

การใช้ปัญญาประดิษฐ์ระดับการเรียนรู้เชิงลึกในการแก้ปัญหาการจัดเส้นทางเดินรถที่มีความจุ

Using Deep Learning Artificial Intelligence to Solve The Capacitated Vehicle Routing Problem

ณนณ ศลนัฏฐนน^{1*} และ มาโนช โลหเตปานนท์²

^{1,2} ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย จ.กรุงเทพมหานคร

² สถาบันการขนส่ง จุฬาลงกรณ์มหาวิทยาลัย จ.กรุงเทพมหานคร

*Corresponding author; E-mail address: sonnattanon.nanon@gmail.com, manoj.l@chula.ac.th

บทคัดย่อ

ปัญหาการจัดลำดับเส้นทางเดินรถเป็นปัญหาในการหาคำตอบที่ดีที่สุดซึ่งมีความยากประเภท NP-Hard เนื่องจากเป็นปัญหาการหาคำตอบที่ดีที่สุดภายใต้เวลาพหุนาม งานวิจัยนี้ใช้ปัญญาประดิษฐ์ระดับการเรียนรู้เชิงลึก (Deep Learning Artificial Intelligence) ประเภทโครงข่ายประสาทเทียม (Neural Network) ในการเลือกอัลกอริทึมประเภทฮิวริสติกส์ที่เหมาะสมสำหรับใช้แก้ปัญหาการจัดลำดับเส้นทางเดินรถในแต่ละกลุ่ม โดยประกอบไปด้วย 6 อัลกอริทึมดังนี้ 2-Optimize, 2-Approximate, Nearest_2Opt, Improve Nearest, Rep Improve Nearest และ OR Tools และใช้การจัดกลุ่มรถด้วยวิธีการกวางมูม ในทุกปัญหาของงานวิจัยนี้กำหนดให้ใช้รถที่มีขนาดใหญ่ที่สุดในการจัดลำดับเส้นทางเป็นอันดับแรก และให้รถที่มีความจุรองลงมาจัดเส้นทางในลำดับถัดไป เนื่องจากการใช้รถที่มีขนาดใหญ่ก่อนทำให้ระยะทางรวมต่ำกว่าวิธีอื่นในการทดสอบด้วยปัญหาตัวอย่างจำนวน 98 ตัวอย่าง การแก้ปัญหาจากปัญญาประดิษฐ์ด้วยวิธีที่นำเสนอ ระยะทางที่ได้จากปัญญาประดิษฐ์มากกว่าระยะทางที่ต่ำที่สุดทางทฤษฎีอยู่เฉลี่ยไม่เกินร้อยละ 17 ภายใต้ระดับความเชื่อมั่นร้อยละ 95 และเวลาที่ใช้ในการแก้ปัญหาที่มีลักษณะเพิ่มขึ้นเป็นฟังก์ชันเอกซ์โพเนนเชียลเมื่อเทียบกับขนาดของปัญหา โดยปัญหาที่มีขนาดน้อยกว่า 200 จุด ใช้ระยะเวลาในการแก้ปัญหาน้อยกว่า 60 วินาที

คำสำคัญ: ปัญญาประดิษฐ์, การจัดเส้นทางเดินรถที่มีความจุ, การเรียนรู้เชิงลึกประเภทโครงข่ายประสาทเทียม, ฮิวริสติกส์, อัลกอริทึมการกวางมูม

Abstract

The vehicle routing problem belongs to the NP-Hard problem class because finding the optimal solution is possible in non-polynomial time. This research proposes the use of neural network deep learning artificial intelligence to determine the most appropriate heuristic algorithms for solving the vehicle

routing problem which include with six algorithms, namely, 2-Optimize, 2-Approximate, Nearest_2Opt, Improve Nearest, Rep Improve Nearest and OR Tools. The clustering of vehicle routing is then performed using the Sweep algorithm. The vehicles are processed in order from largest to smallest since using the larger vehicle results in lower mileage than using smaller vehicles. The results of our study demonstrate that when comparing the optimal distance from the standard dataset to the solved distance by our artificial intelligence model, the mean distance from our model is greater than the optimal distance by no more than 17% at the 95% confidence level. Problems with fewer than 200 nodes take time less than 60 seconds to solve. The solution time increases exponentially with problem size.

Keywords: Artificial Intelligence, The Capacitated Vehicle Routing (CVRP), Neural Network's Deep Learning, Heuristic, The Sweep Algorithm.

1. คำนำ

ปัจจุบันการขนส่งสินค้าที่เกิดขึ้นในประเทศไทยเติบโตเฉลี่ย 1% ถึง 2% ต่อปี และสำหรับการขนส่งสินค้าที่เกิดขึ้นบนท้องถนนของประเทศไทย คำนวณเป็นสัดส่วนได้ถึง 81% ของปริมาณสินค้ารวมทั้งหมด เนื่องจากการขนส่งสินค้าบนถนนมีข้อดีคือลดความเสียหายและการสูญหายของสินค้าระหว่างการขนส่ง แต่อย่างไรก็ตามต้นทุนของการขนส่งสินค้ายังสูงกว่าต้นทุนการขนส่งรูปแบบอื่น ๆ เนื่องจากมีต้นทุนที่แปรผันสูง เช่น ค่าเชื้อเพลิง ค่าแรงงาน เป็นต้น ซึ่งการวางแผนเส้นทางขนส่งให้กับผู้ให้บริการที่เหมาะสมทำให้เกิดต้นทุนการจัดส่งที่ต่ำที่สุด [1] โดยเป็นปัญหาการจัดเส้นทางยานพาหนะ จะต้องจัดกลุ่มของยานพาหนะทุกคันให้มีเกิดต้นทุนการเดินทางต่ำที่สุด (Travel cost) เช่น ระยะทางรวม หรือระยะเวลารวมทั้งหมด เป็นต้น โดยการเดินทางของยานพาหนะทุกคันเริ่มต้นและจบลงที่คลังสินค้าเสมอ และยานพาหนะทุกคันมีความสามารถในการบรรทุกอย่างจำกัด จึงทำให้ปัญหาการจัดลำดับเส้นทางดังกล่าวมีข้อ

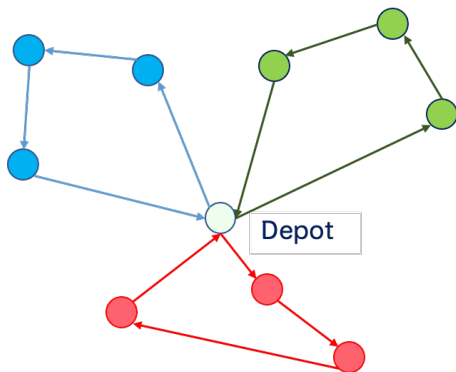
เรียกว่า The Capacitated Vehicle Routing Problem (CVRP) หากสามารถจัดกลุ่มของยานพาหนะได้อย่างมีประสิทธิภาพ สามารถทำให้ต้นทุนการดำเนินงานลดลงได้ถึง 20% [2] ซึ่งเป็นปัญหาที่มีความยากระดับ NP-hard [3,4] เพราะยังไม่มีชุดอัลกอริทึมที่ค้นหาชุดคำตอบที่ดีที่สุด (Optimal solution) ออกมาภายใต้ระยะเวลาพหุนาม แม้จะใช้วิธีการแก้ปัญหาด้วยวิธีการเชิงเส้น (Linear programming) ยังคงใช้ระยะเวลาในการหาคำตอบ ซึ่งความยากในการแก้ปัญหาจะมีความยากมากขึ้น เมื่อจำนวนจุดภายในปัญหาเพิ่มมากขึ้น

การแก้ปัญหาการจัดลำดับเส้นทางด้วยอัลกอริทึมฮิวริสติกส์ เป็นวิธีการแก้ปัญหาอย่างง่ายชนิดหนึ่ง ที่สามารถให้คำตอบในการจัดลำดับเส้นทางได้อย่างรวดเร็ว แต่คำตอบที่ได้มาไม่สามารถการันตีได้ว่าเป็นคำตอบที่ดีที่สุด แต่เป็นคำตอบที่เพียงพอต่อวัตถุประสงค์ที่ตั้งไว้ โดยอัลกอริทึมประเภทฮิวริสติกส์มีหลากหลาย และแต่ละวิธีให้ผลเฉลยที่แตกต่างกันไป ดังนั้นทางผู้วิจัยจึงได้นำปัญญาประดิษฐ์ระดับการเรียนรู้เชิงลึกประเภทโครงข่ายประสาทเทียม เข้ามาใช้ในการเลือกอัลกอริทึมประเภทฮิวริสติกส์ที่เหมาะสมที่สุดในแต่ละปัญหาของการจัดลำดับเส้นทางยานพาหนะที่มีความจุ เพื่อให้ได้คำตอบที่ดีที่สุดเท่าที่เป็นไปได้ (Best solution) และสามารถแก้ปัญหาได้อย่างรวดเร็วและถูกต้อง

2. หลักการ แนวคิด ทฤษฎีและการศึกษาที่เกี่ยวข้อง


2.1 ปัญหาการจัดเส้นทางยานพาหนะแบบมีความจุ (The Capacitated Vehicle Routing Problem ,CVRP)

