

**DISEÑO DE UN MODELO TEÓRICO DE ANÁLISIS CREDITICIO, USANDO REDES  
NEURONALES ARTIFICIALES APLICADAS A START-UPS**

**Autores**

**Gloria Carolina Guerrero Velandia**

**Néstor Alejandro Gómez Ramírez**

**Yair Alexander Prieto Ardila**

**Especialización Gerencia De Proyectos  
Universidad EAN**

**Revisado y aprobado por  
Leidy Natalia Zapata Restrepo  
Tutor: Seminario De Investigación**

**Bogotá, 2020**

## Resumen

La gestión del riesgo crediticio requiere de alternativas que se adapten al mercado constante, mitigando en lo posible la mayoría de los riesgos internos y externos por otorgar un préstamo a cualquier tipo de cliente. Pero, estos modelos de gestión deben ser mucho más precisos cuando se trata de segmentos especializados, tales como Start-ups; por lo que se presentan oportunidades de refuerzo en los modelos actuales para soluciones más eficaces. Además, las Redes Neuronales Artificiales, son empleadas por su capacidad de aprendizaje frente a los errores constantes, mitigando posiblemente más el riesgo de no pago. En Colombia, la información disponible sobre los Start-ups es limitada en comparación con varios países de la Unión Europea. Por tanto, a partir del caso de estudio de 9 Start-ups europeas de naturaleza CleanTech y mediante una exploración teórica se obtienen posibles variables de entrada que interceden como factores de éxito a nivel de financiamiento de un Start-up, utilizando este insumo para posibles análisis fundamentados en el modelo de riesgo crediticio Cinco C del Crédito y Zeta. Esta investigación buscará formular teóricamente, a través de una caracterización y matriz relacional, un modelo de Redes Neuronales Artificiales adaptado al financiamiento de Start-ups en la banca privada, pretendiendo dar las bases para fortalecer las conclusiones de otorgar o no un producto crediticio.

Palabras clave: CleanTech, Start-up, análisis de riesgo crediticio y Redes Neuronales Artificiales, capas.

### Acrónimos:

- RNA: Red Neuronal Artificial.
- RBF: Redes de Función de Base Radial
- PNN: Redes Neuronales Probabilísticas (Probabilistic Neural Network)
- MLF: Perceptrón Multicapa (Multi-Layer Perceptron)
- MRC: Modelo de Riesgo Crediticio.

## Tabla de contenido

Problema de Investigación .....	5
Antecedentes del problema .....	5
Descripción del problema.....	5
Objetivo General.....	6
Objetivos Específicos .....	6
Justificación.....	6
Marco Teórico .....	10
Metodología general.....	16
Definición de Variables.....	17
Definición conceptual .....	20
Definición operacional.....	31
Población y Muestra .....	33
Metodología particular .....	34
Selección de métodos o instrumentos.....	34
Medición de variables .....	37
Resultados.....	38
Fase 1 .....	38
Instrumento.....	38
Análisis de los datos .....	38
Resultados .....	40
Fase 2 .....	41
Instrumento.....	41
Análisis de los datos .....	42
Resultados .....	44
Fase 3 .....	46
Instrumento.....	46
Análisis de los datos .....	47
Resultados .....	49
Resultado General.....	49
Diseño.....	49
Tipología de RNA.....	49
Número de Capas.....	50

Número de Neuronas.....	50
Pesos y umbrales.....	51
Función de activación .....	51
Proceso de Aprendizaje.....	52
Bosquejo RNA aplicada al MRC.....	53
Conclusiones.....	54
Referencias.....	56

## Problema de Investigación

¿De qué forma proponer el diseño teórico de un modelo de análisis crediticio usando redes neuronales, aplicadas a Start-ups?

## Antecedentes del problema

En términos del Índice de Transición Energética del Foro Económico Mundial, Colombia ocupa el puesto 34 entre 115 países y presenta un porcentaje de desempeño del sistema eléctrico de 71%. Uno de los resultados de esta Transición energética es la aparición de emprendimientos sostenibles o Start-ups (CleanTech) relacionadas al sector de Energías renovables permitiendo que el sector energético cumpla con la proyección de un escenario de Desarrollo Sostenible al año 2040 de generar mínimo el 34% de energía eléctrica en el país por medio de energías renovables como la energía eólica, hídrica, solar, geotérmica, hidráulica y biomasa.

A raíz de esta proyección que impacta al sector energético, y con esto las oportunidades para emprendimiento en el país, en esa materia, surge la problemática respecto a las facilidades de financiación para Start-ups (CleanTech), y es que actualmente las entidades financieras no tienen un modelo de análisis de riesgo crediticio donde manejen las posibles variables que puedan predecir de manera más eficaz si el cliente emprendedor incurrirá en impago o no y con ello evitar pérdidas financieras tanto para la entidad financiera como para el proyecto de emprendimiento que hasta ahora está surgiendo. Es por ello por lo que el objetivo de esta investigación es generar una posible solución de este problema mediante la propuesta del diseño de un modelo de análisis crediticio usando redes neuronales, aplicadas a Start-ups.

## Descripción del problema

Actualmente el sector de CleanTech no provee las suficientes variables de estudio (endógenas y exógenas) para que entidades financieras conozcan situaciones reales de operación y financiación. Además, el MRC en Colombia no posee una regulación que ordene a las instituciones financieras a seguir un estándar de lineamientos para que se evalúe el sujeto de estudio más apropiado para análisis de riesgo crediticio y consecuentemente ajustar modelos próximos a una Start-up (CleanTech).

## Objetivo General

Proponer un diseño teórico de modelo riesgo crediticio aplicado a Redes Neuronales Artificiales, enfocado en Start-ups (CleanTech).

## Objetivos Específicos

1. Analizar las características identificadas según el estudio de caso.
2. Caracterizar MRCs seleccionados al contexto de la investigación.
3. Describir la aplicación del modelo de riesgo utilizando redes neuronales artificiales.

## Justificación

El MRC en Colombia actualmente no posee una regulación estricta salvo por el acuerdo de Basilea, Comité de Supervisión de et al., (2001), que propone unos criterios para la gestión del riesgo en entidades del sector financiero. De acuerdo con Sepúlveda Rivillas, C, et al., (2012), hace que los trabajos en la materia que se han elaborado se enfoquen en el establecimiento de la probabilidad de que la(s) deudas(s) con una o varias entidades, no sean canceladas de acuerdo con las condiciones pactadas en la negociación.

Tradicionalmente el análisis de riesgo crediticio ha utilizado información estructurada como el historial de pago de transacciones para crear modelos tales como regresiones lineales con el fin puntajes crediticios (Muns Orenga, A. ,2019), haciendo uso de elementos tanto cuantitativos como cualitativos relacionados principalmente a la capacidad de pago del cliente, las posibles garantías y el historial financiero del sujeto obtenido de bases de datos históricas de la entidad financiera e información de las centrales de riesgo como la Central de Información Financiera (CIFIN).

Ante las distintas variables que genera el sistema financiero, el Sistema de Administración del Riesgo de Crédito (SARC) refuerza el seguimiento y control de procesos que tengan relación directa con el riesgo crediticio para que haya un monitoreo eficiente de las diferentes etapas de vida de una obligación (otorgamiento, comportamiento y provisiones); razón por la cual las variables contempladas en cada uno deben tener relación directa con el objeto mismo del crédito, así como el análisis y seguimiento a las mismas (Villamil Bahamón, R. ,2013).

Debido a esto, (Zuleta, J., & Alberto, L., 2011) sugiere que actualmente en Colombia solo las empresas con liquidez y apalancamiento tienen acceso a todas las modalidades de financiamiento. Es decir, empresas que ya tengan una porción del mercado y generen ventas; por otro lado, las empresas medianas son los sujetos que tienen menos oportunidades crediticias para el sector financiero privado a nivel empresarial, dada su poca o inexistente actividad económica certificada, es por tanto que se deben presentar garantías con base a sus finanzas y están sujetas a criterio de la entidad.

El modelo de riesgo en las entidades financieras, de acuerdo con Sepúlveda Rivillas, C., et al. (2012) centra como sujeto de análisis de estudio el producto que se está ofreciendo (créditos fijos y/o rotativos), teniendo sus fortalezas y debilidades; una de sus fortalezas es la adaptabilidad profunda de los productos a las necesidades de empresas ya establecidas; por otro lado, su principal debilidad es el desconocimiento de mercados potenciales emergentes, lo que limita sus productos al “cliente” tradicional dejando a un lado empresas nuevas o emergentes.

Además, a nivel crediticio las entidades financieras presentan asimetrías en la información que poseen y la que otorga el cliente, es por ello por lo que el análisis del Riesgo requiere de soluciones que provean la habilidad de mitigar los riesgos en el ciclo de adquisición y retención del cliente.

Los recientes avances en tecnología digital y Data Science han permitido que las Fintech (entidades financieras tecnológicas) surjan como una solución potencialmente prometedora para reducir el costo del crédito y aumentar la inclusión financiera. (Bazarbash, Majid, 2019).

Esta investigación, será aplicada a un nicho en particular que es el de las Start-ups cuya naturaleza está relacionada con electricidad, biotecnología, nuevos materiales, biocombustibles, agua y movilidad sostenible, denominadas como CleanTech. El impacto se analiza desde dos ámbitos:

Desde el ámbito de sostenibilidad, la tierra acercándose lentamente a un punto de inflexión ambiental, la necesidad de enfrentar el cambio climático, a nivel global se han establecido una serie de compromisos en el marco del cumplimiento de los Objetivos del Desarrollo Sostenible (ODS). A la vanguardia de este movimiento están las nuevas empresas de tecnología limpia, guiadas por el mismo lema de hacer que la economía y la sociedad sean más sostenibles, eficientes y limpias.

En Colombia de manera particular, de cara a los compromisos del COP21, el país tiene una meta de reducción del 20% de las emisiones de gases efecto invernadero a 2030. Para tal fin el Gobierno Nacional, a través del Ministerio de Minas y Energía a dispuesto un Plan denominado “Misión para la Transformación Energética”.

Este Plan, incorpora dentro de sus pilares la promoción de energías renovables. En ese mismo sentido el Ministerio del Medio Ambiente, ha presentado en el 2019 su estrategia de Desarrollo Bajo en Carbono.

Destaca dentro de la información de referencia, los datos de la evolución que tendrá el sector energético a nivel mundial, en un escenario de desarrollo sostenible a 2040, con una proyección de participación de energías renovables del 34%, siendo actualmente solo del 13%.

Las condiciones ambientales de Colombia, en materia de recurso eólico y solar, son particularmente favorables en zonas como la Guajira, en donde la velocidad del viento está alrededor de 9 metros/segundo, el doble del promedio mundial, o la radiación solar que es 60% mayor al promedio mundial.

Colombia, se posiciona ante este escenario, en un mercado muy importante para desarrollar nuevos negocios, en materia de energías renovables.

Desde el ámbito de emprendimiento, tras una década de intenso trabajo para modernizar las leyes y las redes tecnológicas del país, hoy Colombia se posiciona como uno de los países de Latinoamérica con mejor ecosistema de emprendimiento, según Google Developers. Cientos de nuevas empresas nacen cada año. Sin embargo, hay un tipo de empresa que está cambiándolo todo gracias a su nivel de innovación; las denominadas Start-ups.

¿Qué es una Start-up?

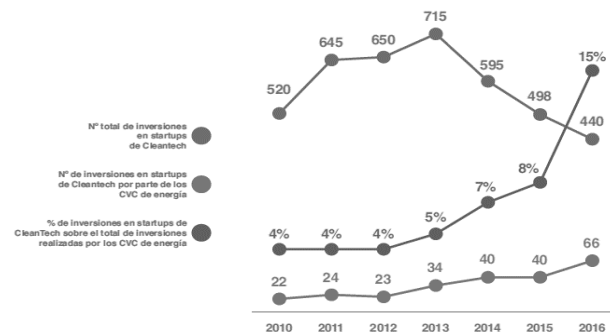
A continuación, se destacan algunas de las definiciones consultadas:

- El blog de Rockcontent (2019), equipo especialista en posicionamiento de marca en la web, define que un Start-up es una empresa con un componente de innovación en etapa temprana que nació y desarrolla su actividad comercial en medios digitales.
- Javier López Menacho, autor del libro “La Farsa de las Start-up” parte de una definición etimológica: “puesta en marcha”, “activación”, “encendido” o “arranque” y a continuación desarrolla una definición propia: empresa basada en una idea de

negocio innovadora, disruptiva en el mercado, con una fuerte vinculación tecnológica (internet y las TIC) y completamente orientada al cliente, cuyo objetivo es satisfacer una necesidad concreta de la sociedad con un modelo económico exponencial y escalable.

- El autor menciona que “Hay muchos proyectos viables, pero pocos invertibles. Un proyecto viable es aquel con el que se puede ganar dinero y va a dar de comer a unas cuantas personas, pero que no es adecuado para un inversor porque no escala. Un proyecto escalable es aquel que en cuatro o cinco años puede convertirse en una referencia global” (Rodolfo Carpintier, 2017)<sup>1</sup>
- Eric Ries, reconocido autor en la materia, describe una Start-up como una institución humana diseñada para crear un nuevo producto o servicio bajo condiciones de incertidumbre extrema. Describe el autor además de un interesante desglose de la definición una conclusión: El futuro es impredecible, los consumidores disponen de una creciente gama de alternativas y el ritmo del cambio se acelera constantemente. Aun así, la mayoría de los Start-ups, ya estén en garajes o en empresas, todavía se gestionan usando las previsiones estándares, los hitos de producto y los detallados planes de negocio.<sup>2</sup>

Dentro de las principales características de las Start-ups, se hace referencia a que son de tamaño reducido en sus equipos, su vocación de negocio global, el distanciamiento con las reglas clásicas de una empresa, la necesidad de una financiación creciente, el requerimiento de un equipo multidisciplinar y los constantes tests de mejora, pruebas ensayo-error a los que someten al producto o servicio<sup>3</sup>.




<sup>1</sup> López Menacho, Javier. La farsa de las Startups.

<sup>2</sup> Ries, Eric. El método Lean Startup

<sup>3</sup> Ilustración, fuente: Everis - Informe Energy Trends Everis.

Everis, empresa de consultoría reconocida en el sector energético a nivel mundial, presenta en su Informe Energy Trends, el análisis de la estrategia inversora de 111 compañías del sector energético (petróleo, gas y electricidad) en el periodo 2008-2016, utilizando como referencia los índices bursátiles internacionales más relevantes. Plantea como objeto de este análisis aquellas Start-ups financiadas con aporte económico por empresas del sector energía (muestra de 483 inversiones en 361 Start-ups); dentro de los datos significativos destaca, una tendencia en aumento de inversiones en CleanTech por parte de empresas del sector energía, a través de inversiones en capital de riesgo (CVC), y a su vez la participación de este segmento sobre el total de inversiones realizadas bajo esta modalidad, que a lo largo de 6 años llegaron a triplicarse, mientras que por otra parte disminuye el total de inversiones por modalidades tradicionales, dentro de las que se encuentran las que son apalancadas por créditos en el sector financiero<sup>4</sup>.

Número de inversiones VC por parte de las corporaciones de energía



## Marco Teórico

Debido a que esta investigación se está llevando a cabo en un periodo de pandemia mundial, no es posible realizar trabajo de campo apropiado que permita dar recopilar datos en una población y obtener resultados de índole cuantitativo, por lo tanto, se optó por realizar este trabajo de investigación mediante la metodología cualitativa complementando la elección del método inductivo ya que, según Cook, T. D., & Reichardt, C. S. (1986), el paradigma cualitativo está “fundamentado en la realidad, orientado a los descubrimientos, exploratorio, expansionista, descriptivo e inductivo”.

A partir del contexto del método inductivo, que se define como el razonamiento que, partiendo de casos particulares, se eleva a conocimientos generales, se aplica el método de inducción incompleta por simple enumeración o conclusión probable, para la demostración de cómo proponer el diseño de un modelo de análisis crediticio usando redes neuronales, aplicadas a Start-ups.

