

# Metodología para el análisis de relevancia de indicadores de rendimiento en educación superior

Morales, M. y Rodríguez, C. y Salmerón, A.

## Resumen

En este artículo proponemos una metodología para el análisis de relevancia de indicadores de rendimiento basada en el uso de redes bayesianas. Estos modelos gráficos permiten obtener, a primera vista, las principales relaciones entre las variables a considerar. Analizamos el comportamiento de la metodología propuesta con un caso práctico, mostrando que es una herramienta útil para ayudar la toma de decisiones en la elaboración de políticas basadas en indicadores de rendimiento.

**Keywords:** Indicadores de rendimiento, Redes bayesianas, Gestión en educación superior.

**AMS:** 62P20,62H99

## 1. Introducción

En las últimas décadas, los mecanismos de financiación de las Universidades públicas por parte de la administración han sido orientados a sistemas donde parte de los fondos están condicionados a la consecución de una serie de metas por parte de la institución. Es aquí donde hacen su aparición los llamados *indicadores de rendimiento* [3] como mecanismos de mejora de la calidad, toma de decisiones y de asignación de recursos.

Algunos autores entienden el término *rendimiento* en un sentido amplio, asumiendo que un indicador de rendimiento es cualquier meta institucional que puede ser medida objetivamente [4].

Con objeto de diseñar políticas eficientes orientadas a incrementar la financiación pública, la dirección de las universidades deben determinar las variables que, estando bajo su control, influyen en el valor de los indicadores de rendimiento que determinan la asignación de los fondos.

Esta tarea requiere el manejo de un alto número de variables de distinta naturaleza (cualitativas y cuantitativas), que pueden tener una compleja estructura de dependencias. En los últimos años, se ha despertado un creciente interés, tanto en el campo de la Estadística como en Inteligencia Artificial, en el manejo de escenarios en los que intervienen un gran número de variables. Una de las soluciones más satisfactorias se

basa en el uso de *modelos gráficos probabilísticos* y, más exactamente, *redes bayesianas* [1, 6].

La principal ventaja de las redes bayesianas es su rica semántica, así como que ofrecen una herramienta clara y de fácil manejo para usuarios no versados en técnicas estadísticas: como modelo gráfico facilita la comprensión del problema, presentando, además, la estructura de dependencia entre las variables. En este marco, las técnicas de propagación ofrecen la posibilidad de estudiar los efectos que tendrían las posibles líneas de actuación sobre las variables de interés.

En este artículo proponemos una metodología, basada en redes bayesianas, para el análisis de relevancia en indicadores de rendimiento en educación superior. Ilustramos la idoneidad de la metodología propuesta para el caso particular del a Universidad de Almería.

El artículo está organizado en las siguientes secciones: en la sección 2 explicamos los fundamentos de la metodología para el análisis de relevancia basada en redes bayesianas. La sección 3 está dedicada a mostrar el comportamiento de la técnica propuesta en un problema real. Finalizamos el artículo con las conclusiones en la sección 4.

## 2. Redes bayesianas y análisis de relevancia

Una *red bayesiana* [1, 6] es un modelo estadístico multivariante definido, para un conjunto de variables,  $\mathbf{X} = \{X_1, \dots, X_n\}$ , mediante dos componentes:

- **Componente cualitativa:** grafo dirigido acíclico (DAG) donde cada vértice representa una de las variables del modelo, de forma que la presencia de un arco uniendo dos variables indica la existencia de dependencia estadística entre ellas.
- **Componente cuantitativa:** distribución condicionada  $p(x_i|pa(x_i))$  para cada variable  $X_i$ ,  $i = 1, \dots, n$  dado sus padres en el grafo, denotados por  $pa(X_i)$ .

Por ejemplo, el grafo representado en la Figura 1 puede ser la componente cualitativa de una red bayesiana para las variables  $X_1, \dots, X_5$ . De acuerdo a la estructura del grafo, sería necesario especificar una distribución condicionada para cada variable dado sus padres. En este caso, las distribuciones son  $p(x_1)$ ,  $p(x_2|x_1)$ ,  $p(x_3|x_1)$ ,  $p(x_4|x_2, x_3)$  y  $p(x_5|x_4)$ .