การจัดกลุ่มของยานพาหนะโดยการค้นหากลุ่มและทำการจัดเส้นทางที่เหมาะสมให้แก่กลุ่มยานพาหนะนั้น ๆ เพื่อให้เกิดระยะทางโดยรวมต่ำที่สุด โดยมีเงื่อนไขในการแก้ปัญหาคือ ยานพาหนะใด ๆ สามารถผ่านเมืองใด ๆ หรือผู้รับบริการใด ๆ ได้เพียง 1 ครั้งเท่านั้น จุดเริ่มต้นและจุดสิ้นสุดของการขนส่งสินค้าอยู่ที่ศูนย์กระจายสินค้า ยานพาหนะไม่สามารถแบ่งสินค้า (Split Delivery) ให้แก่ผู้รับบริการรายอื่น ๆ ได้ หรือ ผู้รับบริการสามารถรับบริการจากยานพาหนะได้เพียงคันเดียวเท่านั้น และยานพาหนะที่ใช้ในการขนส่งมีข้อจำกัดในด้านการขนส่งหรือบรรทุกสินค้า ซึ่งในบางครั้งปัญหานี้มีชื่อเฉพาะคือ The Capacitated Vehicle Routing Problem (CVRP) โดยลักษณะปัญหาดังกล่าวแสดงได้ดังรูปที่ 1



รูปที่ 1 การจัดลำดับเส้นทางยานพาหนะแบบมีความจุ CVRP

ในการศึกษาการจัดลำดับเส้นทางยานพาหนะแบบมีความจุ สามารถแบ่งปัญหาออกได้เป็น 2 ประเภทคือ ปัญหาที่มีจุดกระจายสินค้าเพียง 1 จุด (Single depot) และปัญหาที่มีจุดกระจายสินค้าตั้งแต่ 2 จุดเป็นต้นไป (Multiple depot) แสดงได้ดังรูปที่ 2 [5]



รูปที่ 2 Multiple depot VRP

โดยในการศึกษาการแก้ปัญหาการจัดลำดับเส้นทางยานพาหนะแบบมีความจุ ได้เลือกปัญหาที่มีคลังสินค้าเพียง 1 จุดเท่านั้นในการศึกษา โดยมิลักษณะของฟังก์ชันวัตถุประสงค์ ดังแสดงในสมการที่ (1)

$$\min \sum \sum c_{ij} x_{ij} \quad i, j \in V \quad (1)$$

ภายใต้เงื่อนไขคือ


$$\begin{aligned} \sum_{i \in V} x_{ij} &= 1 \quad \forall j \in V \setminus \{0\} \\ \sum_{j \in V} x_{ij} &= 1 \quad \forall i \in V \setminus \{0\} \\ \sum_{i \in V} x_{i0} &= K \\ \sum_{j \in V} x_{0j} &= K \\ \sum_{i \in S} \sum_{j \in S} x_{ij} &\geq r(S) \quad \forall S \subseteq V \setminus \{0\}, S \neq \emptyset \end{aligned}$$

โดยที่ x_{ij} คือตัวแปรประเภท Binary ที่สัมพันธ์ระหว่างจุด i และ j , C_{ij} คือต้นทุนที่สัมพันธ์กันจากจุด i ไปจุด j , V คือเซตของจุดลูกค้า, K คือจำนวนรถที่ใช้, $r(S)$ คือ จำนวนรถขั้นต่ำที่ใช้ในการบริการลูกค้าทั้งหมดในเซต S จุดกระจายสินค้าเป็นจุด 0 โดยสำหรับเงื่อนไขที่ 1,2 เป็นการกำหนดให้ลูกค้าแต่ละจุดสามารถรับบริการจากรถใด ๆ ได้เพียง 1 ครั้งเท่านั้น สำหรับเงื่อนไข 3.4 เป็นการกำหนดจำนวนเส้นทางยานพาหนะ (Number of vehicle route) และสำหรับเงื่อนไขที่ 5 เป็นเงื่อนไขกำจัดเส้นทางที่ไม่เกี่ยวข้อง (Sub tour elimination) คือ อุปสงค์ของลูกค้าทุกคนที่ได้รับการบริการจากรถที่ถูกกระจายจากคลังสินค้าอย่างทั่วถึง ซึ่งการแก้ปัญหาการจัดลำดับเส้นทางรถด้วยการสร้างแบบจำลองคณิตศาสตร์ดังกล่าว เป็นแบบจำลองเป็นปัญหาแบบโปรแกรมเลขจำนวนเต็ม (Integer Programming) ซึ่งในกรณีที่ปัญหามีขนาดใหญ่ มีความซับซ้อนในการแก้สมการมากขึ้น ส่งผลให้ทำให้ใช้เวลานานมากขึ้นในการแก้ปัญหา ในปัจจุบันจึงนิยมใช้อัลกอริทึมฮิวริสติกส์ในการแก้ปัญหาแทน

2.2 ปัญหาการเดินทางของพนักงานขาย (Travelling Salesman Problem, TSP)

Problem, TSP

การจัดเส้นทางเพื่อหาลำดับของการเดินทางไปยังจุดต่าง ๆ โดยเริ่มต้นจากจุดเริ่มต้นจุดใดจุดหนึ่ง และผ่านทุก ๆ จุดที่กำหนด โดยสามารถผ่านได้เพียง 1 ครั้งเท่านั้น และกลับมาที่จุดเริ่มต้น เพื่อให้เกิดระยะทางที่น้อยที่สุด โดยการเดินทางนี้เดินทางโดยผู้เดินทางเพียง 1 รายเท่านั้น โดยผู้เดินทางไม่มีข้อจำกัดในเรื่องอื่น เช่น มีขอบเขตในการบรรจุสินค้า (Capacity) เป็นต้น โดยสามารถแสดงได้ดังรูปที่ 3 [6]




รูปที่ 3 การจัดลำดับเส้นทางในปัญหาของพนักงานขาย

โดยปัญหาพนักงานขายเป็นปัญหาที่มีอัลกอริทึมฮิวริสติกส์ที่หลากหลายสามารถแก้ไขได้ปัญหาได้อย่างรวดเร็ว แม้ว่าคำตอบที่ได้ออกมาไม่สามารถการันตีคำตอบที่ดีที่สุดได้ แต่คำตอบที่ได้ก็มีความเหมาะสมในการนำไปใช้ต่อไปได้ แม้ว่าแต่ละอัลกอริทึมจะให้ผลเฉลยที่ต่างกันออกไป ซึ่งตัวอย่างของอัลกอริทึมประเภทฮิวริสติกส์ เช่น Greedy Algorithm, Nearest Neighbor, Nearest Insertion, Cheapest Insertion, Random Insertion, Farthest Insertion, Christofides Algorithm, 2-Opt Algorithm, 3-Opt algorithm, Lin-Kernighan Heuristic และอื่น ๆ

2.3 ปัญหาประติรูปประเภทโครงข่ายประสาทเทียม (Neural Network)

ปัญญาประดิษฐ์คือแบบจำลองทางคณิตศาสตร์ที่ทำให้โปรแกรมสามารถเกิดการเรียนรู้จากข้อมูลที่ได้ทำการฝึกฝนไป ส่งผลให้โปรแกรมสามารถคาดการณ์หรือคาดเดาผลลัพธ์ที่มีความแปรปรวนสูงได้อย่างแม่นยำ ซึ่งในงานวิจัยนี้ได้นำปัญหาประติรูประดับการเรียนรู้เชิงลึก (Deep learning) มาใช้งาน โดยเป็นปัญหาประติรูปที่มีระดับการเรียนรู้แบบ Supervised learning ซึ่งเป็นการเรียนรู้ที่ต้องมีชุดข้อมูลมาฝึกฝน ลักษณะการเรียนรู้ที่มีผลลัพธ์ที่คาดหวัง (Desired output) เป็นตัวกำหนดที่ชัดเจน โดยผลลัพธ์ที่นำมาใช้ในงานวิจัยนี้คือการให้ปัญหาประติรูปมีความสามารถในการแยกแยะหรือทำการจัดกลุ่มได้ (Classified machine learning) โดยการทำงานของโครงข่ายประสาทเทียม ทำงานเลียนแบบกับเซลล์ประสาทในสมองมนุษย์ ประกอบไปด้วยเซลล์ประสาทและเส้นประสาท เรียกโดยรวมว่า Artificial Neural Network (ANN) โดยการทำงานของ ANN ประกอบไปด้วย 3 ชั้นหลัก ๆ คือ ชั้นนำข้อมูลเข้า (Input layer) ชั้นประมวลผลข้อมูล (Hidden layer) และ ชั้นนำข้อมูลออก (Output layer) โดยสามารถแสดงได้ดังรูปที่ 4



รูปที่ 4 องค์ประกอบหลักของ Artificial Neural Network (ANN)

2.4 เมตาฮิวริสติกส์ (Metaheuristic)

