

**Determinación de factores financieros relacionados con la incorporación de las compañías  
en Colombia a la Ley 1116 de 2006**

**Presentado por:**

Angélica Viviana Rubio Anaya

Juan Sebastián Parra Zambrano

**CESA - Colegio de Estudios Superiores de Administración**

**Maestría en Finanzas Corporativas**

**Bogotá**

**2019**

**Determinación de factores financieros relacionados con la incorporación de las compañías  
en Colombia a la Ley 1116 de 2006**

**Presentado por:**

Angélica Viviana Rubio Anaya

Juan Sebastian Parra Zambrano

**Director:**

Julio Alejandro Sarmiento Sabogal

**CESA - Colegio de Estudios Superiores de Administración**

**Maestría en Finanzas Corporativas**

**Bogotá**

**2019**

## Tabla de Contenido

<b>1. Introducción</b>	<b>7</b>
<b>2. Estado del arte</b>	<b>12</b>
<b>2.1. El modelo Z-Score Altman</b>	<b>14</b>
<b>2.2. Modelos en el contexto latinoamericano</b>	<b>18</b>
<b>2.3. Nuevas técnicas basadas en inteligencia artificial</b>	<b>23</b>
<b>3. Marco teórico</b>	<b>26</b>
<b>3.1. Beneficios de la deuda y su relevancia en la estructura de capital</b>	<b>26</b>
<b>3.2. Los costos financieros derivados de la insolvencia</b>	<b>28</b>
<b>3.3. Las bases de los modelos de insolvencia</b>	<b>31</b>
3.3.1. Análisis discriminante - MDA	31
4.3.1. Análisis logit	32
3.3.3. Random forest	33
<b>4. Metodología</b>	<b>36</b>
<b>4.1. Construcción del panel de datos</b>	<b>36</b>
<b>4.2. Variables a analizar</b>	<b>38</b>
<b>4.3. Desarrollo del modelo random forest</b>	<b>39</b>
4.3.1. Análisis de resultados	41
<b>4.4. Desarrollo panel de datos logit</b>	<b>42</b>
4.4.1. Análisis de resultados	43
<b>5. Conclusiones</b>	<b>45</b>
<b>6. Bibliografía</b>	<b>48</b>
<b>Anexos</b>	<b>54</b>

## Índice de gráficos

Gráfica 1 Procesos aceptados a reorganización por año de aceptación – Acumulado a marzo 31 de 2019.....	8
Gráfica 2 Procesos aceptados a reorganización por año de aceptación – Acumulado a junio 30 de 2018.....	11
Gráfica 3 Construcción de un bosque aleatorio .....	35
Gráfica 4 Pasos del Machine Learning .....	36
Gráfica 5 Distribución sectorial de empresas en acuerdo sujetas a análisis .....	37

## Índice de tablas

Tabla 1. Ponderaciones Z - Score .....	15
Tabla 2. Ponderaciones Z1 - Score .....	16
Tabla 3. Ponderaciones Z2 - Score .....	18
Tabla 4. Función discriminante ZOC.....	19
Tabla 5. Comparativo de variables en modelos de predicción de insolvencia. ....	22
Tabla 6. Comparativo de variables en modelos de predicción de insolvencia. ....	24
Tabla 7 Indicadores financieros .....	38
Tabla 8 Variables utilizadas en Modelo Random Forest (RF) .....	40
Tabla 9 Matriz de confusión Random Forest (RF) .....	41
Tabla 10 Matriz de confusión Modelo Logit .....	42
Tabla 11 Iteración Variables Dicotómicas y Financieras .....	43
Tabla 12 Iteración Variables Financieras .....	44

Este trabajo es el resultado de un proceso de investigación entre los años 2018 – 2019, con la finalidad de realizar un análisis de los factores financieros, relacionados con la incorporación de empresas colombianas en el Acuerdo de Reorganización Empresarial o Ley 1116 de 2006, enfocado específicamente, en relacionar un conjunto de factores financieros relevantes, asociados a el riesgo de insolvencia, con el fin de detectar de forma oportuna dificultades en compañías de cualquier sector empresarial. El análisis se desarrolló a partir de una base de datos, que involucra información financiera entre los años 2013 y 2017, de compañías que han caído en ley 1116 de 2006 y empresas con buena salud financiera. La base de datos final, contó con más de 34,600 entidades de diferentes sectores de la economía colombiana, entre las más relevantes se encuentran los sectores de servicios, comercio, construcción, industrial, transporte y agroindustrial.

**Palabras clave:** Insolvencia, indicadores relevantes, detección oportuna, sectores.

#### **Abstract**

This work is the result of a research process between 2018 - 2019 with the purpose of conducting an analysis of the financial factors related to the incorporation mainly of Colombian companies in the Business Reorganization Agreement or Law 1116 of 2006, specifically focused , to relate a set of relevant financial factors associated with the risk of insolvency, in order to detect timely problems in companies of any business sector. The analysis was developed from a database that involves financial information between the years 2013 and 2017 of companies that have fallen in law 1116 of 2006 and companies with good financial health. The final database included more than 34,600 entities from different sectors of the Colombian economy, among the most relevant are the services, commerce, construction, industrial, transport and agroindustrial sectors.


**Keywords:** Insolvency, relevant indicators, timely detection, sectors.

## 1. Introducción

La *empresa* es la unidad fundamental del sistema económico; su función esencial es crear *valor* tanto *económico* como *social*. Por esta razón, para una sociedad es relevante contar con compañías sanas que no destruyan valor pero, sobre todo, que sean sostenibles en el tiempo. La salud financiera de una compañía, puede ser medida a través de *indicadores financieros* relevantes, que pueden dar alertas, frente a un problema de *solventia*, que termine derivándose en el no pago de salarios a los empleados, proveedores, gobierno o accionistas y que finalmente lleven a las empresas, a tomar acuerdos de reorganización empresarial; en el caso colombiano a la ley 1116 de 2006.

Durante el 2018, la economía colombiana registró un crecimiento del PIB del 2.7% respecto al año inmediatamente anterior, la ANDI indicó que “El 2018 se puede calificar como un año de recuperación económica”, esto basado en el comportamiento positivo de la mayoría de los sectores económicos y en el pobre resultado de la región (1.2%), en donde Colombia creció 2.7% “más del doble del indicador promedio de la región” (ANDI, 2019, pág. 7) sin embargo, este mejor desempeño no se tradujo en una desaceleración del número de compañías en acuerdos de reorganización empresarial, por el contrario, el indicador continuó en aumento, tanto así que, el año 2018 cerró con 572 nuevas empresas admitidas a Ley 1116, el registro más alto hasta el momento.

Gráfica 1 Procesos aceptados a reorganización por año de aceptación – Acumulado a marzo 31 de 2019



Fuente: Elaboración propia, con base en el informe periódico al corte de julio de 2019 de la Superintendencia de Sociedades.

Así las cosas, entre los años 2007 al 2018 la Superintendencia de Sociedades, cerró con 2,611 compañías en acuerdo de reorganización empresarial, en adelante las denominaremos *en acuerdo*; lo preocupante es que el año 2019 inicia con incertidumbre en los mercados internacionales; el FMI indica en su resumen ejecutivo de cierre 2018 que “...los riesgos para el crecimiento mundial han aumentado en los últimos 6 meses y la posibilidad de sorpresas positivas se ha disipado”, tanto así que para el cierre del primer trimestre de 2019 decidió recortar nuevamente las perspectivas de crecimiento mundial por debajo del 3.5%, esto fomentado principalmente por la tensión comercial



entre E.E.U.U. y China, la salida del Reino Unido de la Unión Europea, sin que medie un acuerdo y la desaceleración de varios países asiáticos entre ellos China. (FMI, 2019). Con un panorama nublado en términos de crecimiento económico global, se puede pensar entonces que el número de empresas con algún tipo de deterioro en sus cifras y que se verán obligadas a acogerse a acuerdos de reorganización empresarial, puede seguir en aumento, cobrando aún más importancia la idea de determinar aquellos ratios financieros que permitan identificar de forma anticipada y oportuna cuando una compañía está en riesgo de insolvencia.

Teniendo en cuenta estos antecedentes, lo primero es introducir el concepto de *insolvencia*<sup>1</sup>; la insolvencia técnica, existe cuando una empresa no puede cumplir con sus obligaciones actuales, lo que significa falta de liquidez, en otras palabras “decir que un negocio cae en insolvencia, es mencionar que no cuenta con una cantidad suficiente de efectivo para satisfacer los pagos programados de intereses y de capital, es decir, la empresa no puede servir su deuda” (Besley S, 2001). Dependiendo de cuán severos sean los problemas de liquidez, las compañías tienen dos opciones, “si el valor intrínseco o económico de una entidad es mayor que su valor de liquidación actual, se le debe permitir a la empresa intentar *reorganizarse* y continuar. Sin embargo, si los activos de la empresa están más muertos que vivos, es decir, si el valor de liquidación excede el valor económico de la empresa, la mejor alternativa es la *liquidación*” (Altman E. I., 2006 Pág. 8). Los acuerdos de reorganización como dice Altman en su libro *Corporate Financial Distress and Bankruptcy*, son “*programas de recuperación*”, que actúan como salvavidas o planes de rehabilitación para garantizar el saneamiento de deudas y encausar las actividades de la empresa en la maximización del valor ex post (Sarmiento J, 2005, págs. 19-30), contribuyendo de esta forma a preservar empresas con la capacidad de generar valor económico para la sociedad.

---

<sup>1</sup> (Altman E. I., 2006) la define como “otro término que describe el rendimiento negativo de la empresa y generalmente se utiliza de una manera más técnica.

Colombia ha tenido dos procesos formales de reorganización empresarial<sup>2</sup>, La *Ley 550*, expedida en 1999 que buscó establecer un régimen para promover la reactivación empresarial, mediante la definición y reglamentación de los acuerdos de reestructuración empresarial y, la *Ley 1116* expedida en 2006, ésta última corresponde al régimen de insolvencia vigente, que en su Artículo 1° establece, "...la presente ley, tiene por objeto la protección del crédito y la recuperación y conservación de la empresa como unidad de explotación económica y fuente generadora de empleo, a través de los procesos de reorganización y de liquidación judicial,...", en éste mismo aparte se define que "El proceso de reorganización pretende a través de un acuerdo, preservar empresas viables y normalizar sus relaciones comerciales y crediticias, mediante su reestructuración operacional, administrativa, de activos o pasivos." (Congreso de la Republica, 2006). En Colombia un proceso de reorganización puede dar inicio cuando la empresa deudora entra en cesación de pagos o cuando se evidencia su incapacidad de pago inminente.<sup>3</sup>

Teniendo en cuenta los antecedentes del caso colombiano, y la relevancia que tiene para una economía que las empresas tengan una buena salud financiera, el presente estudio quiere identificar los ratios financieros comunes en empresas colombianas, que permiten determinar de manera oportuna que una empresa, tiene posibilidades de declararse en insolvencia y por lo tanto requiera incorporarse a la Ley 1116 de 2006. Para lograr este objetivo, se usa información financiera histórica (2013 a 2017) tanto de compañías que a 30 de junio de 2018 se encontraban

---


<sup>2</sup> "..., se utiliza el término "reorganización" en sentido amplio, para referirse a los procedimientos cuya finalidad básica sea la de permitir al deudor superar sus dificultades financieras y reanudar o continuar el funcionamiento de sus operaciones comerciales normales, ..." (Ministerio de Comercio, Industria y Turismo y la Superintendencia de Sociedades, 2007)

<sup>3</sup> "*Cesación de pagos*. El deudor estará en cesación de pagos cuando: Incumpla el pago por más de noventa (90) días de dos (2) o más obligaciones a favor de dos (2) o más acreedores, contraídas en desarrollo de su actividad, o tenga por lo menos dos (2) demandas de ejecución presentadas por dos (2) o más acreedores para el pago de obligaciones.

*Incapacidad de pago inminente*. El deudor estará en situación de incapacidad de pago inminente, cuando acredite la existencia de circunstancias en el respectivo mercado o al interior de su organización o estructura, que afecten o razonablemente puedan afectar en forma grave, e cumplimiento normal de sus obligaciones con un vencimiento igual o inferior a un año." (Congreso de la Republica, 2006)

enlistadas ante la Superintendencia de Sociedades bajo algún esquema de acuerdo de reorganización empresarial, como de empresas con actividad económica similar que, por el contrario, están operando con normalidad y no presentan ningún tipo de marcación ante la Superintendencia de Sociedades.

*Gráfica 2 Procesos aceptados a reorganización por año de aceptación – Acumulado a junio 30 de 2018.*



Fuente: Elaboración propia, con base en el informe periódico al corte de junio de 2018 de la Superintendencia de Sociedades.

## 2. Estado del arte

Los modelos predictivos de quiebra, se basan principalmente en *indicadores o razones financieras*, que se obtienen de los estados financieros, éstos funcionan como una herramienta fundamental para conocer los resultados de la gestión administrativa y financiera; de igual forma estos indicadores, generan señales de alerta en el desarrollo de un negocio, con el objetivo de prevenir o mitigar apuros financieros, que se traduzcan en periodos de iliquidez que pueden llevar a las compañías a acogerse a acuerdos de reorganización, como la ley 1116 de 2006, o en casos más críticos, al cierre definitivo de una compañía a través de un proceso de liquidación.

