

Centro Nacional de Investigación y Desarrollo Tecnológico

Subdirección Académica

Departamento de Ciencias Computacionales

TESIS DE MAESTRÍA EN CIENCIAS

**Evaluación de Modelos del Estudiante de Sistemas
Tutores Inteligentes que emplean Redes Bayesianas como
Técnica Básica de Operación**

presentada por
Ing. Marilú Cervantes Salgado

como requisito para la obtención del grado de
Maestra en Ciencias en Ciencias de la Computación

Director de tesis
Dr. Manuel Mejía Lavallo

Cuernavaca, Morelos, México. Diciembre de 2016.

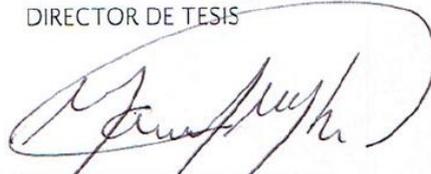
Cuernavaca, Morelos a 17 de noviembre del 2016
OFICIO No. DCC/230/2016

Asunto: Aceptación de documento de tesis

C. DR. GERARDO V. GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de la **Ing. Marilú Cervantes Salgado**, con número de control M14CE057, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis profesional titulado "**Evaluación de Modelos del Estudiante de Sistemas Tutores Inteligentes que emplean Redes Bayesianas como Técnica Básica de Operación**" y hemos encontrado que se han realizado todas las correcciones y observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

DIRECTOR DE TESIS



Dr. Manuel Mejía Lavalle
Doctor en Ciencias
Computacionales
8342472

REVISOR 1



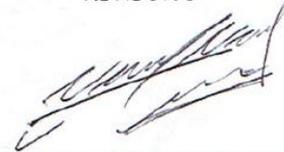
Dr. José Ruiz Ascencio
Doctor en Ciencias
5009035

REVISOR 2



Dr. Raúl Pinto Elías
Doctor en Ciencias en la
Especialidad de Ingeniería Eléctrica
3890453

REVISOR 3



Dr. Luis Gerardo Vela Valdés
Doctor en Ciencias en Ingeniería
Electrónica
7980044

C.p. M.T.I. María Elena Gómez Torres - Jefa del Departamento de Servicios Escolares.
Estudiante
Expediente

NACS/lmz

Cuernavaca, Mor., 2 de diciembre de 2016
OFICIO No. SAC/341/2016

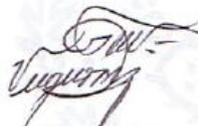
Asunto: Autorización de impresión de tesis

ING. MARILÚ CERVANTES SALGADO
CANDIDATA AL GRADO DE MAESTRA EN CIENCIAS
DE LA COMPUTACIÓN
PRESENTE

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "**Evaluación de Modelos del Estudiante de Sistemas Tutores Inteligentes que Emplean Redes Bayesianas como Técnica Básica de Operación**", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE
"CONOCIMIENTO Y TECNOLOGÍA AL SERVICIO DE MÉXICO"



DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO



SEP TecNM
CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA

C.p. M.T.I. María Elena Gómez Torres.- Jefa del Departamento de Servicios Escolares.
Expediente

GVGR/mcr

Dedicatoria

A mi esposo David Donald Dalman y a mi madre Paulina Salgado Durán.

Agradecimientos

Por su paciencia, su pasión por la investigación y principalmente por ofrecer temas de investigación que ayudan a detectar problemas que afectan a la sociedad en su desarrollo profesional y familiar al Dr. Manuel Mejía Lavalle.

Por su apoyo económico al Consejo Nacional de Ciencia y Tecnología (CONACYT).

Por darme la oportunidad de desarrollar mi proyecto de investigación dentro del departamento de Ciencias Computacionales en la especialidad de Inteligencia Artificial al Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET).

Por las observaciones que permitieron mejorar la investigación que realicé durante este periodo de estudios, agradezco al comité revisor: Dr. José Ruiz Ascencio, Dr. Raúl Pinto Elías, Dr. Luis Gerardo Vela Valdés. Así mismo a la Dra. Yasmín Hernández por su valiosa colaboración y amistad durante mi estancia en el Instituto de Investigaciones Eléctricas.

Por compartir conocimientos y experiencias profesionales a mis amigos y compañeros del Centro Nacional de Investigación y Desarrollo Tecnológico: Estela Ortiz, Hermilo Victorio, Misael Camaños, Christian Hernández, Jorge Ochoa y Liliana Mérida.

Índice General

Lista de Figuras.....	9
Lista de Tablas.....	11
Lista de Algoritmos.....	12
Resumen.....	14
Capítulo 1.....	15
1.1 Motivación.....	16
1.2 Descripción del problema.....	16
1.3 Objetivo general.....	17
1.4 Objetivos Específicos.....	17
1.5 Metodología.....	18
1.6 Justificación y beneficios.....	18
1.7 Organización de la tesis.....	18
Capítulo 2.....	19
2.1 Arquitectura de los Sistemas Tutores Inteligentes.....	20
2.2 Herramientas de Autoría.....	22
2.3 Características del Modelo del Estudiante.....	24
2.4 Redes Bayesianas (RB).....	27
2.5 Lógica Difusa.....	39
2.6 Paquete GeNIe [Pittsburgh, 2016].....	41
2.7 Discusión.....	41
Capítulo 3.....	42
3.1 Antecedentes Institucionales.....	43
3.2 Trabajos relacionados con el proyecto.....	45
3.3 Discusión del estado del arte.....	50
Capítulo 4.....	54
4.1 Model Tracing (Modelo de Trazado).....	55
4.2 Adaptive Bayesian Tests (Pruebas Bayesianas Adaptables).....	57
4.3 Constraint-Based Model (Modelo Basado en Restricciones).....	60
4.4 Análisis de la evaluación de los modelos mostrados en el capítulo.....	63
4.5 Discusión.....	63

Capítulo 5	64
5.1 Caso de estudio, introducción y objetivo	65
5.2 Descripción del diseño de los ME para el caso de estudio	66
5.3 Construcción de los ME para el caso de estudio.....	71
Evaluación del ME a partir de datos.....	72
Evaluación del ME a partir de conocimiento de expertos	76
5.4 Implementación y evaluación de las técnicas de RB a los ME del caso de estudio	76
Evaluación de la técnica de pase de mensajes.....	82
Evaluación de la técnica de Aprendizaje Bayesiano.....	86
Evaluación RB Difusas.....	88
5.5 Análisis.....	89
5.6 Discusión	90
Capítulo 6	91
6.1 Objetivos logrados.....	92
6.2 Resultados finales.....	93
6.3 Trabajo futuro	94
Referencias.....	95
Anexos.....	99

Lista de Figuras

Figura 2.1. Arquitectura básica de un STI [Millán, 2000].	20
Figura 2.2. Tipos de STI con más desarrollo e investigación [Aleven, 2012].	22
Figura 2.3. ME Tipo Estereotipo [Mayo, 2001].	25
Figura 2.4. Modelo de superposición que demuestra el modelado del estudiante con este enfoque [Mayo, 2001].	25
Figura 2.5. Modelo de perturbación [Mayo, 2001].	26
Figura 2.6. Clasificación de ME basados en RB [Mayo, 2001].	27
Figura 2.7. Ejemplo ilustrativo de distribución de probabilidad de una variable aleatoria [Nava, 2002].	29
Figura 2.8. Distribución conjunta de las variables Sabe_Concepto y Resuelve_Ejercicio [Nava, 2002].	30
Figura 2.9. Red Bayesiana para ejemplificar la probabilidad de las variables dados sus padres y la distribución conjunta de dicha red [Huang, 2015].	30
Figura 2.10. Red Bayesiana para desarrollo de ejemplo [Berkeley, 2013].	31
Figura 2.11. Red Bayesiana tipo árbol. [Neapolitan, 2003].	33
Figura 2.12. Red Bayesiana conectada uno a uno [Neapolitan, 2003].	33
Figura 3.1. Relación entre los nodos <i>Rule</i> y <i>Context-Rule</i> en la RB de tipo dominio general de conocimiento [Conati, 2002].	45
Figura 3.2. Modelo diagnóstico NIDA [Chen, 2014].	47
Figura 3.3. Estructura general de GBSM [Millán, 2013].	48
Figura 3.4. Ejemplo de RB estática utilizada en el STI Andes [Conati, 2010].	49
Figura 3.5. Nodos de factorización en el ME de Prime Climb, mostrando el uso de RB dinámicas cuando el usuario hace uso de la acción <i>click</i> [Conati, 2010].	49
Figura 4.1. RB para modelado de estudiante en STI Andes [Conati, 1997].	55
Figura 4.2. Propuesta de resolución de <i>guess & slips</i> por [Conati, 2002].	57
Figura 4.3. Ejemplo a la propuesta de <i>Adaptive Bayesian Test</i> [Millán, 2013].	59
Figura 4.4. Red Bayesiana simple que muestra el desempeño de un estudiante con una sola restricción [Mayo, 2001].	61
Figura 5.1. Objetivo del Caso de Estudio.	65
Figura 5.2. ME a partir de conocimiento de expertos y metodologías utilizadas para su desarrollo.	67
Figura 5.3. RB aprendida de los datos por el algoritmo TAN. Esta red representa el ME.	72
Figura 5.4. ME a partir de conocimiento de expertos.	73
Figura 5.5. Inicialización de nodos $ErroresP_i$.	74
Figura 5.6. Dependencia de nodo Materiales dado nodo ErroresM.	74
Figura 5.7. A) Inicialización del nodo <i>calif_examen_Teórico</i> y B) Evidencia en el nodo <i>calif_examen_Teórico</i> .	74
Figura 5.8. CPT parcial del nodo <i>man</i> .	75

Figura 5.9. Nodos que conservan sus probabilidades condicionales durante el aprendizaje de parámetros.....	75
Figura 5.10. ME utilizado para la implementación del algoritmo de pase de mensajes	78
Figura 5.11. ME utilizado para la implementación de las RB difusas propuestas en [Tang, 2007].	86
Figura 5.12. Función de pertenencia propuesta para el enunciado muchos <i>errores tipo 4</i>	87
Figura 5.13. CPT parcial del nodo <i>man</i>	88
Figura B.1. Conocimiento previo para la obtención de estructura a partir de datos.....	102
Figura C.1. Artículo publicado en MICAI 2016 y que forma parte del caso de estudio presentado en el capítulo cinco sección dos.....	103

Lista de Tablas

Tabla 2.1. Análisis de ME según [Pavlik, 2013].	23
Tabla 2.2. Teorías de aprendizaje según [Mayo, 2001].	24
Tabla 2.3. Clasificación de Modelos de Estudiante en RB [Mayo, 2001].	26
Tabla 2.4. Ejemplo ilustrativo de una tabla de distribución condicional (CPT) [Nava, 2002].	30
Tabla 2.5. Probabilidad de la variable Cliima [Berkeley, 2013].	311
Tabla 2.6. Tabla de probabilidad condicional de la variable <i>Piso mojado</i> [Berkeley, 2013].	31
Tabla 2.7. Fórmulas para el cálculo de λ y π -mensajes, λ y π -valores y probabilidades P^* [Millán, 2000]:	34
Tabla 2.8. Ecuaciones del algoritmo de propagación de evidencia en una red conectada uno a uno [Neapolitan, 2003].	36
Tabla 2.9. Resultados del censo de población [Tang, 2007].	40
Tabla 2.10. Datos del buró de impuestos [Tang, 2007].	40
Tabla 3.1. Resultados de la prueba PEMGU al servidor de tutores [Ceyca, 2004].	44
Tabla 3.2. Resumen de los antecedentes al proyecto de tesis.	44
Tabla 3.3. Heurísticas usadas para actualizar el modelo del estudiante [Mayo, 2001].	46
Tabla 3.4. Concentrado de los trabajos relacionados consultados.	51
Tabla 4.1. Ventajas y desventajas del Modelo de Trazado.	57
Tabla 4.2. Ventajas y desventajas del modelo Pruebas Bayesianas Adaptables.	59
Tabla 4.3. Ventajas y desventajas del Modelo de CBM	62
Tabla 4.4. Análisis de los ME presentados en el presente capítulo.	63
Tabla 5.1. Correspondencia entre Constraint-Based Model y el Modelo a partir de datos.	67
Tabla 5.2. Tabla del sistema AlenED que contiene los errores en la evaluación de la selección de materiales.	68
Tabla 5.3. Tabla del sistema Alen3D la cual contiene los errores de los usuarios de la evaluación de cada maniobra.	68
Tabla 5.4. Tabla del sistema Alen3D que contiene los resultados de la calificación del examen teórico por cada usuario.	68
Tabla 5.5. Tipos de errores en la evaluación de pasos y su descripción.	68
Tabla 5.6. Tipos de errores en la evaluación de selección de materiales y su descripción.	68
Tabla 5.7. Ponderación establecida para los errores en selección de material.	69
Tabla 5.8. Ponderación establecida para los errores en pasos.	69
Tabla 5.9. Descripción de las características utilizadas para el aprendizaje de modelo Bayesiano	69
Tabla 5.10. Valores discretos del atributo <i>califTeorica</i> .	70
Tabla 5.11. Etiquetas y descripción de la discretización de los datos.	71
Tabla 5.12. Ventajas y desventajas del ME a partir de datos.	72
Tabla 5.13. CPT de los nodos <i>Paso1, Paso2, Paso3, Paso4, Paso5, Paso6, Paso7, Paso8, Paso9, Paso10</i> .	73
Tabla 5.14. Evaluación del ME a partir de conocimiento de expertos.	76

Tabla 5.15. Implementación para la obtención de los valores π	78
Tabla 5.16. Fórmulas necesarias para el desarrollo del algoritmo 2.	79
Tabla 5.17. Implementación a cada nodo para obtener los Valores λ	80
Tabla 5.18. Implementación de los mensajes λ	80
Tabla 5.19. π mensajes de nodo origen a sus hijos.....	81
Tabla 5.20. Probabilidad a posteriori del los nodos de ME a partir de conocimiento de expertos modificado.	81
Tabla 5.21. Evaluación de la técnica de pase de mensajes.	82
Tabla 5.22. Muestra de la base de datos utilizada para la implementación del algoritmo Chow&Liu.	83
Tabla 5.23. Evaluación de la técnica de Aprendizaje Bayesiano utilizando el algoritmo Chow&Liu	86
Tabla 5.24. Desarrollo del método propuesto en [Tang, 2007].....	87
Tabla 5.25. Evaluación de la técnica RB difusas	88
Tabla 5.26. Análisis de los ME y técnicas presentadas en este documento	89
Tabla 6.1. Objetivos y actividades realizadas para su logro.....	92
Tabla B.1. Resultados de experimentación de aprendizaje de estructura.....	100

Lista de Algoritmos

Algoritmo 1. Algoritmo de propagación en redes con forma de árbol [Millán, 2000]	35
Algoritmo 2. Propagación de creencias en redes Bayesianas clase <i>polytree</i>	77
Algoritmo 3. Algoritmo Chow&Liu para aprendizaje Bayesiano.....	83

Resumen

Los Sistemas Tutores Inteligentes han crecido en popularidad por ser una herramienta de apoyo para la enseñanza individualizada de los estudiantes. La principal característica de dichos sistemas es su adaptación al aprendizaje del estudiante en turno. Esta característica ha sido abordada con diferentes formalismos de la Inteligencia Artificial, adquiriendo el nombre de Modelo de Estudiante. Los enfoques utilizados para modelar al estudiante engloban aspectos generales y específicos de cada usuario, siendo el criterio del modelador y la finalidad del sistema lo que dicte la forma final de éste. Con el auge de los Sistemas Tutores Inteligentes, se han presentado diferentes metodologías para el modelado del estudiante, siendo las Redes Bayesianas las que han proporcionado la habilidad de lidiar con la incertidumbre de la próxima interacción del estudiante. Debido a lo anterior, se propone una evaluación de metodologías de modelado de estudiantes basadas en Redes Bayesianas con la aplicación a un caso de estudio. También se probarán técnicas de Redes Bayesianas a dichos modelos para encontrar posibles mejoras, estas técnicas son: Propagación de creencias, Redes Bayesianas Difusas y Aprendizaje Bayesiano. Se dará el resultado de la evaluación y cómo ésta evaluación dio pie a la creación de Modelos de Estudiante en el caso de estudio a un sistema tutor existente. Así mismo, se presentará cómo las Redes Bayesianas Difusas pudieran integrarse al Modelo del Estudiante y cómo los errores pueden ser utilizados para el modelado del mismo.

Abstract

Intelligent Tutoring Systems have grown in popularity due to their value as an individual teaching tool. The core feature of an Intelligent Tutoring System is the adaptability to the current student. This feature has been addressed with different approaches within Artificial Intelligence, and it acquired the name of Student Model. The approaches use to model the student include general and specific features of each user, the developer criterion and the purpose of the system that dictates the final shape of it. With the rise of Intelligent Tutoring Systems, different formalisms for modeling student have been presented, being Bayesian Networks the ones that have provided the ability to deal with the uncertainty created by the next student interaction. Because of this, this work proposes an evaluation of student modeling approaches based on Bayesian Networks with a case of study. Also, three techniques of Bayesian Networks will be tested to find possible improvements to the models, the techniques are: beliefs propagation, Fuzzy Bayesian Networks, and Bayesian learning. The result of the evaluation and how it gave the path to the development of Student Models for the study case will be presented. Thus, I will present how the Fuzzy Bayesian Networks could embed into the Student Model and how student's mistakes can be used to model it.

Capítulo 1

Introducción

En las últimas décadas, los Sistemas Tutores Inteligentes han evolucionado y probado ser una herramienta eficaz para la enseñanza de diversos dominios de conocimiento. Dichos sistemas han aumentado su eficacia gracias a las técnicas de Inteligencia Artificial que se utilizan en ellos, en específico al modelar al estudiante.

La técnica de Inteligencia Artificial que se aborda en esta tesis son las Redes Bayesianas y serán descritas en el capítulo dos de este documento. Nótese que la teoría abordada de las Redes Bayesianas es la necesaria para comprender los Modelos de Estudiante de Sistemas Tutores Inteligentes.

Así, en esta tesis, se pretende una evaluación de los Modelos de Estudiante de los Sistemas Tutores Inteligentes que utilizan Redes Bayesianas como técnica de operación y para llevar a cabo dicha evaluación, se generaron modelos con la aplicación GeNIe [Pittsburg, 2016], en procesos de aprendizaje Bayesiano y desarrollo por expertos (véase el capítulo dos sección seis para mayor detalle de la aplicación).

A continuación, se dará a conocer la motivación del problema que se está abordando y que se resolverá; por medio de la determinación de un objetivo general, que a su vez, se divide en objetivos específicos. Así mismo se describirán la justificación de realizar este trabajo y la metodología para resolver dicho problema.

1.1 Motivación

En las últimas cuatro décadas, se ha investigado profundamente en el desarrollo de programas computacionales que enseñen a los estudiantes de manera efectiva. Estos programas son llamados Sistemas Tutores Inteligentes (STI). El deseo de construir STI resulta porque los estudios muestran que la enseñanza uno a uno es altamente efectiva. Sin embargo, hacer ésto con maestros humanos resulta poco factible, debido a que el número de estudiantes supera grandemente el número de maestros. Con el avance en computadoras, este sueño toma un paso hacia la realidad. Si una computadora pudiera emular un maestro entonces la enseñanza uno a uno sería una posibilidad para todos los estudiantes [Mayo, 2001].

Un elemento clave que distingue entre STI y sistemas tradicionales es la habilidad de los primeros para interpretar las acciones del estudiante y mantener el modelo de razonamiento y aprendizaje de cada estudiante – el Modelo del Estudiante (ME). El ME permite a un STI adaptar la interacción a las necesidades específicas del usuario [Conati, 2002].

En este trabajo se proyecta analizar tres ME, debido a que el ME maneja muchas de las decisiones de instrucción de un STI, por ejemplo: qué retroalimentación proporcionar al usuario, cómo y cuándo presentar las secuencia de los temas y ejercicios, cómo ajustarse al ritmo del estudiante, e incluso qué problemas y material es necesario [Nwagwe, 2014]. Por lo que contar con una evaluación de modelos utilizados exitosamente en STI activos, resultará de gran apoyo para las investigaciones y desarrollos que necesiten una comparación a fondo de los ME y así poder decidir cuál paradigma o tipo de modelado les sería útil en la implementación del sistema.

Se debe considerar ampliamente cuál será la herramienta y la metodología que se utilizará para el modelado del estudiante. Para esto, las métricas de evaluación son importantes porque ellas cuantifican si el STI está ayudando a los alumnos [González, 2015] es por ello que la presente tesis titulada “Evaluación de Modelos del Estudiante de Sistemas Tutores Inteligentes que emplean Redes Bayesianas como técnica básica de operación” toma esa dirección y se eligen métricas de evaluación así como tres ME para su evaluación y experimentación.

1.2 Descripción del problema

Delimitación del problema específico

La característica distintiva de un STI es su capacidad de adaptación al alumno, adaptación que se puede realizar en varios niveles: en el nivel en que se presenta el material o las ayudas, en la dificultad de los problemas propuestos o en la selección de la estrategia instructora más adecuada según sus capacidades, habilidades y estilos de aprendizaje preferidos [Millán, 2000].

Por lo tanto, si la característica clave de los STI es su capacidad de adaptarse a cada alumno que utiliza el sistema, el problema de obtener toda la información posible acerca del alumno se convierte en el principal problema a la hora de diseñar un tutor inteligente. En efecto, es necesario que en cada momento el STI disponga de una representación del estado actual del

conocimiento del alumno, con objeto de poder seleccionar el material al nivel adecuado de detalle, proponer el problema apropiado o seleccionar la estrategia tutorial más efectiva en ese momento [Millán, 2000].

Esta problemática es conocida como el problema del modelado del alumno y debido a esto se tiene la necesidad de comparar las técnicas más utilizadas para el modelado del alumno y hacer un estudio de análisis profundo.

Por lo tanto, el problema específico de esta propuesta es la evaluación de modelos encontrados en la literatura relacionados con el ME con Redes Bayesianas (RB).

Complejidad del problema

El desarrollo de STI no está totalmente perfeccionado, lo mismo pasa con el ME, ya que no es una tarea fácil para los desarrolladores ya que la dificultad más significativa para cualquier sistema que modela usuarios es la incertidumbre. El STI debe construir un modelo de cada estudiante con cantidades mínimas de información con alta incertidumbre (lo mismo pasa con los tutores humanos) [Mayo, 2001].

Para el desarrollo de ME se utilizan diversas técnicas entre ellas: RB, Sistemas Basados en Reglas y lógica difusa [Chakraborty, 2010]. La selección de la estructura que se usará para representar el modelo del alumno se convierte en la cuestión fundamental en el problema del modelado del alumno. En otras palabras, el problema de cómo capturar y representar lo que el estudiante sabe, y hacerlo lo más fielmente posible.

Las RB son complejas por sí mismas y se requiere un grado de comprensión alto para estudiar el Modelado Bayesiano del Estudiante. Las técnicas y teoría alrededor de STI son temas amplios por lo que se requiere entender los objetivos para poder ser capaz de analizar los componentes de dichos sistemas, en este caso en particular el modelado del estudiante [Mayo, 2001].

1.3 Objetivo general

Experimentar y evaluar al menos tres ME citados en la literatura especializada en STI que empleen RB con el fin de detectar las mejores prácticas en ese tema y aspectos no considerados en los modelos del estudiante y así proponer mejoras a tales modelos.

1.4 Objetivos Específicos

1. Revisar el tema de los STI, con énfasis de los diversos tipos de ME.
2. Revisar y comprender el funcionamiento de las RB aplicadas a modelar al estudiante.
3. Estudiar ME con y sin RB.
4. Detectar y analizar al menos los tres ME que empleen como técnica básica de operación a las RB.
5. Llevar a cabo experimentos con los ME anteriores buscando detectar aspectos que puedan mejorarse, así como las desventajas de cada propuesta.
6. Reportar los hallazgos encontrados, ventajas y desventajas.

1.5 Metodología

Para la realización de una parte de la presente tesis se contó con una estancia en el Instituto de Investigaciones Eléctricas (IIE). En donde se consiguió insertarse en un proyecto con un Sistema Tutor y datos reales. Dichos datos se utilizan en los ME presentados en el capítulo cinco.

Los ME fueron generados con la aplicación GeNIe [Pittsburg, 2016], en procesos de aprendizaje Bayesiano y desarrollo por expertos (véase el capítulo dos sección seis para mayor detalle de la aplicación).

1.6 Justificación y beneficios

Este trabajo aporta resultados de evaluación e implementación para el modelado del estudiante basado en RB. Podrá ser utilizado en el campo de búsqueda de enfoques diferentes a las RB para la construcción de ME. La experimentación de modelos más citados en la literatura servirá a futuras investigaciones y les brindará herramientas necesarias a aquellos investigadores que requieran una evaluación completa de dichos modelos.

Además, como se menciona en la Introducción de esta propuesta, los STI están tomando gran importancia en la educación de calidad y esta contribución será un parte aguas para que desarrolladores interesados en STI tengan una base de comparación de los ME que actualmente están en investigación.

1.7 Organización de la tesis

Esta tesis está organizada en los capítulos que restan de la siguiente forma: capítulo 2 Marco Teórico, donde se expondrán los conocimientos necesarios para comprender la presente tesis así como la teoría detrás de las RB y los métodos de evaluación que se utilizarán aquí; capítulo 3 Estado del arte, donde se analizarán investigaciones relacionadas con el tema de STI, ME y las formas de evaluación más recientes; capítulo 4 Evaluación de Modelos de Estudiante, se analizarán a fondo los modelos que se utilizarán para la experimentación; el capítulo 5 comprende los experimentos con los ME analizados en el capítulo anterior, además de un caso de estudio real. Para finalizar se analizará la información obtenida en la fase de experimentación y se darán las conclusiones en el capítulo 6.

Capítulo 2

Marco Teórico

En este capítulo se describen los conocimientos generales necesarios para llevar a cabo el proyecto de investigación. Se mencionan, entre otros, los siguientes temas principales: Arquitectura de los Sistemas Tutores Inteligentes (STI), características del Modelo del Estudiante (ME) y Redes Bayesianas (RB).

2.1 Arquitectura de los Sistemas Tutores Inteligentes

La arquitectura básica de un STI consiste en un Módulo Experto, un Módulo del Alumno y un Módulo Instructor, que operan de forma interactiva y se comunican a través de un Módulo Central que se suele denominar Entorno. El Módulo Experto contiene el conocimiento acerca de la materia que se pretende enseñar, el Módulo del Alumno guarda toda la información relativa al mismo, que se genera durante la interacción con el sistema, y el Módulo Instructor controla los planes y las decisiones pedagógicas. Finalmente, el Módulo Entorno gestiona la interacción de las otras componentes del sistema y controla la interfaz hombre máquina [Millán, 2000]. Esta estructura se presenta en la Figura 2.1.

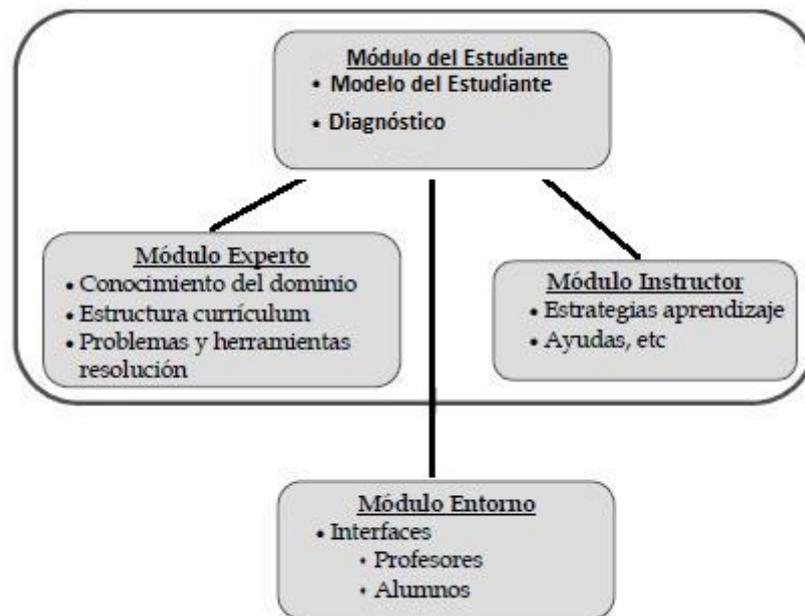


Figura 2.1. Arquitectura básica de un STI [Millán, 2000].

A continuación se describe cada uno de estos módulos con un poco más de detalle.

