



Asociación del Razonamiento Cuantitativo con el Rendimiento Académico en Cursos Introdutorios de Matemática de Carreras STEM

Luis Rojas T.

luisrojasxtorres@gmail.com
Universidad de Costa Rica
Instituto de Investigaciones
Psicológicas

Mónica Mora B.

monica.morabadilla@ucr.ac.cr
Universidad de Costa Rica
Instituto de Investigaciones
Psicológicas

Graciela Ordóñez G.

graciela.ordonez@ucr.ac.cr
Universidad de Costa Rica
Instituto de Investigaciones
Psicológicas

Recibido: Diciembre 19, 2017

Aceptado: Mayo 1, 2018

Abstract. Este trabajo tiene como objetivo encontrar evidencia que respalde la hipótesis de que el razonamiento cuantitativo es un predictor relevante del rendimiento en cursos introductorios de matemática en carreras de Ciencia, Tecnología, Ingeniería y Matemática (STEM por sus siglas en inglés) controlando variables relevantes en la predicción de este rendimiento. El estudio se realizó en grupos de carreras, determinados por el curso de matemática introductoria compartido: a.) Física, Meteorología y Química ($n=132$), b.) Estadística ($n=64$) y c.) Matemática y Ciencias Actuariales ($n=87$); con n igual a la cantidad de estudiantes por grupo. En cada agrupación se estimó un modelo de regresión lineal con medidas remediales apropiadas para el cumplimiento de los supuestos; la variable dependiente de los modelos fue la nota en el curso introductorio de matemática y las variables independientes fueron: el nivel de razonamiento cuantitativo, un indicador de las notas de secundaria y el examen de admisión, el sexo y la dependencia del tipo de colegio. En todos los modelos se obtuvo que la variable más relevante fue el nivel de razonamiento cuantitativo. Los coeficientes de determinación de los modelos fueron relevantes, ya que fueron superiores a 0.20.

Palabras clave: Razonamiento cuantitativo, carreras STEM, rendimiento académico, matemática universitaria introductoria, homocedasticidad, supuestos de los modelos lineales.

Abstract. The objective of this paper is to find evidence that supports a hypothesis in which the quantitative reasoning is an important predictor of achievement in Science Technology Engineering Mathematics (STEM) careers' initial courses of mathematics, controlled by relevant variables in the prediction of this performance. The investigation used career's groups determined by the shared mathematic

course: a.) Physics, Meteorology and Chemistry (n=132), b.) Statistics (n=64) and c.) Mathematics and Actuarial Sciences (n=87); n represents the amount of student by group. In each group was estimated a linear regression model with remedial methods appropriated for the supposals reach; the dependent variable was the mathematics' initial course grade and the independent variables were quantitative reasoning level, an indicator of the high school achievement grade and the admission test, sex and kind of high school. In all models the most relevant variable was the quantitative reasoning level. The determination coefficients models were relevant, because this were higher than 0.20.

KeyWords: Quantitative reasoning; STEM Careers; Academic achievement; Initial university mathematics; Homocedasticity, Linear model assumptions.

1.1 Introducción

Dwyer, Gallagher, Levin y Morley [4, (2003)] definen el razonamiento cuantitativo como “la habilidad para analizar información cuantitativa y determinar cuáles destrezas y procedimientos pueden ser aplicados para obtener la solución de un problema particular” (Dwyer et al, [4, (2003)], p.1) o simplemente, “la habilidad para resolver problemas matemáticos” (p.13), que no se reducen a la repetición de un proceso memorizado; de esta manera, la resolución de una ecuación lineal para un estudiante que domina este contenido no demanda del razonamiento cuantitativo.

De acuerdo con lo anterior, en el razonamiento cuantitativo la aplicación de un algoritmo es solo un elemento instrumental dentro de la resolución de un problema, lo cual es fundamentado en las investigaciones de Mayes, Peterson y Bonilla [15, (2003)], Embretson y Daniel [5, (2010)] y Shavelson [28, (2008)]. Cabe destacar que para propósitos de medición del razonamiento cuantitativo se debe considerar que el conocimiento del contenido matemático es un elemento instrumental de este constructo. Por lo tanto, el dominio del contenido, específicamente, no debe ser el objetivo de la medición, debido a que el razonamiento cuantitativo se debe medir de acuerdo con los contenidos matemáticos que manejan los examinados (Dwyer et al, Dwyer et al, [4, (2003)]; Mayes et al, [15, (2013)], Embretson y Daniel, [5, (2010)]; Shavelson, [28, (2008)]).

En esta misma línea, Dwyer et al., [4, (2003)] fundamentan que los problemas que requieren del razonamiento cuantitativo abarcan tres pasos: 1) comprender y definir el problema, 2) plantear y ejecutar una estrategia de solución y 3) analizar los resultados. En el primer paso se debe comprender la información y la situación planteada, determinar las condiciones del problema, generar soluciones que se ajusten a algunas de las condiciones, reconocer patrones, generar conjeturas, representar el problema matemáticamente o cambiar de un sistema de representación a otro. En el segundo paso se requiere reconocer cuáles son las estrategias que permiten afrontar el problema y, luego, se debe decidir cuál es la más adecuada y ejecutarla correctamente. En el tercer paso, los sujetos deben trasladar la solución matemática al contexto del problema, evaluar la razonabilidad de la respuesta, determinar los errores cometidos, en caso de que la respuesta no sea razonable, y comunicar los resultados.

