

Tipo de artículo: Artículo original

Aplicación de sistema de recomendación en pasarela de pagos nacional

Application of recommendation system in national payment gateway

Lesdaniel Herrera Reyes ^{1*} , <https://orcid.org/0009-0006-9848-0314>

¹ Facultad de Informática. Universidad Tecnológica de La Habana “José Antonio Echeverría”. Cuba. Correo electrónico: lesdaniel.herrera@gmail.com

* Autor para correspondencia: lesdaniel.herrera@gmail.com

Resumen

El auge de los pagos electrónicos y su desarrollo a través de las pasarelas nacionales suponen un reto para la toma de decisiones encaminadas a potenciar los pagos de servicios. Esta rápida expansión ha provocado que cada vez más se recurra al uso de modelos de aprendizaje automático que permitan analizar las características de los clientes y potencie los servicios brindados. Una solución a ello responde a los sistemas de recomendaciones los cuales pueden ser de gran beneficio para aplicaciones como Transfermóvil. El presente artículo demuestra el uso de estos sistemas a través del algoritmo de factorización matricial y como puede emplearse en esta pasarela de pagos. Además, para aplicar su uso se acude a una herramienta AutoML que facilitan el uso del algoritmo.

Palabras clave: Sistemas de recomendación; aprendizaje automático; AutoML; factorización matricial; Transfermóvil

Abstract

The rise of electronic payments and their development through national gateways represent a challenge for decision-making aimed at promoting payments for services. This rapid expansion has led to increasing use of machine learning models that allow analyzing customer characteristics and enhancing the services provided. A solution to this responds to recommendation systems which can be of great benefit for applications such as Transfermóvil. This article demonstrates the use of these systems through the matrix factorization algorithm and how it can be used in this payment gateway. Furthermore, to apply its use, an AutoML tool is used that facilitates the use of the algorithm.

Keywords: recommendation systems; machine learning; AutoML; matrix factorization; Transfermóvil

Recibido: 16/08/2024

Aceptado: 21/10/2024

En línea: 01/11/2024



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

Introducción

El proceso de informatización de la sociedad cubana es una de las prioridades del gobierno para el desarrollo de la nación. Uno de los sectores fundamentales para su implementación es el comercio electrónico, apoyado por el auge del uso de internet en el país. Esto permite acceder de forma más fácil a bienes y servicios y que se realice de manera expedita a través de las pasarelas de pagos. Algunos de los beneficios proporcionados por los sistemas de pago en línea incluyen transacciones garantizadas, costos reducidos, aumento de la protección en la información confidencial y de pago a proveedores (Lowry et al. 2006).

Una pasarela de pagos es un sistema que representa un servicio intermediario entre una página de comercio electrónico y un banco cuando se ejecutan transacciones bancarias online (Fonseca et al. 2013). Se integran a la tienda virtual y almacenan información del banco que maneja las cuentas de compradores y vendedores. En el pago con tarjeta, la pasarela de pagos valida la veracidad de la tarjeta y organiza la transferencia del dinero de la cuenta del comprador a la cuenta del vendedor. Actualmente existe gran diversidad en todo el planeta en cuanto a pasarelas de pagos se refiere, cada una de ellas se diferencia entre sí por los requisitos que cumplen, el costo que cobran por transacciones, y los países con los cuales trabajan (Hassan et al. 2020).

Nuestro país también se ha adentrado en el desarrollo de estas herramientas financieras con el avance de las Tecnologías de la Información y las Comunicaciones. En los últimos años han surgido pasarelas que ofrecen servicios rápidos y sencillos como Enzona (Xetid 2019) y Transfermóvil (ETECSA 2016) que han permitido el auge del comercio electrónico en el país.

Transfermóvil es un proyecto que responde al proceso de informatización que se lleva a cabo en nuestra sociedad y en particular tiene como propósito fomentar el desarrollo del comercio electrónico en Cuba. Es una plataforma desarrollada completamente por ETECSA, cuya arquitectura es modular y escalable y que utiliza como vía de acceso por parte de los usuarios códigos USSD, lo que permite un acceso seguro a dicha plataforma y aumenta la trazabilidad (Trápaga et al. 2018).

