

Modelo Integral de Administración de Riesgos para sociedades financieras de objeto múltiple

Integrated risk management model for multiple purpose financial institutions

Jose Francisco Martínez¹ Teresa de Jesús Pineda² Tomás Gómez³ Adriana Zambrano⁴

¹ PhD en Ciencias Económicas, Líder de Grupo de Investigación en Ingeniería Económica y Financiera, Escuela Superior de Apan, Universidad Autónoma del Estado de Hidalgo, marzan67@gmail.com

² MBA, BS. en Economía. Analista Financiero, Escuela de Negocios y Economía, Universidad de las Américas Puebla

teresaj.pinedahz@udlap.mx

³ PhD en Ciencias Económicas, Escuela Superior de Apan, Universidad Autónoma del Estado de Hidalgo, Profesor Investigador en la UAEH, México tomas_gomez@uaeh.edu.mx

⁴ PhD en Ciencias Económicas, Escuela Superior de Apan, Universidad Autónoma del Estado de Hidalgo, Coordinadora de la Licenciatura en ingeniería económica y financiera en la UAEH México
adriana_zambrano@uaeh.edu.mx

Recibido: Septiembre 23 de 2016 - Aceptado: Octubre 4 de 2016

<http://dx.doi.org/10.18566/puente.v10n2.a08>

Resumen— El lavado de dinero y el financiamiento del terrorismo son delitos financieros que vulneran la integridad y estabilidad del sector financiero, además de impactar negativamente la economía de un país desviando recursos de actividades económicas productivas.

En México se tiene registro (SHCP¹ y PGR²) de este tipo de prácticas en el sector de las Sociedades Financieras de Objeto Múltiple (SOFOMES³), debido a la importancia de estas últimas en el mercado financiero mexicano⁴. Por ello es tema que debe atenderse desde distintos frentes para mantener un sistema financiero saludable y sólido.

Este trabajo de investigación propone crear un modelo de administración de riesgos que permita a las SOFOMES luchar en la prevención de este tipo de delitos dentro del marco legal aplicable y conforme las mejores prácticas internacionales. Asimismo, se busca promover la profesionalización de los participantes en este sector con el desarrollo de habilidades y capacidades de identificación, cuantificación, medición y administración de riesgos en sus distintas líneas de negocio.

Para este propósito se realizará un diagnóstico de las SOFOMES, a través de encuestas representativas y grupos de enfoque que permitan contar con información confiable sobre su situación actual y con base en ello proponer un modelo causal de administración de riesgos con un enfoque de redes bayesianas y simulación Montecarlo.

Palabras clave— Prevención de lavado de dinero, Riesgo, Redes bayesianas, Modelos causales.

Abstract— Money laundering and the financing of terrorism are financial crimes that have economic consequences which may undermine the integrity and stability of the financial sector. These crimes may adversely affect the financial stability and the macroeconomic evolution of a country by reducing welfare and diverting resources from more productive economic activities. In Mexico there are records (SHCP1 and PGR2) of such practices in the sector of Multiple Purpose Financial Companies in (SOFOMES3). Due to the importance of the latter in the Mexican financial market, this is an issue that must be addressed from different fronts, in order to maintain a healthy and solid financial system. Therefore, this research paper aims to create a model of risk management that allows the SOFOM fight in the prevention of such crimes within the applicable legal framework and according to international best practices. It also seeks to promote the professionalization of the participants in this sector with the development of skills and capabilities of identification, quantification, measurement and risk management in its various business lines. For this purpose, a diagnosis of the SOFOM will be carried out, through representative surveys and focus groups that allow reliable information about their current situation, to propose a risk management causal model with a Bayesian network approach and Monte Carlo simulation.

Key words: Money laundering, Risk, Network Bayesian, Causal model.

¹ Secretaría de Hacienda y Crédito Público

² Procuraduría General de la República

³ Cuyo objeto social principal es la realización habitual y profesional de una o más de las actividades de otorgamiento de crédito, arrendamiento financiero y/o factoraje financiero

⁴ Hasta diciembre de 2015 el sector tenía una cartera aproximada de 335 mil millones de pesos que representó el 1.8% del PIB de 2015

I. INTRODUCCIÓN

Los delitos financieros confinan a una amplia categoría de delitos contra la propiedad, cometidos por individuos y organizaciones para obtener una ventaja personal o de negocio, como el lavado de dinero, el fraude en tarjeta de crédito/débito, la malversación, falsificación, fraude hipotecario, entre otros. Estos crímenes cuestan varios miles de millones de dólares al año y afectan la vida de millones de personas [2]. En este estudio nos enfocaremos en el lavado de dinero; éste se da cuando los delincuentes ocultan el verdadero origen de los fondos, enviándolos a través de una serie de transacciones en donde el objetivo es ocultar el hecho de que los fondos fueron adquiridos como resultado de algún tipo de actividad delictiva. Estos recursos, a su vez, pueden ser utilizados para promover actividades ilegales, tales como el financiamiento de actividades terroristas, el tráfico de drogas ilegales, el apoyo a actividades de prostitución, o el contrabando de armas.

El lavado de dinero y el financiamiento del terrorismo pueden amenazar la estabilidad del sector financiero de un país. Los regímenes eficaces de lucha contra el lavado de dinero y el financiamiento del terrorismo son esenciales para salvaguardar la integridad de los mercados financieros mundiales, ya que ayudan a mitigar factores que propician abusos financieros. Las medidas para evitar y combatir el lavado de dinero y el financiamiento del terrorismo, por lo tanto, responden no solo a una imperativa moral sino a una necesidad económica [28].

En México, las Sociedades Financieras de Objeto Múltiple (SOFOMES) se han identificado como un sector del sistema financiero que presenta una alta vulnerabilidad respecto a los crímenes de lavado de dinero y financiamiento del terrorismo. México ha adoptado un sistema operativo de represión, dirigido desde la Procuraduría General de la República (PGR). Los avances en este sentido parecen haber sido poco satisfactorios y deficientes en la lucha contra el lavado de dinero, planteándose frecuentemente dificultades de coordinación con el ministerio de hacienda, generando por lo tanto un distanciamiento entre el sistema financiero y las autoridades del Estado en la persecución del delito.

