

## EL PROBLEMA DEL VIAJERO: APLICACIÓN PARA LA OPTIMIZACIÓN GEOREFERENCIADA DE RUTAS DE COBRADORES

Carlos Daniel Vázquez Rosas, Victor Alejandro Gonzalez-Huitron, Miguel Angel Guzman Rivera, Cesar Cruz Diaz  
1 Minsait, Oferta y Operaciones, CDMX, Mexico, [cdvazquezr@minsait.com](mailto:cdvazquezr@minsait.com)  
2 Tecnológico Nacional de México/Instituto Tecnológico de Querétaro, Av Tecnológico S/N, Centro Histórico, Centro, 76000 Santiago de Querétaro, Qro. Departamento de Sistemas y computación  
[victor.gh@queretaro.tecnm.mx](mailto:victor.gh@queretaro.tecnm.mx), [miguel.gr@queretaro.tecnm.mx](mailto:miguel.gr@queretaro.tecnm.mx)  
3 ESIME Culhuacán, Departamento de control automatico, Av. Sta. Ana 1000, San Francisco Culhuacan, Culhuacan CTM V, Coyoacán, 04440 Ciudad de México, CDMX  
[cesarsquall@gmail.com](mailto:cesarsquall@gmail.com)

### RESUMEN.

En el presente trabajo se aborda el problema de optimización de rutas para cobradores de deuda aplicable a diversas industrias (cobro de deuda bancaria, deuda departamental, deuda de impuestos, etc.). Para afrontar este reto se propone utilizar el algoritmo de optimización del problema del agente viajero (TSP), modificando la función de peso para que el algoritmo propuesto busque una relación óptima entre distancia y monto de la deuda a cobrar. Además, dentro de la función de peso, también se considera la probabilidad de que un cierto deudor pague la deuda. El objetivo principal es brindar la ruta que debe seguir un cobrador para visitar “n” casas de deudores que maximice la cantidad de deuda recaudada.

**Palabras Clave:** Problema del viajero, Aprendizaje automático, Problema del viajero generalizado, optimización combinatoria

### ABSTRACT.

This work addresses the problem of optimizing routes for debt collectors on motorcycles, applicable to various industries (bank debt collection, departmental debt, tax debt, etc.). To address this challenge, the proposal is to use the optimization algorithm for the Traveling Salesman Problem (TSP), modifying the weight function so that the proposed algorithm seeks an optimal relationship between distance and the amount of debt to be collected. Additionally, within the weight function, the probability of a certain debtor paying the debt is also considered. The main goal is to provide the route a collector should follow to visit 'n' debtors' houses that maximizes the amount of debt collected.

**Keywords:** Traveling Salesman Problem, Machine learning, Generalized traveling salesman problem, combinatorial optimization

### 1. INTRODUCCIÓN

La optimización de rutas para transporte terrestre ha cobrado una importancia significativa en los últimos años, causado por el aumento exponencial de la industria del transporte de reparto y por la necesidad de tener una solución que cause un impacto significativo en términos de eficiencia operativa, ahorro de costos y satisfacción del cliente [1]-[3].

Una manera de abordar esta problemática es utilizar el problema del agente viajero (TSP por sus siglas en inglés) que es un problema de optimización combinatoria [4]-[6]. El problema que aborda el algoritmo es el siguiente: Encontrar la ruta más corta posible que un agente viajero debe seguir para visitar un conjunto

de ciudades para poder visitar cada ciudad una vez y regresar a la ciudad de origen [7]. Conforme van aumentando el número de ciudades a visitar, el problema se vuelve más complejo hasta el punto de que no se conoce ningún algoritmo que pueda procesar todas las instancias del problema de manera eficiente si el número de ciudades a visitar es grande.

Un acercamiento sencillo al problema de encontrar la mejor ruta para visitar diferentes puntos es que la ruta más corta siempre es la mejor y más barata, pero esto no es necesariamente cierto, en [8]-[9] se documenta un método de optimización de rutas, donde, además de la distancia entre puntos, se agrega como variable diferentes costos asociados a la entrega de productos.

