

INTEGRACIÓN DE REDES BAYESIANAS Y RAZONAMIENTO BASADO EN CASOS, EN SISTEMAS DE AGENTES

Resumen

En Inteligencia Artificial, a medida que se ha trabajado en dominios más complejos y en aplicaciones más reales, se ha comenzado a utilizar técnicas que integran distintos tipos de razonamiento y que aprendan a través de distintos métodos. En tal sentido, los sistemas de agentes proporcionan una plataforma en la cual estas integraciones pueden estudiarse y experimentarse para obtener diferentes comportamientos y alcanzar sus objetivos.

Como ejemplo de esto, en este trabajo se quiere mostrar posibles integraciones entre redes Bayesianas (BN) y razonamiento basado en casos (CBR). Estas técnicas son utilizadas cooperativamente en la resolución de problemas y en el aprendizaje, para encarar distintos aspectos de un agente o de un sistema multiagente. Se presenta un resumen de los aspectos de ambos paradigmas de resolución de problemas, se dan referencias de su integración y dos ejemplos de aplicaciones de agentes que la utilizan de diferente forma.

Introducción a los conceptos involucrados

Razonamiento basado en casos (CBR)

Según J. Kolodner [9] Razonamiento basado en casos puede significar: adaptar viejas soluciones para cubrir nuevas demandas, usar viejos casos para explicar nuevas situaciones, usar viejos casos para criticar nuevas soluciones, razonar a partir de precedentes para interpretar una nueva situación, o crear una solución equitativa a un nuevo problema. En síntesis, esta línea de investigación en IA destaca la importancia de utilizar, al igual que lo hacemos los seres humanos, experiencias anteriores al enfrentar una situación nueva.

CBR es un paradigma de resolución de problemas y de aprendizaje, que encara la reutilización y adaptación de soluciones almacenadas de problemas similares, donde las soluciones son almacenadas en una base de casos cuidadosamente indexada. Puede verse como un proceso cíclico que combina resolución de un problema y aprendizaje de su experiencia. Debe destacarse dos puntos fundamentales que caracterizan a los sistemas CBR:

- El aprendizaje no es un módulo que se agrega a un sistema basado en conocimiento, sino que constituye una parte básica del desarrollo, integrándose a la metodología con que se aborda la resolución de problemas.
- El papel dinámico y central que adquiere la memoria, que no es ya un simple receptáculo de hechos establecidos en el curso de una consulta, sino que debe organizarse para permitir la memorización de episodios, y su correcto indexado, para poder evocarlos cuando resulten útiles en el análisis de casos futuros

Aadmodt y Plaza [1] utilizan un framework para describir métodos y sistemas CBR y establecen un ciclo general de cuatro subprocesos que lo componen:

- 1- Recuperar (retrieve) recupera el caso o los casos almacenados más similares.

- 2- Reutilizar (reuse): utilizar la información y el conocimiento del caso para resolver el problema.
- 3- Revisar (revision) se revisa la solución propuesta
- 4- Retener (retention) almacenar las partes de esta experiencia que puedan servir en la futura resolución de problemas.

Cada proceso involucra un número de pasos más específicos que Aamodt y Plaza [1] describen en detalle. En la figura 1 se ilustra este ciclo.




Figura 1. El ciclo del CBR

Como se indica en la figura 1, el conocimiento general, dependiente del dominio, toma parte en este ciclo soportando el proceso del CBR. Este soporte puede ser muy débil (o ninguno) a muy fuerte, dependiendo del tipo del método CBR. Como ocurre en general en IA, no hay un método de CBR que se adapte a todo dominio de aplicación, el desafío es entonces, desarrollar métodos que sirvan para un dominio y aplicación particular.

A partir de estas ideas, los sistemas que se desarrollan se fundamentan en una representación extensiva del dominio, caracterizada por un universo de casos disponibles que se utilizan cuando se pretende encarar una nueva situación. Por otra parte, a medida que se enfrentan a nuevos casos, los sistemas incrementan su experiencia incorporando lo que aprenden a la representación que ya disponen.

