

Journal of Engineering and Digital Technology (JEDT)

Thai-Nichi Institute of Technology

Vol.10 No.1

January - June 2022



วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล
สถาบันเทคโนโลยีไทย-ญี่ปุ่น
ปีที่ 10 ฉบับที่ 1 มกราคม - มิถุนายน 2565

ISSN 2774-0617 (Online)

วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล

Journal of Engineering and Digital Technology (JEDT)

ปีที่ 10 ฉบับที่ 1 มกราคม – มิถุนายน 2565 Vol. 10 No. 1 January - June 2022

ISSN (Online) 2774-0617

ความเป็นมา

ด้วยสถาบันเทคโนโลยีไทย-ญี่ปุ่น มีนโยบายสนับสนุนการเผยแพร่บทความจากผลงานวิจัยที่มีคุณภาพ เพื่อเป็นประโยชน์ในการพัฒนาความรู้แก่สังคม โดยเฉพาะภาคธุรกิจและอุตสาหกรรม จึงได้จัดทำวารสารวิชาการ คือ วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล (เดิมชื่อ วารสารสถาบันเทคโนโลยีไทย-ญี่ปุ่น : วิศวกรรมศาสตร์และเทคโนโลยี)

วัตถุประสงค์

1. เพื่อส่งเสริมและเผยแพร่ผลงานวิจัยสาขาวิศวกรรมศาสตร์และเทคโนโลยีที่มีคุณภาพ
2. เพื่อเป็นสื่อกลางในการแลกเปลี่ยนองค์ความรู้ทางการวิจัยในสาขาวิศวกรรมศาสตร์และเทคโนโลยี
3. เพื่อพัฒนาศักยภาพทางการวิจัยสาขาวิศวกรรมศาสตร์และเทคโนโลยี

ที่ปรึกษา

รองศาสตราจารย์กฤษดา วิศวธีรานนท์

ขอบเขตเนื้อหา

บทความวิจัยทางด้านวิทยาศาสตร์ วิศวกรรมศาสตร์ และเทคโนโลยี ได้แก่ เทคโนโลยีวิศวกรรม เทคโนโลยีอุตสาหกรรม เทคโนโลยีวัสดุศาสตร์ เทคโนโลยีสารสนเทศ วิทยาศาสตร์ประยุกต์ วิทยาศาสตร์กายภาพ วิทยาศาสตร์ชีวภาพ วิทยาการคอมพิวเตอร์ วิทยาศาสตร์เคมี และสาขาอื่น ๆ ที่เกี่ยวข้อง

กำหนดออกเผยแพร่

วารสารตีพิมพ์เผยแพร่ราย 6 เดือน (ปีละ 2 ฉบับ)

- ฉบับที่ 1 มกราคม – มิถุนายน
- ฉบับที่ 2 กรกฎาคม – ธันวาคม

เจ้าของ

สถาบันเทคโนโลยีไทย-ญี่ปุ่น (Thai-Nichi Institute of Technology : TNI)

1771/1 ถนนพัฒนาการ แขวงสวนหลวง เขตสวนหลวง กรุงเทพฯ 10250

1771/1 Pattanakarn Rd., Suanluang, Bangkok 10250

บรรณาธิการ

รองศาสตราจารย์ ดร.รัตติกกร วรากุลศิริพันธุ์

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

กองบรรณาธิการ

- | | |
|---|---|
| 1. ศาสตราจารย์ ดร.ธนารักษ์ ชีระมั่นคง | สถาบันเทคโนโลยีนานาชาติสิรินธร
มหาวิทยาลัยธรรมศาสตร์ |
| 2. ศาสตราจารย์ ดร.โกสินทร์ จันทน์ไทย | มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี |
| 3. ศาสตราจารย์ ดร.บุญเจริญ ศิริเนาวกุล | มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี |
| 4. ศาสตราจารย์ ดร.อภิรักษ์ ธารยานนท์ | สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง |
| 5. ศาสตราจารย์ ดร.วรงค์ ตั้งศรีรัตน์ | สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง |
| 6. ศาสตราจารย์ ดร.ประยุทธ์ อัครเอกผาลิน | มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ |
| 7. ศาสตราจารย์ ดร.มานะ ศรียุทธศักดิ์ | จุฬาลงกรณ์มหาวิทยาลัย |
| 8. รองศาสตราจารย์ ดร.จิรณัฐ เสี่ยมศักดิ์ | มหาวิทยาลัยขอนแก่น |
| 9. รองศาสตราจารย์ ดร.ปริทรรศน์ พันธุบรรยงก์ | สถาบันการจัดการปัญญาภิวัฒน์ |
| 10. รองศาสตราจารย์ ดร.ชุมพล อันตรเสน | สถาบันเทคโนโลยีไทย-ญี่ปุ่น |