Además, Dwyer et al. [4, (2003)] y Rhodes [22, (2010)] mencionan que el razonamiento cuantitativo abarca varias capacidades, entre las cuales están: 1) la representación, que es la habilidad para convertir información relevante en varias formas matemáticas; 2) la interpretación, que se define como la habilidad para explicar la información presentada en forma matemática; 3) cálculo, que es la capacidad

de realizar cálculos esencialmente exitosos y suficientemente complejos para resolver problemas; 4) la comunicación, la cual corresponde a la habilidad para expresar evidencia cuantitativa que respalde un argumento, 5) el análisis, que es la habilidad para realizar juicios y desarrollar conclusiones apropiadas basadas en el análisis cuantitativo de los datos, junto con reconocer los límites de ese análisis; y finalmente, 6) las asunciones, determinada como las habilidades para desarrollar y evaluar hipótesis importantes en la estimación, la modelación y el análisis de datos.

1.2 Planteamiento del problema

Este trabajo tiene como objetivo encontrar evidencia que respalde la hipótesis de que el razonamiento cuantitativo es un predictor relevante del rendimiento en cursos introductorios de matemática en carreras de Ciencia, Tecnología, Ingeniería y Matemática (STEM por sus siglas en inglés), controlando variables relevantes en la predicción del mismo. Para justificar el análisis de esta hipótesis se expone por qué este razonamiento es importante en las carreras STEM a analizar. Además, se discute la relevancia de algunas variables consideradas como predictores del rendimiento académico en cursos de matemática las cuales serán controladas, en la medida de lo posible, en el desarrollo de la investigación.

1.3 Antecedentes

Importancia del razonamiento cuantitativo en carreras STEM

La importancia de la habilidad de razonamiento cuantitativo en las personas que optan por carreras universitarias STEM, se evidencian en las publicaciones efectuadas por Rylands, Simbag, Matthews, Coady y Belward [27, (2013)] y Reid y Wilkes [21, (2016)], las cuales destacan que las habilidades de razonamiento cuantitativo conforman una potencial variable predictiva para el éxito en los cursos de matemática en la universidad en estas carreras.

Por ejemplo, en Ciencias Actuariales y Estadística se requiere de la habilidad para realizar predicciones de gran confiabilidad ante la aleatoriedad de los sucesos futuros (Departamento de Matemáticas UPRH, 2013) lo cual implica que los sujetos deben plantear y ejecutar estrategias de solución de problemas, tal y como lo indican Dwyer et al., [4, (2003)]. Por su parte, en las carreras de Meteorología y Física se requiere que los sujetos evalúen e interpreten datos cuantitativos para emitir juicios de valor de acuerdo con teorías y conceptos básicos del campo (Organización Meteorológica Mundial, [18, (2003)]). Por lo tanto, el razonamiento cuantitativo resulta esencial en la resolución de problemas de índole meteorológico y físico, ya que deben emplear números para cuantificar, modelar fenómenos, sean mediante variables paramétricas o constantes. Además, deben convertir información relevante en varias formas matemáticas para efectuar cálculos y resolver problemas complejos manteniendo las variables y los parámetros como símbolos para garantizar la generalización del fenómeno físico o meteorológico (Quinn, [20, (2013)]; Vinitsky-Pindky y Galilli, [33, (2014)]).

Por otra parte, Romero [25, (2014)], Tariq [30, (2013)] y Wright y Chorin [36, (2014)] indican que en Química se deben utilizar razones y proporciones matemáticas para representar reacciones químicas, modelos atómicos y química cuántica. Asimismo, se debe leer, construir e interpretar información

dada en distintos formatos, esto es mediante tablas, gráficos y números de tal forma que se puedan modelar los fenómenos químicos. Lo descrito por estos autores se relaciona con las habilidades de razonamiento cuantitativo, como comprender, plantear, definir y ejecutar estrategias de solución (Dwyer et al., [4, (2003)]; Embretson y Daniel, [5, (2010)] ; Mayes et al., [15, (2013)]), solo que restringido al ámbito químico.

Variables asociadas con el rendimiento académico en cursos de matemática

Las variables de interés para este estudio son: 1) la dependencia del colegio de procedencia (público-privado); 2) el sexo; 3) las pruebas de admisión a universidades; 4) el promedio en cursos de matemática de secundaria; y, 5) el resultado en pruebas asociadas con el razonamiento cuantitativo; por lo que se presenta un breve recorrido con respecto a investigaciones que se han destacado en el análisis de estas variables. Cabe mencionar que otras variables¹ como el grado académico de los padres, el nivel socioeconómico, el desempeño docente, entre otras que han sido objeto de estudio en otras investigaciones, no forman parte de nuestro interés investigativo.

Con respecto a la dependencia del colegio, varios autores han encontrado que los estudiantes de escuelas privadas presentan un mayor rendimiento en pruebas de matemática que sus contrapartes de colegios públicos (Colorado y Corcino, [2, (2014)]; Lefebvre et al., [13, (2011)]; Sulku y Abdioglu, [29, (2015)]; Lubienski et al., [14, (2015)]). Los factores que pueden justificar esta relación son: la preparación y capacitación de los profesores, la calidad de la enseñanza, las metas y el tipo de orientación de las instituciones, el apoyo institucional y factores socioeconómicos, como el ingreso familiar y el nivel de educación de los padres (Colorado y Corcino, [2, (2014)]). Además, Lefebvre et al. [13, (2011)] señalan que las instituciones privadas tienen mejor promoción debido a los procesos de selección de estudiantes, puesto que se elige a estudiantes de “alta habilidad” como candidatos a ingresar a la institución.

