

- Daysi García-Tinizaray, Karla Ordoñez-Briceño y Juan Carlos Torres-Díaz
Loja (Ecuador)

Learning analytics para predecir la deserción de estudiantes a distancia

Learning analytics to predict dropout of distance students

RESUMEN

Los datos que se generan como producto del trabajo de los estudiantes en un entorno virtual tienen el potencial de convertirse en información valiosa para la toma de decisiones y para anticiparse en el tiempo y prevenir la deserción. En esta investigación se explora un conjunto de esos datos en una universidad de Ecuador cuyos estudiantes realizan sus estudios en modalidad a distancia. Se aplican métodos multivariantes y se obtiene un conjunto reducido de variables con las que se predice la deserción. El artículo abarca el desarrollo de un modelo predictivo aplicando regresión logística, los resultados muestran que las variables relacionadas al acceso a un entorno virtual, la participación en foros y la subida y descarga de recursos educativos son las que determinan una potencial deserción.

ABSTRACT

The data generated as a result of the work of students in a virtual environment has the potential to become valuable information for decision making and prevent dropout. In this research a set of data is analyzed in a distance learning Ecuadorian university. Multivariate methods are used to obtain a reduced set of variables which predicts students dropout. The article covers the development of a predictive model using logistic regression; the results show that the variables related to access to a virtual environment, participation in forums and upload and download educational resources are determinants of dropout.

PALABRAS CLAVE / KEYWORDS

Learning analytics, Deserción, Factorial, Logística, Educación, Predictivo.
Learning analytics, Dropout, Factorial, Logistic, Education, Predictive.

SOBRE EL AUTOR/ES

Daysi García-Tinizaray. Universidad Técnica Particular de Loja Ecuador, Profesor investigador (dkgarcia@utpl.edu.ec).
Karla Ordoñez-Briceño. Universidad Técnica Particular de Loja Ecuador, Profesor investigador (kfordonez@utpl.edu.ec).
Dr. Juan Carlos Torres-Díaz. Universidad Técnica Particular de Loja Ecuador, Profesor investigador (jctorres@utpl.edu.ec).

1. Introducción.

El uso de entornos virtuales de aprendizaje o LMS ha abierto nuevas posibilidades tanto en la forma de conducir los procesos de enseñanza aprendizaje como en la innovación asociada a tales procesos. Un campo que hasta hace poco había carecido de atención es la retroalimentación que deben tener el estudiante, el profesor y la institución respecto a la forma en que se desarrollan las distintas actividades, el contar con esta retroalimentación en tiempo real es lo que se denomina analítica del aprendizaje (*learning analytics*) y desde su aparición ha tenido un crecimiento exponencial, entre otras cosas porque abre las puertas a muchas posibilidades para mejorar el desempeño institucional a todo nivel. Schroeder (2009) señala que los LMS se han convertido en una de las herramientas más utilizadas por los educadores, en donde se pueden encontrar datos sobre el comportamiento del estudiante, el análisis del aprendizaje busca transformar estos datos en información útil para la institución educativa y para propiciar un mejor rendimiento de los estudiantes.

Para remontarnos al origen del término *learning analytics*, se pueden señalar dos factores que han sido los más importantes en el desarrollo de este concepto, estos son: la inteligencia de negocios que relaciona y filtra datos en busca de información para la toma de decisiones empresariales y la analítica de la web (*web analytics*) cuyo objetivo en principio fue obtener información acerca del uso de los sitios web, identificar usuarios y sus patrones de navegación (Buckingham & Ferguson, 2011). Inicialmente estos factores no se relacionaban con la educación, sin embargo los dos ámbitos tienen necesidades comunes, el análisis del aprendizaje se refiere al uso de datos inteligentes producidos por los alumnos, y el análisis de los mismos para descubrir la información y las relaciones sociales, con la finalidad de predecir y asesorar alguna acción relacionada con el aprendizaje (Siemens, 2010). El análisis del aprendizaje utiliza los datos que genera el estudiante cuando aprende, éstos se registran en cada sesión y constituyen la base sobre la que se extrae información en una etapa posterior. En el proceso se aplican modelos de análisis para descubrir información que sirve para predecir comportamientos y tomar decisiones al respecto (Siemens, 2010). La analítica del aprendizaje utiliza técnicas analíticas y modelos predictivos para apoyar los objetivos institucionales y curriculares, ofreciendo al estudiante recursos de apoyo como soporte a la consecución de objetivos de aprendizaje (Bach, 2010).