2.1.1 El Módulo Experto

El Módulo Experto de un STI proporciona los conocimientos del dominio, que satisfacen dos propósitos diferentes; en primer lugar, presentar la materia adecuada para que el alumno adquiera las habilidades y conceptos. Esto incluye la capacidad de generar preguntas, explicaciones, respuestas y tareas para el alumno. En segundo lugar, el módulo experto debe ser capaz de resolver los problemas generados y corregir las soluciones presentadas, incluso de aceptar aquellas soluciones válidas que han sido obtenidas por medios distintos. Además, debe poder explicar sus razonamientos en un lenguaje comprensible para el alumno [Millán, 2000].

2.1.2 El Módulo del Alumno

El Módulo del Alumno de un STI representa el conocimiento que tiene el alumno del dominio que se intenta enseñarle. Las acciones del alumno son interpretadas en un intento de reconstruir el estado de conocimiento que le llevó a realizar esas acciones. Esta información

puede compararse con la contenida en el Módulo Experto, y ser usada para tomar decisiones didácticas que guiarán al alumno y organizarán sus actividades [Millán, 2000].

El ME es una representación cualitativa aproximada, posiblemente parcial, del conocimiento del alumno sobre cierto dominio, o tema/habilidad de dicho dominio que puede explicar total o parcialmente aspectos específicos del comportamiento del alumno. Decir que el ME es una representación cualitativa significa que no es ni numérica ni física, sino que describe los objetos y los procesos en términos de relaciones espaciales, temporales y causales. Decir que el ME es aproximado y posiblemente parcial significa que interesa más la utilidad computacional que la fidelidad cognitiva. Un ME más preciso sólo es mejor si el esfuerzo computacional realizado para aumentar su precisión o completitud no es excesivo comparado con la ganancia pedagógica obtenida [Millán 2000].

El problema de inferir y mantener el ME se conoce con el nombre de *problema del Modelado del Estudiante*, se discute en el capítulo 1 sección 2.

2.1.3 El Módulo Instructor

Las representaciones explícitas del conocimiento pedagógico permiten a los sistemas tutores adaptar y mejorar sus estrategias en el tiempo. Un sistema tutor debe ser capaz de: a) controlar el contenido (selección de material y orden de presentación), b) responder a las preguntas de los alumnos y c) saber cuándo un alumno necesita ayuda y determinar qué tipo de ayuda necesita. Para ello se definen las estrategias instructoras, que a nivel global afectan a la ordenación en la presentación de contenidos y a nivel local a las decisiones sobre cuándo y cómo intervenir para proporcionar ayuda, explicaciones, enseñanza, preguntas o correcciones [Millán, 2000].

El Módulo Instructor controla las cantidades e interacción instructora. Diferentes niveles de control determinan diferentes estrategias: en el nivel de control máximo (*monitoring*) el sistema adapta las acciones a las necesidades del alumno, llevando siempre el control. En el nivel intermedio (*mixed-initiative dialogue*) el alumno y el sistema comparten el control mediante el intercambio de preguntas y respuestas. En el otro extremo están las actividades tutorizadas (*guided-discovery learning*), en las que la intervención del sistema se reduce a modificar el entorno. Al elegir entre estas estrategias de control cada dominio y cada alumno deben ser evaluados de forma independiente. De este modo, las estrategias de control pueden guardarse en el Módulo de Instrucción y ser seleccionadas de forma que, también, el tipo de instrucción que recibe el alumno sea individualizada [Millán, 2000].

2.1.4 El Módulo Entorno

Finalmente, el cuarto componente de un STI es el Módulo Entorno (interfaz de usuario). La interfaz es de importancia para un STI. Primero, éste debe proveer de motivación para que el estudiante continúe. Si el estudiante no tiene deseo de usar el sistema, el STI simplemente no será efectivo. Segundo, la interfaz puede mejorar la experiencia de aprendizaje significativamente al reducir la carga cognitiva [Mayo, 2001].

Aunque todos los componentes de un STI son importantes, el Módulo del Alumno es un componente clave. Si el ME es *malo* y ni siquiera se aproxima a describir las estrategias del estudiante utilizadas durante el curso, entonces la calidad de decisiones que el Módulo

Pedagógico presentará, estarán mal del mismo modo. Esto es cierto aunque el Módulo Experto sea de mucha calidad. Substantial investigación, por lo tanto, está siendo concebida específicamente en el modelado del estudiante [Mayo, 2001].

2.2 Herramientas de Autoría

En la última década los STI se han movido de los laboratorios a los salones de clase y lugares de trabajo en donde algunos han mostrado ser altamente eficientes. Mientras que los tutores inteligentes están siendo más comunes y han probado ser incrementalmente eficientes, se ha vuelto difícil y muy costoso el construirlos. Investigadores han estado trabajando en herramientas de autoría para STI desde casi el comienzo de la investigación de los propios STI, y cerca de una docena de sistemas de autoría han sido construidos [Murray, 2007].

La fácil interacción con los modelos, el costo de desarrollo, la complejidad de desarrollo, de los STI son aspectos que se busca mejorar para la producción extensa de dichos sistemas de autoría [Alevén, 2012].

En este apartado se resumirá el estado del arte para las herramientas de autoría para STI. Los tipos de STI que destacan con más desarrollo e investigación son: STI basados en modelos como *Model-Tracing*, *Constraint based*, *cognitive Tutors* y *Example-Tracing Tutors*. En la Figura 2.2 se muestra los tipos más comunes de STI y cuáles de ellos pueden ser desarrollados por la herramienta de autoría CTAT [Alevén, 2012].

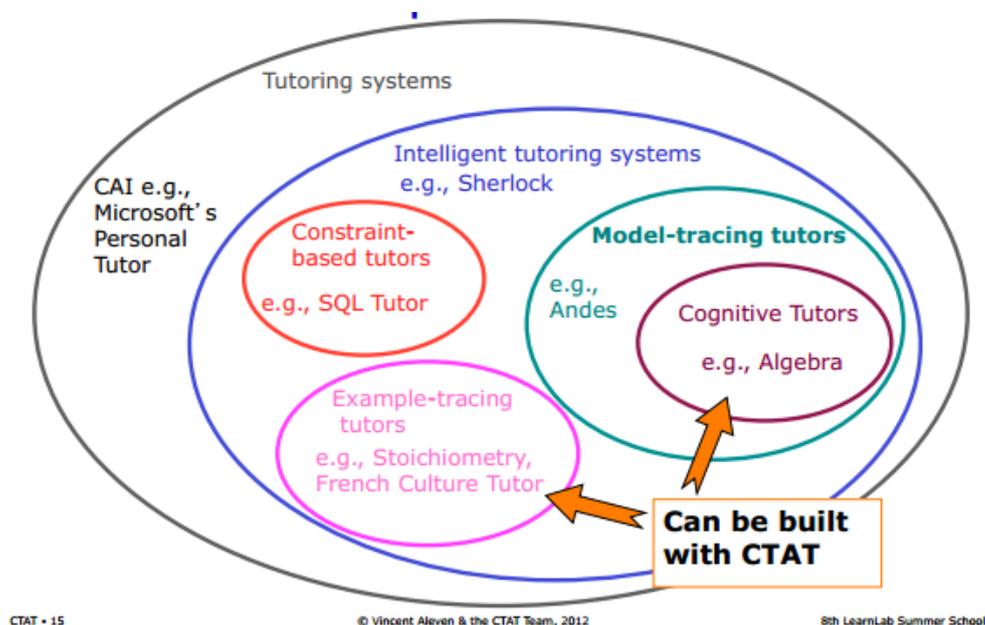


Figura 2.2. Tipos de STI con más desarrollo e investigación [Alevén, 2012].

Doce años de experiencia con los sistemas para desarrollo de STI, son de especial interés para conocer de forma profunda herramientas como CTAT y la forma de representar el conocimiento que ésta emplea. De acuerdo a [Alevén, 2015], el desarrollo de un STI con esta herramienta empieza con la identificación del dominio de trabajo y el tipo de problemas que serán expuestos en el tutor; continúa con el análisis para entender los conceptos y habilidades que se necesitaran en el dominio de trabajo así como entender cómo los alumnos los aprenden; en seguida se diseña y construye la interfaz de resolución de problemas; después se tiene que construir el módulo de dominio usando ejemplos generalizados (para el *example-tracing tutor*) o basado en reglas cognitivas (para un *Cognitive Tutor*). Una vez que la interfaz está lista (se puede desarrollar utilizando el asistente que CTAT provee) se debe de crear y editar el conocimiento que hará que los estudiantes aprendan. Este proceso es de ida y vuelta con los expertos en la materia a enseñar.

CTAT soporta tutores cognitivos (*Cognitive Tutors*) y tutores de ejemplo de trazado (*Example-Tracing Tutors*) [Alevén, 2012]. CTAT es un *framework* de distribución gratuita. El principal objetivo de CTAT es reducir la cantidad de trabajo requerido para desarrollar un STI. Los STI desarrollados por CTAT son de tipo cognitivo los cuales están basados en la teoría cognitiva ACT-R. Para crear dichos modelos se requiere de un experto en programación en Inteligencia Artificial (IA) ya que la implementación del modelo requiere del *Tutor Development Kit* (TDK) o de *Jess rule engine* [Paquette, 2010]. CTAT utiliza las reglas de producción en Jess para representar el conocimiento procedimental y los *Jess facts* para representar el conocimiento declarativo [Paquette, 2010].

En la Tabla 2.1 se muestra un estudio detallado realizado por [Pavlik, 2013] de ME usados en la actualidad en STI. Se resumen los aspectos tomado en cuenta en el estudio y análisis. Se muestran aspectos teóricos de los diferentes modelos de estudiante. Concerniente a esta investigación, los ME relevante son: *Model Tracing Student Models* y los de tipo *Constraint-Based Student Models*.

Tabla 2.1. Análisis de ME según [Pavlik, 2013].

Modelo	Facilidad de entendimiento	Flexibilidad	Costo de creación	Granularidad	Escala de tiempo
Programmed Branching	Alto	Bajo	Bajo	Cualquiera	Tiempo corto
Rule Space	Alto	Alto	Bajo	Cualquiera	De corto a largo
Model Tracing	Bajo	Moderado	Alto	Producción de reglas	Potencialmente largo
Constraint Based Tutors	Moderado	Alto	Moderado	Cualquiera	Potencialmente largo

2.3 Características del Modelo del Estudiante

Es útil considerar el modelado de los estudiantes a la luz de la teoría del aprendizaje. Hay tres principales teorías de aprendizaje [Mayo, 2001], ver Tabla 2.2.

Tabla 2.2. Teorías de aprendizaje según [Mayo, 2001].

<p>Conductismo</p>	<ul style="list-style-type: none"> • Se producen respuestas cuando se expone al estímulo. • Se refuerzan las respuestas correctas, y se castigan las respuestas incorrectas.
<p>Cognitivism</p>	<ul style="list-style-type: none"> • Formación y la reforma de las representaciones mentales del conocimiento. • Se proponen "efectos" como: "efecto de la organización" y "efecto significativo"
<p>Constructivismo</p>	<ul style="list-style-type: none"> • Es una teoría subjetiva en la que se dice al alumno que tiene que construir su propia realidad basada en la experiencia.

En los últimos años, el campo de modelado del estudiante parece haberse vuelto más cognitivista ya que los modelos cognitivos son cada vez más detallados. Sin embargo, el inconveniente de esto es una disminución en la tratabilidad de estos modelos [Mayo, 2001].

Clasificación de ME

Los ME pueden ser clasificados por una serie de factores, que van desde la forma en que se generan, su contenido, y su aplicación. Existe a su vez dos factores esenciales en la clasificación de los ME que son [Mayo, 2001]:

- a) Persistencia: ¿Las creencias sobre el estudiante suelen durar por un corto período, como con posterioridad a un solo intento de problema, o son retenidos para construir un modelo de más largo plazo?
- b) Contenido: Depende generalmente de la persistencia, creencias a corto plazo deben ser muy específicas, el modelo a largo plazo, por otro lado, contiene típicamente una proporción mucho mayor de las creencias inferidas.

Los ME más utilizados se clasifican como sigue:

Estereotipo. Las respuestas de los estudiantes ponen al estudiante en una categoría predefinida. Un modelo tipo estereotipo se presenta en la Figura 2.3 [Mayo, 2001].

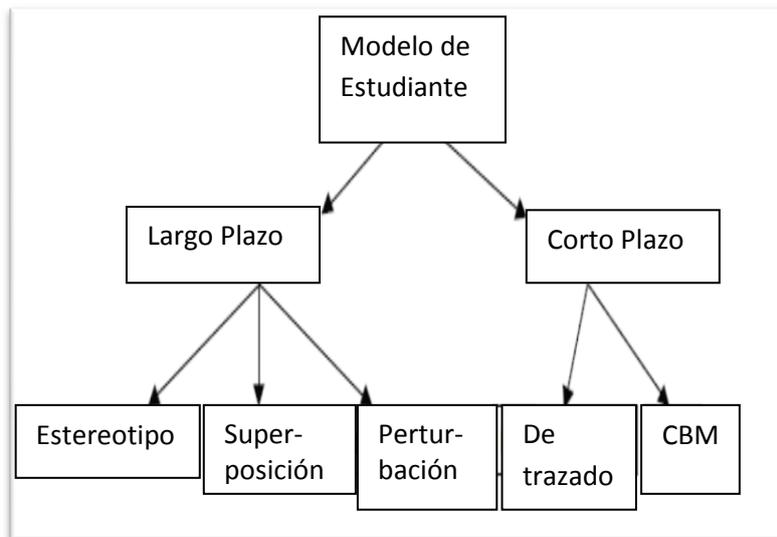


Figura 2.3. ME Tipo Estereotipo [Mayo, 2001].

Superposición (*Overlay Model*). Este modelo proyecta una simple medida de grado de dominio sobre los elementos de la materia que se espera que un experto domine. Por lo tanto, el conocimiento del dominio del estudiante es representado como un subconjunto de los conocimientos del experto [Mayo, 2001]. El esquema de un modelo tipo superposición se presenta en la Figura 2.4.

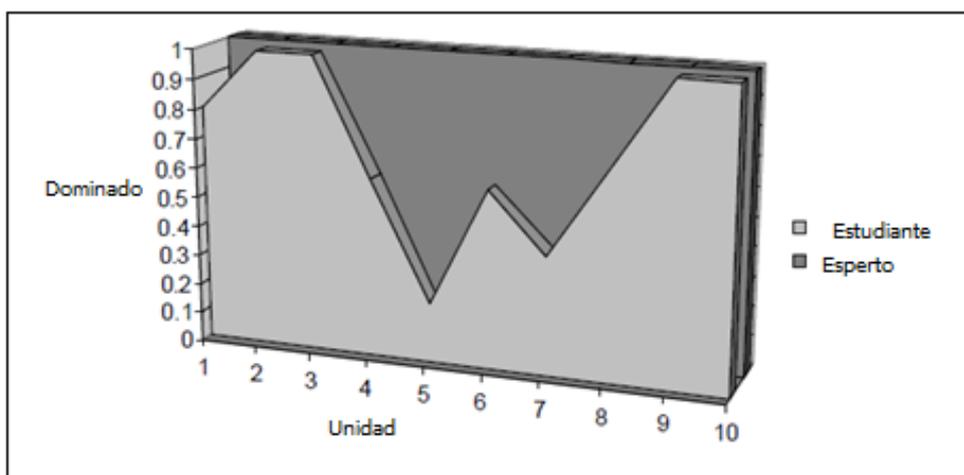


Figura 2.4. Modelo de superposición que demuestra el modelado del estudiante con este enfoque [Mayo, 2001].

Perturbación. La filosofía del modelo de perturbación, es la de representar al estudiante como un subconjunto de los conocimientos del experto y el posible mal-conocimiento [Mayo, 2001]. Véase una ejemplificación gráfica en la Figura 2.5.

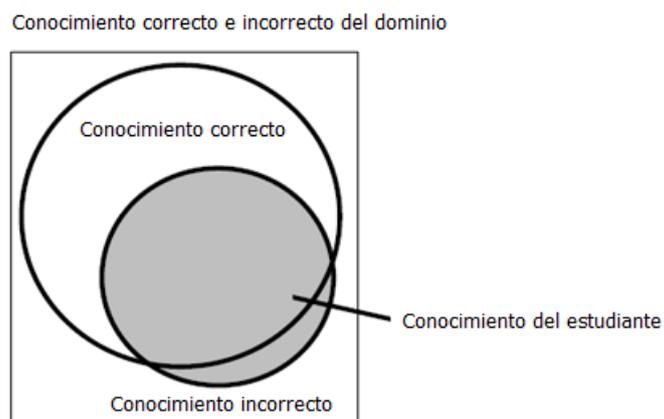


Figura 2.5. Modelo de perturbación [Mayo, 2001].

Model-Tracing (Modelo de Trazado). Se basa en los siguientes principios: da retroalimentación del rendimiento del estudiante cuando resuelve problemas y hace explícita la estructura de un problema. Pretende representar no sólo el conocimiento declarativo que el estudiante posee o usa, sino también el conocimiento procedural [Mayo, 2001]. *Model-Tracing* o Modelo de Trazado será retomado en el capítulo 4 sección 1 para un estudio más profundo.

Modelo basado en restricciones (*Constraint-Based Model*, CBM por siglas en inglés). Este paradigma se apoya en los errores de los estudiantes para crear el modelo y al mismo tiempo dar solución a dichos errores [Kodaganallur, 2005]. Este modelo también será ampliado en el capítulo 4 sección 3.

La Tabla 2.3 clasifica los Modelos de Estudiante basados en RB según [Mayo, 2001] y presenta una breve explicación de ellos.

Tabla 2.3. Clasificación de Modelos de Estudiante Basados en Redes Bayesianas [Mayo, 2001].

Centrado en expertos	<ul style="list-style-type: none"> • Un experto especifica la estructura completa de las probabilidades condicionales del ME bayesiano
Centrado en eficiencia	<ul style="list-style-type: none"> • Se eligen restricciones para maximizar algún aspecto de la eficiencia, tal como el tiempo de evaluación de algún texto o problema.
Centrado en datos	<ul style="list-style-type: none"> • La estructura y probabilidades condicionales de la red se aprenden principalmente a partir de datos para predecir el rendimiento del estudiante.

A continuación se ejemplifica con una ilustración la clasificación antes mencionada, la Figura 2.6 muestra también algunos ejemplos de STI pertenecientes a cada clasificación.

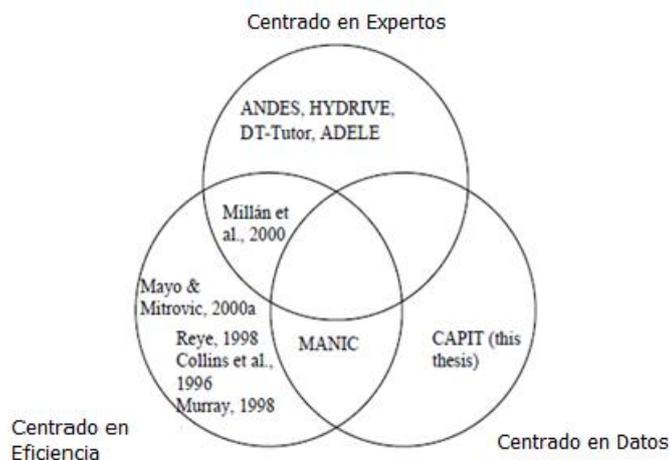


Figura 2.6. Clasificación de ME basados en RB [Mayo, 2001].

2.4 Redes Bayesianas (RB)

¿Por qué RB para el Modelado? Las RB son un formalismo de razonamiento con incertidumbre que ha sido ampliamente adoptado en Inteligencia Artificial (IA). El modelado del estudiante, o sea, el proceso que realiza un STI al construir un modelo relevante a los estados/caminos del alumno durante la interacción con éste, es una tarea llena de incertidumbre, así naturalmente, llama a la utilización de un enfoque probabilístico [Conati, 2010].

En este apartado, se describirán los conceptos básicos de la teoría de probabilidad necesaria para entender las RB utilizadas en el modelado del estudiante de un STI.

2.4.1 Conceptos básicos

¿Por qué molestarse con la incertidumbre? El razonar sobre cualquier dominio siempre requiere que se hagan algunas simplificaciones. Aún desde el acto de la preparación del conocimiento se requiere que se deje fuera hechos que no se conocen, o que no se han dicho o que son resumidos. Por ejemplo, si se decide codificar conocimientos en reglas como *los pájaros vuelan* o *humo sugiere fuego*, dichas reglas tendrán muchas excepciones que no se pueden enumerar y las condiciones bajo las cuales éstas aplican, son usualmente ambiguas o difíciles de precisar en la vida real. Razonar con excepciones es como pasear en un campo minado: muchos pasos pueden ser seguros pero algunos son devastadores [Pearl, 1988].

Las relaciones primitivas del lenguaje de Probabilidad: aunque las probabilidades se expresan en números, el mérito de cálculo de probabilidades se basa en proporcionar un medio para articular y manipular las relaciones cualitativas que se encuentran útiles en el discurso normal. Las siguientes cuatro relaciones son observadas como las primitivas básicas del lenguaje [Pearl, 1988]:

1. Probabilidad (“Es *más probable* que *Tim* corra a que camine”).
2. Condicional (“Si *Tim* está enfermo, no puede correr”).
3. Relación (“Si *Tim* vuela o no, *depende* si está enfermo o no”).
4. Causalidad (“Estar enfermo *ocasiona* la inhabilidad de *Tim* para volar”).

Probabilidad: la relación cualitativa de la forma “*A* es más probable que *B*” ha sido percibida tradicionalmente como el propósito primordial del uso de las probabilidades [Pearl, 1988].

Condicional: la teoría de la probabilidad adopta la frase auto epistémica “...*dado que lo que se es C*” como primitiva del lenguaje. Sintácticamente, esto es denotado al poner *C* detrás de la barra de condición en un enunciado como $P(A|C)=p$. Esta declaración combina las nociones de conocimiento y creencias al atribuir a *A* un grado de creencia *p*, dado el conocimiento de *C*. *C* es también conocido como el contexto de la creencia en *A*, y la notación $P(A|C)$ es llamado *Condicionamiento de Bayes*. Thomas Bayes (1702-1761) hizo esta contribución a la ciencia de la probabilidad al asociar la frase en español “*dado que conozco C*” con la ahora famosa ecuación [Pearl, 1988]:

$$P(A|C) = \frac{P(C|A)P(A)}{P(C)} \quad \text{Ecuación 2.1}$$

Relación: indica un potencial de cambio de creencia ya que se especifica un cambio en el conocimiento [Pearl, 1988].

Causalidad: es una herramienta indispensable para estructurar y especificar conocimiento probabilístico y porque la semántica de las relaciones causales es preservada por la sintaxis de las manipulaciones probabilísticas. Causalidad es un lenguaje con el cual se puede hablar más eficientemente de ciertas estructuras de relaciones relevantes, con el objetivo de separar lo relevante de lo superfluo. Por ejemplo decir que: *el pavimento mojado fue la causa directa que provocó mi caída y que me rompiera la pierna, es una forma concisa de identificar cuáles eventos ya no debían ser considerados relevantes en mi accidente, una vez que se confirmó que el pavimento está mojado. El hecho de que llovió ese día, que la lluvia es bienvenida por los granjeros y que mi amigo también se cayó por el pavimento mojado, ya no deberían ser considerados relevantes al accidente, una vez que se estableció la verdad de pavimento mojado y que se le identificó como la causa directa del accidente* [Pearl, 1988].

Definición 1 Redes Bayesianas (RB): Las RB son modelos gráficos que representan explícitamente independencia condicional entre variables aleatorias de interés, y se explota esta información para reducir la complejidad de la inferencia probabilística [Pearl, 1988].

Variables Aleatorias: muchas veces se tiene un evento con un conjunto de resultados [Nava, 2002]:

- Completo: se conocen todos los posibles resultados
- Mutuamente excluyente: no se permiten dar dos resultados distintos simultáneamente

Ejemplo [Nava, 2002]:

Si se tira una moneda, el resultado es cara o cruz

- Completo: sólo puede salir cara o cruz
- Excluyente: si sale cara no puede salir cruz

En lugar de tener una proposición por resultado se introduce el concepto de *variable aleatoria*. Se permiten proposiciones de la forma *Variable = resultado* [Nava, 2002].

Ejemplo [Nava, 2002]:

- Si $M =$ "Resultado de tirar una moneda con posibles cara o cruz" se permiten las proposiciones:
 - $M = \text{cara}$ y $M = \text{cruz}$ y se puede hablar de
 - $P(M=\text{cara})$ y $P(M=\text{cruz})$ que representan la probabilidad de obtener una cara y una cruz respectivamente
- Abreviaturas
 - Se suele escribir $P(M=\text{cara})$ o $P(\text{cara})$, cuando el contexto lo permite
 - Si una variable aleatoria como *Sarapión* toma únicamente los valores verdadero o falso se suele escribir $P(\text{Sarapión}=\text{verdadero})$ como $P(\text{Sarapión})$ y $P(\text{Sarapión}=\text{falso})$ como $P(\neg\text{Sarapión})$

Distribuciones de Probabilidad [Nava, 2002]:

- Dada una variable aleatoria se desearía conocer la probabilidad para cada valor que pueda tomar, esta descripción se llama *distribución de probabilidad* de la variable aleatoria y consiste en listar los valores de probabilidad para cada valor de la variable (ver Figura 2.7 como ejemplo ilustrativo):

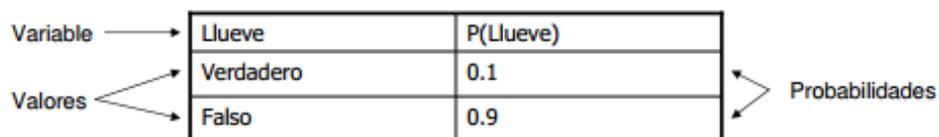


Figura 2.7. Ejemplo ilustrativo de distribución de probabilidad de una variable aleatoria [Nava, 2002].

Distribución Condicional [Nava, 2002]:

Se escribe $P(A | B)$ para representar la probabilidad de A dado B . Esta probabilidad se llama probabilidad condicional. Se puede interpretar como *grado de creencia en cuando todo lo que sé es B*. O de forma alternativa, de los casos en los que se da B , *¿en qué proporción se da A?*

- La distribución condicional permite conocer la probabilidad de que se tomen unos determinados valores por un conjunto de variables, cuando se saben los valores que han tomado otras. Ejemplo: $P(\text{Resuelve_Ejercicio} | \text{Sabe_Concepto})$, ver Tabla 2.4 para detalle visual.

Tabla 2.4. Ejemplo ilustrativo de una tabla de probabilidad condicional (CPT) [Nava, 2002].

Resuelve_Ejercicio	P(Resuelve_Ejercicio Sabe_Concepto)
P(resuelve_ejercicio)	0.95
P(¬resuelve_ejercicio)	0.05

Distribución Conjunta [Nava, 2002]:

Se puede estar interesado en estudiar varias variables en conjunto. Por ejemplo: $P(\text{Sarampión}=\text{verdadero} \wedge \text{Fiebre}=\text{verdadero})$ que es la probabilidad de que el paciente tenga sarampión y fiebre. Para ello se necesita asignar probabilidades a cada posible combinación de los valores de las variables, ver ejemplo en la Figura 2.8. La distribución conjunta contiene todo lo que se necesita saber acerca de un conjunto de variables aleatorias.

En particular, la distribución de cada variable individual se puede calcular a partir de la distribución conjunta (y se llama distribución marginal) [Nava, 2002].

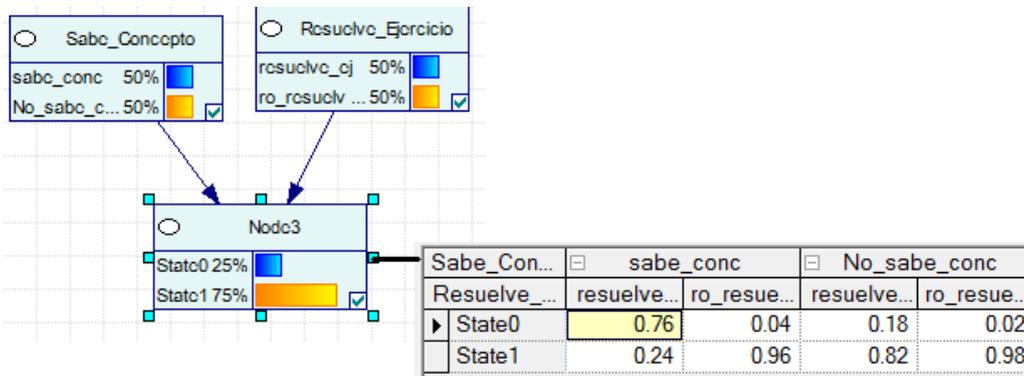


Figura 2.8. Distribución conjunta de las variables Sabe_Concepto y Resuelve_Ejercicio [Nava, 2002].