Luca, A., et al. [7] ได้ใช้ปัญญาประดิษฐ์ในการปรับเปลี่ยนอัลกอริทึมตลอดเวลาในการแก้ปัญหา เพื่อลดขั้นตอนของการคำนวณลง เนื่องจากปัญญาประดิษฐ์สามารถศึกษาและเรียนรู้อัลกอริทึมที่เหมาะสมที่นำมาใช้ในการคำนวณ ซึ่งสอดคล้องกับการศึกษาของ Cooray, P. and D. Thashika, R. [8] ที่ได้ใช้ Machine learning ในการปรับแต่งอัลกอริทึมประเภทเมตาฮิวริสติกส์ โดยการปรับเปลี่ยนพารามิเตอร์ในระหว่างขั้นตอนการคำนวณ เพื่อเพิ่มคุณภาพของคำตอบของการจัดเส้นทางเดินทาง ซึ่งมีความคล้ายคลึงกับการศึกษาของ Bai, R., et al [9] ที่ได้นำเทคนิคการวิเคราะห์ต่าง ๆ เข้าร่วมกับกระบวนการปัญญาประดิษฐ์เพื่อเลือกอัลกอริทึมที่เหมาะสมในการแก้ไขปัญหการจัดเส้นทางเดินทาง การใช้ Markov Decision Process การเรียนรู้แบบ reinforcement learning ในการแก้ปัญหาในรอบของเวลา เพื่อตอบสนองความต้องการของลูกค้า หรือปัญหาที่สามารถมีการเปลี่ยนแปลงได้ตลอดเวลา (Dynamic problem) ได้ถูกเสนอโดย Joe, W. and Lau, H. [10] ซึ่งการฝึกฝนปัญญาประดิษฐ์ที่มีการเรียนรู้แบบ Reinforcement learning ต้องฝึกฝนกับปัญหาที่มีความหลากหลาย แต่ต้องมีขนาดที่ใกล้เคียงกัน เพื่อให้แบบจำลองปัญญาประดิษฐ์สามารถปรับเปลี่ยนเพื่อหาพารามิเตอร์ที่เหมาะสมได้ และเมื่อเจอปัญหาที่มีความใกล้เคียงกัน ปัญญาประดิษฐ์สามารถให้คำตอบที่มีคุณภาพที่ดีและใช้เวลาแก้ปัญหาไม่นาน [11]

3. การสร้างปัญหาประติรูประดับการเรียนรู้เชิงลึก เพื่อใช้ในการแก้ไขปัญหการจัดลำดับเส้นทางที่มีความจุ

การเรียนรู้เชิงลึกประเภทโครงข่ายประสาทเทียม (Neural Network) ได้ถูกนำมาใช้ในงานวิจัยเพื่อแก้ปัญหการจัดลำดับเส้นทางที่มีความจุ โดยองค์ประกอบที่สำคัญในการสร้างปัญหาประติรูปชนิดนี้ประกอบไปด้วย 2 ส่วนคือ ส่วนที่เป็นส่วนนำเข้าข้อมูล (Attributes) ในชั้นของ Input layer และส่วนของผลลัพธ์ (Class) ในชั้น Output layer

3.1 Attributes ที่ใช้ในปัญหาประติรูป

Attribute คือ ข้อมูลที่ใช้นำเข้าสู่ชั้นแรกของโครงข่ายประสาทเทียม เพื่อส่งต่อไปยังชั้น Hidden layer เพื่อทำการคำนวณ และนำไปสู่การคาดคะเนผลลัพธ์ที่เกิดขึ้น โดย Attributes ที่ใช้เป็นการระบุลักษณะของปัญหา ประกอบไปด้วย 13 ลักษณะ โดยลักษณะปัญหาเริ่มต้นคือ การ

กระจายตัวของจุดบนระนาบโดยมีพิกัดของจุดเป็นระบบพิกัดคาร์ทีเซียนในการระบุตำแหน่ง โดยสามารถแสดงได้ดังนี้

- 3.1.1 Node (จำนวนจุด)
- 3.1.2 Moment of the inertia (โมเมนต์ความเฉื่อยแบบจุด)
- 3.1.3 Initial distance (ระยะทางการเรียงจุดเริ่มต้น)
- 3.1.4 Convex Hull length (ความยาวเส้นล้อมรอบขอบนอกสุด)
- 3.1.5 Points on Convex Hull (จุดที่อยู่บนเส้น convex hull)
- 3.1.6 Remain Points (จุดที่ไม่ได้อยู่บน convex hull)
- 3.1.7 Bulk density (ความหนาแน่นเชิงจุดแบบเบ้าท์)
- 3.1.8 Total density (ความหนาแน่นเชิงจุดแบบรวม)
- 3.1.9 Line density (ความหนาแน่นเชิงจุดแบบเส้น)
- 3.1.10 R-square (ค่าความผันแปร)
- 3.1.11 Correlation (ค่าสัมประสิทธิ์สหสัมพันธ์)
- 3.1.12 MSD_x (การกระจายตัวในแนวมิติแกน x)
- 3.1.13 MSD_y (การกระจายตัวในแนวมิติแกน y)

โดย Attributes ทั้งหมดนั้นจะถูกคำนวณให้อยู่ในลักษณะของตัวเลข เพื่อให้ปัญญาประดิษฐ์สามารถใช้ในการประมวลผลได้ในลำดับถัดไป

3.2 Class ที่ใช้ในปัญญาประดิษฐ์

Class คือ ผลลัพธ์ที่ได้จากการคำนวณจากปัญญาประดิษฐ์ โดยชนิดของผลลัพธ์เป็นแบบค่าไม่ต่อเนื่อง (Discrete values) โดยผลลัพธ์ที่เกิดจาก Attributes ที่ปัญญาประดิษฐ์ได้รับ โดยถ้าหากปัญญาประดิษฐ์ได้รับข้อมูลนำเข้าที่ดี การคาดการณ์ผลลัพธ์ย่อมทำให้เกิดค่าที่มีความแม่นยำสูง โดยในงานวิจัยได้กำหนด Class เป็นอัลกอริทึมประเภทฮิวริสติกส์ที่ใช้ในการแก้ปัญหาพนักงานขาย (TSP) ที่เหมาะสม นำมาใช้ในการแก้ปัญหาการจัดลำดับเส้นทางรถที่มีความจุ โดยสามารถแสดงได้ดังตารางที่ 1

ตารางที่ 1 สรุปการกำหนด Class ให้กับอัลกอริทึมในปัญญาประดิษฐ์

ลำดับ	ชื่ออัลกอริทึม	การทำงานของอัลกอริทึมภายใน	Class
1	2-Approximate	Min spanning tree + 2_Opt	0
2	2-Optimization	2_Opt + 2_Opt	1
3	Improve Nearest	Nearest neighbor+ Reverse segment	2
4	Nearest_2Opt	Nearest insertion + 2_Opt	3
5	OR tools	Path cheapest arc	4
6	Rep Improve Nearest	Improve nearest + start dif node	5

โดยอัลกอริทึมที่นำมาเลือกใช้ในการแก้ปัญหาทั้ง 6 อัลกอริทึม มีความสามารถในการแก้ไขได้อย่างรวดเร็วและได้คำตอบที่ดี แสดงได้ดังนี้

3.2.1 อัลกอริทึม 2-Approximate

อัลกอริทึมฮิวริสติกส์ที่ผสมระหว่าง Minimum spanning tree และ 2-Optimization เนื่องจาก Minimum spanning tree เป็นการเชื่อมต่อให้ครบทุกจุดในปัญหาเพื่อให้เกิดระยะทางน้อยที่สุด และการแก้ปัญหาด้วย

2-Optimization ในลำดับถัดไป เพื่อปรับเส้นทางให้เป็นวงปิด และไม่เกิดการทับกันของเส้นทางภายในปัญหา

3.2.2 อัลกอริทึม 2-Optimization

อัลกอริทึมที่มาจากอัลกอริทึมฮิวริสติกส์ 2-Optimization เพียงอย่างเดียว แต่ใช้การแก้ไขปัญหาคด้วยอัลกอริทึมดังกล่าวจำนวนสองรอบ เนื่องจากถ้าจำนวนจุดในปัญหามีเยอะ การแก้ไขเพียงครั้งเดียวทำให้เส้นทางในปัญหาเกิดการตัดกันระหว่างเส้นทาง (Crossing path) ซึ่งทำให้ระยะทางโดยรวมในปัญหาไม่ใช่ระยะรวมที่ต่ำที่สุด

3.2.3 อัลกอริทึม Improve Nearest

อัลกอริทึมฮิวริสติกส์ที่ผสมระหว่าง Nearest neighbor และ Reverse segment โดยที่อัลกอริทึม Nearest neighbor เริ่มต้นจากจุดใดจุดหนึ่งในปัญหา แล้วทำเชื่อมเส้นทางไปยังจุดถัดไปที่อยู่ใกล้ที่สุด และทำซ้ำกระบวนการดังกล่าวจนกระทั่งครบทุกจุดในปัญหา และ Reverse segment เป็นการแก้ไขเส้นทางที่เชื่อมระหว่างจุดสองจุดใด ๆ ที่ตัดกันไม่ให้เกิดการตัดกัน เพื่อให้ระยะทางโดยรวมลดต่ำลง

