

Modelo de clasificación para la adopción de medios digitales en la Banca de Inversión

Jessica Guadalupe Vega Ledesma, Cristina Hernández Márquez,
Alma Chávez Arrieta

Universidad Panamericana,
Facultad de Ingeniería,
México

{0011638, 0136183, 0234447}@up.edu.mx

Resumen. El presente estudio analiza la digitalización del área de Servicio al Cliente de un Banco de Inversión que desea aprovechar medios electrónicos desarrollados (Banca en Línea, Casa de Bolsa Digital o un asistente virtual) para mejorar la atención a sus clientes, reduciendo el número de llamadas al área de Servicio al Cliente y por tanto el costo asociado. Se utilizará aprendizaje supervisado aplicado al registro de llamadas realizadas al área de Servicio a Clientes en donde se podrá obtener la relación directa con la variable que controla la suscripción a la Banca en Línea o Casa de Bolsa Digital. El modelo resultante se utilizará para evaluar el total de llamadas recibidas por el área de Servicio a Cliente logrando predecir si el cliente con base en su perfil es un buen candidato para ser inducido a la utilización de medios electrónicos automatizados o bien, dirigirlo a la atención de un ejecutivo del área de Servicio al Cliente. Se balancearon las muestras y se utilizaron cinco modelos para evaluar donde el Clasificador de Árboles Aleatorios resultó con mejor precisión.

Palabras clave: Adopción de medios digitales, árboles aleatorios, servicios digitales financieros, aprendizaje supervisado.

Classification Model for Digital Media in an Investment Bank

Abstract. The following research analyzes the digitalization of the Customer Service of an Investment Bank that aims to take advantage of mobile devices (Online Banking, Digital Stock Exchange or a virtual assistant) to improve customer service, reducing the number of calls and therefore the associated cost. Supervised learning will be used through the logging of received calls at Customer Service; in where we can obtain the relationship between the variable that controls the subscription to digital banking and the customer's profile. The resulting model will be used to evaluate the total number of calls received in the Call Center, predicting whether the client, based on his profile, is a good candidate to be induced to use automated sources or to direct them to the attention of an executive in the Customer Service area. The samples were balanced, and

five models were used to assess where the Random Tree Classifier was with the best precision.

Keywords: Adoption of digital media, tree conditional random fields, digital financial services, supervised machine learning methods.

1. Introducción

Actualmente uno de los más grandes retos de Sistema Financiero es aprovechar todos los medios electrónicos, la digitalización está cambiando el modo en que los clientes se relacionan con sus servicios y toman control de sus cuentas de inversión. Los grandes bancos alrededor del mundo utilizan modelos de ciencia de datos para el perfilamiento de sus clientes y selección de servicios de atención, mejorando la experiencia del cliente, logrando disminuir costos y bancarizando al mayor número de personas posibles obteniendo a su vez datos del comportamiento de sus clientes para ofrecer productos y servicios personalizados como lo demuestra Arguedas [1] y Cabrera [2].

En este trabajo se presenta un modelo clasificador para la digitalización bancaria que va directamente ligado al desarrollo de la telefonía celular, es decir no basta con que la telefonía sea móvil si no con accesos a internet; siendo ésta su única limitante como lo demuestra el estudio realizado en sus inicios Prior [3] para países en vías de desarrollo como lo son los africanos, en donde su penetración es más difícil.

En este trabajo se presenta un modelo clasificador basado en el algoritmo de Bosque Aleatorio, el cual se pretende implementar como filtro inicial en la recepción de llamadas del área de Servicio al Cliente cuyo objetivo principal sea determinar desde el inicio de la llamada el poder remitir al cliente al uso del servicio digital o de lo contrario al ejecutivo de servicio. Con esta medida, el Banco de Inversión generará un ahorro en número de llamadas personalizadas de al menos un 15% en un periodo de un año y, por otro lado, se atenderá de manera más eficiente al segmento de clientes de nuevas generaciones que prefieren un servicio más rápido y estandarizado.

El análisis siguió un flujo de trabajo estándar: recolección de datos, preprocesamiento de datos, selección de características, selección y evaluación de modelos y evaluación y presentación de resultados.