คณะกรรมการดำเนินงาน

- | | |
|---|------------------------------|
| 1. รองศาสตราจารย์ ดร.วรากร ศรีเชวงทรัพย์ | 8. นางสาวจุฑามาศ ประสพสันต์ |
| 2. ผู้ช่วยศาสตราจารย์ ดร.วุฒิ สุขเจริญ | 9. นางสาวสุพิศ บายคายคม |
| 3. ผู้ช่วยศาสตราจารย์ ดร.จินตวัฒน์ ไชยชนะวงศ์ | 10. นางสาวรณีย์ นารินทร์ |
| 4. ดร.ประมุข บุญเสียง | 11. นายอศิรา พรหมสุทธิ |
| 5. ดร.ศรายุทธ นนท์ศิริ | 12. นางสาวพิมพ์รต พิพัฒน์กุล |
| 6. ผู้ช่วยศาสตราจารย์ ดร.บัณฑิต อนุญาหงษ์ | 13. นางสาวอาริสา จิระเวชถาวร |
| 7. ดร.เอิบ พงษ์ทอง | |

การติดต่อกองบรรณาธิการ

1771/1 ถนนพัฒนาการ แขวงสวนหลวง เขตสวนหลวง กรุงเทพฯ 10250

Tel. 0-2763-2600 (Ext. 2704, 2752)

Website : <https://ph01.tci-thaijo.org/index.php/TNIJournal> E-mail : JEDT@tni.ac.th

บทความวิจัยที่ตีพิมพ์ในวารสารฉบับนี้เป็นความคิดเห็นส่วนตัวของผู้เขียน

กองบรรณาธิการไม่มีส่วนรับผิดชอบใด ๆ ถือเป็นความรับผิดชอบของผู้เขียนแต่เพียงผู้เดียว

บทบรรณาธิการ

นับจากที่ วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล (JEDT) นี้ ได้ปรับเปลี่ยนชื่อวารสารและแบบปกใหม่ ได้รับการตอบรับที่ดีจากนักศึกษา อาจารย์ และนักวิจัย ส่งบทความวิจัยมาลงตีพิมพ์จำนวนมาก ทางกองบรรณาธิการมีความภูมิใจและขอขอบคุณผู้เขียนทุกท่านที่ได้ส่งผลงานที่มีคุณภาพมาลงในวารสารนี้

นโยบายของวารสารยังคงเดิมที่รับบทความที่เป็นทั้งภาษาไทย และภาษาอังกฤษ ผ่านการพิจารณาและคัดกรองโดยผู้ทรงคุณวุฒิ ตรงตามมาตรฐานระดับประเทศและระดับนานาชาติ ภายใต้การรับรองของ TCI (Thai-Journal Citation Index Centre) ผลงานที่ได้รับการตีพิมพ์ในวารสารฉบับนี้ จึงสามารถนำไปใช้ประกอบการสำเร็จการศึกษา หรือใช้ในการขอตำแหน่งทางวิชาการได้

ทางกองบรรณาธิการหวังว่า บทความที่ได้รับการตีพิมพ์ในวารสารฉบับนี้ จะเป็นประโยชน์ทั้งต่อเจ้าของบทความ นักวิจัย นักศึกษา และก่อให้เกิดประโยชน์ต่อวงการวิชาการและวิจัยของประเทศ

รองศาสตราจารย์ ดร.รัตติกกร วรากุลศิริพันธุ์
บรรณาธิการ

Editorial Message

It is very good news to know that the number of paper submission has increased since the Journal of Engineering and Digital Technology (JEDT) has changed the journal name with the new cover. The editorial team is proud and would like to express the sincere gratitude to all the authors who have submitted quality work to this journal.