Abordando el caso particular de cobro de deuda (deudas de tiendas departamentales, bancarias, de cobro de impuestos, etc.) [10], donde existe una serie de cobradores que va casa por casa realizando funciones de cobro, el enfoque de buscar la ruta más corta es ineficiente en términos de maximizar el retorno de la deuda. Si la ruta más corta solo cubre las deudas más pequeñas de la cartera de deudores, se dejarían fuera algunos de los montos de deuda más importantes, dando siempre prioridad solo a las rutas más cortas y no necesariamente a los montos de deuda más altos.

Un aspecto adicional a tener en cuenta es la relación entre la rapidez en el proceso de cobro y la probabilidad de recuperar una deuda, donde, mientras más rápido se contacte al deudor y se realicen las gestiones de cobranza las probabilidades de recuperar la deuda aumentan. Después de un impago, entre otras variables como se estudia en [11]. Los deudores son generalmente más receptivos y las posibilidades de solucionar el impago son más altas antes de que la situación financiera del deudor se deteriore aún más.

Abordar las deudas de manera temprana puede tener un impacto psicológico en el deudor, demostrando que el acreedor está atento y serio con respecto a la recuperación de la deuda, situación que podría motivar al deudor a priorizar el pago de esa deuda sobre otras [12]. Mientras que, en un sentido contrario, la tardanza en la gestión de la deuda proporciona la noción que una deuda no pagada se deteriora con el tiempo, especialmente porque el deudor podría acumular más deuda o su situación financiera podría empeorar.

Teniendo estos aspectos en cuenta, es fácil realizar una conjetura donde, tomando en cuenta diferentes aspectos en el proceso de

rutas de cobranza, como lo es la distancia entre los domicilios de los deudores, el monto de la deuda y la probabilidad de pago basada en el tiempo que tiene la deuda, se podría maximizar la recaudación y optimizar la tarea de los cobradores [13]-[14].

En este trabajo se presenta una solución al problema de optimizar las rutas para los cobradores de deuda utilizando un proceso de optimización de rutas de múltiples criterios. El artículo se organiza de la siguiente manera: En la Sección 2 se presenta el planteamiento del problema. En la sección 3 se presentan los resultados principales donde se explica a detalle la metodología para llegar al resultado. Un ejemplo de aplicación se presenta en la sección 4. Finalmente, en la sección 5 se presentan las conclusiones generales del trabajo.

## 2. PLANTEAMIENTO DEL PROBLEMA

En este estudio, nos enfrentamos al desafío de optimizar las rutas para cobradores de deuda, una problemática que abarca diversas industrias, desde el cobro de deuda bancaria hasta el manejo de deudas departamentales e impuestos [15][16]. Proponemos abordar este problema mediante la aplicación del algoritmo de optimización del Problema del Agente Viajero (TSP).

El problema se puede plantear de la siguiente forma: Sea  $C = \{1, 2, 3, \dots, n\}$  el conjunto de la ubicación de los domicilios de deudores. El objetivo principal se centra en minimizar la función objetivo en la ecuación (1) [17].

$$\text{Min} \sum_{i=1}^n \sum_{j \neq i, j=1}^n d_{ij} x_{ij} \quad (1)$$

Donde  $x_{i,j}$  es una variable binaria que toma el valor de 1 si el viaje va directamente del domicilio  $i$  al domicilio  $j$ , tomando valor de 0 en caso contrario. La distancia entre la dirección  $i$  y la dirección  $j$  es representada por  $d_{i,j}$ . Para que el problema esté completo se consideran las restricciones del modelo mostradas en la ecuación (2) y ecuación (3).

$$\sum_{j \neq i, j=1}^n x_{ij} = \forall i \quad (2)$$

Cada ciudad debe ser visitada exactamente una vez:

$$\sum_{j \neq i, i=1}^n x_{ij} = \forall j \quad (3)$$

Estas restricciones aseguran que todas las ciudades sean conectadas en un ciclo único sin repeticiones.

## 3. RESULTADOS PRINCIPALES

En este capítulo se detallan los resultados obtenidos a través de la investigación, destacando el impacto de una innovadora adaptación de la función de peso en el algoritmo del Problema del Agente Viajero (TSP). Esta modificación no solo considera la distancia entre los puntos de cobro como criterio de optimización, sino que también integra el monto adeudado por cada deudor, así como la probabilidad de pago. Dicha probabilidad se evalúa en función de la antigüedad de la deuda, proporcionando así una estrategia más holística y eficaz para la gestión de cobros. El enfoque propuesto redefine la manera en que los cobradores de deudas priorizan sus visitas, buscando un equilibrio óptimo entre la minimización del tiempo de desplazamiento y la maximización de la recuperación de deudas. Sin embargo, se presenta una modificación innovadora en la función de peso, permitiendo que el algoritmo busque una relación óptima entre la distancia a recorrer, el monto de la deuda a cobrar y el tiempo que tiene la deuda.