3.2.4 อัลกอริทึม Nearest_2Opt

อัลกอริทึมฮิวริสติกส์ที่ผสมระหว่าง Nearest insertion และ 2-Optimization โดยที่อัลกอริทึม Nearest insertion เริ่มต้นจากเส้นทางที่เชื่อมจุดใด ๆ ในปัญหา 2 จุด จากนั้นทำการแทรกจุดใด ๆ ที่ยังไม่ได้อยู่ในเส้นทางโดยก่อให้เกิดระยะทางเพิ่มขึ้นอย่างน้อยที่สุด โดยทำซ้ำจนกระทั่งจุดทุกจุดถูกเชื่อมกันจนเสร็จสิ้น และใช้อัลกอริทึม 2-Optimization ในการปรับเส้นทางให้เส้นทางในปัญหาไม่เกิดการตัดกัน

3.2.5 อัลกอริทึม OR-tools

อัลกอริทึมที่ถูกพัฒนาโดยทีมงานของกูเกิล ซึ่งใช้อัลกอริทึม Path cheapest arc ในการแก้ปัญหา โดยเริ่มต้นจากจุดใดจุดหนึ่งในปัญหา จากนั้นทำการหาเส้นทางที่สั้นที่สุดในการเชื่อมยังไปจุดถัดไปในปัญหา ทำซ้ำจนกระทั่งครบทุกจุดในปัญหา

3.2.6 อัลกอริทึม Rep Improve Nearest

อัลกอริทึมฮิวริสติกส์ที่พัฒนามาต่อจากอัลกอริทึม Improve Nearest โดยการเลือกจุดเริ่มต้นที่ใช้ในการเชื่อมจุดทุกจุดในปัญหาให้แตกต่างกันออกไป ซึ่งจุดเริ่มต้นที่แตกต่างกัน ผลเฉลยของเส้นทางที่เกิดขึ้นย่อมแตกต่างกันออกไป โดยอัลกอริทึม Rep Improve Nearest จะทำการเลือกเส้นทางที่ให้ระยะทางรวมต่ำที่สุด และเส้นทางภายในไม่เกิดการตัดกัน

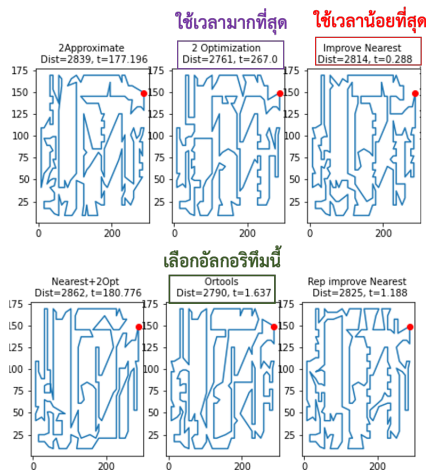
โดยที่ปัญญาประดิษฐ์ทำการเลือกอัลกอริทึมที่เหมาะสมสำหรับปัญหาใด ๆ ทำให้การแก้ไขปัญหานั้นไปอย่างรวดเร็ว และได้ผลเฉลยที่เส้นทางเป็นวงปิด ไม่มีการทับกันของเส้นทาง

3.3 ข้อมูลที่ใช้ในการฝึกฝนปัญญาประดิษฐ์

การสร้างชุดข้อมูลฝึกฝนปัญญาประดิษฐ์จำนวน 450 ชุดข้อมูลฝึกฝน โดยข้อมูลที่นำเข้ามาฝึกฝนเป็นข้อมูลจุดที่มีการกระจายตัวแบบสุ่มตั้งแต่จำนวนจุด 5 ถึง 15 จุด เพื่อเป็นการจำลองปัญหาให้กับปัญญาประดิษฐ์ใน

การแก้ไข เนื่องจากปัญหาที่มีจำนวนจุดเท่ากัน แต่ลักษณะการกระจายของจุดแตกต่างกันออกไป ย่อมส่งผลให้เส้นทางที่ทำให้เกิดระยะทางต่ำที่สุดแตกต่างกันออกไปเช่นกัน โดยทำการแบ่งข้อมูลจุดฝึกฝนออกเป็น 80% เพื่อทำการฝึกฝนปัญญาประดิษฐ์ และ 20% ของข้อมูลจุดฝึกฝนจะไว้ใช้สำหรับการทดสอบประสิทธิภาพของปัญญาประดิษฐ์ ดังนั้นจุดประสงค์ของการฝึกฝนคือต้องการให้ปัญญาประดิษฐ์ค้นหารูปแบบเชิงตัวเลข (Mathematical encoding pattern) ของปัญหาจากข้อมูลจุดฝึกฝนจำนวน 360 จุดผ่าน 13 Attributes เพื่อให้สามารถเลือก Class ที่เหมาะสมกับปัญหาได้อย่างรวดเร็ว มีความถูกต้องในการแก้ปัญหาและมีความแม่นยำที่สูง

เนื่องจากปัญญาประดิษฐ์ที่ใช้ในการจัดลำดับเส้นทางเป็นประเภทที่มีการเรียนรู้แบบมีผู้สอน (Supervised learning) หรือเป็นการเรียนรู้ที่จะต้องมีข้อมูลนำเข้าและผลลัพธ์ที่คาดหวังไว้สำหรับใช้ในการฝึกฝน ดังนั้นการกำหนดให้ปัญญาประดิษฐ์เลือกอัลกอริทึมที่เหมาะสมกับปัญหาใด ๆ โดยจะต้องเป็นอัลกอริทึมที่ให้ระยะทางรวมน้อยสุด ใช้ระยะเวลาไม่นานในการแก้ปัญหา และเส้นทางจะต้องไม่เกิดการทับกัน โดยสามารถแสดงได้ดังรูปที่ 5

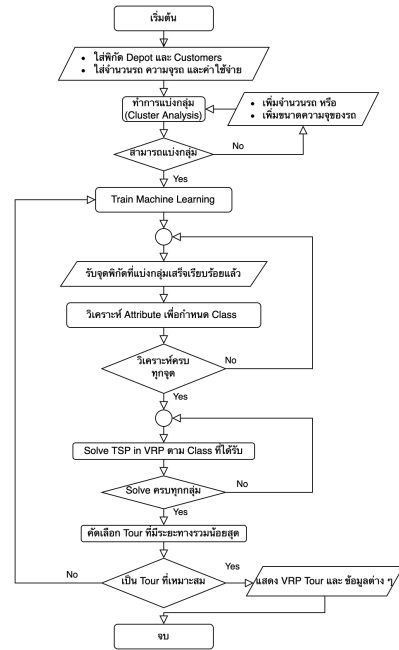


รูปที่ 5 การใช้ทั้ง 6 อัลกอริทึมในการแก้ปัญหาการจัดลำดับเส้นทาง

จากรูปที่ 5 คือการแก้ปัญหาของการจัดเส้นทางผ่านอัลกอริทึมทั้ง 6 ตัว แม้ว่าอัลกอริทึม Improve Nearest ให้ระยะเวลาในการแก้ปัญหาที่ต่ำที่สุด แต่ระยะทางรวมที่ได้มีค่าที่สูง แต่สำหรับอัลกอริทึม 2-Optimization แม้ว่าจะให้คำตอบที่มีระยะทางที่ต่ำที่สุด แต่ในทางกลับกันระยะเวลาที่ได้จากการแก้ปัญหาที่มีค่าที่สูง ดังนั้นสำหรับปัญหานี้จะกำหนดให้ปัญญาประดิษฐ์เรียนรู้ในการเลือกอัลกอริทึม OR-tools ในการแก้ปัญหาเนื่องจากใช้ระยะเวลาไม่นานมากเมื่อเทียบกับอัลกอริทึม Improve Nearest และระยะทางมีค่ามากกว่าเพียงเล็กน้อยเมื่อเทียบกับอัลกอริทึม 2-Optimization และที่สำคัญคือลักษณะของเส้นทางที่ได้จากอัลกอริทึม OR-tools เป็นเส้นทางวงปิด ไม่มีการตัดกันของเส้นทางภายในคำตอบ

3.4 วิธีการแก้ไขปัญหาการจัดลำดับเส้นทางโดยปัญญาประดิษฐ์

แผนผังระบบการทำงานของปัญญาประดิษฐ์สามารถแสดงได้ดังรูปที่ 6



รูปที่ 6 แผนผังสำหรับการทำงานของปัญญาประดิษฐ์ในการแก้ไข CVRP


3.5 การทดสอบสมรรถภาพในการแก้ไขปัญหการจัดลำดับเส้นทางของปัญญาประดิษฐ์ประเภทโครงข่ายประสาท

ในการแก้ปัญหการจัดลำดับเส้นทางยานพาหนะแบบมีความจุ (CVRP) โดยการประเมินคุณภาพของคำตอบ โดยเทียบจากชุดข้อมูลมาตรฐาน (Standard dataset) [12] ซึ่งเป็นชุดข้อมูลที่มีการแก้ปัญหการจัดลำดับเส้นทางรถแบบมีความจุที่มีผลเฉลยของชุดคำตอบที่ดีที่สุด (Optimal solution) หรือเป็นชุดคำตอบที่แก้ไขจนใกล้เคียงกับคำตอบในทางทฤษฎี


