

Análisis de la Influencia de las Inteligencias Múltiples en el Desempeño Académico Aplicando Técnicas de Minería De Datos

Maricela Quintana López, Jorge Eduardo Hernández Patlán

Centro Universitario UAEM Valle de México

mquintanal@uaemex.mx, lb.lalo_2558@hotmail.com

Resumen. Se presenta el trabajo realizado en el Centro Universitario UAEM Valle de México para generar un modelo del desempeño académico de un alumno de la carrera de Ingeniería en Sistemas y Comunicaciones basándose en la teoría de las Inteligencias Múltiples, utilizando técnicas de Minería de Datos. El objetivo principal es determinar si es posible predecir el desempeño académico de un alumno en unidades de aprendizaje del núcleo de Ciencias Básicas y Matemáticas, basándose en sus inteligencias múltiples, y comprobar si la inteligencia que más influye es la lógica matemática. Para lograrlo, se utilizaron los algoritmos de clasificación C4.5 y Naïve Bayes, primero aplicados a las instancias de todas las unidades del núcleo y posteriormente a cada unidad en particular. Los resultados muestran que sí es posible determinar el desempeño de un alumno y permiten determinar cuáles inteligencias son las más influyentes.

Palabras clave: Minería de datos, Árboles de Decisión, Naïve Bayes, Clasificación.

1 Introducción

En el área de la educación, existen investigaciones que centran su interés en determinar cuáles son los factores que influyen en el desempeño académico de un alumno [1, 4, 9, 11, 14, 15, 16]. Esto se debe a que si se sabe cuál es el factor más influyente, entonces es posible crear estrategias para minimizar los efectos negativos de dicho factor. Los factores que se han encontrado que influyen son pedagógicos, psicológicos, sociológicos, fisiológicos e institucionales.

Por otro lado, la inteligencia propia del sujeto, es determinante para su desempeño escolar. Al respecto, en 1900 Alfred Binet creó una forma cuantificable de medir la inteligencia, su test de Coeficiente Intelectual (CI). Sin embargo, este test está orientado únicamente a medir la inteligencia lingüística y la lógica, por lo cual otros investigadores surgieron con teorías que postulan que hay más inteligencias. Tal es el caso de Daniel Coleman con la Inteligencia Emocional [10] y Howard Gardner con la Teoría de las Inteligencias Múltiples (IM)[6].

En el centro universitario UAEM Valle de México, estamos interesados en determinar si es posible predecir el desempeño académico de un alumno en unidades de aprendizaje del área de las ciencias básicas y matemáticas, basándose en sus inteligencias múltiples, y a su vez comprobar si la inteligencia que más influye es la lógico matemática.

El documento está organizado de la siguiente manera: en la sección 2 se describe brevemente la teoría de las Inteligencias Múltiples de Gardner. En la sección 3, presentamos de manera sucinta las técnicas de minería de datos a utilizar. Posteriormente en la sección 4 se muestra los procesos realizados para la preparación de los datos, y en la sección 5 se muestran los experimentos realizados y los resultados obtenidos. Finalmente, en la sección 6 se dan las conclusiones y el trabajo futuro, respectivamente.

2 Inteligencias múltiples

La teoría de las Inteligencias Múltiples de Howard Gardner menciona que cada persona tiene diferentes capacidades y habilidades para resolver problemas o elaborar productos de gran valor en un determinado contexto comunitario o cultural, y define esas capacidades como inteligencias. Las definiciones de las inteligencias se muestran a continuación:

- **Lógica Matemática:** se refiere a la habilidad para efectuar cálculos matemáticos y resolver problemas.
- **Lingüística-Verbal:** esta habilidad trata con la facilidad de palabra, y comprender el orden y el significado de las palabras.
- **Musical Rítmica:** facilidad para tocar un instrumento, cantar y escuchar.
- **Corporal Cinestésico:** se refiere a la habilidad de tener coordinación corporal y buen equilibrio.
- **Visual Espacial:** la facilidad de crear mapas e imágenes mentales.
- **Intrapersonal:** trata acerca de plantearse metas, y reflexionar acerca de sus habilidades personales.
- **Interpersonal:** se refiere a la habilidad de trabajar bien en equipo, ser empáticos, y puede identificar y superar problemas.

De acuerdo al estudio realizado por Gardner, cada perfil profesional requiere del desarrollo de una determinada inteligencia. En la tabla 1, se muestran las siete inteligencias, la clave para referirse a cada una, y el perfil profesional recomendado [6].

