

การทำนายปริมาณการใช้เชื้อเพลิงขนส่งด้วยโครงข่ายประสาทเทียม กรณีศึกษา
รถบรรทุกดินถมในพื้นที่จังหวัดชายแดนใต้ ประเทศไทย*

Prediction of Transport Fuel Consumption by Artificial Neural Network:
A Case Study of Land Reclamation Trucks in the Southern Border
Provinces, Thailand

ธนรัตน์ รัตนกุล¹ และกัณฑ์ธมน สุขกระจ่าง

Tanarat Rattanakool and Kantamon Sukrajang

คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏสงขลา

Faculty of Industrial Technology, Songkhla Rajabhat University.

Email : tanarat.ra@skru.ac.th, kantamon.su@skru.ac.th

วันที่รับ 14 มีนาคม 2565 วันที่แก้ไข 7 เมษายน 2566 วันที่ตอบรับ 19 เมษายน 2566

บทคัดย่อ

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพการทำนายเชื้อเพลิงขนส่งด้วยโครงข่ายประสาทเทียมด้วยค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (MAPE) เริ่มจากการนำข้อมูลปริมาณการใช้เชื้อเพลิงขนส่งรายเดือน ตั้งแต่ปี พ.ศ.2556 - 2560 มาทำนายปริมาณการใช้เชื้อเพลิงด้วยฟังก์ชันถ่ายโอน 3 รูปแบบ คือ แบบซิกมอยด์ แบบไปโพล่าซิกมอยด์ และแบบไฮเปอร์โบลิค-แทนเจนต์ โดยแต่ละฟังก์ชันการถ่ายโอนจะมีการแบ่งโครงข่ายประสาทเทียม ออกเป็น 9 โครงสร้าง คือ ชั้นนำเข้า (input layer) จำนวน 12 โหนด ชั้นซ่อน (hidden layer) ระหว่าง 4 ถึง 12 โหนด และชั้นส่งออก (output layer) จำนวน 1 โหนด ที่สัมพันธ์กับข้อมูลแบบอนุกรมเวลา รวมทั้งสิ้น 27 โครงสร้าง เพื่อใช้ในการประเมินความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิง โดยกำหนดอัตราการเรียนรู้ เท่ากับ 0.05 โมเมนต์ดัม เท่ากับ 0.5 และจำนวนรอบการเรียนรู้ เท่ากับ 100,000 รอบ พบว่า โครงข่ายประสาทเทียมแบบ ANN (12-8-1) ด้วยฟังก์ชันการถ่ายโอนแบบไฮเปอร์โบลิค-แทนเจนต์ ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำที่สุด 0.03 เปอร์เซนต์ จากผลการทดลองนี้สามารถนำไปใช้เป็นข้อเสนอแนะให้บริษัทกรณีศึกษาใช้ในการวางแผนใช้เชื้อเพลิงอย่างมีประสิทธิภาพ รวมไปถึงการนำแนวทางจากการวิจัยนี้ไปใช้ในการปรับปรุงประสิทธิภาพทำนายข้อมูลที่น่าสนใจในภาคอุตสาหกรรมอื่น ๆ ได้ต่อไป

คำสำคัญ: ประสิทธิภาพ, การทำนาย, โครงข่ายประสาทเทียม, เชื้อเพลิง

*บทความวิจัยนี้ได้นำเสนอในที่ประชุมวิชาการระดับชาติเทคโนโลยีภาคใต้ครั้งที่ 13 ประจำปีการศึกษา 2565 Nouveau Economy for Human Security : เศรษฐกิจใหม่เพื่อความมั่นคงของมนุษย์ ณ วิทยาลัยเทคโนโลยีภาคใต้ จ.นครศรีธรรมราช เมื่อวันที่ 2 มีนาคม 2566

*This research was presented at the 13th SCT Conference : Nouveau Economy for Human Security at Southern Technological College, Nakhon Si Thammarat, Thailand, November 2nd , 2023.