Formalmente una RB es un grafo directo no-cíclico, donde los nodos son variables aleatorias y enlaces que representan dependencias directas entre las variables. Si se asocian a cada nodo X_i una tabla de distribución condicional que especifica la distribución de probabilidad de las variables asociadas dados sus padres inmediatos, entonces la RB provee una representación compacta [Conati, 2010].

Una RB contiene variables con sentido común, pero puede no representar el mundo real. Tómese el ejemplo de la Figura 2.9 para ilustrar una RB [Huang, 2015].

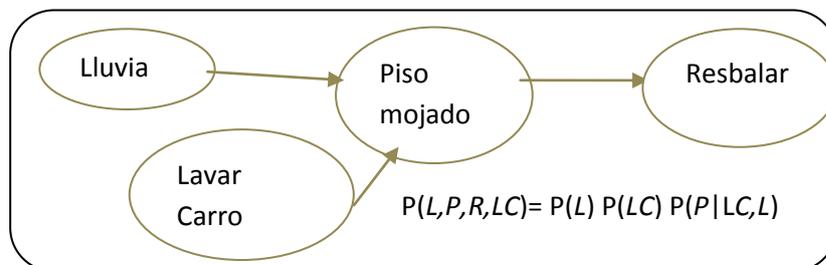


Figura 2.9. Red Bayesiana para ejemplificar la probabilidad de las variables dados sus padres y la distribución conjunta de dicha red [Huang, 2015].

Para comprender la distribución conjunta de la red, $P(L,P,R,LC) = P(L) P(LC) P(P|LC,L) P(R|P)$, se debe notar que no interesa la razón por la cual el piso está mojado, si éste está mojado se puede resbalar. Dada la explicación y por la representación gráfica se sabe que *piso mojado* depende de *lluvia* y *lavar carro*. Si está lloviendo o alguien lavó el coche hay una alta probabilidad de que el piso se moje [Huang, 2015].

Se representa la probabilidad de las variables dados sus padres con:

$$P(X | \text{Padres}(X)) \tag{Ecuación 2.2}$$

Cada variable que no es un ancestro de una variable de consulta o evidencia es irrelevante para la consulta [Huang, 2015].

Teorema de Bayes [Huang, 2015]:

El punto central del teorema de Bayes es el uso del mismo para determinar un diagnóstico probabilístico a partir de la probabilidad causal [Huang, 2015]. En seguida se presenta el teorema de Bayes haciendo significado a lo dicho antes, nótese que el teorema es el mismo presentado en la ecuación 2.1 pero con el significado explícito [Berkeley, 2013].

$$P(\text{Causa}|\text{Efecto}) = \frac{P(\text{Efecto}|\text{Causa})P(\text{Causa})}{P(\text{Efecto})} \tag{Ecuación 2.3}$$

Ejemplo resuelto de una Red Bayesiana [Berkeley, 2013]

Considérese la RB de la Figura 2.10, las variables establecidas y sus correspondientes tablas de probabilidad condicional (Tablas 2.5 y 2.6) con las cuales se puede hacer preguntas como:

1. ¿Cuál es la probabilidad de que esté soleado dado que el piso está seco?
2. ¿Cuál es la probabilidad de que haya llovido dado que el piso está seco?
3. ¿Cuál es la probabilidad de que el piso esté seco?

Tabla 2.5. Probabilidad de la variable Clima [Berkeley, 2013].

soleado	0.8
lluvioso	0.2

Tabla 2.6. Tabla de probabilidad condicional de la variable *Piso mojado*[Berkeley, 2013].

	soleado	lluvioso
mojado	0.1	0.7
seco	0.9	0.3



Figura 2.10. Red Bayesiana para desarrollo de ejemplo [Berkeley, 2013].

Para calcular la probabilidad de *seco*, $P(\text{Piso mojado} = \text{seco})$, tenemos que calcular la probabilidad marginal con la siguiente ecuación [Pearl, 1988]:

$$P(B_j) = \sum_{k=1}^n P(B_j|A_k) * P(A_k) \quad \text{Ecuación 2.4}$$

Para el caso del ejemplo se tiene:

$$P(\text{seco}) = P(\text{seco}|\text{soleado}) * P(\text{soleado}) + P(\text{seco}|\text{lluvioso}) * P(\text{lluvioso}) = 0.9 * 0.8 + 0.3 * 0.2 = 0.78$$

Este resultado es la respuesta a la pregunta tres. Para contestar las preguntas uno y dos se utiliza el teorema de Bayes como sigue, nótese que se usa la probabilidad (*seco*) obtenida con la ecuación 3.4:

$$P(\text{soleado}|\text{seco}) = \frac{P(\text{seco}|\text{soleado})P(\text{soleado})}{P(\text{seco})} = \frac{0.9 * 0.8}{0.78}$$

$$P(\text{lluvioso}|\text{seco}) = \frac{P(\text{seco}|\text{lluvioso})P(\text{lluvioso})}{P(\text{seco})} = \frac{0.3 * 0.2}{0.78}$$

2.4.2 Propagación de probabilidades

Una vez que se tiene la RB, lo interesante es realizar consultas sobre las variables incluidas en la misma. En el campo de los sistemas expertos, el principal interés se centra en ver cómo los valores que toman ciertas variables afectan a las probabilidades del resto. Si se intenta afrontar estos cálculos aplicando el teorema de Bayes, la ley de probabilidad total y las condiciones de independencia condicional se necesitaría realizar un número de operaciones que crece exponencialmente con el número de variables de la red, y se convertiría en una tarea computacionalmente intratable. Los algoritmos de propagación de probabilidades utilizan las relaciones de independencia implícitas en la estructura de una RB para calcular las probabilidades de cada uno de los nodos, dada la evidencia disponible de una forma más eficiente. Calculadas estas probabilidades, se pueden utilizar para hacer inferencias tanto de tipo inductivo como predictivo [Millán, 2000].

El procedimiento implementado en esta tesis es el algoritmo para redes con forma de árbol. Existen algunos otros como el de los llamados métodos de agrupamiento y el algoritmo HUGIN, los cuales no son descritos en este documento.

La idea del algoritmo de propagación para redes en forma de árbol lo desarrolló Pearl en 1982 y consiste en que cuando se modifica la información asociada a un nodo, éste traspasa la información a sus nodos vecinos mediante un conjunto de mensajes; estos nodos a su vez, procesan la información recibida junto con la que ellos poseen y la pasan a sus nodos vecinos (aún no modificados) y así sucesivamente hasta que todos los nodos han actualizado su información. La ventaja de este algoritmo es que funciona en un tiempo de orden lineal

respecto al número de nodos de la red, pero su principal limitación es que sólo se puede aplicar a redes con estructura de árbol [Millán, 2000].

Un *Direct Acyclic Diagram* (DAG) es de tipo árbol si éste tiene un único nodo raíz, sin padres; el resto de los nodos tiene exactamente un padre y cada nodo es descendiente de la raíz [Neapolitan, 2003], ver Figura 2.11.

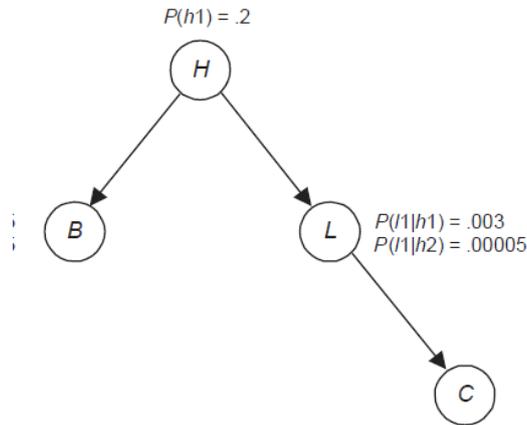


Figura 2.11. Red Bayesiana tipo árbol. [Neapolitan, 2003].

Más adelante en el capítulo, se describirá el algoritmo de paso de mensajes para inferencia en RB tipo conectadas uno a uno, ver Figura 2.12. Red Bayesiana conectada uno a uno

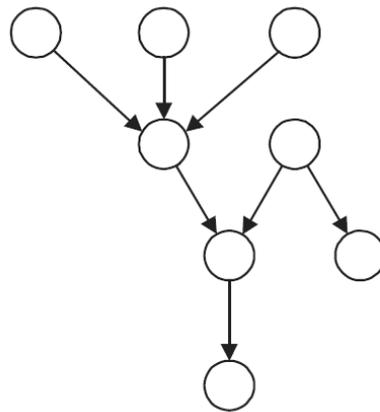


Figura 2.12. Red Bayesiana conectada uno a uno [Neapolitan, 2003].

2.4.2.1 Algoritmo de Inferencia en Redes Bayesianas tipo árbol

El algoritmo de inferencia consta de dos fases [Millán, 2000] y se describe a continuación:

Fase de inicialización. En esta fase se obtienen las probabilidades a priori de todos los nodos de la red, obteniendo un estado inicial de la red que se denotará por S_0 .

Fase de actualización. Cuando una variable se instancia, se actualiza el estado de la red, obteniéndose las probabilidades a posteriori de las variables de la red, basadas en la evidencia considerada, adoptando la red un estado que denominado S_t . Este paso se repite cada vez que una variable se instancia, obteniéndose los sucesivos estados de la red.

La idea principal en la que se basa el algoritmo es la siguiente [Millán, 2000]:

- Cada vez que una variable se instancia, informa a sus nodos vecinos mediante *mensajes*
- La variable instanciada envía a su padre un mensaje, llamado el λ -mensaje
- La variable instanciada envía a sus hijos un mensaje, citado como el π -mensaje
- Así la información se propaga por la red tanto en sentido ascendente como descendente
- Estos mensajes asignan a cada variable unos valores nombrados como λ -valor y π -valor. Multiplicando estos valores se obtienen las probabilidades a posteriori de cada una de las variables de la red.

Las fórmulas utilizadas para calcular los λ y π -mensajes, λ y π -valores y probabilidades P^* para este algoritmo se encuentran en la Tabla 2.7.

Tabla 2.7. Fórmulas para el cálculo de λ y π -mensajes, λ y π -valores y probabilidades P^* [Millán, 2000]:

Descripción	Fórmula	#
El λ -mensaje de B a A es: Si B es un hijo de A , B tiene k valores posibles y A m valores posibles, entonces para $j=1, \dots, m$	$\lambda_B(a_j) = \sum_{i=1}^k P(b_i/a_j) \cdot \lambda(b_i).$	1
Si B es hijo de A y A tiene m valores posibles, entonces para $j=1, \dots, m$, el π -mensaje de A a B :	$\pi_B(a_j) = \begin{cases} \pi(a_j) \cdot \prod_{\substack{c \in S(A) \\ c \neq B}} \lambda_c(a_j) & \text{si } A \text{ no ha sido instanciada} \\ 1 & \text{si } A = a_j \\ 0 & \text{si } A \neq a_j \end{cases}$	2
Si B tiene k valores posibles entonces para $i=1, \dots, k$ el λ -valor de B :	$\lambda(b_i) = \begin{cases} \prod_{c \in S(B)} \lambda_c(b_i) & \text{si } B \text{ no ha sido instanciada} \\ 1 & \text{si } B = b_i \\ 0 & \text{si } B \neq b_i. \end{cases}$	3
Si A es padre de B , B tiene k valores posibles y A tiene m valores posibles, entonces, para $i=1, \dots, k$, el π -valor de B :	$\pi(b_i) = \sum_{j=1}^m P(b_i/a_j) \cdot \pi_B(a_j).$	4
Si B es una variable con k posibles valores, entonces, para $i=1, \dots, k$, la probabilidad a posteriori basada en las variables es:	$P^*(b_i) = \alpha \cdot \lambda(b_i) \cdot \pi(b_i)$	5

Algoritmo 1. Algoritmo de propagación en redes con forma de árbol [Millán, 2000]

1. Inicialización.

- a. Inicializar todos los λ -mensajes y λ -valores a 1.
- b. Si la raíz A tiene m posibles valores, entonces para $j=1,\dots,m$, sea

$$\pi(a_j) = P(a_j) \quad \text{Ecuación 2.5}$$

- c. Para todos los hijos de B de la raíz A , hacer

Enviar un nuevo π -mensaje a B usando la fórmula 2.

2. Actualización

Cuando una variable se instancia o una variable recibe un λ o π -mensaje, se usa uno de los siguientes procedimientos de actualización:

- a. Si una variable B se instancia a un valor b_j , entonces:
 - i. Inicializar $P^*(b_j) = 1$ y $P^*(b_i)=0$, para todo $i \neq j$
 - ii. Calcular $\lambda(B)$ usando la fórmula 3
 - iii. Enviar un nuevo λ -mensaje al padre de B usando la fórmula 1
 - iv. Enviar nuevos π -mensajes a los hijos de B usando la fórmula 2
 - b. Si una variable B recibe un nuevo λ -mensaje de uno de sus hijos y la variable B no ha sido instanciada todavía, entonces:
 - i. Calcular el nuevo valor de $\lambda(B)$ usando la fórmula 3
 - ii. Calcular el nuevo valor de $P^*(B)$ usando la fórmula 5
 - iii. Enviar un nuevo λ -mensaje al padre de B usando la fórmula 1
 - iv. Enviar nuevos π -mensajes a los otros hijos de B usando fórmula 2
 - c. Si una variable B recibe un nuevo π -mensaje de su padre y la variable B no ha sido instanciada todavía, entonces:
 - i. Calcular el nuevo valor de $\pi(B)$ usando la fórmula 4
 - ii. Calcular el nuevo valor de $P^*(B)$ usando fórmula 5
 - iii. Enviar nuevos π -mensajes a los hijos de B usando la fórmula 2
-

2.4.2.2 Algoritmo de Inferencia en RB conectadas uno a uno

Un DAG es llamado conectado uno a uno si hay a lo mucho una cadena entre dos nodos cualesquiera. De otra manera es llamado de conexión múltiple. Por ejemplo, la red mostrada en la Figura 2.12 muestra una red conectada uno a uno y la diferencia con una red de árbol es que en la primera puede haber nodos con más de un padre [Neapolitan, 2003].

A continuación, en la Tabla 2.8, se describen las ecuaciones del algoritmo de propagación de evidencia en una RB conectada uno a uno; en donde por cada variable X se definen λ -mensajes, λ -valores, π -mensajes y π -valores [Neapolitan, 2003].

Tabla 2.8. Ecuaciones del algoritmo de propagación de evidencia en una red conectada uno a uno [Neapolitan, 2003].

1. λ mensajes:

Por cada hijo Y de X , para todos los valores de x ,

$$\lambda_Y(x) \equiv \sum_y \left[\sum_{w_1, w_2, \dots, w_k} \left(P(y|x, w_1, w_2, \dots, w_k) \prod_{i=1}^k \pi_Y(w_i) \right) \right] \lambda(y).$$

donde, W_1, W_2, \dots, W_k son los otros padres de Y .

2. λ valores:

Si $X \in A$ y el valor de X es \hat{x} ,

$$\begin{aligned} \lambda(\hat{x}) &\equiv 1 \\ \lambda(x) &\equiv 0 \quad \text{for } x \neq \hat{x}. \end{aligned}$$

Si $X \notin A$ y X es una hoja, para todos los valores de x ,

$$\lambda(x) \equiv 1.$$

Si $X \notin A$ y X no es una hoja, para todos los valores de x ,

$$\lambda(x) \equiv \prod_{U \in CH_X} \lambda_U(x).$$

donde CH_X es el conjunto de todos los hijos de X .

3. π mensajes:

Dejar Z ser un padre de X . Entonces para todos los valores de Z ,

$$\pi_X(z) \equiv \pi(z) \prod_{U \in CH_Z - \{X\}} \lambda_U(z).$$

Tabla 2.8. Ecuaciones del algoritmo de propagación de evidencia en una red conectada uno a uno [Neapolitan, 2003]. Continuación.

4. π valores:

Si $X \in A$ y el valor de X es \hat{x} ,

$$\begin{aligned}\pi(\hat{x}) &\equiv 1 \\ \pi(x) &\equiv 0 \quad \text{for } x \neq \hat{x}.\end{aligned}$$

Si $X \notin A$ y X es una raíz, para todos los valores de x ,

$$\pi(x) \equiv P(x).$$

Si $X \notin A$, X no es raíz, y Z_1, Z_2, \dots, Z_j son los padres de X , para todos los valores de x ,

$$\pi(x) = \sum_{z_1, z_2, \dots, z_j} \left(P(x|z_1, z_2, \dots, z_j) \prod_{i=1}^j \pi_{X}(z_i) \right)$$

5. Dadas las definiciones anteriores, por cada variable X , se tiene para todos los valores de x ,

$$P(x|a) = \alpha \lambda(x) \pi(x),$$

donde α es una constante de normalización

La implementación del algoritmo 1, redes tipo árbol, se extiende en el capítulo 5 sección 4.1. También puede consultarse [Neapolitan, 2003], donde se incluyen ejercicios resueltos completamente.

2.4.3 Modelado de RB a partir de datos

Al principio, los DAGs en una RB eran desarrollados a mano por expertos del dominio. De la misma forma, las probabilidades condicionales eran establecidas por expertos. Lo cual conducía a un proceso laborioso y difícil cuando se trataba de redes medianas-grandes. Por lo que, se desarrollaron métodos que pudieran generar los DAGs desde datos, además se formalizaron los métodos de aprendizaje de probabilidades condicionales a partir de datos [Neapolitan, 2003].

En una RB el DAG es llamado la Estructura y los valores de distribución de probabilidades condicionales son llamados Parámetros. Sólo se pueden aprender los valores de los parámetros a partir de datos cuando las probabilidades son frecuencias relativas [Neapolitan, 2003].

2.4.3.1 La obtención de los parámetros

En este documento se explora la obtención de parámetros a partir de datos discretos cuando las probabilidades son frecuencias relativas.

Para la obtención de parámetros se establece que la cantidad de información que fluye entre dos nodos puede ser medida usando la ecuación de información mutua, ésto cuando no hay nodos instanciados:

$$I(X_i, X_j) = \sum_{x_i, x_j} P(x_i, x_j) \log \frac{P(x_i, x_j)}{P(x_i)P(x_j)} \quad \text{Ecuación 2.6}$$

Mencionada anteriormente, la probabilidad es establecida por la frecuencia relativa de los datos para cada variable.

2.4.3.2 La obtención de la estructura

A continuación, se presenta el algoritmo Chow&Liu [Chow, 1968] para el aprendizaje de RB; dicho algoritmo proporciona una de las primeras investigaciones para construir DAGs a partir de datos.

El algoritmo es el siguiente:

1. Calcular (T) : Todos los pares de variables posibles de $X(T)$ utilizando la ecuación 2.7:

$$\frac{x(x-1)}{2} \quad \text{Ecuación 2.7}$$

donde x es el número de variables (atributos)

2. Inicializar como árbol vacío
3. Calcular costos para cada par, $I(X_{mi}, X_{mj})$ usando la ecuación 2.6
4. Seleccionar el par con el máximo costo (X_{mi}, X_{mj})
5. Agregar al árbol las variables del par seleccionado y el arco

Iterar

6. Formar un conjunto $B(T)$ con todas las ramas (x_i, x_j) que deriven de alguna de las ramas de $E(T)$, considerando que x_i forma parte de una rama en $E(T)$ y x_j no está en las variables de $V(T)$
7. Seleccionar el par (X_{mi}, X_{mj}) de $B(T)$ con el máximo costo y agregar la nueva variable a $V(T)$ y el par a $E(T)$

Hasta que se procesen todas las variables ($V = X$)

Ver implementación de código en el anexo del CD de esta tesis, donde se implementa el aprendizaje de parámetros y estructura de una red Bayesiana con datos sintéticos. Así mismo, ver la implementación del algoritmo Chow&Liu, con los datos del caso de estudio, en el capítulo 5 sección 4.2.

2.5 Lógica Difusa

La Lógica Difusa fue creada para emular la lógica humana y tomar decisiones acertadas a pesar de la información. Es una herramienta flexible que se basa en reglas lingüísticas dictadas por expertos. Por ejemplo, la velocidad de un automóvil es una variable que puede tomar distintos valores lingüísticos, como *alta*, *media* o *baja*. Estas variables lingüísticas están regidas por reglas que dictan la salida del sistema [Ponce, 2010].

En otras palabras, la Lógica Difusa es un conjunto de principios matemáticos basados en grados de membrecía o pertenencia, cuya función es modelar información. Este modelado se hace con base en reglas lingüísticas que aproximan una función mediante la relación de entradas y salidas del sistema [Ponce, 2010]. Esta lógica representa rangos de membrecía dentro de un intervalo entre 0 y 1, a diferencia de la lógica convencional, en la que el rango se limita a dos valores: el cero o el uno [Ponce, 2010].

Mediante el uso de Lógica Difusa se puede representar la forma de la lógica humana, por ejemplo en afirmaciones como *el día es caluroso*, *el automóvil va rápido*, etc. En el primer caso, se sabe que hay alta temperatura, pero no se sabe a qué temperatura exactamente se refiere; en el segundo caso, se dice que *el automóvil va rápido*, sin embargo nunca se especifica su velocidad [Ponce, 2010].

¿Por qué usar un sistema difuso? Si se requiere automatizar un proceso que controla un trabajador, el sistema difuso tendrá la tarea de emular a dicho trabajador. Además, si se toma en cuenta que el trabajador hace juicios con base en su criterio y experiencia, y que estos juicios y decisiones se realizan en forma lingüística (como *alto*, *lento*, etc.), se puede notar que un sistema convencional no maneja este tipo de entradas, mientras que el sistema difuso sí lo hace [Ponce, 2010].

Cualquier función $\mu_{\tilde{A}}$ la cual pertenece al dominio U con un intervalo cerrado $[0,1]$ comprueba un subconjunto difuso \tilde{A} . La función $\mu_{\tilde{A}}$ es una función de membrecía del subconjunto difuso, así que, $\mu_{\tilde{A}}(u)$ es el grado de membrecía de u para \tilde{A} [Tang, 2007].

Para un conjunto difuso \tilde{A} en un espacio de probabilidad (X,B,P) , si su función de membrecía $\mu_{\tilde{A}}(u)$ es una función medible de tipo Borel, se considera que \tilde{A} es un evento difuso en X y su probabilidad escalar es [Tang, 2007]:

$$P(\tilde{A}) = \sum_{x \in X} \mu_{\tilde{A}}(x)P(x) \quad \text{Ecuación 2.8}$$

2.5.1 Redes Bayesianas Difusas

Existen diferentes enfoques cuando se integran las RB con la Lógica Difusa [Ryhajlo, 2013]. El enfoque utilizado en esta investigación es el utilizado en [Tang, 2007].

En la sección 2.4.1 de este documento se presentó la ecuación Bayesiana (Ecuación 2.3), ahora se presentará la ecuación Bayesiana difusa con un ejemplo [Tang, 2007]:

Suponga que B_1 expresa: $edad > 50$; B_2 expresa: $50 \geq edad \geq 35$; B_3 expresa: $34 \geq edad \geq 20$; B_4 expresa: $edad < 20$, y A_1 expresa: $salario\ anual > 10000$; A_2 expresa: $10000 \geq salario\ anual \geq 3000$; A_3 expresa: $salario\ anual < 3000$.

El censo de población se muestra en la Tabla 2.9.

Tabla 2.9. Resultados del censo de población [Tang, 2007].

B1	B2	B3	B4
20%	25%	30%	25%

Y los datos del buró de impuestos se muestran en Tabla 2.10.

Tabla 2.10. Datos del buró de impuestos [Tang, 2007].

P(A _j B _i)	B1	B2	B3	B4
A1	0.1	0.2	0	0
A2	0.5	0.6	0.8	0
A3	0.4	0.2	0.2	1

Ahora suponga que el salario anual de la gente es más de 10000, ¿cuál es la probabilidad en cada rango de edad? De acuerdo a las condiciones mencionadas anteriormente, se busca el resultado de $P(B_i|A_1)$, $i=1,2,3,4$. A través del total de la ecuación de probabilidad:

$$P(A_j) = \sum_{i=1}^4 P(B_i)P(A_j|B_i) \tag{Ecuación 2.9}$$

con $j=1,2,3$, se puede encontrar $P(A_1)=0.07$, $P(A_2)=0.49$, $P(A_3)=0.44$. De acuerdo con la ecuación Bayesiana (Ecuación 2.3) y se tiene:

$$P(B_1|A_1) = \frac{P(A_1|B_1)P(B_1)}{[P(A_1|B_1)P(B_1)+P(A_1|B_2)P(B_2)+P(A_1|B_3)P(B_3)+P(A_1|B_4)P(B_4)]} = 0.2857$$

$$P(B_2|A_1)=0.7143, P(B_3|A_1)=P(B_4|A_1)=0$$

En el dominio Difuso, importan eventos difusos que involucran a la variable B_i , por ejemplo: $\tilde{B} = \{\text{no muy viejo}\}$. Para este caso la ecuación Bayesiana difusa es:

$$P(\tilde{B}|A_j) = \frac{\sum_{i \in I} \mu_{\tilde{B}}(B_i)P(A_j|B_i)P(B_i)}{P(A_j)} \tag{Ecuación 2.10}$$

O se pudiera estar interesado en eventos difusos donde se involucra a la variable A_j , por ejemplo $\tilde{A} = \{\text{No tan bajo}\}$. Entonces la ecuación Bayesiana difusa sería:

$$P(B_i|\tilde{A}) = \frac{\sum_{j \in J} \mu_{\tilde{A}}(A_j)P(A_j|B_i)P(B_i)}{P(\tilde{A})} \tag{Ecuación 2.11}$$

La posibilidad marginal difusa es:

$$P(\tilde{A}) = \sum_{j \in J} \mu_{\tilde{A}}(A_j)P(A_j) \tag{Ecuación 2.12}$$

Ahora se define la función de membrecía de B :

$$\mu_{\tilde{B}}(B) = \begin{cases} 0.1, & B = B_1 \\ 0.4, & B = B_2 \\ 0.6, & B = B_3 \\ 1.0, & B = B_4 \end{cases}$$

y la función de membrecía de \tilde{A} :

$$\mu_{\tilde{A}}(A) = \begin{cases} 1.0, & A = A_1 \\ 0.5, & A = A_2 \\ 0, & A = A_3 \end{cases}$$

Ahora se puede encontrar los resultados como sigue: asumir que el ingreso anual de la gente es de más de 10000 y que no son tan viejos, entonces la probabilidad es:

$$P(\tilde{B}|A_1) = \mu_{\tilde{B}}(B_1) P(B_1|A_1) + \mu_{\tilde{B}}(B_2) P(B_2|A_1) + \mu_{\tilde{B}}(B_3) P(B_3|A_1) + \mu_{\tilde{B}}(B_4) P(B_4|A_1) = 0.3143$$

Con la aplicación de la ecuación Bayesiana difusa se puede encontrar también, basado en el ejemplo anterior, la probabilidad de los enunciados: “probabilidad cuando la población es de más de 50 años y que su ingreso no es tan bajo”, “la probabilidad cuando el ingreso anual de la población no es tan bajo y no son tan viejos”.

La aplicación de la ecuación Bayesiana difusa en una RB se desarrolla en el capítulo cinco sección 4.3.

2.6 Paquete GeNIe [Pittsburgh, 2016]

Fue desarrollado por el Laboratorio de Sistemas de Decisión de la Universidad de Pittsburgh y puesto a disposición de la comunidad para su uso gratuito con cualquier propósito, (incluidos fines comerciales y educativos), desde 1998.

GeNIe (Graphical Network Interface) es un entorno para la creación de modelos gráficos probabilísticos aplicables al análisis de decisiones, tales como redes bayesianas y diagramas de influencia. Ha sido desarrollada en Visual C++ y concebida para el sistema operativo Windows. Ver referencia [Pittsburgh, 2016] donde se encontrará una liga a la página principal de la aplicación y documentación de uso.

2.7 Discusión

Este capítulo presenta la teoría necesaria para comprender las RB, las dependencias entre las variables y la teoría básica para comprender el modelado de estudiantes utilizando RB. Se presenta e introduce la teoría de las técnicas de RB que se implementan en el capítulo cinco, como son: RB Difusas, aprendizaje Bayesiano (modelado a partir de datos) y propagación de creencias en las RB. Es decir, se presenta la teoría necesaria para satisfacer los experimentos mostrados en el capítulo cinco.