Puede afirmarse que estos sistemas aprenden fundamentalmente de dos formas: almacenando nuevos casos y asignando o adaptando los índices correspondientes en la base de casos. El sistema se volverá más eficiente en su razonamiento y mejorará su actuación al

incrementar su biblioteca de casos disponibles. Pero también es muy importante como se clasifican estos nuevos casos en la memoria. Los índices que se asignan, la similitud o diferencia con los otros casos almacenados, le permite disponer de contextos más ricos que le darán la posibilidad de aproximarse a las nuevas situaciones con mayores probabilidades de éxito. En este punto se debe destacar la importancia que pueden tener los ejemplos negativos. Si bien se han planteado sistemas CBR que solo aprenden desde el éxito, sin duda alcanzan mejores resultados aquellos que tienen en cuenta sus fracasos. Esto se plasma también a través de la correspondiente asignación de índices que muchas veces son fundamentales para evitar que el sistema reitere conductas que en el pasado lo han conducido a cometer errores serios.

En los sistemas que utilizan las técnicas de CBR, también es posible generalizar, desde el momento en que siempre se puede encontrar casos indexados en forma parecida o que apuntan a una misma solución.

Redes Bayesianas (BN)

Las redes Bayesianas permiten modelizar un dominio con incertidumbre, y razonar a partir de él. Los mecanismos de inferencia utilizados se basan en la topología de la red, el uso de probabilidades condicionales y en el teorema de Bayes para su propagación. Dependiendo del dominio, las BN pueden capturar el conocimiento incierto de manera natural y pueden ser eficientes.

Las BN son redes de relaciones probabilísticas entre pequeños grupos de proposiciones relacionadas semánticamente. Son grafos dirigidos acíclicos que pueden modelar dominios con incertidumbre. En estos grafos se tiene la siguiente modelización:

- Los nodos representan proposiciones (conjunto de variables aleatorias)
- Los arcos entre nodos representan relaciones causales entre las proposiciones, la fuerza de los arcos son las probabilidades condicionales
- Por cada nodo hay una tabla de probabilidad condicional que sirve para cuantificar los efectos de los padres sobre el nodo.

Por lo general, para el experto en el dominio resulta sencillo establecer qué relaciones de dependencias directas son válidas, lo que constituye la topología de la red. Podría considerarse a la topología de la red como una base de conocimientos abstractos, que representa la estructura general de los procesos causales del dominio. Luego hay que especificar las probabilidades condicionales de los nodos que intervienen en las dependencias directas, tarea que suele ser más dificultosa. Estas probabilidades representan la incertidumbre inherente a los enlaces, las cuales resumen un conjunto de posibles circunstancias en que las relaciones causales puedan darse. Con estas probabilidades condicionales se calculará la probabilidad de que una proposición (nodo) sea verdadera y es llamada creencia (belief), reflejando nuestra confianza en la proposición.

En la figura 2 se muestra un ejemplo de una red junto a las tablas de probabilidad condicional. Como se considera a todos los nodos boléanos, la probabilidad de que el nodo sea falso será 1 menos la probabilidad del nodo. Cada fila en la tabla de probabilidad condicional asociada a un nodo, representa el valor del nodo condicionado a los valores de los nodos padres.

Estas redes sirven para realizar inferencias en distintas situaciones, el mecanismo consiste en buscar respuestas (nodos) de alta probabilidad a las preguntas (situaciones dadas o planteadas).




Figura 2 Red Bayesiana con probabilidades condicionales

En el ejemplo de la figura 2, para calcular la probabilidad de M sabiendo que se tienen A, $\neg B$ y $\neg E$, debe hacerse:

$$P(M, A, \neg B, \neg E) = P(M/A) P(A/\neg B, \neg E) P(\neg B) P(\neg E) = \\ = 0.7 * 0.95 * (1-0.001) * (1-0.002) = 0.663$$

Este proceso puede generalizarse como:

$$P(x_1, \dots, x_n) = \prod_{i=1, n} P(x_i / \text{Padres}(x_i))$$

Una BN puede construirse incrementalmente agregando nodos y arcos, según las dependencias a los otros objetos y, la tabla de probabilidad condicional correspondiente. Como los arcos en la red señalan dependencia entre conceptos, la independencia se hace explícita en la ausencia de arcos y en la separación de grafos. Un punto principal establecido por Pearl [10] es que los arcos no deben considerarse sólo nodos estáticos, sino como caminos que dirijan el flujo de datos en el proceso de preguntas y de actualización del conocimiento.