Se aplica también como estrategia para prevenir la deserción (Campbell, DeBlois, & Oblinger, 2007) a través de alarmas o indicadores de la actividad de los estudiantes. Uno de los resultados de la aplicación de estas alarmas es la mejora del rendimiento de los estudiantes que se encuentran en situación de riesgo (Arnold, 2010; Johnson, Smith, Willis, Levine, & Haywood, 2011). Los autores Becker (2013); Siemens (2012); Dietz-Uhler & Hurn (2013) concuerdan en que, el análisis del aprendizaje ofrece una solución que podría ayudar a aumentar la retención escolar, predecir el progreso del estudiante, optimizar las técnicas de aprendizaje y enseñanza, además de mejorar la toma de decisiones en la institución educativa. Campbell et al (2007) definen un conjunto de etapas a través de las que se cambia de un escenario desfavorable para el estudiante a un escenario favorable; estas etapas son capturar, reportar, predecir, actuar y refinar. La captura, reporte y predicción tiene dependencia de la tecnología, mientras que la etapa de actuación depende de decisiones a nivel de política institucional.

Existen campos relacionados con el análisis del aprendizaje tales como: Minería de datos para la educación (EDM por sus siglas en inglés), análisis de redes sociales e inteligencia de negocios. El EDM se centra más específicamente en las herramientas y métodos para la exploración de los datos procedentes de contextos educativos (Dyckhoff et al. 2012), realiza un análisis de un conjunto de datos reducido para de esa manera apoyar la toma de decisiones referente al modelo de aprendizaje y enseñanza en las instituciones educativas. La EDM es una disciplina que hace uso de métodos computacionales, psicológicos y enfoques de investigación para entender cómo aprenden los estudiantes (Bienkowski, Feng, Means, 2012). Los sistemas de aprendizaje, herramientas inteligentes, simuladores, juegos, han abierto oportunidades para recopilar y analizar datos relacionados con el estudiante, con la finalidad de descubrir patrones y tendencias en los datos, para con ello descubrir cómo aprenden los estudiantes. Con los datos recogidos de los sistemas de aprendizaje en línea se pueden establecer distintas variables, las mismas que puedan ser exploradas por los algoritmos de minería de datos para la construcción de modelos de predicción.

Learning analytics es un concepto que se implementa sobre un entorno virtual de aprendizaje, uno de los más difundidos es Moodle, cuenta con una comunidad de desarrollo que ha trabajado en distintos plugin, entre otros e-Rubric, Course dedication, Gizmo; existen otras herramientas para distintos LMS que aportan información útil tanto para profesores como para estudiantes, entre las más destacadas están: Course Signals, SNAPP, eLat, entre otras. En la misma línea de trabajo, el desarrollo de los MOOC ha venido acompañado por comunidades e instituciones académicas que han orientado sus esfuerzos al desarrollo de productos que miden el trabajo del estudiante en entornos masivos de formación; esto sin duda abre las puertas a nuevos retos y a la vez necesidades a cubrir.

Por ser la deserción estudiantil uno de los mayores problemas que enfrentan muchas universidades en el mundo, algunas instituciones educativas, han creído conveniente realizar algunos trabajos relacionados con el tema, con la finalidad de encontrar las posibles causas por las que un alumno decide desertar la carrera; entre los cuales podemos señalar los trabajos de Casini, Gonzalez, Gertel, & Giuliadori (2012); Chávez & Zurita (2007); Girón & González (2006); Beltrán & Cosolito (2009), en donde aplicaron métodos estadísticos multivariantes para predecir la deserción y el rendimiento académico de los estudiantes. En el trabajo de Beltrán & Cosolito (2009), se determinaron las variables que condicionan la deserción y retención durante el trayecto universitario de los estudiantes. Por su parte Barber & Sharkey (2012), aplicaron técnicas de análisis predictivo a un extenso grupo de datos de los estudiantes, para predecir cuándo un estudiante reprobará o no un curso.