En los siguientes subapartados describiremos cómo la componente cualitativa codifica las dependencias entre las variables en el modelo, y cómo la fuerza de esta dependencia es determinada por la componente cuantitativa, es decir, la distribución condicionada.

### 2.1. Componente cualitativa de una red bayesiana

Una de las ventajas más importantes de las redes bayesianas es que la estructura del grafo asociado determina las relaciones de dependencia e independencia entre las variables, de forma que es posible descubrir, sin necesidad de cálculos numéricos, qué variables son relevantes para otra variable de interés (por ejemplo, un indicador de rendimiento). Con más exactitud, el análisis de relevancia se realiza en redes bayesianas

a través del concepto de *transmisión de información*, de forma que dos variables son irrelevantes entre sí cuando no puede transmitirse información entre ellas.

Para explicar la transmisión de información en redes bayesianas, recurriremos a un ejemplo tomado de [6].

**Ejemplo (Robo o terremoto)** Holmes está trabajando en su oficina cuando recibe una llamada de su vecino, el Dr. Watson, quien le avisa que la alarma anti-robo de su casa está sonando. Holmes coge su coche y se dirige rápidamente a su casa, convencido de que algún ladrón está en ella. Por el camino escucha en la radio la noticia de un pequeño terremoto en la zona. Sabiendo que los terremotos suelen provocar que salten las alarmas, Holmes da media vuelta y vuelve al trabajo.




Figura 1: Ejemplo de red bayesiana con cinco variables.




Figura 2: Red bayesiana del ejemplo *robo o terremoto*.

El escenario descrito en el ejemplo anterior puede representarse a través de la red bayesiana de la figura 2. En general, sólo existen tres tipos de conexiones entre variables en un DAG: conexiones en serie, convergente y divergente, por lo que basta con explicar cómo fluye la información para estos tres tipos de conexión. Utilizaremos el ejemplo anterior para ilustrarlo.

#### 1. Conexiones en serie.

- “Robo” tiene una dependencia causal sobre “Alarma”, la cual tiene una dependencia causal sobre “Llamada de Watson”. Por lo tanto, la información

se transmite de “Robo” a “Llamada de Watson” y viceversa, de forma que el conocimiento sobre una de las variables proporciona información sobre la otra.

- Sin embargo, si observamos “Alarma”, cualquier información sobre el estado de “Robo” es irrelevante sobre nuestra creencia sobre “Llamada de Watson” y viceversa, una vez que tenemos una certeza sobre el hecho de que la alarma está sonando, la información proporcionada por Watson no cambia nuestro estado de creencia.

## 2. Conexiones divergentes.

- “Terremoto” tiene una influencia causal sobre “Alarma” y “Radio”, por lo que la información se transmite desde “Alarma” a “Radio” y viceversa en el sentido de que el conocimiento sobre una de las variables proporciona información sobre la otra. Por ejemplo, si únicamente sabemos que la radio informa de un pequeño terremoto, nuestra creencia de que la alarma esté sonando crece.
- Por otro lado, si observamos “Terremoto”, i.e., tenemos alguna evidencia sobre esta variable, cualquier información sobre el estado de “Alarma” es irrelevante para nuestra creencia sobre la noticia dada en la radio y viceversa.

## 3. Conexiones convergentes.

- “Alarma” depende tanto de “Robo” como de “Terremoto”. Sin embargo, en este caso estas dos últimas variables son irrelevantes la una sobre la otra: si no tenemos ninguna información sobre la alarma, no hay ninguna relación entre las dos variables.
- Sin embargo, si observamos “Alarma” y “Robo”, esta información tendrá un efecto sobre nuestra creencia sobre “Terremoto”: el robo explica que la alarma esté en funcionamiento, reduciendo nuestra creencia de que haya sido un terremoto el que la haya puesto en marcha, y viceversa.

En general, las reglas para interpretar el flujo de información dada la estructura de una red bayesiana son las siguientes:

- **Conexiones en serie** ( $X \longrightarrow Y \longrightarrow Z$ ). La información puede transmitirse a través de una conexión en serie a no ser que se conozca el estado de la variable intermedia ( $Y$ ).
- **Conexiones divergentes** ( $X \longleftarrow Y \longrightarrow Z$ ). La información puede transmitirse a través de una conexión divergente a no ser que se conozca el estado de la variable intermedia ( $Y$ ).
- **Conexiones convergentes** ( $X \longrightarrow Y \longleftarrow Z$ ). La información puede transmitirse a través de una conexión convergente siempre que se disponga de información sobre el estado de la variable intermedia ( $Y$ ) o sobre una de sus descendientes.