Abstract

The purpose of this research is to compare the transport fuel prediction performance by an artificial neural network with the MAPE. The monthly transportation fuel consumption data from 2013 to 2017 were used to estimate fuel consumption using three transfer functions: sigmoid, bipolar sigmoid, and hyperbolic-tangent. Each transfer function will divide the neural network into 9 structures, namely, input layer (12 nodes), hidden layer (between 4 to 12 nodes), and output (layer 1 node) that is related to time series data, totaling 27 structures to be used to assess the MAPE for fuel consumption predicted. The learning rate was 0.05, the momentum was 0.5, and the number of iterations was 100,000. It was found that an ANN (12-8-1) neural network with a hyperbolic-tangent transfer function has the lowest as 0.03 percent of MAPE. The study's findings may be used to create case studies for businesses wishing to enhance their fuel economy. This includes using the suggestions from this study to increase the accuracy of predicting data of relevance in other sectors.

Keywords: Performance, Prediction, Artificial Neural Network, Fuel

บทนำ

ปริมาณการใช้เชื้อเพลิงเป็นปัญหาที่สำคัญในประเทศไทย เนื่องจากประเทศไทยพึ่งพาเชื้อเพลิงฟอสซิลนำเข้าอย่างมากเพื่อตอบสนองความต้องการด้านพลังงาน ภาพรวมการใช้น้ำมันเชื้อเพลิงเฉลี่ยต่อวันเดือนมกราคม 2565 เพิ่มขึ้นเมื่อเทียบกับช่วงเดียวกันของปีก่อน กลุ่มดีเซลเพิ่มขึ้นร้อยละ 24.4 (Bangkokbiznews, 2022) อีกทั้งแนวโน้มภาคขนส่งทางถนนช่วงปี 2565-2567 มีแนวโน้มเติบโตเฉลี่ย 3-5% ต่อปี ด้วยปัจจัยส่งเสริมจากการเติบโตของภาคอุตสาหกรรมการผลิต การค้า การเกษตร การค้าชายแดน และการค้าออนไลน์ซึ่งเป็นที่ยอมรับมากขึ้น ซึ่งรวมไปถึงภาคขนส่งทางอากาศที่ได้รับความนิยมจากการลงทุนโครงสร้างพื้นฐานภาครัฐที่มีการขยายตัวเพิ่มสูงขึ้น (Piyanuch Sathapongpakdee, 2022) โดยเฉพาะอย่างยิ่งพื้นที่จังหวัดชายแดนภาคใต้ของประเทศไทยที่ประกอบด้วย นราธิวาส ปัตตานี และยะลา จังหวัดเหล่านี้เป็นที่รู้จักในด้านกิจกรรมทางเศรษฐกิจที่สำคัญโดยดัชนีความเชื่อมั่นจังหวัดชายแดนใต้ ไตรมาสที่ 3 ปี 2565 ปรับตัวดีขึ้นมาอยู่ที่ระดับ 53.77 เป็นผลจากความเชื่อมั่นด้านเศรษฐกิจและความเชื่อมั่นด้านสังคมที่ปรับตัวดีขึ้น (Southern Border Provinces Administration Centre, 2022) ส่งผลเกิดการลงทุนในด้านโครงสร้างพื้นฐาน เช่น ถนน และระบบสาธารณูปโภคต่าง ๆ เพิ่มมากขึ้น จึงต้องอาศัยวัสดุในการก่อสร้างที่หลากหลาย เช่น ดิน ทราย วัสดุก่อสร้างที่สำคัญในการปรับปรุงสภาพพื้นผิวและก่อสร้างถนน เป็นโครงสร้างพื้นฐานที่สำคัญต่อขยายตัวทางพื้นที่เศรษฐกิจพื้นที่ชายแดนใต้