2. Datos y métodos.

2.1. Datos.

En el presente estudio se realizó un análisis de los diferentes cursos de la Modalidad Abierta y a Distancia de la Universidad Técnica Particular de Loja, esta modalidad tiene la particularidad de utilizar los recursos tradicionales de la educación a distancia como materiales en papel y al mismo tiempo ofrece acceso a una plataforma virtual. Para este estudio no se han considerado las implicaciones del uso de materiales en papel sino que se utilizan únicamente las variables tecnológicas que se registran con el uso de la plataforma; se han seleccionado los datos de los cursos que poseen una mayor interacción en: foros, tareas, recursos, accesos y mensajes, tanto por parte del profesor como de los estudiantes del curso.

Los cursos tomados en cuenta para la creación del modelo fueron 6, de los cuales 4 pertenecen a la carrera de Sistemas Informáticos y Computación, y los 2 restantes a la carrera de Abogacía y Gestión Ambiental respectivamente, dando un total de 205 estudiantes. Los cursos considerados para el caso de estudio corresponden al período académico Octubre 2012 – Febrero 2013.

Los anuncios que ingresa el docente cuentan con la posibilidad de ser comentados por el estudiante por lo que un comentario a un anuncio o mensaje público del profesor está asociado con el ingreso; lo que significa que siempre que un estudiante ingresa al entorno virtual, tiene la posibilidad de comentar sobre las orientaciones del docente. Esto explica la conformación del primer factor denominado acceso, cuyas variables representan distintas formas de medir el acceso al entorno virtual de aprendizaje.

De los cursos seleccionados para el modelo, se han recolectado datos referentes al: número de veces que un estudiante revisa, agrega un tema de discusión o da un mensaje de respuesta en el foro, o a su vez agrega recursos adjuntos al foro, número de tareas enviadas, número de mensajes enviados a los compañeros o al docente del curso, número de veces que realiza comentarios en los anuncios, número de accesos y tiempo total de duración en los accesos al curso; por último el número de descargas de un recurso.

2.2. Métodos.

Con la finalidad de crear el modelo predictivo, se ha hecho uso de técnicas estadísticas multivariantes, como son el análisis factorial y regresión logística. El análisis factorial es utilizado para agrupar las variables por

ámbito de acción y con el propósito principal de reducir el conjunto de las mismas, y así contar con pocas variables predictoras, que tengan una mayor influencia sobre la deserción; con estas se elaboró un modelo de regresión combinando distintas posibilidades a fin de lograr la mayor explicación de la varianza posible. El modelo de regresión logística es apropiado, puesto que utiliza sola una variable dependiente categórica o nominal y varias variables independientes. La variable dependiente tomada en cuenta para este estudio es: desertor, la misma que indica si un estudiante abandono o no su carrera universitaria.

3. Resultados.

Como producto de la aplicación de análisis factorial se obtuvieron cuatro factores a los que les fueron asignados nombres descriptivos en función de las variables que los conforman.

Variables	Componente				Factores
	1	2	3	4	
Tiempo total de accesos	,868				Acceso
Número de accesos al curso	,817				
Número de comentarios en anuncios	,625				
Participación en foros		,829			Foros
Número mensajes de respuesta en foros		,814			
Número mensajes enviados a compañeros de curso			,846		Mensajes
Número mensajes enviados al profesor			,752		
Número de tareas enviadas				,743	Recursos
Número de descargas de recursos				,721	

Tabla 1. Factores resultantes del análisis factorial.

Los cuatro componentes fueron utilizados en la generación de un modelo de predicción. En éste, se trabajó aplicando regresión logística binaria cuya variable dependiente fue la deserción del estudiante, que es una variable dicotómica con los valores 1=SI y 0=NO.

Coefficientes del modelo:

	B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a FAC1_1	-,437	,203	4,616	1	,032	,646
FAC2_1	-,338	,170	3,958	1	,047	,713
FAC3_1	,032	,165	,038	1	,845	1,033
FAC4_1	-,730	,227	10,373	1	,001	,482
Constant	-,648	,162	15,999	1	,000	,523

Tabla 2. Resultados de la regresión logística.

La variable que mide el número de mensajes entre compañeros y con el profesor no alcanza valores significativos por lo que fue excluida del modelo final. El nivel de predicción alcanzado por el modelo es de 64,4% y la varianza explicada alcanza el 15,7%. El modelo resultante es el siguiente:

$$\text{Ln} \frac{P(x)}{1-P(x)} = -0,648 - 0,437 (\text{acceso}) - 0,338(\text{foros}) - 0,730(\text{recursos})$$

El odds ratio del acceso indica que por cada unidad de incremento en esta variable, la probabilidad de reprobado respecto a no reprobado disminuye 1,54 (1/0,437) veces; el odds ratio de la variable foros indica que por cada unidad de incremento la probabilidad de reprobado respecto a no reprobado disminuye 1,40 (1/0,338) veces; y, el odds ratio de la variable recursos indica que por cada unidad de incremento la probabilidad de reprobado respecto a no reprobado disminuye 2 (1/0,730) veces.