Aplicando estas tres reglas, es posible determinar qué variables son relevantes para nuestra variable objetivo. Por ejemplo, podríamos determinar sobre qué variables debe operar la dirección de una universidad para cambiar el valor de un indicador de rendimiento.

## 2.2. Componente cuantitativa de una red bayesiana

Aunque puede realizarse un análisis de relevancia tan sólo sobre la estructura de la red, una vez que han sido localizadas las variables relevantes para un indicador de rendimiento dado, es necesario saber en qué medida los cambios sobre estas variables afectan al valor del indicador.

Teniendo en cuenta las independencias codificadas por la estructura de la red, la distribución conjunta sobre todas las variables es el producto de las distribuciones condicionadas asignadas a cada nodo:

$$p(x_1, \dots, x_n) = \prod_{i=1}^n p(x_i | pa(x_i)) . \quad (1)$$

Supongamos que  $X_i$  es el indicador de rendimiento en el que estamos interesados, y que  $X_E$  es un conjunto de variables que pueden ser controladas por el consejo de administración. Entonces, la predicción de los valores de  $X_i$  dados  $X_E$  puede obtenerse calculando la distribución  $p(x_i | x_E)$ , que nos proporcionaría la verosimilitud de cada posible valor de  $X_i$  dado cada posible configuración de  $X_E$ . Esta distribución puede ser obtenida de la distribución conjunta en la ecuación (1). De hecho, no es necesario calcular la distribución conjunta, puesto que se disponen de eficientes algoritmos que permiten calcular  $p(x_i | x_E)$  aprovechando las ventajas de la factorización de la distribución conjunta impuesta por la estructura de la red [7, 8].

## 2.3. Construyendo una red bayesiana a partir de una base de datos

Una vez que sabemos cómo usar una red bayesiana para un análisis de relevancia, debemos considerar cómo obtener dicha red. Actualmente, la administración de las universidades están completamente informatizada, de forma que se dispone de gran cantidad de datos estadísticos. En general es posible obtener bases de datos compuesta de registros que contengan el valor de los indicadores de rendimiento, así como de otras variables que pueden ser controladas. Por ejemplo, podemos tener un fichero con la información sobre una asignatura (número de estudiantes, número de profesores, etc.) junto con indicadores de rendimiento relativos a dicho curso (la tasa de éxito, por ejemplo).

Existen varios algoritmos que permiten la construcción de redes bayesianas a partir de bases de datos. En este trabajo utilizaremos dos de los más utilizados: los algoritmos K2 [2] y PC [9]. El algoritmo K2 busca en el espacio de todas las redes bayesianas que contienen las variables de la base de datos e intenta encontrar una red óptima en términos de la verosimilitud de la base de datos para cada red candidata. Por otro lado, el algoritmo PC intenta determinar la estructura de la red a través de test de independencia estadísticos. Ninguno de los dos métodos es absolutamente superior al

otro, por lo que, en la práctica, es común construir dos redes, una con cada algoritmo, y entonces usar la red cuya verosimilitud con la base de datos sea superior. Una característica común a ambos algoritmos es que operan con variables cualitativas, por lo que las variables continuas deben ser discretizadas de antemano.

Existen paquetes de software libre que permiten la construcción de redes bayesianas a partir de bases de datos proporcionando una interfaz para el análisis de relevancia. En este trabajo hemos usado el sistema Elvira [5] disponible en <http://leo.ugr.es/elvira>.

