## Universidad de Las Palmas de Gran Canaria Departamento de Matemáticas



### Tesis doctoral

Modelo Bayesiano para la Optimización y Personalización del Proceso de Aprendizaje en Línea: Estudio Casuístico

Francisco Javier Tapia Moreno

Las Palmas de Gran Canaria, España, Abril de 2007.

## Universidad de Las Palmas de Gran Canaria Departamento de Matemáticas



#### Tesis doctoral

Modelo Bayesiano para la Optimización y Personalización del Proceso de Aprendizaje en Línea: Estudio Casuístico

Presentada por

Francisco Javier Tapia Moreno

Dirigida por:

Dr. D. Manuel Jesús Galán Moreno Dr. D. Enrique Rubio Royo

Los directores El doctorando

## Resumen

En esta tesis presentamos un modelo probabilista basado en Redes Bayesianas (RBs), que puede determinar el tipo de personalización (TP) de acuerdo a las necesidades reales del alumno, con el propósito de ofrecer a éste una alternativa o un plan que optimice su proceso global de aprendizaje (PGA) en línea. Para lograr esto, hemos considerado los objetos de personalización (ops) y los objetivos de personalización (OPs) y realizado relaciones de causa y efecto entre éstos, y las fases de personalización del aprendizaje que tienen un efecto directo en el aprendizaje del alumno, y en la adecuación del sistema electrónico usado para gestionar el proceso de enseñanza-aprendizaje en línea del alumno. Cada op u OP, es considerado como una causa que tiene un efecto directo en alguna de las fases de personalización del aprendizaje que, a su vez, es una causa que tiene un efecto directo en la capacitación del alumno y en la adecuación del sistema electrónico usado por éste. Este tipo de relaciones recopiladas en una RB determinan, mediante cálculos probabilistas, un perfil de personalización deseable del alumno y en base a éste, se puede elaborar el modelo individual que optimice el proceso global de aprendizaje. El alcance del modelo que proponemos en esta tesis, contempla cuatro fases fundamentales de la personalización del aprendizaje en línea: 1) Fase de personalización para los conocimientos previos, 2) Fase de personalización para el progreso del conocimiento. 3) Fase de personalización para objetivos y metas del profesor/alumno y 4) Fase de personalización para las preferencias y experiencia de navegación.

La evaluación del modelo se realiza usando la primera fase y con datos obtenidos en un curso en línea con 45 alumnos simulados de diferentes áreas del conocimiento. Además, con los datos generados en la simulación del curso, hemos obtenido las probabilidades previas de cada una de las variables del modelo propuesto, las tablas de distribución de probabilidades previas para cada uno de los nodos padres, las tablas de distribución de probabilidades condicionales y un conjunto de funciones de distribución de probabilidad (fdps) locales. Las fdps locales se usan para generar las métricas de aprendizaje y diagnosticar los estados de las variables en las cuatro fases de nuestro modelo. Dicha evaluación demuestra empíricamente la eficacia de las redes Bayesianas en la modelación del alumno, específicamente en la realización de inferencia Bayesiana en casos de incertidumbre sobre los objetos y objetivos de personalización del alumno o bien en caso de pérdida de datos.

La investigación realizada se llevó a cabo dentro del contexto del Proyecto Suricata en su segunda fase. El Proyecto Suricata (PS) (Rubio, et al., 2004), es un modelo en red de innovación organizacional, basado en el trabajo en las comunidades virtuales y en el uso de tecnologías de la información, como una respuesta de adecuación al creciente proceso de virtualización social y de las organizaciones, que contribuye al desarrollo competitivo y socialmente sostenible

**Palabras claves**: Aprendizaje en línea personalizado, métricas de aprendizaje, redes Bayesianas.

## **Abstract**

In this paper, we propose a probabilistic model based in Bayesian networks. This model can determine type of personalization according to needs real's learner in order to propose an alternative or plan, with the purpose of optimize global learning on-line process of this learner. To we achieve this, we have considered objects of personalization and objectives of personalization, and we have accomplished cause-and-effect relations among these objects y objectives, and learning phases that have a direct effect in learner's learning, and in adjusting electronic system that is used to manage learner's learning-teaching on-line process

Each object personalization or objective of personalization, is considered as a cause that has a direct effect in any one of learning phases than, in turn, it's a cause that has a direct effect in learner's training, and in system's adjusting. This type of relations, if are compiled in a Bayesian network, could help obtain, by means of probabilistic calculations, a learner's desirable personalization profile, and according to this profile to elaborate learner's personalized model that optimize learner's global learning process.

In this model, four fundamental phases are contemplated: 1) Personalization for Learner's Pre-Knowledge Phase, 2) Personalization for Learner's Progress Knowledge Phase, 3) Personalization for Learner's /Teacher's Aims and Goals Phase, and 4) Personalization for Navigation Preferences and Experiences Phase.

Evaluation model is completed with data that on-line course with 45 learners simulated were compiled. Learners were of different knowledge area. With these data, we have obtained previous probabilities for each proposed model's variables, tables of probabilities distribution for each one parent nodes, tables of conditional probabilities distribution for each one of children nodes in order to we can to initialize our model. In addition, a set of local probability distribution functions is proposed. These functions are used in order to generate the learning metrics for each one of the states of our model's variables.

Bayesian networks efficacy is proven accomplishing model evaluation by means of a learner's diagnosis of the type of personalization in the learner's pre-knowledge phase

This research was accomplished in second phase within Suricata Project's frame. Suricata Project (Rubio et al., 2004) is an innovation organizational model in network, based on the work in virtual communities, and utilization of information technologies that contributes to the competitive and socially sustainable development. Suricata Project is a respond of adjusting to the increasing social virtualization process, and of the organizations.

**Keys Words**: On-line learning personalized, Learning metrics, Bayesian networks.

# **Dedicatoria**

A <b>Dios</b> o en su defecto, a quien corres	sponda,	
A mis padres,		
A mi famili	a,	
	Al pueblo de México,	
		Al pueblo Canario

## **Agradecimientos**

No puedo empezar a citar a las personas a las que debo dar mis agradecimientos sin antes hacer notar un curioso propósito que la lista de agradecimientos parece tener, especialmente en las publicaciones académicas. Con frecuencia da la impresión de que es una manera de indicar al mundo lo importante que es el autor y lo bien relacionado que éste está. Parece que siempre debe haber en la lista de agradecimientos por lo menos dos o tres personas de relevancia intelectual, sólo para demostrar las buenas compañías que frecuenta el autor.

La presente lista no describe mi red social, sino que simplemente menciona a quienes respondieron a peticiones de información o me ayudaron de una manera u otra, mucho, poco o tal vez nada. Esta última, también es una manera de ayudar y, en algunas ocasiones, se convierte en la mejor de éstas.

Cuatro personas a quienes ante todo debo dar las gracias son a: Enrique Rubio, Manuel Galán, Antonio Ocón y Claudio López ya que sin ellos este trabajo de tesis doctoral no habría sido posible. Otras personas a quien debo agradecimientos relacionados ya sea con mi estancia en la isla de Gran Canaria, España, con la obtención de información y asistencia informática, con su motivación y compañía o con este trabajo de investigación son: Edgar Javier Carmona, Carmina Tapia, Gabriela Tapia, Javier Toledo, Ginés Delgado, Inma Suárez, Sonia Marrero, Eliseo Carrasco, Marcos Medina, Pablo Vásquez, Mustapha Maarouf y Asmaa Skareb. Si me he olvidado de alguien, lo siento mucho. Parece ser que a mis 52 años mi memoria ya no es tan óptima como solía serlo hace algunos años, aunque para ser sincero, no recuerdo si ésta era muy buena.

## Tabla de contenido

	Pág
Portada	i
Certificación del Departamento de Matemáticas	
Resumen	iii
Abstract	iv
Dedicatoria	v
Agradecimientos	vi
Tabla de contenido	vii
Tabla de símbolos	ix
Lista de acrónimos	<i>x</i>
Lista de figuras	xii 
Lista de tablas	xiii
Capítulo 1. Introducción	1
1.1. Motivación	6
1.2. El Proyecto Suricata (PS)	8
1.3. Situación de la tesis en el Proyecto Suricata (PS)	10
1.4. Justificación y planteamiento del problema	11
1.5. Razón del uso de modelos y Redes Bayesianas (RBs)	14
1.5.1. ¿Por qué modelos?	14
1.5.2. ¿Por qué RBs?	15
1.6. Objetivos	18
1.7. Aportaciones	19
1.8. Panorama general de los capítulos subsecuentes	19
Capítulo 2 . Aprendizaje en línea	21
2.1. e-Learning	21
2.2 Aprendizaje el linea personalizado (ALP)	24
2.3. Objetos (Ops) y objetivos de personalización (ops)	28
2.4. Tipos de personalización (TPs) y tipos de adaptividad	37
2.5. Modelado del alumno	41
2.5.1. Contenido de un modelo del alumno (MA)	42
2.5.2. Componentes de un modelo del alumno (MA)	49
2.5.3. Técnicas de modelado	51
2.5.4. Inicialización del modelo del alumno (MA)	55 57
2.5.5. Actualización del modelo del alumno (MA)	57 64
2.6. Conclusión del capítulo	61
Capítulo 3. Redes Bayesianas	63
3.1. Introducción	63
3.2. Expresión de relaciones causales	64
3.3. Breve representación de las fidos	67

<ul> <li>3.4. Construcción de RBs usando los bordes causales</li> <li>3.4.1. Determinación de influencias causales usando manipulación</li> <li>3.4.2. Causalidad y la condición de Markov</li> <li>3.5. Modelos de Redes Bayesianas (RBs)</li> <li>3.6. Inferencia Bayesiana (IB) con Variables Discretas</li> <li>3.7. Complejidad de la Inferencia Bayesiana (IB)</li> <li>3.8. Conclusión del capítulo</li> </ul>	71 72 77 80 84 91 92
Capítulo 4. Propuesta de un modelo de integración de técnicas Bayesianas en ALP 4.1. Introducción 4.2. Representación del tipo de personalización (TP) del alumno mediante RBs. (Modelo propuesto) 4.3. Métricas para la personalización 4.4. Conclusión del capítulo	95 95 96 128 138
Capítulo 5. Implementación práctica del modelo Bayesiano 5.1. Introducción 5.2. Valoración del modelo 5.3. Inferencia Bayesiana (IB) 5.4. Conclusión del capítulo	140 140 141 143 154
Capítulo 6. Conclusiones y líneas futuras 6.1. Introducción 6.2. Conclusiones 6.3. Líneas futuras	155 155 156 160
Glosario	162
Apéndice A. Conceptos fundamentales de RBs A1. pdf locales de una red Bayesiana A2. d-Separación A3. Ley de la probabilidad total Apéndice B. Lista de tablas usadas en el capítulo 4 B1. Objetivos (OPs) y objetos de personalización (ops) del alumno B2. Fase de los conocimientos previos B3. Fase del progreso del conocimiento B4. Fase de los objetivos y metas del profesor/alumno B5. Fase de las preferencias y experiencia de navegación	165 166 168 171 172 173 187 190 193 196
Referencias	199

# Tabla de símbolos

G	Gráfica Acíclica dirigida de la red Bayesiana
[A,B,K]	Una cadena
$[A,B.\ldots,A]$	Un ciclo
$A, B, C, \cdots, K$	Eventos
$e_1, e_2, \cdots, e_n$	Conjunto de resultados o estados posibles de un experimento
$\Omega = \left\{ e_1, e_2, \cdots, e_n \right\}$	Espacio de muestra
P(E)	Probabilidad del evento $E$ .
$(\Omega, P)$	Espacio de probabilidad
P(E F)	Probabilidad condicional de $E$ y $F$
$I_P(A,B)$	Eventos o nodos independientes
$X,Y,Z,\cdots$	Variables aleatorias o Nodos en la GAD
$x, y, z, \dots$	Valores correspondientes de las variables $X,Y,Z,\cdots$
P(X=x)	Distribución de probabilidad
P(X=x,Y=y)	Distribución de probabilidad conjunta
V	Conjunto de nodos o variables aleatorias en la gráfica
$pa_X$	Conjunto de padres de la variable X
$nd_X$	Conjunto de los nodos no descendientes
(G,P)	Red Bayesiana
$r_i$	Número de valores o estados de la variable discreta $X_i$
D	Dominio, es decir conjunto principal de datos.
n	Número de puntos en el conjunto de datos.
$S,T,U,\cdots$	Conjuntos de variables o de nodos.
$M_{X}$	Cubierta o malla de Markov de la variable X.
N(X)	Conjunto de vecinos directos de la variable $X$ en la red Bayesiana.
pa <sub>ij</sub>	Conjunto de valores para la asignación de valor $j$ de cada miembro del conjunto de padres $\mathrm{Pa_i}$ de $X_i$

# Lista de acrónimos

AAC	Ambientes artificiales compartidos
ALP	Aprendizaje en línea personalizado
ATI	Aptitude Treatment Interactions
CHAEA	Cuestionario Honey-Alonso de Estilos de Aprendizaje
CICEI	Centro de Innovación para la Sociedad de la Información
CRM	Customer Relationship Management
DNI	Documento Nacional de Identidad
EEP	European Education Paternship
ERP	Enterprise Resources Planning
FAO	Facilidad para tener acceso a un objeto de aprendizaje
fdp	Función de distribución de probabilidad
FP	Fase de personalización
GAD	Grafica Aciclica Dirigida
IA	Ingeniería Artificial
IAU	Interfases Adaptables al Usuario
ΙB	Inferencia Bayesiana
IC	Ingeniería del conocimiento
П	Infraestructuras de la información
IMES	Sistemas Educativos Multimedia Inteligentes
MA	Modelo del alumno
MB	Modelo Bayesiano
NPE	Necesidad del programa de enseñanza
OAs	Objetos de aprendizaje
OI	Objetos inteligentes
OPs	Objetivos de personalización
ops	Objetos de personalización
PAA	Para el aprendizaje activo
PAC	Para el aprendizaje colaborativo
PAs	Preferencias auditivas
PAV	Para el aprendizaje visual
PGA	Proceso global de aprendizaje
PGALP	Proceso global de aprendizaje en línea personalizado
PKs	Preferencias kinestéticas
PS	Proyecto Suricata
PVs	Preferencias Visuales
RB	Red Bayesiana
SEHP	Sistema Educativo Hipermedia Personalizado
SEI	Sistema de Enseñanza Inteligentes
SEMI	Sistema educativo multimedia inteligente
SGA	Sistema de Gestión del Aprendizaje
SGC	Sistemas de Gestión de Contenido
SGCO	Sistema de Gestión del Conocimiento
SH	Sistemas de Hipermedia
SIA	Sistemas Inteligentes de Aprendizaje

Sistemas de Información y Comunicación Sistema de reconocimiento del lenguaje Sistema tutor inteligente SICs SRL

STI

Tecnologías de la Información y Comunicación TICs

Tipo de personalización
Total Quality Management
Variable aleatoria TP TQM

v.a.

# Lista de figuras

	Pag.
Figura 2.1. Mapa mental de las categorías del e-Learning. Adaptado de Siemens (2004)	22
Figura 2.2. Ambiente de ALP. Adaptado de Hava y McManis (2006)	25
Figura 2.3. El mundo real, el alumno y el MA. (Kay, 2000)	41
Figura 3.1. Una GAD causal del TP del alumno.	66
Figura 3.2. Las cinco relaciones causales posibles entre E y A cuando éstos	
están correlacionados.	75
Figura 3.3. X y Y no son independientes si tienen una causa común oculta H.	79
Figura 3.4. Un MB modelando el TP de un alumno.	82
Figura 3.5. En (a) se muestra una RB y en (b) las probabilidades previas de las	
variables de la red.	85
Figura 3.6. Una RB que es un árbol.	88
Figura 4.1. RB modelando el TP del alumno.	103
Figura 4.2. Fdp para los conocimientos previos.	104
Figura 4.3. Fdp para los estilos de aprendizaje.	105
Figura 4.4. Fdp para los estilos cognitivos.	105
Figura 4.5. Fdp para los estilos de comunicación.	106
Figura 4.6. Fdp para los estilos de enseñanza.	107
Figura 4.7. Fdp para las técnicas de aprendizaje.	107
Figura 4.8. Fdp para las preferencias individuales.	108
Figura 4.9. Fdp para el currículo.	108
Figura 4.10. Fdp para las necesidades personales.	109
Figura 4.11. Fdp para la selección de los OAs.	110
Figura 4.12. Fdp para la presentación de los OAs.	111
Figura 4.13. Fdps para la selección de los métodos de entrada.	112
Figura 4.14. Fdp para los dispositivos de aprendizaje.	113
Figura 4.15. Fdp para la usabilidad del sistema por parte de los alumnos.	114
Figura 4.16. RB para la personalización en la fase del pre-conocimiento.	115
Figura 4.17. RB para la personalización en la fase del progreso del conocimiento.	117
Figura 4.18. RB para la personalización en la fase de los objetivos y metas	
del profesor/alumno.	119
Figura 4.19. RB para la personalización en la fase de las preferencias y experiencia de	
navegación.	126
Figura 5.1. Probabilidad previa del nodo de los conocimientos previos.	145
Figura 5.2. Tabla de probabilidad del nivel de conocimientos previos en la fase	
del pre-conocimiento.	147
Figura 5.3. Probabilidades posteriores en la etapa del pre-conocimiento.	149
Figura A1. Una GAD usada para ilustrar cadenas boqueándose y d-separaciones.	169

## Lista de tablas

	Pag.
Tabla 3.1. V.a. del MB de la Figura 3.1 y sus estados.	69
Tabla 4.1. Variables involucradas en el modelo propuesto y sus resultados posibles.	98
Tabla 4.2. Tabla de probabilidades para los OPs y ops.	114
Tabla 4.3. Probabilidades condicionales previas para el nodo de personalización	
en la fase del pre-conocimiento.	116
Tabla 4.4. Probabilidades condicionales previas para el nodo del alumno en	
la fase del pre-conocimiento.	116
Tabla 4.5. Probabilidades condicionales previas para el nodo del sistema en	
la fase del pre-conocimiento.	116
Tabla 4.6. Probabilidades condicionales para el nodo de personalización en	
la fase del progreso del conocimiento.	117
Tabla 4.7. Probabilidades condicionales previas para el nodo del alumno en la fase del	
progreso del conocimiento.	118
Tabla 4.8. Probabilidades condicionales previas para el nodo del sistema en	
la fase del progreso del conocimiento.	118
Tabla 4.9. Probabilidades condicionales para el nodo de personalización en	
la fase de los objetivos y metas del profesor/alumno.	119
Tabla 4.10. Probabilidades condicionales previas para el nodo del alumno	
en la fase de los objetivos y metas del profesor/alumno.	125
Tabla 4.11. Probabilidades condicionales previas para el nodo del sistema	
en la fase de los objetivos y metas del profesor/alumno.	125
Tabla 4.12. Probabilidades condicionales para el nodo de personalización	
en la fase de las preferencias y experiencia de navegación.	126
Tabla 4.13. Probabilidades condicionales previas para el nodo del alumno en la fase de	400
las preferencias y experiencia de navegación.	128
Tabla 4.14. Probabilidades condicionales previas para el nodo del sistema	128
en la fase de las preferencias y experiencia de navegación.	
Tabla 5.1. Perfiles de personalización posibles en la fase de los	150
conocimientos previos y sus probabilidades.	150
Tabla B1. Nivel de conocimientos previos de 45 alumnos.	173
Tabla B2. Distribuciones de frecuencia de la Tabla B1.	173
Tabla B3. Estilos de aprendizaje de 45 alumnos.	174 174
Tabla B4. Distribuciones de frecuencia de la Tabla B3.	174
<b>Tabla B5.</b> Estilos cognitivos de 45 alumnos. <b>Tabla B6.</b> Distribuciones de frecuencia de la Tabla B5.	175
Tabla B6. Distribuciones de frecuencia de la Tabla B5.         Tabla B7. Estilos de comunicación de 45 alumnos.	175
Tabla B8. Distribuciones de frecuencia de la Tabla B7.	176
	177
<b>Tabla B9.</b> Estilo de enseñanza preferido de 45 alumnos. <b>Tabla B10.</b> Distribuciones de frecuencia de la Tabla B9.	177
<b>Tabla B11.</b> Técnicas de aprendizaje de 45 alumnos	
Tabla B11. Technicas de aprendizaje de 43 aldifinos         Tabla B12. Distribuciones de frecuencia de la Tabla B11.	178
Tabla B13. Preferencias individuales de 45 alumnos.	178 179
Tabla B13. Preferencias individuales de 45 alumnos.           Tabla B14. Distribuciones de frecuencia de la Tabla B13.	179
Tabla B15. Currículo de 45 alumnos.	180
Tabla B15. Curriculo de 45 alumnos.         Tabla B16. Distribuciones de frecuencia de la Tabla B15.	180
<b>Tabla B17.</b> Necesidades personales de 45 alumnos.	181
Tabla B17. Necesidades personales de 45 alumnos.           Tabla B18. Distribuciones de frecuencia de la Tabla B17.	181
<b>Tabla B19.</b> Resultados de una muestra de 45 casos del motivo de la	101
rapia profitacios de una muestra de 40 Casos del Molivo de la	

# Lista de tablas (continuación)

			Pag
		selección de los objetos de aprendizaje.	182
Tabla	B20.	Distribuciones de frecuencia de la Tabla B19.	182
Tabla	B21.	Preferencias de la presentación de los objetos de aprendizaje.	183
Tabla	B22.	Distribuciones de frecuencia de la Tabla B21.	183
Tabla	B23.	Resultados de una muestra de 45 casos en relación a la	
		selección de los métodos de entrada.	184
Tabla	B24.	Distribuciones de frecuencia de la Tabla B23.	184
Tabla	B25.	Resultados de una muestra de 45 casos en relación a los	
		dispositivos de aprendizaje.	185
Tabla	B26.	Distribuciones de frecuencia de la Tabla B25.	185
Tabla	B27.	Tipo de usabilidad del sistema de software por parte del alumno.	186
		Distribuciones de frecuencia de la Tabla B27.	186
		Requerimiento de adecuación del sistema en la fase de	
		los conocimientos previos.	187
Tabla	B30.	Distribuciones de frecuencia de la Tabla B29.	187
		Tipo de adecuación del sistema preferida por el alumno en la	
		fase de los conocimientos previos.	188
Tabla	B32.	Distribuciones de frecuencia de la Tabla B31.	188
		Requerimiento de capacitación del alumno para usar el sistema	
		en la fase de los conocimientos previos.	189
Tabla	B34.	Distribuciones de frecuencia de la Tabla B33.	189
		Requerimiento de adecuación del sistema en la fase del progreso	
		del conocimiento.	190
Tabla	B36.	Distribuciones de frecuencia de la Tabla B35.	190
Tabla	B37.	Tipo de adecuación del sistema preferida por el alumno en la	
		fase del progreso del conocimiento.	191
Tabla	B38.	Distribuciones de frecuencia de la Tabla B37.	191
Tabla	B39.	Requerimiento de capacitación del alumno para usar el sistema	
		en la fase del progreso del conocimiento.	192
Tabla	B40.	Distribuciones de frecuencia de la Tabla B39.	192
Tabla	B41.	Requerimiento de adecuación del sistema en la fase de los objetivos	
		y metas del profesor/alumno.	193
Tabla	B42.	Distribuciones de frecuencia de la Tabla B41.	193
Tabla	B43.	Tipo de adecuación del sistema preferida por el alumno en la fase	
		de los objetivos y metas del profesor/alumno.	194
		Distribuciones de frecuencia de la Tabla B43.	194
Tabla	B45.	Requerimiento de capacitación del alumno para usar el sistema	
		en la fase de los objetivos y metas del profesor/alumno.	195
		Distribuciones de frecuencia de la Tabla B45.	195
Tabla	B47.	Requerimiento de adecuación del sistema en la fase	
		de las preferencias y experiencia de navegación.	196
		Distribuciones de frecuencia de la Tabla B47.	196
Tabla	B49.	Tipo de adecuación del sistema preferida por el alumno en la fase	
		de las preferencias y experiencia de navegación.	197
		Distribuciones de frecuencia de la Tabla B49.	197
rabla	B51.	Requerimiento de capacitación del alumno para usar el sistema	
		en la fase de las preferencias y experiencia de navegación.	198
Tabla	B52.	Distribuciones de frecuencia de la Tabla B50.	198

## Capítulo 1

## Introducción

Resumen. En este capítulo resaltamos la necesidad de diseñar un modelo matemático basado en redes Bayesianas (RBs), que ayude a optimizar el Proceso Global de Aprendizaje en Línea Personalizado (PGALP) de los usuarios de la plataforma Suricata (Marrero, 2005), dentro del contexto del proyecto Suricata (PS) (Rubio et al., 2004) del Centro de Innovación para la Sociedad de la Información (CICEI, 2007), y poder ofrecer a los usuarios, una retroalimentación personalizada durante su proceso global de aprendizaje (PGA). Proponemos investigar las relaciones de causa-efecto existentes entre los objetos de personalización (ops) y objetivos de personalización (OPs), y las fases de personalización con el propósito de compilarlas en una RB que pueda usarse para realizar un diagnóstico y/o una retroalimentación en base al estado actual de conocimientos del alumno, sus necesidades reales y sus preferencias personales, Las fases de personalización tienen a su vez, un efecto directo en: 1) la capacitación del estudiante para que éste use, de manera óptima, el sistema de aprendizaje en línea, y 2) la adecuación del sistema de aprendizaje en línea a las necesidades reales del alumno.

La nueva economía del conocimiento impone otros requerimientos dentro de la organización con respecto al proceso de aprendizaje. Con ella surge el concepto de aprendizaje en función de las necesidades reales de cada persona, se percibe la falta de un aprendizaje permanente para mantener la posición o status que

posee y aparecen nuevos perfiles profesionales, estos son los llamados trabajadores del conocimiento (k-workers). Dentro de la sociedad creada por la nueva economía, Ducker (2002), identifica dos tipos de trabajadores, los trabajadores del conocimiento y los trabajadores de servicios. Define a los trabajadores del conocimiento como "ejecutivos instruidos que saben aplicar sus conocimientos a usos productivos", y argumenta:

"Todos los trabajadores del conocimiento pueden trabajar únicamente porque hay una organización. Por este aspecto, son dependientes. Pero al mismo tiempo son propietarios de los "medios de producción", es decir, su conocimiento. Esto implica, que es el individuo el que decide en gran medida lo que él mismo contribuye y de qué magnitud puede o debe ser el rendimiento de su conocimiento".

Comenta también, que es necesario, que todos los miembros actúen como responsables tomadores de decisiones. Todos los miembros deben verse a sí mismos como ejecutivos. El deber de la administración en la organización no es hacer a todos jefes sino hacer que todos contribuyan.

Por otro lado, de acuerdo con Ducker, (2002), la Sociedad del Conocimiento exige "trabajadores del conocimiento" y éstos tienen como característica general, el deber de promover la práctica de la "educación a lo largo de la vida" y de generar el principio de que el conocimiento -constantemente recreado- es un valor de uso continuo en el trabajo cotidiano, superior a la adquisición de un "título universitario". Micheli (2001), comenta que este tipo de trabajadores tienen ingresos variables, no están ligados a una organización y sus carreras no son

lineales ni sometidas a un principio de jerarquía. Trabajan en equipos y en redes, y esta parte de su desempeño es crucial. Para estos trabajadores, los títulos acerca de su nivel y campo de estudios no son importantes, sino que lo es más su capacidad de usar de modo efectivo y creativo su conocimiento y habilidades. De acuerdo con la Gartner Research (2001), de alguna manera, todos somos trabajadores del conocimiento. Sin embargo, la clase de conocimiento que se genera o se aplica, el alcance de dicho conocimiento, el impacto potencial así como el valor que ese conocimiento tiene para la organización, es lo que nos permite diferenciar entre los distintos trabajadores del conocimiento.

El trabajo del conocimiento puede ser visto a través de un modelo que abarca tres aplicaciones primarias de conocimiento:

- Trabajo de conocimiento basado en tareas, el cual enfatiza los procesos operativos.
- Trabajo de conocimiento basado en habilidades, el cual enfatiza áreas de destreza bien definidas y bien prescritas.
- Trabajo de conocimiento enfocado en la innovación, el cual es principalmente desordenado, tácito, altamente interpretativo e improvisado.

De esta manera, partiendo de un modelo tradicional de docencia en una estructura tradicional, se llega a los nuevos paradigmas de docencia y aprendizaje que tiene como característica el estar centrado en el alumno, tener nuevas formas de interacción y manipular nuevos contextos formativos. Existen muchas

componentes importantes en el estudiante tales como conocimientos previos, estilo de aprendizaje, estilo cognitivo, currículo, preferencias y necesidades personales, etc., las cuales tienen influencia en el aprendizaje, y pueden ser recopiladas para incorporarse en un modelo matemático que ayude a optimizar el PGA.

Dentro del contexto de la economía del conocimiento, han surgido nuevos estilos de aprendizaje y de enseñanza tal como e-Learning, que es el aprendizaje por Internet/intranet y ALP que es el aprendizaje por Internet/intranet personalizado. Uno de los objetivos de este último estilo, es hacer llegar el conocimiento a la hora que sea y en dónde sea y está orientado a explotar adecuadamente las cualidades y potencialidades individuales de cada alumno, usando las facilidades de comunicación mediante las redes y las diversas formas de presentar los contenidos.

Por otro lado, el volumen de información no estructurada ha crecido exponencialmente en los últimos años, y esta diversidad ha hecho necesaria la evolución de los Sistemas de Gestión de Contenido (SGC). Su uso se ha hecho indispensable para evitar el caos en los sistemas de Información y Comunicación (SIC). Del mismo modo, los Sistemas de Gestión del Conocimiento (SGCO) son de gran utilidad para llevar a cabo uno de los objetivos principales de la Gestión del Conocimiento que es la de maximizar el aprendizaje organizacional con miras a incrementar la competitividad global. Para apoyar el trabajo de implementación de estos sistemas, se han considerado una serie de herramientas: que van desde

herramientas informáticas (sistema ERP-Enterprise Resources Planning, Datawarehouse, Dataminig, y otros) herramientas de comunicación (Groupware, Workflow, Call Center) herramientas de mejoras continuas (TQM) opciones de Internet, intranet y extranet y herramientas especialmente diseñadas para este propósito, tal como los mapas conceptuales, tablero de comando y algunas herramientas para la gestión documental, compatibles con las tecnologías de Internet/intranet, como los llamados agentes inteligentes de búsqueda en Internet, redes neuronales y Customer Relationship Management (CRM) o gestión de las relaciones con el cliente, entre otras.

Ahora bien, si el desarrollo tecnológico y la utilización de Internet/intranet han transformado la economía y la sociedad, y los sistemas tienden a la utilización de la tecnología Web, integrándose en una cadena de valor del conocimiento o de los intangibles, nada más lógico que explotemos la posibilidad de diseñar un modelo matemático basado en RBs que ayude a optimizar el PGA, partiendo de un modelo tradicional de docencia en una estructura tradicional y considerando los nuevos paradigmas de docencia y aprendizaje, que tengan como característica: el estar centrado en el alumno, tener nuevas formas de interacción y manipular nuevos contextos formativos.

#### 1.1. Motivación

La modalidad actual del aprendizaje en línea, es el aprendizaje en línea personalizado (ALP). Según Martínez (2005), este nuevo estilo de aprendizaje es importante porque:

- 1) faculta a los alumnos a seleccionar sus componentes modulares para construir a la medida sus ambientes de aprendizaje centrados en ellos y,
- 2) los habilita para ofrecer soluciones flexibles que dinámicamente adaptan el contenido para adecuar necesidades de aprendizaje individuales en tiempo real.

De acuerdo con Eklund y Zeiliger (1996), la experiencia nos muestra que la mejor manera de mejorar u optimizar el aprendizaje, es respondiendo claramente a las necesidades identificadas y, a las soluciones articuladas. La tecnología deductiva ofrece una solución mediante el uso de la tecnología existente para mejorar el aprendizaje. En un paradigma de mercado abierto, los Sistemas Inteligentes de Aprendizaje (SIA) evidentemente tienen un impacto positivo en la accesibilidad, productividad y en los retos de calidad que ahora enfrenta la educación global de entrenamiento. Dichos retos se manifiestan en la siguiente frase de Eklund y Zeiliger:

"Dando a la Web inteligencia: la habilidad para "entender" al usuario, hacer a la medida la información y presentación, y ofrecer dinámicamente apoyo de navegación; puede ser el siguiente salto significativo de un medio popular el cual es un mecanismo valioso de enseñanza en su propio derecho"

Por otro lado, el recurso para crear riqueza en la economía actual se centra en la Gestión del Conocimiento y, no podemos hablar de conocimiento sin considerar el aprendizaje, éste juega un papel fundamental en el desarrollo del conocimiento. Las empresas y personas necesitan aprender más rápido, mejor y de la forma menos costosa para poder permanecer en la llamada "economía del conocimiento". Las organizaciones y personas deben estar rodeadas de diversas tecnologías de aprendizaje para proveerse del conocimiento y aplicarlo. Mediante el constante aprendizaje se logra un conocimiento consistente.

Un concepto muy importante que enlaza al aprendizaje en línea con el conocimiento individual u organizacional es la **medición**, la carencia de una medida eficiente y eficaz de la existencia del capital humano y su crecimiento a través del conocimiento, puede ocasionar altibajos en el desempeño personal y empresarial debido a que el mercado requiere cierto conocimiento e indicadores para medir a las organizaciones individuales. Si no existen estándares de medición confiables, que permitan medir el retorno de la inversión del aprendizaje en línea y de las intervenciones de rendimiento del capital humano, el mercado del conocimiento será sumamente volátil. Contar con estos indicadores es importante, no sólo para dejar constancia de nuestra responsabilidad de agudizar el margen competitivo de nuestras corporaciones, sino que también puede revelar los componentes del valor agregado de nuestra transmisión de conocimientos y procesos de creación.

En base a lo antes expuesto, nos surge la motivación de estructurar un modelo Bayesiano (MB) del estudiante, que integre las potencialidades y cualidades del

alumno y que sirva para optimizar su PGA de acuerdo a las necesidades reales. Para llevar a cabo lo anterior, existen muchas componentes importantes o métricas de aprendizaje del estudiante tales como conocimientos previos, estilo de aprendizaje, estilo cognitivo, currículo, preferencias y necesidades personales, etc. las cuales tienen influencia en el aprendizaje y que pueden ser recopiladas para incorporarse en una modelo matemático que ayude a optimizar el proceso de enseñanza-aprendizaje del alumno.

A continuación, describimos el ámbito donde queda enmarcado nuestro trabajo de investigación.

### 1.2. El Proyecto Suricata (PS)

Con la llegada del aprendizaje en línea, las organizaciones están implementando sistemas o procesos comerciales, con el propósito de hacer posible los derechos a la información, entrega, almacenaje y gestión de las ofertas de aprendizaje por Internet a estudiantes tanto internos como externos. El PS (Rubio et al., 2004) es uno de estos procesos que se enmarca dentro de los requerimientos de este nuevo recurso en la cual, el principal producto es el conocimiento y el "motor" principal el Internet. De acuerdo con Marrero et al., (2006), el centro de I+D+i CICEI (2007) de la Universidad de Las Palmas de Gran Canaria (ULPGC, 2007) ha desarrollado el modelo Suricata implementándolo en un entorno de trabajo en

colaboración llamado Idesktop. El objetivo del modelo consiste en "desarrollar métodos y herramientas de apoyo a los trabajadores del conocimiento, en su vertiente personal y corporativa, que les permita aumentar su productividad y capacidad de innovación, en el contexto de una estrategia global de gestión del conocimiento orientada a procesos". La materialización de los conceptos que suponen el modelo en la plataforma de trabajo, es lo que llamamos plataforma Suricata y se describe en (Marrero, 2006).

De acuerdo con Rubio et al., (2004), el PS es un modelo en red de innovación organizacional, basado en el trabajo en las comunidades virtuales y en el uso de tecnologías de la información, como una respuesta de adecuación al creciente proceso de virtualización social y de las organizaciones, que contribuye al desarrollo competitivo y socialmente sostenible. El PS, debido a los acelerados avances tecnológicos y a las necesidades de los usuarios, actualmente se encuentra en una segunda fase como consecuencia del proceso natural de evolución propio de la tecnología actual. Como uno de los frutos de la primera fase del proyecto, la cual es importante destacar debido a que en él se basa la continuidad antes mencionada, es el escritorio IDESKTOP (intranet colaborativa del Gobierno de Canarias, basado en ORACLE) cuya evolución convergerá en la creación de la plataforma Suricata. Para más detalles sobre el PS y la plataforma Suricata, ver Rubio et al., (2004); Marrero et al., (2005) y Marrero et al., (2006). En la sección 1.3 siguiente, mostramos el contexto donde queda enmarcado nuestro trabajo de investigación.

#### 1.3. Situación de la tesis en el Proyecto Suricata (PS)

Nuestro trabajo de investigación se ubica en la sección e-Learning de la segunda etapa del PS, donde uno de los objetivos principales es: desarrollar un Sistema de Gestión del Aprendizaje (SGA) que permita mejorar el aprendizaje, adaptando el proceso al perfil de cada estudiante.

En el contexto del PS, el PGALP se ha dividido en tres etapas:

- 1) Etapa previa al proceso de aprendizaje: aquí se determina el estilo predominante de aprendizaje de cada alumno por medio de la aplicación del Cuestionario Honey-Alonso de Estilos de Aprendizaje (CHAEA) (Alonso et al., 1999; Rubio et al., 2004; Rubio y Delgado 2004), y el nivel de conocimientos previos que se detecta mediante la aplicación de una prueba específica al inicio de cada curso o módulo,
- 2) Etapa del proceso de aprendizaje: aquí se confrontan los objetivos y las actividades particulares de aprendizaje de cada alumno y se seleccionan y/o se diseñan las actividades que permiten lograr un aprendizaje eficiente y eficaz en el alumno.
- 3) Etapa Posterior al proceso de aprendizaje: aquí se evalúan los resultados de las actividades de aprendizaje realizadas durante la segunda etapa (evaluación del profesor y valoración del estudiante).

Como se mencionó antes, existen muchas componentes importantes sobre el estudiante tales como, preferencias personales, necesidades individuales, usabilidad, objetos de presentación, selección de los objetos de aprendizaje

(OAs), dispositivos, selección de métodos de entrada, estilos cognitivos, currículo, etc. que pueden tener influencia en la adquisición de conocimientos, y que podrían incorporarse dentro del marco del proceso arriba mencionado con el propósito de obtener el máximo de indicios sobre el estudiante e integrarlos en un modelo matemático que ayude a optimizar el proceso de aprendizaje del alumno. Basados en lo antes expuesto, nos surge la siguiente idea como proyecto de investigación:

Diseñar un modelo matemático que sirva para proporcionar retroalimentación personalizada al alumno durante su aprendizaje, que contemple las tres etapas arriba mencionadas, y ayude a optimizar el proceso de aprendizaje de los usuarios de la plataforma Suricata.

Dicho proyecto de investigación conlleva a la justificación y planteamiento que se hace en la sección 1.4 siguiente.

### 1.4. Justificación y planteamiento del problema

De acuerdo con la European Education Paternship (EEP, 2004), existen personas interesadas en cómo la tecnología puede mejorar u optimizar los métodos de aprendizaje, y en saber cómo se pueden medir estos efectos. Por otro lado, un argumento que justifica el hecho de llevar a cabo nuestra investigación, dentro del

PS, es que no existe un procedimiento específico para modelar al alumno, por lo que pensamos que puede ser posible tal modelación por medio de las RBs con el propósito de perfeccionar el proceso de aprendizaje contemplado dentro PS y optimizar el PGALP. Para lograr lo anterior, es necesario recopilar métricas de aprendizaje (ver glosario). Muchos estudiantes y profesionales regularmente no miden los esfuerzos que realizan en sus prácticas escolares y/o profesionales, debido ya sea al desconocimiento de alguna técnica, a la carga cognitiva, a la falta de tiempo o de ganas. Por lo tanto, no conocen su grado de efectividad, eficiencia y de satisfacción. También, es muy posible que no conozcan las métricas de usabilidad de los SIC que ellos manejan. La introducción de las métricas de aprendizaje en los sistemas de aprendizaje y de enseñanza actuales puede generar investigaciones pedagógicas y psicológicas que mejorarían notablemente los sistemas actuales.

Por otro lado, Siemens (2002), comenta que las oportunidades que las Tecnologías de la Información y Comunicación (TICs) ofrecen para tener un aprendizaje extendido y personalizado, posibilita a los estudiantes para tomar una mayor responsabilidad de su aprendizaje. Esto, combinado con los diferentes mecanismos por medio de los cuales las TIC añaden valor al aprendizaje y a la enseñanza, es un factor principal para producir grandes mejoramientos en el aprendizaje, que son observados en las escuelas y colegios que han implementado el uso de las TICs. Para posibilitar al alumno a tomar una gran responsabilidad de su aprendizaje, (si ésta es cuestión de incrementar ligeramente la concentración dentro del aula, o de un aprendizaje completamente autónomo

fuera de la misma), la enseñanza necesita ser más explícita y flexible. Los alumnos necesitan ver su progreso. Los profesores necesitan usar la información de los métodos de aprendizaje-aprendizaje y del progreso de sus estudiantes para poder ayudarlos.

Aunque el uso de las TICs ocasiona que el profesor realice más trabajo en el ordenador, éstas pueden también capturar la información del proceso de aprendizaje de maneras que no habían sido posible antes. Los datos pueden llegan a ser accesibles de una gran variedad de sistemas, softwares y contenidos utilizados para el aprendizaje (ver sección 2.2 y secciones 3.1 y 3.5). El problema es, ¿cómo estos datos pueden ser capturados y analizados efectivamente para que los alumnos y profesores puedan utilizarlos?

Por lo tanto, en nuestro trabajo de tesis abordamos el siguiente cuestionamiento como un problema abierto de investigación:

¿Es posible el diseño de un modelo matemático del estudiante, que realice un diagnóstico de la situación actual de éste, basado en sus necesidades reales, con el propósito de proponer al alumno una alternativa o estrategia que optimice su proceso de aprendizaje?

El diseño de este modelo constituye nuestra principal aportación y podría ayudar, en gran medida, a los usuarios de la plataforma Suricata y en general a usuarios de cualquier sistema de enseñanza basado en el aprendizaje en línea.

Finalmente, los antecedentes de nuestra investigación se mencionan en la revisión del estado del arte que se da en el capítulo 2.

A continuación, en la sección 1.5 siguiente, damos las razones de usar las RBs.

#### 1.5. Razón del uso de modelos y RBs

En esta sección, presentamos los argumentos que justifican el hecho de haber tomado la línea de investigación de los modelos probabilisticos y en especial las RBs.

#### 1.5.1. ¿Por qué modelos?

Desde tiempos ancestrales, la gente ha utilizado los modelos como una manera de afrontar la variabilidad y la complejidad de su medio ambiente. Esto se debe a que un modelo puede ser usado en situaciones diferentes de las de donde se generó. Por ejemplo, un modelo para estimar el crecimiento de una población puede ser utilizado para calcular el valor futuro de una suma de dinero. En este contexto, un modelo es en efecto un "patrón" que puede ser reutilizado mientras que éste se adapte adecuadamente a los requerimientos de nuestro entorno.

En el contexto de los sistemas expertos, los modelos pueden usarse para ocultar complejidad o simplificar el análisis. Por ejemplo, para determinar el TP del

alumno, se ocultan los efectos de cómo se determina el perfil del estudiante. Este bajo nivel del proceso puede repetirse en niveles de detalles creciente, teóricamente hasta las partículas más elementales de las variables que participan en la operación de determinación del perfil. Utilizando un modelo de alto nivel ocultaría toda esta complejidad empleando una relación simple de causa-efecto que involucraría únicamente los conocimientos previos, el estilo de aprendizaje, las técnicas preferidas de aprendizaje y el TP del alumno. Es decir, no tomaría en cuenta la manera en que se determina el perfil.

#### 1.5.2. ¿Por qué las RBs?

Para que un sistema experto pueda razonar bajo incertidumbre, se le debe dotar de ciertas capacidades. Muchos han sido los enfoques para incorporar incertidumbre, en los sistemas expertos, teniendo todos sus detractores y defensores. Algunos de estos enfoques son:

- Factores de certeza.
- Teoría matemática de la evidencia (Dempster-Shafer).
- Lógica no monótona.
- Lógica difusa.
- Teoría de probabilidad.