De acuerdo con lo anterior, en este capítulo se describen las principales características de algunos modelos predictivos de quiebra, que se han utilizado en distintos sectores de la economía, a lo largo del tiempo.

Desde los inicios de la década de 1960, se han realizado varias técnicas y diferentes modelos relacionados con predicción de quiebra, entre ellos, se tiene el *modelo univariante*, publicado por William Beaver en 1967, que se basó principalmente en el estudio del flujo de caja / deuda total, desarrollado sobre una base de entidades que cayeron en bancarrota, comparadas con otras que se encontraban sanas, durante los años 1954 - 1964 (Beaver W.H, 1966); a partir de 1968, el profesor Edward Altman fue pionero en el *análisis discriminante múltiple (MDA)*, más adelante se ampliará información debido a su importancia. (Altman E, 1968)

Se han desarrollado aportes en el *sector de empresas manufactureras*, por ejemplo Edward Deakin (1972) desarrolló un modelo basado en variables financieras de los últimos cinco años, aportando como conclusión que, la aplicación de los modelos a corto plazo es la manera más eficiente, para predecir quiebras; Marc Paul Blum (1974), en su artículo *Failing Company Discriminant Analysis*,

Journal of Accounting Research, tomó como base 115 empresas en quiebra y 115 en no quiebra entre los años 1954 y 1968, con pasivos superiores a un millón de dólares, utilizó 12 indicadores financieros y como resultado demostró que la clasificación de las variables correctas está por encima del 70%.

En el *sector de industrias bancarias y pequeñas empresas*, Robert Edmister y Schlarbaum (1974), Joseph Sinkey (1975, 1977), Martin (1977), Anthony Santomero y Joseph Vinso (1977), basaron su trabajo, en la aplicación del modelo MDA, principalmente sobre pequeñas empresas, utilizando variables múltiples, extraídas de los estados financieros, debido a que los modelos anteriores, se basaban en empresas de tamaño mediano y grande; Katherine Schipper (1977) aplicó el modelo MDA, sobre *instituciones educativas*, como herramienta para encontrar las justificaciones a las angustias financieras que tenían las instituciones educativas entre los años 1967 y 1977, al igual que Ronald Shrieves y Stevens (1979), en el *sector de entidades educativas*, George Pinches y Trieschmann (1974) en su libro, *The Efficiency of Alternative Models For Solvency Surveillance in the Insurance Industry*, aplicaron el modelo MDA para clasificar los bonos industriales usando múltiples variables independientes, demostrando que, es más eficiente la aplicación de un modelo MDA que de un modelo Univariante, en el sector de industria de seguros de propiedad y responsabilidad civil; Edward Altman, desarrolló modelos en sectores como la industria de ferrocarril, Instituciones de ahorro y préstamo, industria de casa de bolsa OTC (*over the counter*), industria manufactureras, entre otras.

En el contexto latinoamericano existe el modelo de Ricardo Pascale, elaborado en el año de (1988), basado en la metodología (MDA), el cual se describirá más adelante.

Existen otros modelos como el *Análisis Logit condicional (LA) o regresión logística*, uno de los primeros modelos realizados, con este tipo de metodología, fue la de James A Ohlson, en su libro

titulado “*Financial Ratios and the probabilistic prediction of bankruptcy*” en el año de 1980, basándose en un grupo de entidades, que pertenecían al sector industrial y cotizaban en bolsa o en mercados OTC, entre los años 1970 y 1978, la principal contribución de este trabajo fue la creación de una metodología que se basó en tres modelos que se aplican en diferentes periodos, el primero ( $O_1$ ), para ser aplicado un año antes de la quiebra, el segundo ( $O_2$ ), para ser aplicado dos años antes y el tercero ( $O_3$ ), es el que predice la quiebra uno o dos años antes que se produzca. Adicionalmente Ohlson sostuvo que este método supera algunas de las críticas del MDA, que requiere una asunción de una distribución normal de los predictores y adolece de la naturaleza arbitraria de identificar firmas de emparejamiento no fallidas. (Wang, Ying, 2010)

Una técnica más reciente, para predecir la quiebra, es la aplicación de Redes Neuronales Artificiales (RNA), uno de los primeros trabajos realizados al respecto fue el de Odom y Sharda (1990) y Fletcher y Goss (1993), esta técnica aprovecha la sistematización de información contable y financiera que se carga en una base de datos, de la cual se extraen datos cuantificables de varios años y con base a dicha información se logra determinar con ayuda de parametrización de ecuaciones mediante inputs y outputs, la categorización que una entidad tendrá en el futuro: *quebrada o no quebrada*. (Bo K. Wong, Vincent S. Lai, Jolie Lam, 1994 - 1998)

### **2.1. El modelo Z-Score Altman**

El precursor de los modelos de quiebra fue Edward Altman, quien realizó su análisis basado en 66 compañías manufactureras que cotizaban en bolsa (33 en quiebra y 33 en buen estado), definiendo la siguiente función discriminante:

Ecuación 1. Z-Score de Altman

$$\text{Altman Z - Score} = 1,2 X_1 + 1,4 X_2 + 3,3 X_3 + 0,6X_4 + 1,0 X_5$$

Basado en la formula anterior, transformó las razones para llegar a un único puntaje Z, y por eso el modelo se conoce como Z-score, que fue determinante para clasificar las empresas en dos grupos, entidades en quiebra y no quiebra. (Altman E, 2000)

Altman (1968, 2000) explica que, teniendo una lista inicial de 22 razones financieras y basándose en primera instancia en su popularidad dentro de la literatura financiera y su relevancia potencial para el estudio, logra clasificar las cinco categorías estándar de indicadores financieros, entre los más relevantes están, liquidez, apalancamiento, solvencia y rentabilidad. Es así como Altman (1968) logró estandarizar un modelo con cinco razones financieras para discriminar e identificar las empresas con dificultades financieras (Rufus, 2003), y que las variables de su versión general son las que se detallan a continuación.

Donde,  $X_1 = \text{Capital de Trabajo/Activos}$ ,  $X_2 = \text{Utilidades retenidas/Activos}$ ,  $X_3 = \text{EBIT/Activos}$ ,

$X_4 = \text{Valor de mercado del patrimonio/Valor en libros pasivos}$ ,  $X_5 = \text{Ventas/Activos}$ .

La variable  $X_3 = \text{EBIT/Activos}$  (ROA), se constituyó como la de mayor peso explicativo sobre la probabilidad de quiebra, al ser una medida de la productividad de los activos. Cabe mencionar que el modelo inicial, establecido por Altman, está enfocado en empresas industriales manufactureras que cotizan en los mercados bursátiles.

La lectura de los resultados del modelo inicial es la siguiente:

*Tabla 1. Ponderaciones Z - Score*

<b>Z – Score</b>	<b>Interpretación</b>
Mayor o igual a 2,99	<i>Baja</i> probabilidad de quiebra

Entre 1,81 y 2,99	<i>Zona gris.</i> Existe alguna probabilidad de quiebra, más evidente entre más cercano este el resultado al límite inferior determinado en la función.
Menor o igual a 1,81	<i>Alta</i> probabilidad de quiebra

Fuente: (Valdés, 2006)

Posteriormente el mismo Altman, mejoró su modelo inicial a través del *Modelo Z<sub>1</sub> de Altman*, en el cual planteo una solución, incluyendo en su nuevo modelo los conceptos Z<sub>1</sub> y Z<sub>2</sub> como indicadores, con el propósito de ampliar la aplicación de este modelo a más entidades.

El cambio fundamental se observó en X<sub>4</sub>, en donde reemplazó el patrimonio bursátil e incluyó el patrimonio contable (Valor en libros).

Teniendo en cuenta lo anterior, y con base a los nuevos parámetros establecidos, los coeficientes tuvieron los siguientes cambios:

Ecuación 2. Z<sub>1</sub>-Score de Altman

$$Z_1 = 0,717 X_1 + 0,847 X_2 + 3,107 X_3 + 0,420 X_4 + 0,998 X_5$$

Con base al cambio de los coeficientes predictivos, los resultados se evalúan de la siguiente manera:

*Tabla 2. Ponderaciones Z<sub>1</sub> - Score*

<b>Z<sub>1</sub> – Score</b>	<b>Interpretación</b>
Mayor o igual a 2,90	<i>Baja</i> probabilidad de quiebra
Entre 1,23 y 2,90	<i>Zona gris.</i> Existe alguna probabilidad de quiebra, más evidente entre más cercano este el resultado al límite inferior determinado en la función.



Menor o igual a 1,23	Alta probabilidad de quiebra
----------------------	------------------------------

Fuente: (Valdés, 2006)

El nuevo modelo  $Z_1$ , incluyó el patrimonio contable y su alcance tiene en cuenta a entidades manufactureras, que no cotizan en mercados bursátiles, sin embargo, se presentaba un resultado importante en la variable  $X_5$ , ya que la mayoría de las entidades que pertenecen al sector industrial, tienen un volumen y materialidad relativa en los activos fijos. De acuerdo con lo anterior, se observó una deficiencia de aplicación en entidades que hacían parte de sectores como el comercial y de servicios. (Altman E, 2000)

Posteriormente, buscando que el modelo se pueda utilizar en compañías de sectores diferentes al manufacturero y que coticen o no en Bolsa, Altman, analizó y definió que su modelo  $Z_1$ , debía tener cambios, por lo cual decidió eliminar la variable  $X_5$ , de esa manera le quitó el impacto que tenían los activos fijos, sobre las ventas, debido a que, en entidades diferentes a las industriales, la variable  $X_5$ , distorsiona los resultados del modelo, por lo tanto, la fórmula quedó así:

Ecuación 3.  $Z_2$ -Score de Altman

$$Z_2 = 6,56 X_1 + 3,26 X_2 + 6,72 X_3 + 1,05 X_4$$

Se observa, que dependiendo del sector en donde se aplique el modelo, se tienen valores de coeficientes diferentes en cada variable; con base a los nuevos coeficientes del modelo  $Z_2$ , la evaluación de predicción de quiebra es:

Tabla 3. Ponderaciones Z2 - Score

<b>Z<sub>2</sub> – Score</b>	<b>Interpretación</b>
Mayor o igual a 2,60	<i>Baja</i> probabilidad de quiebra
Entre 1,10 y 2,60	<i>Zona gris</i> . Existe alguna probabilidad de quiebra, más evidente entre más cercano este el resultado al límite inferior determinado en la función.
Menor o igual a 1,10	<i>Alta</i> probabilidad de quiebra

Fuente: (Valdés, 2006)

## 2.2. Modelos en el contexto latinoamericano

En este contexto es importante mencionar el *Modelo de Ricardo Pascale*, quien elaboró en el año de 1988, un esquema basado en coeficientes financieros específicos, con la finalidad de predecir la quiebra de las empresas uruguayas.

El modelo de Pascale, concluyó que la clasificación de acierto para entidades analizadas un año atrás es del 92% sobre las entidades que cayeron en insolvencia, y una correcta clasificación del 82% de entidades a las cuales se les analizaron las cifras dos o tres años después que cayeron en quiebra. (Pascale, R. (1988)). Los resultados en este modelo son de tipo binario, si está por debajo de cero se entenderá que la empresa ha tenido o tiene problemas financieros de lo contrario se clasificara como una empresa sin problemas financieros (Mares, 2013).

En Colombia, también se han realizado trabajos asociados a modelos de predicción de quiebra con metodología de análisis discriminante múltiple (MDA) de Altman, ejemplo de ello es el modelo de Jorge Rosillo, el cual busca tomar correctivos antes de una muerte financiera que es jalonada por la insolvencia. (Rosillo J, 2002), el modelo desarrollado, incluyó una muestra de 106 empresas de diferentes sectores, en las que se determinó una posición de acuerdo con indicadores financieros promedio, tales como: razón corriente, prueba acida, razón de liquidez, endeudamiento, días

periodo de cobro, días de inventario, rotación de activos, margen neto, ROE, ROA y apalancamiento a corto plazo.

Los resultados de los indicadores antes mencionados fueron la base para calcular la función discriminante (*zoc*); inicialmente se habían asignado 12 indicadores para el cálculo, el sistema de estimación paso a paso, los redujo a tres y *determinó una constante de 1,563*. (Rosillo J, 2002).

*Tabla 4. Función discriminante ZOC*

<b>Indicador</b>	<b>Valor</b>
X <sub>1</sub> : Endeudamiento	0,46342418
X <sub>2</sub> : ROE	-0,07814256
X <sub>3</sub> : Leverage Largo Plazo	1,00787766
<i>Constante K</i>	<i>1,563</i>

Fuente: (Rosillo J, 2002)

Ecuación 4. Modelo de Jorge Rosillo

$$Z = -7,165 X_1 + 9,852 X_2 + 1,097 X_3 + 1,563 K$$

$$Z = -1,42165289 \text{ Entidades debiles}$$

En donde: X<sub>1</sub>= Endeudamiento, X<sub>2</sub> = ROE, X<sub>3</sub> = Apalancamiento

El principal aporte realizado por Rosillo a los modelos MDA es el *Punto de Corte Zoc*, el cual con base al resultado obtenido Z, se determina el punto de corte en el que una empresa fuerte pasa a ser una empresa débil.

## Ecuación 5. Modelo Zoc - Rosillo

$$Zoc = \frac{((Zfuerte)(\#empresas fuertes) + (Z debil) (\#empresas debiles))}{Total empresas}$$

$$Zoc = \frac{((50)(0,8527677) + (30) (-1,42165289))}{80}$$

$$Zoc = -0,00016656$$

Define que las empresas fuertes son aquellas que están por encima del Zoc y las empresas débiles que son insolventes son aquellas que tienen un resultado por debajo del Zoc (Rosillo J, 2002).

