

AI-CLUSTER

Volumen 1, número 1 Del conocimiento y otros temas



Agosto - Diciembre 2018

DERECHOS DE AUTOR Y DERECHOS CONEXOS, año 1, No. 1, Agosto - diciembre 2017, es una Publicación semestral editada por el Clúster de Inteligencia Artificial (Ai Cluster), Bulevar Tomás Fernández 8945, Parques Industriales, 32470 Cd. Juárez, Chih. Tel. (656) 2027902, <https://aicluster.org/> Editor responsable: Jorge Rodas Osollo. Reserva de Derechos al Uso Exclusivo No. 00-2018-00000000-000, ISSN: 0000-0000, ambos otorgados por el Instituto Nacional del Derecho de Autor. Responsable de la última actualización de este Número, Ai Cluster, Víctor Hernández, Bulevar Tomás Fernández 8945, Parques Industriales, 32470 Cd. Juárez, Chih., 1 de enero de 2018.

Redes Simbólicas Causales

Por Jorge Rodas-Osollo

Resumen

Para que una base de datos lógica represente fielmente nuestras creencias acerca del mundo, no basta con que sea consistente por lógica sino deberá ser consistente causal.

Intuitivamente, una base de datos es consistente causal si esta soporta cambios en creencias que contradicen nuestras percepciones de las influencias causales. Por ejemplo, cómo podríamos concluir que ha llovido, solo por que no hemos dado cuenta que lloviznó.

1. Noción de una estructura causal para la representación de nuestras percepciones de las influencias causales.
2. Se provee de una definición formal del cuando, una base de datos es consistente causal dada una estructura causal.
3. Introducción de redes causales como una herramienta para construir bases de datos, con garantía de que serán consistentes causales.
4. Algunas aplicaciones de consistencia causal y sus redes, incluyendo razonamiento no-monotónico, Dempster - Shafer, mantenimiento verdadero y razonamiento acerca de acciones.

Introducción.

Considerando la Base de Datos :

$$\Delta = \text{suelo_húmedo} \supset \text{ha_llovido} \\ \text{lloviznó} \supset \text{suelo_húmedo}$$

la cual no proporciona creencia alguna de sí ha llovido la noche anterior : Δ ha_llovido y $\Delta \not\supset \neg \text{ha_llovido}$. Sorprendentemente, si le decimos a esta BD que lloviznó, entonces concluye que ha llovido la noche anterior : $\Delta \cup \{\text{lloviznó}\} \supset \text{ha_llovido}$. Dado que no se percibe una conexión causal entre lloviznó y lluvia, no debemos creer que ha llovido solo porque haya lloviznado.

Como esta BD soporta cambios de creencia que contradicen las percepciones comunes de las influencias causales, le denominaremos *inconsistencia causal*.

Suponiendo que los expertos en BD construyan una BD consistente causal, es común que ésta se transforme en inconsistente causal durante el proceso de aumento de la misma. Por ejemplo :

$$\Delta = \text{suelo_húmedo} \wedge \neg \text{ab1} \supset \text{ha_llovido} \\ \text{lloviznó} \wedge \neg \text{ab2} \supset \text{suelo_húmedo}$$

Ésta es consistente causal porque mantiene una ignorancia sobre la lluvia dada la información de la llovizna. Sin embargo, un formalismo no-monotónico que minimiza anomalías convertirá a Δ en :

$$\text{la BD } \Delta' : \text{suelo_húmedo} \wedge \neg \text{ab1} \supset \text{ha_llovido} \\ \text{lloviznó} \wedge \neg \text{ab2} \supset \text{suelo_húmedo}$$

$$\neg ab1 \wedge \neg ab2$$

que es inconsistente causal porque encuentra que lloviznó es evidencia suficiente para afirmar que ha llovido : $\Delta' \text{ ha_llovido}$ y $\Delta' \cup \{\text{lloviznó}\} \text{ ha_llovido}$.

Causalidad y Cambio de Creencia.

Dado que la consistencia causal es relativa a percepciones específicas de influencias causales, formalizar consistencia causal requiere de una percepción para representarla formalmente.

Para este propósito, se adoptan las estructuras causales, las cuales son DAG's.




Fig. 1 Estructura causal

Fig. 2 Estructura Causal.

Los padres de una proposición p en una estructura causal corresponden a sus causas directas. Los descendientes de p son denominados sus efectos y los no descendientes de p, no efectos. En la figura 2, bebido y lesionado son las causas directas de no_puede_sostenerse, no_puede_sostenerse y licor son efectos de bebido; mientras que lesionado y manchas de sangre son sus no efectos.

Las proposiciones que son relevantes para el dominio en consideración, pero que no aparecen en la estructura causal se llaman proposiciones exógenas de la estructura. Éstas son la fuente de incertidumbre en las influencias causales. Aparecen como predicados anormales en el razonamiento no-monotónico, como símbolos supuestos en ATMS y como perturbaciones aleatorias en modelos de causalidad probabilísticos. Cada estado de proposiciones exógenas será referenciado como extensión. Por ejemplo, si ab1 y ab2 son proposiciones exógenas de la figura 1, entonces $\neg ab1 \wedge ab2$ es una extensión de la estructura, donde ya no debe existir incertidumbre alguna acerca de las influencias causales que esta representa.

Lo que se pretende es que los cambios en nuestras creencias no afecten a las estructuras causales. Entonces si las restricciones son precisas, una BD es consistente con una estructura causal cuando ésta no contradiga cada restricción. La clave para formalizar las restricciones esta en la siguiente interpretación de estructuras causales : "La certidumbre de cada proposición en una estructura causal esta funcionalmente determinada por : a) La certidumbre de sus causas directas y b) La certidumbre de todas las proposiciones exógenas."




Fig. 3 Interacciones Causales

De esta interpretación se desprenden las siguientes restricciones en los cambios de creencias de la estructura causal.

Causas Comunes. (Fig. 3a) La creencia c_2 debe ser independiente de c_1 asumiendo que ninguna información esta disponible sobre e y que todas las proposiciones exógenas son conocidas.

Efectos Indirectos. (Fig. 3b) La creencia e debe ser independiente de c , siempre que la proposición m y todas las propiedades exógenas sean conocidas.

Efectos Comunes. (Fig. 3c) La creencia e_2 debe ser independiente de e_1 dado que la proposición c y todas las propiedades exógenas sean conocidas.

Estas restricciones están contenidas en el principio de independencia causal. Este dice que : "una vez que las proposiciones exógenas y las causas directas de la proposición sean conocidas, la creencia en esa proposición debe ser independiente de sus no-efectos.

Ahora necesitamos definir cuando una BD Δ encuentra a X independiente condicional de Y dado Z , esto es, cuando si adiciona información sobre Y a la Δ y no se tienen cambios en sus creencias sobre X dado que Δ tiene demasiada información (esta saturada) sobre Z .

Definición 1 (Independencia Condicional). Sean X , Y y Z conjuntos disyuntos de proposiciones atómicas y sean X , Y y Z intenciones de esas proposiciones respectivamente. La BD Δ encuentra X independiente de Y dado Z precisamente cuando la consistencia lógica de $\Delta \cup \{Z, X\}$ y $\Delta \cup \{Z, Y\}$ implica consistencia lógica de $\Delta \cup \{Z, Y, X\}$. Esto equivale a decir que si Δ esta saturada de información sobre Z , entonces adicionar información sobre Y a la Δ no cambiará su creencia sobre X . Por ejemplo, $\text{ha_llovido} \cup \text{llovizó} \equiv \text{suelo_húmedo}$, encuentra $\{\text{ha_llovido}\}$ independiente de $\{\text{llovizó}\}$, pero las encuentra dependientes dado $\{\text{suelo_húmedo}\}$.

Definición 2 (Independencia Causal). La BD Δ satisface el principio de independencia causal con respecto a la estructura causal G cuando : a) Δ es consistente lógicamente y b) para cada extensión ε de G que es consistente lógica con Δ , la BD $\Delta \cup \{\varepsilon\}$ encuentra cada proposición en G independiente condicional de sus no-efectos dadas sus causas directas.

Consistencia Causal.

Sí $\Delta = \text{suelo_húmedo} \wedge \neg ab_1 \supset \text{ha_llovido}$

$\text{llovizó} \wedge \neg ab_2 \supset \text{suelo_húmedo}$

esta BD no satisface el principio de Independencia Causal con respecto a la figura 1 porque encuentra llovizó como evidencia suficiente para establecer que ha_llovido, considerando la extensión $\neg ab_1 \wedge \neg ab_2$.

Definición 3 (Consistencia Causal). Sea Δ una BD y G una estructura causal. Una extensión ε de G es consistente causal con Δ cuando $\Delta \cup \{\varepsilon\}$ satisface el principio de independencia causal con respecto a G .

Esto es, la extensión $\neg ab1 \wedge \neg ab2$ es inconsistente causal con Δ , mientras el remanente de la extensión $\neg ab1 \wedge ab2$, $ab1 \wedge \neg ab2$ y $ab1 \wedge ab2$ son consistentes causales con Δ .

Con esto podemos asegurar que una BD es consistente causal cuando al menos una extensión sea consistente causal. Recordando, por más que se tengan todos los cuidados con el dominio del experto a la hora de construir BD consistentes causales, es común que un formalismo no-monotónico la convierta en inconsistente.

Una forma de evitar esta situación sería informar a los formalismos no-monotónicos acerca de la consistencia causal y dando acceso a las estructuras causales. Un formalismo no-monotónico debe entonces insistir en que sólo las extensiones consistentes causales sean seleccionadas.

Otra posibilidad es alimentar a los formalismos no-monotónicos con BD que ya satisfagan el principio de independencia causal. En este caso, los formalismos no-monotónicos no necesitan saber sobre la causalidad, se garantizará así que cualquier extensión que es lógicamente consistente con la BD también es consistente causal.

Redes Simbólicas Causales.

Una red simbólica causal tiene dos componentes : una estructura causal G que refleja las percepciones de las influencias causales y un conjunto de microteorías que sustentan a las relaciones lógicas entre las proposiciones y sus causas directas.

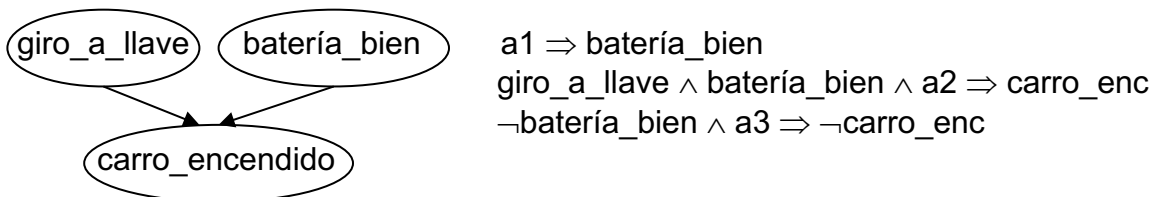


Fig. 4 Red Simbólica Causal.