Los elementos que determinan la deserción del estudiante son las tres variables que se señalan en el modelo. El cambio en los valores de los coeficientes determina un potencial cambio del estado final del estudiante (deserción/no deserción).

4. Discusión.

Las variables utilizadas en el modelo permiten predecir con un nivel de precisión del 64,4%, esto si bien es aceptable, implica que se requiere considerar variables adicionales cuya información aporte en la explicación del estado del estudiante. Una opción viable es trabajar de forma similar a la llevada en el estudio de Ramos & Yudko (2008) en donde se realiza un análisis por curso, en este caso, la uniformidad en el contexto aporta calidad a los datos objeto de análisis (Barber & Sharkey, 2012). Hay que considerar también que no necesariamente solo las variables tecnológicas pueden tomarse en cuenta para predecir un fenómeno que no está ligado completamente a la tecnología; las variables socio-demográficas pueden tener también un nivel importante de impacto en la determinación del estado del estudiante, lo que hace deseable utilizar variables, tanto de desempeño tecnológico, como socio-demográficas para tener un modelo mas efectivo y confiable.

Una de los indicadores de que el análisis de factores es adecuado tiene que ver con la facilidad de interpretación de los resultados (Díaz De Rada, 1998), los factores resultantes muestran claramente que se han agrupado en función del área a la que se refiere la variable; en caso particular del factor acceso, las variables que lo conforman tienen niveles medios de correlación y se refieren a aspectos similares o complementarios. La variable número de comentarios en los anuncios se asocia al acceso debido a que cuando un estudiante ingresa a su entorno virtual, lo primero que ve es el anuncio (orientaciones) del profesor, y cuenta con la posibilidad de comentarlo de manera similar a una red social. De manera similar, los componentes restantes agrupan variables del mismo tipo, lo que permitió designarlos de manera genérica conforme se señala en la Tabla 1.

Resulta extraño que el factor que agrupa las variables que miden la interacción a través de mensajes no sea significativo y no forme parte del modelo, esto va en contra de los postulados de la educación a distancia y virtual, en donde el apoyo que brinda el profesor es crucial para despejar dudas y aportar en la construcción de conocimiento del estudiante. La mensajería puede considerarse determinante en la deserción de un estudiante (Girón & González, 2006), la interacción permite obtener mejores resultados del tiempo de estudio en línea (Castaño-Muñoz, Duart, & Sancho-Vinuesa, 2013); en general, la tutoría constituye el elemento más importante de la relación estudiante profesor, ya que permite que se construyan las relaciones que generan aprendizaje; así también, el intercambio de mensajes entre pares constituye la base de un proceso colaborativo de construcción de conocimiento, son fundamentales en los cMOOC, hoy en día consolidados, los que se basan en el conectivismo (Daniel, 2012), instrumentado a través de relaciones entre los participantes del curso, quienes a través de la interacción estructuran nuevos conocimientos (Sánchez, 2013). Los argumentos señalados, ponen en duda la falta de significación de la variable mensajes y constituyen base suficiente para sugerir el replanteamiento de la investigación, de forma que se analice de forma más detallada las variables relacionadas con el intercambio de mensajes entre los participantes de un curso; también podría implicar que existen deficiencias en el proceso de tutoría, sin embargo, considerando que se trata de un modelo maduro con algunas décadas de experiencia, esta elucubración tiene menos peso.

Las variables número de tareas enviadas y número de recursos digitales descargados están representados por el factor recursos lo que significa que estas variables se correlacionan, o, lo que es lo mismo, quienes des-

cargan recursos también envían las tareas, o viceversa. Este factor es el que tiene mayor peso en la determinación de la deserción de un estudiante, esto concuerda de alguna manera con los resultados obtenidos por Garman (2010) quien demuestra que la calificación lograda en base a la lectura de los recursos es un predictor significativo del éxito en un curso en línea. Así mismo, este resultado tiene sentido si se considera que los recursos digitales en el modelo analizado son parte fundamental del sistema; sin embargo, el que las actividades de interacción como foros o mensajes tengan un efecto menor que los recursos abre interrogantes respecto a las particularidades del modelo educativo.

