



**Colegio de Estudios  
Superiores de Administración**

**Riesgo de Crédito de Proveedores de Instituciones Prestadoras de Servicios  
de Salud en Colombia**

**Felipe García Isaacs**

**Colegio De Estudios Superiores De Administración - CESA**

**Maestría en Finanzas Corporativas**

**Bogotá**

**2019**

**Riesgo de Crédito de Proveedores de Instituciones Prestadoras de Servicios  
de Salud en Colombia**

**Felipe García Isaacs**

**Tutor**

**EDGARDO CAYON FALLON**

**Colegio De Estudios Superiores De Administración - CESA**

**Maestría en Finanzas Corporativas**

**Bogotá**

**2019**

## Contenido

<b>1. Introducción</b> .....	5
<b>1.1. Objetivo General</b> .....	8
<b>1.2. Objetivos Específicos</b> .....	8
<b>2. Estado del Arte</b> .....	9
<b>2.1. Beaver</b> .....	9
<b>2.2. Edward Altman (Z score)</b> .....	11
<b>2.3. James Ohlson (O-Score)</b> .....	13
<b>2.4. Modelos estadísticos para el desarrollo de Credit Scoring</b> .....	14
<b>2.4.1. Análisis Discriminante</b> .....	15
<b>2.4.2. Modelo Logit</b> .....	16
<b>2.5. Investigaciones sobre Credit Scoring</b> .....	17
<b>3. Marco Teórico</b> .....	20
<b>4. Metodología</b> .....	22
<b>4.1. Selección base de datos</b> .....	22
<b>4.2. Definición de las razones financieras para el modelo de crédito</b> .....	23
<b>4.3. Selección Modelo</b> .....	25
<b>4.4. Desarrollo Modelo Logit</b> .....	26
<b>4.5. Análisis Resultados</b> .....	28
<b>4.6. Resumen resultados</b> .....	38
<b>5. Conclusiones</b> .....	44
<b>6. Bibliografía</b> .....	46

## Índice de Tablas

Tabla 1 Composición de Cartera de IPS por edades por tipo de Deudor.....	7
Tabla 2 Predicción del valor de la media en empresa en quiebra y sanas.....	10
Tabla 3 Métodos para el desarrollo de Credit Scoring.....	15
Tabla 4 Resultados regresión Modelo No 1 .....	28
Tabla 5 Resultados predicción Modelo No 1.....	29
Tabla 6 Resultados regresión Modelo No 2 .....	30
Tabla 7 Resultados predicción Modelo No 2.....	31
Tabla 8 Resultados regresión Modelo No 3 .....	32
Tabla 9 Resultados predicción Modelo No 3.....	33
Tabla 10 Resultados regresión Modelo No 4 .....	34
Tabla 11 Resultados predicción Modelo No 4.....	35
Tabla 12 Resultados regresión Modelo No 5 .....	36
Tabla 13 Resultados predicción Modelo No 5.....	37
Tabla 14 Resumen Resultados Regresiones .....	38
Tabla 15 Resumen Resultados Predicción.....	39
Tabla 16 Resumen Resultados Predicción modelo No 4.....	39
Tabla 17 Porcentaje de aciertos.....	40
Tabla 18 67 IPS's no aptas para recibir crédito.....	41
Tabla 19 P&G consolidado año 2013-2018 .....	42
Tabla 20 P&G consolidado por departamentos año 2013-2018.....	42

## **1.Introducción**

El presente trabajo de investigación recae sobre el riesgo de crédito que afrontan los proveedores de las Instituciones Prestadoras de Servicios de Salud (IPS), entidades que hacen parte del Sistema General de Seguridad Social en Salud de Colombia (SGSSS), creado mediante la Ley 100 de 1993. Su alcance consiste en determinar cuando las Instituciones Prestadoras de Servicios de Salud (IPS), son o no óptimas para recibir crédito por parte de sus proveedores, permitiendo disminuir el riesgo de crédito de estos últimos, definido como “la pérdida potencial producto del incumplimiento de la contraparte en una operación que incluye un compromiso de pago” (De Lara Haro, 2005, pág. 16).

Se pretende el desarrollo de un modelo de Credit Scoring cuyo alcance permita a los proveedores decidir a que IPS otorgar crédito, evitando una situación de insolvencia financiera. Credit Scoring es un método estadístico empleado para medir el riesgo de crédito mediante la predicción de la probabilidad de impago de la contraparte, a partir de la información histórica genera un score que permite clasificar el nivel de riesgo (Mester,1997). Los métodos estadísticos de mayor relevancia para estructurar modelos de Credit Scoring son el modelo de probabilidad lineal, modelo probit, modelo logit y el modelo del análisis discriminante, siendo estos dos últimos los más aceptados (Altman & Saunders,1997).

La selección del Sector Salud dentro del tema de investigación, parte de su importancia en el desarrollo social y económico de Colombia y de la grave crisis financiera que sufre, acentuada por la falta de recursos y el lento movimiento de los mismos entre sus principales actores, causa del impacto negativo en la cadena productiva del sistema y la calidad del servicio ofrecido a los usuarios. La investigación se centra en las IPS, compuestas por hospitales, clínicas, laboratorios y consultorios, en las cuales los altos niveles de cartera, producto en su mayoría de los dineros adeudados por las Entidades Promotoras de Salud (EPS), ha afectado el flujo de caja de las mismas, al ir ligado a un prolongado periodo de cobro y alto costo financiero, este último producto de la fuerte

necesidad de obtener recursos para cumplir a sus proveedores, según Juan Carlos Giraldo, Director General de la Asociación Colombiana de Hospitales y Clínicas (2017). Entre los principales proveedores de las IPS encontramos empresas que cubren los segmentos de equipos médicos, insumos médicos, insumos para laboratorio clínico, ortopedia, transporte de ambulancias, medicamentos, lavandería y desinfección.

Dentro de los principales actores de la presente investigación y que hacen parte del Sistema General de Seguridad Social en Salud de Colombia (SGSSS), encontramos, el Estado, representado por el Ministerio de Salud y de Protección Social, como ente de dirección y control, las Empresas Promotoras de Salud (EPS) de carácter público y privado en su rol de aseguradoras, garantizando la prestación de los servicios de salud que se encuentra en el Plan Obligatorio de Salud (POS), las Instituciones Prestadoras de Servicios de Salud (IPS), entidades contratadas por las EPS y que conforman la red para la prestación de los servicios ofrecidos a los usuarios según el Plan Obligatorio de Salud (POS), el Fondo de Solidaridad y Garantía (FOSYGA), el cual cancela a las EPS acorde a su número de afiliados el valor de la Unidad de Pago por Capitación (UPC) y destina los recursos fiscales al Régimen Subsidiado. Finalmente los usuarios que hacen parte del Régimen Contributivo, constituido por empleados y empleadores que aportan a salud y pensión y el Régimen Subsidiado que abarca personas de bajos recursos financiadas por medio de los demás entes del sistema (Calderón, C. A. A., Botero, J. C., Bolaños, J. O., & Martínez, R. R., 2011).

Según Liliana Leveté Añez (2017), Presidente de la Asociación de IPS de Colombia, la crisis de salud es atribuida en parte a la deficiente articulación de los actores en mención, en el cual las IPS han sido las grandes apalancadoras de la insuficiencia de recursos. Se argumenta que las utilidades generadas año a año por muchas IPS, son en su mayoría producto de ventas a crédito constituidas en un alto nivel de cuentas por cobrar a las EPS, donde esta última partida compone en su mayoría el activo corriente de las IPS, lo anterior ha implicado que el tener la mayoría de recursos acumulados en cartera obligue a las IPS a financiarse

externamente, incurriendo en altos costos para cumplirle a sus proveedores y continuar en operación por la falta de liquidez (Giraldo, 2017).

Según estudios realizados por la Asociación de Clínicas y Hospitales, la cartera en mora (mayor a 60 días) de las IPS en Colombia, ha arrojado una participación sobre la cartera total de este actor superior al 60% desde el año 2015 , para el cierre de junio de 2017 su participación se encontraba en el 60,2% equivalente a 4.9 billones de pesos de un total adeudado por 8.2 billones de pesos, distribuido principalmente en EPS del Régimen Contributivo (37.9%), EPS-S del Régimen Subsidiado (30.2%) y el Estado (entes territoriales más FOSYGA) (10.2%) (Giraldo, 2017).

Tabla 1 Composición de Cartera de IPS por edades por tipo de Deudor

**SIN INCLUIR EL “DETERIORO”**

(Miles de \$ y participación %)

Tipo de Deudor	A 30 días más cte	Part % edad	De 31 a 60 días	Part % edad	De 61 a 90 días	Part % edad	Más de 91 días	Part % edad	TOTAL	Part % TOTAL COMPARATIVO	
										Jun 2017	Dic 2016
<b>1. REG. CONTRIBUTIVO</b>	1.082.572.592	39,0%	259.694.205	9,4%	222.779.414	8,0%	1.539.685.111	49,6%	3.104.731.322	37,9%	39,6%
<b>2. ESTADO</b>	230.393.017	30,6%	43.841.587	5,8%	43.489.480	5,8%	518.068.355	62,0%	835.792.438	10,2%	10,2%
ENTE TERRITORIAL	108.478.501	25,3%	26.990.269	6,3%	23.276.668	5,4%	321.492.672	66,9%	480.238.110	5,9%	6,2%
OPERADOR FIDUCIARIO (FOSYGA)	33.760.847	23,7%	5.913.958	4,2%	7.108.081	5,0%	119.544.389	71,9%	166.327.276	2,0%	2,0%
OTRAS	88.153.669	48,6%	10.937.360	6,0%	13.104.731	7,2%	77.031.293	40,7%	189.227.053	2,3%	1,9%
<b>3. REG. SUBSIDIADO</b>	638.492.601	28,2%	193.239.368	8,5%	132.692.174	5,9%	1.512.080.997	61,1%	2.476.505.140	30,2%	32,5%
<b>4. IPS</b>	137.542.258	26,6%	23.382.206	4,5%	23.988.978	4,6%	360.204.820	66,1%	545.118.261	6,6%	3,2%

5. PC Y MP	129.212.500	84,7%	7.685.122	5,0%	4.700.878	3,1%	23.689.227	14,3%	165.287.728	2,0%	2,1%
6. ASEGURADORAS	129.646.974	46,9%	12.640.690	4,6%	10.317.663	3,7%	169.937.087	52,7%	322.542.415	3,9%	3,5%
7. EMPRESA	129.156.669	32,2%	19.286.532	4,8%	24.514.561	6,1%	237.654.670	57,9%	410.612.432	5,0%	5,9%
8. PARTICULARES	74.840.798	69,2%	2.749.211	2,5%	2.758.420	2,5%	42.569.877	34,6%	122.918.307	1,5%	0,9%
9. ARL (RIESGOS LABORALES)	16.245.249	46,7%	2.043.019	5,9%	1.492.754	4,3%	19.088.326	49,1%	38.869.348	0,5%	0,5%
10. MAGISTERIO	2.973.078	17,3%	1.109.917	6,4%	1.273.965	7,4%	11.984.733	69,1%	17.341.693	0,2%	0,7%
11. SIN CLASIFICAR Y OTROS CONCEPTOS	124.489.729	89,0%	2.962.422	2,1%	1.502.583	1,1%	29.591.223	18,7%	158.545.957	1,9%	1,0%
<i>Total general</i>	<i>2.695.565.464</i>	<i>36,2%</i>	<i>568.634.279</i>	<i>7,6%</i>	<i>469.510.870</i>	<i>6,3%</i>	<i>4.464.554.427</i>	<i>54,5%</i>	<i>8.198.265.041</i>	<i>100,0%</i>	<i>100,0%</i>

*Nota:* Fuente Informe de Seguimiento de Cartera Hospitalaria, 2017.