En años recientes, ha habido un notable avance en el uso de la teoría de probabilidad para desarrollar metodos que manejen la incertidumbre. Uno de estos métodos, representa el conocimiento incierto por medio de una gráfica, que ha su vez describe relaciones de dependencia-independencia condicional (Pearl, 1988; Edwards, 1995; Verma y Pearl. 1990a). Estos modelos son conocidos por diferentes nombres: redes causales, redes probabilistas, RBs, diagramas de influencia, modelos gráficos y redes de creencia El término que utilizaremos en esta tesis es el de RBs.

Los motivos principales de haber elegido las RBs se deben principalmente a:

- 1) La necesidad de un método casuístico de modelado del PGA para los usuarios de la plataforma Suricata:
- 2) La teoría de probabilidad es una base fuerte para la toma de decisiones bajo incertidumbre y de gran aceptación en ingeniería artificial (IA).

Además, las RBs cuando se usan junto con técnicas estadísticas, tienen las ventajas siguientes para el análisis de datos:

- 1) Codifican dependencias entre todas las variables y manipulan fácilmente situaciones donde hace falta algunas entradas de datos.
- Son útiles para el aprendizaje de relaciones causales, y por lo tanto para obtener entendimiento de un dominio problemático y pronosticar las consecuencias de intervención.
- 3) Tienen tanto semánticas probabilísticas como causales y utilizan una representación ideal para combinar conocimientos previos (que llegan frecuentemente en forma causal) y datos.

4) Los métodos estadísticos Bayesianos en conjunción con las RBs ofrecen una técnica eficiente basada en principios para evitar el sobre-ajuste de datos.

Finalmente, estamos interesados en derivar las relaciones de causa-efecto de los datos estadísticos con el propósito de optimizar los métodos de enseñanza y de alguna forma medir sus efectos. Para llevar a cabo lo anterior, nosotros proponemos un modelo de RBs para afinar el PGALP. Dicho modelo puede ser aplicable en las siguientes escalas:

- a) en el nivel en que se presenta el material, las ayudas o la retroalimentación.
- b) en la dificultad de los problemas propuestos y/o
- c) en la selección de la estrategia instructora más adecuada según sus capacidades, habilidades, necesidades y preferencias personales, estilos de aprendizaje preferidos, estilo cognitivo y conocimientos previos.

No obstante que pueden utilizarse muchas clases de modelos para representar dominios inciertos, (por ejemplo, árboles de decisión (Hossein, 2006), redes neuronales (Daza, 2005), combinación de funciones básicas (Hong et al., 2006), redes de Markov (Clemente et al., 2002), sólo en la literatura de RBs encontramos motivaciones para representar y aprender relaciones causales dirigidas. Es en este hecho en el cual desarrollamos nuestra última meta de investigación que da pie a los siguientes objetivos de la tesis.

#### 1.6. Objetivos

El objetivo general de este trabajo es:

 Diseñar un MB, que ayude a optimizar el PGA del alumno, dentro del contexto del aprendizaje en línea personalizado (ALP) dentro del Proyecto Suricata (PS).

Los objetivos específicos son:

- Investigar las técnicas de la Inferencia Bayesiana (IB) y la estructura de los
   MB como redes que aprenden.
- Conocer las diferentes técnicas de razonamiento aproximado y su aplicación al problema del modelado del alumno.
- Investigar los diferentes modelos del alumno que inciden en el desempeño del aprendizaje.
- Buscar alternativas de simplificar la aplicación del modelo seleccionado.
- Conocer los diferentes sistemas de ALP. En particular, los que están basados en RBs.
- Proponer un modelo de integración de técnicas Bayesianas en el ALP.
- Validar a través de simulación el modelo propuesto.

#### 1.7. Aportaciones

Nuestra investigación deja las siguientes aportaciones:

- Diseño de un MB para optimizar el PGA del alumno.
- Una lista de ops y OPs que pueden ser usados para mejorar el proceso de aprendizaje del alumno.
- Una serie de herramientas (Tests y encuestas) para determinar cualidades, potencialidades y preferencias personales del alumno.
- Un conjunto de datos estadísticos que pueden ser usados para inicializar el modelo propuesto.
- Una colección de fdps locales que pueden ser usadas para diagnosticar el TP del alumno.

Todo lo anterior, constituye un cúmulo de información que puede ser utilizada en la realización de nuevas investigaciones y en líneas futuras de investigación.

#### 1.8. Panorama general de los capítulos subsecuentes

El resto del contenido de esta tesis está estructurado como sigue:

En el capítulo 2, presentamos el estado del arte de los sistemas de aprendizaje por Internet/intranet que son referidos como e-Learning, y ALP. Analizamos las nuevas direcciones y posibilidades de estos sistemas de aprendizaje. Hacemos una recopilación de los ops y OPs que usamos en la estructuración de nuestro MB

del capítulo 4, cuyo objetivo es optimizar el PGALP de los usuarios de la plataforma Suricata en cada una de las fases del conocimiento consideradas en la sección e-Learning del PS. Además, hacemos un estudio general del modelado del alumno y analizamos las técnicas que se usan para construir un modelo del alumno (MA).

En el capítulo 3, presentamos los aspectos teóricos para poder llevar a cabo la construcción de nuestro MB del capítulo 4. Asimismo, realizamos las relaciones de causa y efecto usando los OAs, ops y OPs para determinar el TP del alumno, estudiamos los modelos de RBs, la importancia y la aplicación de estos, Examinamos un método para realizar IB con variables discretas. En el capítulo 4 desarrollamos nuestra propuesta de MB que diagnostica el TP del alumno, usando los ops y OPs. Presentamos las fdps para cada una de las variables independientes que intervienen en nuestro modelo y mencionamos las limitaciones del mismo. En el capítulo 5, mostramos un caso casuístico, considerando la FP de los conocimientos previos, usando los ops y OPs que tienen un efecto directo en la FP mencionada, con el propósito de ilustrar el método propuesto del capítulo 4 y dar la valoración requerida a nuestro modelo. Finalmente, las conclusiones principales y líneas futuras de investigación se presentan en el capítulo 6.

## Capítulo 2

## Aprendizaje en línea

Resumen. En este capítulo, presentamos el estado del arte de los sistemas de aprendizaje por Internet/intranet conocidos como e-Learning y Aprendizaje en Línea Personalizado. Analizamos las nuevas direcciones y posibilidades de estos sistemas, y hacemos una recopilación de los objetos y objetivos de personalización que usamos en la estructuración de nuestro modelo Bayesiano del capítulo 4, Además, hacemos un estudio general del modelado del alumno y analizamos las técnicas que se usan para construir un modelo del alumno.

#### 2.1. e-Learning

Según Wilson (2001), en la actualidad, la expresión e-Learning abarca una serie de términos que se mezclan entre sí, sin diferenciación aparente. Se habla indistintamente de enseñanza virtual, de universidades y aulas virtuales, y de cursos en línea. e-Learning se define como el uso de las tecnologías multimedia e hipermedia para desarrollar y mejorar nuevas estrategias de aprendizaje. En concreto, e-Learning supone la utilización de herramientas informáticas, tales como CD-ROMs, Internet, intranet, o dispositivos móviles para llevar a cabo una

labor docente y hacerla accesible a un gran número de gente. De acuerdo con Fernández, (2004), la acepción más común para e-Learning es la enseñanza a través de Internet e intranet, donde el conocimiento llega a través de cursos en línea, correos electrónicos, aprendizaje computadorizado, de libros electrónicos, CD-ROMs, simulación virtual, y de otro tipo de software (wikis, foros y otros espacios colaborativos). Dentro del e-Learning existen varias categorías de aprendizaje. La Figura 2.1 presenta un mapa mental donde se resume dichas categorías, dependiendo si el aprendizaje es en el aula, en línea, combinado o implantado.

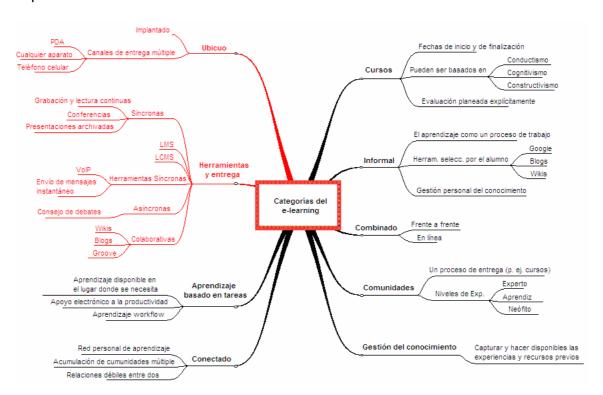


Figura 2.1. Mapa mental de las categorías del e-Learning. Adaptado de Siemens (2004)

Dentro del contexto de esta tesis, usamos el término e-Learning como un sistema de tele-formación (Rosenberg, 2001; Fernández, 2004), que usa las infraestructuras actuales de Internet e intranet, convirtiendo parte de éstas en un medio que permite la entrega de acciones formativas no presénciales, evidentemente sin la necesidad de que las partes involucradas coincidan en espacio y tiempo, proporcionando un abanico de soluciones que aúnan la adquisición de conocimiento, habilidades y capacidades. Una encuesta reciente sobre e-Learning de la Nacional Survey of Student Engagement (Stuckey y González, 2007), indica que un 96% de los estudiantes de universidades considera que e-Learning es más conveniente por su horario disponible, un 77% porque puede trabajar a su ritmo, un 70% porque le gusta aprender por si mismo, un 34% porque las universidades cercanas no tienen los cursos que él necesita.

Existen diversas plataformas de tele-formación de código abierto, que pueden utilizarse para hacer llegar la educación en línea a los alumnos mediante las modalidades de enseñanza-aprendizaje arriba mencionadas. Por ejemplo, Moodle (2006) que es la plataforma más conocida y en donde se basará la plataforma Suricata, ATutor (2006), Bazaar (2006), Claroline (2006), Dokeos (2006), Eledge (2006), Genesha (2006), Llias (2006), LRN (2006), Sakai (2006), Segue (2006), OpenUSS (2006), y Spaghetti Learning (2006) entre otras. Para ver una evaluación de estas herramientas consultar Plataformas (2006). No obstante la gran funcionalidad de algunas de ellas, éstas carecen de un sistema para modelar al alumno.

Con todo lo anterior, el e-Learning se perfila como solución a los problemas a los que la enseñanza tradicional no puede dar respuesta. Sin embargo, por sí sólo no garantiza una educación de mayor calidad ni un mayor rendimiento en el aprendizaje.

A continuación, abordamos una variedad del sistema e-Learning referido en esta tesis como ALP (también conocido en la literatura como Adaptive e-Learning).

# 2.2. Aprendizaje en línea personalizado (ALP)

De acuerdo con Cronbach y Snow, (1977), en la década de los 70s se publicaron los primeros resultados de investigaciones relacionadas en cómo afectan las diferentes actitudes y aptitudes de las personas en su aprendizaje, y en cómo los ambientes de aprendizaje requieren adaptarse a estas diferentes aptitudes individuales para optimizar los resultados del aprendizaje. Shute, (2003), en un artículo describe cómo este concepto de las Interacciones del Tratamiento de Aptitud (ATI, Aptitude Treatment Interactions) puede usarse para crear métodos de ALP en lugar de las técnicas de aprendizaje "que se ajustan a todos".

Conforme a Tapia et al., (2005), el ALP es un sistema de enseñanza que adapta la selección y presentación de contenidos de una manera individual al estudiante basándose en su nivel de estudios, sus necesidades, su estilo de aprendizaje, sus conocimientos previos y sus preferencias. En la Figura 2.2 se muestran los

beneficios de este nuevo ambiente de enseñanza-aprendizaje en el cual, el principal producto es el conocimiento y el "motor" principal el Internet/intranet.



Figura 2.2. Ambiente de ALP. Adaptado de Hava y McManis (2006)

Según Wilson (2003), este sistema de enseñaza es importante porque faculta a los alumnos para seleccionar los componentes modulares, para así construir a la medida los ambientes de aprendizaje centrados en las necesidades de ellos mismos. Además, los habilita para dar soluciones flexibles que dinámicamente se adaptan al contenido para adecuar las necesidades individuales de aprendizaje en tiempo real. La experiencia ha demostrado que la mejor manera de optimizar el aprendizaje es respondiendo claramente a las necesidades identificadas y a las soluciones articuladas, pensamos que la tecnología de inferencia es una gran alternativa para aprovechar sus métodos, y mejorar el aprendizaje del alumno. Además, los SIA tienen un impacto positivo en la accesibilidad, productividad y en

los retos de calidad que actualmente enfrenta la educación global y el entrenamiento. Cronbach y Snow (1977), desarrollaron los conceptos de un motor adaptable, que pueden usarse para construir los ambientes de aprendizaje en línea en los que la necesidad del aprendizaje, ya no sea confinada para elaborar material accesible de aprendizaje, sino que se pueda enfocar en mejorar el aprendizaje mediante la adaptación de la enseñanza y el contenido para satisfacer a los estudiantes autodidactas.

De acuerdo con Smith (2004), los nuevos programas del ALP, se están destacando por su incursión a nuevas áreas, muchas de las cuales involucran un gran número de participantes en el ambiente del aprendizaje distribuido por Internet o intranet. Por ejemplo, los grupos militares de E.E.U.U., utilizan los sistemas adaptables ingeniosos para ayudar a los estudiantes a practicar y adaptar la manera en que ellos adquieren las aptitudes, las habilidades en la toma de decisiones y la conciencia cognitiva de sí mismo. Wilson (2003), detalla algunos ejemplos específicos en su artículo, éstos incluyen el uso del ALP en sistemas distribuidos, con el propósito de preparar grupos militares para combatir disturbios urbanos. Conforme a Shute, (2003), los programadores en el ámbito del ALP, particularmente en aspectos aplicados de inteligencia artificial, actualmente estudian cómo los nuevos algoritmos pueden aplicarse a los ambientes de aprendizaje distribuido.

Pongpech (2003), argumenta:

"el enfoque de sistemas adoptó metas para crear cursos electrónicos de una manera dinámica y personalizada basándose en el perfil del estudiante, usando la base de datos existentes y la tecnología workflow"

Otros programadores se enfocan en la re-usabilidad de los objetos. Brusilovsky y Nijhvan (2002), dos principales investigadores del ALP, realizan una discusión de este enfoque y filosofía. En contraste, Smith (2004), opina que los programadores son muy propensos a entusiasmarse demasiado, que se está perdiendo el enfoque de equipo y argumenta que la educación superior se rezaga a medida que los colegios comunitarios, escuelas y universidades tienden a confiar excesivamente en los módulos y objetos de contenido re-usables empaquetados y proporcionados por las universidades, por los equipos de diseño educativo, por los editores de textos y por los proveedores independientes de contenido. Los modelos de aprendizaje tienden a ser operados por los SGA tales como WebCT (2005), e-College (2005), Blackboard (2005), WebTycho (2005), Desire2Learn (2005), etc. Esto tiende a restringir las experiencias de aprendizaje y colocarlas en lo que ha llegado a ser la norma, grupos de 25 alumnos, lo que significa tiempo sumamente intensivo de estudiantes y de facultad. Para ver algo sobre el funcionamiento de este tipo de sistemas consultar Nichani (2001) y para saber algo sobre sus aplicaciones ver González (2004), aquí realiza un estudio de las principales aplicaciones de la Inteligencia Artificial (IA) en la Educación, tales como los Sistemas Tutores Inteligentes (STI) y Sistemas de Enseñanza Inteligentes (SEI) distribuidos a través de Internet.

Finalmente, de acuerdo con Smith (2004), el ambiente del ALP ofrece una leve esperanza de liberar a los estudiantes y a las universidades de un paradigma educativo medianamente rígido. Además, permite la posibilidad de sobrepasar los límites del tamaño de clase y propone una experiencia educativa verdaderamente individualizada, con un tutor inteligente (semejante a un avatar) que ofrece pistas, que requiere de retroalimentación, que investiga e interactúa justo a tiempo cuando el estudiante reproduce el comportamiento de los juegos exitosos. (Visite There.com, 2005, para un ejemplo.)

# 2.3. Objetivos (OPs) y objetos de personalización (ops)

Como se menciona en la sección 2.2, ALP es un sistema de enseñanza que adapta la selección y la presentación de contenidos a cada alumno en particular, basándose en los estilos de aprendizaje y de enseñanza, conocimientos previos, preferencias, necesidades y circunstancias particulares del estudiante. De acuerdo a nuestro trabajo reportado en Tapia et al., (2005), en el ALP es posible la interacción de los individuos a través de los medios tecnológicos permitiendo la formación de redes sociales (Figura 2.2), dejando atrás la comunicación unidireccional, característica de la formación tradicional. En este contexto de enseñanza-aprendizaje intervienen ops tales como OAs, presentación, métodos de entrada, aparatos, usabilidad de sistemas, etc., y OPs tales como: estilos de

aprendizaje, estilos cognitivos, estilos de enseñanza, conocimientos previos, currículo y condición del conocimiento dirigido, etc. que intervienen de manera directa en la determinación del perfil de alumno el cual es fundamental para obtener el TP (ver sección 2.4) del mismo y así poder finalmente establecer el modelo individual, el cual pueda optimizar el PGA de los usuarios de la plataforma Suricata y de cualquier otra plataforma. Conforme a Tapia et al., (2005), los OPs son los planes individuales de adaptación del alumno basándose, por ejemplo, en su nivel de estudios, su estilo de aprendizaje, su estilo cognitivo, el estilo de enseñanza preferido, sus conocimientos previos, el currículo (área de estudio) y condición del conocimiento dirigido, etc. y los ops son los OAs que se pueden personalizar.

A continuación listamos los ops que usamos en nuestro MB

#### Objetos de personalización.

• Presentación de OAs. Rawlings et al., (2001) define los OAs como "cualquier entidad, digital o no digital, que puede ser utilizada, reutilizada o referenciada durante una experiencia de aprendizaje soportada por la tecnología". Ferran y Minguillón (2005), conceptualizan los OAs como una gráfica individual, o un documento de video, y como una pequeña pieza de enseñanza que señala una meta específica de realización o de productividad, o bien, como la experiencia instructiva independiente más pequeña que contiene un objetivo, una actividad de aprendizaje y una evaluación. Son comúnmente proporcionados en forma de multimedia

interactiva y pueden ser instalados en la computadora, pueden estar disponibles en: 1) CD Rom, 2) en línea o, 3) cualquier combinación de estas dos modalidades. En nuestro MB usaremos estas tres posibilidades de seleccionar los ops.

Selección de los OAs. De acuerdo con Robertson et al., (2003), un OA, regularmente es sometido a algún proceso de selección, por los responsables del plan educativo, antes de ser incorporado al programa de la clase. Este proceso de selección puede resumirse aprovechando la aportación de procesos anteriores realizados por otros colegas, por políticas escolares, o por una revisión de materiales, etc. El proceso de selección de un OA puede deberse a: 1) Una necesidad dentro del programa de la clase. 2) Una facilidad para tener acceso a un OA particular sugerido.

En nuestro MB usamos estas dos opciones de presentar los OAs

usa para determinar el grado para el cual un sistema es utilizable por el mayor número de personas sin necesidad de modificarlo. Este término no debe confundirse con el de usabilidad que se utiliza para describir qué tan fácil una cosa puede ser manejada por cualquier tipo de usuario. La accesibilidad de las computadoras y los sistemas de información se logra primeramente siguiendo las normas reconocidas de accesibilidad (Ver ACM, 2006). La accesibilidad se enfoca especialmente en dispositivos

tales como teclados y ratones alternativos, pulsadores, lectores de pantalla, amplificadores y presentaciones alternativas. Por otro lado, es necesario contar con un sistema de reconocimiento de lenguajes ya que para algunas lenguas, son necesarios el procesamiento complicado y la retroalimentación cuando el usuario hace uso de la computadora. Por ejemplo, para los lenguajes asiáticos regularmente la persona introduce (o digita) la pronunciación de los caracteres, luego en un paso aparte, escoge los caracteres ideográficos apropiados dentro de las diversas posibilidades de esta pronunciación. En nuestro MB consideramos los siguientes métodos de entrada: 1) Ratón, 2) Teclado, 3) Pulsador, 4) Sistema de reconocimiento de lenguaje (SRL).

Dispositivos de aprendizaje. De acuerdo con Dede (1997), existen tres tipos de dispositivos de aprendizaje y que usaremos en nuestro MB: 1) Los objetos inteligentes que ayudan a crear ambientes educativos "articulados", los cuales se comunican con sus integrantes actuando coordinadamente y ayudando a éstos a entender su entorno. 2) Las infraestructuras de la información que proporcionan un acceso remoto con los expertos, a recursos archivables interrelacionados, comunidades virtuales e investigaciones "distribuidas o compartidas" que involucran a muchos participantes en diferentes sitios. 3) Ambientes artificiales compartidos que ayudan a desarrollar una mejor comprensión y apreciación de la realidad. Estos nuevos medios pueden mejorar los resultados educativos si se tiene

un cuidadoso diseño de la interfaz entre los dispositivos, estudiantes y profesores.

• Usabilidad del sistema. "La usabilidad se refiere a la capacidad de un software de ser comprendido, aprendido, usado y ser atractivo para el usuario, en condiciones específicas de uso" (Ver ISO/IEC 9126, 2005). Esta definición hace énfasis en los atributos internos y externos del producto, los cuales contribuyen a su usabilidad, funcionalidad y eficiencia. Por otro lado, de acuerdo con Bevan y Macleod (1994), la usabilidad depende no sólo del producto sino también del usuario. En nuestra tesis usamos la usabilidad del sistema en este sentido y, en nuestro MB la clasificamos como sigue: 1) Buena, 2) Regular y 3) Deficiente.

## Objetivos de personalización

• Estilo de aprendizaje. De acuerdo con Cazau (2003), "los estilos de aprendizaje son los rasgos cognitivos, afectivos y fisiológicos que sirven como indicadores relativamente estables, de cómo los alumnos perciben interacciones y responden a sus ambientes de aprendizaje". Es posible definir el concepto de estilo de aprendizaje con una caracterización de Keefe (Ver Keefe, 1988 y Alonso et al., 1999). Existen otros modelos de estilo de aprendizaje, algunos de ellos son mencionados en (Cazau, 2003). En nuestro MB usamos el modelo de Kolb (1984), que es el que ha sido seleccionado para implementarse en la plataforma Suricata. El modelo

mencionado se basa en la manera que tienen los alumnos de *procesar* o *encausar* la información. Según este prototipo, un aprendizaje óptimo es el resultado de trabajar la información en cuatro fases: 1) Actuar (alumno activo), 2) Reflexionar (alumno reflexivo), 3) Teorizar (alumno teórico) y 4) Experimentar (alumno pragmático). Según Rubio y Delgado, (2004), existen instrumentos para determinar este estilo predominante, son llamados cuestionarios de Honey-Alonso (CHEA) que pueden ser usados provechosamente en programas educativos o en planes de desarrollo de educación de adultos. Existen otros métodos para detectar el estilo de aprendizaje del alumno García et al., (2005) describe un modelo basado en RBs.

• Estilo cognitivo. Conforme a Cazau (2003), el estilo cognitivo son los rasgos cognoscitivos que se relacionan con la forma en que los estudiantes organizan o estructuran los contenidos, forman y utilizan los conceptos, interpretan la información, resuelven los problemas, seleccionan medios de representación (visual, auditivo, kinestético), etc. Los rasgos afectivos se vinculan con las motivaciones y expectativas que influyen en el aprendizaje, mientras que los rasgos fisiológicos están relacionados con el biotipo y el biorritmo individual del estudiante. La construcción de los estilos cognitivos fue inicialmente propuesta por Allport (1937), desde entonces, especialmente en las últimas décadas, se ha realizado investigaciones considerables dentro de esta área. Los estilos cognitivos, han sido investigados por sicólogos tales como Liu y Ginter (1999); Messick (1976),

quien identificó hasta 19 estilos cognitivos. Smith (1988) que calculó al menos 17 estilos de aprendizaje. Kagan y Wallach (1964); Kagan (1981), que contempla los estilos cognitivos: 1) impulsivo y 2) Reflexivo. Witkin et al., (1977) ha identificado un estilo campo-dependiente y un estilo campoindependiente y que usamos en nuestro MB. El instrumento de medida es el test de Kagan (Kagan, 1981). (MFFT, Matching Familiar Figures Test). Este instrumento consta de 12 ítems o preguntas, más dos ítems adicionales que se utilizan en la fase previa de entrenamiento. La versión más completa del test se puede ver en los artículos de Cairns y Cammock, (1978, 1984, 1989). En muchas situaciones, los estilos cognitivos y los estilos de aprendizaje son utilizados de forma intercambiable. Sin embargo, generalmente los estilos cognitivos están más relacionados investigaciones teóricas o académicas (es decir, están ligados a una dimensión bipolar), mientras que los estilos de aprendizaje están más ligados a aplicaciones prácticas (no necesariamente están relacionados a uno o ambos extremos). Las medidas de los estilos cognitivos y de aprendizaje tienden a estar en medio de las medidas de aptitud y de personalidad. Además, los estilos cognitivos y de aprendizaje han sido visualizados en la literatura como tres ramas principales relacionadas: estructura, proceso y, proceso y estructura (Ver Squires, 1981; Tennant, 1988; Wilson, 1981).

 Estilos de comunicación. Nuestro estilo de comunicarnos depende de con quién nos comuniquemos y de una diversidad de variables tales como nuestro estado de ánimo. Heffner (2005), clasifica a las personas mediante los tres estilos de comunicación siguientes: 1) Pasivo, 2) Asertivo. 3) Agresivo y son los que usamos en nuestro MB.

- Estilos de enseñanza. Así como los alumnos tienen estilos individuales de aprendizaje, los profesores también tienen estilos personales de enseñanza que funcionan mejor para ellos. Grasha (1994), ha clasificado los estilos de enseñanza de los profesores en los modelos siguientes y que usamos en nuestro MB: 1) Autoritario formal, 2) Demostrador o modelo personal, 3) Facilitador 4) Delegador o ejecutor. Stein et al., (2001), presentan un instrumento de medición para determinar el tipo de enseñanza predominante de un profesor. Butler y Lalla (2005), en un programa doctoral encontraron que el aprendizaje óptimo es más probable de darse cuando se tienen las siguientes parejas de alumno-profesor respecto a sus respectivos estilos de aprendizaje y estilos de enseñanza: (Acomodador, Demostrador), (Divergente, Facilitador), (Convergente, Delegador) y (Asimilador, Formal autoritario).
- Técnicas o métodos de aprendizaje. En los últimos años se han difundido muchas técnicas para el aprendizaje, frecuentemente integrables y complementarias entre ellas, todas orientadas a mejorar y hacer más eficaz, veloz y duradero el aprendizaje. El cambio de los instrumentos de transmisión del conocimiento (del impreso al electrónico) ha hecho necesario perfeccionar las técnicas de aprendizaje enfocándose en enseñar

el uso y la interpretación de las imágenes y de la representación visual, en otras palabras al aprendizaje visual (aunque esto sea a menudo instintivo). En este nuevo contexto, de acuerdo con Knowledge Manager, (Knowledge Manager, 2006), surgen métodos que complementan a los tradicionales (lectura eficaz, memorización, mapas conceptuales, esquemas, subrayado, atención y concentración, etc.) tales como: el aprendizaje visual, el aprendizaje activo y el aprendizaje colaborativo. En nuestro MB usamos estas tres alternativas para proponer al alumno las técnicas que más se ajusten a su TP.

- Conocimientos previos. Dentro del contexto del PS se contemplan tres niveles de conocimientos previos que usaremos en nuestro MB: Bajo, Intermedio y Alto. Conforme a Rubio y Delgado (2004), el nivel de conocimientos se detecta mediante la aplicación de una prueba específica al inicio de cada curso o módulo.
- Preferencias individuales. Según Gallego y Martínez (2004), las personas perciben y adquieren conocimiento de manera distinta, tienen ideas, piensan y actúan de manera diferente. Además, las personas tienen preferencias hacia unas determinadas estrategias cognitivas que les ayudan a dar significado a la nueva información. Basándose en las propias experiencias y necesidades del alumno, estas preferencias individuales de aprendizaje se han clasificado en: visuales, auditivas y kinestéticas

(tocando, sintiendo y participando activamente). Esta clasificación de preferencias individuales es usada en nuestro MB.

- Currículo. En nuestro MB, dependiendo de la materia o módulo que el alumno va a cursar, se determina el área correspondiente del currículo: Ciencias Exactas y Naturales, Ingeniería, Biología y Ciencias de la Salud, Ciencias Sociales, Económicas y Administrativas y, Humanidades y Bellas Artes.
- Necesidades personales. Conforme a Askew (2000), existen las siguientes necesidades personales: 1) Ambientales (sonidos, iluminación, temperatura del lugar de aprendizaje, etc.), 2) Emocionales (motivación, independencia, dependencia, etc.), 3) Sociales (si estudia solo, con un asesor o tutor, en grupo) y 4) Fisiológicas (alimentación, la necesidad de moverse y la hora del día óptima para aprender). Estas necesidades personales son usadas en nuestro MB.

# 2.4. Tipos de personalización (TPs) y tipos de adaptividad

Como se mencionó en la sección 2.2, la adaptividad es una funcionalidad particular de hipermedia, que puede aplicarse, por medio de una diversidad de métodos, en ambientes de aprendizaje basados en el ordenador que se usan en los ámbitos educativos. Para Eklund y Brusilovsky (2000), el objetivo de la

adaptividad es tener sistemas que se adapten al contexto de utilización con respecto a su funcionalidad, selección y presentación de contenido e interacciones de los alumnos/usuarios. De acuerdo con Markus et al., (2005), los sistemas que expresan tal comportamiento que se puede personalizar con respecto al contexto de utilización, son denominados sistemas concientes de la situación. Un aspecto de la conciencia de la situación está relacionado a las propiedades del mismo estudiante/usuario, tal como el nivel de enseñanza, la tarea actual o comportamiento anterior. Tradicionalmente, estas propiedades han capturadas en los modelos del usuario (ver secciones 2.5), las cuales han sido procesadas para generar el comportamiento personalizado apropiado. De acuerdo con Paramythis y Loidl-Reisinger (2003), actualmente la conciencia de la situación es continuamente incrementada tomando en cuenta más, y más propiedades situacionales. En particular, se usan varios sensores para reunir información sobre las propiedades relacionadas al ambiente físico del contexto de utilización tal como la hora del día, ubicación, línea de visión, nivel de ruido, etc. Según Paramythis y Loidl-Reisinger (2003), otras propiedades situacionales del contexto de utilización de un estudiante, guardan relación con lo que se conoce como entorno social, compuesto por otros usuarios/alumnos de características similares, las interacciones comunicativas y colaborativas, los dispositivos compartidos y tareas comunes. El objetivo de estas propiedades situacionales, es ayudar a los alumnos/usuarios abasteciéndolos pro-activamente de lo que realmente necesitan. De esta manera, los estudiantes/usuarios no son distraídos de su tarea principal de búsqueda y selección.

De acuerdo con Tapia et al., (2005), el TP en el contexto del aprendizaje y la enseñanza, evaluación y realización de exámenes, significa el tipo de adaptación del alumno al ambiente de aprendizaje (por ejemplo, mediante la acumulación del conocimiento, a razón del desarrollo de meta-cogniciones o estrategias de aprendizaje), así como la adaptación de los sistemas electrónicos de aprendizaje al estudiante (verbigracia, contexto cultural, conocimiento previos, objetivos y metas, estilo de comunicación, estilo de aprendizaje y estilo cognitivo). El TP determina cómo el sistema debe comportarse para individualizar el proceso de enseñanza-aprendizaje del alumno, teniendo en cuenta los ops y los OPs.

Albert y Hockemeyer (2001); Albert y Mori (2001), hacen una distinción entre las direcciones y los objetos de adaptividad, los objetivos de adaptividad y el nivel de individualización de adaptividad. Las direcciones y objetivos son por ejemplo los tipos de adaptividad para:

- los requerimientos de diferentes progresos de aprendizaje,
- las metas y objetivos tanto del profesor como del estudiante,
- para los conocimientos previos del estudiante,
- las preferencias en la interacción computadora-humano (navegación),
- los estilos de comunicación y necesidades,
- los estilos cognitivos y estilos de aprendizaje y
- los antecedentes culturales.

Basándonos en estas cuatro distinciones determinamos las FP siguientes y que son usadas en nuestro MB:

- 1) Fase de los **conocimientos previos** o pre-conocimiento. En esta modalidad, basándose en una evaluación del conocimiento personalizado y probando un procedimiento, los OAs son puestos al alcance del alumno dependiendo de su pre-conocimiento.
- 2) Fase del *progreso del conocimiento*. En este tipo, el progreso de aprendizaje del estudiante se controla a través de trayectorias individuales.
- 3) Fase de los *objetivos y metas del profesor/alumno*. En este caso, dependiendo de los objetivos y metas, el estudiante es guiado mediante trayectorias (o itinerarios) de aprendizaje.
- 4) Fase de las *preferencias y experiencia de navegación*. En esta situación, son posibles varios tipos de apoyo a la navegación. Por ejemplo, el alumno puede escoger si desea una libertad total en la navegación o si quiere ser guiado a sus metas con trayectorias de aprendizaje explícitamente determinadas.

Una vez mencionados los ops, OPs, TPs y fases de personalización que necesitamos para el diseño de nuestro MB, en la sección siguiente mencionamos el modelado del alumno y las técnicas que se tienen para modelar al estudiante.

### 2.5. Modelado del alumno

El modelo del usuario es una componente fundamental en los sistemas adaptables de aprendizaje en línea. La adaptación de un sistema de enseñanza en línea, principalmente implica escoger y presentar cada actividad sucesiva como una función del ámbito completo del conocimiento del alumno, de la materia que está siendo enseñada y otras características relevantes del estudiante, las cuales son, a su vez, mantenidas en el modelo del alumno. Por lo tanto, el modelo del estudiante se utiliza para modificar la interacción entre sistema y estudiante a fin de satisfacer las necesidades individuales de los alumnos.

Según Kay (2000), el "mundo real" (ver Figura 2.3) del usuario es percibido por el sistema a través de la interfaz humano-computadora. El MA se basa en esta información y por lo tanto sólo una pequeña parte real del alumno. Sin embargo, el

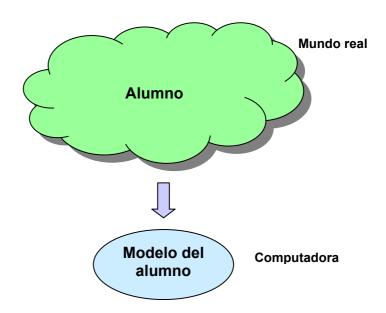


Figura 2.3. El mundo real, el alumno y el MA. (Kay, 2000)

modelo del usuario debe representar las características necesarias del mismo en base al contexto de la aplicación.

De acuerdo con Kosh (2000), el MA representa la creencia del sistema acerca de los propósitos principales del alumno y proporciona la información necesaria para ajustar a la medida la enseñanza en base a las necesidades de éste. Esta información necesaria es representada por el contenido de un MA (ver sección 2.5.1). La totalidad del contenido puede agruparse relacionando las diferentes propiedades de un alumno. Estos grupos son organizados en las componentes de un MA (ver sección 2.5.2). Existen varias formas de construir un modelo (ver sección 2.5.3), dadas las ventajas expuestas en el capítulo 1, hemos elegido las RBs para diseñar nuestro MA. Después de construir el MA, se requiere la inicialización de éste (ver sección 2.5.4) usando datos iniciales que son recabados para tal propósito. Por último, mantener actualizado el MA (ver sección 2.5.5) es ventajoso, esto se lleva a cabo cambiando la información antigua por una más reciente.

### 2.5.1. Contenido de un modelo del alumno (MA)

De acuerdo con Self (1994), un modelo amplio del alumno debe contener información acerca del conocimiento de dominio del alumno, el progreso del alumno, las preferencias, metas, intereses y otro tipo de información relativa al usuario, la cual es importante para el sistema utilizado. Brusilovsky (1994), muestra que los modelos del alumno pueden clasificarse de acuerdo a la

naturaleza y forma de la información contendida en los modelos. Considerando la materia de dominio, la información puede dividirse en dos grupos principales: a) Información específica del dominio y, b) Información independiente del dominio.

### > Información específica del dominio

Esta información representa un reflejo del estado del estudiante y el nivel de conocimiento y habilidades de una materia particular. Brusilovsky (1994), nombra al modelo de la información específica del dominio modelo del conocimiento. El modelo del conocimiento puede basarse en diferentes tipos de modelos o una combinación de éstos. Los tipos posibles de modelos del conocimiento se describen a continuación.

- Modelo escalar. Conforme a Han (2001), en un modelo de este tipo, se determina el nivel de conocimiento del alumno con respecto al dominio total mediante un indicador numérico dentro del intervalo cerrado [1, 5]. Este modelo es la forma más sencilla de un modelo del conocimiento y no proporciona información sobre el conocimiento en el sub-dominio.
- Modelo overlay. De acuerdo con Henze y Nejdl (2003), la información del dominio total, consiste de un conjunto de elementos de conocimiento o elementos del currículo, y representa el conocimiento del experto en este dominio. El modelo overlay describe el conocimiento del alumno como un subconjunto del modelo del dominio completo. La falta de conocimiento en el alumno se deduce comparándolo con el conocimiento experto. Para cada

elemento de conocimiento en el modelo overlay del alumno, se le asigna una cierta medida que representa al conocimiento estimado en este elemento. La medida puede ser un escalar (por ejemplo, un entero, una medida de probabilidad, un indicador o un vector estimado).

- Modelo del error. Conforme a Brusilovsky (1994), una desventaja de los modelos overlay es la incapacidad de almacenar los errores o las equivocaciones realizadas por el estudiante. Por esta razón se ha desarrollado el modelo de fallos o modelo de errores. Con un modelo del error, es posible definir y reflejar conductas erróneas de los alumnos y la razón de estos errores. Los modelos del error pueden clasificarse en modelos de perturbación y modelos diferenciales. Las perturbaciones o equivocaciones de cada elemento de conocimiento se almacenan en el modelo de perturbación. Se supone que existe una o más perturbaciones para cada uno de los elementos de conocimiento en el modelo de dominio. Así, el modelo de perturbación del alumno representa un subconjunto de todas las posibles perturbaciones, que son la causa de comportamientos incorrectos del alumno, relacionados con los elementos particulares de conocimiento.
- Modelo genético. Según Han (2001), los modelos descritos arriba representan el estado de conocimiento del alumno. Pero estos modelos no expresan la estructura del conocimiento de dominio. Por lo tanto, los modelos genéticos se usan para describir el desarrollo del conocimiento del

alumno. Este proceso puede evolucionar gradualmente, desde un proceso simple hasta un proceso complejo o, desde un proceso especial a proceso general. Por ejemplo, un alumno empieza con un conocimiento muy especial y prosigue hacia un conocimiento general y de gran extensión. Es posible describir un modelo genético mediante una gráfica genética donde los nodos y las relaciones entre los nodos representan elementos de conocimiento y sus interacciones.

### información específica adicional del dominio

Además del dominio ya descrito, la información específica de dominio almacenada por diversos tipos de modelos, puede almacenarse información adicional en el MA. De acuerdo con Han (2001), esta información incluye:

- Conocimiento previo acerca del dominio del alumno.
- Registros o actividades de aprendizaje (lecturas tomadas, número de preguntas de ayuda, tiempo para resolver los problemas), y
- Registros de las valoraciones y evaluaciones.

En general, la información específica adicional del dominio puede contener información necesaria para propósitos específicos del MA relacionado a dominios de la materia.

### > Información independiente del dominio

Además del nivel actual de conocimiento del alumno, la información independiente del dominio se necesita para poder habilitar la adaptividad y la personalización. Conforme a Han (2001), esta información acerca del alumno puede incluir metas de aprendizaje, aptitudes cognitivas, estado de motivación, antecedentes y experiencias, preferencias así como también objetivos y datos históricos.

- Metas. Para establecer la estrategia correcta de enseñanza, es importante conocer las metas del alumno. Estas metas responden a las preguntas del por qué el estudiante utiliza el sistema en línea y qué necesita para alcanzarlas. Las metas pueden ser divididas en dos tipos diferentes: 1) metas de aprendizaje, que son relativamente estables para la unidad del curso y 2) metas para resolver problemas, la cual puede cambiar de un problema a otro, incluso dentro de una misma unidad de enseñanza. Ejemplos de metas de aprendizaje son: aprobar un examen o resolver un problema particular.
- Aptitudes cognitivas. Las aptitudes cognitivas son las habilidades intelectuales para diferentes tipos de desempeño cognitivo. Por ejemplo, aptitudes musicales, aptitudes matemáticas, y aptitudes para la lectura. Es decir, son todas las diferentes clases de capacidades cognitivas.
- Estado de motivación. Para medir el manejo en la enseñanza se usa el estado de motivación del alumno. La motivación se mide utilizando un número de parámetros a largo y corto plazo. Tales parámetros son por

ejemplo, el esfuerzo, la atención, el interés, la distracción, la persistencia, etc. Estos parámetros son relacionados a otros factores tales como el nivel de conocimiento, disposición, complejidad del tema y resultado del aprendizaje. Far y Hashimoto (2000), propusieron un MA que considera la motivación y el estado de conocimiento de un alumno. Con este MA, el estado de motivación es representado por una RB, donde la gráfica codifica las dependencias entre las facetas de motivación y las actividades de aprendizaje. Por ejemplo, una vereda desde la propiedad de distracción a la propiedad de atención, indica qué distracción está influyendo en la atención del alumno.

Antecedentes y experiencia. De acuerdo con Brusilovsky (1994), para derivar los parámetros del estudiante, se usa la información acerca de los antecedentes y experiencias. La información de los antecedentes incluye habilidades que pueden afectar el éxito del aprendizaje. Tal información es por ejemplo, la profesión, la experiencia laboral o las perspectivas. La experiencia representa el conocimiento acerca del ambiente de aprendizaje. Los alumnos que son novatos para un ambiente de aprendizaje particular, o inclusive principiantes para el aprendizaje en línea, pueden necesitar diferentes apoyos del sistema, independientemente de si son aprendices o expertos en el dominio de la materia. Esta información podría ser usada para seleccionar el método apropiado de navegación.

**Preferencias.** Los estudiantes pueden tener diferentes preferencias relacionadas a algunos aspectos del ambiente de aprendizaje (ver sección 2.3): estas preferencias están consideradas como no deducibles por el sistema. Así es que el alumno tiene que informar al sistema directa o indirectamente acerca de sus preferencias. Esto es importante para el sistema ALP para que pueda presentar y organizar el material de aprendizaje basado en las preferencias del estudiante. También, las preferencias del alumno pueden utilizarse para formar grupos de alumnos. Esta técnica recibe el nombre de modelado de grupo, y consiste en agrupar a los alumnos con las mismas características. Dos elementos de las preferencias son los estilos de aprendizaje y la inteligencia múltiple; los estilos de aprendizaje y la inteligencia múltiple están mutuamente relacionados uno del otro. La teoría de la inteligencia múltiple fue escrita inicialmente por Howard Gardner en el año 1983 (Gardner, 1983). Lane (2000) indica que existen ocho formas distintas de inteligencia: Lingüística, lógica/matemática, espacial, kinestética, musical, interpersonal, intrapersonal y naturalista. De acuerdo con Lane (2000), H. Gardner demostró que todos poseemos todas estas inteligencias pero en grados diferentes. Considerando la inteligencia múltiple durante el proceso de adaptación, el ambiente de aprendizaje es capaz de ajustar a la medida el material de aprendizaje de acuerdo al poder del estudiante lo que permite sostener el progreso de aprendizaje en una base máxima. Los estilos de aprendizaje son diferentes métodos o maneras de aprendizaje. La inteligencia múltiple

determina varios estilos de aprendizaje. Por lo tanto, cada estudiante tiene diferentes preferencias para, cómo, cuándo, dónde y con qué frecuencia adquirir el conocimiento. Un ejemplo para un modelo de estilo de aprendizaje es el modelo WAVI (Ver Lane, 2000), que respalda al oyente, al analizador, al pronunciador, al analizador y al trazador y describe las preferencias acerca de la visualización del material de aprendizaje. Por ejemplo, si un estudiante prefiere imágenes entonces es cubierto por el trazador.