4. ผลการศึกษา

4.1 ระยะทางโดยรวมจากการจัดลำดับเส้นทางด้วยรถขนาดต่าง ๆ

การจัดลำดับเส้นทางของรถที่มีความจุในปัญหาใด ๆ ปัญหาหนึ่ง การใช้รถเพียง 1 ประเภทที่มีขนาดใหญ่ในการจัดเส้นทาง ทำให้ระยะทางรวมที่เกิดขึ้นและจำนวนรถที่ใช้ในการจัดเส้นทางน้อยกว่าการใช้รถที่มีขนาดเล็กกว่าในการจัดลำดับเส้นทาง โดยสามารถแสดงได้ดังรูปที่ 7 และรูปที่ 8



รูปที่ 7 ความสัมพันธ์ระหว่างระยะทาง จำนวนรถ และขนาดความจุของรถ



รูปที่ 8 การจัดลำดับเส้นทางโดยใช้รถขนาดใหญ่ (ซ้าย) และรถขนาดเล็ก (ขวา)

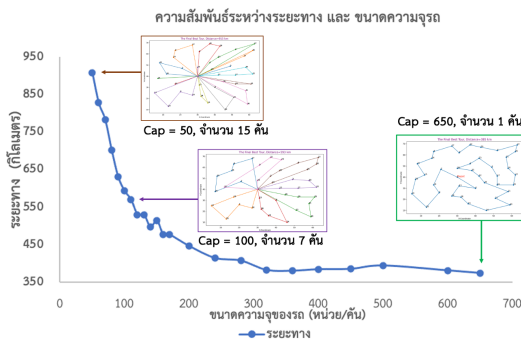
สำหรับปัญหาการจัดลำดับเส้นทางที่มีรถมากกว่า 1 ประเภท การจัดลำดับเส้นทางของรถที่มีขนาดใหญ่ก่อนการใช้รถที่มีขนาดรองลงมาทำให้ระยะทางโดยรวมที่เกิดขึ้นในปัญหามีค่าที่ต่ำลง

4.2 การประมาณระยะทางที่เกิดขึ้นจากผลเฉลยอนุพันธ์เชิงเส้น

ความสัมพันธ์ระหว่างระยะทางโดยรวมจากการจัดลำดับเส้นทางในการขนส่งโดยรถที่มีความจุ พบว่าอัตราส่วนการเปลี่ยนแปลงระยะทางโดยรวมในการจัดลำดับเส้นทางของการขนส่งเทียบกับขนาดของความจุของรถที่ใช้แปรผันโดยตรงของผลต่างของระยะทางในการจัดลำดับเส้นทางแบบ TSP และระยะทางในการจัดลำดับเส้นทางแบบ CVRP ซึ่งสามารถเขียนออกมาได้เป็นความสัมพันธ์ดังแสดงในสมการที่ (2)

$$\frac{dD}{dC} = k(D_{tsp} - D_{cvrp}) \quad (2)$$

โดยที่ dD/dC คือ อัตราส่วนการเปลี่ยนแปลงของระยะทางโดยรวมในการจัดลำดับเส้นทางของการขนส่งเทียบกับขนาดของรถที่ใช้ในการจัดลำดับเส้นทาง, k คือ ค่าคงที่ของฟังก์ชัน โดยมีค่ามากกว่าศูนย์เสมอ, D_{tsp} คือ ระยะทางในการจัดลำดับเส้นทางแบบ TSP (ระยะทางที่เกิดขึ้นทั้งหมดจากการใช้รถเพียง 1 คัน ในการจัดเส้นทางสำหรับกลุ่มลูกค้าทั้งหมดในปัญหา) และ D_{cvrp} คือ ระยะทางในการจัดลำดับเส้นทางแบบ CVRP (ระยะทางที่เกิดขึ้นทั้งหมดจากการใช้รถตั้งแต่ 2 คันเป็นต้นไป ในการจัดลำดับเส้นทางเพื่อให้ครอบคลุมลูกค้าทุกรายในปัญหา) โดยสามารถแสดงลักษณะของสมมุติฐานดังกล่าวได้ดังรูปที่ 9



รูปที่ 9 ความสัมพันธ์ระหว่างระยะทางโดยรวมที่เกิดขึ้น จากขนาดความจุของรถ

จากรูปที่ 9 สำหรับการใช้รถที่มีขนาดความจุเท่ากับ 50 หน่วย และ 100 หน่วย ใช้จำนวนรถในการจัดลำดับเส้นทางเท่ากับ 15 คัน และ 7 คัน ตามลำดับ ซึ่งระยะทางโดยรวมที่ได้จากการจัดลำดับเส้นทางดังกล่าวนี้

เป็นระยะทางโดยรวมประเภท CVRP เนื่องจากใช้จำนวนรถในการจัดลำดับเส้นทางตั้งแต่ 2 คันขึ้นไป แต่สำหรับการจัดลำดับเส้นทางที่ใช้ขนาดความจุรถเท่ากับ 650 หน่วย ใช้จำนวนรถในการจัดลำดับเส้นทางเท่ากับ 1 คัน ซึ่งระยะทางที่ได้จากการจัดลำดับเส้นทางดังกล่าว เป็นระยะทางโดยรวมประเภท TSP

การหาผลเฉลยทั่วไปของฟังก์ชันระยะทางจากการจัดลำดับเส้นทางจำเป็นต้องอาศัยเงื่อนไขทั้ง 3 เงื่อนไข เพื่อใช้ในการแก้สมการอนุพันธ์เชิงเส้น โดยประกอบไปด้วยเงื่อนไขดังต่อไปนี้

4.2.1 เงื่อนไขระยะทางจากความจุเริ่มต้น แสดงได้ดังสมการที่ (3)

$$D(C_0 = \text{Max demand}) = D_{cvrp0} \quad (3)$$


4.2.2 เงื่อนไขระยะทางจากความจุมากที่สุด แสดงได้ดังสมการที่ (4)

$$D(C_f = \text{Total demand}) = D_{tsp} \quad (4)$$

4.2.3 เงื่อนไขระยะทางลดลงครึ่งเท่า แสดงได้ดังสมการที่ (5)

$$D(C_{0.5} = 3C_0) = D_{cvrp} \quad (5)$$

โดยที่ C_0, C_f คือ ขนาดความจุของรถต่ำสุดและขนาดความจุมากที่สุดที่สามารถจัดลำดับเส้นทางได้ ตามลำดับ และ D_{cvrp}, D_{tsp} คือ ระยะทางรวมที่เกิดขึ้นประเภท CVRP และ TSP ตามลำดับ โดยเงื่อนไขทั้ง 3 เงื่อนไขสามารถแสดงได้ดังรูปที่ 10



รูปที่ 10 เงื่อนไขทั้ง 3 เงื่อนไข เพื่อใช้ในการแก้สมการอนุพันธ์เชิงเส้น

การแก้สมการอนุพันธ์เชิงเส้น โดยใช้วิธีการหาตัวประกอบตัวปริพันธ์ที่เหมาะสม ซึ่งได้ผลเฉลยทั่วไปดังแสดงในสมการที่ (6)


$$D(c) = D_{tsp} + Ae^{-kc} \quad (6)$$

โดยที่ c คือ ขนาดความจุของรถที่ใช้ในการจัดลำดับเส้นทางขนาดใด ๆ สำหรับ A และ k เป็นค่าคงที่ แสดงได้ดังสมการที่ (7) และ (8) ตามลำดับ

$$k = \frac{1}{C_{0.5} - C_0} \ln \left(\frac{D_{cvrp0} - D_{tsp}}{D_{cvrp} - D_{tsp}} \right) \quad (7)$$

$$A = (D_{cvrp0} - D_{tsp}) e^{kc_0} \quad (8)$$

ผลเฉลยทั่วไปของอนุพันธ์เชิงเส้น สามารถให้ผลในการประมาณระยะทางที่เกิดขึ้นใด ๆ จากขนาดความจุใด ๆ ที่ใช้ในการจัดลำดับเส้นทางได้ดี โดยสามารถแสดงได้ดังรูปที่ 11




รูปที่ 11 ความสัมพันธ์ระหว่างระยะทางอันเนื่องมาจากความจุของรถ โดยเปรียบเทียบระหว่างระยะทางจากปัญหาประติษฐ์ และผลเฉลยอนุพันธ์เชิงเส้น

จากรูปที่ 11 พบว่าปัญหาใด ๆ ของการจัดเส้นทางการเดินรถที่มีความจุด้วยรถที่มีขนาดเล็กยอมทำให้ระยะทางโดยรวมมีค่าที่สูงกว่าการใช้รถที่มีขนาดใหญ่กว่า และในช่วงแรกการเปลี่ยนจากรถขนาดเล็กไปเป็นรถที่มีขนาดใหญ่ขึ้นเพียงเล็กน้อยทำให้การลดลงของระยะทางโดยรวมมีมาก แต่เมื่อรถที่มีขนาดใหญ่ในระดับหนึ่ง การใช้รถที่มีขนาดใหญ่เพิ่มขึ้นอีก ระยะทางโดยรวมที่ลดลงกลับไม่ได้ลดลงมากเหมือนในช่วงแรก ซึ่งสอดคล้องไปกับกฎผลตอบแทนลดน้อยถอยลง (Diminishing return)