Dado los antecedentes presentados y el alto grado de riesgo en la cartera de las IPS y por ende en las de sus proveedores, tan alta exposición al riesgo constituye un problema de valioso análisis para el desarrollo del presente trabajo de investigación, generando a partir de este un modelo que permita mitigar el riesgo de crédito asumido en la actualidad por cientos de proveedores del Sistema de Salud Colombiano, así mismo generar una directriz para que estos mismos propicien un camino hacia la diversificación de su portafolio de clientes y unidades de negocio.

### 1.1. Objetivo General

Identificar las razones financieras determinantes para que una Institución Prestadora de Servicios de Salud (IPS) sea apta para recibir crédito por parte de un proveedor, disminuyendo el riesgo asumido por este último.

### 1.2. Objetivos Específicos

- Proponer un sistema de Credit Scoring aplicado a las Instituciones Prestadoras de Servicios de Salud.
- Describir las razones financieras que mejor explican la clasificación de un cliente como óptimo para recibir crédito.
- Determinar las IPS aptas para recibir crédito.

## **2. Estado del Arte**

Al desarrollar un modelo de Credit Scoring la información presente en los estados financieros se constituye en el principal insumo de medición de riesgo de crédito, razón por la cual serán abordados los estudios iniciales realizados por Beaver, Altman y Ohlson, en los cuales a partir de razones financieras propusieron modelos para estimar la probabilidad de quiebra. Serán analizados los métodos estadísticos más frecuentes para estructurar modelos de Credit Scoring, así mismo se realizara una revisión de los estudios en los cuales se han implementado estos modelos estadísticos, resaltando sus aportes al tema de investigación.

### **2.1. Beaver**

En 1966 William Beaver en su estudio titulado Financial Ratios as Predictors of Failure, investiga la utilidad de las razones financieras como predictores de quiebra. Según Altman (1968) una de las desventajas de su estudio, radico en que la metodología empleada era de tipo univariado, contemplando el efecto de una razón o varias por separado, prestándose para confusiones dado que una firma podía presentar una baja rentabilidad siendo catalogada con alta posibilidad de quiebra, aunque lo anterior quedara descartado dado que presentaba un óptimo nivel de liquidez.

A partir de la información financiera de una muestra de 79 empresas públicas industriales en quiebra de 38 sectores obtenida de Moody's Industrial Manual, cuyo rango de activos oscilaba entre 6 millones a 45 millones de dólares con una media de 6.3 millones de dólares y de 12,000 empresas industriales sanas con una media de activos de 8.5 millones de dólares, Beaver determino las razones financieras con mayor predictibilidad de quiebra (Beaver, 1966).

Basado en la relación del flujo de caja y las razones financieras, Beaver (1966) defino cuatro proposiciones ceteris paribus:

1. Mayores reservas de efectivo, menor probabilidad de quiebra.
2. Mayor flujo de efectivo operativo, menor probabilidad de quiebra.
3. Mayor deuda retenida, mayor probabilidad de quiebra.
4. Mayor gasto operativo, mayor probabilidad de quiebra.

A partir de las medias calculadas de las razones financieras en los 5 años previos a la quiebra, Beaver (1966) determinó que las empresas que quebraron tenían en comparación a las empresas sanas , un menor nivel de flujo de caja , menores reservas de activo corriente, menor capacidad de atender sus obligaciones financieras y mayor dependencia a aumentar estas últimas.

*Tabla 2 Predicción del valor de la media en empresa en quiebra y sanas*

<b>No</b>	<b>Razón</b>	<b>Predicción</b>
<b>1</b>	Flujo de efectivo/Pasivo total	Sana > Quiebra
<b>2</b>	Ingresos netos/Activo total	Sana > Quiebra
<b>3</b>	Pasivo total/Activo total	Quiebra > Sana
<b>4</b>	Capital de trabajo/Activo total	Sana > Quiebra
<b>5</b>	Activo CP/ Pasivo CP	Sana > Quiebra
<b>6</b>	Intervalo de no crédito	Sana > Quiebra

*Nota:* Fuente Beaver, 1966

Dentro las 30 razones calculadas, Beaver (1966) resalto la habilidad predictiva de quiebra de las 6 razones expuestas en la tabla adjunta. No obstante, aclaro que no todas tenían la misma habilidad predictiva siendo el más importante el Flujo de efectivo/Pasivo total (Beaver, 1966).

## 2.2. Edward Altman (Z score)

Tomando como referencias los estudios de Beaver de enfoque unidimensional, Altman (1968), en su investigación titulada Financial Ratios, Discriminat Analysis and the Prediction of Corporate Bankruptcy, expuso las razones financieras que mejor explicaban la predicción de quiebra. Mediante la metodología de Análisis Discriminante Múltiple (MDA) corrige las imprecisiones del enfoque unidimensional de Beaver, incorporando la posibilidad de considerar el efecto conjunto de varias razones.

El análisis discriminante múltiple es una técnica estadística que entre sus aplicaciones abarca la predicción de problemas donde las variables dependientes son de tipo cualitativo, para el caso de estudio empresas en quiebra o no quiebra, tiene como propósito generar una combinación lineal de variables independientes que mejor discrimine un individuo en uno grupo u otro (Altman,1968).

Altman realizó su investigación sobre 66 compañías manufactureras que cotizaban en bolsa (33 en quiebra y 33 en buen estado), definiendo la siguiente función discriminante:

$$Z=1.2X_1+1.4X_2+3.3X_3+0.6X_4+0.99X_5$$

$V_1, V_2, \dots, V_n$  : representan los coeficientes discriminantes

$X_1, X_2, \dots, X_n$  : representan las variables independientes (razones financieras)

Mediante la función anterior transformo las razones en un único puntaje Z, que posteriormente se empleó para clasificar las empresas en uno u otro grupo.

De 22 razones financieras dentro de las categorías de liquidez, rentabilidad, apalancamiento, solvencia y actividad, las 5 elegidas fueron:

$X_1$ =Capital de Trabajo/Activos

$X_2$ =Utilidades retenidas/Activos

$X_3$ =EBIT/Activos

$X_4$ =Valor de mercado del patrimonio/Valor en libros pasivos.

$X_5$ =Ventas/Activos

Parte de los criterios para la selección de las 5 razones fueron su contribución relativa, grado de correlación y poder de predicción (Valdés,2010).

La variable  $X_3=EBIT/Activos$ , se constituyó como la de mayor peso explicativo sobre la probabilidad de quiebra, al ser una medida de la productividad de los activos.

Interpretación del Z score:

- 3.0 o más no hay probabilidad de quiebra.
- 2.7 a 2.99 área gris por debajo del umbral de mayor seguridad
- 1.82 a 2.7 intervalo inferior del área gris, probablemente se presente problemas financieros en el lapso de 2 años.
- Menor a 1.81, representa alta probabilidad de quiebra (Valdés, 2010).

Posteriormente el modelo inicial fue ajustado para ser aplicado a compañías privadas y no manufactureras, el cambio principal radico en modificar de la variable  $X_4$  el valor de mercado del patrimonio por el valor patrimonial en libros, así mismo fue modificada la ponderación de las razones financieras. (Valdés ,2010).

$$Z_1 = 0.717X_1 + 0.847X_2 + 3.107X_3 + 0.420X_4 + 0.998X_5$$

Interpretación del  $Z_1$  score:

- 2.9 o más no hay probabilidad de quiebra.
- 1.24 a 2.89 área gris, existe alguna probabilidad de quiebra.
- Menor a 1.23, representa alta probabilidad de quiebra (Valdés, 2010).

Finalmente surgió una variante al modelo anterior al eliminar la variable rotación de activos ( $X_5$ ) y darle un mayor peso a la generación de beneficios antes de intereses e impuesto sobre activos ( $X_3$ ) con el fin de aumentar la precisión al aplicar la metodología a empresas de servicios con una baja inversión en activos (Valdés, C. A. L ,2010).

$$Z_2 = 6.56X_1 + 3.26X_2 + 6.72X_3 + 1.05X_4$$

Interpretación del  $Z_1$  score:

- 2.6 o más no hay probabilidad de quiebra.
- 1.11 a 2.59 área gris, existe alguna probabilidad de quiebra.

- Menor a 1.10, representa alta probabilidad de quiebra (Valdés, 2010).

### **2.3. James Ohlson (O-Score)**

En 1980 James Ohlson en su paper titulado Financial Ratios and the Probabilistic Prediction of Bankruptcy, propone un modelo de predicción de quiebra, empleando información financiera del periodo 1,970 a 1,976 sobre 105 empresas en quiebra y 2,058 sanas del sector industrial, mediante el uso de la metodología econométrica de Análisis Condicional Logit. La anterior metodología fue seleccionada dado que identifico las siguientes debilidades en la metodología MDA empleada por Altman:

1. La matriz de varianza y covarianza de los predictores era igual para empresas en quiebra y sanas.
2. Las variables predictores deben asumir una distribución normal.
3. El resultado obtenido por medio de la aplicación de la metodología MDA es un score.
4. Presenta problemas asociados a la clasificación de los grupos.

El desarrollo del modelo se basó en 4 factores que Ohlson (1980) identifico estadísticamente significativos en la predicción de quiebra:

1. El tamaño de la compañía.
2. Medida de la Estructura Financiera.
3. Indicadores de desempeño.
4. Medida de Liquides.

A partir de estos Ohlson (1980) definió 9 razones financieras para realizar su análisis:

1. Tamaño:  $\log(\text{Total Activos} / \text{GNP índice de precios})$
2. TLTA: Total Pasivo sobre Total Activos
3. WCTA: Capital de trabajo sobre Total Activos
4. CLCA: Pasivos Corrientes sobre Activo Corriente

5. OENEG: 1 si el Total Pasivo excede el Total Activo, 0 de lo contrario
6. NITA: Ingreso Neto sobre Total Activos
7. FUTL: Flujo de Caja Operacional sobre Total Pasivo
8. INTWO: 1 si Ingreso Neto era negativo en los últimos 2 años, 0 de lo contrario
9. CHIN:  $\frac{N_{lt}-N_{lt-1}}{|N_{lt}|+|N_{lt-1}|}$ , donde  $N_t$  es el Ingreso neto en el periodo  $t$ , el factor mide la variación en el Ingreso Neto

Basado en estas 9 variables independientes Ohlson (1980) formuló 3 modelos:

- Modelo 1: predicción de quiebra dentro de un año.
- Modelo 2: predicción de quiebra dentro 2 años.
- Modelo 3: predicción de quiebra dentro de 1 o 2 años.

En todos los modelos la variable tamaño fue una de las variables de mayor importancia en la predicción de quiebra.

#### **2.4. Modelos estadísticos para el desarrollo de Credit Scoring**

Antiguamente los métodos tradicionales para otorgar crédito a la contraparte se basaban en el juicio humano realizado para medir el riesgo de impago, no obstante, el auge de demanda de créditos a nivel global, sumado a la creciente competencia de este mercado y al avance tecnológico, impulso el desarrollo de modelos estadísticos para facilitar la decisión de otorgar un crédito, Credit Scoring hace referencia a este proceso formal, (Hand & Henley ,1997).

Para su desarrollo comúnmente se emplean modelos estadísticos, los cuales mediante variables de predicción tienen como objetivo determinar la probabilidad de impago de la contraparte, mediante este cálculo se determina si el crédito es o no aprobado (Hand & Henley,1997).

Entre los métodos de mayor relevancia para estructurar modelos de Credit Scoring encontramos:

Tabla 3 Métodos para el desarrollo de Credit Scoring

Modelo Paramétrico	Lineal	<ol style="list-style-type: none"> <li>1. Análisis Discriminante</li> <li>2. Probabilidad lineal</li> <li>3. Modelo Logit</li> <li>4. Modelo Probit</li> <li>5. Programación Lineal</li> <li>6. Redes Neuronales</li> <li>7. Árboles de decisión</li> </ol>
	No lineal	
Modelo no Paramétrico		

*Nota:* Fuente Kim (2005)

Según Hand & Henley (1997), no se puede presumir de un modelo como el mejor, la veracidad de su resultado dependerá de la naturaleza del problema a abordar, la estructura de los datos, las características empleadas como predictores y su poder para discriminar entre uno u otro grupo.