Aunque el método del análisis discriminante (MDA), es de los más utilizados para predecir la quiebra, también se han utilizado otros modelos como el Modelo de Probabilidad Lineal (LPM), el cual se basa en una regresión de una variable dependiente dicotómica, que toma valores entre 0 (empresas en quiebra) y 1 (empresas sanas), a partir de un conjunto de variables explicativas. Este modelo, busca interpretar la probabilidad condicional de que la empresa no vaya a quiebra, dado el tipo de variables explicativas seleccionadas. (Ginoglou, 2002)

También se han desarrollado estudios alrededor del modelo Probit and Logit, en donde se busca modelar la probabilidad condicional de quiebra en función de la relación deuda/capital. (Ginoglou, 2002).

Existe en Colombia otro método realizado en 2006 por Oscar Martínez, que busca, con los modelos anteriores, elaborar una herramienta predictiva, para no caer el insolvencia o quiebra financiera, para lo cual, quiso identificar una situación de estrés financiero, enfocando la solución para analizar el riesgo de crédito corporativo privado de las entidades colombianas, obteniendo como

resultado un modelo que puede clasificar a las empresas como frágiles o en situación de estrés con dos años de anterioridad a la quiebra con un 69% de probabilidad. (Martinez O, 2006)

A diferencia de los modelos anteriores, que se basaron en aplicaciones de análisis discriminantes múltiples, el modelo de Martínez se basa, en la técnica estadística de regresión *Probit*, justificando que la cantidad de supuestos que implica el desarrollo de un modelo discriminante, no cumple con los supuestos de máxima verosimilitud (Martinez O, 2006).

Adicional a esto, (Martinez O, 2006), identifica que existe un riesgo diferente, el cual depende del tipo de industria al que pertenece una compañía y su tamaño, para lo cual incorpora al modelo variables *Dummies*. El modelo de Martínez es dicotómico e incluye soluciones definidas como empresas *frágiles* o empresas *no frágiles*. Este modelo clasifica correctamente el 82.48% de la muestra como no frágiles y adicionalmente clasifica correctamente el 81.87% como frágiles.

De lo anterior se concluye que son muchas las técnicas y tipos de modelos que buscan identificar la posibilidad de quiebra en las empresas. Todos ellos utilizan diferentes enfoques y metodologías, y cada uno de ellos parte del análisis de uno o varios indicadores financieros. Sin embargo, los modelos concuerdan en que no hay reglas específicas para el universo empresarial, teniendo en cuentas que no determinan las causas de la situación de insolvencia o quiebra de las empresas, sino que son opciones que facilitan reconocer aspectos importantes, en la medición de la situación financiera de las empresas. (Keasy, K., & Watson, R., 1991)

Con base en los diferentes modelos de predicción de quiebra mencionados anteriormente, se elaboró una tabla comparativa, la cual nos permite seleccionar los indicadores financieros que soportan la *Hipótesis de ésta investigación*, que considera la existencia de ciertos indicadores financieros relevantes para determinar de manera oportuna y anticipada, cuando una empresa colombiana, puede declararse en estado de insolvencia..

## COMPARATIVO DE VARIABLES EN MODELOS DE PREDICCIÓN DE INSOLVENCIA

Modelo		DISCRIMINANTE MULTIPLES					REGRESIÓN PROBIT		COINCIDENCIA
		MUNDIAL			LATINO AMERICA	COLOMBIA			
		ALTMAN		FULMER	PASCALE	ROSILLO	MARTINEZ		
		Z - SCORE	Z <sub>1</sub> - SCORE	Z <sub>2</sub> - SCORE	H - SCORE	Z - SCORE	Z - SCORE		
Indicador	Variables								
Endeudamiento	<b>Pasivo Total / Activo Total</b>				X		X	X	3
	Pasivo Corriente / Activo Total				X				1
	Capital de trabajo / Pasivo Total				X				1
	Capitalización Bursátil (Valor del mercado) / Pasivos Totales	X							1
	<b>Patrimonio contable / Pasivos Totales</b>		X	X					2
	Ventas / Pasivo Total					X			1
	Deuda Largo Plazo / Pasivo Total					X			1
	Obligaciones financieras / Total Activos							X	1
	Egresos Financieros / (Ingresos Operacionales + Ingresos Financieros)							X	1
Liquidez	<b>Activos corrientes - Pasivos corriente / Activos Totales</b>	X	X	X				X	4
	Flujo de caja / Pasivo Total				X				1
	Activo Corriente / Pasivos Corrientes							X	1
	Disponible de Efectivo / Pasivos Corrientes							X	1
	Disponible de Efectivo / Total Activos							X	1
Rentabilidad	<b>Utilidades retenidas / Activo Total</b>	X	X	X	X	X			5
	<b>Ventas / Activo Total</b>	X	X		X				3
	Utilidad antes de impuestos / Capital contable (Patrimonio)				X				1
	Logaritmo de la utilidad de operación / Gastos financieros				X				1
	<b>Ebitda / Activos Totales</b>	X	X	X					3
	Utilidad neta / Patrimonio						X		1
	Patrimonio / Activo Total						X		1
	Ingresos Operacionales / Total Activos							X	1
	Utilidad antes de Impuestos / Total Activos							X	1
Utilidad antes de Impuestos / Ingresos Operacionales							X	1	
Activo total tangible				X				1	
Constante del modelo						X		1	

Fuente propia con base a los modelos predictivos de quiebra de Altman E, Fulmer J, Pascale R, Rosillo J y Martinez O.

Tabla 5. Comparativo de variables en modelos de predicción de insolvencia.

A partir de la tabla anterior, se obtienen como resultado, seis indicadores financieros, los cuales fueron seleccionados de acuerdo con la coincidencia de utilización en diferentes modelos previos a esta tesis, los cuales soportan la *hipótesis de investigación*, que considera que hay seis indicadores relevantes para determinar la probabilidad de que una compañía entre en ley 1116 y son los siguientes:

*Indicadores de endeudamiento:*

- Pasivo Total / Activo Total
- Patrimonio contable / Pasivos Totales

*Indicadores de liquidez:*

- Activos corrientes - Pasivos corriente / Activos Totales

*Indicadores de rentabilidad:*

- Utilidades retenidas / Activo Total
- Ventas / Activo Total
- Ebitda / Activos Totales

### **2.3. Nuevas técnicas basadas en inteligencia artificial**

A pesar de que el Z-Score de Altman ha sido uno de los principales modelos para identificar compañías en crisis financiera y alrededor de éste se han desarrollado diferentes investigaciones como las detalladas anteriormente el campo de las finanzas, buscando evolucionar al ritmo de los avances tecnológicos, ha empezado a incursionar en técnicas basadas en inteligencia artificial que permiten implementar modelos estadísticos a partir de desarrollos computacionales que sirven de soporte “a los complejos análisis que se requieren en el descubrimiento de las tendencias del negocio, con el fin de tomar decisiones eficientes y oportunas. Esto le permite a quienes toman decisiones afrontar los retos del nuevo mundo empresarial en el cual, el conocimiento aparece como el factor esencial para el desarrollo de las organizaciones”. (Sosa Sierra, 2006)

Dentro de las técnicas de inteligencia artificial encontramos las redes neuronales, que, aunque datan del siglo XIX, el boom se dio en los años 80 del siglo XX, debido a los avances en el campo tecnológico y en el conocimiento de la estructura del cerebro facultado así la creación de un número

creciente de aplicaciones en distintos campos y con diversos propósitos como se detalla en el siguiente cuadro resumen.

*Tabla 6. Comparativo de variables en modelos de predicción de insolvencia.*

<b>Entidad</b>	<b>Aplicación</b>	<b>Características</b>
Instituto de Ingeniería del Conocimiento de la Universidad Autónoma de Madrid e IBM España, 1996.	Detección de fraudes en tarjetas de crédito	Sistema on line de recepción de información sobre transacciones, estimación de parámetros característicos de las mismas y evaluación de su potencial de riesgo.
Chase Manhattan Bank	Una red neuronal del Chase Manhattan Bank para la concesión de préstamos	Es un sistema mixto que incorpora herramientas estadísticas y un perceptrón multicapa.
Yoon et al. (1993)	Estudios de evaluación del comportamiento de las acciones de las empresas en el mercado de valores.	Se trata de discriminar a las empresas en dos grupos, según las acciones hayan tenido o no un buen comportamiento en los mercados financieros. El estudio obtuvo resultados de un 76%.
Dutta et al. (1994)	Rede Neuronal para calificar la emisión de bonos u obligaciones.	Aplican perceptrón multicapa y regresión lineal, comparando los resultados con los obtenidos por la agencia Standard & Poors. Su estudio muestra las limitaciones de los modelos lineales para abordar el problema de la clasificación de obligaciones.
Wong et al. (1992)	Red neuronal que combina diferentes herramientas de inteligencia artificial para obtener una cartera óptima de acciones.	Se utiliza un modelo de red neuronal fuzzy que emplea la información del mercado de valores (ratios financieros) para predecir las rentabilidades de las acciones obteniendo resultados satisfactorios.
Refenes et al. (1993)	Modelo de construcción de carteras eficientes y colocación de activos en siete mercados financieros.	Esta neuronal utiliza información de los mercados financieros, tipo de interés, precio del petróleo, del oro y una serie de parámetros a fin de predecir construcción de carteras eficientes. Los resultados son satisfactorios.
Odom y Sharda. (1992)	Estudio sobre predicción de quiebras analizando 5 ratios de veintinueve empresas estadounidenses.	Se utilizó red neuronal perceptrón simple, multicapa y red atenia para estudiar el problema de la predicción del fracaso empresarial utilizando información de veintinueve empresas americanas correspondientes al período 1975-1982.

Fuente: (Sosa Sierra, 2006)



Dentro del campo de inteligencia artificial también encontramos el Machine Learning, el cual busca mejorar el análisis de datos para hacer predicciones futuras, mediante el uso de algoritmos basados en información antigua o reciente; algunas entidades financieras utilizan esta técnica para recopilar información de sus clientes, así como revisar y verificar los trámites y transacciones que éstos realizan; tenemos por ejemplo el software IBM Watson, que a partir del uso de algoritmos realiza la mayoría de las operaciones que se transan en Wall Street. (Hinestroza Ramirez, 2018)

Adicionalmente, dentro de las aplicaciones del Machine Learning, tenemos el Random Forest, utilizado en evaluación de riesgo de crédito, ya que el algoritmo que utiliza permite gestionar conjuntos de datos sin necesidad de procesar previamente datos y esto es un punto clave a la hora de imputar valores perdidos. El beneficio de estas técnicas es que permite a los desarrolladores de modelos reducir significativamente el tiempo dedicado a la gestión de datos; otra de sus ventajas es que se ha demostrado que puede reducir el sesgo en el modelado, aunque limita las transformaciones de datos realizadas antes del desarrollo del modelo; no obstante se ha demostrado que se puede argumentar la estabilidad de esta técnica cuando hay cambios estructurales a lo largo del tiempo en una cartera bancaria, por lo cual se recomienda que los bancos deben considerar aumentar la frecuencia de monitoreo y backtesting para mantener el comportamiento del modelo en el buen camino. (Grennepois, 2018)

En Taiwán para el año 2015, una entidad financiera publicó un estudio a partir de diferentes metodologías del Machine Learning, buscando predecir mejor la probabilidad de incumplimiento para sus clientes, así como identificar los factores clave que determinan esta probabilidad, con el objetivo de tener una mejor política a la hora de decidir a qué tipo de clientes otorgar tarjetas de crédito y al mismo tiempo definir que cupo otorgar para cada plástico. En esta investigación, el random forest permitió detectar los clientes leales con adecuada capacidad crediticia y diferenciarlos de aquellos usuarios con mal hábito de pago. No obstante lo anterior, evidenció que random forest, tiene una menor bondad de sobreajuste y dado que utiliza múltiples árboles se reduce la posibilidad de detectar clasificadores inadecuados. (Beeravalli, 2018)

A partir de lo anterior se formula la hipótesis de investigación, en donde el objetivo general de este trabajo será establecer a través de un modelo de paso a paso, las variables financieras que más influyen en la predicción, que una compañía se incorpore a la Ley 1116 de 2006.

Adicionalmente, como objetivos específicos se busca, i) identificar los factores financieros con diferencias significativas entre compañías en Ley 1116 de 2006 y empresas que no están en reorganización a través de un modelo de paso a paso. ii) establecer el porcentaje de verdaderos aciertos a la hora de clasificar una compañía en acuerdo de Ley 1116. iii) contrastar los resultados del presente estudio con los de estudios anteriores.

### **3. Marco teórico**

A lo largo de la historia, se han desarrollado múltiples conceptos para acotar el término *insolvencia*, sin embargo, se pueden distinguir “tres categorías que la mayor parte de los estudios utilizan: (i) Incapacidad de pagar las deudas u obligaciones a corto plazo; (ii) cuando la empresa tiene un patrimonio negativo, y (iii) la declaración legal de suspensión de pagos o quiebra” (Romero, 2013). Dado que este estudio, se basa en el análisis de compañías que se encuentran dentro de un “*programa de recuperación*”, al cual solo puede acceder una empresa, si su valor intrínseco o económico es mayor a su valor de liquidación, es importante primero definir como se determina el valor de una compañía, para así ahondar en los beneficios de la deuda para las empresas de cara a los ahorros fiscales y, entender porque para una compañía es importante establecer el nivel máximo de deuda al que debe llegar, de tal forma que los ahorros tributarios no sean superados por los costos de quiebra.