ส่งผลให้ภาคขนส่งที่เกี่ยวข้องกับวัสดุก่อสร้างต่าง ๆ ดังกล่าว ต้องให้ความสำคัญกับวางแผนใช้เชื้อเพลิงในการขนส่งอย่างมีประสิทธิภาพ ด้วยการอาศัยโครงข่ายประสาทเทียม (Artificial Neural Network :ANNs) มาใช้ในการทำนายปริมาณการใช้เชื้อเพลิงขนส่งและเพิ่มประสิทธิภาพของการใช้เชื้อเพลิงในการลดต้นทุน โดยโครงข่ายประสาทเทียม (ANNs) ถูกนำไปประยุกต์ในการทำนายปริมาณการใช้เชื้อเพลิงในการขนส่งที่หลากหลาย เช่น รถบรรทุกทางถนน (Wysocki, Deka, & Elizondo, 2019) รถบรรทุกภายในเหมืองแร่ (Siarni-Irdemoosa & Dindarloo, 2015) และการขนส่งทางเรือ (Le, Lee, Park, & Kim, 2020) เป็นต้น อีกทั้งยังโครงข่ายประสาทเทียม (ANNs) ไปประยุกต์ใช้ในการทำนายข้อมูลในบริบทอื่น ๆ เช่น ปริมาณผู้โดยสาร

อากาศ (Mostafaeipour, Goli, & Qolipour, 2018) ปริมาณการใช้ไฟฟ้า (Akarslan & Hocaoglu, 2018) และการเจริญเติบโตของพืช (Farooque et al., 2016) เป็นต้น จากการประยุกต์โครงข่ายประสาทเทียมในการทำนายข้อมูลที่สนใจกับบริบทและสถานการณ์ที่หลากหลายทำให้เชื่อมั่นได้ว่า โครงข่ายประสาทเทียมจะเป็นเครื่องมือสำคัญในการเพิ่มประสิทธิภาพในการวางแผนและใช้ทรัพยากรที่เกี่ยวข้องกับเชื้อเพลิงในการขนส่งสินค้าของบริษัทกรณีศึกษาต่อไป


วัตถุประสงค์ของการวิจัย

1. เพื่อทำนายปริมาณการใช้เชื้อเพลิงด้วยโครงข่ายประสาทเทียม
2. เพื่อเปรียบเทียบประสิทธิภาพการทำนายปริมาณการใช้เชื้อเพลิงขนส่ง กรณีศึกษา รถบรรทุกดินถมในพื้นที่จังหวัดชายแดนใต้ ประเทศไทย

วิธีดำเนินการวิจัย


ขั้นตอนการศึกษาการทำนายปริมาณการใช้เชื้อเพลิงขนส่งด้วยวิธีโครงข่ายประสาทเทียม มีรายละเอียดดังนี้

1. ลงพื้นที่เก็บข้อมูล ปริมาณการใช้เชื้อเพลิงขนส่ง (ลิตร) กรณีศึกษา รถบรรทุกดินถมในพื้นที่จังหวัดชายแดนใต้ในพื้นที่ จังหวัดนราธิวาส จำนวน 1 บริษัท เป็นรายเดือน ตั้งแต่ พ.ศ.2556 – 2560 ซึ่งเป็นบริษัทที่ให้การอนุเคราะห์ข้อมูล
2. สร้างกราฟอนุกรมเวลาระหว่างรายเดือนกับปริมาณการใช้เชื้อเพลิงของบริษัทกรณีศึกษา
3. การทำนายข้อมูลด้วยวิธีโครงข่ายประสาทเทียม ด้วยโปรแกรม Zaitun Time Series ที่ใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Sukpan, C., Chopaiad, C., & Chooduang, S., 2015) ในการประมวลผลด้วยฟังก์ชันการถ่ายโอน (Transfer Function) ซึ่งทำหน้าที่เป็นฟังก์ชันในการคำนวณเพื่อทำนายค่าของข้อมูลในขั้นส่งออก ทั้งสิ้น 3 รูปแบบ ดังภาพที่ 1