Por otro lado, el peso de la variable “acceso” en el nivel de determinación de la deserción, tiene sentido al considerar que a mayor cantidad de accesos y tiempo de accesos las actividades y trabajo en el curso se incrementan y la probabilidad de desertar disminuye. Esto guarda relación con la acepción tradicional de brecha digital y concuerda con los hallazgos de Torres-Díaz (2013) quien concluye que el uso de la tecnología incide sobre el rendimiento académico. En la misma línea, los resultados concuerdan con los de Smith, Lange, Huston (2012) quienes encontraron que la frecuencia con la que el estudiante accede al curso es uno de los principales factores que influyen para predecir su éxito.

5. Conclusiones.

En el modelo educativo analizado, el uso de la tecnología se complementa con el uso de materiales tradicionales como el papel, por lo que el nivel de predicción implica que se deben considerar variables complementarias a fin de que el modelo predictivo final alcance un nivel mayor de precisión. Entre las variables adicionales se podría considerar también algunas socio-demográficas como edad, género y nivel de ingresos (nivel socio-económico).

Más allá de las particularidades del modelo analizado, es el factor recursos compuesto por el número de tareas enviadas y por el número de recursos descargados es el que tiene mayor participación en los niveles de predicción, le sigue el acceso y finalmente los foros; este orden de importancia de las variables, así como la exclusión de la variable mensajería, deja claro que se trata de un modelo con particularidades que requiere de un análisis más profundo. De todas maneras, el uso de recursos, especialmente, la descarga no deja de ser un factor importante en la deserción de un estudiante; la ausencia de descargas implica que un estudiante no está siguiendo el ritmo de aprendizaje planteado.

La modalidad de estudio analizada utiliza algunos elementos tradicionales de los modelos educativos a distancia, este podría ser uno de los aspectos que determinan que la mensajería sobre temas académicos no aporte a la predicción del resultado final que logra el estudiante. Este mismo aspecto podría ser el causante que las actividades interactivas en foros tengan la menor incidencia la predicción.

Los datos y análisis iniciales permiten apreciar que los postulados originales de la brecha digital se mantienen, sin embargo es necesario ampliar el alcance que tiene la variable acceso considerando no solo acceso y tiempo en línea sino también usos y patrones de trabajo del estudiante.

Referencias

- Arnold, K. (2010). Signals: Applying Academic Analytics. *EDUCAUSE Quarterly*, 33(1). Retrieved from <http://www.educause.edu/EDUCAUSE+Quarterly/EDUCAUSEQuarterlyMagazineVolum/SignalsApplyingAc>
- Bach, C. (2010). Learning Analytics: Targeting Instruction, Curricula and Student Support. In *International Instruction on Informatics and Systemics Conference*. Orlando, USA. Retrieved from http://www.iiis.org/CDs2010/CD2010SCI/EISTA_2010/PapersPdf/EA655ES.pdf
- Barber, R., & Sharkey, M. (2012). Course correction: using analytics to predict course success. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12)*, Simon Buckingham Shum, Dragan Gasevic, and Rebecca Ferguson (Eds.). ACM, New York, NY, USA, 259-262. DOI=10.1145/2330601.2330664 <http://doi.acm.org/10.1145/2330601.2330664>
- Becker, B. (2013). Learning Analytics: Insights Into the Natural Learning Behavior of Our Students, *Behavioral & Social Sciences Librarian*, 32:1, 63-67. DOI: 10.1080/01639269.2013.751804. Recuperado de: <http://dx.doi.org/10.1080/01639269.2013.751804>
- Beltrán, A., & Cosolito, P. (2009). Variables que condicionan la deserción y retención durante el trayecto universitario de alumnos de la carrera de Ingeniería Agronómica de la Universidad Nacional de Rosario. *Revista de Epistemología y Ciencias Humanas*.

