

# FACULTAD DE CIENCIAS ECONÓMICAS Y EMPRESARIALES

# Credit scoring aplicado a países emergentes

Trabajo de Suficiencia Profesional para optar el Título de Economista

Pedro Alejandro Castillo Flores

Revisor(es): Mgtr. Harry Omar Patrón Torres

Piura, febrero de 2021



#### Resumen

El presente documento analiza los distintos enfoques realizados a partir de la aplicación de modelos Credit Scoring en economías emergentes y presenta sus resultados más relevantes. La literatura coincide en apuntar que el mayor desafío que se debe enfrentar para el desarrollo y masificación de estos modelos en economías como la nuestra es una limitación en la cantidad y calidad de los datos a los que las entidades pueden tener acceso. Se ha encontrado evidencia de que la pobre medición sobre los beneficios y ventajas de la implementación de estos sistemas sumado a la deficiencia en la capacidad técnica en la mayoría de las instituciones participantes y la alta concentración de mercado acarrea costos adicionales a las entidades de menor tamaño para el desarrollo de dichos modelos. Se recomienda ampliar la investigación para el mercado peruano, así como medir el impacto del RCC como herramienta de evaluación y selección de solicitudes de crédito.





# Tabla de contenido

Introducción	11
Capítulo 1 Informe de experiencia profesional	13
1.1 Elektra del Perú S.A Sucursal Tienda Italika Piura	13
1.1.1 Descripción de la empresa	13
1.1.2 Productos y servicios	13
1.1.3 Estructura organizativa de la empresa	13
1.1.4 Puesto, propósito y funciones	14
1.2 Trayectoria y aportes profesionales	15
1.2.1 Relevancia y valoración de la trayectoria en la empresa	15
1.2.2 Contribución de la formación académica en el desempeño profesional	
1.2.3 Aporte individual	16
Capítulo 2 Tópico de economía financiera - Credit Scoring aplicado a países emergentes	17
2.1 Antecedentes	
2.2 Descripción de las principales técnicas de modelado	19
2.2.1 Análisis discriminante	20
2.2.3 Árboles de decisión	22
2.2.4 Random Forest	26
2.2.5 Redes neuronales	28
2.2.6 Ventajas y desventajas de cada modelo	
2.3 Aplicaciones empíricas	31
2.3.1 Schreiner (2000)	31
2.3.2 Thomas (2000)	32
2.3.3 Frame et al. (2001)	33
2.3.4 Avery et al. (2001)	34
2.3.5 Dinh y Kleimeier (2007)	34
2.3.6 Espin-García y Rodríguez-Caballero (2013)	35
2.3.7 Ala'raj et al. (2018)	35
2.4 Dificultades que presentan los países emergentes para la implementación de los modelos	de
credit scoring	36
Conclusiones	39
Lista de referencias	41
Notas al pie de página	43



# Lista de tablas

Tabla 1. Evolución de los modelos y sus aplicaciones empíricas	. 18
Tabla 2. Ventajas y desventajas de los modelos presentados	. 30





# Lista de figuras

Figura 1. Organigrama de Italika, división Perú	. 14
Figura 2. Relación entre puntaje crediticio y probabilidad de default	. 18
Figura 3. Límite de aceptación o punto de corte de un modelo de credit scoring	. 20
Figura 4. Árboles de decisión	. 24
Figura 5. Metodología de un random forest	. 27
Figura 6. Estructura de una ANN	29





#### Introducción

La concesión de préstamos se considera una de las principales fuentes de ingresos de los bancos e instituciones financieras en el mundo. En la mayoría de países desarrollados las entidades financieras a menudo usan el Credit Scoring (fórmulas para predecir el riesgo basadas en el desempeño de préstamos pasados con características similares) para evaluar sus decisiones; en los emergentes, a diferencia, estos modelos aún tienen un uso limitado<sup>1</sup>.

Si bien, por temas regulatorios, en los últimos años, las entidades financieras han tenido que implementar modelos de medición crediticio<sup>2</sup>, éstas aún padecen de una variedad de factores que limitan la completa adopción de estas tecnologías tales como: falta de capacidades para desarrollar e implementar estos modelos, mercados pequeños que no justifican el alto costo de desarrollo software diseñado para el procesamiento de datos<sup>3</sup> y concentración de mercado en unos cuantos participantes. Esto podría estar inclinando las decisiones de la mayoría de las pequeñas instituciones sobre seguir confiando en el criterio del analista en lugar de una herramienta de evaluación automatizada.

Sin embargo, a medida que maduran los mercados financieros de los países emergentes, las entidades se enfrentan a la competencia no sólo de otros bancos nacionales sino también de bancos extranjeros consolidados. Dado el crecimiento sustancial del crédito minorista y la mayor atención regulatoria a la gestión de riesgos, el desarrollo de un marco de evaluación crediticia que funcione correctamente es esencial.

El objetivo del presente trabajo es presentar y analizar los diferentes avances en cuanto a la construcción de modelos de Credit Scoring que se han venido desarrollando durante los últimos veinte años aplicados a países emergentes. Asimismo se pretende identificar las principales dificultades que impiden la completa implementación por las entidades financieras de estos países. Finalmente, se pretende conocer en qué medida la implementación de modelos de Credit Scoring en países emergentes ha mejorado la eficiencia del sector.



#### Capítulo 1 Informe de experiencia profesional

#### 1.1 Elektra del Perú S.A. - Sucursal tienda Italika Piura

#### 1.1.1 Descripción de la empresa

Italika es una firma mexicana que fue fundada en el año 2004 por Ricardo Salinas Pliego. La compañía se ha especializado en la comercialización de una amplia gama de motocicletas de baja cilindrada a precios accesibles para toda la población y con base en los siguientes pilares: los distribuidores, el financiamiento de Banco Azteca, el control de calidad, el desarrollo de producto y los diseños innovadores, la Ensambladora ITALIKA, la atención al cliente y el respaldo a través de refacciones y centros de servicio certificados, lo cual proporciona a los clientes, como resultado, un sentimiento de libertad y eficiencia.

La casa matriz en México tiene por razón social "Comercializadora de Motocicletas de Calidad S.A. de C.V. Sin embargo, en el Perú las operaciones de Italika están a cargo de la empresa "Elektra del Perú S.A.", la cual es una Sociedad Anónima con domicilio fiscal en Calle B, Mz, D, Lote 4B, Urbanización Industrial Bocanegra, Callao, Callao.

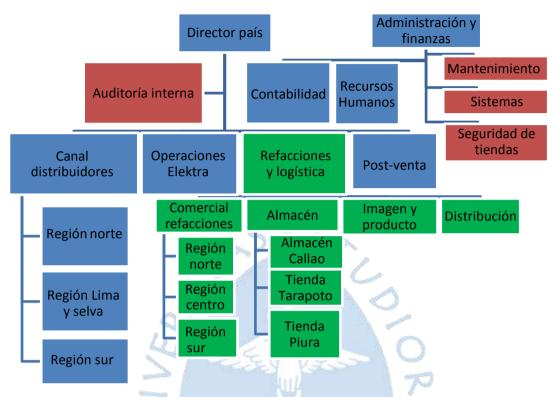
#### 1.1.2 Productos y servicios

En la actualidad, la firma cuenta con una gama de productos de más de 50 modelos en las categorías de trabajo, urbanas, motonetas, deportivas, semiautomáticas, doble propósito, cuatrimotos, chopper y productos infantiles; que van desde 70cc hasta 250cc. Lo cual permite llegar a clientes con diferentes necesidades y cumplir sus expectativas al brindarles el respaldo de la marca con dos años de garantía o 20,000 km en todos los modelos. Asimismo, proporcionan soporte a todos sus clientes a través del call center (con el 01800 ITALIKA); disponibilidad de refacciones, cursos de manejo, casco de regalo en todas las Italikas, manuales de usuario de cada modelo, Centros de Servicio ITALIKA (CESIT) y comunicación continua con nuestros usuarios a través de las redes sociales para dar a conocer tips de seguridad y temas de interés en la comunidad que se ha formado.

#### 1.1.3 Estructura organizativa de la empresa

Italika en el Perú funciona como una división independiente dentro de la empresa Elektra del Perú S.A, la cual posee sus propios departamentos de Administración, Logística, Contabilidad, Comercial, Recursos Humanos, entre otros. Estos departamentos trabajan paralelamente a los de la empresa Elektra y reportan únicamente al director del país. Al mismo tiempo, comparte con Elektra algunos otros departamentos de menor jerarquía como Mantenimiento, Seguridad de Tiendas y Soporte Informático (ver Figura 1).