Fig. 5 Diferentes Redes Simbólicas Causales.

Una microteoría para p es un conjunto de cláusulas δ , donde :

1. Cada cláusula en δ es referida solo a p, sus causas directas y a las proposiciones exógenas.

2. Si δ tiene una cláusula que no aparece en p , entonces esa cláusula deberá ser vacuous.

La primera condición asegura la localidad de una microteoría para una proposición y sus causas directas, mientras que la segunda condición prohíbe una microteoría para p de la especificación de la relación entre las causas directas de p . Podemos asegurar las condiciones previas mediante la adición de microteorías que contienen solo dos tipos de implicaciones materiales :

$\psi \wedge \alpha \supset p$ y $\phi \wedge \beta \supset \neg p$, donde :

1. ψ y ϕ son construidos a partir de las causas directas de p .
2. α y β son construidos a partir de las proposiciones exógenas.
3. $\alpha \wedge \beta$ no se satisface cuando $\psi \wedge \phi$ si.

Formalmente, una microteoría contiene sentencias de proposiciones estándar, restringida solo por su localidad (para proposiciones específicas) y mediante lo que podemos expresar sobre esas proposiciones, ambas son características del modelado causal.

Teorema 1. Sea Δ una BD inducida por una red simbólica causal de estructura G . Entonces Δ satisface el principio de independencia causal con respecto a G . Como un lenguaje representativo, las redes simbólicas causales son completas con respecto a las BD que no restrinjan el estado de las proposiciones exógenas.

Teorema 2. Sea Δ una BD que satisface el principio de independencia causal con respecto a una estructura causal G . Si Δ es consistente lógica con cada extensión de G , entonces Δ puede ser inducida por una red simbólica causal que tenga a G como su estructura.

Aplicaciones de las Redes Simbólicas Causales.

La motivación básica por éstas redes, es que garantizan la consistencia causal. Sin embargo, éstas pueden ser vistas como redes causales probabilísticas y extenderse a sus múltiples aplicaciones.

Consistencia Lógica. Una de las más celebres características de las redes causales probabilísticas es su habilidad de asegurar la consistencia global de la distribución de probabilidades que representa, tanto como las probabilidades asociadas con cada proposición en una estructura causal localmente consistente. Las redes simbólicas causales proveen una garantía similar : en la medida en que las microteorías asociadas con proposiciones individuales satisfagan sus propias condiciones locales, la BD global tiene la garantía de ser consistente lógica (Teorema 1).

Mantenimiento de la Certidumbre Causal. Las RSC tienen soporte en algoritmos que procesan etiquetas ATMS. Por consecuencia heredan las aplicaciones de las ATMS. La diferencia más importante radica en que la BD de las RSC nos protegen de conclusiones que colisionan con nuestro entendimiento del dominio causal.

Razonamiento sobre acciones. Percepciones de influencias causales incluso restringen cambios en creencias que resultan de intervenciones (llamadas actualizaciones de creencias).

La razón por la cual una misma acción conlleva a diferentes resultados desde dos descripciones lógicas equivalentes, pues las descripciones están acompañadas de estructuras causales diferentes.

Conclusión.

Si una BD lógica clásica se tiene como una representación fiel de nuestras creencias sobre el mundo, entonces deberá ser consistente con nuestras percepciones de influencias causales. Para esto se propuso un lenguaje para la representación de cada percepción y formalizar la consistencia de una BD lógica con relación a una estructura causal dada.

También se propuso la utilización de RSC como herramienta de construcción de BD consistentes causales.

Referencia.

Darwiche, Adnan and Pearl, Judea. Proceedings of the Twelfth National Conference on Artificial Intelligence (Vol. 1).

Url=<http://dl.acm.org/citation.cfm?id=199288.178002>

A cerca de la Teoría Interactiva

Por Jorge Rodas-Osollo

Resumen.

Este artículo describe un sistema multiestrategias de aprendizaje, denominado **Concept - Learning in an INTERactive way** (CLINT), ideado para la revisión de teoría interactiva (RTI). CLINT opera en el marco de la lógica de predicados de primer orden y es representativo del paradigma de programación de lógica inductiva.

Introducción.

La revisión de teoría interactiva consiste en : iniciar con una teoría dada y alguna evidencia nueva que aun no ha sido explicada por la teoría. La finalidad es modificar la teoría para que pueda dar explicación a dicha evidencia. Es interactiva porque admite información adicional por parte del usuario cada que sea necesaria.

En el ámbito de la Inteligencia Artificial se destacan dos áreas donde se utiliza la RTI : *Aprendices de Aprendizaje y la Actualización Intencional de Bases de Conocimiento.*

Aprendices de Aprendizaje. Podríamos denominarlos *Agentes (algo que percibe y actúa de la mejor forma posible ante una situación dada en su entorno) que interactúan supervisando el desempeño del sistema auxiliados por el establecimiento y refinamiento de una Base de Conocimiento durante la operación normal del mismo. La RTI entra en acción cuando el usuario detecta errores generados por el sistema. Una vez que estos se le señalan al aprendiz, el sistema hace la revisión de su teoría para evitar que ocurran errores similares en el futuro.

Actualización Intencional de Bases de Conocimiento. Es una técnica utilizada en Bases de Datos deductivas para actualizarlas de forma inteligente. La actualización clásica de BD consiste en que el usuario tiene que especificar que modificaciones deberán realizarse de forma que actualice el contenido en las BD. Con esta técnica el usuario solo necesita declarar que se lleve a efecto la actualización.

Los autores proponen a CLINT como un marco que sirva de base para la RTI. Su diseño tiene dos objetivos principales :

1) Ser amigable al usuario y 2) Oportunista (cada que tenga oportunidad lleve a cabo la RTI).

Lo cual significa que un revisor de teoría debe ser fácil de enseñar (1) y debe anhelar en todo momento aprender (2).

CLINT incluye : Aprendizaje Inductivo por Concepto, Abducción, Cambio de Sesgos, Aplazamiento y Manejo de la Integridad.

Marco Lógico.

CLINT utiliza un marco lógico para representar su teoría. Donde un concepto p (que en lógica corresponde a un predicado) está definido por un conjunto de cláusulas de Horn, las cuales son expresiones lógicas del tipo : $p(t_1 \dots t_n) \leftarrow q_1(v_{1,1}, \dots v_{1,k_1}) \& \dots \& q_n \dots$

Los términos t_i y $v_{i,j}$ son constantes o variables y las p 's y q 's son predicados. Las variables se expresan en mayúsculas y las constantes en minúsculas. Éstas siempre están cuantificadas universalmente en las cláusulas de Horn. No se requiere por tanto escribir \forall . $p(t_1 \dots t_n)$ es conocido como la cabeza de la cláusula (la conclusión) y $q_1(\dots) \& \dots \& q_n(\dots)$ es el cuerpo (las consecuencias). Las cláusulas de Horn establecen que la cabeza es verdadera siempre que el cuerpo lo sea.

Hay dos tipos de definiciones de predicados de nuestro interés : *Los extensionales y los intencionales*. La definición de predicado extensional consiste en un conjunto de hechos fundamentales, los cuales son cláusulas donde todos los términos t_i son constantes y $m = \emptyset$; ejemplo : $es_legal(joker, joker) \leftarrow$. Los hechos son estatutos incondicionales acerca del mundo, además, siempre son verdaderos. Las definiciones intencionales consisten de un conjunto de cláusulas donde todos los términos t_i y $v_{i,j}$ son variables y todas las de la cabeza de la cláusula puedan presentarse del cuerpo de la misma, ejemplo : $es_legal(X, Y) \leftarrow carta(X) \wedge carta(Y) \wedge roja(X) \wedge negra(Y)$. Una teoría es un conjunto de definiciones intencionales y extensionales.

Dentro del aprendizaje - conceptual, CLINT utiliza ejemplos. Existen dos clases : los positivos y los negativos. Un ejemplo es un hecho fundamental junto a su valor de verdad cuando intenta la interpretación. Ésta, contiene un valor de verdad de todo lo formulado en la teoría objetivo, la cual es la teoría deseada, donde todos los predicados están definidos correctamente. Los positivos son verdaderos cuando se intenta la interpretación, mientras que los negativos son falsos.

Dada una teoría objetivo T , un ejemplo e es cubierto por ésta sí y sólo si e es implicado lógicamente por T .

CLINT incluso utiliza una noción de sesgo relacionado con la descripción de lenguaje de conceptos. Una descripción del lenguaje de conceptos impone restricciones sintácticas en las cláusulas permitidas en la definición de predicados intencionales por ejemplo, el lenguaje L_0 establece que todas las variables que aparecen en el cuerpo de la cláusula también tienen que aparecer en la cabeza de la cláusula. CLINT utiliza esta noción para restringir el espacio de búsqueda de definiciones de predicados cuando revisa su teoría.

Como CLINT es un revisor de teoría interactivo, debe consultar al usuario para dar respuesta a preguntas existenciales y de membresía. Una pregunta de membresía interroga al usuario por el valor de verdad (o clasificación) de un ejemplo en la interpretación intentada.

Una pregunta existencial, se refiere a todas las sustituciones (asignación de términos a variables) θ , cada que $p(a_1, \dots, a_n) \theta$ no contenga variables y sea verdadero en la interpretación intentada. Las preguntas existenciales son generadas por el módulo abductivo.

El problema básico puede quedar definido como :

- Una teoría T que contiene las definiciones de predicados intencionales y / o extensionales.
- Un conjunto de ejemplo positivos y negativos.

- Una definición del lenguaje L.
- Un usuario deseoso de responder preguntas de membresía o existenciales de la interpretación intentada.

Se encontró : Una teoría revisada T' obtenida por adición / retracción de hechos de predicados extensionales de aprendizaje para / desde T y adicionando / retractando cláusulas expresadas en un lenguaje L para predicados intencionales para / desde T_1 cada que T' cubre a todos los positivos y ninguno de los negativos.

Inducción - Abducción.

En muchos casos el procedimiento inductivo de CLINT no es suficiente para resolver todo el problema de revisión de teoría.