En cuanto al sexo, Voyer y Voyer [34, (2014)] presentan un metanálisis en el que se muestran diversos estudios que controlaron varias variables, por ejemplo: edad, nacionalidad, contenido del curso, nivel socioeconómico y nivel académico; evidenciando una ventaja de las mujeres en el rendimiento académico en general, incluyendo el área de matemática. Similarmente, este resultado se ha constatado en estudios específicos sobre cursos de matemática (Islam y Al-Ghassani, [11, (2015)]; Rojas, [24, (2014)]; Sulku y Abdioglu, [29, (2015)]; Johnson y Kuennen; [12, (2016)]). Desde esta perspectiva, el sexo es un predictor significativo del rendimiento académico en cursos de matemática. Algunas de las causas mencionadas en Voyer y Voyer [34, (2014)] es que las mujeres ponen mayor esfuerzo, el estilo de aprendizaje por sexo, la influencia biológica, la autodisciplina y factores socioculturales que implican que los padres motiven más esfuerzo en las mujeres que en los varones. Es importante recalcar que este resultado no es equivalente a las diferencias observadas en pruebas de matemática según sexo. De hecho, es conocido que, en promedio, los hombres obtienen mejores desempeños en pruebas de matemática que sus contrapartes (González y de la Rica, [6, (2012)]).

Diversas investigaciones (Guglietta y Delgado, [7, (2010)]; Yunker, Yunker y Krull, [37, (2009)]) han encontrado una correlación positiva de las puntuaciones en pruebas de ingreso a las universidades con el rendimiento académico en cursos de perfil cuantitativo. Esta relación se puede justificar en la similitud de algunos procesos de razonamiento que demandan estas pruebas con los procesos requeridos en los cursos introductorios de matemática, como procesos inductivos, deductivos, argumentativos o

¹ Para profundizar en los predictores potenciales del rendimiento académico en matemática referimos al lector al artículo Zhao et al. (2014).

analógicos (Rojas, [24, (2013)]).

Por otro lado, el rendimiento académico en los cursos de matemática en secundaria, también, ha sido señalado como predictor importante del rendimiento académico en cursos universitarios de matemática. Entre las posibles hipótesis para esta relación se menciona que las notas de secundaria son un indicador del nivel de conocimiento de los estudiantes el cual es necesario para desenvolverse exitosamente en los cursos de educación superior (Rylands y Coady, [26, (2013)]; Rylands y Simbag, [27, (2013)]; Tyson, [31, (2011)] y Nicholas y Poladian, [17, (2015)]).

Por último, varios investigadores (White y Sivitanides, [35, (2013)]; Johnson y Kuennen; [12, (2006)]; Veenstra et al., [32, (2009)]; Guglietta y Delgado, [7, (2010)]; Colorado y Corcino, [2, (2014)]; Islam y Al-Ghassani, [11, (2015)]) han encontrado una correlación positiva entre el razonamiento cuantitativo y el rendimiento académico en cursos universitarios de perfil cuantitativo, o con contenido matemático. A continuación, se presentan algunos casos que ejemplifican esta relación. Guglietta y Delgado [7, (2010)] indican que la parte matemática del Graduate Record Examination (GRE) es un predictor importante de materias con perfil cuantitativo. Asimismo, White y Sivitanides [35, (2003)] mostraron que las notas de la parte matemática del American College Test (MACT) y del Scholastic Aptitude Test (MSAT) presentan correlaciones significativamente positivas con el rendimiento académico de un curso introductorio de matemática universitaria. Igualmente, Yunker, Yunker y Krull [37, (2003)] obtuvieron correlaciones positivas de la MACT con el rendimiento académico en un curso introductorio de contabilidad, controlando el nivel de conocimiento matemático. De igual manera, Johnson y Kuennen [12, (2006)] mencionan que el MACT se asocia positivamente con el rendimiento en el curso introductorio de estadística, controlando varias variables (sexo, profesor, motivación y asistencia). Mientras que Rojas [24, (2014)] observó que, al mantener constantes la nota del test de admisión, el sexo y la dependencia del colegio de procedencia, se obtenía que un aumento en la nota de la Prueba de Habilidades Cuantitativas (PHC) se asociaba a una reducción de la probabilidad de reprobación en cursos introductorios de matemática en las carreras de Física, Meteorología, Matemática, Ciencias Actuariales y Farmacia en la Universidad de Costa Rica (UCR). De acuerdo con estas investigaciones el razonamiento cuantitativo se asocia con el rendimiento académico de los sujetos que optan por carreras STEM, ya que dicho razonamiento es importante para realizar procesos como analizar datos, hacer inferencias, resolver problemas e interpretar los resultados de los cálculos.

1.4 Marco metodológico

Método

Esta investigación se enmarca en el paradigma empírico-analítico, el cual tiene como interés describir la realidad factual y se concentra en el análisis de la realidad definida como objetiva (Habermás, [8, (2014)]). Además, se presenta un diseño ex-post-facto, ya que es un estudio con datos previamente recolectados. También, es un estudio correlacional dado que el énfasis del mismo es analizar las asociaciones entre variables. Por último, el estudio considera la lógica del tiempo para una asociación predictiva, ya que las variables predictoras fueron medidas previas al desarrollo de la variable a predecir, el rendimiento en un curso.