A continuación se realizara énfasis en dos de los modelos más empleados, el Análisis Discriminante y el Modelo Logit.

#### **2.4.1. Análisis Discriminante**

El primer trabajo publicado para emplear el análisis discriminante en el desarrollo de un modelo de Score Credit fue publicado por Durand (1941) en su paper titulado Risk Elements in Consumer Installment Financing, mediante esta metodología estableció dos grupos, aquellos que cumplían con su obligación de pagar el crédito y aquellos que no, sujeto a información como el nivel de ingreso, ocupación, sexo, residencia entre otros.

El análisis discriminante es una metodología estadística de tipo multivariante que permite analizar simultáneamente el comportamiento de un grupo de variables independientes (predictoras), con el propósito de clasificar los individuos objeto de estudio en grupos excluyentes definidos con antelación (Medina& Martí, 2013).

El MDA tiene como objetivos:

1. Determinar las combinaciones lineales de variables independientes que maximice la diferenciación entre grupos, permitiendo discriminar los grupos establecidos de tal forma que el error sea mínimo.
2. Basado en las variables independientes, predecir la clasificación de los individuos objeto de estudio en un determinado grupo (Medina& Martí, 2013).

Para el cumplimiento de los 2 objetivos descritos se requiere maximizar la variabilidad entre grupos y minimizarla al interior de cada grupo obteniendo de esta manera los coeficientes de discriminación que maximicen el poder discriminatorio de la función establecida (Medina& Martí, 2013).

Como fue mencionado en el modelo desarrollado por Ohlson (1980) el MDA tiene las siguientes debilidades:

1. La matriz de varianza y covarianza de los predictores era igual para empresas en quiebra y sanas.
2. Las variables predictores deben asumir una distribución normal.
3. El resultado obtenido por medio de la aplicación de la metodología MDA es un score.
4. Presenta problemas asociados a la clasificación de los grupos.

#### **2.4.2. Modelo Logit**

Uno de los primeros trabajos publicados en la aplicación de la metodología Logit en un modelo de Credit Scoring, fue el realizado por Wiginton (1980), en su investigación titulada Anote on the comparision of logit and discriminant models of consumer credit behavior, en la cual partió de una muestra de datos obtenida del departamento de crédito de una compañía de petróleo durante los años 1967 a 1969. A partir de las investigaciones sustentadas por Duran (1941) basadas en el análisis discriminante, Wiginton (1980) puso en consideración la aplicación de un

modelo Logit como alternativa en la evaluación de riesgo de crédito, arrojando un mayor número de clasificaciones correctas que el MDA.

El modelo Logit es empleado para calcular la probabilidad de que un individuo haga parte o no en uno de los grupos definidos a priori, la clasificación dependerá de las variables independientes que se establezcan, las cuales son las características de cada individuo, la variable dependiente es de tipo binario tomando valores de 1 o 0, para el caso de estudio cada estado representa si se otorga o no el crédito (Medina & Martí, 2013).

Según Medina & Martí (2013) respecto al análisis discriminante presenta las siguientes ventajas:

1. No es necesaria una hipótesis de partida.
2. No existe restricción sobre el seguimiento de una distribución normal para sus variables.
3. No existe restricción frente a la igualdad de la matriz de covarianza y varianza.

No obstante, según estudios realizados Efron (1975), se demostró que en caso que las restricciones 2 y 3 se cumplan los estimadores del análisis discriminante serán más eficientes que los de la regresión logística.

Dado que según Medina & Martí (2013) la mayoría de problemas financieros como el análisis de crédito incorporan variables cualitativas lo cual irrumpe la condición de Normalidad, es preferible emplear el modelo Logit al ser más eficiente bajo esta condición sus estimadores de máxima verosimilitud.

## **2.5. Investigaciones sobre Credit Scoring**

Según Medina & Martí (2013) a partir de la base de datos de préstamos de consumo suministrada por una entidad bancaria en España, conformada por una muestra de 462 personas clasificadas como morosas y 984 como no morosas,

emplearon el modelo de árboles de clasificación y regresión para el desarrollo de un modelo de Credit Scoring, definiendo 13 variables explicativas y una variable dependiente cuyo valor era 1 igual moroso, 0 en caso contrario.

En su modelo definieron los siguientes 3 grupos:

1. Fallidos: prestamos con probabilidad de pago inferior a 30%.
2. No fallidos: probabilidad de pago superior al 70%.
3. Zona dudosa: entre el 30% y 70%.

Al validar los resultados por medio de su metodología y contrastarla frente a los resultados que obtuvieron empleando el análisis discriminante y la regresión logística, concluyendo que el modelo CART resulto ser más preciso que los anteriores, ya que a pesar de presentar un mayor error , el porcentaje de aciertos fue superior.

Miller& Rojas (2004), realizaron de la mano del Banco Mundial y la Corporación Fair Isaacs un estudio para desarrollar un sistema de Credit Scoring aplicado a pequeñas empresas en Latinoamérica, tomando como base Colombia y México. Entre las grandes preocupaciones asociadas a otorgar crédito a este segmento estaban presentes las asimetrías de información, así como la informalidad presente en la veracidad de sus estados financieros. Razón por la cual evidenciaron la aplicación de 3 factores importantes para otorgar los créditos:

1. Análisis de estados financieros.
2. Colateral.
3. Relación personal con el propietario de la compañía.

La Corporación Fair Isaacs fue pionera en crear un sistema de Credit Scoring para el mercado Americano que incluída dentro de su análisis no solo el desempeño financiero de la compañía sino también el de su propietario.

Cavalluzzo & Wolken (2005), analizan el mercado de crédito para pequeñas empresas en Estados Unidos, definiendo estas últimas como aquellas con menos de 500 empleados. Se evidencia que en muchas de estas empresas la riqueza del

dueño hace parte de la misma compañía, razón por la cual antes de otorgar un crédito a la empresa se hace una evaluación de las finanzas personales de este mismo, con el fin de evitar problemas de selección adversa. Dado lo anterior a mayor riqueza personal se presentan menores tasas de rechazo en los créditos solicitados, así mismo existen disparidades en las tasas de rechazo de crédito de acuerdo al origen étnico del propietario.

Ortiz & Morales (2014) proponen un modelo de Credit Scoring en México enfocado a las Instituciones de Micro finanzas cuyo target son pequeñas empresas afectadas normalmente por los ciclos de ventas. El aporte de su investigación radica en predecir el riesgo de impago incluyendo el efecto de la estacionalidad en ventas sobre el flujo de efectivo. Para lo anterior descartaron los métodos tradicionales de Credit Scoring y emplearon el método de Holt- Winters, herramienta empleada para predecir los flujos futuros de efectivo al presentarse estacionalidad.

West (2000), en su investigación titulada Neural network credit scoring models, analizo la precisión en la predictibilidad de impago en los resultados obtenidos de 5 modelos de redes neuronales versus el análisis discriminante y el modelo logit, fueron tomadas para el estudio 2 bases de datos intendentés de clientes en Alemania y Australia que solicitaron créditos. Como resultado se encontró que el panel de expertos fue el método más preciso de las redes neuronales, no obstante el modelo Logit arrojó un mayor nivel de precisión entre todos los modelos mientras que el modelo de árboles de decisión arrojó pobres resultados.

Sepúlveda, Reina & Gutiérrez (2010), en su investigación titulada Estimación del riesgo de crédito en empresas del sector real en Colombia, mediante un modelo probit estimaron la probabilidad de quiebra para inferir el riesgo de crédito, sobre una muestra de 410 empresas solventes y en estrés financiero clasificadas en 8 sectores de la económica. Como conclusión encontraron que las variables más significativas que disminuían la probabilidad de quiebra fueron cobertura de

intereses, relación de flujo de caja operativo a deuda y pertenecer al sector transporte. Por otra parte, las variables que resultaron ser significativas en aumentar la probabilidad de quiebra, fueron apalancamiento operativo y financiero, así como pertenecer a la industria manufacturera y al sector de la construcción.

---

### **3. Marco Teórico**

Las corrientes teóricas que influyen en el tema de estudio parten de la Teoría de Asimetría de Información, Costos de Agencia, Teoría de Costos de Transacción y Teoría de Portafolio.

En el campo de la Teoría de Asimetría de Información cabe destacar los aportes realizados por George Arthur Akerlof, en su célebre artículo The Market of Lemons, estudio que pone en evidencia el impacto de la asimetría de la información bajo el modelo del mercado de automóviles de segunda mano, en el cual solo el vendedor tenía la información real de calidad del auto a vender (Akerlof, G. ,1970). No se pueden desconocer las investigaciones de Myers & Majluf (1984), en las cuales se asume que la gerencia posee información de la cual los inversionistas no tienen acceso, siendo ambas partes conscientes de la asimetría presentada.

Los mercados presentan asimetrías de información entre vendedores y compradores, se oculta información dado que existe un riesgo moral de transferirla directamente a la contraparte y se presenta un incentivo al exagerar las cualidades positivas de las mismas (Leland & Pyle, 1977). Dado lo anterior los términos de crédito establecidos por el vendedor hacia el comprador implican una alta tasa de interés implícita, con el fin de compensar la asimetría de información del vendedor, asociada al riesgo de impago por parte del comprador (Smith, 1987). En este sentido bajo la Teoría de Asimetría de Información, el crédito comercial se constituye como elemento para mitigar su efecto negativo, actuando el plazo de crédito como mecanismo para reducir la incertidumbre del comprador asociada a la calidad del producto, mientras que las condiciones de pago permiten al

vendedor mitigar el riesgo de no recibir el dinero (Pike, Sang, Cravens & Lamminmaki, 2005).

Como segunda corriente encontramos los Costos de Agencia, bajo esta teoría la relación de agencia se define como “un contrato en virtud del cual una o más personas (principal) contratan a otra persona (agente) para que realice algún servicio en su nombre, lo que implica la delegación de alguna autoridad de toma de decisiones al agente”( Jensen & Meckling,1976,pág 308).De la anterior relación surgen costos de agencia asociados a estructurar, monitorear y delimitar la relación con el agente, dado que este no todas las veces toma decisiones que maximicen el bienestar del principal al darse un conflicto de interés(Fama, Eugene & Jensen, 1983). De acuerdo con Jensen & Meckling (1976), los problemas de agencia pueden extenderse a la relación entre las firmas y sus clientes, donde la asimetría de información se hace presente al no tener certeza el cliente de la calidad del producto vendido por la firma.

Como tercera Teoría tenemos los Costos de Transacción, de acuerdo a Petersen & Rajan (1997), el crédito comercial reduce los costos de transacción y da un parte de tranquilidad al comprador sobre la calidad del producto, permitiéndoles separar el ciclo de pago del esquema de despachos. Según Schwartz (1974), las firmas tienen ventajas de costo sobre las demás instituciones financieras para otorgar crédito por la venta de sus productos, dado que les es más fácil detectar a tiempo el nivel de solvencia de sus clientes, así como monitorear y exigir el pago de la cartera vencida. Las 3 fuentes de ventaja de costo son la adquisición de información, control sobre el comprador y recuperación del valor de los activos vendidos (Petersen & Rajan, 1997).

Finalmente los aportes de la Teoría de Portafolio de Markowitz en la cual define el “conjunto de portafolios eficientes como aquellos que proporcionan tanto el rendimiento esperado máximo para una varianza dada, como la varianza mínima para un rendimiento esperado dado” (Jensen & Smith, 1984, pág 6), donde el proceso de selección del portafolio en una primera fase se ve influenciado por la

experiencia y las expectativas sobre el futuro desempeño del mismo (Markowitz, 1952), han dado paso a que esta Teoría se tome como base para determinar el portafolio óptimo de clientes a los cuales se les otorgue un crédito comercial (Michalski ,2013).