The policy of the journal remains the same for accepting articles in both Thai and English languages. All submitted articles are reviewed and evaluated by qualified experts to meet national and international standards under the accreditation of TCI (Thai-Journal Citation Index Centre). Therefore, the accepted articles that be published in this journal can be used for graduation and/or can be used to apply for academic position.

The editorial team hope that all articles that have been published in this journal, will be beneficial to authors, researchers, students, academy and research of the country.

Assoc.Prof. Dr. Ruttikorn Varakulsiripunth
Editor-in-Chief

สารบัญ

- 1 A PM2.5 Prediction Model Using LSTM Neural Network in Bangkok Area
Sriruk Srithongchai
- 10 An Improved Linear Combination of Two Estimators for Reducing the Mean Squared Error in a Sample Survey under Simple Random Sampling
Napattchan Dansawad
- 17 An Innovative Virtual Kitchen Partnership-as-a-Service to Improve Efficiency of Healthy and Hygienic Meal Delivery Service Management in Culinary Industry
Metta Ongkasuwan, Chanasit Thanathawee, Charoen Russametummachot, Akechai Judkrue
- 28 Buildings Classification from Satellite Images by Transfer Learning
Piyanate Touncha-em, Ekarat Rattagan
- 41 Design and Prototyping of an Automatic Solar Panel Cleaner Based on Arduino
Patcharin Intamas, Promphak Boonraksa
- 50 Development of Rapid Prototyping for Ceramic Products Using Layer Manufacturing Technique
Nopporn Bukwan, Sasitron Khonthon, Sukhuman Rianthong
- 62 Sightseeing Guidance System to Maximize Satisfaction Using Real-Time Spot Information
Hirotoishi Honma, Yuya Sato, Yoko Nakajima
- 71 The Model of Sentiment Analysis for Classifying the Online Shopping Reviews
Pisit Bowornlertsutee, Worapat Paireekreng

80 The Study of the Effect of Channel Obstacles on Stream Flooding

*Pongpan Kanjanakaroon, Chuchoke Aryupong, Surachai Amnuaypornlert,
Pornyamol Natenapakorn, Wichai Namkaew*

90 Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System

Amonpan Chomklin, Nuttareepan Nittayoosakulchot

แบบจำลองการพยากรณ์ค่า PM2.5 โดยใช้โครงข่ายประสาทเทียมแบบ LSTM ในพื้นที่กรุงเทพมหานคร

ศรียักษ์ ศรีทองชัย*

*ภาควิชาวิศวกรรมอุตสาหการและการจัดการ คณะวิศวกรรมศาสตร์และเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยศิลปากร,
นครปฐม, ประเทศไทย

*ผู้ประพันธ์บรรณกิจ อีเมล : srithongchai_s@su.ac.th

รับต้นฉบับ : 22 ธันวาคม 2564; รับบทความฉบับแก้ไข : 18 กุมภาพันธ์ 2565; ตอรับบทความ : 1 มีนาคม 2565
เผยแพร่ออนไลน์ : 27 มิถุนายน 2565

บทคัดย่อ

PM2.5 ถือเป็นปัญหาสำคัญของประเทศไทยโดยเฉพาะในกรุงเทพมหานครและปริมณฑล ส่งผลกระทบต่อสุขภาพ เศรษฐกิจและสังคม การพยากรณ์โดยใช้แบบจำลองทางคณิตศาสตร์เพื่อตรวจสอบระดับความเข้มข้นของ PM2.5 เป็นทางเลือกที่ทำให้ทราบค่าประมาณของ PM2.5 งานวิจัยนี้นำเสนอวิธีโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาวในการสร้างแบบจำลองเพื่อใช้ในการทำนายปริมาณฝุ่นอนุภาคขนาดเล็กดังกล่าวบริเวณพื้นที่ทั่วไปและริมถนนในกรุงเทพมหานคร ใช้การวิเคราะห์สหสัมพันธ์คัดเลือกตัวแปรหลักเข้าสู่แบบจำลองและเกณฑ์ RMSE และ MAPE เป็นเครื่องมือวัดประสิทธิภาพการพยากรณ์ ซึ่งพัฒนาแบบจำลองที่แตกต่างกันได้ 8 แบบโดยอาศัยข้อมูลคุณภาพอากาศและข้อมูลอุตุนิยมวิทยา ผลการวิจัยพบว่าสำหรับพื้นที่ทั่วไปแบบจำลองที่ 2 ที่ประกอบด้วยตัวแปร PM10, NO2, CO, O3, SO2 และ LAGPM2.5 เป็นแบบจำลองที่ให้ความแม่นยำสูงสุด ให้ค่าเฉลี่ย RMSE = 8.05, ค่าเฉลี่ย MAPE = 27.22 ส่วนพื้นที่ริมถนนแบบจำลองที่ 8 มีตัวแปร PM10, NO2, CO, Temp, Hum, Press, WindSp, WindDir และ LAGPM2.5 เป็นแบบจำลองที่เหมาะสมที่สุดให้ค่าเฉลี่ย RMSE = 4.83, ค่าเฉลี่ย MAPE = 22.57 แบบจำลองบริเวณริมถนน (แบบจำลองที่ 5-8) มีค่าผิดพลาดน้อยกว่าแบบจำลองในพื้นที่ทั่วไป (แบบจำลองที่ 1-4) และการพยากรณ์ที่ใช้ข้อมูลย้อนหลังเป็นระยะสั้น 1 วันมีแนวโน้มให้ผลลัพธ์ที่ถูกต้องมากขึ้น