Por todas estas razones surge la necesidad de crear un “Modelo integral de administración de riesgos para sociedades financieras de objeto múltiple” que permita a estas SOFOMES tanto a las reguladas como aquéllas que no están vigiladas directamente por la Comisión Nacional Bancaria y de Valores (CNBV), operar de acuerdo a lo expresado en las últimas modificaciones a la Ley General de Organizaciones y Actividades Auxiliares de Crédito, el modelo propuesto apoyará en la prevención del delito de lavado de dinero y ayudará en la lucha contra el financiamiento del terrorismo. También, se espera que una vez implementado este modelo integral de administración de riesgos, las SOFOMES ayuden a lograr un mayor crecimiento económico, además de fomentar la competencia en el sector al permitir a más agentes que sigan operando en el mercado.

Para lo anterior se propone un modelo dinámico causal que permita representar a través de una red estocástica de causa-efecto las relaciones entre los distintos factores que inciden en el riesgo PLD/FT⁵. Para lo cual se hará un estudio de campo en el sector de las SOFOMES, utilizando herramientas como encuestas, entrevistas y grupos de enfoque, que permitan contar con información representativa del sector para incorporarse y ajustar el modelo.

El trabajo se organiza de la siguiente forma, en la sección 2 se analizan los modelos causales, algunas de sus aplicaciones, los principales métodos y técnicas para la solución de modelos causales, tales como arboles de decisión, redes neuronales artificiales y redes bayesianas. En la sección 3 se construye el modelo utilizando redes bayesianas, para cuantificar el riesgo PLD/FT se utilizan probabilidades *a priori*. En caso de existir datos cuantitativos históricos se “ajustan” distribuciones de probabilidad; en caso contrario se recurre a la opinión o juicio de los expertos para obtener las probabilidades correspondientes. Una vez que se cuenta con las probabilidades *a priori* del modelo, en la sección 4 se calculan las probabilidades *a posteriori* a través de algoritmos de inferencia Bayesiana, se estima el riesgo PLD/FT y se generan distintos escenarios. Finalmente, en la sección 5 se dan las conclusiones.

II. APROXIMACIÓN TEÓRICA

En la investigación estudiamos fenómenos complejos mediante los modelos causales, éstos intentan inferir las relaciones que existen entre variables de un sistema complejo y determinar la estructura existente entre tales relaciones. Históricamente éstos modelos tienen su origen en los trabajos de Wright y fue utilizada por primera vez en biología [40]. Posteriormente en el estudio de las Ciencias Sociales por Simon [37] y Blalock [7], [8]. Y finalmente popularizada por Duncan, así como Jöreskog y Sörbom.[13], [24]. Su aplicación permite a la investigación no sólo valorar un modelo causal, sino evaluar si los conceptos utilizados en el modelo son congruentes con las variables medidas en el modelo como nos lo exponen Asher y Bisquerra.[4], [6], [18], [21].

Los modelos causales suponen una serie de etapas u operaciones que soportaran el éxito de esta metodología, éstas fases son: 1) Formulación teórica del modelo, esto es plantear hipótesis causales que permitan encontrar el orden causal entre las variables, un diagrama de red del modelo; 2) Seleccionar aquellas variables que mejor expliquen el fenómeno bajo estudio dando como resultado ecuaciones estructurales que expresan la dependencia o la relación que hay entre las variables; 3) Identificación del modelo, es decir el “ajuste” entre los datos empíricos y el modelo propuesto; 4) Estimación de los parámetros del modelo, una vez identificado el modelo o bien establecidos los parámetros se calculan, y finalmente; 5) La evaluación del modelo, es el proceso estadístico y consiste en determinar mediante pruebas *a posteriori* el ajuste del modelo a los datos [34].

⁵ Se entenderá riesgo PLD/FT, a la probabilidad de que un cliente utilice a la institución financiera para el lavado de dinero.

Existen diferentes técnicas para resolver un modelo causal, como los arboles de decisión, las redes neuronales, las redes bayesianas, entre otros.

El lavado de dinero es un serio crimen económico que amenaza la seguridad nacional de todos los países [15]. Es crucial combatir el lavado de dinero en las instituciones financieras por lo que es necesario contar con capacidades sólidas contra el lavado de dinero y el financiamiento al terrorismo. Las instituciones financieras están legalmente obligadas a cumplir con: requerimientos estatutarios y regulatorios, detectar y reportar actividades sospechosas que pueden estar relacionadas con actividades sospechosas que a su vez podrían estar relacionadas con actividades criminales [35]. Una cantidad importante de transacciones sospechosas se envían a las unidades de inteligencia financiera para identificar, investigar y analizar actividades criminales. La pobre inteligencia de los intermediarios financieros junto con el gran volumen de transacciones sospechosas y reportes de evidencia enviados por los intermediarios financieros han afectado severamente la eficiencia del monitoreo y análisis de este tipo de transacciones y ha reducido extremadamente la eficiencia en la utilización de datos.

Generalmente, para monitorear y analizar los datos de las actividades sospechosas es necesario hacer uso de una gran cantidad de recursos como empleados, computadoras, comunicaciones, almacenamiento, entre otros. Utilizar estos recursos para prevenir el lavado de dinero requiere que los intermediarios financieros inviertan grandes cantidades de dinero.