Una de las limitaciones de las BN es que su complejidad computacional es exponencial con el número de nodos. Se trabaja en este problema y una posible solución es reemplazar una gran red por un conjunto de redes más pequeñas. Otro inconveniente es la asignación de todas las probabilidades condicionales, las cuales deben ser especificadas precisamente y en la práctica, muchas veces, representan juicios subjetivos. Para subsanar este punto un tópico de interés en investigación es el aprendizaje de la estructura de BN [7] y se han planteados distintos métodos para su resolución, en particular se ha usado un CBR para generar los casos de aprendizaje como se verá en uno de los ejemplos que se presentan.

Integración CBR – BN

La integración entre el razonamiento basado en casos y las redes Bayesianas puede realizarse de distintas formas ya que ambas técnicas pueden considerarse como paradigmas de razonamiento y de aprendizaje. La integración varía según que rol o roles se le asigne a cada una y como sea el flujo de información y de control (quien sirve a quien). Se puede usar a una de las dos como método de aprendizaje, o puede ser que se aprenda a través de las dos. La inferencia puede hacerse a través del CBR o puede ser que se utilice la inferencia Bayesiana, o ambas, en distintas etapas de un proceso de razonamiento. Todas estas alternativas hacen que se puede trabajar de forma distinta la colaboración del CBR y BN.

Existen antecedentes de trabajos que han utilizado esta integración. En varios de ellos, el razonamiento lo guía el CBR y se utiliza una red Bayesiana para dar estructura, junto a información probabilística, a la base de casos. Esta estructura de red permite luego recuperar, utilizando la inferencia Bayesiana, los nodos más adecuados (con mayor probabilidad) para una situación dada o planteada.

Entre las experiencias desarrolladas con este enfoque, podemos mencionar el trabajo de Croft & Turtle [5] en tareas de recuperación de documentos. Ellos evalúan la precisión y el recall de los documentos recuperados (casos) dado una consulta (lista de palabras claves). Ellos usan una BN para relacionar los documentos con los nodos de términos y consultas. Las probabilidades de un nodo término dado un caso, refleja la frecuencia de la palabra clave en el caso, mientras que una consulta es simplemente conectada a las palabras claves que contiene. El CBR dada una consulta, recupera el documento con máxima probabilidad, usando la BN.

Breese & Heckerman [3] integran BN y CBR para una tarea diagnóstica, tratando problemas para un sistema operativo de Microsoft. Ellos relacionan causas de casos con síntomas observables en una BN de tres niveles. Un plan reparador es almacenado junto a cada causa. Utilizan un ciclo de CBR que consiste en la búsqueda de posibles causas de un síntoma dado utilizando la red. Las causas recuperadas son rankeadas de acuerdo al costo de reparación, se intentan los planes reparadores hasta que uno tiene éxito. El usuario evalúa el éxito de la reparación que se propone y se actualiza la BN.

Otros trabajos usan CBR como modelo de aprendizaje de una BN. Como la construcción de la red puede ser compleja y dificultosa la asignación de probabilidades condicionales, entonces, se utiliza la técnica de CBR para aprender de los casos.

El aprendizaje puede implementarse a través de los dos modelos, incrementando la base de casos con la actualización de sus índices y actualizando la red Bayesiana con sus probabilidades. La estructura de la base de casos y la BN pueden superponerse o ser independientes. En particular, se describen a continuación dos aplicaciones, una de un agente y otra de un sistema multiagente, en la que la integración se concibe en dos formas distintas.

Cooperación de Razonamiento Bayesiano y Basado en Casos para Resolver Tareas de Planificación Multiagentes [2]

Introducción

INBANCA (Integrating Bayesian Networks with Cased Based Reasoning) [2] es una arquitectura integrada de resolución de problemas, en la cual BN y CBR trabajan cooperativamente en tareas de planificación multiagente. Este incluye tareas dinámicas de dos equipos y si bien fue desarrollado en el Naval Research Laboratory para problemas que enfrenta el personal naval, en trabajos de estrategia y logística, se muestran sus principios en

un ejemplo de soccer. Las BN son usadas para caracterizar la selección de una acción mientras que el CBR es usado para determinar como implementar las acciones seleccionadas.