**Figura 1**Organigrama de Italika, división Perú



Nota. Elaboración propia (2021).

# 1.1.4 Puesto, propósito y funciones

Funciones desarrolladas dentro del puesto:

- Cumplir con la proyección de ventas e ingresos, manejando adecuadamente los descuentos con el fin de mantener la rentabilidad esperada.
- Administrar eficientemente el equipo de colaboradores, velando por mantener un clima laboral interno motivador y comprometido con el objetivo de la tienda y la organización.
- Elaborar y ejecutar el check list diario para apertura y cierre de tienda.
- Responsable de asegurar el orden y presentación de la tienda, ejecutar las acciones necesarias para que ésta cumpla con los estándares definidos por la Empresa.
- Evaluar periódicamente la calidad del servicio brindado, asimismo tomar las acciones correctivas ante una queja o reclamo por parte del cliente.
- Analizar y proponer estrategias comerciales en función a los cambios en el sector, acciones de la competencia y cambios en el comportamiento del cliente.
- Administrar el fondo fijo de la sucursal, velando por cubrir las necesidades de ésta para el correcto desarrollo de sus operaciones.

- Responsable por el control de inventario de la mercadería, así como de todos los activos asignados a la tienda.
- Evaluar permanentemente al personal a su cargo, así como retroalimentar en las oportunidades de mejora.
- Efectuar evaluaciones de los indicadores de gestión de tienda, definiendo estrategias para introducir mejoras.

#### 1.2 Trayectoria y aportes profesionales

## 1.2.1 Relevancia y valoración de la trayectoria en la empresa

Durante los últimos ocho años de mi trayectoria laboral, seis de ellos fueron dedicados a dirigir la labor comercial en diferentes empresas. Destaco de entre todas las experiencias profesionales en este sector mi labor como GERENTE DE TIENDA de la marca Italika en su sucursal de Piura. Dicha posición representó uno de los retos más importantes por la cantidad de responsabilidades y áreas bajo mi control. Como gerente de tienda tenía la función de controlar los ingresos y ventas por las tres líneas de negocio de la tienda (motocicletas, repuestos y servicios post venta); así como administrar el presupuesto de la tienda para gastos fijos y actividades de promoción. Finalmente también tenía a cargo la dirección del talento humano dentro de la sucursal.

Asimismo, fue una de las oportunidades mejor aprovechadas en mi carrera, ya que durante mi gestión se logró llegar a un récord de ventas histórico de 27 motos en una sola semana; además de cumplir con las proyecciones de ventas de las tres líneas de negocio a lo largo de mi permanencia en el puesto, durante los años 2016 y 2017.

## 1.2.2 Contribución de la formación académica en el desempeño profesional

La formación académica recibida en la Universidad de Piura me ayudó para afrontar el reto de dirigir una sucursal de una empresa multinacional, ya que durante los años de estudios pude adquirir conocimientos y habilidades que me permitieron cumplir las obligaciones laborales asumidas.

En los sucesivos cursos de contabilidad llevados durante pregrado aprendí a leer la salud de una empresa mediante sus estados financieros y a crear indicadores de la gestión basados en sus ratios de liquidez, solvencia y rentabilidad; todo lo cual me sirvió para defender las actividades realizadas que se financiaron con el presupuesto de la sucursal y demostrar que los gastos de ventas y promoción tuvieron un impacto positivo en la salud de la empresa por medio de sus estados financieros.

Por otra parte, los conocimientos adquiridos en las clases de Estadística me sirvieron para trabajar con los datos generados por el sistema CRM de la empresa con los cuales pude elaborar y presentar informes acerca la estacionalidad de los productos, correlaciones entre ellos con el fin de promover ventas cruzadas, al mismo tiempo que empleaba encuestas de satisfacción de los clientes como uno de los principales indicadores de nuestro desempeño.

Finalmente, los diversos cursos de Humanidades y Gobierno de Personas me brindaron las bases para desarrollar un adecuado estilo de dirección, centrado en el conocimiento de las personas que laboraron bajo mi cargo, cuáles eran sus motivaciones y ayudarlos a desarrollar sus potencialidades con la finalidad de acercar lo más posible sus objetivos personales con los de la organización.

#### 1.2.3 Aporte individual

Uno de los aportes más resaltantes durante mi estancia en la empresa fue el afrontar el periodo de emergencia ocurrida durante el Fenómeno del Niño Costero del 2017 y dirigir la sucursal en esa época de crisis, logrando recuperar las ventas perdidas a lo largo de los siguientes meses y poder cumplir los objetivos de ventas para ese año.

El 2016 fue un año excepcional para la sucursal ya que se alcanzaron los pronósticos de ventas; sin embargo, a mediados de enero del 2017 empezaron las lluvias en la región y ello conllevó a una disminución en la actividad comercial en todos los sectores. Particularmente, el comercio de vehículos menores decayó notablemente desde enero hasta marzo e inclusive estuvo paralizado varias semanas a causa del desborde del río Piura. A pesar de esto, la organización bajo mi cargo no dejó de operar y siguió trabajando para lograr los objetivos asumidos.

Dicha experiencia fue crucial en mi crecimiento personal y profesional, cada día surgían nuevas adversidades que era preciso sobrellevar, brindando soluciones y apoyo para el personal de la sucursal sin perder de vista la seguridad y bienestar de los mismos, pero al mismo tiempo motivarlos a seguir insistiendo en sus labores, con la intención de demostrarles que la meta es alcanzable para un equipo que cree en sus capacidades.

El siguiente aporte se dio en el área de repuestos de la tienda, la cual venía arrastrando desde la gestión anterior problemas de unidades faltantes, falta de orden en almacén, quiebres de stock constantes y un excesivo tiempo de respuesta a pedidos de los clientes; lo cual se evidenciaba en diferentes quejas registradas en el libro de reclamaciones. En este aspecto se procedió a sincerar el stock devolviendo a la sede central aquellos elementos con más de un año de inventario. Asimismo se reordenaron las ubicaciones físicas atendiendo a las características del producto (tamaño, peso, material de fabricación), se hizo una revisión a las ventas facturadas en los últimos tres años y se cuadraron las cuentas del kardex general; con lo cual se logró eliminar gran parte de los elementos faltantes. Gracias a esto se mejoró la eficiencia del área y se obtuvo una mejor medición de la rentabilidad de sus operaciones.

## Capítulo 2 Tópico de economía financiera - Credit Scoring aplicado a países emergentes

#### 2.1 Antecedentes

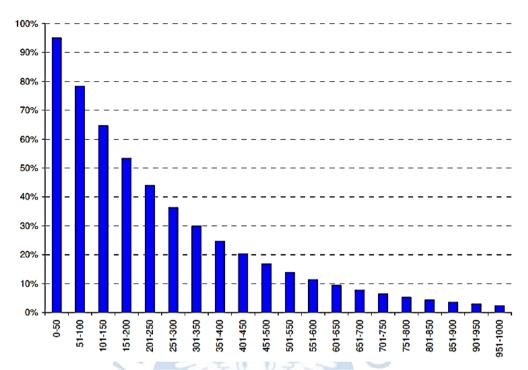
Introducidas en los años 70, el uso de modelos de calificación crediticia o "Credit Score" se generalizó en los años 90 gracias al desarrollo de mejores recursos estadísticos y computacionales. Hoy en día prácticamente todas las entidades financieras emplean estas metodologías al menos para originar sus financiaciones. Esto se ha debido tanto al desarrollo de mejores recursos estadísticos y computacionales como por la creciente necesidad por parte de la industria bancaria de hacer más eficaz y eficiente el desembolso de los créditos y de tener una mejor evaluación del riesgo de su portafolio.

Los métodos o modelos de credit scoring, a veces denominados score-cards o classifiers, son algoritmos que de manera automática evalúan el riesgo de crédito de un solicitante de financiamiento o de alguien que ya es cliente de la entidad. Estos modelos analizan la ocurrencia de default de las operaciones anteriores para perfilar el riesgo de impago de los clientes nuevos. En todos los casos, la construcción de una aplicación de credit scoring se realiza tomando la información del cliente contenida en las solicitudes del crédito, de fuentes internas e incluso de fuentes externas de información.<sup>6</sup>

La función primordial del credit score es brindar una calificación que permita al analista tomar una mejor decisión sobre la aprobación de las solicitudes, clasificación de créditos, asignación de la prima de riesgo, generación de alertas tempranas y estrategias de cobranza (García Sánchez & Sánchez Barradas, 2005).<sup>7</sup>

En la Figura 2 podemos apreciar el resultado esperado de un modelo de credit scoring, que muestra la probabilidad de default (PD) histórica asociada a cada rango del score. La relación entre ambos se muestra para intervalos del puntaje, ya que es una variable continua, y se observa que el riesgo cae de manera exponencial a medida que mejora el score. Esta es una regularidad de las técnicas de credit scoring y sistemas de rating: a medida que mejora el score o calificación, la caída marginal en el riesgo es cada vez menor. (Gutiérrez, 2007)

**Figura 2**Relación entre puntaje crediticio y probabilidad de default



Nota. El eje vertical representa la tasa anual de incumplimiento o default mientras que el eje horizontal representa el puntaje crediticio asociado a dicha tasa. Tomado de "Modelos de credit scoring: qué, cómo, cuándo y para qué" (p. 4), por M. A. Gutiérrez, 2007.