ภาพที่ 1 แสดงฟังก์ชันการถ่ายโอน (Transfer Function) ทั้งสิ้น 3 รูปแบบ

จากภาพที่ 2 เมื่อกำหนดฟังก์ชันถ่ายโอนแล้ว จึงกำหนดโครงสร้างของโครงข่ายประสาทเทียม ชั้นนำเข้า (Input Layer) จำนวน 12 โหนด ชั้นซ่อน (Hidden Layer) ระหว่าง 4 ถึง 12 โหนด และชั้นส่งออก (Output Layer) จำนวน 1 โหนด (ภาพที่ 2) ที่สัมพันธ์กับข้อมูลแบบอนุกรมเวลา โดยกำหนดอัตราการเรียนรู้ (Learning rate) เท่ากับ 0.05 โมเมนตัม (Momentum) เท่ากับ 0.5 และจำนวนรอบการเรียนรู้ (Iteration) เท่ากับ 100,000 รอบ (Fauziah, F. N., Gunaryati, A., & Sari, R. T. K., 2017)



ภาพที่ 2 ภาพโครงข่ายประสาทเทียมกับข้อมูลแบบอนุกรมเวลา (ดัดแปลงจาก Ileri, 2014)

4. วิเคราะห์ความแม่นยำของตัวแบบในการทำนายข้อมูล จากค่า MAPE โดยเลือกตัวแบบการทำนายที่มีค่า MAPE ต่ำที่สุด (Johnson & King, 1988) ดังสมการที่ 1 (Hyndman & Athanasopoulos, 2018)

$$MAPE = 100T^{-1} \sum_t \frac{|x_t - \hat{x}_{t|t-1}|}{|x_t|} \quad (1)$$

เมื่อ T คือ จำนวนข้อมูลทั้งหมด
 x_t คือ ค่าจริงในช่วงเวลา t
 $\hat{x}_{t|t-1}$ คือ ค่าทำนายจากข้อมูลก่อนหน้า

ผลการวิจัย

ผลการศึกษาการทำนายปริมาณการใช้เชื้อเพลิงกรณีศึกษาด้วยวิธีโครงข่ายประสาทเทียม มีรายละเอียด ดังนี้


1. ผลการลงพื้นที่เก็บข้อมูล ข้อมูลปริมาณการใช้เชื้อเพลิง (ลิตร) กรณีศึกษาเป็นรายเดือน ตั้งแต่ พ.ศ.2556-2560 ดังตารางที่ 1

ตารางที่ 1 ปริมาณการใช้เชื้อเพลิงขนส่ง (ลิตร) พ.ศ. 2556-2560

เดือน ปี	ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.
2556	23,169	28,069	16,141	20,508	21,385	22,109	20,305	23,164	14,823	24,738	22,523	17,668
2557	29,451	35,816	29,760	26,090	33,000	30,805	37,480	25,284	31,948	36,523	31,334	30,384
2558	38,128	35,358	34,289	41,718	40,123	35,631	37,437	36,841	35,760	34,574	39,750	31,272
2559	41,154	37,960	41,951	36,477	35,269	35,182	32,556	36,507	32,398	34,463	34,237	38,745
2560	24,955	24,557	24,729	27,475	25,288	23,418	28,271	30,484	24,714	30,732	27,907	21,289

ที่มา : บริษัทกรณีสึกษา

2. การสร้างกราฟอนุกรมเวลาระหว่างเดือนกับปริมาณการใช้เชื้อเพลิง พ.ศ.2556-2560 ดังภาพที่ 3



ภาพที่ 3 กราฟอนุกรมเวลาข้อมูลกรณีสึกษา พ.ศ.2556-2560

3. ผลการทำนายข้อมูลด้วยวิธีโครงข่ายประสาทเทียม

จากการพิจารณาการกระจายตัวของข้อมูลจากภาพที่ 1 จึงเลือกใช้ตัวแบบในการทำนายข้อมูลด้วยวิธีโครงข่ายประสาทเทียม ด้วยการนำเข้าข้อมูลเป็นรายเดือนทั้งหมด 60 เดือน ด้วยฟังก์ชันการถ่ายโอน (Transfer Function) ทั้งสิ้น 3 รูปแบบ ดังภาพที่ 2