La organización del presente documento se divide en cuatro secciones. En la sección 2 presenta trabajo relacionados a la adopción de medios digitales, el análisis comparativo de métodos supervisados se propone en la sección 3, así como también se describe la metodología utilizada y descripción del conjunto de datos. En la sección 4 se comparan los resultados de cada método de aprendizaje comparado y finalmente en la sección 5 se resumen las conclusiones del ejercicio y recomendaciones al negocio.

2. Trabajos relacionados

El Sistema Financiero alrededor del mundo es particularmente sensible a la transformación digital, al tratamiento de los datos personales, a desarrollar nuevos canales y personalizar los servicios para inducir a los clientes a la bancarización digital; estudios alrededor del mundo han presentado que el uso de Inteligencia Artificial ha

mejorado sustancialmente dicha adopción como lo presenta Tater [4], en donde los principales factores en India fueron la comodidad, protección, seguridad, accesibilidad y un registro exacto de las transacciones. De igual manera se presentaron factores estadísticos como edad, sexo, sueldo y capacidad de ahorro que lograban que la innovación bancaria fuera recibida de una manera positiva en los clientes.

Según la interpretación de Angelov [5] acerca del informe de Deutsche Bank (2015), la digitalización del sector financiero es una tendencia que está siendo impulsada especialmente por tres motores: la experiencia del consumidor, el empuje tecnológico y los beneficios económicos.

Los Bancos de Inversión siguen esta misma tendencia, buscan desarrollar medios digitales especializados como bancas en línea personalizadas, casas de bolsa digitales y aplicaciones de fácil adopción ya que los clientes de este perfil con cierta resistencia a la atención tradicional, por pertenecer a un nivel social medio y medio-alto en el que han sido atendidos de manera persona a persona, adicional a que el rango de edad normal es conocido por tener mayor resistencia a la adopción de sistemas automatizados.

Segmentar a los clientes de acuerdo con sus elecciones anteriores es uno de los primeros pasos que han seguido la mayoría de las propuestas de este tipo de análisis. En el trabajo de Ladyzynski [6], los sistemas de recomendación o filtrado son utilizados cada vez más en el sector bancario: se aplican en la generación de calificación bancaria, análisis de riesgos, perfilamiento del cliente, predicción de tipos cambiarios y detección de fraudes.

Sin duda, la cuestión que nos hacemos en este trabajo ha sido analizada años atrás por instituciones financieras como lo estudia Moro [7] en donde el estudio se ha dirigido a la predicción del éxito del marketing de productos bancarios con base en las llamadas recibidas (o de salida) del área de Servicio al cliente pues la centralización de las interacciones con los clientes facilita la gestión de la información y permite enfocarse en maximizar el valor de la vida del cliente. En el trabajo de Moro han sido considerados varios clasificadores como regresión logística clásica, árboles de decisión y redes neuronales. Una de las contribuciones del trabajo de Moro, es haber comprobado que una de las grandes ventajas de los árboles de decisión es que son modelos de fácil entendimiento y que proporcionan buenas predicciones en las tareas de clasificación.

En 2019, Ambulamar [8] inicia con el establecimiento de las principales características de los clientes, aquellas que proporcionan información valiosa sobre los hábitos de vida de los clientes y sus preferencias, permitiendo definir la orientación de productos a clientes realmente interesados.

Adicionalmente es necesario realizar un esfuerzo mayor para lograr adaptar sistemas como asistentes virtuales para aquellos clientes cuya necesidad aún no es cubierta por herramientas automatizadas (Banca en línea) y que logren una adopción de una manera más natural, pues como dice Angelov [9], a raíz de la creciente complejidad tecnológica, los bancos necesitan de la ayuda de colaboradores externos y entran en juego los nuevos agentes con tecnologías que permiten reducir costes y automatizar procesos, de este modo la bancarización digital los clientes podrán mejorar su experiencia y al mismo tiempo reducir costos operativos a la institución de acuerdo con Raja [10].

La atención al cliente automatizada es una funcionalidad que puede brindar beneficios tangibles tanto al cliente por su disponibilidad 24 horas, aumento de la capacidad de atención de llamadas sin aumentar la plantilla de ejecutivos en el área de servicio a clientes, eliminación de tiempos de espera y disminución de porcentajes de abandono. Y de manera muy importante, hay que mencionar que la adopción de procesos automatizados disminuye considerablemente el riesgo de fraude como lo analiza Kartman [11].