คำสำคัญ : ฝุ่นละอองขนาดเล็ก การพยากรณ์ โครงข่ายประสาทเทียม หน่วยความจำระยะสั้นแบบยาว

A PM2.5 Prediction Model Using LSTM Neural Network in Bangkok Area

Sriruk Srithongchai*

**Department of Industrial Engineering and Management, Faculty of Engineering and Industrial Technology,
Silpakorn University, Nakhon Pathom, Thailand*

*Corresponding Author. E-mail address: srithongchai_s@su.ac.th

Received: 22 December 2021; Revised: 18 February 2022; Accepted: 1 March 2022

Published online: 27 June 2022

Abstract

PM2.5 has become a serious concern in Thailand, particularly in Bangkok and its vicinity. It has significant impacts on human health, economy and society. A prediction method based on mathematical models is an alternative approach to obtain estimates of PM2.5 concentrations. This research proposes long short-term memory (LSTM) neural networks to develop models to forecast the levels of fine particulate matter in Bangkok, ambient and roadside areas. Correlation analysis was used to select the key variables, and the RMSE and MAPE criteria were employed as forecasting performance measures. Eight different models were constructed using air quality and meteorological data. The results demonstrated that for ambient area, model 2 (which includes the variables PM10, NO2, CO, O3, SO2 and LAGPM2.5) was the best model with an average RMSE of 8.05 and an average MAPE of 27.22. In roadside area, model 8 (which contains the variables PM10, NO2, CO, Temp, Hum, Press, WindSp, WindDir and LAGPM2.5) showed the best performance with an average RMSE of 4.83 and an average MAPE of 22.57. Additionally, the prediction models at roadside site (model 5-8) were more accurate than the others (model 1-4). Estimates based upon short-term past data, 1 day, tended to have smaller forecast errors.