El razonamiento deductivo e inductivo es de gran utilidad para la investigación. La deducción permite establecer un vínculo de unión entre teoría y observación y permite

<sup>4</sup> Ilustración, fuente: Everis - Informe Energy Trends Everis.

deducir a partir de la teoría los fenómenos objeto de observación. La inducción conlleva a acumular conocimientos e informaciones aisladas.<sup>5</sup>

Taylor y Bogdan (1992) señalan que lo que define la metodología es simultáneamente tanto la manera cómo enfocamos los problemas, como la forma en que le buscamos las respuestas a los mismos.<sup>6</sup>

En este sentido, se ha definido como estudio de caso, el segmento de las Start-up, aprovechando la información disponible en la base de datos [www.crunchbase.com](http://www.crunchbase.com). Los criterios de definición para optar por un estudio de caso pueden ser de naturaleza muy diversa; sin embargo, es posible encontrar algunos lineamientos generales como los que plantea Patton (1988) para dar cuenta de las modalidades de muestreo no probabilístico que conducen a realizar observaciones o búsquedas selectivas en casos específicos. Ejemplos de lo anterior son los muestreos de caso desviado o extraordinario, de variación máxima o casos extremos, de caso típico, y de caso crítico entre otros.<sup>7</sup>

De acuerdo a De Gialdino, V. (2006), “los tres componentes más importantes de la investigación cualitativa son los datos cuyas fuentes más comunes son la entrevista y la observación; los diferentes procedimientos analíticos e interpretativos de esos datos para arribar a resultados o teorías; y, por último, los informes escritos o verbales” por lo tanto este trabajo se llevará a cabo mediante una investigación exploratoria obteniendo información relevante en trabajos de investigación anteriores y textos documentales alcanzando una visión general aproximada al problema general de esta investigación debido a que es un tema que ha sido poco explorado, por lo que es difícil formular una hipótesis precisa.

Sandoval (1996), enuncia que el horizonte desde el cual se construye la exploración de la literatura es el de la constitución de un referente teórico que sirve de guía indicativa y provisional para apoyar la construcción conceptual más que para validar o verificar el conocimiento ya existente. La mirada con la que se hace la lectura correspondiente es de naturaleza crítica y selectiva, donde el investigador extrae sus propias conclusiones y mantiene la atención sobre los aspectos que resultan atinentes al tópico de investigación planteado y a los hallazgos realizados durante el proceso.

Para tal fin, se definen los siguientes pasos como claves dentro de la investigación:

---

<sup>5</sup> Dávila Newman, G., (2006). El razonamiento inductivo y deductivo dentro del proceso investigativo en ciencias experimentales y sociales.

<sup>6</sup> Sandoval Casilimas, C. A., Investigación Cualitativa

<sup>7</sup> Sandoval Casilimas, C. A., Investigación Cualitativa

1. Analizar los sectores CleanTech y Bancario bajo observaciones de datos y exploratorias.

Es importante llevar a cabo este análisis bajo observaciones de datos y exploraciones para conocer a profundidad estos dos sectores.

Javier López Menacho, aporta como referencia, cinco fases en las que evoluciona el crecimiento de los Start-ups, que, enfocados en la necesidad de financiación, tienen las siguientes características:

- Fase inicial o 'Seed Stage': Se suele recurrir al capital semilla, es decir, al aporte de fundadores, amigos, familiares, recursos propios o un pequeño inversor que apuesta por el proyecto.
- Fase temprana o 'Early Stage': Se acude a diferentes fondos de inversión, incubadoras y aceleradoras especialistas en Start-ups, que tratan de ayudar a que la empresa se consolide en el mercado.
- Fase de crecimiento o 'Growth Stage': La financiación externa sigue teniendo un peso importante en la viabilidad de la Start-up, sin embargo, los ingresos internos han debido alcanzar el nivel para solventar los pagos del día a día.
- Fase de expansión o 'Expansion Stage': Aparecen conceptos como el Venture (capital de riesgo), mediante el cual una entidad financiera o un fondo de inversión aportaría capital al Start-up a cambio de un porcentaje de participación.
- Fase de salida o 'Exit': Esta fase puede o no suceder, cuando un Start-up ha alcanzado los objetivos empresariales marcados al comienzo de su creación, con la opción de venta o fusionarse con otras de mayor envergadura.

Como resultado de las fases anteriores, las nuevas empresas o emergentes tienen pocas oportunidades de superar la fase número 4, donde empiezan a requerir financiamiento por parte de terceros (empresas grandes, Estado, fondos de inversión y/o entidades financieras); estas últimas presentan los mayores retos para financiarlas, por lo que es importante hacer una revisión a algunos análisis de riesgo crediticio ya que de acuerdo con Támara-Ayús, A., Aristizábal, R., & Velásquez, E. (2012) se deben conocer variables externas e internas para calcular una serie de conclusiones generales: probabilidad de no pago de cualquier cliente. Además, esto ayudará a determinar una base de riesgos y/o barreras en la banca las cuales pueden ser mitigadas con nuevas variables de los Start-ups del sector energético (CleanTech).

Además, estas observaciones ayudan a conocer los retos actuales en materia de riesgo crediticio como, por ejemplo, Támara Ayús, A. L., Aristizábal Velásquez, R. E., & Velásquez Ceballos, H. (2010) sugiere que uno de los retos de esta industria es conocer la cuantificación anticipadamente de las pérdidas potenciales por cada cliente, es decir, si un cliente es riesgoso al prestarle dinero. Esto hace que se conozcan esfuerzos multiinstitucionales entre la banca privada y entidades gubernamentales (tales como SARC, Superintendencia Financiera de Colombia, entre otros) para conocer riesgos sistemáticos, tales como variables macro de la economía del país.

Finalmente, estas observaciones ayudarán a la investigación a seguir pasos de expertos en la materia para así conocer los antecedentes de este sector. Alexi Ludovic, L. F., Marco Antonio, A. C., & Juan, G. M. (2018), sugiere por ejemplo que conocer las restricciones más apropiadas de financiamiento son críticas para el desarrollo de las pymes, lo cual es esencial para las CleanTech; además sugiere que se puede conocer acciones que se han implementado donde se aseguran recuperación de fondos como medidas de mitigar riesgos de no pago por clientes.

2. Establecer las principales causas de no pago de los MRCs (relacionando los sectores CleanTech y Bancario) bajo inferencias causales.

Con base al anterior ejercicio de observación, empiezan a surgir probables correlaciones entre ambos sectores (Bancario y CleanTech) donde se prevé obtener resultados tales como conocer los modelos actuales de análisis de riesgo crediticio que luego se vinculan con el sector de las CleanTech. Por ejemplo, Rodríguez, A., Horst, E., & Malone, S. (2015) en sus modelos usan causas en sus trabajos de investigación.

Estas causas se basan principalmente en series de tiempo de: precios de los activos, compromisos de pagos futuros, tasas de interés y precio de los activos; en resumen, estos análisis van mostrando causas meramente relacionadas a empresas que ya están constituidas que posean “datos” de evaluación. Por tanto, es importante ampliar esas causas-variables actuales para adaptar los análisis de riesgo crediticio al sector de las CleanTech.

Los diferentes modelos de análisis crediticio han tenido evoluciones desde los años 30s donde Smith, R., & Winakor, A., (1935) propusieron un modelo de riesgo evaluado información de contabilidad e información financiera. Posteriormente, en los años 60s se complementan los modelos ya existentes con trabajos adicionales de por ejemplo Tamari (1966), Beaver (1967) y Altman (1968) (Romani et al, 2002). Durante la década de los 70, surgen otros modelos que utilizan técnicas de análisis discriminante, entre estos destacan, Edmister (1972), Blum (1974), Deakin (1972), Libby (1975), Wilcox (1973) y

Romani et al, (2002). En la década de los 80 y 90, se desarrollan algoritmos con un fuerte componente estocástico a través de modelos de máxima verosimilitud y redes neuronales (Romani et al., 2002).

Como resultado de todos los modelos previamente diseñados, en Colombia destaca modelos Credit Scoring. Estos modelos según Alexi Ludovic, et al,(2018) “*proponen automatizar el proceso de gestión de créditos en cuanto a conceder o no una determinada operación crediticia sujeto a variables relevantes de decisión*”; además, el éxito de estos modelos se debe a las calidades del algoritmo y a un sistema eficiente de análisis de datos, ya que definir las causas de no pago como variables de no pago y organizarlas eficientemente en bases de datos ayudan a dar con resultados más precisos para los clientes.

Para ello es importante tener en cuenta los posibles riesgos como variables dentro de este modelo, tales como el riesgo de quiebra; Anderson, D., et al, (2008), sugieren que este tipo de riesgo tienen las siguientes características lo cual lo hace importante dentro de esta investigación:

- Atiende a problemas multifactoriales.
- Propone el uso de modelos multicriterio<sup>8</sup>.
- Reconoce múltiples criterios como objetivos.
- Incorpora información cualitativa y cuantitativa.

### 3. Conectar las causas de no pago con modelos de Redes Neuronales Artificiales.

En Colombia, la normativa dada por la Superintendencia Financiera de Colombia para el manejo del riesgo de crédito, así como los estándares internacionales, tales como Basilea II, Basilea III y Solvency, están basados en regresiones logísticas y en análisis discriminantes, modelos que usan las entidades financieras dentro del país para medir el riesgo crediticio (Arango Correa, et al, 2018) pero no son lo suficientemente eficaces y precisos en el momento de realizar un estudio de crédito para las Pymes que están surgiendo en el mercado empresarial lo cual hace necesario explorar y mejorar las metodologías actuales que generan una predicción más realista del análisis de riesgo crediticio como por ejemplo las Redes Neuronales Artificiales y el ML aplicadas a sectores particulares.

---

<sup>8</sup> Busca comprender e incorporar buenas prácticas de diferentes modelos en un ya existente, como por ejemplo modelos de evaluación económico-financiera, relacionales, jerárquicos, entre otros.

En los años 50 se empezó a hablar sobre un término que hoy en día no es tan desconocido, la “Inteligencia artificial”, para aquella época no había los suficientes avances tecnológicos, pero ya se planteaba la posibilidad de crear máquinas inteligentes. De acuerdo con VILLAMIL BAHAMÓN, R. (2013), *“Las redes neuronales artificiales (RNA) son modelos computacionales diseñados para simular el funcionamiento del cerebro y la forma como éste procesa información. En el contexto de análisis de series de tiempo, se clasifican como modelos no lineales entrenados para: (i) realizar conexiones entre los valores pasados y presentes de una serie de tiempo y (ii) extraer estructuras y relaciones escondidas que gobiernan el sistema de información”*.

Las redes neuronales artificiales (RNA) emulan el comportamiento del cerebro humano descrito anteriormente. Las RNA están formadas por una serie de procesadores llamadas neuronas artificiales que por medio de un cálculo matemático realizado a partir de un vector de entrada o por medio de “estímulos” (valores de entrada) recibidos de otras neuronas proporciona una respuesta única (Salida). Las neuronas artificiales se clasifican en tres tipos o se representan por medio de tres o más capas; las neuronas de entrada (Capa de entrada) son aquellas que reciben información del exterior; Las neuronas ocultas (Capa oculta o varias capas ocultas) son aquellas que reciben estímulos, llevan a cabo el procesamiento básico de la información y emiten salidas dentro de la red neuronal sin tener ningún contacto con el exterior de la misma; Las neuronas de salida (Capa de salida) son aquellas que envían su señal al exterior del sistema (Resultado del cálculo de la red neuronal).

La mayoría de las aplicaciones de inteligencia artificial que existen en la actualidad pertenecen a la rama del aprendizaje automático (Machine Learning) el cual le permite a una máquina generar conclusiones a partir del análisis estadístico de los datos (Fernández Bedoya, A., 2019).

Los recientes avances en tecnología digital y Big Data han permitido que las Fintech (empresas que ofertan a sus clientes productos y servicios financieros innovadores, mediante la utilización de las tecnologías) surjan como una solución potencialmente prometedora para reducir el costo del crédito y aumentar la inclusión financiera. (Bazarbash, Majid, 2019) debido a que se han visto impulsadas por la Inteligencia artificial y Machine Learning para dar apertura a nuevas vías de crecimiento ofreciendo mayor eficiencia operativa y productividad desarrollando soluciones tecnológicas ágiles y escalables con el fin de atender a más clientes a menor costo. (Cuya, M. L., 2016).

#### 4. Establecer una propuesta teórica para el diseño de un MRC.

La presente propuesta pretende combinar los hallazgos encontrados en el sector de las Start-ups (CleanTech) como variables adicionales al modelo scoring para el riesgo crediticio reforzado por Alexi Ludovic, L. et al. (2018) adaptándolas a variables del modelo con redes neuronales para darle capacidad de aprendizaje, generalización y organización de datos cuyas operaciones están basadas en procesos paralelos y pueden ser entrenadas para anticipar y reconocer el comportamiento de las variables en un conjunto complejo de información de acuerdo al modelo propuesto por VILLAMIL BAHAMÓN, R. (2013).

Esta investigación enuncia que antes de entrar en la valoración de un Start-up los inversores privados (Business Angels y Venture capital) verifican que reúnen tres características fundamentales: es viable (con un mercado claro y una ventaja competitiva), factible (tiene el equipo adecuado y el timing es el correcto) e invertible (el negocio es escalable y es posible una salida del inversor con una alta rentabilidad).

Los métodos tradicionales de valoración de empresas - valor contable, descuento de flujos de caja, múltiplos o fondo de comercio, entre otros - son difícilmente aplicables para las compañías Start-ups por encontrarse en las primeras etapas de vida.<sup>9</sup>

#### Metodología general

##### Enfoque, diseño de la investigación y alcance o tipo de estudio

El enfoque de la investigación se realiza desde la perspectiva cualitativa. Dada la contingencia de salud mundial (COVID-19), este estudio investigativo se centra en un enfoque no experimental de tipo relacional<sup>10</sup> y concluirá con la aplicación teórica a modelos de redes neuronales, permitiendo familiaridad con un tópico poco estudiado y útil para desarrollar métodos.

Como caso de estudio se evalúan características de 9 empresas líderes del sector de CleanTech europeas, que se describen<sup>11</sup>. En Colombia, este sector aún no tiene la

<sup>9</sup> Torres Marín, A., Caso BlogsterApp

<sup>10</sup> Según Gómez, M. M. (2006). La investigación no experimental se realiza sin manipular deliberadamente las variables, sino que se observa los fenómenos tal cual su contexto natural (sin generar ningún tipo de cambio) y posteriormente se analizan, cuando es de tipo correlacional la investigación se centra en describir dos o más variables, conceptos o categorías en un momento determinado.

<sup>11</sup> Véase Anexo. Empresas valoradas en el caso de estudio.

representatividad, que se observa en otros continentes, con potencial para desarrollo de nuevos negocios.

### Definición de Variables

Las variables son las características que varían a lo largo de la unidad de análisis, personas, instituciones, población, entre otras. Sampieri (1997) define que una variable es una propiedad que puede variar (adquirir diferentes valores) y cuya variación es susceptible de medirse. Además, pueden ser definidas conceptual y operacionalmente. Conceptualmente, mediante la expresión de lo que se entiende por tal; operacionalmente, mediante la elección de los indicadores que se utilizan para medir, registrar y observar la variable.<sup>12</sup> En la investigación cualitativa, las variables pueden ser de dos tipos: nominales u ordinales.

Los indicadores permiten medir conceptos, cuantificar dimensiones ideáticas, y convertirlas así en utilizables a efectos de manipulación estadística y, por tanto, a efectos comparativos con otras dimensiones conceptuales (González Blasco. 1990). No siempre es un dato numérico y estrictamente medible, particularmente en la investigación cualitativa.

Mediante las siguientes matrices se muestran las variables por evaluar en esta investigación mediante fases predefinidas a los objetivos de investigación:

---

12 García de Ceretto, J., Giacobbe S. (2009). Nuevos desafíos en investigación: teorías, métodos, técnicas e instrumentos.

Tabla 1. Definición de variables fase 1

Fase	Código	Nombre	Tipo	Clasificación	Variables de proximidad			
					Independientes	Intervinientes	Dependientes	Respuesta
1	F1VI1	Tipo de Start-up	Independiente	Cualitativa	F1VI2 - F1VI3	N/A	F2VI1	N/A
1	F1VI2	Número de empleados	Independiente	Cualitativa	F2VI1	N/A	N/A	F3VR1
1	F1VI3	Monto para financiar	Independiente	Cualitativa	F2VI1	N/A	N/A	F3VR1
1	F1VI4	Movimientos financieros	Independiente	Cualitativa	F2VI1	N/A	N/A	F3VR1
1	F1VI5	Antigüedad	Independiente	Cuantitativa	F2VI1	N/A	N/A	F3VR1
1	F1VI6	Ranking BD Crunchbase	Independiente	Cualitativa	F2VI1	N/A	N/A	F3VR1
1 - 2	F1-2V1	Factores de éxito del Start up a nivel de financiamiento	Dependiente - Interviniente	Cuantitativa	F2VI1	N/A	F2VI1	N/A

Elaboración propia.

