

## **From the extraction to knowledge modeling in a Knowledge Based System. A logical combinatorial conceptual grouping approach**

---

Yunia Reyes González

[yrglez@uci.cu](mailto:yrglez@uci.cu)

*Universidad de las Ciencias Informáticas*

Natalia Martínez Sánchez

[natalia@uci.cu](mailto:natalia@uci.cu)

*Universidad de las Ciencias Informáticas*

Adolfo Díaz Sardiñas

[adolfo@uci.cu](mailto:adolfo@uci.cu)

*Universidad de las Ciencias Informáticas*

Maidelis Milanés Luque

[mmilanes@uci.cu](mailto:mmilanes@uci.cu)

*Universidad de las Ciencias Informáticas*

### **ABSTRACT**

Elucidating and replicating knowledge is the central task in building knowledge-based systems; the subject of this action is the knowledge engineer. The knowledge acquisition from human experts, although necessary and irreplaceable, in some applications in others less, has presented various difficulties ranging from the representation of common sense to excessive delays in the implementation and maintenance of systems. The knowledge acquisition process required in a knowledge-based system can be automated or partially automated. The idea is to reduce the working time between the knowledge engineer and the knowledge expert in the intelligent computer system that is to be built. This paper presents the potential of logical combinatorial grouping for both extraction and knowledge modeling in the construction of this type of computer systems. Three specific cases of Knowledge Based Systems are presented in which concepts are used in their essential processes: how to represent the knowledge and method of solving the problem. This approach allows, among other advantages, the automation of knowledge extraction process which makes it possible to separate it from human experts and bring the Knowledge Based Systems theory to more current paradigms where techniques like Big Data are applied.

**KEYWORDS:** Knowledge Based Systems, Conceptual Algorithms, Logical combinatorial pattern recognition

## **De la extracción al modelado del conocimiento en un Sistema Basado en el Conocimiento. Un enfoque desde el agrupamiento conceptual lógico combinatorio**

---

Yunia Reyes González

[yrglez@uci.cu](mailto:yrglez@uci.cu)

*Universidad de las Ciencias Informáticas*

Natalia Martínez Sánchez

[natalia@uci.cu](mailto:natalia@uci.cu)

*Universidad de las Ciencias Informáticas*

Adolfo Díaz Sardiñas

[adolfo@uci.cu](mailto:adolfo@uci.cu)

*Universidad de las Ciencias Informáticas*

Maidelis Milanés Luque

[mmilanes@uci.cu](mailto:mmilanes@uci.cu)

*Universidad de las Ciencias Informáticas*

### **RESUMEN**

Elucidar y reproducir conocimiento es la tarea central en la construcción de los sistemas basados en el conocimiento; el sujeto de esta acción es el ingeniero de conocimiento. La adquisición del conocimiento a partir de expertos humanos, si bien necesaria e insustituible, en unas aplicaciones más en otras menos, ha presentado diversas dificultades que van desde la representación del sentido común hasta las excesivas demoras en la implementación y el mantenimiento de los sistemas. El proceso de adquisición del conocimiento requerido en un sistema basado en el conocimiento puede ser automatizado o parcialmente automatizado. La idea radica en lograr disminuir el tiempo de trabajo entre el ingeniero del conocimiento y el experto del área del saber en el sistema informático inteligente que se desea construir. En este artículo se presentan las potenciales que ofrece el agrupamiento conceptual lógico combinatorio tanto para la extracción como para la modelación del conocimiento en la construcción de este tipo de sistemas informáticos. Se presentan tres casos específicos de Sistemas Basados en el Conocimiento en los cuales se emplean los conceptos en sus procesos esenciales: forma de representar el conocimiento y método de solución del problema. Este enfoque permite, entre otras ventajas, la automatización del proceso de extracción del conocimiento lo que posibilita independizarlo de los expertos humanos y acercar la teoría de los Sistemas Basados en el Conocimiento a paradigmas más actuales donde se emplean técnicas como Big Data.

**PALABRAS CLAVE:** Sistemas Basados en el Conocimiento, Algoritmos conceptuales, Reconocimiento lógico combinatorio de patrones.

## INTRODUCCIÓN

En este trabajo no se pretende realizar una descripción detallada de los sistemas basados en el conocimiento (SBC), para lo que existe una amplia literatura científica, sino sólo introducir, de forma simple e intuitiva, la relación que existe entre el agrupamiento conceptual y la ingeniería del conocimiento implícita en este tipo de sistema inteligente, así como, mostrar la utilidad de los conceptos en su implementación.

La Inteligencia Artificial (IA)(Rich & Knight, 1988), es una rama de la ciencia de la computación dedicada a la creación de hardware y software que intenta producir resultados similares a los expresados por los humanos. Le conciernen dos ideas básicas: la primera es que ésta involucra el estudio de los procesos del pensamiento de los humanos y la segunda que trata de representar estos procesos en una computadora. Conceptualizar estas ideas básicas condujo al desarrollo de los llamados Sistemas Basados en el Conocimiento (SBC).

Un Sistema Basado en el Conocimiento se puede definir como: "un sistema computacional capaz de soportar la representación explícita del conocimiento de un dominio específico y de explotarlo a través de los mecanismos apropiados de razonamiento para proporcionar un comportamiento de alto nivel en la resolución de problemas"(Guida & Tasso, 1995). En otras palabras, los sistemas basados en el conocimiento tratan con problemas poco estructurados en los que se pueden encontrar requisitos subjetivos, entradas inconsistentes, incompletas o con incertidumbre y que no pueden ser resueltos aplicando los algoritmos clásicos (García, Honey, & Gil, 1994). Además, se caracterizan por tener un solucionador de problemas capaz de manejar conocimiento específico del dominio de aplicación siendo independiente un módulo del otro.

Por esta razón los SBC se componen de tres módulos fundamentales: la base de conocimiento, la máquina de inferencia y la interfaz usuario. La base de conocimiento es la componente más importante y la máquina de inferencia es el intérprete del conocimiento almacenado en la base de conocimiento (Bello, 2002).