En el año 2021 las operaciones realizadas por Transfermóvil representaron el 77.66% del total de operaciones electrónicas en Cuba como se muestra en la Tabla 1 (Trápaga 2022). Este elevado número de operaciones presentes en la pasarela constituye un reto e incentiva a la aplicación de nuevas metodologías para el análisis de datos que permita tanto atraer una mayor cantidad de cliente, así como de mantenerlo e incentivarlo con nuevos servicios y facilidades.



Tabla 1. Crecimiento de las operaciones más populares de Transfermóvil en 2021

Operaciones	2020	2021
Pago Factura de Electricidad	3.3 M	5.5 M
Pagos de la ONAT	120 K	400 K
Compras en Tiendas Virtuales	1.4 M	5 M
Pagos de servicios de telecomunicaciones	15 M	50 M
Transferencias	9 M	15 M
Operaciones totales	140 M	340 M

Fuente: (Trápaga 2022)

En la actualidad la aplicación posee una interfaz de inicio donde el cliente puede organizar los diferentes servicios disponibles como se muestra en la Figura 1. Esta ventana, por defecto, define una serie de accesos rápidos a servicios de la aplicación y a medida que el usuario interactúa con la plataforma puede decidir organizar los mismos basado en su interés.

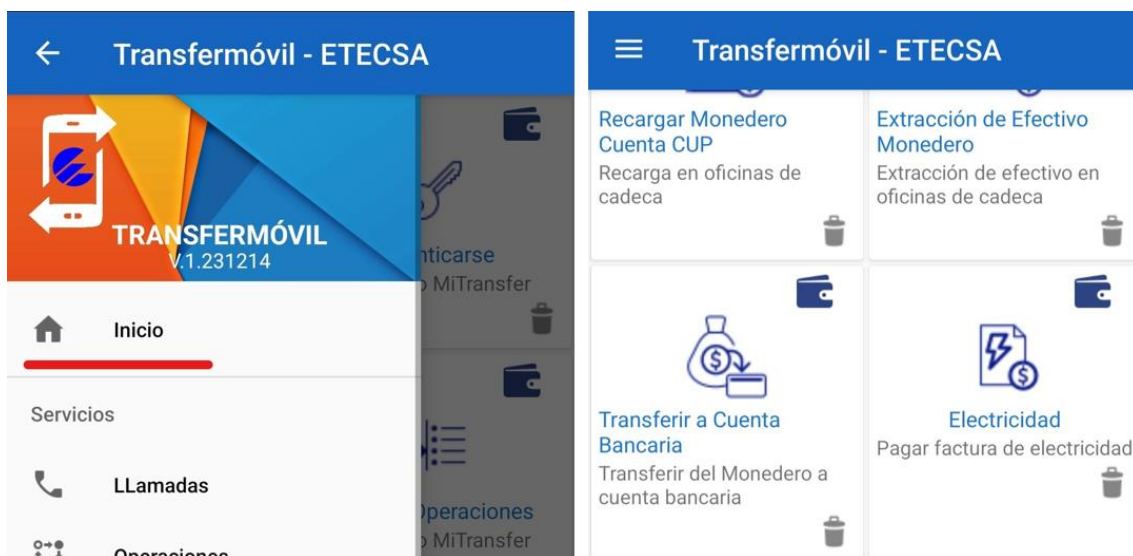


Figura 1. Ventana de inicio de ampliación Transfermóvil.

Con la ampliación de nuevos servicios en la aplicación los usuarios se ven necesitados de interactuar con esta ventana inicial ya que personaliza las necesidades de cada cliente. Por tanto, recomendar a los usuarios un contenido personalizado facilita la experiencia de los mismos, con la plataforma y agiliza la interacción con los servicios disponibles.



El sistema de recomendación es una de las aplicaciones más populares del sistema de aprendizaje automático. Es un sistema de filtrado de información que intenta predecir los intereses de los usuarios y recomendar productos que probablemente sean de su interés. Agiliza las búsquedas y permite a los usuarios acceder al contenido que les interesa de una forma más fácil y rápida. Desde el punto de vista del usuario, le ayuda a obtener recomendaciones más personalizadas y, desde el punto de vista de la empresa, le ayuda a mejorar la participación del cliente en el sitio web y mejora los ingresos por marketing, aumentando así las ganancias (More and Kohle 2022) .

Existen tres tipos principales de sistemas de recomendación: filtrado basado en contenido, filtrado colaborativo y filtrado híbrido.