Participantes Los casos utilizados en este estudio son las personas que ingresaron a las carreras de Física, Meteorología, Matemática, Ciencias Actuariales, Estadística y Química en la UCR, durante el año 2016 y 2017 y, que además llevaron el curso introductorio de matemática de sus carreras (en el caso de Estadística solo se utilizaron datos del 2016, debido a que en el 2017 cambiaron de plan de estudios). El total de personas que satisfizo esta condición fue de 283. La distribución por sexo fue 113 mujeres y 170 hombres; por dependencia del colegio de procedencia fue 120 de colegio privado y 163 de colegio público; y, por carrera fue de 63 de Física, 4 de Meteorología, 27 de Matemática, 60 de Ciencias Actuariales, 65 de Química y 64 de Estadística.

Instrumentos La PHC es un instrumento, desarrollado por un equipo académico del Instituto de Investigaciones Psicológicas (IIP) de la UCR, para seleccionar a los estudiantes con mayores probabilidades de éxito en carreras que requieren del uso de la matemática, particularmente carreras STEM. La prueba se empezó a construir partir del 2005 y fue implementada hasta el 2015 para el proceso de admisión del 2016. Las carreras que utilizaron esta prueba en su primera aplicación fueron Matemática, Ciencias Actuariales, Física, Meteorología, Química, Estadística y Farmacia.

La PHC está conformada por 40 ítems de selección única con cuatro alternativas. Está dividida en cuatro secciones de 10 ítems, definidas por el área de contenido de los reactivos: Análisis de datos, Aritmética, Álgebra y Geometría. El tiempo de resolución otorgado a los examinados es de una hora con cuarenta y cinco minutos. Además, la nota en esta prueba es utilizada para definir requisitos especiales de ingreso para las carreras señaladas.

Los formularios de la Prueba de Habilidades Cuantitativas utilizados en este trabajo fueron los aplicados en el 2015 y el 2016. Los dos formularios mostraron evidencias de que los ítems evaluaban un único constructo, ya que el Análisis Factorial Confirmatorio asociado a la unidimensionalidad (modelo en el que todos los ítems cargan en un único factor) presentó índices de ajuste aceptables ($RMSEA < 0.05$, $CFI > 0.95$ y $TLI > 0.95$). En los dos formularios se obtuvo que 39 de los 40 ítems de la prueba cargaban en el factor general. Por otro lado, el alfa de Cronbach de la prueba fue de 0.87 y 0.86, para los años 2015 y 2016, respectivamente. Además, en ambos años, los índices de dificultad de los ítems, según la Teoría de Respuesta al Ítem de dos parámetros, oscilaron entre -2 y 2 (exceptuando aquellos ítems que no cargaron en el factor general, mencionados previamente) y, la mayoría de los ítems presentaron discriminaciones superiores a 0.30.

También se utilizó el promedio de admisión, que es un promedio de la nota del examen de admisión a la UCR (Prueba de Aptitud Académica) y la nota de presentación (un indicador de las notas en los últimos años de secundaria) expresado en una escala cuya media es 500 y cuya desviación estándar es 100. Este promedio es el indicador utilizado por la UCR para asignar los campos de cada carrera entre los aspirantes que satisfacen las condiciones establecidas para el concurso.

Procedimientos Para alcanzar el objetivo del estudio se dividió la población en grupos de carreras que compartían el curso introductorio de matemática en su carrera, estos grupos fueron: a) Física, Meteorología y Química, b) Estadística y c) Matemática y Ciencias Actuariales. El primer grupo lleva un curso de cálculo en una variable; el segundo, un curso de matemática elemental; y el tercero, uno de introducción a las demostraciones. Para una mayor fluidez de lectura estos grupos se denominan a) Física y Química, b) Estadística y c) Matemática, respectivamente. En cada uno de estos grupos se realizó un análisis de regresión lineal cuya variable dependiente fue la nota del curso introductorio de

matemática y cuyas variables independientes fueron: la nota en la PHC, el promedio de admisión, el sexo y la dependencia del colegio de procedencia del examinado. En estos análisis, la nota de la PHC del 2016 se llevó a la escala de la nota del 2015 por medio del método de equiparación de Haebara. Para realizar los tres modelos de regresión lineal se verificó que hubiese evidencia que respaldara el cumplimiento de los supuestos básicos de esta técnica estadística: igualdad de las varianzas de los errores en cada nivel de la variable dependiente (homocedasticidad), normalidad de los residuos, independencia de los errores, independencia de las variables predictoras y asociación lineal de los predictores con la variable dependiente (Cea, 2002). La estimación de las regresiones lineales se realizó con el software R en su versión 3.3.2.

1.5 Resultados

Primeramente, es importante mencionar que las agrupaciones de carreras presentaron una cantidad aceptable de personas en los distintos grupos determinados por las variables dicotómicas consideradas (sexo y dependencia del colegio). Por otro lado, en la tabla 1 se puede observar que la carrera de Estadística presentó menores medias en el número de ítems correctos de la PHC y en el promedio de admisión que el resto de las agrupaciones consideradas. Mientras que la agrupación de Matemática fue la que presentó el promedio en el curso introductorio de matemática más bajo. Además, las variables cuantitativas, según agrupación de carreras, mostraron una distribución alrededor de sus medias.