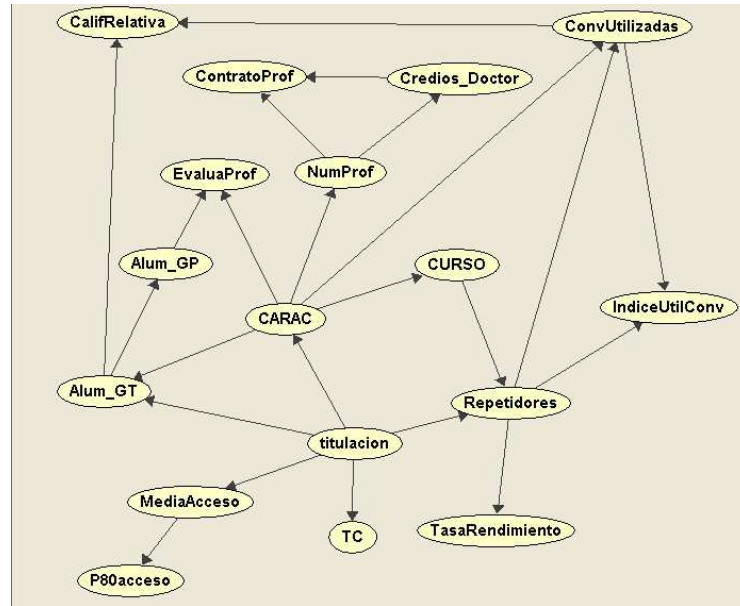


Figura 3: Red bayesiana obtenida para el caso estudiado.

### 3. Estudio de caso: Aplicación del estudio de indicadores de rendimiento en la Universidad de Almería

En esta sección describiremos una aplicación práctica de la metodología introducida en la sección 2, consistente en el análisis de uno de los indicadores de rendimiento usados para la asignación de financiación condicionada dentro del Contrato Programa entre la Junta de Andalucía y las Universidades Públicas andaluzas: el rendimiento académico del alumnado.

Partimos de una base de datos con 1.345 registros y 17 variables relativas a todas las asignaturas impartidas en la Universidad de Almería en las diferentes titulaciones durante el curso 2003-04. En el cuadro 3 se recoge una descripción de las variables consideradas. Las cinco primeras variables corresponden a indicadores de rendimiento.

Tasa de rendimiento	Prob. a priori	Carácter	
		Obligatoria	Optativa
[0, 0,545)	0.03	0.04	0.03
[0,545, 0,735)	0.10	0.15	0.04
[0,735, 0,855)	0.17	0.25	0.09
[0,855, 0,955)	0.20	0.26	0.13
[0,955, 1]	0.49	0.31	0.71

Cuadro 1: Probabilidades condicionadas de la tasa de rendimiento dado el tipo de asignatura.

Calificación relativa	Prob. a Priori	Carácter	
		Obligatoria	Optativa
[0, 0,195)	0.23	0.28	0.15
[0,195, 0,315)	0.27	0.29	0.24
[0,315, 0,465)	0.24	0.21	0.28
[0,465, 0,775)	0.18	0.14	0.23
[0,775, 1]	0.08	0.07	0.09

Cuadro 2: Probabilidades condicionadas de la calificación relativa dado el tipo de asignatura.

La base de datos ha sido previamente procesada, discretizando las variables continuas, a través del algoritmo de clustering de  $k$ -medias, estableciendo 5 categorías para cada variable discretizada. Hemos usado los algoritmos K2 y PC, obteniendo el mejor modelo, en términos de verosimilitud con los datos, con el K2. La red resultante puede verse en la Figura 3.

Atendiendo a la estructura de la red, puede verse que hay dos variables importantes, *Tipo de asignatura* y *Titulación*, que juegan un importante papel en la red, ya que la transmisión de la información hasta las variables de interés (relativas al rendimiento del alumno) pasa a través de ellas. Podemos evaluar la importancia de estas variables usando la parte cuantitativa de la red bayesiana. Por ejemplo, si nos centramos en la variable *Tipo de asignatura*, su influencia sobre dos importantes indicadores, *Tasa de rendimiento* y *Calificación relativa* es clara, si observamos las probabilidades condicionadas recogidas en los cuadros 1 y 2, respectivamente. Las diferencias en la distribución de los valores de ambos indicadores son significativas, dependiendo de si la asignatura es obligatoria u opcional. Este hecho sugiere un estudio separado para cada tipo de asignaturas.