Tabla 2. Definición de variables fase 2

Fase	Código	Nombre	Tipo	Clasificación	Variables de proximidad			
					Independientes	Intervinientes	Dependientes	Respuesta
1 - 2	F1-2V1	Factores de éxito del Start up a nivel de financiamiento	Dependiente - Interviniente	Cuantitativa	F2VI1	N/A	F2VI1	N/A
2	F2VI2	Datos del modelo	Independiente	Cualitativa	F1-2V1	N/A	F2VI1	N/A
2	F2VI3	Uso en el sector				N/A		N/A
2	F2VI4	Susceptibilidad del modelo				N/A		N/A
2	F2VI5	Confianza del modelo		Cuantitativa		N/A		N/A
2	F2VI6	Dependencia de los datos históricos		N/A		N/A		
2	F2VI7	Dependencia del producto solicitado		N/A		N/A		
2	F2VI8	Estudios complementarios		Cualitativa		N/A		N/A
2	F2VI9	Garantías requeridas				N/A		N/A
2	F2VI10	Agrupación de datos				N/A		N/A
2	F2VI11	Costos de implementación				N/A		N/A
2	F2-3V2	Adaptación del modelo de riesgo				Dependiente - Interviniente		Cualitativa

Elaboración propia.

Tabla 3. Definición de variables fase 3

Fase	Código	Nombre	Tipo	Clasificación	Variables de proximidad			
					Independientes	Intervinientes	Dependientes	Respuesta
3	F3VI2	Topología de Red Neuronal Artificial	Independiente	Cualitativa	F2-3V2	N/A	F3VD1	N/A
3	F3VI3	Método de Aprendizaje de la Red Neuronal Artificial			N/A	N/A	F3VI2	N/A
3	F3VI4	Función de Activación de la Red Neuronal Artificial			N/A	N/A	F3VI2	N/A
3	F3VI5	Función de Coste de la Red Neuronal Artificial			N/A	N/A	F3VI2	N/A
3	F3VI6	Número de capas ocultas de la Red Neuronal Artificial		Cuantitativa	N/A	N/A	F3VI2	N/A
3	F3VI7	Adaptabilidad RNA a clasificación		Cualitativa	N/A	N/A	F3VD1	N/A
3	F3VI8	Predicción RNA en el análisis de riesgo			N/A	N/A	F3VD1	N/A
3	F3VI9	Eficiencia RNA en el análisis de riesgo			N/A	N/A	F3VD1	N/A
3	F3VI10	Uso RNA en industrias financieras			N/A	N/A	F3VD1	N/A
3	F3VD1	Adaptación RNA a modelos de riesgo		Dependiente	Cuantitativa	F3VI2, F3VI3, F3VI4, F3VI5, F3VI6, F3VI7, F3VI8, F3VI9, F3VI10	F2-3V2	F3VD1
3	F3VR1	Diseño teórico de modelo riesgo crediticio aplicado a Redes Neuronales Artificiales	Respuesta	Cualitativa	N/A	N/A	N/A	N/A

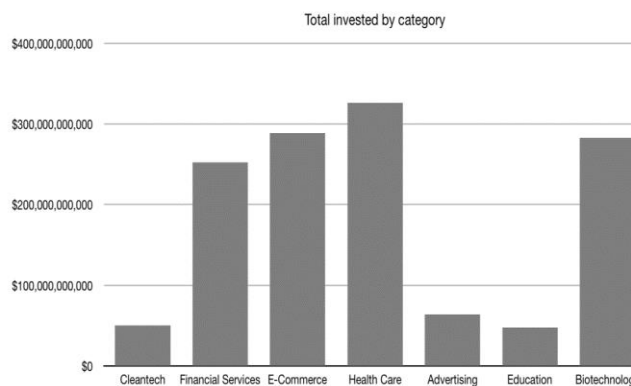
Elaboración propia.

Definición conceptual

Fase 1

**F1VI1 - Tipo de Start-up:** permite identificar de acuerdo con la categoría para la que la Start-up desarrolla un determinado proyecto, el nivel de interés del mercado en inversión en una región específica.

Como referencia, a continuación, se puede observar el nivel de inversión, analizando el comportamiento estadístico disponible de Start-ups registradas en la base de datos Crunchbase, para empresas de la región europea, identificando las siguientes categorías: Cleantech, Financial Services, E-Commerce, HealthCare, Advertising, Education, Biotechnology<sup>13</sup>.



Categoría	Participación
Cleantech	5%
Financial Services	17%
E-commerce	25%
Health Care	30%
Advertising	6%
Education	4%
Biotechnology	13%

A partir de la información estadística disponible se obtiene la participación de cada una de las categorías, la cual es aplicable de manera específica a las Start-up objeto del caso de estudio, por operar éstas en la región europea<sup>14</sup>.

Para este caso, se han seleccionado Start-ups cuyos proyectos se enmarcan en la categoría de Cleantech, considerando ésta de particular interés por su potencial de crecimiento, tal y como se ha descrito en la justificación y

el marco teórico de la presente investigación.

**F1VI2 – Número de empleados:** permite establecer el tipo de empresa con relación a su tamaño, estableciendo en este caso la dimensión de acuerdo con la cantidad de empleados<sup>15</sup>.

<sup>13</sup> Economía de la Empresa (2012) /<https://empresariados.com/cuatro-tipos-de-empresa-segun-su-tamano/>

<sup>14</sup> Ilustración fuente: Economía de la Empresa (2012) /<https://empresariados.com/cuatro-tipos-de-empresa-segun-su-tamano/>

<sup>15</sup> Economía de la Empresa (2012) /<https://empresariados.com/cuatro-tipos-de-empresa-segun-su-tamano/>

**Microempresa:** es un negocio que tiene un máximo aproximado de diez trabajadores en plantilla. Se trata de un micronegocio que puede ser administrado por un único profesional. Pese a que su nivel de facturación sea menor que el de otro tipo de negocios, conviene puntualizar que este tipo de proyectos tienen una gran influencia en la economía social al ser un medio de vida para los profesionales. Además, se trata de un tipo de negocio que puede tener potencial, es decir, una evolución de menos a más.

**Pequeña empresa:** tiene un personal en plantilla de entre 11 y 49 trabajadores. Este tipo de negocio suele tener una tendencia de crecimiento más destacada que la de la microempresa. Además, en su estructura organizacional también cuenta con una división del trabajo. En muchos casos, las pequeñas empresas son negocios familiares.

**Mediana empresa:** en la clasificación de tipos de negocios en función del tamaño también encontramos los negocios medianos. Que ofrecen una mayor oferta de empleo al poder contratar entre 50 y 250 profesionales. Se trata de un tipo de empresa que tiene una mayor estructura a partir de departamentos diferenciados. Tanto las pequeñas como las medianas empresas tienen mucha fuerza en la economía.

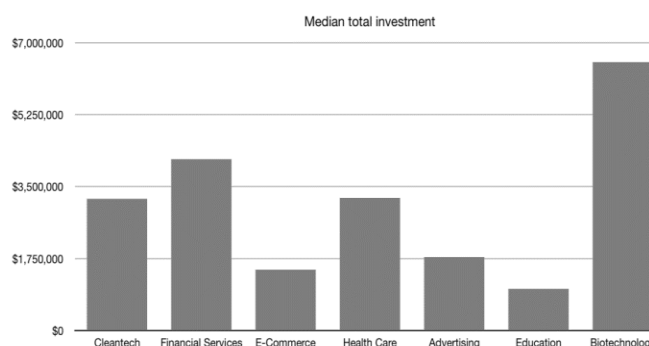
**Grande empresa:** el número de personal en plantilla supera los 250 profesionales. Algunas empresas se desarrollan como multinacionales que tienen sede en distintos países del mundo. Se trata de negocios en expansión internacional.

**F1VI3 – Monto a financiar:** permite identificar en un rango el nivel de dinero que requiere la Start-up y que será objeto de financiación.

Es importante considerar que el sector de tecnologías limpias parece similar a la biotecnología, donde se requieren grandes sumas para desarrollar y comercializar el producto<sup>16</sup>.

David Mytton (2019), experto ambiental y en análisis de riesgo de Start-ups, realiza un análisis del sector

a través de las estadísticas en Crunchbase; enumera 2.044 empresas que se clasifican para sí mismas como CleanTech o Clean Energy, el 95% de las cuales se clasifican como "activas". De esa lista, se han invertido \$ 49.900 millones en 2.694 rondas de



<sup>16</sup> Ilustración, fuente: Estadísticas Crunchbase 2019

financiación. El financiamiento total promedio es de \$ 53 millones, aunque la mediana es de \$ 3 millones.

A partir de la información disponible para las empresas que forman parte del caso, y las referencias estadísticas, se proponen las dimensiones a aplicar, considerando las rondas de financiación activas.

**F1VI4 - Movimientos financieros:** permite establecer el interés de los inversionistas en los proyectos de la Start-up, mediante el histórico de rondas de financiación por año en que ha participado con fondos recaudados.<sup>17</sup>

A diferencia de un Start-up de software que puede construir y lanzar su producto con un solo equipo interno, CleanTech a menudo requiere la comercialización de innovación académica y científica. Al igual que la investigación biotecnológica, puede ser un largo camino hacia la producción de un descubrimiento académico y las fases iniciales tienden a no atraer la inversión del sector privado.

Por lo anterior, las bases de datos que se han venido estructurando a nivel mundial, permiten acceder a históricos de inversión en este tipo de emprendimientos y sectores, detallando no solo los montos a los que han accedido sino también los inversores interesados.

Utilizando como referencia la base de datos Crunchbase, se analizó para las empresas que forman parte del caso, el comportamiento de este aspecto y se proponen las dimensiones a aplicar, considerando el comportamiento anual.

**F1VI5 - Antigüedad:** representa en términos de tiempo la diferencia entre el año en que se hace el análisis con relación al año de fundación de la Start-up. A partir de allí se considera la dimensión en cantidad de años, siendo a mayor tiempo más representativo su posicionamiento individual por la antigüedad en el sector.

Elias (filósofo) define el tiempo como el *“símbolo de una relación que un grupo humano (esto es, un grupo de seres vivos con la capacidad biológica de acordarse y sintetizar) establece entre dos o más procesos, de entre los cuales toma uno como cuadro de referencia o medida de los demás”*.<sup>18</sup>

---

<sup>17</sup> Build Query: Empresas – Crunchbase, 2020

<sup>18</sup> Sobre el tiempo (Edición electrónica 2015)

**F1VI6 - Ranking BD Crunchbase:** Existen diferentes bases de datos en las que se registran las Start-ups, que buscan presentar sus ideas de negocio o proyectos a fin de conseguir inversores, tales como Crunchbase.com o Adventuress.es. Estas organizaciones a partir de la información histórica que se recopila de cada uno de los sectores evalúan y califican a través de un ranking la posición de los diferentes Start-ups, valorando desde aspectos tales como sus credenciales, capacidades, carácter, compromiso hasta su estructura accionaria, transversalidad de los equipos o equilibrio de los fundadores, en general conceptos que no se aplicarían normalmente en el sector tradicional financiero.

Esta variable es cuantitativa. Para efectos de la teorización del modelo, se utilizará el ranking de la base de datos Crunchbase. Cada negocio para el que se busca inversión requiere la confianza en el equipo de la Start-up que llevará la idea de inviable a escalable. La escala inicia en 1 siendo esta la mejor calificación dentro del ranking.

**F1-2V1 - Factores de éxito del Start up a nivel de financiamiento:** a partir de la caracterización de los Start-ups, se proponen los factores de éxito: (i) con el nivel de madurez del Start-up, (ii) el monto a financiar y (ii) con la confianza de los inversores en

Factor De Éxito	Variable	Peso
Nivel de madurez de la Start-up - 15%	F1VI1 Tipo de Start-up	5%
	F1VI2 Número de empleados	5%
	F1-VI5 Antigüedad	5%
Monto para financiar - 25%	F1VI3 monto para financiar	25%
Confianza de los inversores - 60%	F1VI4 movimientos financieros	20%
	F1VI6 Ranking BD crunchbase	40%

la Start-up.

Se asigna un porcentaje a cada variable con el fin de ponderar la valoración de las diferentes variables así

Consultando el Panel Goldsmith ©, que forma parte del modelo Goldsmith © reconocido como “best practice” por el International Business Incubator Association, a continuación, se enuncian las fases del

proyecto de una Start-up: conceptual o fundacional (Pre-semilla), desarrollo o lanzamiento (Semilla) y comercial o expansión (Early/Mid Stage).<sup>19</sup>

El modelo antes mencionado también enuncia cómo se asigna una valoración máxima, basada en una comparativa con otras empresas del mercado en fases de desarrollo similares. Torres Marín (2019), enuncia en su libro “Caso BlogsterApp”, como la confianza en el equipo emprendedor es uno de los factores más importantes a la hora de decidir si invertir o no en un negocio.

<sup>19</sup> Elaboración propia, fuente: Build Query: Empresas – Crunchbase, 2020.

Con base en este criterio se propone como dimensiones, el resultado de la valoración independiente de las variables y su ponderación, expresando los resultados en tres categorías:

- Negocios inviables: Son aquellos que debido a motivos diversos muestran escasas probabilidades de éxito por el momento.
- Negocios sostenibles: son negocios viables, pueden funcionar y ofrecen una rentabilidad interesante para los fundadores y el entorno cercano, pero no necesariamente llegan a cubrir las expectativas de retorno que buscan los inversores profesionales.
- Negocios escalables: son negocios que pueden llegar a tener un crecimiento exponencial, ofreciendo tanto a los inversores la oportunidad de obtener un alto nivel de ganancias. Son el tipo de negocio preferidos por los fondos Venture Capital y los Business Angels profesionales.

## Fase 2

Para la consecución de la fase dos es necesario entender los siguientes conceptos provenientes de diferentes autores. De acuerdo con Chatterjee, S., 2016, un crédito es dinero proporcionado por un acreedor a un prestatario (conocido también como obligado, ya que tiene una obligación de pago) que a su vez tiene un riesgo de crédito que está asociado al incumplimiento de un pago contratado (pactado) y este mismo tiene un costo en el mercado; por ende, un MRC es la función de tomar como insumos diferentes condiciones exógenas (tales como condiciones del mercado, sociedad y cultura) e endógenas (tales como cliente particular para obtener un resultado como diferencial del crédito).

Central de riesgo: de acuerdo con Datacredito<sup>20</sup>, “*son entidades privadas que poseen bases de datos donde las entidades registran las operaciones y el comportamiento crediticio de las personas naturales y jurídicas. Las entidades que reportan información a una central de riesgo pueden ser: bancos, entidades financieras, cooperativas, empresas de telecomunicaciones y del sector real. La información que está contenida en estas bases de datos es tanto positiva como negativa (incumplimiento en el pago de obligaciones)*”.

Asimismo, el alcance de la fase dos estará marcado por dos MRCs encontrados en la literatura; en primer lugar, pasando por enfoques tradicionales se utilizará el modelo de las Cinco Cs del crédito; en segundo lugar, mediante enfoques modernos el modelo Zeta propuesto por Altman. Estos modelos se seleccionaron con base a la relación del modelo

---

<sup>20</sup> Datacredito es una central de riesgo colombiana.

Cinco C del crédito frente a las estrategias de financiamiento a Start-ups frente a la evaluación de características similares a este modelo; mientras que el modelo Zeta buscar evaluar de forma cuantitativa las características exógenas principalmente y endógenas al momento de solicitar un crédito agrupándolo en grupos de financiamiento.

Por consiguiente, el Modelo de las Cinco C del crédito: usado por el prestamista para determinar el riesgo asociado con el préstamo que se solicita, mediante el análisis de cinco macro factores; Carácter, entendido como la honestidad e integridad del deudor a pagar el dinero contratado; Capacidad, entendido como el flujo real de dinero del deudor para afrontar el dinero contratado más sus intereses; Condición, entendido con el análisis de las condiciones exógenas y endógenas del deudor; Capital, entendido como el análisis de los activos resultantes fuera de deudas; Colateral, entendido como el análisis del valor de los activos del deudor y su garantía real Strischek, D. (2009).