Capítulo 3

Estado del Arte

Este capítulo detalla antecedentes actuales que se han generado alrededor de los Sistemas Tutores Inteligentes (ITS), dentro y fuera de CENIDET; del mismo modo se incluyen tablas donde se resume dicha información y se cierra el capítulo con una discusión sobre lo descrito en estos materiales.

3.1 Antecedentes Institucionales

En esta sección se mencionan trabajos de investigación dentro del CENIDET que tienen alguna relación (parcial) con el proyecto que se está proponiendo.

Herramienta para el Desarrollo de Sistemas Tutores [Ingram, 2000] es una tesis en la que se desarrolló un STI, llamado SGyACT, el cual no aborda el problema del modelado del estudiante ya que su principal enfoque es el Módulo de Instrucción del STI. El STI fue desarrollado para la enseñanza del lenguaje SQL en nivel postgrado.

El lenguaje de desarrollo del sistema SGyACT fué Java y se utilizaron librerías tales como Swing JFC, la cual es una ampliación del AWT (*Abstract Windowing Toolkit*), que es a su vez un conjunto de APIs que permiten el desarrollo rápido de prototipos y de interfaces gráficas de usuario en Java.

El módulo de conocimiento contiene el material del curso que se desea enseñar; este material está en diapositivas de PowerPoint, las cuales son transformadas en archivos de imágenes.

El Módulo Pedagógico o de Instrucción emplea un grafo instruccional, en donde cada nodo del grafo representa un átomo de información. Para construir el plan de estudios, una vez que se han establecido las relaciones de precedencia de capítulos como de átomo de información, se hace uso de un algoritmo que el autor llama Planificador. Este algoritmo toma los grafos instruccionales que se han creado y los ordena de acuerdo a las restricciones de precedencia que se hayan establecido. El algoritmo empleado en esta tesis para la construcción del Planificador es una variable del algoritmo para encontrar vías mínimas de Dijkstra.

El Módulo del Alumno del proyecto está conformado por exámenes teóricos y prácticos previamente establecidos.

Desarrollo de un Módulo de Planificación Adaptativa de Enseñanza para un Sistema Tutor [Ceyca, 2004]. Es una tesis que desarrolla un STI basado en la investigación y desarrollo de [Ingram, 2000] donde se busca una mejora al STI para la enseñanza del lenguaje SQL. El proyecto de tesis se enfoca al Módulo Pedagógico de los Sistemas Tutores, con el fin de adaptar el plan de enseñanza de acuerdo a las habilidades cognitivas de memorización y comprensión del estudiante, independientemente del material a enseñar.

Como ya se mencionó, el punto central de este trabajo es el Módulo Pedagógico y se desea adecuar el plan de estudios para permitir al estudiante aprovechar al máximo el material de enseñanza.

La principal aportación de este trabajo es la adición de tres elementos nuevos al Módulo Pedagógico que son: 1) evaluador de exámenes, cuya función principal es obtener los valores de las habilidades de memorización y comprensión en base a las preguntas de los exámenes que evalúan el tema que el estudiante está revisando; 2) psicolexia, este elemento registra las variables que permiten determinar si, por falta de tiempo dedicado en el análisis de las

diapositivas, se originan problemas de memorización o comprensión en el estudiante; 3) analizador, es el elemento encargado de determinar si existen deficiencias en las habilidades de memorización y comprensión, y determina si la causa es por falta de tiempo en el análisis de las diapositivas.

Se aplicó la prueba PEMGU, la cual es una iniciativa europea para sistemas educativos, y se obtuvieron los resultados, en comparación con la versión anterior, que se muestran en la Tabla 3.1.

Tabla 3.1. Resultados de la prueba PEMGU al servidor de tutores [Ceyca, 2004].

Elemento	Valoración de versión Actual	de Valoración de Versión anterior	de Máxima
Objetivos de aprendizaje	9	0	60
Contenido para el aprendizaje	72	65	75
Actividades para el aprendizaje	43	28	60
Evaluación	40	24	55
Motivación	33	20	35

A continuación en la Tabla 3.2, se muestra un resumen de las investigaciones, dentro de la institución (CENIDET), que tienen relación con el proyecto que aquí se propone.

Tabla 3.2. Resumen de los antecedentes al proyecto de tesis.

Nombre	Objetivo	Técnicas Empleadas	Comentarios
Herramienta para el Desarrollo de Sistemas Tutores [Ingram, 2000]	Desarrollo de Sistema Tutor Inteligente para la enseñanza del lenguaje SQL en niveles de postgrado.	Grafo instruccional, algoritmo Panificador, exámenes teóricos y prácticos previamente establecidos.	No aborda el problema del modelado del estudiante, pues utiliza exámenes previamente establecidos para la valoración del conocimiento del estudiante, es decir, se obtienen los datos del conocimiento del alumno como lo haría un tutorial simple.
Desarrollo de un Módulo de Planificación Adaptativa de Enseñanza para un Sistema Tutor [Ceyca, 2004]	Adaptar el plan de enseñanza de acuerdo a las habilidades cognitivas de memorización y comprensión del estudiante.	Evaluador de exámenes, psicolexia y analizador.	Aunque no se establece un modelado "inteligente del estudiante", se realizan pruebas interesantes que pudieran incluirse en el desarrollo de la tesis.

3.2 Trabajos relacionados con el proyecto

En esta sección se mencionan investigaciones externas al CENIDET y con las cuales se trabajó inicialmente para llevar a cabo la propuesta de esta tesis.

Using Bayesian Networks to Manage Uncertainty in Student Modeling [Conati, 2002]. En este artículo los autores pretenden exponer las ventajas del uso de Redes Bayesianas (RB) como técnica del modelado del estudiante para el STI Andes, el cual ayuda a los alumnos con el estudio de física.

Según los autores, las RB de Andes codifican dos tipos de conocimiento: (1) el conocimiento de dominio general (*domain-general knowledge*), que abarca los conceptos y procedimientos generales que definen el dominio de la física newtoniana, y (2) el conocimiento de tarea específica (*task-specific knowledge*), que abarca los conocimientos relacionados con el rendimiento de un estudiante en un problema específico o ejemplo. Para este trabajo de estudio del arte, el enfoque será a la codificación del tipo de conocimiento de dominio general o *domain-general knowledge* y su respectiva implementación Bayesiana.

La parte de dominio general en la RB representa el conocimiento del estudiante a largo plazo, a través de dos tipos de nodos: Regla y Regla Contextual (*Rule and Context-Rule*). Cada nodo tiene dos valores, dominado (*Mastered*) o sin dominar (*Not Mastered*). Para los nodos regla o *Rule*, el dominio significa que el estudiante debe ser capaz de aplicar ese pedazo de conocimiento correctamente siempre que sea necesario para resolver un problema, es decir, en todos los contextos posibles.

Andes utiliza la distinción entre los nodos *Rule* y nodos *Context-Rule* con el fin de modelar la especificidad del contexto de los conocimientos de los estudiantes. Con el objetivo de representar la relación entre las versiones generales y específicas de una pieza de conocimiento, cada nodo *Context-Rule* tiene un padre, el nodo *Rule*, representando la regla general correspondiente, lo cual se puede representar gráficamente con la Figura 3.1.

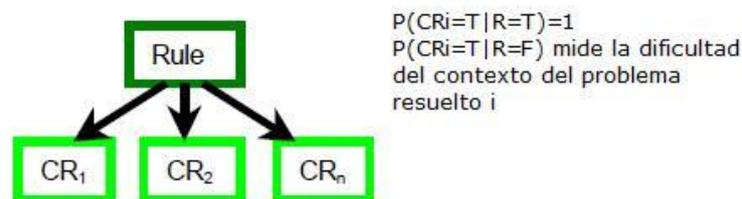


Figura 3.1. Relación entre los nodos *Rule* y *Context-Rule* en la RB de tipo dominio general de conocimiento [Conati, 2002].

Los resultados del uso de redes bayesianas en el STI Andes para el modelado del estudiante son: el sistema fue usado por cuatro semanas por 173 estudiantes de la Academia Naval de EUA en el curso introductorio de Física. Al término del período se aplicó un examen que fue

comparado con un examen de estudiantes (grupo de 162 alumnos) que no usaron Andes en el curso. El resultado fue que los estudiantes que usaron Andes obtuvieron 1.6 puntos más arriba de calificación (en promedio) que los que no usaron el sistema.

A Probabilistic Student Model for SQL-Tutor and Its Application To Problem Selection [Mayo, 2001]. Se pretende extender el STI llamado *SQL-Tutor*, existente actualmente bajo otro enfoque de modelado de estudiante, a un enfoque probabilístico para la presentación de los siguientes problemas de forma más “inteligente”. El enfoque actual muestra los problemas en serie después de las lecciones, el enfoque probabilístico los presentará de acuerdo al conocimiento del alumno.

Se utilizan Redes Bayesianas para implementar el enfoque probabilístico consistente de un conjunto de variables binarias $Mastered_1, Mastered_2, \dots, Mastered_n$, donde n es el total de restricciones. Cada variable puede estar en el estado *YES* o *NO* con cierta probabilidad, indicando si el estudiante ha aprendido la restricción.

Durante el estudio el sistema utiliza una tabla de heurísticas (Tabla 3.3) para actualizar las probabilidades.

Tabla 3.3. Heurísticas usadas para actualizar el modelo del estudiante [Mayo, 2001].

(a) Si la restricción c es satisfecha, entonces $P(Mastered_c = YES)$ incrementa 10% de $(1 - P(Mastered_c = YES))$.
(b) Si la restricción c es violada y no hay retroalimentación acerca de c , entonces $P(Mastered_c = YES)$ decrementa en 20%.
(c) Si la restricción c es violada pero hay retroalimentación acerca de c , entonces $P(Mastered_c = YES)$ incrementa en 20% de $(1 - P(Mastered_c = YES))$.

Las pruebas consisten en dos grupos: el primero daba clic a la opción del sistema para pasar de problema en problema; el segundo utilizó el enfoque Bayesiano, el cual mostraba el siguiente problema a resolver de acuerdo al conocimiento del alumno. Los estudiantes en el segundo grupo experimental fueron capaces de resolver problemas seleccionados por el enfoque Bayesiano en promedio de 2.69 intentos comparados a 3.18 intentos del grupo uno.

Bayesian Student Modeling Improved by Diagnostic Items [Chen, 2014]. Busca obtener información de las respuestas erróneas del estudiante para desarrollar un modelo más robusto del estudiante.

Normalmente sólo se utiliza la información de las respuestas acertadas como parte del modelado del alumno, sin embargo existe información importante en las respuestas incorrectas, por lo que especifica cuáles de los conceptos (o todos) no están dentro del conjunto de conocimiento actual del alumno. Este artículo muestra la implementación de un modelo NIDA (*Noisy Input, Deterministic AND*), donde los códigos 1 y 0 respectivamente representan conceptos correcta y no correctamente utilizados. El modelo NIDA involucra un modelo binario. Cuando los estudiantes dan una respuesta incorrecta, las probabilidades de

saber todos los conceptos relevantes son reducidas. Se propone el modelo NIDA (Figura 3.2) para representar las relaciones entre las respuestas de los estudiantes y su estado de conocimiento. La función determinista f del modelo binario NIDA es el AND lógico.

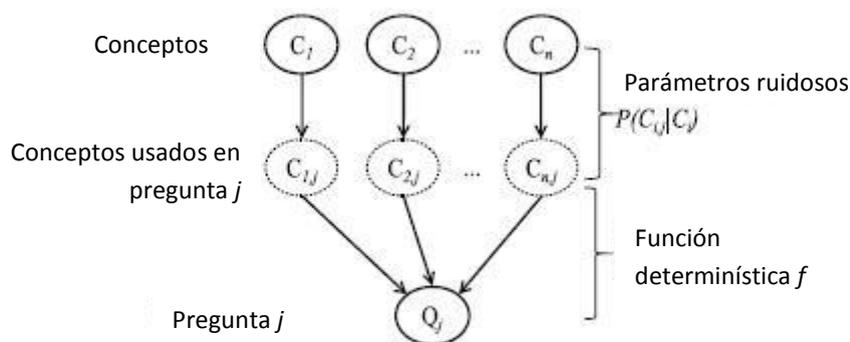


Figura 3.2. Modelo diagnóstico NIDA [Chen, 2014].

Se desarrollaron tres pruebas, la primera consistió en un grupo de 180 estudiantes, los cuales respondieron a 40 preguntas, el 93.61% de los conceptos fueron diagnosticados correctamente. En comparación, la implementación del modelo DINA (*Deterministic Input, Noisy AND*) suministró 73.95% de conceptos diagnosticados correctamente.

Using Bayesian networks to improve knowledge assessment [Millán, 2013]. En este artículo los autores integraron un *Generic Bayesian Student Model* (GBSM) a un sistema computacional de evaluación de matemáticas (PmatE) haciendo uso de *Learnign Objects* (LO) disponibles en Internet.

El estudio tuvo como objetivo saber si las capacidades computarizadas del examen del PMatE pudieran mejorarse usando un Modelo de estudiante Bayesiano (BSM).

El GBSM utilizado para este estudio fue desarrollado por [Millán, 2000]. La diferencia del GBSM utilizado en este estudio y el utilizado por otros autores en Sistemas Tutores Inteligentes es que este GBSM no es de dominio específico, así que puede ser reutilizado.

El estudio de este artículo abarca el uso de 152 estudiantes reales a los cuales se les aplicaron dos exámenes, uno escrito y evaluado por tres profesores reales, y otro, generado por la RB del modelo del estudiante que se propuso y construyó para este sistema. Ver Figura 3.3 para visión general de GBSM.

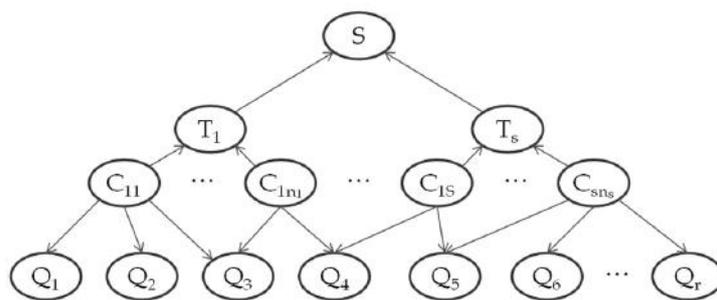


Figura 3.3. Estructura general de GBSM [Millán, 2013].

Los resultados obtenidos mostraron que, el examen escrito tuvo más grado de aceptación por parte de los evaluadores que los resultados arrojados del examen que utilizó el BSM. Se calificaron 1,824 respuestas obtenidas de 152 exámenes con 12 preguntas cada uno. Sin embargo, el BSM dio una estimación del nivel de conocimiento del estudiante en diferentes niveles de granularidad.

Bayesian Student Modeling [Conati, 2010], es un artículo estructurado en dos partes. La primera menciona las ventajas de utilizar RB en el modelado del estudiante para STI. Dichas ventajas son: 1) proveen una manera compacta de representar la distribución de probabilidad de unión, tomando los padres como nodos de interés y no todas las variables existentes en la red; 2) los algoritmos existentes para procesar RB reales son estables y confiables, de esta manera se puede experimentar directamente en ellos; 3) la naturaleza gráfica de las RB facilitan el diseño de modelos, y aun cuando se pudiera dejar fuera alguna variable se puede introducir sin tener que modificar el modelo completo; 4) las RB soportan transparentemente la toma de decisiones que es tan elemental en los STI.

La segunda parte del artículo hace una comparación de STI que utilizan RB estáticas y otros que utilizan RB dinámicas para el modelado del alumno. El artículo lista seis ejemplos que incluyen dos modelos basados en RB dinámicas, los cuales son Prime Climb (enseña la factorización de números) y los tutores de CMU; y cuatro que utilizan RB estáticas, ellos son: Andes (enseña Física), HyDrive (enseña cuestiones de la Aeronáutica), Off- Line (enseña Física), y Wayang Outpost (para Matemáticas).

Un ejemplo del modelado del estudiante en el sistema Andes se ilustra en la Figura 3.4, donde se ejemplifica del uso de RB estáticas y el uso del enfoque de rastreo de conocimiento.

Como ejemplo de modelo de alumno basado en RB dinámica, [Conati, 2010] muestra la RB de la Figura 3.5, la cual corresponde al STI Prime Climb.

Se describió el uso de las RB estáticas y dinámicas en dos diferentes ME de STI Andes y Prime Climb. Se proporciona pequeñas porciones de aplicación de dichos ME.

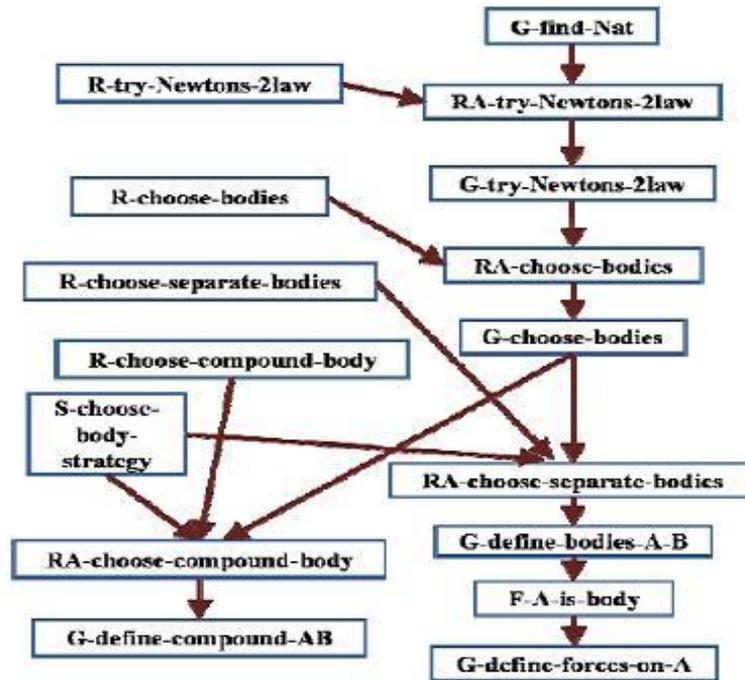


Figura 3.4. Ejemplo de RB estática utilizada en el STI Andes [Conati, 2010].

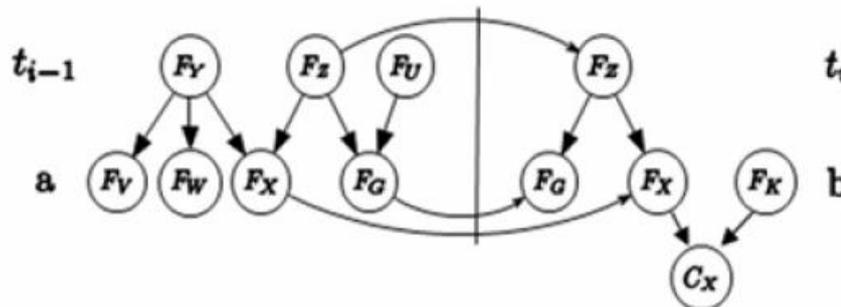


Figura 3.5. Nodos de factorización en el ME de Prime Climb, mostrando el uso de RB dinámicas cuando el usuario hace uso de la acción clic [Conati, 2010].

Learning Bayesian Knowledge Tracing Parameters with a Knowledge Heuristic and Empirical Probabilities [Hawkins, 2014]. Los autores describen que la técnica *Bayesian Knowledge Tracing* es una de las técnicas de modelado de estudiante más populares (dado que predice con precisión y posee la habilidad de inferir el conocimiento del alumno). Sin embargo, se ha encontrado en las investigaciones problemas con algunos de los más populares métodos de ajuste. Estos problemas incluyen: múltiples conjuntos de parámetros altamente diferentes que predicen los datos igualmente bien, mínimos locales, parámetros degenerados y alto costo computacional durante el ajuste.

Bayesian Knowledge Tracing (BKT) es un paradigma de ME usado en STI, el cual infiere el conocimiento del alumno dado su historial de respuestas a problemas, lo cual puede predecir su rendimiento futuro.

Existen en la literatura dos métodos de ajuste muy utilizados en los modelos BKT y son: *Expectation-Maximization* (EM) y red de búsqueda de fuerza bruta.

El método de ajuste propuesto por los autores es llamado Probabilidades Empíricas (EP por sus siglas en inglés) y se compone de un proceso de dos pasos que involucra la anotación de los datos del desempeño y después usar esta información para procesar los parámetros del BTK.

En este artículo los autores comparan modelos BKT ajustados a EM y EP en términos de predicción de precisión, degeneración de modelo y tiempo de entrenamiento.

Los resultados mostraron que las diferencias entre las dos métricas son estadísticamente significativas de acuerdo a los exámenes (MAE (*mean absolute error*): $test(1,578) = 10.88$, RMSE (*root mean squared error*): $test(1,578) = -6.74$, $A'(average)$: $test(1,314) = -7.01$, p (*percentage*) < 0.00001) las diferencias son pequeñas. Sin embargo los dos métodos son comparables en términos de predicción de desempeño.

3.3 Discusión del estado del arte

Los trabajos realizados en CENIDET no implementan el modelado del estudiante con técnicas de Inteligencia Artificial.

Los principales problemas y/o soluciones observados en los trabajos fuera de CENIDET son resumidos a continuación:

1. El uso de RB estáticas ha resultado exitoso en el modelado de estudiantes en STI como Andes. Es interesante que los autores de [Conati, 2002] pudieron satisfacer los objetivos de los STI utilizando sólo RB estáticas. Además de que el sistema fue probado por estudiantes reales y los resultados lograron superar a los de estudiantes con tutor humano.
2. Los autores de [Conati, 2002] reconocen que el modelado del estudiante en STI posee retos únicos para los enfoques probabilísticos debido a que el conocimiento de los estudiantes cambia con el tiempo, conforme ellos aprenden. Con este hecho, la comparación de ME que utilizan RB estáticas y RB dinámicas se entiende como necesaria.
3. En [Mayo, 2001] la línea de investigación se enfoca a la eliminación de heurísticas como método de actualización y hacer uso de la teoría Bayesiana.
4. En [Chen, 2014] el trabajo futuro es planteado en el hecho de la adquisición de información de inicio para la RB requerida por el modelo, dicha información es muy difícil de adquirir de los expertos, por lo que se pretende derivar de datos.

5. En [Millán, 2013] es interesante la perspectiva de un GBSM por lo tanto se puede incluir en cualquier STI y probarse, ya que se amolda a las necesidades del sistema. Lo malo de este artículo es que el modelo del estudiante no es aplicado en un STI sino a un sistema de valoración para estudiantes de Matemáticas en línea. El GBSM es de reciente creación y los autores planean la integración del mismo en STI.

El uso de LO es una nueva forma de desarrollar ME que suprime el consultar a un experto; se puede construir un STI sin necesidad de trabajar con un profesor de la materia. Los autores mencionan como trabajo futuro mejoras al modelo teórico para poder utilizarlo en situaciones reales, no se menciona cuál modelo si el GBSM o el modelo implementado para este estudio.

Del análisis de los seis trabajos revisados se deriva que, las técnicas más utilizadas son los ME con RB estáticas y dinámicas así como la implementación de evaluaciones (con RB) para obtener datos de inicio para las redes. Otra comparación que [Mayo, 2001] menciona y no se ha realizado es: la de los efectos de diferentes técnicas de modelado en la efectividad de la enseñanza de STI.

A continuación se presenta un concentrado de los trabajos relacionados consultados, tomando en cuenta: nombre del artículo, objetivo, técnica empleada, pruebas y resultados y observaciones (Tabla 3.4. Concentrado de los trabajos relacionados consultados).

Tabla 3.4. Concentrado de los trabajos relacionados consultados.

Nombre	Objetivo	Técnicas empleadas	Pruebas y resultados	Observaciones
Learning Bayesian Knowledge Tracing Parameters with a Knowledge Heuristic and Empirical Probabilities [Hawkins, 2014]	Comparar modelos <i>Bayesian Knowledge Tracing</i> (BKT) ajustados a Expectation-Maximization (EM) y Probabilidades Empíricas (EP), en términos de predicción de precisión, degeneración de modelo, y tiempo de entrenamiento.	BKT, EM y EP.	Pruebas de métodos de ajuste en los modelos BKT: EM y red de búsqueda por fuerza bruta. Las diferencias son pequeñas. Sin embargo los dos métodos son comparables en términos de predicción de desempeño.	Los resultados de todos los experimentos están disponibles en línea: https://sites.google.com/sits/whawkins90/publications/ep .
Bayesian Student Modeling Improved by Diagnostic Items [Chen, 2014]	Proveer información acerca de qué conceptos faltan en el conocimiento del alumno por sus respuestas erróneas.	Modelo <i>Noisy Input Deterministic AND</i> para la evaluación previa y RB estáticas.	Comparado con el modelo DINA, la certeza y eficacia del modelo propuesto son mejores.	Se cuenta con suficientes datos para recrear un ME con RB y NIDA. Sin embargo los complementos utilizados para las evaluaciones no están del todo claros.

Tabla 3.4. Concentrado de los trabajos relacionados consultados. Continuación.

Nombre	Objetivo	Técnicas empleadas	Pruebas y resultados	Observaciones
Using Bayesian networks to improve knowledge assessment [Millán, 2013].	Examinar si las capacidades computarizadas del examen del PMatE pudieran mejorarse usando un ME Bayesiano (BSM).	<i>Generic Bayesian Student Model, Learning Objects.</i>	Se calificaron 1824 respuestas obtenidas de 152 exámenes con 12 preguntas cada uno. El BSM dio una estimación del nivel de conocimiento del estudiante en diferentes niveles de granularidad. El examen escrito tuvo mayor aceptación de los profesores.	El artículo no contiene un ejemplo completo del <i>Generic Bayesian Student Model</i> . Se necesita una investigación más exhaustiva para obtener el algoritmo o código del mismo.
Bayesian Student Modeling [Conati, 2010]	Describir técnicas y cuestiones que envuelve el construir un modelo probabilístico del alumno basado en RB y sus extensiones.	RB estáticas y dinámicas.	Por ser un repaso de las principales técnicas no se presentan las pruebas o resultados.	Se presentan las técnicas más utilizadas según la autora, sin embargo no se presenta los algoritmos sólo la teoría.
Using Bayesian Networks to Manage Uncertainty in Student Modeling [Conati, 2002]	Describir las RBs para el tipo de conocimiento <i>domain-general knowledge</i> , el cual constituye uno de los dos tipos de conocimiento que modelan las RBs en el modelo del estudiante del STI Andes.	Redes Bayesianas Estáticas con nodos tipo <i>Rule</i> y <i>Context-Rule</i> .	Evaluación de 173 estudiantes por cuatro semanas. Los resultados fueron comparados con los de estudiantes (grupo de 162 alumnos) que no usaron Andes en el curso.	Esta revisión sólo se extiende a uno de dos tipos de conocimiento codificado en RB por el sistema Andes. Se puede recrear un prototipo con esta estrategia pues se tienen claros los conceptos. Se utiliza RB estática con dos tipos de nodos y relación de independencia simple de padres a hijos.

Tabla 3.4. Concentrado de los trabajos relacionados consultados. Continuación.

Nombre	Objetivo	Técnicas empleadas	Pruebas y resultados	Observaciones
A Probabilistic Student Model for SQL-Tutor and Its Application To Problem Selection [Mayo, 2001]	Extender el STI SQL-Tutor a un enfoque probabilístico además de implementar la selección de problemas <i>inteligentemente</i> .	RB estáticas. Heurística para actualizar las probabilidades	El análisis muestra que el efecto de usar heurísticas en vez del teorema de Bayes, fue una reducción en la sensibilidad del ME, sin embargo los resultados sugieren que el enfoque va hacia la mejora.	Las RB son estáticas y se actualizan con una tabla que contiene las probabilidades en base a heurística. Se pretende la implementación en otro STI haciendo uso del teorema de Bayes para la actualización. Se presentan ejemplos claros para posible implementación pero no el modelo completo ya que el STI es muy amplio.

Este capítulo muestra el estado del arte concerniente a los ME basados en RB. Se emplearon trabajos realizados dentro de CENIDET y trabajos actuales externos con aporte fundamental para el desarrollo de la investigación. Para la evaluación de ME es necesario elegir tres modelos, el estado del arte de este capítulo da pie a entender los conocimientos que se requieren y prepara la adquisición de los modelos a utilizar para el desarrollo de la presente investigación.

Capítulo 4

Evaluación de Modelos de Estudiante

En este capítulo se describen a fondo tres Modelos de Estudiante (ME) que utilizan Redes Bayesianas (RB) como técnica básica de operación. Estos ME sirvieron como teoría básica para el desarrollo del caso de estudio presentado en el capítulo 5. Se presenta de cada modelo: conceptos, teorías, ventajas y desventajas. Al final del capítulo, se muestra la evaluación conjunta de los tres modelos.

