Un sistema basado en el conocimiento para la diagnosis en plantas de tratamiento de aguas residuales

Lluís Belanche*
Miquel Sànchez†
Ulises Cortés
Universitat Politècnica de Catalunya
Departament de Llenguatges i Sistemes Informàtics (IA)
Pau Gargallo, 5. Barcelona. 08028. Catalunya, ESPAÑA
belanche@lsi.upc.es
sanchez@lsi.upc.es

Resumen

En este trabajo se describe el desarrollo de un sistema experto con razonamiento aproximado aplicado a la diagnosis en plantas de tratamiento de aguas residuales, que utiliza una nueva metodología para la selección y estructuración de atributos en los **sistemas basados en el conocimiento**. Antes que nada, se aborda el proceso de depuración y sus problemas, así como los de los métodos automáticos de control convencionales aplicados a procesos industriales. Después, se establece una definición del concepto de relevancia para un conjunto dado de atributos, que incluye el caso especial de los atributos no relevantes o atributos *nought*. Una nueva heurística es propuesta, de tal manera que encuentra los atributos más relevantes de aquellos inicialmente seleccionados por el experto, reduciendo así el coste de formación y validación de reglas de decisión, y ayudando a clarificar la estructura remanente de un dominio pobremente estructurado como son las plantas de tratamiento de aguas residuales.

Palabras clave: Adquisición de conocimientos, inducción de árboles de decisión, sistemas basados en el conocimiento, depuración biológica, diagnosis.

1 Introducción

Un mal funcionamiento en una planta de tratamiento de aguas residuales es un problema social y biológico muy grave. El agua residual incorrectamente tratada a la salida de la planta, es decir, con niveles de contaminación superiores a los límites permisibles, puede comportar peligrosas consecuencias para los seres humanos, sin olvidar a la naturaleza misma.

*Parcialmente financiado por GRANT TIC-90 801/C02. CICyT. ESPAÑA
†Parcialmente financiado por GRANT ROB-89 0479-C03-02. CICyT. ESPAÑA

En este trabajo se muestra la aplicación de Sistemas Basados en el Conocimiento a la diagnosis y control de plantas de tratamiento de aguas residuales. El empleo de una técnica de IA como son los Sistemas Expertos, en una primera aproximación, da un nuevo enfoque al control y diagnosis de procesos industriales en general.

Los sistemas automáticos convencionales de control de procesos (*feed-back control*, *feed-forward control*, control óptimo, control adaptativo, ...) han de enfrentarse con varias dificultades:

- La complejidad del problema. Hay muchos factores que influencian en el sistema: aspectos químicos, mecánicos, físicos, microbiológicos, ...
- Dominio poco estructurado. Las relaciones entre los diferentes conceptos o características del dominio son escasas y no muy claras.
- Gran parte de la información no es ni numérica ni cuantificable. Y por tanto no es expresable en el contexto de un modelo clásico (información sobre las poblaciones microbiológicas presentes en el agua, ...).
- Incertidumbre o conocimiento aproximado. Información subjetiva proveniente de la experiencia acumulada en la gestión de plantas depuradoras por el experto o encargado.
- Sistema dinámico. Cambios continuos que afectan al rendimiento del proceso.

Podríamos decir que los métodos clásicos trabajan correcta y eficazmente en el estado *normal* de operación de la planta, pero no en otros estados *anormales* de trabajo. Nos podemos preguntar ¿ que haría un control automático ante un choque tóxico (brusco aumento de la concentración de materia orgánica en el agua de entrada a la planta ? ¿ sería capaz de detectar las averias en ciertos equipos ? ¿ como utilizarían la información disponible, aunque incompleta, para resolver un problema concreto ?

Teniendo en cuenta las principales ventajas de los sistemas expertos y las dificultades arriba expuestas, se deduce que encajan ciertamente bastante bien. Por tanto, se ha desarrollado un sistema experto para la diagnosis en plantas depuradoras incorporando el tratamiento del razonamiento incierto **[SANC91]**, **[SANC90]**.

Es realmente curioso observar que mientras los sistemas expertos han tenido mucho éxito en distintos campos de aplicación: diagnosis médica, prospecciones mineras, concesiones de préstamos bancarios, ... no se han aplicado frecuentemente al control y diagnosis de procesos industriales, aunque en los últimos años el esfuerzo de investigación en IA en el campo de control de procesos industriales se ha incrementado notablemente (**[MAED89]**, **[FLOR89]**, **[SANZ89]**).

2 Objetivos

El objetivo principal, ya conseguido, ha sido precisamente diseñar y desarrollar este sistema experto con razonamiento incierto aplicado a la diagnosis en plantas de tratamiento de aguas residuales de cara a facilitar la supervisión y control de la planta, incrementar la calidad del agua a la salida de la misma y reducir el coste económico de la operación. Las plantas tomadas como modelo estan basadas en la principal técnica empleada normalmente: *el proceso de fangos activados* **[ROBU90]**.