Por otro lado, existen investigaciones en las que se utilizan las inteligencias múltiples, tal es el caso de la Universidad Complutense de Madrid que requería saber cuáles eran las capacidades, habilidades y destrezas de los estudiantes de las licenciaturas de Periodismo, Comunicación audiovisual, Publicidad y Relaciones Públicas. Se aplicaron los test a los alumnos de diferentes carreras y se encontró que los estudiantes de Periodismo mostraron altos niveles de inteligencia Lingüística-Verbal, los de Comunicación Audiovisual altos niveles de inteligencia Visual-Espacial, Musical y los de

Publicidad y Relaciones Públicas un mejor resultado en la inteligencia Interpersonal [5].

Tabla 1. Perfiles profesionales para cada una de las 7 inteligencias múltiples y clave.

Inteligencia múltiple	Clave	Perfil profesional
Lógica-Matemática	ILM	Economistas, ingenieros, científicos.
Lingüística-Verbal	ILV	Líderes políticos o religiosos, poetas y escritores.
Musical-Rítmica	IMR	Músicos, compositores y críticos musicales.
Corporal-Cinestésico	ICK	Escultores, cirujanos, actores, bailarines, deportistas y atletas.
Visual-Espacial	IVE	Artistas, fotógrafos, arquitectos, diseñadores y publicistas.
Intrapersonal	INTRA	Psicólogos y sociólogos.
Interpersonal	INTER	Administradores, docentes, psicólogos y terapeutas.

Otro de los estudios consistió en identificar la relación que tienen las inteligencias múltiples con los estilos de aprendizaje de los estudiantes, para ello se aplicó el test de las inteligencias múltiples (con una escala del 1 a 5) y el inventario de estilos de aprendizaje (divergentes=D, convergentes=C, asimilador=AS y acomodadores=CA) obteniendo 231 reglas que servirán para predecir el estilo de aprendizaje nuevos estudiantes [13].

En el presente trabajo, nuestro interés se centra en saber si es posible determinar el desempeño de un alumno en las unidades de aprendizaje del área de las ciencias básicas y matemáticas, y comprobar que para esta área debe haber mayor predominio de la inteligencia lógica-matemática. A continuación se presentan las técnicas de minería de datos a utilizar para dicho propósito.

3 Técnicas de minería de datos

Existen varios trabajos de clasificación del desempeño escolar que utilizan algoritmos de minería de datos, algunos utilizan árboles de decisión y otros métodos bayesianos [2] [14] [15][16]. En nuestro caso, los algoritmos a utilizar C4.5 y Naïve Bayes pertenecen a lista de los 10 mejores [12].

Debido a que uno de nuestros intereses se centra en determinar si la inteligencia lógica matemática es la que más influye en el desempeño académico de los alumnos de ingeniería en sistemas y comunicaciones en el núcleo de las ciencias básicas y matemáticas, decidimos utilizar un árbol de decisión. Lo anterior, debido a que los árboles de decisión, utilizan para su construcción una estrategia de “divide y vencerás” es decir, los árboles se construyen de arriba hacia abajo partiendo de un nodo raíz [7]. Dicho nodo raíz representa al atributo que da la mayor ganancia, de ahí que

al emplearlo, nos permite determinar cuál de todas las inteligencias es la más influyente.

Por otro lado, la naturaleza numérica de los datos nos obliga a utilizar algoritmos que puedan procesarlos, tal es el caso del algoritmo *c4.5* desarrollado por J. Ross Quinlan en 1993 como una mejora del *ID3* [8].

Por otro lado, al tomar en cuenta la naturaleza de las inteligencias, sería válido considerarlas como independientes y de ahí que resulte interesante aplicar una técnica basada en la probabilidad condicional de Bayes, tal es el caso del algoritmo *Naïve Bayes* que considera que todos los atributos influyen de la misma manera.

La metodología empleada para realizar el presente trabajo es el modelo *KDD* (*Knowledge Discovery in Databases*) que consiste esencialmente en el proceso de preparación de datos, el proceso de minería de datos y la validación de resultados [7] [8] [16] [18]. Para el proceso de minería de datos utilizamos el software *WEKA* de la universidad de Waikato, Nueva Zelanda, el cual es una herramienta de minería de datos de distribución libre para la obtención de los modelos de clasificación [3] [17].

4 Datos y su preparación

Para poder realizar el presente trabajo, fue necesario aplicar el test de Inteligencias Múltiples de Howard Gardner a los alumnos del Centro Universitario UAEM Valle de México, específicamente a los alumnos de la carrera de Ingeniería en Sistemas y Comunicaciones. El test de IM está conformado por 70 preguntas que se responden con una escala del uno al cinco. Hay 10 preguntas para cada una de las siete inteligencias.