Un SBC es generalmente el resultado de la colaboración de uno o varios expertos humanos especialistas en el tema de estudio y los ingenieros del conocimiento. Los expertos humanos suministran el conocimiento básico en el tema de interés, y los ingenieros del conocimiento trasladan este conocimiento a un lenguaje, que el sistema experto pueda entender. La colaboración de los expertos humanos, los ingenieros del conocimiento y los usuarios es, quizás, el elemento más importante en el desarrollo de este tipo de sistema informático. Esta etapa requiere una enorme dedicación y un gran esfuerzo debido a los diferentes lenguajes que hablan las distintas partes y a las diferentes experiencias que tienen.

Diferentes formas de conocimiento y diferentes mecanismos de inferencias en los sistemas basados en el conocimiento propiciaron el desarrollo de distintos tipos de SBC, entre ellos los sistemas basados en reglas (Rich & Knight, 1988), los sistemas basados en probabilidades (Castillo, Gutiérrez, & Hadi, 2012), sistemas expertos conexionistas o redes expertas (Hilera-González y Martínez-Hernando 1995) y los sistemas basados en casos (J. L. Kolodner, 1992).

En este trabajo se describe cómo utilizar el agrupamiento conceptual en el proceso de ingeniería del conocimiento implícito en la construcción de todo SBC. Este modelo de algoritmos determina, no sólo cuál es la integración de sus agrupamientos sino, además, qué propiedades cumplen los objetos que pertenecen a un mismo grupo, característica distintiva de gran utilidad en la inferencia de la solución a encontrar, que debe ser igual o la más cercana a la expresada por un experto en el área que se desarrolla el SBC. El propósito principal de esta investigación

consiste en destacar las valiosas propiedades de los conceptos para ser utilizados en la construcción de SBC.

## **MARCO TEÓRICO REFERIDO A LA INGENIERÍA DEL CONOCIMIENTO Y EL AGRUPAMIENTO CONCEPTUAL**

La Ingeniería del Conocimiento (IC) es la disciplina tecnológica que se centra en la aplicación de una aproximación sistemática, disciplinada y cuantificable al desarrollo, funcionamiento y mantenimiento de Sistemas Basados en el Conocimiento. En otras palabras, el objetivo de la IC es el establecimiento de metodologías que permitan abordar el desarrollo de SBC de una forma más sistemática (Palma, Paniagua, Martín, & Marín, 2000).

La Ingeniería del Conocimiento surge como consecuencia de la necesidad de establecer principios metodológicos y científicos que permitan desarrollar sistemas basados en el conocimiento a partir de los fundamentos de la informática en general y de la inteligencia computacional en particular. En este aspecto puede vérsela como la especialización de ingeniería de software en su aplicación al desarrollo de Sistemas Inteligentes.

La IC se enfoca al desarrollo de sistemas basados en el conocimiento, destacándose la necesidad de la adquisición del conocimiento así como su especificación, verificación, validación, diseño e implementación en sistemas informáticos o lenguajes apropiados para la construcción de bases de conocimiento para la toma de decisiones (Martínez-Sánchez, 2009).

Uno de los aportes más importantes del trabajo de Buchanan *et al.* (1983) es la identificación del proceso de adquisición de conocimiento como un cuello de botella en el proceso de desarrollo de un SBC.

En función de estos aspectos se desarrollaron varias metodologías basadas en el modelado del conocimiento tales como: KLIC (Guida & Tasso, 1995), CommonKADS (Schreiber, Wielinga, de Hoog, Akkermans, & Van de Velde, 1994), MIKE (Angele, Fensel, Landes, & Studer, 1998), PROTEGE-II (Eriksson, Shahar, Tu, Puerta, & Musen, 1995), VITAL (Shadbolt, Motta, & Rouge, 1993), KSM (Cuenca & Molina, 1997) DESIRE (Brazier, Dunin-Keplicz, Jennings, & Treur, 1997) COMMET (Steels, 1993). Todas ellas comprenden un ciclo incremental y hacen énfasis en el proceso de desarrollo y en la conformación de la base de conocimiento. Puede afirmarse que trabajan en un nivel superior de abstracción y proponen prácticas generales para la construcción de SBC detallando las etapas necesarias en el desarrollo de software. En esta investigación se incide en el proceso de ingeniería del conocimiento utilizando el agrupamiento conceptual en el marco del enfoque lógico combinatorio del reconocimiento de patrones para la construcción de tres tipos de SBC: los Sistemas Basados en Reglas, los Sistemas Basados en Casos y las Redes Neuronales Artificiales.

### **Agrupamiento conceptual lógico combinatorio**

De la Teoría Clásica de Conjuntos se sabe que éstos no se definen, sino que se determinan y que existen dos formas para determinar un conjunto: de manera extensional, que significa dar los

elementos que lo constituyen, y de manera intencional, que significa dar la(s) propiedad(es) que caracteriza(n) al conjunto, que satisfacen los elementos que pertenecen al mismo. Por su parte, la casi totalidad de los modelos de algoritmos para la solución de problemas de clasificación no supervisada ofrecen estructuraciones de los espacios sobre los que se aplican en forma extensional, es decir, determinan qué objetos están en un cierto agrupamiento, o con qué grado pertenecen a un agrupamiento dado (modelos difusos, es decir, basados en la Teoría de los Subconjuntos Difusos). En otras palabras, dan una estructuración extensional de los espacios. El modelo conceptual de Michalski (Ruiz-Shulcloper, 2009) constituye una excepción. Ese modelo de algoritmos pretende determinar, no sólo cuál es la integración de sus agrupamientos sino, además, qué propiedades cumplen los objetos que pertenecen a un mismo agrupamiento. Se puede afirmar que los algoritmos de Michalski son los primeros en dar una estructuración conceptual del espacio. Sin embargo, tanto los algoritmos de Michalski como los restantes desarrollados posteriormente en la línea del enfoque conceptual, presentan restricciones para su aplicación a problemas prácticos.