En el futuro, se extenderá el sistema para construir un Sistema Supervisor Basado en el Conocimiento (figura. 1) aplicado a la diagnosis y control, y que integrará

Fig. 1: Sistema Supervisor Basado en el Conocimiento

conocimiento heurístico y algoritmos de procesamiento numéricos (tales como estimaciones estadísticas, ...).

3 Diseño y desarrollo

Se ha construido un sistema experto denominado DEPUR, sobre el entorno MILORD, de cara a soportar el razonamiento aproximado. El principal *problema* en plantas de tratamiento de aguas residuales es la rotura del equilibrio entre biomasa y substrato (Fig. 2), entendiendo por *biomasa* la agregación de microorganismos que en presencia de oxígeno degradan la materia orgánica disuelta no sedimentable (i.e., el *substrato*) presente en el agua.

Fig. 2: Equilibrio biológico

Este problema (concentración de microorganismos inadecuada para degradar la concentración de materia orgánica disuelta no sedimentable) puede originarse en uno de los tres tratamientos que experimenta el agua hasta que sale de la planta: primario, secundario y terciario. Cada uno se ocupa de la eliminación de un contaminante en concreto. En el tratamiento *primario* se elimina la materia no disuelta (plásticos, maderas, sólidos de gran tamaño, ...), la materia inorgánica (tierra, arenas, ...), aceites y grasas y finalmente materia orgánica disuelta sedimentable. En el tratamiento *secundario* (verdadero núcleo del proceso de la depuración) o proceso biológico se produce la eliminación de la materia orgánica disuelta no sedimentable mediante la acción de los microorganismos aerobios. Finalmente, el proceso *terciario* intenta eliminar otros contaminantes que han escapado a los dos procesos anteriores (nitrógeno, fósforo, ...). Más información referente al proceso de depuración se puede encontrar en bibliografia clásica sobre el tema: [**BENE80**], [**METC79**].

El proceso de diagnosis intenta determinar las causas de los problemas detectados, siendo los más graves los que afectan al proceso biológico.

Un sistema experto se compone de la Base de Datos, la Base de Conocimientos, el módulo de Meta-Conocimiento y otros módulos *generales* independientes del dominio de aplicación. Así, para desarrollar el sistema solamente se requiere construir la Base de Datos, la Base de Conocimientos y el módulo de Meta-Conocimiento (estrategias de control) ya que dichos módulos generales (motores de inferencia, interfície de usuario, ...) vienen proporcionados por el entorno MILORD. El proceso de diseño de un sistema inteligente puede expresarse comúnmente según la figura 3.

Una planta de tratamiento de aguas residuales se compone usualmente de dos subsistemas independientes pero que interactuan entre sí: línea del fango y línea del agua. Nos hemos centrado en el dominio del subsistema de la línea del agua.

La fase de *modelización* del dominio, que suele ser la más difícil, incluye el proceso de *selección* de atributos relevantes y el de *estructuración* de los atributos, que dan lugar, en nuestro caso, a la base de datos y a la base de conocimientos.

El proceso de selección de atributos ha sido desarrollado de dos formas: la primera consiste en la típica selección de atributos relevantes realizada por el experto. La segunda se caracteriza por el empleo de una nueva aproximación a la tarea de selección de atributos basada en los conceptos de relevancia y utilidad potencial [**BELA91**] que se tratará extensamente en la sección 4. El proceso de estructuración del dominio o ingeniería del conocimiento se ha diseñado en base a dos metodologías distintas:

⋆ *Árboles de decisión*: la técnica clásica derivada de las interacciones entre el experto y el ingeniero que dan lugar a la construcción de árboles de decisión. Esta técnica está gobernada por el criterio de causa-efecto. Se han utilizado árboles de decisión *multivaluados* de los cuales se derivan un conjunto reglas de inferencia, para averiguar las causas de un cierto problema o situación que se produce en la planta depuradora.

⋆ *Técnicas de clasificación automática*: ésta es una aproximación más reciente derivada del aprendizaje automático en IA. Se ha empleado el sistema LINNEO en esta fase, basado en clasificaciones difusas de dominios poco estructurados. De la caracterización de las clases obtenidas se obtienen así reglas de inferencia más generales que las anteriores, que guian el proceso deductivo de diagnóstico, apuntando al problema o situación más probable del estado de funcionamiento de la planta.

Cada metodología se ha empleado en una etapa distinta del desarrollo del sistema

Fig. 3: Proceso de diseño de un sistema inteligente.

Fig. 4: Proceso de diagnóstico en un sistema experto.

(DEPUR), coincidiendo con las etapas de diagnóstico de un sistema experto: los árboles de decisión se han usado en la fase de identificación de causas, y las técnicas de clasificación automática en el proceso de identificación del problema, como se muestra en la figura 4.

Pasemos ahora a ver con más detalle, las metodologías o aproximaciones recientes empleadas en el diseño del sistema: la selección de atributos basada en heurísticas para la determinación de la relevancia (utilidad potencial) y la estructuración de los atributos mediante la obtención de de reglas de inferencia a partir de clasificaciones automáticas difusas.

