



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO  
PROGRAMA DE POSGRADO EN ECONOMÍA**

**INSTITUTO DE INVESTIGACIONES ECONÓMICAS ♦ DIVISIÓN DE ESTUDIOS DE POSGRADO**

**Modelación de la calificación de deuda soberana para economías en desarrollo y sus  
determinantes subjetivos 1995-2017.**

**Tesis**

**QUE PARA OPTAR POR EL GRADO DE:  
Maestro en Economía**

**PRESENTA:**

**Elías Ulloa Moreno**

**TUTORA PRINCIPAL**

**DRA. ALICIA ADELAIDA GIRÓN GONZÁLEZ**

**INSTITUTO DE INVESTIGACIONES ECONÓMICAS ♦ DIVISIÓN DE ESTUDIOS DE POSGRADO**

**(CDMX, Octubre 2023)**



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



# Universidad Nacional Autónoma de México

INSTITUTO DE INVESTIGACIONES  
ECONÓMICAS  
DIVISIÓN DE ESTUDIOS DE POSGRADO

Modelación de la calificación de deuda soberana para economías en  
desarrollo y sus determinantes subjetivos 1995-2017.

## T E S I S

que para optar por el grado de  
Maestro en Economía

PRESENTA:  
Elías Ulloa Moreno

Tutor Principal:  
Dra. Alicia Adelaida Girón González

México, CDMX. (Octubre) 2023

## ÍNDICE

Resumen	2
Abstract	2
1.-Introducción	3
2.- Revisión de literatura	7
3.- Metodología y datos	11
4.- Resultados	28
5.- Conclusiones	40
Agradecimientos	46
Bibliografía	46
Apéndice estadístico	50

## ÍNDICE DE GRÁFICOS

Figura 1	13
Figura 2	35
Figura 3	37
Figura 4	50
Figura 5	51
Figura 6	52
Figura 7	53
Figura 8	54
Figura 9	54
Figura 10	55
Figura 11	56
Figura 12	57
Figura 13	58
Figura 14	59
Figura 15	60
Figura 16	61
Figura 17	61
Figura 18	62
Figura 19	63

## ÍNDICE DE TABLAS

Cuadro 1	16
Cuadro 2	21
Cuadro 3	22-23
Cuadro 4	25
Cuadro 5	29
Cuadro 6	30
Cuadro 7	32
Cuadro 8	64

## RESUMEN

Este estudio presenta una exploración exhaustiva de los factores que influyen en las calificaciones crediticias soberanas, con especial enfoque en países en desarrollo. Empleando técnicas avanzadas de Análisis de Clases Latentes y Modelos de Bosques Aleatorios, se identifica una interacción significativa entre elementos cuantitativos y cualitativos en la determinación de las calificaciones crediticias. Los resultados revelan que variables económicas clave, como el Producto Interno Bruto real per cápita, junto con factores institucionales como la protección legal de la propiedad y la percepción de corrupción, son predictores críticos de las calificaciones. Además, el estudio destaca la importancia de la calidad institucional y la estabilidad económica, evidenciando una relación causal entre estas y el riesgo crediticio soberano. La aplicación de modelos de Bosques Aleatorios, particularmente, demuestra una precisión notable en la predicción de calificaciones crediticias, superando a los métodos tradicionales. Estos hallazgos ofrecen perspectivas valiosas para los gobiernos, inversores e instituciones financieras, sugiriendo una mayor consideración de la dinámica económica e institucional en la evaluación del riesgo crediticio soberano.

## ABSTRACT

This study provides an in-depth analysis of the determinants of sovereign credit ratings, with a particular focus on developing countries. Utilizing advanced techniques such as Latent Class Analysis and Random Forest Models, it identifies a significant interplay between quantitative and qualitative factors in determining credit ratings. The results reveal that key economic variables, like Real Gross Domestic Product per capita, along with institutional factors such as legal protection of property and perceptions of corruption, are critical predictors of the ratings. Moreover, the study underscores the importance of institutional quality and economic stability, demonstrating a causal relationship between these and sovereign credit risk. The application of Random Forest models, in particular, shows notable precision in predicting credit ratings, surpassing traditional methods. These findings offer valuable insights for governments, investors, and financial institutions, suggesting a greater consideration of economic and institutional dynamics in assessing sovereign credit risk.

## 1. INTRODUCCIÓN

Una calificación crediticia soberana es una evaluación del riesgo crediticio de un país y da una indicación de la probabilidad de que el país pueda cumplir con las obligaciones contractuales del préstamo. Estas calificaciones tienen una gran influencia en la tasa de interés a la que los gobiernos pueden emitir nueva deuda y, por lo tanto, un gran efecto en el gasto y el déficit públicos. Las calificaciones crediticias soberanas generalmente las otorga una de las tres agencias de calificación crediticia (CRA): Moody's, S&P y Fitch. Estas agencias utilizan una combinación de factores objetivos y subjetivos para determinar la calificación; sin embargo, la metodología de calificación exacta y los factores determinantes siguen sin conocerse. Esta falta de transparencia ha resultado en críticas generalizadas a las CRA.

Las calificaciones crediticias soberanas reflejan la solvencia de los gobiernos o la probabilidad de que paguen sus deudas. Estas agencias de calificación crediticia suelen asignar calificaciones y decidir cambios de calificación teniendo en cuenta varios factores cuantitativos y cualitativos. Una gran cantidad de literatura trata de identificar los determinantes de las calificaciones crediticias soberanas (Afonso, 2003; Cantor & Packer, 1996), así como los indicadores de factores cualitativos, es decir, la opinión del comité de calificación crediticia (De Moor et al., 2018; Ozturk et al., 2016). Sin embargo, el alcance del razonamiento cuantitativo no está claro. Todas las agencias de calificación crediticia señalan que sus calificaciones son simplemente una opinión (Moody's, 2016; Fitch, 2017; Standard and Poor's, 2017). A pesar de la creciente demanda de transparencia del proceso de calificación crediticia, persisten las discrepancias y la falta de claridad, las agencias calificadoras de deuda han sido acusadas, entre otras cosas, de dar calificaciones sesgadas (Luitel et al., 2016), reaccionar lentamente a las circunstancias cambiantes y de tener un comportamiento procíclico (Ferri et al., 1999).

Durante las últimas décadas, facilitadas por las inversiones transfronterizas cada vez mayores, la desregulación financiera y la liberalización, las calificaciones crediticias han adquirido una importancia vital y se han convertido en un componente esencial del sistema financiero mundial. Las calificaciones crediticias se han integrado cada vez más en los contratos financieros, se han convertido en una parte indispensable de los mandatos de inversión de los inversores institucionales y son un indicador clave para

la clasificación de valores. Los cambios en la calificación crediticia o las señales de perspectiva tienen un efecto innegable en los procedimientos de toma de decisiones de los actores financieros globales; por lo tanto, provocan reponderaciones de carteras globales, reasignación de capital, cambios en la liquidez del mercado y fluctuaciones en el costo y flujo de fondos,

Debido a estos factores, los mercados financieros se han vuelto cada vez más dependientes de estas calificaciones crediticias. Esta notable influencia de las calificaciones crediticias en los mercados financieros también ha aumentado el riesgo de consecuencias sistémicas indeseables (Williams et al., 2013). Se ha argumentado ampliamente que un anuncio de calificación desfavorable puede desencadenar una reacción en negativa en cadena, empeorando así las variables económicas del país y provocando posteriores rebajas de calificación. Este tema fue enfatizado particularmente a raíz de la crisis financiera de 2008 y la posterior crisis de la deuda europea. Aunque existe una gran cantidad de literatura sobre muchos aspectos de las calificaciones crediticias y las agencias de calificación crediticia, la relación causal entre el riesgo crediticio soberano y el riesgo económico para los países en desarrollo no se ha investigado a fondo.

Comprender la metodología de calificación y los factores determinantes sería muy útil para los gobiernos, los inversionistas y las instituciones financieras. Los gobiernos podrían anticipar posibles cambios de calificación, mientras que los inversores y las instituciones financieras podrían verificar si las calificaciones se desvían de lo que implican las variables económicas del país.

Para comprender el proceso de calificación crediticia, se necesita un modelo que pueda predecir las calificaciones, idealmente con alta precisión. Hasta hace algunos años, la investigación se ha centrado principalmente en modelar las calificaciones crediticias soberanas utilizando varias formas del modelo ordenado probit/logit (OP/OL), que asume una forma funcional particular para la relación entre una combinación lineal de las variables de entrada y el modelo continuo, ver, por ejemplo, Cantor y Packer (1996), Dimitrakopoulos y Kolossiatis (2015), Reusens y Croux (2017). Estos modelos permiten una fácil interpretación de los factores determinantes y demuestran ser bastante precisos, pero tienen el costo de que la relación lineal que asumen podría no siempre mantenerse. Por lo tanto, una rama reciente de la investigación se ha centrado en el uso

de técnicas de aprendizaje automático (ML) para modelar las calificaciones crediticias soberanas (Bennell et al., 2006; Ozturk et al., 2015, 2016). Ozturk et al. (2015, 2016) muestran que los modelos ML superan a los modelos lineales en precisión predictiva, a veces por un amplio margen de certidumbre.

A pesar de ser conscientes de los problemas ya descritos, los países o gobiernos emisores confían en las agencias de calificación crediticia y las calificaciones crediticias soberanas, ya que dan una señal clara y relativamente confiable a los mercados de capitales internacionales sobre su solvencia. Calificaciones más altas se traducen en menores costos de endeudamiento y viceversa. En consecuencia, los cambios en las calificaciones crediticias soberanas son igualmente importantes, si no más, ya que conducen al deterioro o la mejora de sus costos de endeudamiento en el futuro. De particular importancia es la transición entre el grado de inversión y especulativo, Kiff et al. (2010) encuentra evidencia de que este punto de quiebre de transición tiene efectos significativos en los diferenciales de CDS.

Ser capaz de comprender los determinantes complejos de las transiciones de calificación más allá de los elementos cuantitativos y cualitativos bien establecidos tendría beneficios significativos para los emisores e inversores. Ambos podrían evaluar mejor el impacto potencial de los cambios en el sentimiento y la subjetividad cuando se trata de transiciones de calificación. Algunos estudios intentan estimar matrices de transición soberana ( ver, por ejemplo, Hill et al., 2010; Hu et al., 2002), pero enfrentan limitaciones principalmente debido a la escasez de datos. Sin embargo, el problema subyacente persiste, a saber, que el juicio cualitativo del comité de calificación no se refleja en los determinantes tradicionales de las calificaciones crediticias soberanas.

En este sentido, la importancia del tema radica en la influencia significativa que las calificaciones crediticias soberanas ejercen sobre las economías nacionales y globales. Estas calificaciones afectan las tasas de interés a las que los gobiernos pueden emitir nueva deuda, impactando así el gasto y el déficit públicos. Además, las calificaciones crediticias soberanas son un componente esencial del sistema financiero mundial, ya que se integran en contratos financieros, son indispensables en los mandatos de inversión de los inversores institucionales y constituyen un indicador clave para la clasificación de valores. A pesar de la relevancia de las calificaciones crediticias, las metodologías



y factores determinantes empleados por las agencias de calificación crediticia no son del todo transparentes, lo que ha generado críticas y cuestionamientos en torno a su objetividad y fiabilidad.

Los objetivos de este estudio son analizar los determinantes cuantitativos y cualitativos de las calificaciones crediticias soberanas, así como investigar la relación causal entre el riesgo crediticio soberano y el riesgo económico, especialmente en el caso de los países en desarrollo. Además, se buscará comprender la metodología de calificación y los factores determinantes para que gobiernos, inversionistas e instituciones financieras puedan anticipar posibles cambios de calificación y verificar si las calificaciones se desvían de lo que las variables económicas del país implican.

Las preguntas de investigación que se abordaran en este estudio son: ¿Cuáles son los principales determinantes cuantitativos y cualitativos de las calificaciones crediticias soberanas? ¿Existe una relación causal entre el riesgo crediticio soberano y el riesgo económico en los países en desarrollo? ¿Cómo pueden los gobiernos, inversionistas e instituciones financieras anticipar cambios en las calificaciones crediticias y verificar si estas calificaciones se desvían de lo que las variables económicas del país indican? Al abordar estas preguntas, se planea obtener una comprensión más profunda de las calificaciones crediticias soberanas y su impacto en los mercados financieros, lo cual es crucial para la estabilidad económica y financiera tanto a nivel nacional como global.

En la introducción de este documento, se describe brevemente el tema central del trabajo, que es cómo modelar la deuda soberana y los datos subjetivos. La finalidad es proporcionar un panorama general de los aspectos fundamentales y establecer el marco contextual en el cual se desarrollará el análisis a lo largo de las distintas secciones. Así, se plantea la importancia de la temática y se introducen los objetivos y las preguntas de investigación que se buscarán responder mediante el estudio.

En el Capítulo 2, se realiza una revisión de la literatura previa en relación al modelado de la deuda soberana y los factores subjetivos involucrados. El Capítulo 3 se centra en explicar la metodología utilizada para modelar la deuda soberana, incluyendo las técnicas de análisis y los datos empleados. En el Capítulo 4, se presentan los resultados obtenidos a partir del análisis y se discuten los hallazgos en el contexto de la

literatura revisada previamente. Finalmente, en el Capítulo 5 se exponen las conclusiones del estudio, resumiendo los resultados principales, destacando las implicaciones de la investigación y sugiriendo posibles direcciones para futuras investigaciones en este campo.

## 2. REVISIÓN DE LITERATURA

La literatura en torno a las calificaciones crediticias soberanas se ha centrado principalmente en modelar estas calificaciones en función de sus determinantes cuantitativos y cualitativos. Estos factores evalúan la solvencia de los países calificados considerando un conjunto de variables macroeconómicas, gubernamentales e institucionales, así como incumplimientos históricos. En este sentido, estudios anteriores han intentado modelar las calificaciones crediticias soberanas utilizando factores cuantitativos (Cantor & Packer, 1996; McFadden et al., 1985; Saini & Bates, 1984). Entre estos estudios, Cantor y Packer (1996) descubrieron que ocho indicadores macroeconómicos explicaban las asignaciones de calificación crediticia de Standard & Poor's y Moody's: crecimiento del PIB, inflación, deuda externa, ingreso per cápita, nivel de desarrollo económico e historial de incumplimiento.

Investigaciones posteriores (Afonso, 2003; Erdem & Varli, 2014; Vernazza & Nielsen, 2015) han identificado indicadores adicionales más allá de estas medidas cuantitativas. Los factores cualitativos, como las variables políticas e institucionales (por ejemplo, la eficacia del gobierno, la estabilidad política, la corrupción, el estado de derecho, etc.), también desempeñan un papel importante en la explicación de las calificaciones crediticias soberanas. Esto resalta la importancia de considerar tanto los determinantes cuantitativos como cualitativos al evaluar la solidez crediticia de las entidades soberanas, ya que en conjunto proporcionan una comprensión más completa de los factores que influyen en las calificaciones crediticias.

Investigaciones más recientes han revelado que diversos factores subjetivos también influyen en las calificaciones emitidas por las tres principales agencias calificadoras. Fuchs y Gehring (2017), por ejemplo, estimaron un modelo de Mínimos Cuadrados Ordinarios (OLS) para los principales determinantes de las calificaciones soberanas

proporcionadas por nueve agencias en 143 países. Sus resultados sugieren que componentes subjetivos, tales como la distancia geográfica, cultural, política y económica, ejercen un efecto significativo en las calificaciones. Concretamente, el país donde se encuentra la sede de una agencia (su país de origen), aquellos países con similitudes culturales respecto al país de origen de la agencia, y los países en los que los bancos del país de origen tienen mayor exposición al riesgo, suelen recibir calificaciones más altas de lo que sus condiciones económicas y fundamentos políticos justificarían.

Ozturk et al. (2016) modelaron las calificaciones soberanas de Moody's empleando técnicas de inteligencia artificial y descubrieron que los países que comparten un idioma común con el país de origen de la agencia obtienen calificaciones más altas. Vernazza y Nielsen (2015) concluyeron que si bien el componente objetivo, basado en fundamentos medibles, posee un poder explicativo significativo para predecir incumplimientos tanto a corto como a largo plazo, el componente subjetivo u otros factores residuales tienen escaso poder explicativo para predecir incumplimientos en un horizonte de uno o más años. DeMoor et al. (2018) hallaron que los factores subjetivos, como la proximidad a los Estados Unidos y el poder de cabildeo, son elementos relativamente importantes en las asignaciones de calificaciones. Específicamente, estos factores subjetivos conducen a un ajuste a la baja en la calificación para los países con la calificación más baja, pero a un ajuste al alza para aquellos con la calificación más alta. Además, el componente subjetivo no es homogéneo entre las agencias de calificación y varía a lo largo del tiempo.