En este sistema se utiliza CBR como paradigma de resolución de problemas. Esto permite expresar la experiencia en forma de casos, de tal forma que los usuarios no tienen que formular el conocimiento de algún formalismo (reglas), sino que tienen que proveer conocimiento para indexar, relacionar y adaptar casos. Se necesita algún esquema para incorporar este conocimiento, algunos investigadores han considerado a las BN para este fin. Estas redes pueden ser utilizadas con provecho para cubrir las necesidades de CBR, en particular se puede usar BN para proveer información contextual al CBR y asistirlo en la elección de características. En INBANCA se implementó una aproximación integrada donde métodos Bayesianos proveen conocimiento al CBR, que usa una representación compleja de casos. La figura 3 resume la estructura de control del algoritmo presentado. Se enfoca el trabajo para su aplicación en equipos multiagentes, con modelos de dominios incompletos y frecuentes feedback sobre el proceso de toma de decisiones.

```

Key:
  A: Action network
  L: Case library
  S: Current state

INBANCA(A, L, S) =
  WHILE not(stopping_criterion_satisfied(S))
    Sinitial := S ; Store the initial state
    a := select_action(A, S) ; Fetch 'best' action for this state
    c := retrieve_case(a, L) ; Retrieve an action-specific case
    DO (1 ≤ i ≤ plan_length(c)) ; For each step i in this case's plan:
      Sprevious := S ; Store the current state,
      S := execute(action(c, i), Sprevious) ; execute the case's next action step,
      {A, L} := learn(S, Sinitial, c, i, A, L) ; and learn from the state changes
      IF (failure(S))
        THEN RETURN {A, L} ; failures terminate this loop
  RETURN {A, L}

```

Figura 3 INBANCA: algoritmo que integra CBR y BN para planificación.

INBANCA usa BN para seleccionar acciones utilizando un modelo abstracto de las distintas acciones y CBR para seleccionar el plan que implementa esa acción, donde los casos son experiencias de planes que permiten implementar las acciones. Los pasos del plan son ejecutados en el estado actual hasta que la meta de la acción se cumple o falla. Este bucle selección-ejecución continúa hasta que algún criterio de parada es satisfecho (se anota un gol o se termina el tiempo).

El aprendizaje toma lugar después de que cada acción es ejecutada. Este involucra actualizar las BN en respuesta a la selección de acción, actualizar los casos basándose en el feedback de aplicar sus planes de acción y actualizar la base de casos (agregando, modificando índices, etc). Generalmente se aprende a partir de la falla de un plan, lo que lleva a revisar el modelo de la red. Nuevos casos se agregan a medida que se acumula experiencia. La figura 4 resume en forma simplificada, como cooperan los componentes de esta arquitectura.




Figura 4 Versión simplificada de la arquitectura de INBANCA.

El dominio del soccer

Se selecciona el soccer como caso de prueba para estudiar como un agente puede mejorar su actuación en un entorno interactivo basado en su experiencia. En este juego, cada agente juega un rol distinto y generalmente se encara la resolución de tareas en equipo. Se asume que se dispone de un modelo incompleto para guiar las tareas de soccer. Además el soccer provee un excelente dominio para estudiar el aprendizaje multiagente con estrategias integradas de razonamiento, por lo cual, este dominio ha sido elegido para muchas experiencias con sistemas multiagentes, entre las cuales podemos mencionar la iniciativa RoboCup [8].

El dominio esta definido por objetos y funciones sobre objetos. Los objetos son móviles (pelota, jugadores/ agentes) o estáticos (posiciones, líneas del campo y goles). El entorno es descrito por un conjunto de entradas sensoriales (sensoriales primitivas): orientación, posición, equipo y velocidad. Básicamente, se seleccionan las acciones deseadas sobre la base de estos sensores, utilizando predicados y funciones (sensoriales más abstractas) como por ejemplo:

cerca (O1, O2): si los objetos O1 y O2 están cerca, se le asocia cierta probabilidad

abierto (O): el objeto O está abierto si no existe otro agente A tal que *cerca* (O, A)

posee (A): es verdadero si A tiene la pelota.

visible(A,O): es verdadero si la dirección relativa del objeto O está dentro de los 90° de la *orientación* (A)

Las acciones son representadas por funciones probabilísticas, algunas de las acciones primitivas son:

patear (A,f): si *cerca* (A, b) entonces A patea la pelota b con fuerza f.

mover (A,d): agente A intenta moverse en la dirección relativa d, se actualiza la posición de A.

patear_a (A,d,f): asumiendo que *cerca* (A ,b), A intenta patear la pelota b en dirección d, es implementada usando mover y patear.

pasar (A,O): asumiendo que está *cerca*(A,b) y *visible* (A,O), entonces A intenta patear b a O.