4 Selección de atributos

4.1 Introducción

La naturaleza de la clasificación se ha estudiado ampliamente en *machine learning* (**ML**). En especial aquellos procesos que pueden ser realizados automáticamente por una máquina. Muchos sistemas expertos con éxito de la primera generación eran en la práctica clasificadores. Este tipo de sistemas usa un conjunto de reglas, representadas como árboles de decisión, para determinar la clase de una entrada dada en base a un conjunto de sus características. En el acercamiento clásico, el experto humano es el responsable de decidir cuáles son los *atributos relevantes* para la clasificación y posterior formación de reglas. Las limitaciones de este acercamiento, apuntadas por varios autores, (*e.g.*: [**HAYE84**], [**BAIM88**], etc.), han estimulado el desarrollo de sistemas que puedan tomar la responsabilidad de decidir si un atributo es potencialmente útil o no, usando métodos de inferencia inductiva para descubrir los patrones o relaciones entre datos que puedan ser útiles en la formación de reglas para clasificaciones. En **ML**, varios son los métodos *heurísticos* que se han desarrollado para la evaluación de atributos en términos de su utilidad potencial (que se ha identificado con su relevancia) de cara a decidir la clase a la que pertenece una entrada. La gran mayoría estan basados en la teoría de la información clásica (*e.g.*: [**QUIN79**], [**QUIN86**], [**SCHL86**], [**BAIM88**], [**LOPE90**], etc.).

4.2 El problema de la relevancia

En esta sección se hace una caracterización del problema de la relevancia de un atributo, y se propone una definición formal de relevancia y atributos no relevantes o atributos **nought**.

4.2.1 Caracterización de la relevancia

Sea $\mathcal{U}$ un universo y $\mathcal{C} = \{C_1, C_2, \ldots, C_m\}$ una clasificación (partición) de $\mathcal{U}$. Asúmase que los elementos de $\mathcal{U}$ se pueden representar por la n-tupla $(A_1(u), \ldots, A_n(u))$ ordenada de atributos (*i.e.* características mesurables) de los objectos en $\mathcal{U}$, con rangos $X_1, X_2, \ldots, X_n$, respectivamente. Formalmente hablando, cada A_i es una función con dominio $\mathcal{U}$ y rango X_i. Nótese que, en general, $\{(A_1(u), \ldots, A_n(u)) \mid u \in \mathcal{U}\}$ es un subconjunto de $X_1 \times \ldots \times X_n$ pero no necesariamente igual. Designemos r_i como la cardinalidad de X_i.

Expresado intuitivamente, contra más *información* proporciona un atributo a una clasificación, más relevante es para la clasificación. La manera natural de *mesurar* la información que un atributo proporciona es por medio de su capacidad de discriminar los elementos de $\mathcal{U}$. La relevancia de un atributo no es una propiedad absoluta, sino que es relativa a una clasificación o interpretación. Un atributo puede ser muy importante para una clasificación pero *irrelevante* en otra. Por ejemplo, el color de la piel de las personas no es importante para determinar (discriminar) el tipo de enfermedad cardiovascular que puedan tener, pero sí lo es para determinar su clasificación étnica. En la práctica, el conjunto inicial de atributos potencialmente útiles debe ser escogido por el experto [**BAIM88**].

Establecemos aquí que la relevancia de un atributo depende no solamente en la proporción de objetos que discrimina, sino en *cómo* interactua con el resto de atributos. Cualquier definición formal de relevancia debe, por tanto, tener en cuenta ambos conceptos. Las definiciones siguientes estan extraídas de [**NUÑE91**], y servirán como acercamiento teórico al problema de la relevancia.

Definición 4.1 *El atributo A_i es más relevante que el A_j si, y sólo si, el mínimo número de atributos que se han de añadir a A_i para obtener un conjunto totalmente discriminante, es menor que el número de atributos requeridos para A_j. Si este número es el mismo para ambos, concluiremos que son igualmente relevantes.*

Esta definición se puede expresar como: Sea $N = \{1, 2, \ldots, n\}$, y, por cada $S \subset N$, sea

$$\mathcal{A}_S = \{A_s \mid s \in S\},$$
$$\begin{aligned} \mathcal{S}_i &= \{S \subset N \setminus \{i\} \mid \{A_i\} \cup \mathcal{A}_S \text{ es totalmente discriminante}\} \\ \mathcal{S}_j &= \{S \subset N \setminus \{j\} \mid \{A_j\} \cup \mathcal{A}_S \text{ es totalmente discriminante}\} \end{aligned}$$

Entonces A_i es más relevante que A_j si, y sólo si,

$$min\{\#S|S \in \mathcal{S}_i\} < min\{\#S|S \in \mathcal{S}_j\}.$$

A_i es igualmente relevante que A_j si, y sólo si,

$$min\{\#S|S \in S_i\} = min\{\#S|S \in S_j\}.$$

Definición 4.2 *Sean S_1 y S_2 dos subconjuntos de N, y sea*

$$\begin{aligned} \mathcal{S}_{S_1} &= \{S \subset (N \setminus S_1) \mid \mathcal{A}_{S_1} \cup \mathcal{A}_S \text{ es totalmente discriminante}\} \\ \mathcal{S}_{S_2} &= \{S \subset (N \setminus S_2) \mid \mathcal{A}_{S_2} \cup \mathcal{A}_S \text{ es totalmente discriminante}\} \end{aligned}$$