### 3.1. NOTA TÉCNICA.

Es importante destacar que, debido a la naturaleza confidencial y sensible de los datos utilizados para el desarrollo y validación de nuestro modelo, no se pueden proporcionar detalles específicos sobre los conjuntos de datos. Sin embargo, se han tomado medidas rigurosas para garantizar la integridad del análisis y la veracidad de las conclusiones derivadas. Las técnicas de análisis estadístico y optimización aplicadas han sido diseñadas para ser reproducibles y aplicables a conjuntos de datos similares, permitiendo que investigadores y profesionales del área puedan adaptar nuestro modelo a sus propios contextos operativos.

Para compensar la imposibilidad de compartir los datos exactos, hemos implementado un enfoque detallado sobre la metodología empleada, incluyendo las fases de la selección de variables, la construcción del modelo y las técnicas de validación utilizadas. Además, se proporciona una descripción teórica de los tipos de datos analizados y se discuten los principios éticos seguidos para su manejo, asegurando la confidencialidad y protección de la información.

Aunque los datos específicos no pueden ser divulgados, se ha hecho un esfuerzo por ilustrar la aplicabilidad y robustez del modelo a través de simulaciones basadas en datos sintéticos que reflejan patrones y características similares a los del conjunto de datos real. Estas simulaciones buscan demostrar la efectividad del modelo propuesto y ofrecer una guía clara sobre su implementación práctica en escenarios reales de cobranza de deuda.

Este enfoque te permite ser transparente sobre las limitaciones en la divulgación de datos, mientras te enfocas en la robustez y aplicabilidad de tu metodología. Ofrece a otros investigadores la

oportunidad de entender y aplicar tu trabajo sin comprometer la confidencialidad de los datos sensibles.

### 3.2. SOLUCIÓN PLANTEADA

Si se adiciona la variable de monto de la deuda a cobrar, la función objetivo a minimizar quedaría de la siguiente forma:

$$\text{Min} \sum_{i=1}^n \sum_{j \neq i, j=1}^n (d_{ij} + c_{ij})x_{ij} \quad (4)$$

Donde el término  $c_{i,j}$  es el monto de la deuda.

Esta adición se puede complementar con el uso de diferentes ponderaciones al importe de la deuda y a la distancia entre direcciones, introduciendo coeficientes de ponderación:

$$\text{Min} \sum_{i=1}^n \sum_{j \neq i, j=1}^n (\alpha \cdot d_{ij} + \beta \cdot c_{ij})x_{ij} \quad (5)$$

Donde  $\alpha$  y  $\beta$  son coeficientes que determinan la importancia relativa entre la distancia y el monto de la deuda en la función objetivo. Con estos coeficientes se puede ajustar el impacto de cada factor en la decisión de la ruta. Si se le da una ponderación más alta a la distancia con respecto al monto de la deuda, se podría establecer una relación de los coeficientes  $\beta > \alpha$ ,

### 3.3. PROBABILIDAD DEL PAGO DE LA DEUDA

Este modelo se fundamenta en el análisis exhaustivo de variables clave como los montos de deuda, las fechas de pago e impago, entre otras, permitiendo establecer una correlación significativa entre la celeridad en las acciones de cobranza y la probabilidad de pago por parte del deudor.

El enfoque de probabilidad de pago por parte del deudor se analizó como un sistema que se acerca a un estado de equilibrio o valor final (estado estacionario) de manera exponencial con el tiempo. Una forma de representar matemáticamente este comportamiento es utilizando una ecuación diferencial de primer orden [18]:

$$\frac{dy}{dt} = k(Y_f - y) \quad (6)$$

Donde  $y$  es la probabilidad de pago de deuda. Idealmente toma un valor de 100 (Una probabilidad del 100% que la deuda será cubierta), hasta cero.