#### **3.1. Beneficios de la deuda y su relevancia en la estructura de capital**

Partiendo de la premisa que, la *insolvencia* se da en el momento en que una empresa es incapaz de atender el servicio de la deuda o lo hace, pero con dificultad, es importante conocer qué es la

estructura de capital y cómo ésta, determina el valor de una compañía, para así entender que motiva a las empresas a tener una estructura de capital concentrada en la deuda.

La forma en que una compañía, distribuye su financiación entre *deuda* (corto/largo plazo) y *capital* accionario, es lo que se conoce como *estructura de capital*, la importancia de este concepto radica en la definición de valor de la empresa, según la cual<sup>4</sup>:

Ecuación 6. Definición de valor

$$V = B + S$$

En donde:

*B = Valor de Mercado de la Deuda*

*S = Valor de Mercado del Capital*

Como se observa en la ecuación anterior, el valor de una empresa está determinado por el nivel de endeudamiento y la porción de capital accionario; aunque Modigliani y Miller (M&M) (1958) inicialmente argumentan, a través de su *Proposición I*, que no hay relación directa entre el valor de la empresa y su estructura de deuda/capital, es decir, que en ausencia de impuestos, el valor de una empresa apalancada es el mismo que el de una empresa no apalancada (Ross, 2009), en 1963, los mismo M&M realizan un ajuste a su teoría inicial, integrando tres conceptos, *la tasa de rendimiento de los activos, el costo de la deuda y el ratio de capital* (Brooks, 2013), a esto se le conoce como la *Proposición II*, la cual busca demostrar que la tasa de rentabilidad esperada sobre las acciones de una empresa apalancada aumenta en proporción a su ratio de D/E (Brealey, 2007), debido al subsidio tributario sobre los intereses generados por deuda; según M&M, “los dividendos están sujetos a impuestos corporativos, mientras que los pagos de intereses no, por lo que las empresas pueden realizar importantes ahorros impositivos manteniendo altos niveles de deuda” (Berk, 2007),

---

<sup>4</sup> Ross, Westerfield and Jaffe. Finanzas Corporativas. McGraw Hill. Octava Edición. 2009

más formalmente “el costo de oportunidad del patrimonio es una función lineal y positiva de la estructura de capital de la empresa”. (Rodríguez, 2011)

La *Proposición II* de M&M (1963), sienta las bases de la teoría del *Trade-Off*, en donde “la estructura de capital está determinada por la compensación de los beneficios y costos de la deuda” (Goyal, 2009); con niveles moderados de deuda, la probabilidad de insolvencia es baja, predominando los ahorros fiscales de la deuda, sin embargo, se llega al punto en donde el nivel de deuda aumenta, llevando a que la probabilidad de insolvencia se incremente y por tanto los costos de insolvencia alcanzan, una participación significativa del valor de la empresa. “El nivel óptimo teórico se alcanza, cuando el valor actual del ahorro fiscal, debido al endeudamiento adicional queda compensado por el aumento del valor actual de los costos de insolvencia que este endeudamiento adicional supone” (Brealey, 2007)

La teoría del *Trade-Off*, supone que los gerentes de compañías con deuda, tienen mayor disciplina ya que deben garantizar que la empresa genere flujo de caja libre, suficiente para pagar la deuda y evitar la bancarrota, con lo que se mitigaría problemas de *agencia* (Goyal, 2009).

Cuando se habla de estructura de capital, los *costos de agencia* se dan cuando “al incrementar el riesgo de la firma, se transfiere riqueza de los obligacionistas a los accionistas, quienes cobraron un interés bajo, pensando que se invertiría con bajo riesgo”. (Rodríguez, 2011)

### **3.2. Los costos financieros derivados de la insolvencia**

Aunque del numeral anterior se puede concluir, que los beneficios tributarios de la deuda llevan a que el valor de la empresa incremente; Damodaran (2006), “señala que un factor limitante del nivel de deuda de una firma es el asociado con los costos de quiebra. A medida que la relación D/P aumenta, también aumenta la probabilidad que los accionistas no puedan cumplir con los pagos de intereses y capital prometidos” (Rodríguez, 2011) y aunque en un mundo perfecto “si una empresa es incapaz de hacer frente a los compromisos de su deuda y suspende pagos, la propiedad y el

control sobre sus activos se transfiere, sin coste desde los accionistas a los titulares de la deuda” (Grinblatt, 2003), esto puede no ser totalmente cierto; Haugen y Senbet (1978) también argumentan que los costos de quiebra, no deben ser significativos, pues las empresas deben tener la capacidad de negociar, sin que éstos afecten el valor de las compañías, sin embargo, Kraus & Litzenberger (1973), afirman que los costos asociados a la quiebra desincentivan la emisión de deuda. (Berk, 2007); estudios recientes como los de Bris, Welch y Zhu (2004) , aunque se enfocan en costos directos, logran demostrar, que los costos asociados a la quiebra terminan representando un porcentaje alto de los activos de las compañías antes de la crisis (8,1%), contradiciendo así a Haugen y Senbet (1978).

En (Altman E. I., 2006), los costos y gastos derivados de los procesos de reestructuración, “se reconocen como un importante determinante en el valor de la deuda y la estructura de capital de las compañías”, y se clasifican como: (i) *directos*, aquellos asociados directamente al proceso de quiebra, por ejemplo, abogados, asesores especializados en procesos de reorganización, avalúos, hipotecas, entre otros. Debido a los costos directos de bancarrota, parte del valor de la firma se pierde y este hecho aminora el beneficio del uso de la deuda (Rodríguez, 2011); (ii) *indirectos*, pueden llegar a ser los más relevantes aunque es más difícil estimar su valor, ya que están relacionados con el *costo de oportunidad*, cómo por ejemplo, disminución de ventas, “Titman (1984) sostiene que las empresas con productos únicos comienzan a perder clientes si el mercado detecta que la compañía tiene problemas” (Goyal, 2009), pérdida de financiación por parte de proveedores y bancos, mayores costos financieros (debido al incremento en el riesgo, los bancos aumentan la tasa de colocación), pérdida de los mejores empleados, entre otros. Los costos indirectos se hacen perceptibles cuando las empresas evitan la bancarrota, es decir cuando entran en los *programas de rehabilitación* o como se denomina en Colombia, *acuerdos de reorganización* (Rodríguez, 2011). A pesar de la dificultad en el cálculo, Altman (1984) intenta medir los costos

indirectos, así por ejemplo, calcula la disminución en las ventas de compañías en dificultades y las compara, con la variación de las ventas de otras compañías de la industria (sanas), también mide la desviación entre las ganancias reales de las empresas y las previsiones de sus ganancias durante los tres años anteriores a la presentación en bancarrota, sin embargo su estudio no se considera tan concluyente, pues algunos detractores argumentan que puede haber causalidad entre la caída en ventas y ganancias, con el estado de dificultad financiera. (Tim C, 1994)

Otro costo *indirecto* que generalmente no se contempla pero, que tiene un impacto social importante en la economía, es el costo del *capital humano*, ya que como afirma Titman (1984), los costos indirectos de la bancarrota y los costos precipitados por la presentación a la bancarrota, afectan a varios terceros y no solo a los tenedores de deuda y accionistas, esto se debe a que las partes interesadas, que no están representadas en la mesa de negociación, como los clientes y los empleados, pueden sufrir costos materiales como resultado de la quiebra; debido a que los demandantes en la negociación (titulares de deuda y accionistas) no incurren en estos costos, los demandantes no tienen ningún incentivo, para negociar a su alrededor, sin embargo estos costos pueden ser relevantes, principalmente para la sociedad. (Berk, 2007)

Teniendo en cuenta lo anterior, se evidencia que los procesos de insolvencia y quiebra pueden ser muy costosos para todas las partes implicadas y “estos costos, asociados a la probabilidad de bancarrota o al proceso de bancarrota, disminuyen el valor de la firma apalancada pudiendo cancelar y hasta reversar eventualmente, el efecto positivo de la deuda” (Rodríguez, 2011)

Finalmente, según (Gilson, 1997), los procesos de reorganización les exigen a las empresas, realizar ajustes grandes en los niveles de deuda, y las dificultades financieras llevan a las compañías a alejarse de su estructura de capital óptima, por lo que las empresas en reestructuración deben hacer acuerdos con sus acreedores financieros y proveedores. Roe (1983) y Bebchuk (1988), argumentan que las barreras para reducir la deuda en empresas en reorganización es muy alta.

### **3.3. Las bases de los modelos de insolvencia**

Como se mencionó anteriormente, son muchos los estudios que se han desarrollado a partir del interés por encontrar el mejor modelo para predecir la probabilidad de insolvencia o quiebra de una empresa, es por ello que desde 1967 gracias a William H. Beaver, se desarrolla uno de los primeros modelos de predicción, el cual concluye que la relación flujo de efectivo / deuda total, era el mejor predictor de quiebra, sin embargo, su mayor aporte fue identificar que las razones financieras o los datos contables tenían la capacidad de predecir la quiebra durante los 5 años previos y además sugirió un lineamiento para la evaluación de datos contables (Altman E. I., 1993). Posteriormente en 1968, Edward Altman introduce el concepto de Análisis Discriminante (MDA) en las finanzas (Altman E. I., 1993), este tipo de modelo permite la combinación de dos o más variables como veremos a continuación.

#### **3.3.1. Análisis discriminante - MDA**

En esta metodología, el objetivo común es clasificar un elemento, en uno de los grupos establecidos a priori, dependiente de las características individuales de dicho elemento; también intenta analizar si existen diferencias entre los grupos en cuanto a su comportamiento con respecto a las variables independientes. (Espinosa, 2013)

Es a través de la técnica MDA, que se desarrolla uno de los modelos más utilizados para la predicción de quiebra, el Z-Score, que como vimos anteriormente, su mayor aporte fue determinar las principales 5 razones financieras que permiten clasificar a una compañía en dos grupos “*en quiebra*” o “*no quiebra*” (Altman E. I., 2000).

A pesar de ser uno de los modelos más utilizados, el MDA también tiene algunas restricciones que limitan la validez de sus resultados, algunas de ellas son (Espinosa, 2013):

- Asume que todas las variables independientes se comportan como una distribución normal.
- Implica la igualdad de la matriz varianza-covarianza en ambos grupos, esto rara vez se da, por lo que se trabaja con modelos cuadráticos, sin embargo, esto genera una alta complejidad al modelo.
- No asigna una probabilidad al error tipo I y al error tipo II, asume la misma probabilidad para ambos tipos de error.

A pesar de lo anterior, es a partir del método MDA, que se desarrollan y desprenden otros modelos como el de probabilidad condicional (Logit y Probit), y posteriormente el análisis de inteligencia artificial. (Espinosa, 2013)

#### 4.3.1. Análisis logit

El *Logit* es un modelo usualmente multivariable, para el estudio de variables dependientes no métricas, que busca determinar la probabilidad de pertenencia a un determinado grupo, para ello denota la variable dependiente, como una respuesta binaria (0 o 1) no lineal. (Espinosa, 2013), este tipo de técnica es clave para modelar la pertenencia de una variable a un grupo determinado. Dentro de este capítulo también es importante abordar los *modelos de elección binaria*, los cuales consisten en que “la variable dependiente y puede tomar solo dos valores, que por conveniencia y sin pérdida de generalidad, se denotan por 1 si el suceso ocurre y 0 si no”. (Carrasco Perea, 2001)

Teniendo en cuenta lo anterior, en (Carrasco Perea, 2001) se explica que eventualmente las variables discretas se modelan en términos de variables continuas en donde  $y_i$  es igual a 0 – 1 donde:

$$y_i = \begin{cases} 1 & \text{si } y_i^* \geq 0, \\ 0 & \text{si } y_i^* < 0, \end{cases}$$

y la variable  $y_i^*$  es una función lineal de  $x_i$ :

$$y_i^* = \beta x_i + u_i$$



Por tanto, en estos modelos la variable dependiente  $y_i$  refleja decisión de los individuos. Aunque los *modelos de elección binaria* se consideran sencillos, su principal crítica “es que en muchos casos la esperanza condicional  $E(y_i|x_i)$  no puede interpretarse como la probabilidad de que el suceso ocurra, ya que la esperanza puede estar fuera del intervalo  $(0,1)$ . Por ello  $F$  se suele especificar como una *distribución logística (modelo Logit)*”

$$F(z) = \frac{e^z}{1 + e^z}$$

En (Espinosa, 2013), se afirma que esta metodología, es más adecuada que el MDA, ya que puede utilizar distribuciones diferentes a la normal y no necesita suposiciones tan restrictivas, sin embargo, el *modelo logit*, también tiene limitaciones como por ejemplo, “la dicotomía de la variable dependiente y la multicolinealidad”, ya que utiliza indicadores financieros que pueden tener una correlación alta.

A pesar que el *MDA* y el *Modelo Logit* han sido tradicionalmente muy utilizados, en los últimos años se han venido desarrollando más y más modelos, como por ejemplo las técnicas de partición interactiva y de inteligencia artificial, mediante el uso de redes neuronales u árboles de decisión; en el caso de los modelos de inteligencia artificial, se desarrollan, programas en computador para explorar datos, aprender del comportamiento de las variables y posteriormente elaborar predicciones sobre nuevos datos, tal es el caso de las técnicas *Machine Learning*.