El problema a resolver es la elaboración de herramientas matemáticas y algoritmos de alta eficiencia computacional para la solución de problemas de estructuración de espacios cualesquiera (sin presupuestos algebraicos o topológicos) en los cuales los objetos puedan ser descritos en términos de variables cuantitativas y cualitativas, con ausencia de información en las descripciones de los objetos, de manera simultánea. Esta solución además debe proporcionar una información acerca de las propiedades que caracterizan a los diferentes agrupamientos. En otras palabras, se trata no sólo de dar un agrupamiento en forma extensional sino además de manera intencional para espacios de representación cualesquiera de los objetos. Este problema se presenta con frecuencia, directa o indirectamente, en muchas áreas del conocimiento poco formalizadas, tales como: la elaboración de sistemas de búsqueda y recuperación de la información, la formación de conceptos, el diagnóstico médico, el diagnóstico técnico del estado mecánico de sistemas dinámicos, el pronóstico de perspectiva de ciertos minerales y el pronóstico de fenómenos naturales.

Los algoritmos de agrupamiento conceptual se pueden dividir en dos grandes grupos, los algoritmos incrementales y los no incrementales. Los algoritmos incrementales basan su funcionamiento en la adaptación de los agrupamientos (o conceptos) con los nuevos objetos que se le van presentando, es decir, cada vez que llega un nuevo objeto mediante una cierta estrategia éste es clasificado en los agrupamientos ya existentes o se crean nuevos agrupamientos. Por otro lado, los algoritmos no incrementales estructuran una muestra de objetos sin presuponer que éstos llegan de uno en uno. Los algoritmos de tipo incremental tienen como deficiencia sobresaliente: la dependencia del resultado (la estructuración) en función del orden de entrada o presentación de los objetos al algoritmo.

En general, ambos tipos de algoritmos conceptuales trabajan con la problemática de los datos mezclados y ausencia de información. Una primera solución a este problema es el algoritmo LC-Conceptual (Martínez-Trinidad y Sánchez-Díaz 2001) en el cual nos apoyaremos para lograr la comprensión de este tipo de agrupamiento.

El algoritmo LC-Conceptual incluye dos pasos: el primero es el paso de estructuración extensional, de dicha estructuración, en términos generales se puede decir que se sabe o se desea que se realice en un número dado de agrupaciones; se desconoce en cuántas agrupaciones se estructurará el conjunto de objetos una vez definidos el espacio de representación, los conceptos de similaridad y el criterio de agrupamiento. Consecuentemente, los algoritmos de agrupamiento de objetos pueden tipificarse en dos grandes familias: algoritmos de agrupamiento libres, cuando el número de agrupamientos a obtener es desconocido; y algoritmos de agrupamiento restringidos, cuando se exige que el universo sea estructurado en un número dado de agrupamientos. Es importante resaltar que en ambos casos existen subfamilias de algoritmos, paradigmas de la estructuración de universos, que abordan esos problemas desde una óptica particular (Ruiz-Shulcloper, 2009). En todos estos casos está presente la problemática de los datos mezclados e incompletos y en todos ellos en la actualidad se cuenta con algoritmos que permiten resolver, y se han resuelto, problemas concretos bajo las circunstancias mencionadas.

El segundo y último paso es el de la estructuración intencional donde se construye la propiedad (el concepto) que cumple cada agrupamiento de objetos.

Si se parte de un problema supervisado, donde los objetos están agrupados en clases, se aplica el algoritmo a partir del paso 3, es decir sólo se realiza la etapa intencional.

---

#### **Algoritmo LC-Conceptual**

1. Determinar los criterios de comparación de las variables, la función de semejanza y el criterio de agrupamiento duro.
2. Estructurar la muestra inicial MI con el criterio de agrupamiento seleccionado.
3. Cada agrupamiento constituye una clase y calculamos todos los testores típicos para estas clases.
4. Para cada clase formar los conceptos con todos los testores típicos, usando el operador de REFUNION condicionada.

---

El número de testores típicos para ciertos problemas puede ser muy grande. Esto da como resultado que cada agrupamiento podría tener asociado una gran cantidad de conceptos o propiedades, por lo cual, se recomienda usar un criterio para el cálculo de la utilidad del testor por ejemplo como se utiliza en (Reyes-González, Claro-Arceo, Martínez-Sánchez, & Hernández-Domínguez, 2016).

Para mejor comprensión de qué es un concepto y cómo se calcula se muestra a través de un ejemplo académico.

**Ejemplo 1:** Dada dos clases  $K_1$  y  $K_2$  como se ilustran en la figura 1, cada una con cuatro objetos descritos a través de cinco rasgos  $r_i$  y el testor típico  $TT = \{ r_1, r_3, r_5 \}$ .

Como resultado de aplicar el algoritmo LC-Conceptual para el cálculo de los conceptos se obtienen:

**Concepto de la clase I:**  $C_{11} = (r_1=A \wedge r_3=B \wedge r_5=1) \vee (r_1=B \wedge r_3=[A, B] \wedge r_5=1)$

**Concepto de la clase II:**  $C_{21} = (r_1=[A, C, D] \wedge r_3=D \wedge r_5=[0, 1]) \vee (r_1=[A, C, D] \wedge r_3=[A, D] \wedge r_5=0)$

Estos conceptos representan objetos observables y no observables de cada clase.

Clase I	rasgos				
Objetos	$r_1$	$r_2$	$r_3$	$r_4$	$r_5$
$O_1$	A	C	B	0	1
$O_2$	B	A	A	1	1
$O_3$	A	B	B	0	1
$O_4$	A	A	A	0	1
Clase II	rasgos				
Objetos	$r_1$	$r_2$	$r_3$	$r_4$	$r_5$
$O_5$	C	E	D	1	0
$O_6$	D	D	D	1	1
$O_7$	C	E	D	0	0
$O_8$	A	D	A	1	1

**Figura 1.** Clases  $K_1$  y  $K_2$  (Elaboración Propia)

**Por ejemplo:**

En la clase II la combinación de valores:  $\{C, -, D, -, 0\}$  corresponde a un objeto observable ( $O_7$ ) y la combinación  $\{C, -, D, -, 1\}$  a un objeto no observable, pues sus características son propias de esta clase, pero no existe físicamente ningún objeto.

