



**Colegio de Estudios
Superiores de Administración**

MODELO PREDICTIVO DE QUIEBRA PARA BANCOS ESTADOUNIDENSES

**Andrés Felipe Restrepo
Santiago Amaya Orozco**

**Colegio de Estudios Superiores de Administración –CESA-
Maestría en Finanzas Corporativas
Bogotá
2015**

MODELO PREDICTIVO DE QUIEBRA PARA BANCOS ESTADOUNIDENSES

**Andrés Felipe Restrepo
Santiago Amaya Orozco**

**Directores:
Javier B. Cadena Lozano
Profesor – Investigador CESA
Miller Janny Ariza Garzo
Profesor CESA**

**Colegio de Estudios Superiores de Administración –CESA-
Maestría en Finanzas Corporativas
Bogotá
2015**

TABLA DE CONTENIDO

1	INTRODUCCION	8
1.1	Objetivos:	11
1.1.1	Objetivo General	11
1.1.2	Objetivos Específicos	11
2	ESTADO DEL ARTE	12
2.1	Modelos Discriminante y logístico	12
2.2	Redes Neuronales:	18
3	MARCO TEORICO	23
3.1	Modelos Discriminantes	28
3.2	Modelos de Probabilidad	29
3.2.1	Modelo de Probabilidad Lineal	29
3.2.2	Modelo Logit	30
3.2.3	Modelo Probit	33
3.3	Modelos de Regresión	34
3.4	Redes Neuronales	35
3.5	Ventajas y Desventajas	39
4	METODOLOGIA	40
4.1	Muestra:	40
4.2	Indicadores:	42
4.3	Modelo de Regresión Logística – Logit	48
4.3.1	Tablas de Clasificación	53
4.3.2	Pruebas y Estadísticos	56
4.4	Análisis Financiero Variables Significativas	59
4.5	Árbol Binomial del Modelo	69
4.6	Aplicación Modelo sobre Muestra Total	70
4.7	Evaluaciones Adicionales	73
4.7.1	Matrices de Transición	73
4.7.2	Indicador: Costo de Financiación de los Activos Productivos	75

5 CONCLUSIONES 80

6 REFERENCIAS 83

LISTA DE TABLAS

Tabla 1. Modelos Previos	23
Tabla 2. Ventajas y Desventajas.....	39
Tabla 3. Distribución periodos de Quiebra.....	41
Tabla 4. Información Financiera Disponible.....	42
Tabla 5. Indicadores	47
Tabla 6. Variable Y	48
Tabla 7. Pruebas R Cuadrado	49
Tabla 8. Variables del Modelos.....	50
Tabla 9. Tabla de Clasificación	53
Tabla 10. Tabla de Clasificación del Modelo.....	55
Tabla 11. Pruebas y Estadísticos	56
Tabla 12. Zonas de Clasificación	70
Tabla 13. Resultados del Modelo	70
Tabla 14. Matrices de Rodamiento Bancos Quebrados.....	73
Tabla 15. Matrices de Rodamiento Bancos No Quebrados.....	74
Tabla 16. Zonas de Clasificación Indicador	78
Tabla 17. Resultados Indicador	78

LISTA DE FIGURAS

Figura 1. Red Unicapa.....	38
Figura 2. Curva ROC.....	58
Figura 3. Curva ROC Modelo	59
Figura 4. Margen de Interés Neto.....	60
Figura 5. Ingresos Distintos a Interés	62
Figura 6. ROA	63
Figura 7. Ganancia en Cobertura de Cartera Castigada.....	64
Figura 8. Prestamos Netos/ Activos Totales.....	65
Figura 9. Relación de Solvencia Básica	66
Figura 10. Patrimonio/Activo	67
Figura 11. Reserva.....	67
Figura 12. Pasivo/Patrimonio	68
Figura 13. Zona de Seguridad	69
Figura 14. Evolución del Modelo.....	72
Figura 16. Zona de Seguridad del Indicador	75
Figura 18. Comportamiento Indicador	77
Figura 19. Comportamiento Indicador: Quebrados vs. No quebrados.....	77

LISTA DE ANEXOS

Anexo 1. Variables No Significativas	90
--	----

1 INTRODUCCION

La crisis financiera de 2008, que inicio como un problema de incumplimiento de pagos en el mercado inmobiliario estadounidense, y que estallo cuando el banco de inversión Lehman Brothers se declaró en bancarrota o quiebra (entidad considerada demasiado grande para caer), trajo consigo la peor crisis de la historia y evidencio la debilidad en la regulación financiera estadounidense y la ausencia de respuestas oportunas por parte de los organismos de control.

Teniendo en cuenta que una de las economías más importantes del mundo es la estadounidense, y que su comportamiento tiene un impacto bastante significativo en el resto de economías es necesario monitorear el comportamiento de los bancos estadounidenses y su impacto en la economía.

Al desarrollar un modelo probabilístico con base en los indicadores financieros que permita identificar en que momento un banco puede presentar dificultades financieras que lo lleven a la quiebra, se podrán tomar las acciones y medidas preventivas necesarias para evitar la quiebra, y así salvaguardar la economía de un país.

Adicionalmente, es necesario contar con un modelo que le permita a los inversionistas y entidades financieras colombianas poder realizar una buena toma de decisiones al invertir en el mercado estadounidense mediante la compra de acciones, bonos y notas estructuradas, entre otros.

La bancarrota de Lehman Brothers en octubre de 2008 sacudió al mundo financiero, y aunque la crisis fue detonada por un debacle en los créditos hipotecarios en los Estados Unidos, la transmisión fue instantánea a casi todos los países del mundo, generando la recesión más profunda y de mayor cobertura desde la década de 1930. La quiebra de Lehman Brothers, y la incertidumbre sobre la salud de otras empresas bancarias y no bancarias, como lo menciona la Comisión Económica para América Latina y el Caribe (CEPAL) en su artículo “La crisis y su impacto futuro en la economía internacional”, desencadenó una reacción inmediata de pánico, una caída generalizada de la demanda de

activos de deuda (desaparición del crédito), y el colapso del mercado y los precios de estos activos. El pánico financiero fue mitigado parcialmente por anuncios de recapitalización bancaria, limpieza de activos, extensiones de garantías sobre los pasivos e inyecciones de liquidez por parte de los principales bancos centrales del mundo.

La crisis financiera de 2008 puso al descubierto las imperfecciones del sistema financiero estadounidense y la ineficiencia en la regulación y supervisión bancaria. Si bien lo peor de la crisis financiera mundial parece haber llegado a su fin, el riesgo contagio (sistémico) sigue y seguirá estando presente en los mercados, no por nada la revista Forbes en su artículo “Las 15 empresas financieras más importantes del mundo” de julio de 2013, pone en su lista a los cuatro bancos más grandes (por ventas y valor de mercado) de Estados Unidos en orden JP Morgan Chase (3), Wells Fargo (8), Citigroup (9) y Bank of America (13).

Según la Corporación Federal Aseguradora de Depósitos (FDIC, por sus siglas en inglés), alrededor de 482 bancos estadounidense han cerrado entre 2009 y 2014 (18 bancos en 2014). Lo cual ha generado un costo de pérdida de alrededor de 73.600 billones de dólares a la FDIC.

El impacto de dicha crisis financiera afectó a la mayoría de las economías desarrolladas y a un amplio grupo de países emergentes; como lo menciona la AMV (Autorregulador del Mercado de Valores de Colombia), en su informe “Impacto de la Crisis Financiera Internacional en el Sistema Financiero Colombiano y en su Regulación”, América Latina se vio afectada por la fuerte caída en los precios de exportación de materias primas, el deterioro en la demanda externa y la disminución en el volumen de remesas. Adicionalmente, el precio en los índices accionarios de las bolsas de la región presentaron disminuciones generalizadas: Brasil -42%, Colombia -29% y México con el -24%, lo que terminó afectando el portafolio de inversiones y en general los balances de las entidades con participación en activos del exterior. Según el informe “Actualidad del Sistema Financiero Colombiano” publicado por la Superintendencia Financiera de Colombia, en

agosto de 2014 el 9,64% del portafolio del sistema financiero está invertido en títulos emitidos por agentes del exterior.

Es por ello, que anticiparse a cualquier colapso (deterioro financiero que las lleva a la quiebra) de estas entidades es importante no sólo para la economía mundial sino también para las entidades financieras colombianas que asumen el riesgo emisor al invertir mediante la compra de acciones, bonos, notas estructuradas, entre otros.

Para entrar en contexto es necesario entender la definición de quiebra o bancarrota. Una quiebra bancaria es el cierre de un banco por una agencia reguladora federal o estatal, que resulta generalmente de la incapacidad del banco para satisfacer sus obligaciones a los depositantes y a otros.

Según la CEPAL (2000), las causas de las crisis bancarias pueden dividirse en macroeconómicas y microeconómicas. Dentro de los factores macroeconómicos se encuentran, por una parte, choques que afectaron la calidad de los activos bancarios, el fondeo de recursos, la dinámica crediticia y la expansión excesiva de los agregados monetarios y, por otra parte, el efecto de las expectativas del público y la volatilidad externa e interna. Con respecto a las causas microeconómicas, éstas se caracterizaron por la debilidad en la regulación y supervisión bancarias, la precipitación en los esquemas de liberalización financiera, los marcos contables inadecuados, el aumento en la cartera vencida y en los márgenes de intermediación financiera, la participación estatal en la propiedad de los bancos, el otorgamiento de créditos a partes relacionadas, y los problemas de información asimétrica.

Adicionalmente, es necesario entender la regulación estadounidense con respecto a la quiebra o a la bancarrota. Las leyes federales sobre bancarrota regulan de qué manera las empresas cierran sus negocios o se recuperan de una pésima situación en sus pasivos. Una empresa en bancarrota, el "deudor," podría hacer uso del Capítulo 11 del Código de Bancarrota para "reorganizar" su negocio y tratar de volverse rentable nuevamente. La

administración de la empresa continúa realizando operaciones día a día, pero es un tribunal de bancarrota el que debe tomar todas las decisiones de negocios importantes.

Conforme al Capítulo 7, la empresa detiene todas sus operaciones y cierra el negocio definitivamente. Se designa a un administrador fiduciario para que "liquide" (venda) los activos de la empresa y el dinero recaudado se utiliza para pagar la deuda, la que puede incluir préstamos de los acreedores e inversionistas.

La mayoría de empresas públicas se acogen al Capítulo 11 en lugar que el 7 porque de esa manera todavía pueden administrar su negocio y controlar el proceso de bancarrota. El Capítulo 11 proporciona un proceso para rehabilitar el negocio endeble de la empresa. A veces la empresa hace funcionar un plan de manera exitosa para recuperar su rentabilidad; algunas veces, al final, se liquida.

1.1 Objetivos:

1.1.1 Objetivo General

Desarrollar un modelo probabilístico que prediga con confiabilidad si un banco estadounidense puede presentar dificultades financieras que lo lleven a la quiebra.

1.1.2 Objetivos Específicos

- Analizar los modelos de predicción de quiebra que se han desarrollado en la literatura financiera.
- Realizar un análisis comparativo de los de los indicadores financieros aplicables a cada modelo de predicción.
- Identificar cuales indicadores financieros son más significativos en la probabilidad de quiebra de un banco estadounidense.

2 ESTADO DEL ARTE

2.1 Modelos Discriminante y logístico

La predicción de la quiebra de las compañías ha sido activamente estudiada por la academia y hasta por los entes reguladores, donde los investigadores tomaron un enfoque estadístico aplicado a grandes corporaciones, a pequeñas y mediana empresas e incluso a entidades financieras en diferentes países y en diferentes economías (Bellovary, Giacomino & Akers, 2007).

En la década de los sesenta se realizaron unos acercamientos estadísticos para la medición de quiebra de una corporación donde se clasificaba como exitosa y como no exitosa, estos análisis estadísticos se realizaron a partir de modelos discriminatorios simples (Beaver, 1966) y con múltiples variables (Altman, 1968).

Beaver (1966), realizó un modelo univariante al comparar la medias de 30 razones financieras de 79 compañías en bancarrota y 79 compañías estables en 38 sectores económicos. Adicionalmente, realizó pruebas de predicción individual a cada una de las razones financieras para analizar sus cualidades para clasificar una compañía como en bancarrota y no en bancarrota.

Al concluir su investigación Beaver encontró los siguientes resultados: El Ingreso Neto sobre la Deuda Total tuvo el mayor porcentaje de predicción con un 92% de precisión (Un año antes de la quiebra), lo seguía el Ingreso Neto sobre las Ventas con un 91% de precisión e Ingreso Neto sobre Patrimonio Neto, Flujo de Caja sobre Deuda Total y Flujo de Caja sobre Total de Activos cada uno con un 90% de precisión.

Adicionalmente Beaver en sus conclusiones, advirtió sobre la posibilidad de desarrollar un modelo con múltiples variables analizadas simultáneamente podría presentar un porcentaje de precisión mucho más alto que modelos con una sola variable.

A partir de ese momento, los modelos de probabilidad o predicción de quiebra tuvieron un cambio importante al desarrollar un modelo con múltiples variables analizadas simultáneamente, como se verá a continuación este cambio trascendental se inició con la investigación desarrollada por Altman (1968).

El modelo desarrollado por Altman (1968) para compañías manufactureras, está basado en un análisis discriminativo múltiple en donde se ponderan y se suman cinco razones financieras para clasificar las empresas como en quiebra y no en quiebra. Altman tomo una muestra de 66 compañías del sector manufacturero y se clasificaban de la siguiente manera: 33 que habían quebrado en los últimos 20 años y 33 que seguían en operación a la fecha del estudio.

A la muestra descrita anteriormente, se le calculo 22 razones financieras las cuales se clasificaron en 5 categorías distintas: Liquidez, Rentabilidad, Apalancamiento, Solvencia y Actividad.

Después de realizar algunas corridas, Altman (1968) definió las 5 variables que como modelo dieron el mejor resultado de predicción de quiebra de las compañías. Lo anterior se realizó basado en los siguientes criterios:

1. Observación estadística de la combinación de las variables, incluyendo la contribución relativa de cada variable independiente.
2. Evaluación de correlaciones entre las variables relevantes.
3. Observación de la precisión en la predicción de los modelos.
4. Criterio del analista.

Las variables definidas por Altman (1968), fueron las siguientes:

X_1 = Capital de Trabajo/ Activo Total, Mide los activos Corrientes con relación al tamaño de la compañía.

X_2 = Utilidades Retenidas/ Activo Total

X_3 = Utilidades antes de intereses e impuestos/ Activo Total, Mide la verdadera rentabilidad de la compañía.

X_4 = Valor de mercado del capital/Pasivo Total

X_5 = Ventas/ Activo Total, Mide la habilidad de los activos para generar ventas.

A partir de las variables anteriores se definió la siguiente función, la cual se conoce como el “Z-Score”:

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

Los resultados de la función anterior se pueden interpretar de la siguiente manera, si $Z \geq 2.99$, la compañía no tendrá problemas de quiebra o bancarrota en el futuro; si $Z \leq 1.81$, la compañía de no corregir su curso en el futuro tendrá probabilidades bastante altas de quedar en quiebra. En el modelo planteado se considera que las compañías se encuentran en una zona gris si el resultado del Z se encuentra en un rango entre 1.82 y 2.98.

A partir de este modelo, se concluyó que lograba tener una precisión de predictibilidad del 95% para la muestra un año antes de la quiebra pero el porcentaje de predicción del modelo decrecía a un 72% de precisión dos años antes de la quiebra y seguía decreciendo a un 48%, 29% y 36% de precisión a los tres, cuatro y cinco años antes de la quiebra, respectivamente.

Teniendo en cuenta que este modelo originalmente fue enfocado hacia las compañías manufactureras, Altman realizó una revisión sobre este y definió dos modelos adicionales. El primero fue enfocado hacia todo tipo de compañías que no necesariamente cotizaban en

bolsa y el segundo fue enfocado, hacia compañías industriales no-manufactureras (Altman, 1993) y de mercados emergentes (Altman, 1995).

Después de las investigaciones realizadas por Altman usando el método de análisis discriminante múltiple, varias investigaciones enfocaron esta metodología al pronóstico o predicción de quiebras de los bancos.

Meyer & Pifer (1970), fueron los primeros en aplicar un modelo de regresión lineal partiendo del análisis discriminante múltiple para la predicción de quiebra de los bancos. A partir de una muestra de 78 bancos constituidos en 39 que quebraron y en 39 bancos similares con solvencia, en el periodo comprendido entre 1948 y 1965. Esta muestra fue escogida de acuerdo a los siguientes criterios: los Bancos debían existir desde 6 años antes del estudio y como se mencionó anteriormente, tener un banco solvente con el cuales se pudiera realizar una comparación.

La muestra se agrupo por parejas de acuerdo con los siguientes criterios: Ubicación, Tamaño, tiempo de existencia y normas regulatorias. A partir de la muestra definida, se estimaron alrededor de 32 razones financieras las cuales fueron definidas como variables independientes en los diferentes modelos de regresión probados. Se utilizó un programa de regresión “Paso a Paso”, en donde se aplicaron los métodos de introducción y eliminación progresiva en cada paso de la regresión.

El modelo propuesto por Meyer & Pifer (1970), alcanzo un porcentaje de precisión del 80% para la muestra de bancos quebrados y un 72% de precisión para los otros bancos, esto con un rango de periodo de entre uno a dos años antes de la quiebra. Cuando el periodo cambiaba a tres o más años antes de la quiebra, el modelo era incapaz de discriminar entre bancos quebrados y no quebrados.

De acuerdo con lo anterior, se concluyó que las razones financieras debían usarse junto con otros factores externos (condiciones de la economía local, la calidad gerencial y la

integridad de los empleados) para poder realizar una mejor predicción en la quiebra de los bancos.

Autores como Sinkey Jr. (1975), Santomero & Vinso (1977), Pettway & Sinkey Jr. (1980) y Rose & Kolary (1985), al igual que Meyer & Pifer (1970) enfocaron sus estudios en modelos de discriminación múltiple y programación lineal para predecir la quiebra de los bancos. Obtuvieron resultados semejantes a los de Meyer & Pifer, donde el porcentaje de precisión del modelo era más alto entre uno y dos años antes de la quiebra.

Durante la década de los setenta, el modelo de análisis discriminatorio continuó siendo el modelo predilecto en la predicción de quiebra, aunque el modelo de análisis discriminatorio asume el supuesto de que la información de los estados financieros sigue una distribución normal y que la matriz de varianza-covarianza de los bancos en quiebras y los bancos que no están en quiebras son iguales. Estos supuestos no necesariamente se cumplían, como pudo concluir Ohlson (1980).

Teniendo en cuentas estos supuestos, Martin (1977) realizó el primero método de predicción de quiebra el cual no tenía ningún tipo de restricción o supuesto con respecto a la distribución que debían seguir las variables independientes. El método utilizado fue el de las regresiones Logísticas o como se le conoce comúnmente el modelo "Logit", este método se ha convertido en el método estadístico más usado para la predicción de quiebra.

Martin (1977), en su trabajo examinó todos los bancos comerciales miembros de la Reserva Federal de Estados Unidos a 1974. Se identificaron dos grupos de bancos, 23 quebrados y 5.575 no quebrados, adicionalmente se definieron 25 razones financieras las cuales se clasificaron en cuatro grupos: calidad de los activos, liquidez, adecuación de capital e ingresos. El modelo final definido por Martin (1977), consistía de cuatro variables independientes obtenidas de los grupos definidos calidad de los activos, adecuación de capital e ingresos.

Siguiendo el modelo Logit aplicado por Martin (1977), otros autores se enfocaron en la predicción de quiebra de los bancos. Avery & Hanweck (1984), enfocaron su estudio en 100 bancos quebrados y 1.190 bancos no quebrados en un rango de tiempo estimado entre diciembre de 1978 y junio 1983. El análisis efectuado sobre estos bancos se estimó empleando 9 variables independientes, las cuales después de efectuar las regresiones cinco mostraron significancia. Al igual que el modelo de Martin (1977), las variables significativas se clasificaron como calidad de los activos, adecuación del capital e ingresos.