El cumplimiento de las regulaciones anti lavado de dinero es una pesada y costosa carga para los intermediarios financieros [19]. Como resultado, no todos los intermediarios financieros están dispuestos a comprometer más recursos y soportar el aumento de los costos de cumplimiento de la regulación anti lavado de dinero. Por lo tanto, la creación de un modelo integral de administración de riesgos ayuda a mejorar el monitoreo y análisis de las transacciones. Los estudios en el análisis económico del cumplimiento de la regulación anti lavado de dinero y la efectividad del sistema de reporte de transacciones sospechosas han sido conducidos para resolver las deficiencias prácticas en la implementación de los programas anti lavado de dinero. Haciendo uso de un modelo con un agente principal se estudia como incrementar la efectividad de las reglas anti lavado de dinero a través de un enfoque basado en el riesgo. [33].

Utilizando un juego evolucionario entre los intermediarios financieros y los empleados, se muestra que la eficiencia del combate al lavado de dinero depende de una conjugación de factores entre estos esta un correcto diseño de la regulación anti lavado de dinero y la voluntad de los intermediarios financieros y sus trabajadores para combatir el lavado de dinero [3]. Se propone un modelo dinámico para simular la relación entre las ganancias del crimen organizado, lavado de dinero e inversiones legales. [5]. Otras técnicas de detección de anomalías se han explotado para mejorar la capacidad de los intermediarios financieros para procesar datos de transacciones

sospechosas como: la minería de datos y redes neuronales, algoritmos genéticos y técnicas de inteligencia artificial. [26], [27], [39] y [42].

Los procesos en el área financiera son complicados y dinámicos por naturaleza. Las características dinámicas involucran varios efectos que dependen del tiempo como procesos estacionales, avances de la tecnología, procesos estocásticos, errores humanos, inspecciones, fallas de los equipos de cómputo, lavado de dinero y financiamiento contra el terrorismo. Es importante poder cuantificar los riesgos provenientes de los factores que dependen del tiempo como los antes mencionados. Las metodologías convencionales de análisis de riesgos, por ejemplo: HAZOP, What if Analysis, Árbol de Fallas, Árbol de Eventos, Análisis Bow-Tie y Análisis de capas de protección; todos tienen limitaciones para cuantificar cambios dinámicos en los procesos.

Estos métodos pueden incorporar una respuesta dinámica del sistema, pero de manera limitada. Por ejemplo, un Árbol de Fallas o un Árbol de Eventos describen la relación entre el resultado final y diferentes fallas humanas o de equipo, pero difícilmente incorporan una respuesta dinámica del sistema, variables de variaciones en los procesos y acciones del operador. Los accidentes catastróficos (problemas concernientes al lavado de dinero y financiamiento al terrorismo) pueden ocurrir cuando los parámetros de procesos críticos exceden el límite de seguridad de operación sin ser detectados debido a una falla en el sistema de monitoreo de operaciones riesgosas [41]. Por tanto, es importante desarrollar un método que tenga la habilidad de medir el riesgo que surge de los efectos de eventos dependientes del tiempo.

En el trabajo de Siu, se resumen los diferentes métodos disponibles para el análisis de riesgos de los procesos dinámicos. La modelación de Markov es uno de los métodos más aceptados para el análisis de riesgos dinámicos. Los diagramas de transición de estado son construidos para representar posibles estados del sistema y transiciones de un estado a otro. Una de las limitaciones de los procesos de Markov es que el número de estados incrementa cuando incrementa el tamaño del sistema. Esto hace que la construcción del diagrama de transición del estado del sistema y los cálculos sea complejos. Así mismo, la teoría de los modelos de Markov no considera el efecto de la inspección en transiciones estado-sistema. [36].

El enfoque de la Metodología Analítica Lógica Dinámica fue una de las primeras aplicaciones de este enfoque, se realiza un análisis de confiabilidad del proceso químico [10], [30]. Este modelo tiene la habilidad de cuantificar diferentes efectos dependientes del tiempo al incorporar efectos dinámicos a los procesos. El enfoque de la Metodología Analítica Lógica Dinámica tiene una habilidad limitada de lidiar con muchos escenarios y los cálculos que involucran estos escenarios consumen tiempo y el proceso es costoso. [10], [36]. El árbol de eventos dinámico, permite derivaciones en diferentes puntos en el tiempo, y se puede aplicar para análisis de secuencia de accidentes [1]. El enfoque semi-Markoviano denominado Análisis Dinámico de Riesgo Operacional, la metodología

tiene la habilidad de cuantificar el riesgo de una falla del componente eventos anormales de los componentes y también incorpora el tiempo de inspección para entender su efecto sobre el riesgo [41]. En este trabajo los autores realizan simulaciones de Monte Carlo para entender la condición anormal del sistema de cada una de las transiciones individuales de los componentes de un estado a otro y entonces se hace una simulación de mayor duración para entender el efecto del tiempo de prueba e inspección sobre la probabilidad de un evento anormal de un componente.

En años recientes, las redes Bayesianas, un modelo gráfico basado en la aplicación del teorema de Bayes de probabilidad para medir dependencias complejas se ha utilizado para analizar riesgos en las finanzas. El enfoque Bayesiano es una alternativa viable para el análisis de riesgos en condiciones de incertidumbre. Por construcción, los modelos Bayesianos incorporan información inicial a través de una distribución de probabilidad *a priori*, mediante la cual se puede incluir información subjetiva en la toma de decisiones como es: la opinión de expertos, el juicio de analistas o las creencias de especialistas.

Las redes Bayesianas, son herramientas poderosas para realizar inferencia estadística en dominios complejos utilizando un gran número de variables. [16], [31]. Una red Bayesiana es un modelo probabilístico gráfico que consiste de una estructura gráfica y parámetros de distribuciones de probabilidad condicional correspondientes a la estructura. La estructura gráfica de una red Bayesiana está compuesta por nodos estos representan las variables y arcos que representan las relaciones entre las variables. Los parámetros de las redes Bayesianas representan la naturaleza y la fuerza de las relaciones representadas por los arcos [25].