---

### **Extracción y modelado del conocimiento en un Sistema Basado en el Conocimiento utilizando el agrupamiento conceptual**

Una característica que distingue los sistemas basados en el conocimiento es la separación del conocimiento (base de conocimiento) del método de solución del problema (máquina de inferencia). La construcción de la base del conocimiento lleva implícito un arduo proceso de adquisición del conocimiento y es particular para cada sistema, por lo que será necesario construirla para cada aplicación. Sin embargo, la máquina de inferencia puede reusarse en la construcción de varios sistemas basados en el conocimiento siempre que el tipo de conocimiento y el tipo del razonamiento sea similar.

La envergadura del proceso de adquisición del conocimiento depende del tipo de conocimiento. En los sistemas basados en reglas se desarrolla un proceso complejo y prolongado pues la extracción se refiere a la formalización de reglas y el pensamiento humano no siempre está regido conscientemente por las reglas de la lógica; en ocasiones es básicamente un procesamiento de información recuperada con el tiempo.

En los sistemas basados en probabilidades la adquisición del conocimiento consiste en coleccionar muestras y realizar un procesamiento estadístico que produzca las probabilidades o frecuencias que forman la base de conocimiento. No son factibles para todo tipo de dominio, pues se dificulta construir las redes con ayuda de expertos humanos cuando existen carencias de conocimiento. No son viables para explicar el razonamiento, ya que los métodos y modelos que utiliza están aún lejos de ofrecer explicaciones comprensibles.

En las redes expertas la adquisición del conocimiento incluye la selección de los ejemplos, el diseño de su topología y el entrenamiento de la red para hallar el conjunto de pesos. Facilitan el trabajo con información incompleta y brindan algoritmos poderosos de aprendizaje para crear la base de conocimiento; pero requieren de muchos ejemplos y son cajas negras que no explican cómo la solución se alcanza.

En los sistemas basados en casos la adquisición del conocimiento se reduce a la selección de un conjunto de ejemplos o casos resueltos y su organización en la base de casos. Argumenta una solución mediante los casos que son relevantes al nuevo problema. Cada caso es la experiencia anterior almacenada. Su dificultad radica en la definición adecuada de la función de semejanza, al no existir una función de semejanza general apropiada para cualquier problema.

### **Características generales del modelo agrupamiento conceptual de extracción y modelado del conocimiento**

Para la creación de la base de conocimiento es necesario realizar un arduo proceso de revisión del conocimiento público existente, así como el conocimiento que poseen los expertos en el dominio, conocimiento privado.

El conocimiento público incluye las definiciones, hechos y teorías publicadas, pero la experticia usualmente incluye más que esta clase de conocimiento. Los expertos humanos generalmente poseen conocimiento privado. Sobre el conocimiento público hay consenso, el privado puede llevar a polémicas entre los expertos.

Esta investigación se centra en el conocimiento público, basado en que existe un volumen de información grande a partir del cual se puede extraer conocimiento para su posterior modelación.

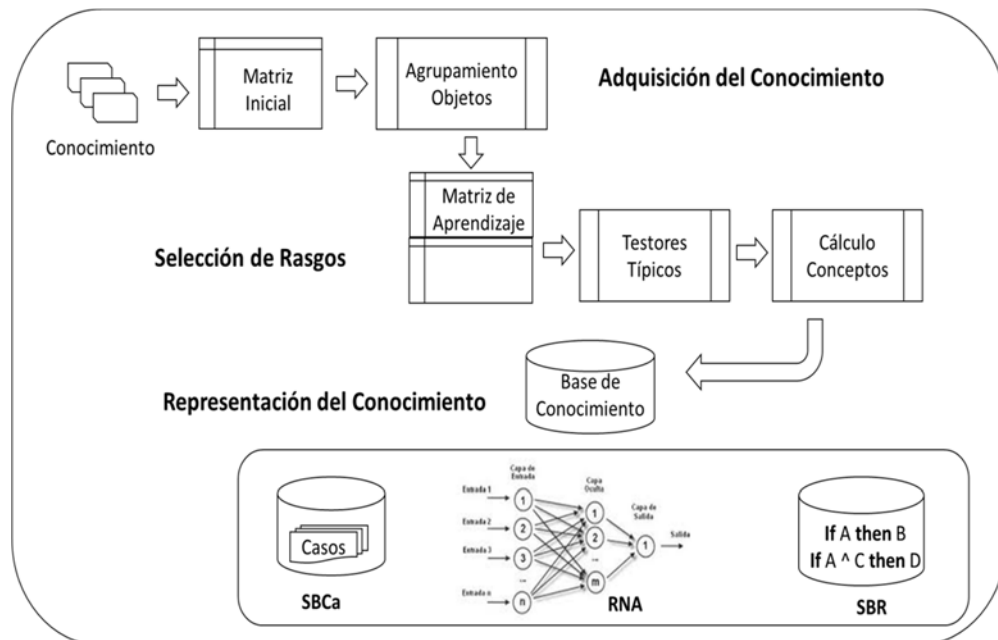
En este trabajo se asume la representación de la información a través de una matriz, independientemente de que se esté en presencia de un problema supervisado o no supervisado. Si el problema es supervisado se trabaja con una matriz de aprendizaje (MA) de  $n$  rasgos que describen los objetos (columnas),  $m$  de objetos (filas) y  $k$  clases. Si el problema es no supervisado se representa a través de una matriz inicial (MI) donde se desconocen las clases.

Independientemente del tipo de SBC es necesaria la selección de rasgos para la descripción de los objetos. Este problema conlleva a la determinación de un subconjunto de rasgos que de una mejor manera caracterizan a los objetos de cada una de las clases. Sobre esta base estos rasgos presentan mayor eficiencia en cuanto a reconocer y clasificar a los nuevos objetos.

Otro aspecto es que dentro del conjunto de rasgos que se seleccionan no todos tienen la misma importancia y esta diferencia debe tenerse en cuenta para comparar objetos. En los SBC dentro de los criterios más comúnmente utilizados en el cálculo de la importancia de cada rasgo están: criterio de los especialistas del dominio de aplicación, dispersión de los valores del rasgo, frecuencia del valor dado al rasgo, carácter diferenciante del rasgo, fuerza predictiva del rasgo, entre otros.