3.1) การทำนายข้อมูลด้วยวิธีโครงข่ายประสาทเทียม ด้วยฟังก์ชันการถ่ายโอนแบบซิกมอยด์ (Sigmoid Transfer Function) ได้ผลความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิงขนส่งของแต่ละโครงข่ายประสาทเทียม ดังตารางที่ 2


ตารางที่ 2 ค่าความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิงขนส่งของแต่ละโครงข่ายประสาทเทียม ด้วยฟังก์ชันการถ่ายโอนแบบซิกมอยด์

ลำดับ	โครงข่ายประสาทเทียม	ค่าความคลาดเคลื่อนในการทำนาย (%)
1	ANN (12-4-1)	9.12
2	ANN (12-5-1)	9.32
3	ANN (12-6-1)	9.18
4	ANN (12-7-1)	9.31
5	ANN (12-8-1)	9.26
6	ANN (12-9-1)	9.16

ตารางที่ 2 (ต่อ)

ลำดับ	โครงข่ายประสาทเทียม	ค่าความคลาดเคลื่อนในการทำนาย (%)
7	ANN (12-10-1)	9.28
8	ANN (12-11-1)	9.16
9	ANN (12-12-1)	9.36

จากตารางที่ 2 โครงข่ายประสาทเทียม แบบมีชั้นนำเข้า (Input Layer) จำนวน 12 โหนด ชั้นซ่อน (Hidden Layer) ระหว่าง 4 โหนด และชั้นส่งออก (Output Layer) จำนวน 1 โหนด (ลำดับที่ 1) มีความคลาดเคลื่อนต่ำที่สุด คือ 9.12 เปอเซ็นต์ และภาพอนุกรมเวลาแสดงการทำนายปริมาณการใช้เชื้อเพลิง ดังภาพที่ 4




ภาพที่ 4 การทำนายข้อมูลจากโครงข่ายประสาทเทียม ANN (12-4-1) ด้วยฟังก์ชันการถ่ายโอนแบบซิกมอยด์

3.2) การทำนายข้อมูลด้วยวิธีโครงข่ายประสาทเทียม ด้วยฟังก์ชันการถ่ายโอนแบบไบโพล่าซิกมอยด์ (Bipolar-Sigmoid Transfer Function) ได้ผลความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิงขนส่งของแต่ละโครงข่ายประสาทเทียม ดังตารางที่ 3

ตารางที่ 3 ค่าความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิงขนส่งของแต่ละโครงข่ายประสาทเทียม ด้วยฟังก์ชันการถ่ายโอนแบบไบโพล่าซิกมอยด์

ลำดับ	โครงข่ายประสาทเทียม	ค่าความคลาดเคลื่อนในการทำนาย (%)
1	ANN (12-4-1)	1.91
2	ANN (12-5-1)	1.32
3	ANN (12-6-1)	0.96
4	ANN (12-7-1)	1.23
5	ANN (12-8-1)	1.41
6	ANN (12-9-1)	0.95
7	ANN (12-10-1)	1.12
8	ANN (12-11-1)	1.25
9	ANN (12-12-1)	0.94

จากตารางที่ 3 โครงข่ายประสาทเทียม แบบมีชั้นนำเข้า (Input Layer) จำนวน 12 โหนด ชั้นซ่อน (Hidden Layer) จำนวน 12 โหนด และชั้นส่งออก (Output Layer) จำนวน 1 โหนด (ลำดับที่ 9) มีความคลาดเคลื่อนต่ำที่สุด คือ 0.94 เปอร์เซ็น และภาพอนุกรมเวลาแสดงการทำนายปริมาณการใช้เชื้อเพลิง ดังภาพที่ 5