Adicionalmente, el rol de las variables fiscales, como la deuda pública y el saldo fiscal (Erdem y Varli, 2014), el déficit público (Afonso, Furceri y Gomes, 2012), la solidez fiscal, la transparencia fiscal y la deuda pública (Vernazza & Nielsen, 2015), y las variables financieras, incluyendo las reservas de divisas, la profundidad y eficiencia financiera (Alexe et al., 2003), la apertura financiera (Andreasen & Valenzuela, 2016) y el tamaño del sistema bancario, han sido propuestas como algunos de los determinantes más relevantes de las calificaciones crediticias soberanas. Aunque con menor frecuencia que las variables previamente mencionadas, diversos estudios han demostrado que otras variables, como el riesgo político del país soberano (Ozturk, 2014; Remolona et al., 2007), el ciclo económico político (Block & Vaaler, 2004), indicadores políticos y sociales

cualitativos (Bissoondoyal-Bheenick, 2005), instituciones legales y políticas (Butler & Fauver, 2006), efectividad del gobierno (Afonso et al., 2011), adopción de metas de inflación (TI) (Balima et al., 2017) y los factores del mercado global (Aizenman et al., 2011), ejercen un impacto en la determinación de la calificación crediticia. Asimismo, se ha señalado que el historial de incumplimiento es uno de los determinantes más importantes de las calificaciones crediticias soberanas (Borio & Packer, 2004).

La segunda línea principal de la literatura examina el efecto de las calificaciones crediticias en el país soberano. Un anuncio de rebaja de la calificación crediticia afecta el acceso del país a los mercados internacionales de capital (Reinhart, 2002), los términos y condiciones de los créditos, conduciendo a un mayor costo del crédito para el país rebajado, lo que podría generar efectos perjudiciales en la economía. Se ha encontrado que un cambio en la calificación soberana puede afectar la calificación del sector bancario, la rentabilidad y los índices de capital de los bancos (Cavallo et al., 2013), y los costos de financiamiento bancario (Williams et al., 2013). Los costos de endeudamiento más elevados generan diversos problemas adicionales, incluyendo un déficit presupuestario más alto, menor gasto e inversión gubernamental (Cantor y Packer, 1996), reducción de la inversión privada real, desaceleración del comercio internacional y la inversión extranjera directa (IED) bilateral (Cai et al., 2018) y deterioro de los fundamentos macroeconómicos.

El efecto de las calificaciones crediticias en los mercados financieros ha sido ampliamente documentado en la literatura académica. Las investigaciones iniciales se enfocaron en el impacto a corto plazo de los anuncios de calificación crediticia en los mercados financieros. Kaminsky (2002) encontró evidencia de un efecto significativo de los cambios en las calificaciones crediticias en los mercados de acciones y bonos de 16 países en desarrollo durante el período 1990-2000. Algunos hallazgos han señalado el efecto de las calificaciones crediticias en los diferenciales de los “swaps de incumplimiento crediticio” (CDS por sus siglas en inglés) (Reisen & Von Maltzan, 1999) y los rendimientos de los bonos gubernamentales (Baum et al., 2016). De acuerdo con numerosos estudios, el cambio en la calificación crediticia es un factor que contribuye a la volatilidad en los mercados financieros, lo que podría ser perjudicial para la estabilidad financiera y, en última instancia, conducir a la volatilidad de la producción (Afonso et al., 2014).

Un aspecto destacado de la literatura es que muchos estudios han confirmado que las calificaciones crediticias tienen un efecto asimétrico en los mercados financieros. Existe un consenso general de que, aunque las rebajas de calificación tienen efectos notables en los mercados, el efecto de las mejoras de calificación es relativamente limitado o incluso inexistente (Hill et al., 2010). El efecto asimétrico inmediato de un anuncio o señal de rebaja de calificación se observa como un aumento de la volatilidad en el mercado de valores, y un efecto similar también se observa en respuesta a los mercados de bonos (Afonso et al., 2014) del país.

Además de su efecto sobre las economías soberanas, la revisión de la calificación también tiene un efecto indirecto internacional considerable, que amplifica su impacto en la economía global. El cambio de calificación de un país puede tener efectos indirectos en los mercados financieros de otros países. Este efecto es particularmente evidente en los mercados bursátiles (Kaminsky & Schmukler, 2002) y de divisas (Alsakka & ap Gwilym, 2012). Una cantidad considerable de investigaciones ha demostrado que las rebajas de calificación crediticia incrementan la volatilidad en los mercados de divisas (Baum et al., 2016) y tienen efectos indirectos en los tipos de cambio de otros países (Alsakka & ap Gwilym, 2012).

Como se resumió previamente, existe una vasta cantidad de literatura sobre diversos aspectos de las calificaciones crediticias soberanas, como los determinantes de las calificaciones y sus efectos a nivel local y global. No obstante, aunque hay estudios sobre la relación causal entre las calificaciones crediticias soberanas y varias variables seleccionadas, esta literatura es relativamente escasa. Por ejemplo, Alfonso et al. (2011) encontraron evidencia de una causalidad bidireccional entre los cambios de calificación y el diferencial de CDS. Además, identificaron cuatro canales para explicar el efecto causal de las calificaciones soberanas en el sector financiero y otros dos canales para describir la dirección inversa de la causalidad. A pesar de que existen estudios que han criticado a las CRA por sus efectos perjudiciales a corto plazo o por el desajuste de sus calificaciones, estos estudios no han proporcionado pruebas suficientes para demostrar que las calificaciones crediticias pueden desencadenar un círculo vicioso (El-Shagi & von Schweinitz, 2015). La literatura sobre la relación causal entre la calificación

crediticia soberana y el riesgo económico del soberano es bastante limitada. Esta cuestión es especialmente relevante para los países en desarrollo que tienen calificaciones históricamente bajas y son propensos a sufrir dificultades financieras.

### 3. METODOLOGÍA Y DATOS

En el contexto de la deuda soberana y la información subjetiva, iniciamos el análisis considerando un vector  $Z$  de  $k$  variables relacionadas con las características sociales y demográficas de los países emisores de deuda, y un vector  $W$  de  $h$  variables referentes a las características económicas y financieras de dichos países, supongamos un modelo básico de clases latentes, es decir

$$\pi_{jl} = \lambda_{0jl} + \sum_{i=1}^k \lambda_{ijl} Z_i + \sum_{m=1}^h \lambda_{mjl} W_m$$

El punto de partida es el modelo representado por el diagrama de trayectorias en el Gráfico 1, se supone que las  $k$  variables exógenas  $Z$ , que representan las características sociales y demográficas; las variables referentes a las características económicas y financieras están influenciadas por estas últimas variables y afectan directamente la variable de clase latente  $X$ . Esto implica que no existe una relación directa entre las características sociales y demográficas del país emisor y la existencia de restricciones en la inversión en el activo  $j$ : se asume que las clases latentes,  $X$ , son el único determinante directo de la tenencia del activo  $j$ -ésimo  $Y$ , es decir la capacidad de deuda del país, nuestro objetivo es estimar varios parámetros. Estos incluyen los parámetros de la función de utilidad  $U_i$ , que podría tomar la forma  $U_i(w_{ij}) = a_i + b_i w_{ij} + c_i w_{ij}^2$ , donde  $a_i, b_i, y c_i$  son parámetros que encapsulan las preferencias de la entidad soberana. Adicionalmente, el parámetro de aversión al riesgo ( $T_i$ ) es un componente crítico del modelo, reflejando la aversión al riesgo de la entidad soberana, la variable de restricción no observada  $x_{ij}$  se supone que sigue una distribución multinomial con parámetros  $\pi_1, \pi_2, \dots, \pi_m$ , donde  $\pi_k$  es la probabilidad de que  $x_{ij}$  sea igual a  $C_k$ , y  $\sum_{k=1}^m \pi_k = 1$ . Estos parámetros  $\pi_k$  deben ser estimados a partir de los datos.

Además, buscamos estimar la distribución de probabilidad conjunta de la fracción observada de la deuda total emitida  $w_{ij}$  y la variable de restricción no observada  $x_{ij}$ , esta distribución conjunta, denotada como  $P(w_{ij}, x_{ij})$ , encapsula la probabilidad de

que la entidad soberana emita una cierta fracción de su deuda total en el instrumento ( $j$ ) dada la restricción no observada sobre esta fracción. La distribución marginal de  $w_{ij}$ , denotada como  $P(w_{ij})$ , se puede obtener integrando la distribución conjunta sobre todos los posibles valores de  $x_{ij}$ :

$$P(w_{ij}) = \sum_{k=1}^m P(w_{ij}, x_{ij} = C_k)$$

La distribución condicional de  $w_{ij}$  dado  $x_{ij}$ , denotada como  $P(w_{ij}|x_{ij})$ , se puede obtener normalizando la distribución conjunta por la distribución marginal de  $x_{ij}$ ,  $P(x_{ij})$ :

$$P(w_{ij}|x_{ij}) = \frac{P(w_{ij}, x_{ij})}{P(x_{ij})}$$


Al estimar estos parámetros y distribuciones, podemos elucidar el comportamiento de emisión de deuda de la entidad soberana y sus preferencias y restricciones subyacentes. Este análisis puede proporcionar valiosos conocimientos para inversores, agencias de calificación crediticia y responsables de políticas, mejorando nuestra comprensión de las calificaciones de deuda soberana.

Siguiendo los requerimientos del análisis de clases latentes, supongamos que la variable de restricción no observada  $x_{ij}$  asume solo  $m$  valores discretos, es decir,  $C_1 = 0, C_2, \dots, C_{m-1}, C_m = 1$ . Cuando  $x_{ij} = C_1 = 0$ , la entidad soberana está impedida de emitir cualquier cantidad en el instrumento de deuda  $j$ . De esto se sigue necesariamente que  $w_{ij} = 0$ . Cuando  $x_{ij} = C_2$ , la entidad soberana tiene permitido emitir en el instrumento  $j$ , pero no puede mantener una participación de deuda mayor que  $C_2$ , es decir,  $w_{ij} \leq C_2$ . De manera similar, cuando  $x_{ij} = C_3$ , la entidad soberana tiene permitido emitir en el instrumento  $j$ , pero no puede mantener una participación de deuda mayor que  $C_3$ , es decir,  $w_{ij} \leq C_3$ . Finalmente, cuando  $x_{ij} = C_m = 1$ , la entidad soberana no tiene restricciones en la emisión en el instrumento  $j$ , lo que implica que  $w_{ij}$  puede asumir cualquier valor entre 0 y 1.

La relación entre la variable de restricción no observada  $x$  y la participación de deuda emitida observada  $w$  puede resumirse en las ecuaciones 6-9, donde  $f_{kk}$  representa la proporción de la población con restricción  $C_k$  y emisión  $C_{k-1} < w \leq C_k$ . Este análisis de clases latentes puede proporcionar valiosos conocimientos sobre las preferencias y

restricciones de la entidad soberana al elegir su cartera de deuda, lo cual puede ser útil para predecir su comportamiento futuro y evaluar su riesgo crediticio.

GRÁFICO 1. Diagrama de clases latentes



*Fuente: Elaboración propia*

En este modelo, las variables sociales y demográficas ( $Z$ ) podrían incluir factores como la estructura política, la gobernanza, la calidad institucional y la estabilidad social, mientras que las variables económicas y financieras ( $W$ ) podrían abarcar aspectos como el PIB per cápita, el crecimiento económico, la inflación y la deuda pública en relación con el PIB. La variable de clase latente  $X$  capturaría información subjetiva no observada directamente, como la percepción de riesgo y la confianza en la capacidad del país para cumplir con sus obligaciones de deuda, este enfoque permite analizar cómo la información subjetiva y las características observables de los países emisores de deuda afectan la evaluación de riesgo y la toma de decisiones de los inversores en el mercado de deuda soberana. Al incorporar las clases latentes en el análisis, se pueden identificar patrones y relaciones subyacentes entre la información subjetiva y las características observables, lo que proporciona una base más sólida para evaluar y predecir el comportamiento del mercado de deuda soberana.



El modelo ilustrado en la Figura 1, se puede expresar en las ecuaciones 1 y 2 en términos de probabilidades de respuesta condicional y parámetros loglineales, respectivamente. Todos los parámetros están sujetos a las restricciones de identificación habituales; las probabilidades condicionales suman uno donde corresponda y los parámetros loglineales suman cero siempre que se sumen sobre cualquiera de sus subíndices.

$$P(Z, W, X, Y) = P(Z) \cdot P(W | Z) \cdot P(X | W) \cdot P(Y | X) \dots (1)$$

Donde

$$\ln(F(\pi_{ZWXY})) = \lambda + \lambda_Y + \lambda_X + \lambda_W + \lambda_Z + \lambda_{XY} + \lambda_{WX} + \lambda_{ZW} + \dots (2)$$

En este modelo, las ecuaciones 1 y 2 permiten analizar cómo las características observables y la información subjetiva de los países emisores de deuda afectan las evaluaciones de riesgo y las decisiones de inversión en el mercado de deuda soberana. Las probabilidades de respuesta condicional, representadas en la ecuación 1, describen la probabilidad de que un país emisor pertenezca a una determinada clase latente (X) dadas, por ejemplo, sus características sociales, demográficas, económicas y financieras (Z y W). Los parámetros loglineales, representados en la ecuación 2, cuantifican las relaciones entre las características observables y las clases latentes, así como entre estas últimas y las inversiones en activos j-esimos (Y), al aplicar estas ecuaciones al análisis de la deuda soberana, se pueden identificar patrones y relaciones subyacentes entre la información subjetiva y las características observables, lo que proporciona una base más sólida para evaluar y predecir el comportamiento del mercado de deuda soberana. Además, este enfoque permite una mejor comprensión de cómo las percepciones de riesgo y la confianza en la capacidad del país para cumplir con sus obligaciones de deuda influyen en las decisiones de inversión en deuda soberana.

La especificación del modelo de clases latentes en el contexto de la deuda soberana y la información subjetiva requiere la definición de una restricción estructural con respecto a la relación entre las clases latentes, X, y su indicador, Y, es decir, la probabilidad condicional de que la variable indicadora  $Y = 1$ , dado que la clase latente  $X = 0$ , es

igual a cero, a continuación, los parámetros de los modelos de clases latentes se estiman mediante un procedimiento iterativo de máxima verosimilitud, llamado algoritmo Expectation-Maximization (EM), que es robusto con respecto a los valores iniciales (Dempster et al.1977). La estimación EM comienza reemplazando la variable de clase (X) por su valor esperado. Luego, utilizando un conjunto de valores iniciales razonables, la expectativa para X y la maximización de las probabilidades condicionales y las proporciones de clases se alternan hasta la convergencia, para obtener estimaciones de máxima verosimilitud para el modelo de clase latente (1), las siguientes ecuaciones (3)-(5):

$$\pi^{ZWYX} = \pi^{Z|X} \cdot \pi^{W|X} \cdot \pi^{Y|X} \cdot \pi^X \dots (3)$$

$$\pi^{ZWY} = \sum_X \pi^{ZWYX} \dots (4)$$

$$\sum_X \pi^X = \sum_Z \pi^{Z|X} = \sum_W \pi^{W|X} = \sum_Y \pi^{Y|X} = 1 \dots (5)$$

tienen que satisfacer las ecuaciones (6)-(9):

$$\pi^X = \sum_{ZWY} f_{ZWY} \cdot \pi^{X|ZWY} \dots (6)$$

$$\pi^{Z|X} = \frac{\sum_{WY} f_{ZWY} \cdot \pi^{X|ZWY}}{\pi^X} \dots (7)$$

$$\pi^{W|X} = \frac{\sum_{ZY} f_{ZWY} \cdot \pi^{X|ZWY}}{\pi^X} \dots (8)$$

$$\pi^{Y|X} = \frac{\sum_{ZW} f_{ZWY} \cdot \pi^{X|ZWY}}{\pi^X} \dots (9)$$

donde  $f_{ZWY}$  identifica la probabilidad observada relativa a la celda  $ZWY$  en la tabulación cruzada de variables observadas  $ZWY$  (McCutcheon, 1987).