Éste procedimiento tiene 2 limitaciones importantes : No permite la adición de hechos a la teoría y éste aprende un predicado, no se toman en cuenta otros predicados. Por lo que si esto se procesa de forma abductiva queda resuelto el problema.

Cambio de Sesgo y Aplazamiento.

Cuando se presentan cláusulas inconsistentes, consideramos una serie de descripciones - conceptuales de lenguaje $L_0, L_1, L_2, \dots, L_n$. Cada L_i impone ciertas restricciones sintácticas en las cláusulas derivadas por CLINT.

Esto significa que si una cláusula puede ser expresada por L_i también lo será por L_{i+1} . Este proceso se hace hasta que se encuentre la cláusula consistente o se detecte que ningún lenguaje podrá cubrir el ejemplo. Si esto último llega a suceder, CLINT asume que la teoría aun esta incompleta y aplaza el tratamiento de dicho ejemplo. Esto significa que la teoría se deja de lado temporalmente de forma que el sistema recuerde que aun hay un ejemplo positivo sin cubrir.

Después, cuando se modifica la teoría a causa de algún otro ejemplo, reinvocará al ejemplo no resuelto e intentará cubrirlo con el procedimiento inductivo.

Conclusiones.

Cuando la teoría objetivo puede ser expresada utilizando los lenguajes de CLINT al igual que la base de conocimiento y el usuario provee un número suficiente de ejemplos y restricciones, CLINT encontrará la definición correcta de la teoría objetivo después de un procesamiento finito de ejemplos / restricciones.

Referencia

De Raedt, Luc and Bruynooghe, Maurice. Interactive Concept-Learning and Constructive Induction by Analogy. Journal Mach. Learn. Doi: 10.1023/A:1022664419589.

Revisión, Consenso y Filtraje del Conocimiento en Sistemas Multiagente.

Por F. Javier Gramajo López y Jorge Rodas-Osollo

Resumen.

Un sistema multiagente se conforma de varios agentes inteligentes, que deberán ofrecer la mejor acción posible ante una situación dada. Sin embargo, durante la formulación de la acción aparecen algunos inconvenientes : ¿Qué hacer ante un fallo en la consecución de la meta en común? ¿Cómo afrontarlo? ¿Qué sucede si no hay acuerdo entre los agentes que componen dicho sistema? ¿Cómo deberá ser el proceso de actuación ante la información proveniente de distintas y diversas fuentes?

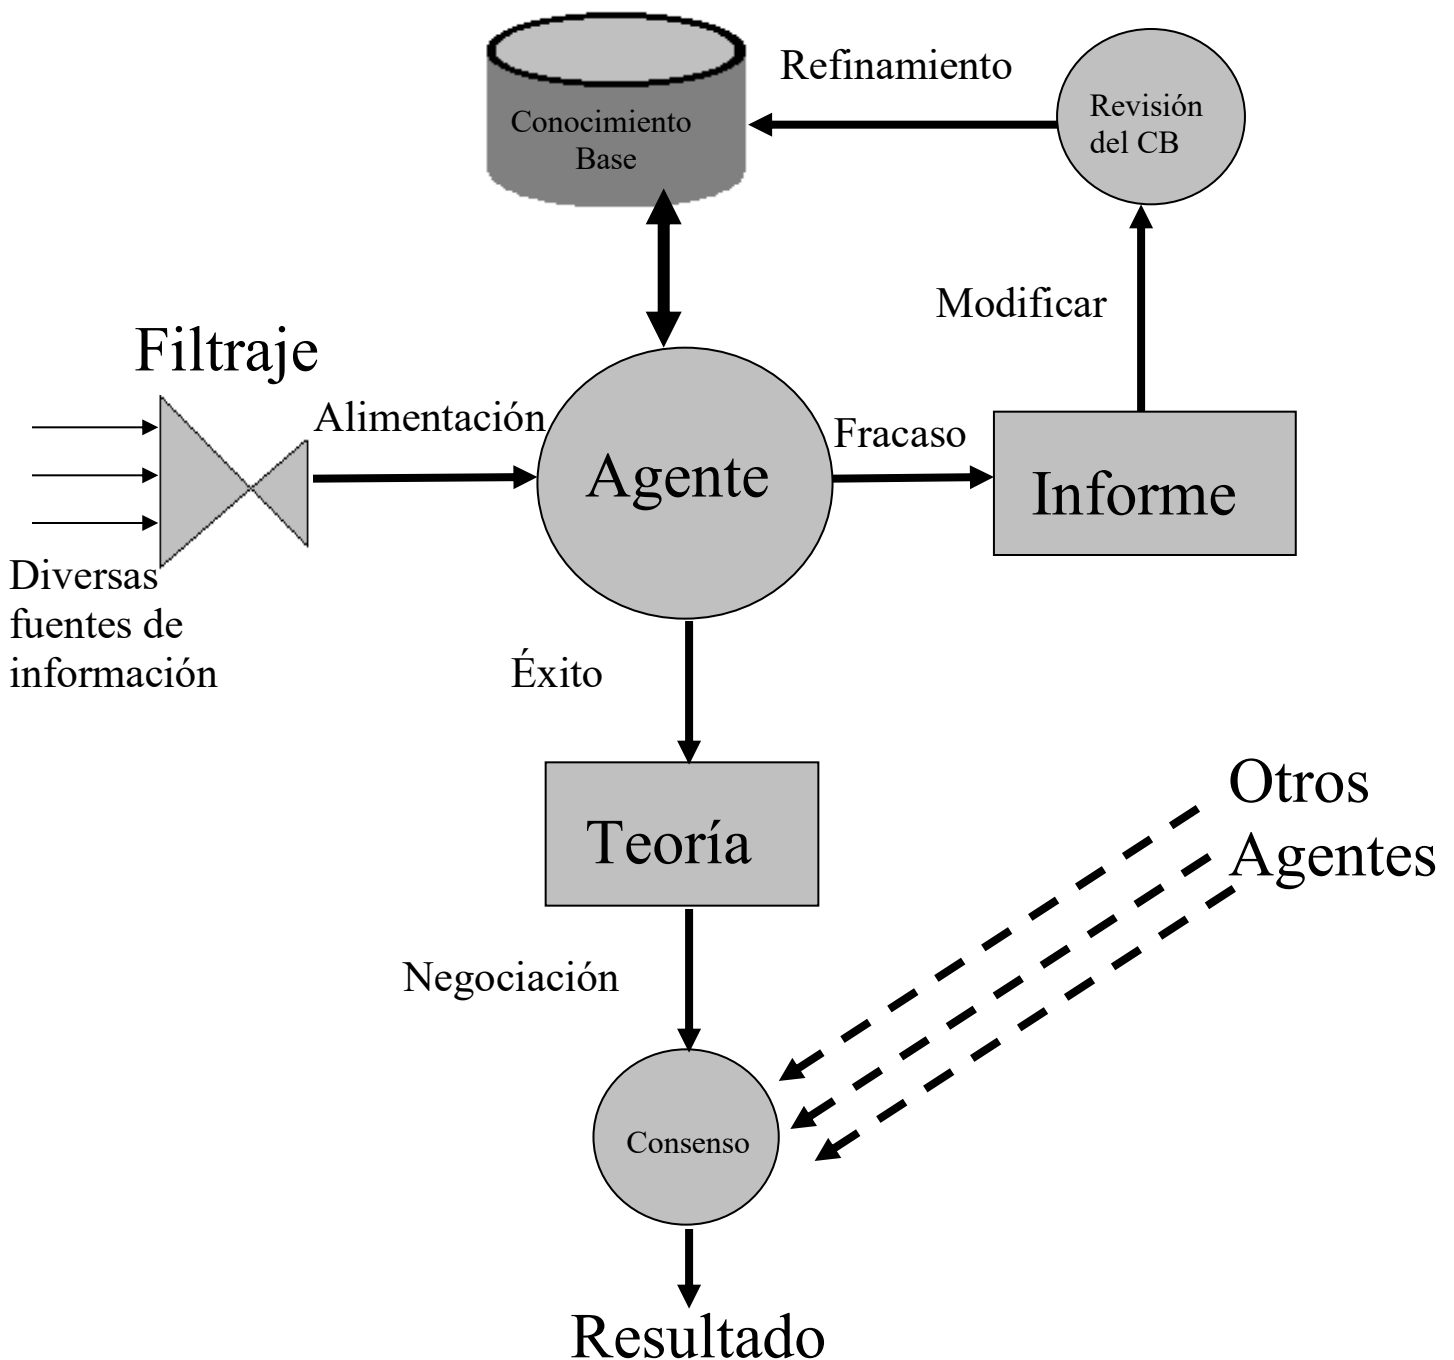
Este documento recopila investigaciones realizadas para resolver tales problemas y presenta un panorama general de cómo mejorar el desempeño del sistema multiagente.

El documento se encuentra organizado de la siguiente manera : Antecedentes (Conceptos relacionados con los Sistema Multiagente), Esquema del Sistema y las Distintas Estrategias (Gráfico que muestra el esqueleto del sistema y donde interactúan las estrategias), Estrategias Adoptadas (Breve explicación de las estrategias) y Conclusiones.

Antecedentes.

- En un sistema consistente de cierto número de agentes inteligentes interactuando, el *desempeño* puede ser evaluado por la coherencia del grupo de agentes o por agentes individuales. Donde la coherencia, se refiere a que tan bien el sistema se comporta como una unidad. Puede ser medida en diferentes dimensiones, incluyendo la calidad de la solución que el sistema produce, la eficiencia de las soluciones generadas y como gradualmente el desempeño se degrada ante la presencia de fallas o incertidumbre.
- El refinamiento de la base del conocimiento de un agente cambia su comportamiento tal que esto afecta a otros agentes, quienes deberán reaccionar ante estos cambios de forma apropiada, por lo que será deseable mantener la *consistencia* de su base del conocimiento.
- Un agente que interactúa con otros agentes necesita distinguir entre 2 tipos de conocimiento : *Conocimiento del Dominio*, se refiere a la solución del problema y al ambiente; *Conocimiento Social*, permite al agente interactuar con otros agentes (dicho conocimiento incluye comunicación, interacción y modelos de agentes).
- Existen tres fases básicas para alcanzar una meta dentro de un sistema multiagente : *Descomposición*, *Asignación* y *Coordinación* de tareas.
- Las fallas en las bases del conocimiento pueden consistir de : *Incorregibilidad*, *incompletitud*, *inconsistencia*, *redundancia* e *intractabilidad*.

Esquema del Sistema y las distintas estrategias.