$Y_f$  es el valor final o de equilibrio que  $y$  alcanzará eventualmente.

La variable  $k$  es una constante de proporcionalidad que determina qué tan rápido se acerca el valor de  $y$  al valor  $Y_f$ .

La solución a la ecuación (6) da como resultado una función que describe cómo y varía con el tiempo aproximándose a su valor final  $Y_f$  de manera exponencial

$$y(t) = Y_f + (y_0 - Y_f)e^{-kt} \quad (7)$$

Donde  $y_0$  es el valor inicial de  $y$  en  $t = 0$ ,  $e^{-kt}$  es el término exponencial que determina la rapidez con la que  $y$  se acerca a  $Y_f$ .

Asumiendo que  $y$  empieza en 100 ( $y_0 = 100$ ) y  $y$  se acerca a un valor final  $Y_f$  con el tiempo, la ecuación se simplifica a:

$$y(t) = Y_f(1 - e^{-kt}) \quad (8)$$

Como se observa en la imagen (1), la curva descrita por la ecuación (8), comienza en 100 cuando  $t = 0$ , y se aproxima asintóticamente a  $Y_f$  a medida que  $t$  aumenta.

Teniendo en cuenta la ecuación (8), los valores para el algoritmo de optimización serían los siguientes:

- $y(t)$  = probabilidad de pago
- $t$  = Tiempo en días desde que comenzó la deuda

Teniendo en cuenta este resultado, la función de peso mostrada en la ecuación (5) sería el siguiente:

$$\text{Min} \sum_{i=1}^n \sum_{j \neq i, j=1}^n ((d_{ij} + c_{ij}) \cdot P_i)x_{ij} \quad (9)$$

Donde  $P_i$  es la probabilidad que el domicilio  $i$  pague su deuda.

#### 3.3.1 DATOS DE PRUEBA

Para obtener la ecuación mostrada en (8), se utilizó una base de datos histórica de deuda correspondiente a varias ciudades del norte de México. Esta base incluye un total de 1215045 registros con información detallada sobre:

- Monto de la deuda
- Fecha de inicio de la deuda
- Fecha de término en los casos en que la deuda fue pagada

El modelo se ajusta bien al comportamiento esperado, mostrando una relación consistente entre la probabilidad de pago y el tiempo de morosidad, lo que valida su utilidad en la optimización de las rutas de cobranza. Las suposiciones del modelo están respaldadas por patrones observados en los datos, aunque su precisión exacta no se puede medir en términos de exactitud tradicional.

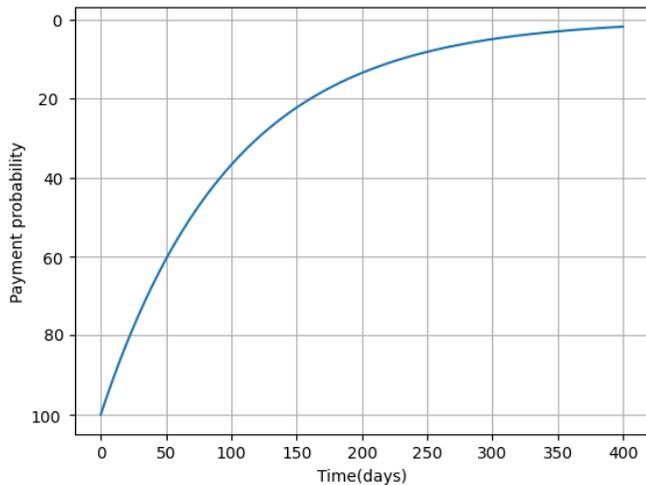


Figura 1. Probabilidad de pago a través del tiempo

#### 4. EJEMPLO DE APLICACIÓN

Para ilustrar la eficacia de la metodología propuesta, un ejemplo hipotético basado en un dataset generado de manera artificial es presentado. Este escenario hipotético refleja situaciones reales las cuales puede afrontar un

##### 4.1. CONTEXTO DEL EJEMPLO

El ejemplo se centra en una empresa hipotética "ABC", que necesita optimizar las rutas diarias de los cobradores en un área urbana específica. La compañía tiene la dirección de 100 deudores con diferentes montos de deuda distribuidos de manera heterogénea. Cada dirección representa un punto de cobro con diferente cantidad de deuda. El algoritmo propuesto genera una ruta óptima que muestra de manera explícita el recorrido que deben seguir los cobradores optimizando el retorno financiero en la empresa.