Keywords: PM2.5, Forecasting, Neural network, LSTM

1) บทนำ

สถานการณ์ปัญหามลพิษทางอากาศ (Air Pollution) เกิดขึ้นในหลายภูมิภาคทั่วโลกและนับวันจะทวีความรุนแรงเพิ่มมากขึ้น ช่วงหลายปีที่ผ่านมาเว็บไซต์รายงานคุณภาพอากาศ IQAir.com ได้จัดให้เชียงใหม่และกรุงเทพมหานครติดอันดับเมืองที่พบมลพิษทางอากาศมากที่สุดในโลก [1], [2] ในฐานะที่กรุงเทพมหานครเป็นเมืองหลวงและเมืองศูนย์กลางทางเศรษฐกิจการค้า จึงได้เกิดการอพยพหลังไหลของผู้คนเข้ามาอยู่อาศัยเพื่อแสวงหาโอกาสในการประกอบอาชีพ การศึกษา และความมั่นคงทางด้านรายได้ จำนวนประชากรที่เพิ่มขึ้นก่อให้เกิดมลพิษทางอากาศเพิ่มมากขึ้นตามไปด้วย ซึ่งส่วนใหญ่มีสาเหตุมาจากการใช้ยานพาหนะและการประกอบกิจการอุตสาหกรรม การจราจรที่ติดขัดนานทำให้น้ำมันถูกเผาผลาญมากขึ้น การเผาไหม้ของเชื้อเพลิงที่ไม่สมบูรณ์ของเครื่องยนต์ทำให้เกิดเขม่าควันและสารพิษปล่อยสู่บรรยากาศ เช่น ก๊าซออกไซด์ของไนโตรเจน ก๊าซคาร์บอนมอนอกไซด์ สารประกอบไฮโดรคาร์บอน ก๊าซซัลเฟอร์ไดออกไซด์และฝุ่นละอองที่มีขนาดเล็ก โรงงานอุตสาหกรรมถือเป็นอีกแหล่งกำเนิดหลักของมลพิษทางอากาศที่มาจากการเผาไหม้เชื้อเพลิงและกระบวนการผลิต มลพิษทางอากาศที่อยู่ในรูปของฝุ่นละอองขนาดเล็กมากจนมองไม่เห็นด้วยตาเปล่านี้ ยิ่งฝุ่นเล็กลงเท่าใดก็ยิ่งเป็นอันตรายต่อสุขภาพ เนื่องจากอนุภาคขนาดเล็กสามารถถูกสูดหายใจเข้าไปได้ลึกถึงปอดและทางเดินหายใจ เสี่ยงต่อการเกิดโรคร้ายแรงถึงขั้นเสียชีวิต เช่น มะเร็งปอด หัวใจขาดเลือด และปอดอักเสบ ปัญหาจากฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน หรือ PM2.5 กำลังเป็นวิกฤตการณ์ด้านสิ่งแวดล้อมในกรุงเทพมหานคร และอีกหลายจังหวัดในประเทศไทย มีแนวโน้มจะเกิดขึ้นต่อเนื่องช่วงต้นปีและปลายปีของทุกปีและกินเวลานานขึ้น การตรวจวัด PM2.5 ในอากาศมีความสำคัญมากเพื่อเฝ้าระวัง เตรียมป้องกันและแก้ไขปัญหา รวมถึงแจ้งเตือนให้ประชาชนดูแลสุขภาพอนามัยอย่างถูกต้อง กรมควบคุมมลพิษติดตามตรวจสอบคุณภาพอากาศโดยสถานีตรวจวัดคุณภาพอากาศที่กระจายทั่วพื้นที่ประเทศ ซึ่งยังมีข้อจำกัดด้านงบประมาณและเครื่องมือวัดที่ไม่เพียงพอ การประเมินความเข้มข้น PM2.5 โดยใช้แบบจำลองทางคณิตศาสตร์ อย่างเช่น โครงข่ายประสาทเทียม (Artificial Neural Network) วิธีการวิเคราะห์การถดถอย (Regression Analysis) ฟัซซีลอจิก (Fuzzy Logic) และวิธีเชิงพันธุกรรม (Genetic Algorithm) จึงเป็นอีกแนวทางหนึ่งที่น่าสนใจ เนื่องจากเสียเวลาและค่าใช้จ่ายน้อยกว่าการตรวจวัดจริง