Cada agente recibe información de distintas y diversas fuentes, por lo cual debe realizarse un proceso de filtrado de dicha información. El agente desarrolla el proceso que le permita alcanzar el objetivo, si se fracasa en el mismo se deberá entrar a un proceso de revisión el cual modificara la base de conocimiento, si tiene éxito se entra a un proceso de consenso con los otros agentes.

Se adoptan distintas estrategias para resolver los problemas de modificación, negociación y selección de información, dichas estrategias las podemos resumir en lo siguiente : En el proceso de *consenso* se elije una teoría de entre todas las propuestas, en la *revisión* se

realizan cambios en la base del conocimiento cuando no se consigue la meta y de esa manera se puede asegurar el éxito en el futuro; y en la de *filtrado* se aplica un proceso que determina la exactitud o veracidad de la información proveniente de distintas y diversas fuentes para modificar el proceso de razonamiento del agente.

Estrategias Adoptadas.

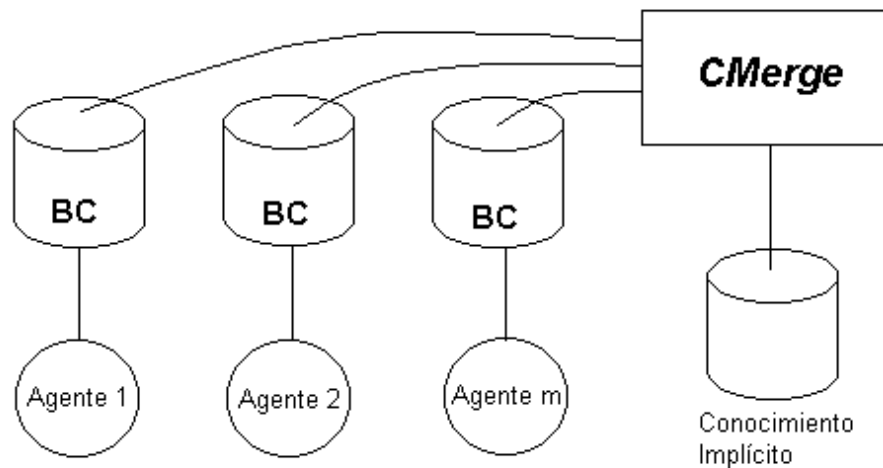
Estrategia para resolver el problema de consenso en un Sistema MultiAgente (SMA)

¿Qué sucede si no hay acuerdo entre los agentes que componen el SMA? (falta de consenso)

Una práctica común para resolver conflictos entre grupos de agentes, es dejar que la mayoría decida. Esto, haciendo una analogía con las sociedades humanas representa una especie de proceso democrático, donde los agentes "votan" por una alternativa de solución. Esta situación ha llevado a Lin y Mendelson a formalizar este principio y aplicarlo al problema de combinación del conocimiento de múltiples agentes. Ellos fundamentan la postulación de propiedades lógicas que todos los operadores de combinación de conocimiento deberán satisfacer, otorgando una caracterización del modelo teórico de todos los operadores de combinación que satisfacen dichos postulados.

Finalmente, proponen un método particular de combinación de conocimiento denominado *CMerge*, el cual satisface a los mismos.

El problema consiste en ¿cómo resolver los conflictos resultantes de combinar el conocimiento de múltiples agentes (que equivale a como combinar múltiples bases de conocimiento) ?



El método más sencillo para llevar a cabo la combinación consiste en : tomar la disyunción del máximo subconjunto consistente de la unión de las bases del conocimiento, tomando en cuenta la presencia de la integridad de restricciones y prioridades sobre las bases de conocimiento.

En cualquier caso, esta postura no toma en cuenta la "popularidad" de las creencias en los distintos grupos de agentes.

Postulados para la Combinación de Mayoría.

Son cuatro postulados, los cuales no son más que propiedades que los operadores de combinación de BC deben cumplir. Los tres primeros se aplican sobre cualquier operador de combinación. El cuarto postulado es específico para operadores que utilizan la regla "por mayoría".

Postulados :

MM1. Asegura que el resultado de la combinación es consistente puesto que no deseamos conflictos entre las BC que queden sin resolver.

MM2. Se encarga de un limitado número de casos, si no existen conflictos entre las BC, entonces el resultado de la combinación es simplemente la unión de las BC.

MM3. Requiere de la función de combinación para ser independiente de la sintaxis de cada BC.

MM4. Calcula el apoyo parcial que pueda tener una proposición evitando las inconsistencias al definir el principio de proposiciones atómicas por medio de comités que votan sobre sentencias atómicas y compuestas. Dicho cálculo es llevado a cabo por el operador de combinación por mayoría. Éste se fundamenta en un mínimo número de átomos en el cual el mundo posible (función sobre un conjunto de átomos finito que otorga valores de verdad $\{V,F\}$) difiere de algún modelo de la BC.

El operador CMerge satisface los postulados anteriores y hace una caracterización sintáctica del mismo, para el manejo o transformación de la BC en una forma normal disyuntiva (DNF), el cual consiste en seleccionar un par de cláusulas tal que su combinación tenga el menor número de pares inconsistentes y el resultado de éste operador es la disyunción de las partes consistentes de estas combinaciones.

Cabe destacar que el convertir la BC a DNF puede requerir tiempo exponencial y el problema de computar CMerge sobre BC arbitrarias puede verse fácilmente como un problema NP-Hard.

(Esta estrategia es un extracto de la referencia [1])

Estrategia para la revisión del conocimiento cuando se produce un fallo

¿Qué hacer ante un fallo en la consecución de la meta en común? ¿Cómo afrontarlo?

Una grupo de agentes inteligentes pueden trabajar juntos para resolver un problema o negociar una meta en común.

Si el grupo de agentes falla, se podrá adaptar la conducta de los mismos agentes y así esa meta puede mejorarse (conseguirse) en el futuro.

Una forma de que la conducta del agente puede cambiarse en el refinamiento de la base de conocimiento de los agentes, es hacerlo individualmente.

El diseño de un sistema distribuido de refinamiento, generalmente ejecuta un ciclo similar al siguiente:

- Reconoce que un fallo se ha producido
- Localiza el punto donde se produjo el fallo
- Determina que refinamiento se necesita hacer, para corregir en la base de conocimiento.

Sobre los fallos podemos decir que los agentes tienen diferentes bases de conocimiento y por consiguiente distintas perspectivas de su ambiente. Desde que los agentes se relacionan con otros agentes, dependiendo de las facilidades que el ambiente permita, las posibilidades de fallo se incrementan.

Existen tres fases básicas en el proceso del logro de un objetivo por parte de un grupo de agentes, la descomposición, la asignación y la coordinación de las tareas, por lo que los agentes pueden fallar durante cualquiera de estas fases.

Además se pueden tener fallos en las bases de conocimiento las cuales pueden incluir: *Incorrectitud, Incompletitud, Inconsistencia, Redundancia e Intractabilidad.*

Se cree que un grupo de agentes puede determinar las causas del fallo e implementar un conjunto efectivo de refinamiento, ya que los agentes pueden cooperar, compartiendo su conocimiento y sus distintas perspectivas de un fallo.

Byrne y Edwards proponen un sistema distribuido del refinamiento que consiste en dos partes:

Un módulo de refinamiento de los agentes y un facilitador del refinamiento.

Los agentes utilizan el módulo de refinamiento para generar refinamientos en su propia base de conocimiento, por otro lado el facilitador coordina el proceso de refinamiento con el grupo, pero no genera por sí mismo el refinamiento. Así un agente reconoce que se ha producido un fallo e informa al facilitador, el cual recoge propuestas de refinamiento de los agentes designados. El facilitador evalúa las propuestas y selecciona un subconjunto para su implementación, es decir actúa como un filtro en el proceso de refinamiento.

Un Agente es definido en términos de las capacidades, un conjunto inicial de creencias (precondiciones) y un número de reglas a cumplir.

Inicialmente, se le da al agente la habilidad de refinar los conjuntos de precondiciones, el agente pide información relevante sobre el fallo, para guiar el refinamiento y determina cual tipo de conocimiento necesita ser refinado aplicando operadores (de refinamiento) para generarlo.

Los agentes deberán “memorizar” información de las circunstancias en las cuales se determino que se llevarán a cabo ciertas acciones. Para realizar el refinamiento el agente

requiere de: a) Saber como describir los fallos para poder comprenderlos y transmitirlos al facilitador. b) Cómo generar los refinamientos y describirlos. c) Cómo actualizar su conocimiento debido a modificaciones durante el refinamiento del conocimiento de otros agentes.

Podemos concluir que el objetivo del refinamiento es la mejora del desempeño del grupo de agentes, y dicho desempeño se mide en función de la calidad de la solución propuesta o producida.

(Esta estrategia es un extracto de la referencia [2])

Estrategia para filtrar información de diversas y distintas fuentes

¿Cómo deberá ser el proceso de actuación ante la información proveniente de distintas y diversas fuentes?

Muchos de los modelos simbólicos y numéricos para la revisión de creencias han sido desarrollados para obedecer los tres principios siguientes:

- *Consistencia*
- *Cambios Mínimos*
- *Prioridad a la información entrante*

Pensando particularmente en sistemas multiagente en los cuales la información proviene de distintas fuentes y aún más, aceptando la información entrante (*esperando que sea consistente y que ésta se mantenga así) implica eliminar parte del conocimiento previamente obtenido, siendo este cambio irrevocable.

Para hacer práctica y útil la revisión de creencias en un ambiente MultiAgente, se sustituye la prioridad de la información entrante por el siguiente principio:

Recuperabilidad (Recoverability): En cualquier momento que se reciba información la misma debe pertenecer al conocimiento actual y debe ser consistente con el mismo.

Se consideran dos bases de conocimiento:

Conocimiento total (Background Knowledge KB): Conjunto de todas las partes del conocimiento disponible para el razonamiento del agente, mientras sea inconsistente no podrá ser utilizado totalmente para el proceso de razonamiento y decisión.

Conocimiento Base (Base Knowledge B): Es la parte más consistente y preferida del conocimiento disponible que puede ser utilizada para el soporte del razonamiento y decisión.

La información proveniente P con su peso de evidencia, es confrontada no solo con B, sino con todo KB.

La forma de la revisión del conocimiento consiste en 4 pasos:

1. Detección de todos los subconjuntos de inconsistencias mínimas de KB U {P} (sentencias malas, nogoods).
2. Generación de todos los subconjuntos máximos consistentes KB U {P} (sentencias buenas, goods).
3. Revisión de los pesos de credibilidad de las proposiciones (sentencias) en KB U {P}
4. Elegir los subconjuntos consistentes preferidos de KB U {P}, como una nueva revisión B'

La formalización de la función de creencias en un sistema multiagente, permite asignar un grado de credibilidad tanto a las sentencias simples como a las buenas. La forma de evaluación de la credibilidad del subconjunto de sentencias buenas no es totalmente satisfactoria, así la formalización de la función de creencias, consiste en un proceso que toma como entrada una lista de parejas de la forma <Fuente, Información> y da como salida un grado de credibilidad para cualquier información recibida.