En el trabajo de Medvedev [12] donde se referencia un caso de estudio de clasificación para identificar clientes que serán más receptivos en una campaña de telemarketing utilizando un perfilamiento previo de los clientes y aplicando el método de aprendizaje de máquina de árboles de decisión para una mejor penetración en su campaña.

En síntesis, la incorporación de tecnologías de avanzada en la producción, la velocidad de los cambios y la convergencia y combinación de múltiples tecnologías de avanzada está permitiendo la transformación digital produciendo eficiencias operativas (reducción de costos), mejora de productividad y nuevas oportunidades y modelos de negocio. Entre las tecnologías que comprenden la cuarta revolución industrial o la tercera ola se puede identificar: Análisis de Grandes Bases de Datos, Internet de las Cosas, Robótica e Impresión 3D e Inteligencia Artificial y el aprendizaje automático como estandarte de esta última que aporta un componente crítico que es la predicción según Agrawal [13], que constituye un valor fundamental en la toma de decisiones. Estas máquinas que predicen son tan valiosas porque pueden realizar mejores predicciones, más rápidas y más baratas que las que realizan los humanos como menciona Brynjolfsson [14]. La inteligencia artificial ofrece, por un lado, decisiones, es decir, conclusiones alcanzadas a partir de la deliberación algorítmica basada en los datos disponibles y por otro, soluciones, es decir cursos alternativos de acción para resolver un problema como dimensiona Von Krogh [15]. Las empresas generan una enorme cantidad de datos que, gracias a estos nuevos sistemas computacionales y algoritmos avanzados, pueden ser procesados y analizados minimizando el esfuerzo humano. Esto permite descentralizar la toma de decisiones, y como se menciona lo menciona Nocetti [16] pasar de modelos preventivos a modelos predictivos que pueden aplicarse en todas las áreas de la organización como lo demuestra Basco [17]. La inteligencia Artificial es el único campo que persigue la construcción de máquinas que funcionen automáticamente en medios complejos y cambiantes analizado por Russell [17]. Este campo no sólo intenta comprender, sino que también se esfuerza en construir entidades inteligentes.

3. Clasificación de clientes basado en aprendizaje supervisado

3.1. Descripción general

Se desea encontrar el modelo que permita la clasificación automática de clientes de acuerdo con sus características básicas. Este modelo se implementará en el receptor de llamadas de atención al cliente: los clientes clasificados con mayor posibilidad de estar registrados en banca electrónica serán motivados a utilizar la Banca digital mediante un mensaje de voz y de aceptar dicha invitación posteriormente podrán ser atendidos



Fig. 1. Flujo de trabajo para el perfilamiento de clientes y aplicación de métodos de aprendizaje automático.

por un agente automático. En la fase de creación de modelos se seleccionaron varios modelos de aprendizaje con el fin de encontrar el que mejor precisión de predicción resulte para el caso de estudio. Se decidió utilizar la característica que nos indica si el cliente está enrolado en Banca electrónica. Esta nos servirá como etiqueta clasificadora, ya que se considera por el negocio, que una persona que ya tiene posibilidades de entrar a su banca electrónica busca la velocidad de la atención sobre el contacto personal y por lo tanto recibirá el autoservicio como una funcionalidad deseable.

En seguida se describen la metodología y materiales utilizados para seleccionar un método de aprendizaje de máquina para clasificar en dos categorías a los clientes que realizan llamadas al área de Servicio al Cliente. El flujo para la evaluación del modelo se visualiza se realizó de acuerdo con la Fig. 1.