4.3 การประมาณจำนวนรถที่ใช้จากผลเฉลยอนุพันธ์เชิงเส้น

จำนวนรถทั้งหมดที่ใช้ในการจัดลำดับเส้นทางในปัญหา สามารถแยกพิจารณาได้ 2 กรณีคือ กรณีที่ใช้รถที่มีความจุน้อยกว่าปริมาณสินค้ารวมทั้งหมดในปัญหา ซึ่งจำนวนรถที่ใช้ในการจัดลำดับเส้นทางมีจำนวนมากกว่าหรือเท่ากับ 2 คันเป็นต้นไป และ กรณีใช้รถที่มีความจุมากกว่าหรือเท่ากับปริมาณสินค้ารวมทั้งหมดในปัญหา จำนวนรถที่ใช้ในการจัดลำดับเส้นทางมีจำนวนเท่ากับ 1 คัน เนื่องจากขนาดความจุรถเพียงพอต่อการรองรับสินค้าครบทุกจุดในปัญหา ซึ่งสามารถแสดงได้ดังในรูปที่ 12 และจำนวนของรถที่ใช้ในการจัดลำดับเส้นทางมีแนวโน้มลดลงเมื่อใช้รถที่มีขนาดใหญ่ขึ้น โดยผลเฉลยของจำนวนรถสามารถเขียนออกมาได้ดังแสดงในสมการที่ (9)



รูปที่ 12 จำนวนรถที่ใช้ในการจัดลำดับเส้นทาง

ผลเฉลยของจำนวนรถที่ใช้ในการจัดลำดับเส้นทาง

$$N(c) = \begin{cases} N_{tsp} + Qe^{-sc} + 1, & c < T.D \\ N_{tsp}, & c \geq T.D \end{cases} \quad (9)$$

โดยที่ $N(c)$ คือ จำนวนรถที่ใช้ที่เป็นฟังก์ชันโดยตรงกับขนาดความจุของรถ, N_{tsp} คือ จำนวนรถที่ใช้ในการจัดเส้นทางแบบ TSP โดยปรกติมีค่าเท่ากับ 1 คัน, c คือ ขนาดความจุของรถ, $T.D$ คือ Total demand, Q และ s คือค่าคงที่ แสดงได้ในสมการที่ (10) และ (11) ตามลำดับ

$$Q = (N_{cvrp} - N_{tsp} - 1)e^{sc_0} \quad (10)$$

$$s = \frac{1}{c_{0.5} - c_0} \ln \left(\frac{N_{cvrp_0} - N_{tsp} - 1}{N_{cvrp} - N_{tsp} - 1} \right) \quad (11)$$

การคำนวณค่าคงที่ Q และ s ประกอบไปด้วยเงื่อนไข 3 เงื่อนไขดังต่อไปนี้

4.3.1 เงื่อนไขจำนวนรถจากความจุเริ่มต้น แสดงได้ดังสมการที่ (12)

$$N(C_0) = N_{cvrp_0} \quad (12)$$

4.3.2 เงื่อนไขจำนวนรถจากความจุที่ทำให้ระยะทางลดลงครึ่งหนึ่งจากการใช้ขนาดความจุเริ่มต้น แสดงได้ดังสมการที่ (13)


$$N(C_{0.5} = 3C_0) = N_{cvrp} \quad (13)$$

4.3.3 เงื่อนไขจำนวนรถจากความจุมากสุด แสดงได้ดังสมการที่ (14)

$$N(C_f) = N_{tsp} \quad (14)$$

โดยที่ N_{cvrp} , N_{tsp} คือ จำนวนรถที่ใช้ทั้งหมดในการจัดลำดับเส้นทางแบบ CVRP และ TSP ตามลำดับ

ผลเฉลยทั่วไปของสมการอนุพันธ์เชิงเส้น สำหรับการประมาณจำนวนรถที่ใช้ในการจัดลำดับเส้นทาง จากขนาดความจุของรถที่ใช้ใด ๆ สามารถให้ผลการประมาณที่ดี โดยสามารถแสดงได้ดังในรูปที่ 13




รูปที่ 13 การประมาณจำนวนรถที่ใช้ในการจัดลำดับเส้นทางจากผลเฉลยอนุพันธ์เชิงเส้นอันดับที่หนึ่ง

4.4 การเลือกขนาดและจำนวนรถที่เหมาะสม เพื่อทำให้เกิดต้นทุนต่ำสุด

การเลือกขนาดรถที่เหมาะสมกับปัญหา ภายใต้งบประมาณที่จำกัด จะต้องเป็นเส้นตรงที่สัมผัสกับผลเฉลยอนุพันธ์เชิงเส้นของระยะทางที่เกิดขึ้น

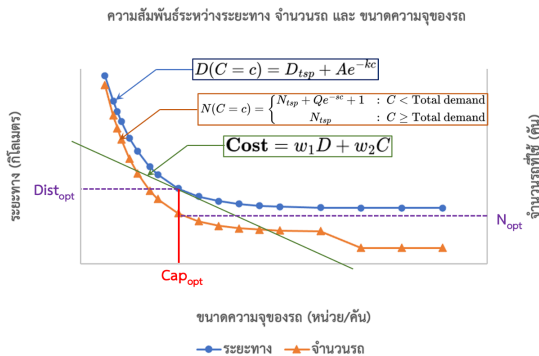
ที่สัมพันธ์กับขนาดความจุของรถ โดยจุดที่สัมพันธ์กันเป็นเขตคำตอบของปัญหาที่เหมาะสมทำให้เกิดต้นทุนต่ำสุด โดยเรียกจุดคำตอบดังกล่าวว่าเป็นจุดที่เหมาะสม (Optimal point) เนื่องจากจุดที่เหมาะสมอยู่บนเส้น Isocost (เส้นที่มีระดับของค่าใช้จ่าย หรือต้นทุนที่เท่ากันตลอดทั้งเส้น) ที่ต่ำที่สุด โดยค่าใช้จ่ายที่นำมาใช้ในการพิจารณาประกอบไปด้วยต้นทุนเฉลี่ยการดำเนินงาน (หน่วยเงินต่อหนึ่งหน่วยระยะทาง, w_1) และต้นทุนเฉลี่ยของสินค้า (หน่วยเงินต่อหนึ่งหน่วยสินค้า, w_2) สามารถแสดงได้ดังในรูปที่ 14



รูปที่ 14 จุดที่เหมาะสมอยู่บนเส้นที่มีระดับต้นทุนต่ำสุด

จากรูปที่ 14 พบว่าจุดที่เหมาะสมเกิดขึ้นที่ตำแหน่ง B ซึ่งเป็นจุดที่อยู่บนเส้นที่มีระดับต้นทุนต่ำสุด และสำหรับจุด A และ C แม้ว่าจะจะเป็นคำตอบที่อยู่บนเส้นของผลเฉลยอนุพันธ์เชิงเส้นที่แตกต่างกัน แต่ระดับต้นทุนทั้งจุด A และจุด C ล้วนมีระดับต้นทุนที่เท่ากัน ซึ่งจุด A และจุด C ทั้ง 2 จุดนี้ล้วนให้ระดับต้นทุนที่สูงกว่าจุดที่เหมาะสมทั้งสิ้น และสำหรับเส้น $Cost_3$ ไม่จัดเป็นคำตอบเนื่องจาก เป็นเส้นที่ไม่ตัดกับผลเฉลยอนุพันธ์เชิงเส้น แม้ว่าจะ เป็นเส้นที่มีระดับต้นทุนต่ำที่สุด

จุดที่เหมาะสมที่จากจุดที่อยู่เส้นที่มีระดับต้นทุนต่ำสุดประกอบไปด้วยระยะทางโดยรวมที่เหมาะสม (D_{opt}) และขนาดความจุรถที่เหมาะสม (C_{opt}) ซึ่งสามารถนำไปสู่การพิจารณาถึงจำนวนรถที่เหมาะสมสำหรับการจัดลำดับเส้นทาง เนื่องจากผลเฉลยอนุพันธ์เชิงเส้นสำหรับการประมาณจำนวนรถที่ใช้ในการจัดลำดับเส้นทางเป็นฟังก์ชันของความจุของรถที่ใช้ในการจัดลำดับเส้นทางด้วยเช่นกัน ดังนั้น ด้วยขนาดความจุรถที่เหมาะสมจากเขตคำตอบจากจุดที่เหมาะสม สามารถนำไปสู่การประมาณจำนวนรถที่เหมาะสมได้ โดยสามารถแสดงได้ดังในรูปที่ 15



รูปที่ 15 การเลือกขนาดความจุของรถที่เหมาะสม และ จำนวนรถที่เหมาะสมในการจัดลำดับเส้นทาง

4.4.1 ค่าใช้จ่ายต่ำสุดสุทธิ (Net cost, N.C)