En conclusión este método proviene de la investigación en sistema multiagente, en los cuales es necesario asegurar la credibilidad de la información proveniente de diferentes fuentes, integrando formalismos numéricos y simbólicos.

(Esta estrategia es un extracto de la referencia [3])

Conclusiones.

En un sistema multiagente se presentan diversos problemas todos ellos relacionados con distintos aspectos, desde el logro de la solución por parte de cada agente y el realizar un consenso para dar un resultado así como haber fracasado en el logro de la meta y la revisión en la base del conocimiento. También el discernimiento de la información que recibe de distintas fuentes para el proceso de razonamiento del agente.

El adoptar distintas estrategias para resolver los diversos problemas dependerá de la complejidad de los mismos y la necesidad de su clasificación oportuna por parte del agente. Es por eso que éstas adoptan modelos numéricos y simbólicos.

La revisión de la Base del Conocimiento está directamente relacionada con la naturaleza del problema y es a través de su análisis el cómo se determinará la representación más adecuada para el fin perseguido.

Referencias.

- [1] Lin, Jinxin and Mendelzon, Alberto: **Knowledge Base Merging by Majority**. Dept. of Computer Science, University of Toronto. Toronto, M5S 1 A4, Canada.
- [2] Byrne, Ciara and Edwards, Peter: **Refinement in Agent Groups**. Department of Computer Science, King's College, University of Aberdeen, Aberdeen Scotland AB9 2UE.
- [3] Dragoni, Aldo Franco and Giorgini, Paolo: **Belif Revisión trough the Belief Function Formalism in a Multi-Agent Environment**. Informatic Institute, Ancona University, v. Breccia Bianche, 60131, Ancona.

Sistemas de soporte a la decisión

Por Ruth Torres Castillo

Resumen

El mejoramiento en la solución de los problemas no depende de la habilidad de producir nuevo conocimiento, mucho tiene que ver la capacidad que se tenga para absorberlo y utilizarlo. Es por eso que los estudiantes del Instituto de Ingeniería tienen a sus disposición Sistemas Expertos como modelo de apoyo a la toma de decisiones. Los ES se aplican a una gran diversidad de campos y/o áreas son capaces de identificar el patrón o combinación de patrones que mejor se adapta a la situación presentada por el usuario, logrando obtener los objetivos básicos que se persiguen con su implantación.

En la actualidad la demanda de aplicaciones ha evolucionado a través del tiempo, inicialmente con la sola demanda de obtener soluciones a los problemas que se presentaban, hoy en día esta demanda es orientada preferentemente a la necesidad de la revelación de oportunidades innovadoras las cuales permitirán obtener ventajas competitivas para quienes sepan aprovecharlas.

El principal objetivo de este artículo es los sistemas de soporte a la decisión, en especial una de sus aplicaciones, los sistemas expertos, indagando de qué modo brindan solución a los estudiantes del Instituto de Ingeniería y Tecnología para aplicar la mejor práctica en la resolución de su problema.

Los Sistemas de Soporte a la Decisión (DSS, Decision Support Systems) comienza a surgir en la década de los 70's bajo el término de sistemas administración de las decisiones, y se definen (**Sprague, 1993**) como:

- Sistemas basados en sistemas de cómputo.
- que ayudan a quien toma decisiones.
- enfocados a problemas mal estructurados.
- a través de una directa interacción.
- con datos y modelos de análisis.

Su objetivo es intentar descubrir qué pasaría si se toman una serie de decisiones, o ir más allá proporcionando automáticamente las decisiones o sugerencias que asistan al administrador. Otra definición (**Keen & Scott-Morton, 1978**) de estos sistemas puede ser:

Los sistemas de soporte a la decisión conjuntan los recursos intelectuales de los individuos con las capacidades de una computadora para incrementar la calidad de las decisiones. Son sistemas de soporte basados en computadoras para administradores que deben tomar decisiones y que se enfrentan con problemas semi-estructurados.

En un enfoque mas específico, la Inteligencia Artificial (AI, Artificial Intelligence) se puede definir como la ciencia que estudia de manera sistemática el comportamiento inteligente, con el fin de imitar o simular las habilidades humanas mediante la creación y utilización de máquinas y computadoras (**Cohen, 1996**) y define a los Sistemas Expertos (Expert Systems, ES) como una de sus áreas de estudio con una aproximación muy exitosa a la solución de los problemas clásicos de AI, el profesor Edward Feigenbaum de

la Universidad de Stanford, define los sistemas expertos como: un programa de computación inteligente que usa el conocimiento y los procedimientos de inferencia para resolver problemas que son lo suficientemente difíciles como para requerir significativa experiencia humana para su solución (**Feigenbaum, 1982**). Estos sistemas permiten la creación de bases de conocimiento que se integran por una serie de reglas de sentido común para que diferentes usuarios las consulten, apoyen la toma de decisiones, la capacitación, etcétera. El aprendizaje adquirido se almacena en una base de conocimiento de donde posteriormente se puede consultar información para aplicarla en situaciones similares futuras teniendo las situaciones pasadas como retroalimentación. Las bases de conocimientos una vez cargadas responden a preguntas, despejan dudas y sugieren cursos de acción emulando el proceso de razonamiento de un experto para resolver un problema. Por lo que dos habilidades fundamentales que poseen los Sistemas Expertos son: Habilidad de aprendizaje y habilidad para simular el proceso del razonamiento humano.

Los ES se aplican a una gran diversidad de campos y/o áreas. A continuación se listan algunas de las principales: Militar, Informática, Telecomunicaciones, Química, Derecho, Aeronáutica, Geología, Arqueología, Agricultura, Electrónica, Transporte, Educación, Medicina, Industria, Finanzas y Gestión.

Datos, Información y Conocimiento:

En contraste con los conceptos de datos e información el conocimiento interpretado por un experto sugiere o recomienda las estrategias que se deben implantar en dada situación. Las reglas heurísticas o basadas en la experiencia, a través de las cuales se representa el conocimiento de un experto, se diseñan utilizando las palabras *si* y *entonces*, denotando un sentido condicional, representando en la primer parte de la regla la condición a evaluar y la acción a seguir, dependiendo del cumplimiento de la condición inicial, se encuentra en la segunda parte de la regla, después del adverbio *entonces*. Ejemplo

Regla: Luz_roja	Regla: Luz_verde
SI la luz es roja	SI la luz es verde
ENTONCES alto	ENTONCES adelante

Arquitectura y componentes básicos de los sistemas expertos.

Generador de sistemas expertos o shell. Es el software que permite desarrollar el sistema. Constituye la herramienta que apoya el proceso de creación de las bases de conocimiento y facilita la utilización del modelo por parte de los usuarios. Diferentes componentes integran el shell, así como el proceso lógico que se sigue para el desarrollo de un Sistema Experto con la ayuda del mismo (**Cohen, 1996**).

Base de conocimientos. Es la parte del sistema experto que contiene el conocimiento sobre el dominio. Hay que obtener el conocimiento del experto y codificarlo en la base de conocimientos. Una forma clásica de representar el conocimiento en un sistema experto son las reglas.

Base de hechos (Memoria de trabajo). Contiene los hechos sobre un problema que se han descubierto durante una consulta. Durante una consulta con el sistema experto, el usuario introduce la información del problema actual en la base de hechos. El sistema empareja esta información con el conocimiento disponible en la base de conocimientos para deducir nuevos hechos.

Motor de inferencia. El sistema experto modela el proceso de razonamiento humano con un módulo conocido como el motor de inferencia. Dicho motor de inferencia trabaja con la información contenida en la base de conocimientos y la base de hechos para deducir nuevos hechos. Contrasta los hechos particulares de la base de hechos con el conocimiento contenido en la base de conocimientos para obtener conclusiones acerca del problema.

Subsistema de explicación. Una característica de los sistemas expertos es su habilidad para explicar su razonamiento. Usando el módulo del subsistema de explicación, un sistema experto puede proporcionar una explicación al usuario de por qué está haciendo una pregunta y cómo ha llegado a una conclusión. Este módulo proporciona beneficios tanto al diseñador del sistema como al usuario. El diseñador puede usarlo para detectar errores y el usuario se beneficia de la transparencia del sistema.

Interfaz de usuario. La interacción entre un sistema experto y un usuario se realiza en lenguaje natural. También es altamente interactiva y sigue el patrón de la conversación entre seres humanos. Para conducir este proceso de manera aceptable para el usuario es especialmente importante el diseño de la interfaz de usuario. Un requerimiento básico de la interfaz es la habilidad de hacer preguntas. Para obtener información fiable del usuario hay que poner especial cuidado en el diseño de las cuestiones. Esto puede requerir diseñar el interfaz usando menús o gráficos.

Ingeniero del conocimiento. Es el especialista en el uso del shell y técnicas de entrevistas hacia el experto. Se encarga de traducir los conocimientos y experiencias en reglas heurísticas, las cuales integran la base de conocimiento de un problema en particular. Generalmente es egresado de las carreras de Computación o Sistemas de Información y cuenta con estudios en el área de AI o ES.

En caso de no contar con el ingeniero del conocimiento se utiliza un medio para la adquisición de conocimiento vía automática para que el usuario introduzca conocimiento en el sistema (**Giarratano, 2001**)

Experto. Es la persona que interactúa con el ingeniero del conocimiento, aportando su conocimiento y experiencia de un área particular del saber humano. Para tener éxito en el desarrollo e implantación de un Sistema experto, se recomienda que los expertos tengan disponibilidad e interés en el proyecto, así como un entendimiento de los objetivos del proyecto para que no se sientan desplazados por él.

Se pueden tomar en cuenta mas o menos componentes de un ES, en el caso de este artículo se consideran solo los moldeos de los autores Joseph Giarratano y Daniel Gohén

Beneficios del uso de los Sistemas Expertos

El implementar un ES trae consigo diferentes beneficios que se comenta a continuación.

Reducción en la dependencia del personal clave. Los conocimientos del experto son guardados durante el proceso de aprendizaje y posteriormente pueden ser utilizados por diferentes personas y para situaciones similares. Esto muchas veces conlleva al celo de lo que el experto conoce, es por eso que éste debe estar completamente de acuerdo con los objetivos del proyecto.