- Bienkowski, M., Feng, M., Means, B. (2012). Enhancing Teaching and Learning Through Educational Data Mining and Learning Analytics: An Issue Brief. Educational Technology.
- Buckingham, S., & Ferguson, R. (2011). Social Learning Analytics. Learning. Retrieved from <http://kmi.open.ac.uk/publications/pdf/kmi-11-01.pdf>
- Campbell, J., DeBlois, P., & Oblinger, D. (2007). Academic analytics a new tool for a new era. *EDUCAUSE review*, 41–51.
- Casini, R., Gonzalez, M., Gertel, H., & Giuliadori, R. (2012). Métodos estadísticos aplicados para el análisis de deserción y rendimiento académico de estudiantes de tres facultades de la universidad nacional de córdoba. In X Congreso Latinoamericano de sociedades de estadística córdoba. Córdoba, Argentina.
- Castañero-Muñoz, J., Duart, J. M., & Sancho-Vinuesa, T. (2013). The Internet in face-to-face higher education: Can interactive learning improve academic achievement? *British Journal of Educational Technology*. doi:10.1111/bjet.12007
- Chávez, M., & Zurita, G. (2007). Estudio estadístico acerca de la deserción estudiantil de la Espol: el Caso de las facultades de ingenierías. Quito, Ecuador.
- Daniel, J. (2012). Making Sense of MOOCs: Musings in a Maze of Myth, Paradox and Possibility.
- Díaz De Rada, J. V. (1998). Diseño de tipologías de consumidores mediante la utilización conjunta del Análisis Cluster y otras técnicas multivariantes. *Revista Española de Economía Agraria*, 182, 75–104. Retrieved from <http://dialnet.unirioja.es/servlet/autor?codigo=173331>
- Dyckhoff, A. L., Zielke, D., Bültmann, M., C., Mamed, A. & Schroeder, U. (2012). Design and Implementation of a Learning Analytics Toolkit for Teachers. Recuperado de: http://www.ifets.info/journals/15_3/ets_15_3.pdf
- Dietz-Uhler, B. & Hurn, J. (2013): Using learning analytics to predict (and improve) student success: a faculty perspective. *Journal of Interactive Online Learning*, 12(1), 17-26.
- Garman, G. 2010. A Logistic Approach to Predicting Student Success in Online Database Courses. *American Journal of Business Education*. 3(12), 1-5.
- Girón, L., & González, E. (2006). Determinantes del rendimiento académico y la deserción estudiantil, en el programa de Economía de la Pontificia Universidad Javeriana de Cali. *Revista de Economía*.
- Johnson, L., Smith, R., Willis, H., Levine, A., & Haywood, K. (2011). *The horizon report*. Media. Austin, Texas: The New Media Consortium.
- Sánchez, M. (2013). Los MOOCs como ecosistema para el desarrollo de prácticas y culturas digitales. *Campus Virtuales*, 1(2), 112–123.
- Ramos, C. & Yudko, E. 2008. "Hits" (Not "Discussion Posts") Predict Student Success in Online Courses: A Double Cross-Validation Study. *Computers & Education*. 50(4), 1174-1182.
- Schroeder, U., (2009). Web Based Learning - Yes we can! *Proceedings of the International Conference on Advances In Web-Based Learning 2009*. Lecture Notes in Computer Science, 5686, 25-33.
- Siemens, G. (2010). What are Learning Analytics? (LA). elearnspace learning, networks, knowledge, technology, community. Retrieved June 17, 2011, from <http://www.elearnspace.org/blog/2010/08/25/what-are-learning-analytics/>
- Siemens, G. (2012). Learning analytics: envisioning a research discipline and a domain of practice. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12)*, Simon Buckingham Shum, Dragan Gasevic, and Rebecca Ferguson (Eds.). ACM, New York, NY, USA, 4-8. DOI=10.1145/2330601.2330605 <http://doi.acm.org/10.1145/2330601.2330605>
- Smith, V. C., Lange, A., & Huston, D. R. (2012). Predictive modeling to forecast student outcomes and drive effective interventions in online community college courses. *Journal of Asynchronous Learning Networks*, 16(3), 51-61.
- Torres-Díaz, J. C. (2013). Análisis de las relaciones entre los niveles de ingreso, edad y género de los estudiantes, los usos de internet y el rendimiento académico en un grupo de universidades ecuatorianas presenciales. UOC.

Cómo citar este artículo / How to cite this paper

García-Tinizaray, D., Ordoñez-Briceño, K. & Torres-Díaz, J. C. (2014). Learning analytics para predecir la deserción de estudiantes a distancia. *Campus virtuales*, 3(1), 120-126.

García-Tinizaray, D., Ordoñez-Briceño, K. & Torres-Díaz, J. C. (2014). Learning analytics to predict dropout of distance students. *Campus virtuales*, 3(1), 120-126.