1. **Recolección de datos.** Del conjunto total de llamadas recibidas durante un trimestre en el área de Servicio a clientes se escogieron como las variables de estudio las características particulares del cliente dejando a un lado el registro, propios de la llamada como horario, duración, etc.
2. **Perfilamiento del cliente.** El conjunto de datos obtenido nos provee de una serie de características de los clientes que han realizado llamadas. Dentro de este conjunto de características, existe una que nos servirá como etiqueta clasificadora, es aquella que define si el cliente se encuentra enrolado en alguna de las plataformas digitales actualmente. Esta característica toma un valor 0 cuando no se encuentra enrolado en la banca en línea, o 1 cuando ya se encuentra enrolado. Ya que contamos con esta característica etiqueta, nuestro conjunto podrá ajustarse a un modelo de aprendizaje supervisado.
3. **Pre procesamiento.** Se requirió una limpieza de datos básica que consiste en evitar datos vacíos intercambiándose con el promedio de la población, esta acción se realizó para evitar sesgar los datos. De esta manera, para la característica "Tipo de Persona (Física/ Moral)" se encontraba vacía, se modificó como Persona Física. De la misma manera analizando la variable saldo contrato (dato representativo que muestra la cantidad a favor invertida en la cuenta de donde el cliente realizó la consulta u operación en Servicio a Clientes) y su correlación con la variable saldo cliente (dato representativo que muestra la suma de las cantidad a favor invertidas en todas y cada una de las cuentas del cliente que llamó a Servicio a Clientes) encontramos prácticamente es directa 1 a 1 ; es decir que los clientes seleccionados tienen solo una cuenta registrada en el banco al ser saldo contrato=saldo cliente.

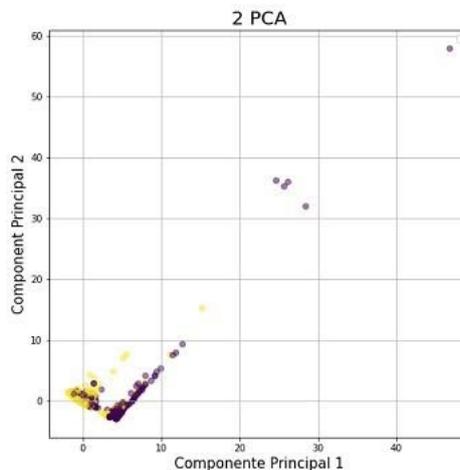


Fig. 2. Aplicación de PCA a las características.

Por lo que se toma la decisión de descartar una de ella sin que haya afectación en los resultados. Por último, usabilidad de internet

4. **Extracción y selección de características.** Se tienen ocho diferentes características a modelar que aportan valor al perfil del cliente e indispensables para el presente trabajo como son: la unidad de negocio es decir si el cliente pertenece al Banco o a la Casa de Bolsa en donde la experiencia nos ha demostrado que los clientes de casa de bolsa cuentan con saldos mayores y mayor resistencia a la adopción digital; la variable Centro Financiero nos otorgará la ubicación geográfica del cliente. Saldo cliente y Tipo de persona previamente explicado; el género (femenino /masculino) que de acuerdo con la Asociación de Internet Mx de su edición 2019 expone que el 66% de los usuarios de internet que usan servicios financieros son hombres usando este parámetro de referencia; edad y por último el estatus de suscripción a la Banca móvil o a la casa de bolsa digital. El análisis de componentes Principales PCA con 90% como varianza total deseada, nos ayudará a mejorar la aproximación de los modelos, así como a lograr visualizar las ocho dimensiones en un plano bidimensional como se muestra en la Fig. 2.
5. **Creación de modelos.** Se tiene la noción básica que el aprendizaje supervisado tendrá mejores resultados en nuestro caso de estudio, sin embargo, se seleccionan cinco diferentes modelos de aprendizaje, uno de ellos no supervisado y el resto supervisado: K-Medias, Árboles de decisión aleatorios, Máquinas de Soporte Vectorial, Clasificador Naive Bayes, Regresión Logística.
6. **Evaluación de modelos.** Para evaluar los modelos seleccionados, se utilizará la ecuación Error (1), donde N es el número de ejemplos en el conjunto de datos, y_i es el valor real y $f(x_i)$ es la estimación de la entrada x_i en el modelo f . Como auxiliar de decisión se utilizará la matriz de confusión, para revelar la distribución de los errores y ubicar el mejor método a aplicar en el centro de atención telefónica:

$$E = \frac{1}{N} \sum_{i=1}^N \|y_i - f(x_i)\|^2 \quad (1)$$

3.2. Conjunto de datos utilizado

El conjunto de datos utilizado describe las características de los clientes que han realizado llamadas al área de Servicio a Clientes de un Banco de Inversión durante un trimestre. Contiene 8,158 registros telefónicos correspondientes al perfil del cliente, así como de las características de la llamada como lo era el horario, duración, tipo de llamada, etc; siendo estas últimas variables eliminadas por no aportar información relevante para el presente estudio.