CUADRO 1. Tabla de contingencia

		Y			Total
		1	2	...	
X	1	$f_{1111}$	$f_{1121}$	...	$\sum_{Z,W,Y} f_{11ZWY}$
	2	$f_{1211}$	$f_{1221}$	...	$\sum_{Z,W,Y} f_{12ZWY}$
	$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
Total		$\sum_{X,Z,W} f_{XZ1W1}$	$\sum_{X,Z,W} f_{XZ2W1}$	...	$N$

la tabla de contingencia construida para el análisis de clases latentes resulta particularmente reveladora. Los subíndices de cada entrada en esta tabla se varían meticulosamente a lo largo de un espectro de variables tanto subjetivas como objetivas, cada una perteneciente a observaciones individuales para diferentes países. Las variables subjetivas en este contexto pueden abarcar percepciones de estabilidad política, calidad de gobernabilidad y credibilidad de políticas, que son inherentemente cualitativas y a menudo sujetas a interpretación. Por otro lado, las variables objetivas se basan en medidas tangibles y cuantificables como el crecimiento del PIB, el equilibrio fiscal, la deuda externa y las reservas de divisas extranjeras, ofreciendo una perspectiva más concreta y medible de la posición económica de un país. Cada celda en la tabla de contingencia multidimensional encapsula la frecuencia observada de una amalgama específica de niveles de estas variables, pintando así un cuadro comprensivo del diverso y multifacético panorama de las calificaciones de deuda soberana en diversas naciones. Este enfoque facilita una comprensión más profunda de las intrincadas interdependencias entre evaluaciones subjetivas e indicadores objetivos, y su influencia colectiva en la evaluación y determinación de la solvencia crediticia soberana en el ámbito financiero global.

Varios criterios se han vuelto más o menos estándar en la evaluación de modelos de clases latentes. Para un modelo de clases latentes, se pueden utilizar el chi-cuadrado de Pearson ( $\chi^2$ ) o la razón de verosimilitud chi-cuadrado ( $L^2$ ) para comparar las frecuencias observadas de los patrones de respuesta con las frecuencias esperadas bajo el modelo ajustado. Los modelos de clases latentes que conducen a frecuencias de celdas esperadas que están demasiado lejos de las frecuencias de celdas observadas se consideran inaceptables o implausibles. Los modelos con más parámetros generalmente

proporcionan un mejor ajuste a los datos. Los modelos más parsimoniosos tienden a tener un ajuste algo peor. Por lo tanto, la tarea habitual es encontrar el modelo más parsimonioso que tenga un ajuste aceptable a los datos observados. Sin embargo, a medida que aumenta el número de variables manifiestas, la tabla de frecuencias de los patrones de respuesta se vuelve dispersa y eso invalida los valores  $p$  obtenidos a partir de las pruebas de  $2F$  y razón de verosimilitud. Se proponen soluciones a este problema cuando se ajusta un modelo en una tabla de contingencia multivariante con variables binarias por Reiser y Lin (1999) y Bartholomew y Leung (2002). Aún no se ha obtenido una prueba estadística formal para tablas de contingencia dispersas en el caso de datos de respuestas múltiples; por lo tanto, el chi-cuadrado de Pearson y la razón de verosimilitud chi-cuadrado solo se pueden utilizar como indicadores de mal ajuste, la selección de modelos entre modelos LCA con diferentes números de parámetros se puede obtener mediante el uso de criterios de información, remuestreo paramétrico, etc. Los criterios de información son probablemente los métodos más convenientes desde el punto de vista de la eficiencia informática, ya que requieren muchos menos esfuerzos informáticos que otros métodos, como el remuestreo paramétrico. El criterio de información de Akaike (AIC) fue una de las primeras propuestas de criterios de información. El AIC tiene la siguiente forma:

$$AIC = L^2 - 2 \bullet df$$

donde  $L^2$  es la razón de chi-cuadrado de verosimilitud y  $df$  es el número total de parámetros libres en el modelo. Woodruffe (1982) demostró que el AIC no es teóricamente consistente, por lo tanto, el AIC no seleccionará el modelo correcto cuando el tamaño de la muestra  $N$  tiende al infinito. El criterio de información bayesiano (BIC) fue propuesto por Schwartz y tiene la siguiente forma:

$$BIC = L^2 - df \bullet \log N$$

El BIC tiene una propiedad consistente (Haughton, 1988) que lleva a una elección de modelo correcta a medida que  $N$  se aproxima a infinito. Bozdogan (1987) derivó una versión consistente de AIC (CAIC) a partir de la medida de información de Kullback-Leibler:

$$CAIC = L^2 - df \cdot (\log N + 1)$$

Debido a que el CAIC tiene una penalización más severa por la sobreparametrización que el BIC o el AIC, el CAIC tenderá a favorecer un modelo con menos parámetros.

La elección de criterios de información específicos, tales como el AIC, BIC y CAIC, es esencial para determinar el número óptimo de clases latentes. Estos criterios son fundamentales para evaluar la bondad de ajuste del modelo y, por ende, para seleccionar el número más adecuado de clases latentes que refleje de manera precisa las dinámicas de la calificación de deuda soberana. El algoritmo EM, por su parte, proporciona un método robusto para la estimación de parámetros del modelo, especialmente en casos donde las tablas de contingencia presentan dispersión. La implementación de esta metodología en el estudio de la deuda soberana posibilita una comprensión más profunda de los factores y dinámicas subyacentes que inciden en las calificaciones crediticias soberanas y los riesgos correlativos. Con respecto al algoritmo Random Forest, el cual, es una técnica de aprendizaje en conjunto que se basa en la construcción de múltiples árboles de decisión, que luego se combinan para proporcionar una salida más precisa y robusta. El algoritmo se puede describir matemáticamente de la siguiente manera:

Supongamos que tenemos un conjunto de datos con  $n$  países y  $p$  variables predictoras (tanto indicadores económicos objetivos como factores subjetivos) para cada país. Dejemos que  $X = (X_1, X_2, \dots, X_p)$  sea el vector de variables predictoras y  $Y$  sea la variable de respuesta que representa el riesgo de la deuda soberana. se construyen  $B$  árboles de decisión. Para cada árbol  $b$ , se genera una muestra de arranque de los datos y crece el árbol en esta muestra. En cada nodo del árbol, selecciona  $m$  variables al azar de las  $p$  predictoras y divide el nodo utilizando la variable que proporciona la mejor división de acuerdo con la función objetivo, la función objetivo para dividir los nodos es típicamente la entropía para las tareas de clasificación y el error cuadrático medio para las tareas de regresión. Si usamos entropía, la división en cada nodo se elige para minimizar la siguiente función:

$$Entropía(t) = - \sum_{i=1}^c p(i|t) \log_2 p(i|t)$$

donde  $t$  es el nodo,  $c$  es el número de clases y  $p(i/t)$  es la proporción de muestras en el nodo  $t$  que pertenecen a la clase  $i$ .

Después de que los árboles han crecido, el algoritmo RF hace predicciones agregando las predicciones de los árboles individuales. Para la clasificación, la predicción de RF se da por la moda de las clases predichas por los árboles individuales:

$$\hat{Y}_{rf} = \text{moda}(\hat{Y}_{b1}, \hat{Y}_{b2}, \dots, \hat{Y}_{bB})$$

donde  $\hat{Y}_{bi}$  es la predicción del árbol  $i$ . Para la regresión, la predicción de RF se da por la media de las predicciones de los árboles individuales:

$$\hat{Y}_{rf} = \frac{1}{B} \sum_{i=1}^B \hat{Y}_{bi}$$

El algoritmo RF puede manejar relaciones complejas y no lineales entre las variables predictoras y la variable de respuesta, lo que lo convierte en una herramienta poderosa para modelar el riesgo de la deuda soberana. Puede incorporar tanto indicadores económicos objetivos como factores subjetivos en el modelo, proporcionando una evaluación integral del riesgo de la deuda soberana. Su robustez al sobreajuste, debido a la aleatoriedad introducida en el proceso de construcción del modelo, al construir múltiples árboles de decisión y combinar sus predicciones, reduce efectivamente la varianza y el sobreajuste.

En el ámbito de la modelización del riesgo de la deuda soberana, la suposición de linealidad y aditividad en la escala de log-odds, tal como se plantea en los modelos de regresión logística tradicionales como Probit y Logit, puede no ser siempre verdadera. Estos modelos presuponen que, para cada cambio unitario en una variable predictora, el cambio en el log-odds de la variable de respuesta permanece constante, independientemente de los valores de otras variables predictoras. Si bien esta suposición simplifica el proceso de modelización y facilita la interpretación de los parámetros del modelo, puede conducir a una especificación errónea del modelo y a un rendimiento subóptimo cuando la suposición no se alinea con la estructura de datos subyacente.

La complejidad de los escenarios del mundo real, incluyendo la modelización del riesgo de la deuda soberana, a menudo resulta en relaciones no lineales entre las variables predictoras y la variable de respuesta. Además, la influencia de una variable

predictora sobre la variable de respuesta puede ser contingente a los valores de otras variables predictoras. Por ejemplo, el impacto del crecimiento del PIB en el riesgo de la deuda soberana podría depender de factores como la estabilidad política, la calidad institucional y otros indicadores económicos y financieros. Tales interacciones entre variables predictoras, que no se tienen en cuenta en los modelos de regresión logística tradicionales, pueden llevar a una posible especificación errónea del modelo.

Adicionalmente, la presuposición de aditividad en la escala de log-odds conlleva una implicación de homogeneidad en el efecto de una variable predictora a lo largo de todos los niveles de la variable de respuesta. No obstante, en el ámbito de la modelización del riesgo asociado a la deuda soberana, es plausible que la influencia de una variable predictora fluctúe a través de distintos niveles de riesgo de deuda soberana. A modo de ejemplo, la estabilidad política podría ejercer un impacto más significativo en el riesgo de la deuda soberana para aquellos países que presentan elevados niveles de deuda, en comparación con aquellos cuyos niveles de deuda son inferiores. En contraposición, metodologías estadísticas de avanzada, tales como el Análisis de Clases Latentes (ACL) y los modelos de Bosque Aleatorio (RF), no establecen estas suposiciones restrictivas. Estos modelos son competentes para gestionar relaciones complejas y no lineales entre las variables predictoras y la variable de respuesta, y poseen la capacidad de integrar interacciones entre las variables predictoras. Dicha flexibilidad y robustez ante la especificación incorrecta del modelo posibilitan que estas metodologías ofrezcan perspectivas más acertadas y matizadas acerca de los perfiles de riesgo de la deuda soberana. En consecuencia, dentro del dominio complejo y multifacético de la modelización del riesgo de la deuda soberana, los modelos ACL y RF se erigen como un enfoque más sofisticado y fidedigno en comparación con los modelos de regresión logística tradicionales.

La muestra seleccionada para este estudio consta de 80 observaciones de diversas economías a nivel global durante el período comprendido entre 1995 y 2017. Las naciones incluidas en la muestra fueron seleccionadas principalmente debido a que cuentan con una calificación de deuda otorgada por las tres Agencias Calificadoras de Crédito (CRA). A continuación, se presenta una tabla que muestra las naciones incluidas en la muestra.

CUADRO 2. Países de la muestra

Albania	Colombia	Guatemala	Malasia	Arabia Saudita
Angola	Congo	Honduras	México	Serbia
Argentina	Costa Rica	Hungría	Moldova	Singapur
Armenia	Croacia	India	Marruecos	Eslovaquia
Australia	Ciprés	Indonesia	Países Bajos	Eslovenia
Austria	República Checa	Irlanda	Nicaragua	Sudáfrica
Azerbaiyán	Dinamarca	Israel	Nigeria	Corea del Sur
Bahréin	Ecuador	Italia	Noruega	Sri Lanka
Bangladesh	Egipto	Jamaica	Panamá	Suecia
Bolivia	El Salvador	Japón	Paraguay	Suiza
Brasil	Estonia	Jordán	Perú	Tailandia
Camboya	Etiopía	Kazajstán	Polonia	Ucrania
Camerún	Finlandia	Kenia	Portugal	Reino Unido
Canadá	Francia	Kuwait	Qatar	Estados Unidos
Chile	Alemania	Letonia	Romania	Uruguay
China	Grecia	Lituania	Rusia	Venezuela

De acuerdo con la literatura revisada, Cantor y Packer (1996) sostienen que los fundamentales de una economía son los principales determinantes de las calificaciones crediticias soberanas. Por fundamentales, se hace referencia a la información objetiva que puede ser medida en una economía, como el PIB, PIB per cápita, cuenta corriente, deuda soberana, tasa de crecimiento, entre otros. Sin embargo, investigaciones realizadas por De Moor et al. (2018), Vernazza y Nielsen (2015) y Ozturk (2016) demuestran que, si bien la información objetiva es estadísticamente significativa, la información subjetiva comprende aquellas variables no observables que influyen en el juicio de los comités de las CRA. Estas variables pueden incluir aspectos como la corrupción, la calidad e independencia de las instituciones de la nación, o el nivel de violencia percibido en el país. Estos factores pueden incidir en la asignación de calificaciones de deuda. En la siguiente tabla, se presentan las variables seleccionadas para incorporar información subjetiva en el modelo analizado en este estudio.



Variable	Descripción	Unidad	Fuente
califprom	La calificación promedio asignada al país en el año de observación por alguna de las 3 CRA	De 0 a 100	Elaboración propia con datos de <a href="http://tradingeconomics.com">tradingeconomics.com</a> (Cuadro 8 en apéndice)
Year	Año de observación	De 1995 a 2017	Elaboración propia
Id	Identificador del país	De 0 a 80	Elaboración propia
rgdpopc	PIB per cápita real del país	Miles de dólares del 2017	Penn World Table (PWT_10)
rgdpo	PIB real por el lado del producto	Miles de millones de dólares del 2017	Penn World Table (PWT_10)
deudapib	Cociente de la deuda gubernamental entre PIB	Adimensional	Elaboración propia con datos de Penn World Table (PWT_10)
pibtcpo	Tasa de crecimiento del PIB	Porcentaje	Penn World Table (PWT_10)
ccpib	Cociente del valor de la cuenta corriente entre el PIB	Adimensional	Elaboración propia con datos de Penn World Table (PWT_10)

*Continuación de la página anterior*

Variable	Descripción	Unidad	Fuente
fh_rol	Variable mide independencia judicial, prevalencia del estado de derecho, control civil, y garantía de igualdad. Países clasificados entre 0 y 10.	Escala de 0 a 10	<a href="#">Freedom House. (2022a). Freedom in the world 2022</a>
fi_legprop	Índice evalúa independencia judicial, confiabilidad legal, protección de propiedad intelectual, y ausencia de interferencia militar.	Escala de 0 a 10	<a href="#">Gwartney et al. (2022)</a>
compi	Índice de Complejidad Económica usando clasificación de productos SITC.	índice	<a href="#">The Growth Lab at Harvard University. (2019)</a>
pcolocat	Clasificación define pasado colonial del país.	0. Nunca colonizado... 1 colonizado	<a href="#">Datos de regímenes autoritarios</a>
bci	Índice de corrupción bayesiano	índice	<a href="#">Standaert, S. (2015)</a>
vdem_exb	Mide soborno ejecutivo basado en codificaciones de expertos y modelo especializado.	Índice	<a href="#">Modelo de medición V-Dem</a>
vdem_egal	Índice evalúa democracia igualitaria, igualdad de derechos, distribución de recursos y nivel de democracia electoral.	Índice	<a href="#">Modelo de medición V-Dem</a>

Las variables elegidas para modelar la calificación crediticia soberana han sido meticulosamente seleccionadas para encapsular diversas facetas del panorama económico,

político y social de un país. Estas variables, que van desde indicadores económicos como el PIB y las ratios de deuda hasta la estabilidad política y la calidad de la gobernabilidad, ofrecen una perspectiva multifacética sobre los factores que influyen en la solvencia de un país. La diversidad y profundidad de estas variables son fundamentales para capturar la complejidad y la naturaleza multifacética del riesgo crediticio soberano.

VARIABLES COMO EL PRODUCTO INTERNO BRUTO PER CÁPITA (rgdpopc), EL PRODUCTO INTERNO BRUTO TOTAL (rgdpo) Y LA RELACIÓN DEUDA A PIB (deudapib) SIRVEN COMO INDICADORES PIVOTALES, ARROJANDO LUZ SOBRE LA VITALIDAD ECONÓMICA Y ESTABILIDAD DE UNA NACIÓN, ELEMENTOS ESENCIALES PARA LA EVALUACIÓN DE CALIFICACIONES CREDITICIAS. LA INCORPORACIÓN DE VARIABLES COMO `vdem_exbribe`, INDICATIVA DE SOBORNOS EJECUTIVOS, Y `pcolocat`, REPRESENTANDO LA LOCALIZACIÓN POLÍTICA, PERMITE QUE EL MODELO INCORPORE CONSIDERACIONES RESPECTO A LA ESTABILIDAD POLÍTICA Y LA CALIDAD DE GOBERNANCIA. ESTOS SON FACTORES NO ECONÓMICOS INTEGRALES QUE INFLUYEN EN LA CAPACIDAD DE UN PAÍS PARA CUMPLIR CON SUS COMPROMISOS FINANCIEROS.