#### **4. Metodología**

A partir de las bases de datos de BPR Benchmark se tomó una muestra de Instituciones Prestadoras de Servicio de Salud, haciendo una previa depuración de aquellas que presenten inconsistencias en la información financiera reportada, con el fin de disponer de una calidad de datos pertinente para el desarrollo del modelo de Credit Scoring. De esta forma la base de datos contendrá información relevante del estado de resultado, balance y flujo de caja. Se procederá a partir de la base de datos depurada a definir las variables predictivas del riesgo de crédito, que comprenden muchas de las razones financieras mencionadas anteriormente. Finalmente se validaran varios de estos modelos realizando los ajustes para identificar cual es el modelo óptimo, con el fin de emitir el análisis de resultados y conclusiones finales del proyecto de investigación.

##### **4.1. Selección base de datos**

A partir de las bases de datos de BPR Benchmark, se extrajo un total de 4.567 registros correspondientes a la información financiera de 913 IPS entre los años 2013 a 2017. A continuación se organizó la base de datos en mención en estructura de panel de datos, eliminando aquellas compañías que no contaban con información financiera en alguno de los 5 años objeto de estudio, lo anterior asegurando que las IPS bajo análisis contaran con la información completa en los 5 años de estudio.

Una vez definida la estructura en panel de datos, fueron eliminadas aquellas compañías con indicadores financieros inconsistentes, especialmente aquellas

que presentan inconsistencias contables (ejemplo: signos incorrectos como fue el caso específico de empresas con ingresos no operacionales negativos). Culminadas las anteriores etapas se obtuvo como resultado una base de datos depurada con 3.140 observaciones, es decir 628 IPS con información financiera durante los años 2013 a 2017.

#### **4.2. Definición de las razones financieras para el modelo de crédito**

A partir de la base de datos compuesta por 3.140 observaciones provenientes de 628 IPS se procedió a calcular las siguientes razones financieras como variables independientes con el objetivo de estructurar el modelo de Credit Scoring:

##### **Indicadores de Liquidez**

- $X_1 = \text{Activo Corriente} / \text{Pasivo Corriente}$

La razón corriente permite determinar la capacidad de las empresas de afrontar sus obligaciones de corto plazo con activos de corto plazo.

- $X_2 = \text{Activo Corriente} - \text{Pasivo Corriente}$

El capital de trabajo neto determina la habilidad para cubrir con los activos corrientes los pasivos corrientes.

##### **Indicadores de Administración**

- $X_3 = \text{Capital de Trabajo} / \text{Total Activo}$

Pretenden determinar qué tan productiva es la gestión del capital de trabajo frente a la inversión realizada en activos.

- $X_4 = \text{Periodo Promedio de Cobro}$

Busca medir el tiempo en que los recursos de la empresa se encuentran inmovilizados por concepto de cartera por cobrar a clientes.

- $X_5 =$  Periodo Promedio de Pago

Su finalidad es medir si existe dificultad en la gestión de pago a proveedores y que tanto tiempo nos estamos financiando por medios de estos.

### **Indicadores de Administración de Pasivos**

- $X_6 =$  Total Pasivos/ Total Activos

Tiene como finalidad determinar la participación de los acreedores en la compañía como medida de riesgo de esta misma.

- $X_7 =$  Ingresos No Operacionales/ Total Pasivos

Su propósito consiste en determinar el aporte de actividades no operacionales al cumplimiento de las obligaciones con acreedores.

- $X_8 =$  Total Pasivos/ EBITDA

Tiene como objetivo determinar en cuantos años la operación antes de intereses, impuestos, depreciación y amortizaciones se tardaría en cubrir el pasivo de la compañía.

- $X_9 =$  Pasivo Corriente/ Total Pasivos

Su finalidad es determinar la concentración del total del pasivo en el corto plazo.

### **Indicadores de Rentabilidad**

- $X_{10} =$  Costo de Ventas/ Ventas

Permite determinar si existe una adecuada gestión de los costos y comparar el mismo indicador frente al sector con el fin de tomar correctivos.

- $X_{11} =$  Utilidad Neta/ Patrimonio

El denominado ROE permite medir el rendimiento del capital

- $X_{12}$ = Gastos No Operacionales/ Ventas

Permite definir el peso de los gastos ajenos a la operación dentro de las ventas de la misma.

- $X_{13}$ = EBITDA/ Ventas

El margen EBITDA es un indicador que permite conocer la salud de la compañía en términos operacionales, es decir que tan adecuada es la gestión del costo y el gasto dejando de lado el sesgo de los rubros no monetarios como la depreciación y las amortizaciones y el efecto de la estructura de capital.

### **4.3. Selección Modelo**

Entre los métodos estadísticos de mayor relevancia para estructurar modelos de Credit Scoring tenemos el modelo de probabilidad lineal, modelo probit, modelo logit y el modelo del análisis discriminante, siendo estos dos últimos los más aceptados (Altman & Saunders, 1997).

Para desarrollar el modelo estadístico de Credit Scoring cuyo objetivo es medir el riesgo de crédito de las IPS, mediante la predicción de la probabilidad de impago, se empleará un modelo logit, el cual es empleado para calcular la probabilidad de que un individuo haga parte o no en uno de los grupos definidos a priori, la clasificación dependerá de las variables independientes que se establezcan, las cuales son las características de cada individuo, la variable dependiente será de tipo binario tomando valores de 0 o 1 (Medina & Martí, 2013).

En el caso objeto de estudio las variables independientes son los indicadores financieros anteriormente definidos, como variables dependientes se definió (Y) el indicador financiero EBITDA/Patrimonio y el ROE, tomando el valor de 0 si la IPS es No rentable y 1 si es rentable.

La selección del modelo Logit parte de su gran conveniencia sobre otros modelos donde según Medina & Martí (2013) respecto al análisis discriminante presenta las siguientes ventajas:

1. No es necesaria una hipótesis de partida.
2. No existe restricción sobre el seguimiento de una distribución normal para sus variables.
3. No existe restricción frente a la igualdad de la matriz de covarianza y varianza.

#### **4.4. Desarrollo Modelo Logit**

Una vez estandarizada la base de datos compuesta por 3.140 observaciones provenientes de 628 empresas objeto de estudio, se procedieron a realizar las regresiones en E-Views con el fin de determinar los indicadores financieros que mejor explican si una IPS es apta o no para recibir crédito. Lo anterior bajo la elección del método ML-Binary Logit.

Dentro del modelo se empleó la siguiente convención para las variables independientes:

**X<sub>1</sub>**=Activo Corriente/Pasivo Corriente : **AC\_PC**

**X<sub>2</sub>**=Activo Corriente-Pasivo Corriente : **CT**

**X<sub>3</sub>**=Capital de Trabajo/Total Activo : **CT\_TA**

**X<sub>4</sub>**= Periodo Promedio de Cobro : **PPC**

**X<sub>5</sub>**= Periodo Promedio de Pago : **PPP**

**X<sub>6</sub>**= Total Pasivo/ Total Activo : **TP\_TA**

**X<sub>7</sub>**= Ingresos No Operacionales/ Total Pasivo : **ING\_NO\_TP**

**X<sub>8</sub>**= Total Pasivo/ EBITDA : **TP\_EBITDA**

**X<sub>9</sub>**= Pasivo Corriente/ Total Pasivo : **PC\_TP**

**X<sub>10</sub>**= Costo de Ventas/ Ventas : **CV\_VT**

**X<sub>11</sub>**= Utilidad Neta/ Patrimonio : **UN\_PAT**

**X<sub>12</sub>**= Gastos No Operacionales/ Ventas : **GT\_NO\_VT**

**X<sub>13</sub>**= EBITDA/ Ventas : **EBITDA\_VT**

Se procedió a correr 5 modelos con las siguientes variables:

### **Modelo No 1**

$$Y_1 = \text{EBITDA/PATRIMONIO}$$

$$Y_1 = \beta_1 * \text{AC\_PC} + \beta_2 * \text{CT} + \beta_3 * \text{CT\_TA} + \beta_4 * \text{PPC} + \beta_5 * \text{PPP} + \beta_6 * \text{TP\_TA} + \beta_7 * \text{ING\_NO\_TP} + \beta_8 * \text{TP\_EBITDA} + \beta_9 * \text{PC\_TP} + \beta_{10} * \text{CV\_VT} + \beta_{11} * \text{UN\_PAT} + \beta_{12} * \text{GT\_NO\_VT} + \beta_{13} * \text{EBITDA\_VT} + \alpha$$

**Modelo No 2:** excluye la variable  $X_{13}$ = EBITDA/ Ventas.

$$Y_2 = \text{EBITDA/PATRIMONIO}$$

$$Y_2 = \beta_1 * \text{AC\_PC} + \beta_2 * \text{CT} + \beta_3 * \text{CT\_TA} + \beta_4 * \text{PPC} + \beta_5 * \text{PPP} + \beta_6 * \text{TP\_TA} + \beta_7 * \text{ING\_NO\_TP} + \beta_8 * \text{TP\_EBITDA} + \beta_9 * \text{PC\_TP} + \beta_{10} * \text{CV\_VT} + \beta_{11} * \text{UN\_PAT} + \beta_{12} * \text{GT\_NO\_VT} + \alpha$$

**Modelo No 3:** es elegido el ROE como variable dependiente y se mantienen las demás variables independientes de la **Ecuación No 1**.

$$Y_3 = \text{ROE}$$

$$Y_3 = \beta_1 * \text{AC\_PC} + \beta_2 * \text{CT} + \beta_3 * \text{CT\_TA} + \beta_4 * \text{PPC} + \beta_5 * \text{PPP} + \beta_6 * \text{TP\_TA} + \beta_7 * \text{ING\_NO\_TP} + \beta_8 * \text{TP\_EBITDA} + \beta_9 * \text{PC\_TP} + \beta_{10} * \text{CV\_VT} + \beta_{11} * \text{GT\_NO\_VT} + \beta_{12} * \text{EBITDA\_VT} + \alpha$$

**Modelo No 4:** se mantienen las variables de la **Ecuación No 3** excluyendo  $X_7$ = Ingresos No Operacionales/ Total Pasivo.

$$Y_4 = \text{ROE}$$

$$Y_4 = \beta_1 * AC\_PC + \beta_2 * CT + \beta_3 * CT\_TA + \beta_4 * PPC + \beta_5 * PPP + \beta_6 * TP\_TA + \beta_7 * TP\_EBITDA + \beta_8 * PC\_TP + \beta_9 * CV\_VT + \beta_{10} * GT\_NO\_VT + \beta_{11} * EBITDA\_VT + \alpha$$

**Modelo No 5:** se mantienen las variables de la **Ecuación No 4** excluyendo **X<sub>13</sub>**= EBITDA/ Ventas.

$$Y_5 = ROE$$

$$Y_5 = \beta_1 * AC\_PC + \beta_2 * CT + \beta_3 * CT\_TA + \beta_4 * PPC + \beta_5 * PPP + \beta_6 * TP\_TA + \beta_7 * TP\_EBITDA + \beta_8 * PC\_TP + \beta_9 * CV\_VT + \beta_{10} * GT\_NO\_VT + \beta_{11} * EBITDA\_VT + \alpha$$

#### 4.5. Análisis Resultados

A partir de las 5 regresiones obtuvimos los siguientes resultados:

Tabla 4 Resultados regresión Modelo No 1

Dependent Variable: Rentable/No Rentable

Method: ML - Binary Logit (Newton-Raphson / Marquardt steps)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
AC_PC	-0.160451	0.502018	-0.319613	0.7493
CT	-0.128564	0.151857	-0.846616	0.3972
CT_TA	0.224244	0.148159	1.513536	0.1301
PPC	0.018722	0.141102	0.132681	0.8944
PPP	0.160447	0.178125	0.900753	0.3677
TP_TA	0.017859	0.134366	0.132913	0.8943
ING_NO_TP	-0.010975	1.492862	-0.007351	0.9941
TP_EBITDA	0.039062	0.045835	0.852234	0.3941
PC_TP	-0.220678	0.101539	-2.173335	<b>0.0298</b>
CV_VT	-0.027380	0.110399	-0.248006	0.8041
UN_PAT	0.155976	0.065419	2.384247	<b>0.0171</b>
GT_NO_VT	-0.063883	0.115745	-0.551933	0.5810
EBITDA_VT	9.145621	0.377315	24.23866	<b>0.0000</b>
C	4.739822	0.201870	23.47952	0.0000
McFadden R-squared	<b>0.776263</b>			
Prob(LR statistic)	<b>0.000000</b>			
Obs with Dep=0	812	Total obs		3140
Obs with Dep=1	2328			

Se realiza una primera regresión con 13 variables identificando como significativas en la determinación de si una empresa es rentable o no y por ende apta o no para otorgarle crédito las siguientes variables:

$X_9$ = Pasivo Corriente/ Total Pasivo: **PC\_TP**

$X_{11}$ = Utilidad Neta/ Patrimonio: **UN\_PAT**

$X_{13}$ = EBITDA/ Ventas: **EBITDA\_VT**

En esta primera aproximación se obtiene un R-squared de 77.62%, es decir el modelo tiene un alto poder explicativo sobre la variable dependiente, no obstante el resultado anterior se ve influenciado en parte al excesivo número de variables empleado en la regresión y al indicador EBITDA/ Ventas cuyo coeficiente tiene un peso muy superior al de los demás indicadores empleados en el análisis arrojando un valor de 9.14. Lo anterior se debe a que la variable dependiente fue definida como EBITDA/Patrimonio existiendo evidentemente una alta correlación.