A través de los años estos modelos han tomado vertientes de uso con modelos lineales, no lineales, paramétricos, no paramétricos, estadísticos y econométricos que buscan encontrar el medidor perfecto. Dicha evolución se presenta a continuación en la Tabla 1:

**Tabla 1** *Evolución de los modelos y sus aplicaciones empíricas* 

Año	Autor	Investigaciones		
1968	Edward Altman	Creación del Z-Score para medir la probabilidad de quiebre de		
		empresas aplicando las variables explicativas en forma de ratios. Esta		
		metodología se empleó posteriormente para predecir la morosidad		
		de los clientes de entidades bancarias.		
1970	Yair Orgler	Usa un modelo de regresión por mínimos cuadrados tomando como		
		base los ratios explicativos de Altman para modelar el		
		comportamiento crediticio de los clientes de una entidad comercial.		

Año	Autor	Investigaciones	
1980	Jhon Wiginton	Elaboró un estudio para evaluar la capacidad predictiva de un modelo	
		de regresión logística y comparar los resultados comparando con el	
		análisis discriminante.	
1992	M. Boyle	Realiza un estudio comparando modelos de árboles de decisión con el	
		análisis discriminante, confrontando así una técnica paramétrica ante	
		otra no paramétrica.	
1994	Eric Rosemberg y	Describen las aplicaciones de las Redes Neuronales en las decisiones	
	Alan Gleit	sobre el crédito y la detección del fraude.	
2006	Fu et al.	Diseñan un modelo de ensamblaje que considera diversos objetivos	
		de aversión al riesgo partiendo de una única serie de datos,	
		obteniendo así un modelo que funciona mejor que los árboles de	
		decisión anteriormente utilizados.	
2016	Hurley y Adebayo	Evalúan los resultados de los principales métodos de Credit Scoring en	
	Li Li	la "era del big data".	

Nota. Elaboración propia (2021).

# 2.2 Descripción de las principales técnicas de modelado

Los modelos de credit scoring se diseñan para obtener una estimación del resultado futuro que tendrá una operación de préstamo determinada. Dichos modelos se emplean para crear sistemas computarizados que ejecutan instantáneamente la medición del riesgo, lo cual permite al analista que los emplea realizar una evaluación de manera más rápida, precisa y objetiva.

Para la construcción de estos modelos se utilizan diferentes atributos que presenta tanto el solicitante como la operación en sí, los cuales se ordenan y reciben una ponderación. La puntuación de un solicitante es la suma de las de todos sus atributos ponderados; cuanto más alta (o baja) es la puntuación, menor (o mayor) es el riesgo. Si la puntuación cae dentro de un "límite" establecido por la entidad, el solicitante presenta un nivel de riesgo aceptable y la entidad puede otorgar el crédito (ver Figura 3).

**Figura 3**Límite de aceptación o punto de corte de un modelo de Credit Scoring

1000 riesgo bajo	Acepta automáticamente	Acepta	Acepta automáticamente
	Revisión	automáticamente	
	Rechaza automáticamente	Revisión	
		Rechaza automáticamente	Revisión
riesgo alto 0			Rechaza automáticamente

Nota. La primera columna representa el puntaje crediticio asociado a cada solicitud de crédito, sobre la cual las entidades han establecido escenarios o puntos de corte. La primera columna corresponde al escenario para una entidad tolerante al riesgo, la segunda corresponde a una entidad neutral al riesgo, mientras que la tercera representa el caso de una entidad adversa al riesgo. Tomado de "Modelos de credit scoring: qué, cómo, cuándo y para qué" (p. 10), por M. A. Gutiérrez, 2007.

Tal como muestra el gráfico anterior, las entidades financieras por lo general determinan un cut off o punto de corte no sólo en función del riesgo exclusivamente, sino que depende del beneficio esperado por la entidad y su apetito por el riesgo. Por ejemplo, una determinada solicitud de crédito puede ser rechazada y aceptada a su vez en dos entidades financieras diferentes, si es que una de ellas maneja de forma más eficiente la gestión de cobranzas que la otra, aunque la probabilidad de impago esperada sea la misma en ambos casos.

Desde sus inicios, los modelos de credit scoring han evolucionado para adaptarse a los cambios en el entorno, tales como los cambios en la cantidad y calidad de los datos. A su vez, las entidades los han ido evaluando de forma periódica con el fin de reducir el error y abarcar un número más amplio de escenarios (flexibilizar los supuestos sobre los que se basan algunos parámetros). Dentro de esta línea de desarrollo describimos las principales metodologías:

#### 2.2.1 Análisis discriminante

Esta técnica estadística multivariado permite estudiar simultáneamente el comportamiento de un conjunto de variables independientes con la finalidad de clasificar un grupo de datos en una serie de subconjuntos previamente definidos y excluyentes entre sí (Fisher, 1936). Las variables explicativas representan las características diferenciadoras de cada individuo, siendo éstas las que permiten realizar la clasificación<sup>8</sup>.

La principal ventaja de esta técnica está en la diferenciación de las características que definen a cada grupo, así como las interacciones que existen entre ellas. Entre los inconvenientes destaca la incapacidad para el cálculo de las probabilidades de impago.

Según Puertas y Martí (2013) el análisis discriminante cumple con dos objetivos:

- Obtener combinaciones lineales de variables independientes que maximicen la diferencia entre los grupos. Estas combinaciones lineales reciben el calificativo de funciones discriminantes.
- Predecir la pertenencia de un individuo a uno de los grupos establecidos a priori. De este modo se evalúa la potencia discriminadora del modelo.

Para esto, se divide en forma aleatoria el total de observaciones: la primera será la "muestra de entrenamiento", que se utilizará para obtener las funciones discriminantes; y la segunda que será la "muestra de testeo", que se usará para determinar la capacidad predictiva del modelo.

Por tanto, los modelos basados en el Análisis Discriminante buscan establecer combinaciones lineales de variables independientes que se ajusten mejor a las dos sub muestras establecidas; así, el error estimado será mínimo. Para ello se maximiza la variabilidad entre los grupos y se minimiza la diferencia al interior de los grupos, obteniendo el vector de coeficientes de ponderación que haga máxima la discriminación.

Puertas y Martí (2013) señalan que existen fuertes hipótesis que necesariamente deben cumplir estos modelos<sup>9</sup>, las cuales son:

- Las variables independientes tienen una distribución normal multivariada.
- Igualdad de la matriz de varianzas-covarianzas de las variables independientes en cada uno de los grupos.
- El vector de medias, las matrices de covarianzas, las probabilidades a priori, y el coste de error son magnitudes todas ellas conocidas.
- La muestra extraída de la población es una muestra aleatoria.

Es importante notar que aunque no se puede asegurar que siempre se cumplen las condiciones de normalidad y de igualdad en la matriz de varianzas y covarianzas (sobre todo para series de tipo financiero); existe consenso en aceptar que el análisis discriminante obtiene a pesar de todo buenas estimaciones, aunque éstas finalmente no lleguen a ser óptimas.

#### 2.2.2 Modelos Probit y Logit

Los modelos de regresión Probit, permiten estimar la probabilidad de que una variable dependiente tome el valor de uno (si un cliente es malo), o cero (si cumple con su obligación de pago). Además, este modelo presenta la ventaja de medir la probabilidad de incumplimiento al mantener la variable explicada siempre dentro de ese rango de variación. Para lograrlo, utiliza un enfoque de regresión por mínimos cuadrados para transformar una combinación lineal de las variables independientes en su valor de probabilidad acumulada de una distribución normal. Por ende:

$$Prob(y = 1|V) = \Phi(\alpha + \delta_1 V_1 + \delta_2 V_2 + \dots + \delta_n V_n) \dots (1)$$

$$\Phi(z) = \int_{-\infty}^{z} \left(\frac{1}{2\pi}\right)^{\frac{1}{2}} exp\left\langle \frac{-u^{2}}{2}\right\rangle du \dots (2)$$

donde y es la variable dicotómica cero-uno para un conjunto de valores dado;  $\Phi$  es la función de distribución acumulada normal estándar;  $\alpha$  es la intersección; y  $\delta_i$  representa el coeficiente de las variables independientes  $V_i$ , para i = de 1 hasta n (Abdou, 2009).