Modelo Zeta: este MRC es la segunda generación del modelo Z-Score previamente propuesto en 1968. De acuerdo con Edward Altman (1968), se “utiliza el análisis discriminante como la técnica apropiada para su modelo, este análisis discriminante en su forma más simple busca obtener una combinación lineal de las características que mejor discriminan entre los grupos clasificados, es decir que maximice la varianza entre los grupos y minimice la varianza dentro de cada grupo”. Esto anterior con el propósito de clasificar a las empresas en dos grupos: Bancarrotas y No Bancarrotas.

Mediante la agrupación de esfuerzos en 1977 entre Altman, Haldeman y Narayanan, fueron introducidas algunas modificaciones al modelo Z-Score original, “siendo el propósito de este modelo el clasificar a las empresas en bancarrotas incluyendo lo siguiente: empresas medianas y grandes; empresas del sector no manufacturero; cambios en los estándares de cálculo de las principales razones financieras y; técnicas más recientes del análisis estadístico” García Sánchez, M., & Sánchez Barradas, C. (2005).

Asimismo, teniendo en cuenta la distribución operativa de esta investigación (dividida por fases explicadas posteriormente), mediante el siguiente listado se describen las razones más importantes de estudio en las variables establecidas.

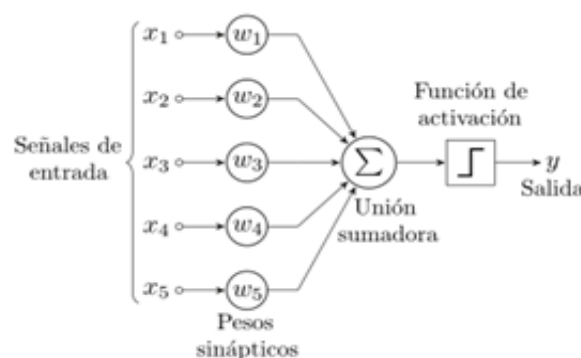
- **F1-2VI1:** conectar los factores de éxito del sector CleanTech en el estudio de caso con los MRCs estudiados.
- **F2VI2:** analizar los datos de entrada y de salida del MRC.
- **F2VI3:** conocer aplicaciones (si existen) de los modelos de riesgo en la literatura del sector CleanTech.

- **F2VI4:** analizar el impacto de los cambios del sector CleanTech en los modelos de riesgo analizados.
- **F2VI5:** conocer la confiabilidad de los modelos a lo largo del tiempo con base a la literatura financiera.
- **F2VI6:** analizar la importancia de los datos históricos del deudor en las respuestas de los modelos analizados.
- **F2VI7:** establecer, con base a la literatura, la dependencia del producto solicitado (crédito) en la respuesta de los modelos estudiados.
- **F2VI8:** revisión de la literatura si el modelo en cuestión se debe complementar con otros modelos.
- **F2VI9:** manejo de las garantías como forma de justificación de un crédito o producto financiero solicitado.
- **F2VI10:** revisión a la literatura frente al grado de agrupación resultantes en los datos de salida (clasificaciones).
- **F2VI11:** revisar la literatura para conocer el grado del costo de implementación del modelo.
- **F2-3V2:** establecer la relación entre las anteriores variables de estudio de la fase 2 obteniendo un nivel de adaptabilidad del MRC en las Start-up CleanTech.

### Fase 3


**F3VI2:** Existen varios de tipos de RNA que se diferencian en su arquitectura, número de capas y su proceso de aprendizaje. Entre los tipos de RNA se encuentran los siguientes:

- **Perceptrón Simple:** De acuerdo con Munt, A. M. (2018). Perceptrón simple es un modelo de Red Neuronal Artificial implementado en 1958 por el psicólogo Frank Rosenblatt y es considerado el modelo más simple y sencillo de las RNA debido a que consta de un conjunto de valores de entrada y una única neurona de salida la cual clasifica los valores en binarios, (1) si la neurona es activada o (0) desactivada<sup>21</sup>.




<sup>21</sup> Ilustración, fuente. Munt, A. M. (2018).

- Perceptrón Multicapa: Según Munt, A. M. (2018). Debido a que el Perceptrón simple era capaz de solucionar problemas de clasificación e implementar funciones lógicas en su procesamiento como las funciones AND y OR pero al mismo tiempo era incapaz de implementar la función XOR y con ello limitándose a no poder solucionar problemas de tipo no lineales, en 1969 Minsky y Papert plantean un modelo de RNA que introducía capas de neuronas artificiales intermedias entre la capa de entrada y capa de salida permitiendo la implementación de cualquier función con el grado de precisión deseado, a este modelo de RNA se le llama Perceptrón Multicapa<sup>22</sup>.



- Redes Convolucionales: Según Á. Iglesias-Puzas,a, P. Boixeda, Las redes neuronales convolucionales (CNN- Convolutional Neural Network) es un modelo de perceptrón multicapa las cuales combinan múltiples capas de aprendizaje especializadas y jerarquizadas con filtros sofisticados que forman redes neuronales profundas para detectar formas complejas.

Las capas ocultas o capas convolucionales reciben valores de entrada que transforman y transmiten a la siguiente capa. Esta modificación de valores u operación convolucional se desarrolla a través de filtros o detectores de patrones establecidos que se representan en una salida reducida y cada vez más abstracta a la entrada recibida (feature maps).

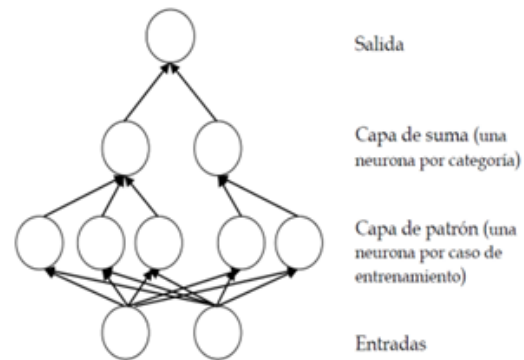
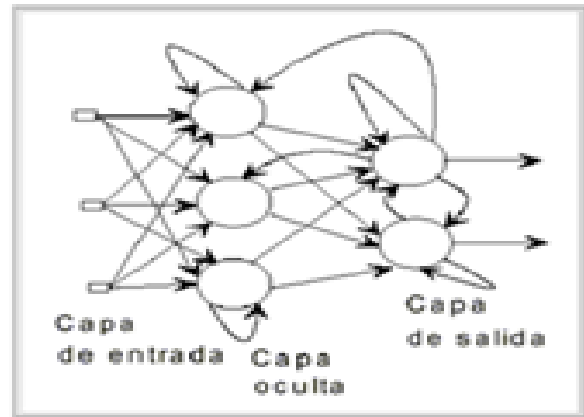


Las capas de clasificación o pooling agregan datos equivalentes tomando la media, el máximo u otras estadísticas de los mapas de características, reduciendo así la incertidumbre de los datos. Las últimas capas obtienen y clasifican los datos en una etiqueta de respuesta (Salida de la red) después de realizar operaciones de normalización<sup>23</sup>.

<sup>22</sup> Ilustración fuente. Munt, A. M. (2018).

<sup>23</sup> Ilustración, fuente Iglesias-Puzas, Á., & Boixeda, P. (2020)

- Redes Recurrentes: De acuerdo con del Peso, M. M. (2001). Las Redes neuronales recurrentes es un modelo de red que es bidireccional (Propagación hacia delante y hacia atrás) debido a que las neuronas se realimentan de sí mismas es decir reciben valores de entrada de la capa anterior, pero al mismo tiempo el valor de salida de las mismas constituye una de sus propias entradas<sup>24</sup>.
- Redes Neuronales Probabilísticas (PNN Probabilistic Neural Network): Según Paucar Sulka, D. C. (2018). Las PNN surgen como una alternativa a las redes neuronales supervisadas. De acuerdo con Villamil Bahamón, R. (2013). Las PNN pertenecen a las redes de función de base radial o RBF y son utilizadas en problemas de clasificación y agrupamiento de información<sup>25</sup>.



La diferencia de las PNN con las redes MLP es que la topología de las PNN se compone de dos capas ocultas y su proceso de entrenamiento se divide en dos fases, una para entrenar la capa oculta de patrón y otra para entrenar la Capa Suma.

**F3VI3:** El método de aprendizaje de las redes neuronales se dividen en dos tipos:

- Aprendizaje supervisado: Según Quesada, F. J. G., Graciani, M. A. F., Bonal, M. T. L., & Díaz-Mata, M. A. (1994)., el aprendizaje supervisado se basa en la utilización de información ya existente donde se suministra a la RNA dos vectores, uno con los valores de entrada y otro con los valores de salida deseados. Con base a la salida generada por la red se realiza una comparación con la salida deseada según la entrada suministrada a la misma, actualizando los pesos sinápticos de la red con el fin de reducir el nivel de error generado. Esto se realiza

<sup>24</sup> Ilustración, fuente. M. M. (2001).

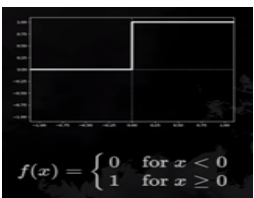
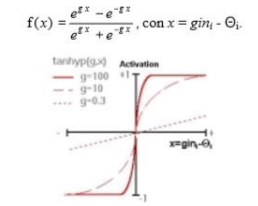
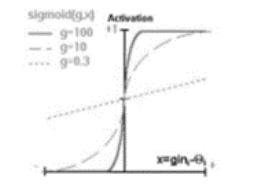
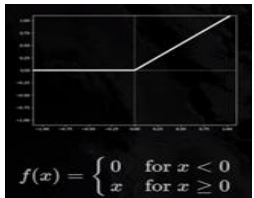
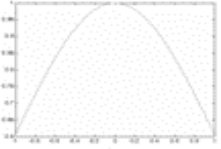
<sup>25</sup> Ilustración, fuente Paucar Sulka, D. C. (2018).

en un número de iteraciones que permitan que el error o coste que existe entre la salida generada y la salida deseada sea el mínimo aceptable.

- Aprendizaje no supervisado: Según Quesada, F. J. G., Graciani, M. A. F., Bonal, M. T. L., & Díaz-Mata, M. A. (1994)., el aprendizaje no supervisado es el más aproximado al funcionamiento del cerebro humano. Este tipo de aprendizaje no hace uso de las salidas deseadas, sino que a partir de las similitudes de las entradas suministradas la red compute, actualice los pesos sinápticos y genere una misma salida.
- Aprendizaje Híbrido: Según Gómez Morales, R. D. J. (2004), aprendizaje híbrido se le denomina al aprendizaje que concentra o incorpora tanto el aprendizaje supervisado como el aprendizaje no supervisado.

**F3VI4:** Las neuronas tanto en las redes neuronales artificiales como las biológicas se activan solamente cuando el procesamiento de información de la neurona anterior sobrepasa un umbral. De acuerdo con Avendaño, J. (2009). En las RNA para que una neurona se active y procese la información recibida de la neurona de la capa anterior necesita de una función de activación la cual generalmente su respuesta está dada por valores binarios de 0 o 1 o valores entre 0 y 1 o entre -1 y 1. Para efecto de este trabajo de investigación se evaluará los siguientes tipos de función de activación:

Tabla 4. Funciones RNAs

Función Escalonada	Función Sigmoide	Función Tangente Hiperbólica	Función RELU	Función Gaussiana
Esta función determina un output o una salida de 1 cuando el valor de entrada es mayor o igual a 0 de lo contrario el output es igual a 0.	Los valores de salida que proporciona se determinan entre 0 y 1, el valor de g determina la pendiente de la función.	Los valores de salida que proporciona esta función se determinan entre -1 y 1, el valor de g determina la pendiente de la función.	RELU o Unidad Rectificada Lineal se comporta como una función lineal tendiendo a 1 cuando el valor de entrada es positiva y constante a 0 cuando el valor es negativo.	La función se expresa de la siguiente forma, donde X es una vector de entrada multidimensional, U <sub>i</sub> es un vector del mismo tamaño que X y Ri(.) es la i-ésima función de base radial con un máximo único o parámetro de ancho $\Omega$ .
 <p>Fuente Dot CSV. (2020)</p>	$f(x) = \frac{e^{gx} - e^{-gx}}{e^{gx} + e^{-gx}}, \text{ con } x = g\text{in}_i - \Theta_i$  <p>Fuente Match, D. J. (2001)</p>	$f(x) = \frac{1}{1 + e^{-gx}}, \text{ con } x = g\text{in}_i - \Theta_i$  <p>Fuente Match, D. J. (2001)</p>	 <p>Fuente Dot CSV. (2020)</p>	 $R_i(X) = \exp\left(-\frac{ X - u_i ^2}{2\sigma_i^2}\right)$ <p>Filali Bouami, M. (2005)</p>

Elaboración propia.

**F3VI5:** El costo o pérdida es el valor que obtiene la red neuronal cuando su predicción es incorrecta, la función de costo tiene como objetivo determinar el error entre el valor

real y el valor estimado o generado por la red con el fin de actualizar y optimizar los parámetros de la RNA (Pesos y umbrales) y que en cada iteración que realice la red mejore su predicción. Entre las funciones de costo se encuentran las siguientes:

Tabla 5. Errores RNAs

Función	Error Cuadrático Medio (MSE- Mean Square Error)	Error Absoluto Medio (MAE – Mean Absolute Error)	Mínimo Error Cuadrado (Least Mean Square)
<b>Descripción</b>	La función MSE realiza una diferencia entre los valores estimados por la RNA y los valores reales, estas diferencias se elevan al cuadrado y posteriormente se calcula el promedio de todas ellas.	La función MAE resulta de que tan cercana es la predicción hecha al resultado real, se realiza una diferencia entre el valor generado por la RNA y el valor real en valor absoluto y luego se calcula el promedio.	Según Filali Bouami, M. (2005). La función LMS se basa en calcular en cada iteración la diferencia entre la salida deseada y la salida generada por el algoritmo.
<b>Fórmula</b>	$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$ <p>Fuente Negrón, P.A. (2014).</p>	$MAE = \frac{1}{N} \sum_{i=1}^N  y_i - \hat{y}_i $ <p>Fuente Negrón, P.A. (2014).</p>	$\sum_{i=1}^n (y_i - f_i^T w_i)^2$ <p>Filali Bouami, M. (2005).</p>

Fuente: Elaboración propia

**F3VI6:** De acuerdo con Matich, D. J. (2001). Las capas ocultas de una RNA son capas internas en la red que no tienen contacto directo con el exterior y según la manera en la que están interconectadas y el número de estas pueden determinar la tipología de red neuronal.

**F3VI7:** Debido a que el análisis de riesgo crediticio está relacionado con problemas de clasificación (Por ejemplo: Clientes buenos/malos), se medirá la adaptación de la tipología de RNA a los problemas de clasificación.

**F3VI8:** Porcentaje de predicción de la tipología de RNA en anteriores investigaciones.

**F3VI9:** Nivel de eficiencia de la tipología de RNA en el análisis de riesgo crediticio.

**F3VI10:** Índice de usabilidad de la tipología de RNA en el análisis de riesgo crediticio actualmente en la industria financiera.

**F3VD1:** Esta variable determinará la tipología y topología (arquitectura) de RNA más adaptable al MRC aplicado a Start-ups.

**F3VR1:** Según los autores se desarrollará un diseño teórico de un MRC adaptado al sector de las Start-ups aplicándolo en un diseño de Modelo de Redes neuronales artificiales con el fin de cumplir el objetivo general de esta investigación.

### Definición operacional

De acuerdo con las variables identificadas por los autores, a través de la siguiente matriz, se describe la consecución de estas por medio de generalizaciones.