Obtuvimos un Prob(LR statistic) de 0 lo cual indica que los coeficientes de las variables independientes son diferentes a 1 y por tanto tienen poder explicativo.

*Tabla 5 Resultados predicción Modelo No 1*

Expectation-Prediction Evaluation for Binary Specification

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)≤C	785	14	799	0	0	0
P(Dep=1)>C	27	2314	2341	812	2328	3140
Total	812	2328	3140	812	2328	3140
Correct	785	2314	3099	0	2328	2328
% Correct	96.67	99.40	98.69	0.00	100.00	74.14
% Incorrect	3.33	0.60	1.31	100.00	0.00	25.86
Total Gain*	96.67	-0.60	24.55			
Percent Gain**	96.67	NA	94.95			

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	719.42	95.82	815.23	209.98	602.02	812.00
E(# of Dep=1)	92.58	2232.18	2324.77	602.02	1725.98	2328.00
Total	812.00	2328.00	3140.00	812.00	2328.00	3140.00
Correct	719.42	2232.18	2951.60	209.98	1725.98	1935.96
% Correct	88.60	95.88	94.00	25.86	74.14	61.65
% Incorrect	11.40	4.12	6.00	74.14	25.86	38.35

Total Gain*	62.74	21.74	32.35
Percent Gain**	84.62	84.08	84.35

En los resultados arrojados podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fueron respectivamente el 96.67% y 99.40% de los casos, adicionalmente el modelo esperado es un 96.67% más acertado que otro elegido al azar.

En la predicción del modelo la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue respectivamente el 88.60% y 95.88% de los casos, adicionalmente el modelo predictivo es un 84.62% más acertado que otro elegido al azar.

Tabla 6 Resultados regresión Modelo No 2

Dependent Variable: Rentable/No Rentable  
Method: ML - Binary Logit (Newton-Raphson / Marquardt steps)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
AC_PC	-0.144675	0.253657	-0.570355	0.5684
CT	0.806151	0.162058	4.974453	0.0000
CT_TA	0.427939	0.082117	5.211357	0.0000
PPC	0.066491	0.072130	0.921820	0.3566
PPP	-0.227875	0.076706	-2.970766	0.0030
TP_TA	0.069064	0.073189	0.943641	0.3454
ING_NO_TP	-37.17402	12.37355	-3.004314	0.0027
TP_EBITDA	0.066556	0.047742	1.394096	0.1633
PC_TP	-0.174634	0.054902	-3.180810	0.0015
CV_VT	-1.178720	0.061112	-19.28779	0.0000
UN_PAT	0.062458	0.070653	0.884016	0.3767
GT_NO_VT	0.238431	0.056624	4.210799	0.0000
C	0.770881	0.230199	3.348764	0.0008
McFadden R-squared	0.224198			
Prob(LR statistic)	0.000000			
Obs with Dep=0	812	Total obs	3140	
Obs with Dep=1	2328			

Se realiza una segunda regresión con 12 variables excluyendo  $X_{13}$ = EBITDA/ Ventas y se determinan como significativas al 10% las siguientes variables:

$X_2$ =Activo Corriente-Pasivo Corriente: **CT**

$X_3$ =Capital de Trabajo/Total Activo: **CT\_TA**

**X<sub>5</sub>**= Período Promedio de Pago: **PPP**

**X<sub>7</sub>**= Ingresos No Operacionales/ Total Pasivo: **ING\_NO\_TP**

**X<sub>9</sub>**= Pasivo Corriente/ Total Pasivo: **PC\_TP**

**X<sub>10</sub>**= Costo de Ventas/ Ventas: **CV\_VT**

**X<sub>12</sub>**= Gastos No Operacionales/ Ventas: **GT\_NO\_VT**

A pesar de ser significativas un número superior de variables respecto al modelo No 1, el poder explicativo sobre la variable dependiente es muy inferior arrojando un R-squared de 22.41%, siendo la variable con mayor poder explicativo Ingresos No Operacionales/ Total Pasivo con un coeficiente negativo de 37.17. Basado en las 2 regresiones puede concluirse que el indicador EBITDA/Ventas es el que está aportando mayor poder explicativo al modelo con lo cual debemos proponer nuevos modelos que nos permitan detectar otras variables independientes con alto poder explicativo.

Obtuvimos un Prob(LR statistic) de 0 lo cual indica que los coeficientes de las variables independientes son diferentes a 1 y por tanto tienen poder explicativo.

*Tabla 7 Resultados predicción Modelo No 2*

Expectation-Prediction Evaluation for Binary Specification

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)<=C	357	130	487	0	0	0
P(Dep=1)>C	455	2198	2653	812	2328	3140
Total	812	2328	3140	812	2328	3140
Correct	357	2198	2555	0	2328	2328
% Correct	43.97	94.42	81.37	0.00	100.00	74.14
% Incorrect	56.03	5.58	18.63	100.00	0.00	25.86
Total Gain*	43.97	-5.58	7.23			
Percent Gain**	43.97	NA	27.96			

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	368.87	443.13	812.00	209.98	602.02	812.00
E(# of Dep=1)	443.13	1884.87	2328.00	602.02	1725.98	2328.00
Total	812.00	2328.00	3140.00	812.00	2328.00	3140.00
Correct	368.87	1884.87	2253.74	209.98	1725.98	1935.96
% Correct	45.43	80.97	71.78	25.86	74.14	61.65
% Incorrect	54.57	19.03	28.22	74.14	25.86	38.35
Total Gain*	19.57	6.83	10.12			
Percent Gain**	26.39	26.39	26.39			

En los resultados arrojados podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 43.97% y 94.42% de los casos, adicionalmente el modelo esperado es un 43.97% más acertado que otro elegido al azar.

En la predicción del modelo podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 45.43% y 80.97% de los casos, adicionalmente el modelo predictivo es un 26.39% más acertado que otro elegido al azar.

Tabla 8 Resultados regresión Modelo No 3

Dependent Variable: Rentable/No Rentable  
Method: ML - Binary Logit (Newton-Raphson / Marquardt steps)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
AC_PC	0.115618	0.465562	0.248342	0.8039
CT	0.081407	0.088254	0.922416	0.3563
CT_TA	0.261098	0.082935	3.148207	0.0016
PPC	0.171101	0.074333	2.301812	0.0213
PPP	-0.054481	0.078884	-0.690649	0.4898
TP_TA	-0.128163	0.074556	-1.719024	0.0856
ING_NO_TP	293.5010	63.22590	4.642101	0.0000
TP_EBITDA	0.100374	0.050083	2.004158	0.0451
PC_TP	0.015728	0.051179	0.307326	0.7586
CV_VT	-0.136929	0.061475	-2.227381	0.0259
GT_NO_VT	-0.704654	0.054703	-12.88141	0.0000
EBITDA_VT	1.265949	0.076571	16.53302	0.0000
C	6.735985	1.166761	5.773236	0.0000
McFadden R-squared	0.244521			
Prob(LR statistic)	0.000000			
Obs with Dep=0	820	Total obs	3140	
Obs with Dep=1	2320			

Se identifican como significativas en la determinación de si una empresa es rentable o no y por ende apta o no para otorgarle crédito las siguientes variables:

**X<sub>3</sub>**=Capital de Trabajo/Total Activo : **CT\_TA**

**X<sub>4</sub>**= Periodo Promedio de Cobro : **PPC**

$X_6 = \text{Total Pasivo} / \text{Total Activo} : \text{TP\_TA}$

$X_7 = \text{Ingresos No Operacionales} / \text{Total Pasivo} : \text{ING\_NO\_TP}$

$X_8 = \text{Total Pasivo} / \text{EBITDA} : \text{TP\_EBITDA}$

$X_{10} = \text{Costo de Ventas} / \text{Ventas} : \text{CV\_VT}$

$X_{12} = \text{Gastos No Operacionales} / \text{Ventas} : \text{GT\_NO\_VT}$

$X_{13} = \text{EBITDA} / \text{Ventas} : \text{EBITDA\_VT}$

En este nuevo modelo cambiamos la variable dependiente empleada en los modelos 1 y 2 por el ROE, el poder explicativo sobre la variable dependiente es muy inferior al modelo No 1 arrojando un R-squared de 24.45%, no obstante supera al arrojado por el modelo No 2 (22.42%), siendo la variable con mayor poder explicativo Ingresos No Operacionales/ Total Pasivo con un coeficiente positivo de 293.

Obtuvimos un Prob(LR statistic) de 0 lo cual indica que los coeficientes de las variables independientes son diferentes a 1 y por tanto tienen poder explicativo.

*Tabla 9 Resultados predicción Modelo No 3*

Expectation-Prediction Evaluation for Binary Specification

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)≤C	333	152	485	0	0	0
P(Dep=1)>C	487	2168	2655	820	2320	3140
Total	820	2320	3140	820	2320	3140
Correct	333	2168	2501	0	2320	2320
% Correct	40.61	93.45	79.65	0.00	100.00	73.89
% Incorrect	59.39	6.55	20.35	100.00	0.00	26.11
Total Gain*	40.61	-6.55	5.76			
Percent Gain**	40.61	NA	22.07			

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	383.64	436.36	820.00	214.14	605.86	820.00
E(# of Dep=1)	436.36	1883.64	2320.00	605.86	1714.14	2320.00
Total	820.00	2320.00	3140.00	820.00	2320.00	3140.00
Correct	383.64	1883.64	2267.28	214.14	1714.14	1928.28
% Correct	46.79	81.19	72.21	26.11	73.89	61.41
% Incorrect	53.21	18.81	27.79	73.89	26.11	38.59
Total Gain*	20.67	7.31	10.80			
Percent Gain**	27.98	27.98	27.98			

En los resultados arrojados podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 40.61% y 93.45% de los casos, adicionalmente el modelo esperado es un 40.61% más acertado que otro elegido al azar.

En la predicción del modelo podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 46.79% y 81.19% de los casos, adicionalmente el modelo predictivo es un 27.98% más acertado que otro elegido al azar.