• Datos históricos y verdaderos. Conforme a Han (2001), los datos demográficos tales como nombre, edad, padres, DNI, etc. con frecuencia se almacenan en los MA. Esta información, combinada con otros datos reales como por ejemplo, los intereses, implica inicializar un modelo individual del alumno. En este apartado se ha descrito el contenido del modelo de un alumno. Este contenido simplemente puede subdividirse en información del dominio específico e información independiente del dominio. Al lado de estas clasificaciones de información, es posible también dividir la estructura de un MA en varias componentes lógicas tal como se describe en la sección 2.5.2.

#### 2.5.2. Componentes de un modelo del alumno (MA)

Antes de dividir un MA en componentes, la información almacenada acerca del alumno tiene que analizarse y agruparse en torno a los diferentes tipos y niveles

de información. Según Zhou y Evens (1999), y Jeremié y Devedzié (2004), las componentes están fuertemente conectadas a la aplicación del MA, pero es común construir un modelo histórico de productividad y de enseñanza. El modelo de productividad almacena los datos relacionados a las valoraciones de las habilidades globales del alumno. El modelo histórico de enseñanza lleva el control de material presentado al alumno durante su enseñanza y el dominio del alumno de las unidades de enseñanza. Son necesarias componentes adicionales para proporcionar una información completa acerca del estudiante. Zhou y Evens (1999), enumeran dos componentes adicionales: 1) Historial de la respuesta y 2) El registro de la solución. En un historial de respuesta del alumno, se anexa y se almacena a cada unidad de enseñanza, la información acerca del material de aprendizaje cubierto y las respuestas del alumno durante esta unidad de enseñanza. La cantidad de errores y la descripción de éstos, lo que hizo y dónde lo hizo, son almacenados durante el proceso de la resolución de un problema en los registros de la solución.

Otro método para dividir el MA en varias componentes se describe en Castillo et al., (1997), donde el MA se divide en tres componentes: un perfil, un modelo overlay cognitivo y un modelo overlay del curso. El perfil del estudiante almacena la información tales como nombre, edad, estilo de aprendizaje, etc. La creencia del sistema sobre el conocimiento del alumno se registra en la componente overlay del alumno mientras que la componente overlay del curso proporciona información acerca de las interacciones del estudiante con el sistema. Para describir los detalles técnicos acerca del MA, se utilizan los componentes técnicos como por

ejemplo, lector de datos, un escritor de datos y un administrador de sesión. Las componentes del escritor de datos y el lector de datos son los responsables de proporcionar el acceso a un almacén de datos. Un administrador de sesión controla y coordina a todos los otros componentes y a la unidad que controla el MA.

Un modelo del estudiante es una combinación de todos los datos relevantes sobre el alumno con respecto a su ambiente de aprendizaje. Existen tipos comunes de información entre el MA tal como la información del dominio de la materia ya descrita arriba, las metas de aprendizaje, la motivación, los antecedentes y la experiencia, las aptitudes cognitivas, preferencias y datos demográficos. El contenido de un MA es organizado en varias componentes según el tipo de información. Para recopilar la información necesaria, en la sección 2.5.3 siguiente se mencionan las diferentes técnicas.

#### 2.5.3. Técnicas de modelado

Antes de identificar la información necesaria almacenada en un MA, el proceso de adquirir esta información cobra relevancia. Existen varios métodos para construir un MA, entre ellos se encuentran:

• Los **métodos de aprendizaje de máquina** que incluyen por ejemplo, métodos de aprendizaje de regla y árbol, métodos de aprendizaje probabilistas y ejemplo/método de aprendizaje basado en un caso. De acuerdo con Webb et al., (2001), este método se usa para modelar: el proceso cognitivo que está

detrás de las acciones del alumno, las diferencias entre las habilidades del alumno y las habilidades del experto, los patrones de comportamiento del estudiante o sus preferencias, y las características del estudiante.

- Los métodos Bayesianos, son muy potentes y versátiles. En general, los métodos Bayesianos están relacionados a los métodos de aprendizaje de máquina pero, se usan con frecuencia en el modelado del usuario. Según Li y Ji (2005), las RBs se usan para el plan de identificación o reconocimiento, inferencia de las necesidades y evaluaciones efectivas del estado del usuario. Para inferir el estado actual y las necesidades del alumno, se consideran las pausas y los errores. También, se pronostican las metas y las necesidades usando los antecedentes, las acciones y las búsquedas del alumno. De acuerdo con Li y Ji (2005), los aspectos mentales y emocionales actuales del estudiante representan una indicación importante de la condición, intención y necesidades del estado del estudiante, sus intenciones y sus necesidades. Las RBs, sostienen el uso de la inferencia probabilista para actualizar y mejorar los valores de creencia. La meta principal de estas redes es hacer posible la inferencia probabilista. La teoría de RBs y el método Bayesiano, por su relevancia en esta tesis, son descritos en el capítulo 3.
- Los **métodos overlay**, se basan en el hecho de que el MA es un subconjunto del modelo experto. El modelo experto se subdivide en diversas partes pequeñas que son agrupadas en módulos de tópicos específicos o conceptos. De acuerdo con Sison y Shimura (1998) cada una de estas partes

puede conectarse a un modelo particular del alumno. en los métodos estereotipo y métodos del plan de identificación o reconocimiento. Conforme a Conlan et al., (2002), la complejidad de un modelo overlay depende de la estructura del conocimiento de dominio, donde la granularidad es importante. Además, la estimación del conocimiento del alumno es importante y se mide mediante el examen de las secciones que el estudiante ha leído y las pruebas o test que son aplicados a éste.

- Los métodos estereotipo, es una colección de características más frecuentes que ocurren en un usuario. De acuerdo con Rich (1979), los estudiantes nuevos son agrupados en categorías y, a cada categoría se le asocia un estereotipo de acuerdo a su modelo de características iniciales. La pequeña cantidad de información inicial se usa para inferir un número mayor de suposiciones predeterminadas. Cuánto más información llegue a estar disponible acerca de las suposiciones individuales predeterminadas, estas suposiciones se irán alterando. De acuerdo con Kobsa (1993), el problema de usar estereotipos es el trabajo para construir y encontrar los estereotipos apropiados.
- Los métodos del plan de identificación o reconocimiento, son usados para describir las intenciones y deseos del estudiante, donde un plan es una sucesión de acciones del alumno que logran una cierta meta. De acuerdo con Li y Ji (2005), el plan de identificación se basa en la observación de las actividades realizadas por el alumno en la computadora. El ordenador trata de

determinar todos los planes posibles del alumno que son válidos con respecto a los datos observados. Este conjunto de planes calculado, se reduce tomando en cuenta las nuevas acciones del estudiante. Conforme a Kobsa (1993), existen dos clases de técnicas que se usan para reconocer el plan del alumno: 1) el plan de librerías y 2) el plan de construcción. En la primera técnica, se construye un plan de librerías que contiene todos los planes posibles, y la selección del plan actual se basa en las acciones observadas mediante la comparación de estas acciones con el conjunto de planes. El problema de esta técnica es que todas las sucesiones permitidas de las acciones del alumno tienen que almacenarse dentro de un plan. Esto requiere de mucho trabajo de computación y un almacenamiento enorme para el plan de librerías. En la segunda técnica, el sistema controla una librería de todas las combinaciones posibles de las acciones del alumno con los efectos y las condiciones previas de esas acciones. Según Kobsa (1993), la sucesión de las acciones del estudiante se enriquece por todas las acciones posibles subsiguientes del usuario. Las acciones posibles del usuario se calculan comparando los efectos de acciones precedentes con las condiciones previas almacenadas en la librería de acciones. De acuerdo con Fröschl (2005) el método del plan de reconocimiento es limitado debido al requerimiento de que todos los planes posibles del alumno, tienen que especificarse con anterioridad. Esto no es un problema si el dominio es lo suficientemente pequeño de tal modo que el estudiante sólo pueda alcanzar un número limitado de metas u objetivos.

Una vez que se diseña un MA, es necesario inicializarlo. En la sección 2.5.4 siguiente analizamos este tema.

### 2.5.4. Inicialización del modelo del alumno (MA)

Después de la construcción de un MA, se continúa con la inicialización de éste, el cual tiene que llenarse con los datos iniciales. En esta sección describimos el proceso de inicialización. La inicialización de un MA es un proceso de recopilación de información acerca del estudiante y el traslado de esta información al modelo. Al proceso de inicialización es también un problema en el campo de los sistemas recomendantes o mediadores, donde se conoce como el problema de la rampa hacia arriba o del arranque en frío. A continuación describimos los métodos de cómo se recupera la información relativa al estudiante. De acuerdo con Self (1994), un MA puede inicializarse de tres maneras: 1) por medio de preguntas explícitas, 2) mediante pruebas o tests iniciales y, 3) por estereotipado.

• Preguntas explícitas. Según Tsiriga y Virvou (2003), los modelos iniciales del alumno se construyen regularmente mediante el cuestionamiento directo del alumno. Este método es una manera muy efectiva de obtener información general acerca del estudiante. El problema es encontrar la cantidad óptima de información. Demasiadas preguntas iniciales puede enfadar al estudiante e incrementar la deserción del curso o la declinación al sistema. Muy pocas preguntas o cuestionamientos mal seleccionados, impiden al sistema extraer la suficiente información para inicializar el MA.

Una alternativa que puede reducir el número de preguntas es el uso de cuestionarios adaptables análogos a los de Kurhila et al., (2001) y Millán (2000). Estos cuestionarios aplican los métodos adaptables para optimizar la longitud del cuestionario mediante la reducción de preguntas no informativas usando métodos Bayesianos.

- **Pruebas o test iniciales.** Los parámetros iniciales en el MA pueden obtenerse, preguntando al estudiante mediante pruebas o test y, analizando estas pruebas o test. Conforme a Self (1994), para controlar la longitud de los tests, se aplica el concepto de vecindad de estados de conocimiento. Por ejemplo, si los elementos A y B están en la misma vecindad, el dominio de A implica el dominio de B. Esto conduce a una reducción de la longitud del test pero presupone un test bien estructurado. Los tests iniciales son con frecuencia usados para conseguir información acerca del conocimiento de dominio del alumno.
- Esterotipado. Los sistemas de modelado del alumno pueden usar métodos de estereotipo para agrupar a los alumnos en categorías similares. Conforme a Han (2001), no obstante que el estereotipado es muy poderoso para proporcionar información basado en muy pocas observaciones, este no ofrece un modelo preciso del alumno. La información requerida para poder aplicar el estereotipado puede recabarse mediante el uso de cuestionarios explícitos. Otro método es asignar un alumno nuevo y desconocido, a un estereotipo predeterminado y refinar el estereotipo

aplicado mediante la observación del estudiante. Esto puede ayudar a reducir las preguntas iniciales.

Después de llenar el MA con la información, cobra importancia el mantenerlo actualizado. En la sección 2.5.5 siguiente abordamos este caso.

### 2.5.5. Actualización del modelo del alumno (MA)

Para mantener la información almacenada actualizada en el MA, las características cambiadas del estudiante tienen que ser determinadas para cubrir los requerimientos de los aspectos de representación común del alumno. En esta sección, además de la descripción de la actualización de la información almacenada en el modelo del usuario, también abordamos la entrega de estos nuevos datos.

Actualizar un MA significa poner al día los datos y la información almacenados acerca del alumno. Puesto que las características a corto plazo del estudiante, no son propiedades constantes, tiene que considerarse una modificación adicional del MA. Para el proceso de actualización de un modelo, son necesarios las fuentes de información y los métodos de actualización:

 Información usada para la actualización de modelos. La información utilizada para actualizar modelos del alumno puede recopilarse de distintas fuentes de información. Inicialmente, debemos considerar la información que actualmente está almacenada en el MA. Esta información puede ser usada como base para inferir nueva información o realizar cambios en la información deducida. Además, la información que está actualmente almacenada en otros componentes del sistema puede ser de utilidad. Por ejemplo, el modelo de dominio de un STI. La fuente principal de información puede obtenerse por medio del monitoreo de la interacción del alumno con el sistema. De acuerdo con Kinshuk (1996), existen varias maneras de obtener información desde las fuentes antes mencionadas estas son: 1) Adquisición implícita, 2) Adquisición explícita, 3) Adquisición estructural, y 4) Adquisición histórica. La adquisición implícita de información se basa en la información de las acciones del alumno durante el proceso de aprendizaje. La consideración de diálogos directos entre el sistema y el alumno conduce a la adquisición explícita (por ejemplo, el cuestionario explícito). La adquisición estructural se realiza mediante el análisis de interrelaciones entre los elementos curriculares. Por ejemplo, si un elemento curricular A es un prerrequisito de un elemento B, una habilidad en B implica el dominio de A. Las suposiciones se basan en la experiencia del alumno que es adquirida durante una adquisición histórica de información. Considerando la información disponible para actualizar un MA, existen diversas técnicas de cómo esta información se usa para llevar a cabo la actualización.

 Métodos para actualizar modelos del alumno. Según Self (1993), la información para actualizar modelos del alumno tiene que derivarse mediante: 1) El análisis de las respuestas del estudiante, 2) El proceso de resolución del problema, y 3) Las acciones del estudiante. Estos tres métodos son procesos analíticos y son denominados diagnosis cognitiva. La diagnosis cognitiva se define como el proceso de inferir un estado cognitivo de una persona basado en el desempeño de esta persona. Otro método para actualizar un MA es determinar los datos antiguos y no hacer uso de ellos nunca más.

Análisis de las respuestas del alumno. El análisis de las respuestas del alumno es llamado por Brusilovsky (1994), medida de desempeño. Básicamente, las preguntas de un examen durante el aprendizaje pueden dividirse en preguntas simples y preguntas complejas. Las preguntas simples están únicamente relacionadas a un elemento específico del currículo mientras que las preguntas complejas requieren del conocimiento de más de un elemento curricular. Consecuentemente, las respuestas del alumno a estos dos tipos de preguntas deben manejarse de diferente manera. Por ejemplo, una respuesta correcta a una pregunta simple incrementa la relevancia de los elementos curriculares relacionados; mientras que una mala respuesta disminuye la relevancia del elemento curricular subyacente. Analizar la respuesta de una pregunta compleja requiere de más esfuerzo. Las respuestas correctas pueden conducir a un incremento de todos los elementos relacionados del currículo, pero una respuesta incorrecta necesita ser investigada más a fondo. La pregunta tiene que ser dividida basándose en la estructura del modelo de dominio y deben considerarse las partes resultantes. Así, algunas partes de la respuesta tal vez sean correctas y otras no. Mediante la aplicación de una perturbación o un modelo de error (ver sección 2.5.1), las perturbaciones que son relevantes para la respuesta incorrecta deben determinarse. Estos cambios deben considerarse y conviene realizar una actualización de las propiedades afectadas del MA.

- Análisis del proceso de solución del problema. Según Brusilovsky (1994), para llevar a cabo el análisis de la resolución del problema es necesario una tecnología, donde todas las reglas correctas posibles, que pueden ser utilizadas por el alumno durante el proceso de resolución, estén disponibles. Combinando estas reglas con una colección de equivocaciones serias para las que el error pueda ocurrir, el sistema puede calcular y detectar todos los pasos correctos de la solución, y todas las equivocaciones realizadas por el alumno en cada paso del proceso de resolución del problema.
- Análisis de las acciones del alumno. De acuerdo con Brusilovsky (1994), las acciones del alumno pueden analizarse considerándolas como resultados de la adquisición de un conjunto de elementos curriculares o de equivocaciones. Esto es posible si se conoce el dominio de la materia. Para esto, es necesario un rastreo simple de las acciones del estudiante.
- Eliminación de datos antiguos. Conforme a Webb y Kuzmycz (1998),
   considerando únicamente los datos actualizados reduce el valor de los datos antiguos en el MA. Esto da importancia a los datos que se derivan de las acciones recientes. El proceso de eliminar datos antiguos se basa en la

suposición de que el tiempo transcurrido desde que estos datos fueron almacenados, disminuye la importancia y la influencia de los datos antiguos al estado actual del estudiante.

En la siguiente sección presentamos las conclusiones de este capítulo.

### 2.6. Conclusión del capítulo

Una vez visto el estado del arte, tenemos las conclusiones siguientes: Hemos resaltado el papel de diversos paradigmas, técnicas y tecnologías de enseñaza-aprendizaje con la finalidad de crear un modelo matemático que ayude a determinar eficientemente el TP del alumno, con el propósito de optimizar el PGALP del alumno. Este modelo puede ser incorporado en el motor de la plataforma Suricata y lograr un sistema más flexible y enriquecido. También puede ser agregado en algún sistema tutor inteligente (STI), sistema educativo multimedia inteligente (SEMI) o Sistema Educativo Hipermedia Personalizado (SEHP) con el objetivo de generar datos que complemente a los ya recopilados por el MA de estos sistemas.

La revisión realizada es sólo una visión general de la literatura del ALP y de ninguna manera es exhaustiva. Una revisión integradora y comparativa de diversas técnicas de personalización, tecnologías aplicables y modelos de

conocimiento con consideraciones especificas de Web y aprendizaje móvil sería un esfuerzo que bien valdría la pena.

Por otro lado, de acuerdo a la investigación realizada en este capítulo, las RBs son útiles en toda clase de situaciones, tienen gran versatilidad sobre todo en el modelado del alumno (ver por ejemplo, Millán, 2000; González, 2004, Henze y Nedjl, 1999, Conati y Gertner et al., 1997) y constituyen una herramienta muy potente para realizar inferencias abductivas y predictivas (Neapolitan, 2004). Sin embargo, no obstante su solidez teórica y su potencial, el área del modelado del alumno aún no está completamente explotada como debiera. Con nuestro trabajo, pretendemos colaborar en algo para que esta área sea aprovechada en su totalidad. Nuestro objetivo principal es usar la teoría de RBs presentada en el capítulo 3, en el modelado del alumno dentro del contexto del ALP con el propósito de predecir el TP del alumno.

# Capítulo 3

## Redes Bayesianas

**Resumen**. En este capítulo presentamos los aspectos teóricos para poder llevar a cabo la construcción de nuestro MB del capítulo 4. Representamos relaciones de causa y efecto usando los objetivos y objetos de personalización para determinar el tipo de personalización del alumno en la fase de los conocimientos previos, estudiamos los modelos de RBs, la importancia y la aplicación de éstos. Examinamos un método para realizar Inferencia Bayesiana con variables discretas y mostramos dos ejemplos que ilustran cómo las independencias condicionales implicadas por la condición de Markov pueden aprovecharse para realizar inferencia en una RB.

#### 3.1. Introducción

Actualmente, las personas pueden aprender mediante el uso de un sistema de enseñanza tal como el ALP, donde predominan los SIA como por ejemplo, los SGC, los Sistemas Tutores Inteligentes (STI), los Sistemas Hypermedia (SH), los Sistemas Educativos Multimedia Inteligentes (IMES), y las Interfases Adaptables al Usuario (IAU). En estos sistemas, el uso de los OAs, ops y OPs juega un papel muy importante ya que éstos envuelven cierta inteligencia que puede usarse para ayudar a guiar a un alumno a obtener un perfil deseable de conocimientos. La

elección particular de los OAs, ops y OPs puede causar un estilo de aprendizaje particular en un alumno, el cual, a su vez, tiene un efecto en el aprendizaje individual de este estudiante. Este es un ejemplo sencillo de lo que llamamos relaciones de causa-efecto. Uno de nuestros objetivos en esta tesis, es buscar este tipo de relaciones, recopilarlas en una red consistente que pueda usarse para ofrecer un diagnóstico y/o una retroalimentación al alumno de su situación actual en determinado concepto, módulo, tema o asignatura; o lograr al menos, que una parte apropiada de la red funcione. Llamamos a tales redes de relaciones de causa-efecto, modelos causales y son vistos en la sección 3.2 siguiente.

Los conceptos de teoría de gráficas y teoría de probabilidad que se mencionan en este capítulo, pueden ser encontrados respectivamente, en cualquier libro de Teoría de Gráficas. Ver por ejemplo, Gross y Yellen (2003) para Teoría de Gráficas y Walpole (1992), para Teoría de Probabilidad.

## 3.2. Expresión de relaciones causales

De acuerdo con Neapolitan (2004), las RBs pertenecen a una amplia clase de modelos que podemos utilizar para representar encajes o anidados (esto es, colocar una serie de objetos unos dentro de otros), pertenecen a los modelos estadísticos acíclicos de prácticamente, cualquier clase de fdp conjunta no anómala. Su característica distintiva reside en su habilidad para codificar

direcciones que pueden representar relaciones de causa-efecto, cosa que otros modelos gráficos no pueden, como por ejemplo las redes de Markov (Ver Pearl, 1988). Como un beneficio adicional, son capaces de representar muchas independencias en un dominio dado a través de una Gráfica Acíclica Dirigida (GAD), (ver Figura 3.1). Estas dos características están íntimamente ligadas: independencia son los efectos directos de las relaciones causales presentes.

En nuestro trabajo, aprovechamos la versatilidad de los modelos arriba mencionados, buscamos relaciones de causa-efecto entre los ops y OPs y las fases del proceso de aprendizaje mencionadas en la sección 2.4, para determinar el TP que pueda optimizar el PGALP del alumno. En esta tesis, determinamos estructuras causales usando restricciones que son únicamente pruebas independientes. Es decir, suponemos que los ops y OPs son eventos independientes entre si.

También, pueden utilizarse otra clase de restricciones para establecer apropiadamente el espacio de la estructura legal. Para más detalles sobre la semántica causal formal de las RBs ver: Neapolitan (2004); Neapolitan (1990); Pearl y Verma (1991); Spirtes, et al., (1993); Druzdzel y Simon, (1993); Heckerman, (1995); Heckerman y Geiger, (1995); Heckerman y Shachter, (1995); Heckerman et al., (1995a); Heckerman et al., (1995b).

Para realizar nuestra discusión de relaciones de causa-efecto e independencias más clara y concretamente, en la Figura 3.1 bosquejamos una GAD causal del TP de un alumno durante la fase de los conocimientos previos. Recordemos de la sección 2.4, que el TP es el tipo de adaptación del alumno al ambiente de

aprendizaje y la clase de adecuación del sistema electrónico de aprendizaje al estudiante con el propósito de que el estudiante optimice su PGA en determinada asignatura, concepto, tema o módulo.

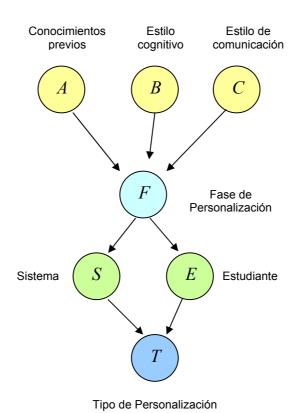


Figura 3.1. Una GAD causal del TP del alumno.

De acuerdo al modelo causal de la Figura 3.1, la fase de los conocimientos previos es causada por el estilo cognitivo, el estilo de comunicación, y el nivel de conocimientos previos. Las tres variables anteriores, determinan la adecuación que requiere el sistema y la capacitación que necesita el alumno. También, establece el perfil del estudiante que a su vez, determinará el TP del mismo. Este es el modelo causal que un programador razonablemente podría tener en mente

en este dominio. La conexión de la estructura de la RB reside en que este modelo involucra, en ese dominio, las tres variables aleatorias (v.v.a.a.) sobresalientes (los conocimientos previos, el estilo cognitivo y el estilo de comunicación del alumno). En adelante, cuando mencionemos la palabra variable, nos referimos una variable aleatoria.

En la sección 3.3 siguiente, estudiamos de forma breve las funciones de distribución de probabilidad (fdps) las cuales son necesarias para cubrir el requerimiento de la técnica de diseño de nuestro MB del capítulo 4.

## 3.3. Breve representación de las fdps

Además de su capacidad para simbolizar relaciones causales, las RBs han sido usadas para representar, de manera compacta, funciones de distribución de probabilidad (fdps) conjunta. De hecho, este es el uso más común de ellas actualmente. Esta habilidad surge de las fdps locales que son asignadas a cada variable en la RB, cuyo propósito es garantizar la potencia de las relaciones causales representadas en la red a través de su estructura: estas fdps locales. Cuando las fdps locales son distribuciones multinomiales, matemáticamente describen el comportamiento de esa variable bajo cada asignación del valor posible de sus nodos padres. Esta es la opción más común para variables categóricas. Puesto que para especificar este comportamiento se requieren una

determinada cantidad de parámetros exponenciales en el número de nodos padre, y dado que este número es regularmente más pequeño que el número de variables en el dominio, esto significa un ahorro en espacio exponencial (de almacenaje de parámetros) y tiempo (al usar las RBs para realizar estimaciones de funciones de un subconjunto de las variables del dominio).

Más concretamente, dada la estructura y las fdps locales de una RB, la fdp conjunta del dominio de n v.v.a.a.,  $P(X_1, X_2, \cdots, X_n)$  puede calcularse por medio de la ecuación (3.1):

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | pa_i)$$
 (3.1)

donde  $pa_i$  son los nodos padres de la variable  $X_i$  en la RB con gráfica G. Las probabilidades condicionales  $P(X_i|pa_i)$  que definen la fdp de la variable  $X_i$  dada una asignación de un valor  $pa_i$  de sus nodos padres en la gráfica de la ecuación (3.1), son exactamente aquellas fdps locales especificadas por cada variable en el dominio. En el apéndice A ampliamos el concepto de fdps locales, y detallamos la noción de d-separación. Usando la ecuación (3.1), pueden calcularse todas las combinaciones posibles de las asignaciones a las variables  $X_1, X_2, \cdots, X_n$ . Por ejemplo, para el caso planteado en la Figura 3.1, todas las variables en este dominio son discretas y las fdps son distribuciones multinomiales.

Los resultados posibles de las variables que aparecen en el GAD causal de la Figura 3.1 aparecen en la Tabla 3.1. Estas variables son discutidas en la sección 2.3.

Tabla 3.1. V.a. del MB de la Figura 3.1 y sus estados.

Variable aleatoria	Estados de la v.a.
Estilos cognitivos	1) Dependiente y 2) Independiente
Nivel conocimientos previos	1) Bajo, 2) Intermedio y 3) Alto
Estilo de comunicación	1) Pasivo, 2) Asertivo y 3) Agresivo
FP del pre-conocimiento	1) Con adaptación y 2) Sin adaptación
Adaptación del sistema	1) Automática y 2) Manual
Adaptación del alumno	1) Con capacitación y 2) Sin capacitación

De acuerdo con el MB de la Figura 3.1, el perfil (Conocimientos previos = Intermedio, Estilo cognitivo = Dependiente, Estilo de comunicación = Asertivo y personalización para el pre-conocimiento = Con adaptación) tiene probabilidad:

P(Intermedio, Dependiente, Asertivo, Con adaptación) =  $= P(Con adaptación | Intermedio, Dependiente, Asertivo,) \times$   $\times P(Intermedio, Dependiente, Asertivo) =$   $= P(Con adaptación | Intermedio, Dependiente, Asertivo) \times$   $\times P(Intermedio) \times P(Dependiente) \times P(Asertivo)$ 

Para efectuar este cálculo, hacemos uso del hecho de que en la estructura de la RB, las tres v.a importantes (Conocimientos previos, Estilo cognitivo y estilo de comunicación) son incondicionalmente independientes entre sí, y por lo tanto, su probabilidad conjunta puede ser calculada por el producto de sus probabilidades marginales. La probabilidad conjunta para cualequiera de los valores asignados a cada una de las variables, puede calcularse de la misma manera.

En este trabajo de tesis nuestro objetivo es calcular probabilidades del perfil del alumno, tales como:

P(Alto, Dependiente, Asertivo, Con adaptación, Automático, Con capacitación)

Este cálculo determinará la credibilidad del sistema que un alumno específico, pertenezca al perfil. Una vez determinado el perfil del estudiante, se puede proceder a la elaboración del MA personalizado. En la sección 4.3, se ilustra la manera de cómo realizar estos cálculos.

También, podemos calcular asignaciones parciales, (por ejemplo, P(Dependiente), las cuales se pueden hacer de varias maneras. Una de las más simples es el cálculo de las probabilidades marginales, que implica sumar (o integrar, cuando se trata de variables contínuas) sobre aquellas variables que no aparecen en la expresión y en cuya probabilidad estamos interesados. La presencia de independencias acelera el cálculo de la conjunción, puesto que reduce el número de entradas que necesitamos sumar excesivamente.

Más allá de nuestro ejemplo, un modelo de RBs puede usarse para calcular la probabilidad de cualquier evento (conjunción de asignaciones de variables) que involucre variables en el dominio, condicionado a cualquier otro evento. Este proceso es llamado inferencia probabilística. En general, la inferencia probabilística es un problema de complejidad *NP*-completo<sup>1</sup>, debido a que cualquier algoritmo puede requerir de marginalización en un número exponencial

SAT. En este grupo caen los problemas de decisión que no pueden ser resueltos en tiempo polinomial.)

70

<sup>&</sup>lt;sup>1</sup> Dependiendo del orden de complejidad de un problema, existen una serie de algoritmos aplicables. El mejor algoritmo que se conozca determina el orden. A la fecha existen cuatro tipos de problemas que escapan a un tratamiento informático: 1) La clase P (de complejidad polinómica), 2) La clase NP (no polinomial deterministas), 3) La clase NP-completos (de extrema complejidad) y 4) la clase NP-duros (de satisfiabilidad

de asignaciones de variables, en el peor de los casos, es decir, cuando existen muchas dependencias en el dominio, Sin embargo, en muchas aplicaciones prácticas un número significativo de independencias está presente, haciendo la inferencia manejable.

Existen una cantidad de algoritmos cuyo propósito es automatizar la inferencia probabilística. Tales algoritmos incluyen métodos exactos tales como el condicionamiento de un conjunto de cortaduras (Pearl, 1997; Darwiche, 1995; Suermondt y Cooper, 1990), unión de árboles (Lauritzen y Spiegelhalter, 1988; Jensen et al., 1990; Huang y Darwiche 1994), extracción de nodo (Schachter, 1990), y manipulación simbólica (Chang y Fung, 1990; Schachter et al., 1990), así como un número de aproximaciones tales como muestreos lógicos (Henrion, 1988) y muestreos Gibas (Pearl, 1987; Chávez y Cooper, 1990).

En la sección 3.4 siguiente, examinamos la técnica que usamos para construir nuestro MB del capítulo 4.

#### 3.4. Construcción de RBs usando los bordes causales

De acuerdo con Neapolitan (2004), dado un conjunto de v.v.a.a. V, si para cada X y  $Y \in V$ , trazamos un borde de X a Y si y sólo sí X es una causa directa de Y relativa a V, llamamos a la GAD resultante una GAD causal. Por lo regular, existen muchas GAD distintas que representan exactamente el mismo conjunto de

relaciones de independencia, y por lo tanto, el mismo conjunto de distribuciones. En este contexto se han desarrollados distintos algoritmos que permiten calcular d-separación (ver sección A2 del Apéndice A y Pearl (1988); Dimitris (2003); Neapolitan (2004)) de cualquier gráfica, y que además son capaces de generar todas las GADs posibles dado un conjunto específico (y conocido) de relaciones de independencia. Si se desea realizar un análisis más profundo sobre GADs causales ver Pearl (2000). En el apartado 3.4.1, revisamos el concepto de causalidad y un método para determinar influencias causales. En la sección 3.4.2., ilustramos el hecho de que la fdp conjunta (frecuencia relativa) de las variables en una GAD causal, regularmente satisface la condición de Markov con la GAD. La condición de Markov es una condición necesaria para poder calcular la fdp conjunta (Ver Neapolitan (2004), p.p. 39 y 42). Además, explicamos el significado de "X" es una causa directa de Y relativa a V (al menos para una definición de causalidad).

#### 3.4.1. Determinación de influencias causales usando manipulación

Según la Real Academia Española (RAE, 2007), la definición de una causa es: "Aquello que se considera como fundamento u origen de algo" Aunque útil, esta sencilla definición no es, en lo absoluto, la última palabra dentro del concepto de causalidad, (ver por ejemplo, Eells, 1991; Hume, 1988; Piaget, 1966; Salmon, 1994; Spirtes et al., 1995; Pearl, (1993, 2000)). Sin embargo, la definición de la Real Academia Española, arroja un método operacional para identificar relaciones

causales. De acuerdo con Cooper (1999), si la acción de hacer que la variable X tome algún valor, algunas ocasiones cambia el valor tomado por la variable Y, entonces suponemos que X es el responsable de algunos cambios en el valor de Y, y concluimos que X es una causa de Y. Más formalmente, decimos que "manipulamos" a X cuando forzamos a que X tome algunos valores, y decimos que X "causa a" Y, si existe alguna manipulación de X que implica un cambio en la fpd de Y. Supongamos que si al manipular X se produce un cambio en la fpd de Y, entonces X, que obtiene un valor por algún medio, también conduciría a un cambio en la fpd de Y. Así que suponemos que las causas y los efectos están estadísticamente correlacionados. Además, como se verá más adelante en esta sección, las variables pueden estar correlacionadas sin que una cause a la otra. Conforme a Neapolitan (2004), una manipulación consiste en un experimento aleatorio controlado, en donde se usa una población específica de identidades (por ejemplo, alumnos con un nivel de conocimientos previos alto), en un contexto específico (por ejemplo, si los alumnos antes mencionados no reciben actualmente un curso en línea y ellos son de un área geográfica particular). La relación causal descubierta es entonces, relativa a esta población y a este contexto. Ahora, veamos de qué modo procede la manipulación.

Primero identificamos a la población de entidades que deseamos considerar. Nuestras v.v.a.a. son características de esas entidades. Luego determinamos las relaciones causales que queremos investigar. Suponga que estamos tratando de determinar si una variable X es una causa de la variable Y. Entonces muestreamos un número de entidades de la población. Para cada entidad

seleccionada, manipulamos el valor de X de tal manera que cada uno de sus valores posibles sea dado al mismo número de entidades. (Si X es contínua, escogemos los valores de X de acuerdo a la distribución uniforme). Después de que el valor de X sea determinado para una entidad dada, medimos el valor de Y para esta entidad. Entre más los datos resultantes muestren una dependencia entre X y Y, más los datos sostienen que X influencia causalmente a Y. Las manipulaciones de X pueden representarse por una variable M que sea externa al sistema que está siendo estudiado. Según Neapolitan (2004), existe un valor  $m_i$  de M para todo valor de  $x_i$  de X, donde las probabilidades de todos los valores de M son los mismos, y cuando M es igual a  $m_i$ , X es igual a  $x_i$ . Esto es, la relación entre M y X es determinista. Los datos indican que X, causalmente influencia a Y para la extensión donde los datos indiquen  $P(y_i|m_j) \neq P(y_i|m_k)$  para  $j \neq k$ . La manipulación es actualmente una clase especial de relación causal que suponemos que existe primordialmente y que está dentro de nuestro control tanto que podemos definir y descubrir otras relaciones causales.

Para ilustrar las ideas anteriores, suponga que E y A representan respectivamente, el estilo de enseñanza de un profesor en un curso dado y el aprendizaje logrado por el alumno en el curso mencionado. Si E causó a A, entonces con toda seguridad estarán relacionados estadísticamente, pero también sería el caso si A causó a E, o bien si hubiera alguna causa común oculta O. En la Figura 3.2 se muestran estas tres posibilidades y dos más.

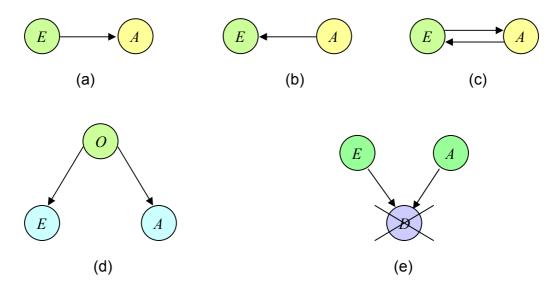


Figura 3.2. Las cinco relaciones causales posibles entre E y A cuando éstos están correlacionados.

La Figura 3.2 (a) muestra la suposición de que E causa a A, es decir, lo que inicialmente sospechábamos. Sin embargo, podría darse el caso de que E cause a A (caso de la Figura 3.2 (b)), podemos argumentar que basado en el conocimiento de dominio, esto no parecería razonable. No obstante, en general no tenemos dominio de conocimiento cuando realizamos un análisis estadístico. Basándose sólo en la correlación, las relaciones causales de la Figura 3.2 (a) y (b) son igualmente razonables. Inclusive en este dominio, E causante de E0 puede parecer posible. Un profesor podría haber estado experimentando los diferentes estilos de enseñanza-aprendizaje y al notar que uno de ellos le dio más resultados que los otros, éste se decidió a elegir ese estilo de enseñanza. Como una tercera posibilidad, puede ser que tanto el estilo de enseñanza del profesor cause un mejor aprendizaje en el alumno como un mejor aprendizaje del alumno cause el estilo de enseñanza del profesor, como resultado tendríamos un lazo causal o una

retroalimentación. Por lo tanto, la Figura 3.2 (c) también es una posibilidad. En la Figura 3.2 (d) se muestra una cuarta posibilidad, cuando E y A tiene causas comunes ocultas (O) que explican su correlación. Por ejemplo, un profesor preocupado por mejorar los resultados en el aprendizaje de sus alumnos, puede tratar con dos estilos distintos de enseñanza, el tradicional y otro. El nuevo estilo puede causar el mejoramiento del aprendizaje en los estudiantes, mientras que el estilo tradicional no. En este caso, la preocupación del profesor es una causa del nuevo estilo de aprendizaje, y del mejoramiento en el aprendizaje de los alumnos (indirectamente de su estilo tradicional), mientras que los dos estilos de enseñanza no se relacionan causalmente. Una quinta posibilidad consiste en que estamos observando a una población, en donde todas las personas involucradas tienen algunos efectos (posiblemente ocultos), tanto en E como en A. Por ejemplo, suponga que el estilo de enseñanza y la preocupación del profesor por mejorar el aprendizaje de sus alumnos son ambas causas de deserción, y pasamos a ser observadores de alumnos que desertaron del curso D. Conforme a Neapolitan (2004), un nodo se dice que está "instantiado", cuando conocemos el valor del estado o entidad en el momento que está siendo modelado. De este modo, estamos diciendo que D está instantiado por el mismo valor para todas las entidades de la población que estamos observando. Esta situación es bosquejada en la Figura 3.2 (e) donde la cruz sobre D significa que la variable está instanciada. Los sicólogos llaman a esto "actualización" (discounting), (Ver Neapolitan (2004), p.p. 51 y 174). De modo que si este fuera el caso, la actualización explicaría la correlación entre E y A.

En la sección 3.4.2 siguiente, ilustramos que la fpd conjunta de las variables en una GAD causal, regularmente satisface la condición de Markov con la GAD y explicamos lo que significa que "X" sea una causa directa de Y relativa a V.

## 3.4.2. Causalidad y la condición de Markov

#### > Causalidad

Basándonos en la definición de manipulación de causalidad dada en la sección 3.4.1 anterior, y conforme a Neapolitan (2004), "X es una causa directa de Y relativa a Y" significa que una manipulación de X cambia la fpd de Y, y que no existe un subconjunto  $W \subseteq V - \{X,Y\}$  tal que si instanciamos los variables en W, una manipulación de X no cambia radicalmente la fpd de Y. Cuando se construye una GAD causal que contiene un conjunto de variables Y llamamos a Y "el conjunto de variables observadas". Veamos ahora el porqué las GAD causales satisfacen la condición de Markov. Primero, ya se han realizado experimentos de manipulación que comprueban esta aseveración. Es decir, ha habido experimentos donde está establecido que X causa a Y, Y causa a X, X y Z no son probabilísticamente independientes y, X y Z son independientes condicionalmente dado Y. (Ver Lugg et al., (1995) para un ejemplo).

En general, cuando todas las veredas causales de X a Y contienen al menos una variable en nuestro conjunto de variables observadas V, X y Y no tienen una causa común, no existen veredas causales de Y de regreso a X, y no tenemos prejuicio

en la selección, entonces consideramos que X y Y son independientes si condicionamos sobre un conjunto de variables, las cuales incluyen al menos una variable en cada una de las veredas causales de X a Y. Puesto que el conjunto de todos los nodos padres de Y es tal conjunto, consideramos que la condición de Markov se satisface en relación a X y Y. Decimos que X y Y tienen una causa común si existe una variable que tenga veredas causales tanto en X y Y. Si X y Y tienen una causa común X, normalmente existe una dependencia entre ellas debido a esta causa común. Sin embargo, si condicionamos en el nodo padre de Y en la vereda de Y Y, rompemos la dependencia por las mismas razones antes discutidas. Así, mientras todas las causas comunes están en nuestro conjunto de variables observadas Y, podemos todavía romper dependencias entre Y y Y (suponiendo como antes que no existen veredas causales de Y Y0, mediante un condicionamiento en el conjunto de los nodos padres de Y10 que significa que la condición de Markov aún se satisface en relación a Y Y.

Podría surgir un problema cuando, por lo menos una causa común, no está en nuestro conjunto de variables observadas V. Esta causa común es llamada variable oculta. Si dos variables tuvieran una causa común oculta, regularmente habría una dependencia entre ellas, que la condición de Markov identificaría como una independencia. Por ejemplo, consideremos la GAD de la Figura 3.3, si identificamos sólo las variables X, Y y Z y las relaciones causales que X y Y causaron en Z, trazaríamos bordes desde X y Y a Z. La condición de Markov implicaría que X y Y fueran independientes. Pero si X y Y tuvieran una causa común oculta H, ordinariamente no serían independientes. Así que, para nosotros

asumir que la condición de Markov se satisface, ninguna de las dos variables en el conjunto de las variables observadas V puede tener una causa común oculta o si la tiene, debe tener el mismo valor desconocido para cada unidad en la población bajo consideración. Cuando este es el caso, decimos que el conjunto es causalmente suficiente.

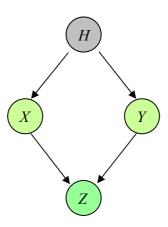


Figura 3.3. X y Y no son independientes si tienen una causa común oculta H.

Por último, debemos asegurarnos también que si X tiene una influencia causal sobre Y, entonces Y no tiene una influencia causal en X. De esta manera garantizamos que los bordes causales identificados producen en realidad una GAD, los lazos de retroalimentación causal es decir, la situación mostrada en la Figura 3.2 (c) se discuten en Richardson y Spirtes (1999).

#### > La suposición causal de Markov.

Hemos ofrecido arriba, una definición de causalidad basada en la manipulación y hemos argumentado que, dada la definición de causalidad, una GAD causal

regularmente satisface la condición de Markov con la fpd de las variables, lo que significa que podemos construir una RB mediante la creación de una GAD causal. En general, dadas cualesquiera definiciones de "causalidad" e "influencia causal directa", si creamos una GAD causal G = (V, E) y suponemos que la fpd de las variables en V satisface la condición de Markov con G, decimos que estamos haciendo la suposición causal de Markov. Finalmente, si las siguientes tres condiciones se satisfacen, la suposición causal de Markov está ordinariamente garantizada (Neapolitan, 2004):

- 1) No debe haber causas comunes ocultas.
- 2) No debe existir sesgo de la selección,
- 3) No debe haber lazos de retroalimentación causal.

Es en estos conceptos teóricos, donde nos basamos para construir nuestra GAD causal del capítulo 4. En la sección 3.5 siguiente, definimos lo que es un MB.

#### 3.5. Modelos de RBs

De acuerdo con Pearl (1988), un modelo de RBs es una representación gráfica de una fpd sobre el conjunto de variables  $\Omega = \{X_1, X_2, \cdots, X_n\}$ . Esta consiste de dos partes:

1) La estructura de la red dirigida en la forma de GAD, y

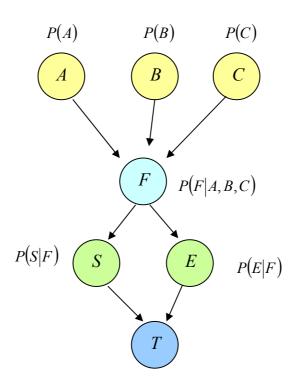
 Un conjunto de fdps condicional locales, una para cada nodo (o variable) en cada combinación de valor de los nodos padres.