Las variables a considerar son las siguientes:

- Unidad Negocio. Fuente del contrato principal del cliente: (Banco/ Casa de Bolsa).
- Centro Financiero. Es la sucursal en la que la cuenta del cliente está adscrita, se refiere a la localización geográfica. Existen 20 diferentes posibles centros financieros repartidos en México.
- Saldo Cliente. Suma del saldo del total de cuentas del cliente.
- Tipo de Persona. Física o Moral.
- Género. Masculino o Femenino.
- Edad del Cliente.
- Usa Internet. Se refiere al porcentaje de penetración de uso de internet en compras por internet en la entidad federativa de la sucursal donde se encuentra el contrato del cliente.
- Status BE: Etiqueta que indica si el cliente está registrado en banca electrónica o no, puede tomar valores (0,1).
- Se utilizará la característica 'Status BE', como etiqueta predefinida, para lograr aplicar métodos de aprendizaje supervisado, ya que el negocio considera que los clientes que actualmente cuentan con acceso a la Banca en línea son clientes que buscan atención rápida y precisa y que por lo tanto tendrán mayor éxito de satisfacción en un medio automatizado.

3.3. Métodos de aprendizaje

Los métodos de aprendizaje máquina utilizados en este trabajo son los siguientes. Para entrenarlos se toma del conjunto total de datos, un 70% para entrenamiento, dejando un 30% para validación del modelo.

1. **K-medias** Para aplicar el modelo de K-Medias, ya que se requieren dos categorías a clasificar, se definen dos centroides. Comparando con la etiqueta predictora 'Status BE', es lograda una precisión de únicamente un 0.2904411. Ejemplo Fig 3.
2. **Árboles de decisión aleatoria** son algoritmos de aprendizaje supervisado tanto para clasificación como para regresión. Se basa en árboles, se dice que entre más árboles tenga, más robusto será el resultado. Como parámetros se

Tabla 1. Precisión obtenida en cada modelo.

Modelo	Precisión Obtenida	Análisis
KMeans	0.2904411	Precisión más baja
Árbol de Decisión	0.866013	Mejor Precisión
Soporte Vectorial	0.822712	
Naive Bayes	0.705065	
Regresión Logística	0.763071	

utilizan 8 estimadores y una profundidad máxima de 8, se definen dos categorías de acuerdo al modelo de negocio a implementar. Con esta modelo se logra una precisión del 0.866013.

3. **Máquina de soporte vectorial** Este clasificador separa puntos usando hiperplanos con el mejor margen posible. Se conocen como un clasificador discriminativo. Se aplicó un kernel de tipo rbf, con 16 grados como parámetros de generación de modelo. Se logra una precisión del 0.822712.
4. **Clasificador Naive Bayes** Este clasificador estadístico está basado en el Teorema de Bayes. Es uno de los más simples algoritmos de aprendizaje supervisado. Se recomienda en segmentos de datos muy grandes. Al aplicarse al conjunto de datos de negocio, logramos obtener únicamente una precisión del 0.705065.
5. **Regresión logística** es uno de los más simples y comúnmente usado para clasificar entre dos clases. Es fácil de implementar y puede ser usado como clasificador binario. Describe y estima la relación entre una variable binaria dependiente y una variable independiente. Por lo que nuestros datos pueden ajustarse bastante bien a este algoritmo. Al tomar un máximo de 500 iteraciones, utilizando la misma proporción 70-30 clásica, se logra una precisión del 0.763071.

4. Resultados y discusión

De los cinco modelos aplicados se obtuvieron las siguientes precisiones habiendo encontrado el modelo de árboles de decisión aleatoria con mayor precisión. Lo elegimos ganador y procedemos a afinar los parámetros estimadores, cuyo principal parámetro es el número de árboles en el bosque a definir. Para tener una mejor aproximación, se realiza un barrido de 40 interacciones.