Tabla 10 Resultados regresión Modelo No 4

Dependent Variable: Rentable/No Rentable  
Method: ML - Binary Logit (Newton-Raphson / Marquardt steps)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
AC_PC	13.49429	13.69182	0.985573	0.3243
CT	0.066458	0.084335	0.788027	0.4307
CT_TA	0.337475	0.082046	4.113218	0.0000
PPC	0.112650	0.073119	1.540633	0.1234
PPP	-0.040299	0.078684	-0.512160	0.6085
TP_TA	-0.185728	0.073822	-2.515895	0.0119
TP_EBITDA	0.128350	0.049392	2.598615	0.0094
PC_TP	0.029376	0.050676	0.579679	0.5621
CV_VT	-0.135656	0.061086	-2.220733	0.0264
GT_NO_VT	-0.623437	0.051428	-12.12246	0.0000
EBITDA_VT	1.130360	0.071550	15.79810	0.0000
C	1.688590	0.351582	4.802828	0.0000
McFadden R-squared	0.229767			
Prob(LR statistic)	0.000000			
Obs with Dep=0	820	Total obs		3140
Obs with Dep=1	2320			

Se identifican como significativas en la determinación de si una empresa es rentable o no y por ende apta o no para otorgarle crédito las siguientes variables:

**X<sub>3</sub>**=Capital de Trabajo/Total Activo : **CT\_TA**

**X<sub>6</sub>**= Total Pasivo/ Total Activo : **TP\_TA**

**X<sub>8</sub>**= Total Pasivo/ EBITDA : **TP\_EBITDA**

$X_{10}$ = Costo de Ventas/ Ventas : **CV\_VT**

$X_{12}$ = Gastos No Operacionales/ Ventas : **GT\_NO\_VT**

$X_{13}$ = EBITDA/ Ventas : **EBITDA\_VT**

En este nuevo modelo se mantienen las variables del modelo No 3 excluyendo  $X_7$ = Ingresos No Operacionales/ Total Pasivo. La razón principal por la cual se realizó este cambio fue el alto valor del coeficiente de este factor en el modelo anterior el cual fue de 293. El poder explicativo sobre la variable dependiente al realizar este cambio disminuye ligeramente sobre el modelo No 3 arrojando un R-squared de 22.98%, siendo la variable con mayor poder explicativo  $X_{13}$ = EBITDA/ Ventas con un coeficiente positivo de 1.13.

Obtuvimos un Prob(LR statistic) de 0 lo cual indica que los coeficientes de las variables independientes son diferentes a 1 y por tanto tienen poder explicativo.

Tabla 11 Resultados predicción Modelo No 4

Expectation-Prediction Evaluation for Binary Specification

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)≤C	313	155	468	0	0	0
P(Dep=1)>C	507	2165	2672	820	2320	3140
Total	820	2320	3140	820	2320	3140
Correct	313	2165	2478	0	2320	2320
% Correct	38.17	93.32	78.92	0.00	100.00	73.89
% Incorrect	61.83	6.68	21.08	100.00	0.00	26.11
Total Gain*	38.17	-6.68	5.03			
Percent Gain**	38.17	NA	19.27			

  

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	372.30	447.70	820.00	214.14	605.86	820.00
E(# of Dep=1)	447.70	1872.30	2320.00	605.86	1714.14	2320.00
Total	820.00	2320.00	3140.00	820.00	2320.00	3140.00
Correct	372.30	1872.30	2244.59	214.14	1714.14	1928.28
% Correct	45.40	80.70	71.48	26.11	73.89	61.41
% Incorrect	54.60	19.30	28.52	73.89	26.11	38.59
Total Gain*	19.29	6.82	10.07			
Percent Gain**	26.10	26.10	26.10			

En los resultados arrojados podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 38.17% y 93.32% de los casos, adicionalmente el modelo esperado es un 38.17% más acertado que otro elegido al azar.

En la predicción del modelo podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 45.40% y 80.70% de los casos, adicionalmente el modelo predictivo es un 26.10% más acertado que otro elegido al azar.

Tabla 12 Resultados regresión Modelo No 5

Dependent Variable: Y2

Method: ML - Binary Logit (Newton-Raphson / Marquardt steps)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
AC_PC	8.922548	11.63886	0.766617	0.4433
CT	0.245467	0.093487	2.625675	0.0086
CT_TA	0.487309	0.079326	6.143137	0.0000
PPC	0.103134	0.069258	1.489134	0.1365
PPP	-0.160916	0.073122	-2.200668	0.0278
TP_TA	-0.118837	0.068533	-1.734011	0.0829
TP_EBITDA	0.136335	0.052952	2.574677	0.0100
PC_TP	-0.016318	0.048077	-0.339409	0.7343
CV_VT	-0.685917	0.052362	-13.09952	0.0000
GT_NO_VT	-0.385002	0.044417	-8.667906	0.0000
C	1.468360	0.299219	4.907317	0.0000
McFadden R-squared				
	0.147673			
Prob(LR statistic)				
	0.000000			
Obs with Dep=0	820	Total obs	3140	
Obs with Dep=1	2320			

Se identifican como significativas en la determinación de si una empresa es rentable o no y por ende apta o no para otorgarle crédito las siguientes variables:

**X<sub>2</sub>**=Activo Corriente-Pasivo Corriente : **CT**

**X<sub>3</sub>**=Capital de Trabajo/Total Activo : **CT\_TA**

**X<sub>5</sub>**= Periodo Promedio de Pago : **PPP**

**X<sub>6</sub>**= Total Pasivo/ Total Activo : **TP\_TA**

**X<sub>8</sub>**= Total Pasivo/ EBITDA : **TP\_EBITDA**

**X<sub>10</sub>**= Costo de Ventas/ Ventas : **CV\_VT**

**X<sub>12</sub>**= Gastos No Operacionales/ Ventas : **GT\_NO\_VT**

En este último modelo se mantienen las variables del modelo No 4 excluyendo **X<sub>13</sub>**= EBITDA/ Ventas. La razón principal por la cual se realizó este cambio se debe a que ha sido en los 4 modelos uno de los factores con mayor poder explicativo y por tanto se desea ver su impacto sobre el R-squared , el cual efectivamente paso de 22.98% a tan solo un 14.77%, siendo la variable con mayor poder explicativo **X<sub>10</sub>**= Costo de Ventas/ Ventas con un coeficiente negativo de 0.69.

Obtuvimos un Prob(LR statistic) de 0 lo cual indica que los coeficientes de las variables independientes son diferentes a 1 y por tanto tienen poder explicativo.

*Tabla 13 Resultados predicción Modelo No 5*

Expectation-Prediction Evaluation for Binary Specification

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)<=C	241	125	366	0	0	0
P(Dep=1)>C	579	2195	2774	820	2320	3140
Total	820	2320	3140	820	2320	3140
Correct	241	2195	2436	0	2320	2320
% Correct	29.39	94.61	77.58	0.00	100.00	73.89
% Incorrect	70.61	5.39	22.42	100.00	0.00	26.11
Total Gain*	29.39	-5.39	3.69			
Percent Gain**	29.39	NA	14.15			

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	319.45	500.55	820.00	214.14	605.86	820.00
E(# of Dep=1)	500.55	1819.45	2320.00	605.86	1714.14	2320.00
Total	820.00	2320.00	3140.00	820.00	2320.00	3140.00
Correct	319.45	1819.45	2138.90	214.14	1714.14	1928.28
% Correct	38.96	78.42	68.12	26.11	73.89	61.41
% Incorrect	61.04	21.58	31.88	73.89	26.11	38.59
Total Gain*	12.84	4.54	6.71			
Percent Gain**	17.38	17.38	17.38			

En los resultados arrojados podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente

el 29.39% y 94.61% de los casos, adicionalmente el modelo esperado es un 29.39% más acertado que otro elegido al azar.

En la predicción del modelo podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 38.96% y 78.42% de los casos, adicionalmente el modelo predictivo es un 17.38% más acertado que otro elegido al azar.

#### 4.6. Resumen resultados

Tabla 14 Resumen Resultados Regresiones

Yi	eq01		eq02		eq03		eq04		eq05	
	EBITDA/PAT				ROE					
	Coef	Valor P								
X <sub>1</sub> =AC_PC	-0.16	74.9%	-0.14	56.8%	0.12	80.4%	13.49	32.4%	8.92	44.3%
X <sub>2</sub> = CT	-0.13	39.7%	0.81	0.0%	0.08	35.6%	0.07	43.1%	0.25	0.9%
X <sub>3</sub> =CT_TA	0.22	13.0%	0.43	0.0%	0.26	0.2%	0.34	0.0%	0.49	0.0%
X <sub>4</sub> = PPC	0.02	89.4%	0.07	35.7%	0.17	2.1%	0.11	12.3%	0.10	13.7%
X <sub>5</sub> = PPP	0.16	36.8%	-0.23	0.3%	-0.05	49.0%	-0.04	60.9%	-0.16	2.8%
X <sub>6</sub> = TP_TA	0.02	89.4%	0.07	34.5%	-0.13	8.6%	-0.19	1.2%	-0.12	8.3%
X <sub>7</sub> = ING_NO_TP	-0.01	99.4%	<b>-37.17</b>	0.3%	<b>293.50</b>	0.0%				
X <sub>8</sub> = TP_EBITDA	0.04	39.4%	0.07	16.3%	0.10	4.5%	0.13	0.9%	0.14	1.0%
X <sub>9</sub> =PC_TP	-0.22	3.0%	-0.17	0.2%	0.02	75.9%	0.03	56.2%	-0.02	73.4%
X <sub>10</sub> = CV_VT	-0.03	80.4%	-1.18	0.0%	-0.14	2.6%	-0.14	2.6%	<b>-0.69</b>	0.0%
X <sub>11</sub> = UN_PAT	0.16	1.7%	0.06	37.7%						
X <sub>12</sub> = GT_NO_VT	-0.06	58.1%	0.24	0.0%	-0.70	0.0%	-0.62	0.0%	-0.39	0.0%
X <sub>13</sub> = EBITDA_VT	<b>9.15</b>	0.0%			1.27	0.0%	<b>1.13</b>	0.0%		
C	4.74	0.0%	0.77	0.1%	6.74	0.0%	1.69	0.0%	1.47	0.0%
R-squared	<b>77.63%</b>		<b>22.42%</b>		<b>24.45%</b>		<b>22.98%</b>		<b>14.77%</b>	
Prob(LR statistic)	<b>0.0%</b>									

Basados en los resultados de los 5 modelos resumidos en la Tabla 14 procedemos a elegir el modelo No 4 para validar el % de predicción correcto en la clasificación de si una empresa es o no rentable y por tanto apta para recibir crédito. Este modelo fue elegido en vista que su R-squared 22.98% es superior al del modelo No 5 y es aproximado al obtenido en los modelos 2 y 3, con la ventaja

que nos permitió obtener 5 variables independientes significativas sin que la magnitud de uno de los coeficientes fuera muy superior al de los otros factores como sucede en los 3 primeros modelos donde los coeficientes de  $X_{13}$ = EBITDA/ Ventas y  $X_7$ = Ingresos No Operacionales/ Total Pasivo , superan en gran magnitud a los de las demás variables significativas.

Tabla 15 Resumen Resultados Predicción

	% Correcto Esperado			% Correcto Predicción		
	No Rentable	Rentable	Percent Gain	No Rentable	Rentable	Percent Gain
eq01	96.67	99.4	96.67	88.6	95.88	84.62
eq02	43.97	94.42	43.97	45.43	80.97	26.39
eq03	40.61	93.45	40.61	46.79	81.19	27.98
eq04	38.17	93.32	38.17	45.4	80.7	26.1
eq05	29.39	94.61	29.39	38.96	78.42	17.38

En la predicción del modelo No 4 podemos ver que la probabilidad de acierto para la variable dependiente No rentable (0) y rentable (1) fue el correcto respectivamente el 45.40% y 80.70% de los casos, adicionalmente el modelo predictivo es un 26.10% más acertado que otro elegido al azar.

Tabla 16 Resumen Resultados Predicción modelo No 4

	Total	Correcto	Incorrecto
<b>No observaciones No rentable</b>	820	345	475
<b>% de predicción</b>		42.1%	57.9%
<b>No observaciones rentable</b>	2,320	2,141	179
<b>% de predicción</b>		92.3%	7.7%

Del total de 3.140 observaciones obtenidas en el ejercicio de 5 años por parte de las 628 IPS's analizadas, obtuvimos que los porcentajes de predicción de si una IPS es o no rentable y por tanto apta para recibir crédito obtenidos en la tabla No 16, se aproximan a los obtenidos en la tabla No 15, resultado generado por E-Views.