### Fase 1

Tabla 6. Definición Operacional Variables – Fase 1

Fase	Código	Dimensiones	Indicadores	Instrumento
1	F1VI1	Porcentaje	% Inversión en el sector	Caracterización y matriz relacional
1	F1VI2	Numérica	No. empleados	
1	F1VI3	Millones de Euros	Capital de la empresa	
1	F1VI4	Numérica	# de financiaciones por año	
1	F1VI5	Tiempo (años)	No. de años: Diferencia en años entre la fecha actual (análisis) y la fundación de la empresa.	
1	F1VI6	Numérica	Según el ranking CB (Crunchbase)	
1	F1-2V1	Numérica de acuerdo con los valores ponderados.	Negocio inviable Negocio Sostenible Negocio escalable	

Fuente: Elaboración propia

Fase 2

Tabla 7. Definición Operacional Variables – Fase 2

Fase	Código	Dimensiones	Indicadores	Instrumento
2	F2VI2	Datos solicitados y generados por el modelo	Grado de adaptabilidad de los siguientes datos del MRC <ul style="list-style-type: none"> <li>Datos de entrada</li> <li>Datos de salida</li> </ul>	Caracterización de modelos de riesgo
2	F2VI3	Ejemplos reales en la literatura de financiamiento a Start-ups del sector CleanTech	Nivel de uso del MRC en el sector de las Start-ups (CleanTech)	
2	F2VI4	Literatura de los MRCs	Nivel de susceptibilidad del MRC ante cambios de la industria	
2	F2VI5	Resultados encontrados en la literatura	Nivel de confianza del MRC en: <ul style="list-style-type: none"> <li>Corto plazo (&lt;1 año)</li> <li>Largo plazo (&gt;1 año)</li> </ul>	
2	F2VI6	Literatura financiera que ahonde en los requisitos de análisis de los modelos	Nivel de dependencia de los siguientes datos históricos en la respuesta del modelo de riesgo: <ul style="list-style-type: none"> <li>Constitución del Start-up.</li> <li>Datos de estados financieros del Start-up.</li> <li>Ventas reales del Start-up.</li> <li>Comportamiento crediticio (centrales de riesgo)</li> </ul>	
2	F2VI7	Revisión de la literatura	Nivel de dependencia del producto solicitado "préstamo" como sujeto de estudio principal del modelo de riesgo	
2	F2VI8		Nivel de dependencia del modelo para complementarse con otros estudios	
2	F2VI9		Dependencia del modelo de una garantía real de pago	
2	F2VI10		Grado de agrupación de datos de salida (clasificaciones)	
2	F2VI11		Grado de costo para implementar el modelo	
2	F2-3V2	Conclusión de hallazgos en la literatura	Nivel de adaptación del modelo en el estudio de caso	

Elaboración propia.

Fase 3

Tabla 8. Definición Operacional Variables – Fase 3

Fase	Código	Dimensiones	Indicadores	Instrumento
3	F3VI2	Tipología: -Perceptrón Simple -Perceptrón Multicapa -Convolutacional -Recurrente	Grado de adaptabilidad de la Tipología de RNA al modelo de riesgo	Caracterización de RNAs y sus variables mediante el análisis de contenido de textos documentales
3	F3VI3	-Aprendizaje Supervisado -Aprendizaje no Supervisado	Grado de adaptabilidad del método de aprendizaje al tipo de RNA seleccionado	
3	F3VI4	Función: -Escalonada -Sigmoide -Tangente Hiperbólica -RELU	Grado de adaptabilidad de la Función de activación al tipo de RNA seleccionado	
3	F3VI5	-Error Cuadrático Medio -Error Absoluto Medio -Error de Sesgo Medio	Grado de adaptabilidad de la Función de costo al tipo de RNA seleccionado	
3	F3VI6	Numero Capas Ocultas; 0, Entre 1 y 2, Más de 2	Cantidad o rango de capas ocultas de la Tipología de RNA	
3	F3VI7	Análisis de la literatura	Nivel de adaptabilidad de la RNA según el problema de clasificación del análisis de riesgo crediticio	
3	F3VI8	Alto > 95% Medio >= 85% <= 95% Bajo < 85%	Nivel de predicción de la Tipología de RNA en el análisis de riesgo crediticio	
3	F3VI9	Análisis de la literatura	Nivel de eficiencia de la Tipología de RNA en el análisis de riesgo crediticio	
3	F3VI10	Análisis de la literatura	Nivel de uso de la RNA en la industria financiera (Riesgo Crediticio)	
3	F3VD1	Arquitectura RNA del estudio realizado	Nivel de adaptación de la RNA al MRC	
3	F3VR1	Teoría del modelo de RNA aplicada al MRC del estudio de Start up	Diseño teórico de la tipología y estudio de las variables de las RNA aplicada al MRC en el caso de estudio	Análisis del Resultado de la variable dependiente(F3VD1)

Elaboración propia.

Población y Muestra

Dadas las condiciones mundiales actuales causadas por el COVID-19, se parte una población en el sector empresarial de energías renovables particularmente en las Start-up. Dado que en Colombia no hay la suficiente representatividad de datos, la muestra se basará en 9 empresas europeas<sup>26</sup>; considerando que es un estudio teórico, este no

<sup>26</sup> Véase Anexo. Empresas valoradas en el caso de estudio.

tendrá un muestreo o procedimiento aplicado, sino más bien búsqueda en la literatura existente y accesible.


Metodología particular

Selección de métodos o instrumentos

Este trabajo va a estar dividido mediante fases que están relacionadas de acuerdo con las diferentes variables definidas en el estudio, sus instrumentos de medición, los objetivos estratégicos y generales.

- **Diagrama de proceso**

- La investigación en curso está dividida en tres fases las cuales agrupan los temas en tres tópicos principales<sup>27</sup>:

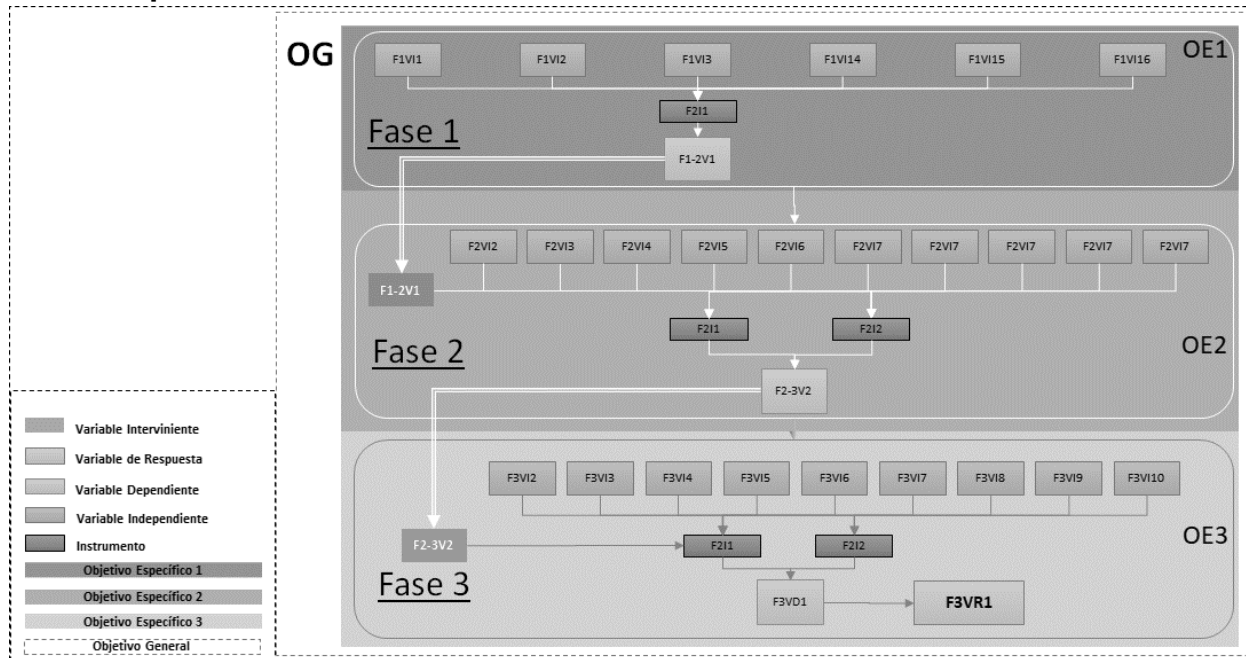


- Fase 1: contempla las variables relacionadas al estudio de caso (10 empresas europeas) del sector CleanTech (Start-ups).
- Fase 2: contempla las variables relacionadas al estudio de los MRCs en investigación (Cinco C del crédito y Zeta).
- Fase 3: contempla las variables relacionadas al estudio de las redes neuronales artificiales en investigación (Perceptrón Simple, Perceptrón Multicapa, Red Neuronal Probabilística)

---

<sup>27</sup> Ilustración, elaboración propia.

● **Mapa mental de interacción**



Elaboración propia.

La anterior ilustración muestra la interdependencia de las variables y los objetivos de la investigación para llevar a cabo el cumplimiento de las fases:

- **Objetivo General (OG):** se obtiene mediante el cumplimiento en secuencia de los objetivos específicos previamente explicado en el diagrama de proceso:
  - **Objetivo Específico 1 (OE1):** ahonda la fase de investigación 1 que revisa los factores de éxito del estudio de caso mediante la caracterización de las variables independientes (Tipo de Start-up, Número de empleados, monto a financiar, movimientos financieros, antigüedad y Ranking CB - base de datos Crunchbase) para obtener los posibles factores de éxito del tipo de Start-up en investigación.
  - **Objetivo Específico 2 (OE2):** ahonda la fase de investigación 2 que revisa los MRCs en esta investigación (Cinco C del crédito y modelo Zeta) mediante la revisión de la literatura bibliográfica de las variables mencionadas anteriormente, para poder calificar las mejores características obteniendo así el modelo más adaptado al estudio de caso; para llevar a cabo el análisis de las variables (en su mayoría cualitativas dado el enfoque teórico de la investigación) de los modelos se utilizará el instrumento “Caracterización” lo cual permitirá ordenarlas y clasificarlas en

el instrumento “Matriz Relacional” de forma cuantitativa y así obtener mediante un puntaje las características más apropiadas a la investigación.

- **Objetivo Específico 3 (OE3):** ahonda la fase de investigación 3 que revisa los tipos de RNAs a evaluar en esta investigación (Perceptrón Simple, Perceptrón Multicapa, Redes Probabilísticas) mediante el análisis bibliográfico sobre las variables (Topología, Método de Aprendizaje, Función de Activación y Función de Coste de la Red Neuronal Artificial, Numero de capas ocultas), para poder calificar las características que mejor se adapten al MRC adoptado en la fase 2; para llevar a cabo este análisis de las variables de los modelos se utilizará el instrumento “Caracterización” lo cual permitirá obtener la topología o arquitectura de RNA según su tipología (tipo de RNA) y posteriormente mediante el instrumento “Matriz Relacional” medir las variables (Adaptabilidad de la RNA al problema de clasificación, Nivel de uso de la RNA en la industria financiera, Nivel de predicción y eficiencia de la Tipología de RNA en el análisis de riesgo crediticio) de forma cuantitativa y así poder obtener mediante un puntaje las características más apropiadas a la investigación.

- **Instrumentos de medición**

- **Caracterización:** la caracterización es útil para conocer las características generales y específicas de un proceso o estado del arte de algo que se presente ahondar. Puntualmente describe que se ha comentado en la literatura y resultados obtenidos en otras investigaciones. Por tanto, una caracterización es una recapitulación de lo dicho e interpretado por otros autores sobre la investigación en curso o un tema relacional.
- **Matriz relacional:** de acuerdo con Sampieri, R. H., Collado, C. F., Lucio, P. B., Valencia, S. M., & Torres, C. P. M. (1998), las matrices son útiles para establecer relaciones entre categorías, temas o ambos, mostrando las variables de estudio en las columnas o filas. En cada celda el investigador documenta si hay o no algún tipo de vinculación entre los mismos y a su vez se puede hacer una versión donde se explique porque se pueden o no asociar. Para este estudio en particular, se hará una calificación relacional entre el modelo y la variable de estudio.

Se va a manejar un modelo de matriz relacional donde en las filas se especificará cada una de las variables previamente establecidas (entiéndase que la fase 2 y fase 3, tendrá una matriz relacional diferente) y los valores de las columnas corresponderá a los modelos o RNAs establecidas. En cada una de las celdas se relaciona el resultado esperado de la medición de estas variables en el MRC o RNA dependiendo su tipo de resultado (cuantitativo o cualitativo). Posteriormente, para las variables

cualitativas se utilizará una conversión numérica (i.e. Alto: 3, Medio:2 u Bajo: 1, así sucesivamente al tipo de medición establecido), para llevar a cabo una sumatoria del resultado de las variables y concluir con un puntaje a comparar entre los MRC o RNAs más adaptables a la investigación<sup>28</sup>.

### Medición de variables

En la siguiente matriz se muestran los tipos de medición por variable:

Tabla 9. Medición de Variables

Fase	Código	Respuestas	Valores de la variable
1	F1VI1	Ordinal	Alto: >25%; Medio: 10% - 25%; Bajo: <10%
1	F1VI2	Nominal	Microempresa: Hasta 10 empleados; Pequeña empresa: Entre 11 y 49 empleados; Mediana empresa: Entre 50 y 250 empleados; Grande: Más de 250 empleados
1	F1VI3	Ordinal	Alto: > 100 y Hasta 500; Medio: > 10 Hasta 100; Bajo: <10 Hasta 0.5
1	F1VI4	Ordinal	Alto: >3; Medio: 2 a 3; Bajo: <2
1	F1VI5	De intervalo	0-100
1	F1VI6	Nominal	Inviable, sostenible, escalable
2	F1-2V1	Nominal	Inviable, sostenible, escalable
2	F2VI2	Ordinal	Alto; Medio; Bajo
2	F2VI3		
2	F2VI4		
2	F2VI5	De intervalo	0% - 100%
2	F2VI6	Ordinal	Alto; Medio; Bajo
2	F2VI7		
2	F2-3V2	Nominal	Adaptable; No Adaptable
3	F3VI2	Ordinal	Alto; Medio; Bajo
3	F3VI3		Alto; Medio; Bajo
3	F3VI4		Alto; Medio; Bajo
3	F3VI5		Alto; Medio; Bajo
3	F3VI6	Rango	0; Entre 1 y 2; Más de 2
3	F3VI7	Ordinal	Alto; Medio; Bajo
3	F3VI8	Ordinal	Alto > 95%;
			Medio >= 85% <= 95%;
			Bajo < 85%
3	F3VI9	Ordinal	Alto; Medio; Bajo
3	F3VI10		Alto; Medio; Bajo
3	F3VD1	Nominal	Adaptable; No Adaptable

<sup>28</sup> Véase Anexo. Modelo de matriz relacional

3	F3VR1	----	Diseño teórico
---	-------	------	----------------

Fuente: Elaboración propia.

## Resultados

### Fase 1

#### Instrumento

En esta fase, se realizó la caracterización de los 9 Start-ups que forman parte del caso de estudio, mediante el uso de una tabla que se estructura enunciando en las columnas cada una de las variables analizadas y en las filas a cada una de las empresas, describiendo en las celdas los resultados y vinculando a la base de datos de la que se extrae la información detallada:

Tabla 10. Instrumento Fase 1

Empresa/Variable	F1VI1	F1VI2	F1VI3	F1VI4	F1VI5	F1VI6
Northvolt	Cleantech	101-250	1,1 B	5	2016	2,658
Sono Motors	Cleantech	101-250	71,9 M	4	2016	4,749
Zeleros	Cleantech	1-10	222 K	3	2016	34,15
Zolar	Cleantech	51-100	14 M	2	2016	13,453
Ecoligo	Cleantech	10-Jan	3,5 M	3	2016	24,343
Solytic	Cleantech	Nov-50	8 M	2	2017	11,975
Energy Vault	Cleantech	Nov-50	110 M	4	2017	3,32
Instagrid	Cleantech		8,5 M	3	2018	14,964
Lancey Energy Storage	Cleantech	Nov-50	10,2 M	3	2016	24,743

Fuente: Elaboración propia.

#### Análisis de los datos

A partir de los resultados, se construye una segunda tabla con la misma estructura, actualizando las equivalencias de acuerdo con las dimensiones e indicadores propuestos, considerando los modelos consultados en que realizan evaluaciones similares para otorgar financiación, pero en modalidades diferentes a las financieras tradicionales; ésta tabla consolida en las celdas la valoración de las variables que formarán parte del modelo para cada una de las empresas.