En el enfoque lógico combinatorio una alternativa de solución al problema de la selección de rasgos es a partir de la utilización del conjunto de testores típicos. En esencia, un testor es un conjunto de características (rasgos) que diferencia a elementos (objetos) de clases distintas. Los testores típicos constituyen variantes minimales de subconjuntos de rasgos, existiendo algoritmos que permiten calcular la importancia del rasgo a partir de éstos (Lazo-Cortes, Ruiz-Shulcloper, & Alba-Cabrera, 2001), (Martínez, León, & García, 2007).

En (Alganza & Porrata, 2003) se hace referencia a artículos donde se pueden encontrar ejemplos de algoritmos para el cálculo de los testores típicos tales como CC, CT, BT, TB, REC y CER. Además, se describe el algoritmo LEX, haciendo un análisis comparativo con los algoritmos antes señalados. Estos algoritmos están basados en el concepto de testor típico descrito en (Carrasco-Ochoa, Ruiz-Shulcloper, & De-la-Vega-Doría, 2004).



**Figura 2.** Proceso de Ingeniería del Conocimiento (Elaboración Propia)

Las ventajas de los SBC en la solución de problemas en diferentes áreas del saber son ampliamente reconocidas, por lo que en este trabajo nos centraremos en cómo puede ser útil la teoría del agrupamiento conceptual para atenuar las principales limitantes en los diferentes tipos de SBC.

Los pasos esenciales para el proceso de ingeniería del conocimiento utilizando el agrupamiento conceptual, ilustrado en la figura 2, se describen a través de tres tipos de SBC: Sistema Basado en Casos, Redes Neuronales Artificiales y Sistemas Basados en Reglas.

### Sistema Basado en Casos

El Razonamiento Basado en Casos (RBC) (J. Kolodner, 1993), (Sánchez, Lorenzo, & Valdivia, 2009), es un enfoque que aborda nuevos problemas tomando como referencia problemas similares resueltos en el pasado. De modo que problemas similares tienen soluciones similares, y la similitud juega un rol esencial (Rodríguez & García, 2007). Sus componentes fundamentales son la base de casos, el módulo de recuperación de casos y el módulo de adaptación de las soluciones.

La base de casos (BC) contiene las experiencias, ejemplos o casos a partir de los cuales el sistema realiza sus inferencias. Esta base puede ser generada a partir de casos o ejemplos resultantes del trabajo de expertos humanos o por un procedimiento automático o semiautomático que construye los casos desde datos existentes registrados, por ejemplo, en una base de datos.

En el módulo de recuperación se accede y se recuperan de la BC los casos más semejantes al problema. No existe una medida de semejanza única, general, para cualquier dominio, de ahí que una arista importante en la eficiencia del sistema radica en la función de similitud que se defina.

Un razonador basado en casos depende de la estructura y el contenido de la base de conocimiento. Hasta el presente, para resolver el problema de organizar una BC, un enfoque ha sido almacenar los casos de forma secuencial y analizarlos todos para resolver el nuevo problema. Este tipo de organización hace lento el proceso de recuperación.

Un método alternativo consiste en particionar los casos en grupos y organizarlos jerárquicamente. Esta jerarquía permite una búsqueda más eficiente ya que se sigue por un determinado camino en dependencia de los valores de los rasgos predictores del nuevo problema, pero no garantiza encontrar la solución óptima.

La selección de rasgos es cuestión central tanto en la definición del modelo de la base de casos como en el modelo de recuperación de casos. Potencialmente, en el conjunto de casos podrían estar todas las propiedades que describen los objetos; pero existen rasgos inútiles que carecen de importancia de acuerdo al dominio de aplicación.

El conjunto de rasgos determina qué información será almacenada en memoria para cada uno de sus elementos, la cual debe permitir la posterior recuperación de los casos semejantes dada la descripción de un nuevo problema. Otro aspecto es que dentro del conjunto de rasgos que se seleccionan no todos tienen la misma importancia y esta diferencia debe tenerse en cuenta para comparar casos.

Las limitantes de los sistemas basados en casos están en la definición de la función de semejanza y en lo difícil que resulta encontrar una estructura apropiada para describir el contenido de un caso y decidir cómo la memoria de casos debe ser organizada e indexada para un almacenamiento, recuperación y reuso efectivo.

Consecuentemente con las anteriores limitaciones se propone la aplicación 1 utilizando los conceptos.

---

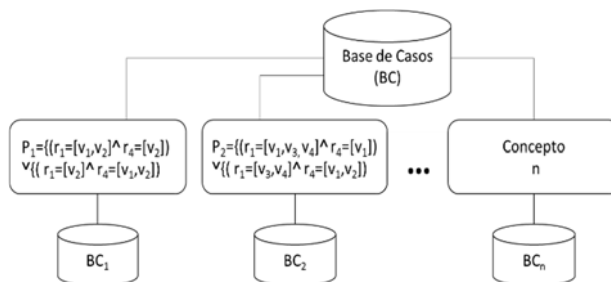
#### **Aplicación 1: Sistemas Basados en Casos**

1. **Modelo de la BC:** puede estructurarse jerárquicamente la BC, donde cada clase está representada por el o los conceptos asociados.
  2. **Módulo de acceso y recuperación:** dado un nuevo caso se compara con el o los conceptos de cada grupo empleando una medida de similitud adaptativa que aprovecha la importancia informacional de los valores de los rasgos, lo cual va a permitir trabajar solo con los casos del grupo seleccionado.
  3. **Módulo de Adaptación:** considerando los casos de dicho grupo como los casos más semejantes y a partir de los mismos, se adapta la solución al nuevo caso reagrupando la BC en dependencia de la tipicidad o no del nuevo ejemplo.
- 

Los modelos jerárquicos son recomendables cuando la base de casos contiene un gran número de casos, pues es más eficiente computacionalmente garantizando a su vez encontrar una solución, pero no necesariamente la óptima. El modelo jerárquico que se propone en este trabajo

es eficaz, pues reduce la complejidad temporal y encuentra la solución óptima, lo cual se garantiza a partir de la característica distintiva de los conceptos de que no existe objeto alguno en otro grupo que satisfaga al mismo.

La figura 3 ilustra un ejemplo de la representación gráfica de la base de casos estructurada a partir de los conceptos.