การจัดลำดับเส้นทางด้วยรถเพียง 1 ประเภทเพื่อให้เกิดต้นทุนต่ำที่สุดภายใต้ต้นทุนเฉลี่ยการดำเนินงาน และต้นทุนเฉลี่ยของสินค้า โดยค่าใช้จ่ายสุทธิที่เกิดขึ้น สามารถเขียนได้ดังสมการที่ (15)

$$N.C = w_1 D_{opt} + N_{opt} w_2 C_{opt} \quad (15)$$

โดยสามารถแบ่งได้เป็น 2 กรณีคือ กรณีที่ความจุเหมาะสมของรถน้อยกว่า Total demand ซึ่ง Net cost สามารถแสดงได้ดังสมการที่ (16)


$$N.C = w_1 D_{tsp} + \frac{1}{k} w_2 \ln \left(e \left(\frac{Akw_1}{w_2} \right)^{N_{tsp} + Q} \left(\frac{w_2}{Akw_1} \right)^{s/k} + 1 \right) \quad (16)$$

กรณีที่ความจุเหมาะสมของรถมากกว่าหรือเท่ากับ Total demand ซึ่ง Net cost สามารถแสดงได้ดังสมการที่ (17)

$$N.C = w_1 D_{tsp} + \frac{1}{k} w_2 \ln \left(e \left(\frac{Akw_1}{w_2} \right)^{N_{tsp}} \right) \quad (17)$$

4.5 ความแม่นยำของปัญหาประดิษฐ์ในการเลือกอัลกอริทึมสำหรับการแก้ไขปัญหการจัดลำดับเส้นทางของรถที่มีความจุ

การสร้างปัญหาประดิษฐ์ประเภทโครงข่ายประสาทเทียม สามารถแสดงออกมาในลักษณะของ Confusion matrix เพื่อแสดงความแม่นยำในการเลือกอัลกอริทึมที่เหมาะสม จากอัลกอริทึมที่แก้ปัญหา TSP ทั้งสิ้น 6 อัลกอริทึม โดยสามารถแสดงได้ดังในรูปที่ 16



รูปที่ 16 Confusion matrix เพื่อพิจารณาความแม่นยำในการเลือกอัลกอริทึมของปัญหาประดิษฐ์

จากรูปที่ 16 การทดสอบประสิทธิภาพของปัญหาประดิษฐ์มีความแม่นยำในการคัดเลือกอัลกอริทึมที่เหมาะสมกับปัญหาถึง 95% โดยตัวเลขที่อยู่ในแนวเส้นทแยงมุมของเมทริกซ์คือจำนวนปัญหาที่ปัญหาประดิษฐ์สามารถเลือกอัลกอริทึมที่เหมาะสม (Predicted class) ได้อย่างถูกต้องเมื่อเทียบกับอัลกอริทึมที่ได้ทำเลือกไว้ตั้งแต่ในชุดข้อมูลการฝึกฝน (Actual class) ซึ่งแสดงให้เห็นว่าปัญหาประดิษฐ์มีความสามารถในการเรียนรู้และสามารถเลือกอัลกอริทึมที่เหมาะสมในการจัดลำดับเส้นทางเมื่อมีปัญหการจัดเส้นทางใหม่ ๆ ได้อย่างมีประสิทธิภาพถึง 95%

4.6 ประสิทธิภาพการใช้ปัญหาประดิษฐ์ในการแก้ไขปัญหการจัดลำดับเส้นทาง

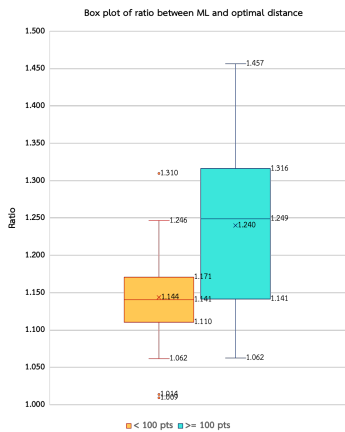
ในการทดสอบประสิทธิภาพของปัญญาประดิษฐ์ที่ไว้สำหรับการแก้ไข ปัญหาการจัดลำดับเส้นทาง ผู้วิจัยได้ทำการทดสอบประสิทธิภาพเทียบกับ ชุดข้อมูลมาตรฐานที่มีการแก้ไขปัญหานั้นได้คำตอบที่ใกล้เคียงหรือเทียบเท่ากับทฤษฎี โดยในการทดสอบประสิทธิภาพ สามารถแบ่งออกได้เป็น 2 การทดสอบดังต่อไปนี้

4.6.1 การทดสอบระยะทางที่ได้จากปัญญาประดิษฐ์เมื่อเทียบกับ ระยะทางจากชุดข้อมูลมาตรฐาน

ในการทดสอบระยะทางที่เกิดขึ้น กำหนดให้พิจารณาจากสัดส่วน ระยะทาง จากจำนวน 98 ชุดตัวอย่าง โดยสามารถแสดงได้ดังสมการที่ (18)

$$ratio = \frac{D_{ML}}{D_{op}} \quad (18)$$

โดยที่ *ratio* คือ อัตราส่วน ซึ่งมีค่ามากกว่าหรือเท่ากับ 1 เสมอ, D_{ML} คือ ระยะทางรวมที่ได้จากปัญญาประดิษฐ์ และ D_{op} คือ ระยะทางรวมที่ได้ จากชุดข้อมูลมาตรฐาน (Optimal solution)



รูปที่ 17 Box plot ของอัตราส่วนระหว่างระยะทางจากปัญญาประดิษฐ์และชุด ข้อมูลมาตรฐาน


จากรูปที่ 17 ได้แยกพิจารณาออกเป็นอีก 2 กลุ่มคือ กลุ่มที่ปัญหา มีจำนวนลูกค้าน้อยกว่า 100 ราย และกลุ่มที่มีจำนวนลูกค้าตั้งแต่ 100 ราย เป็นต้นไป พบว่ากลุ่มปัญหาที่มีจำนวนลูกค้าน้อยกว่า 100 ราย ปัญญาประดิษฐ์สามารถแก้ไขปัญหการจัดลำดับเส้นทางและให้ระยะทาง รวมที่มากกว่าชุดข้อมูลมาตรฐานเฉลี่ยอยู่ไม่เกิน 17% ภายใต้ระดับความ เชื่อมั่น 95% และสำหรับกลุ่มที่มีจำนวนลูกค้ามากกว่า 100 รายขึ้นไป ระยะที่ทางรวมได้จากปัญญาประดิษฐ์มีค่ามากกว่าระยะทางจากชุดข้อมูล มาตรฐานอยู่เฉลี่ยที่ 24%

4.6.2 การทดสอบจำนวนรถที่ใช้จากปัญญาประดิษฐ์เมื่อเทียบกับชุด ข้อมูลมาตรฐาน

ในการทดสอบจำนวนรถที่ใช้ กำหนดให้พิจารณาจากความแตกต่าง โดย สามารถแสดงได้ดังสมการที่ (19)

$$\Delta = Veh_{ML} - Veh_{op} \quad (19)$$

โดยที่ Δ คือ ความแตกต่างระหว่างจำนวนรถ ซึ่งมีค่ามากกว่าหรือ เท่ากับศูนย์, Veh_{ML} คือ จำนวนรถที่ใช้ในการจัดลำดับเส้นทางจาก ปัญญาประดิษฐ์ และ Veh_{op} คือ จำนวนรถที่ใช้ในการจัดลำดับเส้นทางจาก ชุดข้อมูลมาตรฐาน จากการทดสอบกับชุดข้อมูลมาตรฐานสำหรับการ ทดสอบจำนวนรถที่ใช้ จำนวนทั้งสิ้น 135 ชุดตัวอย่าง สามารถแสดงได้ดังใน รูปที่ 18




รูปที่ 18 จำนวนรถที่แตกต่างกันจากปัญญาประดิษฐ์และชุดข้อมูลมาตรฐาน

จากการทดสอบจำนวนรถที่ได้จากปัญญาประดิษฐ์ พบว่า 97.04% ให้ จำนวนรถที่ใช้ในการจัดลำดับเส้นทางเท่ากับจำนวนรถที่ใช้ในทางทฤษฎี ($\Delta=0$) ต่อมา มี 2.22% ที่จำนวนรถที่ใช้ในการจัดลำดับเส้นทางมากกว่า จำนวนรถในทางทฤษฎีอยู่ 1 คัน ($\Delta=1$) และสุดท้ายมีอยู่ 0.74% ที่ใช้ จำนวนรถในการจัดลำดับเส้นทางมากกว่าจำนวนรถในทางทฤษฎีมากกว่า 1 คัน เป็นต้นไป โดยส่วนใหญ่กรณีที่จำนวนรถที่ใช้ในการจัดลำดับเส้นทางจาก ปัญญาประดิษฐ์มากกว่าจำนวนรถในทางทฤษฎีมากกว่า 1 คัน เป็นต้นไป จะ เกิดขึ้นเมื่อแก้ปัญหามาเป็นปัญหาที่มีจำนวนจุดตั้งแต่ 100 เป็นต้นไป แต่สำหรับ ปัญหาที่มีจำนวนจุดน้อยกว่า 100 จุด จำนวนรถที่ใช้ในการจัดลำดับเส้นทาง ใช้จำนวนรถเท่ากับจำนวนรถที่ใช้ในการจัดลำดับเส้นทางในทางทฤษฎี