4.1 Model Tracing (Modelo de Trazado)

Modelar al estudiante con este enfoque envuelve una enorme cantidad de incertidumbre. El modelo tiene que tratar de establecer el camino para la solución. Aún cuando el estudiante se salte pasos del proceso de solución es necesario seguir la trayectoria (o estrategia) que el alumno pudiera o está utilizando para resolver el problema. La solución que se ha dado es el uso de técnicas de Inteligencia Artificial como RB [Conati, 2002].

A continuación se enumeran características del Modelo de Trazado [Conati, 2002]:

- El Modelado de Trazado es usado para monitorear el progreso del alumno mientras resuelve un problema
- Este trazado se lleva a cabo en segundo plano, se igualan las acciones del estudiante a las del modelo
- De esta manera el tutor sabe dónde se encuentra el estudiante y le provee de pistas individualizadas para resolver el problema
- El tutor tiene la capacidad de asignar crédito por los pasos adivinados o por los errores cometidos durante el desarrollo

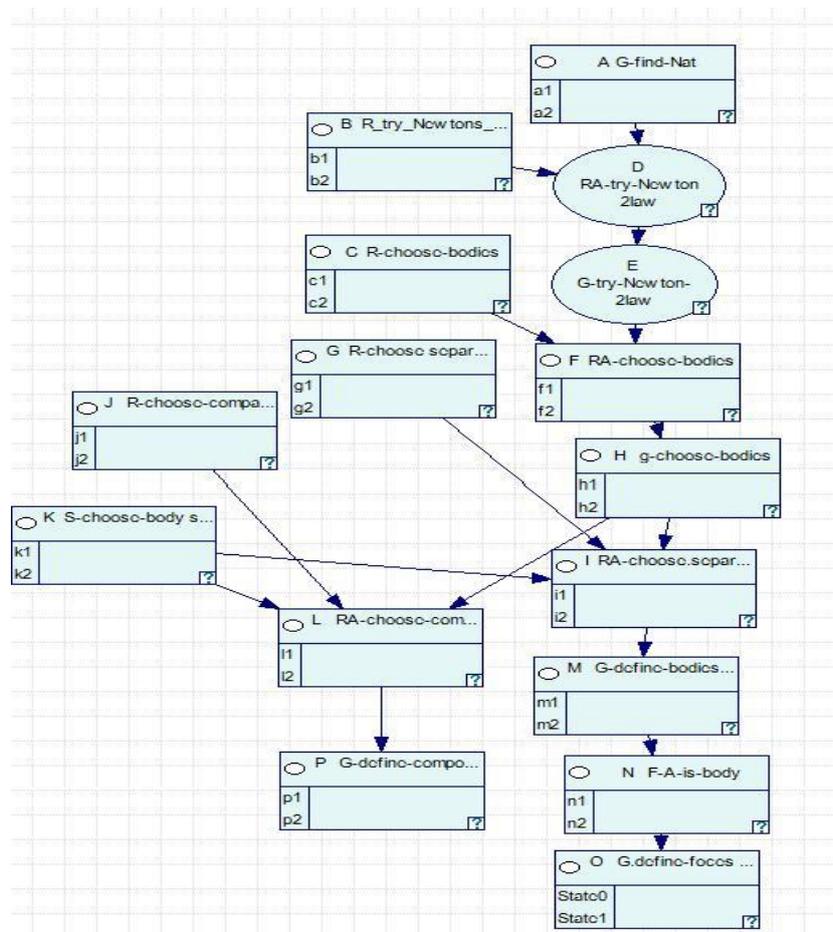


Figura 4.1. RB para modelado de estudiante en STI Andes [Conati, 1997].

Para ejemplificar gráficamente este modelo se muestra la Figura 4.1, que esquematiza un problema del Sistema Tutor Inteligente (STI) Andes [Conati, 1997], el cual ha sido reconocido por su alta eficacia. Andes es un STI que se utiliza para la enseñanza de la materia de Física, en donde es importante el desarrollo de cada ejercicio. El saber en qué paso del problema se encuentra el estudiante se soluciona con el uso de las RB. Por lo tanto se tiene una RB por cada problema en el STI y conforme el estudiante avanza de un problema a otro, el STI actualiza su conocimiento general y esa información es utilizada para inicializar la siguiente RB. La RB mostrada en la Figura 4.1 está construida con nodos discretos de dos valores para así seguir el camino que el estudiante sigue [Conati, 1997].

4.1.1 Manejo de errores

El STI Andes ha hecho uso de las RB para modelar al estudiante [Conati, 2002]. Además, las RB están presentes en Andes para solucionar diversas problemáticas, entre ellas el manejo de errores [Conati, 2002].

Como se mencionó, Andes permite que haya diferentes soluciones a un problema, por lo que el sistema (ME) necesita asignar crédito tanto a reconocer el plan de solución como la calificación del mismo. Es decir, si el alumno sigue un plan de desarrollo diferente, ¿cómo se debería de calificar?, Andes hace uso de RB para resolver este problema [Conati, 2002].

En Andes, la probabilidad para el manejo de *guessing* es llamada la probabilidad *leak* (β) y es la solución al problema de adivinar el procedimiento a la solución del problema. Ésta representa la probabilidad de que el alumno obtenga la respuesta *adivinando, preguntando a un amigo la respuesta o algún otro método que no se ha modelado por la red*. La probabilidad *leak* (β) puede ser ajustada para representar qué tan fácil es adivinar correctamente una respuesta o un paso del problema [Conati, 2002].

Por ejemplo, el hecho de que la aceleración de un objeto es constante es más fácil de adivinar que la dirección de la aceleración, ya que la aceleración es constante o no constante, y hay muchas posibilidades de expresar la dirección. Por lo tanto, las RB en Andes permiten expresar una hipótesis precisa acerca de adivinar, sin embargo es mencionado por el autor que se tiene que hacer más investigación de este tema [Conati, 2002].

El parámetro *noise* (α) representa el hecho de que si una *Regla de contexto* es aprendida correctamente y todas sus precondiciones también, un estudiante puede fallar al aplicarlas, un fenómeno llamado *slip*. Así que α debería ser vista como parte de la definición de aprendido (*Mastered*), porque ésta representa la frecuencia de los *slips* [Conati, 2002]. Ver la red propuesta por [Conati, 2002] para la resolución de esta problemática en la Figura 4.2.

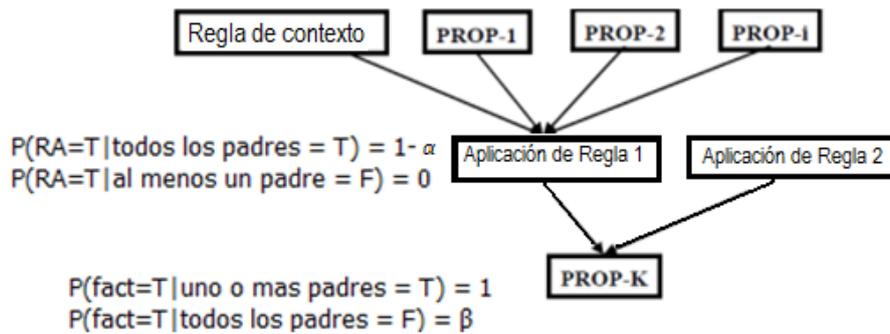


Figura 4.2. Propuesta de resolución de *guess & slips* por [Conati, 2002].

Una Tarea Específica en la red de Andes representa una o más soluciones a un problema en términos de cómo cada elemento de la solución se deriva de una regla en Física, y de que se solucionen los elementos marcados como precondiciones para la regla (*Aplicación de Regla*). Los elementos de la solución son hechos en Física o metas para resolver el problema (aquí llamados por el autor nodos *proposiciones* – PROP en la Figura 4.). Las reglas específicas de aplicación son representadas en la red como nodos *Aplicación de Regla* (Figura 4.2) [Conati, 2010].

4.1.2 Evaluación del modelo

A continuación, en la Tabla 4.1, se muestra un compendio de las ventajas y desventajas que se encontraron a este ME; éstas son observaciones teóricas.

Tabla 4.1. Ventajas y desventajas del Modelo de Trazado.

Aspectos positivos:	Aspectos negativos:
<ol style="list-style-type: none"> 1. Traza el conocimiento sin necesidad de introducir todos los pasos del proceso de solución. 2. Ideal para materias donde es necesario utilizar un procedimiento de solución. 3. Puede haber diferentes maneras de resolver un problema. 	<ol style="list-style-type: none"> 1. Es necesario contar con un experto en la materia a enseñar para construir cada una de las redes de cada uno de los problemas. 2. Redes Bayesianas muy extensas difíciles de reconfigurar. 3. Difícil de entender.

4.2 Adaptive Bayesian Tests (Pruebas Bayesianas Adaptables)

Este tipo de modelo fue propuesto como una herramienta que ofrece dos intenciones a la vez: 1) evaluación del conocimiento y 2) adaptación de la enseñanza de acuerdo al conocimiento.

El modelo propuesto por Millán [Millán, 2013] está compuesto por dos tipos de nodos (variables): *Conocimiento* y *Evidencias*.

- Las variables *Conocimiento* representan el conocimiento adquirido por el estudiante (ya sea declarativo o procedimental, pero también pueden ser habilidades) siendo éstas las variables de interés del modelo, ya que éstas se utilizan para adaptar la enseñanza a cada estudiante. Los valores no son evidenciados directamente [Millán, 2013].
- Las variables *Evidencia* (nodos evidencia) representan las acciones de los estudiantes y se puede evidenciarlos directamente, se consideran nodos binarios con valores cero (incorrecto) ó uno (correcto) [Millán, 2013].

4.2.1 Estimación de parámetros

Los parámetros necesarios para el ME propuesto por Millán [Millán, 2013] son los siguientes:

- Por cada concepto básico: la probabilidad a priori puede ser estimada por datos disponibles, si existieran, o si no se pueden establecer como uniformes.
- Por cada variable conocimiento: la probabilidad condicional de estas variables dependerá del conocimiento a evaluar dados los nodos: conceptos básicos.
- Por cada nodo evidencia: las probabilidades del nodo evidencia serán dadas por los conceptos envueltos (por ejemplo: pregunta de examen).

Por cada nodo evidencia, cuatro parámetros necesitan ser especificados por expertos [Millán, 2013]:

- g : factor adivinar, representa la probabilidad que el estudiante sin conocimiento adivine correctamente.
- s : factor resbalar, representa la probabilidad de que el estudiante con conocimiento falle a contestar correctamente.
- d : nivel de dificultad, estima la dificultad de la pregunta o tarea.
- α : discriminación, representa el grado por el cual la pregunta o tarea discrimina entre estudiantes.

En el caso de que el estudiante no tenga conocimiento (ninguno de los conceptos es conocido), la probabilidad se le asigna a g . Al contrario, si el estudiante tiene todos los conocimientos necesarios, la probabilidad es $1-s$. Las probabilidades faltantes son asignadas incrementado valores entre g y $1-s$. De esta manera, la probabilidad de respuestas correctas incrementa con el número de conceptos conocidos [Millán, 2013].

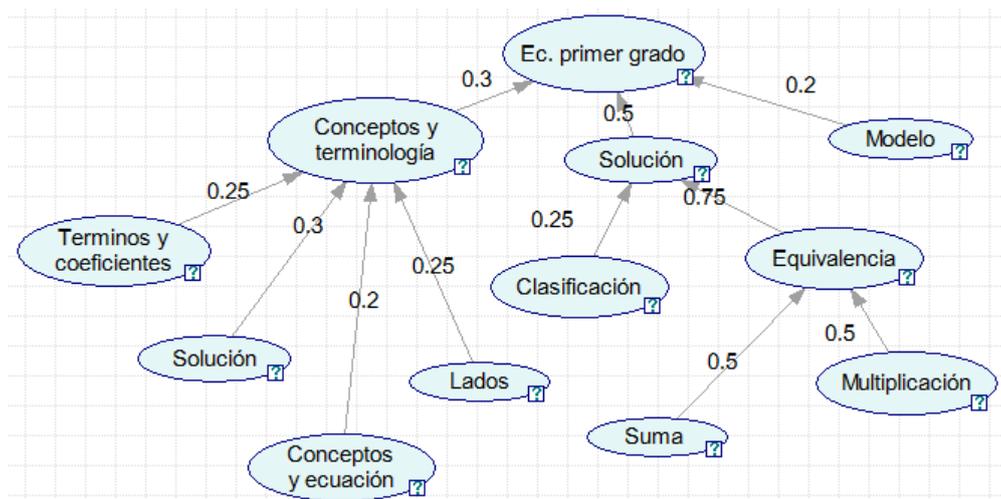


Figura 4.3. Ejemplo a la propuesta de *Adaptive Bayesian Test* [Millán, 2013].

Para mostrar la propuesta de Millán [Millán, 2013] se presenta la Figura 4.3, en donde se muestra que los nodos raíz representan preguntas a un examen (variables evidencia), los nodos intermedios y la hoja representan conocimiento (variables conocimiento). Según el autor [Millán, 2013], las probabilidades de los nodos raíz fueron establecidas siguiendo los parámetros $\{g, s, d, a\}$.

4.2.2 Evaluación del modelo

A continuación, en la Tabla 4.2, se muestra un compendio de las ventajas y desventajas del modelo; éstas son observaciones teóricas.

Tabla 4.2. Ventajas y desventajas del modelo Pruebas Bayesianas Adaptables.

Aspectos positivos:	Aspectos negativos:
<ol style="list-style-type: none"> 1. Este modelo permite determinar el conocimiento del estudiante basado en las repuestas a preguntas de examen y acorde con esto presentar nuevos conceptos. 2. El modelo es fácil de entender. 3. Toma en cuenta el factor adivinanza y el factor resbalar. 	<ol style="list-style-type: none"> 1. La asignación de los parámetros de nodos evidencia se establecen por cada nodo. 2. Dependiendo de la extensión del sistema, el modelo podría crecer a niveles difíciles de controlar.

4.3 Constraint-Based Model (Modelo Basado en Restricciones)

Un Sistema Tutor Inteligente (STI) difiere de otros sistemas educativos porque éste usa conocimiento para guiar el proceso pedagógico. Un STI intenta optimizar la transferencia del conocimiento del dominio al estudiante, controlando la introducción de nuevos problemas, conceptos e instrucciones/retroalimentación. Al centro de este proceso está el ME, el cual provee información acerca de lo que el estudiante sabe [Martin, 2001].

El ME representa las creencias del estudiante, en términos de lo que ellos saben y, algunas veces, lo que ellos creen que saben. Mucha de la investigación del modelado de estudiante se ha centrado en conocimiento, sin embargo, otras consideraciones como motivación y metas, pueden también ser incluidas. Hay muchos diferentes enfoques para modelar al estudiante: la forma en que el modelo es construido, el contenido del modelo y cómo éste es usado para guiar el proceso del tutor [Mitrovic, 2007].

Constraint-Based Modeling (CBM) representa ambos: dominio y el conocimiento del estudiante, en forma de restricciones. Donde las restricciones representan los principios básicos fundamentales del dominio. Una restricción es caracterizada por la cláusula aplicabilidad y la cláusula cumplimiento. La cláusula aplicabilidad es una condición que debe ser cierta antes de que la restricción sea cumplida en la solución presente. Una vez que la cláusula aplicabilidad ha sido satisfecha, la cláusula cumplimiento debe ser verdadera para que la solución sea correcta [Martin, 2001].

Las restricciones que componen el conocimiento del dominio pueden ser un conjunto de reglas parciales, donde cada restricción es una regla de la forma: "Si (condición de aplicabilidad) es verdadera, entonces (condición de cumplimiento) debe ser también verdadera" [Berkeley, 2013]. Alternativamente, podrían ser considerados como una biblioteca de errores implícitos. Un error implícito contiene una lista de errores que han sido empíricamente juntados por las soluciones del estudiante y un medio para determinar qué error contiene la respuesta actual [Martin, 2001].

En CBM, cada restricción representa un error en la forma "Cuando (cláusula de cumplimiento) falla sostener el valor verdadero para (la cláusula aplicabilidad), el estudiante ha introducido un error" [Martin, 2001].

El ME es un conjunto de restricciones que han sido violadas, lo cual representa los conceptos del dominio que el estudiante no ha aprendido. También se menciona en la literatura que, el pensar que las restricciones no violadas representen que el estudiante sabe, porque se pudiera haber satisfecho restricciones sin darse cuenta, pudiera o no ser que el estudiante no hubiese entendido el concepto. Sin embargo, una restricción violada siempre representa una creencia inconsistente o un descuido [Mitrovic, 2007].

4.3.1 Predicción del desempeño del estudiante con restricciones únicas

Se usa la RB mostrada en la Figura 4.4 para representar el desempeño de un estudiante dado un problema P con una restricción única C . $Dominado_c$ es la variable de dominio del ME. Ambas, $RelevantIS_{c,p}$ y $RelevantSS_{c,p}$ son variables con valores si/no. $RelevantIS_{c,p}$ es Sí si la

restricción C es aplicable a la solución ideal del problema P . Ya que ésta puede ser determinada por una base de datos de problemas, $RelevanteIS_{c,p}$ es siempre conocida con certeza. $RelevanteSS_{c,p}$ es Sí si la restricción C es aplicable a la solución que el estudiante le da al problema P . Ésta es una variable con incertidumbre porque el estudiante puede o no introducir una solución incorrecta no aplicable a C , o él/ella puede introducir una solución alterna correcta que es también no aplicable a la restricción en cuestión. $Ejecución_{c,p}$ es un nodo con tres valores y toma *Satisfecho*, *Violado* o *Irrelevante* como valores. Los arcos indican que la aplicabilidad de la restricción de la solución del estudiante, $RelevanteSS_{c,p}$, depende de la aplicabilidad de la restricción de la solución ideal, $RelevanteIS_{c,p}$. El desempeño del estudiante en su siguiente intento a la restricción, $Ejecución_{c,p}$ es dependiente de sí o no el estudiante a dominado la restricción C y la aplicabilidad de C a la solución del problema [Mayo, 2001].

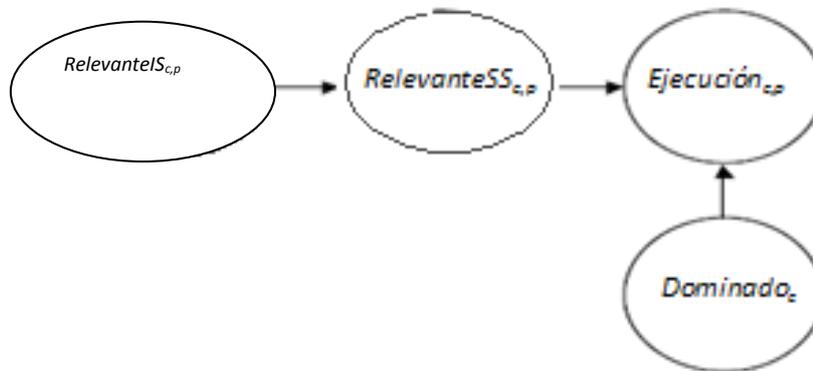


Figura 4.4. Red Bayesiana simple que muestra el desempeño de un estudiante con una sola restricción [Mayo, 2001].

Mayo [Mayo, 2001] justifica el uso de CBM en su trabajo con cinco pasos que envuelven la metodología que él utiliza. Los cinco pasos son:

1. Adquisición de datos: esto requiere de un sistema parcialmente completo sin ME para recolectar datos de los estudiantes. Este paso provee la fuente de datos para el siguiente paso.
2. Aprendizaje Bayesiano: obtener una red que será el ME. Este paso se describe más extensamente en la siguiente sección.
3. Construcción Estratégica con decisión teórica: este paso se refiere a definir los problemas de decisión a los cuales se enfrentará el STI y así poderlos ligar al ME.
4. *Machine Learning*: una vez que un nuevo estudiante esté usando el sistema y haya datos siendo recolectados, este nuevo conjunto de datos puede reemplazar al anterior.

5. Evaluación a alta escala: el propósito es esencialmente probar el sistema completo en el salón de clases, para asegurarse que los esfuerzos computacionales hechos en los pasos anteriores sean los esperados. El producto final debe mostrar ser más eficiente que el ME inicializado con valores por omisión.

4.3.2 Generación del Modelo

Mayo [Mayo, 2001] considera este paso como la inducción del modelo, es decir, la construcción de una RB para predecir el desempeño del estudiante dado el estudiante actual y una acción seleccionada por el tutor. Los datos recolectados en el paso uno sirven para el aprendizaje Bayesiano. En este paso se puede introducir conocimiento de expertos opcionalmente. Esto se puede hacer añadiendo dependencias y probabilidades entre las variables, o después del aprendizaje, cuando se afina el modelo.

Mayo [Mayo, 2001] hace uso del algoritmo propuesto por Cheng [Cheng, 1997] el cual describe un algoritmo de aprendizaje Bayesiano capaz de ser inicializado desde especificación parcial. Sin embargo, las variables sólo pueden representar observaciones.

4.3.3 Evaluación del Modelo

A continuación, en la Tabla 4.3, se muestra un compendio de las ventajas y desventajas del modelo CBM; éstas son observaciones teóricas.

Como puede observarse, los aspectos positivos de este modelo el uso de los datos como herramienta para obtener las variables que se buscan para el modelo.

Un aspecto negativo importante es que no se utilizan los errores cometidos por los alumnos.

Tabla 4.3. Ventajas y desventajas del Modelo de CBM

Aspectos positivos:	Aspectos negativos:
1. Este modelo puede ser inducido con aprendizaje Bayesiano, si es que existieran datos.	1. No toma en cuenta el factor adivinanza y el factor resbalar.
2. El modelo es fácil de entender.	2. Se tiene que considerar todo el dominio para cada problema.

4.4 Análisis de la evaluación de los modelos mostrados en el capítulo

En la Tabla 4.4 se puede apreciar el análisis obtenido por la evaluación teórica de los modelos del capítulo.

Tabla 4.4. Análisis de los ME presentados en el presente capítulo.

Modelo	Facilidad de entendimiento	Flexibilidad	Costo creación	Uso de datos para aprendizaje	Uso de errores
Model Tracing	Bajo	Bajo, cada problema necesita una red específica.	Alto, se requiere un experto en el dominio para crear las redes de cada problema.	No	sí
Adaptive Bayesian Tests	Alto	Alto, se puede usar para cualquier dominio.	Bajo	Probablemente	sí
Constraint Based Model	Moderado	Alto	Moderado, se requiere un experto para verificar las dependencias en la RB.	sí	sí

4.5 Discusión

El presente capítulo muestra tres metodologías para modelar a un estudiante, estas metodologías deben ser basadas en RB y ser citadas constantemente en la literatura actual.

Se presentó en este capítulo las características principales, ventajas y desventajas por modelo, así como algunas técnicas utilizadas por los autores para la creación de dichos modelos.

Se pretende tener el conocimiento necesario para desarrollar un caso de estudio a partir de este análisis.

Al final se presenta un análisis de los tres modelos presentados en el capítulo. El análisis, hasta este momento, se considera teórico, sin embargo en el siguiente capítulo se presentará un análisis con los experimentos realizados.

Capítulo 5

Experimentación y resultados

Los Modelos de Estudiante (ME) son parte principal de los Sistemas Tutores Inteligentes (STI) dado que les proporciona la parte adaptativa de la interacción de los estudiantes con el sistema. Como parte de este trabajo de investigación se desarrolla un caso de estudio en el cual se pretende introducir un ME al sistema tutor Alen3D. Para esto, se cuenta con información recabada por el sistema en producción y se implementa el conocimiento teórico de los ME descritos en el capítulo anterior.

Como parte del objetivo de esta investigación, se hace la implementación y evaluación de técnicas de Redes Bayesianas (RB) a los ME obtenidos del caso de estudio. Esto con la finalidad de encontrar posibles mejoras a los modelos.

Este capítulo contiene los siguientes puntos: 1) descripción del caso de estudio realizado con los datos del Sistema Tutor Alen3D, 2) descripción del diseño, desarrollo y evaluación de dos ME para el Sistema Alen3D, 3) implementación y evaluación de técnicas de RB a los ME resultantes del caso de estudio.

Al final se presenta el análisis a los ME y técnicas implementadas en este trabajo de investigación.

5.1 Caso de estudio, introducción y objetivo

En las últimas décadas, los STI han evolucionado y probado ser una aplicación viable de las técnicas de inteligencia artificial. Una parte de la inteligencia de estos sistemas reside en saber el conocimiento de los estudiantes y, consecuentemente, responder a las necesidades individuales de dichos estudiantes. Este proceso de adaptación es basado en el ME el cual es una estructura donde se almacena conocimiento del estudiante tal como errores, ideas equivocadas, rutas y también puede almacenar información acerca de personalidad, emociones y motivación [Hernández, 2016].

El caso de estudio está basado en datos del sistema tutor Alen3D el cual fue desarrollado por el Instituto de Investigaciones Eléctricas. Alen3D utiliza realidad virtual para entrenar a los eléctricos de mantenimiento de la Comisión Federal de Electricidad. Este sistema ha sido usado por varios años como herramienta complementaria para certificar eléctricos en procedimientos de mantenimiento en líneas eléctricas de media tensión. El objetivo del caso de estudio es construir un ME para medir el nivel de capacitación de los técnicos después de interactuar con el sistema.

Las RB han sido utilizadas en los STI para modelar el conocimiento del estudiante, predecir su comportamiento y para tomar decisiones tutoriales debido a su fuerte mecanismo para manejar la incertidumbre [Hernández, 2016]. En esta tesis se requiere evaluar los ME basados en RB ya que se utilizan para relatar probabilísticamente el comportamiento y acciones del estudiante y así medir su conocimiento; todo esto a partir de los datos existentes en la base de datos del sistema Alen3D.

Objetivo del caso de estudio

El objetivo es proponer un ME con los datos existentes para dar un veredicto de la utilización del sistema Alen3D por cada operador/usuario.

Para cumplir con dicho objetivo se proponen dos estrategias: la primera es la obtención del ME a partir de los datos y la segunda es la construcción de un ME a partir de conocimiento de expertos.

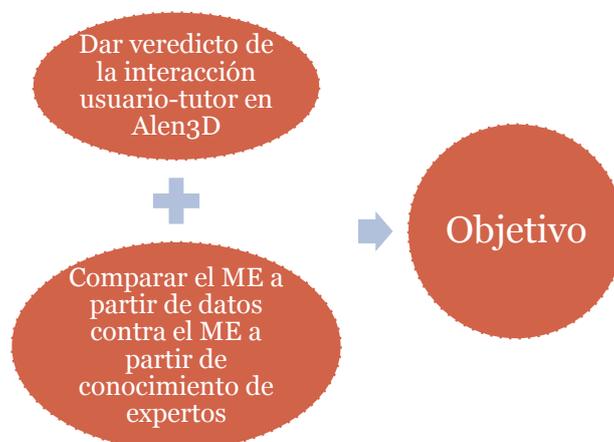


Figura 5.1. Objetivo del Caso de Estudio.

Se pretende comparar los dos modelos para verificar su factibilidad. El objetivo de este experimento se muestra en la Figura 5.1.

5.2 Descripción del diseño de los ME para el caso de estudio

Para el diseño de los ME del caso de estudio se utilizó el conocimiento adquirido en la etapa tres de la metodología de solución del problema de tesis (capítulo 4 secciones 1, 2 y 3). Las metodologías utilizadas para el diseño de los ME son:

- *Model Tracing*. Esta metodología de modelado de estudiantes descrita en [Conati, 2002] utiliza el concepto de *Guess & Slips*, el cual hace uso de errores cometidos por el estudiante. En este caso de estudio se utilizan los errores de los usuarios durante su interacción con el sistema Alen3D. Los errores son utilizados en ambos ME aquí propuestos.
- *Adaptive Bayesian Tests*. Esta metodología de modelado de estudiantes fue propuesta en [Millán, 2013]. Dicha metodología es utilizada para evaluar el conocimiento del estudiante después de su interacción con el STI. Esta metodología se utiliza para el *ME a partir de conocimiento de los expertos* que se propone para el caso de estudio.
- *Constraint-Based Model (CBM)*. Esta metodología es aplicada en [Mayo, 2001], siendo lo interesante de ella que se pueden aprovechar los datos para generar el ME. En este trabajo se utiliza la técnica de aprendizaje de RB en el *ME a partir de datos*.

Como ya se mencionó, para el caso de estudio se diseñaron dos ME. El *ME a partir de datos* se diseñó para ser aprendido a partir de datos existentes, del sistema Alen3D. Para ésto se utilizó el software GeNie [Pittsburgh, 2016].

El segundo ME (ME a partir de conocimiento de expertos) tuvo el propósito de comparar los resultados arrojados por el primer ME.