Tabla 1.1: Estadísticas descriptivas según agrupación de carreras

Agrupación de carreras	% Hombres	% Col. Priv.	Media PHC	Media P.Ad.	Media curso	N
Fís. y Quím.	62%	47%	26.18	659.54	6.88	132
Estadística	48%	33%	16.64	578.57	6.70	64
Matemática	66%	43%	26.13	663.38	4.70	87

PHC = Número de ítems correctos de la Prueba de Habilidades Cuantitativas, su variación es de 0 a 40.

P.Ad. = Promedio de admisión, su variación es de 200 a 800.

Curso = Curso inicial de matemática de la agrupación de carreras, su variación es de 0 a 10.

Luego de la revisión de las variables, se procedió a realizar los análisis predictivos de las notas de los cursos. En el caso de la agrupación de Física y Química, primeramente, se estimó una regresión por mínimos cuadrados ordinarios (OLS, por sus siglas en inglés: Ordinary Least Squares). No obstante, esta regresión presentó problemas de heteroscedasticidad y violación a la normalidad. Estos problemas se evidencian en las pruebas estadísticas de Breush-Pagan y de Kolmogórov-Smirnov. En la primera se rechazó la hipótesis de que los residuos fueran homocedásticos ($X^2 = 10.96$, $p < 0.05$) y en la segunda se rechazó la hipótesis de que los residuos se distribuyeran normalmente ($D = 0.15$, $p < 0.01$). De igual forma, el análisis gráfico de los residuos, presentado en la figura 1, muestra que la estimación por OLS genera residuos heterocedásticos (en particular, se observa una varianza decreciente de los residuos según nivel de valor predicho) y lejanos a la normalidad (el gráfico de cuantiles observados contra cuantiles teóricos se aleja de la recta identidad).




Figura 1.1: Gráfico de residuos de los modelos de regresión para Física y Química

Los gráficos de la izquierda corresponden al modelo estimado con Mínimos Cuadrados Ordinarios (OLS) y los de la derecha al modelo con la variable dependiente elevada al cuadrado. Los gráficos de la primera fila muestran los residuos estandarizados contra los valores predichos y los de la segunda fila, los cuartiles obtenidos en la muestra contra los cuartiles teóricos de una distribución normal.

Para solventar esta violación de los supuestos se procedió a analizar si una transformación de Box-Cox de la variable dependiente permitía el cumplimiento de los supuestos (Neter, Kutner, Nachtsheim y Wasserman, 1996). El estudio de los distintos casos de Box-Cox sugirió el uso de la transformación cuadrática. Luego de implementar esta sugerencia se obtuvo evidencia de que el supuesto de normalidad se satisfizo, tanto por la prueba de Kolmogórov-Smirnov ($D=0.09$, $p=0.23$), como por el análisis gráfico. Esto último se puede observar en la figura 1, ya que los pares ordenados definidos por los cuantiles observados en los residuos y los cuantiles teóricos de una distribución normal se asemejan a la recta identidad. Con respecto al problema de la heterocedasticidad se obtuvo que la prueba de Breush-Pagan siguió rechazando la hipótesis de homocedasticidad ($X^2 = 11.91$, $p < 0.05$), no obstante, el gráfico de residuos mostró una mejoría considerable en la variabilidad de los residuos. Por tanto, se consideró que este modelo era aceptable para la interpretación.

En la tabla 2 se puede observar que en el modelo estimado con la transformación de Box-Cox, la variable más importante en la predicción de la nota del curso introductorio de matemática fue la PHC, ya que presentó el coeficiente estandarizado más alto, cuyo valor fue 0.37. Este coeficiente indica que si la puntuación en la PHC se aumenta en una desviación estándar y las demás variables se mantienen constantes, el cuadrado de la nota del curso se aumenta en 0.37 desviaciones estándares. La siguiente variable más importante fue el promedio de admisión, mientras que las otras dos variables consideradas no fueron importantes (coeficientes estandarizados menores a 0.10). Por otro lado, el coeficiente de determinación de este modelo indica que un 31% de la variabilidad del cuadrado de la nota del curso introductorio de matemática es explicada por el modelo. Finalmente, la prueba F resultó significativa, lo cual quiere decir que se rechazó la hipótesis de que todos los coeficientes de regresión de

las variables utilizadas sean nulos.

La principal diferencia entre los dos modelos fue el coeficiente asociado a la PHC, con OLS 0.07 unidades estandarizadas más bajo que en el modelo con la transformación. Por otro lado, el coeficiente de determinación (R^2) también aumentó en la búsqueda de un modelo más adecuado, ya que se pasó de 0.23 a 0.31.

Variabes	OLS		Y^2	
PHC	0.30	***	0.37	***
Pr. Admisión	0.22	**	0.22	**
Mujer	-0.09		-0.09	
Colegio público	0.04		0.03	
Ajuste				
R^2	0.23	n.a.	0.31	n.a.
F del test de ajuste	9.46	***	14.14	***
Supuestos				
X^2 de Breush-Pagan	10.96	**	11.91	**
D de Kolmogórov-Smirnov	0.15	***	0.09	

OLS: Modelo inicial, Y^2 : Modelo final, en el cual la variable dependiente fue elevada al cuadrado.
 ** $p < 0.05$,
 *** $p < 0.01$,
 n.a. no presenta prueba estadística asociada.