### 3.3.3. Random forest

El *Random forest* es un algoritmo que se deriva de la técnica del *Machine Learning*, uno de los campos dentro de las metodologías de inteligencia artificial, en donde los algoritmos tratan de aprender de los datos, por lo que entre más nutrida sea la información que se introduce al algoritmo, más complejo será el modelo y por lo tanto mejor los resultados.


El *Random forest* o bosque aleatorio, es un algoritmo de clasificación que consta de una gran cantidad de árboles de decisión individuales que operan como un conjunto (Yiu, 2012), protegiéndose entre sí de sus errores individuales. Bajo esta técnica, cada árbol de decisión opera como un modelo relativamente no correlacionado, pero que trabajan como un conjunto, por lo cual sus resultados serán superiores a los de un árbol individual, “los modelos no correlacionados pueden producir predicciones de conjunto que son más precisas que cualquiera de las predicciones individuales” (Yiu, 2012). En (Liaw, 2002), ésta es una técnica fácil de usar ya que solo tiene dos parámetros: (i) el número de variables en el subconjunto aleatorio de cada nodo y (ii) el número de árboles de decisión (Breiman, 2001).

En (Liaw, 2002), el *random forest* arroja dos resultados, (i) *Una medida de la importancia de las variables predictoras*: Este es un concepto difícil de definir, porque la importancia de una variable puede estar dada por su interacción con otras variables, es decir que estima la importancia de una variable al observar cuánto aumenta el error de predicción cuando los datos para esa variable se permutan mientras que todos los demás se dejan sin cambios. Los cálculos necesarios se realizan árbol por árbol, a medida que el bosque aleatorio es construido. (ii) *Una medida de la estructura interna de los datos (proximidad)*: La intuición es que las observaciones "similares" deben estar en los mismos nodos terminales con mayor frecuencia que los distintos. La matriz de proximidad se puede utilizar para identificar la estructura en los datos o para el aprendizaje no supervisado con bosques aleatorios.

A pesar que, el *Random forest* trabaja a partir de árboles de decisión, la lógica bajo la que opera es muy diferente a la de un árbol de decisión normal ya que, en un árbol de decisión tradicional al momento de dividir un nodo, se consideran todas las características posibles y se elige aquella que produce la mayor separación entre las observaciones en el nodo izquierdo y el nodo derecho mientras que, cada árbol en un bosque aleatorio puede elegir solo un subconjunto aleatorio de

características, esto obliga a una mayor variación entre los árboles en el modelo y por lo tanto da como resultado una menor correlación entre los árboles y una mayor diversificación, en otras palabras el *Random Forest* “hace uso de un conjunto de árboles de decisión y a cada uno le asigna una porción de los datos como entrenamiento. El resultado final es la combinación del criterio de todos los árboles que formen el bosque” (Zaforas, 2017).

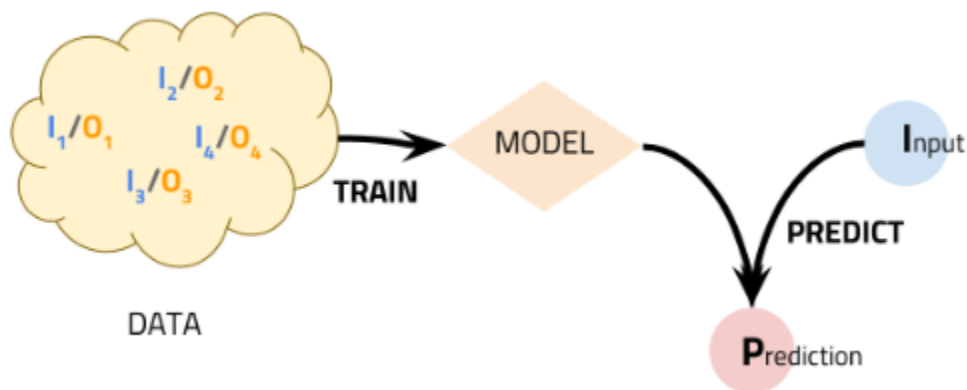
Gráfica 3 Construcción de un bosque aleatorio



Fuente: (Zaforas, 2017)

Dado que el *Random forest* se ejecuta bajo la metodología del *Machine Learning*, el primer paso es proporcionarle al algoritmo datos para *entrenarlo* y que aprenda de los patrones, para finalmente generar un modelo entrenado, para ello lo ideal es que los datos estén etiquetados, por ejemplo, en la *Gráfica 4. Pasos del Machine Learning*, las características a analizar se catalogan con ( $I_n$ ), mientras que la variable dummy se etiqueta con ( $O_n$ ); el segundo paso es pedirle que haga la predicción al darle las características de la variable que queremos clasificar, finalmente “el modelo será capaz de dar una predicción con base en el conocimiento que extrajo de los datos de entrenamiento”. (Zaforas, 2017)

Gráfica 4 Pasos del Machine Learning



Fuente: (Zaforas, 2017)

En el *Machine Learning* “Lo que define a un buen o mal algoritmo es la precisión con la que haga las predicciones en un dominio y contexto dado, y en base a unos datos de entrenamiento disponibles”. (Zaforas, 2017)

## 4. Metodología

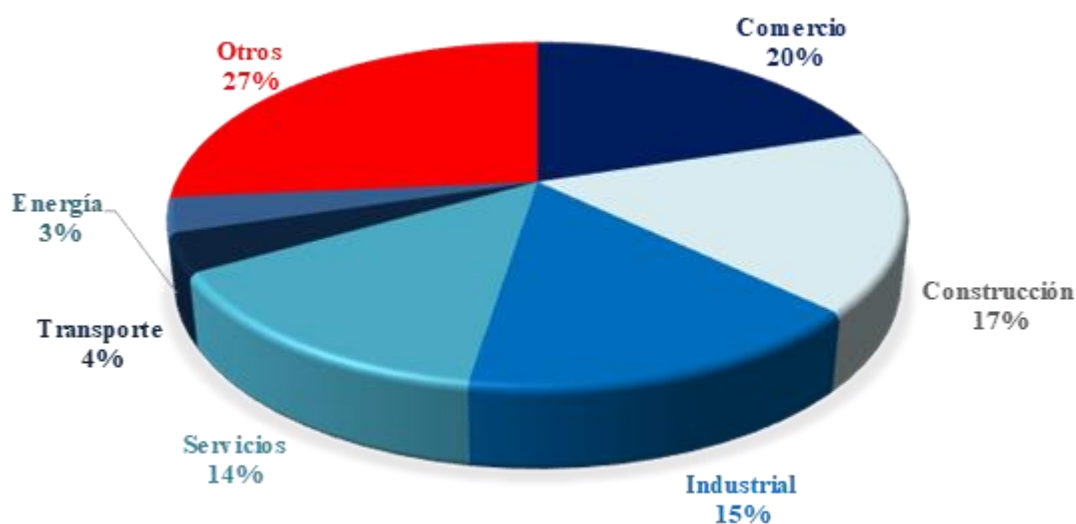
### 4.1. Construcción del panel de datos

El estudio, parte del informe de compañías en reorganización empresarial y validación judicial<sup>5</sup>, acumulado al 30 de junio de 2018 y publicado por la Superintendencia de Sociedades, el cual incluía 1,629 empresas. Se realizó una depuración inicial para eliminar las compañías en estado de liquidación por adjudicación o liquidación por Validación, dejando una muestra inicial de 1,185 compañías, con disponibilidad en información financiera desde el año 2013 hasta el año 2017.

<sup>5</sup> “Alternativa de reorganización empresarial que permite que, en cualquier momento, se pueda iniciar negociaciones con los acreedores externo con el fin de llegar a un acuerdo extrajudicial de reorganización” (Romero, 2013).

Los indicadores financieros y características cualitativas fueron extraídos de la base de datos BPR Benchmark, de diferentes sectores de la economía colombiana, principalmente de los sectores comercio, construcción, industrial, servicios, entre otros. En adelante denominaremos a este grupo de empresas *en acuerdo*. Teniendo en cuenta la relevancia de la información para la construcción del panel de datos, finalmente, se depuró la muestra inicial de 1,185 eliminando 606 entidades que no contaban con información financiera para los años 2013 a 2017 o en alguno de los años, lo que dio como resultado un total de 579 entidades, sujetas de análisis de investigación que bien podían tener información histórica para los 5 años de estudio o menos.

*Gráfica 5 Distribución sectorial de empresas en acuerdo sujetas a análisis*



Fuente:

Elaboración propia con base clasificación registrada en BPR Benchmark.

La base se complementa, con un listado de compañías que no están en Ley 1116 de 2006 y que en adelante denominaremos como *en no acuerdo*, las cuales pertenecen a los mismos sectores económicos (según BPR Benchmark) de aquellas en reorganización sujetas de análisis (en acuerdo). Esta segunda parte de la base de datos, sirve como *contrafactual* y nos deja con una base final de 34.035 entidades con información financiera histórica, de los mismos periodos de aquellas

que cayeron en ley 1116 de 2016, (2013 a 2017), con la finalidad de tener un panel de datos coherente.

Por lo anterior, se cuenta con una base de datos con un total de 34.614 entidades.

Finalmente, la base de datos se completa con 21 indicadores financieros que clasificamos en 4 categorías: (i) actividad (ii) endeudamiento, (iii) liquidez y (iv) rentabilidad y 4 cuentas relacionadas con el tamaño de la compañía, como son las ventas, nivel de activos, utilidad y patrimonio, en la base también se incluye el sector y subsegmento que asigna BPR para cada empresa; con la finalidad de analizar cuáles de estas variables son las más relevantes, para determinar de manera oportuna, cuando una empresa es propensa a caer en insolvencia y validar su coincidencia con los seis indicadores seleccionados en la hipótesis inicial.

#### 4.2. Variables a analizar

La utilización de múltiples ratios lleva a tener una serie de variables que incluirán información repetida y redundante, lo cual podría causar multicolinealidad, principal limitante en la construcción de los modelos de predicción empresarial. Una de las principales hipótesis de una regresión lineal, es que no existe una relación lineal exacta entre sus variables, es decir, que no existe multicolinealidad en el modelo.

Teniendo en cuenta lo anterior, la base inicial incluye los siguientes indicadores:

*Tabla 7 Indicadores financieros*

<p><b>Indicadores de Actividad:</b> Permiten medir la eficiencia de una empresa en la utilización de sus activos, mediante el tiempo que tarda en recuperar la inversión realizada en ellos. También se incluyen aquellos relacionados con la evolución de la compañía</p>	<ol style="list-style-type: none"> <li>1. Crecimiento en Ventas (C_VENTAS)</li> <li>2. Crecimiento de Activos (C_ACTIVOS)</li> <li>3. Crecimiento de Utilidad Neta (C_UNETA)</li> <li>4. Crecimiento del Patrimonio (C_PATRIMONIO)</li> <li>5. EBITDA</li> <li>6. Rotación de Cartera (ROT_COBRO)</li> <li>7. Rotación de Inventarios (ROT_INV)</li> <li>8. Rotación de Proveedores (ROT_PROV)</li> <li>9. Ciclo Operativo (CICLO)</li> </ol>
--	---

<p><b>Indicadores de Endeudamiento:</b> Miden el grado de financiación de la empresa con pasivos externos y el nivel de riesgos de la organización. Así mismo, miden el grado de participación de los acreedores en la estructura de financiación de la empresa y determinan el nivel de riesgo y la conveniencia de esta estructura de financiamiento</p>	<p>10. Pasivo Total / Activo Total (ENDEUDAMIENTO)  11. APALANCAMIENTO  12. Pasivo Total / Ventas (PTOTAL_VENTAS)  13. Pasivo Corriente / Pasivo Total (CORTO/TOTAL)</p>
<p><b>Indicadores de Liquidez:</b> Evalúan la capacidad de la empresa para cumplir con sus obligaciones a corto plazo mediante la conversión de los activos corrientes.</p>	<p>14. Activos corriente - Pasivos Corrientes / Activos Totales (R_CORRIENTE)  15. Prueba Acida (P_ACIDA)  16. Capital de Trabajo (KT)</p>
<p><b>Indicadores de Rentabilidad:</b> Presenta la efectividad de la administración para convertir ventas y la inversión en utilidades, miden el beneficio o la productividad de los fondos comprometidos en la empresa.</p>	<p>17. Utilidad neta / Ventas (UNETA_VENTAS)  18. Rentabilidad del Activo (RENT_ACTIVOS)  19. Utilidad neta / Patrimonio (UNETA_PATRIMONIO)  20. Utilidad Operacional / Ventas (UOPER_VENTAS)  21. Utilidad Bruta (UBRUTA)</p>
<p><b>Variables de Tamaño:</b> Se incluyen variables relacionadas con el tamaño de la compañía</p>	<p>22. Ventas  23. Activos  24. Utilidad  25. Patrimonio</p>

Fuente: Elaboración propia con base en (Espinosa Fredy, 2015)

#### 4.3. Desarrollo del modelo random forest

Uno de los objetivos específicos de esta investigación se desarrolló a partir de la técnica *Random Forest*, para ello el modelo se ejecutó a través del software estadístico R; el proceso se desarrolló a través de 3 fases: (i) Carga del paquete de Random Forest, paquete que se asocia a la configuración preestablecida con la cual se ejecutarán los cálculos, cabe mencionar que dicho paquete es un modelo estándar (Ver Anexo A. Código Random Forest); en este primer paso se depura nuevamente la base a partir de la calidad de la información, seleccionando solo 10 variables y 108.050 observaciones, es decir que se trabaja con aquellas empresas e indicadores con la mayor cantidad de datos históricos de tal forma que se alimente el aplicativo R con información completa,

ya que como se indicó en capítulos anteriores, la base inicial contenía empresas que bien podían tener información durante los 5 años de estudio (2013- 2017) o menos años.