La estructura de la red es forzada a que sea acíclica, se permiten ciclos no dirigidos, es decir, ciclos por los cuales no todos los bordes son dirigidos en el mismo sentido. Tales estructuras representan veredas alternativas de influencia posible entre ciertas variables en el ciclo. Friedman y Goldszmidt, (1996) presentan un modelo que contiene cinco v.v.a.a. y éstos sugieren ver a las RBs como una "historia".

Estos modelos según Pearl (1988), cuando se usan junto con técnicas estadísticas, la estructura gráfica tienen las siguientes ventajas para el análisis de datos:

- El modelo codifica dependencias entre todas las variables, fácilmente manipula situaciones donde haga falta algunas entradas de datos.
- Una RB puede usarse para aprender relaciones causales, y por lo tanto, puede utilizarse para obtener entendimiento de un dominio problemático y realizar pronósticos de las consecuencias de la intervención.
- El modelo tiene tanto semánticas probabilísticas como causales, es una representación ideal para combinar conocimiento previo (el cual frecuentemente viene en forma causal) y datos.
- Los métodos estadísticos Bayesianos junto con las RBs ofrecen un método basado en principios y eficiente para evitar el "sobre-ajuste" de datos.

La Figura 3.4 muestra un MB que puede ser usado para modelar el TP del alumno en la fase de los conocimientos previos.



Tipo de personalización

Figura 3.4. Un MB modelando el TP de un alumno.

En la Figura 3.4, A, B y C son eventos independientes entre si y, A y S son independientes dado F. Esto nos indica que no hay eventos que afecten a los conocimientos previos y al sistema.

También  $A^c$  y S son independientes dado F. Esto significa que un ajuste o adaptación en la fase de los conocimientos previos, puede deberse únicamente a causa del sistema, este ajuste o adaptación no resultaría como una consecuencia del nivel de conocimientos previos del alumno.

m El uso de las RBs ofrece muchas ventajas sobre los métodos tradicionales para determinar la relación causal. La independencia entre variables es fácil de reconocer y de aislar mientras que las relaciones condicionales son delimitadas claramente por una arista dirigida del gráfico: dos variables son independientes si todas las trayectorias entre ellas están bloqueadas (dado que las aristas son direccionales). No todas las probabilidades conjuntas necesitan calcularse para tomar una decisión; los ramas y relaciones extrañas pueden ignorarse (Uno puede hacer una predicción de una visita de la policía sin importar si se da una señal de alarma). Se asocia a cada nodo un conjunto de distribuciones de probabilidades condicionales. En la sección 5.2, presentamos un caso casuístico donde usamos MB para realizar los cálculos y hacer las inferencias del TP del alumno.

En general, la representación de una RB consiste de un conjunto de afirmaciones estadísticas condicionales e independientes, que son implicadas por su estructura. Bajo las suposiciones que se describen en la sección 3.4, las cuales incluyen afirmaciones de independencia a partir de una serie de axiomas descritos en Neapolitan (2004), y en Pearl (1997), podemos formar el conjunto completo de relaciones de independencia que son implicados por este modelo de RBs. Sin embargo, determinar las relaciones de independencia que son ocasionadas por G a partir de estos axiomas puede resultar difícil, debido a que éstos requieren su uso repetido hasta que la relación deseada sea probada o desaprobada. Un método equivalente es "leer" esas independencias de la estructura de un modelo

de RBs utilizando las reglas de d-separación (ver sección A2 del apéndice A), puesto que es significativamente más fácil que usar el conjunto de axiomas arriba citados, regularmente es el método de elección en la práctica.

Por último, existen varios STIs basados en RBs tales como OLAE (Martin y VanLehn (1995a, 1995b)), POLA (Conati y VanLehn (1996a, 1996b)), ANDES (VanLehn et al., 1998; Conati et al., (1997a, 1997b); Gertner, 1998; VanLehn, 1996). HYDRIVE (Mislevy y Gitomer, 1996). CAPIT (Mayo et al., 2000; Mayo, 2001). POET (Royalty et al., 2002) y SIETTE (Millán, 2000) que son utilizados con éxito para construir y actualizar el MA. En Millán (2000), se realiza una descripción de estos y otros STIs. Ahora, una vez vistos los modelos de RBs, en la sección 3.6 siguiente, mostramos como realizar inferencias usando estos modelos.

### 3.6. Inferencia Bayesiana (IB) con variables discretas

Una aplicación típica del teorema de Bayes (Ver Walpole, 1992), y que realizamos en esta sección, es la inferencia en una RB de dos nodos. Las RBs más grandes, conducen al problema de representar la fdp conjunta de un gran número de variables y realizar IB con estas variables. A continuación, presentamos dos ejemplos que ilustran cómo las independencias condicionales

implicadas por la condición de Markov pueden aprovecharse para conseguir inferencia en una RB.

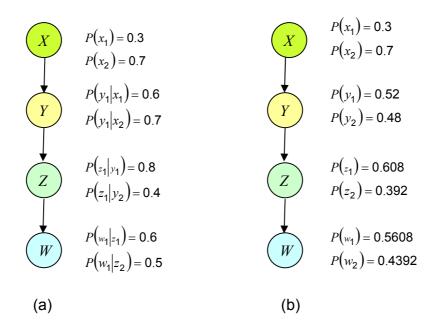


Figura 3.5. En (a) se muestra una RB y en (b) las probabilidades previas de las variables de la red.

Como primer ejemplo, consideremos la RB de la Figura 3.5(a), (En la Figura 3.5, cada variable tiene sólo dos valores; en (a) se muestra la probabilidad de una sola variable). Las probabilidades previas de todas las variables pueden calcularse usando la ley de la probabilidad total (ver sección A3 del Apéndice A), como sigue:

$$P(y_1) = P(y_1|x_1)P(x_1) + P(y_1|x_2)P(x_2) = (0.6)(0.4) + (0.7)(0.4) = 0.52$$
(3.2)

$$P(z_1) = P(z_1|y_1)P(y_1) + P(z_1|y_2)P(y_2) = (0.8)(0.52) + (0.4)(0.48) = 0.608$$
(3.3)

$$P(w_1) = P(w_1|z_1)P(z_1) + P(w_1|z_2)P(z_2) = (0.6)(0.608) + (0.5)(0.392) = 0.5608$$
 (3.4)

Estas probabilidades se muestran en la Figura 3.5 (b). Nótese que el cálculo de cada variable requiere de la información determinada por su padre. Podemos, por

lo tanto, considerar este método un algoritmo para transmitir un mensaje en el que cada nodo trasmite a su hijo un mensaje requerido para calcular las probabilidades de los hijos. Claramente, este algoritmo se aplica a una lista larga enlazada arbitrariamente, y a árboles. Supongamos ahora que X está instantiado (es decir, conocemos el valor de su estado al instante de modelarlo) por  $x_1$ , puesto que la condición de Markov implica que cada variable es independiente condicionalmente de X, dado su nodo padre, podemos calcular las probabilidades condicionales de las variables restantes, trasmitiendo el mensaje una vez más hacia debajo de la manera siguiente:

$$P(y_1|x_1) = 0.6$$

$$P(z_1|x_1) = P(z_1|y_1, x_1)P(y_1|x_1) + P(z_1|y_2, x_1)P(y_2|x_1)$$

$$= P(z_1|y_1)P(y_1|x_1) + P(z_1|y_2)P(y_2|x_1)$$

$$= (0.8)(0.6) + (0.4)(0.4) = 0.64$$
(3.5)
$$(3.6)$$

$$P(w_1|x_1) = P(w_1|z_1, x_1)P(w_1|z_2) + P(z_1|y_2, x_1)P(z_2|x_1)$$

$$= P(w_1|z_1)P(z_1|x_1) + P(w_1|z_2)P(z_2|x_1)$$

$$= (0.6)(0.64) + (0.7)(0.36) = 0.636$$
(3.11)

Evidentemente que, este algoritmo también se aplica a una larga lista de nodos enlazada arbitrariamente, y a árboles.

La instantiación precedente muestra cómo podemos usar la propagación de mensajes hacia abajo para calcular las probabilidades condicionales de variables abajo de la variable instanciada. Supongamos ahora, que W está instanciada por  $w_1$  (y que ninguna otra variable está instanciada). Podemos usar la propagación de los mensajes hacia arriba para calcular las probabilidades condicionales de las variables siguientes como sigue: primero usamos el teorema de Bayes para calcular  $P(z_1|w_1)$ .

$$P(z_1|w_1) = \frac{P(w_1|z_1)P(z_1)}{P(w_1)} = \frac{(0.6)(0.608)}{0.5608} = 0.6505$$
 (3.12)

Luego, para calcular  $P(y_1|w_1)$ , aplicamos una vez más el teorema de Bayes (Walpole, 1992), de la manera siguiente:

$$P(y_1|w_1) = \frac{P(w_1|y_1)P(y_1)}{P(w_1)}$$
 (3.13)

Pero, aún no podemos terminar este cálculo porque desconocemos  $P(w_1|y_1)$ . Sin embargo, podemos obtener este valor de la manera mostrada anteriormente, cuando discutimos la propagación del mensaje hacia abajo. Esto es,

$$P(w_1|y_1) = P(w_1|z_1)P(z_1|y_1) + P(w_1|z_2)P(z_2|y_1)$$
(3.14)

Después de realizar este cálculo, calculamos también  $P(w_1|y_2)$  (ya que X necesitará este valor más tarde), y luego determinando  $P(y_1|w_1)$  trasmitimos  $P(w_1|y_1)$  y  $P(w_1|y_2)$  a X. Entonces calculamos  $P(w_1|x_1)$  y  $P(x_1|w_1)$  consecutivamente como sigue:

$$P(w_1|x_1) = P(w_1|y_1)P(y_1|x_1) + P(w_1|y_2)P(y_2|x_1)$$
(3.15)

$$P(x_1|w_1) = \frac{P(w_1|x_1)P(x_1)}{P(w_1)}$$
 (3.16)

Naturalmente que, este esquema de propagación se aplica a una larga lista enlazada arbitrariamente. Como un segundo ejemplo, consideremos la RB de la Figura 3.6. Aquí, cada v.a. tiene sólo dos valores posibles, mostramos la probabilidad de una sola variable.

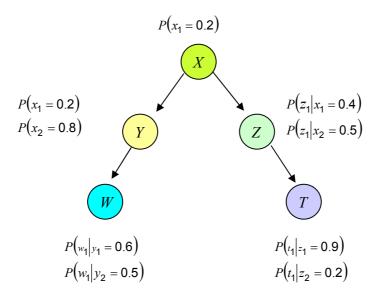


Figura 3.6. Una RB que es un árbol.

Supongamos que W está instantiado por  $w_1$ . Podemos calcular  $P(y_1|w_1)$  seguido de  $P(x_1|w_1)$ , usando el algoritmo de propagación hacia arriba de la siguiente manera:

$$P(y_1|w_1) = \frac{P(w_1|y_1)P(y_1)}{P(w_1)}$$
 (3.17)

Pero,

$$P(w_1|y_1) = P(w_1|y_1)P(y_1) + P(w_1|y_2)P(y_2)$$
(3.18)

$$P(y_1) = P(y_1|x_1)P(x_1) + P(y_1|x_2)P(x_2)$$
(3.19)

У

$$P(w_1) = P(w_1|y_1)P(y_1) + P(w_1|y_2)P(y_2)$$
(3.20)

Sustituyendo los valores dados en la Figura 3.6 de abajo hacia arriba, se obtiene el resultado deseado.

Para calcular  $P(x_1|w_1)$  se tiene que:

$$P(x_1|w_1) = \frac{P(w_1|x_1)P(x_1)}{P(w_1)}$$
 (3.21)

Pero,

$$P(w_1|x_1) = P(w_1|y_1)P(y_1|x_1) + P(w_1|y_2)P(y_2|x_1)$$
(3.22)

Al sustituir los valores dados en la Figura 3.6 de abajo hacia arriba, se tiene el valor buscado.

Ahora bien, para calcular  $P(z_1|w_1)$  seguido de  $P(x_1|w_1)$  se utiliza el algoritmo de propagación hacia abajo. Se tiene que,

$$P(z_1) = P(z_1|x_1)P(x_1) + P(z_1|x_2)P(x_2)$$
(3.23)

$$P(w_1) = P(w_1|y_1)P(y_1) + P(w_1|y_2)P(y_2)$$
(3.24)

$$P(w_1|z_1) = P(w_1|y_1, x_1)P(y_1|x_1) + P(w_1|y_2, x_1)P(y_2|x_1)$$
(3.25)

$$= P(w_1|y_1)P(y_1|x_1) + P(w_1|y_2)P(y_2|x_1)$$
(3.26)

Y como

$$P(z_1|w_1) = \frac{P(w_1|z_1)P(z_1)}{P(w_1)}$$
 (3.27)

Sustituyendo los valores dados en la Figura 3.6 de arriba hacia abajo, obtenemos el valor deseado. Para calcular  $P(t_1|w_1)$ , se procede de manera similar a la antes expuesta. Tenemos que,

$$P(z_1) = P(z_1|x_1)P(x_1) + P(z_1|x_2)P(x_2)$$
 (3.28)

$$P(t_1) = P(t_1|z_1)P(z_1) + P(t_1|z_2)P(z_2)$$
(3.29)

$$P(w_1) = P(w_1|y_1)P(y_1) + P(w_1|y_2)P(y_2)$$
(3.30)

Pero,

$$P(t_1|x_1) = P(t_1|z_1, x_1)P(z_1|x_1) + P(t_1|z_2, x_1)P(z_2|x_1)$$

$$= P(t_1|z_1)P(z_1|x_1) + P(t_1|z_2)P(z_2|x_1)$$
(3.31)

$$P(w_1|t_1) = P(w_1|t_1, z_1)P(t_1|x_1) + P(w_1|t_2, z_1)P(t_2|x_1)$$

$$= P(w_1|t_1)P(t_1|x_1) + P(w_1|t_2)P(t_2|x_1)$$
(3.34)

У

$$P(t_1|w_1) = \frac{P(w_1|t_1)P(t_1)}{P(w_1)}$$
 (3.35)

Sustituyendo los valores dados en la Figura 3.6 de arriba hacia abajo, se tiene el valor buscado. Para saber más sobre IB y algoritmos que realizan IB, ver por ejemplo, Neapolitan (2004); Millán (2000) y Loredo (2000).

## 3.7. Complejidad de la inferencia Bayesiana (IB)

Se ha demostrado que el problema de IB es *NP*-duro (ver sección 3.3). Específicamente, Cooper (1990), obtuvo el resultado de que, para el conjunto de RBs que no están restringidas a tener más de dos valores por nodo, y no más de dos padres por nodo, sin la restricción en el número de hijos, el problema de determinar las probabilidades condicionales de variables faltantes, dado que ciertas variables han sido instanciadas, en redes multi-conectadas, es #*P*-completo. Los problemas #*P*-completos son un caso especial de algoritmos *NP*-duros –particularmente, la respuesta a un problema #*P*-completo sería la solución a varios problemas *NP*-completos. A la luz de este resultado, los investigadores han trabajado en algoritmos de aproximación para inferir en RBs (Ver por ejemplo, Neapolitan, 2004).

A continuación presentamos las conclusiones de este capítulo

## 3.8. Conclusión del capítulo

Una vez visto el marco teórico necesario para el diseño de nuestro MB, presentamos la conclusión metodológica. En este capítulo se han presentado los conceptos básicos de las RBs, que nos son útiles para formular el diseño del MB que nos permite hacer un diagnóstico del TP del alumno. Existen los elementos suficientes para que nuestro modelo sirva para adecuar al alumno al sistema electrónico y el sistema electónico al alumno a fin de que el estudiante optimice su PGALP.

La IB puede realizarse tanto con variables discretas como continuas y a medida que se recopilen más datos, el pronóstico del TP del alumno, será más exacto. Mostramos además, ejemplos de cómo se puede realizar la IB y referimos algunos algoritmos para llevar a cabo esta inferencia.

A continuación, explicaremos las razones por las que hemos descartado otros modelos de razonamiento aproximado (tal como lógica difusa, factores de certeza, teoría de Dempster-Shafer y la lógica no monótona)

No obstante que la lógica difusa es una alternativa a las RBs por su capacidad para procesar datos de entrada expresados verbalmente de forma imprecisa, ésta debe ser considerada en aquellas situaciones en que:

◆ El razonamiento que hay que realizar se pueda describir en términos de conceptos, operadores o reglas imprecisas. Este razonamiento puede ser el relativo al alumno, cuyo comportamiento se está

- tratando de anticipar, o al tutor humano cuyo conocimiento estamos intentando transferir al sistema tutor.
- Necesitamos procesar datos de entrada imprecisos, por ejemplo, en el caso de un tutor que tenga que procesar afirmaciones en lenguaje natural.

Ninguno de los dos casos mencionados es el nuestro, ya que si utilizamos lógica difusa nos veremos en la necesidad de elegir diferentes interpretaciones para algunos conceptos, como por ejemplo entre diferentes procesos de pasarse de difuso a nítido o diferentes significados para los operadores AND, OR y NOR.

- No hemos elegido el uso de factores de certeza debido a la carencia de una base teórica sólida. Cuando se usan este tipo de modelos sin bases teóricas, las inconsistencias pueden hacer que el comportamiento del MA sea imprescindible, especialmente en situaciones que no han sido consideradas previamente por sus autores.
- En la teoría de Dempster-Shafer encontramos dos problemas:
  - Fundamentar una decisión en los resultados del análisis es más complicado que cuando utilizamos una RB, puesto que con ésta, cada hipótesis se asocia con una sola probabilidad, mientras que en la teoría de Dempster-Shafer para cada hipótesis existen tres medidas diferentes para explicar la compatibilidad de la hipótesis con la evidencia existente y se requieren criterios adicionales.

◆ La teoría de Dempster-Shafer realiza inferencia abductiva, pero no predictiva, con lo cual no permite realizar predicciones que es nuestro propósito en este nuestro trabajo de tesis.

Finalmente, aunque las RBs presentan ciertas desventajas tales como:

- ◆ El esfuerzo que se requiere para especificar el modelo (variables y relaciones causales) y estimar los parámetros (probabilidades condicionales).
- ◆ La complejidad computacional de los algoritmos de propagación.
- ◆ La dificultad que requiere la implementación de los mismos.

El tema nos ha llamado la atención para expresar nuestras ideas. Estamos convencidos que los modelos probabilisticos basados en RBs, son una buena opción para llevar a cabo la modelación del alumno. Estos modelos, a medida que se recopile un mayor número de datos, pueden realizan un diagnóstico más exacto del tipo de personalización del alumno.

### Capítulo 4

# Propuesta de un modelo de integración de técnicas Bayesianas en el ALP

Resumen. En este capítulo presentamos nuestro MB que realiza un diagnósis del tipo de personalización del alumno y que puede usarse para optimizar el PGALP del alumno. Este modelo contempla los objetos y objetivos de personalización que determinan las necesidades reales del alumno, las cuatro fases de personalización: El alcance del modelo que proponemos en esta tesis, contempla cuatro fases fundamentales de la personalización del aprendizaje en línea: 1) Fase de personalización para los conocimientos previos, 2) Fase de personalización para el progreso del conocimiento, 3) Fase de personalización para objetivos y metas del profesos/alumno y 4) Fase de personalización para las preferencias y experiencia de navegación. La evaluación del modelo se realiza usando la primera fase y con datos obtenidos en un curso en línea con 45 alumnos simulados de diferentes áreas del conocimiento. 1) Definimos las métricas de personalización para cada una de las variables de personalización que intervienen en el MB y proponemos las fdps para cada una de dichas variables. La evaluación arriba mencionada, demuestra empíricamente la eficacia de las redes Bayesianas en la modelación del alumno, específicamente en la realización de inferencia Bayesiana en casos de incertidumbre sobre los objetos y objetivos de personalización del alumno o bien en caso de pérdida de datos.

#### 4.1. Introducción

De acuerdo con Negnevitsky (2004) y Russell y Norvig (2003), una manera de construir una RB es mediante la ingeniería del conocimiento (IC). Un ingeniero del conocimiento puede interactuar con un dominio experto para identificar los

aspectos cualitativos de un problema, tal como las relaciones directas entre las variables involucradas en el problema. Luego, estas relaciones se codifican en la estructura de la RB para que pueda ser procesado por un sistema. En la sección 4.2., usaremos el método de la IC, combinado con el procedimiento descrito en la sección 3.3, suponemos que hay independencia entre los OPs, ops, fases de aprendizaje, alumno y sistema para construir la RB que representa al TP del alumno. Esto conforma nuestro MB propuesto.

## 4.2. Representación del tipo de personalización (TP) del alumno mediante RBs (Modelo propuesto)

De acuerdo con Henrion (1989) y Neapolitan (2004), construir una RB para un dominio de aplicación específico, implica una serie de pasos o tareas. El primero de estos pasos consiste en: 1) Identificar cada una de las variables importantes en el dominio, y 2) Determinar el conjunto de los posibles resultados o estados. Este conjunto, en la literatura matemática, es señalado como "mutuamente exclusivo y exhaustivo". Esto significa que dicho conjunto, debe cubrir todas las posibilidades de la variable y, las diferencias sin importancia son divididas entre los resultados o estados de la variable. En nuestro dominio de aplicación (el aprendizaje personalizado), las variables independientes representan a los ops y OPs y, las variables dependientes a los tipos de personalización (todos mencionados en la sección 2.3 de esta tesis. En la tabla 4.1 se resumen las variables involucradas en

el modelo propuesto, con su respectivo conjunto de resultados posibles, así como su notación. En general, las variables del modelo correspondientes a los ops y OPs son denotadas por  $O_1, O_2, \cdots, O_{14}$ . Los posibles resultados para cada una de las variables  $O_i$ ,  $1 \le i \le 14$  son denotados por  $O_i^j$ , con  $1 \le i \le 14$  y  $1 \le j \le k$  y en donde  $k \ge 2$  es el número de resultados posibles o estados de la variable  $O_i$ . La probabilidad de ocurrencia de un estado es indicada por  $P(O_i^j)$ , y la probabilidad de no ocurrencia de un estado de la variable es denotado por  $P\!\left(\sim O_i^j\right)$  con  $1 \le i \le 14$  y  $1 \le j \le k$  respectivamente. Similarmente, la variable respectiva a las FP (fase para el pre-conocimiento, fase para el progreso del conocimiento, fase para las metas y objetivos del profesor/alumno y fase para las preferencias y experiencias de navegación), es denotada por  $F_r$  y los resultados posibles por  $F_r^s$ con  $1 \le r \le 4$ , y  $1 \le s \le 2$ . La probabilidad de éxito de requerir algún TP es indicada por  $P(F_r^s)$ , y la de fracaso por  $P(\sim F_r^s)$  con  $1 \le r \le 4$ , y  $1 \le s \le 2$ respectivamente. Por último, las variables concernientes a la demanda de personalización para el sistema (adaptar el sistema al alumno), es denotada por  $D_s^m$  con  $1 \le m \le 2$ ; para el alumno (adaptar el alumno al sistema), es indicada por  $D_{\rm A}^n$  con  $1 \le n \le 2$ , y los posibles resultados por  $D_{{\rm A}\,r}^m$ , con  $1 \le m \le 2$ ,  $1 \le n \le 2$  y  $1 \le r \le 4$ . La probabilidad de ocurrencia de la demanda por parte del sistema es denotada por  $P(D^m_{{
m S}r})$ , y la no ocurrencia por  $P(\sim D^m_{{
m S}r})$  y la probabilidad de éxito de la demanda por parte del alumno es indicada por  $P(D_{Ar}^m)$ , y la no ocurrencia por  $P(\sim D_{\rm Ar}^m)$  con  $1 \le m \le 2$ ,  $1 \le n \le 2$  y  $1 \le r \le 4$  respectivamente. Todas las v.v.a.a. y sus posibles resultados se resumen en la siguiente Tabla 4.1.

Tabla 4.1. Variables involucradas en el modelo propuesto y sus resultados posibles.

Variable	Estados o resultados posibles y su notación	
Objetivos de personalización		
1. Conocimientos previos $(O_1)$ .	1) Bajo $\left(O_1^1\right)$ , 2) Intermedio $\left(O_1^2\right)$ , y 3) Alto $\left(O_1^3\right)$	
2. Estilo de aprendizaje $\left(O_{2}\right)$ .	1) Activo $\left(O_2^1\right)$ , 2) Reflexivo $\left(O_2^2\right)$ , 3) Teórico $\left(O_2^3\right)$ , y 4) Pragmático $\left(O_2^4\right)$ .	
3. Estilo cognitivo $(O_3)$ .	1) Dependiente $\left(O_3^1 ight)$ , y 2) Independiente $\left(O_3^2 ight)$ .	
4. Estilo de comunicación $\left(O_4\right)$ .	1) Pasivo $\left(O_4^1\right)$ , 2) Asertivo $\left(O_4^2\right)$ , 3) Agresivo $\left(O_4^3\right)$	
5. Estilo de enseñanza	1) Autoritario $\left(O_5^1\right)$ , 2) Demostrador $\left(O_5^2\right)$ , 3) Facilitador $\left(O_5^3\right)$ , y	
preferido $(O_5)$ .	4) Delegador $\left(O_5^4\right)$ .	
6. Técnicas de	1) Para aprendizaje visual $\left( O_{6}^{1} \right)$ , 2) Para aprendizaje activo	
aprendizaje $\left(O_{6}\right)$ .	$\left(O_6^2 ight)$ , y 3) Para aprendizaje colaborativo $\left(O_6^3 ight)$ .	
7. Preferencias individuales $(O_7)$ .	1) Visuales $(O_7^1)$ , 2) Auditivas $(O_7^2)$ , y 3) Kinestéticas $(O_7^3)$ .	
	1) Ciencias Exactas y Naturales $\left(O_8^1\right)$ , 2) Ingeniería $\left(O_8^2\right)$ , 3)	
	Biología y Ciencias de la Salud $\left(O_8^3 ight)$ , 4) Ciencias Sociales $\left(O_8^4 ight)$ ,	
8. Currículo $(O_8)$ .	5) Económicas y Administrativas $\left(O_8^5 ight)$ ,y 6) Humanidades y	
	Bellas Artes $\left(O_8^6 ight)$ .	
Objetos de personalización	1	
9. Necesidades personales	1) Ambientales $\left(O_9^1\right)$ , 2) Emocionales $\left(O_9^2\right)$ , 3) Sociales $\left(O_9^3\right)$ , y	
$(O_9)$ .	4) Fisiológicas $\left(O_9^4\right)$ .	
10. Selección de los OAs $\left(O_{10}\right)$ .	1) En CD ROM $\left(O_{10}^1\right)$ , 2) En línea $\left(O_{10}^2\right)$ , y 3) Combinado $\left(O_{10}^3\right)$ .	
11. Presentación de los OAs	1) Por necesidad del programa de enseñanza $\left(O_{11}^{1} ight)$ , y 2) Como	
$(O_{11}).$	una facilidad para tener acceso a un objeto de aprendizaje particular sugerido $\left(O_{11}^2\right)$ .	
12. Selección de métodos de	1) Ratón $\left(O_{12}^1\right)$ , 2) Teclado $\left(O_{12}^2\right)$ , 3) Pulsador $\left(O_{12}^3\right)$ , 4) Sistema	
entrada $(O_{12})$ .	de reconocimiento de lenguaje (SRL) $\left(O_{12}^4 ight)$	
13. Dispositivos de aprendizaje	1) Objetos inteligentes $\left( O_{13}^1 \right)$ , 2) Infraestructuras de la	

$(O_{13}).$	información $\left(O_{13}^2\right)$ , y 3) Ambientes artificiales compartidos $\left(O_{13}^3\right)$ .
14. Usabilidad del sistema de software por parte del alumno $\left(O_{\text{14}}\right)$	1) Buena $\left(O_{14}^1\right)$ , 2) Regular $\left(O_{14}^2\right)$ , 3) Deficiente $\left(O_{14}^3\right)$ .
Fase de personalización	
15. para el pre-conocimiento $(F_1)$	1) Con adaptación $\left(F_{\mathrm{1}}^{\mathrm{1}}\right)$ , 2) Sin adaptación $\left(F_{\mathrm{1}}^{\mathrm{2}}\right)$
para el progreso del conocimiento $\left(F_2\right)$	1) Con adaptación $\left(F_2^1\right)$ , 2) Sin adaptación $\left(F_2^2\right)$
para los objetivos y metas del profesor/alumno $\left(F_3\right)$ .	1) Con adaptación $\left(F_3^1\right)$ , 2) Sin adaptación $\left(F_3^2\right)$
para las preferencias y experiencia de navegación $\left(F_4\right).$	1) Con adaptación $\left(F_4^1\right)$ , 2) Sin adaptación $\left(F_4^2\right)$
Demanda	
Demanda fase 1	
Sistema $\left(D_{\mathrm{S}}^{1}\right)$	1) Adecuación automática, $\left(D^1_{\mathrm{S1}} ight)$ , 2) Adecuación manual $\left(D^2_{\mathrm{S1}} ight)$
Alumno $\left(D_{A}^{1}\right)$	1) Con capacitación $\left(D_{A1}^1 ight)$ , 2) Sin capacitación $\left(D_{A1}^2 ight)$
Demanda fase 2	
Sistema $\left(D_{\mathrm{S}}^{2}\right)$	1) Adecuación automática, $\left(D^1_{ exttt{S2}} ight)$ , 2) Adecuación manual $\left(D^2_{ exttt{S2}} ight)$
Alumno $\left(D_{A}^{2}\right)$	1) Con capacitación $\left(D_{A2}^1 ight)$ , 2) Sin capacitación $\left(D_{A2}^2 ight)$
Demanda fase 3	
Sistema $\left(D_{\mathrm{S}}^{3}\right)$	1) Adecuación automática, $\left(D^1_{\mathrm{S3}} ight)$ , 2) Adecuación manual $\left(D^2_{\mathrm{S3}} ight)$
Alumno $\left(D_{A}^{3}\right)$	1) Con capacitación $\left(D_{A3}^{1}\right)$ , 2) Sin capacitación $\left(D_{A3}^{2}\right)$
Demanda fase 4	
Sistema $\left(D_{\mathbb{S}}^{4}\right)$	1) Adecuación automática, $\left(\!D^1_{ exttt{S4}} ight)$ , 2) Adecuación manual $\left(\!D^2_{ exttt{S4}} ight)$
Alumno $\left(D_{A}^{4}\right)$	1) Con capacitación $\left(D^1_{A4}\right)$ , 2) Sin capacitación $\left(D^2_{A4}\right)$

El estado o resultados posibles de estas variables, por ejemplo, para el caso de los conocimientos previos y del estilo de aprendizaje de un alumno específico, puede determinarse mediante una RB (ver Millán (2000), para el caso de los conocimientos previos con tests adaptativos y, García et al., (2005) para el caso de los estilos de aprendizaje) o mediante cuestionarios o test (ver Alonso et al., 1999 y Gallego, 2005). Por supuesto, existen más ops y OPs que podrían incluirse

en la Tabla 4.1. Sin embargo, pensamos que los ops y OPs más significativos son los que aparecen en la tabla antes mencionada.

El siguiente paso es construir la parte cualitativa, esto es, identificar las independencias entre las variables involucradas y expresarlas en una GAD que codifique las aseveraciones de las independencias condicionales. La gráfica resultante recibe el nombre de estructura de la RB. En otras palabras, debemos establecer las relaciones de dependencia causal entre las variables. Esto implica la creación de arcos (líneas y flechas) que van desde el nodo padre al nodo hijo.

Dado un dominio  $V = \{X_1, X_2, \cdots, X_n\}$  y un ordenamiento de las variables  $(X_1, X_2, \cdots, X_n)$ , la estructura de la RB representa la fpd conjunta P(X), sobre el conjunto de las v.v.a.a.  $X_i$ , del dominio V. Esta probabilidad conjunta se calcula mediante la ecuación (4.1):

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^{n} P(x_i | \Pi_i)$$
 (4.1)

En donde, para cada variable  $x_i$ ,  $\Pi_i \subseteq \{x_1, x_2, \cdots, x_{n-1}\}$  es un conjunto de variables en el que  $x_i$  es dependiente condicionalmente. El par formado por la estructura de la RB (la gráfica), y la colección de distribuciones  $P(x_i|\Pi_i)$  para cada nodo en el dominio V, constituye la RB para este dominio. Aplicando la regla de la cadena para v.v.a.a. (ver Neapolitan (2004), pág. 17), en la ecuación (4.1), obtenemos la fpd conjunta de la ecuación (4.2).

$$P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n | E = e) = \prod_{i=1}^n P(x_i | x_1, x_2, \dots, x_{n-1}, e)$$
 (4.2)

Ahora, para cada  $X_i$  existirá algún subconjunto  $\Pi_i \subseteq V$  tal que  $X_i$  y V son independientes condicionalmente dado  $\Pi_i$ . Esto es,

$$P(X_i = x_i | X_1 = x_1, X_2 = x_2, \dots, X_{n-1} = x_{n-1}, E = e) = P(x_i | \Pi_i, e)$$
 (4.3)

Estas independencias condicionales definen la estructura de la RB. La GAD del modelo propuesto aparece en la Figura 4.1. En la Figura 4.1, el PGALP está dividido en 4 FP: 1) Fase de los conocimientos previos, 2) fase del progreso del conocimiento, 3) Fase de los objetivos y metas del profesor/alumno y 4) Fase de preferencia y experiencia de navegación. La primera fase es considerada como una causa de los OPs: conocimientos previos, el estilo cognitivo y estilo de comunicación del alumno. Con estos objetivos, se obtienen los datos necesarios para que el alumno sea preparado para las fases siguientes y adaptar al sistema a las necesidades reales del alumno para que éste pueda usarlo óptimamente durante las siguientes fases. La segunda fase es considerada como una causa de los OPs: estilo de aprendizaje y técnicas de aprendizaje, y el op: preferencias individuales. Con ellos es posible capacitar al alumno y adaptar al sistema, de acuerdo a la actividad que se va a desarrollar en base a los OPs y ops de esta fase y la fase previa, a fin de que el alumno obtenga el conocimiento deseado durante la etapa de aprendizaje. La tercera fase es considerada como una causa de los OPs: currículum (área de experiencia), necesidades personales y estilo de enseñanza preferido, y el op: dispositivos de aprendizaje preferidos. Con éstos es posible preparar al alumno y al sistema de acuerdo a los objetivos y metas tanto del profesor como del alumno, así como seleccionar los contenidos y la presentación de éstos. Finalmente, la cuarta etapa es considerada como una causa de los ops: usabilidad del sistema por el alumno, selección de los métodos de entrada, selección de los OAs y presentación de los OAs. Con ellos, es posible preparar al alumno para la navegación y al sistema de acuerdo a las preferencias y experiencia del estudiante. Los resultados obtenidos en todas las fases son utilizados para determinar el modelo personalizado del alumno. El último paso para construir el MB, consiste en evaluar las distribuciones locales  $P(x_i|\Pi_i,e)$ . Esto significa, llenar el modelo con probabilidades numéricas para cada una de las variables, dependiendo del número de padres que la variable recibió en el paso anterior. Las funciones de probabilidad asociadas a cada uno de los nodos independientes, se generan gradualmente mediante los resultados que se obtienen de las evaluaciones o valoraciones realizadas a los alumnos. Sin embargo, para cubrir las necesidades de evaluación e inicialización del modelo, se realizó un curso en línea con 45 alumnos simulados, hemos incluido alumnos de todas las áreas de conocimiento mencionadas en la Tabla 4.1., para poder inferir el área de conocimiento (currículum) del alumno. Los resultados obtenidos se pueden consultar en las Tablas del apéndice B.

A continuación mostramos las distribuciones de probabilidad para cada uno de los nodos padres de la Figura 4.1, y posteriormente, las Tablas de probabilidad condicional para los nodos hijos, todas ellas generadas a partir de los datos recopilados en el curso simulado.

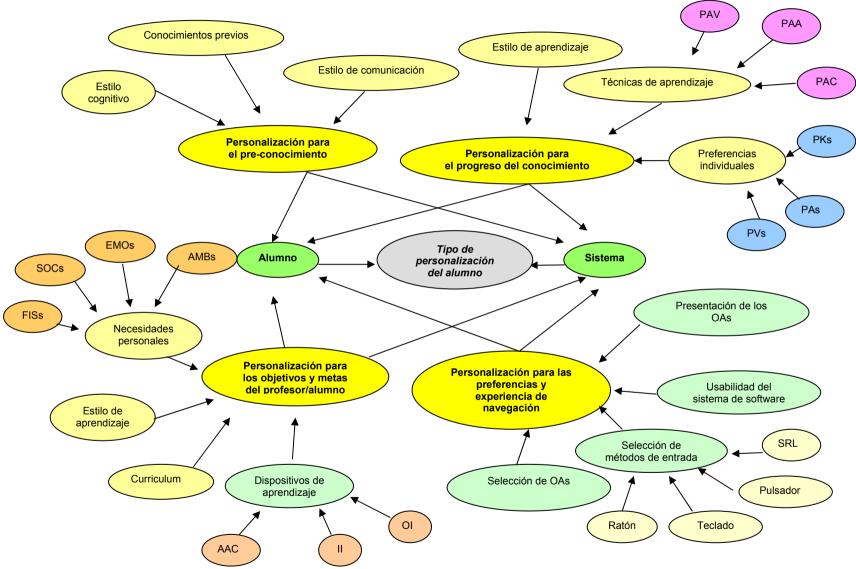


Figura 4.1. RB modelando el TP del alumno.

Para la variable de los conocimientos previos, la fdp es la que aparece en la Figura 4.2.

1. Nivel de conocimientos	Probabilidad
previos	
1. Alto	0.2667
2. Intermedio	0.4222
3. Bajo	0.3111

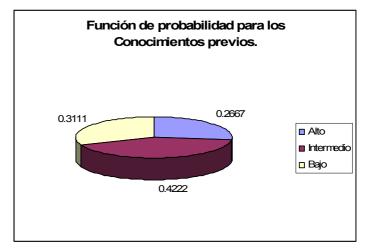


Figura 4.2. Fdp para los conocimientos previos.

Haciendo uso de la notación propuesta al inicio de esta sección,  $P(O_1^2)$  significa la probabilidad previa que un alumno tenga un nivel de conocimientos previos intermedio. Así, de la Tabla 4.1 se tiene que  $P(O_1^2 = \text{Intermedio}) = 0.4222$ . Es decir, existe una probabilidad previa del 42.22% de que un alumno, seleccionado al azar, tenga conocimientos previos intermedio.

Para la variable de los estilos de aprendizaje, la fdp es la que se muestra en la Figura 4.3. En esta Figura, se tiene que  $P(O_2^1 = \text{Activo}) = 0.1778$ . Esto quiere decir que existe una probabilidad previa del 17.78% de que un alumno, seleccionado al azar, tenga un estilo de aprendizaje activo predominante.

2. Estilo de aprendizaje	Probabilidad
1. Activo	0.1778
2. Reflexivo	0.2445
3. Teórico	0.3333
4. Pragmático	0.2444

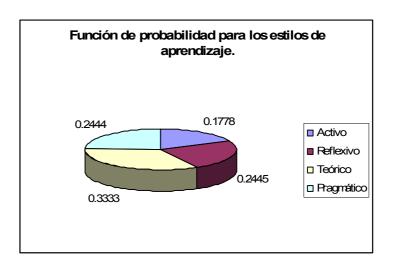


Figura 4.3. Fdp para los estilos de aprendizaje.

Para la variable de los estilos cognitivos, la fdp es la que se muestra en la Figura 4.4. Aquí,  $P(O_3^2 = \text{Independiente}) = 0.4444$  significa la probabilidad previa que un alumno, seleccionado al azar, tenga un estilo cognitivo Independiente. Es decir, existe una probabilidad previa del 44.44% que un alumno, seleccionado al azar, tenga el estilo cognitivo antes mencionado.

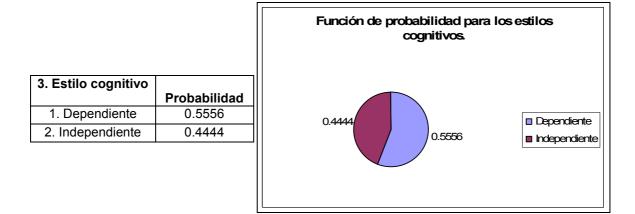


Figura 4.4. Fdp para los estilos cognitivos.

Para la variable de los estilos de comunicación, la fdp es la que aparece en la Figura 4.5. En este caso,  $P(O_4^2 = \text{Asertivo}) = 0.2223$  significa la probabilidad previa que un alumno seleccionado al azar, tenga un estilo de comunicación asertivo. Es decir, existe previamente una probabilidad del 22.23% que un alumno, seleccionado al azar, tenga el estilo de comunicación antes mencionado.

4. Estilo de comunicación	Probabilidad
1. Pasivo	0.4444
2. Asertivo	0.2223
3. Agresivo	0.3333



Figura 4.5. Fdp para los estilos de comunicación.

Para la variable de los estilos de enseñanza preferido por los alumnos, la fdp es la que se muestra en la Figura 4.6. Aquí,  $P(O_5^4 = \text{Delegador}) = 0.3556$  significa la probabilidad previa que un alumno, seleccionado al azar, prefiera el estilo de enseñanza delegador. Esto es, hay previamente un 35.56% de posibilidades de que un alumno, seleccionado al azar, prefiera un estilo de enseñanza delegador por parte del profesor.

5. Estilo de	
enseñanza	Probabilidad
1. Autoritario	0.2444
2. Demostrador	0.1556
<ol><li>Facilitador</li></ol>	0.2444
4. Delegador	0.3556

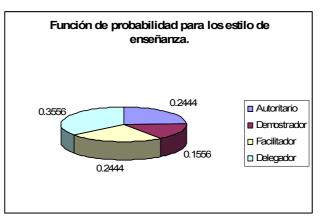


Figura 4.6. Fdp para los estilos de enseñanza.

Para la variable de las técnicas de aprendizaje en línea, la fdp es la que aparece en la Figura 4.7.  $P(O_6^2 = \text{Aprendizaje Activo}) = 0.1556$  significa que la probabilidad previa que un alumno, seleccionado al azar, opte por las técnicas de aprendizaje para el aprendizaje activo, la cual es del 15.56%.

6. Técnicas de aprendizaje	Probabilidad
Para aprendizaje	0.0444
visual (PAV)	0.2444
<ol><li>Para aprendizaje</li></ol>	
activo (PAA)	0.1556
<ol><li>Para aprendizaje</li></ol>	
colaborativo (PAC)	0.2444

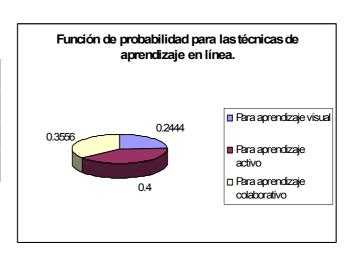


Figura 4.7. Fdp para las técnicas de aprendizaje.

Para la variable de las preferencias individuales, la fdp es la que aparece en la Figura 4.8.  $P(O_7^2 = \text{Auditivas}) = 0.3556$  es la probabilidad previa que un alumno, seleccionado al azar, tenga preferencias auditivas. Es decir, existe una probabilidad previa del 35.56% de que un alumno, seleccionado al azar, tenga preferencias individuales auditivas.

7. Preferencias	
individuales	Probabilidad
1. Visuales	0.3778
2. Auditivas	0.3556
3. Kinestéticas	0.2666

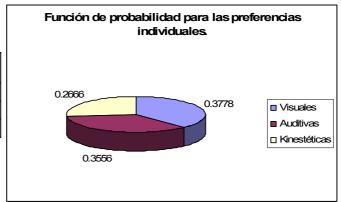


Figura 4.8. Fdp para las preferencias individuales.

Para la variable del currículo\* (área de la materia, tema o módulo), la fdp es la que aparece en la Figura 4.9.

8. Currículo*	Probabilidad
1) CEN	0.2
2) ING	0.0889
3) BCS	0.2444
4) CSO	0.1778
5) ECA	0.1556
6) HBA	0.1333

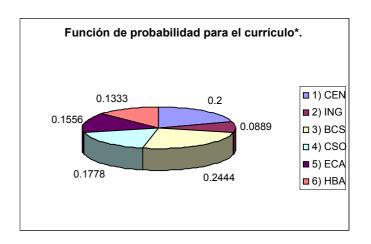


Figura 4.9. Fdp para el currículo.

\* 1) Ciencias Exactas y Naturales (CEN), 2) Ingeniería (ING), 3) Biología y Ciencias de la Salud, (BCS) 4) Ciencias Sociales (CSO), 5) Económicas y Administrativas (ECA) y, 6) Humanidades y Bellas Artes (HBA).