Tabla 1.2: Coeficientes estandarizados e índices de ajuste de los modelos de regresión para la agrupación Física y Química

Con respecto a los modelos para Estadística y Matemática, se obtuvo que la estimación por OLS arrojó resultados que no evidenciaron incumplimiento de los supuestos de la regresión lineal, por lo cual no fue necesario realizar transformaciones o técnicas adicionales. Los resultados de estas estimaciones se presentan en la tabla 3. Al igual que en el modelo para Física y Química, la variable más importante fue la puntuación en la PHC.

Tabla 1.3: Coeficientes estandarizados e índices de ajuste de los modelos de regresión para Estadística y Matemática

Variabes	Estadística		Matemática	
PHC	0.48	***	0.42	***
Pr. Admisión	-0.06		0.25	
Mujer	0.32	***	0.16	
Colegio público	-0.20		0.24	**
Ajuste				
R^2	0.27	n.a.	0.35	n.a.
F del test de ajuste	5.37	***	10.91	***
Supuestos				
X^2 de Breush-Pagan	8.61		3.39	
D de Kolmogórov-Smirnov	0.11		0.09	

** $p < 0.05$,
 *** $p < 0.01$,
 n.a. no presenta prueba estadística asociada.

En el modelo de Estadística se obtuvo que la segunda variable más importante fue el sexo y la tercera fue la dependencia del colegio. En particular, si se controlan las variables consideradas, las mujeres

tienden a obtener mejores promedios que los hombres y los estudiantes provenientes de colegio público menores promedios que los de colegios privados. No obstante, en el último caso se encontró que esta hipótesis no fue significativa ($p=0.11$). Por otro lado, el modelo presentó un porcentaje de explicación de las notas del curso introductorio de matemática de un 27%.

En cuanto al modelo de Matemática, la segunda variable más importante fue el promedio de admisión (aunque esta variable no fue significativa, $p=0.09$) y luego, el tipo de colegio. A partir de lo último, se concluye que, si se controlan todas las variables, los estudiantes provenientes de colegios públicos obtienen mejores notas en el curso de ingreso que aquellos de colegios privados. Finalmente, este modelo presentó el porcentaje de explicación de la variabilidad del curso más alta, el valor alcanzado fue de 35%.

1.6 Discusión y conclusiones

Primeramente, se debe mencionar que en todos los modelos finales la variable más importante fue la PHC, lo cual es una evidencia de que el razonamiento cuantitativo es una variable relevante para la predicción del rendimiento en cursos introductorios de matemática en carreras STEM tal y como lo indican Mayes, Peterson y Bonilla (2013). Lo anterior indica que, aun controlando por el sexo, la dependencia del colegio de procedencia, el promedio de notas en secundaria y la nota en el examen de admisión, se observa que a mayor nivel de razonamiento cuantitativo hay un mejor rendimiento en los cursos en cuestión. Este resultado coincide con lo hallado en las investigaciones presentadas en la introducción y apoya el uso del nivel de razonamiento cuantitativo como indicador para la selección de los estudiantes de carreras STEM. Además, este resultado es esperable teóricamente, dado que la estructura del razonamiento cuantitativo evidencia la necesidad de este constructo en los cursos introductorios de matemática.

La segunda variable más relevante en los modelos varió según agrupación de carreras. En Física y Química y en Matemática fue el promedio de admisión, aunque en Matemática no fue significativa. La alta importancia de esta variable también era esperable, debido a que es un indicador que se compone de dos predictores importantes del rendimiento académico universitario: el rendimiento académico previo y la nota de una prueba que evalúa habilidades de razonamiento en contextos verbales y matemáticos, las cuales son necesarias para un desempeño exitoso en carreras universitarias (PPPAA, 2014).

En Estadística, la segunda variable más importante fue el sexo. Al igual que en la literatura consultada, estos modelos indicaron que, si se controlan todas las covariables, las mujeres presentan un mayor rendimiento que los hombres en los cursos introductorios de matemática. Este resultado indica que las características del curso utilizado en Estadística brindan una condición que favorece al desempeño de las mujeres, lo cual supera las condiciones difíciles que encuentran muchas mujeres en las carreras STEM (Hughes, 2011). Una hipótesis relacionada a este resultado puede estar asociada al contenido al curso, ya que se ha documentado que las mujeres presentan mejores rendimientos que los hombres en los ejercicios correspondientes a la reproducción de algoritmos (De Lisi, Holst, McGillicuddy-De Lisi, Morely y Cahalan, 2000), lo cual es parte fundamental del curso introductorio de Estadística (este curso se enfoca en álgebra básica e introducción a las funciones).

Por otro lado, la dependencia del tipo de colegio solo fue significativa en el modelo de Matemática, con una ventaja para los estudiantes provenientes de colegios públicos. Este comportamiento inesperado puede deberse a las características particulares de la muestra. No obstante, hay que resaltar que las particularidades del curso llevado por Matemática posibilitan un escenario en el que los estudiantes provenientes de colegios públicos sobresalgan. Entre estas particularidades destacan la escasa dependencia de los contenidos de la educación secundaria.