**Figura 3.** Estructura jerárquica utilizando los conceptos (Elaboración Propia)

### Redes Neuronales Artificiales

Una red neuronal artificial (RNA) es un modelo computacional que pretende simular el funcionamiento del cerebro a partir del desarrollo de una arquitectura que toma rasgos del funcionamiento de este órgano sin llegar a desarrollar una réplica del mismo.

Las redes neuronales o sistemas neuronales artificiales constituyen en la actualidad un activo campo multidisciplinar, en el que confluyen investigadores procedentes de diferentes áreas como la electrónica, física, matemáticas, ingeniería, biología o psicología.

En las RNA la adquisición del conocimiento incluye la selección de los ejemplos, el diseño de su topología y el entrenamiento de la red para hallar el conjunto de pesos. Facilitan el trabajo con información incompleta y brindan algoritmos poderosos de aprendizaje para crear la base de conocimiento; pero requieren de muchos ejemplos y son cajas negras que no explican cómo la solución se alcanza.

Existen dos tipos principales de aprendizaje en RNA: el aprendizaje supervisado, con este tipo de aprendizaje, se proporciona a la red un conjunto de datos de entrada y la respuesta correcta. El conjunto de datos de entrada es propagado hacia delante hasta que la activación alcanza las neuronas de la capa de salida. Entonces se puede comparar la respuesta calculada por la red con aquella que se desea obtener, el valor real (objetivo). Luego se ajustan los pesos para asegurar que la red produzca de una manera más probable una respuesta correcta en el caso de que se vuelva a presentar el mismo o similar patrón de entrada. Este tipo de aprendizaje será útil especialmente para las tareas de regresión y clasificación. Por otra parte, si se está en presencia de un aprendizaje no supervisado, sólo se proporciona a la red un conjunto de datos de entrada.

La red debe auto-organizarse (es decir, auto enseñarse) dependiendo de algún tipo de estructura existente en el conjunto de datos de entrada.

Las RNA deben “aprender” cómo procesar la información de entrada antes de que ésta pueda ser utilizada en una aplicación. El proceso de entrenamiento de una RNA involucra el ajuste de los pesos de entrada de cada neurona hasta que la salida de la red se aproxima a la salida deseada. El procedimiento comprende la creación de un conjunto de entrenamiento, el cual está formado por los datos de cada neurona de entrada y la respuesta deseada para cada neurona de salida. Una vez entrenada la RNA dado un nuevo dato de entrada ésta recuerda lo “aprendido” durante el entrenamiento y da la respuesta.

Una de las desventajas principales de las RNA es que hay que realizar múltiples pruebas para determinar la arquitectura (topología de la red) adecuada. El entrenamiento es costoso computacionalmente. Por otra parte, todo SBC requiere de un módulo de explicación de la respuesta, he aquí otra desventaja de las RNA.


En las RNA también es válido el empleo de los conceptos teniendo permitiendo su extensión como se describe en la aplicación 2.

---

#### **Aplicación 2: Redes Neuronales Artificiales**

1. **Base de Conocimiento:** es posible conformar y estructurar el conjunto de entrenamiento con los conceptos asociados a cada clase. También posibilita organizar la secuencia y frecuencia de presentación de estos ejemplos al entrenamiento.
  2. **Topología de la red:** la cantidad de neuronas de la capa de salida se determina a partir de la cantidad de grupos que se forman, el número de neuronas de la capa oculta se corresponde con la cantidad total de conceptos generados y el modelo de la neurona se puede definir según los conceptos. Esto permite contar con una heurística para el diseño de la topología de la red.
  3. **Conjunto inicial de pesos:** es posible definirlo a partir de la relevancia asociada a cada rasgo que conforma el concepto o utilizar las métricas propuestas en (Reyes González, Martínez Sánchez y García Lorenzo 2015) y (Reyes González, Rodríguez Vallejo, Martínez Sánchez, & Yero Oses, 2016) lo cual permite comenzar el entrenamiento de la red con un conjunto de pesos que ubican el proceso de entrenamiento en un punto cercano al mínimo global de la superficie de error, evitando que sean pesos aleatorios como se recomienda en la literatura.
-

Un ejemplo del diseño de una Red Neuronal Artificial de tipo Perceptron Multicapa se ilustra en la figura 4.



**Figura 4.** Topología de un perceptron multicapa utilizando los conceptos

### Sistemas Basados en Reglas

Los sistemas basados en reglas (SBR) son altamente modulares. Cada regla es una unidad de conocimiento que puede ser añadida, modificada o removida independientemente de las otras reglas existentes. Esto da flexibilidad en el desarrollo de la BC. Todo el conocimiento del sistema se expresa en el mismo formato.

Las reglas son un formato natural para expresar conocimiento en algunos dominios. Los expertos lógicamente piensan en los problemas y sus soluciones usando las situaciones existentes para indicar las conclusiones deseadas.

Una regla es una afirmación lógica que relaciona dos o más objetos e incluye dos partes, la premisa y la conclusión. Cada una de estas partes consiste en una expresión lógica con una o más afirmaciones objeto-valor conectadas mediante los operadores lógicos (“y”, “o”, “no”). Una regla se escribe normalmente como “Si premisa, entonces conclusión”. En general, ambas, la premisa y la conclusión de una regla, pueden contener afirmaciones múltiples objeto-valor.

El conocimiento se almacena en la base de conocimiento y consiste en un conjunto de objetos y un conjunto de reglas que gobiernan las relaciones entre esos objetos.

En un SBR hay dos tipos de elementos: los datos (hechos o evidencia) y el conocimiento (el conjunto de reglas almacenado en la base de conocimiento). El motor de inferencia usa ambos para obtener nuevas conclusiones o hechos.

En la construcción de un SBR uno de los procesos de mayor complejidad es la formalización del conocimiento a través de reglas, para lo cual es necesario inicialmente seleccionar las variables que definen las premisas para inferir la conclusión. Además, es necesario construir un módulo de explicación para las conclusiones que se obtienen que no puede ser explícitamente las reglas utilizadas por el motor de inferencia el encadenamiento para la inferencia, ya sea para obtener las conclusiones.