El modelo Logit queda definido por la siguiente función de distribución logística obtenida a partir de la probabilidad a posteriori aplicada al AD mediante el teorema de Bayes, (Bonilla et al., 2003). La probabilidad de éxito se evalúa en la función  $G(z)=\Lambda(z)$  donde  $\Lambda(z)$  es la función de distribución acumulada logística estándar:

$$P_i = P(Y = 1/X) = F(Z_i) = \frac{1}{1 + e^{-Z_i}} = \frac{1}{1 + e^{-(\beta_0 + \beta X_i)}} \dots (3)$$

en donde  $\beta_0$  representa los desplazamientos laterales de la función logística,  $\beta$  es el vector de coeficientes que pondera las variables independientes y del que depende la dispersión de la función, y X es la matriz de variables independientes

Dentro de los enfoques econométricos, los modelos Probit y Logit son superiores al análisis discriminante ya que proveen para cada deudor una probabilidad de default, en tanto que este sólo clasifica a los deudores en grupos de riesgo. A pesar de que los Probit y Logit en teoría son herramientas econométricas más apropiadas que la regresión lineal, ésta arroja estimaciones similares a las de los anteriores cuando sus probabilidades estimadas se ubican entre el 20% y el 80%.

#### 2.2.3 Árboles de decisión

Los árboles de decisión son una técnica no paramétrica de clasificación binaria que presenta varias ventajas, por un lado reúnen las características de los modelos de variable única y multivariados

en un solo sistema; por otro lado, permiten separar las observaciones que componen la muestra asignándolas a grupos establecidos a priori, con la finalidad de minimizar el coste esperado de los errores tipo I y II (Puertas y Martí, 2013).

Para los árboles de decisión, existen diferentes metodologías, entre ellas Cart, Chaid, Chaid exhaustivo, Quest, C4.5, que difieren en la forma de asignación, las reglas de partición y los criterios de parada. Cualquiera de ellos generará *N* nodos terminales y una escala de probabilidades con *N* posibles valores, que es el resultado final y la probabilidad empleada tanto para validar el modelo, como para el cálculo de la pérdida esperada.

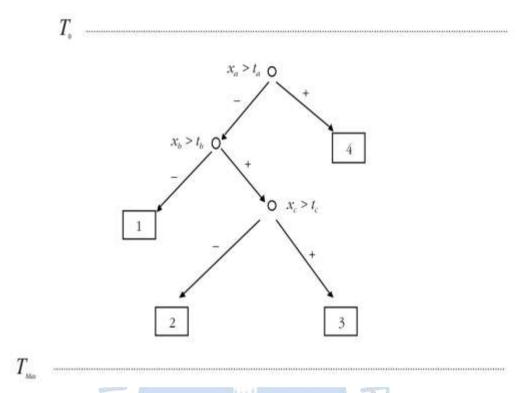
El aprendizaje del árbol de decisiones es un método de clasificación popular que hace crecer una estructura basada en árboles con probabilidades condicionales de clase al final de las ramas del árbol.

El árbol de decisión comienza con un nodo raíz y gradualmente construye subárboles con nodos internos que están conectados por ramas que emanan y termina con nodos terminales llamados hojas. Cada nodo interno corresponde a una prueba de una característica (por ejemplo, un prestatario es dueño de una casa o no) y las ramas representan una partición binaria del atributo de prueba.

El proceso de construcción de un árbol de decisión es un enfoque de divide y vencerás en el sentido de que el nodo raíz corresponde a todos los datos de entrenamiento y cada división de nodo corresponde a una partición de los datos disponibles en ese nodo según la condición de prueba para el característica asociada.

El modelo, como vemos en la Figura 4, se estructura en forma de árbol compuesto de una sucesión de nodos y ramas que constituyen, respectivamente, los grupos y divisiones que se van realizando de la muestra original. Cada uno de los nodos terminales representa aquel grupo cuyo coste esperado de error sea menor, es decir, aquellos que presenten menor riesgo. El riesgo total del árbol se calcula sumando los correspondientes a cada uno de los nodos terminales.

**Figura 4** *Árboles de decisión* 



Nota. Tomado de "Análisis del credit scoring" (p. 309), por R. M. Puertas & M. L. Martí, 2007, RAE-Revista de Administração de Empresas.

Así pues, el proceso consiste en dividir sucesivamente la muestra original en submuestras, sirviéndose para ello de reglas univariantes que buscarán aquella variable independiente que permita discriminar mejor la división. Con ello, se pretende obtener grupos compuestos por observaciones que presenten un alto grado de homogeneidad, incluso superior a la existente en el grupo de procedencia (denominado nodo madre).

Con objeto de encontrar la mejor regla de división, el algoritmo estudiará cada una de las variables explicativas, analizando los puntos de corte para, de este modo, poder elegir aquella que mayor homogeneidad aporte a los nuevos subgrupos. El proceso finaliza cuando resulte imposible realizar una nueva división que mejore la homogeneidad existente.

En definitiva, el algoritmo de partición recursiva puede resumirse en los siguientes cuatro pasos:

 Estudiar todas y cada una de las variables explicativas para determinar para cuál de ellas y para qué valor es posible incrementar la homogeneidad de los subgrupos. Existen diversos criterios para seleccionar la mejor división de cada nodo, todos ellos buscan siempre aquella división que reduzca más la impureza del nodo, definida ésta mediante la siguiente expresión,

$$i(t) = -\sum p\left(\frac{j}{t}\right) \cdot \log[p(j/t)] \dots (4)$$

siendo p(j/t) la proporción de la clase j en el nodo t. Como medida de la homogeneidad o impureza se utiliza una extensión del índice de Gini para respuestas categóricas. El algoritmo optará por aquella división que mejore la impureza, mejora que se mide comparando la que presenta el nodo de procedencia con la correspondiente a las dos regiones obtenidas en la partición.

- El paso anterior se repite hasta que, o bien resulte imposible mejorar la situación realizando otra división, o bien el nodo obtenido presente el tamaño mínimo. En esta fase del algoritmo se obtiene el árbol máximo en el cual cada uno de sus nodos interiores es una división del eje de características. Ahora bien, este procedimiento, tal y como ha sido expuesto, presenta un grave problema, el sobre aprendizaje: el modelo memoriza las observaciones de la muestra siendo incapaz de extraer las características más importantes, lo que le impedirá «generalizar adecuadamente», obteniendo resultados erróneos en los casos no contemplados con anterioridad. Para evitarlo Friedman (1977) propuso la siguiente solución: desarrollar el árbol al máximo, y posteriormente ir podándolo eliminando las divisiones y, por lo tanto, los nodos que presenten un mayor coste de complejidad, hasta encontrar el tamaño óptimo, que será aquel que minimice el coste de complejidad.
- Calcular la complejidad de todos y cada uno de los subárboles podando aquellos que verifiquen la siguiente expresión,

$$R_K(T_1) = minR_K(T'); T' \le T \dots (5)$$

siendo el coste de complejidad,

$$R_K(T) = [R(T) + K. |T|] ... (6)$$

donde  $R_K(T)$  es el coste de complejidad del árbol T para un determinado valor del parámetro K, R(T) es el riesgo de errar (K se denomina parámetro de complejidad que penaliza la complejidad del árbol y siempre será positivo) y |T| es el número de nodos terminales.

• Encontrar todos los valores críticos de K, y utilizar la técnica de validación cruzada para cada uno de ellos con objeto de estimar R(T(K)), eligiendo aquella estructura que presente mejor valor estimado de R(T(K)).

Por tanto, el principal problema con el que se enfrenta este modelo es la complejidad de su estructura que, como ya hemos indicado, fácilmente puede desembocar en el sobre aprendizaje del

modelo. De ahí que no sólo se persiga crear conjuntos homogéneos con bajo riesgo, sino también obtener aquella estructura que presente una complejidad óptima. Bajo este doble objetivo, resulta necesario penalizar la excesiva complejidad del árbol. (Puertas y Martí, 2013)

La principal ventaja de esta metodología es que no está sujeta a supuestos estadísticos referentes a distribuciones o formas funcionales. Aunque conllevan una comprensión interna difícil sobre su funcionamiento, presentan relaciones visuales entre las variables; por ello, este método es muy usado en el credit scoring.