4.7 ระยะเวลาที่ใช้ในการแก้ปัญหาการจัดลำดับเส้นทางของรถที่มีความจุ

ระยะเวลาในการแก้ปัญหาด้วยปัญญาประดิษฐ์ ใช้เวลามากขึ้นตาม จำนวนจุดในปัญหาเป็นหลัก โดยสามารถแสดงได้ดังในรูปที่ 19



รูปที่ 19 ความสัมพันธ์ระหว่างระยะเวลาในการแก้ปัญหาการจัดลำดับเส้นทาง และจำนวนจุดในปัญหา

จากรูปที่ 19 ได้แสดงให้เห็นถึงแนวโน้มของระยะเวลาในการแก้ปัญหาที่ เพิ่มขึ้นตามจำนวนจุดในปัญหา โดยลักษณะการเพิ่มขึ้นของเวลาที่ใช้ในการ แก้ปัญหาเป็นลักษณะของฟังก์ชันเอกซ์โพเนนเชียล แต่อย่างไรก็ตาม ระยะเวลาที่ใช้ในการแก้ปัญหาโดยเฉลี่ยต่ำกว่า 60 วินาที ที่จำนวนจุดปัญหา ไม่เกิน 200 จุด

4.8 ข้อจำกัดในการจัดลำดับเส้นทางด้วยปัญญาประดิษฐ์

ระยะเวลาที่ใช้การแก้ปัญหาของการจัดลำดับเส้นทางของการขนส่งของรถที่มีความจุด้วยปัญญาประดิษฐ์มีการเพิ่มขึ้นแบบเอกซ์โพเนนเชียล ทำให้ปัญหาที่มีจำนวนจุดมาก จำเป็นต้องใช้ระยะเวลาในการแก้ปัญหาเพิ่มขึ้นอย่างมาก แม้ว่าจะสามารถแก้ไขปัญหามี 200 จุดภายในระยะเวลา 60 วินาที แต่เมื่อจำนวนจุดเพิ่มขึ้นเป็น 550 จุด การแก้ไขใช้เวลาถึง 60 นาทีในการแก้ปัญหา สำหรับระยะทางโดยรวมจากการจัดลำดับเส้นทางเป็นการรวมการกระจัดระหว่างจุดสองจุดที่เชื่อมกัน เนื่องจากถ้าหากคำนวณเป็นระยะทางจริงระหว่างจุดสองจุด จำเป็นต้องสร้างเมทริกซ์ระหว่างจุดทุกจุดในปัญหา ทำให้ไม่สามารถแก้ไขปัญหามีขนาดใหญ่ได้อันเนื่องจากข้อจำกัดด้านหน่วยความจำของคอมพิวเตอร์ และการจัดลำดับเส้นทางของปัญญาประดิษฐ์ปริมาณความต้องการของสินค้าคงที่ไม่มีมีการแปรเปลี่ยนไปตามเวลาหรือเป็นปัญหาที่ไม่มีพลวัต (Non dynamic problem)

5. สรุปผลการศึกษา

การแก้ปัญหการจัดเส้นทางรถที่มีความจุด้วยปัญญาประดิษฐ์ประเภทโครงข่ายประสาท การจัดกลุ่มของลูกค้าในปัญหาจัดออกเป็นกลุ่มย่อยด้วยอัลกอริทึมการกวาดมุม ลูกค้าภายในกลุ่มของแต่ละกลุ่มถูกจัดลำดับเส้นทางรถด้วยอัลกอริทึมที่เหมาะสมจาก 6 อัลกอริทึมโดยปัญญาประดิษฐ์ สำหรับช่วยในการวางแผนเส้นทางรถจากกรณีที่ผู้ประกอบการมีอยู่ โดยใช้รถขนาดใหญ่จัดเส้นทางก่อนรถขนาดเล็กกรณีที่ผู้ประกอบการมีรถมากกว่า 1 ประเภท เพื่อให้เกิดระยะทางโดยรวมอย่างต่ำที่สุด โดยมีความแม่นยำในการเลือกอัลกอริทึมที่ดีถึง 95% ระยะทางที่ได้จากปัญญาประดิษฐ์มากกว่าระยะทางจากทฤษฎีอยู่เฉลี่ยไม่เกิน 17% จำนวนรถที่ใช้ในการจัดลำดับเส้นทางเท่ากับจำนวนรถในทางทฤษฎี สำหรับปัญหาที่มีจำนวนน้อยกว่า 100 จุด ปัญญาประดิษฐ์สามารถจัดเส้นทางได้อย่างรวดเร็วภายในระยะเวลา 60 วินาที สำหรับปัญหาที่มีน้อยกว่า 200 จุด และการวางแผนผังรถภายใต้ข้อจำกัดด้านต้นทุนค่าใช้จ่ายดำเนินงานสามารถพิจารณาได้จากทางเลือกขนาดรถโดยเป็นรถที่มีเพียงหนึ่งขนาดและจำนวนรถที่ใช้ในการจัดเส้นทางเหมาะสมในปัญหาของการขนส่งสินค้าผ่านผลเฉลยอนุพันธ์เชิงเส้น ซึ่งปัญญาประดิษฐ์เข้ามาช่วยในการวางแผนเส้นทางเพื่อหาลำดับเส้นทางของการขนส่งของลูกค้าในแต่ละกลุ่มภายใต้จำนวนรถ และขนาดรถที่เหมาะสม เพื่อให้เกิดต้นทุนการขนส่งต่ำที่สุด

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณอาจารย์ที่ปรึกษา รศ.ดร.มาโนช โลหเตปานนท์ ผู้อำนวยการสถาบันขนส่ง ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์วิทยาลัย ที่ช่วยให้คำปรึกษาและคำแนะนำที่ทำให้งานวิจัยนี้สามารถลุล่วงได้เป็นอย่างดีและได้งานวิจัยที่มีคุณภาพ

เอกสารอ้างอิง

[1] เกียรติกุลไชย จิตต์เอื้อ (2560). ปัญหาการจัดเส้นทางรถขนส่งภายใต้ความไม่แน่นอนของอุปสงค์. *วารสารวิชาการนายเรืออากาศ*, ปีที่ 13, ฉบับที่ 13, หน้า 20-24.

[2] ธารชุตดา พันธนิกุล, กนกกอร์ โรหิตะ และ รุ่งฤดี บัวศรียอด (2554). การลดต้นทุนในการจัดเส้นทางรถขนส่งด้วยแบบจำลองคณิตศาสตร์กรณีศึกษา : โรงงานอุบลอควาริส จ.อุบลราชธานี. *การประชุมวิชาการด้านการวิจัยดำเนินงานแห่งชาติ ประจำปี 2554*, โรงแรม เอส ดี อเวนิว กรุงเทพมหานคร, 8-9 กันยายน 2554, หน้า 60-64

[3] Furian, N., O'Sullivan, M., Walker, C. and Cela, E. (2021). A machine learning-based branch and prices algorithm for a sampled vehicle routing problem. *Springer*. pp. 694-732.

[4] Reinelt, G. (1994). *The Travelling Salesman Computation Solutions for TSP Application*. Springer-Verlag Berlin Heidelberg, pp.10-12.

[5] Yang, X. and Zhu, S. (2016). Solution to the Multidepot Inventory Slack-Routing Problem at the Planning Stage. *Journal of Computing in Civil Engineering*.

[6] Shokouhifar, M., Jalali, A. and Torfehnejad, H. (2015). Optimal Routing in Traveling Salesman Problem using Artificial Bee Colony and Simulated Annealing, *1st National Road ITS Congress*, Tehran, Iran, January 2015, pp.1-7

[7] Luca, A., Andrea, L. and Daniele V. (2022). Guidelines for the computational testing of machine learning approaches to vehicle routing problems. *Operations Research Letters*, Volume 50, pp.229-234.

[8] Cooray, P. and D. Thashika, R. (2017). Machine learning-based parameter turned genetic algorithm for energy minimizing vehicle routing problem. *Journal of Industrial Engineering*, ISSN 2314-4882, pp.1-10.

[9] Bai, R., Chen, X., Chen, Z., Cui, T., Gong, S., He, W., Jiang, X., Jin, H., Jin, J. and Kendall, G. (2021). Analytics and machine learning in vehicle routing research. *International Journal of Production Research*, ISSN 0020-7543, pp.1-27.

[10] Joe, W. and Lau, H. (2020). Deep reinforcement learning approach to solve dynamic vehicle routing problem with stochastic customers. *Proceedings of the international Conference on Automated Planning and Scheduling*, 30, pp.394-402.

[11] Nazari, M., Oroojlooy, A., Snyder, L. and Takác, M. (2018). Reinforcement learning for solving the vehicle routing problem. *Advance in neural information processing systems*, 31, pp.1-10.

[12] Pessoa, A., Sadykov, R., Uchoa, E. and Vanderbeck, F. (2020). A genetic exact solver for vehicle routing and related problems. *Mathematical Programming*, 183, pp.483-523.