En la década de los noventa, se continuo con las investigaciones enfocadas en los modelos Logit, Thomson (1991) realizo un estudio sobre los bancos comerciales asegurados en la FDIC (Federal Deposit Insurance Corporation), en donde examino el porcentaje de precisión del modelo Logit empleando los siguientes grupos de variables: calidad de los activos, adecuación de capital, ingresos, liquidez y calidad de la administración. La decisión de incluir como variable la calidad de la administración estuvo basado en el estudio realizado por Graham & Horner (1983).

La muestra definida por Thomson (1991), se tomó a partir de los bancos en quiebra entre 1984 y 1989. Donde se pudo demostrar que la probabilidad de quiebra es una función de las variables ponderadas de cada uno de los grupos definidos anteriormente, los cuales demostraron ser precisos para ambos grupos de la muestra.

Otras investigaciones usando el método Logit, se han enfocado en la definición de las razones financieras a incluir como variables en el modelo. Estrella, Park & Persitiani (2000) examinaron y compararon la efectividad de indicadores simples de capital e indicadores más complejos de capital de riesgo ponderado, representando el riesgo factor del capital adecuado.

Con este estudio, se concluyó que los indicadores simples de capital logran predecir la quiebra de un banco igual de bien que los indicadores más complejos de capital de riesgo ponderado y que por lo tanto el riesgo factor del capital adecuado puede ser ponderado sin

problema por un número de indicadores de capital simple. Adicionalmente, se examinó el comportamiento de las calificaciones de crédito como un indicador en la predicción de quiebra.

En estudios más recientes como el realizado por Andersen (2008), se utilizó el modelo Logit para determinar los indicadores financieros más significativos en la predicción de quiebra de los bancos noruegos. A partir de un muestra inicial de 23 variables independientes se encontraron seis variables significativas las cuales fueron consistentes con estudios anteriores, estas seis variables se agruparon en adecuación de capital, calidad del activo, ingresos y liquidez.

Existen diversos estudios enfocados a la predicción de quiebra de los bancos estadounidenses después de la crisis de 2008. Isaac & Flores (2010) realizaron un modelo de predicción de quiebra de los bancos estadounidenses para la toma de decisiones, teniendo en cuenta el impacto que tuvo sobre las entidades financieras mexicanas la crisis del 2008.

Las variables usadas por Isaac & Flores (2010), fueron rentabilidad, calidad del crédito y eficiencia. En donde sus resultados fueron la significancia de las cuatro variables independientes y un porcentaje de predicción del modelo del 99,86%.

2.2 Redes Neuronales:

Cuando se analizan los modelos de predicción de quiebra es necesario hacer énfasis en los modelos de predicción de quiebra usando redes neuronales artificiales. Recientemente investigadores como Al-Shayea, El-Refae & El-Itter (2010), usaron las redes neuronales artificiales como modelos de análisis discriminante de la predicción de quiebra con resultados de altos porcentajes de precisión.

Los primeros modelos de predicción de quiebra usando redes neuronales artificiales se enfocaron en la predicción de quiebra de compañías del sector real. Una de las primeras investigaciones de redes neuronales artificiales enfocadas a la predicción de quiebra fue la realizada por Odom & Sharda (1990), en esta investigación los autores se enfocaron en la comparación de las habilidades de predicción entre los modelos de redes neuronales y los discriminantes. A partir de una muestra de 129 firmas, 65 firmas que se quebraron entre 1975 y 1982, y 64 firmas que tuvieron estabilidad en ese mismo periodo.

Las variables usadas fueron las mismas que establecidas por Altman (1968), los resultados obtenidos de la comparación de ambos modelos muestra que el modelo de redes neuronales tuvo un mejor rendimiento y robustez. Adicionalmente si se usaran diferentes variables es posible que la precisión del modelo sea mayor.

Una de las primeras investigaciones de redes neuronales artificiales enfocadas a la predicción de quiebra de bancos fue la realizada por Tam & Kiang (1992), en esta investigación los autores introdujeron en un modelo de redes neuronales indicadores financieros como adecuación del capital, calidad del activo, utilidades y liquidez. Establecieron una muestra de bancos que quebraron en Texas entre 1985 a 1987 y definieron un total de 19 indicadores financieros como variables.

A partir de esto pudieron demostrar que las redes neuronales ofrecen un mejor porcentaje de predicción que los modelos de análisis discriminante, le atribuyeron esta superioridad a la habilidad de las redes neuronales de manejar datos No-lineales y de acomodarse a cualquier distribución de probabilidad.

Autores como Salchenger, Mine & Lash (1992) y Fletcher & Goss (1933), usaron redes neuronales artificiales para la predicción de quiebra de asociaciones de préstamos y ahorro, adicionalmente comparando su rendimiento con los modelos de regresión logística. Wilson & Sharda (1993) realizaron una comparación de redes neuronales con un modelo de

análisis discriminante múltiple, en donde nuevamente se observó que las redes neuronales tienen un mejor rendimiento que los otros modelos.

Brockett, Cooper, Golden & Pitakong (1994), usaron un modelo de redes neuronales artificiales como un sistema de alerta temprana para la predicción de la insolvencia de las aseguradoras. Con el fin de investigar la inclinación de una firma hacia la insolvencia y a partir de un algoritmo de retropropagación “Feed-Forward” aplicado a información financiera dos años antes de la insolvencia para una muestra de aseguradoras de propiedad y responsabilidad civil, las cuales se volvieron insolventes entre 1991 y 1992. Así mismo con una muestra de igual tamaño para aseguradoras solventes en el mismo periodo de tiempo.

Una de las principales conclusiones arrojadas de la investigación realizada por Brockett et al. (1994) es que los sistemas de redes neuronales artificiales pueden adaptarse a diferentes influencias económicas predominantes y que en esencia el modelo de redes neuronales puede evolucionar y cambiar a medida que la información, el sistema o el mismo problema cambian. A diferencia de los modelos estáticos, ya que estos modelos no tienen estas propiedades.

Jo & Han (1996), se enfocaron en un modelo integrado para la predicción de quiebra, en donde se integraban un modelo de análisis discriminante y dos modelos de inteligencia artificial (redes neuronales y proyección de escenario base). En conclusión el modelo integrado contaba con un mejor rendimiento y mayores porcentajes de predicción que los modelos analizados individualmente.

Entre 1997 y 1998, algunos investigadores como Bell (1997) utilizaron las redes neuronales con algoritmos de retro propagación para compararlo con un modelo de regresión logístico en la predicción de quiebra de un banco. En su investigación Bell (1997) uso 28 variable predictores y la arquitectura de la red neuronal tenía 12 nodos de entrada, 6 nodos ocultos y un nodo de salida.

En conclusión Bell (1997), encontró que ni el modelo de regresión logístico ni la red neuronal usando algoritmo de retro propagación tenía un porcentaje de predicción más alto que el resto de los modelos. Sin embargo, el modelo de red neuronal usando el algoritmo de retro propagación tiene un mejor desempeño para procesos de decisiones complejas.

Alam, Booth, & Thordason (2000), presentaron su investigación usando el agrupamiento difuso junto a dos redes neuronales auto organizadas como una herramienta de clasificación para identificar un banco potencialmente en quiebra. Ante todo describieron las características distintivas del algoritmo de agrupamiento difuso, el cual proporciona la probabilidad de que el banco eventualmente quiebre.

Una vez concluido la investigación, Alam *et al.* (2000) concluyeron que al comparar los resultados del particionamiento del agrupamiento difuso con los de las dos redes neuronales auto organizadas encontraron que ambos proveen herramientas de clasificación para identificar los bancos potencialmente en quiebra.

Algunas investigaciones como Swicegood & Clark (2001), incluyeron en sus investigaciones variables humanas como el criterio humano para la predicción de quiebra de un banco. En donde realizaron una comparación entre el modelo de análisis discriminante, red neuronales y el criterio humano usando la información incluida en los reportes bancarios enviados periódicamente a la FDIC.

De acuerdo con lo anterior, encontraron que el modelo de análisis discriminante clasifica correctamente como quebrados al 86,4% y 79,5% de los bancos regionales y comunitarios, respectivamente. Sin embargo, el modelo de redes neuronales clasifica correctamente como quebrados al 81,4% y al 78,25% de los bancos regionales y comunitarios. En conclusión se observó que las redes neuronales superan a otros modelos en la identificación de bancos en bajo rendimiento.

Boyacioglu, Kara & Baykan (2008), realizaron una comparación de varias redes neuronales artificiales y métodos de análisis discriminativo para la predicción de quiebra de bancos en Turquía. Se usaron cuatro arquitecturas diferentes para las redes neuronales, entre ellas Mapa Auto organizado, Vectores de Aprendizaje Cuántico, Perceptrón Multicapa y Capas Convolucional. Mientras que los métodos discriminativos usado fue el método de regresión logística.

Al concluir la investigación, Boyacioglu et al. (2008) concluyeron que los métodos que mejor rendimiento mostraban en cuanto al porcentaje de predicción de quiebra eran las redes neuronales, más exactamente los Vectores de Aprendizaje Cuántico y el Perceptrón Multicapa.

Otras investigaciones usando redes neuronales se enfocaron en distintas arquitecturas de red, Ravi & Pramodh (2008) plantearon una red neuronal de componente principal para la predicción de quiebra de los bancos comerciales. Esta red neuronal de componente principal consiste de una capa de la red compuesta de componentes seleccionados que desarrollan la función de nodos ocultos. En esta arquitectura, la capa oculta es reemplazada en su totalidad por la capa denominada “componente principal”.

A partir de esta arquitectura Ravi & Pramodh (2008), lograron comprobar que modelos híbridos que combinan redes neuronales de componentes principales logran un rendimiento superior a otros modelos de predicción de quiebra bancaria.

De la revisión bibliográfica, se puede concluir que las variables significativas en un modelo de predicción de quiebra de bancos se dividen en criterios de: liquidez, rentabilidad, capital y calidad del activo. Este estudio estará enfocado en las variables significativas de estudios anteriores, más los implementados por el Comité de Basilea y los calculados por la FDIC.

Adicionalmente, se hará la comparación de los diferentes modelos usados en la literatura, implementando un modelo con información de la crisis de 2008 y después de la crisis,

donde analizaremos la significancia de las variables, el impacto de las medidas de regulación con la coyuntura económica presente y la confiabilidad del modelo implementado.

3 MARCO TEORICO

Desde los trabajos de Beaver (1966) y Altman (1968), diversos autores han trabajado distintos métodos y modelos estadísticos para tratar el problema de predecir la crisis financiera de una compañía; cada uno de ellos basa su estudio en análisis financieros relevantes, seleccionando indicadores de liquidez, calidad del crédito, solvencia, rentabilidad y eficiencia.

En la Tabla 1, se presentan algunos estudios previos donde determinaron cuales indicadores son significativos a la hora de medir la probabilidad de default de una compañía.

Tabla 1.
Modelos Previos

Autor	Año	Objetivo	Variables Significativas / Conclusión / Resultados
Beaver	1966	Probabilidad de quiebra mediante un Análisis Discriminante Simple (ADS)	Más de 30 indicadores financieros fueron probados. El ratio de flujo de caja sobre deuda fue el mejor predictor de la insolvencia

Autor	Año	Objetivo	Variables Significativas / Conclusión / Resultados
Altman	1968	Estado de Quiebra (Análisis discriminante)	Capital de Trabajo/ Activo Total; Utilidades Retenidas/ Activo Total; Utilidades antes de intereses e impuestos/ Activo Total; Valor de mercado del capital/Pasivo Total; Ventas/ Activo Total.
Martin	1977	Probabilidad de Quiebra Bancos Reserva Federal EE.UU	Se definieron 25 razones financieras las cuales se clasificaron en cuatro grupos: calidad de los activos, liquidez, adecuación de capital e ingresos. El modelo final definido consistía de cuatro variables independientes obtenidas de los grupos definidos calidad de los activos, adecuación de capital e ingresos
Ohlson	1980	Probabilidad de Quiebra	Tamaño, Pasivos Totales / Activos Totales, Capital de Trabajo/ Activos Totales, Razón corriente, Dummy de solvencia (que es igual a uno en el caso de que el total de los pasivos sea mayor que el total de los activos, en caso contrario, es igual a cero), Retorno sobre los activos o EBIT/ Activos Totales, Resultado operacional sobre el total de las obligaciones, Dummy de rentabilidad (igual a uno cuando los ingresos –en los últimos dos años- han sido negativos; en caso contrario, es igual a cero), Variación en los Ingresos ((Ingreso Neto t – Ingreso Neto t-1) / (Ingreso Neto t + Ingreso Neto t-1)).

Autor	Año	Objetivo	Variables Significativas / Conclusión / Resultados
Avery & Hanweck	1984	Probabilidad de Quiebra	Las variables significativas se clasificaron como calidad de los activos, adecuación del capital e ingresos.
Frydman, Altman & Kao	1985	Estado de Quiebra - Algoritmo de partición sucesiva (RPA)	Flujo de Caja sobre Deuda, Beneficio Retenido sobre Activo, Deuda entre Activo y Tesorería entre Activo.
Mar-Moliner & Ezzamel	1991	Predicción de Quiebra - Técnica de Escalamiento Multidimensional (MDS)	Apalancamiento Financiero (deuda total entre activo), Rentabilidad (fondo de maniobra de las actividades ordinarias entre ventas), Flujo de Caja Operativo (flujo de caja de las actividades ordinarias), Liquidez (activo circulante entre activo) y Actividad (ventas entre activo).
Tam y Kiang	1992	Predicción de Quiebra - Modelos de Redes Neuronales	Suficiencia del Capital del Banco (capital entre activo), Calidad de los Activos (préstamos comerciales e industriales entre préstamos netos y arrendamientos financieros), Beneficios Actuales del Banco (gastos totales entre activo) y la Liquidez (préstamos totales y arrendamientos financieros entre depósitos totales).

Autor	Año	Objetivo	Variables Significativas / Conclusión / Resultados
Benito & Vlieghe	2000	Probabilidad de Quiebra	Rentabilidad: retorno sobre el capital, márgenes de utilidades; Endeudamiento: relación entre deuda neta y costo de reemplazo del capital (apalancamiento), medida de presión financiera de la compañía (directamente afectada por tasas de interés y rentabilidad); Liquidez: activos corrientes/pasivos corrientes, activos corrientes-inventarios/pasivos corrientes y efectivo + inversiones negociables/pasivos corrientes.
Quintanilla, Tschorne & Parisi	2002	Modelo Predictivo de Quiebra Bancaria (Caso Ecuador)	Activos Productivos/Pasivos con costo, Cartera vencida/Capital más reservas, Intereses Pagados/Pasivo con costo, Margen bruto financiero más ingresos ordinarios/Activos productivos promedio.
Martínez	2003	Determinantes de fragilidad de las empresas del sector corporativo privado	La rentabilidad, la liquidez y el endeudamiento son los indicadores claves a la hora de medir la insolvencia de una compañía colombiana.
Bunn & Redwood	2003	Estimación de Probabilidad de Quiebra	La probabilidad de que una firma se quiebre está positivamente relacionada con el Endeudamiento y negativamente con la Rentabilidad, la Cobertura de Intereses, el Tamaño y la Inversión Extranjera.

Autor	Año	Objetivo	Variables Significativas / Conclusión / Resultados
Arango, Zamudio & Orozco	2005	Determinantes de la probabilidad de quiebra de las empresas colombianas	Rentabilidad, Endeudamiento, Tamaño de la firma, Inversión Extranjera, Tasa de Crecimiento del PIB.
Gómez, Orozco & Zamudio	2006	Probabilidad condicional de incumplimiento utilizando un modelo de duración	El Endeudamiento es el principal determinante de la probabilidad condicional de incumplimiento.
Zamudio	2007	Probabilidad de incumplimiento a partir de un modelo multinomial	Liquidez (disponible sobre activos totales), relaciones bancarias y características de los créditos (número de entidades con que tiene relación cada empresa, tipo de garantías, plazo de los créditos, tipo de entidad), ciclo económico (tasa de crecimiento del PIB real), y entorno (sector económico)
Gómez & Orozco	2009	Probabilidad de Incumplimiento con Matrices de Transición	Liquidez, Tamaño, Costo de Oportunidad, Composición de la Deuda, PIB.

Existen dos tipos de modelos para determinar la situación financiera de una compañía:

- a) Modelos univariados: modelos que utilizan una sola variable independiente para predecir la quiebra.

b) Modelos multivariantes: modelos que utilizan una combinación de variables para predecir la quiebra, los cuales se clasifican a su vez en dos grupos:

1. Modelos Paramétricos:

- Modelos discriminantes
- Modelos de probabilidad condicional (logit y probit)

2. Modelos no Paramétricos:

- Modelo de particiones iterativas
- Modelo de Argenti
- Modelos de redes neuronales.

3.1 Modelos Discriminantes

Cómo lo señalan Ortega, Martínez & Valencia (2010), el análisis discriminante es una técnica estadística que permite clasificar una observación en uno de varios grupos definidos a priori dependiendo de sus características individuales. Se usa principalmente para clasificar y/o hacer predicciones en problemas donde la variable dependiente es de carácter cualitativo. La idea básica consiste en obtener una serie de funciones lineales (llamadas funciones discriminantes) a partir de variables independientes que permiten interpretar las diferencias entre los grupos y clasificar a los individuos en alguna de las subpoblaciones definidas por la variable dependiente. Se parte de p variables (X_1, X_2, \dots, X_p) medidas para (g) grupos de individuos preestablecidos.

3.2 Modelos de Probabilidad

En los modelos de probabilidad, la variable dependiente sólo puede tomar dos valores, cero o uno. Existen tres formas generales de estimar este tipo de modelos: 1) mínimos cuadrados ordinarios, el cual es conocido como el modelo de probabilidad lineal, siendo el menos utilizado por no cumplir en la mayoría de los casos con los axiomas de la probabilidad; 2) el modelo logit, donde la función de distribución que siguen los errores es logística; y 3) el modelo probit, cuando las perturbaciones se asumen con distribución normal.

3.2.1 Modelo de Probabilidad Lineal

Un Modelo de Probabilidad Lineal es aquel en donde la variable independiente es dicotómica (la variable endógena puede tomar dos valores: (0, 1)) y es función de las variables explicativas X_i .

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

La distribución de la muestra en este tipo de modelos se caracteriza por mostrar una nube de puntos de tal forma que las observaciones muestrales se dividen en dos subgrupos. Uno de los cuales es el formado por las observaciones en las que ocurrió el hecho objetivo de estudio, es decir cuando $Y_i = 1$, y el otro, por los puntos muestrales en los que no ocurrió, es decir, $Y_i = 0$. Por tanto, el coeficiente de determinación R^2 no es particularmente útil ya que no es posible que todos los datos se encuentren exactamente en la recta de regresión ($R^2 = 1$).

El modelo lineal de probabilidad, se puede interpretar en términos probabilísticos, en el sentido de que un valor concreto de la recta de regresión mide la probabilidad de que ocurra el hecho objetivo de estudio. Es decir, \hat{Y}_i se puede considerar como la estimación de la probabilidad de que ocurra el hecho objetivo de estudio $Y_i = 1$ siguiendo el siguiente criterio: Valores próximos a cero se corresponde con una baja probabilidad de ocurrencia

del hecho estudiado (menor cuanto más próximos a cero); mientras que a valores próximos a uno se les asigna una probabilidad elevada de ocurrencia (mayor cuanto más próximos a uno).