### 3.1. Análisis de relevancia para asignaturas troncales y obligatorias

La red bayesiana obtenida usando los registros de la base de datos concerniente a asignaturas obligatorias se muestra en la Figura 4. En base a ella, podemos llegar las

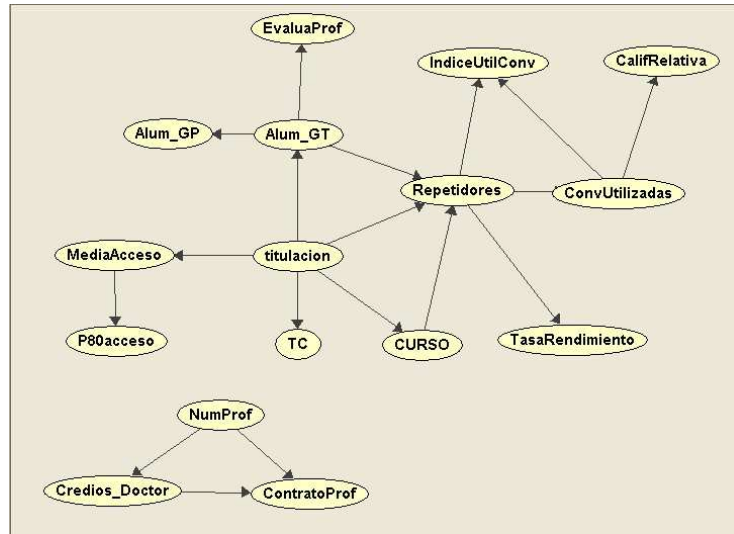


Figura 4: Red bayesiana para asignaturas obligatorias.

siguientes conclusiones:

- La estructura de la plantilla de profesores es irrelevante a el resto de la red, ya que las variables *número de profesores*, *contrato del profesor* y *porcentaje de doctores* están desconectadas del resto.
- La evaluación obtenida por un profesor en las encuestas de opinión está fuertemente determinada por el número de alumnos en las clases teóricas. Esto supone una importante conclusión, ya que es común encontrar resultados bajos en dichas evaluaciones en clase masificadas, lo que sugiere que más que el perfil del profesor, es el tamaño del grupo teórico el que determina la evaluación de éste.
- Cualquier flujo de información hasta los indicadores de rendimiento pasa por la variable *Titulación*. Es cierto que la dirección de la universidad no puede controlar la titulación donde un alumno se matricula, pero sí puede actuar sobre algunas características de los estudios, como la nota de acceso o el número de estudiantes por clase de teoría/práctica. Los efectos de estas variables sobre la tasa de rendimiento se muestra en los cuadros 4, 5 y 6.
- Atendiendo a los resultados del cuadro 4, podemos concluir que una buena política dirigida a incrementar la tasa de rendimiento del alumnado es establecer un número máximo de estudiantes no superior a 49.
- La influencia del número de estudiantes en las clases prácticas no es tan importante, como puede verse en el cuadro 5 (los valores de las columnas son muy similares).



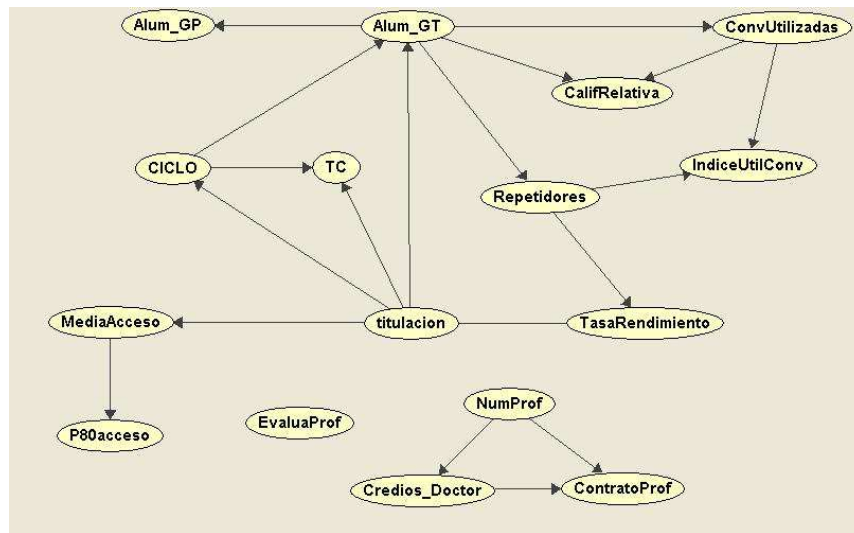


Figura 5: Red bayesiana para asignaturas optativas.