ภาพที่ 5 การทำนายข้อมูลจากโครงข่ายประสาทเทียม ANN (12-12-1) ด้วยฟังก์ชันการถ่ายโอนแบบไฮเพอร์โบลิก-ซิกมอยด์

3.3) การทำนายข้อมูลด้วยวิธีโครงข่ายประสาทเทียม ด้วยฟังก์ชันการถ่ายโอนแบบไฮเพอร์โบลิก-แทนเจนต์ (Hyperbolic-Tangent Transfer Function) ได้ผลความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิงขนส่งของแต่ละโครงข่ายประสาทเทียม ดังตารางที่ 4

ตารางที่ 4 ค่าความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิงขนส่งของแต่ละโครงข่ายประสาทเทียม ด้วยฟังก์ชันการถ่ายโอนแบบไฮเพอร์โบลิก-แทนเจนต์

ลำดับ	โครงข่ายประสาทเทียม	ค่าความคลาดเคลื่อนในการทำนาย (%)
1	ANN (12-4-1)	2.02
2	ANN (12-5-1)	0.34
3	ANN (12-6-1)	0.17
4	ANN (12-7-1)	0.23
5	ANN (12-8-1)	0.03
6	ANN (12-9-1)	0.12
7	ANN (12-10-1)	0.07
8	ANN (12-11-1)	0.11
9	ANN (12-12-1)	0.34

จากตารางที่ 4 โครงข่ายประสาทเทียม แบบมีชั้นนำเข้า (Input Layer) จำนวน 12 โหนด ชั้นซ่อน (Hidden Layer) จำนวน 8 โหนด และชั้นส่งออก (Output Layer) จำนวน 1 โหนด (ลำดับที่ 9) มีความคลาดเคลื่อนต่ำที่สุด คือ 0.03 เปอร์เซ็น และภาพอนุกรมเวลาแสดงการทำนายปริมาณการใช้เชื้อเพลิง ดังภาพที่ 6



ภาพที่ 6 การทำนายข้อมูลจากโครงข่ายประสาทเทียม ANN (12-8-1) ด้วยฟังก์ชันการถ่ายโอนแบบไฮเพอร์โบลิค-แทนเจนต์

อภิปรายผลการวิจัย

ผลที่ได้จากการทำนายวิธีโครงข่ายประสาทเทียมจากกรณีศึกษาครั้งนี้ พบว่า การทำนายปริมาณเชื้อเพลิงด้วยโครงข่ายประสาทเทียมด้วยฟังก์ชันการถ่ายโอนแบบไฮเพอร์โบลิค-แทนเจนต์ มีความแม่นยำและมีประสิทธิภาพมากที่สุด สอดคล้องกับ Badyalina, B., et al (2022) ที่ได้นำโครงข่ายประสาทเทียมที่มีฟังก์ชันการถ่ายโอนแบบไฮเพอร์โบลิค-แทนเจนต์ ไปใช้ในการทำนายความเร็วลมเพื่อการผลิตกระแสไฟฟ้า เช่นเดียวกับ (Ibrahim, N. N. A. N., Razak, I. A. W. A., & Bohari, Z. H., 2018) ได้นำโครงข่ายประสาทเทียมไปใช้ในการทำนายค่าไฟฟ้าและพบว่าฟังก์ชันการถ่ายโอนแบบไฮเพอร์โบลิค-แทนเจนต์ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำที่สุดเช่นกัน อีกทั้งยังพบว่าโครงข่ายประสาทเทียมยังสามารถนำไปใช้ในการปรับปรุงค่าความคลาดเคลื่อนในการพยากรณ์ได้ จากการศึกษาของ Affan, M. F., Abdullah, A. G., & Surya, W. (2019) ได้เปรียบเทียบความคลาดเคลื่อนในการพยากรณ์ระหว่างวิธีการปรับเรียบเอ็กโพเนนเชียลและโครงข่ายประสาทเทียม ซึ่งจากงานวิจัยที่ผ่านมาชี้ให้เห็นว่าโครงข่ายประสาทเทียม เป็นเครื่องมือที่มีประโยชน์สำหรับการทำนายปริมาณการใช้เชื้อเพลิงและอุตสาหกรรมต่าง ๆ อย่างไรก็ตามค่าความคลาดเคลื่อนอาจมีความแตกต่างกันไปขึ้นอยู่กับลักษณะเฉพาะของข้อมูลในแต่ละอุตสาหกรรม จึงมีความจำเป็นที่ต้องพิจารณาอย่างรอบคอบว่า วิธีการทำนายใดเหมาะสมที่สุดสำหรับอุตสาหกรรมที่สนใจ