Cómo lo indican Alamilla-López y Camargo (2009), la forma funcional del Modelo Lineal de Probabilidad (MLP) tiene algunas limitaciones cuando se estima por Mínimos Cuadrados Ordinarios (MCO), ya que no responden algunos supuestos básicos que lo hagan eficientes. Por ejemplo, el coeficiente de determinación en base a la R^2 tiene un valor limitado en los modelos de respuesta dicotómica, la normalidad de las perturbaciones no asegura que tenga una distribución normal, hay estimaciones no acotadas y puede existir heterocedasticidad, lo que restringe la bondad del MLP. Dado este inconveniente, los autores sugieren la aplicación de modelos de respuesta binaria como los modelos Logit y Probit, que típicamente son estimados por el método de máxima verosimilitud, debido a que este estimador tiene buenas propiedades; en particular, es asintóticamente eficiente, es decir, es un estimador más preciso.

3.2.2 Modelo Logit

El análisis logit es una técnica estadística desarrollada para investigar las relaciones entre una variable binaria y una o más variables independientes. En nuestro caso, las variables independientes son los indicadores financieros y el criterio de clasificación de la variable dependiente es de 1 para bancos quebrados y 0 para bancos no quebrados.

Este modelo permite, además de obtener estimaciones de la probabilidad de un suceso, identificar los factores de riesgo que determinan dichas probabilidades, así como la influencia o peso relativo que éstos tienen sobre las mismas.

El modelo de regresión Logit se basa en la función logística:

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

La cual está acotada entre 0 y 1 ya que:

$$\lim_{z \rightarrow -\infty} f(z) = 0, \quad \lim_{z \rightarrow \infty} f(z) = 1,$$

Y dado que la regresión Logit utiliza una función de distribución logística (mientras la regresión Probit utiliza una función de distribución normal estándar), la distribución de sus probabilidades esta entre 0 y 1, presentando un crecimiento no lineal deseado (leves incrementos en los extremos y mayores en la parte central).

El modelo de regresión Logit será de la forma:

$$Y_i = f(Z_i) + u_i, \quad i = 1, \dots, n,$$

Donde $Z_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki}$ y, dados los valores de las variables independientes x_2, \dots, x_k , las probabilidades de que la variable dependiente tome los valores 1 y 0 son:

$$P_r(Y = 1 | x_2, \dots, x_k) = E(Y_i | X = x) = \frac{e^{z_i}}{1+e^{z_i}}$$

$$P_r(Y = 0 | x_2, \dots, x_k) = 1 - \frac{e^{z_i}}{1+e^{z_i}} = \frac{1}{1+e^{z_i}}$$

Con $z_i = \beta_1 + \beta_2 x_{2i} + \dots + \beta_k x_{ki}$.

La estimación en modelos Logit y Probit se realiza mediante el método de Máxima Verosimilitud (MV). En este tipo de modelo no resulta posible interpretar directamente las estimaciones de los parámetros β , ya que son modelos no lineales, por lo que en la práctica, se determina es el signo de los estimadores. Si el estimador es positivo, significará que

incrementos en la variable asociada causan incrementos en $P(Y = 1)$, por el contrario, si el estimador muestra un signo negativo, ello supondrá que incrementos en la variable asociada causarán disminuciones en $P(Y = 1)$.

Gujarati & Dawn (1978) mencionan las siguientes observaciones generales:

- Al emplear el método de máxima verosimilitud, que en general es para muestras grandes, los errores estándar estimados son asintóticos.
- Como resultado, en vez del estadístico t para evaluar la importancia estadística de un coeficiente, se emplea el estadístico (normal estandarizado) Z, por lo que las inferencias se basan en la tabla normal. Si el tamaño de la muestra es razonablemente grande, la distribución t converge a la distribución normal.
- La medida convencional de la bondad de ajuste, R^2 , no es particularmente significativa para los modelos con regresada binaria. Existen diversas medidas similares a R^2 , llamadas pseudo R^2 . Sin embargo, en los modelos con regresada binaria, la bondad del ajuste tiene una importancia secundaria. Lo que interesa son los signos esperados de los coeficientes de la regresión y su importancia práctica y/o estadística.
- A fin de probar la hipótesis nula respecto de que todos los coeficientes de pendiente son simultáneamente iguales a cero, el equivalente de la prueba F en el modelo de regresión lineal es el estadístico de la razón de verosimilitud (RV). Con la hipótesis nula, el estadístico RV sigue la distribución X^2 con gl (grados de libertad) igual al número de variables explicativas.

Un modelo logit permite calcular la probabilidad que tienen las empresas de quebrar en función de indicadores financieros, que especifican la situación financiero de los bancos, que repercuten directamente en esa probabilidad de quiebra de manera diferente.

3.2.3 Modelo Probit

El modelo de estimación que surge de una función de distribución acumulativa FDA normal se conoce comúnmente como modelo probit:

$$\Phi(z) = P(Z \geq z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{s^2}{2}} ds,$$

Donde $Z \sim N(0,1)$ y es tal que, dados los valores x_2, \dots, x_k de las variables independientes, se verifica que:

$$P(Y = 1 | x_2, \dots, x_k) = \Phi(z_i),$$

Con $z_i = \beta_1 + \beta_2 x_{2i} + \dots + \beta_k x_{ki}$ tal que:

$$Y = \begin{cases} 1 & \text{si } z_i > 0 \\ 0 & \text{si } z_i < 0 \end{cases}$$

En la actualidad los modelos más sofisticados que se están utilizando a nivel de investigación son los llamados modelos de probabilidad condicional, logit y probit, sin embargo, como lo describe Gujarati & Dawn (1978), en la práctica, muchos investigadores eligen el modelo logit debido a su comparativa simplicidad matemática; la principal diferencia es que la probabilidad condicional P_i se aproxima a cero o a uno con una tasa menor en el modelo logit, en comparación con el probit.

Según un análisis comparativo realizado por los autores Laffarga, Martín & Vázquez (1987), en donde comparan el modelo lineal discriminante, técnica implementada por Altman (1968), con el modelo logit, los porcentajes de clasificación correcta de un modelo logit resultan más elevados. Además, el porcentaje de aciertos en las empresas fracasadas es mucho mayor con el modelo logit que con el modelo discriminante, lo cual es altamente significativo teniendo en cuenta que el coste de clasificación errónea de las empresas fracasadas es mucho mayor. Adicionalmente, Lennox (1999) realizó un estudio en donde

evaluó los méritos de usar modelos probit y logit bien especificados en lugar de análisis discriminante, en el que concluyó, que los modelos logit y probit tienen mejor nivel de predicción.

3.3 Modelos de Regresión

Existen tres tipos de datos: series de tiempo, de corte transversal y de panel. En los datos de series de tiempo se observan los valores de una o más variables durante un periodo (por ejemplo, el PIB durante varios trimestres o varios años). En los datos de corte transversal, se recopilan valores de una o más variables para varias unidades muestrales, o entidades, en el mismo punto en el tiempo (por ejemplo, la tasa de criminalidad en 50 estados de Estados Unidos en un año determinado). En los datos de panel, la misma unidad de corte transversal (una familia, una empresa o un estado) se estudia a lo largo del tiempo. En resumen, en los datos de panel está la dimensión del espacio y la del tiempo.

Existen otros nombres para los datos de panel, como datos agrupados (agrupamiento de observaciones de series de tiempo y de corte transversal); combinación de datos de series de tiempo y de corte transversal; datos de micropanel; datos longitudinales (un estudio a lo largo del tiempo de una variable o grupo de sujetos); análisis de historia de sucesos (por ejemplo, el estudio del movimiento de sujetos a lo largo del tiempo y a través de sucesivos estados o condiciones); análisis de generaciones (por ejemplo, dar seguimiento a la trayectoria profesional de los egresados en 1965 de una escuela de administración). Si bien hay variaciones sutiles, todos estos nombres en esencia tienen una connotación de movimiento de unidades de corte transversal a lo largo del tiempo.

Gujarati, D.N., & Porter, D.C. (1978) mencionan las siguientes ventajas de los datos de panel respecto de los datos de corte transversal o de series de tiempo:

- Como los datos de panel se refieren a individuos, empresas, estados, países, etc., a lo largo del tiempo, lo más seguro es la presencia de heterogeneidad en estas

unidades. Las técnicas de estimación de datos de panel toman en cuenta de manera explícita tal heterogeneidad, al permitir la existencia de variables específicas por sujeto.

- Al combinar las series de tiempo de las observaciones de corte transversal, los datos de panel proporcionan “una mayor cantidad de datos informativos, más variabilidad, menos colinealidad entre variables, más grados de libertad y una mayor eficiencia”.
- Al estudiar las observaciones en unidades de corte transversal repetidas, los datos de panel resultan más adecuados para estudiar la dinámica del cambio. Los conjuntos de datos respecto del desempleo, la rotación en el trabajo y la movilidad laboral se estudian mejor con datos de panel.
- Los datos de panel permiten estudiar modelos de comportamiento más complejos. Por ejemplo, fenómenos como las economías de escala y el cambio tecnológico son más maniobrables con los datos de panel que con los datos puramente de corte transversal o de series de tiempo.
- Al hacer disponibles datos para varios miles de unidades, los datos de panel reducen el sesgo posible si se agregan individuos o empresas en conjuntos numerosos.

Los autores concluyen, que los datos de panel enriquecen el análisis empírico de manera que no sería posible con sólo datos de corte transversal o de series de tiempo.

3.4 Redes Neuronales

Una de las últimas técnicas aplicables a la predicción de la quiebra son las Redes Neuronales Artificiales RNA (o “Artificial Neural Networks”), cuya aplicación, según Ringeling (2004), ha mostrado su eficiencia para la solución de problemas complejos y no lineales, en el cual existe una amplia base de datos y en donde no existe una modelación matemática. La quiebra cumple con estas tres características.

Para el autor, las redes neuronales pueden entenderse como modelos multi-ecuacionales o multietapas, en los que el output de unos constituye el input de otros, en el caso de las redes

multicapas, existen etapas en las cuales las ecuaciones operan en forma paralela. Los modelos de redes neuronales, utilizan inputs para generar un output en la forma de una proyección. La diferencia radica en que las redes neuronales incorporan inteligencia artificial en el proceso que conecta los inputs con los outputs. El establecimiento de las Redes Neuronales Artificiales es metodología poderosa para la predicción de quiebra.

Martín del Brío y Sanz (1997), define las redes neuronales artificiales (R.N.A.) como sistemas de procesamiento que copian esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades. En consecuencia, son una clase de modelos no lineales flexibles que se caracterizan por ser sistemas paralelos (cuentan con una gran cantidad de neuronas o procesadores elementales 'PE', cada una de las cuales trabaja paralelamente con una pequeña parte de un problema mayor.), distribuidos (cuentan con muchos PEs a través de los cuales distribuyen su memoria.) y adaptativos (tienen la capacidad de adaptarse al entorno modificando sus pesos y sinapsis de manera de encontrar una solución aceptable al problema.). Según estos autores, estos tres conceptos se traducen en un mejor rendimiento y en una mayor velocidad de procesamiento.

En una red neural hay pares de inputs y outputs que son usados para entrenar la red. Pueden haber múltiples inputs (variables explicativas) y múltiples outputs (proyecciones de diferentes variables). Entre los inputs y los outputs hay una capa -o múltiples capas- de procesamiento que imitan el trabajo del cerebro humano; luego, dado un nuevo conjunto de inputs, la red puede producir un nuevo output (proyección) sobre la base de lo que aprendió de los pares de inputs y outputs que le fueron provistos. Estos modelos se caracterizan porque en ellos el resultado es conocido y la red se entrena a sí misma hasta que es capaz de predecir aquel resultado asociado con los datos de entrada.

Los estudios con redes neuronales en el área de la predicción de quiebra se pueden dividir en dos grupos según las decisiones que se tomaron para la generación del experimento, por un lado están las variables (ej. Indicadores financieros) que se eligieron y, por el otro, el tipo de arquitectura neuronal que se ocupó.

Para seleccionar el tipo de arquitectura neuronal, Ringeling (2004) menciona que el mayor consenso en relación al sistema o la red neuronal a usar, es el uso de la Percepción Multicapa 'MLP' (Multilayer Perception). En las aplicaciones vistas, dos tercios específicamente ocupan MLP y cuatro intenta hacer una comparación con MLP y otros sistemas neuronales. El MLP continúa siendo la referencia para los problemas de clasificación.

Ringeling (2004) da algunas razones para usar el MLP: primero, muchos estudios se han realizado sobre MLP y sus bondades, especialmente para problemas de clasificación; segundo, está el tema de la disponibilidad de datos de empresas no quebradas y quebradas, la cual concuerda con las variables de entrada y salida requeridas por la herramienta MLP, los datos de input y output concuerdan con los ratios financieros y la separación en dos grupos (quebradas y no quebradas), respectivamente. Y, tercero, su construcción y uso son relativamente simples.

Collantes (2001) define los siguientes componentes en la arquitectura de una red: entradas, capas y salidas; así mismo, la interconexión y dirección de la red, que se refiere a la forma en que se interrelacionan las neuronas.

- Entradas: canal de alimentación de la red, donde se deben establecer el número de entradas de acuerdo al caso de estudio. Los datos de entrada son numéricos y en muchos casos puede ser conveniente escalarlos o procesarlos (convertirlos a datos entre 0 y 1 o -1 y 1).
- Capas: también se les denomina capas ocultas o intermedias, por encontrarse entre la entrada y la salida de la red. Con frecuencia no es suficiente una sola neurona para resolver el problema, sino que se requiere de varias neuronas que operen en paralelo, lo que se denomina capa.

- Salidas: son neuronas o nodos de salida. El número de salidas de la red dependerá del problema en estudio. La salida de la red deberá estar expresada en la misma escala de los datos originales.
- Interconexión: se pueden clasificar como Totalmente Conectadas (la salida de una neurona de la capa i es entrada a todas las neuronas de la capa $i+1$) o Localmente Conectadas (la salida de una neurona de la capa i es entrada a una región de neuronas de la capa $i+1$).
- Dirección: se pueden clasificar en Redes de Alimentación Adelantada (la información fluye solamente de la entrada a la salida), Redes Retroalimentadas (las salidas de las neuronas de una capa pueden ser entradas de las neuronas de las capas anteriores), Redes de Alimentación Lateral (las salidas de las neuronas pueden ser entradas de neuronas de la misma capa) y Redes Recurrentes (existen lazos cerrados).

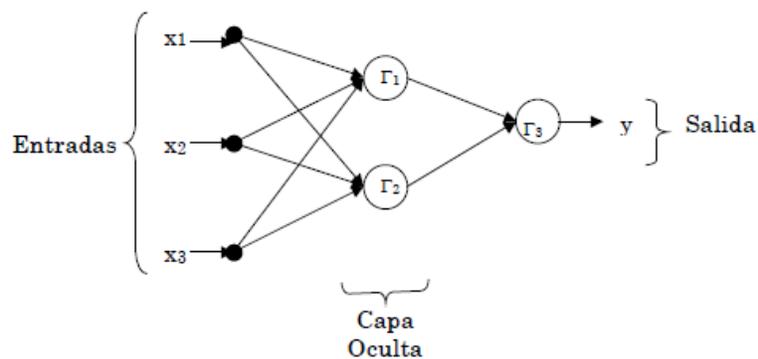


Figura 1. Red Unicapa

En la Figura 1. Se observa un ejemplo de red unicapa totalmente conectada, de alimentación adelantada, con tres entradas, dos neuronas o nodos en la capa oculta, y una de salida.

3.5 Ventajas y Desventajas

En la Tabla 2, se observa un cuadro comparativo con las ventajas y desventajas de cada modelo revisado en el marco teórico:

Tabla 2.
Ventajas y Desventajas

Modelo	Ventajas	Desventajas
Modelo Discriminante	<ul style="list-style-type: none"> ▪ Múltiples Variables Dependientes. ▪ Tasa de errores reducidas. ▪ Interpretación más sencilla entre diferencias entre grupos: cada función discriminante mide algo único y diferente. 	<ul style="list-style-type: none"> ▪ Cada función discriminante debe seguir una distribución normal. ▪ Se asume que cada función discriminante debe tener igualdad de varianzas. ▪ Se asume relaciones lineales entre variables. ▪ Ninguna variable puede estar perfectamente correlacionada con una combinación lineal de las otras variables (Multicolinealidad).
Modelo Lineal	<ul style="list-style-type: none"> ▪ Simplicidad en la estimación de los coeficientes. ▪ Directa interpretación de los coeficientes. Los coeficientes del modelo lineal se interpretan como probabilidades marginales (efectos marginales) de que ocurra el evento respecto al evento base 	<ul style="list-style-type: none"> ▪ El coeficiente de determinación R² está subestimado. ▪ La normalidad de las perturbaciones no asegura que tenga una distribución normal. ▪ Hay estimaciones no acotadas y puede existir heterocedasticidad, lo que restringe la bondad.
Modelo Logit	<ul style="list-style-type: none"> ▪ Los porcentajes de clasificación correcta son más elevados. ▪ El porcentaje de aciertos de empresas fracasadas es altamente significativo. ▪ Mejor nivel de predicción. ▪ Al ser la variable dependiente dicotómica no necesita que se 	<ul style="list-style-type: none"> ▪ El tamaño de muestra debe ser grande, ya que tiene como método de estimación la máxima verosimilitud.

Modelo	Ventajas	Desventajas
	cumple el supuesto de normalidad.	
Modelo Probit	<ul style="list-style-type: none"> ▪ Se pueden obtener estimaciones de probabilidad para la ocurrencia de un suceso. 	<ul style="list-style-type: none"> ▪ El tamaño de muestra debe ser grande, ya que tiene como método de estimación la máxima verosimilitud. ▪ Los coeficientes no tienen una interpretación directa.
Redes Neuronales	<ul style="list-style-type: none"> ▪ Pueden sintetizar algoritmos a través de un proceso de aprendizaje. ▪ No es necesario conocer los detalles matemáticos. ▪ La solución de problemas no lineales es uno de sus fuertes. 	<ul style="list-style-type: none"> ▪ Se deben entrenar para cada problema y es necesario realizar múltiples pruebas para determinar la arquitectura adecuada. ▪ Requiere la definición de muchos parámetros antes de poder aplicar la metodología. ▪ Efecto “Caja Negra”, en donde no se permite conocer en una red el impacto que tiene cada variable dependiente sobre la variable independiente.

De acuerdo con la Tabla 2 y teniendo en cuenta los objetivos del presente trabajo de grado, se consideró que el modelo adecuado para la predicción de quiebra de bancos Estadounidenses, es el modelo Logit.

Lo anterior, se determinó teniendo en cuenta que se busca poder realizar un análisis financiero detallado de cada variable significativa en la predicción de quiebra; y que en el caso de las Redes Neuronales existe el efecto “Caja Negra” por lo tanto para el estudio que se pretende el modelo adecuado es el Logit.

4 METODOLOGIA

4.1 Muestra:

Se seleccionó, de forma aleatoria, una muestra de 200 bancos quebrados y 300 bancos que operan actualmente en Estados Unidos. La información para cada uno de ellos se obtuvo de

la Corporación Federal Aseguradora de Depósitos (FDIC, por sus siglas en inglés). Adicionalmente se incluyeron los bancos más grandes de Estados Unidos como por ejemplo J.P Morgan, Citibank, Bank of America, etc.

La FDIC es una agencia independiente del gobierno de los Estados Unidos que protege a los consumidores contra la pérdida de sus depósitos si un banco o asociación de ahorros asegurado por la FDIC se cierra. El seguro de la FDIC está respaldado por el gobierno de los Estados Unidos y asegura los depósitos en la mayoría de los bancos y asociaciones de ahorros.

La entidad, en su página web (www.fdic.gov), publica los estados financieros de los bancos, con información anual desde el año 1992 hasta el 2001, y de manera trimestral desde marzo 31 de 2002 a la fecha. Actualmente se encuentran en operación un total de 5.643 bancos en operación, y desde 2001 hasta 2014 han quebrado un total de 532 bancos.