Para el cálculo del porcentaje de predicción correcto de la Tabla 16 para empresas no rentables y rentables calculamos la predicción del modelo No 4 para cada una de las 3.140 observaciones mediante la siguiente ecuación:

$$Y_4 = 0.337475 * CT\_TA - 0.185728 * TP\_TA + 0.128350 * TP\_EBITDA - 0.135656 * CV\_VT - 0.623437 * GT\_NO\_VT + 1.130360 * EBITDA\_VT + 1.688590$$

Se procedió a comparar el valor obtenido para cada observación con el punto de corte de 0.5, definiendo como no rentables las observaciones por debajo de este valor y rentables aquellas superiores al 0.5. Posteriormente se calcularon el número de aciertos del modelo en su clasificación frente al criterio empleado del ROE en la clasificación de una empresa como No rentable (0) y rentable (1). Del anterior análisis se obtuvo que el porcentaje de predicción correcto para empresas no rentables y rentables fue respectivamente del 42.1% y 92.3%.

Basados en el ejercicio anterior se tomó como muestra el año 2017 y se validó aquellas empresas que bajo el criterio del ROE daban no rentable para ese año y que a sí mismo al aplicar la ecuación del modelo No 4 el valor daba por debajo de 0.5 es decir no rentable, "Y4 = 0.337475 \* CT\_TA - 0.185728 \* TP\_TA + 0.128350 \* TP\_EBITDA - 0.135656 \* CV\_VT - 0.623437 \* GT\_NO\_VT + 1.130360 \* EBITDA\_VT + 1.688590".

De este ejercicio según Tabla No 17 para el año 2017 coincidieron 67 empresas como no rentables bajo el criterio del ROE y bajo el criterio de la ecuación, las cuales fueron definidas como no aptas para recibir crédito.

Tabla 17 Porcentaje de aciertos

ROE	No Aciertos	% Correcto
<b>0</b>	<b>172</b>	
no	105	
si	67	39%
<b>1</b>	<b>456</b>	
no	40	
si	416	91%
<b>Total general</b>	<b>628</b>	

Tabla 18 67 IPS's no aptas para recibir crédito

HOSPITAL JOSÉ CAYETANO VÁSQUEZ - PUERTO BOYACÁ	E.S.E. HOSPITAL LOCAL PEDRO SÁENZ DÍAZ - ULLOA
E.S.E. HOSPITAL SAN PEDRO DEL PIÑÓN	E.S.E. HOSPITAL SAN JUAN
E.S.E. HOSPITAL SAN JUAN DE DIOS - PEÑOL	E.S.E. HOSPITAL LOCAL PRIMER NIVEL - FUENTEDEORO
E.S.E. CENTRO DE SALUD - CUCUNUBÁ	E.S.E. HOSPITAL SAN JUAN DE DIOS – ITUANGO
E.S.E. HOSPITAL SAN RAFAEL - VENECIA	E.S.E. HOSPITAL MARCO FIDEL SUÁREZ – BELLO
E.S.E. CENTRO DE SALUD DE SUESCA	E.S.E. HOSPITAL SAN JUAN DE DIOS - PUERTO CARREÑO
E.S.E. HOSPITAL SAN JOSÉ DE MARSELLA	E.S.E. HOSPITAL MENTAL DE ANTIOQUIA – HOMO
E.S.E. CENTRO DE SALUD SAN BERNARDO	E.S.E. HOSPITAL SAN JUAN DE DIOS – VALPARAISO
E.S.E. HOSPITAL SAN JUAN DE DIOS DE BETULIA	E.S.E. HOSPITAL NIÑO JESÚS – BARRANQUILLA
E.S.E. CENTRO DERMATOLÓGICO FEDERICO LLERAS ACOSTA	E.S.E. HOSPITAL SAN JULIÁN – ARGELIA
E.S.E. HOSPITAL SAN RAFAEL - EL ÁGUILA	E.S.E. HOSPITAL NUESTRA SEÑORA DE LA CANDELARIA - GUARNE
E.S.E. CENTRO HOSPITAL DIVINO NIÑO - TUMACO	E.S.E. HOSPITAL SAN MARTÍN – ARMENIA
E.S.E. INSTITUTO DEPARTAMENTAL DE REHABILITACIÓN Y EDUCACIÓN ESPECIAL DEL CESAR	E.S.E. HOSPITAL NUESTRA SEÑORA DEL CARMEN
E.S.E. FABIO JARAMILLO LONDOÑO	E.S.E. HOSPITAL SAN RAFAEL – ANDES
E.S.E. CENTRO DE SALUD - BETÉITIVA	E.S.E. HOSPITAL NUESTRA SEÑORA DEL ROSARIO - BELMIRA
E.S.E. HOSPITAL ANTONIO ROLDAN LA PINTADA	E.S.E. HOSPITAL SAN RAFAEL – EBÉJICO
E.S.E. HOSPITAL SAN JUAN DE DIOS - CARMEN DE VIBORAL	E.S.E. HOSPITAL PEDRO NEL CARDONA - ARBOLETES
E.S.E. HOSPITAL DEPARTAMENTAL JUAN DOMÍNGUEZ ROMERO DE SOLEDAD	E.S.E. HOSPITAL SAN RAFAEL – GIRARDOTA
E.S.E. HOSPITAL SAN JUAN DE DIOS - VALDIVIA	E.S.E. HOSPITAL RAFAEL PABA MANJARREZ - SAN SEBASTIÁN
E.S.E. HOSPITAL DONALDO SAÚL MORÓN MANJARREZ - JAGUA DEL PILAR	E.S.E. HOSPITAL SAN RAFAEL – ITAGÜÍ
E.S.E. HOSPITAL SAN LUIS BELTRÁN - SAN JERÓNIMO	E.S.E. HOSPITAL REGIONAL DEL MAGDALENA MEDIO
E.S.E. HOSPITAL GABRIEL PELÁEZ M. - JARDÍN	E.S.E. HOSPITAL SAN VICENTE DE PAUL – BARBOSA
E.S.E. HOSPITAL SAN RAFAEL - ANGOSTURA	E.S.E. HOSPITAL SAN ANTONIO – AMBALEMA
E.S.E. HOSPITAL ISABEL LA CATÓLICA - CÁCERES	E.S.E. HOSPITAL UNIVERSITARIO DEL VALLE EVARISTO GARCÍA
E.S.E. HOSPITAL SAN RAFAEL - HELICONIA	E.S.E. HOSPITAL SAN ANTONIO – CARAMANTA
E.S.E. HOSPITAL JOSÉ MARÍA CÓRDOBA - CONCEPCIÓN	E.S.E. MANUEL CASTRO TOVAR – PITALITO
E.S.E. HOSPITAL SAN VICENTE DE PAUL - SAN CARLOS	E.S.E. HOSPITAL SAN ANTONIO – CISNEROS
E.S.E. HOSPITAL LA MISERICORDIA - YALÍ	HOSPITAL ALEJANDRO MAESTRE - EL DIFÍCIL (ARIGUANI)
EMPRESA MUNICIPAL PARA LA SALUD	E.S.E. HOSPITAL SAN FERNANDO – AMAGÁ
E.S.E. HOSPITAL LA UNIÓN - SUCRE	HOSPITAL NUESTRA SEÑORA SANTA ANA
HOSPITAL SAN JOSÉ - SAN ANDRÉS	E.S.E. HOSPITAL SAN FRANCISCO – IBAGUÉ
E.S.E. HOSPITAL LOCAL DEL RÍO DE ORO	I.P.S. CENTRO DE SALUD UCATÁ – CHARTA SANTANDER
E.S.E. HOSPITAL SAN JOSÉ - SALGAR	E.S.E. HOSPITAL SAN FRANCISCO JAVIER DEL MUNICIPIO DE ACEVEDO
	E.S.E. HOSPITAL SAN JOSÉ

Tabla 19 P&G consolidado año 2013-2018

Año	2013		2014		2015		2016		2017	
<b>Ventas</b>	<b>6,196,281</b>		<b>6,565,743</b>		<b>7,233,541</b>		<b>7,268,726</b>		<b>7,789,316</b>	
Costo Venta	4,126,919	66.6%	4,494,654	68.5%	4,921,424	68.0%	4,924,145	67.7%	5,255,780	67.5%
<b>U.Bruta</b>	<b>2,069,362</b>	<b>33.4%</b>	<b>2,071,089</b>	<b>31.5%</b>	<b>2,312,117</b>	<b>32.0%</b>	<b>2,344,580</b>	<b>32.3%</b>	<b>2,533,535</b>	<b>32.5%</b>
G.Adm	1,741,907	28.1%	1,828,193	27.8%	2,088,597	28.9%	2,207,238	30.4%	2,324,132	29.8%
G.Ventas	11,113	0.2%	6,149	0.1%	5,660	0.1%	7,619	0.1%	4,275	0.1%
<b>U.Operacional</b>	<b>316,342</b>	<b>5.1%</b>	<b>229,930</b>	<b>3.5%</b>	<b>212,174</b>	<b>2.9%</b>	<b>129,723</b>	<b>1.8%</b>	<b>205,129</b>	<b>2.6%</b>
ING NO	651,700	10.5%	712,401	10.9%	624,821	8.6%	617,611	8.5%	1,016,065	13.0%
GT NO	420,179	6.8%	399,208	6.1%	445,528	6.2%	532,348	7.3%	686,981	8.8%
<b>UA. Impuestos</b>	<b>547,863</b>	<b>8.8%</b>	<b>543,387</b>	<b>8.3%</b>	<b>388,034</b>	<b>5.4%</b>	<b>214,987</b>	<b>3.0%</b>	<b>534,212</b>	<b>6.9%</b>

Como análisis complementario se procedió a consolidar el Estado de Pérdidas y Ganancias de las 628 IPS's en los 5 años de análisis, evidenciando que la estructura de Costo de Venta se mantuvo relativamente estable con un valor promedio del 32.3% sobre los ingresos. No obstante el resultado operacional decreció durante el periodo 2013-2016 por el incremento en los Gastos de Administración y Ventas que presentaron su mayor participación en el año 2016. Así mismo cabe resaltar que en todos los años el margen operacional es muy inferior al porcentaje que representa la Utilidad Antes de Impuestos sobre los ingresos, lo anterior por el fuerte efecto positivo que tienen los Ingresos no Operacionales, los cuales presentan su mayor aumento en el año 2017 participando el 13%.