Otro aspecto a tener en cuenta y presente en los SBR es que los humanos actúan cotidianamente sobre la base de información parcial. La información imperfecta es omnipresente casi toda la información que se tiene sobre el mundo es no cierta, completa o precisa, por lo que si se quiere resolver problemas reales hay que considerar la incertidumbre. La cual puede estar presente tanto en los datos (valores que toman las variables) como en las conclusiones, si se tiene en cuenta la certeza con la que se arriba a la misma.

En correspondencia con las dos características principales que limitan el potencial de un SBR utilizando los conceptos se propone la aplicación 3.

---

### Aplicación 3: Sistemas Basados en Reglas

1. **Generar las reglas:** a partir del conjunto de valores de los rasgos presentes en los conceptos se conforman las premisas, obteniéndose las reglas.
  2. **Razonamiento con incertidumbre:** los valores que se obtienen utilizando las métricas propuestas en (Reyes-González, Rodríguez-Vallejo, et al. 2016) pueden considerarse como el grado de certeza del valor de cada variable y de cada regla y de esta forma aplicar un modelo de tratamiento de la incertidumbre descrito en la literatura afín.
  3. **Módulo explicativo:** la misma obtención del conocimiento utilizando las reglas permite una explicación natural de los resultados, lo que se beneficia aún más con la agrupación de las reglas de acuerdo a los conceptos de cada grupo.
- 

Las reglas obtenidas a partir de los conceptos se ilustran como se describe en el ejemplo 2.

**Ejemplo 2:** A partir del concepto:

$$P = \{ (r_1 = [v_1, v_2] \wedge r_4 = [v_2]) \vee \{ (r_1 = [v_2] \wedge r_4 = [v_1, v_2]) \} \}$$

se puede extraer una regla más general de la forma:

$$R_1: \text{If } (r_1 v_1 \vee r_1 v_2 \wedge r_4 v_2) \vee (r_1 v_2 \vee r_4 v_1 \wedge r_4 v_2) \rightarrow G_1$$

o descomponer esta, en dos reglas de la forma:

$$R_1: \text{If } (r_1 v_1 \vee r_1 v_2 \wedge r_4 v_2) \rightarrow G_1 \quad \text{y} \quad R_2: \text{If } (r_1 v_2 \vee r_4 v_1 \wedge r_4 v_2) \rightarrow G_1$$

## CONCLUSIONES

El objetivo principal de este trabajo no es mostrar el uso de los conceptos del reconocimiento lógico combinatorio de patrones en la implementación de un SBC como una alternativa sumamente ventajosa ante otras que ya existen y han sido validadas con éxito en disímiles aplicaciones. La esencia del trabajo es resaltar las propiedades tan valiosas que tienen los conceptos para ser utilizados en la construcción de este tipo de sistemas inteligentes y que a criterio de los autores han sido poco utilizados.

Por otra parte debe señalarse la estrecha relación existente entre el agrupamiento conceptual y el proceso de ingeniería del conocimiento necesario para desarrollar sistemas inteligentes. El carácter complementario de ambos enfoques permite la exitosa utilización de los conceptos como parte de la extracción y modelado del conocimiento.

La propuesta de utilizar los algoritmos conceptuales puede parecer muy costoso teniendo en cuenta la complejidad computacional de los algoritmos del reconocimiento lógico combinatorio de patrones que se utilizan, tanto los algoritmos para el cálculo de los testores típicos como los utilizados para el cálculo de los conceptos, pero ambos sólo se utilizan durante la etapa de ingeniería del conocimiento implícita en la implementación de un SBC.

## **TRABAJOS FUTUROS**

Este trabajo es el resultado de investigaciones científicas del grupo de Inteligencia Artificial de la Universidad de las Ciencias Informáticas, la cual tiene dentro de sus misiones desarrollar aplicaciones y servicios informáticos, a partir de la vinculación estudio-trabajo como modelo de formación. La universidad cuenta con una red de centros de desarrollo de software agrupados en cinco grandes áreas del saber; Salud, Educación, Administración Pública, Telemática y Empresa-Industria que se comercializan bajo la estrategia marcara XAVIA, XAUCE, XEDRO, XILEMA y XABAL respectivamente. La introducción de estos resultados científicos en el desarrollo de estos software permite dar un valor agregado a los mismos influyendo tanto en su eficacia como en su nivel de comercialización.

En (Reyes González, Claro Arceo, et al., 2016) y (Reyes González & Martínez Sánchez, 2014) se describe detalladamente la primera de las aplicaciones propuestas en esta investigación, donde se utilizan los algoritmos conceptuales lógico-combinatorios en el proceso de Ingeniería del Conocimiento para la construcción de un Sistema Basado en Casos, así como su validación y para la implementación de un Sistema Tutorial Inteligente respectivamente. Las aplicaciones en los Sistemas Basados en Reglas y en las Redes Neuronales Artificiales constituyen el propósito de futuras investigaciones en las que trabajan los autores.

El análisis en torno a la utilidad de los conceptos en la construcción de sistemas basados en casos, sistemas basados en reglas y el diseño de redes neuronales artificiales, sugiere la posible utilización de estos hacia la concepción de otros modelos de la inteligencia artificial como por ejemplo la construcción de clasificadores basados en árboles de decisión.

## **REFERENCIAS**

- Alganza, Y. S., & Porrata, A. P. (2003). LEX: Un nuevo algoritmo para el cálculo de los Testores Típicos. *Ciencias Matemáticas*, 21(1).
- Angele, J., Fensel, D., Landes, D., & Studer, R. (1998). Developing knowledge-based systems with MIKE. In *Domain Modelling for Interactive Systems Design* (pp. 9–38). Springer.