Además de estas preguntas, cada test va acompañado de un formulario donde se solicitan los datos de identificación del estudiante, tanto personales (nombre, edad y sexo), así como académicos (matrícula, grupo, semestre y estatus académico). La información anterior se relacionó con las calificaciones obtenidas en el periodo anterior cursado.

Dentro los atributos a utilizar además de las inteligencias múltiples, están las unidades de aprendizaje que comprenden el Área de las Ciencias Básicas y Matemáticas así como el semestre en que se imparte.

En cuanto a la limpieza de los datos, se eliminaron aquellos registros de los alumnos que no completaron el test de las IM. También los de aquellos que completaron el test pero no cursaron una unidad de aprendizaje se descartaron al momento de realizar la minería de datos para esa unidad de aprendizaje en particular.

En la tabla 3 se muestra el registro de un alumno que no completó el test de IM pero sí curso sus materias correspondientes al tercer semestre; por otro lado, en la tabla 4 el alumno sí completo su test de IM pero no curso la materia de métodos numéricos.

Cabe mencionar que las calificaciones de cada unidad de aprendizaje están en valores numéricos y se transformaron a valores nominales de acuerdo a la escala de la tabla 5.

Tabla 2. Asignaturas que comprenden el núcleo las Ciencias Básicas y Matemáticas

Semestre	Asignatura	Nº de alumnos
1	Álgebra y Geometría Analítica	58
1	Estática y Dinámica	58
2	Química	58
2	Álgebra lineal	56
2	Cálculo diferencial e integral	58
3	Matemáticas discretas	44
3	Ecuaciones diferenciales	43
3	Métodos numéricos	42
4	Lógica matemática	43
4	Cálculo vectorial	39
4	Electromagnetismo	43
4	Probabilidad y estadística	43

Tabla 3. Datos de inteligencias múltiples incompletos

I. Intrapersonal											I. Interpersonal											I. Lingüístico-Verbal										
4	5	4	3	2	3	2	3	2	2	30	3	2	2	3	2					12									0			
I. Lógico-Matemático											I. Musical-Rítmico											I. Corporal-Cinestésico										
										0										0									0			
I. Visual-Espacial											Métodos numéricos					Matemáticas discretas						Ecuaciones diferenciales										
										0	7					7.8						6.3										

Tabla 4. Alumno que no curso una unidad de aprendizaje

I. Intrapersonal											I. Interpersonal											I. Lingüístico-Verbal										
4	4	4	5	5	4	5	5	5	4	45	5	4	2	4	3	5	4	4	5	4	40	4	5	5	4	3	5	4	3	4	4	41
I. Lógico-Matemático											I. Musical-Rítmico											I. Corporal-Cinestésico										
4	5	4	5	4	5	3	2	4	2	38	5	5	5	5	5	4	4	3	3	5	44	5	4	4	4	5	4	5	5	4	5	45
I. Visual-Espacial											Métodos numéricos					Matemáticas discretas					Ecuaciones diferenciales											
5	4	5	4	4	4	3	4	5	2	40						8.5					6.4											

Tabla 5. Transformación de valores numéricos a nominales.

Referencia numérica	Nivel de desempeño
8 a 10	A
Menor a 8	B

5 Experimentos y resultados

El primer experimento se realizó con 585 instancias que representan a los alumnos que tomaron una o más unidades de aprendizaje del núcleo de las ciencias básicas y matemáticas. De estos, 210 pertenecen a la clase A y 375 a la clase B. Se aplicaron los algoritmos C4.5 (J48 en el software Weka) y Naïve Bayes. En ambos casos se utilizó la validación cruzada con 10 particiones, la cual consiste en utilizar el 90% de los datos para entrenar y el 10% restante para validar; repitiendo este proceso 10 veces [16].

Como podemos apreciar en la tabla 6, los resultados obtenidos por ambos algoritmos en cuanto a la eficiencia del clasificador, no difieren por mucho. Sin embargo, el árbol de decisión resulta mejor.

Tabla 6. Comparación de algoritmos

Área	Árbol de Decisión (C4.5)		Naïve Bayes	
	Correctas	Incorrectas	Correctas	Incorrectas
Ciencias básicas y matemáticas	66.1538 %	33.8462%	61.8803%	38.1197%

En la figura 1, se muestra el árbol obtenido al aplicar el algoritmo C4.5 a los datos, se puede apreciar que el nodo raíz ILM, hace referencia a la inteligencia lógica matemática, lo que nos indica que este atributo fue el que proporcionó la mejor ganancia al momento de construir el árbol, y concuerda con los resultados que se esperaban.