El éxito de las acciones es definido probabilísticamente. Las acciones complejas serán guiadas por un plan de acción, por ejemplo pueden definirse planes para diferentes pases (triangulares, etc). La adquisición de planes involucra aprendizaje. Se verá un ejemplo de la integración con la acción *pasar*.

Seleccionando acciones mediante Redes Bayesianas

Para el modelo de selección de la acción, se dispone de una red para cada posible acción. Esta es una BN que contienen nodos sensores primitivos o no primitivos (*posición, velocidad, cerca, abierto*, etc) y nodos acciones (*pasar, patear_a*, etc). Todos los nodos representan valores Booleanos y la creencia en su valor es representada por la probabilidad condicional. Un agente evalúa cada red respecto a su estado actual y selecciona la acción con mayor probabilidad. Las redes de acciones están organizadas jerárquicamente.

En esta propuesta el comportamiento de un agente es determinado por la selección de una acción y la base de casos acciones. Se hace énfasis en la reutilización de planes, donde los planes son guardados como casos, y permite no tener que iniciar la planificación cada vez que se encara una acción.

La red de acción de un agente es actualizada cuando nueva experiencia es adquirida y cuando se revisan características abstractas importantes en el modelo de la red. La calidad de la salida al ejecutar un plan, junto al estado resultante, proveen el feedback para la red de acción, el cual es usado para actualizar las probabilidades condicionales. El conjunto de nodos en una red también puede ser actualizado, ya que generalmente los modelos de acción, inicialmente están incompletos.

Usando CBR para implementar acciones

Un caso describe un plan para la acción que ha sido seleccionada. Como las acciones pueden fallar durante la ejecución, los agentes necesitan reparar la causa de la falla o intentar acciones alternativas. Se define que un plan de acción consta de tres partes: condiciones, secuencia de acciones y salidas esperadas. Un ejemplo de un caso para la acción *pase* (A1, A2) se tiene en el siguiente caso:

Nombre: *Caso 1*

- Condiciones:
 - *Cerca* (A1,b)
 - *Compañero* (A1,A2)
 - *Abierto* (A2)
 - *Orientación_relativa* (b,A2,d)
- Secuencia de acciones:
 - *moverse_hacia* (A1, posición(b))
 - *patear_a* (A1,d,f1)
 - *mover* (A1,NW)
- Salidas esperadas:
 - *recibe*(A2,-d)
 - *posee* (A2)
 - *patear* (A2,N,f2)

El ciclo general del CBR consiste en:

Recuperación de casos: La base de casos es particionada de acuerdo a los planes de acción de los casos, un subconjunto para cada acción posible. Se calcula la similaridad para aquellos casos que realizan la acción seleccionada, para ello se utiliza los valores del sensor del estado actual. El caso más similar es recuperado para ser reutilizado.

Reutilización de casos: Cuando un caso es recuperado su plan de acción es activado. Luego las acciones del caso son ejecutadas. Si hay alguna acción no primitivas, esta disparará otra recuperación de casos. Puede verse a esta selección dinámica de casos para alcanzar un paso acción, como una forma de adaptación.

Revisión de casos: Cada acción del caso es ejecutada hasta que la secuencia es completada o alguna acción no puede realizarse, lo que señala la necesidad de que el caso debe revisarse. La reparación de la falla se difiere hasta el fin de la ejecución..

Retención de casos: Involucra actualizar las bases de casos y sus estructuras de indexación. Se almacenan los casos necesarios para cubrir mejor el espacio de posibles estados. La estructura de indexación también es actualizada con los nuevos casos almacenados..

El ciclo mencionado es ejecutado por cada agente de un sistema multiagente. Si bien cada agente aprende sus propias experiencias, asumimos que los resultados del aprendizaje son compartidos por todos los agentes. Sin embargo debido a que la capacidad de percepción de cada agente es limitada, los casos que seleccione serán diferentes. Para seleccionar una estrategia para esta cooperación, dos de los puntos a tener en cuenta son: un agente sólo quiere comunicar sus intenciones a sus compañeros y los agentes deben anticipar las acciones de sus compañeros para producir un comportamiento de planificación cooperativa. Mientras que algunas estrategias son grupales, cada agente tienen sus propias tendencias y el trabajo en equipo involucra aprender como anticiparse mejor a cada comportamiento individual. Los autores planean dos propuestas: compartida e individual para llevar adelante la cooperación entre agentes de un equipo.