##### 4.2. DESCRIPCIÓN DE LA BASE DE DATOS

El ejemplo se centra en una empresa hipotética "ABC", que necesita optimizar las rutas diarias de los cobradores en un área urbana específica. La compañía tiene la dirección de 100 deudores con diferentes montos de deuda distribuidos de manera heterogénea. Cada dirección representa un punto de cobro con diferente cantidad de deuda. El algoritmo propuesto genera una ruta óptima que muestra de manera explícita el recorrido que deben seguir los cobradores optimizando el retorno financiero en la empresa.

Las direcciones corresponden al área urbana de Nueva York en los Estados Unidos y fueron extraídas de la base de datos "New York Housing Market" [15]. Los datos que tienen que ver con el monto

de la deuda fueron creados de manera artificial. La base de datos tiene la siguiente estructura:

- Deudor ID: Dato de tipo entero. Puede estar repetido en el dataset, en caso de que el deudor tenga más de una deuda registrada.
- Fecha del día: Dato de tipo fecha.
- Nombre del deudor: Dato de tipo string.
- Latitud de la dirección: Dato de tipo flotante
- Longitud de la dirección: Dato de tipo flotante
- Código postal del deudor: Dato de tipo string.
- Monto de la deuda: Dato de tipo flotante
- Fecha de inicio de la deuda: Dato de tipo fecha.

Los siguientes datos se obtienen mediante el procesamiento de la base de datos original:

Duración de la deuda: Es calculada por la diferencia del número de días entre la fecha de inicio de la deuda y la fecha del día.

Probabilidad de que se pague la deuda: Dato de tipo flotante. Se calcula utilizando el nuevo dato "Duración de la deuda" y la fórmula mostrada en la ecuación (8). Idealmente se evalúa de 0 a 100, pero, a partir de los datos observados, se concluyó que en un escenario real, la ventana de valores que ofrecen un mejor resultado es, 10%-66.6% de probabilidad de pago de un deudor dependiendo la antigüedad de su deuda. Este valor indica los diferentes riesgos de impago.

##### 4.3. IMPLEMENTACIÓN DEL CÓDIGO

Se utilizó Python como lenguaje de implementación y se modificó la función de peso estándar para adaptarla al contexto específico del problema de cobranza. Los pasos que se siguieron fueron los siguientes:

Generación del Grafo: Los domicilios se representan como nodos de un grafo, y las aristas entre ellos están ponderadas con la función de peso adaptada.

Algoritmo Heurístico: Se utilizó una variación del algoritmo nearest neighbor (vecino más cercano) para obtener una solución inicial, que posteriormente fue refinada mediante una búsqueda local. Este método itera sobre las soluciones iniciales y realiza pequeñas modificaciones a la ruta, evaluando si la nueva solución mejora el costo total de la ruta.

Iteraciones y Mejoras: Se ejecutaron varias iteraciones del algoritmo para optimizar la ruta final.

El utilizar un algoritmo iterativo, tiene como consecuencia un alto costo computacional que se traduce en largos tiempos de ejecución del algoritmo. En nuestra prueba con datos sintéticos y teniendo en cuenta 100 domicilios a optimizar, el algoritmo tardó 15.1 minutos. Es importante aclarar que, el aumentar domicilios al algoritmo de optimización, aumentará de manera exponencial los

tiempos de cómputo, por lo cual, si se busca correr el algoritmo con un alto número de domicilios, se podría pensar en una mejora de la implementación en python utilizando computo paralelo.

**4.4. DESCRIPCIÓN VISUAL E LOS RESULTADOS**

La figura 2 muestra un mapa visual de las rutas optimizadas calculadas a partir del algoritmo propuesto en este trabajo. Cada punto representa la dirección de un deudor en el área urbana de Nueva York, los cuales están conectados mostrando gráficamente qué destino hay que seguir después de visitar un punto. Este mapa destaca tanto el punto inicial como el final, proporcionando un mapa visual de las rutas optimizadas.