La estructura de una red Bayesiana es útil para modelar relaciones causales [32]. Por lo tanto, las redes Bayesianas ofrecen características únicas ya que permiten integrar el conocimiento de expertos y datos dentro de la construcción del modelo. [9], [16], [22], [44], [45]. Esto es especialmente conveniente cuando la disponibilidad de datos relevantes es limitada, pero se cuenta con un extenso conocimiento de los expertos. Como resultado, las redes Bayesianas han sido usadas en problemas complejos en diversas áreas las que incluyen: medicina, leyes Finanzas, y deportes. [11], [12], [17], [29].

Teorema de Bayes.

El teorema de Bayes es una regla que puede ser utilizada para actualizar creencias con base en nueva información (por ejemplo, datos observados). [46]

Definición 1.- Si se denota por E como la evidencia y se supone que un experto cree que se puede asociar con una probabilidad $P(E)$, el teorema de Bayes (TB) dice que después de observar los datos, D , las creencias sobre, E , son ajustadas de acuerdo con la siguiente expresión:

$$P(E | D) = \frac{P(D|E)P(E)}{P(D)}, \text{ donde} \quad (1)$$

1) $P(D | E)$ es la probabilidad condicional de los datos, dado que la evidencia *a priori*, D , es cierta.

2) $P(D)$ es la probabilidad incondicional de los datos, $P(D) > 0$; también se puede expresar como:

$$P(D) = P(D|E)P(E) + P(D|E^c)P(E^c).$$

La probabilidad de E , antes de tener los datos $P(E)$, es llamada probabilidad *a priori*, una vez actualizada $P(E|D)$, es denominada probabilidad *a posteriori*.

Definición 2.- Se reescribe la forma continua del TB de la siguiente manera:

$$P(\theta | \mathbf{y}) \propto L(\theta | \mathbf{y})\pi(\theta) \quad (2)$$

Donde, θ es un parámetro desconocido a estimar, \mathbf{y} es un vector de observaciones, registradas, $\pi(\theta)$ es una distribución *a priori* que depende de uno o más parámetros, denominados hiper-parámetros, $L(\theta | \mathbf{y})$ es la función de verosimilitud para θ y $P(\theta | \mathbf{y})$ es la distribución *a posteriori* de θ (actualización de la *a priori*).

Dos preguntas surgen de lo anterior, como traducir la información *a priori* en su forma analítica, $\pi(\theta)$, y que tan sensible es la inferencia *a posteriori*, a la selección de la *a priori*, estas preguntas han sido un amplio tema de interés en la literatura Bayesiana [14].

Inferencia Bayesiana

La distribución *a posteriori* del parámetro o vector de parámetros θ , dada la información \mathbf{y} , denotada por $P(\theta | \mathbf{y})$ es obtenida a través de la aplicación del teorema de Bayes. Es una combinación de datos y de la distribución *a priori*, la distribución *a posteriori* contiene la información relevante sobre el parámetro desconocido.

Redes Bayesianas

Definición 3.- Las Redes Bayesianas son Gráficas Dirigidas Acíclicas (GDAs). Una gráfica es definida como un conjunto de nodos unidos por arcos. Si entre cada par de nodos hay una relación de precedencia representada por arcos, entonces la gráfica es dirigida.

Definición 4.- Un ciclo es una trayectoria que inicia y termina en el mismo nodo.

Definición 5.- Una trayectoria es una serie de nodos contiguos conectados por arcos dirigidos.

Cada nodo en una RB se asocia con un conjunto de tablas de probabilidades. Los nodos representan las variables de interés, las cuales pueden ser discretas o continuas. Una red causal es

una RB con la propiedad adicional de que los nodos “padres” son las causas dirigidas [23] [33] [38].

Algoritmos para cálculo de inferencia en Redes Bayesianas

Una Red Bayesiana es empleada básicamente para inferencia a través del cálculo de las probabilidades condicionales dada la información disponible hasta el momento para cada nodo (creencias). Existen dos clases de algoritmos para el proceso de inferencia, el primero genera una solución exacta y el segundo produce una solución aproximada con alta probabilidad. Entre los algoritmos de inferencia exacta se tienen, por ejemplo: *polytree*, *clique tree*, *junction tree*, *algorithms of variable elimination* y *method of Pear*.

El uso de soluciones aproximadas es motivado por el crecimiento exponencial de tiempo de procesamiento requerido para soluciones exactas, de acuerdo con este tipo de algoritmos puede agruparse en *stochastic simulation*, *model simplification methods*, *search based methods* y *loopy propagation methods*, el más conocido es el de simulación estocástica, el cual se divide en *importance sampling algorithms* y *Markov Chain Monte Carlo (MCMC) methods* [20].

III. PLANTEAMIENTO Y CONSTRUCCIÓN DEL MODELO (METODOLOGÍA)

Construcción de la Red bayesiana (RB)

En esta sección se plantea y construye la red tomando como base los aspectos normativos que le aplican a las SOFOMES y mejores prácticas internacionales, generando una red bayesiana con nodos que representa factores de riesgo que inciden de manera diferenciada en el riesgo PLD. En términos estadísticos son variables aleatorias que se les asocia una distribución de probabilidades ya sea discretas o continuas cuya información se obtuvo de registros históricos o en su defecto de información proporcionada por los expertos⁶.

En la Tabla 1 se detallan las características de casa uno de los nodos de la red y la Figura 1 es la representación gráfica de la red⁷.

Así mismo, de la Tabla 2 a la Tabla 9 se muestran las probabilidades *a priori*, en su mayoría resultado de un trabajo de campo que consistió en visitar a 9 SOFOMES y llevar a cabo un levantamiento de información, a través del uso de instrumentos de recopilación como las encuestas y grupos de enfoque.

Con la información recopilada el grupo de trabajo involucrado en este proyecto, realizó un análisis y síntesis de la misma que dio como resultado las probabilidades que se muestran en cada una de las tablas.