- Bello, R. (2002). *Aplicaciones de la inteligencia artificial*. Ediciones de La Noche, Guadalajara, Jalisco, México. ISBN, 970(27), 0177.
- Brazier, F. M., Dunin-Keplicz, B. M., Jennings, N. R., & Treur, J. (1997). Desire: Modelling multi-agent systems in a compositional formal framework. *International Journal of Cooperative Information Systems*, 6(01), 67–94.
- Buchanan, B. G., Barstow, D., Bechtal, R., Bennett, J., Clancey, W., Kulikowski, C., ... Waterman, D. A. (1983). Constructing an expert system. *Building Expert Systems*, 50, 127–167.
- Carrasco-Ochoa, J. A., Ruiz-Shulcloper, J., & De-la-Vega-Doría, L. A. (2004). Feature selection using typical  $\epsilon$ : Testors, working on dynamical data. In *Iberoamerican Congress on Pattern Recognition* (pp. 685–692). Springer.
- Castillo, E., Gutierrez, J. M., & Hadi, A. S. (2012). *Expert systems and probabilistic network models*. Springer Science & Business Media.
- Cuena, J., & Molina, M. (1997). KSM: an environment for design of structured knowledge models. *Knowledge-Based Systems: Advanced Concepts, Techniques and Applications*.
- Eriksson, H., Shahar, Y., Tu, S. W., Puerta, A. R., & Musen, M. A. (1995). Task modeling with reusable problem-solving methods. *Artificial Intelligence*, 79(2), 293–326.
- García, C. M. A., Honey, P., & Gil, D. J. G. (1994). Los estilos de aprendizaje: procedimientos de diagnóstico y mejora.
- Guida, G., & Tasso, C. (1995). *Design and development of knowledge-based systems: from life cycle to methodology*. John Wiley & Sons, Inc.
- Hilera González, J. R., & Martínez Hernando, V. J. (1995). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Addison-Wesley.
- Kolodner, J. (1993). 10 - Indexing and Retrieval. In *Case-Based Reasoning* (pp. 369–389). San Francisco (CA): Morgan Kaufmann. Retrieved from <http://www.sciencedirect.com/science/article/pii/B9781558602373500169>
- Kolodner, J. L. (1992). An introduction to case-based reasoning. *Artificial Intelligence Review*, 6(1), 3–34. <https://doi.org/10.1007/BF00155578>
- Lazo-Cortes, M., Ruiz-Shulcloper, J., & Alba-Cabrera, E. (2001). An overview of the evolution of the concept of testor. *Pattern Recognition*, 34(4), 753–762.
- Martínez, N., León, M., & García, Z. (2007). Features selection through FS-testors in case-based systems of teaching-learning. *MICAI 2007: Advances in Artificial Intelligence*, 1206–1217.
- Martinez Sanchez, N. (2009). *Modelo para diseñar Sistemas de Enseñanza-Aprendizaje Inteligentes utilizando el Razonamiento Basado en Casos*. (Tesis en opción al grado científico de Doctor en Ciencias Técnicas). Universidad Central “Marta Abreu” de Las Villas, Santa Clara.
- Martinez-Trinidad, J. F., & Sánchez-Díaz, G. (2001). LC: A Conceptual Clustering Algorithm. In P. Perner (Ed.), *Machine Learning and Data Mining in Pattern Recognition: Second International Workshop, MLDM 2001 Leipzig, Germany, July 25–27, 2001 Proceedings* (pp. 117–127). Berlin, Heidelberg: Springer Berlin Heidelberg. Retrieved from

[http://dx.doi.org/10.1007/3-540-44596-X\\_10](http://dx.doi.org/10.1007/3-540-44596-X_10)

- Palma, J. T., Paniagua, E., Martín, F., & Marín, R. (2000). Ingeniería del Conocimiento. De la Extracción al Modelado de Conocimiento. *Revista Iberoamericana de Inteligencia Artificial*, (11), 46–72.
- Reyes González, Y., Claro Arceo, A., Martínez Sánchez, N., & Hernández Domínguez, A. (2016). Combinatorial logic conceptual clustering: an alternative to Decision Making. *Revista Iberoamericana de Inteligencia Artificial*, 19(57), 82–96.
- Reyes González, Y., & Martínez Sánchez, D. N. (2014). La toma de decisiones en los Sistemas Tutoriales Inteligentes utilizando el agrupamiento conceptual. *Revista Cubana de Ciencias Informáticas*, 8, 104–116.
- Reyes Gonzalez, Y., Martinez Sanchez, N., & Garcia Lorenzo, M. M. (2015). El agrupamiento conceptual en el contexto de la teoría de los conjuntos aproximados. *DYNA New Technologies*, 2(1). Retrieved from <http://www.dyna-newtech.com/busqueda-NT/el-agrupamiento-conceptual-en-contexto-de-teoria-de-conjuntos-aproximados-2>
- Reyes González, Y., Rodríguez Vallejo, L., Martínez Sánchez, N., & Yero Oses, E. A. (2016). Métricas para la validación de los conceptos en el Reconocimiento Lógico Combinatorio de Patrones. Presented at the XVI Convención y Feria Internacional INFORMÁTICA 2016, La Habana. Retrieved from <http://www.informaticahabana.cu/sites/default/files/ponencias/CCI55.pdf>
- Rich, E., & Knight, K. (1988). *Inteligencia artificial*. Ed McGraw-Hill ISBN 0-07-450364-2.
- Rodríguez, Y., & García, M. (2007). Generalización de la métrica basada en la diferencia de valores (VDM) para variables lingüísticas y su aplicación en sistemas basados en el conocimiento. Tesis presentada en opción del grado científico de Doctor en Ciencias Técnicas. UCLV.
- Ruiz-Shulcloper, J. (2009). Reconocimiento lógico combinatorio de patrones: teoría y aplicaciones (Tesis en opción al grado científico de Doctor en Ciencias). Universidad Central de Las Villas, Santa Clara.
- Sánchez, N. M., Lorenzo, M. M. G., & Valdivia, Z. Z. G. (2009). Modelo para diseñar sistemas de enseñanza-aprendizaje inteligentes utilizando el razonamiento basado en casos. *Avances En Sistemas e Informática*, 6(3), 67–78.
- Schreiber, G., Wielinga, B., de Hoog, R., Akkermans, H., & Van de Velde, W. (1994). CommonKADS: A comprehensive methodology for KBS development. *IEEE Expert*, 9(6), 28–37.
- Shadbolt, N., Motta, E., & Rouge, A. (1993). Constructing knowledge-based systems. *IEEE Software*, 10(6), 34–38.
- Steels, L. (1993). The componential framework and its role in reusability. *Second Generation Expert Systems*, 273–298.

Artículo recibido: 11/04/2017  
Artículo publicado: 26/10/2017

*Editor in Chief: Prof. Dr. Luis Camilo Ortigueira-Sánchez*