*Tabla 8 Variables utilizadas en Modelo Random Forest (RF)*

<b>Indicadores de Endeudamiento</b>	1. Pasivo Total / Activo Total (ENDEUDAMIENTO) 2. Pasivo Corriente / Pasivo Total (CORTO/TOTAL)
<b>Indicadores de Liquidez</b>	3. Activos corriente - Pasivos Corrientes / Activos Totales (R_CORRIENTE) 4. Prueba Acida (P_ACIDA) 5. Capital de Trabajo (KT)
<b>Indicadores de Rentabilidad</b>	6. Utilidad neta / Patrimonio (UNETA_PATRIMONIO)
<b>Variables de tamaño</b>	7. Ventas 8. Activos 9. Utilidad 10. Patrimonio

Fuente: Elaboración propia

(ii) Carga de la base de datos (Panel del Datos), como se mencionó anteriormente al ser un algoritmo del *Machine Learning*, el *Random Forest* trabaja a partir de la combinación de múltiples arboles de decisión suponiendo la interacción entre variables, por lo que se requiere que los datos se entrenen primero, es por ello que inicialmente se carga solo el 80% de las observaciones para que el aplicativo pueda primero ensayar y luego pueda predecir el modelo; el 20% de las observaciones restantes se utilizan para probar o validar las predicciones.

(iii) Informe de Resultados, una vez el modelo valida la predicción, arroja un informe con los resultados que, en el caso de esta investigación, corresponde al desarrollo del objetivo general de la misma y es el listado de variables financieras más significativas para determinar la incorporación de una empresa colombiana a la Ley 1116.



### 4.3.1. Análisis de resultados

La variable dependiente es una dummy, que toma el valor de uno (1) cuando una empresa está en *acuerdo*, en el mismo año o algún año en el futuro, y cero (0) cuando no.

Como se mencionó anteriormente, la selección de variables independientes se basó en tener el menor número de datos perdidos y tener la mayor correlación con la variable dependiente, por lo que la base de datos quedó con un total 108.050 observaciones y 10 variables, las cuales se detalla en la *Tabla 8 Variables utilizadas en Modelo Random Forest (RF)*

*Tabla 9 Matriz de confusión Random Forest (RF)*

		Real	
		0	1
Predicción	0	21343	98
	1	1	167

Accuracy : 0.9954

95% CI : (0.9944, 0.9963)

Sensitivity : 1.0000

Specificity : 0.6302

Fuente: Elaboración propia

En este caso para el modelo *Random Forest*, tenemos un *Accuracy* de 0.9954, el cual indica que el 99.54% de las observaciones están correctamente clasificadas entre *acuerdo* (1) y *no acuerdo* (0). Así mismo, RF genera un porcentaje del 63,02% de predecir *acuerdo* cuando en realidad la compañía está en reorganización. Finalmente, la *Sensitivity* indica un porcentaje del 100% de predecir *no acuerdo* cuando en realidad es *no acuerdo*.

Los anteriores resultados, nos permiten concluir que el algoritmo *Random Forest* tiene una alta probabilidad de clasificar correctamente las compañías dependiendo de su estado de solvencia, en

comparación con un *Modelo Logit*, el cual una vez se corren los resultados también en R genera los siguientes resultados:

*Tabla 10 Matriz de confusión Modelo Logit*

		Real	
		0	1
Predicción	0	21340	264
	1	4	1

Accuracy : 0.9876

95% CI : (0.986, 0.989)

Sensitivity : 0.999813

Specificity : 0.003774

Fuente: Elaboración propia

A pesar de que, el *Accuracy* para ambos modelos es alto (99,54% para *random* y 98,76% para *logit*), en el caso del modelo *logit*, el porcentaje de predecir si una empresa está en *acuerdo* cuando en realidad está en reorganización es bajo, solo del 3.77% frente al 63.02% del *random forest*.

#### 4.4. Desarrollo panel de datos *logit*

Buscando alcanzar el objetivo general de esta investigación, que es determinar aquellos indicadores financieros relevantes a la hora de determinar si una compañía puede estar en riesgo de insolvencia se desarrolló un modelo paso a paso, el cual consiste en correr repetidas iteraciones a partir de las variables del panel de datos, hasta obtener el mejor resultado posible, que es identificar las variables que contribuyan a explicar que la probabilidad tome el valor de 1, es decir *acuerdo*.

A diferencia del método anterior, esta vez se corre el modelo con los 21 indicadores financieros y las 4 variables de tamaño como se detalló en la *Tabla 6. Indicadores financieros*, adicionalmente incluimos las variables *Sector* y *Segmento*, esta información al igual que los datos financieros se generaron a la información contenida en BPR Benchmark; la idea de incluir estas dos variables

dicotómicas es determinar si para el caso colombiano el sector al que pertenece una empresa también está relacionado con la incorporación de la una compañía en Ley 1116.

#### 4.4.1. Análisis de resultados

Teniendo en cuenta que este es un modelo paso a paso, la primera iteración que se corre es utilizando todos los indicadores financieros y las variables *Sector* y *Segmento*, de esta primera prueba se evidencia que ambas variables dicotómicas están relacionadas con la incorporación de una empresa en un acuerdo, y al relacionar todas las variables financieras se obtiene en principio los siguientes resultados.

*Tabla 11 Iteración Variables Dicotómicas y Financieras*

	<b>COEFFICIENT</b>	<b>STD. ERROR</b>
<b>INTERCEPT</b>	8.966E+00 **	-3.66E+00
<b>C_VENTAS</b>	2.30E-01**	-9.07E-02
<b>C_ACTIVOS</b>	9.00E-02	-1.83E-01
<b>C_UNETA</b>	9.33E-02**	-4.05E-02
<b>C_PATRIMONIO</b>	-2.10E-01	-1.68E-01
<b>EBITDA</b>	-5.14E-4**	-2.13E-04
<b>ROT_COBRO</b>	-1.15E+00	-1.61E+00
<b>ROT_INV</b>	-1.15E+00	-1.61E+00
<b>ROT_PROV</b>	5.97E-03*	-3.12E-03
<b>CICLO</b>	1.15E+00	-1.61E+00
<b>ENDEUDAMIENTO</b>	-3.64E+00	-2.31E+00
<b>APALANCAMIENTO</b>	-1.67E-01**	-8.24E-02
<b>PTOTAL_VENTAS</b>	4.66E-01	-4.62E-01
<b>PASIVOCORTO/PASIVOTOTAL</b>	-8.918E+00***	-3.20E+00
<b>R_CORRIENTE</b>	-8.77E-01	-6.96E-01
<b>P_ACIDA</b>	2.37E-01	-7.35E-01
<b>KT</b>	-2.56E-05	-5.27E-05
<b>UNETA_VENTAS</b>	-13.04E+0**	-6.15E+00
<b>UNETA_PATRIMONIO</b>	-2.186E+0**	-9.75E-01
<b>UOPER_VENTAS</b>	11.69E+00*	-6.27E+00
<b>UBRUTA</b>	-1.83E+00	-1.64E+00
<b>VENTAS</b>	9.46E-05**	-3.81E-05
<b>ACTIVOS</b>	-4.27E-05	-4.38E-05

<b>UTILIDAD</b>	4.00E-04	-2.55E-04
<b>PATRIMONIO</b>	4.06E-06	-5.07E-05

\*\*\* Resultados relevantes en la predicción para que una entidad caiga en ley 1116

\*\*\* p<0.01, \*\* p<0.05, \* p<0.1

Fuente: Elaboración propia con base a los resultados obtenidos en logit

De esta primera iteración validamos que al relacionar las variables dicotómicas con los indicadores financieros, la estructura de deuda (*Pasivo Corriente / Pasivo Total*) de las compañías colombianas en el periodo 2013 a 2017, es el indicador financiero con mayor significancia a la hora de determinar si una empresa está en riesgo de acogerse a una Ley 1116.

Se realiza una segunda iteración *excluyendo* las variables dicotómicas, para determinar los indicadores financieros con mayor significancia a partir de la relación entre ellos mismos, y se obtienen los siguientes resultados.

*Tabla 12 Iteración Variables Financieras*

	<b>COEFFICIENT</b>	<b>STD. ERROR</b>
<b>INTERCEPT</b>	-4.036E+00**	-7.43E-01
<b>C_PATRIMONIO</b>	-4.48E-03***	-1.61E-03
<b>PASIVOCORTO/PASIVOTOTAL</b>	-2.289***	-2.31E-01
<b>R_CORRIENTE</b>	-1.81E-02**	-8.05E-03

\*\*\* Resultados relevantes en la predicción para que una entidad caiga en ley1116

\*\*\* p<0.01, \*\* p<0.05, \* p<0.1

Fuente: Elaboración propia con base a los resultados obtenidos en logit

Finalmente, se evidencia que para el caso de estudio, hay tres indicadores relevantes, siendo el indicador Pasivo Corriente / Pasivo Total, el de mayor significancia; como segundo indicador relevante, se obtuvo la razón corriente (activo corriente / pasivo corriente), indicador de estructura de deuda, que también está relacionado con la forma en la que se apalancan las empresas, que permite determinar el índice de liquidez de una entidad, o su capacidad para disponer de efectivo ante una eventualidad o contingencia que se lo exija a corto plazo; por último, respecto a la

*Variación del Patrimonio*, se puede analizar la importancia que tiene sobre la liquidez de las empresas colombianas, debido a que la variación patrimonial, es el resultado entre los activos (recursos) menos los pasivos (obligaciones) a un corte específico, el cual tiene inmerso el resultado del ejercicio (Ganancias o pérdidas), derivados de la adecuada administración de la gerencia; con base en los resultados del periodo, la junta directiva o dueños de la empresa toman decisiones, sobre pagos de dividendos, constituciones de reservas legales u ocasionales o capitalizaciones; quiere decir que al realizar un análisis financiero sobre las variaciones patrimoniales sin tener en cuenta los cambios en los componentes de otros resultados integrales (ORI), puede alertar a una empresa a revisar el flujo de caja operativo, ya que los aumentos en patrimonio en diferentes periodos, pueden dar como resultado insolvencia, ya que la empresa podría estar presentando dificultades de efectivo y por ende, el no pago de dividendos a los inversionistas.

## 5. Conclusiones

Teniendo en cuenta el objetivo general de ésta investigación, que consiste en establecer las variables financieras que más influyen en la predicción de que una compañía se incorpore a la Ley 1116 de 2006, y con base a modelos predictivos, bajo algoritmos parametrizados con un modelo logit de panel de datos con iteraciones paso a paso y un modelo de inteligencia artificial Random Forest, los cuales permiten realizar simulaciones sobre bases de datos, hemos obtenido lo siguiente: Al analizar los resultados obtenidos con base a nuestra hipótesis, la cual planteaba, seis indicadores como relevantes para predecir la entrada en insolvencia de una empresa, la información financiera generada a partir BPR Benchmark, solo nos permitió estudiar: (i) Pasivo Total / Activo Total y (ii) Activos corrientes - Pasivos corriente / *Activos Totales*, mientras que los otros cuatro indicadores: (iii) *Patrimonio contable / Pasivos Totales*, (iv) *Utilidades retenidas / Activo Total*, (v) *Ventas /*

*Activo Total* y (vi) *Ebitda / Activos Totales*, quedaron por fuera del análisis por no encontrarse información para incluirse en el panel de datos.

La metodología del *Random Forest*, tiene un porcentaje del 63.02% de acierto a la hora de clasificar de forma correcta una compañía entre empresas en *acuerdo de reorganización o en no acuerdo*, siendo este resultado muy superior al de una metodología logit de corte transversal.

El desarrollo de esta investigación permite concluir que el indicador de *Pasivo Corriente / Pasivo Total* es el más relevante a la hora de identificar que compañías, pueden estar en riesgo de solicitar ser admitidas en acuerdo de reorganización empresarial, adicionalmente se identifica que hay una relación inversa entre éste y la probabilidad de entrar en acuerdo, esto está dado por el signo negativo que acompaña el coeficiente de este indicador.

El indicador *Pasivo corriente / Pasivo Total*, se entiende como la *concentración del endeudamiento a corto plazo*, que posee una compañía en un periodo específico, y la lectura que se aplica a dicho ratio financiero, es que, en la medida que se concentra la deuda en el pasivo corriente con un resultado mayor que uno (1), la empresa se ve afectada en su liquidez; la empresa básicamente está atentando contra la solvencia financiera de periodos futuros, y si la concentración es menor que uno (1), se presenta mayor solvencia y liquidez para cumplir con sus obligaciones con terceros, es decir que el manejo del endeudamiento está enfocado más a largo plazo.

Por tal razón, el resultado que arroja el modelo utilizado, sobre el ratio financiero de la concentración del endeudamiento a corto plazo, indicando que este tiene una lectura inversa, está acorde con la interpretación financiera que tiene el mismo sobre los estados financieros.