La poca importancia de las variables dicotómicas utilizadas en los modelos (sexo y dependencia de colegio) refleja que el rendimiento en los cursos está asociado principalmente a variables relacionadas con las habilidades del estudiante. Por otro lado, las variables no asociadas con las necesidades del curso resultaron poco importantes en la predicción de las notas, lo cual es un aspecto positivo desde el enfoque de igualdad de oportunidades educativas. Es decir, el sexo y la dependencia del colegio de procedencia tienen poca importancia para tener éxito en estos cursos, ya que el mayor peso recae en las habilidades requeridas por el curso.

El ajuste de los modelos finales a los datos resultó satisfactorio, puesto que en todos se encontraron evidencias que sustentaban el cumplimiento de los supuestos. Además, los coeficientes de determinación presentaron valores superiores a 0.25 y las pruebas F resultaron significativas a un nivel del 5%, lo cual respaldó que los modelos efectivamente se ajustaron a los datos. Esto muestra que las variables utilizadas en las regresiones lineales son pertinentes para predecir el rendimiento en los cursos introductorios de matemática de carreras STEM, en especial, el nivel de razonamiento cuantitativo.

Luego, es importante mencionar que en este estudio se procuró utilizar la regresión lineal acorde a los supuestos estadísticos subyacentes a esta técnica, ya que el incumplimiento de los supuestos obstaculiza las interpretaciones estadísticas. En particular, el modelo para Física y Química presentó una violación a la normalidad y la homocedasticidad, las cuales fueron paliadas con la implementación de una transformación de Box-Cox.

Por último, la heterocedasticidad observada en el modelo de Física y Química indicó que la varianza de los residuos decrecía conforme se aumentaba el valor de los valores predichos por la regresión, lo cual se suele denominar como una tendencia en forma de megáfono en el gráfico de predichos contra residuos. Este resultado indica que la precisión de la predicción de notas bajas es menor que la predicción de las notas altas, lo cual es esperable si se considera que la población de notas bajas está más influenciada por variables confusoras que sus contrapartes. Por ejemplo, deserción o falta de estudio, es decir, un sujeto con el perfil para obtener una buena nota en el curso puede presentar una mala nota porque lo abandonó o dejó de estudiar para el mismo, en cambio, la presencia de estas variables en aquellos que aprobaron el curso es poco probable. Este hallazgo debe ser considerado por los estudios de rendimiento académico, ya que su omisión puede llevar a conclusiones erróneas.

Bibliografía

-
- [1] Cea, M. A. *Análisis Multivariante: Teoría y práctica en la investigación social*. Madrid: Síntesis. 2012.
 - [2] Colorado, R. y Corcino, L. *Diferencias en el desempeño académico y en los predictores de éxito universitario por escuela de procedencia*. *Pedagogía*. 47 (1), 159-191. 2014.
 - [3] De Lisi, R., Holst, P. C., McGillicuddy-De Lisi, A. V., Morely, M. y Cahalan, C. *Gender differences in advanced mathematical problem solving*. *Journal of experimental psychology*, 75, 165-190. 2000.

- [4] Dwyer, C.; Gallagher, A.; Levin, J. y Morley, M. *What is Quantitative Reasoning? Defining the Construct for Assessment Purposes*. Research Reports. Educational Testing Service. Princeton, NJ. 2003.
- [5] Embretson, S., Daniel, R. Designing Cognitive Complexity in Mathematical Problem Solving Items. *Applied Psychological Measurement*. 34 (5), 348-364. 2010.
- [6] González, A. y de la Rica, S. Gender Gaps in PISA Test Scores: The Impact of Social Norms and the Mother's Transmission of Role Attitudes. *IZA Discussion Paper*, 6338. 2012.
- [7] Guglietta, L. y Delgado, C. *Validez de constructo de un modelo de admisión a posgrado. Un análisis de ruta*. Revista Galego-portuguesa de psicología e educación. 18 (1), 227-237. 2010.
- [8] Habermás, J. *Conocimiento e Interés* (M. Jiménez, trad.). En Quitás, G. (Comp.), *Conocimiento e Interés/La filosofía en la crisis de la humanidad europea* (pp. 31-47). Valencia: Universidad de Valencia (Obra original publicada en 1968). 1997.
- [9] Hegener, M., Buring, S., y Papas, E. *Impact of a Required Pharmaceutical Calculations Course on Mathematics Ability and Knowledge Retention*. *American Journal of Pharmaceutical Education*. 77 (6), 124. 2013.
- [10] Hughes, R. *Are the Predictors of Women's Persistence in STEM Painting the Full Picture? A Series of Comparative Case Studies*. *International Journal of Gender, Science and Technology*, 3(3), 548-570. 2011.
- [11] Islam, M. y Al-Ghassani, A. *Predicting college math success: do high school performance and gender matter? Evidence from Sultan Qaboos University in Oman*. *International Journal of higher educations*. 4 (2). 2015.
- [12] Johnson, M. y Kuennen, E. *Basic math skills and performance in an introductory statistics course*. *Journal of statistics education*. 14 (2). 2016.
- [13] Lefebvre, P., Merrigan, P., y Verstraete, M. *Public subsidies to private schools do make a difference for achievement in mathematics: longitudinal evidence from Canada*. *Economics of Education Review*, 30(1), 79-98. 2011.
- [14] Lubienski, S., Lubienski, C., y Crane, C. *Achievement differences and school type: The role of school climate, teacher certification, and instruction*. *American Journal of Education*, 115(1), 97-138. 2008.
- [15] Mayes, R., Peterson, F., Bonilla, R. *Quantitative Reasoning Learning Progressions for Environmental Science: Development a Framework*. *Numeracy*. 6 (4)1-28. 2013.
- [16] Neter, J., Kutner, M. H., Nachtsheim, C. J. y Wasserman, W. *Applied Linear Statistical Models* (Cuarta edición). New Jersey: McGraw-Hill. 1996.
- [17] Nicholas, J., Poladian, L., Mack, J., y Wilson, R. *Mathematics preparation for university: entry, pathways and impact on performance in first year science and mathematics subjects*. *International Journal of Innovation in Science and Mathematics Education (formerly CAL-laborate International)*, 23(1), 37-51. 2015.
- [18] Organización Meteorológica Mundial. Consultado en Enero del 2017. En línea http://www.wmo.int/pages/index_es.html. 2012.
- [19] PPPAA (2014). Prueba de Aptitud Académica. En Smith, V. (Ed.), *Compendio de Instrumentos de Medición del IIP-2014*. 2014.
- [20] Quinn, R. *"Students' Confidence in the Ability to Transfer Basic Math Skills in Introductory Physics and Chemistry Courses at a Community College"*. Consultado en enero del 2017. En línea en The Aquila Digital Community. The University of Southern Mississippi. 2013.
- [21] Reid, J., y Wilkes, J. *Developing and applying quantitative skills maps for STEM curricula, with a focus on different modes of learning*. En *International Journal of Mathematical Education in Science and Technology*. 2016.
- [22] Rhodes, T. L. (Ed.) *Assessing outcomes and improving achievement: Tips and tools for using rubrics*. Washington, DC: Association of American Colleges and Universities. 2010.