 $P(O_8^3 = BCS) = 0.2444$  significa la probabilidad previa de que un alumno, seleccionado al azar, sea del área de Biología y Ciencias de la Salud. Esto es, hay una probabilidad previa del 24.44% que el alumno pertenezca al área de estudio antes mencionada.

Para la variable de las necesidades personales, la fdp es la que aparece en la Figura 4.10.  $P(O_9^2 = \text{Emocionales}) = 0.2889$  significa la probabilidad previa que un alumno, seleccionado al azar, presente necesidades emocionales durante el curso. Es decir, hay una probabilidad previa del 28.89% que un alumno, seleccionado al azar, presente este tipo de necesidades durante el curso.

9. Necesidades	Probabilidad
personales	
1. Ambientales	0.4
2. Emocionales	0.2889
3. Sociales	0.2
4. Fisiológicas	0.1111

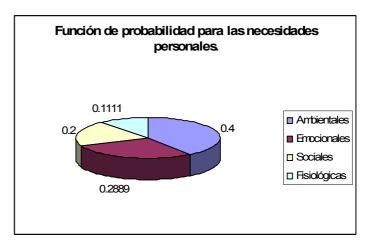


Figura 4.10. Fdp para las necesidades personales.

Para la variable de la selección de los OAs, la fdp es la que aparece en la Figura 4.11.

10. Selección	
de los OA	Probabilidad
1. Por necesidad	0.0444
del programa de enseñanza (NPE)	0.6444
2. Como una	
facilidad para tener	
acceso a un objeto	0.3556
de aprendizaje	
particular sugerido (FAO)	



Figura 4.11. Fdp para la selección de los OAs.

 $P(O_{10}^2 = \text{FAO}) = 0.3556$  significa la probabilidad previa que un objeto de aprendizaje específico sea seleccionado para facilitar el acceso a un objeto de aprendizaje particular sugerido. Es decir, el 35.56% de las veces, un objeto de aprendizaje, es seleccionado para facilidad el acceso a un objeto de aprendizaje particular sugerido.

Para la variable de la presentación de los OAs, la fdp es la que aparece en la Figura 4.12.

11. Presentación de los objetos	Probabilidad
de aprendizaje 1. En CD ROM	0.3111
2. En línea	0.2667
3. Combinado	0.4222

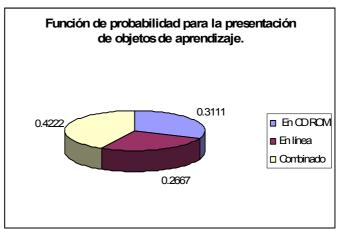


Figura 4.12. Fdp para la presentación de los OAs.

 $P(O_{11}^1 = {\sf EnCDROM}) = 0.3111$ , representa la probabilidad previa que un alumno prefiera que los OAs sean entregados en CD ROM. Es decir, hay un 31.11% de probabilidad previa que los OAs en un curso en línea determinado, sean entregados en la presentación antes mencionada.

Para la variable de la presentación de los métodos de entrada, la fdp es la que aparece en la Figura 4.13.  $P(O_{12}^2=\text{Con teclado})=0.9556$ , es la probabilidad previa que un alumno, seleccionado al azar, utilice el teclado normal. Esto es, existe un 95.56% de probabilidad que, en un curso en línea, se use el teclado normal como método de entrada.

12. Selección de los métodos de entrada	Probabilidad (Si)
1. Ratón	0,9333
2. Teclado	0,9556
3. Pulsador	0.0222
Sistema de reconocimiento de lenguaje (SRL)	0.6667



Figura 4.13. Fdps para la selección de los métodos de entrada.

Para la variable de los dispositivos de aprendizaje, la fdp es la que aparece en la Figura 4.14. Aquí,  $P(O_{13}^3 = \text{AAC}) = 0.2889$  es la probabilidad previa que el aprendizaje en línea se lleve a cabo mediante ambientes artificiales compartidos. Es decir, existe un 30% de probabilidad previa que los dispositivos de aprendizaje sean mediante el mecanismo antes mencionado.

13. Dispositivo de aprendizaje	Probabilidad
1. Objetos inteligentes (OI)	0.3111
2. Infraestructuras de la información (II)	0.4
3. Ambientes artificiales compartidos (AAC)	0.2889



Figura 4.14. Fdp para los dispositivos de aprendizaje.

Para la variable de la usabilidad del sistema de software por parte de los alumnos, la fdp es la que aparece en la Figura 4.15.  $P(O_{14}^2 = \text{Regular}) = 0.3556$  es la probabilidad previa que un alumno, seleccionado al azar, presente una usabilidad regular durante el proceso de enseñanza del curso en línea. Es decir, hay previamente un 35.56% de probabilidad que un alumno, seleccionado al azar, tenga una usabilidad regular del sistema de software empleado en la Gestión del Conocimiento. Aquí, el estado deficiente implica una usabilidad menor del 40% de la exigencia establecida. Es decir, el alumno utiliza muy poco el sistema. Regular supone una usabilidad del 40% y menos del 80% de la exigencia establecida y, Buena comprende una usabilidad del 80% o más de la exigencia establecida.

14. Usabilidad	Probabilidad
1. Deficiente	0.4222
2. Regular	0.3556
3. Buena	0.2222

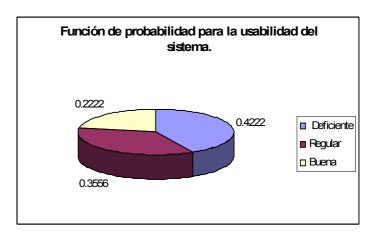


Figura 4.15. Fdp para la usabilidad del sistema por parte de los alumnos.

De las funciones de probabilidad expuestas, arriba obtenemos la Tabla 4.2 con las siguientes probabilidades:

Tabla 4.2. Tabla de probabilidades para los OPs y ops.

1. Nivel de conocimientos previos	8. Currículo	
$P(O_1^1 = Alto) = 0.2267$	$P(O_8^1 = CEN) = 0.2$	
$P(O_1^2 = Intermedio) = 0.4222$	$P(O_8^2 = ING) = 0.0889$	
$P(O_1^3 = Bajo) = 0.3111$	$P(O_8^3 = BCS) = 0.2444$	
2. Estilo de aprendizaje	$P(O_8^4 = CSO) = 0.1778$	
$P(O_2^1 = Activo) = 0.1778$	$P(O_8^1 = ECA) = 0.1556$	
$P(O_2^2 = \text{Reflexivo}) = 0.2445$	$P(O_8^2 = HBA) = 0.1333$	
$P(O_2^3 = \text{Teórico}) = 0.3333$	9. Necesidades personales	
$P(O_2^4 = \text{Pragmático}) = 0.2444$	$P(O_9^1 = Ambientales) = 0.4$	
3. Estilo cognitivo	$P(O_9^2 = \text{Emocionales}) = 0.2889$	
$P(O_3^1 = Dependiente) = 0.5556$	$P(O_9^3 = Sociales) = 0.2$	
$P(O_3^2 = \text{Independiente}) = 0.4444$	$P(O_9^4 = \text{Fisiológicas}) = 0.1111$	
4. Estilo de comunicación	10. Selección de los OAs	
$P(O_4^1 = Pasivo) = 0.4444$	$P(O_{10}^1 = NPE) = 0.6667$	
$P(O_2^2 = Asertivo) = 0.2223$	$P(O_{10}^2 = FAO) = 0.3333$	
$P(O_2^3 = Agresivo) = 0.3333$	11. Presentación de los OAs	
5. Estilo de enseñanza	$P(O_{11}^1 = CD ROM) = 0.3111$	
$P(O_5^1 = \text{Autoritario}) = 0.2444$	$P(O_{11}^2 = \text{En línea}) = 0.2667$	

$P(O_5^2 = \text{Demostrador}) = 0.1556$	$P(O_{11}^3 = \text{Combinado}) = 0.4222$	
$P(O_5^3 = \text{Facilitador}) = 0.2444$	12. Selección de los métodos de entrada	
$P(O_5^4 = \text{Delegador}) = 0.3556$	$P(O_{12}^1 = \text{Con componente s}) = 0.2667$	
6. Técnicas de aprendizaje	$P(O_{12}^2 = \text{Sin componente s}) = 0.7333$	
$P(O_6^1 = PAV) = 0.2444$	13. Dispositivo de aprendizaje	
$P(O_6^2 = PAA) = 0.1556$	$P(O_{13}^1 = OI) = 0.3$	
$P(O_6^3 = PAC) = 0.2444$	$P(O_{13}^2 = II) = 0.4$	
7. Preferencias individuales	$P(O_{13}^3 = AAC) = 0.3$	
$P(O_7^1 = \text{Visuales}) = 0.3778$	14. Usabilidad	
$P(O_2^2 = \text{Auditivas}) = 0.3556$	$P(O_{14}^1 = \text{Deficiente}) = 0.4222$	
$P(O_2^3 = \text{Kinest\'eticas}) = 0.2666$	$P(O_{14}^2 = \text{Regular}) = 0.3556$	
	$P(O_2^3 = \text{Buena}) = 0.2222$	

A continuación se muestran las RBs y las Tablas de probabilidad condicional para cada uno de los nodos hijo de la Figura 4.1. La Figura 4.16 muestra la RB para la personalización del alumno en la fase del pre-conocimiento, las probabilidades condicionales dados sus padres se resumen en la Tablas 4.3, 4.4 y 4.5.

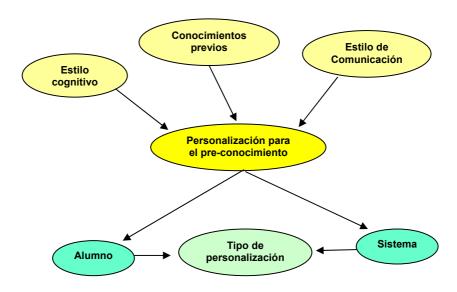


Figura 4.16. RB para la personalización en la fase del pre-conocimiento.

Tabla 4.3. Probabilidades condicionales previas para el nodo de personalización en la fase del pre-conocimiento.

Nodos Padres Adecuación del sistema er la fase del pre-conocimient					
Conocimientos previos	Estilo de Comunicación		tilo nitivo	Con adaptación	Sin adaptación
	Pasivo	Depen	diente	0.5	0.5
	1 83100	Indepe	ndiente	1	0
Bajo	Asertivo		diente	0	1
Бајо	Ascitivo	Indepe	ndiente	1	0
	Agresivo	Depen	diente	0.6667	0.3333
	Agresivo	Independiente		0.3333	0.6667
Pasivo		Depen	diente	0.25	0.75
	Fasivo	Indepe	ndiente	0.5	0.5
Intermedio	Asertivo	Depen	diente	0.6	0.4
intermedio	ASCILIVO	Indepen		0	1
	Agresivo Depen		diente	1	0
	Agresivo	Independiente		0.6667	0.3333
	Pagivo		diente	0.5	0.5
			ndiente	1	0
Alto			diente	0.6667	0.3333
AIIU			ndiente	1	0
	Agraciya	Depen	diente	0	1
	Agresivo	Indepe	ndiente	0.6667	0.3333

Tabla 4.4. Probabilidades condicionales previas para el nodo del alumno en la fase del pre-conocimiento.

Nodo Padre	Alumno		
Personalización en el pre-conocimiento	Con capacitación	Sin capacitación	
Requiere adaptación	0.5769	0.4230	
No requiere adaptación	0.6316	0.3684	

Tabla 4.5. Probabilidades condicionales previas para el nodo del sistema en la fase del pre-conocimiento.

Nodo Padre	Sistema		
Personalización en	Adecuación Adecuació		
el pre-conocimiento	automática	manual	
Con adaptación	0.6484	0.3516	
Sin adaptación	0.5544	0.4456	

La Figura 4.17 muestra la RB para la personalización del alumno en la fase del progreso del conocimiento, las probabilidades condicionales dados sus padres se resumen en la Tablas 4.6, 4.7 y 4.8.

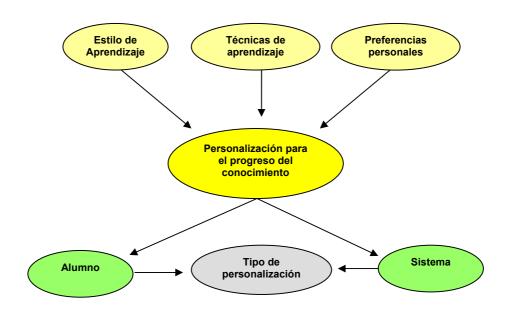


Figura 4.17. RB para la personalización en la fase del progreso del conocimiento.

Tabla 4.6. Probabilidades condicionales para el nodo de personalización en la fase del progreso del conocimiento.

			Adecuación del sistema en se del progreso del conocimiento		
Estilo de aprendizaje	Técnicas para aprendizaje	Preferencias personales		Con adaptación	Sin adaptación
		Visu	ıales	1	0
	Visual	Audi	itivas	0	1
		Kinest	téticas	0.5	0.5
		Visu	ıales	0.5	0.5
Activo	Activo Activo		tivas	0	1
	Kin	Kinest	téticas	1	0
		Visu	ıales	1	0
	Colaborativo	Audi	tivas	0	1
			téticas	1	0
Reflexivo		Visu	ıales	0	1
	Visual		itivas	1	0
		Kinestéticas		1	0
		Visu	ıales	0	1
	Activo	Audi	itivas	1	0
		Kinest	téticas	1	0

		Visuales	1	0
	Colaborativo	Auditivas	1	0
			1	0
		Visuales	0.3333	0.6667
	Visual	Auditivas	0.3333	0.6667
		Kinestéticas	0.6	0.4
		Visuales	0.5	0.5
Teórico	Activo	Auditivas	0	1
		Kinestéticas	0.2	0.8
		Visuales	0.5	0.5
	Colaborativo	Auditivas	1	0
		Kinestéticas	0.5	0.5
		Visuales	0.3333	0.6667
	Visual	Auditivas	0.3333	0.6667
		Kinestéticas	0.3333	0.6667
		Visuales	0.6667	0.3333
Pragmático	Activo	Auditivas	0.5	0.5
		Kinestéticas	0.3333	0.6667
		Visuales	0	1
	Colaborativo	Auditivas	0.6667	0.3333
İ		Kinestéticas	0.3333	1

Tabla 4.7. Probabilidades condicionales previas para el nodo del alumno en la fase del progreso del conocimiento.

Nodo Padre	Alumno		
Personalización en el progreso del conocimiento	Con Sin capacitación capacitaci		
Con adaptación	0.5909	0.4090	
Sin adaptación	0.3043	0.6957	

Tabla 4.8. Probabilidades condicionales previas para el nodo del sistema en la fase del progreso del conocimiento.

Nodo Padre	Sistema	
Personalización en el progreso del conocimiento	Adecuación Adecuacion automática manual	
Con adaptación	0.4545	0.5455
Sin adaptación	0.5217	0.4783

La Figura 4.18 muestra la RB para la personalización del alumno en la fase de los objetivos y metas del profesor/alumno, las probabilidades condicionales dados sus padres se resumen en la Tablas 4.9, 4.10 y 4.11.

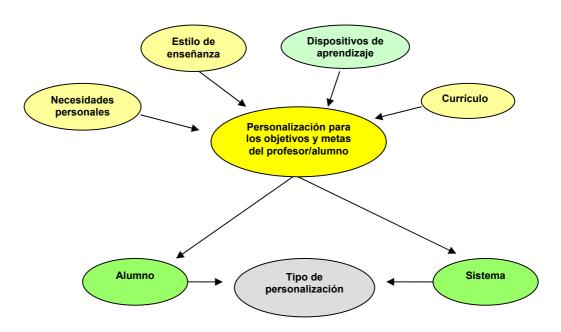


Figura 4.18. RB para la personalización en la fase de los objetivos y metas del profesor/alumno.

Tabla 4.9. Probabilidades condicionales para el nodo de personalización en la fase de los objetivos y metas del profesor/alumno.

				Adecuación del sistema en la fase de los					
N	Nodos Padres								
				objetivos y metas del profesor/alumno					
Necesidades	Estilos de	Dispositiv		Àrea del	Con	Sin			
personales	enseñanza	enseñan	za	conocimiento	adaptación	adaptación			
Ambientales				CEN	0	1			
				ING	0	1			
		OI		BCS	0	1			
				CSO	0	1			
				ECA	0	1			
				HBA	0	1			
				CEN	1	0			
		II		ING	0	1			
	Autoritario			BCS	0	1			
			П	"	"	"		CSO	0
				ECA	0	1			
				HBA	0	1			
				CEN	0	1			
			ING	0	1				
		^^		BCS	0	1			
		AAC		CSO	0	1			
				ECA	1	0			
				HBA	0	1			
Ţ	Demostrador	OI		CEN	0	1			
				ING	0	1			
				BCS	1	0			

			CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
			BCS	0	1
		II	CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
			BCS	0	1
		AAC	CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
			BCS	0	1
		OI	CSO	0	1
			ECA	1	
					0
			HBA	0	1
			CEN	0	1
	- "	II	ING	0	1
	Facilitador		BCS	0	1
			CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
		AAC	BCS	0	1
			CSO	0	1
			ECA	0	1
			HBA	1	0
			CEN	1	0
			ING	0	1
		C.	BCS	0	1
		OI	CSO	1	0
			ECA	0	1
			HBA	0	1
			CEN	1	0
			ING	0	1
	Delegador		BCS	0.5	0.5
	_ = 0.09000.	II	CSO	1	0
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
				0	1
		AAC	BCS		
			CSO	0	1
			ECA	0	1
			HBA	0	1

Sociales			CEN	0	1
Sociales			ING	0	1
			BCS	0	1
		OI	CSO	0	1
			ECA	0	1
			HBA	0	1
	-		CEN	1	0
			ING	0	1
	Autoritario		BCS	0	1
	ratoritario	II	CSO	0	1
			ECA	0	1
			HBA	0	1
	-		CEN	0	1
			ING	0	1
			BCS	0	1
		AAC	CSO	0	1
			ECA	1	0
			HBA	0	1
			CEN	0	1
			ING	0	1
		OI	BCS	1	0
			CSO	0	1
			ECA	0	1
			HBA	0	1
	-		CEN	0	1
		ador II	ING	0	1
			BCS	0	1
	Demostrador		CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
		AAC	BCS	0	1
			CSO	0	1
			ECA	0	1
			HBA	0	1
	Facilitador		CEN	0	1
			ING	0	1
		01	BCS	0	1
		OI	CSO	0	1
			ECA	1	0
			HBA	0	1
			CEN	0	1
			ING	0	1
		11	BCS	0	1
		II	CSO	0	1
			ECA	0	1
			HBA	0	1
		AAC	CEN	0	1
			ING	0	1
			BCS	0	1

			CSO	0	1
			ECA	0	1
			HBA	1	0
			CEN	1	0
			ING	0	1
			BCS		<u> </u>
		OI	CSO	1	
					0
			ECA	0	1
	_		HBA	0	1
			CEN	1	0
	Dalamata		ING	0	1
	Delegador	II	BCS	0.5	0.5
			CSO	1	0
			ECA	0	1
	_		HBA	0	1
			CEN	0	1
			ING	0	1
		AAC	BCS	0	1
		7010	CSO	0	1
			ECA	0	1
			HBA	0	1
Emocionales			CEN	0	1
		OI	ING	0	1
			BCS	0	1
			CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	1	0
			ING	0	1
	Autoritario		BCS	0	1
		II	CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
		A A C	BCS	0	1
		AAC	CSO	0	1
			ECA	1	0
			HBA	0	1
j	Demostrador		CEN	0	1
			ING	0	1
		6.	BCS	1	0
		OI	CSO	0	1
			ECA	0	1
			HBA	0	1
	<del> </del>		CEN	0	1
			ING	0	1
			BCS	0	1
		II	CSO	0	1
			ECA	0	1
			HBA	0	1
			LIDA	l 0	l l

			CEN	0	1
			ING	0	1
		A A O	BCS	0	1
		AAC	CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
			BCS	0	1
		OI	CSO	0	1
			ECA	1	0
			HBA	0	1
			CEN	0	1
			ING	0	1
	Facilitador		BCS	0	1
	i aciiitadoi	II	CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING		
				0	1
		AAC	BCS	0	1
			CSO	0	1
			ECA	0	1
			HBA	1	0
			CEN	1	0
			ING	0	1
		OI	BCS	0	1
			CSO	1	0
			ECA	0	1
			HBA	0	0
			CEN	1	0
			ING	0	1
	Delegador	II	BCS	0.5	0.5
		"	CSO	1	0
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
		AAC	BCS	0.5	0.5
		AAC	CSO	0	1
			ECA	0	1
			HBA	0	1
Fisiológicas	Autoritario		CEN	0	1
			ING	0	1
			BCS	0	1
		OI	CSO	0	1
			ECA	0	1
			HBA	0	1
		II	CEN	1	1
		"	ING	0	1
			BCS	0	1
	L		L		ı

			CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
		AAC	BCS	0	1
		AAC	CSO	0	1
			ECA	1	0
			HBA	0	1
			CEN	0.5	0.5
			ING	0	1
		OI	BCS	1	0
			CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
	Demostrador	п	BCS	0	1
	Demostrador	II	CSO	0	1
			ECA	0	1
			HBA	0	1
			CEN	0	1
			ING	0	1
		AAC	BCS	0	1
			CSO	0	1
			ECA	0	1
			HBA	0	1
		OI	CEN	0	1
			ING	0	1
			BCS	0	1
			CSO	0	1
			ECA	1	0
			HBA	0	1
			CEN	0	1
			ING	0	1
	Facilitador		BCS	0	1
		II	CSO	0	1
			ECA	0	0
			HBA	0	1
			CEN	0	1
			ING	0	1
		^^^	BCS	0	1
		AAC	CSO	0	1
			ECA	0	1
			HBA	1	0
	Delegador		CEN	1	0
			ING	0	1
			BCS	0	1
		OI	CSO	1	0
			ECA	0	1
			HBA	0	1
	1	ı	1		·

		CEN	1	0
		ING	0	1
	11	BCS	0.5	0.5
	II  -  -	CSO	1	0
		ECA	0	1
		HBA	0	1
		CEN	0.5	0.5
		ING	0	1
	AAC	BCS	0	1
	AAC	CSO	0	0
		ECA	0	1
		HBA	0	1

Tabla 4.10. Probabilidades condicionales previas para el nodo del alumno en la fase de los objetivos y metas del profesor/alumno.

Nodo Padre	Alumno		
Personalización en Los objetivos y metas del profesor/alumno	Con capacitación	Sin capacitación	
Con adaptación	0.2727	0.7273	
Sin adaptación	0.8696	0.1304	

Tabla 4.11. Probabilidades condicionales previas para el nodo del sistema en la fase de los objetivos y metas del profesor/alumno.

Nodo Padre	Sistema		
Personalización en Los objetivos y metas del profesor/alumno	Adecuación automática	Adecuación Manual	
Con adaptación	0.55	0.45	
Sin adaptación	0.2444	0.7556	

La Figura 4.19 muestra la RB para la personalización del alumno en la fase de los objetivos y metas del profesor/alumno, las probabilidades condicionales dados sus padres se resumen en la Tablas 4.12, 4.13 y 4.14.

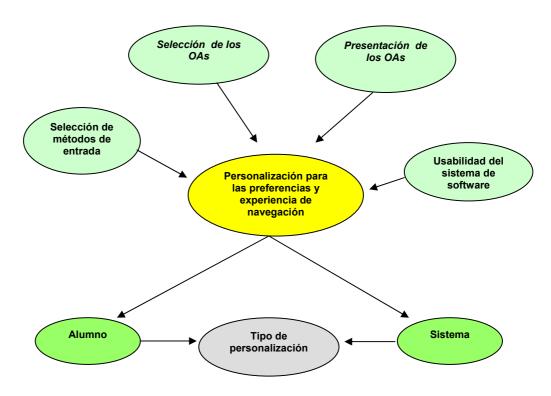


Figura 4.19. RB para la personalización en la fase de las preferencias y experiencia de navegación.

Tabla 4.12. Probabilidades condicionales para el nodo de personalización en la fase de las preferencias y experiencia de navegación

Nodo	Nodos padres Adec			cuación del sistema en la fase de de las preferencias y experiencia de navegación			
Presentación de los OAs	Usabilidad	Sel. de r de en	nétodos trada	Selección de los OAs	Con adaptación	Sin adaptación	
CD ROM		Ra	tón	NPE	0.6667	0.3333	
				FAO	1	0	
	Ì	Tool	lada	NPE	0.6667	0.3333	
	Duana	reci	lado	FAO	1	0	
	Buena	Puls	ador	NPE	0	1	
				FAO	0	1	
		SRL	NPE	0	1		
			FAO	0	1		
		Ratón	tón	NPE	0.5	0.5	
				FAO	0	1	
		Teclado	lado	NPE	0.5	0.5	
	Regular	1 601	Teclado	FAO	0	1	
	Regulai	Pulsa	ador	NPE	0	1	
				FAO	0	1	
		SF	OI.	NPE	0	1	
		OI.	\L	FAO	0	1	
	Deficiente	Ra	tón	NPE	1	0	
				FAO	0.5	0.5	
		Tacl	lado	NPE	1	0	
		1 60	iauu	FAO	0.5	0.5	

		Pulsador	NPE	0	1
			FAO	0	1
		ODI	NPE	0	1
		SRL	FAO	0	1
		Ratón	NPE	0	1
			FAO	1	0
		Tablada	NPE	1	0
	Duana	Teclado	FAO	1	0
	Buena	Pulsador	NPE	1	0
			FAO	0	1
		CDI	NPE	0	1
		SRL	FAO	0	1
		Ratón	NPE	0	1
			FAO	1	0
		<del>-</del>	NPE	0.6667	0.3333
- "		Teclado	FAO	1	0
En línea	Regular	Pulsador	NPE	0.6667	0.3333
			FAO	0	1
			NPE	0	1
		SRL	FAO	0	1
		Ratón	NPE	0	1
	_	raton	FAO	0	1
		Teclado	NPE	0	1
			FAO	0	1
	Deficiente —	Pulsador	NPE	0	1
		i dioddoi	FAO	0	1
		SRL	NPE	0	1
			FAO	0	1
		Ratón	NPE	0	1
			FAO	0	1
		Teclado	NPE	0	1
			FAO	0.5	0.5
	Buena —	Pulsador	NPE	0	1
		1 dioddoi	FAO	0.5	0.5
			NPE	0	1
		SRL	FAO	0	1
		Ratón	NPE	0	1
			FAO	0	1
			NPE	0.6	0.4
• • • •		Teclado	FAO	1	0
Combinado	Regular	Pulsador	NPE	0.6	0.4
			FAO	1	0
			NPE	0	1
		SRL	FAO	0	1
		Ratón	NPE	0	1
		1.0.011	FAO	0	1
			NPE	0.5	0.5
		Teclado	FAO	0.3	1
	Deficiente	Pulsador	NPE	0.5	0.5
		i disadoi	FAO	0.5	1
	-		NPE	0	<u> </u>
		SRL	FAO	0	1
			FAU	U	I

Tabla 4.13. Probabilidades condicionales previas para el nodo del alumno en la fase de las preferencias y experiencia de navegación.

Nodo Padre	Alumno		
Personalización en las preferencias y experiencia de navegación	Con capacitación	Sin capacitación	
Con adaptación	0.5	0.5	
Sin adaptación	0.4117	0.5882	

Tabla 4.14. Probabilidades condicionales previas para el nodo del sistema en la fase de las preferencias y experiencia de navegación.

Nodo Padre	Sistema	
Personalización en	Adecuación	Adecuación
las preferencias y experiencia de navegación	automática	manual
Con adaptación	0.3929	0.6071
Sin adaptación	0.2353	0.7647

Por ejemplo, de la Tabla 4.2 se tiene que:

$$P(Con adaptación|Alto, Asertivo, Dependiente) = 0.6667$$
 (4.4)

Esto significa que, existe una probabilidad del 66.67% de que un sistema deba adaptarse al alumno, sabiendo que éste tiene un nivel de conocimientos alto, un estilo de comunicación asertivo y un estilo cognitivo dependiente.

#### 4.3. Métricas para la personalización

En esta sección precisamos las métricas para cada una de las variables de personalización que se mencionan en la sección 2.3 de esta memoria. Es decir, proponemos las fdps para cada una las variables de personalización (ver sección 3.3 y la sección A1 del apéndice A) que intervienen en nuestro modelo. Estas fdps generarán las métricas requeridas para determinar las características del alumno

en caso de duda o de pérdida de datos. A medida que se obtengan más datos acerca de las particularidades del estudiante, los parámetros de estas fdps serán determinandos. Entre más datos se recopilen, la inferencia de las características del alumno y el TP serán más exactos.

En cada una de las variables de personalización usamos indistintamente la notación  $p_i$ ,  $1 \le i \le n$ , para indicar las probabilidades de ocurrencia del evento respectivo.

1) En los conocimientos previos  $(O_1)$ , usamos las v.v.a.a.  $\{O_1^1,O_1^2,O_1^3\}$  (ver Tabla 4.1), para representar a cada uno de los tres niveles de conocimientos previos (bajo, intermedio y alto, respectivamente), mencionados en la sección 2.3. Cada variable sigue una fdp trinomial (ver sección A1 del apéndice A), con probabilidad

$$p(x_1, x_2, x_3; p_1, p_2, p_3, n) = \binom{n}{x_1, x_2, x_3} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$
 (4.5)

Donde  $p_1, p_2, p_3$  son las probabilidades respectivas de ocurrencia de cada uno de los tres niveles de conocimientos previos,  $x_1, x_2, x_3$  es el número de ocurrencias en n pruebas de  $O_1^1, O_1^2$  y  $O_1^3$  respectivamente, y  $p_1 + p_2 + p_3 = 1$ .

2) En el estilo de aprendizaje  $(O_2)$ , utilizamos las v.v.a.a.  $\{O_2^1, O_2^2, O_2^3, O_2^4\}$  (ver Tabla 4.1), para representar a cada uno de los diferentes estilos predominantes de aprendizaje (activo, reflexivo, teórico y pragmático,

respectivamente), mencionados en la sección 2.3 Cada variable sigue una fpd multinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3, x_4; p_1, p_2, p_3, p_4, n) = \binom{n}{x_1, x_2, x_3, x_4} p_1^{x_1} p_2^{x_2} p_3^{x_3} p_4^{x_4}$$
(4.6)

Donde  $p_1,p_2,p_3,p_4$  son las probabilidades respectivas de ocurrencia de cada uno de los cuatro estilos de aprendizaje mencionados,  $x_1,x_2,x_3,x_4$  es el número de ocurrencias en n pruebas de  $O_2^1,O_2^2,O_2^3$  y  $O_2^4$  respectivamente, y  $p_1+p_2+p_3+p_4=1$ .

3) En el estilo cognitivo  $(O_3)$ , usamos las v.v.a.a.  $\{O_3^1,O_3^2\}$  (ver Tabla 4.1), para representar a cada uno de los dos estilos cognitivos (dependiente, independiente, respectivamente), mencionados en la sección 2.3 Cada variable sigue una fpd binomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2; p_1, p_2, n) = \binom{n}{x_1, x_2} p_1^{x_1} p_2^{x_2}$$
 (4.7)

Donde  $p_1$  y  $p_2$  son las probabilidades respectivas de ocurrencia de cada uno de los dos estilos cognitivos mencionados,  $x_1$  y  $x_2$  es el número de ocurrencias en  $p_1$  pruebas de  $p_2$  respectivamente, y  $p_1 + p_2 = 1$ .

4) En los estilos de comunicación  $(O_4)$ , usamos las v.v.a.a.  $\{O_4^1,O_4^2,O_4^3\}$  (ver Tabla 4.1), para representar a cada uno de los tres estilos de comunicación (pasivo, asertivo y agresivo, respectivamente), mencionados en la sección 2.3 Cada variable sigue una fpd trinomial (ver sección A1 del Apéndice A),con probabilidad

$$p(x_1, x_2, x_3; p_1, p_2, p_3, n) = \binom{n}{x_1, x_2, x_3} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$
 (4.8)

Donde  $p_1,p_2,p_3$  son las probabilidades respectivas de ocurrencia de cada uno de los tres estilos de comunicación,  $x_1,x_2,x_3$  es el número de ocurrencias en n pruebas de  $O_4^1,O_4^2$  y  $O_4^3$  respectivamente, y  $p_1+p_2+p_3=1$ .

5) En los estilos de enseñanza  $(O_5)$ , utilizamos las v.v.a.a.  $\{O_5^1, O_5^2, O_5^3, O_5^4\}$  (ver Tabla 4.1), para representar a cada uno de los diferentes estilos de enseñanza (autoritario, demostrador, facilitador y delegador, respectivamente), mencionados en la sección 2.3 Cada variable sigue una fpd multinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3, x_4; p_1, p_2, p_3, p_4, n) = \binom{n}{x_1, x_2, x_3, x_4} p_1^{x_1} p_2^{x_2} p_3^{x_3} p_4^{x_4}$$
(4.9)

Donde  $p_1, p_2, p_3, p_4$  son las probabilidades respectivas de ocurrencia de cada uno de los cuatro estilos de enseñanza arriba mencionados,  $x_1, x_2, x_3, x_4$  es el número de ocurrencias en n pruebas de  $O_5^1, O_5^2, O_5^3$  y  $O_5^4$  respectivamente, y  $p_1 + p_2 + p_3 + p_4 = 1$ .

6) En las técnicas de aprendizaje  $(O_6)$ , usamos las v.v.a.a.  $\{O_6^1, O_6^2, O_6^3\}$  (ver Tabla 4.1), para representar a cada uno de las tres técnicas de enseñanza (para el aprendizaje visual, para el aprendizaje activo y para el aprendizaje colaborativo, respectivamente), mencionadas en la sección 2.3 Cada variable sigue una fpd trinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3; p_1, p_2, p_3, n) = \binom{n}{x_1, x_2, x_3} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$
(4.10)

Donde  $p_1,p_2,p_3$  son las probabilidades respectivas de ocurrencia de cada uno de las tres técnicas de aprendizaje,  $x_1,x_2,x_3$  es el número de ocurrencias en n pruebas de  $O_6^1,O_6^2$  y  $O_6^3$  respectivamente, y  $p_1+p_2+p_3=1$ .

7) En las preferencias individuales  $(O_7)$ , usamos las v.v.a.a.  $\{O_7^1, O_7^2, O_7^3\}$  (ver Tabla 4.1), para representar a cada uno de las tres preferencias individuales (visuales, auditivas y kinestéticas), mencionadas en la sección 2.3 Cada variable sigue una fpd trinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3; p_1, p_2, p_3, n) = \binom{n}{x_1, x_2, x_3} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$
(4.11)

Donde  $p_1,p_2,p_3$  son las probabilidades respectivas de ocurrencia de cada uno de las tres preferencias individuales,  $x_1,x_2,x_3$  es el número de ocurrencias en n pruebas de  $O_7^1,O_7^2$  y  $O_7^3$  respectivamente, y  $p_1+p_2+p_3=1$ .

8) En currículo  $(O_8)$ , utilizamos las v.v.a.a.  $\{O_8^1, O_8^2, O_8^3, O_8^4, O_8^5, O_8^6\}$  (ver Tabla 4.1), para representar a cada uno de las distintas áreas de estudio (ciencias exactas y naturales, ingeniería, biología y ciencias de la salud, ciencias sociales, económicas y administrativas y, humanidades y bellas artes.,

respectivamente), mencionados en la sección 2.3 Cada variable sigue una fpd multinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3, x_4, x_5, x_6; p_1, p_2, p_3, p_4, p_5, p_5, n) = = \binom{n}{x_1, x_2, x_3, x_4, x_5, x_6} p_1^{x_1} p_2^{x_2} p_3^{x_3} p_4^{x_4} p_5^{x_5} p_6^{x_6}$$

$$(4.12)$$

Donde  $p_1, p_2, p_3, p_4, p_5, p_6$  son las probabilidades respectivas de ocurrencia de cada uno de las seis áreas de estudio arriba mencionadas,  $x_1, x_2, x_3, x_4, x_5, x_6$  es el número de ocurrencias en n pruebas de  $O_8^1, O_8^2, O_8^3, O_8^4, O_8^5$  y  $O_8^6$  respectivamente, y  $p_1 + p_2 + p_3 + p_4 + p_5 + p_6 = 1$ .

9) En las necesidades personales  $(O_9)$ , utilizamos las v.v.a.a.  $\{O_9^1, O_9^2, O_9^3, O_9^4\}$  (ver Tabla 4.1), para representar a cada uno de los diversos tipos de necesidades (ambientales, emocionales, sociales y fisiológicas, respectivamente), mencionados en la sección 2.3. Cada variable sigue una fpd multinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3, x_4; p_1, p_2, p_3, p_4, n) = \binom{n}{x_1, x_2, x_3, x_4} p_1^{x_1} p_2^{x_2} p_3^{x_3} p_4^{x_4}$$
(4.13)

Donde  $p_1, p_2, p_3, p_4$  son las probabilidades respectivas de ocurrencia de cada uno de los cuatro tipos de necesidades personales arriba mencionadas,  $x_1, x_2, x_3, x_4$  es el número de ocurrencias en n pruebas de  $O_9^1, O_9^2, O_9^3$  y  $O_9^4$  respectivamente, y  $p_1 + p_2 + p_3 + p_4 = 1$ .

10) En la selección de los OAs  $(O_{10})$ , usamos las v.v.a.a.  $\{O_{10}^1, O_{10}^2, O_{10}^3\}$  (ver Tabla 4.1), para representar a cada uno de las tres formas de seleccionar los OAs (CD ROM, en línea y combinado), mencionadas en la sección 2.3.

Cada variable sigue una fpd trinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3; p_1, p_2, p_3, n) = \binom{n}{x_1, x_2, x_3} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$
(4.14)

Donde  $p_1,p_2,p_3$  son las probabilidades respectivas de ocurrencia de cada uno de los tres tipos de selección,  $x_1,x_2,x_3$  es el número de ocurrencias en n pruebas de  $O_{10}^1,O_{10}^2$  y  $O_{10}^3$  respectivamente, y  $p_1+p_2+p_3=1$ .

11) En la presentación de los OAs  $(O_{11})$ , usamos las v.v.a.a.  $\{O_{11}^1,O_{11}^2\}$  (ver Tabla 4.1), para representar a cada una de las dos presentaciones (por necesidad del programa de enseñanza, y como una facilidad para tener acceso a un objeto de aprendizaje particular sugerido, respectivamente), mencionados en la sección 2.3. Cada variable sigue una fpd binomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2; p_1, p_2, n) = \binom{n}{x_1, x_2} p_1^{x_1} p_2^{x_2}$$
(4.15)

Donde  $p_1$  y  $p_2$  son las probabilidades respectivas de ocurrencia de cada uno de los dos presentaciones mencionadas,  $x_1$  y  $x_2$  es el número de ocurrencias en  $p_1$  pruebas de  $Q_{11}^1$  y  $Q_{11}^2$  respectivamente, y  $p_1 + p_2 = 1$ .

12) En la selección de métodos de entrada  $(O_{12})$ , usamos las v.v.a.a.  $\{O_{12}^1,O_{12}^2,O_{12}^3,O_{12}^4\}$  (ver Tabla 4.1), para representar cada una de las dos posibles selecciones (ratón, teclado, pulsador y SRL, respectivamente), mencionados en la sección 2.3. Cada variable sigue una fpd multinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3, x_4; p_1, p_2, p_3, p_4, n) = \binom{n}{x_1, x_2, x_3, x_4} p_1^{x_1} p_2^{x_2} p_3^{x_3} p_4^{x_4}$$
(4.16)

Donde  $p_1$ ,  $p_2$ ,  $p_3$  y  $p_4$  son las probabilidades respectivas de ocurrencia de cada uno de los dos selecciones mencionadas,  $x_1$  y  $x_2$  es el número de ocurrencias en n pruebas de  $O_{12}^1$ ,  $O_{12}^2$ ,  $O_{12}^3$ , y  $O_{12}^4$  respectivamente, y  $p_1 + p_2 + p_3 + p_4 = 1$ .

13) En los dispositivos de aprendizaje  $(O_{13})$ , usamos las v.v.a.a.  $\{O_{13}^1, O_{13}^2, O_{13}^3\}$  (ver Tabla 4.1), para representar a cada uno de las tres tipos dispositivos de aprendizaje (objetos inteligentes, infraestructuras de la información y ambientes artificiales compartidos), mencionados en la sección 2.3. Cada variable sigue una fpd trinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3; p_1, p_2, p_3, n) = \binom{n}{x_1, x_2, x_3} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$
(4.17)

Donde  $p_1,p_2,p_3$  son las probabilidades respectivas de ocurrencia de cada uno de los tres tipos de dispositivos,  $x_1,x_2,x_3$  es el número de ocurrencias en n pruebas de  $O_{13}^1,O_{13}^2$  y  $O_{13}^3$  respectivamente, y  $p_1+p_2+p_3=1$ .

14) . En la usabilidad del sistema de software por parte del alumno  $(O_{14})$ , usamos las v.v.a.a.  $\{O_{14}^1,O_{14}^2,O_{14}^3\}$  (ver Tabla 4.1), para representar a cada uno de los tres estados de la usabilidad (buena, regular y deficiente), mencionados en la sección 2.3. Cada variable sigue una fpd trinomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2, x_3; p_1, p_2, p_3, n) = \binom{n}{x_1, x_2, x_3} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$
(4.18)

Donde  $p_1,p_2,p_3$  son las probabilidades respectivas de ocurrencia de cada uno de los tres estados de usabilidad,  $x_1,x_2,x_3$  es el número de ocurrencias en n pruebas de  $O_{14}^1,O_{14}^2$  y  $O_{14}^3$  respectivamente, y  $p_1+p_2+p_3=1$ .

15) En cada una de las cuatro FP denotadas por  $(F_1)$ ,  $(F_2)$ ,  $(F_3)$  y  $(F_4)$  respectivamente, usamos las v.v.a.a. respectivas para cada una de las cuatro fases  $\{F_1^1, F_1^2\}$ ,  $\{F_2^1, F_2^2\}$ ,  $\{F_3^1, F_3^2\}$  y  $\{F_4^1, F_4^2\}$  (ver Tabla 4.1), para representar a cada una de las dos posibles modalidades (con adaptación y sin adaptación, respectivamente), mencionados en la Tabla 4.1. Cada variable sigue una fpd binomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2; p_1, p_2, n) = \binom{n}{x_1, x_2} p_1^{x_1} p_2^{x_2}$$
 (4.19)

Donde  $p_1$  y  $p_2$  son las probabilidades respectivas de ocurrencia de cada uno de las dos modalidades mencionadas,  $x_1$  y  $x_2$  es el número de ocurrencias en n pruebas de  $\left\{F_1^1, F_1^2\right\}$  o  $\left\{F_2^1, F_2^2\right\}$  o  $\left\{F_3^1, F_3^2\right\}$  o  $\left\{F_4^1, F_4^2\right\}$  respectivamente, (una distribución distinta para cada fase) y  $p_1 + p_2 = 1$ .