Los autores se proponen utilizar el simulador RoboCup para testear esta propuesta y evaluarla en su conducción de las competencias de soccer. También plantean varios desafíos en el futuro plan de investigación como: la evolución cooperativa, un paradigma integrado de razonamiento, lenguaje de representación y organización de la memoria.

Construcción de perfiles de usuarios con Razonamiento Basado en Casos y Redes Bayesianas [11].

Introducción

En esta aplicación se usa un método de inferencia basado en la red Bayesiana para construir perfiles de usuarios. CBR participa como método de aprendizaje de la red, proveyendo información almacenada en la base de casos, para desarrollar en forma incremental la BN y también para filtrar parte de las conclusiones que se deduzcan utilizando inferencia Bayesiana.

La tecnología de agentes desarrolla actualmente muchos asistentes a los usuarios, entre los cuales podemos considerar filtrado y recuperación de información, automatización de tareas, interfaces, etc. Para asistir a los usuarios correctamente, los agentes deben aprender

sus preferencias, hábitos e intereses, los cuales son representados por medio de perfiles de usuarios.

Los perfiles de los usuarios varían en contenidos, mecanismo de adquisición y uso de un agente a otro, y el tipo de información que usan es dependiente de la aplicación. Existen distintas técnicas para la construcción de perfiles, una que permite su desarrollo incremental se basa en la integración de BN y CBR. CBR provee un mecanismo para almacenar las experiencias de los usuarios que valen la pena recordar para determinar sus hábitos y preferencias. BN provee una técnica para modelar cuantitativamente y cualitativamente las relaciones entre ítems de interés. La red se construye a partir de la información de los casos almacenados en la base de casos. Los casos también proveen el conocimiento para detectar patrones en la conducta del usuario y determinar su rutina.

Construcción del perfil de un usuario

Se muestra a través de un ejemplo, como funciona esta integración de paradigmas en la construcción de perfiles. Se considera la base de datos de una universidad y que el usuario es un profesor o alumno que realiza consultas y realiza distintas tareas sobre la base, para obtener la información que necesita (departamentos, carreras, estudiantes, cursos, asistentes, etc) Se enfoca en la información que los usuarios necesitan habitualmente o rutinariamente para realizar sus tareas. El objetivo de un agente asistente es determinar la información que necesita en los distintos momentos y proveérsela directamente. El agente observará al usuario mientras realiza las consultas y guardará esta información en forma de casos. Cada caso registrará los atributos usados para la consulta, sus valores y datos temporales (hora, día, mes, etc.) de la consulta. Las consultas son clasificadas de acuerdo a su similitud con consultas ya realizadas, utilizando una métrica de similaridad que considera tipos y valores de atributos e información temporal. Las relaciones entre atributos son modeladas usando BN y la fuerza de cada relación es determinada por la probabilidad asociada.

La información almacenada en la base de casos y en la BN de un usuario dado, es usada para construir su perfil. El perfil contiene información sobre los tipos de consultas que realiza el usuario frecuentemente y su ubicación temporal. Este consiste en información estadística (frecuencia de cada atributo en las consultas, etc.) junto a información inferida, la cual es obtenida básicamente a través de la BN. La rutina del usuario pertenece al perfil inferido y comprende una serie de situaciones en las cuales el usuario hace consultas frecuentes, junto a las consultas asociadas. A partir de la construcción del perfil del usuario se obtienen consultas sugeridas con los atributos y los valores de atributos que se consideran relevantes. El perfil es usado para proponer la ejecución de consultas relevantes para un usuario en un momento apropiado. La figura 5 muestra el proceso general de construcción del perfil del usuario utilizando esta técnica.




Figura 5 Construcción del perfil del usuario integrando CBR y BN

Usando Razonamiento Basado en casos

En el contexto de un usuario que siempre realiza consultas a una base de datos, las consultas realizadas en el pasado proveen alguna información sobre las posibles consultas que hará en el futuro. Supongamos que un profesor del departamento de Computación de una Universidad realiza consultas a la base de datos de la facultad con cierta frecuencia y de forma similar. En este caso la información que necesita puede ser inferida con la técnica presentada. Un agente cuyo objetivo es asistir a los usuarios que consultan a la base de datos de esta universidad, debe detectar la información que necesita cada usuario y construir el perfil de cada uno y de esta forma puede realizar las consultas que se infieran como relevantes con anticipación.