Además, variables como `fh_rol` y `fi_legpropd` reflejan la robustez de la infraestructura legal de una nación y la protección de derechos, elementos que tienen una influencia significativa sobre la confianza del inversor y, consecuentemente, las calificaciones crediticias. La variable `vdem_egaldem` cuantifica el grado de democracia igualitaria, ofreciendo perspectivas sobre los niveles de igualdad social e inclusividad, factores que pueden ejercer una influencia indirecta en la estabilidad económica y el crecimiento, en la siguiente tabla se muestran los estadísticos descriptivos de las variables seleccionadas

CUADRO 4. Estadísticos descriptivos

Variable	Obs	Mean	Std. Dev.	Min	Max
califprom	1,564	63.44043	25.27299	5	100
year	1,564	2007.137	6.31805	1995	2017
id	1,564	43.05563	22.68288	1	81
rgdpopc	1,564	24.63683	21.12089	.4342607	169.2003
rgdpo	1,564	1033943	2496561	9974.494	1.97e+07
deudapib	1,564	53.77103	39.08813	-3.4	495.2
pibtcpo	1,564	.046988	.0797053	-.7989208	.5586384
ccpib	1,564	-.0753964	8.256389	-29.8	45.46
fh_rol	1,564	6.18766	2.717765	.625	10
fi_legprop~d	1,564	5.941151	1.585494	2.314241	8.998176
compi	1,564	3.501676	.9477607	.8265927	5.825319
pcolocat	1,564	.4411765	.4966865	0	1
bci	1,564	42.45746	16.93649	7.067162	74.12354
vdem_exbribe	1,564	2.272601	1.091139	.126	3.944
vdem_egalDEM	1,564	.5212251	.252445	.081	.876

En relación con la metodología empleada, se decide implementar un proceso de dos pasos que consiste en aplicar primero un análisis de perfil latente (APL) y luego utilizar el algoritmo de Random Forest. A lo largo de nuestra discusión, hemos hecho referencia predominantemente a la utilización del Análisis de Clases Latentes (ACL); sin embargo, es fundamental aclarar que nuestro enfoque metodológico real emplea el Análisis de Perfiles Latentes (APL). Esta distinción surge de la naturaleza de nuestro conjunto de datos, que abarca una mezcla de variables categóricas y continuas, lo que requiere una técnica analítica más matizada. El APL es particularmente apto para manejar estos diversos tipos de datos, permitiendo la identificación de perfiles latentes basados en la distribución tanto de variables observadas categóricas como continuas. Una distinción fundamental entre el ACL y el APL es la búsqueda de varianzas constantes dentro de cada clase en el APL, asegurando homogeneidad y facilitando una delimitación de clases más precisa. El objetivo principal de utilizar el APL en nuestro estudio es extraer meticulosamente valiosos conocimientos sobre el número óptimo de clases en las que se puede clasificar nuestro conjunto de datos. Al hacerlo, buscamos descubrir patrones y

heterogeneidades subyacentes dentro de los datos, mejorando así la robustez y precisión de nuestros análisis y modelos subsiguientes.

Este enfoque ayuda a controlar el efecto de las fuentes subjetivas de información de diversas maneras. En el contexto de las fuentes subjetivas de información, estos perfiles latentes pueden representar diferentes sesgos, estándares de información o errores de medición. Al identificar y tener en cuenta estos perfiles latentes, el modelo puede capturar mejor las verdaderas relaciones entre las características y la variable objetivo, mitigando el impacto de las fuentes subjetivas de información.

Además, al incorporar las pertenencias a clases latentes como características adicionales en el modelo de Random Forest, se reduce efectivamente el ruido en los datos causado por fuentes subjetivas de información. Esto permite que el modelo de Random Forest se enfoque en las verdaderas relaciones subyacentes entre las características y la variable objetivo. La naturaleza de conjunto del algoritmo de Random Forest también ayuda a evitar el sobreajuste, ya que promedia las predicciones de múltiples árboles de decisión basados en diferentes subconjuntos de datos, lo que reduce la influencia de cualquier fuente subjetiva individual.

Al identificar los perfiles latentes, el proceso de dos pasos puede proporcionar información más significativa sobre los datos. Esto es particularmente útil al abordar fuentes subjetivas de información, ya que puede ayudar a descubrir patrones o tendencias ocultas que, de otro modo, podrían verse oscurecidos por el ruido introducido por estas fuentes.

En este estudio, se analiza una muestra compuesta por 1564 observaciones correspondientes a 80 países, integrando tanto variables subjetivas ( $X$ ) como objetivas ( $Y$ ). Las variables subjetivas incluyen *bci*, *vdem\_exbribe*, *vdem\_egaldem*, *legprop\_pd* y *fh\_rol*, mientras que las objetivas abarcan *rgdpopc*, *rgdpo*, *deudapib*, *pibtcpo*, *ccpib* y *compi*. El objetivo principal es modelar la relación entre las variables observadas ( $X$ ) y los perfiles latentes ( $Z$ ) a través de una distribución de probabilidad:  $(P(X|Z))$ , utilizando para ello las probabilidades de respuesta al ítem.

Se opta por estimar las probabilidades de pertenencia a la clase para cada país, representadas como  $P(Z|X)$  mediante el Análisis de Perfiles Latentes (LPA). Posteriormente, estas probabilidades se combinan para conformar un nuevo conjunto de

datos  $D$ , que se estructura de la siguiente manera:

$$\begin{aligned} D = & Y, P(Z = 1|X), \\ & P(Z = 2|X), \\ & \dots, \\ & P(Z = K|X). \end{aligned}$$

Este conjunto de datos se divide en dos subconjuntos: uno de entrenamiento  $D_{\text{train}}$  y otro de prueba  $D_{\text{test}}$ .

El siguiente paso en la metodología es el entrenamiento de un clasificador de Random Forest (RF) en el conjunto de entrenamiento ( $D_{\text{train}}$ ), utilizando una combinación de variables objetivas y subjetivas como características (( $Y$ ) y ( $P(Z|X)$ )) y las clases de calificación crediticias ( $C$ ) como variable objetivo. El modelo RF se compone de ( $T$ ) árboles de decisión, cada uno construido a partir de un subconjunto aleatorio de los datos de entrenamiento (técnica de bagging) y un subconjunto aleatorio de las características en cada nodo.

Cada árbol ( $t$ ) en el modelo RF se construye mediante un proceso de partición recursiva que busca minimizar una medida de impureza del nodo, como la entropía o la impureza de Gini, para una división dada ( $S$ ). Las fórmulas para la entropía ( $H(S)$ ) y la impureza de Gini se expresan como:

$$H(S) = - \sum p(x) * \log_2(p(x))$$

$$Gini(S) = 1 - \sum [p(x)^2]$$

La ganancia de información para la entropía, representada como ( $IG(S, A)$ ), se calcula como:

$$IG(S, A) = H(S) - \sum \left[ \left( \frac{|S_v|}{|S|} \right) * H(S_v) \right]$$

Una vez construido el modelo RF, se evalúa su rendimiento en el conjunto de prueba ( $D_{\text{test}}$ ) utilizando métricas apropiadas como precisión, exhaustividad, sensibilidad y

puntuación F1. Estas métricas proporcionan una evaluación integral del modelo, permitiendo ajustar y optimizar su rendimiento. La combinación de LPA y RF en este enfoque metodológico es fundamental para capturar la estructura oculta en los datos subjetivos y aprovechar tanto las variables objetivas como subjetivas. El resultado es la creación de un modelo de calificación crediticia más preciso y robusto para los países incluidos en la base de datos. Este enfoque dual permite una exploración profunda de las relaciones subyacentes entre las características y la variable objetivo, mitigando el impacto de las fuentes subjetivas de información y reduciendo efectivamente el ruido en los datos. La naturaleza de conjunto del algoritmo RF contribuye a evitar el sobreajuste, promediando las predicciones de múltiples árboles de decisión y reduciendo la influencia de cualquier fuente subjetiva individual.

Al identificar perfiles latentes mediante LPA, se obtiene información más significativa sobre los datos, lo cual es especialmente útil para abordar fuentes subjetivas de información y descubrir patrones o tendencias ocultas. Este proceso de identificación y análisis en profundidad contribuye a la robustez y precisión del modelo final de calificación crediticia, proporcionando una herramienta valiosa para la evaluación de la solvencia de los países analizados.

#### 4. RESULTADOS

En la siguiente tabla se muestran los resultados del análisis de clases latentes y de acuerdo con estos la impureza de clase dado el conjunto de datos contenidos en la muestra seleccionada se minimiza cuando se clasifican las observaciones en 6 distintas clases

La estimación del modelo convergió con éxito y se replicó el mejor valor de verosimilitud logarítmica, lo que sugiere que es probable que se haya encontrado el máximo global.

La tabla presentada esclarece las estadísticas de ajuste del modelo para una serie de modelos, cada uno caracterizado por un número distinto de clases latentes, que varían de dos a ocho. Estas estadísticas sirven como indicadores cruciales para discernir el número óptimo de clases que encapsulan adecuadamente la estructura inherente de los datos.

CUADRO 5. Resumen de estadísticos de información

No de clases	Akaike (AIC)	Bayesian (BIC)	Entropy	LMR
2	24063.855	24219.150	0.966	0.0000
3	21786.879	22027.854	0.971	0.0000
4	20608.105	20934.760	0.971	0.0000
5	19621.170	20033.505	0.971	0.0000
6	19612.628	20110.644	0.989	0.0432
7	19687.213	20270.908	0.975	0.8047
8	19170.824	19840.199	0.982	0.2265

Al observar el Criterio de Información de Akaike (AIC) y el Criterio de Información Bayesiano (BIC), se evidencia una tendencia discernible de decremento a medida que el número de clases aumenta, alcanzando un nadir en ocho clases tanto para AIC como para BIC. Estos criterios tienen una importancia primordial en el ámbito de la comparación de modelos, siendo los valores inferiores indicativos de un equilibrio armonioso entre la fidelidad y la complejidad del modelo. La trayectoria decreciente de AIC y BIC sugiere una mejora en la fidelidad del modelo con la adición incremental de clases. Sin embargo, se justifica una nota de precaución para evitar las trampas de la sobre-segmentación y el sobreajuste, especialmente cuando el decremento es marginal.

Dirigiendo la atención hacia los valores de entropía, se observa una elevación consistente a través del espectro de modelos, con valores oscilando entre 0.966 y 0.989. La entropía, que actúa como un barómetro de la precisión de la clasificación, arroja valores cercanos a uno, señalando una demarcación clara y una disminución de la incertidumbre en la asignación de clases. Los valores elevados de entropía, observados de forma ubicua a través de los modelos, indican la precisión con la que los individuos son asignados a las clases latentes correspondientes, independientemente de la cantidad de clases.

Profundizando en la Prueba de Razón de Verosimilitud Ajustada de Lo-Mendell-Rubin (LMR), esta métrica esclarece la significancia estadística de la mejora en el ajuste entre el modelo con  $k$  clases y su predecesor con  $k-1$  clases. Un valor de LMR estadísticamente significativo, típicamente demarcado por un valor  $p$  inferior a 0.05, respalda la presencia de  $k$  clases sobre  $k-1$  clases. En el contexto de los modelos presentados, los valores de LMR exhiben significancia estadística hasta seis clases, sugiriendo



así que la incorporación de cada clase adicional mejora el ajuste del modelo. Sin embargo, se observa una transición en los modelos de siete y ocho clases, donde los valores de LMR se vuelven no significativos, indicando que estos modelos no ofrecen una mejora significativa en el ajuste sobre sus predecesores respectivos, al sintetizar la interpretación de las estadísticas de ajuste del modelo, se percibe que un aumento en el número de clases latentes generalmente va acompañado de una mejora en el ajuste del modelo, como lo evidencian el decrecimiento de AIC y BIC y la entropía elevada. No obstante, los valores de LMR no significativos observados en los modelos de siete y ocho clases demarcan un umbral de rendimientos decrecientes, donde la incorporación de clases adicionales deja de producir mejoras significativas en el ajuste. Al equilibrar la tríada de ajuste del modelo, complejidad e interpretabilidad, un modelo caracterizado por seis clases emerge como un óptimo potencial, respaldado por el valor significativo de LMR y el BIC disminuido.

Se ha procedido a segmentar la muestra en una proporción de 80/20 con el propósito de entrenar y validar el algoritmo de Random Forest. Este algoritmo ha sido entrenado considerando las seis clases que, según el análisis de clases latentes, se presentan como ideales para categorizar la información contenida en la muestra. La tabla subsiguiente exhibe las métricas de rendimiento del modelo, expresadas en términos de precisión, exhaustividad, puntuación F1 y soporte, para cada una de las seis clases identificadas (0 a 5):

CUADRO 6. Métricas de clasificación

	Precision	Recall	F1-Score	Support
0	0.89	0.74	0.81	23
1	0.84	0.87	0.86	62
2	0.82	0.82	0.82	62
3	0.75	0.79	0.77	56
4	0.69	0.62	0.66	40
5	0.95	0.99	0.97	70
Accuracy			0.83	313
Macro Avg	0.82	0.80	0.81	313
Weighted Avg	0.83	0.83	0.83	313

Este desglose meticuloso de métricas proporciona una visión detallada del desempeño del modelo en la clasificación de los países según su riesgo de deuda soberana, permitiendo así una evaluación rigurosa de la capacidad del modelo para discernir y categorizar adecuadamente las distintas clases, es esencial profundizar en las métricas clave presentadas, a saber, precisión, sensibilidad (recall), puntuación f1 y soporte, para cada una de las seis clases (0 a 5), así como la precisión general, promedio macro y promedio ponderado del modelo.

El modelo demuestra una precisión general del 83 %, lo que indica que clasifica correctamente el 83 % de las instancias en el conjunto de prueba, que consta de 313 observaciones. Esto sugiere un alto nivel de rendimiento, pero para obtener una comprensión más matizada, es crucial examinar las métricas por clase.

Para la Clase 0, el modelo exhibe una precisión del 89 %, lo que significa que el 89 % de las instancias predichas como Clase 0 se clasifican correctamente. La sensibilidad para esta clase es del 74 %, lo que indica que el modelo identifica con éxito el 74 % de las instancias reales de la Clase 0. La puntuación f1, media armónica de precisión y sensibilidad es de 0.81 para la Clase 0, reflejando un rendimiento de clasificación equilibrado para esta clase.

La Clase 1 demuestra una precisión del 84 % y una sensibilidad del 87 %, con una puntuación f1 de 0.86. Esto sugiere que el modelo es tanto fiable como sensible para identificar instancias de la Clase 1, logrando un equilibrio armonioso entre falsos positivos y falsos negativos.

De manera similar, la Clase 2 exhibe un rendimiento consistente con una precisión del 82 %, sensibilidad del 82 % y una puntuación f1 del 82 %. Esta simetría en precisión y sensibilidad indica un equilibrio justo para la Clase 2.

La Clase 3 presenta una precisión del 75 % y una sensibilidad superior del 79 %, resultando en una puntuación f1 de 0.77. Aunque el modelo es hábil para capturar la mayoría de las instancias reales de la Clase 3, hay una ligera propensión a los falsos positivos.

La Clase 4 revela una precisión del 69 % y una sensibilidad del 62 %, culminando en una puntuación f1 de 0.66. Esta clase exhibe la puntuación f1 más baja entre las seis

clases, indicando posibles desafíos en la clasificación precisa de instancias de la Clase 4, particularmente en términos de falsos negativos.

La Clase 5 se destaca con la precisión y sensibilidad más altas entre todas las clases, con 0.95 y 0.99 respectivamente, obteniendo una impresionante puntuación f1 de 0.97. Esto indica un rendimiento ejemplar en la clasificación de la Clase 5, con mínimos errores de clasificación.