16) En cada una de las posibles demandas por parte del sistema o del alumno indicadas por  $\left(D_{\rm S}^1\right)$  y  $\left(D_{\rm A}^1\right)$  para la fase 1,  $\left(D_{\rm S}^2\right)$  y  $\left(D_{\rm A}^2\right)$  para la fase 2,  $\left(D_{\rm S}^3\right)$  y  $\left(D_{\rm A}^3\right)$  para la fase 3 y por  $\left(D_{\rm S}^4\right)$  y  $\left(D_{\rm A}^4\right)$  para la fase 4 respectivamente, usamos las v.v.a.a.  $\left\{D_{\rm S1}^1,D_{\rm S1}^2\right\}$  para representar cada modalidad del sistema

en la fase 1 y por  $\{D_{A1}^1, D_{A1}^2\}$ , para indicar cada variante del alumno en la fase 1. Similarmente, usamos las v.v.a.a.  $\{D_{S2}^1, D_{S2}^2\}$ ,  $\{D_{A2}^1, D_{A2}^2\}$ ;  $\{D_{S3}^1, D_{S3}^2\}$ ,  $\{D_{A3}^1, D_{A3}^2\}$ ; y  $\{D_{S4}^1, D_{S4}^2\}$ ,  $\{D_{A4}^1, D_{A4}^2\}$  ver Tabla 4.1), para representar a cada una de las dos posibles adecuaciones (automática, manual) para el sistema y (con capacitación, sin capacitación) para el alumno respectivamente, en cada una de las fases 2, 3 y 4 mencionadas en la Tabla 4.1. Cada variable sigue una fpd binomial (ver sección A1 del Apéndice A), con probabilidad

$$p(x_1, x_2; p_1, p_2, n) = \binom{n}{x_1, x_2} p_1^{x_1} p_2^{x_2}$$
 (4.20)

Donde  $p_1$  y  $p_2$  son las probabilidades respectivas de ocurrencia de cada uno de las dos modalidades mencionadas,  $x_1$  y  $x_2$  es el número de ocurrencias en n pruebas de  $\left\{D_{\text{S1}}^1,D_{\text{S1}}^2\right\}, \left\{D_{\text{A1}}^1,D_{\text{A1}}^2\right\}$  o  $\left\{D_{\text{S2}}^1,D_{\text{S2}}^2\right\}, \left\{D_{\text{A2}}^1,D_{\text{A2}}^2\right\}$  o  $\left\{D_{\text{S3}}^1,D_{\text{S3}}^2\right\}, \left\{D_{\text{A3}}^1,D_{\text{A3}}^2\right\}$  o  $\left\{D_{\text{S4}}^1,D_{\text{S4}}^2\right\}, \left\{D_{\text{A4}}^1,D_{\text{A4}}^2\right\}$  respectivamente, para cada una de las cuatro fases (una distribución distinta para cada fase), y  $p_1 + p_2 = 1$ .

Una vez definidas las fdps locales para cada una de las variables de los nodos padres y nodos hijos de la GAD, el modelo propuesto queda completo. En la sección 4.4 siguiente presentamos las conclusiones de este capítulo.

### 4.4. Conclusión del capítulo

En este capítulo, se ha propuesto un MB que es útil para realizar inferencias del TP del alumno basado en objetos y objetivos de aprendizaje y de personalización. Este modelo no contempla en su totalidad todos los objetos y objetivos de aprendizaje, pero sí la mayor parte, los más importantes y los que a nuestro modo de pensar, pueden optimizar el PGALP del alumno, si su perfil de personalización es determinado con exactitud, y se ofrece al estudiante el contenido, el apoyo, la infraestructura y la orientación necesaria que se acople a las necesidades reales del alumno. Es posible incrementar en el modelo propuesto, las variables y también algunos estados o resultados de éstas lo que ampliaría la gama de perfiles y los modelos de personalización posibles, pero también podría incrementar la complejidad del modelo lo que puede llevar a un modelo intratable computacionalmente.

Hemos calculado las probabilidades previas de los nodos padres y las probabilidades condicionales previas de los nodos hijos basándonos en los datos obtenidos en un curso en línea con 45 alumnos simulados (ver sección 4.2), con estas Tablas de distribución hacemos la evaluación del modelo en el capítulo 5.

Hemos propuesto las fdps locales (ver sección 4.3) que generarán las métricas de los estados de cada una de las variables que conforman nuestro MB. Los parámetros de las fdps, locales se irán determinando gradualmente, a medida que las RBs sean alimentadas con los datos que generen los alumnos y las

interacciones que tengan éstos con el sistema. Estos parámetros son los que ayudarán notoriamente en la detección del perfil de personalización más probable de un estudiante, en él se basará el modelo de personalización del mismo.

Es importante mencionar que el modelo por si mismo, no garantiza el aprendizaje del alumno, depende en su mayor parte de la actitud de éste, de su desempeño e interés en obtener el conocimiento. Teniendo este apoyo por parte del estudiante, el modelo propuesto puede ser una gran alternativa para optimizar el aprendizaje personalizado.

En el capítulo siguiente presentamos la valoración del modelo mediante un ejemplo práctico.

### Capítulo 5

# Implementación práctica del modelo Bayesiano

**Resumen**. En este capítulo presentamos evaluación del modelo Bayesiano desarrollado en el capítulo 4. Usamos la fase de personalización para los conocimientos previos para llevar a cabo su valoración y poder usarlo para diagnosticar el perfil de personalización del alumno y elaborar su modelo de personalización del aprendizaje. Además, obtenemos las probabilidades de ocurrencia de cada uno de los perfiles posibles de la fase mencionada y mostramos ejemplos de cómo realizar inferencias Bayesianas en caso de incertidumbre o de datos perdidos.

#### 5.1. Introducción

En este capítulo usamos la fase de los conocimientos previos para mostrar la valoración del MB propuesto en el capítulo anterior. Esta fase se compone (ver Figura 4.16) de los siguientes OPs del aprendizaje: los conocimientos previos, el estilo cognitivo y el estilo de comunicación del alumno como objetivos causantes de la adaptación del alumno (mediante la capacitación para el uso del sistema) y del sistema de cómputo (mediante la adecuación de acuerdo a las necesidades del alumno) para posteriormente, dar inicio con la segunda fase del modelo.

### 5.2. Valoración del modelo

El procedimiento para realizar diagnósticos mediante la RB, es similar al que se menciona en la sección 3.6, sólo que en nuestro caso se trata de un modelo con variables multinomiales. Consideremos la Tabla 4.1 y la situación de la personalización para el pre-conocimiento de la Figura 4.16 para calcular

$$P(O_1^3, O_3^2, O_4^2, F_1^1, D_{A1}^1, D_{s1}^1) =$$

$$= P(Alto, Indep., Asertivo, Con adapt., Con capac., Adec. Autom.)$$
 (5.1)

Primero calculamos la probabilidad para el nodo del alumno. Esto es, aplicando la regla de la cadena (Neapolitan, 2004, pag 17, 65) dos veces, se tiene:

$$P(D_{A1}^{1} F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) = P(D_{A1}^{1} | F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3})$$
(5.2a)

$$= P(D_{A1}^{1}|F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(F_{1}^{1}|O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(O_{4}^{2}, O_{3}^{2}, O_{1}^{3})$$
(5.2b)

Finalmente, puesto que el nivel de conocimientos previos, el estilo cognitivo y el estilo de comunicación son independientes entre sí, se tiene

$$= P(Alto, Independiente, Asertivo, Con adaptación, Con capacitación)$$
 (5.3a)

$$P(D_{A1}^{1} F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) = P(D_{A1}^{1} | F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3})$$
(5.3b)

$$= P(D_{A1}^{1}|F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(F_{1}^{1}|O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(O_{4}^{2}) \times P(O_{3}^{2}) \times P(O_{1}^{3})$$
(5.3c)

Ahora, usamos las Tablas 4.2, 4.3, 4.4 y 4.5.

$$P(O_1^3, O_3^2, O_4^2, F_1^1, D_{A1}^1, D_{s1}^1) = (0.5769)(1)(0.2223)(0.2667) = 0.0342$$
 (5.4)

El resultado obtenido muestra que el 3.4% de las veces el alumno tendrá el perfil de personalización de la ecuación (5.3a) y representaría la creencia del sistema electrónico acerca del perfil de personalización del estudiante. De acuerdo a este resultado, el sistema tomará la decisión de ofrecer al alumno alternativas diseñadas de acuerdo al perfil de la ecuación (5.3a). Esta probabilidad, en comparación con los resultados posibles que se pueden generar mediante las Tablas arriba mencionadas, representa una probabilidad relativamente baja. Sin embargo, el 3.4% de las veces, el sistema deberá usar este perfil para proponer al alumno las opciones pertinentes.

Ahora, calculamos la probabilidad para el nodo del sistema. Esto es,

$$= P(Alto, Indep., Asertivo, Con adaptación, Adecuación automática)$$
 (5.5a)

$$= P(D_{S1}^{1} F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) = P(D_{S1}^{1} | F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3})$$
(5.5b)

$$= P(D_{S1}^{1}|F_{1}^{1}, O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(F_{1}^{1}|O_{4}^{2}, O_{3}^{2}, O_{1}^{3}) \times P(O_{4}^{2}, O_{3}^{2}, O_{1}^{3})$$
(5.5c)

Usando las Tablas antes referidas, se tiene que:

$$P(D_{S1}^1 F_1^1, O_4^2, O_3^2, O_1^3) = (0.5769)(1)(0.2223)(0.6484) = 0.0831$$
 (5.6)

Esta probabilidad indica que el 8.3% de las veces, el sistema electrónico deberá ajustarse al perfil de la ecuación (5.6a). Ahora bien, para determinar la probabilidad conjunta, calculamos el producto de las dos probabilidades encontradas. Esto es:

$$P(O_1^3, O_3^2, O_4^2, F_1^1, D_{A1}^1, D_{s1}^1) = (0.0342)(0.0831) = 0.0028$$
 (5.7)

El valor obtenido muestra que según nuestro MB, el 0.28% de las veces, el alumno tendrá el perfil de personalización de la ecuación (5.1) y por lo tanto, el sistema se ajustará a éste esa cantidad de veces a fin de ofrecer al alumno, las alternativas que optimicen su PGALP.

### 5.3. Inferencia Bayesiana (IB)

Cuando se tienen datos perdidos o casos de incertidumbre, podemos utilizar el teorema de Bayes (Ver Neapolitan (2004), pág. 8) para hacer inferencias o pronósticos de los datos perdidos y de los casos dudosos. Por ejemplo, para deducir la probabilidad previa de que un alumno tiene un nivel de conocimientos previos alto, usamos la Ley de Probabilidad Total (Ver sección A3 del Apéndice A) como sigue:

$$P(\operatorname{Con\,adap.}) = P(\operatorname{Con\,adap.}|\operatorname{Bajo},\operatorname{Pas.},\operatorname{Depend.}) \times P(\operatorname{Bajo},\operatorname{Pas},\operatorname{Depend.}) + \\ + P(\operatorname{Con\,adap.}|\operatorname{Bajo},\operatorname{Pas.},\operatorname{Indep.}) \times P(\operatorname{Bajo},\operatorname{Pasivo},\operatorname{Indep.}) + \\ + P(\operatorname{Con\,adap.}|\operatorname{Bajo},\operatorname{Aser.},\operatorname{Depend.}) \times P(\operatorname{Bajo},\operatorname{Aser.},\operatorname{Depend.}) + \\ + P(\operatorname{Con\,adap.}|\operatorname{Bajo},\operatorname{Agres.},\operatorname{Indep.}) \times P(\operatorname{Bajo},\operatorname{Agres.},\operatorname{Indep.}) + \\ + P(\operatorname{Con\,adap.}|\operatorname{Interm.},\operatorname{Pas.},\operatorname{Depend.}) \times P(\operatorname{Interm.},\operatorname{Pas.},\operatorname{Depend.}) + \\ + P(\operatorname{Con\,adap.}|\operatorname{Interm.},\operatorname{Pas.},\operatorname{Indep.}) \times P(\operatorname{Interm.},\operatorname{Pas.},\operatorname{Indep.}) + \\ (5.8)$$

```
+P(Con adap.|Interm., Aser, Depend.) \times P(Interm., Asert., Depend.) +
       + P(Con adap.|Interm., Agres., Indep.) \times P(Interm., Agres., Indep.) +
           + P(Con adap.|Alto, Pas., Depend.) \times P(Alto, Pas., Depend.) +
              +P(Con adap.|Alto, Pas., Indep.) \times P(Alto, Pas., Indep.) +
          + P(Con adap.|Alto, Asert., Depend.) \times P(Alto, Aser, Depend.) +
          +P(Con adap.|Alto, Agres., Indep.) \times P(Alto, Agresivo, Indep.) =
     = P(Con adap.|Bajo, Pas., Depend.) \times P(Bajo) \times P(Pas.) \times P(Depend.) +
        +P(Con adap.|Bajo, Pas., Indep.) \times P(Bajo) \times P(Pas.) \times P(Indep.) +
   +P(Con adap.|Bajo, Asert., Depend.) \times P(Bajo) \times P(Asert.) \times P(Depend.) +
      +P(Con adap.|Bajo, Asert., Indep.) \times P(Bajo) \times P(Asert.) \times P(Indep.) +
   +P(Con adap.|Bajo, Agres., Depend.) \times P(Bajo) \times P(Agres.) \times P(Depend.) +
      +P(Con adap.|Bajo, Agres., Indep.) \times P(Bajo) \times P(Agres.) \times P(Indep.) +
  +P(Con adap.|Interm., Pas., Depend.) \times P(Interm.) \times P(Pas.) \times P(Depend.) +
+P(Con adap.|Interm., Pas., Indep.) \times P(Interm.) \times P(Pas.) \times P(Indep.) +
                                                                                        (5.9)
 +P(Con adap.|Interm., Asert., Depend.) \times P(Interm.) \times P(Asert.) \times P(Depend.) +
   +P(Con adap.|Interm., Asert., Indep.) \times P(Interm.) \times P(Asert.) \times P(Indep.) +
+P(Con adap.|Interm., Agres., Depend.) \times P(Interm.) \times P(Agres.) \times P(Depend.) +
```

$$+P(\mathsf{Con\ adap.}|\mathsf{Interm.},\mathsf{Agres.},\mathsf{Indep.})\times P(\mathsf{Interm.})\times P(\mathsf{Agresivo})\times P(\mathsf{Indep.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Pas.},\mathsf{Indep.})\times P(\mathsf{Alto})\times P(\mathsf{Pas.})\times P(\mathsf{Indep.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Asert.},\mathsf{Depend.})\times P(\mathsf{Alto})\times P(\mathsf{Asert.})\times P(\mathsf{Depend.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Asert.},\mathsf{Indep.})\times P(\mathsf{Alto})\times P(\mathsf{Asert.})\times P(\mathsf{Indep.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Agres.},\mathsf{Depend.})\times P(\mathsf{Alto})\times P(\mathsf{Agres.})\times P(\mathsf{Depend.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Agres.},\mathsf{Depend.})\times P(\mathsf{Alto})\times P(\mathsf{Agres.})\times P(\mathsf{Indep.}).$$

Usando los valores de las Tablas 4.2, 4.3, 4.4 y 4.5 en la ecuación (5.9), obtenemos el valor para el dato buscado. Hemos usado el software MSBNX (MSBNX, 2007) para calcular este dato. El resultado obtenido se muestra en la Figura 5.1.

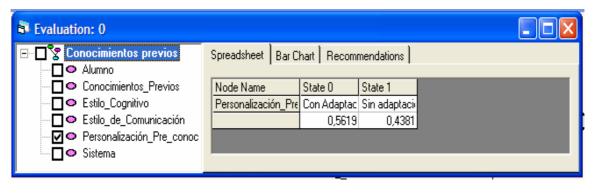


Figura 5.1. Probabilidades previas del nodo de los conocimientos previos.

Esto es,

$$P(F_1^1 = \text{Con adap.}) = 0.5619$$
 (5.10)

Esto indica según el MB propuesto, que en la fase de los conocimientos previos, el 59.19% de las veces es necesario adaptar el sistema electrónico a fin de ofrecer la actividad de enseñanza-aprendizaje en línea y optimizar el PGALP. El sistema electrónico se basaría en este dato para realizar la decisión de ofrecer o no sugerencias de adaptación con el propósito de llevar a cabo la actividad mencionada. El resultado obtenido no está muy lejos de la realidad, es muy frecuente la adaptación del sistema (por ejemplo, agregando nuevos contenidos) para llevar a cabo una actividad de enseñanza-aprendizaje.

Ahora bien, usando el resultado obtenido de la forma siguiente,  $0.5619 = P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Bajo}, \mathsf{Pas.}, \mathsf{Depend.}) \times P(\mathsf{Bajo}) \times P(\mathsf{Pas.}) \times P(\mathsf{Depend.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Bajo}, \mathsf{Pas.}, \mathsf{Indep.}) \times P(\mathsf{Bajo}) \times P(\mathsf{Pas.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Bajo}, \mathsf{Asert.}, \mathsf{Depend.}) \times P(\mathsf{Bajo}) \times P(\mathsf{Asert.}) \times P(\mathsf{Depend.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Bajo}, \mathsf{Asert.}, \mathsf{Indep.}) \times P(\mathsf{Bajo}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Bajo}, \mathsf{Agres.}, \mathsf{Depend.}) \times P(\mathsf{Bajo}) \times P(\mathsf{Agres.}) \times P(\mathsf{Depend.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Pas.}, \mathsf{Depend.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Pas.}) \times P(\mathsf{Depend.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Pas.}, \mathsf{Indep.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Pas.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Depend.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Depend.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Depend.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Depend.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Depend.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Depend.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Indep.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Indep.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Indep.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Indep.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Interm.}, \mathsf{Asert.}, \mathsf{Indep.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Asert.}, \mathsf{Asert.}, \mathsf{Indep.}) \times P(\mathsf{Interm.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Indep.}) + \\ + P(\mathsf{Con} \ \mathsf{adap.} | \mathsf{Asert.}, \mathsf{Asert.}, \mathsf{Asert.}, \mathsf{Asert.}, \mathsf{Asert.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Asert.}) \times P(\mathsf{Asert.}) \times$ 

```
+P(\mathsf{Con\ adap.}|\mathsf{Interm.},\mathsf{Agres.},\mathsf{Depend.})\times P(\mathsf{Interm.})\times P(\mathsf{Agres.})\times P(\mathsf{Depend.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Interm.},\mathsf{Agres.},\mathsf{Indep.})\times P(\mathsf{Interm.})\times P(\mathsf{Agresivo})\times P(\mathsf{Indep.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Pas.},\mathsf{Indep.})\times P(\mathsf{Alto})\times P(\mathsf{Pas.})\times P(\mathsf{Indep.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Asert.},\mathsf{Depend.})\times P(\mathsf{Alto})\times P(\mathsf{Asert.})\times P(\mathsf{Depend.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Asert.},\mathsf{Indep.})\times P(\mathsf{Alto})\times P(\mathsf{Asert.})\times P(\mathsf{Indep.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Agres.},\mathsf{Depend.})\times P(\mathsf{Alto})\times P(\mathsf{Agres.})\times P(\mathsf{Depend.})+\\ +P(\mathsf{Con\ adap.}|\mathsf{Alto},\mathsf{Agres.},\mathsf{Indep.})\times P(\mathsf{Alto})\times P(\mathsf{Agres.})\times P(\mathsf{Indep.})
```

Y usando los valores de las Tablas 4.2, 4.3 y 4.4 en ecuación (5.11), obtenemos los datos buscados. Una vez más, hemos usado el software mencionado para obtener los resultados que se muestran en la Figura 5.2.

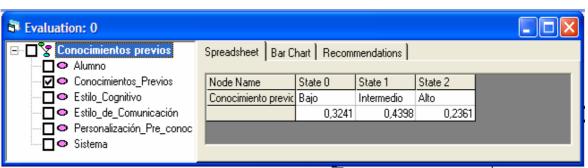


Figura 5.2. Probabilidades posteriores del nivel de conocimientos previos en la fase del preconocimiento

Los resultados indican que, en base a los datos recopilados por el sistema electrónico acerca de los alumnos y, ante la duda sobre los conocimientos previos

de un estudinte, el modelo sugiere que al estudiante se le otorgue un nivel de conocimientos previos intermedio. Comparando los resultados de la Figura 5.2 con los mostrados en la Figura 4.2 (pág. 105) observamos que la inferencia realizada se acopla a los datos reales obtenidos en la simulacón del curso.

Ahora, podemos aplicar el teorema de Bayes de la manera siguiente:

$$P(Con adap.|Alto, Pas., Depend.) =$$

$$= \frac{P(\mathsf{Alto},\mathsf{Pas.},\mathsf{Depend.}|\mathsf{Con\,adap.}) \times P(\mathsf{Con\,adap.})}{P(\mathsf{Alto},\mathsf{Pas.},\mathsf{Depend.})} = \tag{5.12a}$$

$$\frac{P(\mathsf{Alto}, \mathsf{Pasivo}, \mathsf{Dependiente} | \mathsf{Con} \, \mathsf{adaptaci\'{o}n}) \times P(\mathsf{Con} \, \mathsf{adaptaci\'{o}n})}{P(\mathsf{Alto}) \times P(\mathsf{Pasivo}) \times P(\mathsf{Dependiente})} = (5.12b)$$

$$0.5 = \frac{P(\text{Alto, Pasivo, Dependiente}|\text{Con adaptación}) \times (0.5619)}{(0.2361) \times (0.4444) \times (0.5556)} \tag{5.12c}$$

Así que,

$$P(Alto, Pasivo, Dependiente|Con adaptación) = 0.052$$
 (5.13)

El resultado obtenido indica que, sabiendo que se requirió adaptar al sistema para llevar a cabo una actividad de enseñanza-aprendizaje el línea, existe una probabilidad del 5.2% de que el estudiante sea de nivel de conocimientos alto, de estilo de comunicación pasivo y de estilo cognitivo dependiente. Este resultado representa la credibilidad del sistema de acuerdo a nuestro MB para realizar decisiones sobre las características del alumno en cuestión.

Del mismo modo, usando las Tablas 4.2, 4.3, 4.4 y 4.5 el sistema está en posibilidades de inferir el TP para un alumno. El software MSBNX, (MSBNX 2006), nos da las siguientes probabilidades posteriores para la fase de los conocimientos previos:

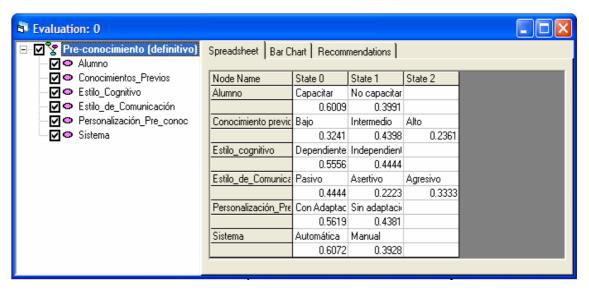


Figura 5.3. Probabilidades posteriores en la etapa del pre-conocimiento.

Conforme a nuestro MB los resultados de la Figura 5.3 indican que hay un 60.09% de posibilidades de que un determinado alumno, requiera capacitación antes de realizar cualquier actividad en el ordenador. Por lo tanto, el sistema tomará la decisión el 60.09% de las veces para sugerir al estudiante formas de capacitación. Con respecto al estilo cognitivo, hay un 55.56% de probabilidad de que el alumno sea dependiente y un 44.44% de que su estilo de comunicación sea

pasivo. Por lo tanto, de acuerdo al MB propuesto, el sistema se decidirá por el estilo cognitivo dependiente el 55.56% de las veces, y por el estilo cognitivo independiente el 44.44% de las veces. En referencia al estilo de comunicación, hay un 44.44% de posibilidades de que el alumno tenga un estilo pasivo de comunicación, un 22.23% de que sea del estilo asertivo y un 33.33% de probabilidad de que tenga un estilo de comunicación agresivo. Así, el sistema seleccionará el estilo pasivo para un alumno el 44.44% de las veces, el estilo asertivo 22.23% de las veces y el estilo agresivo el 33.33%. Por otro lado, existe una probabilidad de 60.72% de que las adaptaciones que se le hagan al sistema sean de manera automática y una probabilidad de 39.28% de que se lleven a cabo de manera manual. Por lo tanto, el sistema realizará las adaptaciones de manera automática el 60.72% de las veces, mientras que el 22.23% de las veces se realizarán de manera manual ya sea por el alumno o por el asistente.

Finalmente, con los resultados que aparecen en la Figura 5.3 obtenemos la Tabla 5.1 que contiene todos los perfiles de personalización posibles que pueden generarse en la fase de los conocimientos previos y su probabilidad de ocurrencia.

Tabla 5.1. Perfiles de personalización posibles en la fase de los conocimientos previos y sus probabilidades

Perfil	Conoc. previos	Estilo cognitivo	Estilo de comun.	Pers. en la fase de conoc. prev.	Adap. del alumno	Adec. del sistema	Probab.
1	Bajo	Bajo Dependiente			Capacitar	Manual	0,0164
2				Adaptar	Capacitai	Automática	0,0106
3			Auaptai	No	Manual	0,0109	
4			Pasivo		capacitar	Automática	0,0070
5			Pasivo		Congoitar	Manual	0,0128
6				No	Capacitar	Automática	0,0083
7				adaptar	No	Manual	0,0085
8					capacitar	Automática	0,0055
9			Asertivo	Adaptar	Capacitar	Manual	0,0205

10						Automática	0,0133
11					No	Manual	0,0136
12	- - -				capacitar	Automática	0,0088
13					Capacitar	Manual	0,0160
14				No		Automática	0,0103
15				adaptar		Manual	0,0106
16				adaptai	capacitar	Automática	0,0069
17						Manual	0,0164
18					Capacitar	Automática	0,0104
19				Adaptar	No	Manual	0,0109
20					capacitar	Automática	0,0070
21			Agresivo		Capacitai	Manual	0,0070
22				No	Capacitar	Automática	0,0128
23				adaptar	No	Manual	0,0085
24					capacitar	Automática	
25					Capacitai	Manual	0,0055
26					Capacitar	Automática	0,0164
27				Adaptar	,	Manual	0,0106
28				-	No		0,0109
			Pasivo		capacitar	Automática	0,0070
29				Na	Capacitar	Manual	0,0128
30				No	·	Automática	0,0083
31				adaptar	No	Manual	0,0085
32		Independiente			capacitar	Automática	0,0055
33			Asertivo		Capacitar	Manual	0,0131
34				Adaptar		Automática	0,0085
35					No	Manual	0,0087
36					capacitar	Automática	0,0056
37		'			Capacitar	Manual	0,0102
38	- - - -			No adaptar		Automática	0,0066
39					No	Manual	0,0068
40			Agresivo		capacitar	Automática	0,0044
41				Adaptar	Capacitar	Manual	0,0164
42						Automática	0,0106
43					No	Manual	0,0109
44					capacitar	Automática	0,0070
45					Capacitar No	Manual	0,0128
46						Automática	0,0083
47				adaptar		Manual	0,0085
48					capacitar	Automática	0,0055
49	Intermedio	ermedio Dependiente		Adaptar	Capacitar No	Manual	0,0223
50	-					Automática	0,0144
51			Pasivo			Manual	0,0148
52					capacitar	Automática	0,0096
53					Capacitar	Manual	0,0174
54				No		Automática	0,0112
55				adaptar	No	Manual	0,0115
56					capacitar	Automática	0,0075
57			Asertivo		Capacitar	Manual	0,0278
58				Adaptar		Automática	0,0180
59				Adaptai	No	Manual	0,0185
60					capacitar	Automática	0,0120

61						Manual	0,0217
62	1			No	Capacitar	Automática	0,0140
63				adaptar	No	Manual	0,0144
64					capacitar	Automática	0,0093
65						Manual	0,0223
66					Capacitar	Automática	0,0144
67				Adaptar	No	Manual	0,0148
68					capacitar	Automática	0,0096
69			Agresivo			Manual	0,0174
70				No	Capacitar	Automática	0,0112
71				adaptar	No	Manual	0,0115
72					capacitar	Automática	0,0075
73					·	Manual	0,0223
74					Capacitar	Automática	0,0144
75	-			Adaptar	No	Manual	0,0148
76	-				capacitar	Automática	0,0096
77			Pasivo			Manual	0,0174
78	1			No	Capacitar	Automática	0,0112
79	1			adaptar	No	Manual	0,0115
80	-			0.0.0.1	capacitar	Automática	0,0075
81					·	Manual	0,0178
82					Capacitar	Automática	0,0115
83				Adaptar	No	Manual	0,0118
84	1				capacitar	Automática	0,0077
85	1	Independiente	Asertivo			Manual	0,0139
86	-			No	Capacitar	Automática	0,0090
87				adaptar	No	Manual	0,0092
88					capacitar	Automática	0,0060
89						Manual	0,0223
90					Capacitar	Automática	0,0144
91				Adaptar	No	Manual	0,0148
92					capacitar	Automática	0,0096
93			Agresivo			Manual	0,0174
94				No	Capacitar	Automática	0,0112
95				adaptar	No	Manual	0,0115
96					capacitar	Automática	0,0075
97	Alto	Dependiente			0	Manual	0,0120
98		•		A -l t	Capacitar	Automática	0,0077
99				Adaptar	No capacitar	Manual	0,0079
100			Б.			Automática	0,0051
101			Pasivo			Manual	0,0093
102				No	Capacitar	Automática	0,0060
103				adaptar	No	Manual	0,0062
104				-	capacitar	Automática	0,0040
105			Asertivo		Consoiter	Manual	0,0149
106				Adoptor	Capacitar	Automática	0,0097
107				Adaptar	No	Manual	0,0099
108					capacitar	Automática	0,0064
109				No		Manual	0,0117
110				adaptar	Capacitar	Automática	0,0075
111				-	No	Manual	0,0077

112					capacitar	Automática	0,0050
113			Agresivo	Adaptar	Capacitar	Manual	0,0120
114						Automática	0,0077
115					No	Manual	0,0079
116					capacitar	Automática	0,0051
117				No adaptar	Capacitar	Manual	0,0093
118						Automática	0,0060
119					No	Manual	0,0062
120					capacitar	Automática	0,0040
121			Pasivo	Adaptar	Capacitar	Manual	0,0120
122						Automática	0,0077
123					No	Manual	0,0079
124					capacitar	Automática	0,0051
125				No adaptar	Capacitar	Manual	0,0093
126						Automática	0,0060
127					No	Manual	0,0062
128					capacitar	Automática	0,0040
129					Capacitar	Manual	0,0096
130				Adaptar		Automática	0,0062
131				rauptai	No	Manual	0,0063
132		Independiente	Asrtivo		capacitar	Automática	0,0041
133		пасрепастис		No adaptar	Capacitar	Manual	0,0075
134						Automática	0,0048
135					No	Manual	0,0050
136					capacitar	Automática	0,0032
137					Capacitar	Manual	0,0120
138				Adaptar		Automática	0,0077
139				/ taaptai	No	Manual	0,0079
140			Agresivo		capacitar	Automática	0,0051
141			Agresivo	No adaptar	Capacitar	Manual	0,0093
142						Automática	0,0060
143					No	Manual	0,0062
144				capacitar	Automática	0,0040	

De acuerdo a nuestro MB, la creencia del sistema experto sobre el TP del alumno será el perfil con probabilidad más alta. En este caso, se tienen tres posibles perfiles con la misma probabilidad, ellos son el perfil 49, 65 y 73 de la Tabla 5.1, el sistema experto elegirá al azar uno de éstos. Del resultado obtenido podemos observar que, en este caso, predomina el hecho de adaptar el sistema en esa fase, capacitar al alumno para que use efecientemente el sistema y la adecuación preferida del alumno es hacerlo manualmente.

### 5.4. Conclusión del capítulo

Hemos evaluado el MB del alumno propuesto en el capítulo 4, usando una de las cuatro fases del conocimiento. En esta primera fase de aprendizaje, surgen 142 perfiles diferentes en qué apoyarse para crear el modelo apropiado para el alumno en base a las necesidades reales, con el propósito de preparar al alumno para la fase del progreso del conocimiento. En la segunda fase, se tienen 288 perfiles distintos en qué basarse para elaborar el modelo adecuado del alumno en esa fase, basándose en los requerimientos reales a fin de que el estudiante optimice los mecanismos de hacerse llegar el conocimiento para cubrir las necesidades de la tercera fase. En la fase de las metas y objetivos del profesor/alumno se tienen 2,304 perfiles diferentes para crear el modelo adecuado del alumno que vaya de acuerdo a los objetivos y metas tanto del maestro como del alumno. Por último, se tienen 576 perfiles distintos para formar el modelo personalizado del alumno, con el propósito de aprovechar las preferencias y experiencias de navegación del alumno para que éste optimice el uso de la computadora y se haga llegar el conocimiento de acuerdo a sus necesidades y preferencias. Por supuesto, el número de perfiles distintos no implica el mismo número de modelos del alumno distintos.

Finalmente, el MB propuesto puede usarse total o parcialmente durante el proceso de enseñanza-aprendizaje, para resolver casos de duda o de datos perdidos mediante la IB que, a medida que se recopilen el mayor número de datos de los alumnos, el pronóstico será más exacto.

### Capítulo 6

### Conclusiones y líneas futuras

**Resumen**. En este capítulo presentamos las conclusiones y líneas futuras de nuestra investigación.

#### 6.1. Introducción

Los ambientes de aprendizaje adaptable tales como los STI, SEMI y SEHP sumado a las IAU, ofrecen a los alumnos un mayor grado de libertad y control para realizar búsquedas de información, aplicar diferentes técnicas de aprendizaje y adquirir el conocimiento. Tener una forma de optimizar el PGALP del alumno, es necesaria en estos sistemas. En esta tesis, hemos propuesto un MB usando OAs, OPs y ops que puede optimizar el PGALP de los usuarios de la Plataforma Suricata. En la sección 6.2 de este capítulo presentamos las conclusiones obtenidas en nuestro trabajo de tesis y en la sección 6.3, mostramos las líneas futuras de investigación.

#### 6.2. Conclusiones

Dentro de los objetivos, o de las pregunta de investigación de esta tesis o en los problemas abiertos planteamos la posibilidad del diseño de un modelo matemático del estudiante, el cual realice un diagnóstico de la situación actual de éste, basado en sus necesidades reales, con el propósito de proponer al alumno una alternativa o estrategia que optimice su proceso de aprendizaje.

En esta tesis, hemos construido un modelo que es útil para hacer inferencias del TP usando los OAs, ops y OPs que a consideración nuestra, puede optimizar el PGALP de los usuarios de la plataforma Suricata si los contenidos, el apoyo, la infraestructura y la orientación adecuados son ofrecidos al usuario. Para llevar a cabo lo anterior, es necesario realizar un trabajo multidisciplinario entre profesionales de la Educación, Informática y Psicología ayudados por la IA cuya aplicación pueden responder, en general, a las demandas y problemáticas concretas de los alumnos y profesores.

Los principales resultados obtenidos en esta tesis son los siguientes:

 Presentamos un modelo Bayesiano aplicado al proceso de aprendizaje en línea personalizado usando relaciones causales entre los objetos y objetivos de personalización, fases de aprendizaje, alumno, y sistema de gestión del aprendizaje en línea. En base a este modelo es posible guiar a cada alumno a conocer su perfil deseable de conocimientos, es decir, a elaborar su modelo individual de aprendizaje.

- Se obtuvieron un conjunto de perfiles de personalización en los cuales se puede trabajar para elaborar el modelo del alumno que optime el proceso global de aprendizaje en línea personalizado. Dichos perfiles de personalización consideran las características personales del alumno como son su estilo de aprendizaje, su estilo cognitivo, sus conocimientos previos, su área de conocimiento, estilo de enseñanza preferido, entre otros.
- El modelo propuesto nos sirvió para obtener los perfiles del tipo de personalización del alumno que presentamos en la Tabla 5.1, los cuales son útiles para .realizar el diagnóstico del tipo de personalización del alumno. Para llevar a cabo esto, nos hemos basado en las probabilidades posteriores de las Figura 5.3.
- El modelo Bayesiano fue evaluado a través de simulación mediante un curso en línea con alumnos virtuales y enfocados en la etapa de los conocimientos previos. La creencia del sistema experto acerca del tipo de personalización del alumno en la fase correspondiente, se basa en el perfil de personalización con la probabilidad más alta. Los resultados de la evaluación muestran (ver Tabla 5.1 perfiles 49, 65 y 73) que en la fase de los conocimientos previos, el sistema experto elegirá aleatoriamente, en este caso, uno de los siguientes perfiles para determinar el tipo de personalización del alumno:

P(Bajo, Dependiente, Pasivo, Con adap., Con capac., Adec. manual,)

P(Intermedio, Dependiente, Agresivo, Con adap., Con capac., Adec. manual,)

P(Intermedio, Independiente, Pasivo, Con adap., Con capac., Adec. manual,)

- Dada la importancia de medir la usabilidad y accesibilidad de los sistemas de enseñanza-aprendizaje en línea por medios electrónicos, fue necesario proponer una manera de generar los indicadores o métricas para ofrecer alternativas de optimización de tales sistemas. Esto es posible mediante las funciones de distribuciones de probabilidad propuestas en el capítulo 4.
- En este trabajo se puede encontrar la información necesaria, tanto de la teoría de probabilidad como la de Redes Bayesianas, que son suficientes para entender y llevar a cabo el modelado del alumno. Además, presentamos las ventajas de las Redes Bayesianas como técnicas de razonamiento aproximado, en comparación con otras técnicas usadas generalmente en la literatura, tales como: lógica difusa, reglas y factores de certeza y la Teoría de Dempster-Shafer.

Dada la complejidad y el costo que conlleva implantar nuestro modelo, en este trabajo de tesis usamos datos de estudiantes simulados, siguiendo las recomendaciones de publicaciones recientes (estado del arte) y nuestras propuestas personales. Consideramos que nuestras iniciativas de simulación son significativas desde el punto de vista tecnológico, en función de sus aplicaciones

al área educativa ya que una vez demostrada su efectividad, pueden ser usadas para evaluar los efectos en situaciones reales.

El diseño y simulación del nuestro modelo Bayesiano dejó los siguientes resultados:

- Un grupo de relaciones de causa-efecto entre objetos de personalización, objetivos de personalización, fases de aprendizaje, alumno y sistema electrónico de enseñanza.
- Un conjunto de Tablas con resultados simulados de las variables que componen nuestro modelo. Que pueden ser utilizados para inicializar otros modelos y realizar inferencias.
- Una colección de probabilidades previas y posteriores de cada una de las variables del modelo Bayesiano, Tablas de distribución de probabilidades previas de cada uno de los nodos padre y Tablas de distribución de probabilidades condicionales de cada uno de los nodos hijos, todas usadas para inicializar el modelo.
- Propusimos un conjunto de funciones de distribución de probabilidades locales, que generarán las métricas de aprendizaje para los estados de las variables que conforman el modelo Bayesiano y cuyos parámetros serán determinados gradualmente a medida que las Redes Bayesianas sean alimentadas con los datos reales recabados acerca del alumno.

En conclusión, la evaluación presentada del modelo Bayesiano, nos permite asegurar que nuestra propuesta responde a las necesidades planteadas en el capítulo 1. El modelo mencionado puede usarse total o parcialmente durante cualquier proceso global de enseñanza-aprendizaje, para realizar diagnósticos del tipo de personalización del alumno o para resolver casos de incertidumbre o de datos perdidos acerca de las características personales de éste.

Finalmente, es importante mencionar que nuestro modelo Bayesiano no garantiza por si solo el aprendizaje del alumno. La optimización del proceso de aprendizaje en línea personalizado puede llevarse a cabo mediante la propuesta adecuada de la trayectoria de aprendizaje y ésta depende (en gran medida) de las aptitudes del alumno, sus esfuerzos, su desempeño e interés para obtener ese conocimiento.

#### 6.3. Líneas futuras

Como pesquisas futuras de investigación, se tienen las siguientes:

Dar la validez correspondiente al MB propuesto. Es decir, demostrar que (a)
 el MB está libre de errores y (b) que éste genera resultados correctos para
 cualquier combinación coherente de valores de las variables de entrada.

- Estudiar la dependencia o independencia estadística entre todos los objetos de personalización y objetivos de personalización existentes, para ver si es posible disminuir las variables del modelo.
- Crear modelos probabilistas que combinen el uso de las redes Bayesianas y la lógica difusa, para que realicen diagnósticos de los objetos y objetivos de personalización, adecuación del sistema y tipo de capacitación del alumno. Esto permitirá disminuir la carga cognitiva del alumno.
- Comparar los resultados obtenidos con otros resultados usando otros modelos de diagnóstico existentes.

### Glosario

Accesibilidad: es un término que se usa para determinar el grado para el cual un sistema es utilizable por el mayor número de personas sin necesidad de modificarlo. La accesibilidad es una cualidad que tiene algo de ser usado o conocido sin que las limitaciones que un usuario pueda tener, supongan una barrera. Así, una herramienta es accesible cuando el usuario no necesita tener un nivel de inteligencia, audición, visión, movilidad o capacidad de memorización determinado. (Sánchez, 2005). <a href="https://www.gusgsm.com/pep04.php">www.gusgsm.com/pep04.php</a>.

**Adaptive e-learning:** es un sistema de enseñanza que adapta la selección y presentación de contenidos de una manera individual al estudiante basándose en su nivel de estudios, sus necesidades, su estilo de aprendizaje, sus conocimientos previos y sus preferencias. (Tapia et al., 2004).

**Algoritmo**: secuencia explícita y finita de operaciones que conduce a la solución de un problema. Aplicado a los Sistemas Inteligentes de Gestión suele tratarse de un conjunto de operaciones de álgebra de mapas y/o sobre bases de datos que permiten obtener un resultado mediante combinación de información espacial y alfanumérica.

www.ingeominas.gov.co/option,com\_glossary/limit,10/limitstart,100.htm .

Causalidad: El Principio de causalidad postula que todo efecto -todo eventodebe tener siempre una causa. (Que, en idénticas circunstancias, una causa tenga siempre un mismo efecto se conoce como "principio de uniformidad".) Se usa para la búsqueda de leyes definidas, que asignan a cada causa su correspondiente efecto. <a href="http://es.wikipedia.org/wiki/Principio de causalidad">http://es.wikipedia.org/wiki/Principio de causalidad</a>

**Determinista**: se aplica al modelo, proceso o simulación cuyos resultados no dependen de ningún factor con valores aleatorios. www.etsimo.uniovi.es/~feli/pdf/glosario.pdf .

**Dominio**: En una base de datos se aplica al conjunto de valores posibles de un atributo. www.etsimo.uniovi.es/~feli/pdf/glosario.pdf .

e-learning: es un término que procede del inglés. Se puede definir como el uso de las tecnologías multimedia e hypermedia para desarrollar y mejorar nuevas estrategias de aprendizaje. En concreto, supone la utilización de herramientas informáticas, tales como CD-ROMs, Internet o dispositivos móviles para llevar a cabo una labor docente. La acepción más común para e-learning es la enseñanza a través de Internet. En español se utiliza el término teleformación. Wilson, (2001).

**Incertidumbre**: falta de certeza en un resultado derivada del error en los datos y en los procesos; va asociada a un valor de probabilidad de que la medida sea correcta. www.etsimo.uniovi.es/~feli/pdf/glosario.pdf.

**Independencia**: se dice que un evento B es independiente de un evento A, si la probabilidad de que ocurra B no es afectada por la ocurrencia del evento A.

(Neapolitan, 2004).

**Inicialización del modelo**: Inicializar es situar al modelo en la posición inicial para prepararlo para el uso. <a href="https://www.himnariodigital.org/glossary">www.himnariodigital.org/glossary</a> a-l.html .

**Instantiar:** Conocer el valor para el estado que está siendo modelado en ese instante. (Neapolitan, 2004).

**Ingenieria del conocimiento**: Proceso mediante el cual se traspasa al ordenador la pericia o conocimiento humano en un campo determinado, o varios campos del conocimiento. <a href="https://www.control-systems.net/recursos/glosario/i.htm">www.control-systems.net/recursos/glosario/i.htm</a>.

Inteligencia artificial: Dominio de la ciencia informática que se centra en provocar en la máquina un comportamiento que si proviniera de un ser humano se diría que es inteligente. Uno de los objetivos de la inteligencia artificial es hacer que los ordenadores sean más útiles para todo el mundo. La investigación de la inteligencia artificial puede resultar también muy útil a la hora de ayudarnos a comprender nuestros propios procesos mentales. http://www.mallorcaweb.net/mostel/glosario.htm.

**Métricas de aprendizaje**: son toda clase de evaluaciones formativas y sumativas, toda clase de información acerca de los procesos y actividades del aprendizaje, toda manera de registrar el desarrollo del aprendizaje. (Tapia et I., 2004).

**Manipular:** Forzar a una variable aleatoria a que tome algunos valores específicos. (Neapolitan, 2004).

**Modelo del alumno:** es la estructura que representa y almacena el estado actual del conocimiento que alumno ha adquirido en el dominio a aprender. Para almacenar este tipo de conocimiento se pueden utilizar diferentes tipos de estructuras como pueden ser vectores, redes semánticas, redes bayesianas, repositorios de afirmaciones, etc.

http://ma.ei.uvigo.es/desma2004/articulos/Desma2004\_Laza.pdf

**Modelo Bayesiano**: consiste de un conjunto de distribuciones de probabilidades previas y probabilidades condicionales, y una red que representa las relaciones de independencia entre los nodos que la forman. (Neapolitan, 2004).