$\mathcal{A}_{S_1}$ es más relevante que $\mathcal{A}_{S_2}$ si, y sólo si,

$$min\{\#S|S \in S_{S_1}\} < min\{\#S|S \in S_{S_2}\}.$$

Los conjuntos de atributos A_{S_1} y A_{S_2} tienen la misma relevancia $\mathcal{R}$ si, y sólo si,

$$min\{\#S|S \in S_{S_1}\} = min\{\#S|S \in S_{S_2}\}.$$

La idea intuitiva que subyace a la definición es que dos conjuntos de atributos, independientemente de su cardinalidad, son igualmente relevantes si tienen la misma capacidad de discriminación o, equivalentemente, si *la cantidad de información que les falta para ser totalmente discriminantes es la misma.*

Por tanto, para determinar si un conjunto dado de atributos es más relevante que otro tendriamos que generar, como mínimo, todos los conjuntos totalmente discriminantes (de relevancia máxima) que contengan alguno de los dos conjuntos dados. Pero este es un método impráctico e intratable desde el punto de vista de la complejidad. Así, la solución propuesta ha sido establecer heurísticas para evaluar la utilidad potencial de un atributo, de tal manera que escogen, sucesivamente, aquellos que llevarán a obtener árboles de decisión cercanos al óptimo. Las soluciones propuestas hasta ahora tienen varios elementos comunes, y su discusión nos lleva a la heurística definida más adelante. Para un completo estudio de estas medidas y sus características, véase **[BELA91]**, **[NÚÑE91]**.

La definición de relevancia para un conjunto dado de atributos $\mathcal{A}$ introduce una relación de equivalencia $\mathcal{R}$ en el conjunto potencia $\mathcal{P}(\mathcal{A})$, donde las clases de equivalencia estan formadas por conjuntos igualmente relevantes. Junto con la anterior definición, esto nos permite introducir un *orden total,* $\leq$, en el conjunto cociente de clases de equivalencia $\mathcal{P}(\mathcal{A})/\mathcal{R}$.

Definición 4.3 *Sean $\mathcal{A}_{S_1}$, $\mathcal{A}_{S_2}$ dos conjuntos de atributos y $[\mathcal{A}_{S_1}]$, $[\mathcal{A}_{S_2}]$ sus clases de equivalencia. Entonces:*

$$[\mathcal{A}_{S_1}] \ \leq \ [\mathcal{A}_{S_2}]$$

si, y sólo si,

$$min\{\#S|S \in S_{S_1}\} \leq min\{\#S|S \in S_{S_2}\}.$$

Nótese que las clases $[\mathcal{A}]$ y $[\emptyset]$ son, respectivamente, el máximo y el mínimo con respecto a ese orden, *i.e.* $[\emptyset] \leq [\mathcal{A}_S] \ \leq \ [\mathcal{A}], \quad \forall\, \mathcal{A}_S \subset \mathcal{A}$. Otro punto importante es que si $\mathcal{A}_{S_1}$ es más relevante que $\mathcal{A}_{S_2}$, entonces cualquier subconjunto de $\mathcal{A}_{S_1}$ es más relevante que cualquier otro de $\mathcal{A}_{S_2}$. El problema, en la práctica, es obtener el *óptimo representante de $[\mathcal{A}]$, que clasifica el conjunto original $\mathcal{U}$ con el mínimo esfuerzo.* Este es el objetivo de los algoritmos antes mencionados.

4.2.2 Los atributos nought

Se ha dicho ya que la relevancia de un conjunto de atributos no es inherente a ellos, sino que depende de la clasificación. Frecuentemente nos enfrentamos con situaciones en que un atributo o, en general, un conjunto de atributos, no son inportantes para un proceso de clasificación dado (aunque podrian serlo para otro), es decir, *no tienen relevancia para una determinada clasificación.* Esta relevancia nula será referida como relevancia **nought** [**SANC89**] . A partir de ahora, nos referiremos también a los atributos no relevantes como atributos **nought**.

En estos casos estos atributos estan ya dados y no pueden ser ignorados. Lo que querriamos es que no distorsionaran la clasificación considerando sólo los no **nought**.

De acuerdo con la definición de relevancia, los atributos **nought** son aquellos sin capacidad de discriminación. Por tanto, cualquier conjunto **nought** tiene relevancia nula y es un elemento de $[\emptyset]$, el conjunto vacío.

Definición 4.4 *Un conjunto de atributos $\mathcal{A}_{\mathbf{n}}$ es* **nought** *si, y sólo si, $[\mathcal{A}_{\mathbf{n}}] = [\emptyset]$.*

Nótese que cualquier conjunto de atributos **nought** $\mathcal{A}_{\mathbf{n}}$, añadido a un conjunto de atributos $\mathcal{A}_S$ dado, no le altera la relevancia, es decir, la capacidad de discriminación de la clase $[\mathcal{A}_S]$ es la misma que la de la clase $[\mathcal{A}_{\mathbf{n}} \cup \mathcal{A}_S], \ \forall\, \mathcal{A}_S \subset \mathcal{A}$.