Adicionalmente, los resultados obtenidos, incluyen el indicador de la *razón corriente* (Activos corrientes / pasivos corrientes), como un ratio financiero que se debe analizar, para tomar acciones oportunas y así evitar que la empresa caiga en insolvencia y posteriores dificultades económicas,

por el no pago a empleados, proveedores, inversionistas y entes gubernamentales, que lleven a la entidad a acogerse a ley 1116 de 2006 o su extinción.

Finalmente, como resultado sorprendente pero no alejado de la lógica del análisis de la situación financiera de una compañía, se obtuvo como indicador relevante, la variación sobre el patrimonio; variación que puede ser analizada con base al estado de cambios en el patrimonio (ECP) a un corte específico, del cual se podrá obtener sin tener en cuenta las variaciones del otro resultado integral (ORI), un alerta sobre la razonabilidad entre el incremento o disminución del patrimonio vs los pagos realizados a los inversiones por dividendos en efectivo o capitalizaciones para futuros crecimiento de la empresa traducidos en compra de bienes muebles o inmuebles (CAPEX) para fortalecer la compañía. Pero principalmente el pago de dividendos en efectivo, será un componente de las variaciones de patrimonio, que podrán alertar a una empresa sobre la liquidez que tiene en el presente y que puede afectar la solvencia económica de futuros periodos.

Con base a los modelos de predicción realizados por Altman, Fulmer, Pascale, Rosillo y Martinez, detallados en la Tabla 5, del presente trabajo y tomados como base para entablar nuestra hipótesis, se evidencia que los ratios coincidentes entre los modelos no toman como relevante el resultado obtenido por nuestra investigación, para lo cual podemos concluir que las diferencias entre las bases de datos de cada modelo y de nuestra investigación, determinan ratios específicos, adicionalmente las diferencias geográficas de las empresas que conforman la base de datos son completamente diferentes, razón por la cual los resultados no son coincidentes en la determinación de las variables relevantes para que una entidad caiga en insolvencia y posteriormente para el caso colombiano para entidades analizadas entre los años 2013 y 2017, integrando los acuerdos de reorganización empresarial que considera la ley 1116 de 2006.

## 6. Bibliografía

(Arnold y Earl, 2006). (s.f.).

Altman E. (1968). *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy*, *The Journal of Finance*.

Altman E. (Julio de 2000). *Predicting Financial Distress of Companies: Revisiting the Z-Score and Zeta® Models*. Recuperado el 03 de Junio de 2.018, de <http://pages.stern.nyu.edu/~ealtman/Zscores.pdf>

Altman, E. I. (1.993). *Corporate Financial Distress and Bankruptcy: A complete Guide to Predicting and Avoiding Distress and Profiting from Bankruptcy*. Wiley Finance Edition. Recuperado el 10 de Junio de 2.018

Altman, E. I. (Julio de 2.000). *Predicting Financial Distress of Companies: Revisiting the Z-Score and Zeta® Models*. Recuperado el 03 de Junio de 2.018

Altman, E. I. (2006). *Corporate Financial Distress and Bankruptcy : Predict and Avoid Bankruptcy, Analyze and Invest in Distressed Debt* (3rd ed. ed.). Hoboken, N.J. : Wiley. Recuperado el 03 de Junio de 2.018, de <http://search.ebscohost.com/login.aspx?direct=true&db=e020mww&AN=147866&lang=es&site=ehost-live>

ANDI. (2019). *Colombia: Balance 2018 y perspectivas 2019*. Recuperado el 01 de Abril de 2.019, de [http://www.andi.com.co/Uploads/ANDI%20-%20Balance%20y%20Perspectivas\\_636882495815285345.pdf](http://www.andi.com.co/Uploads/ANDI%20-%20Balance%20y%20Perspectivas_636882495815285345.pdf)

Banco de la Republica. (2.108). *Reporte de Estabilidad Financiera I Semestre 2.018*. Bogota.

Beaver W.H. (1966). *Financial Ratios as Predictors of Failure*, *Journal of Accounting Research, Supplement, Empirical Research in Accounting: Selected Studies*, pp. 71-111.

Beaver, W. H. (1.966). *Financial Ratios As Predictors of Failure*. *Journal of Accounting Research*, 4. Recuperado el 03 de Junio de 2.018, de <http://www.jstor.org/stable/2490171>

Beeravalli, V. (30 de Septiembre de 2018). *Comparison of Machine Learning Classification Models for Credit Card Default Data*. Recuperado el 14 de



- Noviembre de 2019, de <https://medium.com/@vijaya.beeravalli/comparison-of-machine-learning-classification-models-for-credit-card-default-data-c3cf805c9a5a>
- Berk, J. B. (April de 2007). Human Capital, Bankruptcy and Capital Structure. *National Bureau of Economic Research*. Recuperado el 12 de Agosto de 2.018
- Besley S, & B. (2001). *Fundamentos de Administracion Financiera* (12 ed.). Mexico, D.F: McGraw Hill. Recuperado el 02 de Junio de 2.018
- Bo K. Wong, Vincent S. Lai, Jolie Lam. (1994 - 1998). *A Bibliography of neural network business applications research*. Hong Kong.
- Brealey, M. a. (2007). *Fundamentos de Finanzas Corporativas* (Quinta ed.). McGraw Hill. Recuperado el 10 de Junio de 2.018
- Breiman, L. (2001). Random Forests. En L. Breiman, & R. E. Schapire (Ed.), *Machine Learning* (págs. 5-32). California: Kluwer Academic Publishers. Recuperado el 19 de 08 de 2019, de <https://link.springer.com/content/pdf/10.1023/A:1010933404324.pdf>
- Brooks, R. M. (2013). *Financial Management: Core Concepts* (Segunda ed.). Pearson. Recuperado el 10 de Junio de 2.018
- Caliendo, M. y. (26 de Abril de 2.005). Some Practical Guidance for the Implementation of Propensity Score Matching. *Econstor*. Recuperado el 02 de Septiembre de 2.018
- Carrasco Perea, R. (Octubre de 2001). Modelos de elección discreta para datos de panel y modelos de duración: una revisión de la literatura. Madrid. Recuperado el 2019 de 09 de 23, de <https://core.ac.uk/download/pdf/29400111.pdf>
- Cayon Edgardo, C. J. (2.017). Does Attending a Public or Private University Make a Difference for Students en Colombia? *International Review of Management and Marketing*. Recuperado el 29 de Julio de 2.018
- Congreso de la Republica. (27 de Diciembre de 2006). Ley 1116 de 2006. Bogota. Recuperado el 03 de Junio de 2.018
- Deakin E B. (1972). *A Discriminant Analysis of Predictors of Business Failure, Journal of Accounting Research*,.

- Espinosa Fredy, M. M. (2015). Fracaso empresarial de las pequeñas y medianas empresas (pymes) en COlombia. *El Servier / Suma de Negocios*, 6(13), 29-41. Recuperado el Abril de 13 de 2.019
- Espinosa, F. R. (05 de Junio de 2013). Alcances y limitaciones de los modelos de capacidad predictiva en el análisis del fracaso empresarial. Medellín, Colombia. Recuperado el 01 de Abril de 2.019
- Espinosa, F. R. (05 de Junio de 2013). Alcances y limitaciones de los modelos de capacidad predictiva en el análisis del fracaso empresarial. Medellín, Colombia. Recuperado el 01 de Abril de 2.019
- FMI. (11 de Enero de 2019). *Fondo Monetario Internacionl*. Recuperado el 02 de Abril de 2.019, de <https://www.imf.org/es/Publications/WEO/Issues/2019/01/11/weo-update-january-2019>
- Gilson, S. C. (Marzo de 1997). Transactions Costs and Capital Structure Choice: Evidence from Financially Distressed Firms. *The Journal of Finance*, LII(1). Recuperado el 20 de Julio de 2.018
- Ginoglou, D. A. (2002). Predicting Corporate Failure oPredicting corporate failure of problematic firms in Greece with LPM logit probit and discriminant analysis models. *Journal of Financial Management and Analysis*, 15(1), 15(1), 1. Recuperado el 22 de Julio de 2.018
- Goyal, M. Z. (2009). *Capital Structure Decisions: Which Factors Are Reliably Important?* Financial Management. Recuperado el 20 de Julio de 2.018
- Grennepois, N. (Septiembre de 2018). Using Random Forest for credit risk models. *Machine learning and Credit Risk : a suitable marriage?* Deloitte. Recuperado el 14 de Noviembre de 2019, de <https://www2.deloitte.com/content/dam/Deloitte/nl/Documents/financial-services/deloitte-nl-fsi-using-random-forest-for-credit-risk-models.pdf>
- Grinblatt, M. y. (2003). *Mercados Financieros y Estrategia Empresarial* (Segunda ed.). McGraw-Hill. Recuperado el 08 de Julio de 2.018
- Hinestroza Ramirez, D. (2018). El Machine Learning a traves de los tiempos, y los aportes a la humanidad. Pereira. Recuperado el Noviembre de 14 de 2019, de <https://repositorio.utdt.edu/handle/utdt/10967>

- <https://www.academiadeinversion.com/altman-z-score-formula-predecir-queiebras/>. (22 de 07 de 2018). Obtenido de <https://www.academiadeinversion.com/altman-z-score-formula-predecir-queiebras/>: <https://www.academiadeinversion.com/altman-z-score-formula-predecir-queiebras/>
- Julio, C. E. (2.104). Testing COntagion with Propensity Matching Estimators: A three Country Empirical Example. *European Journal of Scientific Research*, 122(1), 107-113. Recuperado el 29 de Julio de 2.108
- Keasy, K., & Watson, R. (1991). *Financial Distress Prediction Models: A Review of their Usefulness*. *British Journal of Management*, 2, 89-102.
- Liaw, A. a. (12 de 2002). *Research Gate*. Recuperado el 19 de 08 de 2019, de [https://www.researchgate.net/profile/Andy\\_Liaw/publication/228451484\\_Classification\\_and\\_Regression\\_by\\_RandomForest/links/53fb24cc0cf20a45497047ab/Classification-and-Regression-by-RandomForest.pdf](https://www.researchgate.net/profile/Andy_Liaw/publication/228451484_Classification_and_Regression_by_RandomForest/links/53fb24cc0cf20a45497047ab/Classification-and-Regression-by-RandomForest.pdf)
- Martinez O. (2006). *DETERMINANTES DE FRAGILIDAD EN LAS EMPRESAS COLOMBIANAS*.
- Martinez O. (2006). *DETERMINANTES DE FRAGILIDAD EN LAS EMPRESAS COLOMBIANAS*. Obtenido de Pagina Banco de la Republica de Colombia: <http://www.banrep.gov.co/sites/default/files/publicaciones/pdfs/borra259.pdf>
- Ministerio de Comercio, Industria y Turismo y la Superintendencia de Sociedades. (2007). *Cartilla: Nuevo Régimen de Insolvencia Empresarial Ley 1116 de 2006*. Recuperado el 11 de Agosto de 2.018
- Pascale, R. (1988). (s.f.). "A Multivariate Model to Predict Firm Financial Problems: The Case of Uruguay", *Studies in Banking and Finance*, Vol. 7, pp. 171–182.
- Platt\*, H. D. (2.002). Predicting Corporate Financial Distress: Reflections on Choice-Based Sample Bias. 26(2). *Journal of Economics and Finance*. Recuperado el 03 de Junio de 2.018, de <https://link.springer.com/article/10.1007/BF02755985>
- Rodriguez, A. (2011). Teoria de la estructura de capital y su impacto en la toma de decisiones de inversión y financiamiento. *Visión Gerencial*(1), 188-206. Recuperado el 27 de Agosto de 2.018

- Romero, F. (Marzo de 2013). Variables financieras determinantes del fracaso empresarial para la pequeña y mediana empresa en Colombia: análisis bajo el modelo Logit. *Pensamiento & Gestión*, núm. 34, enero-junio, 235-277.
- Rosillo J. (2002). *Modelo de predicción de quiebras de las empresas colombianas*.
- Ross, W. a. (2009). *Finanzas Corporativas* (Octava ed.). Mexico: McGraw Hill. Recuperado el 29 de Julio de 2.018
- Sarmiento J. (01 de Julio de 2005). ¿De que depende que una empresa entre en bancarrota? *Revisata Facultad de Ciencias Economicas: Investigacion y Reflexion*, XIII(1), 19 -30.
- Sosa Sierra, M. d. (2006). *Contribuciones a la Economía*. Obtenido de <http://www.eumed.net/ce/2006/mcss.htm>
- Superintendencia de Sociedades. (30 de Junio de 2.018). *Sociedades en Reorganización y Validación Judicial Acumulado a Sociedades en Acuerdos de Reestructuración acumulado a 30 de Junio de 2018*. Estadísticas de Insolvencia. Recuperado el 10 de Julio de 2.018, de Superintendencia de Sociedades: [https://www.supersociedades.gov.co/delegatura\\_insolvencia/Documents/Informes\\_Periodicos\\_Junio\\_30\\_2018/Reorganizacion\\_Empresarial\\_Validacion\\_Judicial\\_Acumulado\\_30Junio2018.htm](https://www.supersociedades.gov.co/delegatura_insolvencia/Documents/Informes_Periodicos_Junio_30_2018/Reorganizacion_Empresarial_Validacion_Judicial_Acumulado_30Junio2018.htm)
- Tim C, O. a. (1994). Financial Distress and Corporate Performance. *The Journal of Finance*, 1015 - 1037. Recuperado el 21 de Julio de 2.018
- Valdés, L. (2006). *El análisis financiero como herramienta en la predicción de quiebras e insolvencia financiera*.
- Wang, Ying. (2010). *FINANCIAL RATIOS AND THE PREDICTION OF BANKRUPTCY: THE OHLSON MODEL APPLIED TO CHINESE PUBLICLY TRADED COMPANIES*. Las Vegas.
- Yaw M., M. (1.984). An Examination of Stationarity of Multivariate Bankruptcy Prediction Models: A Methodological Study. *Journal of Accounting Research*, 22(1), 380-395. Recuperado el 22 de Julio de 2.018
- Yiu, T. (Junio de 2012). *Towards Data Science*. Recuperado el 11 de 08 de 2019, de <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>