- **Filtrado basado en contenido:** El objetivo del filtrado basado en contenido es clasificar productos con palabras clave específicas, saber qué le gusta al cliente, buscar esos términos en los datos y luego hacer recomendaciones similares. Filtra un elemento similar según los atributos del elemento (Badriyah et al. 2018; Reddy et al. 2019).
- **Filtrado colaborativo:** En el filtrado colaborativo, se dan recomendaciones basadas en otros usuarios que tienen preferencias similares a las del usuario actual. Se basa en recopilar y analizar datos sobre el comportamiento de los usuarios (Herlocker et al. 2000; Sarwar et al. 2001).
- **Filtrado híbrido:** La técnica de recomendación híbrida es una combinación de filtrado colaborativo y basado en contenido. Proporciona mejores recomendaciones en comparación con el uso de una única técnica de recomendación. La combinación de múltiples técnicas de recomendación ayuda a superar las limitaciones del uso de una técnica en particular (Geetha et al. 2018).

Teniendo en cuenta que la mayoría de los usuarios realizan tareas básicas como pagos de servicios de ETECSA o transferencias bancarias y en menor medida interactúan con otros servicios. El desafío es predecir estas entradas faltantes, de tal manera que se pueda clasificar la frecuencia de su uso sin haber interactuado con el mismo. Para ellos el uso de factorización matricial juega un papel clave.

La factorización matricial es una técnica de filtrado colaborativo que identifica las relaciones entre elementos y entidades de los usuarios. Ayuda a descubrir las características latentes al encontrar la interacción subyacente entre los usuarios y los elementos. Por ejemplo, en un sistema de recomendación de películas, hay un grupo de usuarios y un conjunto de elementos. Dado que cada usuario ha calificado algunas películas, nos gustaría predecir la calificación que un usuario podría darle a un elemento que aún no ha sido calificado. Según las calificaciones predichas por la factorización matricial, se dan recomendaciones al usuario (Chen and Wang 2022; Koren et al. 2009).



En este trabajo se propone el uso de un sistema de recomendación basado en factorización matricial enfocado a la ventana de inicio de la pasarela de pagos Transfermóvil. También se presenta una herramienta de aprendizaje automático que permite demostrar los beneficios de esta técnica con el objetivo facilitar la experiencia de usuario con la pasarela de pagos.

Materiales y métodos

El aprendizaje automático, es un subcampo de las ciencias de la computación y una rama de la inteligencia artificial, cuyo principal objetivo es desarrollar técnicas que permitan que las computadoras aprendan. Para llevar a cabo este propósito se utilizan algoritmos avanzados que permitan descubrir patrones o tendencias en el conjunto de datos, para luego pulirlos y generar conocimiento que permitan tomar decisiones, con poca intervención humana. Esto quiere decir, que las máquinas tengan la capacidad de aprender y tomar decisiones para las que fueron entrenadas, sin requerir mayor interacción humana o programación previa (Zhou 2021).

Entre las herramientas de código abierto que permiten implementar aprendizaje automático destacan las desarrolladas bajo Java y Python respectivamente. Sin embargo, no son las únicas, en los últimos años han surgido soluciones como ML.NET (Microsoft 2002) que ofrece la posibilidad de insertar aprendizaje automático y AutoML a soluciones en .NET. Además, presenta un alto rendimiento y precisión con respecto a otras alternativas en el mercado como se muestra la Figura 2, donde se expone una mayor precisión y un menor tiempo de ejecución para ML.NET.




Figura 2. Comparación de ML.NET con otras bibliotecas de aprendizaje automático.

El uso de este generador de modelos permite facilitar el ciclo de vida del proyecto de aprendizaje automático basado en la metodología CRIP-DM, por sus siglas en inglés (Truong et al. 2019). Este generador infiere y automatiza el proceso como se ilustra en Figura 3 a través de AutoML, permitiendo el uso de la herramienta a todos aquellos que no posean gran experiencia en el uso del aprendizaje automático.