Otra situación que podemos observar es que la inteligencia lógica matemática por sí sola no es suficiente para determinar la clase de desempeño que tendrá un alumno, podemos observar esto en las ramas más cortas del árbol donde al menos son dos las inteligencias que se utilizan.

Por poner un ejemplo para la clase A, veamos la rama más corta que se encuentra del lado derecho del árbol, esta rama nos indica que si la inteligencia lógica matemática es mayor a 46 y la intrapersonal es menor o igual a 42, el desempeño del alumno será A, es decir que tendrá un promedio entre 8 y 10 en unidades del núcleo.

Para el caso de la clase B, veamos la rama del camino más largo que termina en el nodo B(101/18). En este caso particular, la lectura sería que si la inteligencia lógica matemática es menor o igual a 46 y la inteligencia cinestésica es mayor a 35, y la visual espacial es mayor a 36 entonces debemos revisar nuevamente la inteligencia lógica matemática, si es menor o igual a 39 entonces el desempeño del alumno en materias del núcleo de las ciencias básicas y matemáticas será menor a 8.

También es posible observar que las inteligencias musical rítmica (IMR) y lingüística verbal (ILV) no aparecen en ninguna parte del árbol. Lo que significa que no son relevantes para las unidades de aprendizaje del núcleo básico.

Si bien este primer experimento nos permite ver, a grosso modo, cuál será el desempeño de un alumno en las unidades de aprendizaje, no nos permite determinar qué ocurrirá en una unidad de aprendizaje particular, por lo que decidimos realizar un segundo experimento en el cual se realiza la minería de datos a cada unidad. Los algo-

ritmos empleados en este segundo experimento siguen siendo C4.5 y Naïve Bayes. Los resultados obtenidos se muestran en la tabla 7, en ella se puede observar que el algoritmo C4.5 tiene mejor desempeño que el de Bayes, con excepción de la unidad de electromagnetismo.




Fig. 1. Árbol generado por el algoritmo C4.5 para el núcleo de Ciencias básicas y Matemáticas.

Tabla 7. Resultados de los algoritmos C4.5 y Naïve Bayes.

Unidad de Aprendizaje	Árbol de Decisión (C4.5)		Naïve Bayes	
	Correctas	Incorrectas	Correctas	Incorrectas
Matemáticas Discretas	68.18%	31.82%	61.36%	38.64%
Electromagnetismo	58.14%	41.86%	62.79%	37.21%
Estática y Dinámica	68.97%	31.03%	56.90%	43.10%
Probabilidad y estadística	74.42%	25.58%	51.16%	48.84%
Química	53.45%	46.55%	51.72%	48.28%
Álgebra lineal	51.79%	48.21%	50.00%	50.00%
Álgebra y geometría analítica	100.00%	0.00%	100.00%	0.00%
Lógica matemática	62.79%	37.21%	53.49%	46.51%
Métodos numéricos	78.57%	21.43%	57.14%	42.86%
Cálculo vectorial	66.67%	33.33%	64.10%	35.90%
Ecuaciones diferenciales	55.81%	44.19%	46.51%	53.49%
Cálculo diferencial e integral	56.90%	43.10%	46.55%	53.45%

Podemos observar en la tabla 7, que la unidad de aprendizaje de Álgebra y geometría analítica tiene un 100%, esto se debe a que ningún alumno obtuvo 8 o más.




Fig. 2. Árboles para las unidades de aprendizaje del tercer semestre.

Por otro lado, vale la pena recordar que algunas de las unidades de aprendizaje se imparten en el mismo semestre, por lo que los mismos valores de inteligencias múltiples se utilizan para clasificar resultados de unidades de aprendizaje diferentes. Por ejemplo, en la figura 2 se muestra que para ecuaciones diferenciales las inteligencias relevantes son lógica matemática, inteligencia visual espacial, y la musical rítmica mientras que para matemáticas discretas, la única inteligencia a considerar es la lingüística verbal. En el caso de métodos numéricos las que más afectan son la musical rítmica y la cinestésica.

6 Conclusiones y trabajo futuro

Una de las principales conclusiones, es que sí es posible obtener un modelo que permita clasificar el desempeño académico de un alumno basándose en las inteligencias múltiples, y que una de las inteligencias más influyente es la inteligencia lógica matemática. Sin embargo, el desempeño no es el mejor, consideramos que en el momento que tengamos más datos en nuestra base, podremos tener mejores desempeños e incluso ampliar los intervalos de calificación.

Consideramos de suma importancia aplicar las encuestas cada semestre para llevar un seguimiento histórico de la evolución de las inteligencias desde que el alumno ingresa hasta el término de su carrera. Esto permitirá generar clasificadores no solo para el área de las ciencias básicas y matemáticas sino también en las áreas de la ingeniería aplicada, ciencias de la ingeniería, y ciencias sociales y humanidades.