**TABLA I
DESCRIPCIÓN DE NODOS DEL MODELO**

Nombre	Descripción	Tipo	Origen de datos	Estados
<i>Estructura Interna</i>	Es un nodo que describe el nivel organizacional de la entidad financiera, es decir la forma en que se pueden agrupar, relacionar y hacer eficiente la SOFOM.	Discreto	Expertos	0-0.2
				0.2-0.4
				0.4-0.6
				0.6-0.8
<i>Automatización</i>	Este nodo indica el nivel de uso de sistemas o elementos computarizados y electromecánicos para controlar datos y procesos dentro de la entidad financiera.	Discreto	Expertos	0-0.2
				0.2-0.4
				0.4-0.6
				0.6-0.8
<i>Identificación</i>	El nodo nos describe el grado de información que tenemos de un cliente.	Discreto	Expertos	MB
				B
				A
				R
<i>Conocimiento</i>	Este nodo nos da el nivel de identificación que tenemos de un cliente en cuanto a su riesgo de ser políticamente expuesto.	Discreto	Expertos	MB
				B
				A
				R
<i>Operaciones Relevantes</i>	El nodo muestra el número de operaciones relevantes que se registraron en la entidad financiera en determinado tiempo.	Continuo	Datos Históricos	D
<i>Operaciones Preocupantes</i>	El nodo nos muestra el porcentaje de operaciones preocupantes que se registraron en la entidad financiera en determinado tiempo.	Discreto	Expertos	Si
				No
<i>Personas Politicamente expuestas</i>	Nodo nos muestra el porcentaje de personas políticamente expuestas.	Discreto	Expertos	Si
				No
<i>Riesgo PLD/FT</i>	Este nodo nos da la probabilidad de que un cliente use a la entidad financiera para fines de lavado de dinero.	Continuo	Datos Históricos	

Fuente: Elaboración propia

⁶ Entenderemos como “experto” personal de la SOFOM que conoce los procesos operativos de la institución

⁷ Para la creación de la RB y el cálculo de las probabilidades *a posteriori*, se utilizó el software AGENA.

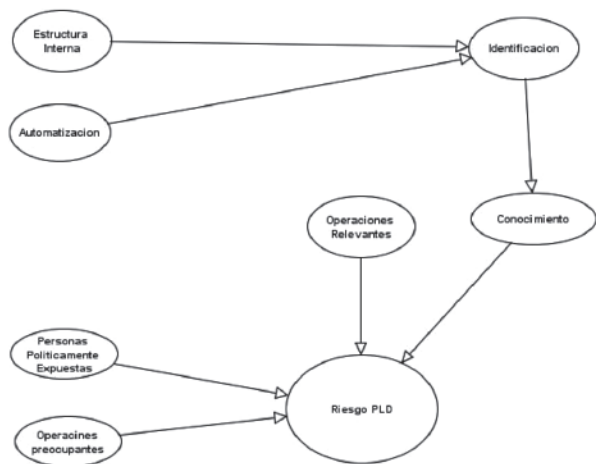


Fig 1. Modelo de red bayesiana para medir el riesgo PLD
Fuente: Elaboración propia

Distribuciones de probabilidades *a priori*

TABLA II
ESTRUCTURA INTERNA

Estado	Probabilidad
0-0.2	0.7
0.2-0.4	0.1
0.4-0.6	0.1
0.6-0.8	0.05
0.8-1	0.05

Fuente: Elaboración propia

TABLA III
AUTOMATIZACIÓN

Estado	Probabilidad
0-0.2	0.6
0.2-0.4	0.2
0.4-0.6	0.05
0.6-0.8	0.05
0.8-1	0.1

Fuente: Elaboración propia

Los estados para los nodos *estructura interna* y *automatización* se definen en un intervalo de 0 a 1, donde 0 es el nivel mínimo y 1 el nivel máximo en un sentido de eficiencia en su operación.

TABLA IV
IDENTIFICACIÓN

Estado	0-0.2				
	0-0.2	0.2-0.4	0.4-0.6	0.6-0.8	0.8-1
MB	0.2173913	0.2040816	0.1923077	0.3333334	0.3333334
B	0.17391305	0.1632653	0.15384616	0.2666666	0.2666668
A	0.13043478	0.1224489	0.115384616	0.2	0.2
R	0.08695652	0.0816326	0.07692308	0.1333333	0.1333334
D	0.39130434	0.4285714	0.46153846	0.0666666	0.0666667
Estado	0.2-0.4				
	0-0.2	0.2-0.4	0.4-0.6	0.6-0.8	0.8-1
MB	0.33333334	0.25	0.4993758	0.4	0.4
B	0.41666666	0.1875	0.37453184	0.3	0.3
A	0.16666667	0.125	0.001248439	0.2	0.2
R	0.083333336	0.4375	0.12484395	0.1	0.1
D	0	0	0	0	0
Estado	0.4-0.6				
	0-0.2	0.2-0.4	0.4-0.6	0.6-0.8	0.8-1
MB	0.27272728	0.18181819	0.2	0.2	0.22222222
B	0.18181819	0.18181819	0.2	0.2	0.22222222
A	0.18181819	0.27272728	0.2	0.2	0.11111111
R	0.18181819	0.18181819	0.2	0.2	0.22222222
D	0.18181819	0.18181819	0.2	0.2	0.22222222
Estado	0.6-0.8				
	0-0.2	0.2-0.4	0.4-0.6	0.6-0.8	0.8-1
MB	0.2	0.20792079	0.2	0.2	0.2
B	0.2	0.1980198	0.2	0.2	0.2
A	0.2	0.1980198	0.2	0.2	0.2
R	0.2	0.1980198	0.2	0.2	0.2
D	0.2	0.1980198	0.2	0.2	0.2
Estado	0.8-1				
	0-0.2	0.2-0.4	0.4-0.6	0.6-0.8	0.8-1
MB	0.2	0.2	0.16666667	0.16666667	0.52941173
B	0.2	0.2	0.33333334	0.33333334	0.11764706
A	0.2	0.2	0.16666667	0.16666667	0.11764706
R	0.2	0.2	0.16666667	0.16666667	0.11764706
D	0.2	0.2	0.16666667	0.16666667	0.11764706

Fuente: Elaboración propia

La tabla anterior muestra las probabilidades del nodo *identificación*, condicionadas a los posibles estados que toman los nodos *estructura interna* y *automatización*. Los estados de este nodo son muy bueno (MB), bueno (B), aceptable (A), regular (R) y deficiente (D).