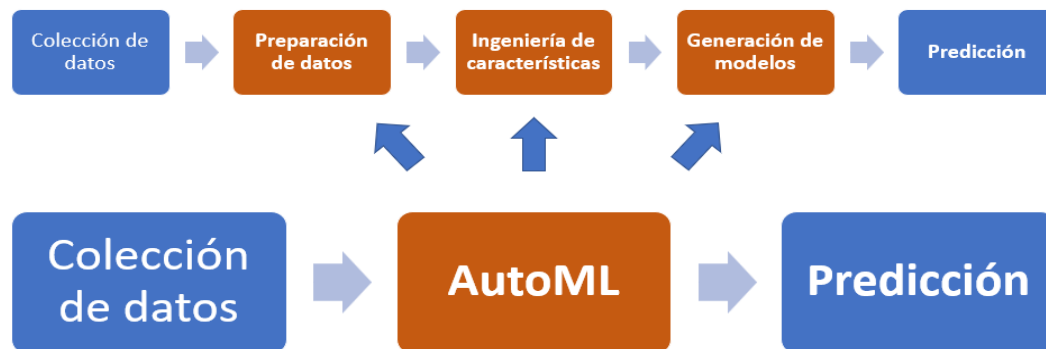


Figura 3. Flujo de generador de modelo ML.NET.

Entre las tareas que brinda ML.NET se expone la recomendación basada en algoritmos de factorización matricial. Este permite experimentar con recomendaciones de productos basado en clasificaciones o interacciones, lo que permite elaborar un experimento que satisfaga la solución al problema presentado en Transfermóvil.

Este experimento tiene un enfoque de filtrado colaborativo que opera bajo el supuesto subyacente que, si una persona A tienen la misma opinión que una persona B sobre un tema, es más probable que A tenga el mismo interés que B sobre un servicio diferente que la de una persona elegida al azar.

Para modelar el sistema de recomendación se concibió un escenario donde se manejasen un identificar del cliente, los servicios disponibles y la cantidad de veces que hace uso del mismo como se muestra en la Tabla 2. Estas variables permitirán estimar los servicios recomendado basado en la puntuación obtenida por el algoritmo y teniendo en cuenta que a mayor puntuación es más recomendable un servicio.

Tabla 2. Variables necesarias en experimento de factorización matricial.

Variables	Categoría	Tipo	Observación
Usuario	Identificador	Numérico	Identificador del usuario
Servicio	Elemento	Numérico	Producto o servicio que consume el usuario
Cantidad	Calificador	Numérico	Puntuación, calificador o valor que evalúa al servicio

El experimento inicialmente carga los datos de un archivo de texto en formato CSV, sobre el cual se entrena el algoritmo tomando el 80% de los datos y el resto de los mismos, se toma con caracteres evaluativo. Se modela la matriz factorial con los datos correspondientes al identificador y el elemento, tomado como referencia el calificador como se muestra en la Figura 4.



```
// Configuración de la factorización
var matrixFactory = (MLContext ctx, MatrixFactorizationOption param) =>
{
    var matrixOption = new MatrixFactorizationTrainer.Options();
    matrixOption.MatrixColumnIndexColumnName = nameof(ProductEntry.CustomerID) + "Encoded";
    matrixOption.MatrixRowIndexColumnName = nameof(ProductEntry.ProductCategoryID) + "Encoded";
    matrixOption.LabelColumnName = nameof(ProductEntry.Quantity);
    matrixOption.LossFunction = MatrixFactorizationTrainer.LossFunctionType.SquareLossRegression;
    matrixOption.NumberOfIterations = 20;
    matrixOption.ApproximationRank = 100;

    return estimator.Append(ctx.Recommendation().Trainers.MatrixFactorization(matrixOption));
};
```

Figura 4. Generación de modelo de aprendizaje automático en Visual Studio.

Resultados y discusión

El modelo fue ejecutado en un ordenador con un procesador I9 10900F a 2.8Ghz, acompañado de 32GB de memoria RAM. Como no se cuenta con acceso público a los datos de la plataforma Transfermóvil simularemos el comportamiento de estos datos, para ello este estudio consta de 250000 registros sin valores nulos y fue tomado del repositorio Kaggle en un archivo de 20 MB. Originalmente provienen un conjunto de datos sintético utilizando la biblioteca Faker Python. Simula un entorno integral de comercio electrónico, capturando varios aspectos del comportamiento del cliente y el historial de compras dentro de un mercado digital (Jagtap 2023). La Tabla 3 muestra la relación de los datos de simulación y los datos que debería manejar la plataforma Transfermóvil para aplicar este experimento.