Facilita el entrenamiento del personal. El ES ayuda de manera importante y a un costo menor, a la capacitación y adiestramiento del personal sin experiencia. Por medio de la reglas de inferencia el usuario puede ir dando respuesta a las preguntas que se le hacen lo

cual va generando experiencia hacia el usuario en el manejo y razonamiento de los sistemas.

Mejora en la calidad y eficiencia en el proceso de la toma de decisiones. Las decisiones se lograrán tomar de manera más ágil, además de que podrán ser consistentes ya que un ES siempre responderá de la misma forma ante las mismas situaciones. Esto mejora el desempeño del personal menos especializado que se enfrenta a decisiones complejas.

Transferencia de la capacidad de decisiones. El conocimiento de los expertos puede transferirse a varias personas, por lo que la toma de decisiones puede ser tomada por diferentes niveles en caso de ser necesario, además de reflexionar y cuestionar la forma de resolver problemas y dar tiempo a los expertos de enfocarse a resolver problemas más difíciles e importantes.

Como saber si un problema es dominio de un sistema experto

Definitivamente no todos los problemas a resolver son aptos para la implantación de un ES. Sin embargo se puede realizar una evaluación, cuestionándose las siguientes preguntas(**Giarratano, 2001**) y analizando cada una de las respuestas y de esta manera conocer si la situación a resolver pertenece al dominio de los Sistemas Expertos.

¿Puede solucionarse el problema con programación convencional?

¿Esta bien delimitado el dominio?

¿Hay la necesidad de tener un sistema experto?

¿Hay al menos un especialista que este dispuesto a cooperar?

¿Puede el experto explicar el conocimiento en forma comprensible al ingeniero del conocimiento?

¿El conocimiento para resolver problemas es principalmente heurístico e incierto?

Si bien es cierto, el área de estudio de los Sistemas Expertos es de gran amplitud y tomando en cuenta que actualmente la cantidad de información que la Tecnología ofrece para la toma de decisiones es en sobre manera abundante, es necesario tomar en cuenta que el mejoramiento en la solución de los problemas no depende de la habilidad de producir nuevo conocimiento, mucho tiene que ver la capacidad que se tenga para absorberlo y utilizarlo. Es por eso que los estudiantes del Instituto de Ingeniería tienen a sus disposición estos sistemas como modelo de apoyo a la toma de decisiones. El estudiante puede ser de cualquier área de estudio, eléctrica, computación, mecatrónica, sistemas digitales, etc., pero en cada uno de sus temas de estudios se presentarán situaciones en las cuales el estudiante debe contar con el conocimiento actual y la habilidad para usar las tecnologías de información ya que ellos vivirán y trabajarán en un mundo completamente tecnológico, por lo que no deben cerrar las puertas a la opción de que en algún dado caso puedan tomar en cuenta la implementación de un sistema experto en la resolución de problemas. Para ello, es necesario cambiar la cultura actual en la resolución de problemas. Una vez definido el problema se establecen objetivos, alcance, participantes y ámbito donde se puede utilizar el sistema, una vez conocidos todos estos datos, el sistema experto es capaz de identificar el patrón o combinación de patrones que mejor se adapta a la situación presentada por el usuario, logrando obtener los objetivos básicos que se persiguen con su implantación:

- Automatizar los procesos.
- Proporcionar información que sirva de apoyo al proceso de toma de decisiones.

- Lograr ventajas competitivas a través de su utilización.

Conclusión.

Cada persona que realiza la toma de decisiones en su área de trabajo o estudio debe empezar a desarrollar una adaptación con las nuevas características para la solución de problemas que se presentan, todo esto con el fin de lograr ser competitivo. Un ES es una herramienta que permite obtener de manera oportuna la información que se requiere durante el proceso de la toma de decisiones que se desarrolla en un ambiente de incertidumbre donde el objetivo principal es proporcionar la mayor cantidad de información relevante en el menor tiempo posible, con el fin de decidir lo más adecuado.

Los sistemas educativos con mejores rendimientos son producto de sociedades exigentes en las que los gobiernos se ven obligados a presentar buenos resultados de calidad (Beltrán, 2008).

Referencias

- Beltran, Rosa Esther. (Febrero, 2008). Para dejar de ser un país de burros. Documento electrónico consultado el 3 de marzo de 2008 en: <http://0-proquest.umi.com.millennium.itesm.mx:80/pqdweb?did=1422315871&sid=1&Fmt=3&clientId=23693&RQT=309&VName=PQD>
- Cohen, Daniel K.(1996). Sistemas de información para la toma de decisiones. Segunda edición. México. Editorial McGraw-Hill.
- Feigenbaum, Edward A. (1982). Knowledge Engineering in the 1980's. Dept. of Computer Science, Stanford University, Stanford, CA.
- Giarratano, Joseph; Riley, Gary. (2001).Sistemas expertos: principios y programación. Tercera Edición. México. Editorial International Thomson.
- Keen, P. G. W.; Scott-Morton M.S. (1978). Decision Support Systems, An Organizational Perspective. Reading, MA. Editorial Addison-Wesley.
- Lardent, Alberto R. (2001). Sistemas de información para la gestión empresarial: planeamiento, tecnología y calidad. Buenos Aires. Editorial Pearson Educación.
- Rich, Elaine; Knight Kevin (1994). Inteligencia artificial. Segunda edición. Madrid. Editorial McGraw-Hill.
- Sprague, Ralph H; Watson, Hugh J. (1993) Decision support systems: putting theory into practice. Tercera edición. Englewood Clifts, N.J. Editorial Prentice Hall.
- Turban, Efraim. (1993). Decision support and expert systems: management support systems. Tercera Edición. New Cork. Edictorial Maxwell Macmillan Internacional.

A cerca de la utilización de tablas de restricciones en Redes de Creencias. Por Jorge Rodas-Osollo

Resumen.

Este artículo describe un Algoritmo que pretende satisfacer restricciones para eficientizar la creación de Redes de Creencias a partir de una Base de datos. Se propone generar una tabla de restricciones orientada por un especialista. Considerando 3 tipos de atributos : (1) Independientes, (2) por grupos y (3) en secuencia.

El enfoque de este trabajo esta dirigido a un tipo específico de Redes de Creencias: Los Grafos Simples. De lo cual se espera que el resultado sea una red más fiel a la expectativa del especialista.

Introducción.

Redes de Creencias.

Una red de creencia (conocida también por : red de creencia, red causal o diagrama de influencia) [Pearl, 1988] es una representación gráfica de (in)dependencia entre variables aleatorias. Una red de creencia es un grafo acíclico dirigido (GAD) donde los nodos representan variables aleatorias. Si existe un arco desde una variable B a una variable A, se dice que B es un padre de A. La presunción de independencia de una red de creencia dice que cada variable es independiente, sus no descendientes dados sus padres.

Supongamos que tenemos una red de creencia con variables aleatorias X_1, \dots, X_n . Los padres de X_i son descritos como $\Pi_{X_i} = \langle X_{i_1}, \dots, X_{i_{k_i}} \rangle$. Asociadas a la red de creencia están las tablas de probabilidades condicionales las cuales ofrecen las probabilidades marginales de los valores de X_i dependiendo de los valores de sus padres en Π_{X_i} . En esto consiste que para cada $v_j \in \text{valores}(X_j)$, probabilidades de la forma : $P(X_i = v_i | X_{i_1} = v_{i_1} \wedge \dots \wedge X_{i_{k_i}} = v_{i_{k_i}})$.

Para cualquier distribución de probabilidades, podemos procesar una distribución conjunta por :

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \Pi_{X_i}).$$

Esta frecuentemente es la definición formal de red de creencia y su síntesis para proposiciones con variables que tienen valores particulares quedaría como :

$$P(X_i = v_i \wedge \dots \wedge X_n = v_n) = \prod_{i=1}^n P(X_i = v_i | X_{i_1} = v_{i_1} \wedge \dots \wedge X_{i_{k_i}} = v_{i_{k_i}}).$$

En una red de creencia, se tiene un componente cualitativo (el grafo) que representa las relaciones de dependencia / independencia : la ausencia de algunos arcos significa la existencia de cierta independencia condicional en las relaciones entre variables, y la presencia de arcos puede representar la existencia de relaciones de dependencia directa (si una interpretación causal es dada, entonces los arcos significan la existencia de influencias causales directas entre variables ligadas). El componente cuantitativo es una colección de medidas de incertidumbre, las cuales dan una idea de la fortaleza de las dependencias.

Una vez que se construye la red de creencia, se puede ver como un dispositivo eficiente de desarrollo de inferencias.

Sin embargo, esto nos hace recordar el problema de como proporcionar la estructura del grafo y los parámetros numéricos necesarios para la caracterización de la red. Así, una tarea interesante es el desarrollo automático de métodos que le permitan aprender a la red directamente de los datos, como una alternativa o un componente al método de consulta de opiniones a los especialistas.

El enfoque de este documento se centra en una clase específica de grafos acíclicos dirigidos (*directed acyclic graphs - DAG*), los denominados grafos simples. Éstos representan un extenso conjunto de relaciones de independencia de grafos de conexión simple; particularmente, el establecimiento de independencias condicionales de alto orden ($O(n-2)$).

Consideramos que de los datos podemos obtener una buena representación del problema en cuestión, y que cualquier algoritmo de aprendizaje para redes de creencia trata de encontrar la red que se ajuste mejor a dicha representación, de acuerdo con criterios específicos establecidos en una tabla de creencias.

Desafortunadamente, existen muchas formas de establecer la tabla de creencias, es así que proponemos la implementación de una tabla de restricciones para encontrar la configuración de la red más fiel a la expectativa del especialista.

Grafos Simples.

Una *DAG* G se dice simple sí y sólo si, cada par de nodos con un hijo directo en común no tienen ancestros en común ni uno es ancestro del otro.

Considerando el criterio de *d-separation*^{*}, un grafo simple es de la clase de *DAG* donde los padres de cualquier variable son siempre marginalmente independientes (*d-separated* por el conjunto vacío) entre ellos. Así, la siguiente caracterización de los grafos simples es inmediata :

Sea G un *DAG*. Las definiciones a continuación son equivalentes :

1. G es un grafo simple.
2. Todos los ciclos en G contienen al menos 2 conexiones cabeza - cabeza.
3. Cada par de nodos en G con un hijo directo en común están *d-separated* por el conjunto vacío.

En la vida diaria, podemos encontrar modelos que se pueden representar a partir de grafos simples. En general, y considerando la definición anterior, cualquier modelo donde no estén correlacionadas las fuentes de evidencia pueden ser representados por grafos simples.