TABLA V
CONOCIMIENTO

Estado	MB	B	A	R	D
MB	0.07518797	0.25862068	0.2040816	0.2727272	0.2
B	0.07518797	0.043103445	0.0510204	0.0909090	0.1
A	0.07518797	0.043103445	0.0510204	0.0909090	0.1
R	0.3007519	0.17241378	0.2040816	0.3636363	0.4
D	0.4736842	0.48275864	0.4897959	0.1818181	0.2

Fuente: Elaboración propia

En la tabla 5 se presentan las probabilidades del nodo *conocimiento*, condicionadas a los estados en que puede estar la variable *identificación*.

TABLA VI
OPERACIONES RELEVANTES

Es una distribución exponencial con parámetro $\lambda=4$

Fuente: Elaboración propia

TABLA VII
PERSONAS POLÍTICAMENTE EXPUESTAS

SI	0.8
NO	0.2

Fuente: Elaboración propia

TABLA VIII
RIESGO PLD

Es una distribución normal truncada con Media que Proviene de las operaciones relevantes

Fuente: Elaboración propia

TABLA IX
OPERACIONES PREOCUPANTES

SI	0.9
NO	0.1

Fuente: Elaboración propia

IV. RESULTADOS

Una vez construida la red e incorporado las distribuciones *a priori* se generan las distribuciones *a posteriori* a través de algoritmos Montecarlo Cadenas de Markov (MCMC) de inferencia bayesiana⁸, a continuación, se presentan los resultados y su interpretación

Distribuciones de probabilidad *a posteriori*

Estructura Interna. - tiene una distribución de probabilidad *a posteriori* con media de 0.23 y varianza de 0.056




Fig 2. Estructura Interna
Fuente: Elaboración propia

Automatización. - su distribución de probabilidad es similar al nodo “estructura interna”, con media 0.27 y varianza de 0.072




Fig 3. Automatización
Fuente: Elaboración propia

Identificación. - como se mostró en la Figura 1, este nodo tiene dos “padres”, “estructura interna” y “automatización”, los cuales tienen incidencia directa en la distribución *a posteriori* del nodo “identificación”, en la Figura 4 se ve que existe una probabilidad del 28.5% de que las SOFOMES identifiquen en forma deficiente a sus clientes lo que tiene una incidencia importante en el riesgo PLD.




Fig 4. Identificación
Fuente: Elaboración propia

⁸ Utilizando AGENA.

Conocimiento. - este nodo tiene como “padre” al nodo “identificación” y nos indica con un 41.2% de probabilidad que las SOFOMES tienen un regular conocimiento de sus clientes, y en congruencia con el nodo “padre” abona a un mayor riesgo PLD.




Fig 5. Conocimiento
Fuente: Elaboración propia

Operaciones Relevantes. - este nodo no tiene “padre”, su distribución de probabilidad *a posteriori* se muestra en la Figura 6, con media de 2 y varianza de 1.33. Su distribución *a priori* es una exponencial con tasa de crecimiento igual a 4. Este último resultado se genera a partir de datos históricos proporcionados por las SOFOMES.




Fig 6. Operaciones Relevantes
Fuente: Elaboración propia

Personas Políticamente Expuestas y Operaciones Preocupantes. - Nos indican el porcentaje de personas clasificadas como políticamente expuestas y el porcentaje de operaciones preocupantes respecto al total de operaciones de las SOFOMES.




Fig 7. Personas Políticamente Expuestas
Fuente: Elaboración propia




Fig 8. Operaciones Preocupantes
Fuente: Elaboración propia

Riesgo PLD. - Finalmente el nodo objetivo indica que con una probabilidad del 29.3 % las SOFOMES son de alta incidencia para ser utilizadas como medio de lavado de dinero, en forma similar con un 33.1% de media incidencia y un 37.4 % de baja incidencia para ser utilizadas para lavado de dinero.




Fig 9. Riesgo PLD
Fuente: Elaboración propia

V. CONCLUSIONES

Los delitos relacionados con el lavado de dinero y financiamiento al terrorismo son temas poco estudiados a pesar del impacto que tienen estas prácticas tanto para el sector financiero como en el desvío de recursos a actividades que no generan desarrollo y bienestar de las sociedades. Ejemplos de estas prácticas aparecen todos los días en revistas y periódicos nacionales e internacionales, las principales agencias de información destacan el efecto dañino que tienen estas actividades en todo el mundo.

Organismos internacionales como Financial Action Task Force (FATF), han promovido la creación de mecanismos e instrumentos legales y operativos para enfrentar este flagelo, México se adhiere a esta convocatoria y genera su propio andamiaje jurídico, legal y operativo para prevenir y sancionar estas prácticas.

En particular el sector financiero relacionado con el sector no bancario (SOFOMES) son blanco de actividades de LD/FT, desafortunadamente las SOFOMES son un sector que no es vigilado totalmente por las autoridades competentes, lo que lo convierte en un sector altamente vulnerable para este tipo de prácticas.

Recientemente las autoridades en México emitieron una serie de políticas para la prevención del lavado de dinero, en específico se establece la conveniencia de contar con un indicador de riesgo PLD, es decir, calcular la probabilidad de que un cliente o usuario utilice a las SOFOMES para lavar dinero.