El promedio macro y el promedio ponderado de precisión, sensibilidad y puntuación f1 proporcionan una visión integral del rendimiento del modelo en todas las clases. El promedio macro, calculado como la media no ponderada de la métrica para cada clase, es de 0.82 para la precisión, 0.80 para la sensibilidad y 0.81 para la puntuación f1. El promedio ponderado, teniendo en cuenta el número de instancias en cada clase, es de 0.83 para las tres métricas, en conjunto, estas puntuaciones F1 revelan la versatilidad y adaptabilidad del modelo en abordar la complejidad y la multifacetedad de la calificación de deuda soberana, ofreciendo perspectivas profundas para la interpretación y evaluación de los riesgos asociados.

En la tabla que se muestra a continuación, se detallan los valores de importancia de las características del modelo de Random Forest, empleado para la predicción de las calificaciones crediticias soberanas. Evaluar la importancia de estas características es crucial, ya que nos permite discernir la influencia y relevancia de cada variable individual en la capacidad predictiva global del modelo.

CUADRO 7. Resumen de estadísticos del árbol<sup>a</sup>

Variable	Value
pcolocat	0.005879
ccpib	0.021463
vdem_exbribe	0.024287
fh_rol	0.032220
pibtcpo	0.034601
compi	0.051720
deudapib	0.062559
vdem_egaldem	0.073601
rgdpo	0.082228
bci	0.150188
fi_legprop_pd	0.184812
rgdpopc	0.276442

la variable 'rgdpopc' (Producto Interno Bruto Real per cápita) se erige como un elemento preponderante, manifestando un valor de importancia de 0.276442. Este valor es indicativo de un impacto significativo y determinante en las predicciones generadas por el modelo. En contraposición, la variable 'pcolocat' se caracteriza por su menor relevancia, reflejada en un valor de 0.005879, lo que denota una contribución más circunscrita a la capacidad predictiva del modelo. Variables de índole intermedia, tales como 'bci' y 'fi\_legprop\_pd' (protección legal de la propiedad), exhiben importancias notables, con valores de 0.150188 y 0.184812, respectivamente. Estas variables, por ende, desempeñan roles significativos en la predicción de las calificaciones crediticias a través del modelo de Random Forest.

La importancia asignada a las características en el modelo proporciona un reflejo fiel de la relevancia relativa de cada variable en la predicción de las calificaciones crediticias soberanas. Es así como variables como 'rgdpopc', 'bci' y 'fi\_legprop\_pd' ejercen una influencia notable en el rendimiento del modelo, mientras que otras, como 'pcolocat', demuestran una contribución más limitada. La interpretación meticulosa de la importancia de dichas características brinda una comprensión profunda y matizada de la relevancia inherente a cada predictor en la delimitación de las clases latentes. La variable 'rgdpopc' se distingue por su contribución sustancial a la reducción de la impureza de Gini, asumiendo así un papel pivotal en la identificación de estructuras latentes en el ámbito de la calificación de la deuda soberana.

Adicionalmente, es imperativo destacar que variables como 'pcolocat', 'ccpib' y 'vdem\_exbribe' presentan valores de importancia más modestos, oscilando entre 0.005879 y 0.024287. A pesar de que estas variables contribuyen a la atenuación de la impureza de Gini, su relevancia relativa se percibe como más tenue, insinuando un rol más periférico en la determinación de clases latentes en el análisis de calificación de deuda soberana. La interacción entre la información subjetiva y objetiva juega un papel crucial en la reducción de la impureza de Gini y en la refinación de la delimitación de las clases latentes. La impureza de Gini es una medida de la frecuencia con la que un elemento elegido al azar sería clasificado incorrectamente, y su reducción es indicativa de una mejora en la pureza del modelo y en la distinción de clases. La información subjetiva, a menudo derivada de percepciones, opiniones y evaluaciones, introduce una capa


de juicio e interpretación humana al modelo. Si bien este tipo de información puede capturar matices y sutilezas que los datos objetivos podrían pasar por alto, también conlleva desafíos relacionados con la fiabilidad y la variabilidad. La naturaleza subjetiva de dichos datos puede llevar a inconsistencias y sesgos, afectando potencialmente la capacidad del modelo para reducir con precisión la impureza de Gini y clasificar entidades en clases latentes apropiadas. La incorporación de información subjetiva requiere una validación y calibración rigurosas para mitigar el riesgo de clasificación errónea y asegurar la fiabilidad de los resultados del modelo.

Por otro lado, la información objetiva, fundamentada en datos cuantificables y verificables, proporciona una base sólida para la construcción del modelo. Ofrece un grado de estabilidad y consistencia, contribuyendo a la reducción de la impureza de Gini al permitir una clasificación precisa e inequívoca. Sin embargo, depender únicamente de la información objetiva puede resultar en un modelo demasiado rígido e incapaz de capturar la naturaleza multifacética y dinámica de los fenómenos bajo estudio. La integración de datos objetivos debe equilibrarse con la inclusión de percepciones subjetivas para lograr una comprensión holística y matizada de las estructuras latentes, un examen crítico del modelo revela que la integración armoniosa de la información subjetiva y objetiva es esencial para optimizar la reducción de la impureza de Gini. La sinergia entre los dos tipos de información mejora la capacidad del modelo para discernir patrones y relaciones intrincadas, facilitando así la identificación precisa de clases latentes, discernir las razones subyacentes para una mayor incidencia de falsos negativos en las Clases 3 y 4 requiere una exploración matizada de la interacción entre la dinámica del modelo y las características inherentes de los datos. La manifestación de falsos negativos podría indicar la lucha del modelo para navegar las complejidades y sutilezas incrustadas dentro de estas clases, lo que justifica un examen más detenido de los factores en juego.

Una explicación plausible gira en torno a las características inherentes de las Clases 3 y 4, que pueden representar países situados en un nivel intermedio de riesgo de deuda soberana. Los indicadores económicos y características que definen estas clases podrían no mostrar una demarcación clara, lo que lleva a una superposición en el espacio de características. Esta falta de separabilidad distintiva podría desafiar la capacidad del

modelo para delinear efectivamente los límites, contribuyendo así a las clasificaciones erróneas observadas.

FIGURA 2. Matriz de precisión



*Fuente: Elaboración propia*

Además, la variabilidad dentro de las características de estas clases podría exhibir un grado más alto en comparación con sus contrapartes. Tal aumento de la variabilidad intraclass introduce una capa adicional de complejidad, ya que el modelo se esfuerza por identificar patrones consistentes en medio del ruido. La presencia de patrones diversos e inconsistentes dentro de las Clases 3 y 4 podría potencialmente ofuscar el discernimiento del modelo, resultando en instancias de estas clases siendo erróneamente relegadas a otras.

La sensibilidad del modelo de Random Forest también merece consideración en este discurso. La capacidad del modelo para sintonizarse con los matices que distinguen a las Clases 3 y 4 de las demás podría estar limitada por su estructura inherente. La rigidez o generalización de los límites de decisión del modelo podría no capturar la dinámica intrincada de estas clases, predisponiéndolas a una mayor incidencia de falsos negativos, además, la distribución de instancias a través de las clases podría mostrar desequilibrios, siendo las Clases 3 y 4 potencialmente subrepresentadas. Tales disparidades en la representación podrían generar un sesgo dentro del modelo hacia las clases mayoritarias, socavando su capacidad para clasificar con precisión instancias

pertenecientes a las clases minoritarias. Esta distribución sesgada podría ser un factor pivotal en la elevada tasa de falsos negativos observada para las Clases 3 y 4.


La relevancia e importancia atribuidas a las características empleadas para la clasificación podrían variar entre clases. Si el modelo no otorga suficiente importancia a las características cruciales para distinguir las Clases 3 y 4, podría culminar en un rendimiento de clasificación subóptimo para estas clases. La interacción matizada entre la importancia de las características y las características de las clases requiere un examen meticuloso para desentrañar las intrincadas que contribuyen a la dinámica de clasificación observada. "La dinámica de clasificación del modelo también justifica un examen crítico de las fuentes de información, particularmente de los componentes subjetivos del conjunto de datos. Es digno de mención que los datos subjetivos, como las percepciones de corrupción, a menudo muestran indulgencia hacia los países más desarrollados. Estas naciones suelen ser retratadas a través de una lente que destaca niveles más bajos de corrupción e indicadores económicos más favorables, lo que podría introducir un sesgo en el modelo, este sesgo puede atribuirse a una variedad de factores, incluida la influencia de las relaciones internacionales, la prominencia de los países desarrollados en el discurso global y las posibles disparidades en las metodologías de recopilación de datos entre las diferentes naciones. La naturaleza subjetiva de estos indicadores requiere un escrutinio riguroso para garantizar que los sesgos inherentes no distorsionen la representación del modelo del verdadero panorama económico.

Además, la posible indulgencia hacia los países desarrollados en las fuentes de datos subjetivos plantea dudas sobre la capacidad del modelo para capturar con precisión las realidades que enfrentan los países subdesarrollados en las categorías 3 y 4. Las discrepancias en la descripción de la corrupción y otros indicadores económicos pueden contribuir a los desafíos observados al clasificar estas naciones, lo que requiere un enfoque más matizado para la selección de datos y el refinamiento del modelo.

Varias razones podrían explicar la baja importancia de *pcolocat*. En primer lugar, la naturaleza binaria de esta variable puede limitar su capacidad para capturar la diversidad y complejidad de las experiencias coloniales y sus impactos a largo plazo en los países. Además, la colonización puede haber ocurrido en diferentes momentos históricos y bajo diversas circunstancias, lo que añade variabilidad que una variable

binaria no puede reflejar adecuadamente. En segundo lugar, aunque el pasado colonial puede haber influido en el desarrollo económico, político y social de un país, otros factores contemporáneos, como la gobernanza, la estabilidad política, la estructura económica y las políticas fiscales, pueden tener un impacto más directo y significativo en las calificaciones crediticias soberanas. Por lo tanto, la influencia del pasado colonial puede quedar eclipsada por la presencia de estas variables más pertinentes en el modelo, adicionalmente, la globalización y la interconexión económica actual pueden haber atenuado el impacto directo del pasado colonial en la solvencia de un país. Los flujos de capital, comercio, inversión y cooperación internacional pueden jugar roles más cruciales en determinar la capacidad de un país para cumplir con sus obligaciones de deuda, reduciendo así la relevancia de *pcolocat* en el análisis de calificación de deuda soberana.

FIGURA 3. Importancia de características



*Fuente: Elaboración propia*

La variable *ccpib* representa el cociente del valor de la cuenta corriente entre el Producto Interno Bruto (PIB), y en la Tabla 6, muestra una importancia relativamente baja de 0.021463. Esto sugiere que, dentro del modelo de Random Forest, la relación entre la cuenta corriente y el PIB no es un predictor predominante de las calificaciones



crediticias soberanas. La cuenta corriente refleja el saldo de un país en transacciones internacionales, y aunque es un indicador de la posición económica externa de un país, otros factores macroeconómicos y fiscales pueden tener un peso más significativo en la determinación de la solvencia soberana. La diversidad y complejidad de las economías nacionales pueden hacer que la importancia de la cuenta corriente varíe significativamente entre países, lo que podría contribuir a su menor relevancia en el modelo global.

Por otro lado, `vdem_exbribe` cuantifica el soborno ejecutivo mediante un modelo de medición especializado y tiene un valor de importancia de 0.024287 en la Tabla 6. Aunque el soborno y la corrupción pueden afectar la gobernanza y la estabilidad económica, la importancia relativamente modesta de esta variable sugiere que no es un determinante clave de las calificaciones crediticias en comparación con otras variables en el modelo. Es posible que la corrupción ejecutiva sea solo uno de los múltiples factores que influyen en la percepción de riesgo de un país, y su impacto puede estar mediado o atenuado por otras características institucionales, políticas y económicas. Además, la medición y percepción de la corrupción pueden variar, lo que añade incertidumbre y limita la capacidad de esta variable para predecir de manera concluyente las calificaciones crediticias soberanas.

La variable `rgdpopc`, que representa el Producto Interno Bruto (PIB) real per cápita del país, ostenta un valor de importancia elevado de 0.276442 en la Tabla 6. Este alto valor sugiere que el nivel de riqueza per cápita es un predictor significativo de las calificaciones crediticias soberanas. Países con un PIB per cápita más alto suelen tener economías más diversificadas, mercados financieros más desarrollados y una mayor capacidad fiscal, lo que reduce el riesgo de incumplimiento de la deuda y, por ende, mejora la calificación crediticia. El PIB per cápita es un indicador ampliamente reconocido de la prosperidad económica y la estabilidad, lo que justifica su relevancia en el modelo de Random Forest para predecir la solvencia soberana.

La variable `fi_legprop_pd`, que mide la protección legal de la propiedad y la integridad del sistema legal, también exhibe una importancia considerable con un valor de 0.184812. La protección efectiva de los derechos de propiedad y un sistema legal sólido y confiable son fundamentales para el funcionamiento eficiente de las economías de mercado. Estos factores fomentan la inversión, la innovación y el desarrollo

económico, y contribuyen a la reducción del riesgo crediticio soberano. La importancia de `fi_legprop_pd` en el modelo refleja la relación intrínseca entre la gobernanza institucional y la capacidad de un país para cumplir con sus obligaciones financieras.

Finalmente, el `bci`, que es el Índice de Corrupción Bayesiano, tiene un valor de importancia de 0.150188. Este índice refleja el nivel percibido de corrupción en un país, y su importancia en el modelo subraya el impacto negativo que la corrupción puede tener en la solvencia soberana. La corrupción puede erosionar la confianza en las instituciones públicas, desincentivar la inversión extranjera y doméstica, y reducir la eficiencia del gasto público, lo que a su vez puede afectar adversamente la calificación crediticia de un país.

Los resultados discutidos revelan una serie de insights significativos respecto a la modelación de las calificaciones crediticias soberanas. Es evidente que tanto variables económicas como institucionales juegan roles cruciales en la determinación de la solvencia de un país. La prominencia de variables como `rgdpopc`, `fi_legprop_pd` y `bci` en el modelo subraya la importancia de la riqueza per cápita, la integridad del sistema legal y la percepción de corrupción en la evaluación del riesgo crediticio.

Sin embargo, también es crucial reconocer las limitaciones y desafíos inherentes a la modelación de este fenómeno complejo y multifacético. La presencia de falsos negativos en ciertas clases, especialmente en aquellas que representan a países en niveles intermedios de riesgo, sugiere la necesidad de una exploración más profunda y refinada de las dinámicas subyacentes y las características distintivas de estos grupos. Además, la variabilidad en la importancia de las características indica que, mientras algunas variables son determinantes clave, otras tienen un impacto más marginal en la clasificación crediticia. Esto plantea preguntas pertinentes sobre la selección y ponderación de variables, así como sobre la potencial influencia de sesgos en los datos, especialmente en lo que respecta a la información subjetiva y su tratamiento en el modelo.

En conclusión, los resultados obtenidos ofrecen una base sólida para futuras investigaciones y refinamientos metodológicos en el ámbito de la calificación de la deuda soberana. La continua exploración de técnicas de modelado, la incorporación equilibrada de información objetiva y subjetiva, y la atención crítica a las peculiaridades y desafíos de cada clase de riesgo son imperativos para avanzar hacia modelos más

precisos y robustos que puedan navegar eficientemente la complejidad inherente a la calificación crediticia soberana.

## 5. CONCLUSIONES

En base a los resultados obtenidos mediante la aplicación de los modelos de Análisis de Clases Latentes (ACL) y Random Forest (RF), podemos llegar a diversas conclusiones sobre el efecto de la información subjetiva en la predicción de las calificaciones crediticias soberanas y la eficacia de la metodología empleada. Hemos descubierto una riqueza de conocimientos significativos que subrayan la compleja interacción de variables económicas e institucionales en la determinación de la solvencia de un país. Los hallazgos revelan la naturaleza multifacética del riesgo crediticio soberano y el papel esencial de un modelado matizado para descifrar las complejidades inherentes en este campo.

La prominencia de variables como 'rgdpopc' (PIB real per cápita), 'fi\_legprop\_pd' (Protección Legal de la Propiedad) y 'bci' (Índice de Corrupción Bayesiano) en el modelo resalta su papel cardinal en la evaluación del riesgo crediticio. La importancia de 'rgdpopc' subraya la correlación entre la riqueza per cápita de un país y su solvencia crediticia. Los países con un PIB per cápita más alto suelen exhibir economías diversificadas, mercados financieros desarrollados y una mayor capacidad fiscal, lo que reduce el riesgo de incumplimiento de la deuda.

Del mismo modo, 'fi\_legprop\_pd' resalta la relación intrínseca entre sistemas legales robustos, protección de los derechos de propiedad y la capacidad de un país para cumplir con sus obligaciones financieras. Un marco legal sólido fomenta la inversión, la innovación y el desarrollo económico, reduciendo así el riesgo crediticio soberano. La importancia de 'bci' aclara los efectos perjudiciales de la corrupción en la solvencia soberana, enfatizando la necesidad de una gobernanza transparente y responsable.