Como se ha comentado anteriormente, las redes de creencia nos permiten representar conocimiento sobre un dominio dado por medio de éste tipo de grafos. De forma abstracta, una red de creencia puede ser considerada como una representación de un **Modelo de Dependencia**, un par $M = \{U, I\}$, donde U es un conjunto de variables e I es una regla de asignación de valores de verdad para los predicados $I(X|Z|Y)$, ("X es independiente de Y, dada Z"). Donde X, Y y

* ver anexo

Z son subconjuntos disjuntos de las variables en U. Una interpretación a $I(X|Y|Z)$ es que habiendo observado a Z, sin información adicional de X puede ser obtenida por la observación a Y. El criterio para probar el establecimiento de la independencia es un componente esencial de cualquier modelo de dependencia. La conexión entre redes de creencia y modelos de dependencia se puede establecer por medio del criterio de *d-separated*, que se puede considerar como una definición gráfica de independencia condicional (que convierte una red creencial en un modelo de dependencia por si mismo).

Nuestro interés recae en aquellos algoritmos que nos permitan obtener las relaciones que darían forma al grafo, pudiendo formar así las tablas de creencias sobre las cuales aplicaríamos nuestro algoritmo para converger en la tabla de restricciones. Un algoritmo de este tipo es el propuesto por Geiger, Paz y Pearl (GPP). Este algoritmo toma como entrada un modelo de dependencia M , y otorga un grafo simple como salida, el cual es el modelo "bien" representado.

Algoritmo de Geiger, Paz y Pearl (GPP)	
1	Inicia con un grafo G completo no directo.
2	Elimina de G cada borde x - y cuando $I(x U \setminus \{x, y\} y)$ lo tiene.
3	Elimina de G cada borde x - y cuando $I(x O y)$ lo tiene.
4	Para cada par adyacente de bordes x - y y y - z en G, si $I(x O z)$ lo tiene, entonces dirige los bordes como x y z.
5	Dirige los bordes restantes sin introducir las nuevas conexiones cabeza - cabeza. Si el grafo resultante no es simple, otorga como salida un código de error.
6	Si el grafo resultante no es el modelo bien representado, otorga un código de error como salida. En cualquier otro caso, regresa como resultado el grafo.

Por otra parte, Pearl establece una serie de condiciones para poder identificar los efectos causales en la información observable o datos.

Una condición necesaria y suficiente para la identificación de los efectos causales de un conjunto de variables X en Y, es que el DAG G contenga X y Y satisfaga alguna de las siguientes condiciones :

1. Que no exista un camino directo de X a Y en G.
2. Que no exista una "ruta de escape" (Un conjunto de variables Z satisface el criterio de escape con respecto a un par ordenado de variables (X_i, X_j) en un DAG G si : (1) ningún nodo en Z es descendiente de X_i ; (2) Z bloquea cada camino entre X_i y X_j quien contiene una flecha hacia X_j) desde X a Y en G (no hay ninguna ligadura en X);
3. Que exista un conjunto de nodos B que no bloquee los caminos desde X a Y.
4. Que exista un conjunto de nodos Z_1 y Z_2 donde :
 - ningún elemento de Z_2 sea descendiente de X;
 - Z_2 bloquee cada camino directo desde X a Y en C_x ;
 - Z_2 bloquee todos los caminos en G_x entre X y Z_1 en C_x ;
 donde C_x sea el grafo obtenido a partir de haber borrado las flechas que apuntaban a X en G.

Una buena aproximación para la recuperación de grafos es un vistazo de forma local al conjunto de nodos directamente conectados con cada variable x en el modelo (sus padres y sus hijos) y así construir la estructura fusionando todos esos componentes. Con esto, la primera tarea por hacer es detectar la existencia de una conexión directa (o no) entre dos variables cualesquiera x y y . Una regla general es : dadas dos variables cualesquiera, x y y , podemos encontrar un conjunto de variables Z donde la relación de independencia $I(x|Z|y)$ la tiene, entonces x y y , no pueden ser adyacentes en ningún grafo que represente al modelo.

El algoritmo GPP utiliza esta metodología, en combinación de propiedades específicas para grafos simples que nos permitirán identificar los conjuntos d -separated Z directamente, sin ningún procedimiento de búsqueda.

Nuestra aproximación es el aprovechamiento de este algoritmo GPP o cualquier otro que identifique dichas relaciones causales o de creencia. Sobre las cuales, aplicaremos nuestro algoritmo, el cual aplicará las restricciones convenidas por el especialista, como parte del proceso de obtención de las tablas de restricciones creencia.

Algoritmo MR.

Considerando una base de datos con atributos de la forma $S = \{A1, A2, A3, A4, A5, A6, A7, A8, A9, A10\}$, se consideran 3 formas de relaciones entre ellos:

Relaciones definidas por grupos (G_n), por ejemplo, $G1\{A1, A2, A3\}$, $G2\{A4, A5, A6\}$, $G3\{A7, A8\}$.

Relaciones definidas por las secuencias de eventos (S_n), por ejemplo, $S1\{A1 \rightarrow A2 \rightarrow A3\}$, $S2\{A4 \rightarrow A5\}$.

Relaciones independientes o desconocidas ($I_n A_m$), por ejemplo, $I1(A9)$, $I2\{A10\}$.

Una relación que define los grupos está dada por la probabilidad que tiene un elemento de pertenecer a un conjunto de atributos que se sabe que pertenecen a un mismo dominio o a un mismo conocimiento cognoscitivo del mundo real, por ejemplo, supongamos que se analizan las medidas de genéticas de una persona, formando los grupos con los atributos correspondientes de su padre, de su madre y de la persona. La probabilidad de un atributo A_m pertenecer a un grupo n se puede representar como:

$$PG_n(A_m) = nA_m [\%].$$

Dentro de esta relación de grupos existen tres características importantes, que el especialista puede proporcionar:

- 1) Que exista alguna dependencia entre los grupos, es decir, $G1 \subseteq G2$.
- 2) Que no exista alguna dependencia entre los grupos, decir, $G1 \not\subseteq G2$.
- 3) Que no se sepa si existe alguna relación entre grupos.

Una relación de secuencia de eventos está definida por la probabilidad de dirección que tiene un atributo con respecto a otro, al ser generados en una forma secuencial, por ejemplo, en un conjunto de datos que muestran los diferentes pesos de una persona a través del tiempo, se establece una relación del tiempo en que las diferentes medidas fueron tomadas. La probabilidad de A_m de pertenecer a una secuencia de k a l con destino final n está expresada como:

$$PS_n(A_m) = [k,l,n] A_m [\%].$$

Donde el último nodo será $k = l = n$.

Una relación de independencia o desconocida por parte del especialista está definida por la probabilidad nula de pertenecer a un grupo de variables y por consiguiente, formar una secuencia de variables. Cuando no es proporcionada alguna restricción de su grupo o de secuencia a alguna variable, está se comportará con todos los valores dados por el DAG.

Considerando las tres formas de relacionar un atributo A_m se llega a la siguiente expresión general para un representar un atributo:

$$j [k,l,n] A_m, P\%, Q\% \quad (1)$$

donde

j es el grupo al cual el atributo pertenece, k,l,m es la secuencia inicial, intermedia y final, entre los atributos, donde $l = n$, en caso de ser una secuencia simple. $P\%$ es la probabilidad de pertenecer a un grupo, 0% en caso de ser un atributo independiente o que no conocido. $Q\%$ es la probabilidad de pertenecer a una secuencia de atributos. Está etiqueta se colocará a cada nodo del DAG.

De la representación (1) se forma la tabla de restricciones de acuerdo a las definidas por el especialista. Primero se comienza por la definición de grupos de variables y posteriormente por sus secuencias de generación. En caso de que no se declare ninguna, el algoritmo tratará a todas independientes y dejará que la formación de arcos se genere sin ninguna restricción al algoritmo generador de DAGs.

A continuación se describe como se puede agregar este algoritmo a cualquier otro algoritmo generador de DAG. Primeramente se analizará si debe existir un arco entre dos nodos, de acuerdo a la definición del especialista y posteriormente se definirá si la dirección del arco corresponde a esos mismos criterios, usando la secuencia de los atributos.

Considerando un DAG simple con dos nodos $N1$ y $N2$ y un arco, comprobar si no existe alguna restricción en el arco, de tal forma que para nuestro caso se tomarían sin tomarlo desde unos enfoques de relación padre - hijo, sino como una lista de secuencias de atributos. La representación de dos nodos y un arco se representará como $[A1 \rightarrow A2]$.

Figura 1: Algoritmo de dependencia o independencia entre grupos y secuencia de atributos.

```

Observar la relación entre los nodos  $[A1 \rightarrow A2]$  dados por un DAG.
Generar todas las etiquetas para la tabla de restricciones tanto de  $PSn(Am)$  como de  $GSn(Am)$ 
% Buscar la existencia de alguna restricción  $j[k,l,n]Am,P\%,Q\%$  en la tabla de restricciones.
Buscar  $j_1 [k_1,l_1,n_1] A1, P_1\%, Q_1\%$  y  $j_2 [k_2,l_2,n_2] A2, P_2\%, Q_2\%$ 
  Sí  $j_1 = j_2$  (pertenecen al mismo grupo)
    % Comprobar si existe secuencia entre  $[k_1,l_1,n_1]$  y  $[k_2,l_2,n_2]$  de la forma
    Sí no hay restricciones  $k_1,l_1,n_1 = \emptyset$  ó  $k_2,l_2,n_2 = \emptyset$  ó
       $n_1 = n_2$  y  $k_1 < k_2$  % Para ver si corresponde a la dirección  $[N1 \rightarrow N2]$ 
      Permitir colocar el arco en la red
    Sí no
      No permitir colocar el arco
      Guardar el arco restringido en arcos_no_aceptados
  Sí no
    Verificar Sí  $j_1 \in G_1$  y  $j_2 \in G_2$ 
      Sí  $G_1 \subseteq G_2$  (son dependientes)
        Permitir colocar el arco en la red
      Sí  $G_1 \not\subseteq G_2$  (son independientes)
        No colocar el arco
        Guardar el arco restringido en grupos no aceptados
  Sí no
    Colocar el arco en la red

Mostrar todos los DAG que no cumplieron con la restricción de grupo con su respectiva probabilidad
DAG%, de la forma  $\{A \rightarrow B\}$  probabilidad del DAG (%).
Mostrar todos los DAG que no cumplieron con la restricción de secuencia con su respectiva probabilidad
P%, de la forma  $\{A \rightarrow B\}$  probabilidad del DAG (%).
%Adicionar el cálculo del Factor de Aproximación (FA) del DAG en relación a las restricciones del
especialista desde un punto de vista de grupo o de secuencia de atributos.
FA GRUPO = (Prob. de Dist. de cada clase del DAG / %P del grupo ) x 100
FA SECUENCIA = (Prob.de Dist. de cada clase DAG / %Q de la secuencia) x 100

```

En caso de que ningún DAG se haya generado debido a las restricciones, se propone la creación de Factores de aproximación para determinar que tan distante está el DAG de todas las restricciones declaradas por el especialista.