Teorema 4.1 *Sea $\mathcal{A}_{\mathbf{n}}$ un conjunto de atributos* **nought**. *Entonces $[\mathcal{A}_{\mathbf{n}} \cup \mathcal{A}_S] = [\mathcal{A}_S]\,, \quad \forall\, \mathcal{A}_S \in \mathcal{P}(\mathcal{A})$*

4.3 Una medida de la utilidad potencial de un atributo

Dado $i \in N$, para cada a_{ij} $(j = 1, 2, \ldots, r_i)$, sea $p_{jk} = \#(A_i^{-1}(a_{ij}) \cap C_k)$, donde $k = 1, \ldots m$, el número de objetos que toman el valor a_{ij}, y emplazados en la clase C_k. Ya que $C_1, C_2, \ldots, C_m$ es una partición del universo, se tiene que

$$p_j = \sum_{k=1}^{m} p_{jk} = \#A_i^{-1}(a_{ij}).$$

Sea $\overline{p_j}$ la media aritmética de los objetos con valor a_{ij} en las classes, es decir,

$$\overline{p_j} = \frac{\#A_i^{-1}(a_{ij})}{m}.$$

Sea $D = \{(p_{j1}, p_{j2}, \ldots, p_{jm}) \mid j = 1, 2, \ldots, r_i\}, \quad i \in N$. Entonces, la utilidad potencial de cada atributo A_i puede ser expresada como una función del conjunto D a $R^+ \cup \{0\}$.

Definición 4.5 *Sea $u : \mathcal{A} \to \mathcal{R}^+ \cup \{0\}$ la función que evalua la utilidad potencial de un atributo, definida como sigue:*

$$u(A_i) = \sum_{j=1}^{r_i} \sum_{k=1}^{m} (p_{jk} - \overline{p_j})^2.$$

Nótese que tal función u es no negativa, y que $u(A_i) = \sum_{j=1}^{r_i} (m-1) S_j^2$, donde S_j^2 es la varianza estadística de los valores $\{p_{jk} \mid k = 1, \ldots, m\}$.

Definición 4.6 *Dado un par de atributos, A_i, A_l, el atributo A_i es potencialmente más útil que el atributo A_l si, y sólo si, $u(A_l) < u(A_i)$.*

Esto es, el atributo A_i es más relevante que el atributo A_l si, y sólo si,

$$\begin{aligned} &\sum_{j=1}^{r_l} \sum_{k=1}^{m} (\#(A_l^{-1}(a_{lj}) \cap C_k) \quad - \tfrac{\# A_l^{-1}(a_{lj})}{m})^2 \\ < &\sum_{j=1}^{r_i} \sum_{k=1}^{m} (\#(A_i^{-1}(a_{ij}) \cap C_k) \quad - \tfrac{\# A_i^{-1}(a_{ij})}{m})^2. \end{aligned}$$

Para cada $j = 1, 2, \ldots, r_i$, sea $u_j((p_{j1}, p_{j2}, \ldots, p_{jm})) = (m-1) S_j^2$. El sumatorio $(m-1)S_j^2$, para cada j, representa la contribución del valor a_{ij} a la utilidad potencial del atributo A_i, y puede interpretarse como *la utilidad potencial del valor a_{ij}*. Así las cosas, la utilidad potencial de un atributo es la suma de la de sus valores.

Una característica útil de la función u_j es que, contra mas lejanos de la media $\overline{p_j}$ estan los valores $p_{j1}, p_{j2}, \ldots, p_{jm}$, mayor es el valor de la función. Un incremento en unos valores provoca un decremento en otros. En particular, si la distribución es alterada de manera que la proporción de objetos en una de las clases se incrementa —decrementándose consecuentemente en otra—, resultando en una nueva distribución no tan aleatoria como la anterior, entonces la utilidad potencial del valor es mayor. Esto se puede formalizar de la siguiente manera:

Si para algún entero positivo z, $z \le p_{js}$ consideramos $(p_{js} - z)$ y $(p_{jt} + z)$, $s, t \in M = \{1, \ldots, m\}$ y

$$(p_{js} - \overline{p})^2 + (p_{jt} - \overline{p})^2 < ((p_{js} - z) - \overline{p})^2 + ((p_{jt} + z) - \overline{p})^2,$$

entonces

$$u_j((p_{j1}, p_{j2}, \ldots, p_{jm})) < u_j((p_{j1}, \ldots, p_{js} - z, \ldots, p_{jt} + z, p_{t+1}, \ldots p_m)).$$

Otra característica útil de la estimación de la utilidad potencial de un atributo es el hecho de que u_j es muy *sensitiva* al número de objetos que cada valor clasifica: contra mayor sea este número, mayor es u_j, siendo *muy* significativa la diferencia entre un valor que clasifique muchos objetos y otro que no clasifique tantos. Como resultado, la evaluación de la utilidad potencial de cada valor de un atributo —y la del atributo mismo— es mejor en muchos casos, ya que tiene en cuenta la capacidad de clasificación de cada valor y, con ello, del atributo.