Tabla 2. Simulación de datos para experimento

Nombre de variables en BD de simulación	Variabes para Transfermóvil
CustomerID	Número de teléfono
ProductCategoryID	Servicios de la pasarela
Quantity	Cantidad de veces usado el servicio

Para ejecutar el experimento fue necesario agrupar la cantidad de productos por consumidor y categoría ya que esta estaba sujeta a la variable de la fecha que no será valorada en el experimento, lo que disminuyó la cantidad de registros a 142623. Luego de ello el experimento se configuró para que tuviese una duración de 30 minutos usando la herramienta AutoML, el cual ejecuta el entrenamiento y evaluación basado en el algoritmo de matriz factorial. La Figura 2 muestra una de la iteración de la misma en el periodo configurado.



En este resultado, hay 20 iteraciones. En cada iteración, la medida del error disminuye y converge cada vez más cerca de 0. La desviación cuadrática media (RMS o RMSE, por sus siglas en inglés) se utiliza para medir las diferencias entre los valores predichos del modelo y los valores observados del conjunto de datos de prueba. Técnicamente es la raíz cuadrada del promedio de los cuadrados de los errores. Cuanto más bajo sea, mejor será el modelo.

iter	tr_rmse	obj
0	0.4835	5.6114e+04
1	0.3914	4.2559e+04
2	0.3680	3.9393e+04
3	0.3538	3.7388e+04
4	0.3457	3.6599e+04
5	0.3416	3.6070e+04
6	0.3395	3.5703e+04
7	0.3379	3.5682e+04
8	0.3370	3.5599e+04
9	0.3323	3.4937e+04
10	0.3313	3.4825e+04
11	0.3320	3.4969e+04
12	0.3321	3.4887e+04
13	0.3313	3.4932e+04
14	0.3304	3.4654e+04
15	0.3309	3.4900e+04
16	0.3295	3.4734e+04
17	0.3289	3.4540e+04
18	0.3303	3.4711e+04
19	0.3305	3.4820e+04

Root Mean Squared Error : 0,4001163188010089

Figura 2. Iteración de experimento AutoML con matriz factorial.

La Figura 3 expone el resultado del mejor modelo de matriz factorial entrenado basado en el RMSE para el conjunto de datos proporcionados. Además, se detallan otros criterios relevantes como el uso de los recursos consumidos y el tiempo de ejecución del modelo seleccionado.

```
Trial 53 finished training in 1128ms with pipeline ReplaceMissingValues=>OneHotHashEncoding=>Concatenate=>Unknown
===== Init best prediction =====
Peak Memory in MegaByte CPU : 83,35546875
Duration in milliseconds : 1806
Model : Matrix Factorization
Metric RMSE : 0,40054096446286397
===== End best prediction =====
===== Making a prediction =====
El servicio 1 y usuario 21703 es recomendado con una puntuación 0,20479
El servicio 2 y usuario 21703 es recomendado con una puntuación 0,20465
El servicio 3 y usuario 21703 es recomendado con una puntuación 0,20816
El servicio 4 y usuario 21703 es recomendado con una puntuación 0,2071
```

Figura 3. Resultado de mejor entrenamiento y prueba de resultado



Además, se muestra la prueba del resultado para el usuario 21703, para cada uno de los servicios disponible en los datos. La puntuación del servicio 3 al ser la más elevada corresponde al servicio más recomendado, mientras que el servicio 2 el menos recomendado.

La puntuación puede contribuir a organizar el orden en que se muestra en la aplicación los múltiples servicios, lo que facilita la selección rápida de los servicios recomendados para cada usuario teniendo en cuenta los patrones de uso.

Conclusiones

El trabajo de investigación demuestra el uso de las herramientas de aprendizaje automático en especial los sistemas de recomendación basado en la factorización matricial. Además, muestra el uso del aprendizaje automático automatizado y como facilita las tareas iterativas presentes en estas herramientas que pueden ser compleja para usuarios que no dominan la temática.

El uso de los sistemas de recomendación pueden ser una alternativa en aras de mejorar la calidad de los servicios en las pasarelas de pagos nacionales. Aplicaciones como Transfermóvil pueden verse beneficiadas con este tipo de herramientas que busca mejorar la interacción de los clientes con la plataforma y facilitar su uso.

Conflictos de intereses

Los autores no poseen conflictos de intereses.