Tabla 20P&G consolidado por departamentos año 2013-2018

No	Etiquetas de fila	No IPS's	Ventas	Costo Venta	U. Bruta	G.Adm	G.Ventas	U.Operacional	ING NO	GT NO	UA. Imp
1	Valle del Cauca	32	2,566,154	1,734,731	831,423	1,011,700	5,428	-185,705	474,412	315,090	-26,384
2	Meta	11	1,032,133	777,654	254,478	310,863	860	-57,245	70,505	68,706	-55,446
3	Córdoba	8	749,728	437,206	312,522	316,624	3,480	-13,638	47,601	30,040	4,399
4	Guaviare	1	128,030	91,533	36,497	45,930	0	-9,432	21,454	10,293	1,728
5	Caquetá	3	154,947	117,327	37,620	46,415	0	-8,795	35,276	19,569	6,912
6	Putumayo	9	446,203	286,145	160,058	163,966	0	-3,908	70,583	59,388	7,287
7	Chocó	1	9,462	6,461	3,001	4,425	0	-1,425	2,378	1,077	-124
8	Vichada	1	40,089	20,807	19,282	20,647	0	-1,365	8,781	6,736	680

9	La Guajira	13	662,236	432,825	229,411	224,640	39	862	84,711	63,479	19,328
10	Arauca	2	437,889	279,797	158,092	156,470	0	1,622	45,718	28,427	18,913
11	Sucre	7	398,480	212,541	185,939	180,800	2,561	2,578	13,593	16,802	-632
12	Atlántico	13	895,710	550,924	344,786	339,554	1,925	3,307	93,625	61,415	35,517
13	Cesár	22	1,160,450	730,366	430,085	416,696	6,678	6,710	91,815	119,601	-21,076
14	Risaralda	15	520,008	357,032	162,976	132,993	0	29,983	58,436	46,137	42,282
15	Quindío	13	694,726	435,717	259,008	228,661	0	30,347	91,409	54,385	67,371
16	Bolívar	11	934,759	690,220	244,539	206,164	103	36,691	56,300	53,334	39,278
17	Casanare	4	605,726	436,558	169,168	127,276	0	41,892	30,955	56,883	15,964
18	Magdalena	21	607,064	304,528	302,535	255,807	4,573	42,155	40,387	76,425	6,118
19	Santander	57	1,181,668	759,525	422,144	367,862	746	53,535	88,312	60,220	81,627
20	Caldas	21	1,037,805	639,157	398,648	329,108	103	69,437	69,993	68,934	70,496
21	Cauca	18	1,773,154	1,168,268	604,886	529,519	42	75,325	180,687	87,170	168,842
22	Tolima	41	1,842,328	1,254,752	587,576	509,389	1,455	75,735	164,567	91,670	148,132
23	Nariño	53	1,711,703	1,118,257	593,446	510,602	3,065	79,779	103,266	88,534	94,511
24	Cundinamarca	33	1,517,250	972,690	544,560	457,694	147	86,719	147,285	76,656	157,349
25	Boyacá	61	1,126,161	735,256	390,905	287,052	611	103,241	67,026	80,678	89,589
26	Norte de Santander	14	1,510,563	996,480	514,084	380,264	425	133,395	249,634	97,334	285,694
27	Bogotá D.C	3	2,098,323	1,566,766	531,558	371,278	0	160,279	103,784	75,380	188,684
28	Antioquia	106	6,973,021	5,158,623	1,814,398	1,651,928	8	162,462	953,715	527,288	588,889
29	Huila	34	2,237,839	1,450,779	787,060	605,738	2,566	178,756	156,391	142,591	192,556
<b>Total general</b>		<b>628</b>	<b>35,053,607</b>	<b>23,722,923</b>	<b>11,330,684</b>	<b>10,190,067</b>	<b>34,815</b>	<b>1,093,298</b>	<b>3,622,598</b>	<b>2,484,244</b>	<b>2,228,483</b>

Al agrupar el Estado de Pérdidas y Ganancias del periodo 2013-2017 por departamento acorde a lo reflejado en la Tabla No 20, se aprecia que los departamentos con mayor estrés financiero dado que operativamente arrojan pérdidas son el Valle del Cauca, Meta y Córdoba, siendo el Meta el departamento con mayores pérdidas antes de impuestos. Por su parte Huila, Antioquia y Bogota, en consolidado presentan la mayor utilidad operativa siendo el mercado menos riesgoso por parte de los proveedores de IPS's para ampliar su mercado y otorgar crédito con un menor riesgo de impago.

## 5. Conclusiones

El alcance del actual proyecto de grado consistió en el desarrollo de un modelo de Credit Scoring para determinar cuáles Instituciones Prestadoras de Servicios de Salud (IPS), son o no óptimas para recibir crédito por parte de sus proveedores, permitiendo disminuir el riesgo de crédito de estos últimos. Para su desarrollo se profundizó en los dos métodos estadísticos de mayor relevancia para estructurar modelos de Credit Scoring, como el modelo de análisis discriminante y el modelo logit, eligiendo este último gracias a sus bondades sobre el MDA, como la no restricción sobre el seguimiento de una distribución normal para sus variables.

De las 13 razones financieras elegidas dentro de las categorías de liquidez, rentabilidad, apalancamiento, solvencia y actividad, el modelo elegido se basó en las siguientes variables estadísticamente significativas en la predicción de riesgo de crédito:

**X<sub>3</sub>**=Capital de Trabajo/Total Activo : **CT\_TA**

**X<sub>6</sub>**= Total Pasivo/ Total Activo : **TP\_TA**

**X<sub>8</sub>**= Total Pasivo/ EBITDA : **TP\_EBITDA**

**X<sub>10</sub>**= Costo de Ventas/ Ventas : **CV\_VT**

**X<sub>12</sub>**= Gastos No Operacionales/ Ventas : **GT\_NO\_VT**

**X<sub>13</sub>**= EBITDA/ Ventas: **EBITDA\_VT**

$$Y4 = 0.337475 * CT\_TA - 0.185728 * TP\_TA + 0.128350 * TP\_EBITDA - 0.135656 * CV\_VT - 0.623437 * GT\_NO\_VT + 1.130360 * EBITDA\_VT + 1.688590$$

La variable **X<sub>13</sub>**= EBITDA/ Ventas, se constituyó como la de mayor peso explicativo sobre la predicción de una empresa como óptima o no para recibir crédito, al ser una medida que permite conocer la salud de la compañía en términos operacionales, es decir que tan adecuada es la gestión del costo y el gasto dejando de lado el sesgo de los rubros no monetarios como la depreciación y el efecto de la estructura de capital. Así mismo la variable **X<sub>3</sub>**=Capital de Trabajo/Total Activo

al ser una medida de qué tan productiva es la gestión del capital de trabajo frente a la inversión realizada en activos, aporta positivamente a la determinación de una IPS como rentable y por tanto apta para recibir crédito. Las variable  $X_{12}$ = Gastos No Operacionales/ Ventas es la segunda con mayor peso explicativo sobre la predicción de una empresa como rentable o no rentable siendo evidente que generar un alto nivel de gastos ajenos a la operación tiene gran incidencia en clasificar una IPS como no rentable, de igual manera sucede en menor medida con la variable  $X_{10}$ = Costo de Ventas/ Ventas la cual refleja el adecuado control del costo de las IPS's en su operación, por medio del control del costo médico y la frecuencia de visita de los pacientes, la cual puede disminuirse mediante la efectiva implementación de planes de promoción y prevención de enfermedades. Finalmente la variable  $X_6$ = Total Pasivo/ Total Activo impacta negativamente en la clasificación de una empresa como apta para recibir crédito al tener como finalidad determinar la participación de los acreedores en la compañía como medida de riesgo de esta misma.

Finalmente se logró concluir que los departamentos con mayor estrés financiero dado que operativamente arrojan pérdidas son el Valle del Cauca, Meta y Córdoba, siendo el Meta el departamento con mayores pérdidas antes de impuestos. Así mismo se evidencio que existe un fuerte efecto positivo de los Ingresos no Operacionales en el resultado final de las IPS's, siendo el margen operacional muy inferior al porcentaje que representa la Utilidad Antes de Impuestos sobre los ingresos. Se concluye con el listado de las 67 IPS's cuya recomendación es la otorgación de crédito dado los resultados arrojados por el modelo.

## 6. Bibliografía

- Akerlof, G. (1970). The market for lemons. *Quarterly journal of Economics*, 84(3), 488-500.
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4), 589-609.
- Altman, E. I., & Saunders, A. (1997). Credit risk measurement: Developments over the last 20 years. *Journal of banking & finance*, 21(11-12), 1721-1742.
- Altman, E. I., & Saunders, A. (1997). Credit risk measurement: Developments over the last 20 years. *Journal of banking & finance*, 21(11-12), 1721-1742.
- Banda Ortiz, H., & Garza Morales, R. (2014). Aplicación teórica del método Holt-Winters al problema de credit scoring de las instituciones de microfinanzas. *Mercados y Negocios*, 15(2).
- Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of accounting research*, 71-111.
- Calderón, C. A. A., Botero, J. C., Bolaños, J. O., & Martínez, R. R. (2011). Sistema de salud en Colombia: 20 años de logros y problemas. *Ciencia & Salud Colectiva*, 16, 2817-2828.
- Cavalluzzo, K., & Wolken, J. (2005). Small business loan turndowns, personal wealth, and discrimination. *The Journal of Business*, 78(6), 2153-2178.
- De Lara Haro, A. (2005). *Medición y control de riesgos financieros*. Editorial Limusa.
- Durand, D. (1941). Risk elements in consumer installment financing. National Bureau of Economic Research, New York
- Efron, B. (1975). The efficiency of logistic regression compared to normal discriminant analysis. *Journal of the American Statistical Association*, 70(352), 892-898.
- Fama, Eugene, and Michael Jensen, 1983, Agency Problems and Residual Claims, *Journal of Law and Economics* 26, 327-349.
- Giraldo, (2018). Último Informe de Cartera con corte a Junio de 2017, [achc.org.co](http://achc.org.co), Recuperado de: <http://achc.org.co/wp-content/uploads/2018/01/ULTIMO-INFORME-CARTERA-A-JUNIO-DE-2017-con-y-sin-deterioros.pdf>.

Giraldo, (2017), Gremio de hospitales y clínicas asegura que informes de Supersalud son inexactos, *www.dinero.com*, Recuperado de: <https://www.dinero.com/empresas/articulo/hospitales-y-clinicas-critican-informes-de-supersalud/253143>

Hand, D. J., & Henley, W. E. (1997). Statistical classification methods in consumer credit scoring: a review. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 160(3), 523-541.

Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of financial economics*, 3(4), 305-360.

Jensen, M. C., & Smith, C. W. (1984). The theory of corporate finance: a historical overview.

Kim, J. (2005). A credit risk model for agricultural loan portfolios under the new basel capital accord (Doctoral dissertation, Texas A&M University).

Leland, Hayne E., & David Pyle, (1977). Informational Asymmetries, Financial Structure, and Financial Intermediation. *Journal of Finance* 32, 371-387.

Levete Añez, (2017). IPS se declaran al borde de la quiebra. *Portafolio.co*. Recuperado de: <http://www.portafolio.co/economia/ips-se-declaran-al-borde-de-la-quiebra-504204>.

Markowitz, H. (1952). Portfolio selection. *The journal of finance*, 7(1), 77-91.

Mester, L. J. (1997). What's the point of credit scoring?. *Business review*, 3(Sep/Oct), 3-16.

Michalski, G. (2013). Portfolio management approach in trade credit decision making. arXiv preprint arXiv:1301.3823.

Miller, M., & Rojas, D. (2004). Improving access to credit for smes: an empirical analysis of the viability of pooled data sme credit scoring models in Brazil, Colombia & Mexico. *World Bank working paper*.

Myers, S. C., & Majluf, N. S. (1984). Corporate financing and investment decisions when firms have information that investors do not have. *Journal of financial economics*, 13(2), 187-221.

- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, 109-131.
- Petersen, M. A., & Rajan, R. G. (1997). Trade credit: theories and evidence. *The review of financial studies*, 10(3), 661-691.
- Pike, R., Nam Sang, C., Cravens, K., & Lamminmaki, D. (2005). Trade Credit Terms: Asymmetric Information and Price Discrimination Evidence From Three Continents. *Journal Of Business Finance & Accounting*, 32(5/6), 1197-1236. doi:10.1111/j.0306-686X.2005.00627
- Puertas Medina, R., & Martí Selva, M. L. (2013). Análisis del credit scoring. *RAE-Revista de Administração de Empresas*, 53(3).
- Sepúlveda Rivillas, C., Reina Gutiérrez, W., & Gutiérrez Betancur, J. C. (2010). Estimación del riesgo de crédito en empresas del sector real en Colombia (Master's thesis, Universidad EAFIT).
- Schwartz, R. A. (1974). An economic model of trade credit. *Journal of financial and quantitative analysis*, 9(4), 643-657.
- Smith, J. K. (1987). Trade credit and informational asymmetry. *The journal of finance*, 42(4), 863-872.
- Valdés, C. A. L. (2010). El análisis financiero como herramienta en la predicción de quiebra e insolvencia financiera. *Apuntes Contables*, (2).
- West, D. (2000). Neural network credit scoring models. *Computers & Operations Research*, 27(11-12), 1131-1152.
- Wiginton, J. C. (1980). A note on the comparison of logit and discriminant models of consumer credit behavior. *Journal of Financial and Quantitative Analysis*, 15(3), 757-770.