สรุปผลการวิจัย

การศึกษาตัวแบบทำนายปริมาณการใช้เชื้อเพลิง เริ่มจากการลงพื้นที่เก็บข้อมูลปริมาณการใช้เชื้อเพลิง กรณีศึกษา รถบรรทุกดินถมในพื้นที่จังหวัดชายแดนใต้ รายเดือนตั้งแต่ พ.ศ. 2556-2560 จากนั้นนำข้อมูลมาสร้างกราฟอนุกรมเวลา และใช้โครงข่ายประสาทเทียมในการทำนายปริมาณการใช้เชื้อเพลิงในการขนส่งด้วยฟังก์ชันถ่ายโอน 3 รูปแบบ คือ ฟังก์ชันการถ่ายโอนแบบซิกมอยด์ แบบไปโปลาซิกมอยด์ และแบบไฮเพอร์โบลิค-แทนเจนต์ โดยที่แต่ละฟังก์ชันการถ่ายโอนจะมีการแบ่งโครงข่ายประสาทเทียม ออกเป็น 9 โครงสร้าง คือ ชั้นนำเข้า (Input Layer) จำนวน 12 โหนด ชั้นซ่อน (Hidden Layer) ระหว่าง 4 ถึง 12 โหนด และชั้นส่งออก (Output Layer) จำนวน 1 โหนด ที่สัมพันธ์กับข้อมูลแบบอนุกรมเวลา รวมทั้งสิ้น 27

โครงสร้าง เพื่อใช้ในการประเมินความคลาดเคลื่อนในการทำนายปริมาณการใช้เชื้อเพลิง โดยกำหนดอัตราการเรียนรู้ (Learning Rate) เท่ากับ 0.05 โมเมนตัม (Momentum) เท่ากับ 0.5 และจำนวนรอบการเรียนรู้ (Iteration) เท่ากับ 100,000 รอบ พบว่า โครงข่ายประสาทเทียมแบบ ANN (12-8-1) ด้วยฟังก์ชันการถ่ายโอนแบบไฮเปอร์โบลิค-แทนเจนต์ ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำที่สุด 0.03 เปอร์เซ็นต์

ข้อเสนอแนะ

การวิจัยในครั้งถัดไปสามารถนำโครงข่ายประสาทเทียมไปใช้ในการทำนายปริมาณการใช้เชื้อเพลิงในการขนส่งในภาคส่วนอื่น ๆ ได้ทั้งภาคการผลิตหรือโลจิสติกส์ อีกทั้งผลที่ได้จากการศึกษาในครั้งนี้เป็นเพียงการอาศัยข้อมูลที่มีลักษณะของอนุกรมเวลาเท่านั้น เพื่อเป็นการเพิ่มความแม่นยำในการทำนายอาจมีการเก็บข้อมูลเพิ่มขึ้นในอนาคตและเพิ่มปัจจัยนำเข้าที่มีผลต่อปริมาณการใช้เชื้อเพลิง เช่น ข้อมูลเกี่ยวกับสภาพอากาศ การบำรุงรักษายานพาหนะ รูปแบบการขับขี่ และความหนาแน่นของโครงการก่อสร้างในพื้นที่ เป็นต้น เพื่อนำผลที่ได้จากการทำนายไปใช้ประโยชน์ในการวางแผนจัดเตรียมเชื้อเพลิงให้สอดคล้องต่อความต้องการใช้รถบรรทุกถมดินกรณีศึกษาต่อไป