La función $u(A)$ es una suma de los $u_j((p_{j1}, p_{j2}, \ldots, p_{jm}))$, $j = 1, 2, \ldots, r_i$. De la caracterización de las funciones u_j es posible inducir también las propiedades de la función u. Las siguientes son propiedades de las funciones u_j, susceptibles de extensión a u. Tales propiedades son útiles a la hora de estimar la utilidad potencial de un atributo. En aras de la simplicidad, no se incluye el subíndice j en p_{jk}. Sea $(p_1, p_2, \ldots, p_m) \in D$, arbitrario.

Propiedad 1 (Simetría)
$$u_j((p_{\sigma(1)}, p_{\sigma(2)}, \ldots, p_{\sigma(m)})) = u_j((p_1, p_2, \ldots, p_m)),$$
para cada permutación σ de grado m.

Propiedad 2 (Máximo de la función u_j)
$$u_j((p_1, p_2, \ldots, p_m)) \leq u_j((0, \ldots, 0, p_1 + p_2 + \ldots + p_m, 0, \ldots, 0)),$$
para cada posición k, $1 \leq k \leq m$.

Propiedad 3 (Mínimo de la función u_j)
$$u_j((\overline{p_j}, \overline{p_j}, \ldots, \overline{p_j})) \leq u_j(p_1, p_2, \ldots, p_m).$$
(De hecho, $u_j((\overline{p_j}, \overline{p_j}, \ldots, \overline{p_j})) = 0$).

La primera propiedad dice que lo que realmente interesa es el número de objetos clasificados en una determinada clase, más que qué clase es ésta. Es más, en lo que se refiere a la función $u(A)$, no importa cual es el valor del atributo que asigna el mayor número de objetos a una clase dada, sino que exista tal valor. En particular (propiedad 2), u_j toma su valor máximo cuando todos los objetos se concentran en la misma clase. Finalmente, u_j es mínima cuando se tiene una distribución uniforme en las clases (propiedad 3). Entonces decimos que el valor a_{ij} tiene utilidad potencial mínima.

Otra propiedad remarcable de la función u es que, si el número de objetos que un valor asigna a una clase es igual a la suma del número de objetos que otros dos valores asignan a esa clase, entonces la utilidad potencial del valor único es mayor o igual que la de los otros dos valores combinados. Esto significa que la función u no realza atributos con muchos valores, fundamental para propósitos de eficiencia.

De cara a obtener una caracterización operacional de los atributos *nought*, aquellos con utilidad potencial cero podrían ser vistos como nought potenciales, o incluso se podría forzar que un atributo tuviera utilidad potencial cero si quisiéramos *neutralizarlo* para una clasificación.

4.4 Validación de la medida

4.4.1 Un modelo para la clasificación difusa: LINNEO$^+$

LINNEO$^+$ ([**MART91**]) es un *software* para la clasificación difusa y la generación de reglas que recurre a técnicas analíticas y empíricas de adquisición del conocimiento.

Fig. 5. LINNEO: aspecto de la metodología

La figura 5 muestra la estructura general de su metodología. El experto humano abstrae una colección de observaciones y un conjunto de atributos que cree relevantes. Al mismo tiempo, el experto puede también expresar lo que sabe de entrada sobre el dominio. Este conocimiento es representado en forma de características y/o ejemplos de las clases de las que se conoce su existencia de antemano.

Partiendo de este conocimiento y datos, LINNEO^{+} hace inducción sobre las observaciones para generar una clasificación. El experto entonces evalua los resultados y, eventualmente, modifica algunos atributos o aspectos de su teoría del dominio de cara a generar una nueva clasificación. Cuando se obtiene una satisfactoria, se derivan reglas difusas de las clases generadas.

4.4.2 El módulo de relevancia

Un módulo de relevancia ha sido construido sobre LINNEO^{+} de cara a guiarlo en el proceso de clasificación. Esto se realiza de una manera cooperativa: primero, LINNEO^{+} produce una clasificación de acuerdo con el experto. Después, y usando la teoría inicial del dominio y dicha clasificación, el módulo de relevancia genera una lista ordenada de las relevancias relativas de los atributos para esa clasificación. En ese momento, esta lista es susceptible de ser modificada por el experto. Además, se establece un lindero de manera que el módulo genera una lista final en la cual solamente unos cuantos atributos del conjunto inicial estan presentes (por ejemplo, un 25%). El clasificador recomienza su tarea usando esta nueva lista y se obtiene la clasificación final. De esta se espera que sea muy cercana a la obtenida considerando la lista inicial entera. Los atributos no incluidos son tomados, así, como nought.

Un desarrollo posterior se ha realizado de cara a mejorar aún más la lista final de relevancias. Dada una clasificación, se puede aplicar el módulo de relevancia a cada clase tomada por separado, considerando de esta manera sólo aquellos objetos pertenecientes a esa clase. Lo que se obtiene es la relevancia relativa de los atributos tomados para caracterizar una subclase de la clasificación. Una interacción con el experto es también posible aquí para cada lista de relevancia, y se pueden establecer linderos locales. Entonces, se forma la lista global de relevancias en base a las listas de las subclases.