- Finalmente, la nota de acceso tienen un pequeño impacto sobre la tasa de rendimiento. Únicamente incrementando el percentil 80 de la nota de acceso por encima de 7.3 puntos, se obtiene una ligera mejora en el rendimiento académico.

### 3.2. Análisis de relevancia para asignaturas optativas

La red bayesiana obtenida usando los registros de la base de datos concernientes a asignaturas optativas se muestra en la Figura 5. Analizando la estructura de esta red, podemos deducir que el perfil del profesorado, incluyendo los resultados de su evaluación, es irrelevante para los indicadores de rendimiento de la asignatura.

Las notas de acceso están conectadas a la tasa de rendimiento a través de la titulación. Su impacto sobre este indicador se mide en el cuadro 7. Las probabilidades de la tabla indican que el mejor rendimiento se obtiene para notas medias de acceso superiores a 6.69 puntos y percentiles 80 sobre 7.22 puntos.

El número de estudiantes en clases de teoría es más relevante en este tipo de asignaturas que en el caso de troncales y obligatorias, al estar conectada directamente con la calificación relativa, el número de convocatorias utilizadas y el porcentaje de alumnos repetidores. También está indirectamente conectada con la tasa de rendimiento.

El cuadro 8 recoge las probabilidades del indicador *tasa de rendimiento* dado el número de estudiantes en clase de teoría. Puede observarse que la tasa de rendimiento está fuertemente influida por esta variable, de forma que el rendimiento más bajo aparece cuando el número de estudiantes incrementa. Por lo tanto, cualquier política

Variable	Descripción
Tasa de éxito	Ratio entre el número de estudiantes que superan una determinada asignatura y el n. de alumnos presentados al examen.
Calificación relativa	Media de las notas obtenidas por cada estudiante en la asignatura en relación con las notas del resto de estudiantes.
Repetidores	Porcentaje de alumnos repetidores en la asignatura.
Convoca. utilizadas	Número de veces que un alumno se presenta a examen antes de aprobarlo.
IndiceUtilConv	Número de veces que un alumno se presenta a examen dividido entre el número máximo de intentos permitidos.
Alum_GT	Número de alumnos por grupo teórico.
Alum_GP	Número de alumnos por grupo de práctica.
CARAC	Carácter de la asignatura: obligatoria u optativa
Curso	en el que se imparte la asignatura
NumProf	Núm. de profesores distintos que imparten asignatura al mismo grupo.
EvaluaProf	Puntuación obtenida por el prof. en las encuestas al alumnado.
ContratoProf	Porcentaje de créditos impartidos por profesores permanentes.
Creditos_Doctor	Porcentaje de créditos impartidos por profesores doctores.
Titulación	donde se imparte la asignatura.
TC	Porcentaje de alumnos matriculados a tiempo completo.
MediaAcceso	Media aritmética de las notas de acceso de los alumnos de la asignatura.
P80acceso	Percentil 80 de las notas de acceso de los alumnos de la asignatura.

Cuadro 3: Descripción de las variables del caso estudiado.

Tasa de Rendimiento	Prob. a Priori	número de alumnos por grupo de teoría				
		< 25,5	[25,5, 49,5)	[49,5, 79,25)	[79,25, 114,75)	≥ 114,75
[0, 0,355)	0.20	0.18	0.19	0.20	0.20	0.24
[0,355, 0,535)	0.28	0.26	0.27	0.28	0.28	0.29
[0,535, 0,695)	0.23	0.23	0.23	0.23	0.23	0.22
[0,695, 0,845)	0.18	0.20	0.19	0.18	0.18	0.15
[0,845, 1]	0.11	0.13	0.12	0.11	0.11	0.09

Cuadro 4: Tasa de rendimiento frente al número de alumnos en grupos teóricos de asignaturas obligatorias.

orientada a disminuir el número de estudiantes por clase conllevará un incremento significativo en el rendimiento de la asignatura.

Finalmente, puede concluirse de las probabilidades mostradas en el cuadro 9, que la influencia del número de alumnos en clases prácticas no están importante como en el caso de clases teóricas.