**Modelo causal:** es un modelo o gráfica de las relaciones causales supuestas entre los conceptos v/o las variables. (Neapolitan, 2004).

**Modelo**: es una descripción simplificada de la realidad. Se utilizan para propósitos de predicción y control, y nos permite mejorar nuestra comprensión de las características del comportamiento de la realidad estudiada de una forma más efectiva que si se la observara directamente. (Glosario financiero, 2007). <a href="http://www.gruposantander.es/ieb/glosario/glosario/glosariom.htm">http://www.gruposantander.es/ieb/glosario/glosario/glosariom.htm</a>.

**Nodo**: Vértice inicial o final de una línea. Se aplica por extensión a las entidades puntuales que están interconectadas en una estructura en red. El orden de los nodos (de inicial à final) permite asignar a la línea una dirección y dejar definidos los conceptos topológicos de izquierda/derecha.

http://www.gruposantander.es/ieb/glosario/glosariom.htm.

**Nodo instantiado:** Se dice que un nodo está instantiado cuando sabemos su valor para el estado que está siendo modelado en ese instante. (Neapolitan,

2004).

**Objetivos de personalización**: son los planes individuales de adaptación del alumno basándose, por ejemplo, en su nivel de estudios, su estilo de aprendizaje, su estilo cognitivo, estilo de enseñanza preferido, conocimientos previos, currículo y condición del conocimiento dirigido, etc. (Tapia et I., 2004).

**Objetos de personalización**: son los objetos que pueden adaptarse de manera individual al alumno, por ejemplo, los objetos de aprendizaje, su presentación, los métodos de entrada, los aparatos y dispositivos, la usabilidad del sistema, etc. (Tapia et I., 2004).

**Productividad**: la relación entre lo producido y los medios empleados, tales como mano de obra, materiales, energía, etc. (RAE, 2001).

**Red Bayesiana**: es un Gráfica Acíclica Dirigido (GAD) en el que cada nodo representa una variable y cada arco una dependencia probabilística. Son utilizadas para proveer una forma compacta de representar el conocimiento y métodos flexibles de razonamiento. (Neapolitan 2004).

**Relación causal**: tipo de relación asociativa entre dos conceptos, uno de los cuales corresponde a una causa y el otro, a un efecto o consecuencia. Puede incluir, además, al nexo causal que permite este vínculo. Por ejemplo, "accidente-víctima"; "enseñanza-docente-alumno-aprendizaje". (Barite, 2000).

Sistema experto: Programa o conjunto de programas informáticos concebidos para resolver problemas o situaciones de un modo similar al que utilizaría un experto humano dentro de su dominio de su competencia. En consecuencia, el sistema experto persigue la simulación de los procesos de asociación, análisis y síntesis que se realizan en el cerebro humano, y por ello han posibilitado el desarrollo de nuevos estudios sobre Teoría del Conocimiento. Todo sistema experto se apoya en: a) una base de conocimientos. b) un sistema de inferencias que sirve para detectar las condiciones iniciales, las reglas aplicables en función del estado de esas condiciones y del conocimiento que hay que explotar. Los resultados obtenidos por los sistemas expertos generados hasta la fecha, han sido irregulares, y sólo han sido operativos en el contexto de disciplinas altamente formalizadas; por ejemplo, el diagnóstico médico. (Barite, 2000).

**Sumativo (a):** Investigación usada para evaluar o resumir el valor de un producto o una actividad perfeccionada. <a href="www.audiencedialogue.org/gloss-eval.html">www.audiencedialogue.org/gloss-eval.html</a>

**Usabilidad**: es la eficacia, la eficiencia, y la satisfacción que obtienen los alumnos de un sistema de software. Una alta usabilidad quiere decir que el sistema sea fácil de aprender y recordar, eficiente, visualmente agradable y fácil de usar.

www.buzoneo.info/diccionario marketing/diccionario marketing u.php.

**Validación de un modelo**: proceso de verificación mediante el cual se asegura que: (a) el modelo está libre de errores y (b) genera resultados correctos para cualquier combinación coherente de valores de las variables de entrada. http://www.fao.org/docrep/009/v4666s/v4666s0c.htm

# Apéndice A

## Conceptos fundamentales de RBs

En este apéndice presentamos algunos aspectos teóricos importantes de las fdps locales que no pudimos incorporar en el marco teórico del capítulo 3 por falta de espacio.

### A1. pdf locales de una red Bayesiana

La segunda componente de una red Bayesiana es un conjunto de funciones locales de distribuciones de probabilidad condicional, que junto con la estructura gráfica son suficiente para representar la fdp conjunta del dominio. Más concretamente,

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | Pa_i)$$
 (A.1)

Donde  $Pa_i$  es el conjunto que contiene a los padres de  $X_i$  en la red Bayesiana. En otras palabras, las pdf conjunta del dominio puede ser factorizada en una más pequeña, las pdfs locales cada una involucra un nodo y sus padres únicamente. Visto de esta manera, las pdfs locales proporcionan las probabilidades cuantitativas que, cuando son multiplicadas conjuntamente de la manera descrita por las independencias cualitativas que están implicadas por la estructura de la red Bayesiana, son suficientes para reconstruir la pdf conjunta del dominio. Cualquier distribución de probabilidad familiar puede usarse para las pdfs locales. Las independencias presentadas en la estructura de la red Bayesiana conservan su validez para cada miembro de la familia que es consistente con la estructura. En otras palabras, son verdaderas para cualquier selección de parámetros para las pdfs locales. En la práctica, cuando en la gráfica una variable y su padre son discretos, estas pdfs locales frecuentemente son representadas por una distribución multinomial, esta distribución, es una extensión de la distribución binomial que involucra probabilidades conjuntas, envuelve un experimento

estadístico similar, pero en esta ocasión existe más de dos resultados posibles. Específicamente, en cada intento o ensayo puede ser que se obtenga cualquiera de los k eventos  $E_1$ ,  $E_2$ , ....,  $E_k$  con probabilidades respectivas  $p_1$ ,  $p_2$ , ....,  $p_k$ . En este caso, la distribución multinomial es la fdp conjunta del conjunto de variables aleatorias  $X_1$ ,  $X_2$ , ....,  $X_k$  donde  $X_i$  es el número de ocurrencias de  $E_i$ , con i=1,2,....,k, en n intentos independientes. La distribución tiene una función de probabilidad masiva de la forma siguiente:

$$p(x_1, x_2, \dots, x_k; p_1, p_2, \dots, p_k, n) = \binom{n}{x_1, x_2, \dots, x_k} p_1^{x_1} p_2^{x_2} \dots p_k^{x_k}$$
 (A.2)

Donde  $\sum_{i=1}^k x_i = n$ , y  $\sum_{i=1}^k p_i = 1$ . El término multinomial  $\binom{n}{x_1, x_2, \dots, x_k} = \frac{n!}{x_1!, x_2!, \dots, x_k!}$ 

representa el número de maneras que se reparten los  $x_1$  resultados de  $E_1$ , los  $x_2$  resultados de  $E_2$ , ..., los  $x_k$  resultados de  $E_k$ , entre las n pruebas o ensayos. El término  $p_1^{x_1}p_2^{x_2}\cdots p_k^{x_k}$  es la probabilidad de que existan los  $x_1$  resultados de  $E_1$ , los  $x_2$  resultados de  $E_2$ , ..., los  $x_k$  resultados de  $E_k$ . El producto de estos términos nos da la probabilidad de que en n intentos, existan  $x_1$  resultados de  $E_1$ ,  $x_2$  resultados de  $E_2$ , ...,  $x_k$  resultados de  $E_k$ .

Cuando son continuas, mezclas de Gaussianos (Ver Davies y Moore, 1999) y redes neuronales artificiales (Ver Monti y Cooper, 1998 han sido utilizados en la práctica.

#### A2. d-Separación

De acuerdo con Neapolitan (2004), si tenemos una GAD con un conjunto de vértices V, un subconjunto A de V, X y Y son nodos distintos en el conjunto V-A (V menos A), y  $\rho$  es una cadena entre X y Y entonces decimos que  $\rho$  está **bloqueada** por A si una de las siguientes proposiciones es verdadera.

- 1) Existe un nodo  $Z \in A$  en la cadena  $\rho$ , y los bordes incidentes a Z en  $\rho$  se encuentran cabeza a cola en Z.
- 2) Hay un nodo  $Z \in A$  en la cadena  $\rho$ , y los bordes incidentes a Z en  $\rho$  se encuentran cola a cola en Z.
- 3) Existe un nodo  $Z \in A$ , tal que Z y todos sus descendientes no están en A, en la cadena  $\rho$ , y los bordes incidentes en Z en  $\rho$  se encuentra cabeza a cabeza en Z.

Decimos que la cadena está bloqueada en algún nodo de A donde uno de los encuentros arriba mencionados llega a suceder. Puede haber más de uno nodo que esté bloqueando la cadena. La cadena es llamada activa dado A si no está bloqueada por A. Por ejemplo, en la GAD de la Figura 3.6, la cadena [Y,X,Z,S] está bloqueada por  $\{X\}$  porque los bordes en la cadena incidente a X se encuentra cola a cola en X. Esta cadena también está bloqueada por  $\{Z\}$  porque los bordes de la cadena incidente a Z se encuentra cabeza a cola en Z. Además, Y y Z son independientes porque ambas veredas entre Y y Z están bloqueadas y W es independiente condicionalmente de Z dado  $\{Y,X\}$  porque a pesar de que X está

desbloqueada, R lo está. La cadena [W,Y,R,Z,S] no está bloqueada por  $\{R\}$  porque los bordes en la cadena incidente a R se encuentran cabeza a cabeza en R. Además, esta cadena no está bloqueada por  $\{T\}$  porque T es un descendiente de R.

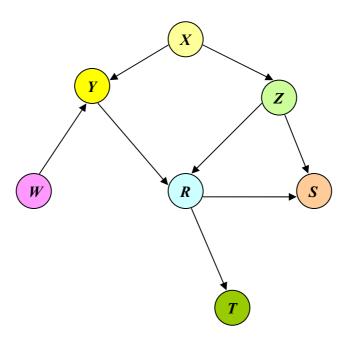


Figura A1. Una GAD usada para ilustrar cadenas boqueándose y d-separaciones.

Si G es una GAD,  $A \subseteq V$  y X, Y son nodos distintos de V-A, decimos que X y Y están d-separados por A en G si cada cadena entre X y Y está bloqueada por A. No es difícil notar que cada cadena entre X y Y está bloqueada por A si y sólo si cada cadena simple entre X y Y está bloqueada por A. Por ejemplo, refiriéndonos a la GAD de la Figura A1, X y X están d-separados por X0 porque la cadena X1 está bloqueada en X2 porque la cadena X3 está bloqueada en X4 porque la cadena X5 porque la cadena X6 porque la cadena X7 porque la cadena X8 porque la cadena X9 porque la cadena X9 porque la cadena

[X,Z,R,T] está bloqueada en Z, y la cadena [X,Z,S,R,T] está bloqueada en Z y en S. W y X no están d-separados por  $\{Y\}$  porque la cadena [W,Y,X] no está bloqueada en Y puesto que  $Y \in \{Y\}$  y claramente no puede ser bloqueado en cualquier parte de alguna manera. La condición de Markov vista en la sección 3.4.2 implica que:

- 1) Todas las d-separaciones son independientes condicionalmente, y
- 2) Cada independencia condicional causada por la condición de Markov está identificada mediante una d-separación. Además cada independencia condicional que sea común a todas las distribuciones de probabilidad que satisfacen la condición de Markov con G está identificada por una dseparación.

La demostración de estas aseveraciones puede encontrarse en Verma y Pearl, 1990b y en Neapolitan, 1990.

Finalmente, Si A, B y C son subconjuntos de V ajenos entre si, y G es una GAD, decimos que A y B están d-separados por C si para cada  $X \in A$  y cada  $Y \in B$ , X y Y están d-separados por C. Escribimos  $I_G$  (A,B|C). Si  $C = \emptyset$ , sólo escribimos  $I_G$  (A,B). Si A y B son d-separados por C en G, la condición de Markov implica que G0 (G0). Por esta razón, si G0, G1) satisfacen la condición de Markov, decimos que G1 es un mapa de independencia de G2 que indicamos por G3. Para más detalles sobre d-separaciones ver Neapolitan (2004) y Verma y Pearl (1990b).

## A3. Ley de probabilidad total

Sean  $E_1,E_2,\cdots,E_n$  eventos tales que  $E_i\cap E_j=\varnothing$  para  $i\neq j$  y  $E_1\cup E_2\cup,\cdots,\cup E_n=\Omega$ . La ley de probabilidad total dice que para cualquier otro evento F,

$$P(F) = \sum_{i=1}^{n} P(F \cap E_i)$$
 (A.3)

Si  $P(E_i) \neq 0$ , entonces  $P(F \cap E_i) = P(F|E_i) \cdot P(E_i)$ . Por lo tanto, Si  $P(E_i) \neq 0$  para toda i, la ley se aplica frecuentemente como sigue:

$$P(F) = P(F|E_i) \cdot P(E_i)$$
 (A.4)

# Apéndice B

## Lista de tablas usadas en el capítulo 4

En este apéndice se muestran las tablas con los resultados obtenidos en el curso en línea con 45 alumnos simulados, en relación a sus ops, OPs y TPs en cada una de las cuatro fases del proceso de enseñanza-aprendizaje. Los resultados que aparecen en las tablas mencionadas, se obtuvieron mediante un proceso aleatorio en cual asignó a cada alumno un estado o característica de cada una de las variables. Además, se presentan las tablas de distribución de frecuencias y distribución de frecuencias relativas, para facilitar los cálculos de las probabilidades condicionales que se requieren en el capítulo 4 y 5.

# B1. Objetivos (OPs) y objetos de personalización (ops) del alumno

La Tabla B1 presenta el nivel de conocimientos previos de 45 alumnos.

Tabla B1. Nivel de conocimientos previos de 45 alumnos

Alumno		Conocimientos Alumno	
	previos		previos
1	Bajo	23	Alto
2	Intermedio	24	Intermedio
3	Bajo	25	Bajo
4	Bajo	26	Intermedio
5	Alto	27	Intermedio
6	Bajo	28	Intermedio
7	Intermedio	29	Bajo
8	Alto	30	Intermedio
9	Bajo	31	Alto
10	Intermedio	32	Intermedio
11	Bajo	33	Alto
12	Alto	34	Alto
13	Alto	35	Intermedio
14	Intermedio	36	Intermedio
15	Intermedio	37	Intermedio
16	Alto	38	Bajo
17	Bajo	39	Intermedio
18	Intermedio	40	Bajo
19	Alto	41	Bajo
20	Alto	42	Intermedio
21	Alto	43	Intermedio
22	Bajo	44	Intermedio
_		45	Bajo

Tabla B2. Distribuciones de frecuencia de la Tabla B1.

Nivel	Cantidad	Frecuencia Relativa
Alto	12	0.2667
Intermedio	19	0.4222
Bajo	14	0.3111

La Tabla B3 muestra los estilos de aprendizaje de 45 alumnos.

Tabla B3. Estilos de aprendizaje de 45 alumnos

Alumno	Estilo de Alumno		Estilo de
	aprendizaje		aprendizaje
1	Reflexivo	23	Teórico
2	Teórico	24	Pragmático
3	Activo	25	Teórico
4	Teórico	26	Teórico
5	Reflexivo	27	Pragmático
6	Pragmático	28	Reflexivo
7	Pragmático	29	Reflexivo
8	Teórico	30	Teórico
9	Teórico	31	Pragmático
10	Activo	32	Reflexivo
11	Activo	33	Activo
12	Pragmático	34	Teórico
13	Pragmático	35	Reflexivo
14	Pragmático	36	Pragmático
15	Reflexivo	37	Activo
16	Teórico	38	Teórico
17	Reflexivo	39	Reflexivo
18	Reflexivo	40	Teórico
19	Teórico	41	Reflexivo
20	Activo	42	Pragmático
21	Teórico	43	Teórico
22	Activo	44	Pragmático
		45	Activo

Tabla B4. Distribuciones de frecuencia de la Tabla B3.

Estilo de aprendizaje	Cantidad	Frecuencia Relativa
Activo	8	0.1778
Reflexivo	11	0.2445
Teórico	15	0.3333
Pragmático	11	0.2444

La Tabla B5 presenta los estilos cognitivos de 45 alumnos.

Tabla B5. Estilos cognitivos de 45 alumnos

Alumno	Estilo Alumno		Estilo
	Cognitivo		Cognitivo
1	Dependiente	23	Independiente
2	Dependiente	24	Dependiente
3	Dependiente	25	Independiente
4	Dependiente	26	Independiente
5	Dependiente	27	Independiente
6	Independiente	28	Independiente
7	Independiente	29	Dependiente
8	Dependiente	30	Dependiente
9	Independiente	31	Independiente
10	Dependiente	32	Independiente
11	Independiente	33	Independiente
12	Independiente	34	Dependiente
13	Dependiente	35	Dependiente
14	Dependiente	36	Dependiente
15	Dependiente	37	Independiente
16	Dependiente	38	Dependiente
17	Independiente	39	Independiente
18	Dependiente	40	Independiente
19	Dependiente	41	Dependiente
20	Dependiente	42	Independiente
21	Independiente	43	Independiente
22	Dependiente	44	Dependiente
		45	Dependiente

Tabla B6. Distribuciones de frecuencia de la Tabla B5.

Estilo cognitivo	Cantidad	Frecuencia Relativa
Dependiente	25	0.5556
Independiente	20	0.4444

La Tabla B7 muestra los estilos de comunicación de 45 alumnos.

Tabla B7. Estilos de comunicación de 45 alumnos

Alumno	Estilo de comunicación	Alumno	Estilo de comunicación
1	Pasivo	23	Agresivo
2	Asertivo	24	Agresivo
3	Agresivo	25	Asertivo
4	Pasivo	26	Agresivo
5	Agresivo	27	Agresivo
6	Pasivo	28	Pasivo
7	Pasivo	29	Agresivo
8	Pasivo	30	Pasivo
9	Agresivo	31	Agresivo
10	Pasivo	32	Pasivo
11	Agresivo	33	Agresivo
12	Asertivo	34	Asertivo
13	Asertivo	35	Pasivo
14	Asertivo	36	Asertivo
15	Asertivo	37	Pasivo
16	Pasivo	38	Agresivo
17	Agresivo	39	Pasivo
18	Asertivo	40	Pasivo
19	Asertivo	41	Pasivo
20	Agresivo	42	Agresivo
21	Pasivo	43	Pasivo
22	Pasivo	44	Pasivo
		45	Pasivo

Tabla B8. Distribuciones de frecuencia de la Tabla B7

Estilo de comunicación	Cantidad	Frecuencia Relativa
Pasivo	20	0.4444
Asertivo	10	0.2223
Agresivo	15	0.3333

La Tabla B9 presenta los estilos de enseñanza preferido de 45 alumnos.

Tabla B9. Estilo de enseñanza preferido de 45 alumnos

Alumno	Estilo de Alumno		Estilo de
	Enseñanza		Enseñanza
1	Facilitador	23	Autoritario
2	Delegador	24	Delegador
3	Demostrador	25	Demostrador
4	Facilitador	26	Autoritario
5	Delegador	27	Delegador
6	Facilitador	28	Delegador
7	Demostrador	29	Autoritario
8	Autoritario	30	Delegador
9	Autoritario	31	Demostrador
10	Facilitador	32	Demostrador
11	Autoritario	33	Facilitador
12	Delegador	34	Facilitador
13	Autoritario	35	Autoritario
14	Facilitador	36	Autoritario
15	Demostrador	37	Delegador
16	Demostrador	38	Facilitador
17	Delegador	39	Facilitador
18	Autoritario	40	Facilitador
19	Facilitador	41	Delegador
20	Delegador	42	Autoritario
21	Delegador	43	Delegador
22	Delegador	44	Delegador
		45	Delegador

Tabla B10. Distribuciones de frecuencia de la Tabla B9

Estilo de enseñanza	Cantidad	Frecuencia Relativa
Autoritario	11	0.2444
Demostrador	7	0.1556
Facilitador	11	0.2444
Delegador	16	0.3556

La Tabla B11 muestra las técnicas de aprendizaje en línea usadas por 45 alumnos.

Tabla B11. Técnicas de aprendizaje de 45 alumnos

Técnica de aprendizaje		Técnica de aprendizaje					
Alumno	Visual	Activo	Colaborativo	Alumno	Visual	Activo	Colaborativo
1	NO	SI	NO	23	NO	NO	NO
2	NO	NO	NO	24	NO	NO	NO
3	SI	NO	SI	25	SI	NO	NO
4	NO	SI	NO	26	SI	SI	SI
5	NO	NO	SI	27	NO	SI	SI
6	SI	SI	NO	28	NO	NO	SI
7	SI	SI	SI	29	NO	NO	NO
8	SI	SI	NO	30	SI	SI	NO
9	SI	SI	NO	31	NO	SI	NO
10	SI	SI	SI	32	SI	SI	NO
11	NO	NO	SI	33	NO	SI	SI
12	SI	SI	NO	34	SI	SI	SI
13	NO	SI	NO	35	SI	SI	SI
14	SI	SI	SI	36	SI	SI	SI
15	NO	SI	NO	37	SI	NO	NO
16	SI	NO	SI	38	NO	SI	SI
17	SI	SI	SI	39	NO	NO	NO
18	SI	SI	NO	40	SI	NO	SI
19	SI	SI	SI	41	NO	NO	NO
20	NO	SI	NO	42	NO	SI	SI
21	SI	NO	NO	43	NO	SI	NO
22	NO	NO	NO	44	SI	NO	SI
				45	SI	NO	NO

Tabla B12. Distribuciones de frecuencia de la Tabla B11

Técnicas de aprendizaje	Cantidad	Frecuencia Relativa
Para aprendizaje visual	24	0.5333
Para aprendizaje activo	27	0.6
Para aprendizaje colaborativo	20	0.4444

La Tabla B13 presenta las preferencias individuales de 45 alumnos.

Tabla B13. Preferencias individuales de 45 alumnos

	Prefer	encias		Preferencias			
Alumno	Visuales	Auditivas	Kinest.	Alumno	Visuales	Auditivas	Kinest.
1	NO	NO	SI	23	SI	NO	NO
2	SI	NO	SI	24	SI	SI	SI
3	NO	NO	NO	25	NO	NO	NO
4	SI	NO	SI	26	NO	NO	NO
5	NO	NO	NO	27	NO	NO	NO
6	SI	NO	SI	28	SI	SI	NO
7	NO	NO	NO	29	NO	SI	NO
8	SI	SI	NO	30	NO	NO	NO
9	SI	SI	SI	31	NO	SI	SI
10	SI	NO	SI	32	SI	SI	NO
11	SI	NO	SI	33	NO	NO	SI
12	SI	SI	SI	34	NO	NO	SI
13	SI	NO	NO	35	NO	SI	SI
14	NO	NO	NO	36	NO	SI	NO
15	NO	NO	SI	37	NO	NO	SI
16	NO	SI	SI	38	SI	NO	SI
17	NO	NO	NO	39	NO	NO	SI
18	NO	NO	NO	40	NO	NO	SI
19	SI	NO	NO	41	NO	SI	SI
20	SI	SI	NO	42	NO	SI	NO
21	SI	NO	SI	43	SI	NO	SI
22	NO	NO	NO	44	SI	SI	SI
				45	NO	NO	NO

Tabla B14. Distribuciones de frecuencia de la Tabla B13.

Preferencias individuales	Cantidad	Frecuencia Relativa
Visuales	19	0.4222
Auditivas	15	0.3333
Kinestéticas	23	0.5111

La Tabla B15 muestra el currículo\* (área de estudio) de 45 alumnos.

Tabla B15. Currículo de 45 alumnos

Alumno	Currículo	Alumno	Currículo
1	HBA	23	CEN
2	BCS	24	CEN
3	CEN	25	BCS
4	ING	26	CSO
5	BCS	27	BCS
6	ECA	28	HBA
7	CEN	29	BCS
8	CEN	30	BCS
9	ECA	31	BCS
10	BCS	32	HBA
11	ING	33	CSO
12	CSO	34	ECA
13	HBA	35	ECA
14	ING	36	CEN
15	BCS	37	BCS
16	BCS	38	CEN
17	HBA	39	ING
18	CSO	40	ECA
19	CSO	41	CEN
20	ECA	42	HBA
21	ECA	43	CSO
22	CSO	44	CSO
		45	CEN

Tabla B16. Distribuciones de frecuencia de la Tabla B15.

Currículo*	Cantidad	Frecuencia Relativa
Ciencias Exactas y Naturales (CEN)	9	0.2
Ingeniería (ING)	4	0.0889
Biología y Ciencias de la Salud (BCS)	11	0.2444
Ciencias Sociales (CSO)	8	0.1778
Económicas y Administrativas (ECA)	7	0.1556
6) Humanidades y Bellas Artes (HBA)	6	0.1333

La Tabla B17 presenta las necesidades personales de 45 alumnos.

Tabla B17. Necesidades personales de 45 alumnos

Necesidades personales						Necesio	dades pe	rsonales	
Alumno	Amb.	Emoc.	Soc.	Fis.	Alumno	Amb.	Emoc.	Soc.	Fis.
1	SI	SI	SI	NO	23	NO	NO	NO	SI
2	NO	SI	SI	NO	24	SI	SI	NO	SI
3	SI	SI	SI	NO	25	NO	SI	SI	NO
4	NO	NO	NO	NO	26	SI	NO	SI	NO
5	SI	SI	SI	SI	27	NO	SI	NO	NO
6	SI	SI	SI	SI	28	NO	SI	SI	SI
7	NO	NO	NO	SI	29	SI	SI	SI	NO
8	SI	NO	NO	SI	30	NO	SI	NO	SI
9	NO	NO	NO	NO	31	NO	SI	NO	SI
10	NO	SI	NO	NO	32	NO	SI	SI	NO
11	SI	SI	SI	SI	33	NO	SI	NO	SI
12	SI	SI	NO	NO	34	NO	SI	SI	SI
13	NO	SI	NO	SI	35	SI	SI	SI	NO
14	NO	NO	NO	NO	36	NO	NO	NO	SI
15	SI	NO	NO	SI	37	SI	SI	NO	NO
16	SI	NO	NO	NO	38	NO	SI	SI	SI
17	SI	SI	NO	SI	39	SI	SI	NO	NO
18	NO	NO	NO	SI	40	SI	NO	SI	NO
19	NO	SI	SI	NO	41	NO	SI	NO	SI
20	SI	SI	NO	SI	42	NO	SI	SI	SI
21	SI	SI	SI	SI	43	SI	NO	SI	SI
22	SI	NO	NO	SI	44	NO	SI	NO	NO
					45	SI	NO	SI	SI

Tabla B18. Distribuciones de frecuencia de la Tabla B17.

Necesidades personales	Cantidad	Frecuencia Relativa
Ambientales	22	0.4889
Emocionales	30	0.6667
Sociales	20	0.4444
Fisiológicas	25	0.5555

La Tabla B19 muestra los resultados obtenidos en una muestra de 45 casos en relación al motivo de la selección de los objetos de aprendizaje.

Tabla B19. Resultados de una muestra de 45 casos del motivo de la selección de los objetos de aprendizaje.

	Selección de los		Selección de los
Caso	objetos de aprendizaje*	Caso	objetos de aprendizaje
1	NPE	23	NPE
2	FAO	24	FAO
3	NPE	25	NPE
4	FAO	26	NPE
5	NPE	27	NPE
6	NPE	28	NPE
7	NPE	29	NPE
8	NPE	30	FAO
9	FAO	31	NPE
10	NPE	32	NPE
11	NPE	33	FAO
12	FAO	34	NPE
13	FAO	35	FAO
14	FAO	36	NPE
15	NPE	37	NPE
16	NPE	38	NPE
17	NPE	39	FAO
18	NPE	40	FAO
19	NPE	41	FAO
20	FAO	42	NPE
21	FAO	43	NPE
22	NPE	44	NPE
		45	FAO

\*NPE = Por necesidad del programa de enseñanza. FAO = Como una facilidad para tener acceso a un objeto de aprendizaje particular sugerido.

Tabla B20. Distribuciones de frecuencia de la Tabla B19.

Selección de los objetos	Cantidad	Frecuencia
de aprendizaje		Relativa
1) Por necesidad del programa de enseñanza	29	0.6444
2) Para facilitar el acceso a un objeto de	16	0.3555
aprendizaje particular sugerido		

La Tabla B21 presenta la preferencia de la presentación de los objetos de aprendizaje de 45 alumnos.

Tabla B21. Preferencias de la presentación de los objetos de aprendizaje.

Alumno	Presentación de los objetos de aprendizaje	Alumno	Presentación de los objetos de aprendizaje
1	En línea	23	Combinado
2	Combinado	24	CD ROM
3	Combinado	25	Combinado
4	Combinado	26	CD ROM
5	CD ROM	27	CD ROM
6	En línea	28	Combinado
7	Combinado	29	Combinado
8	CD ROM	30	En línea
9	En línea	31	Combinado
10	En línea	32	Combinado
11	En línea	33	Combinado
12	CD ROM	34	En línea
13	En línea	35	CD ROM
14	En línea	36	Combinado
15	Combinado	37	CD ROM
16	Combinado	38	CD ROM
17	CD ROM	39	CD ROM
18	Combinado	40	CD ROM
19	En línea	41	En línea
20	CD ROM	42	CD ROM
21	Combinado	43	Combinado
22	En línea	44	Combinado
		45	Combinado

Tabla B22. Distribuciones de frecuencia de la Tabla B21.

Presentación de los objetos de aprendizaje	Cantidad	Frecuencia Relativa
En CD ROM	14	0.3111
En línea	12	0.2667
Combinado	19	0.4222

La Tabla B23 muestra los resultados de selección de los métodos de entrada en una muestra de 45 alumnos.

Tabla B23. Resultados de una muestra de 45 casos en relación a la selección de los métodos de entrada.

Selección de los métodos de entrada					Selecc	ción de los	método	s de ent	rada
Alum.	Ratón	Tecl.	Puls.	SRL	Alum.	Ratón	Tecl.	Puls.	SRL
1	SI	SI	NO	SI	23	SI	SI	NO	SI
2	SI	SI	NO	NO	24	NO	NO	NO	NO
3	SI	SI	NO	SI	25	SI	SI	NO	SI
4	SI	SI	NO	SI	26	SI	SI	NO	SI
5	NO	SI	NO	SI	27	SI	SI	NO	SI
6	SI	SI	NO	NO	28	SI	SI	NO	NO
7	SI	SI	NO	SI	29	SI	SI	NO	NO
8	SI	SI	NO	SI	30	SI	SI	NO	SI
9	SI	SI	NO	SI	31	SI	SI	NO	SI
10	NO	NO	SI	SI	32	SI	SI	NO	SI
11	SI	SI	NO	NO	33	SI	SI	NO	SI
12	SI	SI	NO	NO	34	SI	SI	NO	SI
13	SI	SI	NO	SI	35	SI	SI	NO	SI
14	SI	SI	NO	SI	36	SI	SI	NO	SI
15	SI	SI	NO	SI	37	SI	SI	NO	SI
16	SI	SI	NO	SI	38	SI	SI	NO	SI
17	SI	SI	NO	SI	39	SI	SI	NO	SI
18	SI	SI	NO	SI	40	SI	SI	NO	SI
19	SI	SI	NO	NO	41	SI	SI	NO	SI
20	SI	SI	NO	NO	42	SI	SI	NO	SI
21	SI	SI	NO	NO	43	SI	SI	NO	SI
22	SI	SI	NO	SI	44	SI	SI	NO	SI
		-	-		45	SI	SI	NO	SI

Tabla B24. Distribuciones de frecuencia de la Tabla B23.

Selección de los métodos de entrada	Cantidad	Frecuencia Relativa
Ratón	42	0,9333
Teclado	43	0,9556
Pulsador	1	0.0222
Sistema de reconocimiento de lenguaje (SRL)	30	0.6667

La Tabla B25 presenta los resultados de una muestra de 45 casos de los dispositivos de aprendizaje mediante los cuales se llevó a cabo el proceso de enseñanza-aprendizaje de los alumnos.

Tabla B25. Resultados de una muestra de 45 casos en relación a los dispositivos de aprendizaje.

Caso	Dispositivos de	Caso	Dispositivos de
	aprendizaje		aprendizaje
1	AAC	23	AAC
2	OI	24	II
2 3 4	AAC	25	II
4	II	26	Ol
5 6	II	27	AAC
	OI	28	II
7	OI	29	AAC
8	II	30	AAC
9	OI	31	II
10	II	32	AAC
11	II	33	Ol
12	OI	34	II
13	II	35	AAC
14	II	35	AAC
15	II	37	II
16	OI	38	II
17	AAC	39	Ol
18	OI	40	OI
19	II	41	Ol
20	AAC	42	AAC
21	AAC	43	II
22	OI	44	II
		45	Ol

Tabla B26. Distribuciones de frecuencia de la Tabla B25.

Dispositivos de aprendizaje	Cantidad	Frecuencia Relativa
Objetos inteligentes (OI)	14	0.3111
Infraestructuras de la información (II)	18	0.4
Ambientes artificiales compartidos (AAC)	13	0.2889

La Tabla B27 presenta los resultados del tipo de usabilidad del sistema de software por parte del estudiante en una muestra de 45 alumnos.

Tabla B27. Tipo de usabilidad del sistema de software por parte del alumno.

Alumno	Usabilidad	Alumno	Usabilidad
1	Regular	23	Deficiente
2	Buena	24	Deficiente
3	Deficiente	25	Deficiente
4	Regular	26	Deficiente
5	Regular	27	Buena
6	Regular	28	Deficiente
7	Deficiente	29	Deficiente
8	Buena	30	Regular
9	Regular	31	Regular
10	Deficiente	32	Deficiente
11	Regular	33	Deficiente
12	Buena	34	Buena
13	Deficiente	35	Deficiente
14	Buena	36	Regular
15	Regular	37	Regular
16	Regular	38	Regular
17	Deficiente	39	Buena
18	Deficiente	40	Deficiente
19	Regular	41	Regular
20	Deficiente	42	Buena
21	Deficiente	43	Regular
22	Deficiente	44	Buena
_		45	Buena

Tabla B28. Distribuciones de frecuencia de la Tabla B27.

Usabilidad del sistema	Cantidad	Frecuencia Relativa
Deficiente	19	0.4222
Regular	16	0.3556
Buena	10	0.2222

## B2. Fase de los conocimientos previos

La Tabla B29 muestra los resultados de requerimiento de adecuación del sistema en la fase de los conocimientos previos.

Tabla B29. Requerimiento de adecuación del sistema en la fase de los conocimientos previos.

Alumno	Adaptación	Alumno	Adaptación
1	Si	23	Si
2	No	24	Si
3	Si	25	Si
4	No	26	Si
5	No	27	No
6	Si	28	Si
7	No	29	Si
8	No	30	No
9	No	31	No
10	Si	32	Si
11	Si	33	Si
12	No	34	No
13	Si	35	Si
14	No	36	Si
15	Si	37	No
16	Si	38	No
17	No	39	No
18	Si	40	Si
19	Si	41	Si
20	No	42	Si
21	Si	43	Si
22	No	44	No
		45	Si

Tabla B30. Distribuciones de frecuencia de la Tabla B29.

Requerimiento de adaptación del sistema	Cantidad	Frecuencia Relativa
Si	26	0.5778
No	19	0.4222

La Tabla B31 presenta el tipo de adecuación del sistema preferida por el alumno en la fase de los conocimientos previos.

Tabla B31. Tipo de adecuación del sistema preferida por el alumno en la fase de los conocimientos previos.

Alumno	Adecuación	Alumno	Adecuación
	del sistema		del sistema
1	Automática	23	Automática
2	Manual	24	Manual
3	Manual	25	Manual
4	Automática	26	Automática
5	Automática	27	Manual
6	Automática	28	Automática
7	Manual	29	Manual
8	Automática	30	Automática
9	Manual	31	Manual
10	Automática	32	Automática
11	Manual	33	Manual
12	Automática	34	Automática
13	Manual	35	Manual
14	Manual	36	Automática
15	Manual	37	Manual
16	Automática	38	Manual
17	Manual	39	Automática
18	Automática	40	Manual
19	Automática	41	Manual
20	Manual	42	Manual
21	Automática	43	Automática
22	Automática	44	Automática
		45	Manual

Tabla B32. Distribuciones de frecuencia de la Tabla B31.

Tipo de adaptación	Cantidad	Frecuencia Relativa
automática	19	0.4889
Manual	16	0.5111

La Tabla B33 presenta los resultados de la necesidad de capacitar al alumno para usar el sistema usado para el proceso de enseñanza-aprendizaje en linea en la fase de los conocimientos previos.

Tabla B33. Requerimiento de capacitación del alumno para usar el sistema en la fase de los conocimientos previos.

Alumno	Capacitación	Alumno	Capacitación
1	No	23	Si
2	Si	24	Si
3	Si	25	Si
4	No	26	No
5	No	27	Si
6	Si	28	Si
7	Si	29	Si
8	Si	30	No
9	No	31	Si
10	Si	32	Si
11	No	33	Si
12	No	34	Si
13	No	35	No
14	No	36	Si
15	Si	37	Si
16	Si	38	Si
17	Si	39	Si
18	No	40	Si
19	No	41	No
20	No	42	Si
21	No	43	Si
22	Si	44	Si
		45	No

Tabla B34. Distribuciones de frecuencia de la Tabla B33.

Capacitación	Cantidad	Frecuencia Relativa
Si	28	0.6222
No	17	0.3778

### B3. Fase del progreso del conocimiento

La Tabla B35 muestra los resultados de requerimiento de adecuación del sistema en la fase del progreso del conocimiento.

Tabla B35. Requerimiento de adecuación del sistema en la fase del progreso del conocimiento.

Alumno	Adaptación	Alumno	Adaptación
1	NO	23	SI
2	NO	24	NO
3	SI	25	NO
4	NO	26	NO
5	NO	27	SI
6	NO	28	NO
7	NO	29	SI
8	SI	30	SI
9	NO	31	NO
10	SI	32	NO
11	NO	33	SI
12	NO	34	SI
13	NO	35	SI
14	NO	36	SI
15	SI	37	NO
16	SI	38	SI
17	SI	39	NO
18	SI	40	NO
19	SI	41	SI
20	NO	42	NO
21	SI	43	SI
22	SI	44	SI
		45	NO

Tabla B36. Distribuciones de frecuencia de la Tabla B35.

Requerimiento de adaptación del sistema	Cantidad	Frecuencia Relativa
Si	22	0.4889
No	23	0.5111

La Tabla B37 presenta el tipo de adecuación del sistema preferida por el alumno en la fase del progreso del conocimiento.

Tabla B37. Tipo de adecuación del sistema preferida por el alumno en la fase del progreso del conocimiento.

Alumno	Adecuación	Alumno	Adecuación
	del sistema		del sistema
1	Automática	23	Manual
2	Automática	24	Manual
3	Automática	25	Manual
4	Manual	26	Manual
5	Manual	27	Manual
6	Manual	28	Manual
7	Automática	29	Automática
8	Automática	30	Automática
9	Automática	31	Automática
10	Manual	32	Automática
11	Automática	33	Manual
12	Automática	34	Automática
13	Automática	35	Manual
14	Manual	36	Manual
15	Automática	37	Manual
16	Automática	38	Manual
17	Manual	39	Automática
18	Automática	40	Manual
19	Manual	41	Manual
20	Automática	42	Automática
21	Automática	43	Automática
22	Manual	44	Manual
		45	Manual

Tabla B38. Distribuciones de frecuencia de la Tabla B37.

Tipo de adaptación	Cantidad	Frecuencia Relativa
automática	22	0.4889
Manual	23	0.5111

La Tabla B39 muestra los resultados de la necesidad de capacitar al alumno para usar el sistema usado para el proceso de enseñanza-aprendizaje en línea en la fase del progreso del conocimiento.

Tabla B39. Requerimiento de capacitación del alumno para usar el sistema en la fase del progreso del conocimiento.

Alumno	Capacitación	Alumno	Capacitación
1	NO	23	NO
2	NO	24	NO
3	SI	25	SI
4	SI	26	NO
5	SI	27	SI
6	NO	28	NO
7	SI	29	NO
8	NO	30	SI
9	SI	31	NO
10	SI	32	NO
11	NO	33	NO
12	NO	34	NO
13	SI	35	NO
14	SI	36	NO
15	NO	37	NO
16	SI	38	NO
17	SI	39	NO
18	SI	40	SI
19	SI	41	SI
20	SI	42	NO
21	SI	43	SI
22	SI	44	SI
		45	NO

Tabla B40. Distribuciones de frecuencia de la Tabla B39.

Capacitación	Cantidad	Frecuencia Relativa
Si	22	0.4889
No	23	0.5111

#### B4. Fase de los objetivos y metas del profesor/alumno

La Tabla B41 muestra los resultados de requerimiento de adecuación del sistema en la fase de los objetivos y metas del profesor/alumno.

Tabla B41. Requerimiento de adecuación del sistema en la fase de los objetivos y metas del profesor/alumno.

Alumno	Adaptación	Alumno	Adaptación
1	SI	23	SI
2	SI	24	SI
3	NO	25	NO
4	NO	26	NO
5 6	NO	27	SI
6	SI	28	SI
7	NO	29	NO
8	SI	30	SI
9	NO	31	NO
10	NO	32	SI
11	NO	33	NO
12	SI	34	NO
13	NO	35	SI
14	NO	36	NO
15	NO	37	SI
16	SI	38	SI
17	NO	39	NO
18	NO	40	SI
19	SI	41	NO
20	NO	42	NO
21	NO	43	NO
22	SI	44	SI
	_	45	SI

Tabla B42. Distribuciones de frecuencia de la Tabla B41.

Requerimiento de adaptación del sistema	Cantidad	Frecuencia Relativa
Si	20	0.4444
No	25	0.5556

La Tabla B43 presenta el tipo de adecuación del sistema preferida por el alumno en la fase de los objetivos y metas del profesor/alumno.

Tabla B43. Tipo de adecuación del sistema preferida por el alumno en la fase de los objetivos y metas del profesor/alumno.

	•		
Alumno	Adaptación del sistema	Alumno	Adaptación del sistema
1	Manual	23	Manual
2	Automática	24	Manual
3	Manual	25	Manual
4	Automática	26	Manual
5	Automática	27	Automática
6	Automática	28	Manual
7	Manual	29	Manual
8	Automática	30	Automática
9	Automática	31	Manual
10	Manual	32	Manual
11	Automática	33	Automática
12	Automática	34	Manual
13	Automática	35	Automática
14	Automática	36	Manual
15	Manual	37	Manual
16	Automática	38	Manual
17	Automática	39	Automática
18	Automática	40	Automática
19	Manual	41	Manual
20	Manual	42	Manual
21	Automática	43	Manual
22	Automática	44	Manual
		45	Automática

Tabla B44. Distribuciones de frecuencia de la Tabla B43.

Tipo de adaptación	Cantidad	Frecuencia Relativa
automática	22	0.4889
Manual	23	0.5111

La Tabla B45 muestra los resultados de la necesidad de capacitar al alumno para usar el sistema usado para el proceso de enseñanza-aprendizaje en línea en la fase de los objetivos y metas del profesor/alumno.

Tabla B45. Requerimiento de capacitación del alumno para usar el sistema en la fase de los objetivos y metas del profesor/alumno.

Alumno	Capacitación	Alumno	Capacitación
1	SI	23	SI
2	NO	24	SI
3	NO	25	NO
4	NO	26	NO
5	SI	27	NO
6	SI	28	SI
7	NO	29	SI
8	NO	30	SI
9	NO	31	SI
10	SI	32	SI
11	NO	33	SI
12	SI	34	SI
13	NO	35	NO
14	NO	36	SI
15	SI	37	SI
16	SI	38	SI
17	NO	39	SI
18	NO	40	SI
19	NO	41	SI
20	SI	42	NO
21	NO	43	SI
22	NO	44	SI
		45	NO

Tabla B46. Distribuciones de frecuencia de la Tabla B45.

Capacitación	Cantidad	Frecuencia Relativa
Si	25	0.5556
No	20	0.4444

#### B5. Fase de las preferencias y experiencia de navegación

La Tabla B47 muestra los resultados de requerimiento de adecuación del sistema en la fase de las preferencias y experiencia de navegación.