¿Cómo se deben interpretar dichas listas locales? Los primeros atributos de cada una son aquellos más relevantes para discriminar los objetos de la clase a que se refiere entre sí. Los últimos (en orden de relevancia) nos servirán para distinguir esa clase de las demás. No sorprendentemente, estos últimos aparecen en la lista global original en los primeros lugares y, simétricamente, los atributos menos relevantes de la lista global aparecen como muy significativos en alguna (normalmente una sola) lista local.

5 Arquitectura

La arquitectura del prototipo del sistema DEPUR (figura 6) es la clásica de un sistema experto, en la que se han considerado además, algunos aspectos importantes para nuestro dominio, como son los microbiológicos y los temporales. La *base de datos* es una representación del estado actual del sistema en un momento dado, pudiendo contener aspectos pasados y/o futuros del mismo. En esta representación se consideran los atributos (o conceptos o hechos) más relevantes para la caracterización del dominio.

El *diccionario* de la base de datos finalmente consta de 167 atributos, habiéndose reducido estos en un 15% al aplicar el módulo de relevancia a la clasificación obtenida inicialmente.

Un ejemplo de una entrada del diccionario puede ser:

```
(CAUDAL-ENTRADA-NORMAL
 "El caudal de entrada es normal"
 "El caudal de entrada a la planta
  es normal (35 000 - 45 000) m3/dia ?"
 DIFUSO)
```

La *base de conocimientos* consiste en la organización del conocimiento que se tiene sobre el dominio en cuestión, explicitado por el experto y procedente del análisis del sistema.

Usualmente el conocimiento se estructura en forma de *reglas de inferencia*. Un ejemplo de una regla podría ser:

```
(RMENU003B
             (SI  (DQO-SALIDA-ALTA
                   EDAD-FANGO-JOVEN))
```

```
SEGURO
(ENTONCES
   (CONCLUIR (CLASE-3B))))
```

La aplicación consta de 79 reglas, agrupadas en 12 módulos. Un módulo es un elemento estructuracional de la base de conocimientos, formado por un conjunto de reglas relacionadas entre sí (conclusiones similares, condiciones similares, ...). El *módulo de control* es el encargado de supervisar cómo y cuándo puede ser usado el conocimiento que se tiene del dominio. Típicamente se explicita en forma de *metareglas* que pueden actuar sobre: reglas, módulos o estrategias.

Un ejemplo de metaregla puede ser:

```
(M003B
        (SI  (CLASE-3B))
         SEGURO
        (ENTONCES
           (MODULOS-A-VISITAR  C3)))
```

Se han obtenido 15 metareglas: 3 orientadas a reglas y 12 sobre módulos y estrategias. La *modularidad* de la aplicación, que favorece su comprensibilidad y modificabilidad, la *autoexplicación* y la *interfície agradable* con el usuario proporcionada por MILORD son otros aspectos a destacar.

6 Resultados

Se han obtenido 10 clases (ver figura 7), cada una de ellas representando las principales situaciones prototípicas, que muestran las situaciones y problemas más comunes en el funcionamiento de las plantas de tratamiento de aguas residuales. Dichas clases guían el proceso de inferencia en la diagnosis, para posteriormente investigar más a fondo dentro de las clases, mediante las reglas de inferencia derivadas de los árboles de decisión. Por tanto, el resultado visible del trabajo de investigación realizado en estos años (estudio y modelización de plantas depuradoras de tratamiento de aguas residuales, desarrollo de nuevas técnicas de selección y estructuración de atributos para la modelización de un dominio, construcción del sistema informático) es el sistema experto DEPUR (en fase experimental). La contraposición de los diagnósticos del sistema a las respuestas de los expertos humanos ha dado buenos resultados. Ha sido probada en varias situaciones arquetípicas en el trabajo de una planta (*bulking*, *foaming*, ...).

7 Conclusiones

Indudablemente, la construcción de una herramienta de diagnosis para el control de una planta de tratamiento de aguas residuales es una contribución interesante al campo de los sistemas inteligentes aplicados a procesos industriales, que pueden ser de gran ayuda para el encargado de la planta. El uso de nuevos métodos de

Fig. 6: Arquitectura general de DEPUR.

selección de atributos es también significativo en lo que respecta a la extracción del conocimiento del experto. Asimismo, las nuevas técnicas difusas para clasificación automática representan otro aspecto importante de cara a la estructuración del dominio de conocimiento, ya que el empleo de la incertidumbre en un Sistema Basado en el Conocimiento aplicado a procesos industriales no suele ser muy habitual. En ese sentido, DEPUR supone un paso adelante hacia la construcción de Sistemas Inteligentes preservadores del medio ambiente. En nuestro caso, del agua. Otro punto interesante es la posibilidad de adecuar el sistema a las características particulares y habitualmente bastante distintas de la planta de tratamiento concreta que está bajo control. Con todo, se puede decir que DEPUR es una bocanada de aire fresco para los Sistemas convencionales de Control de Procesos.