Los modelos de árboles de decisión tienen varias propiedades atractivas: son fáciles de interpretar, pueden manejar datos tanto numéricos como nominales y son fáciles de construir. No obstante, no siempre son competitivos con otras técnicas de clasificación. Para superar estas dificultades, se diseñaron diversas técnicas como el boosting (aprendizaje iterativo de instancias mal clasificadas) y los modelos de ensamblaje (construcción de múltiples árboles y combinación de los resultados).

#### 2.2.4 Random Forest

El Random Forest o bosque aleatorio es una versión mejorada del árbol de decisiones, que altera el algoritmo de la forma en que se aprenden los subárboles, de modo que las predicciones resultantes de todos los los subárboles tienen menos correlación. (Chopra y Bhilare, 2018)

Los árboles de decisión y los métodos de conjuntos relacionados, como el random forest, son herramientas de vanguardia en el campo del aprendizaje automático para la regresión predictiva y la clasificación. Sin embargo, los inputs carecen de significado por sí mismos y pueden ser menos relevantes en aplicaciones de calificación crediticia, donde los responsables de la toma de decisiones y los reguladores necesitan una función de calificación lineal transparente que generalmente corresponde a la función de enlace en regresiones logísticas. (Van Sang et al., 2016)

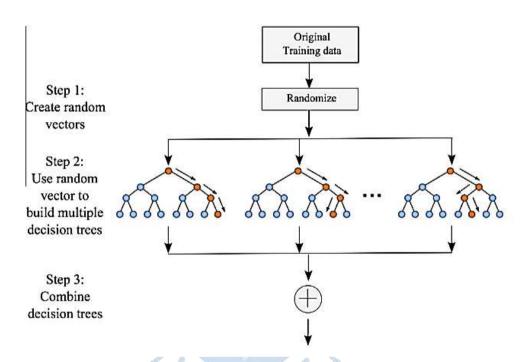
El random forest es un clasificador de conjuntos que utiliza un modelo de ensamblaje y consta de un conjunto de clasificadores CART. Cada nodo de un árbol solo selecciona un pequeño subconjunto de características para una división, lo que permite al algoritmo crear clasificadores para datos altamente dimensionales muy rápidamente. En cada sección, se debe determinar el número de características seleccionadas al azar. El valor predeterminado es p que es el número de características. El criterio de separación es el índice de Gini como se muestra en la ecuación (7):

$$gini(N) = \frac{1}{2} \left( 1 - \sum_{j} p(\omega_j)^2 \right) \dots (7)$$

Una vez que se calculan los índices de Gini para cada atributo de división, la división se realiza en el atributo que tiene el índice de Gini más alto.

Al construir estos árboles, los atributos de división candidatos en cada árbol se eligen mediante una selección aleatoria de *m* atributos del conjunto completo de *p* atributos, como se ilustra en la Fig. 6. La selección de atributos se realiza en cada división. En cada árbol, se continúa partiendo hasta que el árbol alcanza una profundidad final (ver Figura 5).

**Figura 5** *Metodología de un random forest* 



Nota. Tomado de "Application of ensemble models in credit scoring models" (p. 7), por A. Chopra & P. Bhilare, 2018, Business Perspectives and Research.

Hay dos cuestiones críticas en el aprendizaje del árbol de decisiones: (1) cómo elegir el atributo de división en cada nodo interno y (2) cuántos niveles tener en cada rama del árbol, es decir, cuándo dejar de dividir. En el contexto de random forest, que son colecciones de árboles de decisión, la división se realiza con respecto al índice de Gini presentado anteriormente, y el número de niveles en cada rama de árbol se controla mediante un parámetro del algoritmo.

Los modelos de random forest, que pueden verse como una técnica de ensamblaje mejorada, son un método poderoso para construir un bosque de árboles de decisiones aleatorias. Esta metodología desvincula los árboles de decisión en el bosque mediante la aleatorización de los atributos

divididos, lo que conduce a una mejora con respecto a los árboles tradicionalmente empaquetados y reduce la varianza cuando se promedia sobre los árboles (Breiman, 2001).

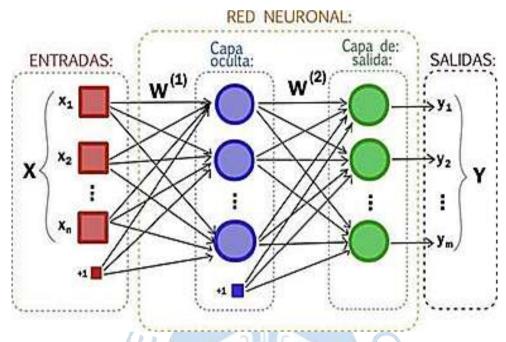
#### 2.2.5 Redes Neuronales

Las redes neuronales artificiales (ANN por sus siglas en inglés) es una técnica de inteligencia artificial que se inspiró originalmente en la forma en que el cerebro humano procesa la información. ANN imita este proceso al permitir el procesamiento complejo concurrente de entradas para lograr una salida (Bhattacharyya y Maulik, 2013). Una de las arquitecturas más comunes para las ANN es el perceptrón multicapa, que consta de una capa de entrada, una o más capas ocultas y una capa de salida. Uno de los problemas clave que deben abordarse en la construcción de ANN es su topología, estructura y algoritmo de aprendizaje (Angelini et al., 2008). La topología más comúnmente utilizada del modelo ANN en la calificación crediticia es la propagación retroalimentada de tres capas.

Como se muestra en la Figura 6, el modelo ANN se compone de tres capas: capas de entrada, ocultas y de salida. Los "nodos" representan neuronas, al igual que el cerebro humano. Para la calificación crediticia, la estructura del modelo ANN es ingresar los atributos de cada solicitante en la capa de entrada para procesarlos; luego se transfieren a la capa oculta, que contiene un algoritmo para procesar todos los atributos basados en pesos; y los valores se envían luego a la capa de salida que proporciona la respuesta final, que es dar o no un préstamo. La salida se calcula utilizando pesos (ver Figura 6). En resumen, ANN tiende a establecer la relación entre la probabilidad de incumplimiento de un cliente y sus características determinadas. (Ala'raj et al., 2018)

Figura 6

Estructura de una ANN



Nota. Tomado de Unidad 4 redes neuronales, Google sites, 202 (https://sites.google.com/site/mayinteligenciartificial/unidad-4-redes-neuronales)

Según Rayo et al. (2010), muchas veces resulta complejo diseñar modelos de credit scoring puesto que el proceso interno de aprendizaje y retroalimentación funciona como una "caja negra" o "capa oculta", por lo cual la comprensión completa de lo que realmente ocurre al interior requiere de conocimientos especializados.<sup>10</sup>

#### 2.2.6 Ventajas y desventajas de cada modelo

No existe un modelo o un método perfecto de identificación de credit score por varias situaciones, el uso de un modelo dependerá de la calidad de la información y sobre qué variables se deberán trabajar. Lo cierto es que los modelos se refinan en su uso mejorando la característica lineal a no lineal asumiendo que la información y los datos no son perfectamente lineales ni tampoco son totalmente normales. A pesar de lo anterior y considerando las investigaciones realizadas hasta el momento, presentamos un resumen de los principales puntos a favor y en contra de cada modelo (ver Tabla 2).

**Tabla 2** *Ventajas y desventajas de los modelos presentados* 

Modelo	Ventajas	Desventajas
Análisis discriminante	Es efectivo cuando las variables no	Son menos resistentes cuando no
	son del tipo cualitativo y la	se cumplen algunos de los
	distribución de la muestra es	supuestos del análisis estadístico
	normal.	clásico (p. ej, normalidad de las
		variables).
Modelos Logit y Probit	Facilidad de interpretación, facilidad	Parten de una función de
	de manejo en el proceso	distribución conocida y se limitan
	matemático. Frente al análisis	a estimar los parámetros que
	discriminante presenta la ventaja de	mejor ajusten las observaciones.
	no plantear restricciones ni con	Por lo que pueden ser sensibles
	respecto a la normalidad de la	frente a la violación de las
	distribución, ni a la igualdad de	hipótesis de partida.
	matrices de varianzas y covarianzas.	P
Árboles de decisión	Son superiores a los modelos	Son inestables: cualquier pequeño
	estadísticos cuando se desconoce y	cambio en los datos de entrada
	se presume que la función no es	puede suponer un árbol de
	lineal. Presentan la relación entre las	decisión completamente
	variables de manera visual, con lo	diferente. No se puede garantizar
	cual facilita entender cómo funciona	que el árbol generado sea el
	el scoring.	óptimo.
Random forest	Es uno de los algoritmos de	El sobreajuste es una de las
	aprendizaje más precisos y también	principales desventajas de esta
	proporciona información de	técnica con una tarea ruidosa de
	variables importantes en la	clasificación / regresión
	clasificación	

MODELO	VENTAJAS	DESVENTAJAS
Redes neuronales	Pueden ajustarse a formas y	Son poco intuitivos y de difícil
	relaciones no lineales. Son robustas	implementación. Debido a su
	y tolerantes a fallas (la falla de una o	mecanismo de aprendizaje
	varias neuronas no implica un fallo	requieren de una gran cantidad de
	total en la red neuronal).	datos para ajustarse a todos los
		escenarios posibles.