Aquí es donde este trabajo propone un modelo de riesgos, utilizando redes bayesianas, para calcular el riesgo PLD. Los principales hallazgos son los siguientes:

- 1) Se realizaron un total de 9 visitas a campo con SOFOMES cuya principal función son los créditos a través de nómina, arrendamiento financiero y factoraje
- 2) De las 9 SOFOM ninguna tiene un modelo expreso para el cálculo del riesgo PLD, a pesar de que la normatividad lo estable como requisito.
- 3) La mayoría de las SOFOMES están en proceso de adecuar sus procedimientos al cumplimiento de la normatividad en materia de PLD/FT.
- 4) El registro y administración de la información en las SOFOMES es muy diversa, hay procedimientos que no se registran, o que la información no es confiable.
- 5) Un evento recurrente es la deficiencia en conocimientos fundamentales de administración de riesgos, lo cual provoca una mayor incidencia en el riesgo PLD.

Con relación a los objetivos planteados, los resultados fueron consistentes en el sentido de que logra captar las condiciones de causa-efecto que se dan en los distintos factores de riesgo representados por cada uno de los nodos de la red.

Por ejemplo, los nodos etiquetados como “estructura interna” y “automatización” tienen un desempeño débil de acuerdo con la información recopilada, estos nodos “afectan” al nodo “identificación”; lo cual queda reflejado después de realizar la inferencia bayesiana, este último nodo toma un valor deficiente (D) con probabilidad del 28.5%. Otro ejemplo es el nodo “conocimiento”, “afectado” por el nodo “identificación”, se espera que al tener una deficiente identificación del cliente provoque un conocimiento erróneo del mismo; al revisar la distribución *a posteriori* de probabilidad del nodo “conocimiento” se encontró que existe una probabilidad de más del 36% de un deficiente conocimiento (D) del cliente en congruencia con el nodo anterior.

El nodo objetivo “Riesgo PLD”, puede tomar tres estados, *Alto*, *Medio* y *Bajo*, esto se entiende como un *Ranking*, revisando los resultados se encontró que con una probabilidad del 37.4% las SOFOMES tienen una baja incidencia de ser utilizadas para lavado de dinero, con un 33.1% son de mediana incidencia y con un 29.3% están en un rango alto de ser utilizadas en prácticas de lavado de dinero.

Con esta herramienta las SOFOMES tienen en un solo número la probabilidad de que sean utilizadas para prácticas ilícitas y además es posible analizar la red e identificar áreas de oportunidad de mejora en sus distintos procesos que permitan disminuir el riesgo PLD a través del diseño e instrumentación de políticas y procedimientos, acompañado de un programa de profesionalización de la administración de riesgos.

Aunque se visitaron a 9 SOFOMES, no se puede concluir que estos resultados reflejan las condiciones actuales de todo el sector, habrá que ampliar el número de instituciones a visitar y posiblemente sea recomendable hacer el análisis por tamaño de las SOFOMES. Además de revisar con mayor cuidado los nodos y sus interrelaciones en la red bayesiana.

REFERENCIAS

- [1] Acosta, C. y Siu, N. (1993). “Dynamic event trees in accident sequence analysis: application to steam generator tube rupture.” *Reliability Engineering and System Safety*, 41(2), 135-154.
- [2] Agus, S., Sheela, N., Ming, Y., Zhang, A. J., & Fernando, C. D. (2010). *Statistical Methods for Fighting Financial Crimes*. *Technometrics*, (1), 5-19.
- [3] Araujo, R. A. (2010) “An evolutionary game theory approach to combat money laundering,” *Journal of Money Laundering Control* (13), 70–78.
- [4] Asher, H. B. (1983). *Causal modeling* (No. 3). Sage.
- [5] Barone R. y Masciandaro, D. (2011) “Organized crime, money laundering and legal economy: theory and simulations,” *European Journal of Law and Economics*, (5), 1–28.
- [6] Bisquerra Alzina, R. (1989). *Introducción conceptual al análisis multivariable*. Vol. II.
- [7] Blalock, H. M. (1961). *Correlation and causality: The multivariate case*. *Social Forces*, 39(3), 246-251.
- [8] Blalock, H. M. (1964). *Causal inferences in nonexperimental research*.
- [9] Cheng, J., Bell, D. y Liu, W. (1998). *Learning Bayesian networks from data: An efficient approach based on information theory*. On World Wide Web at <http://www.cs.ualberta.ca/~jcheng/bnpc.htm>.
- [10] Cacciabue, P., Amendola, A. and Cojazzi, G. (1986). “Dynamic logical analytical methodology versus fault tree: the case of the auxiliary feedwater system of a nuclear power plant.” *Nuclear Technology*, 74(2), 195.