8 Trabajo futuro

El futuro ha de avanzar hacia la construcción de un Sistema supervisor basado en el conocimiento, más amplio y potente que un sistema experto, que incorpore diagnosis y control, e integre algoritmos de control numéricos y aspectos heurísticos. En concreto hay que mejorar el tratamiento temporal de la información (desarrollando un sistema de actualización en tiempo real de los parámetros, ...). Investigar más pro-

Fig. 7: Clasificación final obtenida.

fundamente el conocimiento aportado por la información microbiológica (poblaciones microbiológicas presentes, ...). Revisar el tratamiento de la incertidumbre, para adecuarlo mejor a nuestro dominio. Extender el dominio que cubre el sistema. Se ha de ampliar al circuito o línea del fango. También la investigación ha de centrarse en la relación entre los conceptos de *utilidad potencial* y *relevancia*. Se ha establecido que un atributo con utilidad potencial cero no tiene por qué ser un atributo *nought*. Es más, recíprocamente, no es necesario que un atributo tenga utilidad potencial cero para poder ser *nought*. Asimismo, se necesita una caracterización operacional de los atributos *nought*, basada en la heurística propuesta de utilidad potencial. Todo ello llevará a un proceso de clasificación capaz de clarificar y simplificar el dominio sobre el que se está aplicando, como es —en nuestro actual desarrollo— el tratamiento de aguas residuales.

Bibliografía

[BAIM88] Baim, P. W. *A method for attribute selection in inductive learning systems.* IEEE Transaction on pattern analysis and machine intelligence 10 (6), (1988) pp. 888–896.

[BELA91] Belanche, Ll. *To be or nought to be. An irrelevant question?.* Master Thesis. Departament de Llenguatges i Sistemes Informàtics. Universitat Politècnica de Catalunya (1991).

[BENE80] Benefield L.D., Randall C.W. *Biological process design for watewater treatment.* Prentice-Hall, N.J., (1980).

[FLOR89] Floris, V., *Artificial Intelligence in the operation and management of water resources in South Florida.* Personal Comm. (1989).

[HAYE84] Hayes-Roth, F. *The knowledge-based expert system: A tutorial.* Computer 17 (9), (1984).

[LÓPE90] López de Mántaras, R., Crespo, J. J., *El problema de la seleción de atributos en el aprendizaje inductivo: nueva propuesta y estudio experimental.* In Memorias IBERAMIA 90, 2º Congreso Iberoamericano de Inteligencia Artificial. Ed. Limusa-Noriega. México, (1990) pp. 259–271.

[MAED89] Maeda, K. *A knowledge-based system for the wastewater treatment plant.* A future generation computer systems 5, pp. 29-32. North Holland (1989)

[MART91] Martín, M., Sangüesa, R., Cortés, U. (1991) *Knowledge acquisition combining analytical and empirical techniques.* In Birnbaum, L., and Collins, G. (eds.) Machine Learning: Proceedings of the Eighth International Workshop. San Mateo, CA: Morgan Kaufmann.

[METC79] Metcalf-Eddy, Inc. *Wastewater engineering: treatment/disposal/reuse.* McGraw Hill, Inc. second edition, (1979).

[NUÑE91] Núñez, G., Alvarado, M., Cortés, U., Belanche, Ll. *About the attribute relevance's nature.* In Proceedings of the TECCOM-91. México, D.F.

[QUIN79] Quinlan, J. R. *Learning efficient classification procedures and their application to chess end games* In Michalski, R.S., Carbonell, J.G. and Mitchell, T.M. (Eds): *Machine Learning: An Artificial Intelligence Approach.* Tioga, PA, California, (1984) pp. 463–482.

[QUIN86] Quinlan, J.R. *Induction of decision trees* In Machine Learning 1(1). Kluwer Academic Publishers, Boston MA (1989), p81-106.

[ROBU90] Robusté, J. *Modelització i identificació del procés de fangs activats.* Ph.D. Thesis. Departament de Química. Universitat Autònoma de Barcelona (1990).

[SÁNC89] Sánchez, E. *Importance in knowledge systems.* Information System 14 (6) (1989) pp. 455-464.

[SÁNC90] Sánchez, M. *DEPUR: una aplicació de MILORD al tractament de les aigües residuals en una depuradora.* Research report. (LSI 90-12). Departament de Llenguatges i Sistemes Informàtics. Universitat Politècnica de Catalunya (1990).

[SÁNC91] Sánchez, M. *DEPUR: Aplicació del sistemes basats en el coneixement al diagnòstic en plantes de tractament d'aigües residuals.* Master Thesis. Departament de Llenguatges i Sistemes Informàtics. Universitat Politècnica de Catalunya (1991).

[SANZ89] Sanz, R., Aguilar J., Sierra C., Godó Ll., Ollero A. *Adaptative control with a supervisor level using a rule-based inference system with approximate reasoning.*. In A.I. in scientific computation: towards secong generation systems. IMACS 1989.

[SCHL86] Schlimmer, J. C., Fisher, D. *A case study of incremental concept induction.* In Proc. of the fifth national conference on artificial intelligence. Ed. Morgan Kaufmann, (1986) pp. 496–501.