Como trabajo futuro queda el desarrollo de una herramienta que utilice los modelos generados y permita realizar la clasificación de un estudiante en dos niveles, primero a nivel macro determinando su desempeño en general en el núcleo de materias en

particular y luego a nivel micro, generando el detalle del desempeño en una materia dada.

Referencias

1. Alcover, R., Benlloch, J., Blesa, P., Calduch, M. A., Celma, M., Ferri, C., & Zúñica, L. R.: Análisis del rendimiento académico en los estudios de informática de la Universidad Politécnica de Valencia aplicando técnicas de minería de datos. XIII Jornadas de Enseñanza universitaria de la Informática. Teruel, España. Disponible en: <http://bioinfo.uib.es/~joemiro/aenui/procJenui/Jen2007/alanal.Pdf>. (2007).
2. Berry, M., & Gordon, L.: Data mining Techniques. Canada: Wiley Computer Publishing. (2004).
3. Dapozo, G. N., Porcel, E., López, M. V., Bogado, V. S., & Bargiela, R.: Aplicación de minería de datos con una herramienta de software libre en la evaluación del rendimiento académico de los alumnos de la carrera de Sistemas de la FACENA-UNNE. En VIII Workshop de Investigadores en Ciencias de la Computación. (2006).
4. Garbanzo, V., Guiselle, M.: Factores asociados al rendimiento académico en estudiantes universitarios, una reflexión desde la calidad de la educación superior pública. Educación, . 43-63. (2007).
5. GARCÍA NIETO, M. T.: La dimensión comunicativa de las inteligencias múltiples. CIC. Cuadernos de Información y Comunicación, 14() 141-157. Recuperado de <http://www.redalyc.org/articulo.oa?id=93512977010>. (2009).
6. Gardner, H.: Inteligencias múltiples: teoría en la practica. México: Paidós. (2008).
7. Han, J., Kamber, M., & Pei, J.: Data Mining Concepts and Techniques. USA: Morgan Kaufmann. (2011).
8. Hernández, J., Ramírez, M^a., & Ferri, C.: Introducción a la Minería de Datos. España: Pearson Educación. (2004).
9. Izar Landeta, J.M., Ynzunza Cortés, C.B. & López Gama, H.: Factores que afectan el desempeño académico de los estudiantes de nivel superior en Rio verde, San Luis Potosí, México. Revista de Investigación Educativa. vol. 12. Recuperado de <http://www.uv.mx/cpue/num12/opinion/completos/izar-desempeno%20academico.html>. (2011).
10. Martínez, C. E., Vicente, E. S., & Moreno, C. M.: Revisión histórica del concepto de inteligencia: una aproximación a la inteligencia emocional. Revista latinoamericana de Psicología, 30(1), 11-30 [6]. (1998).
11. Salagre, D. J., & Serrano, S. O.: Determinacion de los factores que afectan al rendimiento académico en la educación superior. XII Jornadas de la Asociación de Economía de la Educación. (2003).
12. Xindong, W., & Vipin, K.: The top ten algorithms in data mining. USA: CRC Press. (2009).
13. Narlı, S., Özgen, K., & Alkan, H.: In the context of multiple intelligences theory, intelligent data analysis of learning styles was based on rough set theory. Learning and Individual Differences, 21(5), 613-618. (2011).

14. Carvajal Olaya, P., Mosquera M., J. C. & Artamonova, I.: Modelos de predicción del rendimiento académico en matemáticas I en la Universidad Tecnológica de Pereira. *Scientia Et Technica*, XV(43) 258-263. Recuperado de <http://www.redalyc.org/articulo.oa?id=84917310045>. (2009).
15. Porcel, E., Dapozo, G. N., & López, M. V.: Modelos predictivos y técnicas de minería de datos para la identificación de factores asociados al rendimiento académico de alumnos universitarios. In XI Workshop de Investigadores en Ciencias de la Computación. (2009).
16. Moreno Sabido, M., & Martínez Maldonado, R., Modelo Clasificador para Predecir el Desempeño Escolar Terminal de un Estudiante.
17. Sposito, O. M., Etcheverry, M. E., Ryckeboer, H. L., & Bossero, J. Aplicación de técnicas de minería de datos para la evaluación del rendimiento académico y la deserción estudiantil.
18. Valcárcel Asencios, V.: Data Mining y el descubrimiento del conocimiento. *Industrial Data*, 7(2) 83-86. Recuperado de <http://www.redalyc.org/articulo.oa?id=81670213>. (2004).