Cada consulta realizada por el usuario es representada en forma de caso. Cada caso es una porción de conocimiento que representa una experiencia, el cual ayudará al proceso de razonamiento. Los atributos y características usadas en la consulta son importantes para determinar los tópicos en que el usuario está interesado. Un caso tiene tres partes importantes: la descripción de la situación o problema, la solución y los resultados de aplicar la solución al problema. En esta aplicación, la descripción incluye los atributos usados para realizar la consulta (filtros), los valores de los atributos, la meta del usuario, información sobre el usuario y datos temporales. La solución en este ejemplo es un código que identifica cierto tópico de interés. El código es determinado comparando la consulta nueva con anteriores y es usado para agrupar consultas similares. Se utilizan métricas de similaridad para comparar los atributos involucrados y sus valores, las cuales darán como resultado un puntaje representando la similitud de las consultas (si es alto tendrán igual código, sino, se le asigna un nuevo código a la nueva consulta). También hay métricas para comparar los aspectos temporales de las consultas. La parte correspondiente a la salida, describe los resultados de la consulta. En la figura 6 se puede ver un ejemplo de caso que representa la consulta hecha por John Smith.




Figura 6 Un caso representando una consulta

Usando las Redes Bayesianas

En la técnica descrita las BN modelan las necesidades de información de un usuario. Cada nodo representa un atributo o característica usada en la consulta a la base de datos. Los arcos corresponden a las relaciones entre los atributos usados como filtros, las cuales son dependientes del dominio. Las probabilidades se obtienen a partir de las veces que cierto atributo aparece en las consultas de un usuario (casos en la base de casos), considerando que esta frecuencia representa la importancia del atributo para el usuario.

En el ejemplo de la universidad, existen relaciones de dependencia entre los elementos involucrados. Las carreras pertenecen a departamentos, cada carrera tiene cursos y profesores asociados. Estas relaciones constituyen la topología de la BN. También modelan a través de las probabilidades condicionales, la probabilidad de que un nodo hijo (carrera) sea usado como filtro, dado que el nodo padre (departamento) también es usado. Estas relaciones pueden establecerse mediante algoritmos de aprendizaje, mientras el usuario consulta a la base de datos. La figura 7 muestra un ejemplo de BN que modela el espacio de consulta de John Smith en este ejemplo.




Figura 7 BN representando el espacio de consulta de un usuario

La BN es construida gradualmente mientras el usuario consulta. Cada consulta es almacenada en la forma de caso y por cada atributo involucrado, se agrega un nodo a la red. Se establecen arcos entre los nodos de acuerdo al modelo de relaciones en el dominio. También se actualizan las probabilidades con cada consulta.

Integración

En esta técnica se utiliza al CBR como esclavo, ya que sirve como método de aprendizaje para la BN. Los casos almacenados en la base de casos son utilizados para actualizar la BN. A partir del modelo expresado en la BN se utilizan algoritmos existentes para inferir las consultas más probables. Los casos son usados también, para filtrar las consultas que fueron sugeridas por el mecanismo Bayesiano de inferencia.

El perfil del usuario se construye con información almacenada en la base de casos y en la BN. Contiene información estadística sobre las consultas (atributos más frecuentes, valores más frecuentes, metas y códigos más frecuentes, etc) e información inferida sobre los tópicos de interés (atributos y valores relevantes, combinación de atributos relevantes, etc.). También la rutina del usuario es parte del perfil, esta consiste en una serie de situaciones en la cual el usuario consulta a la base. Como parte importante del perfil inferido se encuentran las consultas sugeridas. Estas se formulan combinando los atributos y valores de atributos que se infirieron como relevantes en las distintas situaciones. Las consultas resultantes son filtradas

utilizando los casos para considerar solo las que tengan sentido para el usuario. La Figura 8 muestra un ejemplo del perfil de John Smith.