เอกสารอ้างอิง

- Affan, M. F., Abdullah, A. G., & Surya, W. (2019). Forecasting of wind speed using exponential smoothing and artificial neural networks (ANN). *Journal of Physics: Conference Series*, 1402(3), 033082. IOP Publishing.
- Akarslan, E., & Hocaoglu, F. O. (2018). Electricity demand forecasting of a micro grid using ANN. *2018 9th International Renewable Energy Congress (IREC)*, 1–5. IEEE.
- Badyalina, B., Mokhtar, N. A., Azimi, A. I. F., Majid, M., Ramli, M. F., & Yaa'coob, F. F. (2022). Data-driven models for wind speed forecasting in malacca state. *MATEMATIKA: Malaysian Journal of Industrial and Applied Mathematics*, 125–139.
- Bangkokbiznews. (2022). *Thailand imported more than 1 million barrels of fuel in January 2022, an increase of 9.9%*. Retrieved from <https://www.bangkokbiznews.com/business/992133>. (in Thai)
- Farooque, A. A., Zaman, Q. U., Nguyen-Quang, T., Groulx, D., Schumann, A. W., & Chang, Y. K. (2016). Development of a predictive model for wild blueberry harvester fruit losses during harvesting using artificial neural network. *Applied Engineering in Agriculture*, 32(6), 725–738.
- Fauziah, F. N., Gunaryati, A., & Sari, R. T. K. (2017). Comparison forecasting with double exponential smoothing and artificial neural network to predict the price of sugar. *Int. J. Simul. Syst. Sci. Technol*, 18(4), 1-8.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice*. OTexts.
- Ibrahim, N. N. A. N., Razak, I. A. W. A., & Bohari, Z. H. (2018). Electricity price forecasting using artificial neural network: Activation function selection. *Proceedings of Symposium on Electrical, Mechatronics and Applied Science 2018 (SEMA'18)*, 151–152.

- Ileri, A. M. (2014). *A Data Mining approach to private healthcare services demand forecast in Nairobi County* (PhD Thesis).
- Johnson, D., & King, M. (1988). *BASIC forecasting techniques Butterworths*. London.
- Le, L. T., Lee, G., Park, K.-S., & Kim, H. (2020). Neural network-based fuel consumption estimation for container ships in Korea. *Maritime Policy & Management*, 47(5), 615–632.
- Mostafaeipour, A., Goli, A., & Qolipour, M. (2018). Prediction of air travel demand using a hybrid artificial neural network (ANN) with bat and firefly algorithms: a case study. *The Journal of Supercomputing*, 74(10), 5461–5484.
- Piyanuch Sathapongpakdee. (2022). Industry Outlook 2022-2024: Road Freight Transportation Service. Retrieved from <https://www.krungsri.com/th/research/industry/industry-outlook/logistics/road-freight-transportation/IO/road-freight-transportation-2022-2024>. (in Thai)
- Siami-Irdemoosa, E., & Dindarloo, S. R. (2015). Prediction of fuel consumption of mining dump trucks: A neural networks approach. *Applied Energy*, 151, 77–84.
- Southern Border Provinces Administration Centre. (2022). *Sentiment Index for Southern Border Provinces* Retrieved from <https://www.sbpac.go.th/wp-content/uploads/2020/08/>
- Sukpan, C., Chopaiad, C., & Chooduang, S.. (2015). Price Forecasting of Ribbed Smoked Rubber Sheet No.3 in the Agricultural Futures Market by Leading Indicators and Artificial Neural Networks. *Thaksin University Journal*, 18(1), 32–40. (in Thai).
TPS.pdf. (in Thai)
- Wysocki, O., Deka, L., & Elizondo, D. (2019). Heavy duty vehicle fuel consumption modeling using artificial neural networks. *2019 25th International Conference on Automation and Computing (ICAC)*, 1–6. IEEE.