Nota. Elaboración propia (2021).

Dados estos criterios, cinco tipos básicos de modelos de puntuación son relevantes para las entidades financieras:

- El primer modelo predice la probabilidad de default (o atraso por más de "x" días) de una solicitud de crédito actualmente actualmente aprobada (Schreiner, 2000). Esta información se puede utilizar para determinar la prima a cargar por riesgo o para observar los desembolsos pendientes para una revisión documentaria adicional.
- El segundo tipo de modelo predice la probabilidad de que un préstamo con "x" días de atraso eventualmente llegue a "y" días de atraso; esta información se puede utilizar para priorizar las visitas de los analistas a los prestatarios morosos.
- El tercer tipo de modelo predice la probabilidad de que un cliente en regla elija no renovar el préstamo una vez concluido el actual; esta información se puede utilizar para ofrecer incentivos a los buenos clientes que probablemente abandonen la entidad.
- El cuarto tipo de modelo predice el monto esperado del desembolso del próximo préstamo.
- En quinto y último lugar se encuentra el modelo que combina la información de los cuatro anteriores (ingresos esperados, costos esperados, probabilidad de deserción, etc.) para estimar el valor financiero de la relación banco-cliente.

# 2.3 Aplicaciones empíricas

# 2.3.1 Schreiner (2000)

Nos indica que las principales fuentes de datos en la mayoría de países desarrollados se basan en los historiales crediticios completos tomados de las centrales de riesgo de sus respectivos países, dentro de estas bases las principales variables a considerar suelen ser la experiencia crediticia del solicitante y el nivel de ingresos sobre todo si provienen de un empleo formal.

Por otra parte, en la mayoría de los países emergentes, no todas las entidades locales tienen acceso completo a los historiales de crédito de los solicitantes, o en todo caso no todos los solicitantes cuentan con un historial crediticio, aunado a que suelen tener ingresos no sustentables, los cuales son variables y de fuentes informales.

El autor resalta que estos escenarios, en que las entidades otorgan préstamos grupales cuyos miembros usan capital social para disminuir el riesgo de impago y préstamos a individuos cuyos analistas de crédito conocen lo suficiente como para descartar características negativas, se basan fundamentalmente en información cualitativa almacenada en "la memoria humana". Por el contrario los modelos de Scoring se basan principalmente en información cuantitativa cuyos datos se almacenan en los servidores informáticos de las entidades bancarias.

Por todo lo expresado cabe preguntarse: ¿Es posible para las entidades financieras en países emergentes cambiar su esquema de evaluación por el Credit Scoring a fin de reducir el costo financiero de un mal crédito? Y si lo hacen ¿Lograrán ellos una reducción significativa en la ocurrencia de impagos y por lo tanto mejorar la eficiencia y rentabilidad en su sector? El autor cita dos experimentos llevados a cabo en Bolivia (1999) y Colombia (2000).

La evidencia sugiere que el puntaje obtenido por medio de un modelo de credit scoring para las nuevas solicitudes en realidad sí mejora el juicio del evaluador con respecto al riesgo. La implementación de estos modelos será muy útil ya que existen algunas características que no son costosas de cuantificar y que las tecnologías microfinancieras actuales no están aprovechando. Por ejemplo, en Colombia, se encontró que la periodicidad de los pagos afectaba el riesgo de impago (por cada cuota mensual adicional, el riesgo de impago aumentaba en 3 puntos porcentuales, asimismo, un crédito reembolsado mensualmente era aproximadamente 0,6 puntos porcentuales más riesgoso que uno reembolsado semanalmente).

En conclusión, el autor indica que el score crediticio obtenido por medio de modelos econométricos puede ser la más importante innovación tecnológica que se aplique en países emergentes, sin embargo podría no ser tan efectivo como en los países desarrollados porque gran parte del riesgo de estos créditos no está relacionado con características que pueden cuantificarse de manera económica. Por lo tanto, recomienda no reemplazar la forma en que trabajan actualmente los créditos grupales ni los analistas de crédito sino complementar.

#### 2.3.2 Thomas (2000)

Plantea que los modelos de credit scoring desarrollados deberían además de estimar la probabilidad de incumplimiento de un solicitante, estimar también la ganancia que un cliente traerá a la entidad financiera. Una de las principales objeciones que plantea es que el objetivo de los modelos de scoring solo se enfoca en predecir qué solicitante incurrirá en incumplimiento pero no puede dar explicaciones de por qué incumple ni tampoco plantear hipótesis sobre la relación entre el incumplimiento y otras variables económicas o sociales determinantes.

El autor ahonda en las técnicas de muestreo para la recolección de datos desarrolladas y descubre que la tasa de incumplimiento depende del tiempo que el cliente ha estado con la

organización ya que ésta es baja inicialmente y es solo después de doce meses aproximadamente que comienza a sincerarse (más generalmente para préstamos de consumo).

Por lo tanto, escoger un horizonte demasiado corto para la muestra a testear estará subestimando la tasa de default y no reflejará correctamente las características de la población que predigan el incumplimiento. Un horizonte temporal de más de dos años, por el contrario, deja el modelo a la deriva, ya que la distribución de las características de una población cambia con el tiempo, por lo que la muestra testeada puede ser significativamente diferente de aquella en la que se utilizará el modelo de scoring.

En conclusión, lo ideal es emplear esencialmente modelos transversales, es decir, aquellos que comparan dos instantáneas de un individuo en diferentes momentos, para producir modelos que sean estables cuando se examinan longitudinalmente en el tiempo. El horizonte de tiempo, el tiempo entre estas dos instantáneas, debe elegirse cuidadosamente para que los resultados sean estables en el tiempo.

#### 2.3.3 Frame et al. (2001)

Proporcionan evidencia empírica sobre si los hogares y las empresas que operan en áreas de bajos y medianos ingresos (Low Medium Income - LMI) en Estados Unidos se han beneficiado de la adopción de un software de calificación crediticia, diseñado para evaluar las solicitudes de préstamos de pequeñas empresas.

Específicamente, se centraron en analizar las solicitudes de crédito de 99 grandes organizaciones bancarias en el sureste de los Estados Unidos a fines de 1997. Llegaron a estimar que la calificación crediticia aumenta los préstamos para pequeñas empresas en las áreas LMI en \$16.4 millones por cada sucursal. Este efecto es aproximadamente 2,5 veces mayor que el estimado para las ubicadas en distritos de ingresos más altos (Medium High Income - MHI). El uso de la calificación crediticia también aumenta la probabilidad de que una gran organización bancaria otorgue préstamos en un distrito en particular. Para las áreas LMI, la probabilidad aumenta en un 3.8 por ciento y para las áreas MHI 1.7 por ciento.

En general, estos resultados sugieren que las áreas de bajos ingresos se benefician de las mejoras tecnológicas y que, a veces, estos beneficios son mayores que los experimentados en las áreas de mayores ingresos. La investigación sugiere que la evaluación de préstamos para pequeñas empresas se realiza de manera diferente en bancos grandes que en los pequeños. Una mejor información sobre las probabilidades de impago de una pequeña empresa solicitante hace que sea más probable que un prestamista fije el precio del préstamo en función del riesgo esperado, en lugar de negar el préstamo por temor a cobrar muy poco. Apuntan que, a la fecha, la mayor competencia en estas áreas da como resultado que las pequeñas empresas tengan acceso a más posibilidades y por lo tanto a una reducción en los costos de sus préstamos.

#### 2.3.4 Avery et al. (2004)

Sostienen que los modelos tradicionales de credit scoring no toman en cuenta las condiciones económicas locales y personales de los individuos, lo cual implicaría que el puntaje del historial crediticio estaría sesgado para aquellas personas que han pasado por un período de condiciones económicas temporales.

En particular, estos modelos generalmente se construyen sin relacionar la información en las centrales de riesgo y la información relacionada con el entorno económico en el que viven o trabajan los solicitantes, u otra información sobre sus circunstancias personales. Por lo tanto, a una persona que ha experimentado problemas crediticios por razones transitorias, como una recesión económica local o un evento personal adverso como una emergencia médica, normalmente se le asignará una puntuación comparable a una persona cuyos problemas crediticios reflejan un sobreendeudamiento o falta de voluntad para pagar las deudas.