En la Tabla 3, se puede observar la distribución de los años de quiebra de los Bancos Quebrados escogidos aleatoriamente.

Tabla 3.
Distribución periodos de Quiebra

Año	Bancos Quebrados	Porcentaje (%)
2007	2	1.00%
2008	21	10.54%
2009	76	38.18%
2010	59	29.65%
2011	28	14.08%
2012	9	4.53%
2014	4	2.01%

Como se puede observar en la Tabla 3, el 67,83% del total de bancos, quebraron entre 2009 y 2010, siendo estos dos periodos determinantes a la hora de evaluar cuáles factores incidieron en su quiebra, sin embargo, la regulación post crisis cambio el contexto y las

normas con las que los bancos operan (Basilea II y Basilea III) por lo que tomar una muestra de bancos quebrados entre 2011 y 2014 es igual de significativo.

En la Tabla 4, se puede observar la información financiera de los bancos que se encuentra disponible en la FDIC.

Tabla 4.
Información Financiera Disponible

No.	Información Financiera
1	Activos y Pasivos
2	Ingresos y Gastos
3	Indicadores de Rendimiento y Condiciones
4	Indicadores de Rendimiento (% , anualizados)
5	Indicadores de Condición (%)

Se descargó la información trimestral para cada banco desde el primer trimestre de 2002 hasta el cuarto trimestre de 2014. Se obtuvieron 27 archivos en Excel por banco por lo que fue necesario consolidar dicha información en un solo archivo de Excel mediante el desarrollo de una macro en Visual Basic.

Una vez se obtuvo la base de bancos consolidada se realizó el cálculo por banco de los indicadores que se van a definir en el punto 4.2. A continuación se consolidaron los trimestres por año usando los siguientes métodos: un promedio y una mediana de los indicadores por año.

Para los bancos quebrados se utilizó la información de los 3 años anteriores a la quiebra del mismo, en cambio para los bancos No Quebrados se tomaron los datos de los años 2011 a 2014. Teniendo la base de datos consolidada por tres años, se agrupo esta información por los 3 años escogidos, este cálculo se realizó para cada banco y para cada tipo de indicador.

4.2 Indicadores:

Las variables fueron escogidas bajo los siguientes criterios:

- Indicadores de Rendimiento (Performance Ratios)
- Indicadores de Condición (Condition Ratios)
- Otros Indicadores

A continuación se realizó una breve descripción de cada variable definida, así mismo se identificó que tipo de impacto (Positivo o Negativo) tendrá dicha variable sobre la probabilidad de quiebra:

Indicadores de Rendimiento (Performance Ratios):

- 1. Margen de Interés Neto (Net Interest Margin):** Corresponde a la diferencia entre los ingresos por intereses y los gastos por intereses como porcentaje de los activos productivos promedio (préstamos e inversiones que generen ingresos por intereses o dividendos). Es la diferencia entre lo pagado por la entidad financiera a sus ahorradores y la tasa que la entidad cobra a sus clientes por créditos otorgados. El margen neto siempre debe ser positivo ya que señala que la institución financiera está generando ingresos suficientes en sus activos para cubrir su costo de fondeo (productos de ahorro y otras fuentes de fondos), sin embargo, la FDIC divide dicho indicador sobre los Activos Productivos Promedio, por lo que una buena calidad en su cartera y el portafolio de inversiones, disminuyen el valor del indicador.
Se espera que el impacto en la probabilidad de quiebra sea positivo entre mayor sea el indicador.
- 2. Ingresos Distintos a Intereses (Noninterest Income to Assets):** Ingresos derivados de servicios bancarios y de otras fuentes distintas de los activos que generan intereses como porcentaje de los activos promedio. Un alto valor indica que la entidad está generando ingresos distintos a intereses, por lo que su cartera no estaría siendo productiva, y el banco buscaría otras fuentes de ingresos distintas a su core (generar ingresos por cartera). Se espera que entre más alto sea este indicador, el impacto en la probabilidad de quiebra sea positivo.
- 3. Utilidad Operacional como porcentaje del activo promedio (Net Operating Income to Assets):** Este indicador muestra la utilidad operacional (utilidad después

de gastos operativos) como un porcentaje de los activos. Un valor alto implica una mayor rentabilidad después de descontar los gastos operativos, por lo tanto se espera que tenga un impacto negativo en la probabilidad de quiebra.

4. **Rentabilidad sobre el Activo (ROA):** Este indicador mide la eficiencia y el rendimiento operacional de un banco, se determina a través de la rentabilidad del activo. Un mayor valor indica una alta eficiencia y un alto rendimiento operativo, por lo tanto se espera que tenga un impacto negativo en la probabilidad de quiebra.
5. **Rentabilidad antes de Impuestos como porcentaje del Activo (Pretax Return on Assets):** Este indicador permite identificar la habilidad de un banco para administrar y operar sus reservas. Un mayor valor implica una alta eficiencia y un alto rendimiento de sus reservas, por lo tanto se espera que el impacto en la probabilidad de quiebra sea negativo.
6. **Rentabilidad sobre el Patrimonio (ROE):** Este es una medida de la rentabilidad sobre los fondos de los accionistas y por lo tanto cuantifica la eficiencia de un banco en la generación de ganancias por cada unidad de los fondos de los accionistas. Un mayor valor implica una mayor rentabilidad, por lo tanto se espera que tenga un impacto negativo en la probabilidad de quiebra.
7. **Cancelaciones Netas (Net charge-offs to Loans and Leases):** Este indicador es ampliamente usado para medir el porcentaje de “deuda mala” que un banco tiene en un periodo determinado y permite determinar qué porcentaje de la cartera se podrían recuperar. La FDIC lo calcula como la diferencia entre la deuda mala por cobrar menos recuperaciones como porcentaje de la cartera promedio. Un alto valor implica una cantidad mayor de “deuda mala” que posee el banco, por lo tanto se espera que tenga un impacto positivo en la probabilidad de quiebra.
8. **Ganancias en Cobertura de Cartera Castigada (Earnings coverage of net charge-offs (x)):** Este indicador se calcula como la Utilidad Neta Antes de Impuestos y otras partidas extraordinarias, más provisiones en cartera, más ganancias o pérdidas en títulos al vencimiento, más ganancias o pérdidas en títulos disponibles para la venta, como porcentaje de la diferencia de la Cartera Castigada y las Recuperaciones. Un alto valor implica un mayor volumen en recuperaciones de

cartera castigada, y ganancias en la operación y el portafolio de inversiones, por lo que se espera que su impacto sea negativo en la probabilidad de quiebra.

- 9. Eficiencia (Efficiency Ratio):** Este indicador se mide como la diferencia entre los gastos Operacionales menos la amortización de activos intangibles como porcentaje de los ingresos totales, y permite medir la habilidad del banco para convertir sus recursos en ingresos, por tanto, un valor alto de la eficiencia implica un incremento en los costos o una disminución en los ingresos, por lo tanto se espera que tenga un impacto positivo en la probabilidad de quiebra.

Indicadores de Condición (Condition Ratios):

- 1. Activos Productivos como porcentaje de los Activos Totales (Earning Assets to Total Assets):** Los activos productivos incluyen todos los activos que generan ingresos de intereses, lo que refleja la principal fuente de ingresos de un banco. Un valor alto refleja una buena calidad de los activos, por lo tanto se espera que tenga un impacto negativo en la probabilidad de quiebra.
- 2. Provisiones para Insolvencia como porcentaje de la Cartera Total (Loss Allowance to Loans and Leases):** Es un indicador de cubrimiento de cartera, y representa el porcentaje de provisiones realizado por la entidad frente al total de la cartera. Un valor alto implica un riesgo alto del portafolio de la cartera, por lo tanto se espera que su impacto con relación a la probabilidad de quiebra sea positivo.
- 3. Préstamos netos como porcentaje de los activos totales (Net Loans and Leases to Assets):** Es un indicador de estructura que muestra que porcentaje representan las colocaciones en préstamos sobre los activos totales. Es deseable que todos los recursos que la entidad capte sean orientados hacia la principal actividad del banco, sin excesos que puedan presionar su liquidez. Sin embargo, la FDIC toma los préstamos netos (netos de provisiones), por lo que entre más provisionada esté la cartera bruta más riesgo de incumplimiento implica (mayores probabilidades de default de cada cliente conlleva a mayores provisiones). Este indicador se debe ver en detalle y hacer detallado de cada banco, ya que un indicador muy elevado podría

generar presiones a la liquidez y un indicador muy bajo habla del riesgo de la cartera (mayores provisiones).

4. **Préstamos netos como porcentaje de los depósitos totales (Net Loans and Leases to Deposits):** Este indicador mide la liquidez de un banco a través de la relación entre los fondos de los que dispone en sus depósitos con respecto al volumen de créditos concedidos a clientes. Si el porcentaje del indicador es muy elevado, implica que la entidad tendría dificultades para responder a una demanda masiva de dinero. Se espera que entre más alto sea el indicador (por encima de 100 significa que el banco no tiene suficientes depósitos de clientes para cubrir sus colocaciones de cartera), su impacto en la probabilidad de quiebra sea positivo.
5. **Relación de Solvencia Básica (Total risk-based capital ratio):** Se define como el valor del Patrimonio Básico Ordinario dividido por el valor de los activos ponderados por nivel de riesgo crediticio y de mercado.

Otros Indicadores:

1. **Cartera y Leasing / Depósitos y Exigibilidades:** Es un indicador de estructura y mide la colación eficiente de las captaciones. Si los depósitos son superiores a la cartera, la entidad está gastando los recursos costosos en actividades diferentes a la colocación en cartera, lo cual puede afectar su productividad. Se espera que entre menor sea el indicador, el impacto en la probabilidad de quiebra sea positivo.
2. **Deuda Subordinada / Patrimonio:** Este indicador representa el porcentaje total del patrimonio que su fuente es a través de deuda subordinada. La deuda subordinada es la forma menos permanente del capital y con un riesgo más alto (en caso de que el emisor tenga problemas para pagar dichos títulos sus inversores estarán en la parte baja de la lista de acreedores, primero cobrarán los acreedores ordinarios y luego, si queda un remanente en los activos, podrán cobrar los poseedores de este tipo de deuda, por lo que ofrecen una rentabilidad mayor que otros activos de deuda), por lo tanto se busca un menor valor de dicho indicador. Se espera que entre menor sea el indicador, el impacto en la probabilidad de quiebra sea negativo.

3. **Patrimonio / Activo:** Este indicador puede ser visto como una medida de capitalización, ya que representa la proporción de capital contable que respalda los activos de la entidad. Sin embargo, se debe tener en cuenta que entre más riesgo tenga la cartera del banco (principal cuenta del activo) más capital va a requerir, así, a mayor riesgo de cartera, más provisiones y más capital, por lo tanto se espera que entre más alto sea el indicador mayor sea su impacto en la probabilidad de quiebra.
4. **Reserva = Efectivo / Depósitos.** Este indicador es una medida de liquidez, y representa la proporción de recursos de inmediata disponibilidad de los que la entidad dispone para hacer frente a sus obligaciones de captación.
5. **Pasivo / Patrimonio:** Este indicador permite medir el apalancamiento de un banco e implica con cuanta deuda se está financiando, un valor alto de este indicador generalmente implica que un banco ha sido agresivo al apalancar su crecimiento a través de deuda y esto podría afectar rentabilidad a estar sujeto al riesgo de tasas de interés altas. De acuerdo con lo anterior, se espera un impacto positivo en la probabilidad de quiebra.
6. **Activos Líquidos / Total Activos:** Este indicador se calcula cómo la suma del efectivo y equivalente y los títulos valores (securities) como porcentaje de los activos totales, esto permite medir el porcentaje activos que se hacen líquidos con mayor facilidad. Un mayor valor de este indicador implica una mayor liquidez, por lo tanto se espera que su impacto con relación a la probabilidad de quiebra sea negativo.

En la Tabla 5 se pueden observar los indicadores definidos anteriormente con su respectivo código de identificación.

Tabla 5.
Indicadores

Código	Indicador
MargenN_Int	Margen de Interés Neto
Ing_Dint	Ingresos Distintos a Intereses
UtilO_Actpro	Utilidad Operacional porcentaje del activo promedio

Código	Indicador
ROA	Rentabilidad sobre el Activo (ROA)
Rent_Pretax	Rentabilidad antes de Impuestos como porcentaje del Activo
ROE	Rentabilidad sobre el Patrimonio (ROE)
ChrO_Car	Cancelaciones Netas
Util_ChrO	Ganancias en Cobertura de Cartera Castigada
Eficiencia	Eficiencia
Actprod_ActTot	Activos Productivos como porcentaje de los Activos Totales
ReserC_Ctot	Reserva de Perdidas en la Cartera como porcentaje de la Cartera total
Cart_ActTot	Préstamos netos como porcentaje de los activos totales
Cart_DepTot	Préstamos netos como porcentaje de los depósitos totales:
Rel_Sol	Relación de Solvencia Básica
Cart_Dep	Cartera y Leasing / Depósitos y Exigibilidades
DeuS_Patri	Deuda Subordinada / Patrimonio
Patri_Act	Patrimonio / Activo
Reser	Reserva (Efectivo / Depósitos)
Pasiv_Patri	Pasivo / Patrimonio:
ActL_ActTot	Activos Líquidos / Total Activos

4.3 Modelo de Regresión Logística – Logit

De acuerdo con el análisis de la bibliografía existente, se decidió implementar un modelo de Regresión Logística – Logit.

Aplicando la teoría del modelo Logit para el cálculo de la probabilidad de quiebra de los bancos estadounidenses. Existen únicamente dos opciones: que el banco se quiebre, lo cual se denotara con el valor 1; y que el banco no se quiebre, lo cual se denotara con el valor 0.

En la Tabla 6, se puede observar la definición de la Variable Y.

Tabla 6.
Variable Y

Estado	Y
No Quebrados	0
Quebrados	1

Adicionalmente, se definió la matriz X como la matriz de variables independientes que denotan los atributos que caracterizan un banco en quiebra. De igual manera se definió β como el vector de parámetros que miden el impacto de los indicadores sobre la probabilidad de quiebra. Teniendo en cuenta lo anterior a continuación se muestra el modelo:

Se debe aclarar que p es la probabilidad de que Y=1

$$p = \frac{1}{1 + e^{-z}} = \frac{1}{1 + e^{-(\beta_0 + X_1\beta_1 + \dots + X_k\beta_k)}}$$

Dónde:

X = Son las variables a incluir en el modelo

B = Son los Parámetros del modelo.

p = es la probabilidad de que Y sea igual a 1, es decir que sea un banco quebrado.

Una vez definido el modelo, se verificó la base de datos y se definieron las variables independientes que se utilizarán para explicar la variable dependiente (Quebrado o No Quebrado), se escogió el programa estadístico SPSS Ver. 22 para la estimación del modelo usando la opción de Regresión Logística Binaria que incluye este paquete estadístico.

A partir de una regresión logística binaria y usando el método de selección por pasos hacia adelante que contrasta la entrada basándose en la significación del estadístico de puntuación y contrasta la eliminación basándose en la probabilidad del estadístico de Wald. Se encontraron los resultados que se analizarán y explicarán a continuación.

Tabla 7.
Pruebas R Cuadrado

Prueba	Estadístico
R cuadrado de Cox y Snell	0.424

R cuadrado de Nagelkerke 0.758

En la Tabla 7, se pueden observar los resultados de las pruebas de R cuadrado de Cox y Snell y el R cuadrado de Nagelkerke los cuales permiten evaluar la validez global del modelo. A continuación se realizara una breve descripción de cada uno de estos:

- **R Cuadrado de Cox y Snell:** Es un coeficiente de determinación que se utiliza para estimar la proporción de varianza de la variable dependiente explicada por las variables independientes. La R cuadrado de Cox y Snell se basa en la comparación del log de la verosimilitud para el modelo respecto al log de la verosimilitud para un modelo de línea base. Sus valores oscilan entre 0 y 1.

Para este caso el valor es de 0,424, el cual indica que el 42,4% de la variación de la variable dependiente es explicada por las variables incluidas en el modelo. Esto implica que solo un 42,4% de la probabilidad de quiebra es explicada por las variables incluidas en el modelo. Cabe mencionar que esta R cuadrado es un intento de aproximación de los R cuadrados normales, donde por lo general estos indicadores toman valores bajos

- **R Cuadrado de Nagelkerke:** Este estadístico indica en que porcentaje las variaciones de la variable dependiente son explicadas por las variables independientes. A través de este se puede establecer la bondad del ajuste.

Para este caso el R cuadrado de Nagelkerke muestra un valor de 75,8%, el cual indica que el 75,8% de las variaciones de la variable dependiente son explicadas por las variables independientes. Cabe mencionar que esta R cuadrado es un intento de aproximación de los R cuadrados normales, donde por lo general estos indicadores toman valores bajos

Tabla 8.
Variables del Modelo

Indicador	Beta	Odds
MargenN_Int	1.258***	3.519
Ing_Dint	0.996***	2.707
ROA	-1.744***	0.175
Util_ChrO	0.002***	1.002
Cart_ActTot	0.002***	1.002
Rel_Sol	-0.660***	0.517
Patri_Act	0.871**	2.389
Reser	-1.008***	0.365
Pasiv_Patri	1.408***	4.088
Constante	-15.538	0.000

Nota: *** Significancia al 1%; ** Significancia al 5%; *Significancia al 10%.

En la Tabla 8, se observa que 9 de las 20 variables incluidas eran significativas por lo que se mantienen en el modelo, por lo tanto 11 variables no fueron significativas y se pueden observar en la Anexo 1.

Adicionalmente en la Tabla 8 se pueden observar los coeficientes ODDS del modelo, estos coeficientes son el cociente entre la probabilidad de que un evento ocurra frente a la probabilidad de que no ocurra.

En el caso en que el coeficiente Odds sea mayor a 1 la relación es positiva, es decir que la presencia del factor se asocia a la mayor ocurrencia del evento. En cambio si el resultado del coeficiente de Odds es menor a 1 la relación es negativa, es decir que la presencia del factor no se asocia con la mayor ocurrencia del evento.

Cuando el resultado del coeficiente de Odds es igual a 1 no hay relación entre las variables, es decir que la cantidad de veces que el evento ocurra va a ser igual con o sin la presencia de la variable, la relación es 1:1.

Por lo tanto y de acuerdo a la Tabla 8, se pueden interpretar de la siguiente manera:

- **Margen de Interés Neto (MargenN_Int):** Por cada Banco No Quebrado en donde aumenta el Margen de Interés Neto en un 1%, se da una ocurrencia de 3,5 Bancos Quebrados en donde aumenta en un 1% el Margen de Interés Neto. Por lo tanto tiene una relación de 1:3,5.
- **Ingresos Distintos a Intereses (Ing_Dint):** Por cada Banco No Quebrado en donde aumentan los Ingresos Distintos a Intereses en un 1%, se da una ocurrencia de 2,7 Bancos Quebrados en donde aumentan en un 1% los Ingresos Distintos a Intereses. Por lo tanto tiene una relación de 1:2,7.
- **Rentabilidad sobre el Activo - ROA (ROA):** Por cada Banco No Quebrado en donde aumenta el ROA en un 1%, se da una ocurrencia de 0,17 Bancos Quebrados en donde aumentan en un 1% el ROA. Por lo tanto tiene una relación de 1:0,17.
- **Ganancias en Cobertura de Cartera Castigada (Util_Chro):** Por cada Banco No Quebrado en donde aumentan las Ganancias en Cobertura de Cartera Castigada en una vez, se da una ocurrencia de 1 Banco Quebrado en donde aumentan en una vez las Ganancias en Cobertura de Cartera Castigada. Por lo tanto tiene una relación de 1:1.
- **Préstamos Netos como porcentaje de los Activos Totales (Cart_ActTot):** Por cada Banco No Quebrado en donde aumentan los Prestamos Netos como Porcentaje de los Activos Totales en un 1%, se da una ocurrencia de 1 Banco Quebrado en donde aumentan en un 1% los Prestamos Netos como Porcentaje de los Activos Totales. Por lo tanto tiene una relación de 1:1.
- **Relación de Solvencia Básica (Rel_Sol):** Por cada Banco No Quebrado en donde aumentan la Relación de Solvencia Básica en un 1%, se da una ocurrencia de 0,5 Bancos Quebrados en donde aumentan en un 1% la Relación de Solvencia Básica. Por lo tanto tiene una relación de 1:0,5.