#### 4. Conclusiones

En este artículo hemos introducido una metodología para el análisis de relevancia de indicadores de rendimiento en educación superior. Hemos mostrado a través de un estudio aplicado cómo esta metodología puede ayudar en el proceso de toma de decisiones cuando se diseñan políticas orientadas a incrementar la cantidad de fondos

Tasa de Rendimiento	Prob. a Priori	núm. de alumnos por grupo práctico				
		< 23,9	[23,9, 41,65)	[41,65, 68,5)	[68,5, 114,16)	≥ 114,16
[0, 0,355)	0.20	0.19	0.20	0.21	0.20	0.24
[0,355, 0,535)	0.28	0.27	0.28	0.28	0.28	0.29
[0,535, 0,695)	0.23	0.23	0.23	0.23	0.23	0.24
[0,695, 0,845)	0.18	0.19	0.18	0.18	0.18	0.15
[0,845, 1]	0.11	0.12	0.11	0.11	0.11	0.10

Cuadro 5: Tasa de rendimiento frente al número estudiantes en grupos prácticos de asignaturas obligatorias.

Tasa de Rendimiento	Prob. a Priori	Nota de acceso media				
		[5,32, 5,92)	[5,92, 6,17)	[6,17, 6,46)	[6,46, 6,83)	[6,83, 7,71]
[0, 0,355)	0.20	0.19	0.21	0.21	0.19	0.19
[0,355, 0,535)	0.28	0.28	0.28	0.28	0.27	0.27
[0,535, 0,695)	0.23	0.24	0.23	0.23	0.23	0.23
[0,695, 0,845)	0.18	0.18	0.17	0.17	0.18	0.19
[0,845, 1]	0.11	0.11	0.11	0.11	0.12	0.13

Tasa de Rendimiento	Prob. a Priori	Percentil 80 de la nota de acceso				
		[5,46, 6,30)	[6,30, 6,65)	[6,65, 7,30)	[7,30, 7,61)	[7,61, 8,5]
[0, 0,355)	0.20	0.19	0.21	0.21	0.20	0.19
[0,355, 0,535)	0.28	0.28	0.28	0.28	0.27	0.27
[0,535, 0,695)	0.23	0.23	0.23	0.23	0.23	0.23
[0,695, 0,845)	0.18	0.18	0.18	0.18	0.18	0.19
[0,845, 1]	0.11	0.11	0.11	0.11	0.12	0.12

Cuadro 6: Tasa de rendimiento frente al perfil del alumnado en asignaturas obligatorias.

públicos cuando éstos son asignados de acuerdo al cumplimiento de objetivos formulados a través de indicadores de rendimiento.

La naturaleza gráfica del modelo usado permite extraer conclusiones sin necesidad de interpretar datos numéricos, debido a que el análisis de relevancia puede llevarse a cabo sobre la estructura de la red bayesiana. Si el usuario está también interesado en cuantificar la fuerza de las dependencias entre las variables, puede realizarse usando las distribuciones de probabilidad condicionadas proporcionadas también por la red bayesiana.

La disponibilidad de herramientas de software para redes bayesianas, como el sistema Elvira, ayudan a la aplicabilidad de la metodología propuesta.

Próximamente, planeamos aplicar tecnología bayesiana para construir un sistema que aconseje a los estudiantes las asignaturas a elegir con el fin de maximizar sus oportunidades de éxito.

Tasa de Rendimiento	Prob. a priori	Nota de acceso media				
		[5,32, 6,00]	[6,00, 6,20]	[6,20, 6,44]	[6,44, 6,69]	[6,69, 8,03]
[0, 0,59)	0.20	0.18	0.19	0.22	0.22	0.17
[0,59, 0,71)	0.19	0.17	0.20	0.29	0.19	0.18
[0,71, 0,82)	0.20	0.21	0.21	0.21	0.21	0.18
[0,82, 0,92)	0.20	0.23	0.21	0.19	0.19	0.19
[0,92, 1]	0.21	0.20	0.19	0.19	0.20	0.28

Tasa de Rendimiento	Prob. a Priori	Percentil 80 de la nota de acceso				
		[5,37, 6,28]	[6,28, 6,61]	[6,61, 6,92]	[6,92, 7,22]	[7,22, 8,57]
[0, 0,59)	0.20	0.19	0.19	0.21	0.21	0.18
[0,59, 0,71)	0.19	0.18	0.19	0.19	0.19	0.18
[0,71, 0,82)	0.20	0.21	0.21	0.21	0.20	0.18
[0,82, 0,92)	0.20	0.22	0.21	0.20	0.19	0.19
[0,92, 1]	0.21	0.20	0.20	0.20	0.21	0.26

Cuadro 7: Tasa de rendimiento dada las notas de acceso en asignaturas optativas.