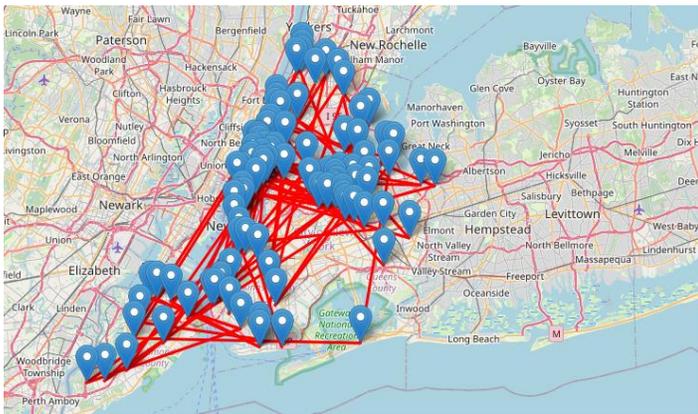


Figura 2. Mapa con rutas optimizadas

**4.5. DISTANCIAS Y TIEMPOS DE TRASLADO**

La Tabla 1 especifica el ID del deudor. El orden en que es visitado el domicilio. Las coordenadas del domicilio utilizando los datos de latitud y longitud. Finalmente se especifica el monto de la deuda. En la Tabla 2 se especifica el punto de la ruta donde empieza el trayecto y el punto de término. Un estimado (es segundos) se muestra, para saber cuánto tiempo toma un cobrador en el trayecto de un punto a otro. Finalmente se muestra la distancia (en metros) desde el punto de origen al destino.

Tabla 1. Orden de visitas

ID	Orden-Visita	Lat	Lon	Deuda(\$)
1667	0	40.868175	-73.889765	928
1112	1	40.760649	-73.966893	338
1229	2	40.798904	-73.960481	3283
1502	3	40.709735	-73.818829	3226
1142	4	40.88093	-73.910749	2487
1619	95	40.588988	-74.153058	4496
1620	96	40.583827	-73.824314	4061
1908	97	40.76671	-73.78272	4579
1069	98	40.829632	-73.915924	4648
1842	99	40.765481	-73.817873	4536

Tabla 2. Duración y distancias de las visitas

Origen	Destino	Duración(s)	Distancia(m)
0	1	642.8	7356.5
1	2	509.9	5107.8
2	3	285.2	2694.1
3	4	153	1074.5
4	5	780.6	9158.7
94	95	1497.6	23577.8
95	96	1247.9	14386.7
96	97	1907.4	24610.2
97	98	2164.8	30445.4
98	99	1445.3	23941.5

Es importante destacar que, por cuestiones de espacio, en ambas tablas solo se muestran los primeros cinco domicilios a visitar y los últimos cinco.

**4.6. DISCUSIÓN DE LOS RESULTADOS.**

Los resultados obtenidos sugieren que el algoritmo desarrollado en esta investigación es capaz de encontrar de manera efectiva la solución para una ruta optimizada con el objetivo de maximizar la recolección de deuda.

Sin embargo, es importante considerar que el uso de datos artificiales podría limitar la generalización de estos resultados en un ambiente de productivización y con datos reales.

**4.7. IMPLICACIONES PRÁCTICAS DEL ALGORITMO.**

Las implicaciones prácticas de este estudio son importantes para industrias que requieren optimización de rutas, y si bien podría usarse para industrias como logística y transporte, su mayor efectividad es en industrias enfocadas en el cobro de deudas. Aunque los datos utilizados son artificiales, los patrones y optimizaciones observados podrían aplicarse para mejorar las operaciones en escenarios reales.

**5. CONCLUSIONES**

El objetivo principal de este enfoque es proporcionar una ruta óptima para que los recolectores visiten el mayor número de residencias de deudores. Esta ruta no solo minimiza el tiempo de viaje, sino que también maximiza la eficiencia en la recolección de deudas. La propuesta ofrece una herramienta valiosa para mejorar la planificación de rutas en el campo de la recolección, integrando de manera efectiva consideraciones de tiempo, la cuantificación de deudas pendientes y la probabilidad de que se pague la deuda.

**6. REFERENCIAS**

[1] K. L. Hoffman and M. Padberg, 'Traveling Salesman Problem (TSP)Traveling salesman problem', in Encyclopedia of Operations Research and Management Science, S. I. Gass and C. M. Harris, Eds. New York, NY: Springer US, 2001, pp. 849–853.