Los autores agruparon las variables explicativas de partida en tres grandes bloques: variables del cliente (cuantitativas y cualitativas), variables de la operación de préstamo y, por último, variables macroeconómicas. La consideración de variables que incorporan la realidad macroeconómica es un aspecto importante en esta investigación, ya que la base de datos inicial de la cartera no las contemplaba, y su incorporación mejoró significativamente los resultados del modelo.

Se concluye que los modelos deben considerar las circunstancias económicas y personales de los individuos para mejorar su capacidad para cuantificar con más precisión el riesgo crediticio de los individuos. Además, el puntaje de su historial crediticio ex ante sobreestima la probabilidad de incumplimiento del nuevo préstamo en áreas que se están recuperando de una recesión económica y subestima dichos riesgos en áreas que han estado experimentando condiciones económicas excepcionalmente favorables.

# 2.3.5 *Dinh y Kleimeier* (2007)

Encuentran evidencia de que la inclusión de variables como el tipo de garantía, la duración del préstamo o el género es altamente significativa en países emergentes; en particular, toman como evidencia el caso de las entidades financieras de Vietnam y demuestran que el género y la duración del préstamo son predictores muy efectivos.

En primer lugar, el género es verdaderamente indicativo de incumplimiento y ayuda en la evaluación adecuada del riesgo crediticio incluso cuando se tienen en cuenta otros factores de riesgo como el propósito del préstamo o el valor de la garantía. El coeficiente negativo de género implica que las mujeres vietnamitas incumplen con menos frecuencia que los hombres.

Con estos datos los autores diseñaron un modelo de credit scoring para evaluar las solicitudes de un banco representativo de Vietnam. Al reemplazar su método de evaluación crediticia informal, el banco en mención experimentó una disminución en su tasa de default de 3.3% a 2%. Además,

utilizaron el modelo para implementar un esquema de precios basados en el riesgo para administrar la composición de su cartera de préstamos. Al establecer una tasa de interés más baja para los prestatarios menos riesgosos, el banco espera ser más competitivo y poder atraer a más prestatarios de bajo riesgo.

Finalmente, se redujo el tiempo de evaluación y, por lo tanto, el costo que le dedicaba el analista de crédito. Concluyen que para beneficiarse completamente del aumento de la competitividad y la reducción del costo de evaluación, es importante diseñar el modelo de Score basándose en las características y probabilidades predictivas del solicitante las cuales son específicas de cada país.

#### 2.3.6 Espin-García y Rodríguez-Caballero (2013)

Presentan una metodología general para construir un modelo credit scoring enfocado en el sector financiero latinoamericano, el cual ha venido tomando una mayor importancia en las últimas décadas. Las instituciones financieras han desarrollado y usado modelos de credit scoring para estandarizar y automatizar las decisiones de crédito, sin embargo, no es común encontrar metodologías para aplicarlos a clientes sin referencias crediticias.

Los autores usan la información sociodemográfica proveniente de las solicitudes de crédito de una pequeña institución bancaria mexicana para ejemplificar la metodología. Asimismo señalan que las diversas instituciones financieras, entre ellas algunos bancos comerciales, han incrementado sus nichos de mercado a favor de la inclusión de clientes que carecen de información crediticia en las centrales de riesgo, lo cual a finales de la década pasada fue una importante política a seguir tanto en instituciones grandes como en pequeñas.

Sin embargo, a diferencia de las grandes compañías usualmente las pequeñas no consiguen tener el suficiente capital para solicitar a las consultoras financieras con experiencia internacional, algún modelo de evaluación enfocado a este tipo de clientes.

# 2.3.7 Ala'raj et al. (2018)

Toman el caso del mercado financiero de Jordania y mencionan que los sistemas de Credit Scoring no se utilizan aún de igual modo que en los países desarrollados. Siendo los análisis subjetivos y el juicio del analista la herramienta principal en la decisión de crédito.

Estas formas de evaluación de préstamos no son eficientes ya que están sujetas a errores humanos y sesgos, además de consumir mucho tiempo. Argumentan que el hecho de que el porcentaje de préstamos morosos en Jordania sea más alto que el promedio internacional sería una consecuencia de esto (7% contra 5% respectivamente en el 2014); esto indica que siguen existiendo problemas para evaluar el riesgo en Jordania.

# 2.4 Dificultades que presentan los países emergentes para la implementación de los modelos de Credit Scoring

Un punto recurrente en la bibliografía es que la principal dificultad para la construcción y puesta en marcha de estos sistemas es la disponibilidad de datos en cantidades suficientes. Para desarrollar un modelo adecuado se requiere una gran muestra de datos con aproximadamente 800-1200 préstamos "malos" y un número igual o mayor de "préstamos buenos" y solicitantes rechazados (Miller y Rojas, 2004). Sin una abundante base de datos acerca del desempeño y las características de anteriores préstamos, la calificación es imposible. La base de datos debe estar computarizada e idealmente incluiría tanto a los solicitantes aprobados como a rechazados, aunque la mayoría de las entidades sólo mantienen registros de los aprobados. La base de datos también debe incluir una gama completa de características de prestatarios, prestamistas y préstamos, así como datos sobre el momento y la duración de cada período de mora. Una base de datos grande, precisa y completa sobre el desempeño de los préstamos anteriores es un activo que muchas entidades en países emergentes no han podido desarrollar o utilizar al máximo.

Muy aparte de eso, Schreiner (2000) nos indica que la parte difícil es la implementación del modelo en una entidad acostumbrada a trabajar con una tecnología de préstamos ya existente. Los gerentes y jefes de la misma deben comprometerse a respaldar su adopción e integración dentro de la organización. De lo contrario, el modelo recién desarrollado puede quedar sin usar; "un modelo no utilizado no sirve para nada, y un modelo mal utilizado es peor que ningún modelo".

Una clave para la aceptación de los modelos de score es su facilidad de uso. Esto requiere que los sistemas de puntuación se integren en el sistema de información de gestión existente y que requieran poca entrada de datos más allá de los procesos estándar. Dicha integración también permite que las estimaciones de riesgo se incluyan en informes estándar. En Colombia, por ejemplo, el sistema de información gerencial genera un informe con el riesgo estimado de "atrasos costosos", junto con otra información clave sobre posibles préstamos para ser revisada en la reunión diaria del comité de crédito de cada sucursal. Los oficiales de crédito también reciben una lista de sus prestatarios actualmente pendientes en orden de riesgo estimado, dando prioridad a las visitas preventivas. En resumen, un buen sistema de puntuación permite que un prestamista continúe con sus actividades habituales, pero con la adición de estimaciones cuantitativas de riesgo. Schreiner (2000)

En tercer lugar, cabe mencionar lo señalado por Avery et al. (2004) ya que existen limitaciones importantes en la información histórica contenida en las centrales de riesgo. Por ejemplo, para las cuentas que alcanzaron un estado de pérdida o atraso importante pero que finalmente se normalizaron, la información histórica que se almacena solo corresponde a la fecha en que se inició el atraso y la fecha final en que se regularizó, por lo general no se guarda registro sobre los saldos de las cuentas y los límites de crédito para poder observar la evolución de dicha cuenta. Estas limitaciones

en los datos pueden dificultar la vinculación del periodo de impago con los cambios sucedidos en la situación personal del cliente tal como la información sobre el momento en que se pierde el empleo.

Más allá de la cuestión de saber el momento exacto en que empezaron los problemas para el cliente, es probable que existan limitaciones adicionales en la capacidad de una entidad para usar dicha información. Por ejemplo, a menudo se dispone de información sobre las condiciones económicas locales, como las tasas de desempleo a nivel de distrito, el costo de vida, entre otras. Sin embargo, la dificultad podría estar en determinar la ubicación exacta donde residía una persona cuando surgieron cambios en su comportamiento de pago. Más difícil aún sería saber si la empresa en la que trabajaba pertenece o no al sector que se vio más afectado por una ola de despidos. (Avery et al., 2004)





#### **Conclusiones**

Para lograr replicar el éxito que tienen los modelos de Credit Scoring en los países desarrollados es necesario reunir suficiente información y que ésta sea relevante y concreta, mientras que en los países emergentes mucha de esta información suele ser cualitativa e informal. Sin embargo, esto no impide que la calificación crediticia tenga lugar en las operaciones diarias de las entidades financieras. Si bien hay consenso entre los investigadores de que ésta no llega a tener la eficacia que tiene en los países desarrollados y que no reemplazará a la evaluación cualitativa de los analistas; aun así, el puntaje obtenido puede ser útil en la estimación y predicción del riesgo (y por lo tanto en la estimación del costo) incluso si la entidad basa su decisión en el criterio del analista de créditos. Por lo tanto, en los países emergentes, la calificación complementa aunque no reemplaza las metodologías financieras actuales.