Tabla B47. Requerimiento de adecuación del sistema en la fase de las preferencias y experiencia de navegación.

Alumno	Adaptación	Alumno	Adaptación
1	SI	23	NO
2	NO	24	SI
3	SI	25	SI
4	SI	26	SI
5	SI	27	SI
6	SI	28	NO
7	SI	29	NO
8	SI	30	SI
9	SI	31	SI
10	NO	32	NO
11	SI	33	NO
12	SI	34	SI
13	NO	35	SI
14	SI	36	SI
15	NO	37	SI
16	NO	38	NO
17	NO	39	SI
18	SI	40	SI
19	SI	41	NO
20	SI	42	NO
21	NO	43	SI
22	NO	44	NO
		45	SI

Tabla B48. Distribuciones de frecuencia de la Tabla B47.

Requerimiento de adaptación del sistema	Cantidad	Frecuencia Relativa
Si	28	0.6222
No	17	0.3778

La Tabla B49 presenta el tipo de adecuación del sistema preferida por el alumno en la fase de las preferencias y experiencia de navegación.

Tabla B49. Tipo de adecuación del sistema preferida por el alumno en la fase de las preferencias y experiencia de navegación.

Alumno	Adecuación	Alumno	Adecuación
	del sistema		del sistema
1	Automática	23	Automática
2	Manual	24	Automática
3	Manual	25	Manual
4	Automática	26	Automática
5	Manual	27	Manual
6	Automática	28	Manual
7	Automática	29	Manual
8	Automática	30	Manual
9	Automática	31	Manual
10	Automática	32	Manual
11	Automática	33	Manual
12	Manual	34	Manual
13	Automática	35	Manual
14	Manual	36	Automática
15	Manual	37	Manual
16	Automática	38	Manual
17	Manual	39	Manual
18	Manual	40	Automática
19	Manual	41	Manual
20	Manual	42	Automática
21	Manual	43	Manual
22	Manual	44	Manual
		45	Manual

Tabla B50. Distribuciones de frecuencia de la Tabla B49.

Tipo de adaptación	Cantidad	Frecuencia Relativa
automática	16	0.3556
Manual	29	0.6444

La Tabla B51 muestra los resultados de la necesidad de capacitar al alumno para usar el sistema usado para el proceso de enseñanza-aprendizaje en línea en la fase de las preferencias y experiencia de navegación.

Tabla B51. Requerimiento de capacitación del alumno para usar el sistema en la fase de las preferencias y experiencia de navegación.

Alumno	Capacitación	Alumno	Capacitación
1	NO	23	NO
2	SI	24	SI
3	NO	25	SI
4	NO	26	SI
5	NO	27	SI
6	NO	28	NO
7	SI	29	NO
8	SI	30	SI
9	NO	31	SI
10	SI	32	NO
11	NO	33	NO
12	NO	34	SI
13	NO	35	NO
14	SI	36	SI
15	NO	37	NO
16	SI	38	NO
17	SI	39	NO
18	NO	40	SI
19	NO	41	SI
20	SI	42	SI
21	NO	43	NO
22	SI	44	NO
		45	SI

Tabla B52. Distribuciones de frecuencia de la Tabla B51.

Capacitación	Cantidad Frecuencia Rela	
Si	21	0.4667
No	24	0.5333

## Referencias

ACM, (2004): "ACM Code of Ethics and Professional Conduct", ACM Computing and Public Policy: A Fair Society in Computing, §1.4. 2004.

Albert, D. y Hockemeyer, C., (2001). "State of the art in adaptive learning techniques". EASEL Consortium, D03 Requirements Specification, version 1.4 (pp. 24-40).

Albert, D., y Mori, T., (2001). "Contributions of Cognitive Psychology to the Future of e-Learning." Bulletin of the Graduate School of Education Hiroshima University, Part I (Learning and Curriculum Development), 50, 25–34.

Allport, G. W., (1937). "Personality: A psychological interpretation." New York: Holt & Co. 1937. Alonso et al., 1999; Alonso, C., Gallego, D y Honey, P., "Los estilos de aprendizaje: Procedimientos de diagnóstico y mejora". Bilbao: Ediciones Mensajero. 1999.

Askew M., (2000). "Cinco modelos de estilos de aprendizaje", disponible en

http://elhogar.tripod.com/2000/2000-10/cinco modelos de estilos de aprendizaje.htm. Ultima visita Enero de 2007.

ATutor, (2006): http://www.atutor.ca/. (Ultima visita. junio de 2006).

Barite Mario, (2000). "Diccionario de Organización y Representación del Conocimiento. Clasificación, Indización, Terminología." Escuela Universitaria de Bibliotecolog'ia y Ciencias Afines (eubeca). 2000 <a href="http://www.eubca.edu.uy/old/diccionario/letra r.htm">http://www.eubca.edu.uy/old/diccionario/letra r.htm</a>. Última visita, abril de 2007.

Bazaar, (2006): http://bazaar.athabascau.ca/. (Última visita, junio de 2006).

Bevan, N. and Macleod, M., (1994). "*Usability measurement in context*". Behaviour and Information Technology, vol. 13 nos. 1 & 2. 1994.

http://www.usability.serco.com/papers/music94.pdf (Última visita, Septiembre de 2005).

Blackboard, 2005: http://www.blackboard.com/us/index.aspx (Última visita, Septiembre de 2005).

Brusilovsky P.y Nijhvan H., (2002). "A Framework for Adaptive E-Learning Based on Distributed Re-usable Learning Activities".

http://www2.sis.pitt.edu/~peterb/papers/ELearn02.pdf . (Última visita, abril de 2005)

Brusilovsky Peter, (1994) "*The Construction and Application of Student Models in Intelligent Tutoring Systems*". Journal of Computer and System Sciences International, vol. 32, no. 1 p.p. 70–89, 1994. <a href="http://www2.sis.pitt.edu/~peterb/papers/studentmodels.pdf">http://www2.sis.pitt.edu/~peterb/papers/studentmodels.pdf</a>. (Ultima visita mayo 2005).

Butler A. y Lalla S., (2005). "Two Student's experiencies in a Distance Learning Doctoral Program". WebCT impact 7<sup>th</sup> Annual User Conference July 2005.

http://scooby.webct.com/webct\_userconf\_2005/Th/Butler.ppt#256 (Última visita, enero de 2005)

Cairns E. y Cammock, T., (1978). "The development of a more reliable version of the Matching Familiar Figures Test", en Developmental Psychology, 5, 555-560. 1978.

Cairns, E. y Cammock, T. (1989). "The 20-Item Matching Familiar Figures Test: Technicaldata." Manuscrito no publicado.

Cairns, E. y Cammock, T., (1984). "The development of reflection-impulsivity: further data", en Personality and Individual Differences, 5 (1), 113-115. 1984.

Castillo et al., (1997): Castillo, E., Gutiérrez, J. M., y Hadi, A. "*Expert Systems and Probabilistic Network Models*". New York: Springer-Verlag. 1997.

Cazau P., (2003). "Estilos de Aprendizaje: Generalidades".

http://galeon.hispavista.com/pcazau/guia esti01.htm. (Última visita, abril de 2005).

Chang K.-C. y R. Fung, (1990). "Symbolic probabilistic inference with continuous variables." In *Uncertainty in Artificial Intelligence (UAI)*, pages 77.85. Morgan Kaufmann, 1991.

Chávez R. M. y Cooper G. F., (1990). "A randomized approximation algorithm for probabilistic inference on Bayesian belief networks." Networks, 20:661.685, 1990.

CICEI (2007): Centro de Innovación para la Sociedad de la Información <a href="http://www.cicei.com">http://www.cicei.com</a> Última visita, 23 de marzo de 2007.

Claroline, (2006): http://www.claroline.net/. (Última visita, junio de 2006).

Clemente et al., (2002): Eduardo Clemente, Alcira Vargas, Alejandra Olivier, Ingrid Kirschning, Ofelia Cervantes "Entrenamiento y Evaluación de reconocedores de Voz de Propósito General basados en Redes Neuronales feedforward y Modelos Ocultos de Markov" TLATOA-CENTIA, Depto. Ingeniería en Sistemas Computacionales Universidad de las Américas-Puebla Sta. Catarina Mártir, Cholula, Puebla, 72820, México

Conati et al., (1997a): Conati, C., Gertner, A., VanLehn, K., y Druzdzel, M. "*On-line student modelling for coached problem solving using Bayesian Networks*". *Proceedings of the6th International Conference on User Modelling UM'97* (pp. 231-242). Vienna: Springer-Verlag.

Conati et al., (1997b): Conati, C., Larkin, J., & VanLehn, K. (1997). A computer framework to support selfexplanation. En *Knowledge and Media in Learning Systems. Proceedings of the 8th WorldConference on Artificial Intelligence in Education AIED'97* (pp. 279-286). IOS Press.

Conati, C., y VanLehn, K., (1996a). "**POLA:** A student modeling framework for probabilistic online assessment of problem solving performance". Proceedings of the 5th International Conference on User Modeling UM'96 (pp. 75-82). User Modeling Inc.

Conati, C., y VanLehn, K., (1996b). "Probabilistic Plan Recognition for Cognitive Apprenticeship". Proceedings of the 18th Annual Conference of the Cognitive Science Society. 1996.

Conlan et al. (2002): Owen Conlan, Declan Dagger, y Vincent Wade. "Towards a Standards-based Approach to e-Learning Personalization using Reusable Learning Objects". In Proceedgins of the World Conference on E-Learning in Corporate, Government, Healthcare and Higher Education (E-Learn 2002), P.p. 210–217, September 2002.

http://www.cs.tcd.ie/~oconlan/publications/eLearn2002\_v1.24\_Conlan.pdf. (Última visita, Julio de 2005).

Cooper, G. F., (1990), "The Computational Complexity of Probabilistic Inference Using Bayesian Belief Networks" Artificial Intelligence, Vol. 33, 1990.

Cooper, G. F., (1999), "An Overview of the Representation and Discovery of Causal Relationships Using Bayesian Neworks", in Glymour, C., y G. F. Cooper (Eds.) Computation Causation, and Discovery, AAAI Press, Menlo Park, California 1999.

Cronbach, L.J., y Snow, R.E., (1977). "Aptitudes and instructional methods: A handbook for research on aptitude-treatment interactions". New York: Irvington. 1997.

Darwiche A., (1995). "Conditioning methods for exact and approximate inference in causal networks". In Uncertainty in Artificial Intelligence (UAI). Morgan Kaufmann, 1995.

Davies S. y Moore. A., (1999). "Bayesian networks for lossless dataset compression". In Conference on Knowledge Discovery in Databases (KDD), 1999.

Daza Sandra Patricia, (2005). "Redes Neuronales Artificiales, Fundamentos, Modelos y Aplicaciones" Disponible en <a href="http://www.monografias.com/trabajos12/redneur/redneur.shtml">http://www.monografias.com/trabajos12/redneur/redneur.shtml</a> (Ultima visita marzo de 2007).

Dede Chris, (1997). "The Evolution of Learning Devices: Smart Objects, Information Infrastructures, and Shared Synthetic Environments. The Future of Networking Technologies for Learning". <a href="http://www.ed.gov/Technology/Futures/dede.html">http://www.ed.gov/Technology/Futures/dede.html</a> (Última visita, Noviembre de 2005).

Desire2Learn, 2005: http://www.desire2learn.com/. (Última visita, Septiembre de 2005).

Dimitris Margaritis, (2003). "Learning Bayesian Network Model Structure from Data" CMU-CS-03-153. School of Computer Science. Carnegie Mellon University. 2003.

Dokeos, (2006): http://www.dokeos.com/. (Última visita. Junio de 2006).

Druzdzel Marek y Simon. Herbert, (1993). "Causality in Bayesian Belief Networks". In Proceedings of the Ninth Annual Conference on Uncertainty in Artificial Intelligence (UAI-93), pages 3-11, Morgan Kaufmann Publishers, Inc., San Francisco, CA, 1993.

Duker P., (2002). "Sistemas del Conocimiento" Disponible en:

http://www.sistemasdeconocimiento.org/Portal/oferta\_academica/recursos\_materia/sc230/1\_2002/perfil.zip . (Última visita, Abril de 2005).

e-College, (2005): http://www.ecollege.com/indexflash.learn. (Última visita, Septiembre de 2005).

Edwards D., (1995). "Introduction to Graphical Modelling". Springer-Verlag, New York, 1995.

Eells, E., (1991). "Probabilistic Causality, Cambridge University Press", London, 1991.

EEP, (2004): European Education Patership "The critical importance of learning metrics in ICT-rich learning environments". Disponible en:

http://www.eep-edu.org/innservice/Critical%20Issues/Learning%20Metrics.htm V. Mayo de 2006.

Eklund J. y Brusilovsky P., (2000). "The Value of Adaptivity in Hypermedia Learning Environments: A Short Review of Empirical Evidence". Disponible en:

http://wwwis.win.tue.nl/ah98/Eklund.html .(Última visita, noviembre de 2005).

Eklund, J., Zeiliger, R., (1996). "Navigating the Web: Possibilities and Practicalities for Adaptive Navigational Support", proceedings of AUSWEB'96, Gold Coast, Australia. 1996.

Eledge, (2006): http://eledge.sourceforge.net/. (Última visita, Junio de 2006).

Far Behrouz Homayoun y Hashimoto A. H., (2000). "A Computational Model for Learner's Motivation States in Individualized Tutoring System". In Proceedings of the 8th International Conference on Computers in Education (ICCE 2000), P.p. 21–24, 2000.

Fernández E., (2004). "*E-learning: implementación de proyectos de formación on-line*". Alfaomega, 2004.

Ferran Ferrer Núria y Minguillón Julià, (2005). "Información cualitativa sobre el uso de los objetos de Aprendizaje". Universitat Oberta de Catalunya, Barcelona España. 2005.

Friedman, N., y M., Goldszmidt, (1996). "*Building Classifiers and Bayesian Networks*", Proceeding of the National Conference on Artificial Intelligence, AAAI Press, Menlo Park, California, 1996.

Fröschl Christoph, (2005). "User Modeling and User Profiling in Adaptive E-learning Systems" An approach for a service-based personalization solution for the research project AdeLE (Adaptive e-Learning with Eye-Tracking). Institute for Information Systems and Computer Media (IICM) Faculty of Computer Science Graz University of Technology A-8010 Graz, Austria. November 2005. Gallego R. A. y Martínez C. E., (2004). "Estilos de aprendizaje y e-learning. Hacia un mayor rendimiento académico". Depto. de Economía de la Empresa, Universidad Politécnica de Cartagena. 2004.

García et al., (2005): García P., Amandi A. Schiaffino S. Campo M. "*Using Bayesian Networks to Detect Student's Learning Styles in Web-based education system*" 7o. Simposio Argentino de Inteligencia Artificial –ISAI2005. Rosario, 29-30 de Agosto de 2005.

Gardner, Howard, (1983). "Frames of Mind: The Theory of Multiple Intelligences." New York: Basic,1983

Gartner Research Strategic Analysis Report, (2001), "Leading, Motivating and Supporting the Workforce of the New Knowledge Economy", 2001. Disponibe en:

https://acc.dau.mil/GetAttachment.aspx?id=22144&pname=file&aid=2117 (Última visita, Abril de 2005)

Genesha, (2006): <a href="http://www.anemalab.org/ganesha/">http://www.anemalab.org/ganesha/</a>. (Última visita, Junio de 2006).

Gertner, A. S., (1998): "Providing feedback to equation entries in an intelligent tutoring system for Physics". En Lecture Notes in Computer Science: Vol. 1452. Intelligent Tutoring Systems. Proceedings of 4th International Conference ITS'98 (pp. 434-443). Berlin: Springer-Verlag.

González Carina Soledad, (2004) "Sistemas Inteligentes en la Educación: Una revisión de las líneas de investigación actuales". Disponible en: Revista ELectrónica de Investigación y EValuación Educativa, v. 10, n. 1, y en

http://www.uv.es/RELIEVE/v10n1/RELIEVEv10n1 1.htm. Última visita, enero de 2007).

Grasha, A.F., (1994) "A matter of style: The teacher as expert, formal authority, personal model, facilitator, and delegator." College Teaching. 42, 142-149. 1994. Disponible en: <a href="http://teaching.uchicago.edu/pod/grasha.html">http://teaching.uchicago.edu/pod/grasha.html</a> (Última visita Enero de 2007).

Gross J., Yellen J., (2003). "*Handbook of Graph Theory*" CR C Press, 2003. Series: Discrete Mathematics and Its Applications Volume: 25.

Han Binglan, (2001). "Student Modelling and Adaptivity in web based Learning Systems". Master's thesis, Massey University/New Zealand, 2001.

Hava Muntean Cristina y McManis Jennifer, (2006). "End-User Quality of Experience Oriented

**Adaptive E-learning System**". Performance Engineering Laboratory, Dublin City University, Glasnevin, Dublin 9, Ireland. 2006. Disponible en: <a href="http://journals.tdl.org/jodi/article/viewArticle/jodi-173/159">http://journals.tdl.org/jodi/article/viewArticle/jodi-173/159</a>. Última visita, 24 de marzo de 2007.

Heckerman D. y Shachter R., (1995). "A definition and graphical representation of causality". In Proceedings of the Eleventh Conference on Uncertainty in Articial Intelligence. 1995.

Heckerman D., (1995). "A tutorial on learning Bayesian networks." Technical report MSR-TR-95-06. Microsoft research. Redmond. WA.

Heckerman David y Geiger Dan, (1995). "*Learning bayesian networks*." Technical Report MSR-TR-95-02, Microsoft Research, Redmond, WA, February 1995.

Heckerman et al., (1995a): Heckerman, D., Geiger, D., y Chickering, D. (1995a). "*Learning Bayesian networks: The combination of knowledge and statistical data*." Machine Learning, 20:197-243

Heckerman et al., (1995b): Heckerman, D., Mamdani, A., y Wellman, M. "Real world applications of Bayesian networks". Communications of the ACM, 38.

Heffner C. L. (2005). "Communication Styles". Disponible en:

http://www.siu.edu/offices/counsel/talk.htm. (Última visita, mayo de 2005).

Henrion, Henrion, M., (1989). "Some Practical Issues in Constructing Belief Networks". In: Kanl, L.N., Levitt, T.S., Lemmer, J.F. (eds), Uncertainty in Artificial Intelligence 3. Elsevier Science Publishers, 1989.

Henrion, M., (1988). "Propagation of uncertainty by probabilistic logic sampling in Bayes' networks." In J. F. Lemmer and L. N. Kanal, editors, Uncertainty in Artificial Intelligence 2. Elsevier Science Publishers B.V. (North-Holland), 1988.

Henze Nicola y Nejdl Wolfgang, (2003). "Logically Characterizing Adaptive Educational Hypermedia Systems." In Proceedings of International Workshop on Adaptive Hypermedia and Adaptive Web-Based Systems (AH'03), P.p. 15–29. AH2003, 2003. <a href="http://wwwis.win.tue.nl/ah2003/proceedings/paper2.pdf">http://wwwis.win.tue.nl/ah2003/proceedings/paper2.pdf</a>. (Última Visita Junio de 2006.

Henze, N., y Nedjl, W., (1999). "Student Modelling for the KBS Hyperbook System using Bayesian Networks". En Open Learning Environments: New Computational Technologies to Support Learning, Exploration and Collaboration. Proceedings of the 9<sup>th</sup> World Conference of Artificial Intelligence and Education AIED'99. IOS Press.

Hong et al., (2006): Hong Rolando, Ortiz Carlos Martínez, Sautié Castellanos Miguel, Valdés Crespo Kiria, Hernández Cáceres José Luis. "Computación Biomolecular: algunos apuntes" Revista Cubana de Informática Médica # 6. Centro de Cibernética Aplicada a la Medicina (CECAM). Disponible en: <a href="https://www.cecam.sld.cu">www.cecam.sld.cu</a>. Última visita, Marzo de 2007.

Hossein Arsham, (2006). "Herramientas para el Análisis de Decisión: Análisis de Decisiones Riesgosas". Disponible en

http://home.ubalt.edu/ntsbarsh/opre640S/SpanishP.htm. Última visita, 21 de marzo de 2007

Huang C. y A. Darwiche, (1994). "Inference in belief networks: A procedural guide". International Journal of Approximate Reasoning, 11:1.158, 1994.

Hume, D., (1988). "*An Inquiry Concerning Human Understanding*", Prometheus, Amhurst, New York, 1988 (originalmente publicado en 1748).

ISO/IEC 9126, (2005): <a href="http://www.usability.serco.com/trump/resources/standards.htm#9126-1">http://www.usability.serco.com/trump/resources/standards.htm#9126-1</a>. (Última visita, Septiembre de 2005).

Jensen et al., (1990): Jensen F.V., Lauritzen S.L., y Olesen K.G., "*Bayesian Updating in Causal Probabilistic Networks by Local Computation*" Computational Statical Quarterly, Vol 4 1990.

Jeremié Zoran y Devedžié Vladan, (2004). "**Design Pattern ITS: Student Model Implementation**". In Proceedings of the IEEE International Conference on Advanced Learning Technologies (ICALT'04), P.p. 864–865, 2004. Disponible en:

http://csdl2.computer.org/comp/proceedings/icalt/2004/2181/00/21810864.pdf (Última visita, Octubre de 2005).

Kagan, J., (1981). "*Matching familiar figures test*." Cambridge, MA: Harvard University. 1981 Kagan, N. (1971). "*Educational implications of cognitive styles.*" In G. S. Lesser (Ed.), Psychology and educational practice (pp. 242-292). Glenview, IL: Scott, Foresman, & Company. 1971.

Kagan, N., y Wallach, M. A., (1964) "Risk-taking: A study in cognition and personality." New York: Holt, Rinehart, & Winston. 1964.

Kay Judy, (2000). "Stereotypes, Student Models and Scrutability". In Proceedings of the 5th International Conference on Intelligent Tutoring Systems (ITS 2000), P.p. 19–30, 2000.

Keefe, J. W. (1988). "Profiling and utilizing learning style." Reston, VA: National Association of Secondary School Principals.

Kinshuk, (1996). "Computer Aided Learning for Entry Level AccountancyStudents". PhD thesis. De Montfort University, 1996. Disponible en:

http://infosys.massey.ac.nz/~kinshuk/thesis/mainpageps.html. (Última visita, octubre de 2005).

Knowledge Manager, (2006). "Técnicas de aprendizaje" Hypersoft-net SRL. Disponible en: http://www.mapasconceptuales.info/KM-LearningTech-esp.htm .(Última visita Junio de 2006).

Kobsa Alfred, (1993). "User Modeling: Recent Work, Prospects and Hazards. In Adaptive User

Interfaces: Principles and Practise". M. Schneider-Hufschmidt, T. K"uhme and U. Malinowski, eds., 1993. Disponible en: http://www.ics.uci.edu/~kobsa/papers/1993-aui-kobsa.pdf. (Última visita, Agosto de 2005).

Koch Nora, (2000). "Software Engineering for Adaptive Hypermedia Systems". PhD thesis, Ludwig-Maximilians-University Munich/Germany, 2000. Disponible en:

http://www.pst.informatik.unimuenchen.de/personen/kochn/PhDThesisNoraKoch.pdf . (Última visita, Mayo de 2006).

Kolb, D. A. (1984). "Experiential learning: Experience as the source of learning and development." New Jersey: Prentice-Hall. 1984.

Kurhila et al. (2001): Jaakko Kurhila, Miikka Miettinen, Markku Niemivirta, Petri Nokelainen, Tomi Silander, y Henry Tirri. "Bayesian Modeling in an Adaptive On-Line Questionnaire for Education and Educational Research". In Proceedings of the 10th International PEG Conference, P.p. 194–201, 2001. Disponible en: <a href="http://cosco.hiit.fi/Articles/peg2001eduform.pdf">http://cosco.hiit.fi/Articles/peg2001eduform.pdf</a>. (Última visita, Octubre de 2005).

Lane Carla, (2000). "Implementing Multiple Intelligences and Learning Styles in Distributed Learning/IMS Projects". Technical report, The Education Coalition (TEC), 2000. Disponible en: http://www.tecweb.org/styles/imslsindl.pdf . (Última visita, Junio de 2005).

Lauritzen S. L. y Spiegelhalter D. J., (1988). "Local Computation with Probabilities in Graphical Structures and Their Applications to Expert Systems", Journal of the Royal Statistical Society B, Vol. 50, No. 2, 1988.

Li Xiangyang y Ji Qiang, (2005). "Active Affective State Detection and Assistance with Dynamic Bayesian Networks". IEEE Transactions on Systems, Man, and Cybernetics: Special Issue on Ambient Intelligence, vol. 35, no. 1 p.p. 93-105, 2005.

Liu Y. y Ginter D., (1999). "Cognitive Styles and Distance Education" Online Journal of Distance Learning Administration, Volume II, Number III, Fall1999 State University of West Georgia, Distance Education 1999.

Llias, (2006): http://www.ilias.uni-koeln.de/ios/index-e.html (Última visita, Junio de 2006).

Loredo Tom, (2000). "BIPS: Bayesian Inference for the Physical Sciences". Disponible en: http://astrosun.tn.cornell.edu/staff/loredo/bayes/. (Última visita Abril de 2007).

LRN, (2006): Learn, Research, Network. http://dotlrn.org/. (Última visita Junio de 2006).

Lugg et al., (1995): Lugg J. A., J. Raifer, y C.N.F. González, "Dihydrotestosterone is the Active Androgen in the maintenance of Nitric Oxide-Mediated penile Erection in the Rat', Endrocrinology, Vol. 136, No. 4. 1995.

Markus et al., (2005): Markus K., Markus E., Reinhard O., Volker W., "Shared initiative: Crossfertilisation between system adaptivity and adaptability" Fraunhofer Institute for Applied Information Technology FIT. Fraunhofer FIT, Schloss Birlinghoven, 53754 Sankt Augustin. 2005. Marrero et al., (2005): Marrero Sonia, Ocón Antonio, Galán Manuel, Rubio Enrique

"Methodology for the generation and maintenance of a "base of procedures" in processoriented knowledge management strategy". CICEI (Center for Innovation in the Information Society) – U. Las Palmas Gran Canaria – Spain. Disponible en:

www.mc.manchester.ac.uk/eunis2005/medialibrary/papers/paper 131.pdf. (Última visita, Abril de

2007).

Marrero et al., 2006: Marrero Sonia,. Nelson José C, Rubio Enrique, Carmona Edgar, "Los mapas Conceptuales para Compartir la Base de Procedimientos y las Ontologias en el Proyecto Suricata" Concept Maps: Theory, Methodology, Technology Proc. of the Second Int. Conference on Concept Mapping A. J. Cañas, J. D. Novak, Eds. San José, Costa Rica, 2006. Disponible en: http://cmc.ihmc.us/cmc2006Papers/cmc2006-p20.pdf (Última visita, Abril de 2007).

Martin, J., y VanLehn, K. (1995b). "Student assessment using Bayesian nets". International Journal of Human-Computer Studies. 42, 575-591, 1995

Martin, J., y VanLehn, K., (1995a). "A Bayesian approach to cognitive assessment". En P. Nichols, S. Chipman, & R. L. Brennan (eds), Cognitively Diagnostic Assessment (pp. 141-165). Hillsdale, NJ: Erlbaum. 1995.

Martinez Margaret, (2005). "The Next Generation of E-Learning is Adaptive Learning". Disponible en: <a href="http://www.trainingplace.com/source/research/adaptivelearning.htm">http://www.trainingplace.com/source/research/adaptivelearning.htm</a>. (Última visita, Abril de 2005).

Mayo et al., (2000): Mayo M., Mitrovic A. y McKenzie J. "*CAPIT: An Intelligent Tutoring System for Capitalisation and Punctuation*." In Kinshuk, Jesshope C. and Okamoto T. (Eds.) Advanced Learning Technology: Design and Development Issues, Los Alamitos, CA: IEEE Computer Society (ISBN 0-7695-0653-4), pp. 151-154. See also Appendix F, this volume. 2000.

Mayo M. J., (2001). "Bayesian Student Modelling and Decision-Theoretic Selection of Tutorial Actions in Intelligent Tutoring Systems". Tesis Doctoral, Universidad de Canterbury

Mitrovic A. and Ohlsson S. (1999). "Evaluation of a Constraint-Based. Tutor for a Database Language". Int. J. on Artificial Intelligence in Education, 10(3-4), 238-256.

Messick, S. (1976). "Individuality in learning." Ed. San Francisco: Jossey-Bass. 1976).

Micheli J., (2001). (http://www.narxiso.com/conocimiento.html. (Última visita, Abril de 2005)

Millán E., (2000). "Sistema Bayesiano para Modelado del Alumno". Tesis Doctoral, Universidad de Málaga. 2000.

Mislevy, R., y Gitomer, D. H., (1996). "The Role of Probability-Based Inference in an Intelligent Tutoring System". User Modeling and User-Adapted Interaction, 5, 253-282. 1996.

Monti S. y Cooper G., (1998). "Learning hybrid Bayesian networks from data". In M. Jordan, editor, Learning and Inference in Graphical Models. Kluwer Academic Publishers, 1998.

Moodle, (2006): <a href="http://moodle.org/">http://moodle.org/</a>. (Última visita, Junio de 2006).

Neapolitan R.E. ., (2004). "Learning Bayesian Networks" Prentice Hall, 2004.

Neapolitan, R.E., (1990). "Probabilistic Reasoning in Expert Systems", Wiley, New York, 1990.

Negnevitsky, M., (2004). "Artificial Intelligence: A Guide to Intelligent Systems", Pearson.

Nichani: Nichani M., (2001). "LCMS = LMS + CMS". Disponible en:

http://www.aegean.gr/culturaltec/c karagiannidis/2003-2004/SpecialTopics/nichanigr.pdf y en http://www.elearningpost.com/ features/archives/002084.asp "'Ultima visita, Abril de 2005).

OpenUSS, (2006): <a href="http://openuss.sourceforge.net/openuss/index.html">http://openuss.sourceforge.net/openuss/index.html</a>. (Última visita, Junio de 2006).

Paramythis y Loidl-Reisinger,: Paramythis A. y Loidl-Reisinger S., (2003) "Adaptive Learning Environments and e-Learning Standards". 2nd European Conference on e-Learning (ECEL 2003).

Pearl J. y Verma T.S., (1991). "A Theory Of Inferred Causation" KR'91: Principles of Knowledge Representation and Reasoning. Disponible en:

http://clopinet.com/isabelle/Projects/ETH/SummaryPearlChapter2.pdf (Última visita, Junio de 2006).

Pearl J., (1987). "Evidential reasoning using stochastic simulation of causal models." Artificial Intelligence, 32: 245.257, 1987.

Pearl, J., (1988). "Probabilistic Reasoning in Expert Systems: Networks of Plausible Inference". San Francisco: Morgan Kaufmann Publishers, Inc.1988

Pearl, J., (1988). "*Probabilistic reasoning in Intelligent Systems*", Morgan Kaufmann, San Mateo, California, 1988.

Pearl, J., (1993). "Causality: models, reasoning, and inference." Cambridge University Press.

Pinto and Reiter, 1993.

Pearl, J., (1997). "Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference". Morgan Kaufmann, 2nd Ed., 1997.

Pearl, J., (2000). "Causality". Cambridge. 2000.

Piaget J., (1966). "The Child's Conception of Physical Causality", Routledge y Kegan Paul, London, 1966.

Plataformas, (2006): "Catálogo LMS de software libre" Disponible en:

http://www.ossite.org/join/sp/lms/catalog.htm. (Última visita, Junio de 2006).

Pongpech Alex, (2003). Seminario "Adaptive e-Learning Considerations". Disponible en: <a href="http://www.itee.uq.edu.au/~seminar/archive/2003/sem-0047.html">http://www.itee.uq.edu.au/~seminar/archive/2003/sem-0047.html</a>. (Última visita, Agosto de 2005). RAE, (2007): Real Academia Española. <a href="http://buscon.rae.es/drael/">http://buscon.rae.es/drael/</a>. Consultado el 11 de abril de

Rawlings et al., (2002): Rawlings, A., van Rosmalen, P., Koper, R., Rodríguez Artacho, M. and Lefrere, P. *CEN/ISSS WS/LT Learning Technologies Workshop: Survey of Educational Modelling Languages (EMLs)*. Disponible en: <a href="http://sensei.lsi.uned.es/palo/eml-version1.pdf">http://sensei.lsi.uned.es/palo/eml-version1.pdf</a> Última visita, Abril de 2007.

Rich Elaine, (1979). "*User Modeling via Stereotypes*". Cognitive Science, vol. 3, p.p. 329–354, 1979. Disponible en: <a href="http://www.cs.utexas.edu/users/ear/CogSci.pdf">http://www.cs.utexas.edu/users/ear/CogSci.pdf</a>. (Última visita, octubre de 2005).

Richardson, T. y P. Spirtes, (1999). "Automated Discovery of Linear Feedback Models". In Glymour, C., y G. F. Cooper (Eds.) Computation Causation, and Discovery, AAAI Press, Menlo Park, California 1999.

Robertson et al., (2003): Robertson M., Fluck A., y Webb I., "Children, on-line learning and authentic teaching skills in primary education". A LINKAGE project by the University of Tasmania, Tasmanian Department of Education, Catholic Education Office and Telstra. 2003. Disponible en: <a href="http://www.educ.utas.edu.au/users/ilwebb/Research/learning\_objects.htm">http://www.educ.utas.edu.au/users/ilwebb/Research/learning\_objects.htm</a> (Última visita, Junio de 2006)

Rosenberg, M. J. (2001). "*E-learning: estrategias para transmitir conocimiento en la era digital*", Bogotá, McGraw-Hill Interamericana. 2001.

Royalty et al., (2002): Royalty, J., R. Holland, A. Dekhyar and J. Goldsmith. "*POET, The Online Preference Elicitation Tool*". Submitted for publication, 2002.

Rubio E. y Delgado G., (2004). "*Diseño de Tareas de Aprendizaje* según los Estilos de Aprendizaje" 1er. Congreso internacional de estilos de aprendizaje. Universidad Nacional de educación a distancia (UNED). Madrid, España, Julio de 2004. Disponible en:

http://www.uned.es/congreso-estilos-aprendizaje. (Última visita, Octubre de 2005).

Rubio, et al., (2004): Rubio, Ocón A., Galán M., Marrero S., Nelson J.C. "A personal and corporative process-oriented knowdelege manager: suricata model". EUNIS 2004. Disponible en: <a href="http://eunis.fri.uni-lj.si/EUNIS2004/program.pdf">http://eunis.fri.uni-lj.si/EUNIS2004/program.pdf</a>. (Última visita, Octubre de 2005).

Russell Stuart y Norvig Peter, (2003). "Artificial Intelligence: A Modern Approach". 2nd Edition, Prentice Hall, 2003.

Sakai, (2006): http://collab.sakaiproject.org/portal. (Última visita, Junio de 2006).

Salmon W.C., (1994) "Causality without Counterfactuals", Philosophy of Science, Vol 61, 1994.

Sánchez Gustavo, (2005). "Glosario de artes gráficas, diseño y afines". Disponible en:

www.gusgsm.com/pep04.php. (Última visita, Abril de 2007).

Schachter et al., (1990): Schachter R. D., D'Ambrosio B., y Del Favero B. A. "**Symbolic probabilistic inference in belief networks**". In *Proceedings of the Eighth Conference in Artificial Intelligence*, pages 126.131. MIT Press, 1990.

Schachter R. D., (1990). "Evidence absorption and propagation through evidence reversals." In *Uncertainty in Artificial Intelligence (UAI)*, pages 173.190, San Francisco, 1990. Elsevier Science Publishers B.V. (North-Holland).

Segue, (2006): <a href="https://segue.middlebury.edu/">https://segue.middlebury.edu/</a>. (Última visita, Junio de 2006).

Self John, (1993). "*Model-based Cognitive Diagnosis. User Modeling and User-Adapted Interaction*". Vol. 3, no. 2 p.p. 89–106, 1993. <a href="ftp://ftp.comp.lancs.ac.uk/pub/aai/aai-report-82.ps.Z">ftp://ftp.comp.lancs.ac.uk/pub/aai/aai-report-82.ps.Z</a> (Última visita Junio, 2005).

Self John, (1994). "Student Modelling: the key to individualize knowledge based Instruction", chapter Formal Approaches to Student Modelling, P.p. 295–352. Springer-Verlag Berlin, 1994. <a href="mailto:thermology:thecomp.lancs.ac.uk/pub/aai/aai-report-92.ps.z">the key to individualize knowledge based Instruction", chapter Formal Approaches to Student Modelling, P.p. 295–352. Springer-Verlag Berlin, 1994. <a href="mailto:thecomp.lancs.ac.uk/pub/aai/aai-report-92.ps.z">the key to individualize knowledge based Instruction"</a>, chapter Formal Approaches to Student Modelling, P.p. 295–352. Springer-Verlag Berlin, 1994. <a href="mailto:thecomp.lancs.ac.uk/pub/aai/aai-report-92.ps.z">the key to individualize knowledge based Instruction"</a>, chapter Formal Approaches to Student Modelling, P.p. 295–352. Springer-Verlag Berlin, 1994. <a href="mailto:thecomp.lancs.ac.uk/pub/aai/aai-report-92.ps.z">the key to individualize knowledge based Instruction</a>,

Shute V., (2003). "Adaptive E-Learning". Disponible en:

http://www.elearning-reviews.org/topics/pedagogy/learning-design/ (Última visita, Febrero de 2005). Siemens G., (2002). "A Learning Development Model For Today's Students and Organizations". Disponible en: <a href="http://www.elearnspace.org/Articles/NewModel.htm">http://www.elearnspace.org/Articles/NewModel.htm</a>. (Última visita, Abril de 2005)

Siemens George, (2004). "*Categories of eLearning*" elearningspace everything elearning. 2004. http://www.elearnspace.org/Articles/elearningcategories.htm (Última visita, 24 de marzo de 2007).

Sison y Shimura, 1998: Raymund Sison and Masamichi Shimura. "*Student Modeling and Machine Learning*". International Journal of Artificial Intelligence in Education, vol. 9, p.p. 128–158, 1998

Smith S., (2004). "*Adaptive E-Learning: New Directions and Possibilities*". Disponible en: <a href="http://www.xplanazine.com/archives/2004/03/adaptive\_elearn.php">http://www.xplanazine.com/archives/2004/03/adaptive\_elearn.php</a>. (Última visita Septiembre de 2005).

Smith, C. D., (1988). "*The educational value of computer-mediated communications*." Media in Education and Development, 21 (4), 169-171. 1988.

Spaghetti Learning, (2006): <a href="http://www.docebolms.org/doceboCms/index.php">http://www.docebolms.org/doceboCms/index.php</a> . (Última visita, Junio de 2006).

Spirtes et al., (1995): Spirtes P., C. Glymour, y R. Sheines, (1995) "Causation, prediction, and Serch", Springer-Verlag, New York, 1993, 2<sup>nd</sup> ed,: MIT Press, Cambridge, Massachusetts, 2000.

Spites et al., (1993): P. Spirtes, G. Glymour, and R. Scheines. "Causation, Prediction, and Search." Springer-Verlag, New York, 1993.

Squires, G., (1981). "Cognitive styles and adult learning." Nottingham: University of Nottingham. 1981.

Stein et al., (2001): Stein Jennifer, Steeves Linda, Smith-Mitsuhashi, "T*eaching Styles Categories*". Disponible en: <a href="http://members.shaw.ca/mdde615/tchstycats.htm#formal">http://members.shaw.ca/mdde615/tchstycats.htm#formal</a>. (Última visita, Marzo de 2005).

Stuckey David y González Alejandro, (2007). "*Learning Today*" USA TODAY. February 9, 2007. www.usatoday.com. (Última visita, Abril de 2007)

Suermondt H.J., y Cooper, G.F., (1990). "Probabilistic Inference in Multiply Connect Belief Networks Using Loop Cutsets", International Journal of Approximate Inference, Vol. 4, 1990.

Tapia et al., (2004): Tapia, F. Galán M., Ocón A., Rubio E., "*Using Bayesian Networks In The Global Adaptive e-Learning Process*". EUNIS, 2005. Disponible en:

http://www.mc.manchester.ac.uk/eunis2005/medialibrary/papers/paper 130.pdf . (Última visita, Octubre de 2005).

Tennant, M. (1988). "Psychology and adult learning". London: Routledge. 1988.

There.com, (2005): <a href="http://www.there.com">http://www.there.com</a> (Última visita, Abril de 2005).

Tsiriga Victoria y Virvou Maria, (2003). "Initializing Student Models in Web-Based ITSs: A Generic Approach". In Proceedings of the 3rd IEEE International Conference on Advanced Learning Technologies (ICALT 2003), P.p. 42–46, 2003. Disponible en:

http://thalis.cs.unipi.gr/~vtsir/Tsiriga%40Virvou\_ICALT2003.pdf. (Última visita, Octubre de 2005). ULPGC, 2007; Universidad de Las Palmas de Gran Canaria. http://www.ulpgc.es . (Última visita, abril de 2007).

VanLehn et al., (1998): VanLehn, K., Niu, Z., Siler, S., y Gertner, A. S. "Student modeling from conventional test data: A Bayesian approach without priors". En Lecture Notes in Computer Science: Vol. 1452. Intelligent Tutoring Systems. Proceedings of 4th International Conference ITS'98 (pp. 434-443). Berlin: Springer-Verlag.

VanLehn K., (1996). "Conceptual and Meta Learning during Coached Problem Solving". En Lecture Notes in Computer Science: Vol. 1086. Proceedings of 3rd International Conference ITS'96 (pp. 29-47). Berlin: Springer-Verlag.

Verma T. S. y Pearl J., (1990a). "Equivalence and synthesis of causal models. In *Uncertainty in Artificial Intelligence (UAI)*", pages 220.227, San Francisco, 1990. Elsevier Science Publishers

B.V. (North-Holland).

Verma T. S. y Pearl J., (1990b). "*Causal Networks: Semantics and Expressiveness*", in R.D., T.S. Levitt, L.N. Kanal, and J.F. Lemmer (Eds.): Uncertainty in Artificial Intelligence; Proceeding of the Fourth Conference, North-Holland, Amsterdam, 1990.

Walpole M. (1992). "Probabilidad y Estadística." McGraw-Hill. 1992.

Webb et al., (2001): Webb Geoffrey I. Pazzani Michael J., y Billsus Daniel. "*Machine Learning for User Modeling*". User Models User-Adapted Interaction, vol. 11, no. 1-2 p.p. 19–29, 2001.

Webb Geoffrey I. y Kuzmycz Mark, (1998). "Evaluation of Data Aging: A Technique for Discounting Old Data During Student Modeling". In Proceedings of the 4th International Conference on Intelligent Tutoring Systems (ITS'98), P.p. 384–393, 1998.

WebCT, (2005): http://www.webct.com/ (Última visita, Septiembre de 2005).

WebTycho, (2005): <a href="http://faculty.ed.umuc.edu/~prichard/dist\_ed/WebTycho.html">http://faculty.ed.umuc.edu/~prichard/dist\_ed/WebTycho.html</a> (Última visita, Septiembre de 2005) y <a href="http://tychousa2.umuc.edu/sys/login.html?/WebTycho.nsf&0">http://tychousa2.umuc.edu/sys/login.html?/WebTycho.nsf&0</a> (Última visita, Septiembre de 2005).

Wilson J.R, (2003). "Adaptive Training," Military Training Technology": Online Edition. Vol 8: Issue 1, Jan 1, 2003. Disponible en:

http://www.military-training-technology.com/article.cfm?DocID=227. (Última visita, Marzo de 2005). Wilson, J. D., (1981). "Student learning in higher education." London: Croom Helm. 1981.

Wilson, J., (2001). "Lessons of a Virtual Timetable: Education. The Economist", (17 February, 2001), p. 1 (CDROM).

Witkin et al., (1977): Witkin, H. A., Moore, C. A., Goodenough, D. R., & Cox, P. W. "Field dependent and field independent cognitive styles and their educational implications". Review of Educational Research, 47, 1-64. 1977.

Zhou X. y Conati C., (2003). "Inferring User Goals from Personality and Behavior in a Causal Model of User Affect", IUI'03, Miami, FL, 211-218. 2003.

Zhou Yujian y Evens Martha W., (1999). "A Practical Student Model in an Intelligent Tutoring System". In Proceedings of the 11th IEEE International Conference on Tools with Artificial Intelligence (ICTAl'99), P.p. 13–18, 1999.