy diferentes maneras (en cascada, en forma de árbol, o cualquier otra), pero resulta muy interesante poder establecer una estructura que refleje de alguna manera el conocimiento que se tiene del sistema, aprovechándolo así en beneficio de la eficiencia de la clasificación. Las técnicas de combinación también pueden basarse en un proceso puramente estadístico de refinamiento de los resultados como el Boosting, o con una estrategia basada en algoritmos genéticos. En estos casos en los que no se parte de ningún conocimiento del funcionamiento del

sistema, es posible que después de haber llegado a un modelo de sistema de clasificación con múltiples clasificadores base formando una estructura específica, dicha estructura que se ha alcanzado de manera autoorganizada o no supervisada (dependiendo del caso) pueda proporcionar un conocimiento explícito acerca del sistema bajo estudio.

Pronóstico y Clasificación de Series Temporales. Existen básicamente cuatro formas de tratar una serie temporal: la predicción, la clasificación, la descripción y la transformación. Los problemas de predicción se pueden transformar en uno de clasificación, si para ello se han definido distintas clases en el parámetro a pronosticar. En el campo de la predicción, se han presentado varios trabajos. Así en [6] se mostraban cuatro técnicas para usar las RNA en predicción meteorológica, combinando paradigmas de aprendizaje supervisado y no supervisado, y también redes con y sin realimentación. En los casos en los que se optó por redes sin realimentación, se probó la organización de varios módulos clasificadores básicos en tres tipos de estructura jerárquica:

- Una jerarquía de MLP's con dos niveles: Los nodos más profundos son expertos entrenados en una porción de la serie temporal. El nodo superior combina de forma no lineal los resultados de los nodos inferiores.
- Un sistema autoorganizado que realiza una separación no supervisada de los datos de la serie, y a cada clase así construida se le asigna un experto con entrenamiento supervisado.
- Una etapa de codificación no supervisada mediante mapas autoorganizados, transforma la serie temporal en una secuencia de etiquetas, que sirven como entrada a una red recurrente, que pretende ser utilizada como un autómata finito.

Los resultados demostraron que si bien los sistemas que combinaban varios módulos clasificadores contruidos con RNA no recurrentes ofrecían buenos resultados, los mejores se alcanzaban con una red parcialmente recurrente tipo Jordan. Y siguiendo con el mismo planteamiento, en [7] se muestran los resultados relativos a la utilización de una red neuronal parcialmente recurrente en la predicción meteorológica para varios horizontes temporales.

En cuanto a la combinación de expertos, de la cual ya se ha hablado en el punto anterior, en [5] se presenta un estudio comparativo del comportamiento de los paradigmas de RNA's más extendidos (MLP y SOM) trabajando tanto de forma aislada como en combinación (formando ensembles) sobre un conjunto de problemas estándar de series temporales sintéticas. Este trabajo se encuentra aún en una fase inicial y aunque los primeros resultados son satisfactorios, es preciso seguir investigando para obtener resultados más concluyentes.

4. Para más información...

La lógica limitación de este informe impide profundizar en ninguna de las técnicas presentadas. Para más información, visitar la página del grupo, www.gsi.infor.uva.es, o ponerse en contacto con alguno de los autores.

Referencias

1. Carlos J. Alonso, J. Belarmino Pulido, Juan J. Rodríguez, and César Llamas. Diagnosis of dynamic systems: a framework to integrate fault modes and learned domain knowledge. In J.A. Ortega, R.M. Gasca, and M. Toro, editors, *Current trends in Qualitative Reasoning and Applications. 2000 Edition*, pages 33–47. Edición Digital @tres, Sevilla, Spain, 2000.
2. J. de Kleer, A. K. Mackworth, and R. Reiter. Characterising diagnosis and systems. In *Readings in Model Based Diagnosis*, pages 54–65. Morgan-Kaufman, 1992. originally appeared in *Artificial Intelligence*, 56.
3. O. Dressler and P. Struss. The consistency-based approach to automated diagnosis of devices. In Gerhard Brewka, editor, *Principles of Knowledge Representation*. CSLI Publications, 1996.
4. J. A. Maquet, J. C. Pastor, and L. F. de la Fuente. El glaucoma crónico simple. guía para su comprensión. Technical report, IOBA, Universidad de Valladolid, 1993.
5. Q. Isaac Moro, Carlos Alonso, and Juan José Rodríguez. Applying simple combining techniques with artificial neural networks to some standard time series classification problems. In *4th International Symposium on Soft Computing and Intelligent Systems for Industry – SOCO/ISFI 2001*, page 128, Paisley, Scotland, 2001.
6. Q. Isaac Moro Sancho, Luis Alonso Romero, and Carlos E. Vivaracho Pascual. Four experiments for short-term weather forecasting using ann. In *EANN2000 Conference*, 2000.
7. Q. Isaac Moro Sancho, Luis Alonso Romero, and Carlos E. Vivaracho Pascual. A multi step weather forecast using partial recurrent artificial neural networks and local data. In *4th International Symposium on Soft Computing and Intelligent Systems for Industry – SOCO/ISFI 2001*, page 128, Paisley, Scotland, 2001.
8. Stephen Muggleton. Scientific knowledge discovery using inductive logic programming. *Communications of the ACM*, 42(11):42–46, 1999.
9. Mark J. Orr. Introduction to radial basis function networks. Technical report, 1996. <http://www.anc.ed.ac.uk/~mjo/papers/intro.ps.gz>.
10. B. Pulido Junquera and C. J. Alonso González. An alternative approach to dependency-recording engines in consistency-based diagnosis. In S. A. Cerri and D. Dochev, editors, *Artificial Intelligence: Methodology, Systems and Applications, 9th International Conference, AIMSA 2000*, pages 111–121. Springer, 2000.
11. Juan J. Rodríguez and Carlos J. Alonso. Integración de un sistema de aprendizaje en la diagnosis basada en consistencia con modos de fallo. In Juan Antonio Ortega, Xavier Parra, and Belarmino Pulido, editors, *IV Jornadas ARCA – Sistemas Cualitativos y Diagnosis*, pages 101–110, 2002.
12. Juan J. Rodríguez, Carlos J. Alonso, and Henrik Boström. Boosting interval based literals. *Intelligent Data Analysis*, 5(3):245–262, 2001.
13. Juan J. Rodríguez Diez and Carlos J. Alonso González. Learning classification RBF networks by boosting. In *Multiple Classifier Systems: second international workshop, MCS 2001*, Lecture Notes in Computer Science. Springer, 2001. To appear.
14. Robert E. Schapire. A brief introduction to boosting. In Thomas Dean, editor, *16th International Joint Conference on Artificial Intelligence (IJCAI-99)*, pages 1401–1406. Morgan Kaufmann, 1999.

15. A. Simón, L. Alonso, and A. Antón. Sistema híbrido borroso para ayuda al diagnóstico del glaucoma. In *Primeras Jornadas de Trabajo sobre Diagnosis*, pages 193–201, 2001.
16. A. Simón, L. Alonso, D. Bahillo, E. de la Fuente, and A. Antón. Clasificación de campos visuales mediante redes neuronales. In *Actas del I TALLER AIRENE sobre Reconocimiento de Patrones con Redes Neuronales*, pages 90–94, 1999.