Adicionalmente, la elaboración de un método de puntuación nos revela cómo ciertas características de los solicitantes, los créditos y de las mismas entidades afectan el riesgo, siendo este conocimiento útil para el evaluador que utiliza indicadores para guiar sus decisiones diarias. No cabe duda que en los próximos años la mayoría de las entidades (sino todas) de países emergentes harán de los modelos de calificación crediticia una de sus herramientas de decisión más importantes.

Ciertamente, es importante tener en cuenta que los costos de invertir en un sistema intensivo en tecnología e información económica y situacional de los solicitantes deberían estar compensados con la mejora en la productividad y en la rentabilidad de las empresas financieras. Es en este sentido que se propone una combinación de sistemas cuantitativos y cualitativos para superar estos problemas y aprovechar la experiencia y el conocimiento de los analistas y responsables de crédito.



#### Lista de referencias

- Abdou, H. A. (2009). Genetic programming for credit scoring: The case of Egyptian public sector banks. *Expert systems with applications*, *36*(9), 11402-11417.
- Ala'raj, M., Abbod, M., & Radi, M. (2018). The applicability of credit scoring models in emerging economies: an evidence from Jordan. *International Journal of Islamic and Middle Eastern Finance and Management*.
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4), 589-609.
- Avery, R. B., Calem, P. S., & Canner, G. B. (2004). Consumer credit scoring: do situational circumstances matter? *Journal of Banking & Finance*, 28(4), 835-856.
- Bonilla, M., Olmeda, I., & Puertas, R. (2003). Modelos paramétricos y no paramétricos en problemas de credit scoring. *Spanish Journal of Finance and Accounting/Revista Española de Financiación y Contabilidad*, 32(118), 833-869.
- Boyle, M. (1992). Methods for credit scoring applied to slow payers, Credit Scoring and Credit Control, (edited by L. Thomas, J. Crook and D. Edelman).
- Chopra, A., & Bhilare, P. (2018). Application of ensemble models in credit scoring models. *Business Perspectives and Research*, 6(2), 129-141.
- Dinh, T. H. T., & Kleimeier, S. (2007). A credit scoring model for Vietnam's retail banking market.

  International Review of Financial Analysis, 16(5), 471-495.
- Dumitrescu, E., Hue, S., Hurlin, C., & Tokpavi, S. (2018). Machine learning for credit scoring: improving logistic regression with non linear decision tree effects (Doctoral dissertation, Ph. D. thesis, Paris Nanterre University, University of Orleans).
- Espin-García, O., & Rodríguez-Caballero, C. V. (2013). Metodología para un scoring de clientes sin referencias crediticias. *Cuadernos de economía*, 32(59), 137-162.
- Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 7(2), 179-188.
- Frame, W. S., Padhi, M., & Lynn, W. (2001). The Effect of Credit Scoring on Small Business Lending in Low-and Moderate-Income Areas. *Working Paper* 2001-6]. Federal Reserve Bank of Atlanta.
- Fu, Z., Golden, B. L., Lele, S., Raghavan, S., & Wasil, E. (2006). Diversification for better classification trees. *Computers & operations research*, 33(11), 3185-3202.
- García Sánchez, M., & Sánchez Barradas, C. (2005). Riesgo de crédito en México: aplicación del modelo CreditMetrics. México: Departamento de Contaduría y Finanzas. Escuela de Negocios, Universidad de las Américas Puebla.
- Gutiérrez Girault, M. A. (2007). Modelos de credit scoring: qué, cómo, cuándo y para qué.

- Hurley, M., & Adebayo, J. (2016). Credit scoring in the era of big data. Yale JL & Tech., 18, 148.
- Malekipirbazari, M., & Aksakalli, V. (2015). Risk assessment in social lending via random forests. *Expert Systems with Applications*, 42(10), 4621-4631.
- Miller, M., & Rojas, D. (2004). Improving access to credit for smes: an empirical analysis of the viability of pooled data sme credit scoring models in Brazil, Colombia & Mexico. *World Bank working paper*.
- Orgler, Y. E. (1970). A credit scoring model for commercial loans. *Journal of money, Credit and Banking*, 2(4), 435-445.
- Puertas Medina, R. M., & Martí Selva, M. L. (2013). Análisis del credit scoring. *RAE-Revista de Administração de Empresas*, 53(3), 303-315.
- Rayo Cantón, S., Lara Rubio, J., & Camino Blasco, D. (2010). Un Modelo de Credit Scoring para instituciones de microfinanzas en el marco de Basilea II. *Journal of Economics, Finance and Administrative Science*, 15(28), 89-124.
- Schreiner, M. (2000). Credit scoring for microfinance: Can it work?. *Journal of Microfinance/ESR Review*, 2(2), 6.
- Thomas, L. C. (2000). A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers. *International journal of forecasting*, 16(2), 149-172.
- Van Sang, H., Nam, N. H., & Nhan, N. D. (2016). A novel credit scoring prediction model based on Feature Selection approach and parallel random forest. *Indian Journal of Science and Technology*, 9(20), 1-6.
- Wiginton, J. C. (1980). A note on the comparison of logit and discriminant models of consumer credit behavior. *Journal of Financial and Quantitative Analysis*, 757-770.

#### Notas al pie de página

- <sup>1</sup> Dinh (2007) argumenta que en los mercados de países emergentes las prácticas crediticias tienden a ser deficientes y los bancos (especialmente microfinancieras) carecen de los datos necesarios sobre las características de los prestatarios y su historial crediticio para diseñar modelos fiables.
- <sup>2</sup> Desde 2004 las entidades financieras cuyos países están suscritos al acuerdo de Basilea deben disponer de modelos de medición (scorings y ratings) que les permitan discriminar según el riesgo del cliente y evaluar su nivel de exposición y la severidad en el riesgo de crédito (Rayo et al., 2010).
- <sup>3</sup> Por lo general, el desarrollo de un modelo de Credit Scoring implica un costo fijo significativo, pero una vez implementado se puede utilizar para seleccionar clientes adicionales a costos marginales muy bajos, lo que da una ventaja decisiva a las grandes entidades frente a las pequeñas. Una investigación reciente de Beck, Demirguc-Kunt y Maksimovic (2004) muestra que los modelos de Credit Scoring reducirían el poder de mercado de los grandes prestamistas y podrían aumentar el acceso a la financiación.
- <sup>4</sup> Los credit score son metodologías estadísticas que pronostican, en el momento en el que se está llevando a cabo la solicitud de crédito, cuál será el comportamiento del mismo hasta su vencimiento.
- <sup>5</sup> A pesar de la proliferación de los modelos de credit scoring, el juicio del analista continúa siendo fundamental, expresado en algunos casos como un conjunto de reglas que la entidad aplica de manera sistemática para filtrar solicitudes o deudores. De hecho, en la práctica ambas metodologías muchas veces coexisten y se complementan. (Gutiérrez, 2007)
- <sup>6</sup> Dentro de los modelos de evaluación de créditos de consumo, suelen emplearse variables socioeconómicas como: edad, estado civil, número de personas a su cargo, antigüedad laboral, nivel educativo, si la vivienda es propia o no, nivel de ingresos, gastos promedio, ocupación, cantidad de líneas de crédito, cantidad de ahorro, número de consultas en las centrales de riego, entre otras
- <sup>7</sup> Los beneficios de la calificación crediticia son claros en la investigación de Mester (1997), por ejemplo, señala que la calificación crediticia ha reducido sustancialmente la duración del proceso de aprobación de préstamos de dos semanas a 12.5 horas para préstamos para pequeñas empresas en los EE. UU., o de nueve a tres días para préstamos al consumo en Canadá.
- <sup>8</sup> Altman (1968) desarrolló la metodología más utilizada para pronosticar la insolvencia empresarial aplicando variables explicativas en forma de ratios. Esta metodología se adaptó posteriormente a la predicción de la morosidad de clientes de entidades bancarias.
- <sup>9</sup> Tan sólo bajo estas hipótesis la función discriminante obtenida será óptima (Puertas y Martí, 2013).
- <sup>10</sup> Ripley (1994) describió algunas aplicaciones que se emplearon posteriormente en detectar fraudes y evaluar las conveniencias sobre el crédito.