Los rangos que se asocian a los indicadores para cada una de las variables se establecen a partir de la información histórica del Start-up utilizadas para el caso de estudio. Sin embargo, con la implementación del modelo propuesto utilizando RNA, es

posible hacer que sea dinámico actualizando los parámetros conforme se comporte el mercado. A continuación, se presenta el resumen de los indicadores para cada una de las variables y empresas analizadas:

Tabla 11. Análisis – Fase 1

Empresa/Variable	F1VI1	F1VI2	F1VI3	F1VI4	F1VI5	F1VI6
Northvolt	Bajo	Mediana	Alto	Alto	4	2658
Sono Motors	Bajo	Mediana	Medio	Alto	4	4749
Zeleros	Bajo	Micro	Bajo	Medio	4	34,15
Zolar	Bajo	Mediana	Medio	Medio	4	13453
Ecoligo	Bajo	Micro	Bajo	Medio	4	24343
Solytic	Bajo	Mediana	Bajo	Medio	3	11975
Energy Vault	Bajo	Pequeña	Alto	Alto	3	3,32
Instagrid	Bajo	Mediana	Bajo	Medio	2	14964
Lancey Energy Storage	Bajo	Pequeña	Medio	Medio	4	24,743

Fuente: Elaboración propia

Conversión: a continuación, se estableció la equivalencia numérica que permita construir la variable dependiente a partir de los factores de éxito, utilizando la siguiente información:

Tabla 12. Conversión – Fase 1

Indicador	Equivalencia
Alto	3
Medio	2
Bajo	1
Micro	4
Pequeña	3
Mediana	2
Grande	1

Elaboración propia.

## Resultados

Indicadores Negocio inviable, sostenible, escalable: El cálculo de esta variable, dependiente, implica la ponderación de la equivalencia de las variables independientes de la fase 1. Conforme al resultado se obtiene el indicador, aplicando la siguiente tabla de equivalencia:

Tabla 13. Indicador resultado – Fase 1

Indicador	Equivalencia
<b>Negocio inviable</b>	>15
<b>Negocio sostenible</b>	Entre 5 y 15
<b>Negocio escalable</b>	<5

Fuente: Elaboración propia

A continuación, se presenta el resumen de los resultados para cada una de las variables contempladas en la fase 1, conforme la información obtenida para cada una de las empresas. La suma de éstas arroja el resultado de la variable dependiente F1-2V1:

Tabla 14. Resultado – Fase 1

Variable/Empresa	F1-2V1		F1VI1	F1VI2	F1VI3	F1VI4	F1VI5	F1VI6
<b>Northvolt</b>	Negocio Escalable	276,320	0,05000	0,10000	0,75000	0,60000	0,20000	106,320
<b>Sono Motors</b>	Negocio Escalable	334,960	0,05000	0,10000	0,50000	0,60000	0,20000	189,960
<b>Zeleros</b>	Negocio Sostenible	1,476,000	0,05000	0,20000	0,25000	0,40000	0,20000	1,366,000
<b>Zolar</b>	Negocio Sostenible	663,120	0,05000	0,10000	0,50000	0,40000	0,20000	538,120
<b>Ecoligo</b>	Negocio Sostenible	1,083,720	0,05000	0,20000	0,25000	0,40000	0,20000	973,720
<b>Solytic</b>	Negocio Sostenible	574,000	0,05000	0,10000	0,25000	0,40000	0,15000	479,000
<b>Energy Vault</b>	Negocio Escalable	302,800	0,05000	0,15000	0,75000	0,60000	0,15000	132,800
<b>Instagrid</b>	Negocio Sostenible	688,560	0,05000	0,10000	0,25000	0,40000	0,10000	598,560
<b>Lancey Energy Storage</b>	Negocio Sostenible	1,119,720	0,05000	0,15000	0,50000	0,40000	0,20000	9,89720

Fuente: Elaboración propia

## Fase 2

### Instrumento

Para la segunda fase se llevó a cabo una caracterización de los modelos de riesgo previamente seleccionados (Cinco C del Crédito y Zeta), para luego clasificar cada variable previamente escrita de una forma nominal o por razón; para ello se llevó a cabo la siguiente matriz donde se revisaron los siguientes autores sobre el modelo de riesgo de las Cinco C del Crédito: Strischek, D. (2009), Luna Altamirano, K., Henry Sarmiento, W., & Tinto Arandes, J. (2018), García Sánchez, M., & Sánchez Barradas, C. (2005); y sobre el modelo ZETA: Popov, D. (2018), Altman, E. (2000), García Sánchez, M., & Sánchez Barradas, C. (2005).

Para la matriz se tuvo en cuenta un grado cualitativo de “Alto”, “Medio” y “Bajo” para clasificar las variables principalmente cualitativas; dado que también existen variables cuantitativas, dependiendo el tipo de resultado en la revisión de la literatura puede tener una clasificación de tipo razón o intervalo.

Tabla 15. Instrumento – Fase 2

Variables (indicadores)	Cinco C del Crédito			ZETA		
	Autor 1	Autor 2	Autor 3	Autor 1	Autor 2	Autor 3
<b>F2VI2</b>						
<b>(Indicador 1)</b>	Alto	Alto	Alto	Medio	Medio	N/A
<b>(Indicador 2)</b>	Alto	Alto	Alto	Alto	Alto	N/A
<b>F2VI3</b>	Medio	N/A	N/A	Medio	N/A	N/A
<b>F2VI4</b>	Medio	Medio	Alto	Bajo	Bajo	N/A
<b>F2VI5</b>						
<b>(Indicador 1)</b>	N/A	Medio	N/A	N/A	0.9	0.96
<b>(Indicador 2)</b>	N/A	Alto	N/A	N/A	0.7	0.7
<b>F2VI6</b>						
<b>(Indicador 1)</b>	Medio	Alto	Medio	N/A	N/A	N/A
<b>(Indicador 2)</b>	Medio	Alto	Medio	Alto	Alto	N/A
<b>(Indicador 3)</b>	Medio	Alto	Alto	Alto	Alto	N/A
<b>(Indicador 4)</b>	Medio	Medio	Medio	N/A	Bajo	N/A
<b>F2VI7</b>	Medio	Bajo	Bajo	Bajo	Bajo	N/A
<b>F2VI8</b>	Alto	Alto	Alto	Alto	Alto	Alto
<b>F2VI9</b>	Alto	N/A	Alto	Bajo	Bajo	N/A
<b>F2VI10</b>	N/A	Medio	Bajo	Alto	Alto	N/A
<b>F2VI11</b>	N/A	Alto	Alto	Bajo	Medio	N/A

Elaboración propia.

## Análisis de los datos

### Justificación

Una vez obtenida la información de las características generales y específicas de los MRCs, se llevó a cabo una caracterización de estos en las variables escogidas con el fin de reforzar la elección de los autores<sup>29</sup>

### Conversión

Una vez revisadas las clasificaciones de acuerdo a la información que se interpreta de los autores, se procede a convertir las respuestas cuantitativas en valoraciones cualitativas de la siguiente forma; tipo 1: Alto=3, Medio=2, Bajo=1; tipo 2: Alto=1, Medio=2, Bajo=2; puntualmente para la variable F2VI5 y sus dos indicadores se establece un tipo 3, donde 0% equivale a uno y 3 equivale al 100%, mediante una regla de tres se aplica la proporcionalidad del grado de confianza obtenido por los autores.

Tabla 16. Clasificación – Fase 2

Variables (indicadores)	Conversión cuantitativa	Cinco C del Crédito			ZETA		
		Autor 1	Autor 2	Autor 3	Autor 1	Autor 2	Autor 3
<b>F2VI2</b>							
<b>(Indicador 1)</b>	Tipo 1	3.00	3.00	3.00	2.00	2.00	0.00
<b>(Indicador 2)</b>	Tipo 1	3.00	3.00	3.00	3.00	3.00	0.00
<b>F2VI3</b>	Tipo 1	2.00	0.00	0.00	2.00	0.00	0.00
<b>F2VI4</b>	Tipo 2	2.00	2.00	1.00	3.00	3.00	0.00
<b>F2VI5</b>							
<b>(Indicador 1)</b>	Tipo 1/Tipo 3	0.00	2.00	0.00	0.00	2.70	2.88
<b>(Indicador 2)</b>	Tipo 1/Tipo 3	0.00	3.00	0.00	0.00	2.10	2.10
<b>F2VI6</b>							
<b>(Indicador 1)</b>	Tipo 2	2.00	3.00	2.00	0.00	0.00	0.00
<b>(Indicador 2)</b>	Tipo 1	2.00	3.00	2.00	3.00	3.00	0.00
<b>(Indicador 3)</b>	Tipo 1	2.00	3.00	3.00	3.00	3.00	0.00
<b>(Indicador 4)</b>	Tipo 1	2.00	2.00	2.00	0.00	1.00	0.00
<b>F2VI7</b>	Tipo 1	2.00	1.00	1.00	1.00	1.00	0.00
<b>F2VI8</b>	Tipo 2	1.00	1.00	1.00	1.00	1.00	1.00
<b>F2VI9</b>	Tipo 2	1.00	0.00	1.00	3.00	3.00	0.00
<b>F2VI10</b>	Tipo 1	0.00	2.00	1.00	3.00	3.00	0.00
<b>F2VI11</b>	Tipo 2	0.00	1.00	1.00	3.00	2.00	0.00

Elaboración propia.

<sup>29</sup> Véase Anexo. Caracterización – Fase 2.

De acuerdo con la variación de los datos dada por la interpretación de la lectura de los autores, se decide ponderar los datos de los tres autores por modelo mediante un promedio, buscando así aplanar picos entre las interpretaciones y finalmente llevar a cabo una sumatoria de los puntajes obtenidos.

Tabla 17. Conversión – Fase 2

<b>Variables (indicadores)</b>	<b>Promedio de autores (Cinco C del Crédito)</b>	<b>Promedio de autores (ZETA)</b>
<b>F2VI2</b>		
<b>(Indicador 1)</b>	3	1.33
<b>(Indicador 2)</b>	3	2
<b>F2VI3</b>	0.67	0.67
<b>F2VI4</b>	1.67	2
<b>F2VI5</b>		
<b>(Indicador 1)</b>	0.67	1.86
<b>(Indicador 2)</b>	1	1.4
<b>F2VI6</b>		
<b>(Indicador 1)</b>	2.33	0
<b>(Indicador 2)</b>	2.33	2
<b>(Indicador 3)</b>	2.67	2
<b>(Indicador 4)</b>	2	0.33
<b>F2VI7</b>	1.33	0.67
<b>F2VI8</b>	1	1
<b>F2VI9</b>	0.67	2
<b>F2VI10</b>	1	2
<b>F2VI11</b>	0.67	1.67
<b>Suma</b>	24	20.93

Elaboración propia.

El resultado anterior muestra, en un nivel general, que el modelo de las cinco Cs puede llegar a ser más adaptable frente al estudio de caso de esta investigación (Sector CleanTech para Start-ups). Sin embargo, en los mismos resultados se puede notar que a pesar de la calificación de este modelo, no demuestra ser el que se acople perfectamente a la realidad de este tipo de mercados; por ejemplo se sabe poco del análisis (en la literatura) de estos modelos implementados en el sector de las CleanTech y no se tiene un grado de confianza superior que ofrezca el modelo en el largo plazo, sin mencionar también la dependencia del modelo a complementarse con otros y por último su coste de implementación.

Por tanto, surge, la siguiente relación que recomienda, de acuerdo con los puntajes promedios por los autores, que modelo usar para cada variable en mención.

Tabla 18. Refuerzo Variable MRC – Fase 2

Variables (indicadores)	Modelo que refuerza la variable
<b>F2VI2</b>	
<b>(Indicador 1)</b>	5Cs
<b>(Indicador 2)</b>	5Cs
<b>F2VI3</b>	Indiferente
<b>F2VI4</b>	5Cs
<b>F2VI5</b>	
<b>(Indicador 1)</b>	ZETA
<b>(Indicador 2)</b>	ZETA
<b>F2VI6</b>	
<b>(Indicador 1)</b>	ZETA
<b>(Indicador 2)</b>	5Cs
<b>(Indicador 3)</b>	5Cs
<b>(Indicador 4)</b>	5Cs
<b>F2VI7</b>	5Cs
<b>F2VI8</b>	Indiferente
<b>F2VI9</b>	5Cs
<b>F2VI10</b>	ZETA
<b>F2VI11</b>	5Cs

Elaboración propia.

## Resultados

La fase dos de esta investigación tiene como resultado una combinación de los dos modelos en estudio que recomiendan los autores para que el lector aplique, considerando las siguientes razones:

- La industria no tiene precedentes informativos en el país.
- No hay ningún MRC comprobado en la industria.
- En términos de financiamiento a Start-ups, el riesgo siempre va a ser alto.
- No hay un modelo de riesgo que se adapte en un 100% a una industria tan cambiante y nueva como la mencionada.

Consecuentemente, la combinación entre un experto en la industria con conocimientos de riesgo crediticio y herramientas matemáticas, pueden llevar a cabo una revisión mucho más exhaustiva de lo que una Start-up puede ofrecer al mercado. Por tanto,

surgen nuevas incógnitas que se mencionan en diferentes modelos de riesgo como probabilidades de no pago y bancarrota; puntualmente para este sector se recomienda análisis de probabilidad condicionales, dado el segmento, para determinar valoraciones adicionales que puedan complementar un MRC especializado y en línea directa a esta investigación una RNA.

### Fase 3

#### Instrumento

En la tercera fase el análisis y medición de las variables se divide en dos etapas. En la primera etapa se realiza una caracterización de las tipologías de RNA (Perceptrón Simple, Perceptrón Multicapa y Redes Probabilísticas) y así poder obtener las mejores características de las mismas con el fin de obtener el diseño de la RNA ajustada a un MRC para Start ups según la tipología más adaptable a este tema de investigación cuyo resultado será la etapa 2 donde por medio de una Matriz Relacional se medirá aquellas variables que definen la tipología de RNA relativamente más adaptable al problema de investigación.

Tabla 19. Etapa 1 Caracterización de tipologías de RNA – Fase 3

Variables de caracterización según Tipología de RNA		Tipología de RNA (F3VI2)		
		Perceptrón Simple	Perceptrón Multicapa	Red Probabilística
		Valoración	Valoración	Valoración
<b>Grado de adaptabilidad del método de aprendizaje al tipo de RNA seleccionado (F3VI3)</b>	Aprendizaje Supervisado	Alto	Alto	Bajo
	Aprendizaje no Supervisado	Bajo	Bajo	Bajo
	Aprendizaje Híbrido	Bajo	Bajo	Alto
<b>Grado de adaptabilidad de la Función de activación al tipo de RNA seleccionado (F3VI4)</b>	-Escalonada	Alto	Bajo	Bajo
	-Sigmoide	Bajo	Alto	Bajo
	-Tangente Hiperbólica	Bajo	Alto	Bajo
	Gaussiana	Bajo	Bajo	Alto
	-RELU	Bajo	Medio	Bajo
<b>Grado de adaptabilidad de la Función de costo al tipo de RNA seleccionado (F3VI5)</b>	Error Cuadrático Medio	Bajo	Alto	Bajo
	Error Absoluto Medio	Bajo	Bajo	Bajo
	Error de Mínimo Error Cuadrado	Bajo	Bajo	Alto
<b>Número Capas Ocultas (F3VI6)</b>	0	Alto	Bajo	Bajo
	Entre 1 y 2	Bajo	Alto	Alto
	Más de 2	Bajo	Medio	Bajo

Elaboración Propia.<sup>30</sup>

<sup>30</sup> Véase Anexo. Justificación - Caracterización Tipologías de RNA.

## Análisis de los datos

De acuerdo con la caracterización tanto el Perceptrón simple como el Perceptrón Multicapa pertenecen al tipo de aprendizaje supervisado, en cambio las Redes probabilísticas trabajan de manera híbrida (Aprendizaje híbrido) dividida en dos fases, el primer aprendizaje se realiza de manera no supervisada en su capa oculta de patrón y el segundo aprendizaje lo realiza de manera supervisada en la capa oculta de suma de su topología.

El perceptrón simple trabaja solamente con la función de activación escalonada con el objetivo de solucionar problemas de clasificación linealmente separables a comparación del Perceptrón multicapa que es capaz de solucionar problemas lineales y no linealmente separables y para ello hace uso de funciones sigmoideas en su capa oculta (Sigmoidea, Tangente Hiperbólica) y funciones sigmoideas o lineales para su capa de salida (RELU). Las redes probabilísticas trabajan de forma diferente donde para la activación de sus capas la realiza usando una función Gaussiana donde el valor más cercano al centro o a cero generará un valor de 1 en su salida y así activar la neurona.

Asimismo, el perceptrón simple tiene su propia regla de aprendizaje y función de costo el cual lleva su nombre (Regla de aprendizaje del perceptrón) y se calcula por la diferencia de la salida esperada con la salida generada por la red. El perceptrón multicapa hace uso de la función de error cuadrático medio debido a que trabaja con el optimizador descenso del gradiente (Backpropagation) y las Redes probabilísticas hacen uso de la función del mínimo error cuadrático o regla delta debido a que el algoritmo no supervisado K-means (Algoritmos normalmente usado en el aprendizaje de las redes RBF) utiliza dicha función de coste.