- [2] O. Cheikhrouhou and I. Khoufi, 'A comprehensive survey on the Multiple Traveling Salesman Problem: Applications, approaches and taxonomy', *Computer Science Review*, vol. 40, p. 100369, 2021.
- [3] M. Battarra, G. Erdoğan, G. Laporte, and D. Vigo, 'The Traveling Salesman Problem with Pickups, Deliveries, and Handling Costs', *Transportation Science*, vol. 44, no. 3, pp. 383–399, 2010.
- [4] C. Han and Y. Jang, 'Effects of debt collection practices on loss given default', *Journal of Banking & Finance*, vol. 37, no. 1, pp. 21–31, 2013.
- [5] E. Storms and G. Verschraegen, 'Time regimes in debt collection and mediation', *Time & Society*, vol. 28, no. 4, pp. 1382–1408, 2019.
- [6] V. Asudani, S. Uparkar, S. Upadhye, and M. Seth, 'Application of the Traveling Salesman Model for Rural Development of the Vidarbha Region', *ECS Transactions*, vol. 107, no. 1, p. 6725, 2022.
- [7] Y. Shi and Y. Zhang, 'The neural network methods for solving Traveling Salesman Problem', *Procedia Computer Science*, vol. 199, pp. 681–686, 2022.
- [8] O. Nurdiawan, F. A. Pratama, D. A. Kurnia, Kaslani, and N. Rahaningsih, 'Optimization of Traveling Salesman Problem on Scheduling Tour Packages using Genetic Algorithms', *Journal of Physics: Conference Series*, vol. 1477, no. 5, p. 52037, Mar. 2020.
- [9] P. C. Pop, O. Cosma, C. Sabo, and C. P. Sitar, 'A comprehensive survey on the generalized traveling salesman problem', *European Journal of Operational Research*, vol. 314, no. 3, pp. 819–835, 2024.
- [10] Z. Zhang, H. Liu, M. Zhou, and J. Wang, 'Solving Dynamic Traveling Salesman Problems With Deep Reinforcement Learning', *IEEE Transactions on Neural Networks and Learning Systems*, vol. 34, no. 4, pp. 2119–2132, 2023.
- [11] C. Wu, X. Fu, J. Pei, and Z. Dong, 'A Novel Sparrow Search Algorithm for the Traveling Salesman Problem', *IEEE Access*, vol. 9, pp. 153456–153471, 2021.
- [12] S. Liu, Y. Zhang, K. Tang, and X. Yao, 'How Good is Neural Combinatorial Optimization? A Systematic Evaluation on the Traveling Salesman Problem', *IEEE Computational Intelligence Magazine*, vol. 18, no. 3, pp. 14–28, 2023.
- [13] M. Mosayebi, M. Sodhi, and T. A. Wettergren, 'The Traveling Salesman Problem with Job-times (TSPJ)', *Computers & Operations Research*, vol. 129, p. 105226, 2021.
- [14] A. Santini, A. Viana, X. Klimentova, and J. P. Pedroso, 'The Probabilistic Travelling Salesman Problem with Crowdsourcing', *Computers & Operations Research*, vol. 142, p. 105722, 2022.
- [15] N. Elgiryewithana, 'New York Housing Market'. 2024.
- [16] Z. Ling, X. Tao, Y. Zhang, and X. Chen, 'Solving Optimization Problems Through Fully Convolutional Networks: An Application to the Traveling Salesman Problem', *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 51, no. 12, pp. 7475–7485, 2021.
- [17] A. Di Placido, C. Archetti, and C. Cerrone, 'A genetic algorithm for the close-enough traveling salesman problem with application to solar panels diagnostic reconnaissance', *Computers & Operations Research*, vol. 145, p. 105831, 2022.
- [18] S. Wang, M. Liu, and F. Chu, 'Approximate and exact algorithms for an energy minimization traveling salesman problem', *Journal of Cleaner Production*, vol. 249, p. 119433, 2020.
- [19] A. C. P. Mesquita and C. A. A. Sanches, 'Air cargo load and route planning in pickup and delivery operations', *Expert Systems with Applications*, vol. 249, Part B, 2024.
- [20] P. Agarwal, R. P. Agarwal, and M. Ruzhansky, *Special functions and analysis of differential equations*. CRC Press, 2020.