- [11] Constantinou, C., Fenton, N. y Neil, M. (2012). "pi-football: A Bayesian network model for forecasting Association Football match outcomes." *Knowledge-Based Systems*, 36, 322-339.
- [12] Constantinou, C., Fenton, N. y Neil, M. (2013). "Profiting from an inefficient Association Football gambling market: Prediction, Risk and Uncertainty using Bayesian networks." *Knowledge-Based Systems*, 50, 60-86.
- [13] Duncan, O. D. (1966). *Path analysis: Sociological examples*. American journal of Sociology, 1-16.
- [14] Ferguson, T. S. (1973). "A Bayesian Analysis of Some Nonparametric Problems". *Annals of Statistics*, 2(4), 615-629.
- [15] F. F. I. E. Council, (2010) "Bank Secrecy Act/ Anti-Money Laundering Examination Manual".
- [16] Fenton, N. y Neil, M. (2012). *Risk assessment and decision analysis with Bayesian networks*, CRC Press.
- [17] Fenton, N., Neil, M. & Lagnado, D. (2013). "A general structure for legal arguments about evidence using Bayesian networks." *Cognitive science*, 37, 61-102.
- [18] Fuentes, A. (1986). Los modelos causales en la investigación del rendimiento académico. *Revista de investigación educativa*, RIE, 4(7), 35-48.
- [19] Geiger H. y Wuensch, O. (2007) "The fight against moneylaundering: An economic analysis of a cost-benefit paradoxon," *Journal of Money Laundering Control* 1(10), 91-105.
- [20] Guo H. and W. Hsu (2002). *A Survey of Algorithms for Real-Time Bayesian Network Inference*. Join Workshop on Real Time Decision Support and Diagnosis Systems, Edmonton, Alberta Canada.
- [21] Heise, D. R. (1975). *Causal analysis*. John Wiley & Sons.
- [22] Heckerman, D. (1997). "Bayesian networks for data mining." *Data mining and knowledge discovery*, 1, 79-119.
- [23] Jensen, F. V. (1996). *An Introduction to Bayesian Networks*. First edition, Springer.
- [24] Jöreskog, K. G., y Sörbom, D. (1978). *LISREL IV user's guide*. Chicago: National Educational Resources.
- [25] Koller, D. y Friedman, N. 2009. *Probabilistic graphical models: principles and techniques*, MIT press.
- [26] Le-Khac, N.A., Markos, S. y Kechadi, M. T. (2010) "A Data Mining- Based Solution for Detecting Suspicious Money Laundering Cases in an Investment Bank ," in *International Conference on Advances in Databases, Knowledge, and Data Applications – DBKDA*.
- [27] Lintao Lv, N. J. y Zhang, J. (2008) "A RBF neural network model for anti-money laundering ," in *International Conference on Wavelet Analysis and Pattern Recognition – ICWAPR*.
- [28] Mitsilegas, V., y Gilmore B. (2007). *The EU Legislative Framework against Money Laundering and Terrorist Finance: A Critical Analysis in the Light of Evolving Global Standards*. Cambridge University Press.
- [29] Neil, M., Hager, D. y Andersen, B. (2009). "Modeling operational risk in financial institutions using hybrid dynamic Bayesian networks." *Journal of Operational Risk*, 4, 3-33.
- [30] Nivolianitou, Z., Amendola, A. y Reina, G. (1986). "Reliability analysis of chemical processes by the DYLAM approach". *Reliability Engineering*, 14, 163-182.
- [31] Pearl, J. (1988) *Probabilistic reasoning in intelligent systems: networks of plausible inference*, Morgan Kaufmann.
- [32] Pearl, J. (2000) *Causality: models, reasoning and inference*, Cambridge Univ Press.
- [33] Pellegrina, L. D. y Masciandaro, D. (2009) "The Risk-Based Approach in the New European Anti-Money Laundering Legislation: A Law and Economics View," *Review of Law and Economics* (5).
- [34] Pina, F. H. (1993). Los modelos causales aplicados al estudio de las variables de aprendizaje de una L2. *Revista española de lingüística aplicada*, (9), 69-83.
- [35] Sathye, M. (2008) "Estimating the cost of compliance of AMLCTF for financial institutions in Australia," *Journal of Financial Crime*, (15), 347-363.
- [36] Siu, N. (1994). "Risk assessment for dynamic system: an overview". *Reliability Engineering and System Safety*, 43(1), 43-73.
- [37] Simon, H. A. (1954). "Spurious correlation: A causal interpretation". *Journal of the American statistical Association*, 49(267), 467-479.

- [38] Svetlozar T., J. Hsu, S. Biliiana and F. Fabossi (2008). Bayesian Methods in Finance, The Frank J. Fabozzi Series, Wiley Finance.
- [39] Tang, J. y Yin, J. (2005) “Developing an intelligent data discriminating system of anti-money laundering based on SVM,” in International Conference on Machine Learning and Cybernetics.
- [40] Wright, S. (1934). The method of path coefficients. The annals of mathematical statistics, 5(3), 161-215.
- [41] Yang, X. y Mannan, M.S. (2010). “The development and application of dynamic operational risk assessment in oil/gas and chemical process industry.” Reliability Engineering and System Safety, 95, 806-815.
- [42] Xuan Liu, P. Z. y Zeng, D. (2008) “Suspicious activity reporting using dynamic bayesian networks,” in Intelligence and Security Informatics.
- [43] Yet, B., Bastani, K., Raharjo, H., Lifvergren, S., Marsh, W. y Bergman, B. (2013). “Decision support system for Warfarin therapy management using Bayesian networks.” Decision Support Systems, 55, 488-498.
- [44] Yet, B., Perkins, Z., Fenton, N., Tai, N. & Marsh, W. (2014a) “Not just data: a method for improving prediction with knowledge.” Journal of Biomedical Informatics, 48, 28-37.
- [45] Yet, B., Perkins, Z., Rasmussen, T., Tai, N. y Marsh, W. (2014b) “Combining data and meta-analysis to build Bayesian networks for clinical decision support.” Journal of Biomedical Informatics.
- [46] Zellner, A. (1971). An Introduction to Bayesian Inference in Econometrics, New York: Wiley.



Teresa de Jesús Pineda Hernández.
MBA, BS. En Economía.
Analista Financiero.
Encargada de negociación y presupuesto de reserva territorial para proyectos Federales dentro de la Secretaria Obras Públicas Desarrollo Urbano y Vivienda del Estado de Tlaxcala, México.
Responsable de Tesorería en Construcciones PROSA S.A de C.V. Actualmente profesora en la UAEH México.



Tomás Gómez Rodríguez.
PhD en Ciencias Económicas,
Profesor Investigador en la UAEH México.



Adriana Zambrano Reyes.
PhD en Ciencias Económicas,
Coordinadora de la Licenciatura en ingeniería económica y financiera en la UAEH México

BIOGRAFÍA



Jose Francisco Martínez Sánchez.
PhD en Ciencias, Master en Investigación de Operaciones, BS. Matemáticas.
Trabajó para Casa de Bolsa Finamex, Wall Street International Consulting, empresa dedicada a inversiones en mercado FOREX, realizando análisis técnico y fundamental. Durante 10 años laboró para el sector gobierno en áreas de

tecnologías de información y procesos de control de calidad. Durante los cuales desarrolló metodologías para evaluación de proyectos, control de calidad y medición de riesgo tecnológico. Con aproximadamente 15 años de experiencia profesional incursionó en la consultoría de empresas públicas y privadas. Actualmente Investigador en la UAEH México.