El uso del conocimiento adquirido a través de la revisión de los ME mas citados en la literatura (capítulo anterior) fué fundamental para el desarrollo de los modelos del caso de estudio.

En la Figura 5.2 se muestra cómo se conjuntaron los conocimientos adquiridos para la construcción del ME a partir de conocimiento de expertos.

En [Mayo, 2001] se utiliza el aprendizaje Bayesiano para modelar en base a restricciones. En el caso de estudio se contaba con errores, así que se toma la técnica de aprendizaje Bayesiano para modelar el conocimiento del estudiante.

En este caso la técnica de modelado es la misma, así que puede decir que no se alteró el modelo ni los atributos. Para mejor visualización, ver la Tabla 5.1.

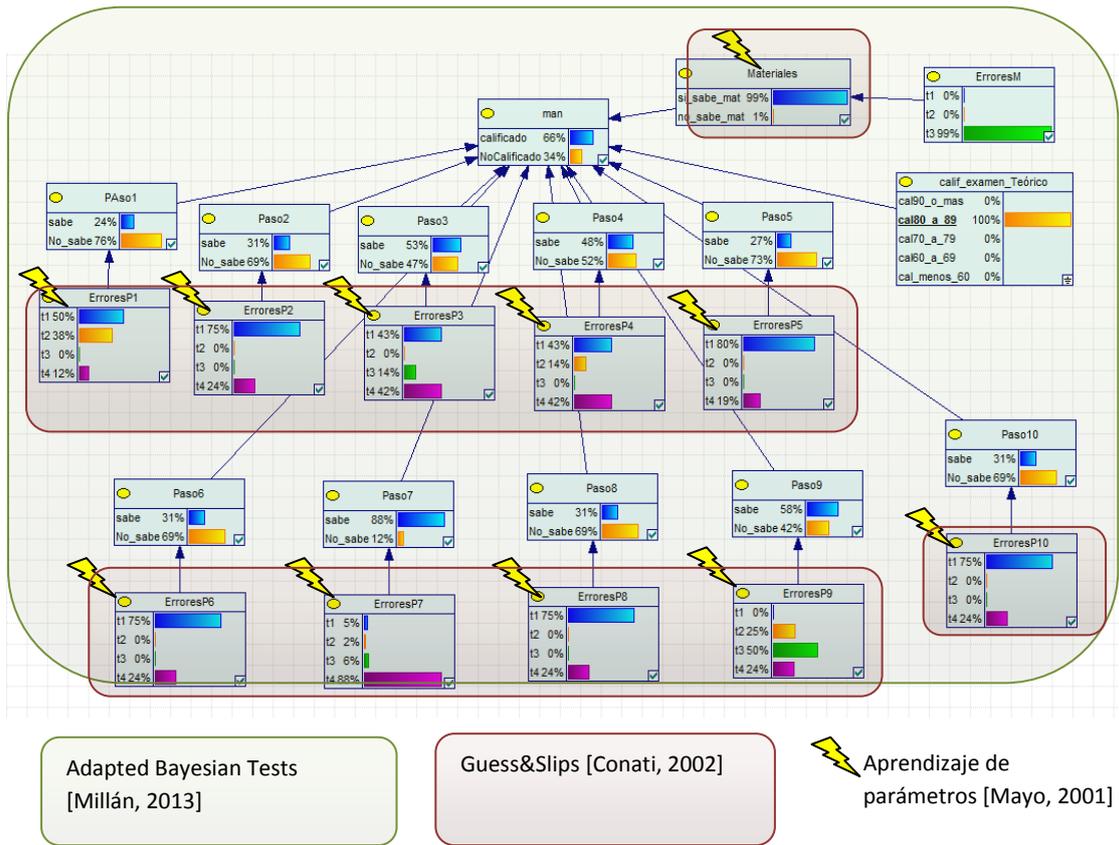


Figura 5.2. ME a partir de conocimiento de expertos y metodologías utilizadas para su desarrollo.

Tabla 5.1. Correspondencia entre Constraint-Based Model y el Modelo a partir de datos.

Modelo	Técnica	Datos	Salida	Modelo
Constraint-Based Model [Mayo, 2001]	Aprendizaje Bayesiano	Restricciones	Análisis de resultados.	
Modelo a partir de datos	Aprendizaje Bayesiano	Errores y calificación teórica.	Probabilidad de estar calificado después de la interacción con el tutor.	

A continuación se describe la información utilizada para la construcción de los ME a partir de datos y por conocimiento de expertos. Como se mencionó en la introducción de este capítulo, el historial utilizado para el caso de estudio es el perteneciente a la interacción de los usuarios del sistema Alen3D, que se ha recolectado a través de su funcionamiento.

Los datos

La base de datos utilizada para el caso de estudio contiene la interacción de los eléctricos en entrenamiento con el sistema Alen3D. Las estructuras de los datos que se utilizaron se muestran en las Tablas 5.2, 5.3 y 5.4.

Tabla 5.2. Tabla del sistema AlenED que contiene los errores en la evaluación de la selección de materiales.

id_evaluacio	id_usr	cve_man	hora	id_error_sel
---------------------	---------------	----------------	-------------	---------------------

Tabla 5.3. Tabla del sistema Alen3D la cual contiene los errores de los usuarios de la evaluación de cada maniobra.

Id_usr	cve_man	hora	id_evaluacio	num_paso	id_error_paso	subpaso
---------------	----------------	-------------	---------------------	-----------------	----------------------	----------------

Tabla 5.4. Tabla del sistema Alen3D que contiene los resultados de la calificación del examen teórico por cada usuario.

id_examen	id_usr	id_evaluacio	cve_man	hora_i	hora_f	calificación
------------------	---------------	---------------------	----------------	---------------	---------------	---------------------

Entre los datos disponibles, se tiene una lista de los errores cometidos por cada usuario. Se dispone de dos grupos: errores en el paso y errores en la selección de materiales. Los registros incluyen el tipo de cada uno de los errores. Ver en las Tablas 5.5 y 5.6 donde se describen los tipos de errores en la selección de materiales y en pasos.

Al analizar los datos que genera el sistema se notó que se disponía de los errores cometidos como evidencia de aprovechamiento del sistema, además de la calificación del examen teórico, dicha calificación se puede ver en la Tabla 5.4.

Tabla 5.5. Tipos de errores en la evaluación de pasos y su descripción.

id_error_paso	descripción
1	Clic sobre un elemento incorrecto
2	Selección de un elemento incorrecto
3	Clic sobre un elemento cuando se pidió algo de los menús
4	Selección de material cuando se necesitaba interacción con la escena

Tabla 5.6. Tipos de errores en la evaluación de selección de materiales y su descripción.

id_error	error_sel_mat
1	El elemento no se utiliza en la maniobra
2	La cantidad que se introdujo no es la correcta
3	El elemento ha sido seleccionado anteriormente

También se notó, gracias a la interacción con el sistema, que a los errores se les puede asignar una ponderación. La ponderación de los errores en la selección de materiales se describe en la Tabla 5.7.

Tabla 5.7. Ponderación establecida para los errores en selección de material.

Tipo de error	Ponderación
1	El eléctrico en entrenamiento está tratando de adivinar dado que seleccionó una herramienta que no es requerida en la maniobra
2	El eléctrico en entrenamiento tiene conocimiento incompleto dado que seleccionó la herramienta correcta pero cantidad incorrecta
3	El eléctrico en entrenamiento estaba distraído dado que la herramienta ha sido seleccionada anteriormente.

La ponderación de los errores en los pasos de la maniobra se describe en la Tabla 5.8.

Tabla 5.8. Ponderación establecida para los errores en pasos.

Tipo de error	Ponderación
1	El eléctrico en entrenamiento está tratando de adivinar dado que ha dado clic a un elemento erróneo dentro del ambiente virtual.
2	El eléctrico en entrenamiento está tratando de adivinar dado que ha seleccionado una herramienta que no se requiere en la maniobra
3	El error tipo 3 se considera moderado pues el usuario pudiera estar confundido o poco familiarizado con la interfaz del sistema
4	El error tipo 4 se considera no severo, el usuario tiene conocimiento pero pudiera estar distraído

Los errores en los pasos son obtenidos por *maniobra*. Alen3D cuenta con 43 maniobras las cuales son enseñadas en diversos cursos dependiendo las necesidades del grupo en capacitación.

Se cuenta con la base de datos de la división sur y ésta cuenta con 1400 usuarios. Para este experimento se tomaron: los errores en pasos de la maniobra uno, los errores en la selección de materiales maniobra uno y la evaluación teórica de la maniobra uno, de un total de 175 usuarios. La maniobra uno tiene 10 pasos.

Los datos fueron organizados, procesados y concentrados, para la generación de un Modelo Bayesiano, de la forma que se especifica en la Tabla 5.9.

Tabla 5.9. Descripción de las características utilizadas para el aprendizaje de modelo Bayesiano

Atributo	Descripción
Clase	Variable obtenida por método de agrupamiento utilizando el algoritmo k-means
califTeórica	Es el resultado de la evaluación teórica, que se obtiene de la Tabla 5.4
EPT1	Número total de errores de tipo uno en todos los pasos de la maniobra
EPT2	Número total de errores de tipo dos en todos los pasos de la maniobra
EPT3	Número total de errores de tipo tres en todos los pasos de la maniobra

Tabla 5.9. Descripción de las características utilizadas para el aprendizaje de modelo Bayesiano. Continuación.

Atributo	Descripción
EPT4	Número total de errores de tipo cuatro en todos los pasos de la maniobra
EMT1	Número total de errores de tipo uno en la selección de materiales de la maniobra
EMT2	Número total de errores de tipo dos en la selección de materiales de la maniobra
EMT3	Número total de errores de tipo tres en la selección de materiales de la maniobra

La variable Clase se obtuvo utilizando el método de agrupamiento con el algoritmo k-means de la aplicación Weka [Waicato, 2016]. Para esta agrupación se utilizó la calificación de la evaluación teórica y el número de total de errores (pasos y materiales) de cada usuario.

Debido a que los datos utilizados son continuos (excepto el atributo clase) se necesitó un pre procesamiento de datos para discretizarlos. La discretización de los atributos es mostrada en las Tablas 5.10 y 5.11.

Tabla 5.10. Valores discretos del atributo *califTeorica*.

Valor	Descripción
A	Calificación de 90 a 100 obtenida por el eléctrico en entrenamiento.
B	Calificación de 80 a 89 obtenida por el eléctrico en entrenamiento.
C	Calificación de 70 a 79 obtenida por el eléctrico en entrenamiento.
D	Calificación de 60 a 69 obtenida por el eléctrico en entrenamiento.
E	Calificación de menos de 60 obtenida por el eléctrico en entrenamiento.

Los datos con los que se cuenta por parte del sistema Alen3D muestran el número de errores por cada eléctrico por cada paso y se dividen por tipo de error. El número de errores puede variar por lo que es necesario conseguir un valor discreto, para esto se obtuvo la frecuencia del tipo de error por cada eléctrico en entrenamiento en cada paso de la evaluación, las etiquetas y su descripción se pueden observar en la Tabla 5.11.

Tabla 5.11. Etiquetas y descripción de la discretización de los datos.

Etiqueta	Descripción
frec_0_10	Porcentaje de error entre 0 y 10
frec_11_20	Porcentaje de error entre 11 y 20
frec_21_30	Porcentaje de error entre 21 y 30
frec_31_40	Porcentaje de error entre 31 y 40
frec_41_50	Porcentaje de error entre 41 y 50
frec_51_60	Porcentaje de error entre 51 y 60
frec_61_70	Porcentaje de error entre 61 y 70
frec_71_80	Porcentaje de error entre 71 y 80
frec_81_90	Porcentaje de error entre 81 y 90
frec_91_100	Porcentaje de error entre 91 y 100

Al obtener los valores discretos de todos los datos de las variables mostradas en Tabla 5.9 se procedió a introducirlos al sistema GeNIe [Pittsburgh, 2016]. Los resultados obtenidos se muestran en la siguiente sección.

5.3 Construcción de los ME para el caso de estudio

En esta sección se describe el diseño, desarrollo y evaluación de los ME resultantes del caso de estudio. Los ME son llamados: modelo a partir de datos y modelo a partir de conocimiento de expertos.

5.3.1 Modelo a partir de datos

Para la construcción del ME a partir de datos se probó con las diferentes alternativas disponibles en GeNIe. Esas alternativas son los algoritmos: *Bayesian search*, *PC*, *essential graph search*, *greedy thick thinning*, *augmented naive Bayes*, *Tree Augmented Naive Bayes* y *naive Bayes* (ver los resultados de implementación en Apendice B). Sin embargo, el único que encontró las creencias y dependencias que se estaban buscando fue el algoritmo *Tree Augmented Naive Bayes* (TAN).

El procedimiento del algoritmo TAN sigue la idea general de Chow&Liu [Chow, 1968] excepto que en vez de usar información mutua entre dos atributos, éste usa información condicional mutua entre atributos y la variable clase que se ha seleccionado.

La red resultante utilizando el algoritmo TAN del sistema GeNIe es la presentada en la Figura 5.3.

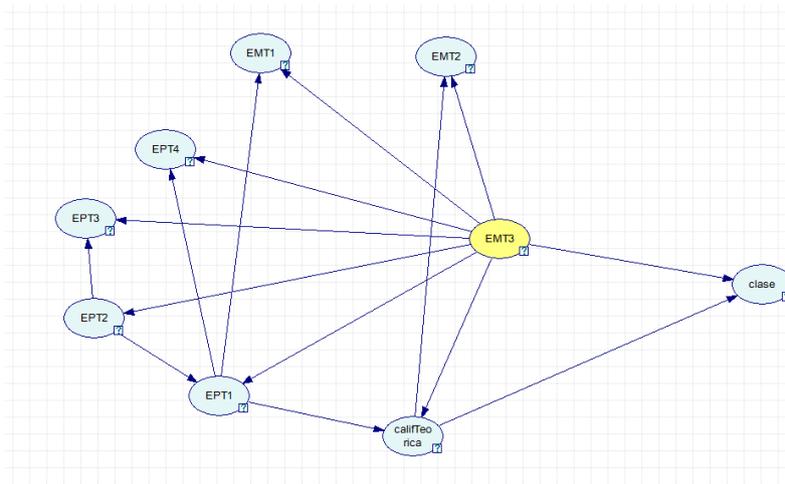


Figura 5.3. RB aprendida de los datos por el algoritmo TAN. Esta red representa el ME.

Aquí se aprecia que el nodo *EMT3* (errores en la selección de materiales) es el nodo que se seleccionó como clase. Esto fue decidido por la siguiente razón: si el eléctrico en entrenamiento comete errores de *tipo 3* en la selección de material, se considera que se sabe los materiales de la maniobra y esto resultará en que al evaluar los pasos de la maniobra no cometerá errores de mala selección de herramientas por lo que no cometerá errores de tipo *EPT1* (que serían los más severos de acuerdo a la Tabla 5.8. Entonces, estará capacitado dependiendo de la frecuencia de errores en el nodo *EMT3*.

Evaluación del ME a partir de datos

Para la evaluación del ME a partir de datos se enlistan las ventajas y desventajas del modelo (ver Tabla 5.12). De dicha evaluación se puede afirmar que el ME a partir de datos provee una fuerte ventaja: la eliminación de un experto en redes Bayesianas, debido a que las relaciones de dependencia son construidas por la aplicación de aprendizaje Bayesiano (en este caso GeNIe). Además se pudo hacer uso de los datos disponibles, lo cual representa un ahorro de tiempo pues no se necesitó recabar datos, es decir se pudo omitir la tarea de modificación del sistema y ejecución extra del sistema para obtener dichos datos.

Tabla 5.12. Ventajas y desventajas del ME a partir de datos.

Ventajas	Desventajas
1. Para su construcción se usaron datos existentes.	1. Se utilizó mucho tiempo en el pre procesamiento de los datos.
2. Las relaciones de dependencia son encontradas por la herramienta / algoritmo sin necesidad de un experto en ME y/o RB.	2. No hay un punto de comparación para saber si los resultados arrojados por el modelo son congruentes.
	3. El análisis de veracidad corre a cargo de un experto del dominio.

5.3.2 Modelo a partir de conocimiento de expertos

Como parte del caso de estudio, había la necesidad de comparar el ME a partir de datos. Para esto, se construyó un ME a partir del conocimiento de expertos. El ME basado en conocimiento de expertos se muestra en la Figura 5.4.

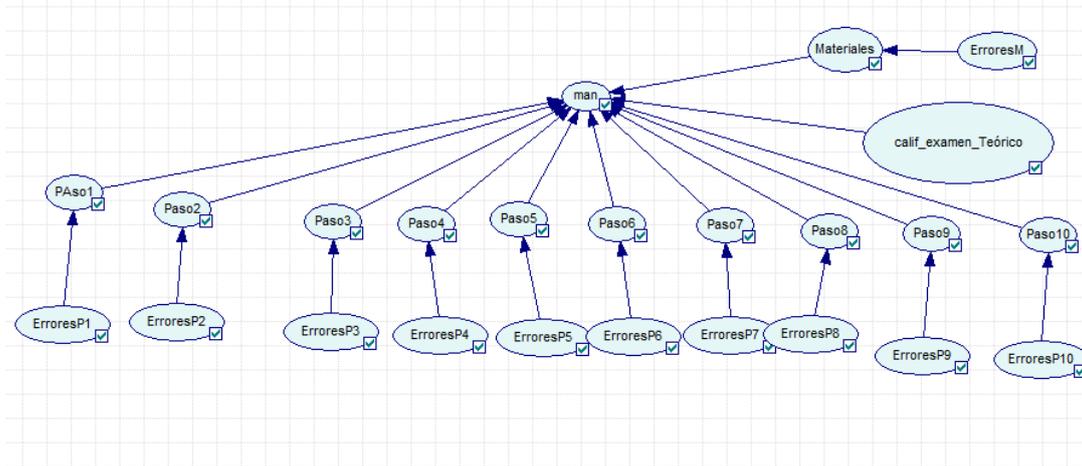


Figura 5.4. ME a partir de conocimiento de expertos

En el ME a partir de conocimiento de expertos se hace uso de la ponderación de los errores que se describió previamente en las Tablas 5.7 y 5.8. La ponderación sirvió para especificar las probabilidades condicionales de los nodos:

- Paso1, Paso2, Paso3, Paso4, Paso5, Paso6, Paso7, Paso8, Paso9, Paso10
- Materiales

El ME a partir de conocimiento de expertos es basado, principalmente, en la ponderación de los errores. Es decir, se especifica las probabilidades condicionales dada la gravedad del error en los nodos: Paso1, Paso2, Paso3, Paso4, Paso5, Paso6, Paso7, Paso8, Paso9, Paso10 y Materiales. Por ejemplo, las probabilidades condicionales del Paso1 son: “probabilidad de que sepa el paso uno, dada la probabilidad de errores tipo1 igual a 10 %”, “probabilidad de no saber el paso uno dada la probabilidad de errores tipo1 igual a 90 %”. Ver Tabla 5.13.

Tabla 5.13. CPT (Conditional Probability Table) de los nodos Paso1, Paso2, Paso3, Paso4, Paso5, Paso6, Paso7, Paso8, Paso9, Paso10.

ErroresP1	t1	t2	t3	t4
sabe	0.10008...	0.20000...	0.60000...	0.94999...
No_sabe	0.89991...	0.79999...	0.39999...	0.05000...

Un ejemplo de los valores de los nodos ErroresP1, ErroresP2, ErroresP3, ErroresP4, ErroresP5, ErroresP6, ErroresP7, ErroresP8, ErroresP9, y ErroresP10 se muestra en la Figura 5.5. El nodo tiene cuatro valores que representan la probabilidad de errores de tipo uno, dos, tres y cuatro.

También, se muestra que en la inicialización del nodo se da un porcentaje mayor al tipo de error cuatro, ya que si no existen errores en el paso no se influenciará negativamente al nodo padre *Paso_i*.

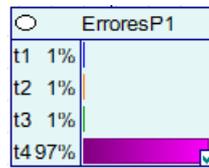


Figura 5.5. Inicialización de nodos *ErroresP_i*, donde se considera los cuatro tipos de errores y se inicializa el error tipo cuatro con porcentaje mayor.

La probabilidad de cada valor del nodo *ErroresP_i*, se obtienen de los datos usando la frecuencia relativa de los errores de cada paso. El aprendizaje de los atributos de cada nodo *ErroresP_i* es por usuario del sistema y también por número de maniobra.

Los nodos *Materiales* y *ErroresM* tienen un diseño similar a los nodos *Paso_i* y *ErroresP_i*. Ver los valores del nodo *Materiales* y los valores de nodo *ErroresM* en la Figura 5.6.

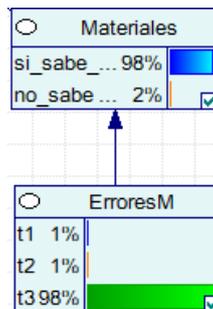


Figura 5.6. Dependencia de nodo *Materiales* dado nodo *ErroresM*.

Los valores del nodo *calif_examen_Teórico* son los mostrados en la Figura 5.7. Este nodo es el único nodo del modelo que será evidenciado de acuerdo a la calificación obtenida en el examen teórico.

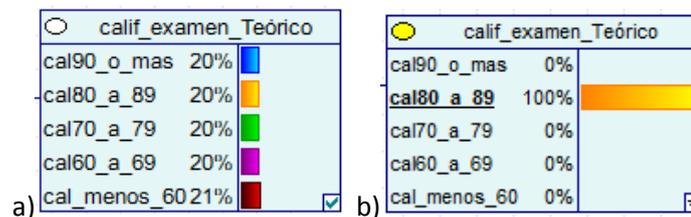


Figura 5.7. a) Inicialización del nodo *calif_examen_Teórico* y b) Evidencia en el nodo *calif_examen_Teórico*.

Para el veredicto final de la interacción del usuario con el sistema se tiene el nodo *man*. Este nodo tiene valores: *calificado* y *noCalificado*. Las probabilidades condicionales de este nodo se extrajeron del conocimiento del experto y se muestran en la Figura 5.8. Nótese que, de acuerdo con el experto, el peso de los nodos (importancia mayor a menor) es:

- *Paso_i*
- *Materiales*
- *calif_examen_Teórico*

Con la clasificación anterior se asignaron las probabilidades condicionales al nodo *man* y sus valores de *calificado* y *NoCalificado*; por cada paso fallido se hacen decrementos de cinco puntos porcentuales a la probabilidad condicional, de igual manera se implementó en el nodo *materiales*. La evaluación se implementó así: se dividió la calificación en rangos de 10 hasta alcanzar 100 para la calificación perfecta, por cada rango perdido de calificación se hacen decrementos de 5 puntos porcentuales en la probabilidad condicional.

Ejemplo: si sabe *paso1*, *paso 2*, *paso 3*, *paso 4*, *paso 8* y *materiales*; y no sabe pasos 5, 6, 7, 9 y 10 entonces su probabilidad es de menos 25 puntos de estar calificado. Si su calificación es de 88 entonces su porcentaje se reduce en 5 puntos porcentuales. La probabilidad condicional de estar calificado es de 70%.

	sabe		No_sabe		sabe		No_sabe		sabe		No_sabe	
Paso3												
Materiales												
calif_examen...												
Paso2												
PAso1												
Paso4												
Paso5												
Paso6												
Paso7												
Paso10												
Paso9												
Paso8												
calificado	1	0.95	0.95	0.9	0.95	0.9	0.9	0.85	0.95			
NoCalificado	0	0.05	0.05	0.1	0.05	0.1	0.1	0.15	0.05			

Figura 5.8. CPT parcial del nodo *man*.

Para el aprendizaje de los parámetros de los nodos *ErroresPi* y *ErroresM* se mantienen las probabilidades de los nodos *Pasoi*, *Materiales*, *man* y *Calif_examen_teorico*. Ver Figura 5.9 en donde se muestra esta configuración en el sistema GeNIe para el aprendizaje de parámetros.

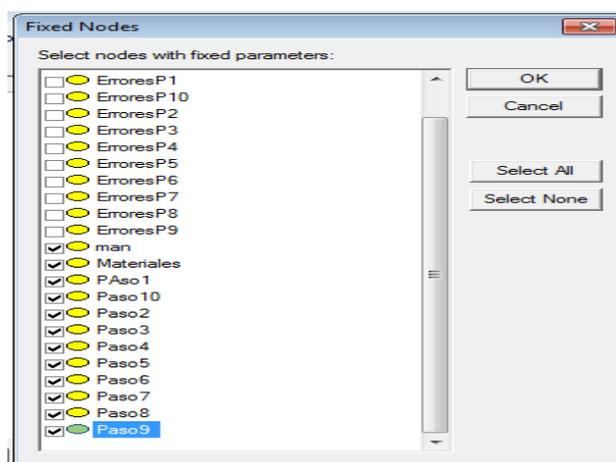


Figura 5.9. Nodos que conservan sus probabilidades condicionales durante el aprendizaje de parámetros.

El nodo *calif_examen_Teórico* es el único nodo que se evidenciará en este modelo. Esto dependiendo de la calificación obtenida por el usuario. Ver Figura 5.6b.

Evaluación del ME a partir de conocimiento de expertos

Para la evaluación del ME a partir de conocimiento de expertos se enlistan las ventajas y desventajas del modelo (ver Tabla 5.14). De dicha evaluación se desprende la afirmación de que se tiene la certeza del resultado y su correspondencia al objetivo del caso de estudio: determinar si el eléctrico sabe realizar una maniobra dada su interacción con el sistema Alen3D. Como desventaja se enlistó la dependencia de al menos un experto en el sistema Alen3D y al menos un experto en redes Bayesianas. Lo anterior habla de que la automatización de la obtención de un ME no se dio, pues se necesitó un equipo de al menos dos expertos para su construcción.

Tabla 5.14. Evaluación del ME a partir de conocimiento de expertos.

Ventajas	Desventajas
<ol style="list-style-type: none"> 1. Se tuvo un dominio exacto de las dependencias y probabilidades condicionales entre las variables. 2. Se implementó una modificación a la metodología <i>Guess&Slips</i> ya que se ponderó los errores de los usuarios. 3. Para su ejecución se hace uso del aprendizaje Bayesiano – parámetros. 4. Se tiene certeza de que el resultado corresponde a lo solicitado por el cliente. 	<ol style="list-style-type: none"> 1. Se tuvo que depender de un experto en el sistema y de un experto en RB para su construcción. 2. El nodo <i>man</i> (el cual da el resultado) posee una tabla de probabilidad condicional con 20480 valores.

5.4 Implementación y evaluación de las técnicas de RB a los ME del caso de estudio

A continuación se describen brevemente las técnicas implementadas a los ME obtenidos del caso de estudio.

Para la mejor comprensión del modelado de estudiantes se investigó ampliamente y se implementaron las siguientes técnicas relacionadas a las RB:

- Propagación de creencia en RB. Se implementó el algoritmo de pase de mensajes en redes tipo árbol, propuesto por [Pearl, 1983], al ME *a partir de conocimiento de expertos*.
- RB Difusas. Se implementó el concepto difuso de [Tang, 2007] al ME *a partir de conocimiento de expertos* del caso de estudio.
- Aprendizaje Bayesiano. Se implementó el algoritmo [Chow, 1968] a los datos utilizados para el ME *a partir de datos*.

5.4.1 Propagación de creencia en RB

La tarea básica de una RB es el cálculo de la distribución de probabilidad posterior de un conjunto de variables, dado el conjunto de variables *evidencia*. Este proceso es conocido como

inferencia, pero hay autores que le llaman: actualización Bayesiana, actualización de la creencia o razonamiento y como lo propuso [Pearl, 1983]: propagación de información.

Hay dos maneras de enfrentar la inferencia: exacta o aproximada. La inferencia exacta es sólo posible en clases restringidas de redes. Esto es, redes que pertenecen a la clase de redes conectadas uno a uno, también conocidas como *polytrees*. Una red pertenece a esta clase si el grafo contiene cero o una sola ruta entre dos nodos cualquiera. En la realidad son pocas las RB de la clase de *polytrees* para las cuales se utilizan los métodos aproximados cuando se realiza la inferencia [Koiter, 2006].

En esta tesis se describe a fondo uno de los primeros algoritmos de inferencia que se desarrolló: el algoritmo de propagación en árboles [Pearl, 1983]. La idea consiste en que cuando se modifica la información asociada a un nodo, éste traspasa la información a sus nodos vecinos mediante un conjunto de mensajes; estos nodos, a su vez, procesan la información recibida junto con la que ellos poseen y la pasan a sus nodos vecinos (aún no modificados) y así sucesivamente hasta que todos los nodos han actualizado su información [Millán, 2000]. El procedimiento se describe en Algoritmo 2.