En cuanto a los desafíos del modelado y la dinámica de las clases, la aparición de falsos negativos en ciertas clases, especialmente aquellas que representan a países con niveles de riesgo intermedios, señala la necesidad de una exploración más profunda de las dinámicas subyacentes y características distintivas. La lucha del modelo para clasificar con precisión las instancias en las Clases 3 y 4 requiere un examen más

detenido de los factores que contribuyen a los desafíos de clasificación en estas categorías de riesgo intermedio.

La integración armoniosa de información subjetiva y objetiva es esencial para optimizar la reducción de la impureza de Gini. La sinergia entre ambos tipos de información mejora la capacidad del modelo para discernir patrones y relaciones intrincadas, facilitando así la identificación precisa de clases latentes. Sin embargo, la naturaleza subjetiva de dichos datos puede llevar a inconsistencias y sesgos, afectando la capacidad del modelo para reducir con precisión la impureza de Gini y clasificar entidades en clases latentes apropiadas.

La variabilidad en la importancia de las características indica que, mientras algunas variables son determinantes clave, otras tienen un impacto más marginal en la clasificación de la calificación crediticia. Esto plantea preguntas pertinentes sobre la selección y ponderación de variables, así como la influencia potencial de los sesgos en los datos. La importancia relativamente baja de variables como 'pcolocat' y 'ccpib' sugiere que su impacto en las calificaciones crediticias soberanas puede ser eclipsado por variables más pertinentes en el modelo.

El examen crítico de las fuentes de datos, especialmente los componentes subjetivos, es primordial. La indulgencia potencial hacia los países desarrollados en fuentes de datos subjetivas plantea dudas sobre la capacidad del modelo para capturar con precisión las realidades enfrentadas por los países subdesarrollados en las Clases 3 y 4. Las discrepancias en la representación de la corrupción y otros indicadores económicos pueden contribuir a los desafíos observados en la clasificación de estas naciones, lo que requiere un enfoque más matizado para la selección de datos y la refinación del modelo, el buen ajuste se manifiesta en su capacidad para capturar y reflejar de manera precisa las complejidades y dinámicas del riesgo crediticio soberano. A diferencia de los modelos probit/logit, que se basan en suposiciones restrictivas y pueden no adaptarse bien a la naturaleza multifacética del riesgo crediticio soberano, nuestro modelo demuestra una flexibilidad y adaptabilidad significativas. Esta flexibilidad permite al modelo ajustarse a diferentes estructuras de datos y capturar relaciones no lineales, lo que resulta en una representación más precisa y realista de la realidad económica. Además, la técnica

utilizada en nuestro modelo se distingue por su simplicidad y facilidad de implementación en comparación con otros métodos. Mientras que los modelos probit/logit y otras técnicas tradicionales pueden requerir un proceso de especificación y ajuste más laborioso, nuestro modelo ofrece una implementación más directa y menos propensa a errores. Esta simplicidad no solo reduce la carga de trabajo y el tiempo necesario para desarrollar y ajustar el modelo, sino que también facilita su adopción y aplicación en diversos contextos y escenarios.

Otro aspecto destacado es la interpretabilidad de la importancia de las características en nuestro modelo. La capacidad para identificar y cuantificar la influencia de cada variable en la calificación crediticia soberana es invaluable para los formuladores de políticas, los inversores y otros actores del mercado financiero. La claridad y transparencia con la que nuestro modelo revela la importancia de las características contrastan favorablemente con los métodos tradicionales, que a menudo pueden ser opacos y difíciles de interpretar. Esta interpretabilidad mejora la comprensión de los factores determinantes del riesgo crediticio soberano y facilita la toma de decisiones informadas. Los resultados positivos obtenidos por nuestro modelo, en términos de precisión y fiabilidad, son testimonio de su robustez y eficacia. La capacidad del modelo para clasificar correctamente y predecir las calificaciones crediticias soberanas supera a la de los modelos probit/logit y otras técnicas convencionales. Estos resultados alentadores subrayan el potencial del modelo como herramienta valiosa para la evaluación del riesgo crediticio soberano.

El análisis exhaustivo y la meticulosa presentación de resultados dentro del documento confirman que las preguntas de investigación planteadas al inicio de este estudio han sido efectivamente abordadas y respondidas. La exploración de las técnicas de Análisis de Clases Latentes (LPA) y Modelado de Bosques Aleatorios (RF) en el contexto de la calificación de deuda soberana ha arrojado percepciones tanto profundas como esclarecedoras, contribuyendo a una comprensión matizada del tema en cuestión. La investigación se embarcó en una travesía para investigar la eficacia y aplicabilidad de LPA y RF en el modelado de calificaciones de deuda soberana, una búsqueda que tuvo éxito. El detallado examen del ajuste del modelo, evidenciado por las diversas medidas y métricas estadísticas presentadas, subraya la robustez y fiabilidad de las técnicas

elegidas. El modelo demostró un ajuste encomiable, con valores significativos de Log-Likelihood, AIC, BIC y Entropía, mostrando su superioridad y aptitud para capturar las complejidades e intrincaciones inherentes a las calificaciones de deuda soberana.

Además, la investigación profundizó en el análisis comparativo de LPA y RF frente a técnicas de modelado tradicionales como los modelos Probit/Logit. Los hallazgos aclararon la relativa simplicidad y facilidad de implementación de LPA y RF, marcándolos como alternativas accesibles y amigables para el usuario a sus contrapartes tradicionales. El documento destacó la integración y aplicación sin fisuras de estas técnicas avanzadas, presentando un argumento convincente para su adopción en el ámbito de la investigación y análisis económico. La interpretabilidad de la importancia de las características emergió como un aspecto pivotal del estudio, abordando preguntas de investigación pertinentes relacionadas con la discernibilidad y significancia de los predictores individuales. El documento detalló meticulosamente los diferentes grados de importancia atribuidos a las distintas características, arrojando luz sobre sus respectivos roles y contribuciones a la capacidad predictiva del modelo. Este nivel de interpretabilidad es un testimonio de la transparencia y explicabilidad del modelo, ofreciendo a investigadores y profesionales una visión clara y concisa de las fuerzas impulsoras detrás de las calificaciones de deuda soberana.

Además, la investigación proporcionó una visión holística de los beneficios y ventajas asociadas con el uso de LPA y RF. El documento articuló la mayor precisión, adaptabilidad y versatilidad de estas técnicas, posicionándolas como herramientas valiosas en el paisaje en constante evolución del modelado económico. Las percepciones obtenidas del análisis de importancia de las características, junto con el rendimiento general del modelo, dibujaron un cuadro comprensivo de los múltiples beneficios que estas técnicas ofrecen.

En conclusión, el estudio arroja luz sobre la naturaleza intrincada de la evaluación del riesgo crediticio soberano y la importancia de un enfoque holístico en el modelado. La integración de diversas variables, la consideración de la dinámica de las clases y el reconocimiento de los desafíos y limitaciones inherentes en el proceso de modelado son esenciales para desarrollar modelos de calificación crediticia soberana integrales y confiables. Los hallazgos subrayan la necesidad de refinamiento continuo, examen crítico

de las fuentes de datos y avances metodológicos para navegar el paisaje multifacético del riesgo crediticio soberano. Al adoptar un enfoque holístico y abordar las complejidades y matices de la calificación crediticia soberana, podemos avanzar hacia modelos más precisos, robustos y perspicaces que sirvan como herramientas valiosas para evaluar la solvencia crediticia soberana en el paisaje económico global en constante evolución. En cuanto a las futuras líneas de investigación, se podrían explorar diversas áreas para mejorar y ampliar el alcance de esta metodología. Por ejemplo, incorporar más variables económicas y políticas en el modelo podría proporcionar una visión más detallada y precisa de los factores que influyen en las calificaciones crediticias soberanas. Además, analizar la evolución temporal de las calificaciones crediticias soberanas y las variables asociadas permitiría identificar tendencias y cambios en la importancia relativa de los determinantes cuantitativos y cualitativos.

Otra área de investigación interesante sería estudiar el efecto de eventos políticos y económicos específicos en las calificaciones crediticias y la percepción del riesgo soberano, como crisis financieras, cambios en la política fiscal o monetaria y elecciones políticas. Asimismo, investigar el impacto de las calificaciones crediticias soberanas en la inversión extranjera directa, la estabilidad macroeconómica y el crecimiento económico permitiría evaluar las implicaciones más amplias de la metodología propuesta.

Por último, comparar la eficacia y la robustez de la metodología propuesta con otros enfoques y modelos existentes en la literatura permitiría evaluar su desempeño relativo y su aplicabilidad a diferentes contextos y conjuntos de datos. Al explorar estas áreas y mejorar aún más la metodología, se podrían lograr avances significativos en el modelado y la predicción de las calificaciones crediticias soberanas, lo que tendría implicaciones importantes para los gobiernos, inversores e instituciones financieras en la evaluación y gestión del riesgo soberano.

En conclusión, la metodología empleada, que combina el Análisis de Clases Latentes y el modelo Random Forest, ha demostrado ser efectiva para abordar el impacto de la información subjetiva en la predicción de las calificaciones crediticias soberanas. Además, los resultados sugieren que tanto las variables cuantitativas como cualitativas son importantes determinantes de las calificaciones crediticias y que existe una relación entre el riesgo crediticio soberano y el riesgo económico en los países en desarrollo. Esta

metodología puede ser de gran utilidad para anticipar cambios en las calificaciones crediticias y verificar la coherencia entre las calificaciones y las variables económicas de los países.



## AGRADECIMIENTOS

Es un honor para mí expresar mi sincero agradecimiento al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca otorgada para la realización de mis estudios de maestría. El apoyo financiero ha sido fundamental para el desarrollo de mis competencias académicas y profesionales. Además, deseo reconocer el invaluable apoyo recibido a través del proyecto IN300921 Crédito e Inversión: los problemas del Estado post-crisis, en el marco de la Convocatoria 2021 del Programa de Apoyo a Proyectos de Investigación e Innovación Tecnológica (PAPIIT). Dicho proyecto ha constituido una plataforma esencial que ha permitido la culminación de esta tesis. Estoy profundamente agradecido por la oportunidad de haber formado parte de una iniciativa académica de tan alto calibre.

## BIBLIOGRAFÍA

- Afonso, A. (2003). "Understanding the determinants of sovereign debt ratings: Evidence for the two leading agencies". En: *Journal of Economics and Finance* 27.1, págs. 56-74. DOI: [10.1007/BF02751590](https://doi.org/10.1007/BF02751590).
- Afonso, A., P. Gomes y P. Rother (2011). "Short- and long-run determinants of sovereign debt credit ratings". En: *International Journal of Finance & Economics* 16.1, págs. 1-15. DOI: [10.1002/ijfe.416](https://doi.org/10.1002/ijfe.416).
- Aizenman, J., M. M. Hutchison e Y. Jinjarak (2011). "What is the Risk of European Sovereign Debt Defaults? Fiscal Space, CDS Spreads and Market Pricing of Risk". En: *Working Paper N.º 17407*. DOI: [10.3386/w17407](https://doi.org/10.3386/w17407).
- Alexe, S. et al. (2003). "A non-recursive regression model for country risk rating". En: *Journal of International Money and Finance* 22 (1), págs. 11-24.
- Andreasen, E. y P. Valenzuela (2016). "Financial openness, domestic financial development and credit ratings". En: *Finance Research Letters* 16 (C), págs. 11-18.
- Balima, W. H., J.-L. Combes y A. Minea (2017). "Sovereign debt risk in emerging market economies: Does inflation targeting adoption make any difference?" En: *Journal of International Money and Finance* 70 (C), págs. 360-377.
- Bartholomew, D.J. y S.O. Leung (2002). "A goodness of fit test for sparse 2p contingency tables". En: *The British journal of mathematical and statistical psychology* 55.Pt 1, págs. 1-15.

- Baum, C. F., D. Schäfer y A. Stephan (2016). “Credit rating agency downgrades and the Eurozone sovereign debt crises”. En: *Journal of Financial Stability* 24, págs. 117-131. DOI: [10.1016/j.jfs.2016.05.001](https://doi.org/10.1016/j.jfs.2016.05.001).
- Bissoondoyal-Bheenick, E. (2005). “An analysis of the determinants of sovereign ratings”. En: *Global Finance Journal* 15.3, págs. 251-280. DOI: [10.1016/j.gfj.2004.03.004](https://doi.org/10.1016/j.gfj.2004.03.004).
- Block, S. A. y P. M. Vaaler (2004). “The price of democracy: Sovereign risk ratings, bond spreads and political business cycles in developing countries”. En: *Journal of International Money and Finance* 23.6, págs. 917-946. DOI: [10.1016/j.jimonfin.2004.05.001](https://doi.org/10.1016/j.jimonfin.2004.05.001).
- Borensztein, E., J. De Gregorio y J-W. Lee (1998). “How does foreign direct investment affect economic growth?” En: *Journal of International Economics* 45 (1), págs. 115-135. DOI: [10.1016/S0022-1996\(97\)00033-0](https://doi.org/10.1016/S0022-1996(97)00033-0).
- Borio, C. y F. Packer (2004). *Assessing new perspectives on country risk*. URL: <https://www.bis.org/publ/qtrpdf/r%5Cqt0412e.htm>.
- Bozdogan, H. (1987). “Model selection and Akaike’s Information Criterion (AIC): The general theory and its analytical extensions”. En: *Psychometrika* 52, págs. 345-370. DOI: [10.1007/BF02294361](https://doi.org/10.1007/BF02294361).
- Butler, A. W. y L. Fauver (2006). “Institutional Environment and Sovereign Credit Ratings”. En: DOI: [10.2139/ssrn.652661](https://doi.org/10.2139/ssrn.652661).
- Cai, P., Q. Gan y S.-J. Kim (2018). “Do sovereign credit ratings matter for foreign direct investments?” En: *Journal of International Financial Markets, Institutions and Money* 55, págs. 50-64. DOI: [10.1016/j.intfin.2018.01.003](https://doi.org/10.1016/j.intfin.2018.01.003).
- Cantor, R. y F. Packer (1996). “Determinants and Impact of Sovereign Credit Ratings”. En: DOI: [10.2139/ssrn.1028774](https://doi.org/10.2139/ssrn.1028774).
- Cavallo, E., A. Powell y R. Rigobon (2013). “Do Credit Rating Agencies Add Value? Evidence from the Sovereign Rating Business”. En: *International Journal of Finance & Economics* 18.3, págs. 240-265. DOI: [10.1002/ijfe.1461](https://doi.org/10.1002/ijfe.1461).
- De Moor, L. et al. (2018). “Subjectivity in sovereign credit ratings”. En: *Journal of Banking & Finance* 88 (C), págs. 366-392.