A continuación, se presentan los resultados de acuerdo con la Tabla 1.

De acuerdo Fig. 2 podemos visualizar que el mejor resultado se obtiene cuando se utilizan 69 árboles y una profundidad máxima de 8 finalmente logrando una precisión de 87.6225%. Después de dichos 69 estimadores, la precisión no incrementa, únicamente varía y se mantiene cercana a la misma precisión.

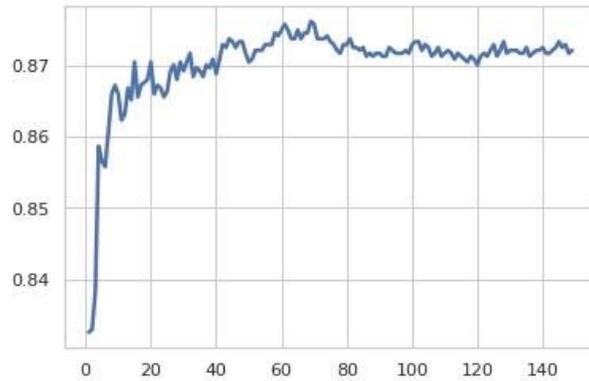


Fig. 2. Relación n estimadores - precisión resultante.

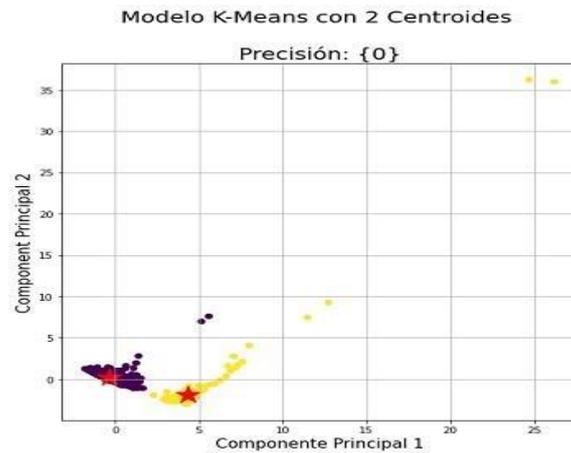


Fig. 3. Modelo K-Medias.

Tabla 2. Predicción de porcentaje de redireccionamiento de llamadas.

Etiqueta	Número de casos	Porcentaje
A Redireccionar	1425	91%
Atención Personal	141	9%

La discusión siguiente, es definir si la precisión resultante es suficiente para el modelo de negocio analizado ya que se requiere obtener al menos un 15% de las llamadas se direccionen a la atención automática de Banca en línea. Teniendo esta precisión, podemos obtener un 91% de direccionamiento de Banca en Línea, con un 87.62% de precisión con lo cual se da por válido el modelo para el negocio y se procederá a su implementación productiva. Tabla 2.



Fig. 3. Matriz de confusión resultado del método de Árbol de decisión.

Adicionalmente al modelo, se recomendará al negocio repetir el ejercicio después de un trimestre de ejecución para revalidar los resultados y reevaluar las características de entrada.

Por último, se obtuvo la matriz de confusión en donde se puede observar que existen 720 verdaderos positivos y 1425 falsos negativos siendo estas cifras las más altas de nuestra matriz apoyando a los resultados generados por el modelo.

5. Conclusiones

El aprendizaje supervisado a través del modelo de árboles de decisión es muy útil en el caso de la clasificación de datos cuando se tiene una característica que funcione como etiqueta clasificadora.

Se propone una aproximación distinta para nuestro caso de estudio, obteniendo una relación adecuada a la población mexicana, utilizando diferentes fuentes de datos que den características con mayor valor a cada cliente, por ejemplo, explorar la calificación dada a la experiencia anterior y no únicamente basado en el perfil del cliente.

Adicionalmente al modelo, se realizarán las siguientes recomendaciones al negocio en donde se deduce que la adopción de la tecnología puede estar relacionado con la edad de los clientes y posiblemente el monto de inversión. Los clientes pertenecen a la generación de los sesentas aproximadamente y será necesario acoplar tanto los scripts de ventas como las aplicaciones a las características propias de esta generación, por lo que creemos que la utilización de las herramientas de Banca en Línea o Casa de Bolsa Digital para operaciones sencillas puede ser adoptada con mayor facilidad.