Algoritmo 2. Propagación de creencias en redes Bayesianas clase *polytree*

1. Inicialización.

A. Inicializar todos los λ -mensajes y λ -valores a 1.

B. Si la raíz A tiene m posibles valores, entonces para $j = 1, \dots, m$, sea

$$\pi(a_j) = P(a_j).$$

C. Para todos los hijos B de la raíz A , hacer

Enviar un nuevo π -mensaje a B usando la fórmula 2.

(En ese momento comenzará un flujo de propagación debido al procedimiento de actualización 2.C).

2. Actualización.

Cuando una variable se instancia o una variable recibe un λ o π -mensaje, se usa uno de los siguientes procedimientos de actualización:

A. Si una variable B se instancia a un valor b_j , entonces:

A.1. Inicializar $P^*(b_j) = 1$ y $P^*(b_i) = 0$, para todo $i \neq j$.

A.2. Calcular $\lambda(B)$ usando la fórmula 3.

A.3. Enviar un nuevo λ -mensaje al padre de B usando la fórmula 1.

A.4. Enviar nuevos π -mensajes a los hijos de B usando la fórmula 2.

B. Si una variable B recibe un nuevo λ -mensaje de uno de sus hijos y la variable B no ha sido instanciada todavía, entonces:

B.1. Calcular el nuevo valor de $\lambda(B)$ usando la fórmula 3.

B.2. Calcular el nuevo valor de $P^*(B)$ usando la fórmula 5.

B.3. Enviar un nuevo λ -mensaje al padre de B usando la fórmula 1.

B.4. Enviar nuevos π -mensajes a los otros hijos de B usando la fórmula 2.

C. Si una variable B recibe un nuevo π -mensaje de su padre y la variable B no ha sido instanciada todavía, entonces:

C.1. Calcular el nuevo valor de $\pi(B)$ usando la fórmula 4.

C.2. Calcular el nuevo valor de $P^*(B)$ usando la fórmula 5.

C.3. Enviar nuevos π -mensajes a los hijos de B usando la fórmula 2.

La idea principal en la que se basa el algoritmo es la siguiente: cada vez que una variable se instancia, informa a sus nodos vecinos mediante *mensajes* (λ mensaje, del hijo al padre; π mensaje, del padre a los hijos) que ha sucedido una modificación, así hasta alcanzar la raíz u hojas. Estos mensajes asignan a cada variable valores (λ y π); multiplicando estos valores se obtienen las probabilidades a posteriori de cada una de las variables de la red.

Las fórmulas que se utilizan para obtener los mensajes λ y π y los valores λ y π de cada variable se describen en la Tabla 5.16.

Para la implementación de esta técnica se utilizó el ME a partir de conocimiento de expertos mostrado en la Figura 5.10, donde se aprecia la evidencia de prueba en los nodos *ErroresP1*, *ErroresP2*, *ErroresP3*, *ErroresM* y *calif_examen_Teórico*. Cabe mencionar que el ME de la Figura 5.10 es un modelo parcial del ME a partir de conocimiento de expertos, esto por razones de espacio para desarrollo de las tablas que se presentan a continuación.

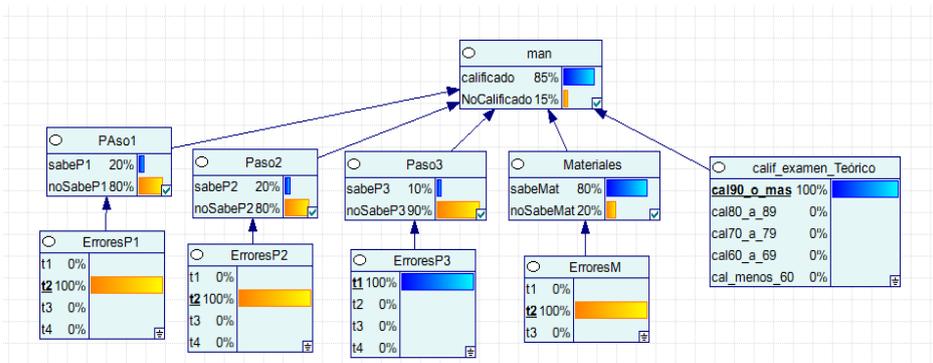


Figura 5.10. ME utilizado para la implementación del algoritmo de pase de mensajes

En la Tabla 5.15 se muestra la implementación hecha para la obtención de los valores π .

Tabla 5.15. Implementación para la obtención de los valores π .

Nodo	π valor de cada valor del nodo			
<i>ErroresP1</i>	$\pi(t1)=0$	$\pi(t2)=1$	$\pi(t3)=0$	$\pi(t4)=0$
<i>ErroresP2</i>	$\pi(t1)=0$	$\pi(t2)=1$	$\pi(t3)=0$	$\pi(t4)=0$
<i>ErroresP3</i>	$\pi(t1)=1$	$\pi(t2)=0$	$\pi(t3)=0$	$\pi(t4)=0$
<i>ErroresM</i>	$\pi(t1)=0$	$\pi(t2)=1$	$\pi(t3)=0$	
<i>Paso1</i>	$\pi(sabeP1)=P(sabeP1 t1)\pi_{Paso1}(t1) + P(sabeP1 t2)\pi_{Paso1}(t2) + P(sabeP1 t3)\pi_{Paso1}(t3) + P(sabeP1 t4)\pi_{Paso1}(t4)$			

La implementación hecha para la obtención de los nodos *Paso2*, *Paso3*, *Materiales*, *calif_examen_Teórico* y *man* podrá ser encontrada en el CD que acompaña esta tesis (Anexo D).

Tabla 5.16. Fórmulas necesarias para el desarrollo del algoritmo 2.

Componente del algoritmo paso de Mensajes de Pearl	Fórmula
1. λ mensajes	<p>Un Solo padre: Por cada hijo Y de X, para todos los valores de x</p> $\lambda_Y(x) \equiv \sum_y P(y x)\lambda(y).$ <p>Varios padres: Por cada hijo Y de X, para todos los valores de x,</p> $\lambda_Y(x) \equiv \sum_y \left[\sum_{w_1, w_2, \dots, w_k} \left(P(y x, w_1, w_2, \dots, w_k) \prod_{i=1}^k \pi_Y(w_i) \right) \right] \lambda(y)$ <p>donde, W_1, W_2, \dots, W_k son los otros padres de Y.</p>
2. π mensajes	<p>Dejar Z ser un padre de X. Entonces para todos los valores de Z,</p> $\pi_X(z) \equiv \pi(z) \prod_{U \in \text{CH}_Z - \{X\}} \lambda_U(z).$
3. λ valores	<p>Si $X \in A$ y el valor de X es \hat{x},</p> $\begin{aligned} \lambda(\hat{x}) &\equiv 1 \\ \lambda(x) &\equiv 0 \quad \text{for } x \neq \hat{x}. \end{aligned}$ <p>Si $X \notin A$ y X es una hoja, para todos los valores de x,</p> $\lambda(x) \equiv 1.$ <p>Si $X \notin A$ y X no es una hoja, para todos los valores de x,</p> $\lambda(x) \equiv \prod_{U \in \text{CH}_X} \lambda_U(x).$ <p>donde CH_X es el conjunto de todos los hijos de X.</p>
4. π valores	<p>Si $X \in A$ y el valor de X es \hat{x},</p> $\begin{aligned} \pi(\hat{x}) &\equiv 1 \\ \pi(x) &\equiv 0 \quad \text{for } x \neq \hat{x}. \end{aligned}$ <p>Si $X \notin A$ y X es una raíz, para todos los valores de x,</p> $\pi(x) \equiv P(x).$ <p>Si $X \notin A$, X no es raíz, y Z_1, Z_2, \dots, Z_j son los padres de X, para todos los valores de x,</p> $\pi(x) = \sum_{z_1, z_2, \dots, z_j} \left(P(x z_1, z_2, \dots, z_j) \prod_{i=1}^j \pi_X(z_i) \right).$

Tabla 5.16. Fórmulas necesarias para el desarrollo del algoritmo 2. Continuación.

Componente del algoritmo paso de Mensajes de Pearl	Fórmula
5. Probabilidad a posteriori	<p>5. Dadas las definiciones anteriores, por cada variable X, se tiene para todos los valores de x,</p> $P(x a) = \alpha \lambda(x) \pi(x),$ <p>donde α es una constante de normalización.</p>

En la Tabla 5.17 se muestra la implementación para la obtención de los valores λ a cada nodo.

Tabla 5.17. Implementación a cada nodo para obtener los Valores λ .

Nodos	λ valores para cada valor del nodo
ErroresP1	$\lambda(t1)=0 \quad \lambda(t2)=1 \quad \lambda(t3)=0 \quad \lambda(t4)=0$
ErroresP2	$\lambda(t1)=0 \quad \lambda(t2)=1 \quad \lambda(t3)=0 \quad \lambda(t4)=0$
ErroresP3	$\lambda(t1)=1 \quad \lambda(t2)=0 \quad \lambda(t3)=0 \quad \lambda(t4)=0$
ErroresM	$\lambda(t1)=0 \quad \lambda(t2)=1 \quad \lambda(t3)=0$
calif_examen_Teórico	$\lambda(cal90_o_mas)=1 \quad \lambda(cal80_a_89)=0$ $\lambda(cal70_a_79)=0 \quad \lambda(cal60_a_69)=0$ $\lambda(cal_menos_60)=0$
Paso1	$\lambda(sabeP1)=\lambda_{man}(sabeP1)$ $\lambda(noSabeP1)=\lambda_{man}(noSabeP1)$
Paso2	$\lambda(sabeP2)=\lambda_{man}(sabeP2)$ $\lambda(noSabeP2)=\lambda_{man}(noSabeP2)$
Paso3	$\lambda(sabeP3)=\lambda_{man}(sabeP3)$ $\lambda(noSabeP3)=\lambda_{man}(noSabeP3)$
Materiales	$\lambda(sabeMat)=\lambda_{man}(sabeMat) \lambda(noSabeMat)=\lambda_{man}(noSabeMat)$
man	$\lambda(calificado)=1 \quad \lambda(noCalificado)=1$

Los valores π de cada uno de los nodos representan la actividad en los nodos padre o en los antecesores del nodo observado. Los valores π de cada nodo son obtenidos para cada valor del nodo. En Tabla 5.18 se muestra la implementación de los mensajes λ .

Tabla 5.18. Implementación de los mensajes λ .

Nodo origen de λ mensaje	λ (lamda) mensaje del nodo origen a cada uno de los valores del nodo padre
Paso1	$\lambda_{Paso1}(t1)=P(sabeP1 t1)\lambda(sabeP1) + P(noSabeP1 t1)\lambda(noSabeP1)$ $\lambda_{Paso1}(t2)=P(sabeP1 t2)\lambda(sabeP1) + P(noSabeP1 t2)\lambda(noSabeP1)$ $\lambda_{Paso1}(t3)=P(sabeP1 t3)\lambda(sabeP1) + P(noSabeP1 t3)\lambda(noSabeP1)$ $\lambda_{Paso1}(t4)=P(sabeP1 t4)\lambda(sabeP1) + P(noSabeP1 t4)\lambda(noSabeP1)$
Paso2	$\lambda_{Paso2}(t1)=P(sabeP2 t1)\lambda(sabeP2) + P(noSabeP2 t1)\lambda(noSabeP2)$ $\lambda_{Paso2}(t2)=P(sabeP2 t2)\lambda(sabeP2) + P(noSabeP2 t2)\lambda(noSabeP2)$ $\lambda_{Paso2}(t3)=P(sabeP2 t3)\lambda(sabeP2) + P(noSabeP2 t3)\lambda(noSabeP2)$ $\lambda_{Paso2}(t4)=P(sabeP2 t4)\lambda(sabeP2) + P(noSabeP2 t4)\lambda(noSabeP2)$

Tabla 5.18. Implementación de los mensajes λ . Continuación.

Nodo origen de λ mensaje	λ (lamda) mensaje del nodo origen a cada uno de los valores del nodo padre
<i>Paso3</i>	$\lambda_{Paso3}(t1)=P(sabeP3 t1)\lambda(sabeP3) + P(noSabeP3 t1)\lambda(noSabeP3)$ $\lambda_{Paso3}(t2)=P(sabeP3 t2)\lambda(sabeP3) + P(noSabeP3 t2)\lambda(noSabeP3)$ $\lambda_{Paso3}(t3)=P(sabeP3 t3)\lambda(sabeP3) + P(noSabeP3 t3)\lambda(noSabeP3)$ $\lambda_{Paso3}(t4)=P(sabeP3 t4)\lambda(sabeP3) + P(noSabeP3 t4)\lambda(noSabeP3)$
<i>Materiales</i>	$\lambda_{Materiles}(t1)=P(sabeMat t1)\lambda(sabeMat) +$ $P(noSabeMat)\lambda(noSabeMat)$

La Tabla 5.19 muestra la implantación de los mensajes π .

Tabla 5.19. π mensajes de nodo origen a sus hijos

Nodo del que se origina el π mensaje	π mensajes de cada valor del nodo origen a sus hijos
<i>ErroresP1</i>	$\pi_{Paso1}(t1)=\pi(t1)$ $\pi_{Paso1}(t2)=\pi(t2)$ $\pi_{Paso1}(t3)=\pi(t3)$ $\pi_{Paso1}(t4)=\pi(t4)$
<i>ErroresP2</i>	$\pi_{Paso2}(t1)=\pi(t1)$ $\pi_{Paso2}(t2)=\pi(t2)$ $\pi_{Paso2}(t3)=\pi(t3)$ $\pi_{Paso2}(t4)=\pi(t4)$
<i>ErroresP3</i>	$\pi_{Paso3}(t1)=\pi(t1)$ $\pi_{Paso3}(t2)=\pi(t2)$ $\pi_{Paso3}(t3)=\pi(t3)$ $\pi_{Paso3}(t4)=\pi(t4)$
<i>ErroresM</i>	$\pi_{Materiales}(t1)=\pi(t1)$ $\pi_{Materiales}(t2)=\pi(t2)$ $\pi_{Materiales}(t3)=\pi(t3)$
<i>calif_examen_Teórico</i>	$\pi_{man}(cal90_o_mas)=\pi(cal90_o_mas)$ $\pi_{man}(cal80_a_89)=\pi(cal80_a_89)$ $\pi_{man}(cal70_a_79)=\pi(cal70_a_79)$ $\pi_{man}(cal60_a_69)=\pi(cal60_a_69)$ $\pi_{man}(cal_menos_60)=\pi(cal_menos_60)$
<i>Paso1</i>	$\pi_{man}(sabeP1)=\pi(sabeP1)$ $\pi_{man}(noSabeP1)=\pi(noSabeP1)$
<i>Paso2</i>	$\pi_{man}(sabeP2)=\pi(sabeP2)$ $\pi_{man}(noSabeP2)=\pi(noSabeP2)$
<i>Paso3</i>	$\pi_{man}(sabeP3)=\pi(sabeP3)$ $\pi_{man}(noSabeP3)=\pi(noSabeP3)$
<i>Materiales</i>	$\pi_{man}(sabeMat)=\pi(sabeMat)$ $\pi_{man}(noSabeMat)=\pi(noSabeMat)$

Con los valores y mensajes λ y π de cada nodo se puede obtener la probabilidad a posteriori de los nodos no evidenciados, lo cual se muestra en la Tabla 5.20.

Tabla 5.20. Probabilidad a posteriori del los nodos de ME a partir de conocimiento de expertos modificado.

nodo	probabilidad a posteriori
<i>Paso1</i>	$P^*(sabeP1)= (\lambda(sabeP1) \pi(sabeP1))\alpha =0.1999$ $P^*(noSabeP1)=(\lambda(noSabeP1) \pi(noSabeP1))\alpha =0.8001$
<i>Paso2</i>	$P^*(sabeP2)= (\lambda(sabeP2) \pi(sabeP2))\alpha =0.1999$ $P^*(noSabeP2)=(\lambda(noSabeP2) \pi(noSabeP2))\alpha =0.8001$

Tabla 5.20. Probabilidad a posteriori del los nodos de ME a partir de conocimiento de expertos modificado. Continuación.

nodo	probabilidad a posteriori
<i>Paso3</i>	$P^*(sabeP3) = (\lambda(sabeP3) \pi(sabeP3))\alpha = 0.0988$ $P^*(noSabeP3) = (\lambda(noSabeP3) \pi(noSabeP3))\alpha = 0.9012$
<i>Materiales</i>	$P^*(sabeMat) = (\lambda(sabeMat) \pi(sabeMat))\alpha = 0.798$ $P^*(noSabeMat) = (\lambda(noSabeMat) \pi(noSabeMat))\alpha = 0.202$
<i>man</i>	$P^*(calificado) = (\lambda(calificado) \pi(calificado))\alpha = 0.846$ $P^*(noCalificado) = (\lambda(noCalificado) \pi(noCalificado))\alpha = 0.154$

Como se puede apreciar en la Tabla 5.20 la probabilidad a posteriori de los nodos está dada por los valores λ y los valores π , es decir por la actividad realizada por los antecesores y los sucesores del nodo observado.

Evaluación de la técnica de pase de mensajes

A partir de la Tabla 5.21 se puede decir que la aplicación del algoritmo de pase de mensajes se pudo realizar sólo en uno de los modelos del caso de estudio. Esto debido a que el ME a partir de datos es una red que no pertenece a la clase *polytree*.

Tabla 5.21. Evaluación de la técnica de pase de mensajes.

Ventajas	Desventajas
<ol style="list-style-type: none"> Ya implementado el algoritmo <i>corre</i> rápidamente. En este ejemplo el tiempo es despreciable. 	<ol style="list-style-type: none"> Este algoritmo no se puede ocupar para el ME a partir de datos ya que este modelo no es de la clase <i>polytree</i>. Se tiene que reservar memoria para las probabilidades condicionales de los nodos al igual que se hace si se utilizara la ecuación de la teoría de Bayes. Es complicado de entender, y cuando se tiene una red pequeña el tiempo invertido para el desarrollo del algoritmo se torna en desventaja.

5.4.2 Aprendizaje Bayesiano

En esta sección se presenta el algoritmo Chow&Liu [Chow, 1968]; este algoritmo es utilizado como base para algunos de los algoritmos de aprendizaje bayesiano como en TAN. La implementación del aprendizaje de Bayesiano de esta sección se hizo con los datos del sistema Alen3D.

Tabla 5.22. Muestra de la base de datos utilizada para la implementación del algoritmo Chow&Liu.

clase	califTeorica	EPT1	EPT2	EPT3	EPT4	EMT1	EMT2	EMT3
0	B	frec_31_40	frec_0_10	frec_0_10	frec_0_10	frec_21_30	frec_11_20	frec_11_20
0	B	frec_11_20	frec_0_10	frec_0_10	frec_0_10	frec_71_80	frec_0_10	frec_11_20
1	A	frec_31_40	frec_0_10	frec_0_10	frec_0_10	frec_61_70	frec_0_10	frec_0_10
1	A	frec_21_30	frec_0_10	frec_0_10	frec_0_10	frec_0_10	frec_21_30	frec_51_60
1	A	frec_0_10	frec_0_10	frec41_50	frec_0_10	frec41_50	frec_0_10	frec_0_10
0	C	frec_0_10	frec_31_40	frec_0_10	frec_0_10	frec_0_10	frec_31_40	frec_31_40
0	B	frec_0_10	frec_0_10	frec_11_20	frec_0_10	frec_31_40	frec_11_20	frec_11_20
0	D	frec_71_80	frec_0_10	frec_0_10	frec_0_10	frec_21_30	frec_0_10	frec_0_10
0	D	frec_61_70	frec_0_10	frec_0_10	frec_0_10	frec_31_40	frec_0_10	frec_0_10
0	B	frec_0_10	frec_31_40	frec_0_10	frec_0_10	frec_0_10	frec_11_20	frec_31_40
0	B	frec_0_10	frec_0_10	frec_11_20	frec_0_10	frec_0_10	frec_11_20	frec_51_60
0	B	frec_0_10	frec41_50	frec_0_10	frec_0_10	frec_0_10	frec_31_40	frec_11_20

El procedimiento Chow&Liu se describe e implementa con el Algoritmo 3. Para éste, se requiere una base de datos D con variables $X = \{X_{m1}, \dots, X_{mn}\}$, la cual se puede observar en la Tabla 5.22.

Algoritmo 3. Algoritmo Chow&Liu para aprendizaje Bayesiano, implementación y resultado.

1. Calcular $SUFF_D(T)$: Todos los pares de variables posibles de $X(T)$, utilizando la ecuación:

$$\frac{x(x - 1)}{2}$$

Dadas las variables:

0 = clase, 1=califTeorica, 2=EPT1, 3=EPT2, 4=EPT3, 5=EPT4, 6=EMT1, 7=EMT2, 8=EMT3

Se tiene:

36 pares posibles

2. Inicializar como árbol vacío

$T = (V,E)$ donde $V(T) = \{\emptyset\}$ y $E(T) = \{\emptyset\}$

Algoritmo 3. Algoritmo Chow&Liu para aprendizaje Bayesiano, implementación y resultado.
Continuación.

3. Calcular costos para cada par, $I(X_{mi}, X_{mj})$, utilizando la ecuación:

$$I(X_i, X_j) = \sum_{X_i, X_j} P(X_i, X_j) \log \frac{P(X_i, X_j)}{P(X_i) P(X_j)}$$

Resultado:

0.443120	0.000000	1.000000
0.104789	0.000000	2.000000
0.037506	0.000000	3.000000
0.095808	0.000000	4.000000
0.103341	0.000000	5.000000
0.117165	0.000000	6.000000
0.072271	0.000000	7.000000
0.104334	0.000000	8.000000
0.304985	1.000000	2.000000
0.092175	1.000000	3.000000
0.078689	1.000000	4.000000
0.138810	1.000000	5.000000
0.273581	1.000000	6.000000
0.207618	1.000000	7.000000
0.186532	1.000000	8.000000
0.197986	2.000000	3.000000
0.159573	2.000000	4.000000
0.174710	2.000000	5.000000
0.468347	2.000000	6.000000
0.284084	2.000000	7.000000
0.363835	2.000000	8.000000
0.155967	3.000000	4.000000
0.043007	3.000000	5.000000
0.101423	3.000000	6.000000
0.155566	3.000000	7.000000
0.097035	3.000000	8.000000
0.130968	4.000000	5.000000
0.091671	4.000000	6.000000
0.092380	4.000000	7.000000
0.236082	4.000000	8.000000
0.124964	5.000000	6.000000
0.124410	5.000000	7.000000
0.373083	5.000000	8.000000
0.212110	6.000000	7.000000
0.311775	6.000000	8.000000
0.246873	7.000000	8.000000

4. Seleccionar el par con el máximo costo (X_{mi}, X_{mj})

0.468347 2.000000 6.000000

5. Agregar al árbol las variables del par seleccionado y el arco

$V(T) = \{ 2,6 \}; E(T) = \{(2,6)\}$

Algoritmo 3. Algoritmo Chow&Liu para aprendizaje Bayesiano, implementación y resultado.
Continuación.

-primera iteración-

6. Formar un conjunto $B(T)$ con todas las posibles ramas (x_i, x_j) que deriven de las ramas en $E(T)$, considerando que x_i forma parte de una rama en $E(T)$ y x_j no está en las variables de $V(T)$.

$$B(T) = \{ (2,8), (1,2), (2,7), (1,6), (6,7), (2,3), (2,5), (2,4), (5,6), (0,6), (0,2), (3,6), (4,6) \}$$

-iterar-

7. Formar un conjunto $B(T)$ con todas las posibles ramas (x_i, x_j) ...

$$B(T) = \{ (1,2), (2,7), (1,6), (7,8), \dots \}$$

8. Seleccionar el par (X_{mi}, X_{mj}) ... con el máximo costo...

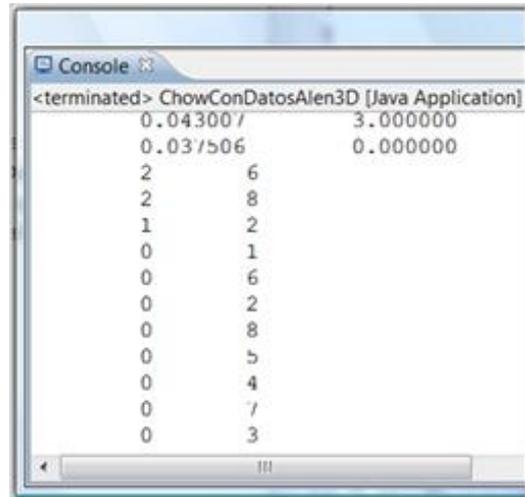
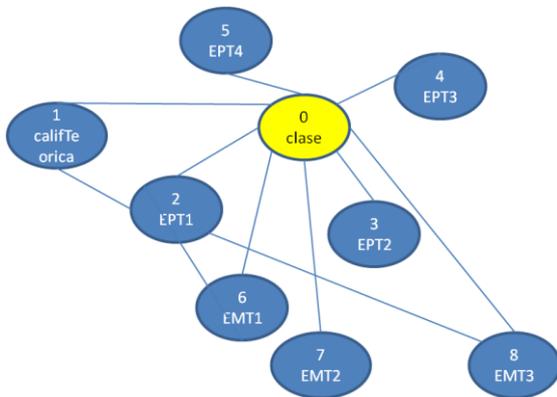
$$(1,2)$$

$$V(T) = V(T) \cup \{ X_{mj} \} = \{ 2,6,8,1 \}$$

$$E(T) = E(T) \cup \{ (X_{mi}, X_{mj}) \} = \{ (2,6), (2,8), (1,2) \}$$

Hasta que se procesen todas las variables ($V = X$)

Resultado obtenido



Se puede apreciar que el resultado del algoritmo Chow&Liu es un grafo sin dirección. Algoritmos como TAN asignan las dependencias de los nodos. Chow&Liu es la base para TAN y con ello se comprende el funcionamiento básico de éste.

Evaluación de la técnica de Aprendizaje Bayesiano

El algoritmo Chow&Liu muestra las bases de algoritmos como TAN. Al comprender el funcionamiento de Chow&Liu se está comprendiendo el funcionamiento de los algoritmos que utilizan la información mutua para desarrollar las dependencias basadas en la frecuencia de los datos. La Tabla 5.23 muestra las ventajas y desventajas de la técnica de Aprendizaje Bayesiano implementada en este documento.

Tabla 5.23. Evaluación de la técnica de Aprendizaje Bayesiano utilizando el algoritmo Chow&Liu

Ventajas	Desventajas
1. Se comprendió la base del algoritmo TAN.	1. No muestra un grafo dirigido.
2. Se obtuvo un árbol en el cual se pueden deducir las dependencias de los nodos.	2. Existen varios algoritmos con mucho más investigación aplicada a ellos que obtienen resultados más apegados a los que un experto podría proponer.
3. Su desarrollo no resulta complicado.	

5.4.3 Redes Bayesianas Difusas

Las RB difusas se pusieron bajo evaluación en esta tesis para comprender su funcionamiento cuando se requiere que el resultado responda a una pregunta como:

- ¿Cuál es la probabilidad de que un técnico esté calificado dado que tiene muchos errores de tipo 4?

Los datos que actualmente se muestran al preparador en el reporte de interacción son los siguientes:

- Id de prueba
- Número de errores por paso y su tipo
- Datos del eléctrico en capacitación

Se desearía proporcionar una herramienta en donde se pueda saber si el eléctrico está capacitado, al revisar la información que se le da al preparador. En base a esto se propuso implementar las redes Bayesianas difusas al ME a partir de conocimiento de expertos. El ME utilizado para esta implementación se muestra en la Figura 5.11. La técnica de RB difusas es la que se implementa en [Tang, 2007].

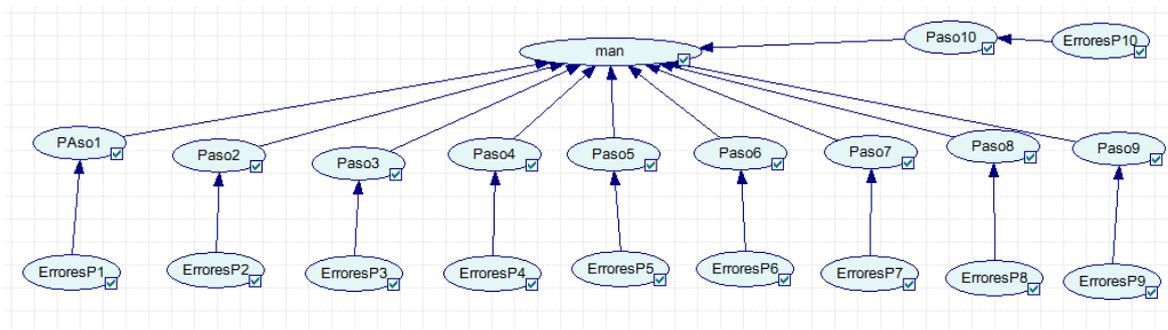


Figura 5.11. ME utilizado para la implementación de las RB difusas propuestas en [Tang, 2007].