- **Patrimonio / Activo (Patri_Act):** Por cada Banco No Quebrado en donde aumentan la razón Patrimonio sobre Activo en un 1%, se da una ocurrencia de 2,39 Bancos Quebrados en donde aumentan en un 1% la razón Patrimonio sobre Activo. Por lo tanto tiene una relación de 1:2,39.
- **Reserva = Efectivo / Depósitos (Reser):** Por cada Banco No Quebrado en donde aumentan la razón de Reserva en un 1%, se da una ocurrencia de 0,36 Bancos Quebrados en donde aumentan en un 1% la razón de Reserva. Por lo tanto tiene una relación de 1:0,36.
- **Pasivo / Patrimonio (Pasiv_Patri):** Por cada Banco No Quebrado en donde aumentan la razón Pasivo sobre Patrimonio en un 1%, se da una ocurrencia de 4 Bancos Quebrados en donde aumentan en un 1% la razón Pasivo sobre Patrimonio. Por lo tanto tiene una relación de 1:4.

4.3.1 Tablas de Clasificación

Kohavi & Provost (1998), definieron la matriz de confusión como un conjunto de información de clasificación actual. En donde la matriz de confusión contiene información actual y predicciones realizada por un sistema de clasificación. El rendimiento de este sistema es evaluado usando información contenida en la matriz, la Tabla 9 muestra la matriz de clasificación para dos clasificadores de dos clases:

Tabla 9.
Tabla de Clasificación

		Predicción	
		Negativo	Positivo
Actual	Negativo	a	b
	Positivo	c	d

Los datos de la matriz de clasificación, tienen los siguientes significados:

- a es el número de predicciones correctas en la cual un dato es negativo.
- b es el número de predicciones incorrectas en la cual un dato es positivo.
- c es el número de predicciones incorrectas en la cual un dato es negativo.
- d es el número de predicciones correctas en la cual un dato es positivo.

Algunos de los términos estándar se han definido para la matriz de dos clases:

1. **Exactitud:** La exactitud es la proporción del número total de predicciones que fueron correctas, se determina a partir de la siguiente ecuación:

$$Exactitud = \frac{a + b}{a + b + c + d}$$

2. **Verdadera Tasa Positiva:** Es la proporción de los datos positivos que se identificaron correctamente, se determina a partir de la siguiente ecuación:

$$Verdadera Tasa Positiva = \frac{d}{c + d}$$

3. **Falsa Tasa Positiva:** Es la proporción de los datos negativos que se identificaron incorrectamente como positivos, se determina a partir de la siguiente ecuación:

$$Falsa Tasa Positiva = \frac{b}{a + b}$$

4. **Verdadera Tasa Negativa:** Es la proporción de los datos negativos que se identificaron correctamente, se determina a partir de la siguiente ecuación:

$$Verdadera Tasa Negativa = \frac{a}{a + b}$$

5. **Falsa Tasa Negativa:** Es la proporción de los datos positivos que se identificaron incorrectamente como negativos, se determina a partir de la siguiente ecuación:

$$\text{Falsa Tasa Negativa} = \frac{c}{c + d}$$

6. **Precisión:** La precisión es la proporción del número de predicciones positivas que fueron correctas, se determina a partir de la siguiente ecuación:

$$\text{Precisión} = \frac{d}{b + d}$$

A continuación, se hará una pequeña descripción de los Errores Tipo 1 y Tipo 2:

Error Tipo 1: También denominado error de tipo alfa (α) o falso positivo, es el error que se comete cuando el investigador rechaza la hipótesis nula siendo ésta verdadera. Es equivalente a encontrar un resultado falso positivo, porque el investigador llega a la conclusión de que existe una diferencia entre las hipótesis cuando en realidad no existe.

Error Tipo 2: También denominado error de tipo beta (β) o falso negativo, es el error que se comete cuando el investigador no rechaza la hipótesis nula siendo ésta falsa. Es equivalente a la probabilidad de un resultado falso negativo, ya que el investigador llega a la conclusión de que ha sido incapaz de encontrar una diferencia que existe en la realidad.

En la Tabla 10, se puede observar la Tabla de Clasificación del Modelo para la predicción de quiebra de bancos.

Tabla 10.
Tabla de Clasificación del Modelo

		Pronosticado		
		Quiebra		Corrección de porcentaje
Observado		No	Si	
	Quiebra	No	297	3
Si		11	39	78
Porcentaje global				96

De acuerdo con la Tabla 10, se puede concluir que el modelo está clasificando correctamente el 78% del total de la muestra de Quebrados y está clasificando correctamente el 99% del total de la muestra de no quebrados, mientras que clasifica erróneamente el 1% de los no quebrados como quebrados. Por último, el modelo consigue clasificar correctamente un 96% del total de la muestra.

4.3.2 Pruebas y Estadísticos

Tabla 11.
Pruebas y Estadísticos

Prueba	Estadístico
Omnibus	193.309***
Hosmer & Lemeshow	4.792
ROC	0.970***
K-S	5.398***

Nota: *** Significancia al 1%; ** Significancia al 5%; *Significancia al 10%.

En la Tabla 11, se encuentran la prueba ómnibus de coeficientes del modelo. Esta prueba de bondad de ajuste se realiza a través de una prueba Chi-cuadrado, la cual permite evaluar la hipótesis nula de que los coeficientes (β) de todos los términos (excepto la constante) incluidos en el modelo son cero. Por lo tanto se rechaza la hipótesis nula donde los coeficientes de todos los términos del modelo son diferentes de cero.

Adicionalmente, se puede concluir que el modelo se ajusta a los datos al tener un nivel de significancia inferior al 0,05. Por lo tanto el modelo podría identificar bancos que se podrán encontrar en quiebra con una buena precisión.

Por otro parte, en la Tabla 11 se puede observar los resultados de la prueba de Hosmer y Lemeshow del modelo. Esta prueba de bondad de ajuste, permite comparar las probabilidades estimadas con el modelo frente a las proporciones de quiebra en cada uno de los grupos determinados por lo deciles. En la hipótesis nula se afirma que el modelo propuesto se ajusta a los datos

Por lo tanto, se puede observar que para el modelo propuesto se tiene un nivel de significancia superior al 10%. Lo cual permite concluir que el modelo estima adecuadamente las probabilidades de predicción de quiebra.

La prueba Kolmogorov-Smirnov o también llamada prueba K-S de dos muestras, intenta determinar si dos muestras difieren significativamente es decir que si ambas muestras tienen la misma distribución. La ventaja de este test es que no asume ninguna distribución para los datos.

En donde las hipótesis son las siguientes:

Hipótesis Nula: Los datos de una variable en dos grupos diferentes siguen la misma distribución.

Hipótesis Alterna: Los datos de una variable en dos grupos diferentes no siguen la misma distribución.

En donde el estadístico del Test K-S, es:

$$D = \sup_{1 \leq i \leq n} |F_{n1}(x_i) - F_{n2}(x_i)|$$

Dónde:

x_i : es el i-ésimo valor observado en la muestra.

$F_n(x_i)$: es un estimador de la probabilidad de observar valores menores o iguales que x_i .

$F_{n2}(x_i)$: es la probabilidad de observar valores menores o iguales que x_i cuando la hipótesis nula es cierta.

Por lo tanto el criterio para la toma de decisión será de la siguiente forma:

Si $D \leq D_\alpha$ se acepta la Hipótesis Nula

Si $D \geq D_\alpha$ se rechaza la Hipótesis Nula

Siendo α el nivel de significancia.

Con respecto a la Prueba K-S del modelo se rechaza la hipótesis nula, por lo tanto los datos de una variable en dos grupos diferentes no siguen la misma distribución. Lo anterior teniendo en cuenta el estadístico presentado en la Tabla 11.

La Curva ROC (acrónimo de Receiver Operating Characteristic, o Característica Operativa del Receptor) o el estadístico ROC es un test no paramétrico, también conocida como la curva de intercambio debido a que representa el intercambio entre No quebrados y Quebrados, es decir el porcentaje del total de Quebrados que deben ser aceptados para aceptar cierto porcentaje del total de No Quebrados según el umbral de clasificación.

Por lo tanto, en el eje X están los falsos positivos (1-especificidad) que son los Quebrados que el modelo clasificó como No Quebrados (Quebrados mal clasificados) y en el eje Y, están los verdaderos positivos (sensibilidad) que son los No Quebrados bien clasificados según varía el umbral de clasificación.

El estadístico c es equivalente al área bajo la curva ROC (AUC), teóricamente puede tomar valores entre 0.5 y 1. En donde a mayor sea el valor del área bajo la curva mejor es la discriminación del modelo entre las distribuciones de No Quebrados y Quebrados.

En la Figura 2, se puede observar algunos ejemplos de la curva ROC.

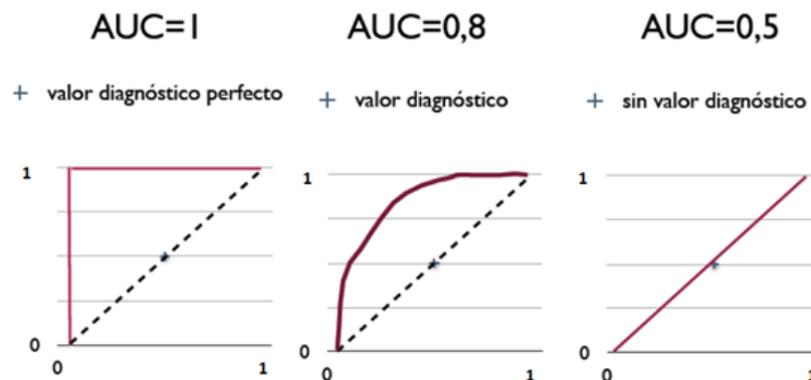


Figura 2. Curva ROC

A partir de la Figura 3 y del estadístico ROC de la Tabla 11, se puede observar que el modelo tiene un Área Bajo la Curva de 0,97 y que su significancia es mínima. De lo anterior se logra concluir que el modelo tiene un alto rendimiento en la probabilidad de quiebra de la muestra.

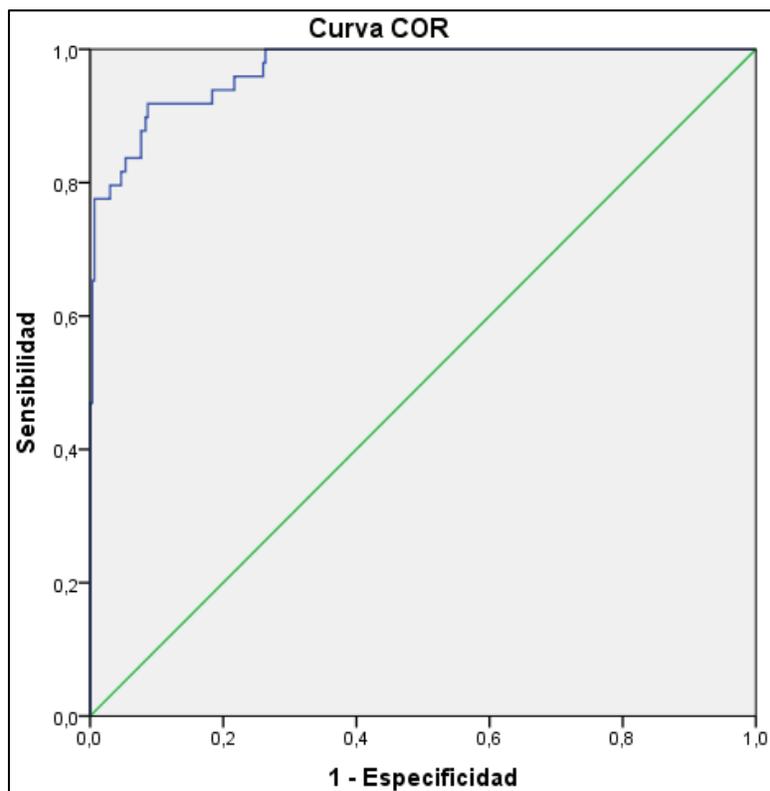


Figura 3. Curva ROC Modelo

4.4 Análisis Financiero Variables Significativas

Conforme con los resultados y variables encontradas en el capítulo anterior, la Z del modelo logit para predecir la quiebra de bancos estadounidenses puede representarse de la siguiente manera:

$$Z = -15,538 + 1,258 * MargenN_Int + 0,996 * Ing_Dint - 1,744 * ROA + 0,002 * Util_ChrO + 0,002 * Cart_ActTot - 0,660 * Rel_Sol + 0,871 * Patri_Act - 1,008 * Reser + 1,408 * Pasiv_Patri$$

A continuación se describen los resultados de cada uno de los indicadores significativos del modelo, y se muestra la evidencia tomando el comportamiento histórico de cada indicador para dos bancos durante la crisis de 2008 (que finalmente terminó afectando a todo el sistema bancario estadounidense y por ende sus razones financieras), Bank of America, segundo banco más grande por nivel de activos en EE.UU, y el Washington Mutual, considerado como el mayor hundimiento de un banco en la historia de EE.UU (adquirido por JP Morgan el 26 de septiembre de 2008).

1. Margen de Interés Neto (MargenN_Int):

Se observa en el modelo que su impacto en la probabilidad de quiebra es positivo, lo anterior se debe a que un Banco con alta probabilidad de quiebra tendrá un mayor costo de fondeo debido a que tendrá un mayor riesgo asociado. Por lo que el margen entre sus ingresos por intereses y sus gastos por intereses será menor. De igual manera sus activos productivos (Cartera) serán menores, ya que una mayor proporción no se podrá cobrar o recuperar. Lo anterior se refleja en un valor más alto para los Banco Quebrados.

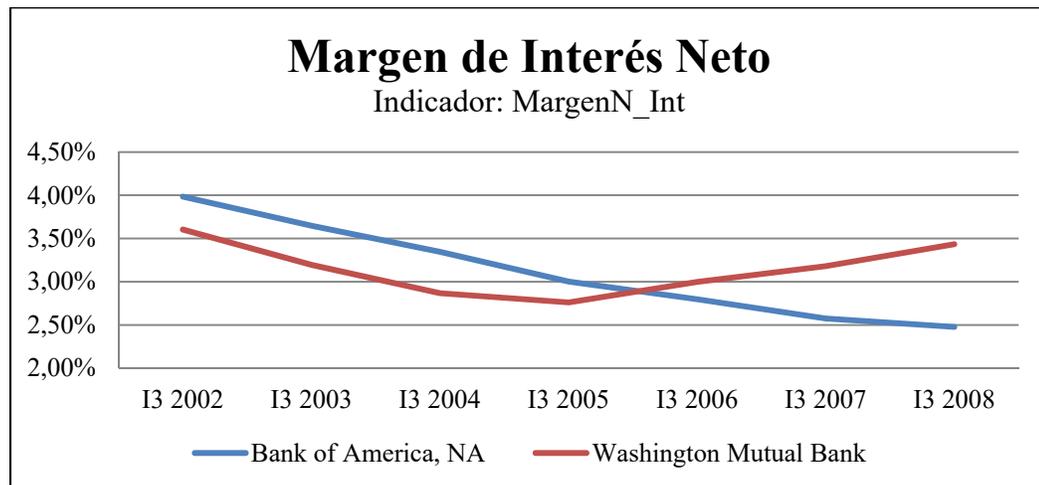


Figura 4. Margen de Interés Neto

En la Figura 4 se puede observar como el Margen de Interés Neto aumenta significativamente para el Washington Mutual desde el año 2005 hasta su quiebra en 2008, sobrepasando el registrado por Bank of America.

2. Ingresos Distintos a Intereses (Ing_Dint):

De acuerdo con los resultados del modelo, se puede observar que el impacto de este indicador en la probabilidad de quiebra es positivo. Lo anterior se debe a que en un Banco con alta probabilidad de quiebra, la mayoría de sus ingresos serán derivados por servicios bancarios y de otras fuentes distintas de los activos que generan intereses.

Lo anterior, muestra una amplia separación de los bancos por buscar ingresos alternativos a los ingresos tradicionales como son el prestar dinero y de fondearse a través de los depósitos de los clientes del común. Se evidencia una alta dependencia de estos bancos en sus ingresos alternativos como el de prestar dinero a Bancos de gran tamaño, así como a grandes corporaciones.

Estos ingresos alternativos son mucho más volátiles que los ingresos tradicionales, lo cual hace que el banco este expuesto a mayores fluctuaciones en sus ingresos

De igual manera, se observa una dependencia en sus ingresos de sus transacciones bursátiles las cuales también son bastantes volátiles. Lo cual expone al banco a mayores fluctuaciones en sus ingresos y por ende a una mayor probabilidad quiebra.

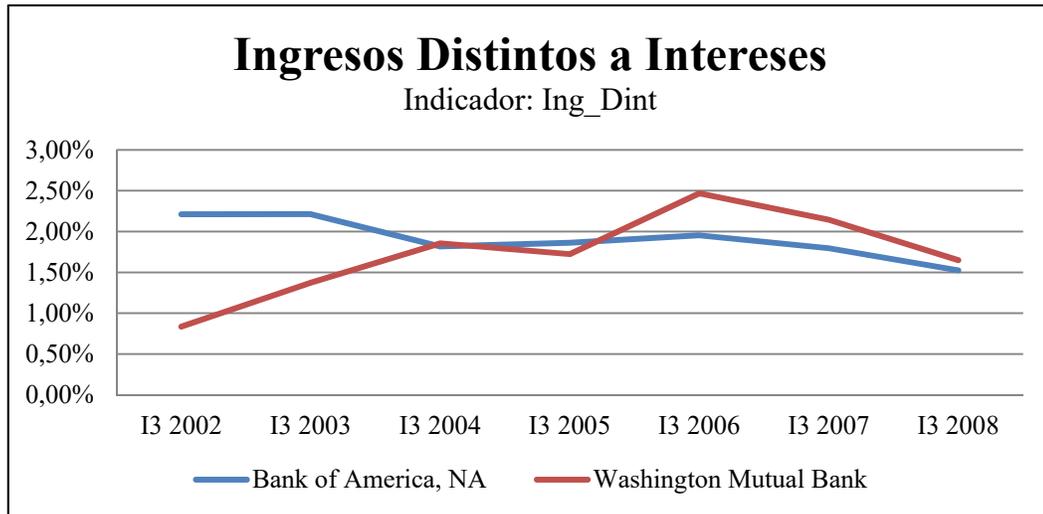


Figura 5. Ingresos Distintos a Interés

En la Figura 5 se puede observar un aumento del indicador para el banco quebrado desde 2005, superando el reportado por el banco no quebrado. Si bien desde 2002 hasta 2004 su indicador era menor al reportado por el Bank of America, se observa una tendencia al alza considerable, hasta finalmente a partir del 2006 superar al registrado por el banco no quebrado.

3. Rentabilidad sobre el Activo (ROA):

Se observa en el modelo que este indicador tiene un impacto negativo en la probabilidad de quiebra. Esto se debe a que un menor valor del ROA implica que el Banco no está generando suficientes ingresos por el uso de sus activos, por lo que no está siendo eficiente en el manejo de sus recursos.