Contribución de los autores

1. Conceptualización: Lesdaniel Herrera Reyes
2. Curación de datos: Lesdaniel Herrera Reyes
3. Análisis formal: Lesdaniel Herrera Reyes
4. Investigación: Lesdaniel Herrera Reyes
5. Metodología: Lesdaniel Herrera Reyes
6. Administración del proyecto: Lesdaniel Herrera Reyes
7. Software: Lesdaniel Herrera Reyes
8. Supervisión: Lesdaniel Herrera Reyes
9. Validación: Lesdaniel Herrera Reyes
10. Visualización: Lesdaniel Herrera Reyes
11. Redacción – borrador original: Lesdaniel Herrera Reyes



12. Redacción – revisión y edición: Lesdaniel Herrera Reyes

Financiamiento

La investigación no requirió fuente de financiamiento externa.

Referencias

- BADRIYAH, T., S. AZVY, W. YUWONO AND I. SYARIF. Recommendation system for property search using content based filtering method. In *2018 International conference on information and communications technology (ICOIACT)*. IEEE, 2018, p. 25-29.
- CHEN, Z. AND S. WANG A review on matrix completion for recommender systems. *J Knowledge Information Systems*, 2022, 64(1), 1-34.
- ETECSA. Transfermóvil. In., 2016, vol. 2022.
- FONSECA, D. S., W. R. PÉREZ AND M. L. M. FAURÉS Pasarela de pagos para la seguridad de transacciones bancarias en línea. *3c Empresa: investigación y pensamiento crítico*, 2013, 2(6), 4.
- GEETHA, G., M. SAFA, C. FANCY AND D. SARANYA. A hybrid approach using collaborative filtering and content based filtering for recommender system. In *Journal of Physics: Conference Series*. IOP Publishing, 2018, vol. 1000, p. 012101.
- HASSAN, M. A., Z. SHUKUR AND M. K. HASAN An efficient secure electronic payment system for e-commerce. *Computers*, 2020, 9(3), 66.
- HERLOCKER, J. L., J. A. KONSTAN AND J. RIEDL. Explaining collaborative filtering recommendations. In *Proceedings of the 2000 ACM conference on Computer supported cooperative work*. 2000, p. 241-250.
- JAGTAP, S. E-commerce Customer Data For Behavior Analysis. In., 2023, vol. 2024.
- KOREN, Y., R. BELL AND C. J. C. VOLINSKY Matrix factorization techniques for recommender systems 2009, 42(8), 30-37.



- LOWRY, P. B., T. M. WELLS, G. D. MOODY, S. HUMPHREYS, et al. Online payment gateways used to facilitate e-commerce transactions and improve risk management. *Communications of the Association for Information Systems*, 2006, 17(6), 1-48.
- MICROSOFT. Microsoft .NET. In., 2002, vol. 2016.
- MORE, T. AND S. KOHLE Recommendation System Using Matrix Factorization. *International Journal & Research Paper Publisher*, 2022, 10(9).
- REDDY, S., S. NALLURI, S. KUNISETTI, S. ASHOK, et al. Content-based movie recommendation system using genre correlation. In *Smart Intelligent Computing and Applications: Proceedings of the Second International Conference on SCI 2018, Volume 2*. Springer, 2019, p. 391-397.
- SARWAR, B., G. KARYPIS, J. KONSTAN AND J. RIEDL. Item-based collaborative filtering recommendation algorithms. In *Proceedings of the 10th international conference on World Wide Web*. 2001, p. 285-295.
- TRÁPAGA, J. A. G. Proyecto Transfermóvil: Evolución, Desarrollo e Impacto en el Comercio Electrónico en Cuba. In *Simposio Telecomunicaciones Transfermovil Informatica 2022*. Palacio de las convenciones: XVIII Convención y Feria Internacional, 2022.
- TRÁPAGA, J. A. G., O. H. ROMERO, F. C. VALBUENA, A. F. FUSTE, et al. “Transfermóvil: Infraestructura para el pago de servicios a través del móvil utilizando la tarjeta magnética del banco.” Transfermóvil: Infrastructure for the payment of services through mobile using the bank's magnetic card 2018.
- TRUONG, A., A. WALTERS, J. GOODSITT, K. HINES, et al. Towards automated machine learning: Evaluation and comparison of AutoML approaches and tools. In *2019 IEEE 31st international conference on tools with artificial intelligence (ICTAI)*. IEEE, 2019, p. 1471-1479.
- XETID. Enzona. In., 2019, vol. 2022.
- ZHOU, Z.-H. *Machine learning*. Edition ed.: Springer Nature, 2021. ISBN 9811519676.