Figura 2: Algoritmo para en caso de no generar ningún DAG.

```

Si no se tiene ningún DAG
%Comparar P% del grupo y Q% de la secuencia contra DAG%
%Calcular el Factor de Aproximación del DAG en relación a las restricciones del especialista desde un
punto de vista de grupo o de secuencia de atributos.
FA GRUPO = (Prob. de Dist. mayor entre todos los DAG / %P del grupo ) x 100
FA SECUENCIA = (Prob. de Dist. mayor entre todos los % DAG / %Q de la secuencia) x 100

```

Ejemplo:

Dada la siguiente restricción del especialista referente a los grupos:

$G1=\{A1, A2, A3, A4, A5\}$ y $G2=\{A6, A7\}$

con una probabilidad de pertenecer al grupo $PGn(Am) = 100\%$ en todos sus atributos.

Considerando también la siguiente restricción de secuencia:

$S1=\{A1 \rightarrow A3 \rightarrow A4 \rightarrow A5\}$ y $S2 = \{A6 \rightarrow A7\}$


con una probabilidad de secuencia $PSn(Am) = 100\%$ en todos sus atributos.

Además el especialista señala que:

$G1 \not\subset G2$

Por otra parte, dado el siguiente DAG generado:

Fig. DAG generado por cualquier método.



Como primer paso se buscan todas las relaciones entre los nodos del DAG de la siguiente forma:

$A1 \rightarrow A4, A4 \rightarrow A5, A5 \rightarrow A8, A7 \rightarrow A6, A6 \rightarrow A8$

Posteriormente se forma la tabla de restricciones colocando todas las etiquetas de la forma $j [k,l,n] Am, P\%, Q\%$.

Fig: Tabla de restricciones.

1	[1, 3, 5]	A1, 100%, 100%
1	[]	A2, 100%
1	[3, 4, 5]	A3, 100%, 100%
1	[4, 5, 5]	A4, 100%, 100%
1	[5, 5,5]	A5, 100%, 100%
2	[6, 7, 7]	A6, 100%, 100%
2	[7, 7, 7]	A7, 100%, 100%

De acuerdo con el algoritmo, se busca el primer arco DAG $A1 \rightarrow A4$. Se cazan los atributos (nodos) A1 y A4 con los de la tabla de restricciones. Como estos están en la tabla de restricciones y pertenecen al mismo grupo 1, se busca su secuencia, la cual es exitosa porque $1 = 1$ y $1 < 5$ (por que $n1 = n2$ y $k1 < l2$). Consecuentemente se permite colocar el arco.

Este procedimiento se repite hasta formar el DAG final con la siguiente restricción:

Fig. DAG generado con restricciones.




Tabla de Restricciones de Secuencia
A7 → A6 (80% 10% 8% 2%) (80%)

Conclusiones.

En algunas ocasiones los DAG no siempre está correctos, ya que el espacio de hipótesis con el que cuentan es muy grande. Este trabajo demuestra como se puede adecuar un DAG, generado por cualquier método, a un mundo real, definido por un especialista. Se consideran tres tipos de relaciones entre los atributos: por grupos, por secuencia y cuando se tiene una independencia o no se conoce la relación del atributo con respecto a los otros.

Fue dado un algoritmo que está compuesto en dos partes. La primera intenta colocar todas las restricciones dadas por el especialista en el DAG. La segunda parte, intenta dar reconstruir el DAG, dando diferentes informaciones al especialista, para que él pueda reducir sus restricciones o usar otro algoritmo para construir un DAG. Como trabajo futuro se propone optimizar está segunda parte del algoritmo.

Por otra parte, en este trabajo fue propuesto un factor de aproximación, tanto en las contradicciones de las restricciones de grupos y de secuencias que fueron declaradas. Ésta restricción forma una medida para indicar que tan lejos está un DAG de una restricción. En caso de que ningún DAG se haya generado, el factor de aproximación determina que tan distante está todo el DAG de todas las restricciones declaradas por el especialista.

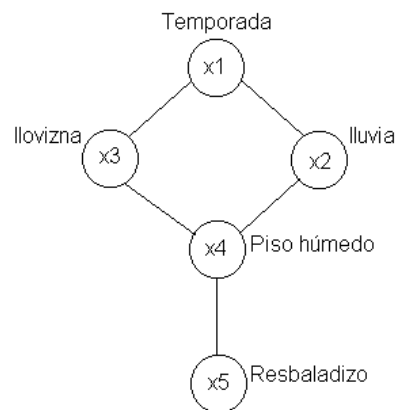
Finalmente algunas aplicaciones de este tipo de restricciones forman problemas donde los atributos son secuencias de tiempo, lo hace que este tipo de restricciones sean demasiado importantes. Otros usos de este tipo de restricciones son en problemas genéticos, donde debe existir una clara separación entre los atributos de los padres del individuo.

Anexo Concepto de d-separation.

Si X, Y y Z son subconjuntos disjuntos de nodos en un GAD, entonces se dice d-separate X de Y, si no existe camino desde un nodo en X hasta uno en Y, donde las siguientes condiciones establecen : (1) Cada nodo con flechas convergiendo es o tiene un descendiente en Z y (2) los demás están fuera de Z.

Un camino se dice activo si satisface estas condiciones, de lo contrario se dice que está bloqueado por Z.

Ejemplo.



Dada ésta RB, donde $x1 = \{\text{Primavera, Verano, Otoño e Invierno}\}$ y las demás son de tipo binario ($x2 = \{\text{lluvia, -lluvia}\}$, etc). Los conjuntos $X = \{x2\}$ y $Y = \{x3\}$ están d-separated por $Z = \{x1\}$; el camino $x2 \leftarrow x1 \rightarrow x3$ esta bloqueado por $x1$ que pertenece a Z y el camino $x2 \rightarrow x4 \leftarrow x3$ esta bloqueado porque $x4$ y todos sus descendientes están fuera de Z . Por otra parte, X y Y no están d-separated por $Z' = \{x1, x5\}$ por que el camino $x2 \rightarrow x4 \leftarrow x3$ es activo por $x5$, quien es descendiente de $x4$ y pertenece a Z' .

Referencias Bibliográficas.

[Pearl, 1988]	Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference. Morgan Kaufmann, San Mateo, CA, 1988.
[Gavin Falk G, Fahey T.]	Clinical prediction rules. BMJ2009;339:b2899
[Doust, Jenny]	Using probabilistic reasoning. BMJ Publishing Group Ltd. Doi:10.1136/bmj.b3823

Transmisión de Conocimiento.

Por Jorge Rodas-Osollo

Se suele recurrir a la imagen de la Sociedad del Conocimiento para definir la tendencia de los países desarrollados. Más allá de las escenas que nos ofrecen diariamente los medios de comunicación y de la posible distorsión de la realidad que puedan proporcionarnos, es cierto que la sofisticada especialización que han alcanzado las diferentes ramas del saber produce una ingente cantidad de información que, si fuera convenientemente divulgada, mejoraría sin duda las condiciones de vida de millones de personas y en algunos casos ayudaría a explicar fenómenos que parecerían sujetos al ámbito de lo enigmático.

Sin embargo, tales resultados apenas rebasan los límites de las publicaciones especializadas y sólo alcanzan a las comunidades de intereses de los científicos y en el mejor de los casos, de quienes financian las investigaciones. Frente a ese aislamiento, aumentan cada vez más las supersticiones y prospera el oscurantismo, que tanto desprestigia la búsqueda del conocimiento tras las apariencias y las preguntas audaces.

Se hace necesario cubrir ese abismo que parece infranqueable entre el saber y sus destinatarios, que son los seres humanos, mediante una labor paciente y meticulosa de indagación, divulgación y transmisión. Es indispensable ese esfuerzo, si no queremos que la ignorancia acabe por embrutecernos, si queremos que la Edad media que se detecta sobre todo en los síntomas sociales, no vuelva a sumirnos en la oscuridad de los miedos y el analfabetismo.

La posibilidad de cubrir el abismo la ofrece las nuevas tecnologías de la comunicación, que tanto están marcando los hábitos en nuestro tiempo, pues nos plantean cada día nuevos retos que ponen a prueba nuestra capacidad de adaptación a un medio siempre cambiante.

Por ejemplo tenemos Internet, como una plataforma global donde se escenifican los cambios de orientación en los comportamientos y se ponen en evidencia las debilidades sociales y morales del sistema que sustenta ese potente instrumento de comunicación.

Todavía es pronto para poder calibrar en su justa proporción de qué manera esta compleja red de relaciones está influyendo en los procesos cognitivos de los que navegan por sus aguas virtuales, aunque ya hemos podido detectar que favorece determinados vicios inconfesables y también alienta y beneficia a los que buscan el conocimiento, por muy fragmentado y disperso que se encuentre en los laberintos de las líneas que nos ponen en contacto con los más recónditos archivos o bases de datos.

Tenemos también la certeza de otro interesante estímulo y es el desafío que presenta a la creatividad, en el sentido de la puesta en práctica de la potencia imaginativa para encontrar nuevos estilos, aplicaciones originales y en cierto sentido extraer todos los posibles beneficios que puede proporcionarnos.

La evolución tecnológica, que ha logrado la Humanidad en esta fase de su Historia, debe corresponderse con un desarrollo de las potencialidades que aun están latentes en cada ser humano, sin olvidar la necesidad de profundizar en una ética que oriente el sentido de las finalidades y de los objetivos.

La técnica nos invita a mirar hacia delante, a experimentar nuevos métodos y estilos, a sacudirnos inercias que pertenecen a un tiempo ya pasado. He aquí uno de los desafíos de nuestro tiempo.

Finalmente, no cabe duda que Internet—entre las más populares tecnologías de comunicación—está cumpliendo un deber divulgador, dando facilidades a los investigadores y esta revista pretende

aportar su granito de arena difundiendo aquello que nos resulta interesante para mejorar la interpretación del mundo hoy en día.