Zaforas, M. (15 de 03 de 2017). *Paradigma Digital*. Recuperado el 22 de 09 de 2019, de <https://www.paradigmadigital.com/techbiz/machine-learning-dummies/>

## Anexos

### Anexo A. Código Random Forest

```
## Probability of Default Using Machine Learning

# Workspace

setwd("F:/Probability of Agreement")

set.seed(12)

# Import Data

#install.packages("readxl")

library(readxl)

datos=read_excel("Consolidado Panel v3 Febrero 27.xlsx", sheet = "Consolidado")

# Adjusting names

colnames(datos)[3]="Acuerdo"

colnames(datos)[6]="AAcuerdo"

colnames(datos)[7]="ACifras"

View(datos)

## Groups of categories

# Segmento

#datos$SegmentoC=as.numeric(factor(datos$Segmento))

#table(datos$Segmento)

# Sector

#datos$SectorC=as.numeric(factor(datos$Sector))

#table(datos$Sector)
```

```

## Eliminating agreements that are in the past years of the data

drop=datos$AAcuerdo-datos$ACifras

datos1=subset(datos,drop>=0 | is.na(drop))

rm(drop)

## Collapse data

#datos1=aggregate(datos1,list(datos1$NIT),mean)

## Drop string variables

# "Año Acuerdo" since it is just for Año Acuerdo=1 / 6

# "NIT", "RazonSocial", "Sector", "Segmento" since those are names or IDs / 1,2,4,5

# "Año Cifras" not useful for now / 7

datos1=subset(datos1,select=-c(6,1,2,4,5,7))

## Number of missing values by variable

NAs=sort(sapply(datos1,function(x) sum(is.na(x))),decreasing = FALSE)

variables=names(NAs)

View(NAs)

# Number of variables to consider with less missing values

n0=14                                     # Indicate the # of variables

to keep because the low number of missing data

inicio=n0+1

datos1=cbind(subset(datos1,select=Acuerdo),subset(datos1,select=variables[2:inicio]))

## Correlations

correlations=cor(datos1$Acuerdo,datos1[,2:ncol(datos1)],use="pairwise.complete")

correlations1=t(apply(abs(correlations),1,sort))

variables=colnames(correlations1)

```

```
View(t(correlations1))

## Dataset

# Number of variables within the Machine Learning and Logit estimation. Mayor correlations
with Agreement variable

n1=10 # Indicate the number of
variables to include

inicio=ncol(datos1)-n1

datos2=cbind(subset(datos1,select=Acuerdo),subset(datos1,select=variables[inicio:ncol(correlati
ons1]]))

# Drop missing values

datos2=na.omit(datos2)

## Training and testing data bases

#install.packages("caret",dependencies=TRUE)

library(caret)

index=createDataPartition(datos2$Acuerdo,p=0.80,list=FALSE)

# Training Data

datos.training=datos2[index,]

# Testing Data

datos.test=datos2[-index,]

## Logit estimation

Logit=glm(Acuerdo~.,data=datos.training,family=binomial(link="logit"))

summary(Logit)
```



```
# Predictions

PredictLogit=predict(Logit,type="response")

PredictLogit1=predict(Logit,type="response",newdata=datos.test)

# ROC curve for optimal threshold

t=0.65

# Confusion matrix

table(datos.training$Acuerdo,PredictLogit>t)

table(datos.test$Acuerdo,PredictLogit1>t)

confusionMatrix(datos.training$Acuerdo,PredictLogit>t)

confusionMatrix(datos.test$Acuerdo,PredictLogit1>t)

# Variable importance

Importance=varImp(Logit,scale=FALSE)

plot(Importance)

## Random Forest estimation

#install.packages("rpart",dependencies=TRUE)

#install.packages("rpart.plot",dependencies=TRUE)

#install.packages("mlbench",dependencies=TRUE)

#install.packages("ranger",dependencies=TRUE)

library(rpart)

library(rpart.plot)

library(mlbench)

library(ranger)

RF=train(Acuerdo~.,data=datos.training,method="ranger")
```

```
print(RF)

# Predictions

PredictRF=predict(RF,type="response")

PredictRF1=predict(RF,type="response",newdata=datos.test)

# Confusion matrix

table(datos.training$Acuerdo,PredictRF)

table(datos.test$Acuerdo,PredictRF)

confusionMatrix(datos.training$Acuerdo,PredictRF)

confusionMatrix(datos.test$Acuerdo,PredictRF1)
```

### Anexo B. Código panel de datos logit

```

sheet("Consolidado") cellrange(A1:AG173071) firstrow
destring AñoCifras, generate(año)

list año if año==.

drop in 17015

tab año

encode Sector, generate(sector_n)

encode Segmento, generate(segmento_n)

logit EnAcuerdo1NoAcuerdo0 i.sector_n i.segmento_n Ventas Activos Utilidad Patrimonio
CrecimientoenVentas CrecimientoDisminuciónenAct CrecimientoDisminuciónenUti
CrecimientoDisminucióndelPa EBITDA UtilidadNetaVentas UtilidadNetaPatrimonio
UtilidadOperacionalVentas Endeudamiento Apalancamiento PasivoTotalVentas
RotacióndeCobro RotacióndeInventario RotacióndeProveedores CicloOperativo RatioCorriente
PruebaAcida CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta

testparm i.sector_n

testparm i.segmento_n

areg EnAcuerdo1NoAcuerdo0 i.sector_n i.segmento_n Ventas Activos Utilidad Patrimonio
CrecimientoenVentas CrecimientoDisminuciónenAct CrecimientoDisminuciónenUti
CrecimientoDisminucióndelPa EBITDA UtilidadNetaVentas UtilidadNetaPatrimonio
UtilidadOperacionalVentas Endeudamiento Apalancamiento PasivoTotalVentas
RotacióndeCobro RotacióndeInventario RotacióndeProveedores CicloOperativo RatioCorriente
PruebaAcida CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta, absorb(NIT)

tabulate AñoCifras, missing

tab año

```

tabulate año, missing

bysort AñoCifras: gen secuencia=\_n

xtset secuencia año

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad Patrimonio

CrecimientoenVentas CrecimientoDisminuciónenAct CrecimientoDisminuciónenUti

CrecimientoDisminucióndelPa EBITDA UtilidadNetaVentas UtilidadNetaPatrimonio

UtilidadOperacionalVentas Endeudamiento Apalancamiento PasivoTotalVentas

RotacióndeCobro RotacióndeInventario RotacióndeProveedores CicloOperativo RatioCorriente

PruebaAcida CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta

testparm i.sector\_n

testparm i.segmento\_n

estimate store modelo1

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad Patrimonio

CrecimientoenVentas CrecimientoDisminuciónenAct CrecimientoDisminuciónenUti

CrecimientoDisminucióndelPa EBITDA UtilidadNetaVentas UtilidadNetaPatrimonio

UtilidadOperacionalVentas Endeudamiento Apalancamiento PasivoTotalVentas

RotacióndeCobro RotacióndeInventario RotacióndeProveedores CicloOperativo RatioCorriente

PruebaAcida CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad

CrecimientoenVentas CrecimientoDisminuciónenAct CrecimientoDisminuciónenUti

CrecimientoDisminucióndelPa EBITDA UtilidadNetaVentas UtilidadNetaPatrimonio

UtilidadOperacionalVentas Endeudamiento Apalancamiento PasivoTotalVentas

RotacióndeCobro RotacióndeInventario RotacióndeProveedores CicloOperativo RatioCorriente

PruebaAcida CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminuciónenAct CrecimientoDisminuciónenUti  
 CrecimientoDisminucióndelPa EBITDA UtilidadNetaVentas UtilidadNetaPatrimonio  
 UtilidadOperacionalVentas Endeudamiento Apalancamiento PasivoTotalVentas  
 RotacióndeCobro RotacióndeInventario RotacióndeProveedores CicloOperativo RatioCorriente  
 CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta  
 xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa EBITDA  
 UtilidadNetaVentas UtilidadNetaPatrimonio UtilidadOperacionalVentas Endeudamiento  
 Apalancamiento PasivoTotalVentas RotacióndeCobro RotacióndeInventario  
 RotacióndeProveedores CicloOperativo RatioCorriente CapitaldeTrabajo  
 PasivoCorrientePasivoTotal UtilidadBruta  
 xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa EBITDA  
 UtilidadNetaVentas UtilidadNetaPatrimonio UtilidadOperacionalVentas Endeudamiento  
 Apalancamiento PasivoTotalVentas RotacióndeProveedores CicloOperativo RatioCorriente  
 CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta  
 xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa EBITDA  
 UtilidadNetaVentas UtilidadNetaPatrimonio UtilidadOperacionalVentas Endeudamiento  
 PasivoTotalVentas RotacióndeProveedores CicloOperativo RatioCorriente CapitaldeTrabajo  
 PasivoCorrientePasivoTotal UtilidadBruta  
 xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa EBITDA

UtilidadNetaVentas UtilidadNetaPatrimonio UtilidadOperacionalVentas Endeudamiento

PasivoTotalVentas RotacióndeProveedores RatioCorriente CapitaldeTrabajo

PasivoCorrientePasivoTotal UtilidadBruta

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad

CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa EBITDA

UtilidadNetaVentas UtilidadNetaPatrimonio Endeudamiento PasivoTotalVentas

RotacióndeProveedores RatioCorriente CapitaldeTrabajo PasivoCorrientePasivoTotal

UtilidadBruta

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad

CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa EBITDA

UtilidadNetaVentas UtilidadNetaPatrimonio PasivoTotalVentas RotacióndeProveedores

RatioCorriente CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad

CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa

UtilidadNetaVentas UtilidadNetaPatrimonio PasivoTotalVentas RotacióndeProveedores

RatioCorriente CapitaldeTrabajo PasivoCorrientePasivoTotal UtilidadBruta

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad

CrecimientoenVentas CrecimientoDisminuciónenUti CrecimientoDisminucióndelPa

UtilidadNetaVentas UtilidadNetaPatrimonio PasivoTotalVentas RotacióndeProveedores

RatioCorriente CapitaldeTrabajo PasivoCorrientePasivoTotal, nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad

CrecimientoenVentas CrecimientoDisminucióndelPa UtilidadNetaVentas

UtilidadNetaPatrimonio PasivoTotalVentas RotacióndeProveedores RatioCorriente

CapitaldeTrabajo PasivoCorrientePasivoTotal, nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminucióndelPa UtilidadNetaVentas  
 UtilidadNetaPatrimonio PasivoTotalVentas RotacióndeProveedores RatioCorriente  
 CapitaldeTrabajo PasivoCorrientePasivoTotal, nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminucióndelPa UtilidadNetaVentas  
 UtilidadNetaPatrimonio RotacióndeProveedores RatioCorriente CapitaldeTrabajo  
 PasivoCorrientePasivoTotal, nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminucióndelPa UtilidadNetaVentas  
 UtilidadNetaPatrimonio RotacióndeProveedores RatioCorriente PasivoCorrientePasivoTotal,  
 nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminucióndelPa UtilidadNetaVentas  
 RotacióndeProveedores RatioCorriente PasivoCorrientePasivoTotal, nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Ventas Activos Utilidad  
 CrecimientoenVentas CrecimientoDisminucióndelPa RotacióndeProveedores RatioCorriente  
 PasivoCorrientePasivoTotal, nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Activos Utilidad CrecimientoenVentas  
 CrecimientoDisminucióndelPa RotacióndeProveedores RatioCorriente  
 PasivoCorrientePasivoTotal, nolog

xtlogit EnAcuerdo1NoAcuerdo0 i.sector\_n i.segmento\_n Activos Utilidad CrecimientoenVentas  
 CrecimientoDisminucióndelPa RatioCorriente PasivoCorrientePasivoTotal, nolog

```
xtlogit EnAcuerdo1NoAcuerdo0 i.sector_n i.segmento_n Activos Utilidad
CrecimientoDisminucióndelPa RatioCorriente PasivoCorrientePasivoTotal, nolog
xtlogit EnAcuerdo1NoAcuerdo0 i.sector_n i.segmento_n Utilidad
CrecimientoDisminucióndelPa RatioCorriente PasivoCorrientePasivoTotal, nolog
xtlogit EnAcuerdo1NoAcuerdo0 i.sector_n i.segmento_n CrecimientoDisminucióndelPa
RatioCorriente PasivoCorrientePasivoTotal, nolog
testparm i.segmento_n
estimate store modelofinal
testparm i.sector_n
outreg2 [modelo1 modelofinal] using resultados.xls
```