Otro dato importante analizado fue la co-relación que obtuvimos entre saldo cliente y saldo contrato, lo que quiere decir que la mayoría de estos usuarios únicamente cuentan con un solo contrato, es decir son clientes que buscan simplificación y utilizan una sola cuenta para diversificar su dinero y no varias cuentas destinadas a fines distintos, lo que hace que la aplicación se entienda de mejor manera. El género del cliente que predomina es masculino, aunque no parece tener relevancia en el análisis realizado.

El presente análisis está basado en datos reales y en el reto que representa ahora para los bancos poder llegar a la digitalización de los servicios.

Referencias

1. Arguedas-Sanz, R.: La Transformación Digital en el Sector Financiero. Universidad Nacional de Educación a Distancia, pp. 1–3 (2019)
2. Cabrera-Vergara, C.: Análisis de los principales factores que permitieron desarrollar una eficiente transformación digital en las principales empresas del sector banca múltiple peruano. Universidad Peruana de Ciencias Aplicadas (UPC) <https://repositorioacademico.upc.edu.pe/handle/10757/650437> (2019)
3. Prior, F.: La banca móvil como catalizadora de la bancarización de los pobres: modelos de negocio y desafíos regulatorios. (2008)
4. Tater, B., Tanwar, M., Murari, K.: Customer Adoption of Banking Technology in Private Banks of India. *International Journal of Banking and Finance*, 8(3) (2011)
5. Angelov, A.S.: El sistema financiero digital: los nuevos agentes. Universidad de Alcalá, http://www3.uah.es/iaes/publicaciones/DT_04_19.pdf (2019)
6. Ładyżyński, P., Żbikowski, K., Gawrysiak, P.: Direct marketing campaigns in retail banking with the use of deep learning and random forests. *Expert Systems with Applications*, 134, pp. 28–35 (2019)
7. Moro, S., C.P.R.P.: A data-driven approach to predict the success of bank telemarketing. <https://www.sciencedirect.com/science/article/pii/> (2014)
8. Anbumalar S., C.J.H.: A study on perception of customer towards digital banking present scenario. *Our Heritage* (2), pp. 47–54 (2020)
9. Angelov, A. S.: El sistema financiero digital: los nuevos agentes Universidad de Alcalá. http://www3.uah.es/iaes/publicaciones/DT_04_19.pdf (2019)
10. Raja, K.: Virtual banking Paramakudi, India: *Studies in Indian Place Names (UGC Care Journal)* (2020)
11. Squadex: The top 9 machine learning use cases in business. <https://squadex.com/insights/top-machine-learning-use-cases-business/amp/> (2019)
12. Towards Data Science: Machine learning classification with python for direct marketing. <https://towardsdatascience.com/machine-learning-classification-with-python-for-direct-marketing-2da27906ddac> (2019)
13. Agrawal, A., Gans, J., Goldfarb, A.: *Prediction machines: the simple economics of artificial intelligence*. Harvard Business Press (2018)
14. Brynjolfsson, E., McAfee, A.: *Machine, platform, crowd: Harnessing our digital future*. WW Norton & Company (2017)
15. Von-Krogh, G.: Artificial Intelligence in Organizations: New Opportunities for Phenomenon-Based Theorizing. *Academy of Management Discoveries*, 4(4), pp. 404–409 (2018)
16. Nocetti, N.: Promesas de la Inteligencia Artificial y el Aprendizaje Automático para la Banca Tradicional Privada. Un análisis de oportunidades, aplicaciones, barreras y riesgos. Universidad de San Andrés, pp. 63–69 (2019)
17. Basco, A., Beliz, G., Coatz, D., Garnero, P.: *Industria 4.0. Fabricando el Futuro*.
18. Russell, S., & Norvig, P. *Artificial intelligence: A modern approach*. Prentice Hall, Englewood cliffs, NJ (2018)

Jessica Guadalupe Vega Ledesma, Cristina Hernández Márquez, Alma Chávez Arrieta