Statistic Profile	
Most Freq. Attr.	
Department	100%
Career	80%
Course	80%
Most Freq. Values	
Department: Computer Sc	70%
Career: Comp. Sc. Eng.	100%
Programmer	100%
Course: Logic Prog	50%
OO Prog	87%

Inferred Profile	
Most relevant indep. attr.	
Department: Comp Sc.	70%
Most relevant dep. attr.	
Career/department	
Comp. Sc. Eng/Comp Sc	100%
Programmer/Comp Sc	100%
Course/career	
Logic Prog/Comp Sc Eng	50%
OO Prog/ Comp Sc Eng	87%
Attendance/course	
Present/Logic Prog	100%
Query situations	
Sit 1: Tuesdays	17.30
Sit 2: Mondays	10.00
Suggested Queries	
Query	Routine
{Comp Sc, Comp Sc Eng, Logic Prog, present}:	Sit 1
{Comp Sc, Comp Sc Eng, OO Prog, present}:	Sit 2

Figura 8 Perfil del usuario

La técnica propuesta ha sido incorporada en el desarrollo de un agente inteligente que asiste a un usuario que opera un subsistema encargado del muestreo dentro de un LIMS. Los experimentos realizados han demostrado la utilidad de la técnica propuesta para modelar los intereses y preferencias del usuario. Esta forma de integración también se ha utilizado en otras aplicaciones de agentes asistentes [6]. Se está estudiando la capacidad de esta técnica para modelar los cambios de interés del usuario y se trabaja para considerar el feedback del usuario en la construcción del perfil.

Breves Conclusiones

Se ha presentado dos paradigmas de razonamiento y aprendizaje los cuales se pueden utilizar en forma integrada, obteniéndose una variedad de comportamientos resultantes. Se ha descrito con cierto detalle dos aplicaciones de integración, donde ésta se plantea de forma diferente, asignándole roles diferentes al CBR y a la BN. El fin de esta presentación no ha sido compararlas y analizar las ventajas o desventajas de cada una, ya que las propuestas tienen objetivos diferentes. El interés de mostrar posibles integraciones e implementaciones de las mismas, reside en destacar la importancia de usar aproximaciones integradoras en IA, para encarar problemas más complejos y reales. También a partir de estos ejemplos se puede

ver que las integraciones pueden darse de diferente forma, lo que enriquece más la diversidad de modalidades de trabajo y resultados posibles.

Los agentes y sistemas multiagentes, demandan de nuevas estrategias para obtener comportamientos cooperativos donde el aprendizaje juega un rol fundamental. También constituyen una tecnología donde es posible su experimentación con lo cual se pueden evaluar las distintas propuestas.

Bibliografía

1. Aamodt A. & Plaza E., Case-Based Reasoning: Foundational Issues, Methodological Variations, and System Approach - AI Communications IOS Press Vol 7:1, pp 39-59 – 1994.
2. Aha, D. W., & Chang, L. W. Cooperative Bayesian and case-based reasoning for solving multiagent planning tasks (Technical Report AIC-96-005). Washington, DC: Naval Research Laboratory, Navy Center for Applied Research in Artificial Intelligence, 1996.
3. Breese, J. & Heckerman, D. Decision-Theoretic case-based reasoning. Proceedings of the Fifth International Workshop on Artificial Intelligence and Statistics, pp. 56-63, 1995
4. Cordero D., Roldán P., Schiaffino S., A. Amandi. Intelligent Agents Generating Personal Newspapers”- Proceedings del ICEIS '99 - International Conference on Enterprise Information Systems – Setúbal, Portugal – Marzo 1999
5. Croft, W. & Turtle, H. Retrieval strategies for hipertext. Information Processing & Management, 29, 313-324, 1993.
6. Godoy, D., Amandi, A.: PersonalSearcher: An Intelligent Agent for Searching Web Pages. IBERAMIA-SBIA 2000 - Lecture Notes in Artificial Intelligence LNAI 1952 - Springer Verlag - pp 43 -52 , 2000
7. Heckerman, D. A tutorial on Learning with Bayesian Networks- Technical Report MSR-tr-9506- Advance Technology Division, Microsoft Research, 1995.
8. Kitano, H., Asada, M., Kuniyoshi, Y., Noda, I. & Osawa, E. RoboCup: The robot world cup initiative. Working Notes of the IJCAI Workshop on Entertainment and AI/Alife. Montreal, 1995.
9. Kolodner, J. Case-Based Reasoning – Morgan Kaufmann Publishers, 1993.
10. Pearl, J. Probabilistic reasoning in expert systems: Networks of plausible inference. San Mateo, CA, Morgan Kaufmann.
11. Schiaffino S., Amandi A. "User Profiling with Case-Based Reasoning and Bayesian Networks" - Open Discussion Proceedings, IBERAMIA-SBIA 2000 - Atibaia, Brazil - November 2000 - pp. 12 – 21.