El número de capas ocultas para un perceptrón simple es cero ya que es considerado un modelo monocapa a diferencia su sucesor Perceptrón multicapa que tiene 3 o más capas, pero de acuerdo con los autores de las investigaciones relacionadas en el análisis de la caracterización, este tipo de red trabajo óptimamente con una capa oculta o dos por mucho. Las redes probabilísticas siempre tienen dos capas ocultas (capa de patrón y capa de suma.)

Consecuentemente, se realiza una relación por medio de una calificación cualitativa (Alto, Medio, Bajo) entre las distintas tipologías de RNA y las variables relacionadas a la obtención de la tipología más adaptable a un análisis de riesgo crediticio

Tabla 20. Etapa 2 Matriz de relación – Fase 3

	Tipología de RNA (F3VI2)		
	Perceptrón Simple	Perceptrón Multicapa	Red Probabilística
Variables	Valoración	Valoración	Valoración
(F3VI7)	Bajo	Alto	Alto
(F3VI8)	Bajo	Medio	Alto
(F3VI9)	Bajo	Alto	Alto
(F3VI10)	Bajo	Alto	Bajo

Elaboración propia.<sup>31</sup>

### Conversión

La conversión de los valores cualitativos a cuantitativos de la matriz relacional será dada de la siguiente forma: 1-Bajo, 2-Medio y 3-Alto; posteriormente se realizará una sumatoria de los valores correspondientes para así definir la tipología de RNA más adaptable al análisis de riesgo crediticio.

Tabla 21. Conversión – Fase 3

	Tipología		
	Perceptrón Simple	Perceptrón Multicapa	Red Probabilística
	Valoración	Valoración	Valoración
(F3VI7)	1	3	3
(F3VI8)	1	2	3
(F3VI9)	1	3	3
(F3VI10)	1	3	1
<b>Calificación</b>	<b>4</b>	<b>11</b>	<b>10</b>

Elaboración propia.

<sup>31</sup> Véase Anexo. Justificación - Matriz Relacional Tipologías de RNA.

## Resultados

De acuerdo con la Matriz relacional de la etapa 2, el resultado de esta fase se relaciona de la siguiente manera:

- Según la Matriz, la Red Perceptrón Multicapa es la tipología que relativamente se adapta más a la clasificación de clientes para el análisis de riesgo crediticio.
- Actualmente la red neuronal más común para el análisis de riesgo crediticio en las entidades financieras que utilizan estos modelos de predicción es el perceptrón multicapa.
- Aunque el análisis de la matriz arroje como respuesta el Perceptrón multicapa como la tipología más adaptable a un análisis de riesgo crediticio, no se puede confirmar que sea la mejor opción, inclusive varios autores señalan que la Red probabilística genera mejores resultados y su proceso de aprendizaje es más rápido que el Perceptrón multicapa.

Consecuentemente, la combinación entre un experto en el área de Inteligencia artificial con conocimientos en RNA, pueden llevar a cabo una revisión mucho más exhaustiva de lo que una tipología de red neuronal como la de Perceptrón Multicapa, la Red probabilística u otras tipologías podrían aportar al campo financiero específicamente en el análisis de riesgo crediticio.

## Resultado General

### Diseño

De acuerdo con los resultados obtenidos en las 3 fases de esta investigación el diseño de una RNA adoptada a un modelo análisis crediticio aplicado a Start-ups se llevará a cabo bajo los siguientes criterios:

1. Tipología de RNA
2. Número de capas
3. Número de Neuronas (Capa de Entrada, Capa oculta y Capa de Salida).
4. Pesos y Umbrales
5. Función de activación
6. Proceso de aprendizaje

### Tipología de RNA

De acuerdo con el resultado de la Matriz Relacional de la Fase 3 de esta investigación, este diseño se va a realizar bajo una tipología de Perceptrón Multicapa para la

clasificación de riesgo crediticio de los clientes (Start-ups) y con ello poder definir la concesión del crédito o no.

### Número de Capas

La topología de la red Perceptrón Multicapa se basa en tres o más capas de neuronas artificiales; una capa de entrada, una o más capas ocultas y una capa de salida. Según la caracterización de la tipología del Perceptrón Multicapa (Ver Caracterización – Fase 3), para este diseño se recomienda hacer uso de una capa oculta, sin embargo, se puede hacer uso de dos capas ocultas, esto depende de cómo se comporte la red neuronal con base al porcentaje de predicción de la misma en un ambiente experimental.

### Número de Neuronas

1. Capa de Entrada: El número de neuronas en la capa de entrada está directamente relacionado con el número de variables a analizar por la red neuronal. De acuerdo con el resultado de la fase 1, 2 y 3 de esta investigación, las variables de entrada de la red neuronal son las siguientes:
  1. De acuerdo con el resultado de la fase 1:
    - a. F1VI1: Tipo de Start-up.
    - b. F1VI2: Número de empleados.
    - c. F1VI3: Monto para financiar.
    - d. F1VI4: Movimientos financieros (movimientos bancarios).
    - e. F1VI5: Antigüedad.
    - f. F1VI6: Ranking BD Crunchbase
  2. De acuerdo con el resultado de la fase 2 (modelo recomendado):
    - i. F2VI6:
      1. Indicador 1: Tipo de constitución del Start-Up
      2. Indicador 2: Estados financieros.
      3. Indicador 3: Ventas reales.
      4. Indicador 4: Comportamiento crediticio.
    - ii. F2VI9 (modelo 5 Cs del Crédito): tipo de garantía que ofrece el Start-up (\$).
2. **Capa Oculta:** Según Llano, L., Hoyos, A., Arias, F., & Velásquez, J. (2007), el número de neuronas en la capa oculta normalmente se determina por ensayo y error, aunque también se puede considerar que el número de neuronas ocultas se establece por el promedio entre el número de neuronas de entrada y neuronas de salida.

$$\frac{(nE + nS)}{2}$$

Donde  $nE$  es el número de neuronas en la capa de entrada y  $nS$  es el número de neuronas en la capa de salida.

- Capa de salida: El número de neuronas de salida para este diseño se determina por el número de clases o clasificaciones que se espera como resultado de la red neuronal, lo anterior se relaciona de la siguiente manera:
  - Cada neurona corresponde a una clasificación del resultado de la solicitud de crédito de un cliente.
  - La red neuronal indica que el resultado de una solicitud de un cliente se ubica en una clasificación cuando el resultado que genera la neurona de salida tiende a 1, por lo tanto, las otras neuronas de salida tenderían a 0.

De acuerdo con el MRC seleccionado en la caracterización de la fase 2, se determina que el número de neuronas en la capa de salida (Clasificación de resultados de una solicitud de crédito) son:

- Solicitud aprobada, monto solicitado.
- Solicitud aprobada, monto condicionado.
- Solicitud denegada, recomendación de factores específicos a mejorar.
- Solicitud denegada, recomendación general para mejorar factores.

### Pesos y umbrales

Con el objetivo que una neurona realice sinapsis (se active o se inhibe) entre una capa y otra a cada una de las neuronas de capa de entrada y de la capa oculta se le asigna un valor de peso sináptico y un solo umbral por capa. Según Matich, D. J. (2001), los pesos sinápticos iniciales se pueden determinar por varios criterios, entre ellos, se puede asignar un valor aleatorio entre un intervalo de  $[-n, n]$  donde  $n$  es un número natural positivo. Cabe señalar que estos pesos sinápticos y umbrales se irán modificando en el proceso de aprendizaje de la red neuronal para determinar un grado de predicción alto.

### Función de activación

De acuerdo con la caracterización de la tipología del Perceptrón Multicapa (Ver Caracterización – Fase 3), esta red trabaja con funciones de activación sigmoideas para la capa oculta y funciones lineales o sigmoideas para la capa de salida según el resultado esperado de la red neuronal. Por lo tanto, para este diseño se toma como función de activación la Función sigmoidea ya que para los valores de salida se requiere una predicción de un valor tendiendo a 1 si el cliente se relaciona en una de las clasificaciones de riesgo crediticio, y un valor tendiendo 0 cuando no se clasifica en una de ellas.

$$f\left(\sum_{j=0}^n W_{ij} \cdot X_j - \theta\right)$$
$$f(x) = \frac{1}{1 + e^{-x}}$$

Donde  $W_{ij}$  representa los pesos sinápticos de la red y cada conexión entre neuronas se define por un peso  $W_{ij}$  el cual determina el efecto de la señal de entrada  $j$  sobre la unidad de salida  $i$ . Según Munt, A. M. (2018), los pesos pueden tomar valores positivos, negativos o 0 indicando que no existe ningún tipo de relación entre el par de neuronas.  $X_j$  representa el valor de entrada y  $\theta$  representa el valor del umbral que normalmente es 1.

### Proceso de Aprendizaje

De acuerdo con la caracterización de la tipología del Perceptrón Multicapa (Ver Caracterización – Fase 3), una de las características es el utilizar el algoritmo de Backpropagation (Retro propagación hacia atrás) por lo tanto para este diseño se recomienda realizar el proceso de aprendizaje de la red neuronal con el algoritmo de Backpropagation el cual mediante la obtención del error cuadrático medio que hay entre la salida esperada y la salida generada por la red (según sus variables de entrada) en cada una de las capas iniciando desde la capa de salida la cual propaga el error hacia las capas intermedias y estas a su vez propagan el error hacia la capa de entrada con el fin de actualizar cada uno de los pesos y respectivos umbrales de cada una de las neuronas artificiales. Para entender mejor las matemáticas del algoritmo Backpropagation se recomienda mirar las citas; Mattamala, M. (2013) y Dot CSV. (2018).


## Bosquejo RNA aplicada al MRC

En resumen, el bosquejo muestra un perceptrón multicapa con cada uno de los criterios de diseño de la RNA descritas anteriormente; una capa de entrada con 10 neuronas artificiales (variables de entrada de la solicitud de crédito), una capa oculta de 7 neuronas y una capa de salida con 4 neuronas (clasificaciones de solicitudes de crédito) demostrados de la siguiente forma:

### Capas de entrada

### Capas ocultas

### Capas de salida



Función de activación (hacia la derecha)

# capas puede variar durante la ejecución de la RNA

Proceso de aprendizaje (hacia la izquierda)

Elaboración propia

## Conclusiones

El enfoque propuesto se fundamenta en evaluar el éxito a partir del comportamiento de datos históricos en la naturaleza de la actividad que realiza la Start-up o el proyecto específico para el que requiere inversión. En este punto, existe una oportunidad que ofrece el hecho de que las Start-up, se registran a través de la web con el objeto de exponer sus proyectos y que expertos valoren de acuerdo con las tendencias, estrategias y modelos de negocio la aplicabilidad y potencial de estos. Esta entrada en modelos de riesgo crediticio permite integrar el uso tecnologías como lo son las RNA para hacer estudios mucho más específicos generando así alternativas para que el sector financiero aborde este nicho de mercado.

En la literatura financiera, se pueden encontrar múltiples modelos de riesgo crediticio que van desde una evaluación subjetiva de expertos hasta modelos de alta complejidad estadística, inferencial y matemática; desde la caracterización, se puede contemplar que no hay un único modelo de riesgo crediticio que evalúe las condiciones puntuales y reales de un cliente, así como lo demuestra Altman, E. (2000) en su aplicabilidad del modelo ZETA complementándolo con comportamientos crediticios y Strisczek, D. (2009) en el modelo Cinco C del crédito sugiriendo estudios complementarios para evitar subjetividades en el resultado; se considera que nuevos modelos de riesgo crediticio se empiezan a aplicar a sectores mucho más específicos que le ofrezcan valor a una entidad privada.

De forma paralela, existen varias tipologías de las RNAs, dependiendo su finalidad, son capaces de predecir en un alto porcentaje una salida deseada; por ejemplo, en el ámbito del análisis de riesgo crediticio las RNAs pueden llegar a ser un modelo de estudio óptimo para la concesión de créditos financieros y esto se debe a su gran capacidad para encontrar patrones dentro de la información, realizar un proceso de aprendizaje a partir de ello, clasificar clientes y/o solicitudes de préstamos según su resultado y determinar la viabilidad de la concesión del crédito a un usuario o en este caso una Start-up, mejorando su eficiencia de acuerdo con lo explicado por (Bazarbash, Majid, 2019) en su aplicación de Machine Learning en la banca.

Consecuente, a partir de las variables que permiten caracterizar el nivel de madurez de la Start-up, el monto a financiar y la confianza de los inversores, incorporando no solo datos particulares de la empresa sino también información histórica, se puede lograr minimizar la incertidumbre que tienen los Start-ups de este tipo y genera las bases adecuadas para formular un modelo teórico de análisis de riesgo aplicado a RNA.

Por tanto, el perceptrón multicapa es una RNA capaz de resolver el problema de clasificación que se presenta cuando una entidad financiera realiza un análisis de riesgo crediticio a un Start-up porque se adapta al problema de clasificación, generado en el MCR, a su capacidad de predicción en este tipo de problemas, reforzando lo que la literatura recomienda de RNAs en aplicaciones financieras Khashman, A. (2011). Concluyendo que este tipo de red es capaz de llevar a cabo con resultados a un nivel de confianza del 94% en el análisis de riesgo crediticio Pérez Ramírez, F. O., & Fernández Castaño, H. (2007).

Sin embargo, los autores abren un debate para los lectores en cuanto a la posible implementación de las RNAs probabilísticas en este problema de clasificación. Ya que podría llegar a generar predicciones igualmente certeras o mejores, es decir, *“Las redes probabilísticas son adecuadas para el problema de clasificación del riesgo crediticio ya que, entre otras razones, permite discriminar ampliamente las probabilidades de cumplimiento e incumplimiento”*. ARAYA, V. E. M. (2009).

Por lo tanto, es recomendable para futuras investigaciones tener presente el uso de estos dos tipos RNAs desde una visión teórica para su experimentación aplicada en Start-ups.

## Referencias

- Anderson, D., Sweeney, D. y Williams, T., (2008), *Statistics for Business and Economics*, Mason, Ohio, Estados Unidos: Thomson
- Alexi Ludovic, L. F., Marco Antonio, A. C., & Juan, G. M. (2018). Análisis de riesgo crediticio, propuesta del modelo credit scoring. *Revista Facultad De Ciencias Económicas: Investigación y Reflexión*, 26(1), 181-207. doi: <http://bdbiblioteca.universidadean.edu.co:2138/10.18359/rfce.2666>
- Altman, E. (1968), *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy*, *Journal of Finance*, 23(4), 589-609.
- Altman, E. (2000). PREDICTING FINANCIAL DISTRESS OF COMPANIES: REVISITING THE Z-SCORE AND ZETA® MODELS. *Journal Of Banking & Finance*, 1(1). Retrieved from <http://pages.stern.nyu.edu/~ealtman/Zscores.pdf>
- ARAYA, V. E. M. (2009). Estudio de aplicación de redes neuronales en la evaluación de riesgo crediticio (Doctoral dissertation, PONTIFICIA UNIVERSIDAD CATÓLICA DE VALPARAÍSO).
- Arango Correa, D. M., Colmenares, L. J., & Rave Contreras, I. C. (2018). Comparación entre el método tradicional y algunos basados en inteligencia artificial para el estudio del riesgo crediticio en instituciones financieras colombianas (Master's thesis, Universidad EAFIT).
- Bazarbash, M. (2019). *Fintech in financial inclusion: machine learning applications in assessing credit risk*. International Monetary Fund.
- Barrios, J.C., & Martínez, D.N, & Alcántara, O.M.(2014). Redes Neuronales, "Reporte Final de la Backpropagation"
- Bechara, J. E. A., Cruz, J. C. T., & Ceballos, H. V. (2009). Predicciones de modelos econométricos y redes neuronales: el caso de la acción de SURAMINV. *Semestre Económico*, 12(25), 95-109.
- Britos, M. I. P. (2005). Entrenamiento de redes neuronales basado en algoritmos evolutivos.