Para esta la implementación de RB difusas se necesita una función de membrecía la cual está representada en la Figura 5.12. La función de membrecía es propia del autor de este documento dado que, según [Santafé, 2010], cualquier función sería válida para definir conjuntos difusos.

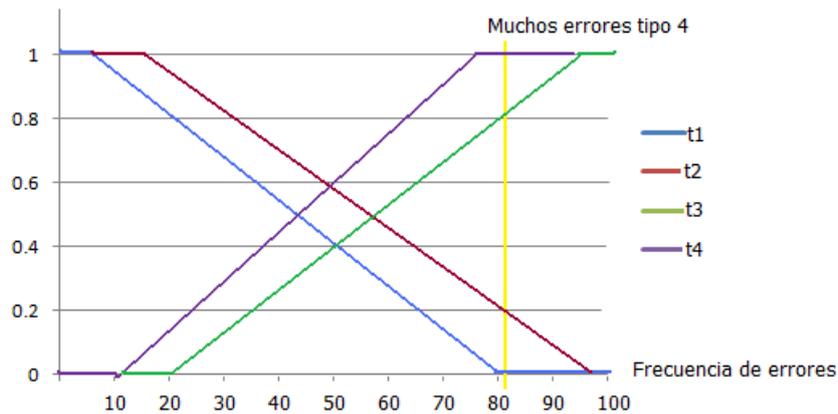


Figura 5.12. Función de pertenencia propuesta para el enunciado muchos errores tipo 4.

En la Tabla 5.24 se muestran las ecuaciones y el desarrollo de la propuesta de RB difusas aplicadas al ME a partir de conocimiento de expertos.

Tabla 5.24. Desarrollo del método propuesto en [Tang, 2007].

Ecuación	Desarrollo
$\mu_{\widetilde{erroresP1}}(erroresP1)$	$\begin{cases} 0 & t1 \\ 0.2 & t2 \\ 0.8 & t3 \\ 1 & t4 \end{cases}$
$P(\widetilde{erroresP1}) = \sum \mu_{\widetilde{erroresP1}}(ei)P(Ti)$	$P(\sim ErroresP1) = 0.982$
$P(Paso1 \sim erroresPi) = \frac{\sum \mu_{\widetilde{erroresPi}}(ei)P(Paso1 erroresPi)P(erroresPi)}{P(\sim erroresPi)}$	$P(Paso1 \sim ErroresP1) = 0.943991039$
$P(calificado \sim ErroresPi)$ $= \sum_{i=1...10} (Paso1 \sim erroresPi)P(calificado Paso1)$	0.949591935

La CPT parcial de $P(man|Paso_i)$ se muestra en la Figura 5.13.

Paso1	☐												
Paso2	☐												
Paso3	☐												
Paso4	☐												
Paso5	☐												
Paso6	☐ sabe												
Paso7	☐ sabe												
Paso8	☐ sabe												
Paso9	☐ sabe No_sabe												
Paso10	☐ sabe No_sabe												
► calificado	1	0.95	0.95	0.9	0.95	0.9	0.9	0.85	0.95	0.9	0.9	0.9	0.9
NoCalificado	0	0.05	0.05	0.1	0.05	0.1	0.1	0.15	0.05	0.1	0.1	0.1	0.1

Figura 5.13. CPT parcial del nodo *man*.

Dado el resultado se puede decir que cuando hay muchos errores de tipo 4 la probabilidad de que, el eléctrico en entrenamiento, esté calificado es de arriba de 90%.

Evaluación RB Difusas

De acuerdo a la evaluación mostrada en la Tabla 5.25 se puede decir que la implementación del concepto difuso al ME a partir de conocimiento de expertos resulta en una tarea extra. Los resultados se pueden apreciar con la RB posiblemente sólo ofrecer una función de pertenencia al nodo *man* el cual muestre resultados como *calificado* = x ; en donde $x \leq 0.80$ diga *usuario no calificado* y $x > 0.80$ sea considerado como *usuario calificado*.

Tabla 5.25. Evaluación de la técnica RB difusas

Ventajas	Desventajas
<ol style="list-style-type: none"> Se puede introducir el concepto difuso a un ME y darle al preparador una alternativa más, pues él puede ver el informe y saber si el eléctrico está o no capacitado de acuerdo al estimado de errores de tipo 4. La implementación de la técnica difusa al ME dio el razonamiento de hacer el nodo <i>man</i> difuso. 	<ol style="list-style-type: none"> Parece tiempo extra para obtener resultados que la red Bayesiana por sí sola ofrece. La técnica mostrada en [Tang, 2007] es aplicable a redes pequeñas según el autor. Se requiere un experto en lógica difusa para obtener resultados óptimos.

5.5 Análisis

A continuación, en la Tabla 5.26, se muestra un conglomerado del análisis de los ME y técnicas implementadas en este documento.

Tabla 5.26. Análisis de los ME y técnicas presentadas en este documento

Nombre del ME/técnica	Modelo/técnica base para la implementación	Uso de datos disponibles en caso de estudio	Propuesta de mejoras encontradas	Grado de dificultad de implementación	Observaciones
ME a partir de datos	Aprendizaje Bayesiano / Constraint-Based Model [Mayo, 2001]	Sí, para todo el modelo.	N/A	Alto	El tiempo de pre procesamiento de datos fue de 40 días.
ME a partir de conocimiento de expertos	Adapted Bayesian Test [Millán, 2013] / Guess and Slips [Conati, 2002]	Para el aprendizaje de parámetros en los nodos raíz.	El uso de cuatro y tres tipos de errores (adaptación a la técnica Guess and Slips [Conati, 2002]).	Medio	Se hace necesario expertos en redes Bayesianas y en el sistema al que se desea aplicar el ME.
Pase de mensajes en ME a partir de conocimiento de expertos	Inferencia en redes tipo árbol [Pearl, 1983]	No	N/A	Medio	La aplicación del algoritmo no se recomienda para una red de este tamaño.
Redes Bayesianas difusas en ME a partir de conocimiento de expertos	Redes Bayesianas difusas [Tang, 2007]	No	El uso de función de pertenencia al nodo hoja.	Alto	Se hace necesario el apoyo de expertos en redes Bayesianas tanto como en Lógica difusa.
Aprendizaje Bayesiano	Algoritmo de Chow and Liu [Chow, 1968]	Sí	N/A	Bajo	Fácil de entender y sirve de base para los algoritmos actuales.

5.6 Discusión

En este capítulo se presentó la aplicación práctica de los ME descritos en el capítulo anterior. Se muestra también, el uso de datos para el modelado haciendo uso del aprendizaje Bayesiano, todo esto aplicado al caso de estudio. Además, se implementan técnicas de RB a los mismos modelos para tratar de encontrar mejoras y se evalúan con los ME resultantes del caso de estudio.

El análisis hecho en la sección 5.5 es un compendio del capítulo y muestra información que pudiera facilitar la toma de decisiones para futuros desarrollos de ME.

Se mostró que los ME revisados de la literatura pueden adaptarse a los datos disponibles.

Capítulo 6

Conclusiones

Este capítulo tiene como objetivo presentar los puntos concluyentes del trabajo, estos incluyen: objetivos logrados, resumen de resultados finales, lecciones aprendidas y trabajo futuro.

6.1 Objetivos logrados

Al inicio del presente trabajo de investigación se presentó la propuesta de tesis con el nombre “Evaluación de Modelos del Estudiante de Sistemas Tutores Inteligentes que emplean redes Bayesianas como técnica básica de operación” y cuyo objetivo general es: Experimentar y evaluar al menos tres Modelos del Estudiante (ME) citados en la literatura especializada en Sistemas Tutores Inteligentes (STI) que empleen Redes Bayesianas (RB) con el fin de detectar las mejores prácticas en ese tema y aspectos no considerados en los ME y así proponer mejoras a tales modelos.

Del objetivo general se desprendieron los objetivos específicos que incluyen:

- Revisar el tema de los STI, con énfasis de los diversos tipos de Modelos del Estudiante
- Revisar y comprender el funcionamiento de las Redes Bayesianas aplicadas a modelar al estudiante
- Estudiar Modelos del Estudiante con y sin Redes Bayesianas
- Detectar y analizar al menos los tres Modelos del Estudiante que empleen como técnica básica de operación a las Redes Bayesianas
- Llevar a cabo experimentos con los Modelos del Estudiante anteriores buscando detectar aspectos que puedan mejorarse, así como las desventajas de cada propuesta
- Reportar los hallazgos encontrados, ventajas y desventajas

Cabe mencionar que en los objetivos específicos de la propuesta de tesis no se menciona el Caso de Estudio realizado en la estancia de investigación.

En resumen, de la presente sección, se muestra la Tabla 6.1 donde se sintetizan los objetivos específicos y las actividades realizadas para el logro de los mismos.

Tabla 6.1. Objetivos y actividades realizadas para su logro.

Objetivo específico	Actividades
1. Revisar el tema de los STI, con énfasis de los diversos tipos de Modelos del Estudiante.	Se revisaron 30 artículos referentes a STI.
2. Revisar y comprender el funcionamiento de las Redes Bayesianas aplicadas a modelar al estudiante.	Se revisaron 9 artículos referentes a RB aplicadas a los ME.
3. Estudiar Modelos del Estudiante con y sin Redes Bayesianas.	Se revisaron 17 artículos referentes a ME no importando la técnica de Inteligencia Artificial utilizada.
4. Detectar y analizar al menos los tres Modelos del Estudiante que empleen como técnica básica de operación a las Redes Bayesianas.	Se escogieron tres ME, se analizaron y se presentaron en el capítulo cuatro del presente documento.
5. Llevar a cabo experimentos con los Modelos del Estudiante anteriores buscando detectar aspectos que puedan mejorarse, así como las desventajas de cada propuesta.	Se realizó el caso de estudio presentado en el capítulo cinco del presente documento, llevando a cabo implementación y experimentación con una combinación de los ME analizados en el capítulo cuatro.
6. Reportar los hallazgos encontrados, ventajas y desventajas.	Secciones 5.5, 5.3.1, 5.3.2, 5.4.1, 5.4.2, y 5.4.3 del presente documento.

6.2 Resultados finales

A continuación se describen los productos y aportaciones realizadas con el trabajo de investigación de la presente tesis.

6.2.1 Productos

Los productos resultantes de la presente investigación incluyen:

- Código de implementación del algoritmo Chow&Liu en lenguaje C para datos sintéticos y para datos del sistema Alen3D, incluidos en el CD que acompaña el presente documento.
- Implementación del algoritmo de pase de mensajes de [Pearl, 1983] en hoja de cálculo incluida en el CD que acompaña este documento.
- Artículo aceptado en *MICAI 2016, 15th Mexican International Conference on Artificial Intelligence*. Título del artículo: "Data-driven construction of a student model using Bayesian networks in an electrical domain". El artículo se anexa en el CD que acompaña este documento. Anexo C.
- Modelo a partir de conocimiento de expertos en formato xdsl (GeNie). Anexo en el CD que acompaña este documento.
- Modelo a partir de datos en formato xdsl (GeNie). Anexo en el CD que acompaña este documento.

6.2.2 Logros

Entre los logros o aspectos de mejora encontrados destacan:

- La utilización de la teoría de los tres ME (capítulo cuatro en su totalidad) para la construcción de dos ME propios. Es decir, se tomó la teoría de tres modelos de la literatura y se desarrollaron dos modelos al combinar las ideas y mejores aspectos de cada uno de esos tres ME, y así proponer nuevas alternativas de modelado.
- Se ingenió la manera de utilizar los datos existentes. No se tuvo que modificar el sistema del caso de estudio para obtener datos acorde a las metodologías existentes.
- Se logró que los errores fueran esenciales para la construcción del ME basado en conocimiento de expertos. También la categorización de los errores, ver capítulo 5 sección 2.
- Se considera no óptima la inserción de una RB difusa en el modelado del estudiante, al menos en el ME basado en conocimiento de expertos presentado en el capítulo 5 sección 4.3. Se propone la lógica difusa para el nodo resultado, en lugar de utilizarla en todos los nodos de la red.

6.3 Trabajo futuro

Existen diferentes caminos no explorados en la presente tesis que pudieran ofrecer una alternativa viable para futura investigación.

Entre estos caminos se puede mencionar mayor experimentación con los ME propuestos en el capítulo cinco sección 3. Se considera importante la revisión de la influencia e independencia de variables del ME a partir de datos. En los últimos años se han propuesto diferentes metodologías que pudieran aplicarse al ME propuesto en este documento (ME a partir de datos, capítulo cinco sección 3.1) y así verificar que las dependencias encontradas por el algoritmo TAN del sistema utilizado, GeNIe, son indispensables para el modelo.

También, se deja como trabajo futuro la inserción de los ME al sistema Alen3D. Con esto se requiere codificación de dichos modelos para ajustarse al STI.

Referencias

- [Aleven, 2015] Aleven Vincent, Sewall Jonathan, Octav Popescu, Martin van Velsen, Demi Sandra, Leber Brett. Reflecting on Twelve Years of ITS Authoring Tools. Journal: *Design Recommendations for Intelligent Tutoring Systems*, vol 3. 2015.
- [Aleven, 2012] Aleven Vincent. *Building Intelligent Tutoring Systems with the Cognitive Tutor Authoring Tools (CTAT)*. 8th Annual LearnLab Summer School, Pittsburgh, PE, Agostot 6-10, 2012.
- [Berkeley, 2013] University of Berkeley, CS188Fall2013. *Lecture 13: Bayes Nets [Archivo de video]*. Octubre 10, 2013. Recuperado de <https://www.youtube.com/watch?v=VfyxPtlqZh4>
- [Ceyca, 2004] Ceyca Jorge. *Desarrollo de un Módulo de planificación adaptativa de enseñanza para un sistema tutor*. Tesis de Maestria. 2004. Centro Nacional de Investigación y Desarrollo Tecnológico. Cuernavaca, México.
- [Chakraborty, 2010] Chakraborty S., Roy D., & Basu A. *Development of Knowledge Based Intelligent Tutoring System*. Advance Knowledge Based Systems: Model, Applications and Research. Editorial Jones and Bartlett. Vol. 1, pp 74-100, 2010
- [Chen, 2014] Chen Yang, Wullemin Pierre-Henri, Labat Jean-Marc. Bayesian Student Modeling Improved by Diagnostic Items. En, *Intelligent Tutoring Systems: 12th International Conference, ITS 2014, Honolulu, HI, USA, June 5-9, 2014. Proceedings* (pp. 144–149). Cham: Springer International Publishing. doi:10.1007/978-3-319-07221-0_17
- [Cheng, 1997] Cheng Jie, Bell David, & Liu, Weire. An algorithm for Bayesian belief network construction from data. En *IN PROCEEDINGS OF AI & STAT'97* (pp. 83–90). 1997.
- [Chow, 1968] Chow C., & Liu C. Approximating Discrete Probability Distributions with Dependence Trees. *IEEE Trans. Inf. Theor.*, 14(3), 462–467. doi:10.1109/TIT.1968.1054142. 1968.

- [Conati, 2010] Conati Cristina. Bayesian student modeling. *Advances in Intelligent Tutoring Systems* (pp. 281–299). Berlin, Heidelberg: Springer Berlin Heidelberg. doi:10.1007/978-3-642-14363-2_14. 2010.
- [Conati, 2002] Conati C., Gertner A. & VanLehn K. Using Bayesian networks to manage uncertainty in student modeling. *User Modelling and User-Adapted Interaction*, 12, 371–417. doi:10.1023/A:1021258506583.
- [Conati, 1997] Conati C., Gertner S., VanLehn K. & Druzdzel M. J. On-line student modeling for coached problem solving using Bayesian networks. *User Modeling: Proceedings of the Sixth International Conference, UM97.*, 231–242. doi:10.1.1.117.5761.
- [González, 2015] González-Brenes J. P. & Huang Y. Your model is predictive — but is it useful? Theoretical and Empirical Considerations of a New Paradigm for Adaptive Tutoring Evaluation. In *Proceedings of the 8th International Conference on Educational Data Mining, 2015*. Retrieved from <http://d-scholarship.pitt.edu/26046/>
- [Hawkins, 2014] Hawkins, William J., Neil T. Heffernan, and R. S. J. D. B. Learning Bayesian Knowledge Tracing Parameters with a Knowledge Heuristic and Empirical Probabilities. In *Intelligent Tutoring Systems* (pp. 150–156).
- [Hernández, 2016] Hernández M. Yasmin, Cervantes Marilu, Perez Miguel, & Mejia Manuel. Data-driven Construction of a Student Model using Bayesian networks in an Electrical Domain. *15th Mexican International Conference on Artificial Intelligence, MICAI 2016*, Cancun, México.
- [Huang, 2015] Huang Bert, Virginia Tech (Bert Huang). *16 Bayesian Networks*, Introduction to Artificial Intelligence [Archivo de Video]. March 25, 2015. Recuperado de <https://www.youtube.com/watch?v=TuGDMj43ehw>
- [Ingram, 2000] Ingram J. W. *Herramienta para el Desarrollo de Sistemas Tutores*. Tesis de Maestria. 2000. Centro Nacional de Investigación y Desarrollo Tecnológico. Cuernavaca, México.
- [Kodaganallur, 2005] Kodaganallur V. & Weitz R. A comparison of model-tracing and constraint-based intelligent tutoring paradigms. *International Journal of Artificial Intelligence in Education*, 15(2), 117–144. 2005.
- [Koiter, 2006] Koiter J. R. Visualizing inference in Bayesian networks, 2006, Dept. Comput. Sci., Delft Univ. Technol.

- [Martin, 2001] Martin B. Constraint-Based Modeling: Representing Student Knowledge. *New Zealand Journal of Computing*. 1999 Nov; 7(2):30-8.
- [Mayo, 2001] Mayo M. J. Bayesian Student Modelling and Decision-Theoretic Selection of Tutorial Actions in Intelligent Tutoring Systems. Tesis de doctorado. 2001.
- [Millán, 2013] Millán E., Descalço L., Castillo G., Oliveira P. & Diogo S. Using Bayesian networks to improve knowledge assessment. *Computers & Education*, 60(1), 436–447. 2013. doi:10.1016/j.compedu.2012.06.012
- [Millán, 2000] Millán E. *Sistema bayesiano para modelado del alumno*. PhD diss., Universidad De Málaga, 2000.
- [Mitrovic, 2007] Mitrovic A., Martin B. & Suraweera P. Constraint-based tutors: past, present and future. *IEEE*, 22(Intelligent Education Systems), 38–45. 2007.
- [Murray, 2007] Murray T. Authoring Intelligent Tutoring Systems : An analysis of the state of the art Authoring Intelligent Tutoring Systems : An Analysis of the State of the Art, 98–129. 2007.
- [Nava, 2002] Nava Pérez F. *Redes Bayesianas e Inteligencia Artificial : Aplicaciones en Educación*. Programa de doctorado de Física e Informática. Bienio 02-04. Depto. Estadística, I.O. y Computación. Universidad de la Laguna.
- [Neapolitan, 2003] Neapolitan R. E. *Learning Bayesian Networks*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc.
- [Nwaigwe, 2014] Nwaigwe A. Evaluating Student Models. *EDM (Workshops)*. 2014.
- [Paquette, 2010] Paquette L., Lebea, J.-F. & Mayers A. Authoring Problem-Solving Tutors: A Comparison between ASTUS and CTAT. In R. Nkambou, J. Bourdeau, & R. Mizoguchi (Eds.), *Advances in Intelligent Tutoring Systems SE - 19* (Vol. 308, pp. 377–405). Springer Berlin Heidelberg. doi:10.1007/978-3-642-14363-2_19.
- [Pavlik, 2013] Pavlik Philip I., Keith Brawner & Andrew Olney. A Review of Student Models Used in Intelligent Tutoring Systems. In *Design Recommendations for ITS: Volume 1a - Learning Modeling*.
- [Pearl, 1988] Pearl J. Probabilistic Reasoning in Intelligent Systems. *Morgan Kauffmann San Mateo*. doi:10.2307/2026705.
- [Pearl, 1985] Pearl J. Bayesian Networks A Model of self-Activated Memory for evidential Reasoning. UCLA. 1985.

- [Pearl, 1983] Pearl J., & Kirn J. H. A computational Model for causal and diagnostic reasoning in inference systems. In *IJCAI*, vol. 83, pp. 190-193. 1983.
- [Pittsburgh, 2016] University of Pittsburgh. GeNIe. Laboratorio de Sistemas de Decisión. Accesado desde: <http://genie.sis.pitt.edu/wiki/Probabilistic-Decision-Support-System:-Bayesian-Networks>
- [Ponce, 2010] Ponce Cruz P. *Inteligencia Artificial Con Aplicaciones a La Ingeniería*. Editorial Marcombo, 2010. ISBN 8426717063, 9788426717061.
- [Ryhajlo, 2013] Ryhajlo N. *Fuzzy Bayesian Networks for Prognostics and Health Management*. Publisher Montana State University-Bozeman, College of Engineering. 2013.
- [Santafé, 2010] Santafé R. Y. Diseño de un controlador de temperatura difuso, *Revista de la Facultad de Ciencias Naturales e Ingeniería*. 1–10. 2010, Colombia.
- [Tang, 2007] Tang H. & Liu S. Basic Theory of Fuzzy Bayesian Networks and Its Application in Machinery Fault Diagnosis. *Fourth International Conference on Fuzzy Systems and Knowledge Discovery (Vol. 4)*, (Fskd), 132–137. doi:10.1109/FSKD.2007.202.
- [Waicato, 2016] University of Waicato. Weka. Machine Learning Group. Retrieved from <http://www.cs.waikato.ac.nz/ml/weka/index.html>

Anexos

A. Acrónimos

ACT-R	<i>Arquitectura cognitiva desarrollada en CMU Adaptive Control Thought-Rational</i>
AND	<i>Logic gate AND</i>
API	<i>Application program interface</i>
AWT	<i>Abstract Windowing Toolkit</i>
BKT	<i>Bayesian Knowledge Tracing</i>
CD	<i>Compact Disc</i>
CENIDET	Centro Nacional de Investigación y Desarrollo Tecnológico
CMB	<i>Constraint-Based Model</i>
CMU	<i>Carnegie Mellon University</i>
CPT	<i>Conditional probability table</i>
CTAT	<i>Cognitive Tutor Autoring Tools</i>
DAG	<i>Direct acyclic graph</i>
EM	<i>Expectation-Maximization</i>
EP	Probabilidades Empíricas (por sus siglas en Inglés)
EUA	Estados Unidos de America
GBSM	<i>Generic Bayesian Student Model</i>
IA	Inteligencia Artificial
ITS	Sistema(s) Tutor Inteligente
Jess	<i>Rule Engine for the Java Platform</i>
Jess facts	Datos que contienen los Jess
JFC	Java Foundation Classes
LO	<i>Learnign Objects</i>
MAE	<i>mean absolute error</i>
ME	Modelo(s) de Estudiante
NIDA	<i>Noisy Input, Deterministic AND Pedagogical Evaluation Methods and Guidelines for Multimedia applications</i>
PENGU	<i>applications</i>
PmatE	Sistema computacional de evaluación de matemáticas
RB	Red(es) Bayesiana(s)
RMSE	<i>root mean squared error</i>
SGyACT	Sistema Generador y Administrador de Cursos Tutores
SQL	<i>Structured Query Language</i>
TAN	<i>Tree Augmented Naive Bayes</i>

B. Modelos resultantes a partir de datos del sistema Alen3D

A continuación se muestran las redes bayesianas obtenidas por los diferentes algoritmos de aprendizaje del sistema GeNIe [Pittsburgh, 2016] para el ME a partir de datos. Los algoritmos que indican *Background Knowledge* implementan un conocimiento previo, el cual viene dado por la experiencia del experto y del autor, donde se prohíbe dependencias del tipo: EPT_i no puede depende del nodo *califTeorica* ni de la clase determinada, ver la Tabla B.1.

Tabla B.1. Resultados de experimentación de aprendizaje de estructura

Algoritmo de aprendizaje	Red Bayesiana resultante
Bayesian Search with Background Knowledge	
PC with Background knowledge	

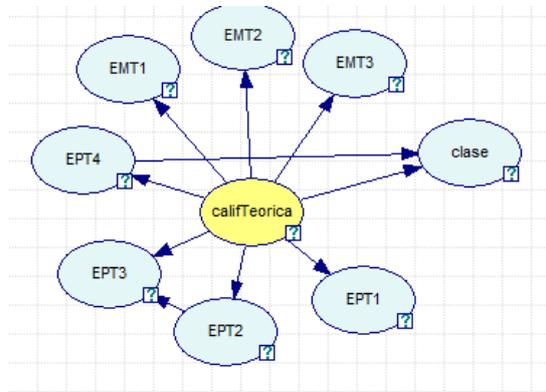
Tabla B.1. Resultados de experimentación de aprendizaje de estructura. Continuación.

Algoritmo de aprendizaje	Red Bayesiana resultante
Essential Graph Search with Background knowledge	
Greedy Thinning with Background knowledge	
Tree Augmented Naïve Bayes	

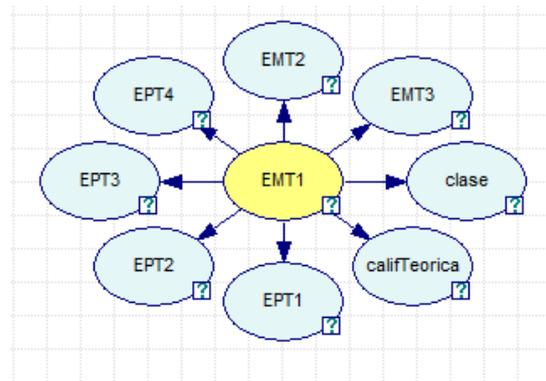
Tabla B.1. Resultados de experimentación de aprendizaje de estructura. Continuación.

Algoritmo de aprendizaje	Red Bayesiana resultante
---------------------------------	---------------------------------

Augmented Naïve Bayes



Naïve Bayes



A continuación (Figura B.1) se muestra el conocimiento previo aplicado a los atributos de los datos. Se puede apreciar que se previenen dependencias entre los nodos EPT_i y $clase$. Esto debido a que los errores no pueden depender del nodo $clase$.

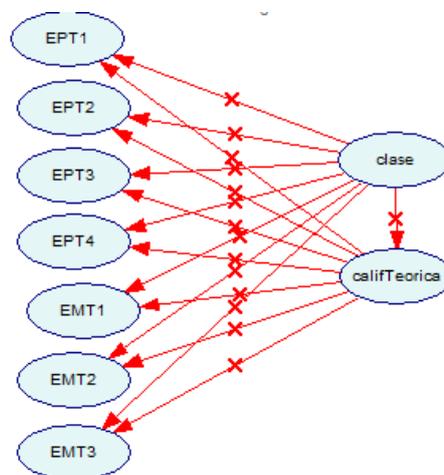


Figura B.1 Conocimiento previo para la obtención de estructura a partir de datos.

C. Artículo publicado

A continuación, en la Figura C.1, se muestra una parte del artículo publicado en 15th *Mexican International Conference on Artificial Intelligence*, MICA I 2016, Cancun, México.

Data-driven Construction of a Student Model using Bayesian networks in an Electrical Domain

Abstract. The student model is a key component of intelligent tutoring systems since enables them to respond particular needs of students. In last years, educational systems have widespread in school and industry and they produce data which can be used to know students and to understand and improve the learning process. The student modeling has been improved thanks to educational data mining, which is concerned with discovering novel and potentially useful information from large volumes of data. To build a student model, we have used the data log of a virtual reality training system that has been used for several years to train electricians. We rely on Bayesian networks to represent the student models. Here we present the student models and the results of an initial evaluation.

Keywords: Student model, educational data mining, Bayesian networks.

1 Introduction

In last decades, intelligent tutoring systems (ITS) have evolved and proved to be a successful application of artificial intelligent techniques. A part of the intelligence of these systems resides in knowing students and, consequently, they respond to individual needs of students. This adaptation process is based on the student model which is a structure storing knowledge about student such as errors, misconceptions, trials, and also it can store information about personality, emotions and motivation.

There is extensive research in student modeling [1, 2, 3, 4], and a novel approach is

Figura C.1. Artículo publicado en MICA I 2016 y que forma parte del caso de estudio presentado en el capítulo cinco sección dos.