- [23] Rojas, L. *Validez predictiva de los componentes del promedio de admisión a la Universidad de Costa Rica utilizando el género y el tipo de colegio como variables control*. Revista Electrónica "Actualidades Investigativas en Educación", 13(1), 1-24. 2013.
- [24] Rojas, L. *Predicción de la reprobación de cursos de matemática básicos en las carreras de Física, Meteorología, Matemática, Ciencias Actuariales y Farmacia*. Revista Electrónica Educare, 18(3), 3-15. 2014.
- [25] Romero, N. *Relaciones cuánticas y proporcionalidad*. Universidad Nacional de Colombia. Trabajo de investigación para optar al grado de Magister en Enseñanza de las Ciencias Exactas y Naturales. 2014.
- [26] Rylands, L. y Coady, C. *Performance of students with weak mathematics in first-year mathematics and science*. International Journal of Mathematical Education in Science and Technology, 40(69), 741-753. 2009.
- [27] Rylands, L., Simbag, V., Matthews, K., Coady, C. y Belward, S. *Scientists and mathematicians collaborating to build quantitative skills in undergraduate science*. International Journal of Mathematical Education in Science and Technology, 44(69), 834-845. 2013.
- [28] Shavelson, R. *Reflections on Quantitative Reasoning: An Assessment Perspective*. In Calculation vs context: Quantitative literacy and its implications for teacher education, eds. B. L. Madison, and L. A. Steen. Mathematical Association of America. 22-47. Washington. 2008.
- [29] Sulku, S., y Abdioglu, Z. *Public and Private School Distinction, Regional Development Differences, and Other Factors Influencing the Success of Primary School Students in Turkey*. Educational Sciences: Theory and Practice, 15(2), 419-431. 2015.
- [30] Tariq, V. *Quantitative skills in science*, International Journal of Mathematical Education in Science and Technology, 44:6, 779-781. 2013
- [31] Tyson, W. *Modeling engineering degree attainment using high school and college physics and calculus coursetaking and achievement*. Journal of Engineering Education, 100(4), 760-777. 2011.
- [32] Veenstra, C., Dey, E., y Herrin, G. *A model for freshman engineering retention*. Advances in Engineering Education, 1(3), 1-31. 2009.
- [33] Vinitsky-Pindky, L., y Galili, I. *The need to clarify relationship between Physics and Mathematics in Science Curriculum: Cultural Knowledge as possible Framework*. En línea Procedia - Social and Behavioral Sciences (611 – 616). 2014.
- [34] Voyer, D. y Voyer, S. *Gender Differences in Scholastic Achievement: A Meta-Analysis*. Psychological Bulletin. Advance online publication. 2014.
- [35] White, G. y Sivitanides, M. *An empirical investigation of the relationship between success in mathematics and visual programming courses*. Journal of information systems education. 14 (4), 409-416. 2003.
- [36] Wright, M., y Chorin, A. *Mathematics and Science*. National Science Foundation Report. 2000.
- [37] Yunker, P. y Yunker, J. Krull, G. *The influence of mathematics ability on performance in principles of accounting*. The accounting educators journal. XIX, 1-20. 2009.
- [38] Zhang, G., y Anderson, T., Ohland, M., y Thorndyke, B. *Identifying Factors Influencing Engineering Student Graduation: A Longitudinal and Cross-Institutional Study*. Journal of Engineering Education, 93 (4), 313-320. 2004.
- [39] Zhao, N., Valcke, M., Desoete, A., Zhu, C., Sang, G., y Verhaeghe, J. *A holistic model to infer mathematics performance: the interrelated impact of student, family and school context variables*. Scandinavian Journal of Educational Research, 58(1), 1-20. 2014.