- Cerón, L. Á. M., & Otero, R. A. M. (2011). Valoración y riesgo crediticio en Colombia. *Revista Finanzas y Política Económica*, 3(2), 65-82.
- Chatterjee, S., 2016. MODELOS DEL RIESGO DE CRÉDITO. *Centre for Central Banking Studies, Banco de Inglaterra*, 34, pp.273-300.
- Cook, T. D., & Reichardt, C. S. (1986). Métodos cualitativos y cuantitativos en investigación evaluativa. Madrid: Morata.
- Cuya, M. L. (2016). La disrupción de los Start-ups FinTech en el mundo financiero.
- De Gialdino, V. (2006). Estrategias de investigación cualitativa. Barcelona: Gedisa, 42-50.
- Dávila Newman, G., (2006). El razonamiento inductivo y deductivo dentro del proceso investigativo en ciencias experimentales y sociales. *Laurus, Revista de educación. Universidad Pedagógica Experimental Libertador. Caracas, Venezuela.* Recuperado el 24/04/2020 de: <http://www.redalyc.org/articulo.oa?id=76109911>
- Dot CSV. (2018). ¿Qué es una Red Neuronal? Parte 3 : Backpropagation | DotCSV . Recuperado de: [https://www.youtube.com/watch?v=eNlqz\\_noix8](https://www.youtube.com/watch?v=eNlqz_noix8)
- Dot CSV. (2020). ¿Qué es una Red Neuronal? Parte 2 : La Red | DotCSV. Recuperado de <https://www.youtube.com/watch?v=uwbHOpp9xkc&t=428s>
- Fernández Bedoya, A. (2019). Inteligencia artificial en los servicios financieros. *Boletín económico/Banco de España [Artículos]*, n. 2, 2019, 10 p.
- García de Ceretto, J., Giacobbe S. (2009). Nuevos desafíos en investigación: teorías, métodos, técnicas e instrumentos. Homo Sapiens Ediciones. Rosario, Argentina. Recuperado de la base de datos de la Universidad EAN – E-BOOKS
- García Sánchez, M., & Sánchez Barradas, C. (2005). Riesgo de crédito en México: aplicación del modelo CreditMetrics (Licenciatura). Universidad de las Américas Puebla.
- Gómez, J., Sánchez, J., Ocampo, A., & Restrepo, J. W. (2012). APPLICATION OF NEURAL NETWORKS IN CLASSIFICATION OF CLAYS. *Revista EIA*, (17), 183-191.

- Gómez, M. M. (2006). Introducción a la metodología de la investigación científica. Editorial Brujas.
- Gómez Morales, R. D. J. (2004). Nuevo principio de protección diferencial de transformadores aplicando redes neuronales de base radial (RBF) (Doctoral dissertation, Universidad Autónoma de Nuevo León).
- González Cano, L. C. (2019). *Análisis del impacto de la cuarta revolución industrial en el sector bancario colombiano* (Master's thesis, Universidad EAFIT).
- Heaton, J. (2008). Introduction to neural networks with Java. Heaton Research, Inc.
- Hurtado, S., (1999), Criterio de Expertos. ¿Su Procesamiento a través del Método Delphy, [http://www.ub.edu/histodidactica/index.php?option=com\\_content&view=article&id=21](http://www.ub.edu/histodidactica/index.php?option=com_content&view=article&id=21)
- Hurwitz, J. & Kirsh, D. (2018). Machine learning for dummies. New Jersey, Estados Unidos, John Wiley & Sons. Recuperado de: <https://www.ibm.com/downloads/cas/GB8ZMQZ3>
- Investigaciones cualitativas en ciencia y tecnología. Cictec (2017); Editorial Area de Innovación y Desarrollo, S.L. Alicante. Recuperado el 15/03/2020 de: <https://books.google.com.co/books?id=okdVDwAAQBAJ&pg=PA149&dq=investigaciones+cualitativas+sobre+ analisis+de+riesgo&hl=es&sa=X&ved=0ahUKEwjuyymV4rHoAhXwQ98KHRuFB7IQ6AEIKDAA#v=onepage&q=investigaciones%20cualitativas%20sobre%20 analisis%20de%20riesgo&f=false>
- Iglesias-Puzas, Á., & Boixeda, P. (2020). Deep Learning and Mathematical Models in Dermatology. Actas dermo-sifiliograficas.
- Khashman, A. (2011). Credit risk evaluation using neural networks: Emotional versus conventional models. Applied Soft Computing, 11(8), 5477-5484. Recuperado de: <https://www-science-direct-com.bdbiblioteca.universidadean.edu.co/science/article/pii/S1568494611001700>
- Hájek, P. (2010, October). Probabilistic Neural Networks for Credit Rating Modelling. In IJCCI (ICFC-ICNC) (pp. 289-294). Mattamala, M.(2013). Red Neuronal Feed-Forward con Backpropagation. Recuperado de [https://www.u-cursos.cl/usuario/63d40150c4f598d5a65524a836c3b72a/mi\\_blog/r/Tarea\\_2\\_-\\_Matias\\_Mattamala\\_A..pdf](https://www.u-cursos.cl/usuario/63d40150c4f598d5a65524a836c3b72a/mi_blog/r/Tarea_2_-_Matias_Mattamala_A..pdf)

- Llano, L., Hoyos, A., Arias, F., & Velásquez, J. (2007). Comparación del Desempeño de Funciones de Activación en Redes Feedforward para aproximar Funciones de Datos con y sin Ruido. *Avances en Sistemas e Informática*, 4(2).
- López Menacho, Javier. *La farsa de las Start-ups. La cara oculta del mito emprendedor*. Catarata. 2019. Madrid, España. Recuperado el 23/03/2020 de [https://books.google.com.co/books?id=QWWHDwAAQBAJ&printsec=frontcover&dq=tipos+de+Start-up&hl=es&sa=X&ved=0ahUKEwiNnl\\_RyrHoAhVwn-AKHSj8CaY4ChDoAQhuMAg#v=onepage&q=tipos%20de%20Start-up&f=false](https://books.google.com.co/books?id=QWWHDwAAQBAJ&printsec=frontcover&dq=tipos+de+Start-up&hl=es&sa=X&ved=0ahUKEwiNnl_RyrHoAhVwn-AKHSj8CaY4ChDoAQhuMAg#v=onepage&q=tipos%20de%20Start-up&f=false)
- Luna Altamirano, K., Henry Sarmiento, W., & Tinto Arandes, J. (2018). Estudio del riesgo financiero (5c) bajo el enfoque difuso (pp. 47-58). *Revista Economía y Política*. Retrieved from <https://dialnet.unirioja.es/servlet/articulo?codigo=6745359>
- Martín Del Paso, M. (2005). Aplicaciones de las redes neuronales artificiales a problemas de predicción y clasificación financiera. Recuperado de: <https://bdbiblioteca.universidadean.edu.co:2102/lib/bibliotecaeansp/reader.action?docID=3159910&query=redes+neuronales>
- Matich, D. J. (2001). *Redes Neuronales: Conceptos básicos y aplicaciones*. Universidad Tecnológica Nacional, México.
- Moguel Rodriguez Ernesto A. *Metodología de la Investigación*; 2003; Universidad Juárez Autónoma de Tabasco, Recuperado el 15/03/2020 de: <https://books.google.com.co/books?id=r4yrEW9Jhe0C&pg=PA29&dq=metodo+inductivo+y+deductivo&hl=es&sa=X&ved=0ahUKEwiSwvy477HoAhWNTd8KH Yi6BSUQ6AEIPzAD#v=onepage&q=metodo%20inductivo%20y%20deductivo&f=false>
- Munt, A. M. (2018). *Introducción a los modelos de redes neuronales artificiales el perceptrón simple y multicapa*. Universidad de Zaragoza, España.
- Parra, X., Angulo, C., Agell, N., & Rovira, X. (2001). Aproximación a un problema financiero mediante redes neuronales con funciones base radiales y máquinas de soporte vectorial. *Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial*, 5(14), 54-67.
- Quesada, F. J. G., Graciani, M. A. F., Bonal, M. T. L., & Díaz-Mata, M. A. (1994). Aprendizaje con redes neuronales artificiales. *Ensayos: Revista de la Facultad de Educación de Albacete*, (9), 169-180.

- Muns Orenga, A. (2019). *Inteligencia Artificial en los mercados financieros. Consecuencias y aplicaciones* (Bachelor's thesis, Universitat Politècnica de Catalunya).
- Nava R., y Marbelis, A. (2009), Análisis financiero: una herramienta clave para una gestión financiera eficiente, *Revista Venezolana de Gerencia (RVG)*, Año 14. N° 48, 2009, 606 – 628
- Norbert E., (2015). *Sobre el tiempo*. Editorial Fondo de Cultura Económica, México. Consultado el 21/05/2020 de: <https://elibro-net.bdbiblioteca.universidadean.edu.co/es/ereader/bibliotecaeaan/109882>
- Paucar Sulka, D. C. (2018). Evaluación de riesgos crediticios en la empresa Mibanco SA–agencia Chupaca, mediante redes neuronales.
- Pérez Ramírez, F. O., & Fernández Castaño, H. (2007). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías Universidad de Medellín*, 6(10), 77-91.
- Popov, D. (2018). Application of Altman Z-score for Viability of Small and Medium Enterprises. *Journal Business Directions / Journal Biznes Posoki*, 2, 5–17.
- Quichíz, P., & Esteban, L. (2012). Modelo de RNA para predecir la morosidad de microcredito en la Banca Estatal Peruana.
- Ramos Chagoya Ena. (2008, julio 1). *Métodos y técnicas de investigación*. Recuperado el 15/03/2020 de: <https://www.gestiopolis.com/metodos-y-tecnicas-de-investigacion/>
- Ries Eric, 2011. *Cómo crear empresas de éxito utilizando la Innovación Continua*. El método Lean Start-up, Ediciones Deusto, España. Recuperado el 23/03/2020 de [https://books.google.com.co/books?id=v3\\_C4yd-wR4C&printsec=frontcover&dq=tipos+de+Start-up&hl=es&sa=X&ved=0ahUKEwikjMGxxrHoAhWYVt8KHWdWAXUQ6AEITTAE#v=onepage&q=tipos%20de%20Start-up&f=false](https://books.google.com.co/books?id=v3_C4yd-wR4C&printsec=frontcover&dq=tipos+de+Start-up&hl=es&sa=X&ved=0ahUKEwikjMGxxrHoAhWYVt8KHWdWAXUQ6AEITTAE#v=onepage&q=tipos%20de%20Start-up&f=false)
- Romani, G., Aroca, P., Aguirre, N., Leiton, P. y Muñoz, J., (2002), Modelos de clasificación y predicción de quiebra de empresas: Una aplicación a empresas chilenas, *Forum Empresarial*, mayo, año/vol. 7, n° 001

- Roy, J., Lum, K. J., Zeldow, B., Dworkin, J. D., Re, V. L., & Daniels, M. J. (2018). Bayesian nonparametric generative models for causal inference with missing at random covariates. *Biometrics*, 74(4), 1193–1202. <https://bdbiblioteca.universidadean.edu.co:2111/10.1111/biom.12875>
- Rodríguez, A., Horst, E., & Malone, S. (2015). *Bayesian Inference for a Structural Credit Risk Model with Stochastic Volatility and Stochastic Interest Rates*. *Journal of Financial Econometrics*, Volume 13, Issue 4, Fall 2015, Pages 839–867.
- Rodríguez, L., (2012), *Análisis de los estados financieros*, 1ª edición. México: McGraw Hill
- Salinas Gonzalez Javiera; Gómez Navas Juan Sebastian, (2018). Egresius Ediciones. *La investigación cualitativa en la comunicación y en la sociedad digital: nuevos retos y oportunidades*. Recuperado el 15/03/2020 de [https://books.google.com.co/books?id=u31xDwAAQBAJ&printsec=frontcover&dq=investigaciones+cualitativas+sobre+Start-up&hl=es&sa=X&ved=0ahUKEwjUroCh2rHoAhWRMd8KHVFkD\\_oQ6AEIXTAG#v=onepage&q&f=false](https://books.google.com.co/books?id=u31xDwAAQBAJ&printsec=frontcover&dq=investigaciones+cualitativas+sobre+Start-up&hl=es&sa=X&ved=0ahUKEwjUroCh2rHoAhWRMd8KHVFkD_oQ6AEIXTAG#v=onepage&q&f=false)
- Sampieri, R. H., Collado, C. F., Lucio, P. B., Valencia, S. M., & Torres, C. P. M. (1998). *Metodología de la investigación* (Vol. 6). México, DF: Mcgraw-hill.
- Sampieri, R. H. (2010). *Metodología de la investigación*. McGraw-Hill Interamericana. Retrieved from <http://bdbiblioteca.universidadean.edu.co:2071/?il=285>
- Sepulveda Rivillas, C., Reina Gutierrez, W., & Gutierrez Betancur, J. (2012). Estimación del riesgo de crédito en empresas del sector real en Colombia. *Estudios Gerenciales*, 28(124), 169-190.
- Smith, R., & Winakor, A., (1935), *Changes in the Financial Structure of Unsuccessful Industrial Corporations*, Bulletin No. 51, University of Illinois, Bureau of Business Research, Urbana
- Soriano Llobera, J.M., Garcia Pellicer, M.C, Torrents Arevalo, J.A. (2012). *Economía de la Empresa*. Universitat Politècnica de Catalunya, Barcelona. Consultado el 21/05/2020 de <https://elibro-net.bdbiblioteca.universidadean.edu.co/es/ereader/bibliotecaeaan/52179>

- Strischek, D. (2009). The five cs of credit. The RMA Journal, 91(8), 34-37,11. Retrieved from <https://search-proquest-com.bdbiblioteca.universidadean.edu.co/docview/209782549?accountid=34925>
- Start-ups en Colombia: Cuales están cambiando la forma de emprender en el país. (2019). Blog Rockcontent. Recuperado el 15/03/2020 de: <https://rockcontent.com/es/blog/Start-ups-en-colombia/>
- Tablada, C. J., & Torres, G. A. (2009). Redes neuronales artificiales. Revista de educación matemática, 24(3).
- Támara-Ayús, A., Aristizábal, R., & Velásquez, E. (2012). Matrices De Transición en El Análisis Del Riesgo Crediticio Como Elemento Fundamental en El Cálculo De La Pérdida Esperada en Una Institución Financiera Colombiana. Revista Ingenierías Universidad de Medellín, 11(20), 105–114.
- Támara Ayús, A. L., Aristizábal Velásquez, R. E., & Velásquez Ceballos, H. (2010). *ESTIMACIÓN DE LAS PROVISIONES ESPERADAS EN UNA INSTITUCIÓN FINANCIERA UTILIZANDO MODELOS LOGIT Y PROBIT*. Colombia: Universidad Pontificia Bolivariana.
- Tamari, M., (1966), Financial ratios as a means of forecasting bankruptcy, Management International Review, 4, 15-21
- Tojar Hurtado Juan Carlos, Investigación cualitativa: comprender y actuar, 2006. Editorial La Muralla, S.A. Recuperado el 15/03/2020 de: <https://books.google.com.co/books?id=IXcdV7aLbWcC&pg=PA209&dq=investigaciones+cualitativas+sobre+analisis+de+riesgo&hl=es&sa=X&ved=0ahUKEwjuypmV4rHoAhXwQ98KHRuFB7IQ6AEIQDAD#v=onepage&q=investigaciones%20cualitativas%20sobre%20analisis%20de%20riesgo&f=false>
- Torres, J. A. V., & Rivera, J. A. D. (2007). Entrenamiento de una red neuronal multicapa para la tasa de cambio euro-dólar (EUR/USD). Ingeniería e investigación, 27(3), 106-117.
- Torres Marín, A., Arregui, V., Hernandez Oaknín, Y., Moratiel Yugueros, A., Sevilla Bernardo, J., (2019). Caso BlogsterApp: creación de un Start-up y su financiación a través de crowdfunding. ESIC Business & Marketing School. Madrid. Recuperado de la base de datos de la Universidad EAN – E-BOOKS

Villamil Bahamón, R. (2013). Modelo predictivo neuronal para la evaluación del riesgo crediticio (Doctoral dissertation, Universidad Nacional de Colombia).

Zhao, Z., Xu, S., Kang, B. H., Kabir, M. M. J., Liu, Y., & Wasinger, R. (2015). Investigation and improvement of multi-layer perceptron neural networks for credit scoring. *Expert Systems with Applications*, 42(7), 3508-3516. Recuperado de: [https://www.sciencedirect-com.bdbiblioteca.universidadean.edu.co/science/article/pii/S0957417414007726](https://www.sciencedirect.com/bdlibiblioteca.universidadean.edu.co/science/article/pii/S0957417414007726)

Zuleta, J., & Alberto, L. (2011). Política pública e instrumentos de financiamiento a las pymes en Colombia.