Tasa de Rendimiento	Prob. a Priori	núm. de alumnos por grupo de teoría				
		< 10	[10, 18)	[18, 28)	[28, 51)	[51, 137]
[0, 0,59)	0.20	0.18	0.20	0.19	0.21	0.20
[0,59, 0,71)	0.19	0.15	0.19	0.19	0.20	0.19
[0,71, 0,82)	0.20	0.17	0.20	0.21	0.21	0.22
[0,82, 0,92)	0.20	0.19	0.19	0.19	0.21	0.23
[0,92, 1]	0.21	0.31	0.22	0.21	0.17	0.16

Cuadro 8: Resultados para asignaturas optativas dado el tamaño de los grupos teóricos.

## Referencias

- [1] Castillo, E., J. Gutiérrez, and A. Hadi (1997). *Expert systems and probabilistic network models*. New York: Springer-Verlag.
- [2] Cooper, G. and E. Herskovits (1992). A Bayesian method for the induction of probabilistic networks from data. *Machine Learning* 9, 309–347.
- [3] Cuenin, S. (1987). The use of performance indicators in universities: An international survey. *International Journal of Institutional Management in Higher Education* 2, 117–139.
- [4] Dochy, F., M. Segers, and W. Wijnen (1990). Selecting performance indicators. A proposal as a result of research. In F. Goedegebuure, F. Maasen, and D. Westerheijden (Eds.), *Peer review and performance indicators*, pp. 135–153. Lemma B.V.
- [5] Elvira Consortium (2002). *Elvira: An environment for creating and using probabilistic graphical models*. In J. Gámez and A. Salmerón (Eds.), *Proceedings of the First European Workshop on Probabilistic Graphical Models*, pp. 222–230.
- [6] Jensen, F. V. (2001). *Bayesian networks and decision graphs*. Springer.

Tasa de Rendimiento	Prob. a Priori	núm. de alumnos por grupo práctico				
		< 9	[9, 17)	[17, 25)	[25, 38)	≥ 38
[0, 0,59)	0.20	0.18	0.20	0.20	0.20	0.20
[0,59, 0,71)	0.19	0.16	0.18	0.19	0.19	0.19
[0,71, 0,82)	0.20	0.17	0.20	0.21	0.21	0.21
[0,82, 0,92)	0.20	0.19	0.19	0.20	0.21	0.22
[0,92, 1]	0.21	0.30	0.23	0.20	0.18	0.17

Cuadro 9: Resultados para asignaturas optativas dado el tamaño de los grupos prácticos.

- [7] Madsen, A. and F. Jensen (1999). *Lazy propagation: A junction tree inference algorithm based on lazy evaluation*. *Artificial Intelligence* 113, 203–245.
- [8] Shenoy, P. and G. Shafer (1990). *Axioms for probability and belief function propagation*. In R. Shachter, T. Levitt, J. Lemmer, and L. Kanal (Eds.), *Uncertainty in Artificial Intelligence 4*, pp. 169–198. North Holland, Amsterdam.
- [9] Spirtes, P., C. Glymour, and R. Scheines (1993). *Causation, prediction and search*, Volume 81 of *Lecture Notes in Statistics*. Springer Verlag.

María Morales

*Departamento de Estadística y Matemática Aplicada, Universidad de Almería, Almería*  
 maria.morales@ual.es

Carmelo Rodríguez

*Departamento de Estadística y Matemática Aplicada, Universidad de Almería, Almería*  
 crt@ual.es

Antonio Salmerón

*Departamento de Estadística y Matemática Aplicada, Universidad de Almería, Almería*  
 antonio.salmeron@ual.es

Este trabajo ha sido financiado por el Ministerio de Educación y Ciencia

bajo el proyecto TIN2004-06204-C03-01