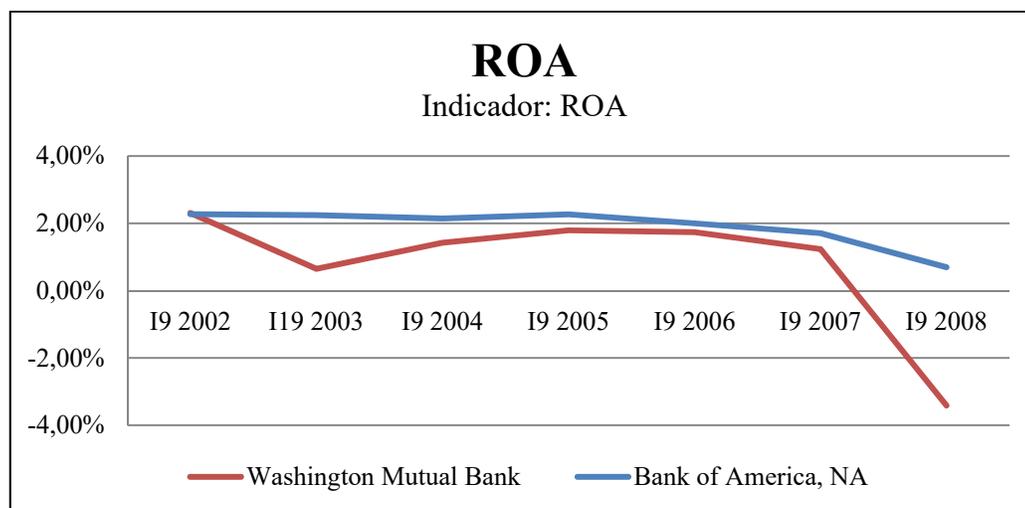


Figura 6. ROA

En la Figura 6 se puede observar un deterioro significativo del indicador para el banco quebrado desde el año 2007, alcanzando terreno negativo en el 2008 cerrando en -3,42%. Bank Of America también presenta un deterioro de su indicador, pasando de 1,71% en 2007 a 0,7% en 2008, a cierre de 2014 el banco presentó un ROA de 1,31%.

4. Ganancias en Cobertura de Cartera Castigada (Util_ChrO):

De acuerdo con los resultados del modelo y el análisis previamente realizado, un indicador bajo hace referencia a menores recuperaciones de cartera castigada, y de menores ganancias ya sea por su resultado de operación antes de impuestos o por las pérdidas en sus títulos disponibles para la venta y hasta el vencimiento, por lo que el resultado obtenido implica que a mayor valor, mayor será su probabilidad de incumplimiento.

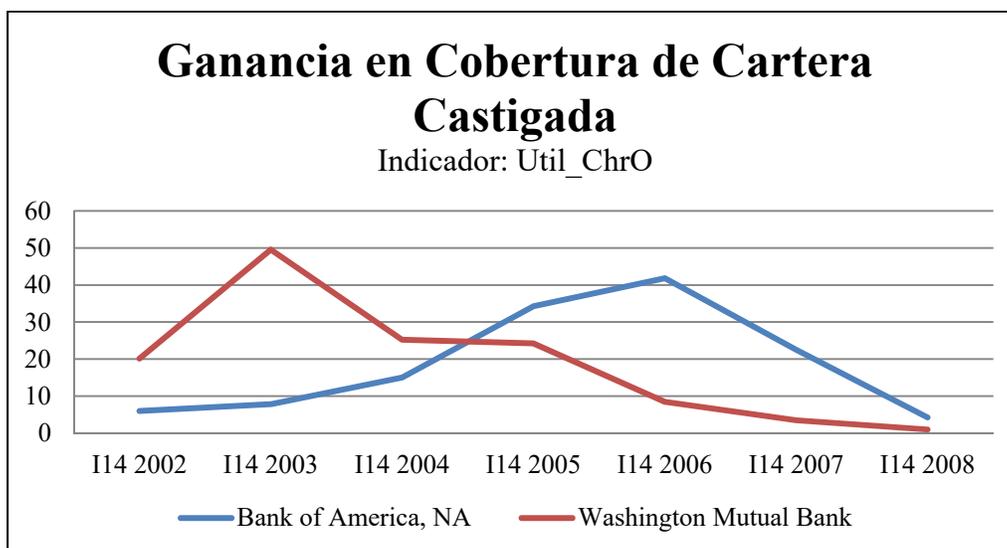


Figura 7. Ganancia en Cobertura de Cartera Castigada

La Figura 7 evidencia un menor valor para el banco quebrado, cerrando en 2008 en 0,98x, mientras el banco no quebrado cerró para el mismo año en 4,26x pese una tendencia a la baja, a corte de 2014 el indicador para Bank of America fue de 9,60x.

5. Préstamos netos como porcentaje de los activos totales (Cart_ActTot):

Como lo mencionamos anteriormente, este indicador puede ser analizado desde dos perspectivas, presiones de liquidez y calidad de cartera, la primera nos dice que un indicador muy elevado podría afectar la liquidez del banco, y la segunda, que ante mayores provisiones (mayor probabilidad de incumplimiento de los clientes) menor será la calidad de su cartera por lo cual su indicador será más bajo.

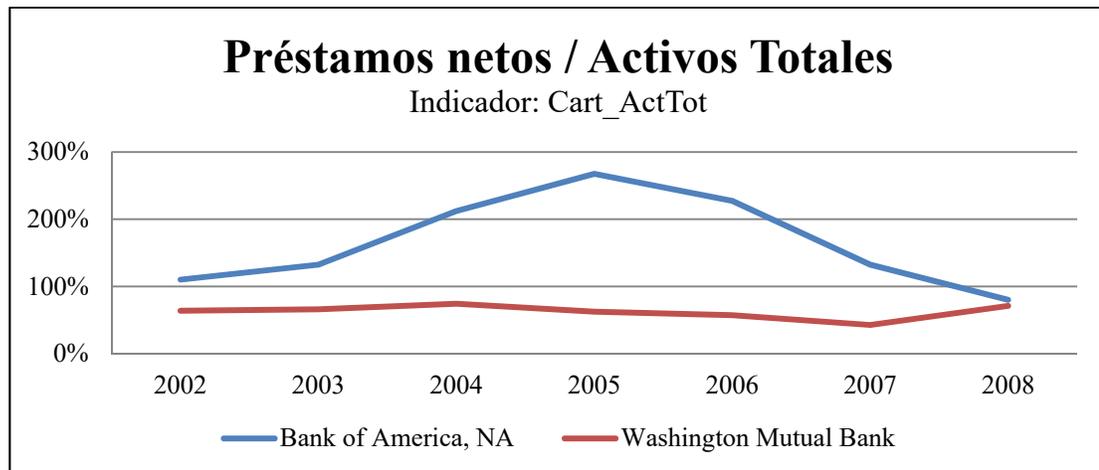


Figura 8. Prestamos Netos/ Activos Totales

Como se puede observar en la Figura 8, el indicador para los dos bancos converge en la crisis de 2008, Bank of America reportó un indicador de 80,07% y el Washington Mutual de 71,04%. Dada la significancia del indicador y el valor del beta arrojado por el modelo, se decidió por dejar este indicador, sin embargo se debe mirar en detalle otros indicadores que podrían afectar la estabilidad del banco.

6. Relación de Solvencia Básica (Rel_Sol):

Como se observa en el modelo, este indicador tiene un impacto negativo en la probabilidad de quiebra, debido que entre más alto sea, mayor será la capacidad de la institución para afrontar y absorber pérdidas inesperadas en sus operaciones, por ende menor será su probabilidad de default.

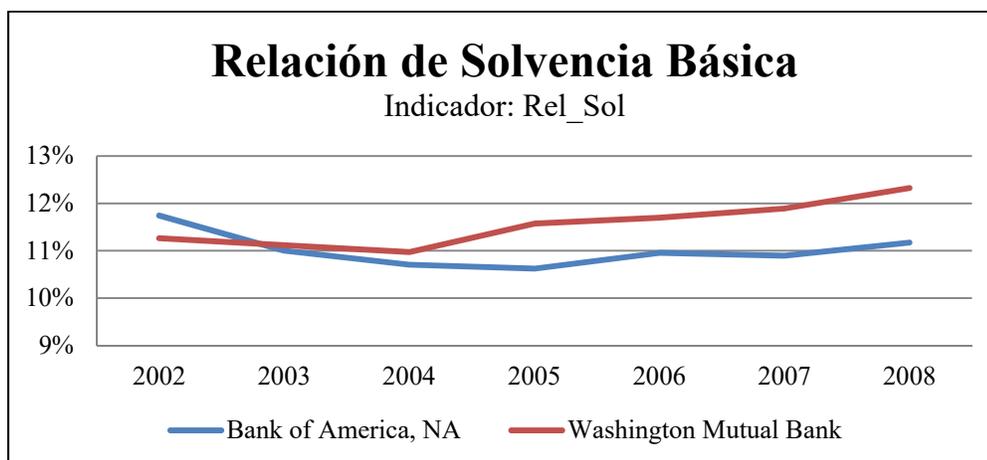


Figura 9. Relación de Solvencia Básica

Como se puede observar en la Figura 9, la relación de solvencia por sí solo no indica la probabilidad de quiebra de un banco, y no debe ser el único parámetro para evaluar la salud del banco. En 2008 cuando quebró el Washington Mutual (particularmente golpeado por la crisis “subprime”) su nivel de solvencia básico fue de 12,33% mientras la de Bank of America de 11,17%, evidenciando que su significancia del modelo depende de la significancia y del aporte de otros indicadores financieros.

7. Patrimonio/Activo (Patri_Act)

Como se observa en el modelo que este indicador tiene un impacto positivo en la probabilidad de quiebra de un banco, esto obedece al riesgo que pueda tener la cartera y por ende al nivel de sus provisiones, lo que hace que el valor del activo disminuya y aumente el valor del indicador. Así mismo, el requerimiento de capital aumenta a medida que aumenten las probabilidades de incumplimiento de los clientes (capital económico) por lo que se requerirá mayor nivel de patrimonio.

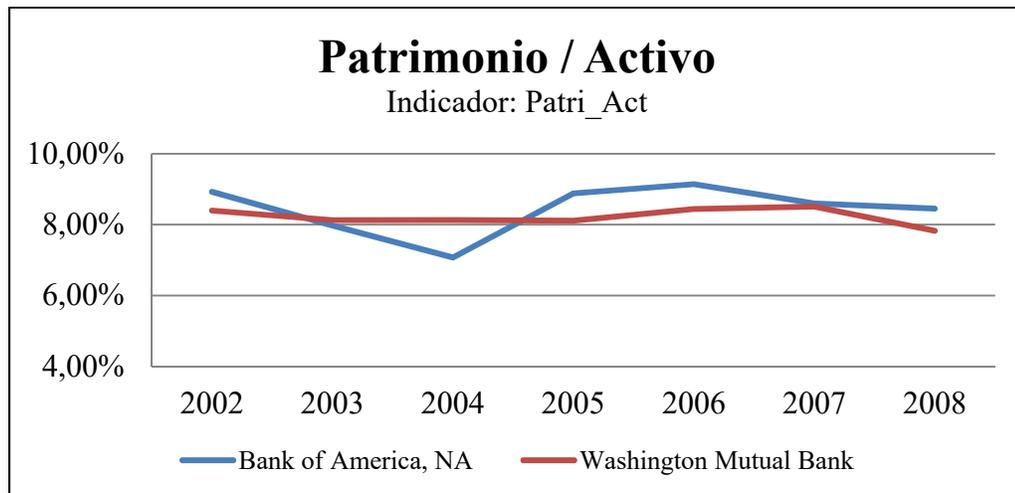


Figura 10. Patrimonio/Activo

Si bien la Figura 10 no muestra una tendencia clara, en el último año el indicador para Washington Mutual paso de 8,51% en 2007 a 7,83% en 2008, equivalente a una disminución de -8%, mientras para Bank of America pasó de 8,6% a 8,45% (-1,74%), por lo cual se debe hacer un análisis en el tiempo que pueda dar señales del deterioro en su cartera.

8. Reserva = Efectivo / Depósitos (Reser)

De acuerdo con los resultados del modelo, este indicador tiene un impacto negativo en la probabilidad de incumplimiento, ya que entre más recursos de inmediata disponibilidad posea el banco, menor será su probabilidad de quiebra.

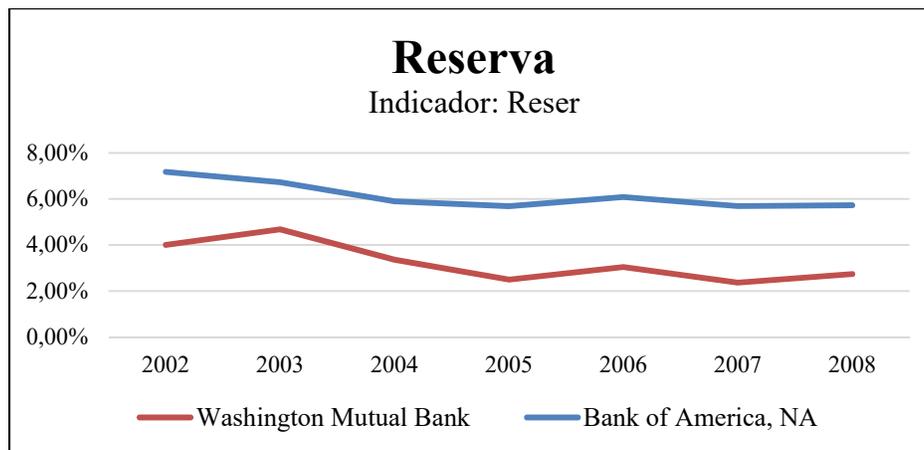


Figura 11. Reserva

La Figura 11 permite evidenciar mayores niveles de reserva para el banco no quebrado que para el banco quebrado, tal como se había esperado.

9. Pasivo/Patrimonio (Pasiv_Patri):

Este indicador tiene un impacto positivo en la probabilidad de quiebra de un banco, ya que podría estar apalancando su crecimiento mediante deuda financiera, así como presentar un deterioro en su patrimonio consecuencia de utilidades negativas.

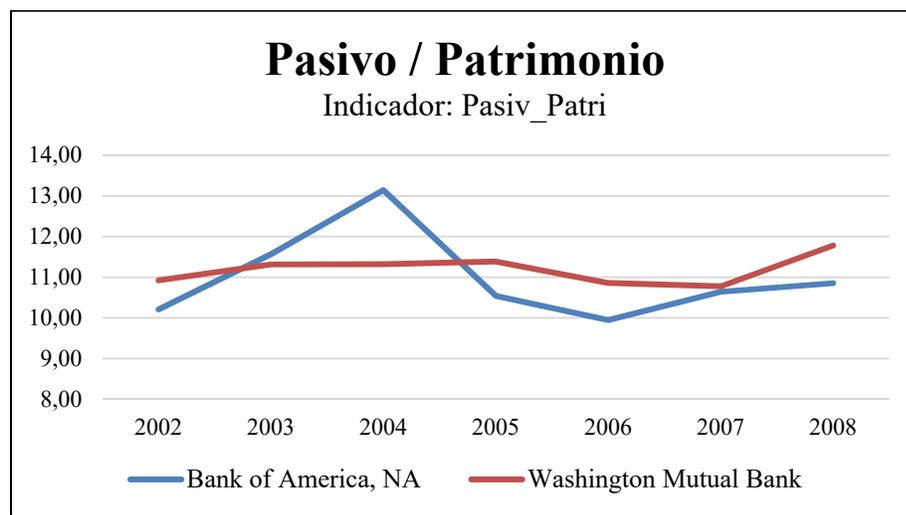


Figura 12. Pasivo/Patrimonio

Como se observa en la Figura 12, en el último año el indicador para el banco quebrado supero al no quebrado debido a un deterioro en su patrimonio ocasionado por las pérdidas que lo llevaron finalmente a la quiebra.

Del análisis anterior podemos concluir que la relevancia de los indicadores a la hora de predecir la probabilidad de quiebra de un banco se da con la construcción de un modelo probabilístico que tome los indicadores más significativos y que le dé una mayor bondad de ajuste al modelo, ya que en muchos casos, el indicador por sí solo no puede ser una unidad de medición para clasificar, si el banco está bien o mal, ejemplo de ello, la solvencia básica, mayor en el Washington Mutual que en Bank of America, sin embargo fue el primero

quien cayó en quiebra, de allí la importancia de crear un modelo probabilístico que combine los mejores indicadores.

4.5 Árbol Binomial del Modelo

En la Figura 13, se realizó un árbol binomial para determinar una zona de seguridad, una zona gris y una zona de peligro. Los resultados arrojaron que un resultado del logit superior al 0,481 tiene una probabilidad de default de 94,3% (de 35 bancos que se encuentran en ese rango, 33 están en quiebra), mientras que los bancos con un resultado de $-4,202$ tienen una probabilidad de no caer en quiebra de 100% (de 209 bancos que se encuentran en este rango, ninguna está en quiebra). Existen dos zonas grises, una más segura, que llamamos “Zona Gris 1” en donde se tiene un rango de $-4,202$ a $-1,653$, en esta zona de 70 bancos, el 92,9% no está quebrado mientras el 7,1% está en default, y la “Zona Gris 2” donde existe un mayor porcentaje de bancos quebrados que la “Zona gris 1”, en esta zona el rango es de $-1,653$ a $0,481$, y de 35 bancos que se encuentran en ella, el 31,4% se encuentra en default.

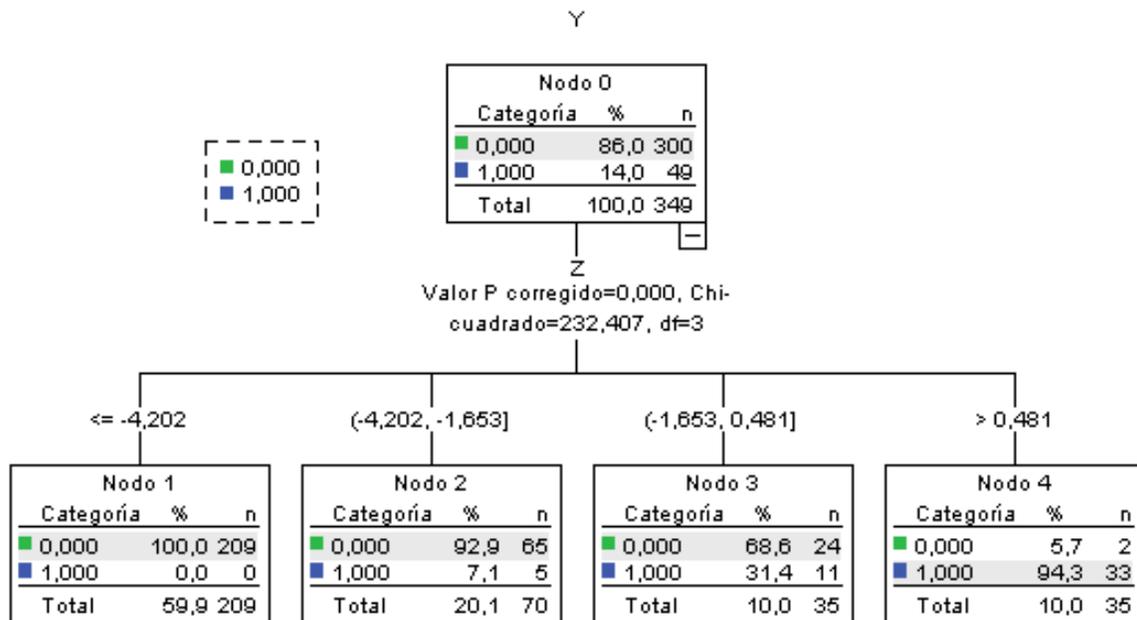


Figura 13. Zona de Seguridad

Como se mencionó anteriormente, las zonas identificadas de acuerdo con el árbol binomial del modelo son las que se pueden observar en la Tabla 12. Donde se tienen cuatro zonas de clasificación: Zona Segura, Zona Gris 1, Zona Gris 2 y Zona de Peligro.