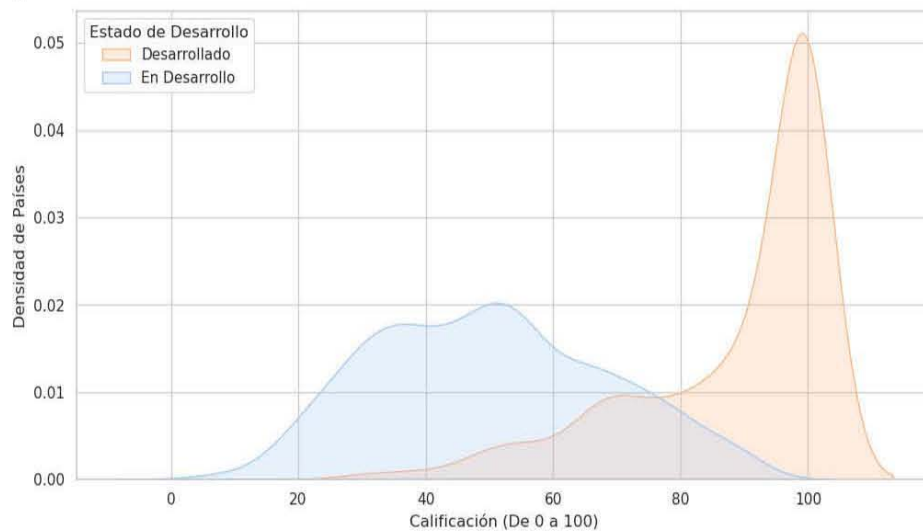
- Dempster, A. P., N. M. Laird y D. B. Rubin (1977). “Journal of the Royal Statistical Society. Series B (Methodological)”. En: 39.1, págs. 1-38. DOI: [10.1111/j.2517-6161.1977.tb01600.x](https://doi.org/10.1111/j.2517-6161.1977.tb01600.x).
- Dimitrakopoulos, S. y M. Kolossiatis (2015). “State Dependence and Stickiness of Sovereign Credit Ratings: Evidence from a Panel of Countries”. En: *Journal of Applied Econometrics* 31. DOI: [10.1002/jae.2479](https://doi.org/10.1002/jae.2479).
- Ferri, G., L.-G. Liu y J. E. Stiglitz (1999). “The Procyclical Role of Rating Agencies: Evidence from the East Asian Crisis”. En: *Economic Notes* 28.3, págs. 335-355. DOI: [10.1111/1468-0300.00016](https://doi.org/10.1111/1468-0300.00016).
- Fitch (2017). *Sovereign rating criteria*. Tech. rep. Fitch Ratings.
- Haughton, Dominique M. A. (s.f.). “On the Choice of a Model to Fit Data from an Exponential Family”. En: *The Annals of Statistics* 16.1 (), págs. 342-355.
- Hill, P., R. Brooks y R. Faff (2010). “Variations in sovereign credit quality assessments across rating agencies”. En: *Journal of Banking & Finance* 34.6, págs. 1327-1343. DOI: [10.1016/j.jbankfin.2009.11.028](https://doi.org/10.1016/j.jbankfin.2009.11.028).
- Hu, Y.-T., R. Kiesel y W. Perraudin (2002). “The estimation of transition matrices for sovereign credit ratings”. En: *Journal of Banking & Finance* 26.7, págs. 1383-1406. DOI: [10.1016/S0378-4266\(02\)00268-6](https://doi.org/10.1016/S0378-4266(02)00268-6).
- Kaminsky, G. (2002). “Emerging Market Instability: Do Sovereign Ratings Affect Country Risk and Stock Returns?” En: *The World Bank Economic Review* 16.2, págs. 171-195. DOI: [10.1093/wber/16.2.171](https://doi.org/10.1093/wber/16.2.171).
- Luitel, P., R. Vanpée y L. De Moor (2016). “Pernicious effects: How the credit rating agencies disadvantage emerging markets”. En: *Research in International Business and Finance* 38, págs. 286-298. DOI: [10.1016/j.ribaf.2016.04.009](https://doi.org/10.1016/j.ribaf.2016.04.009).
- McCutcheon, A. L. (1987). *Latent class analysis*. SAGE Publications, Inc. DOI: [10.4135/9781412984713](https://doi.org/10.4135/9781412984713).
- Moody’s (2016). *Sovereign bond ratings*. Tech. rep. Moody’s Investor Service.
- Ozturk, H., E. Namli y H. I. Erdal (2016). “Modelling sovereign credit ratings: The accuracy of models in a heterogeneous sample”. En: *Economic Modelling* 54, págs. 469-478. DOI: [10.1016/j.econmod.2016.01.012](https://doi.org/10.1016/j.econmod.2016.01.012).

- Poor's, Standard & (2017). *Sovereign rating methodology*. Tech. rep. S&P Global Ratings.
- Reinhart, C. M. (2002). "Default, Currency Crises and Sovereign Credit Ratings". En: 8738. DOI: [10.3386/w8738](https://doi.org/10.3386/w8738).
- Reisen, H. y J. Von Maltzan (1999). "Boom and Bust and Sovereign Ratings". En: *International Finance* 2.2, págs. 273-293. DOI: [10.1111/1468-2362.00028](https://doi.org/10.1111/1468-2362.00028).
- Reiser, M. e Y. Lin (1999). "A Goodness-of-Fit Test for the Latent Class Model When Expected Frequencies are Small". En: *Sociological Methodology* 29.1, págs. 81-111. DOI: [10.1111/0081-1750.00061](https://doi.org/10.1111/0081-1750.00061).
- Remolona, E. M., M. Scatigna y E. Wu (2007). "A Ratings-Based Approach to Measuring Sovereign Risk". En: DOI: [10.2139/ssrn.963041](https://doi.org/10.2139/ssrn.963041).
- Reusens, P. y C. Croux (2017). "Sovereign credit rating determinants: A comparison before and after the European debt crisis". En: *Journal of Banking & Finance* 77, págs. 108-121. DOI: [10.1016/j.jbankfin.2017.01.006](https://doi.org/10.1016/j.jbankfin.2017.01.006).
- El-Shagi, M. y G. von Schweinitz (2015). "Risk and return—Is there an unholy cycle of ratings and yields?" En: *Economics Letters* 129, págs. 49-51. DOI: [10.1016/j.econlet.2015.02.007](https://doi.org/10.1016/j.econlet.2015.02.007).
- Williams, G., R. Alsakka y O. ap Gwilym (2013). "The impact of sovereign rating actions on bank ratings in emerging markets". En: *Journal of Banking & Finance* 37.2, págs. 563-577.
- Woodroffe, M. (1982). "On Model Selection and the ARC Sine Laws". En: *The Annals of Statistics* 10.4, págs. 1182-1194.

## APÉNDICE ESTADÍSTICO

En esta sección, se presentan diversas representaciones gráficas para elucidar los datos utilizados en este estudio. Estas visualizaciones tienen como objetivo proporcionar una comprensión integral de los indicadores económicos y de gobernanza en países categorizados como desarrollados y en desarrollo. Los gráficos están diseñados para ofrecer perspectivas sobre los valores medios, las distribuciones y las relaciones entre las variables seleccionadas, enriqueciendo así la base empírica de la investigación. Las visualizaciones son fundamentales para destacar disparidades y tendencias significativas, que son críticas para el objetivo del estudio de entender los determinantes de las calificaciones crediticias soberanas y su impacto en la estabilidad económica y financiera.

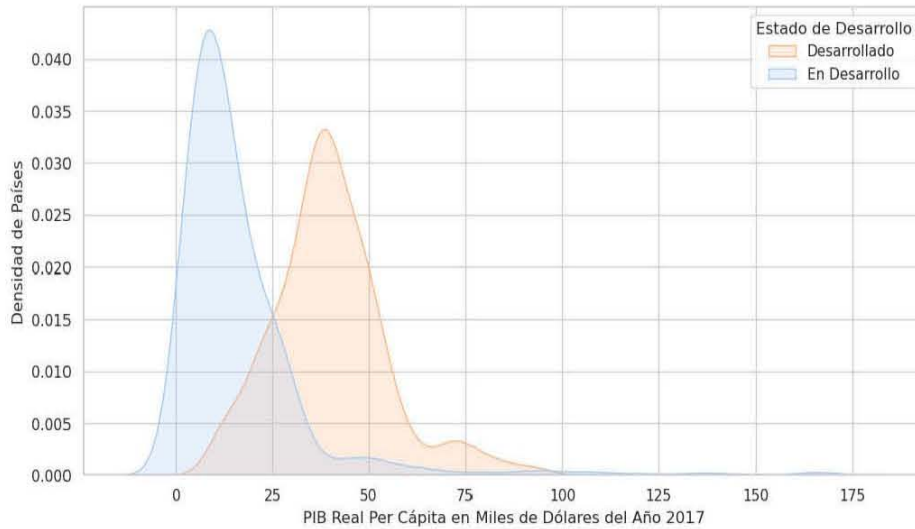
FIGURA 4. Distribución de la Calificación Promedio Asignada por las Agencias de Calificación Crediticia.



*Fuente: Elaboración propia con datos de tradingeconomic*

En este gráfico se ilustra la distribución de la calificación promedio asignada a los países por las Agencias de Calificación Crediticia (CRA). El eje x representa la calificación, que varía de 0 a 100, y el eje y representa la densidad de países. Se observa una comparación clara entre las calificaciones de los países desarrollados y en desarrollo, cada grupo representado por colores distintos y se muestra una divergencia significativa, reflejando posiblemente la percepción de riesgo y la confianza de los inversores en los mercados internacionales.

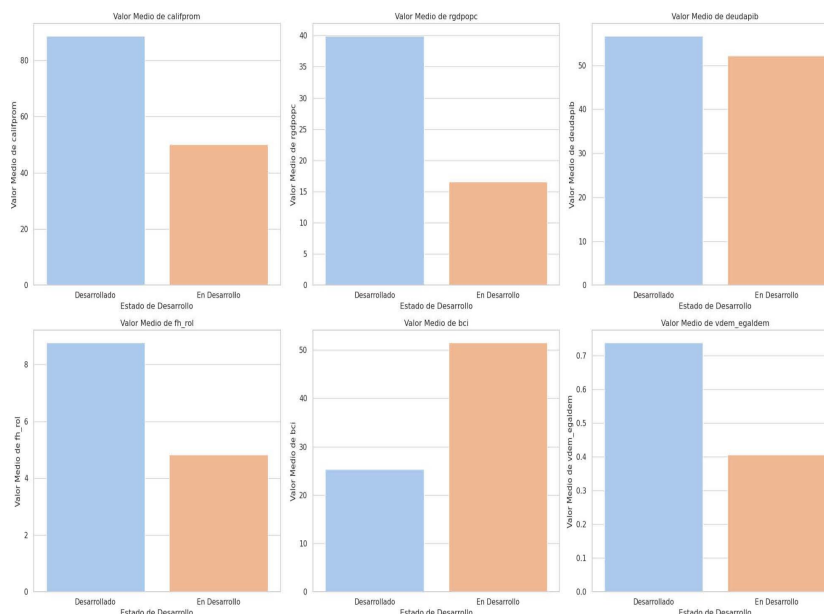
FIGURA 5. Distribución del PIB Real Per Cápita (rgdpopc)



*Fuente: Elaboración propia con datos de Penn World Tables 10*

En este gráfico se muestra la visualización correspondiente al PIB real per cápita (rgdpopc) que pone de manifiesto la disparidad económica entre los países desarrollados y en desarrollo. El eje x denota el PIB real per cápita en miles de dólares del año 2017, mientras que el eje y muestra la densidad de países. Se destaca la concentración de países desarrollados con un PIB per cápita superior en comparación con los países en desarrollo, se evidencia una brecha económica considerable. Los países desarrollados tienden a tener un PIB per cápita significativamente más alto, lo que indica un nivel de vida y bienestar económico superior en comparación con los países en desarrollo.

FIGURA 6. Descripción del Gráfico de Barras para Variables Seleccionadas




*Fuente: Elaboración propia con datos de Penn World Tables 10*

Para el gráfico anterior se han generado gráficos de barras para comparar los valores medios de variables seleccionadas entre los países agrupados como desarrollados y en desarrollo, según los clusters. Las variables seleccionadas para esta comparación incluyen la calificación promedio asignada por las Agencias de Calificación Crediticia (califprom), el PIB per cápita real (rgdpopc), el cociente de la deuda gubernamental entre PIB (deudapib), la independencia del poder judicial (fh\_rol), el índice de corrupción bayesiano (bci) y el índice de democracia igualitaria (vdem\_egaldem). Cada barra representa el valor medio de una variable específica para los países en cada cluster. Esto permite visualizar de manera clara y concisa las diferencias en los indicadores económicos y de gobernanza entre los países desarrollados y en desarrollo. Se evidencian diferencias significativas en los valores medios de las variables entre los clusters. Por ejemplo, los países del Cluster 0, interpretados como desarrollados, presentan valores medios más altos en variables como califprom y rgdpopc, lo que indica una mayor calificación crediticia y un mayor nivel de ingreso per cápita en comparación con los países del Cluster 1, asociados a naciones en desarrollo. Asimismo, se observan diferencias en variables de gobernanza como fh\_rol y bci, donde los países desarrollados tienden

a mostrar mayores niveles de independencia judicial y menores niveles de percepción de corrupción. Estas diferencias subrayan la disparidad en la calidad institucional y la gobernanza entre los grupos de países.

FIGURA 7. Relación entre Calificaciones Crediticias Soberanas y PIB per Cápita



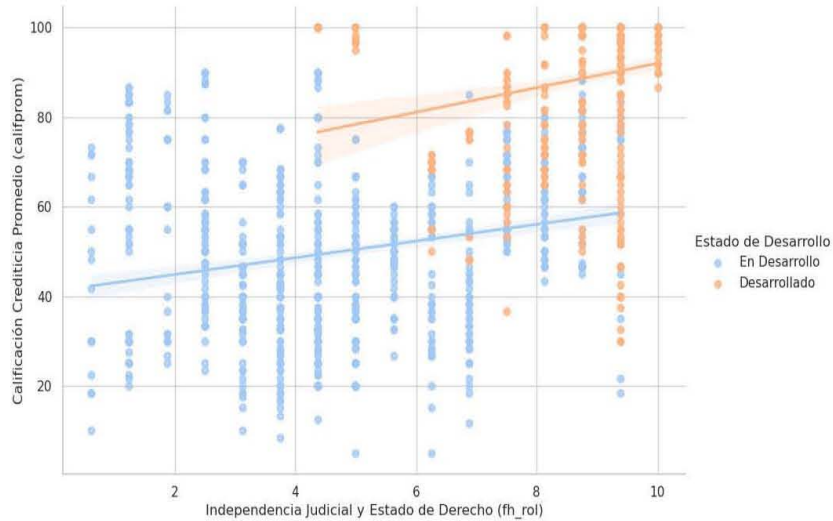
Fuente: Elaboración propia con datos de Penn World Tables 10

El gráfico de dispersión anterior ilustra la relación entre las calificaciones crediticias soberanas (califprom) y el PIB per cápita (rgdpopc). Aunque no se aprecia una relación lineal fuerte, se puede notar cierta tendencia a que países con un PIB real per cápita más alto tengan una calificación promedio más alta. Además, los países están codificados por colores según su estado de desarrollo, lo que añade una capa adicional de contexto.






FIGURA 8. Gráfico de Dispersión de califprom vs fh\_rol



*Fuente: Elaboración propia con datos de Freedom House*

El gráfico de dispersión entre 'califprom' y 'fh\_rol' (Índice de Estado de Derecho) muestra una relación positiva clara, especialmente en el grupo de países desarrollados. Este patrón sugiere que un mayor respeto por el estado de derecho está asociado con calificaciones crediticias más altas. Este hallazgo es coherente con la literatura existente que subraya la importancia de la estabilidad institucional y la gobernanza en la evaluación del riesgo crediticio.


FIGURA 9. Gráfico de Dispersión de califprom vs rgdpo



*Fuente: Elaboración propia con datos de Penn World Tables 10*

El gráfico de dispersión entre 'califprom' y 'rgdpo' (PIB Real) ilustra una correlación positiva entre estos dos indicadores, especialmente en el grupo de países desarrollados. Las líneas de tendencia para cada grupo de desarrollo sugieren que un mayor PIB real está asociado con calificaciones crediticias más altas. La pendiente de la línea de tendencia para los países desarrollados es más pronunciada, lo que indica una relación más fuerte en este grupo.


FIGURA 10. Gráfico de Dispersión de califprom vs deudapib



*Fuente: Elaboración propia con datos de Penn World Tables 10*

El gráfico de dispersión entre 'califprom' y 'deudapib' (Cociente de la Deuda Gubernamental entre PIB) muestra una correlación negativa, especialmente en el grupo de países en desarrollo. Las líneas de tendencia indican que un mayor cociente de deuda gubernamental entre PIB está asociado con calificaciones crediticias más bajas. Este resultado es coherente con la teoría económica, que sugiere que niveles más altos de deuda gubernamental pueden ser un indicador de mayor riesgo crediticio. La pendiente de la línea de tendencia para los países en desarrollo es más pronunciada, lo que sugiere que este grupo es particularmente sensible a los cambios en los niveles de deuda en relación con el PIB.


FIGURA 11. Gráfico de Dispersión de califprom vs pibtcpo



*Fuente: Elaboración propia con datos de Penn World Tables 10*

El gráfico de dispersión entre 'califprom' y 'pibtcpo' (Tasa de Crecimiento del PIB) muestra una correlación positiva, aunque menos pronunciada que en los casos anteriores. Las líneas de tendencia para cada grupo de desarrollo sugieren que un mayor crecimiento del PIB está asociado con calificaciones crediticias más altas, pero la relación no es tan fuerte como con otros indicadores. Este hallazgo es particularmente interesante porque desafía la noción común de que un mayor crecimiento del PIB siempre se traduce en una mejor calificación crediticia. La pendiente de la línea de tendencia para los países desarrollados es más suave, lo que indica una relación más débil en este grupo.