Tabla 12.
Zonas de Clasificación

Zona de Clasificación	Intervalos Z
Zona Segura	$-4.202 \leq Z$
Zona Gris 1	$-4.202 < Z \leq -1.653$
Zona Gris 2	$-1.653 < Z \leq 0.481$
Zona de Peligro	$Z > 0.481$

4.6 Aplicación Modelo sobre Muestra Total

Una vez definidas las variables significativas y el modelo de Probabilidad de Quiebra, se realizó el cálculo del Z para cada banco total de la muestra de bancos (499 Bancos).

Se aplicó el modelo a los siguientes grupos de datos:

- Indicadores 1 año antes de la quiebra.
- Indicadores 2 años antes de la quiebra.
- Indicadores 3 años antes de la quiebra.

De acuerdo con los resultados arrojados por el modelo. En la Tabla 13, podemos observar las clasificaciones del total de la muestra para cada análisis (uno, dos y tres años antes de la quiebra) en las cuatros zonas definidas en la Tabla 12.

Tabla 13.
Resultados del Modelo

Clasificación	3 Años antes de la Quiebra					
	No	Si	No. Bancos	% No	% Si	% Total
Zona de Peligro	21	58	79	26.58%	73.4%	15.83%
Zona Gris 1	99	45	144	68.75%	31.3%	28.86%
Zona Gris 2	25	64	89	28.09%	71.9%	17.84%
Zona Segura	155	32	187	82.89%	17.1%	37.47%
Total	300	199	499			100.00%

2 Años antes de la Quiebra

Clasificación	No	Si	No. Bancos	% No	% Si	% Total
Zona de Peligro	20	76	96	20.83%	79.2%	19.24%
Zona Gris 1	92	50	142	64.79%	35.2%	28.46%
Zona Gris 2	28	52	80	35.00%	65.0%	16.03%
Zona Segura	160	21	181	88.40%	11.6%	36.27%
Total	300	199	499			100.00%

1 Año antes de la Quiebra

Clasificación	No	Si	No. Bancos	% No	% Si	% Total
Zona de Peligro	18	158	176	10.23%	89.8%	35.27%
Zona Gris 1	90	16	106	84.91%	15.1%	21.24%
Zona Gris 2	26	16	42	61.90%	38.1%	8.42%
Zona Segura	166	9	175	94.86%	5.1%	35.07%
Total	300	199	499			100.00%

Se puede observar en la Tabla 13 que el modelo clasifico tres años antes de la quiebra al 15,83% del total de la muestra en la Zona de Peligro, es decir 79 bancos que se encuentran con una probabilidad alta de quiebra. De estos 79 bancos clasifico correctamente 58 bancos quebrados, es decir clasifico correctamente un 73,4% de los bancos que eventualmente quebraron tres años después.

Adicionalmente, se observar que el modelo clasifico incorrectamente 21 bancos no quebrados en la Zona de Peligro. De igual manera el modelo clasifico incorrectamente 32 bancos que quebraron en la Zona Segura, es decir un error de 17,1%.

Dos años antes de la quiebra se observa un incremento en el porcentaje de clasificación para la Zona de Peligro donde el modelo clasifica un 19,24% del total de la muestra, es decir 96 bancos que se encuentran con una alta probabilidad de quiebra. De estos 96 bancos clasifico correctamente 76 bancos quebrados, es decir clasifico correctamente un 79,2% de los bancos que eventualmente quebraron dos años después.

Adicionalmente, se observar que el modelo clasifico incorrectamente 20 bancos no quebrados en la Zona de Peligro. De igual manera el modelo clasifico incorrectamente 21

bancos que quebraron en la Zona Segura, es decir un error de 11,6%. Se observa una reducción en el error de 5,5%.

En cambio, con la información de un año antes de la quiebra se observa un crecimiento en el porcentaje de clasificación. Donde el modelo clasifico un 35,27% del total de la muestra, por lo tanto clasifico 176 bancos que se encuentran con una alta probabilidad de quiebra. De estos 176 bancos clasifico correctamente 158 bancos quebrados, es decir clasifico correctamente un 89,8% de los bancos que eventualmente quebraron un año después.

Adicionalmente, se observar que el modelo clasifico incorrectamente 18 bancos no quebrados en la Zona de Peligro. De igual manera el modelo clasifico incorrectamente 9 bancos que quebraron en la Zona Segura, es decir un error de 5,1%. Se observa una reducción en el error de 6,5%.

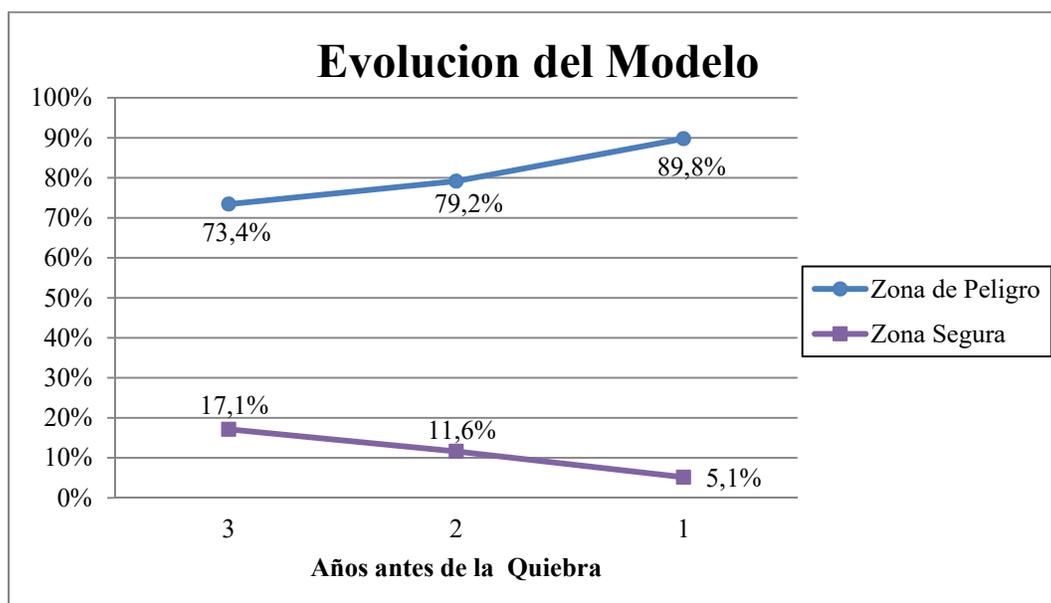


Figura 14. Evolución del Modelo

En la Figura 14, se puede apreciar la evolución del modelo donde entre más se acerque el banco a la quiebra el modelo aumenta su porcentaje de clasificación en la Zona de Peligro. En cambio para la Zona Segura su porcentaje de clasificación disminuye.

4.7 Evaluaciones Adicionales

4.7.1 Matrices de Transición

Para medir la estabilidad del modelo se realizaron matrices de rodamiento o de transición para los bancos quebrados y no quebrados, con el fin de medir la probabilidad que tiene un banco de migrar o moverse de una Zona Segura a una de Peligro o a una Gris, así como de una Zona de Peligro a una Gris o Segura en un horizonte de tiempo de tres años.

Tabla 14.
Matrices Rodamiento Bancos Quebrados

Matriz de Rodamiento de 3 a 2 años - Bancos Quebrados					
	Zona Segura	Zona Gris 1	Zona Gris 2	Zona de Peligro	Total
Zona Segura	50.0%	40.6%	6.3%	3.1%	100.0%
Zona Gris 1	6.7%	55.6%	24.4%	13.3%	100.0%
Zona Gris 2	3.1%	15.6%	45.3%	35.9%	100.0%
Zona de Peligro	0.0%	3.4%	17.2%	79.3%	100.0%

Matriz de Rodamiento de 2 a 1 años - Bancos Quebrados					
	Zona Segura	Zona Gris 1	Zona Gris 2	Zona de Peligro	Total
Zona Segura	19.0%	19.0%	14.3%	47.6%	100.0%
Zona Gris 1	2.0%	10.0%	12.0%	76.0%	100.0%
Zona Gris 2	1.9%	5.8%	11.5%	80.8%	100.0%
Zona de Peligro	3.9%	5.3%	1.3%	89.5%	100.0%

Como se observa en la Tabla 14, la probabilidad que tiene un banco quebrado que se encuentre en una Zona Segura tres años antes de su quiebra de pasar a una Zona de Peligro un año después es de 3,1%, sin embargo si hacemos el mismo análisis pero dos años antes de su quiebra, vemos que la probabilidad de pasar a una Zona de Peligro es de 47,6% un año después, por lo que el modelo es más predictivo dos años antes de su quiebra que para tres años. De igual manera, el modelo clasifica bien los bancos quebrados en las dos matrices, ya que el 79,3% de los bancos quebrados que estaban en Zona de Peligro tres años antes de su quiebra se mantienen en la misma zona un año después, y dos años antes

de su quiebra el porcentaje sube a 89,5%. Para los bancos que se encontraban en Zona Gris 1 y Zona Gris 2 dos años antes de su quiebra, la probabilidad de pasar a Zona de Peligro es considerablemente alta, del 76% y 80.8% respectivamente.

Tabla 15.
Matrices Rodamiento Bancos No Quebrados

Matriz de Rodamiento de 3 a 2 años - Bancos No Quebrados					
	Zona Segura	Zona Gris 1	Zona Gris 2	Zona de Peligro	Total
Zona Segura	90.3%	8.4%	0.6%	0.6%	100.0%
Zona Gris 1	18.2%	69.7%	11.1%	1.0%	100.0%
Zona Gris 2	0.0%	32.0%	56.0%	12.0%	100.0%
Zona de Peligro	9.5%	9.5%	9.5%	71.4%	100.0%

Matriz de Rodamiento de 2 a 1 años - No Bancos Quebrados					
	Zona Segura	Zona Gris 1	Zona Gris 2	Zona de Peligro	Total
Zona Segura	91.3%	8.8%	0.0%	0.0%	100.0%
Zona Gris 1	19.6%	72.8%	4.3%	3.3%	100.0%
Zona Gris 2	0.0%	28.6%	71.4%	0.0%	100.0%
Zona de Peligro	10.0%	5.0%	10.0%	75.0%	100.0%

La Tabla 15 muestra la probabilidad que tienen los bancos no quebrados de cambiar de zona en un horizonte de tiempo de tres años, así, la probabilidad de un banco no quebrado que se encuentra en la Zona Segura de pasar a la Zona de Peligro es de 0.6% tres años antes y de 0.0% dos años antes, por lo que pasar de una Zona Segura a una Zona de Peligro es poco probable en ambos casos, la probabilidad de mantenerse en la Zona Segura es de 90.3% y 91.3% respectivamente, y de pasar a la Zona Gris 1 de 8.4% y 8.8%. Por otra parte, la probabilidad que un banco que se encuentra en una Zona de Peligro pase a una Zona Segura tres y dos años antes, es de 9.5% y 10% respectivamente, una probabilidad pequeña si se busca tomar una posición en un banco que se encuentre actualmente en Zona de Peligro.

4.7.2 Indicador: Costo de Financiación de los Activos Productivos

Al momento de correr el modelo con todas las variables propuestas, se encontró que existe un indicador que predice fuertemente la probabilidad de quiebra de un banco, el Costo de Financiación de los Activos Productivos (Cost of Funding Earning Assets), calculado por la FDIC como: gastos totales de intereses (en depósitos y otro dinero prestado) como porcentaje de los activos productivos promedio (la media de todos los préstamos y otras inversiones generadores de ingresos por intereses o dividendos), ya que individualmente hacía que el modelo tuviese un gran poder de predicción y volvía de las demás variables no significantes, por lo que se decidió elaborar un análisis con respecto a este indicador.

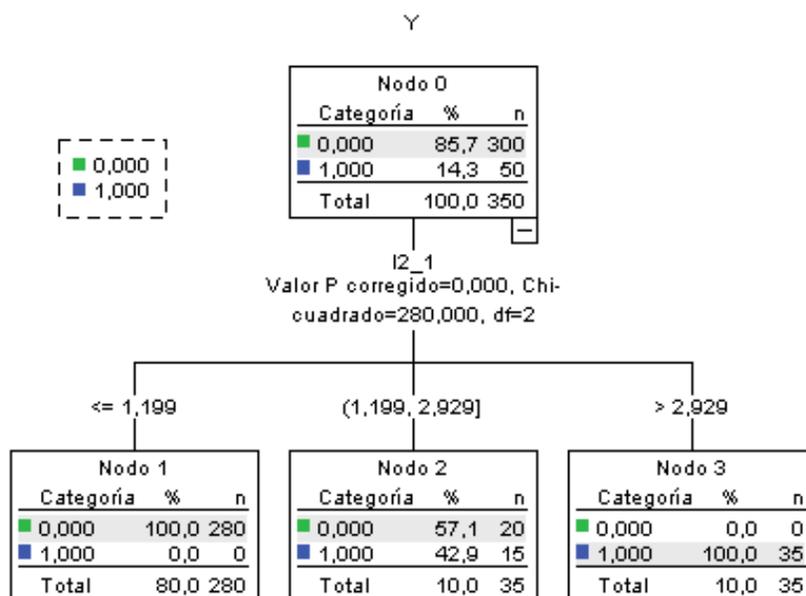


Figura 15. Zona de Seguridad del Indicador

Al igual que modelo anterior, se realizó un árbol binomial para determinar una Zona Segura, una Zona Gris y una Zona de Peligro (Figura 16). Se puede determinar cómo un Z mayor a 8,776 tiene una probabilidad de quiebra del 100%, mientras la Zona Gris está en un rango de -5,388 a 8,776, y la Zona Segura es aquella en la que el Z es menor a -5,388.

La interpretación financiera de dicho indicador se puede hacer mediante dos vías:

1. La primera dice que entre mayor riesgo tenga el banco, medido ya sea por la calificación asignada de una entidad calificadora o por su tamaño y por ende una menor confianza del consumidor, mayor será la tasa exigida por sus depositantes, por ende mayor será su costo de fondeo, no sería lo mismo que un consumidor o inversionista institucional deposite sus ahorros en un banco sólido y bien capitalizado (poco riesgo y por ende una menor tasa) al de un banco pequeño con poco respaldo patrimonial (mayor riesgo y mayor tasa).
2. La segunda dice que entre menos activos productivos promedio tenga el banco, ya sea por un deterioro en su cartera o por desvalorizaciones en su portafolio de inversión, mayor será el indicador.

Esto se evidencia en los resultados arrojados por el modelo, en donde el signo del beta estimado es positivo, y en el árbol de decisiones, donde la zona de seguridad se da con un menor indicador.

Para tener más evidencia del indicador, se graficó su comportamiento histórico para dos bancos quebrados y dos no quebrados, seleccionando a Bank of America y Washington Mutual analizados previamente, y otros dos bancos seleccionados aleatoriamente.

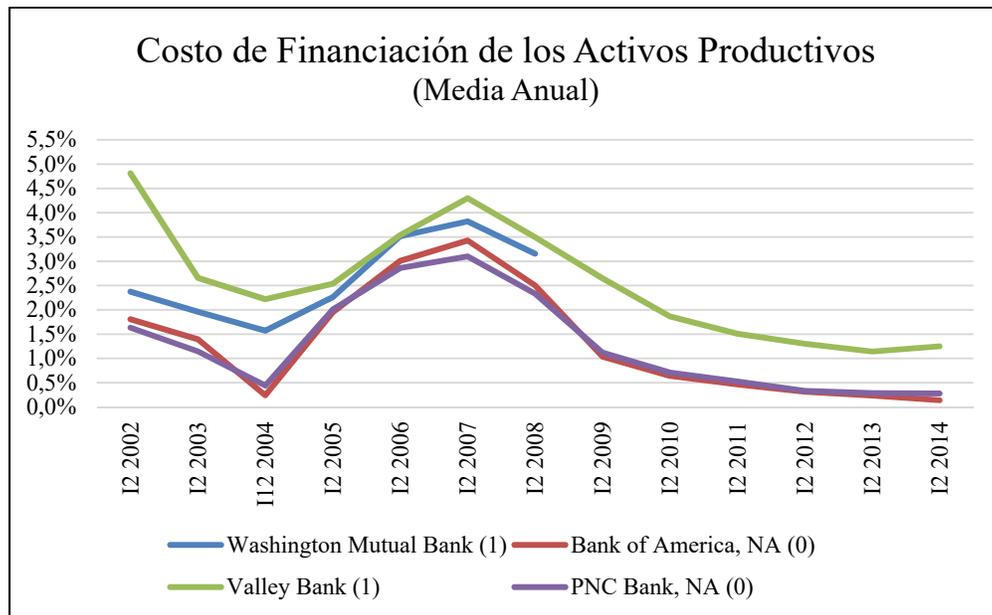


Figura 16. Comportamiento Indicador

Como se observa en la figura 18, el indicador es más alto para los dos bancos quebrados (demarcados con el número 1) que para los no quebrados. También se evidencia cómo desde el 2005 hasta el 2007, para los cuatro bancos el indicador presenta un comportamiento al alza, que se podría explicar por la calidad de sus activos productivos.

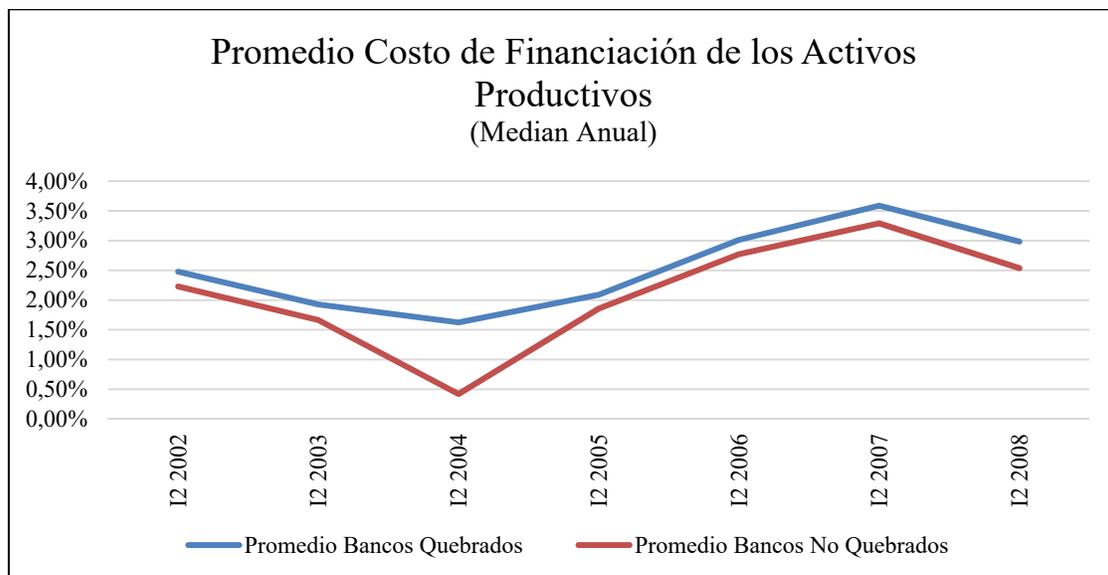


Figura 17. Comportamiento Indicador: Quebrados vs. No quebrados

En la figura 19 se muestra el promedio del indicador por año para el total de bancos quebrados y no quebrados de la muestra, evidenciando un mayor valor para los bancos quebrados a lo largo del periodo.

Como se mencionó en la Figura 16, se identificaron tres zonas para el valor del indicador descritas en la Tabla 16: Zona Segura, Zona Gris, Zona de Peligro.

Tabla 16.
Zonas de Clasificación Indicador

Zona de Clasificación	Intervalos del Indicador
Zona Segura	$\leq 1,199$
Zona Gris	$1,199 < Z \leq 2,929$
Zona de Peligro	$Z > 2,929$

De acuerdo con los resultados arrojados por el modelo, en la Tabla 17, podemos observar las clasificaciones del total de la muestra para cada análisis.

Tabla 17.
Resultados del Indicador

3 Años antes de la Quiebra						
Clasificación	No	Si	No.Bancos	% No	% Si	% Total
Zona de Peligro	0	145	145	0.00%	100.0%	29.06%
Zona Gris	30	54	84	35.71%	64.3%	16.83%
Zona Segura	270	0	270	100.00%	0.0%	54.11%
Total	300	199	499			100.00%

2 Años antes de la Quiebra						
Clasificación	No	Si	No.Bancos	% No	% Si	% Total
Zona de Peligro	0	153	153	0.00%	100.0%	30.66%
Zona Gris	16	46	62	25.81%	74.2%	12.42%
Zona Segura	284	0	284	100.00%	0.0%	56.91%
Total	300	199	499			100.00%

1 Año antes de la Quiebra						
Clasificación	No	Si	No.Bancos	% No	% Si	% Total
Zona de Peligro	0	109	109	0.00%	100.0%	21.84%
Zona Gris	10	85	95	10.53%	89.5%	19.04%
Zona Segura	290	5	295	98.31%	1.7%	59.12%
Total	300	199	499			100.00%

Como se puede observar en la Tabla 17, el modelo clasifico tres años antes de la quiebra al 29,06% del total de la muestra en la Zona de Peligro, es decir 145 bancos que se encuentran con una probabilidad alta de quiebra. De estos 145 bancos clasifico correctamente al 100% de los bancos que eventualmente quebraron tres años después. Adicionalmente, se puede observar como el modelo clasificó correctamente el total de la muestra de bancos para 3 años antes de la quiebra ya que no clasifica ningún banco quebrado en la Zona Segura y viceversa.

Para dos años antes de la quiebra, se puede observar un aumento en el porcentaje de clasificación de los bancos, ya que clasifica un 30,66% de la muestra total en la Zona de Peligro, es decir 153 bancos, de los cuales, clasificó correctamente al 100% de los bancos que eventualmente quebraron 2 años después.

En cambio, con la información de un año antes de la quiebra se observa una disminución en el porcentaje de clasificación, donde el modelo clasifico un 21,84% del total de la muestra en la Zona de Peligro. Sin embargo, de los 95 bancos clasificados en la Zona Gris, el 89,5% son bancos quebrados (85 bancos), por lo cual se evidencia que el indicador no es tan preciso tomando sólo el valor del último año. Dicho evento de clasificación, puede ser explicado por la crisis económica en Estados Unidos que vino después del 2008, con aumentos considerados de la tasa de desempleo y del Producto Interno Bruto, lo que provocó una disminución en la demanda de los hogares y por ende de la inflación y las tasas de interés, lo que ocasionó una disminución del valor del índice, así, por citar un ejemplo, vemos cómo el indicador para el Citizens First National Bank, quebrado en 2012, pasó de 0.72% en 2011 a 0.47% en 2012, entrando a una Zona Segura un año antes de la quiebra, sin embargo esto se debe al valor del indicador del sector financiero

estadounidense durante la crisis subprime, ya que tomando como ejemplo el mismo banco anterior, dicho indicador fue de 2,72% en 2008 y de 1,96% en 2009, clasificando en la Zona Gris. De lo anterior concluimos, que niveles presentados como los reportados por el sistema en 2008 a 2010 conllevan a una probabilidad de incumplimiento alta.

5 CONCLUSIONES

La crisis financiera de 2008 tuvo un impacto considerable en la economía global y desencadenó una crisis histórica en el sistema financiero de Estados Unidos, donde una gran cantidad de bancos quebraron debido a la desregulación financiera y económica evidenciadas en la crisis subprime.

Desde 2007 a 2014, 530 bancos estadounidenses se han declarado en quiebra, por lo que este trabajo de grado pretende desarrollar un análisis actualizado de los indicadores y razones financieras que determinan la probabilidad de quiebra de dichas entidades, tomando como referencia los estados financieros publicados por la FDIC (Federal Deposit Insurance Corporation).

Con respecto a la predicción de quiebra, la literatura y la teoría existente han sido ampliamente desarrolladas a lo largo de los años. Se pudo observar que la liquidez, la rentabilidad, el capital, la calidad del activo y el apalancamiento tienen una relación directa con la quiebra de los bancos. Lo anterior permite contar con una base generosa de indicadores y razones financieras con la cual generar las variables independientes del modelo.

De igual manera, la literatura existente permitió identificar plenamente los indicadores y razones más usadas. Donde se encontró que indicadores convencionales como el ROA, el ROE, el Margen Neto de Interés y las razones de apalancamiento como son el Activo sobre el Patrimonio y los Pasivos sobre el Patrimonio, son de bastante utilidad y significancia en la probabilidad de quiebra de los bancos.

De acuerdo a lo anterior, se decidió incluir como parte de las variables independiente los indicadores propuestos por la FDIC, así como indicadores propuestos en otros estudios de probabilidad de quiebra de bancos, y otros de cálculo propio de los autores, con el fin de analizar su comportamiento y significancia en la predicción de la quiebra.

Por otra parte, los modelos y las metodologías aplicadas a la predicción de quiebra han sido desarrollados en gran medida a partir del estudio realizado por Beaver en 1966, sin embargo, se encontró que uno de los modelos de mayor confiabilidad, precisión y uso es el modelo de Regresión Logístico, por lo que se escogió como método a implementar. Adicionalmente, se encontraron otros modelos validos como las Redes Neuronales y los modelos de análisis discriminante los cuales se analizaron y explicaron en el marco teórico del presente trabajo de grado.

En cuanto a la muestra, se seleccionaron aleatoriamente 200 bancos quebrados con años de quiebra que iban desde el 2007 hasta 2014 y 300 bancos no quebrados con información desde el 2011 hasta el 2014. Se encontró que esta muestra es consistente con estudios previos encontrados en la literatura existente. Se incluyeron un total de 20 variables (indicadores o razones financieras) de rendimiento, condición y otros.

Una vez se obtuvieron los resultados del modelo Logit, y a partir del análisis de la Curva ROC y de las Tablas de Clasificación, donde se pudo observar que el modelo estimado tiene un porcentaje de predicción de un 97% de la probabilidad de quiebra, se encontró que nueve indicadores y razones financieras determinan la probabilidad de quiebra de los bancos estadounidenses: Margen Neto de Interés, Ingresos Distintos a Intereses, ROA, Ganancias en Cobertura de Cartera Castigada, Préstamos Netos como Porcentaje de los Activos Totales, Relación de Solvencia Básica, Patrimonio sobre Activo, Reserva (Efectivo/Depósitos) y Pasivo sobre Patrimonio.

Estas variables son consistentes con su razonamiento financiero y literatura existente, tal como se detalló en la Tabla 1, por lo que se puede concluir que las variables usadas

anteriormente son válidas para calcular la probabilidad de quiebra de los bancos estadounidenses.

Para evaluar en profundidad el poder predictivo del modelo, se calculó la probabilidad de quiebra sobre el 100% de la muestra de bancos quebrados usando información hasta tres años antes de la quiebra del banco. Se evidencio que el modelo clasifica en la Zona de Peligro al 73,4% de los bancos quebrados tres años antes de la quiebra, al 79,2% de los bancos quebrados dos años antes de la quiebra y al 89,8% de los bancos quebrados un año antes de la quiebra.

Adicionalmente, se evidencio una disminución en el porcentaje de clasificación de los Bancos Quebrados en la Zona segura. Donde el modelo clasifica en la Zona Segura al 17,1% de los bancos quebrados tres años antes de la quiebra, al 11,60% de los bancos quebrados dos años antes de la quiebra y al 5,10% de los bancos quebrados un año antes de la quiebra. De acuerdo con lo anterior se puede concluir que el modelo es adecuado para la predicción de la quiebra en los bancos estadounidenses hasta tres años antes de la quiebra.

Por otra parte, se pudo observar que cuando se incluía el Costo de Financiación de los Activos Productivos junto con las otras variables propuestas las volvía no significativas dado su poder de predicción y significancia, por lo que se decidió construir un modelo independiente con este indicador, ya que individualmente tiene un gran poder predictivo. A partir de del análisis de la Curva ROC y de la Tablas de Clasificación, se pudo observar que el modelo Logit estimado con solo el Costo de Financiación de los Activos Productivos tiene un porcentaje de predicción del 99.1%%.

6 REFERENCIAS

- Alam, P., Booth, L. K., & Thordason, T. (2000). The use of fuzzy clustering algorithm and self-organizing neural networks for identifying potentially failing banks: An experimental study. *Expert Systems with Applications*, 18, pp. 185–199.
- Alamilla-López y Camargo (2009). Limitaciones del modelo lineal de probabilidad y alternativas de modelación microeconómica. *Temas de Ciencia y Tecnología*, vol. 13, número 39, pp. 3-12.
- Altman, E.I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, 23(4), pp. 589-609
- Altman, E.I. (1993). *Corporate financial distress and bankruptcy: A complete guide to predicting & avoiding distress and profiting from bankruptcy*. New York: John Wiley & Sons.
- Altman, E.I., Hartzell, J., & Peck, M. (1995). *Emerging Markets Corporate Bonds: A Scoring System*. New York: Salomon Brothers Inc.
- Amieva-Huerta, J, & Urriza, B. (2000). Crisis Bancarias: causas, costos, duración, efectos y opciones de política. *Serie Política Fiscal No.108, CEPAL*. Recuperado el 20 de Septiembre de 2014 de <http://hdl.handle.net/11362/7512>.
- Andersen, H. (2008). Failure Prediction of Norwegian Banks; A Logit Approach. *Working Paper, Norges Bank*. Recuperado el 28 de Agosto de 2014 de http://www.norges-bank.no/upload/english/publications/working%20papers/2008/norges_bank_working_paper_2008_02.pdf.

Arango, J.P., Zamudio, N., Orozco I. (2005). Riesgo de crédito: un análisis desde las firmas. *Reporte de Estabilidad Financiera, Banco de la República*. Recuperado el 16 de Septiembre de 2014 de http://www.banrep.gov.co/sites/default/files/publicaciones/archivos/tema_estabilidad_dic_2005_riesgo.pdf.

Avery, R.B., & Hanweck, G.A. (1984). A Dynamic Analysis of Bank Failures. *Research Papers in Banking and Financial Economics-Board of Governors of the Federal Reserve System*, No. 74

Barth, J.R., Brumbaugh, R.D., Sauerhaft, D., & Wang, G.H.K. (1985). Thrift Institution Failures: Causes and Policy Issues. *Proceedings-Federal Reserve Bank of Chicago*, pp. 184-216.

Beaver, W.H. (1966). Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, 4, pp. 71-102.

Bell, T. B. (1997). Neural nets or the logit model? A comparison of each model's ability to predict commercial bank failures. *International Journal of Intelligent Systems in Accounting, Finance and Management*, 6, pp.249–264.

Bellovary, J.L., Giacomino, D.E., & Akers, M.D. (2007) A Review of Bankruptcy Prediction Studies: 1930 to Present. *Journal of Financial Education*, 33, pp. 1-43.

Benito, A., Vlieghe, G. (2000). Stylized facts on UK corporate financial health: evidence from micro-data. *Financial Stability Review, Bank of England*. Recuperado el 25 de septiembre de 2014 de <http://www.bankofengland.co.uk/archive/Documents/historicpubs/fsr/2000/fsrfull10006.pdf>.

- Boyacioglu, M.A., Kara, Y., Baykan, O.K. (2008) Predicting bank financial failures using Neural Networks, Support Vector Machines and Multivariate Statistical Methods: A comparative analysis in the sample of savings deposit insurance fund (SDIF) transferred banks in Turkey, *Expert Systems with Applications*, 36(2), pp. 3355–3366.
- Brockett, P. L., Cooper, W. W., Golden, L. L, & Pitaktong, U. (1994), A Neural Network Method for Obtaining an Early Warning of Insurer Insolvency, *The Journal of Risk and Insurance*, 61(3), pp. 402-424.
- Bunn & Redwood (2003). Company accounts based modeling of business failures and the implications for financial stability [Working Paper no. 210, Bank of England]. Recuperada el 16 de Octubre de 2014.
- Collantes (2001). Predicción con Redes Neuronales: Comparación con las Metodologías de Box y Jenkins [Trabajo de grado, Universidad de Los Andes, Venezuela]. Recuperada el 14 de Enero de 2015.
- Estrella, A., Park, S., & Peristiani, S. (2000). Capital Ratios as Predictors of Bank Failure. *Economic Policy Review - Federal Reserve Bank of New York*, No.6.
- Fletcher, D., & Goss, E. (1993). Application forecasting with neural networks an application using bankruptcy data. *Information and Management*, 24, pp. 159–167.
- Gómez, J.E., Orozco, I., & Zamudio, N. (2006). Análisis de la probabilidad condicional de incumplimiento de los mayores deudores privados del sistema financiero colombiano. *Reporte de Estabilidad Financiera, Banco de la República*. Recuperado 16 de Septiembre de 2014 de http://www.banrep.gov.co/sites/default/files/publicaciones/archivos/analisis_gomez_orozco_zamudio-sept06.pdf

- Gómez, J., Orozco P. (2009). Un Modelo de Alerta Temprana para el Sistema Financiero Colombiano. *Borradores de Economía, Banco de la República*. Recuperado el 16 de Septiembre de 2014 de <http://www.banrep.gov.co/es/contenidos/publicacion/un-modelo-de-alerta-temprana-para-el-sistema-financiero-colombiano>
- Gujarati, D.N., & Porter, D.C. (1978). *Econometría Básica (5ª. Ed)*. Ciudad de México: McGraw-Hill
- Isaac, J.F., & Flores, O. (2010). Modelo probabilístico para bancos norteamericanos ante la recesión no reconocida del 2008. Una herramienta para la toma de decisiones, *Contribuciones a la Economía*. Recuperado el 14 de agosto de 2014 de <http://www.eumed.net/ce/2010a/igf.htm>.
- Jo, H., & Han, I. (1996). Integration of case-based forecasting, neural network, and discriminant analysis for bankruptcy prediction. *Expert Systems with Applications*, 11, pp. 415–422.
- Laffarga, J., Martín, J., & Vázquez, M.J. (1987). Predicción de la crisis bancaria en España. Comparación entre el análisis logit y el análisis discriminante. *Cuadernos de Investigación Contable*, 1(1), pags. 103-110.
- Lennox, C. (1999). Identifying Failing Companies: A Reevaluation of the Logit, Probit and DA Approaches. *Journal of Economics and Business*, 51, pp. 347–364.
- Martin, D. (1977). Early Warning of Bank Failure: A Logit Regression Approach. *Journal of Banking & Finance*, 1(3), pp. 249-276.

- Martínez, O. (2003). Determinantes de fragilidad en las empresas colombianas. *Borradores de Economía, Banco de la República* vol. 259. Recuperado el 30 de septiembre de 2014 de <http://www.banrep.gov.co/sites/default/files/publicaciones/pdfs/borra259.pdf>.
- Meyer, P.A., & Pifer, H.W. (1970). Prediction of Bank Failures. *The Journal of Finance*, 25(4), pp. 853-868.
- Modelos de Elección Discreta. [Trabajo de grado, Universidad de Granada, España]. Recuperada el 14 de Enero de 2015 de <http://www.ugr.es/~romansg/material/WebEco/Eco2-Discreta.pdf>
- Murari, K. (2012). Insolvency Risk and Z-Index for Indian Banks: A Probabilistic Interpretation of Bankruptcy. *IUP Journal Of Bank Management*, 11(3), pp. 7-21.
- Odom, M., & Sharda, R. (1990). A neural network model for bankruptcy prediction. *In Proceedings of the second IEEE international Joint Conference on Neural Networks*, Vol. II, pp. 163–168.
- Ohlson, J.A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), pp. 109-131.
- Ortega, J., Martínez, J., & Valencia, J.C. (2010). El Modelo de Calificación Crediticia Z-Score: Aplicación en la evaluación del riesgo crediticio de HB Fuller Colombia Ltda. *Revista MBA EAFIT*, Recuperado el 16 de septiembre de 2014 de <http://www.eafit.edu.co/revistas/revistamba/Documents/modelo-calificacioncrediticia-z-score.pdf>.
- Petrisor, M., & Lupu, D. (2013). The forecast of bankruptcy risk using Altman model. *USV Annals of Economics & Public Administration*, 13(2), pp. 154-161.

- Pettway, R., & Sinkey, J. (1980). Establishing on-site banking examination priorities: An early warning system using accounting and market information. *Journal of Finance*, 35(1), pp. 137-150.
- Quintanilla, C., Tschorne, A., & Parisi, F. (2002). *Modelo Predictivo de Quiebra Bancaria: El Caso Ecuador. Facultad de Ciencias Económicas y Administrativas. Universidad de Chile.*
- Ravi, V., & Pramodh, C. (2008). Threshold accepting trained principal component neural network and feature subset selection: Application to bankruptcy prediction in banks. *Applied Soft Computing*, 8(4), pp. 1539-1548.
- Ringeling, E. (2004). Análisis Comparativo de Modelos de Predicción de Quiebra y la Probabilidad de Bancarrota [Trabajo de grado, Universidad de Chile]. Recuperada el 9 de Febrero 2015.
- Rose, P., & Kolari, J. (1985). Early warning systems as a monitoring device for bank condition. *Quarterly. Journal of Business and Economics*, 24(1), pp. 43-60.
- Sánchez, M., Sánchez, I., & Castillo, A. Análisis Económico Financiero de los Modelos de Predicción de Quiebra y la Probabilidad de Quiebra. Ponencia presentada en el *Primer Congreso Internacional de Administración*. Hidalgo, México: Universidad Autónoma del Estado de Hidalgo.
- Salchenberger, L., Mine, C., & Lash, N. (1992). Neural networks: A tool for predicting thrift failures. *Decision Sciences*, 23, pp. 899–916.
- Santomero, A., & Vinso, J. (1977). Estimating the probability of failure for firms in the banking system. *Journal of Banking and Finance*, 1(2), pp. 185-205.

- Sinkey, J. (1975). A Multivariate Statistical Analysis of the Characteristics of Problem Banks. *Journal of Finance*, 30(1), pp. 21-36.
- Swicegood, P., & Clark, J. A. (2001). Off-site monitoring for predicting bank under performance: A comparison of neural networks, discriminant analysis and professional human judgment. *International Journal of Intelligent Systems in Accounting, Finance and Management*, 10, pp. 169–186.
- Tam, K. Y., & Kiang, M. (1992). Predicting bank failures: A neural network approach. *Decision Sciences*, 23, pp. 926–947.
- Thomson, J.B. (1991). Predicting Bank Failures in the 1980s. *Economic Review, Federal Reserve Bank of Cleveland*, 27(1), pp. 9-20.
- Wilson, R. L., & Sharda, R. (1994). Bankruptcy prediction using neural networks. *Decision Support Systems*, 11, pp. 545–557.
- Zamudio, N., (2007). Determinantes de la probabilidad de incumplimiento de las empresas Colombianas. *Borradores de Economía, Banco de la República vol. 466*. Recuperado el 30 de septiembre de 2014 de <http://www.banrep.gov.co/sites/default/files/publicaciones/pdfs/borra466.pdf>.

APENDICE

Anexo 1.

Variables No Significativas

Indicador	Beta
UtilO_Actpro	0.477
Rent_Pretax	0.202
ROE	0.848
ChrO_Car	0.889
Eficiencia	0.148
Actprod_ActTot	0.391
ReserC_Ctot	0.609
Cart_DepTot	0.716
Cart_Dep	0.716
DeuS_Patri	0.141
ActL_ActTot	0.127

Nota: *** Significancia al 1%; ** Significancia al 5%;
*Significancia al 10%.