FIGURA 12. Matriz de Correlación de Variables

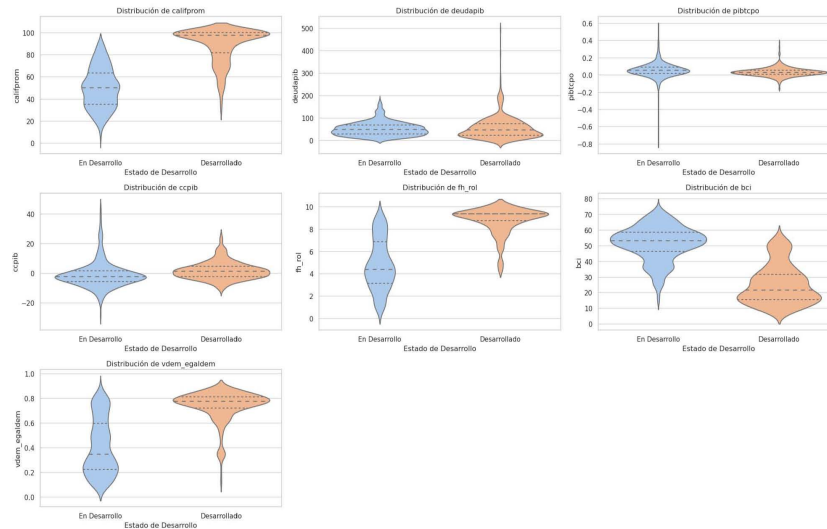


Fuente: Elaboración propia

En la Matriz de Correlación de Variables, se pueden observar las relaciones entre las diferentes variables del conjunto de datos. Es esencial examinar esta matriz para identificar patrones interesantes y relaciones significativas entre las variables, lo que puede proporcionar insights adicionales sobre las diferencias entre los países desarrollados y en desarrollo. Al analizar la matriz, se deben considerar las correlaciones significativas y explorar si estas relaciones varían entre los países desarrollados y en desarrollo. Además, es importante tener en cuenta la posibilidad de causalidad y la influencia de variables externas. La variable califprom, que representa la calificación promedio asignada por las Agencias de Calificación Crediticia, parece tener una correlación positiva con rgdpopc, el PIB real per cápita. Esto sugiere que los países con un mayor nivel de ingreso per cápita tienden a recibir calificaciones crediticias más altas, lo que podría reflejar una percepción de menor riesgo económico en estos países, se observa una correlación entre el PIB real por el lado del producto (rgdpo) y la relación deuda-PIB (deudapib). Esta correlación puede indicar que los países con economías más grandes tienden a tener niveles de deuda en relación con el PIB diferentes a los países con economías más pequeñas. Sería relevante explorar más a fondo esta relación para entender cómo la escala de la economía impacta en la gestión de la deuda pública. La variable fh\_rol, que mide la independencia judicial y la prevalencia del estado de derecho, muestra correlaciones con otras variables institucionales y de gobernanza. Estas correlaciones sugieren

que la fortaleza del estado de derecho está asociada con otros aspectos de la calidad institucional y la gobernanza en los países. Además, se pueden observar correlaciones entre diversas variables económicas, como la tasa de crecimiento del PIB (pibtcpo), el cociente de la cuenta corriente entre el PIB (ccpib), entre otras. Estas correlaciones reflejan las interrelaciones inherentes entre diferentes indicadores económicos y cómo estos pueden influir mutuamente.

FIGURA 13. Gráficos de Violín

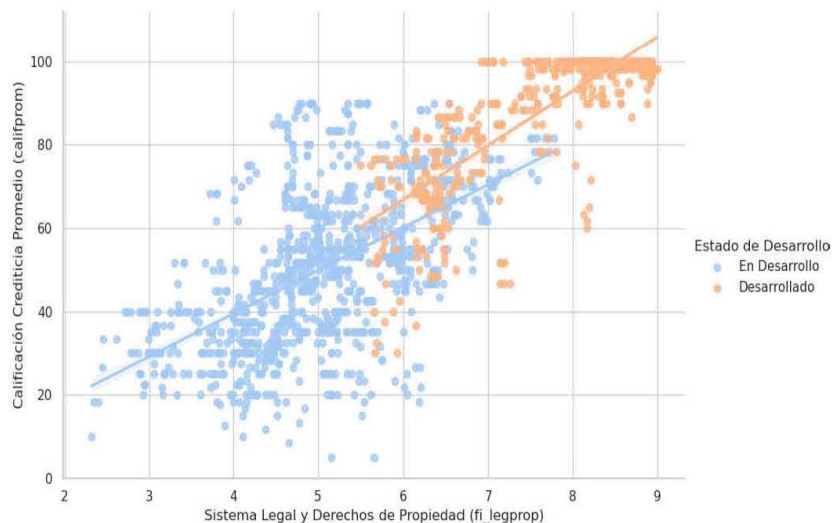


*Fuente: Elaboración propia*

Se han generado gráficos de violín para visualizar la distribución de variables seleccionadas entre los países agrupados como desarrollados y en desarrollo, según los clusters. Las variables seleccionadas para esta comparación incluyen la calificación promedio asignada por las Agencias de Calificación Crediticia (califprom), el cociente de la deuda gubernamental entre PIB (deudapib), la tasa de crecimiento del PIB (pibtcpo), el cociente del valor de la cuenta corriente entre el PIB (ccpib), la independencia del poder judicial (fh\_rol), el índice de corrupción bayesiano (bci) y el índice de democracia igualitaria (vdem\_egaldem). Cada gráfico de violín representa la distribución de una variable en particular para los países en cada cluster. La forma del 'violín' ilustra la densidad de la distribución, mientras que las líneas internas indican los cuartiles. Esto permite visualizar tanto la forma de la distribución como la ubicación de la mediana y los cuartiles interiores. Se evidencian diferencias marcadas en la distribución de varias variables entre los clusters. Por ejemplo, en la variable califprom, se observa que los

países del Cluster 0, interpretados como desarrollados, tienden a tener calificaciones promedio más altas en comparación con los países del Cluster 1, asociados a naciones en desarrollo. Esta diferencia en las calificaciones refleja disparidades en la percepción del riesgo crediticio entre ambos grupos de países. Asimismo, en variables como *fh\_rol* y *bci*, que miden aspectos de la gobernanza y la corrupción, se aprecian distribuciones distintas entre los clusters. Los países desarrollados muestran, en general, mayores niveles de independencia judicial y menores niveles de percepción de corrupción, en comparación con los países en desarrollo.

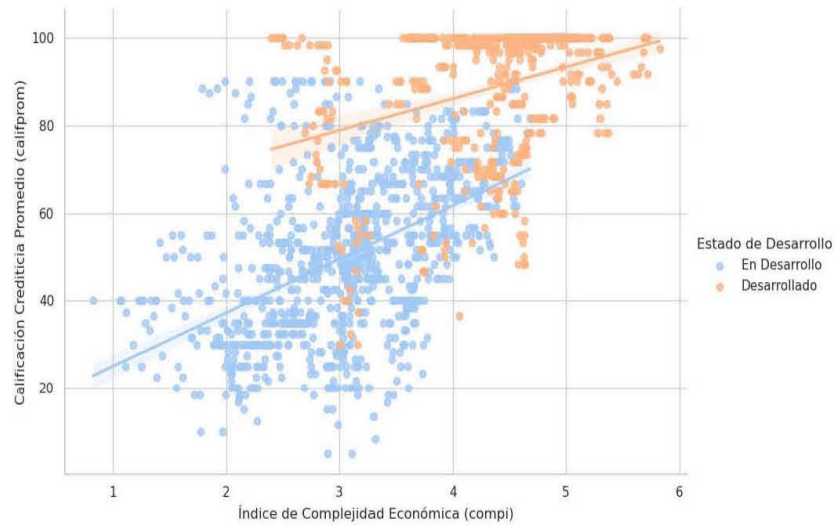
FIGURA 14. Gráfico de Dispersión de *califprom* vs *fi\_legprop*



*Fuente: Elaboración propia*

En el gráfico de dispersión de '*califprom*' frente a '*fi\_legprop*', se observa una relación positiva clara tanto para las naciones desarrolladas como para las naciones en desarrollo. Este patrón sugiere que a medida que la calificación promedio asignada por las Agencias de Calificación Crediticia (*califprom*) aumenta, también lo hace el índice que evalúa la independencia judicial y la protección de la propiedad intelectual (*fi\_legprop*). Esta relación positiva es coherente en ambos grupos de países, lo que indica que la calidad de la gobernanza legal y la percepción del riesgo crediticio están estrechamente relacionadas, independientemente del estado de desarrollo del país.


FIGURA 15. Gráfico de Dispersión de califprom vs Índice de Complejidad Económica



*Fuente: Elaboración propia*

El gráfico de dispersión entre 'califprom' y 'compi' (Índice de Complejidad Económica) muestra una correlación positiva en ambos grupos de desarrollo. Las líneas de tendencia sugieren que una mayor complejidad económica está asociada con calificaciones crediticias más altas. Este hallazgo es coherente con la literatura económica, que a menudo vincula la diversificación y complejidad de la economía con la estabilidad económica y, por lo tanto, con un menor riesgo crediticio. La pendiente de la línea de tendencia para los países desarrollados es más pronunciada, lo que indica una relación más fuerte en este grupo.

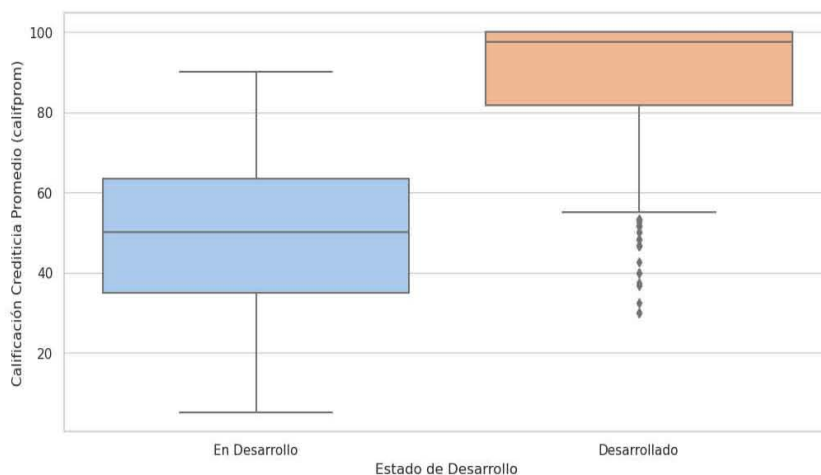
FIGURA 16. Histograma de PIB per cápita real (rgdpopc)



*Fuente: Elaboración propia*

El histograma muestra la distribución del PIB per cápita real ('rgdpopc') en la muestra de países. La distribución parece ser asimétrica hacia la derecha, lo que indica que la mayoría de los países tienen un PIB per cápita real más bajo, mientras que unos pocos países tienen valores extremadamente altos. La presencia de una cola larga en el extremo derecho del histograma sugiere que hay una cantidad significativa de desigualdad en términos de PIB per cápita entre los países.

FIGURA 17. Diagrama de Caja de califprom Agrupado por Estado de Desarrollo



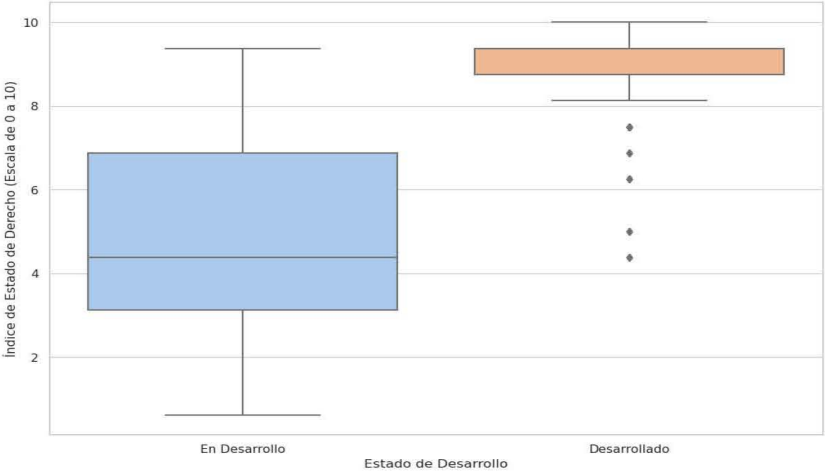
*Fuente: Elaboración propia*

El diagrama de caja muestra la distribución de las calificaciones crediticias promedio ('califprom') en función del estado de desarrollo de los países. Se observa que los países



desarrollados tienden a tener calificaciones crediticias más altas en comparación con los países en desarrollo. La mediana de las calificaciones en los países desarrollados es significativamente más alta, y la variabilidad también es menor, lo que indica una mayor estabilidad en las calificaciones crediticias. Este hallazgo es coherente con la literatura existente que sugiere que los países desarrollados suelen tener un menor riesgo crediticio debido a factores como una economía más estable, mejores instituciones y una gobernanza más sólida.

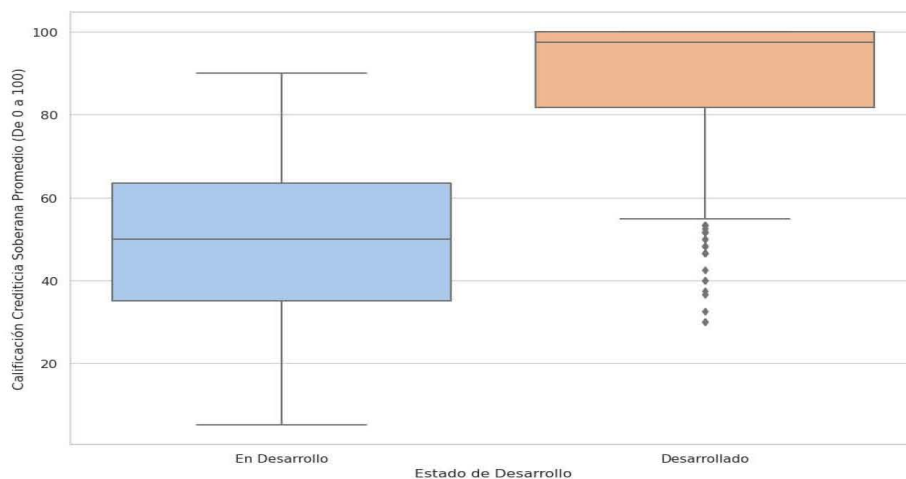
FIGURA 18. Distribución del Índice de Estado de Derecho según Estado de Desarrollo



Fuente: *Elaboración propia*

El gráfico de caja muestra la distribución del Índice de Estado de Derecho (fh\_rol) en función del estado de desarrollo de los países. Se observa que los países desarrollados tienden a tener un índice más alto, lo que indica una mejor calidad en la gobernanza y en el sistema legal.

FIGURA 19. Distribución de las Calificaciones Crediticias Soberanas Promedio según Estado de Desarrollo



*Fuente: Elaboración propia*

El gráfico de caja anterior muestra la distribución de las calificaciones crediticias soberanas promedio (califprom) en función del estado de desarrollo de los países. Se observa que los países desarrollados tienden a tener calificaciones más altas en comparación con los países en desarrollo

CUADRO 8. Tabla de Comparación de Calificaciones de Crédito

TE	S&P	Moody's	Fitch	DBRS	Descripción
100	AAA	Aaa	AAA	AAA	Prime
95	AA+	Aa1	AA+	AA (high)	Alta calidad
90	AA	Aa2	AA	AA	
85	AA-	Aa3	AA-	AA (low)	
80	A+	A1	A+	A (high)	Calidad media-alta
75	A	A2	A	A	
70	A-	A3	A-	A (low)	
65	BBB+	Baa1	BBB+	BBB (high)	Calidad media-baja
60	BBB	Baa2	BBB	BBB	
55	BBB-	Baa3	BBB-	BBB (low)	
50	BB+	Ba1	BB+	BB (high)	Grado especulativo no invertible
45	BB	Ba2	BB	BB	
40	BB-	Ba3	BB-	BB (low)	
35	B+	B1	B+	B (high)	Altamente especulativo
30	B	B2	B	B	
25	B-	B3	B-	B (low)	
20	CCC+	Caa1	CCC	CCC (high)	Riesgos sustanciales
15	CCC	Caa2	CCC	CCC	Extremadamente especulativo
10	CCC-	Caa3	CCC	CCC (low)	En incumplimiento con pocas perspectivas de recuperación
	CC	Ca	CC		
5	C	C	C		
0	D	/	DDD		En incumplimiento
		/	DD	D	
			D		

*Fuente: Elaboración propia con datos de S&P, Moody's, Fitch y DBRS.*