ปัจจุบันโครงข่ายประสาทเทียมถูกนำมาประยุกต์ใช้กันอย่างแพร่หลายสำหรับการจำแนกข้อมูล (Classification) การจัดกลุ่มข้อมูล (Clustering) การรู้จำจำแบบ (Pattern Recognition) และการพยากรณ์ (Prediction) งานวิจัยหลาย ๆ ชิ้นใช้โครงข่ายประสาทเทียมศึกษาทำนายปริมาณของสารมลพิษที่เจือปนอยู่ในอากาศ (เช่น PM2.5, PM10, CO และ SO₂) Kurt [3] Perez [4] Voukantsis [5] และคณะ นำเสนอโครงข่ายแบบป้อนไปข้างหน้า (Feed-Forward Neural Network: FNN) ที่มีการเรียนรู้แบบแพร่ย้อนกลับ (Backpropagation) มาสร้างแบบจำลองพยากรณ์ Oprea [6] Chang-Hoi [7] และผู้ร่วมวิจัย ทำการศึกษาโดยใช้โครงข่ายแบบวนซ้ำ (Recurrent Neural Network: RNN) Tsai [8] Bai [9] และคณะ ใช้โครงข่ายที่เรียกว่าหน่วยความจำระยะสั้นแบบยาว (Long-Short Term Memory: LSTM) ในส่วนของงานวิจัยในประเทศที่เกี่ยวข้อง เช่น Thaweephon และ Wiwatwattana [10] เปรียบเทียบประสิทธิภาพของแบบจำลองโครงข่าย LSTM และแบบจำลองทางสถิติ SARIMAX สำหรับพยากรณ์ฝุ่น PM2.5 รายชั่วโมง ระหว่างปี พ.ศ. 2560-2561 ของพื้นที่กรุงเทพมหานครชั้นใน (สถานีตำรวจนครบาลโชคชัย) พบว่า LSTM แม่นยำมากกว่า SARIMAX โดยใช้ตัวแปรสภาพอากาศและอุตุนิยมวิทยา 16 ตัวแปรและลบทิ้งแถวข้อมูลสูญหาย (Missing Data) Rong-O และ Wiwatwattana [11] ศึกษาผลกระทบการแทนค่าสูญหายและคัดเลือกตัวแปรเข้าสู่แบบจำลอง (Feature Selection) ซึ่งการทำนาย PM2.5 ด้วยวิธี LSTM ในพื้นที่เดียวกับที่ได้กล่าวมาข้างต้นมีความผิดพลาดน้อยลง ทั้งนี้แต่ละอัลกอริทึมโครงข่ายประสาทเทียมมีคุณลักษณะและสมรรถนะแตกต่างกัน โดย FNN ทำงานด้วยการส่งผ่านข้อมูลไปข้างหน้าทิศทางเดียว ขณะที่ RNN ป้อนข้อมูลย้อนกลับจึงเรียนรู้ได้มากขึ้น และถูกพัฒนาต่อยอดเป็น LSTM ช่วยให้เก็บข้อมูลไว้ได้นานและมักใช้กับข้อมูลอนุกรมเวลา (Time Series Data) LSTM จึงเหมาะสมกับข้อมูลที่ใช้ในการศึกษาครั้งนี้ซึ่งก็คือ ข้อมูลคุณภาพอากาศและอุตุนิยมวิทยา (Air Quality and Meteorological Data) งานวิจัยนี้เสนอแบบจำลองโครงข่าย LSTM เพื่อพยากรณ์ค่า PM2.5 ในกรุงเทพมหานคร โดยเพิ่มเติมจากงานวิจัยที่ผ่านมาด้วยการพิจารณาเปรียบเทียบแบบจำลองหลายตัวแปรที่แตกต่างกันรวมทั้งศึกษาในพื้นที่ทั่วไป (Ambient Area) ที่ใช้ข้อมูลจากสถานีตรวจวัดคุณภาพอากาศบางนาและสถานีอุตุนิยมวิทยาบางนาและบริเวณริมถนน (Roadside Area) ใช้ข้อมูลของสถานีโรงพยาบาลจุฬาลงกรณ์และสถานีศูนย์ประชุมแห่งชาติสิริกิติ์

2) ข้อมูลการวิจัย

กรุงเทพมหานคร [12] ตั้งอยู่ภาคกลางตอนล่างของประเทศ บริเวณละติจูดที่ 13.44 องศาเหนือ ลองจิจูด 100.34 องศาตะวันออก ลักษณะภูมิประเทศเป็นพื้นที่ราบลุ่ม แม่น้ำเจ้าพระยาเป็นแม่น้ำสายหลักไหลผ่าน มีพื้นที่ทั้งหมดประมาณ 1,568.74 ตารางกิโลเมตร อากาศเป็นแบบร้อนชื้นมีอุณหภูมิเฉลี่ยตลอดปี 28-30 องศาเซลเซียส มีสถานีอุตุนิยมวิทยาจำนวน 4 สถานีและสถานีตรวจวัดคุณภาพอากาศจำนวน 62 สถานี (ภายใต้การกำกับดูแลของกรมควบคุมมลพิษ 12 สถานีและกรุงเทพมหานคร 50 สถานี) ผู้วิจัยสนใจศึกษาปริมาณฝุ่นละออง PM2.5 ในกรุงเทพมหานครทั้งบริเวณพื้นที่ทั่วไปและพื้นที่ริมถนน โดยใช้ข้อมูลสารก่อมลพิษทางอากาศจากสถานีตรวจวัดคุณภาพอากาศบางนาเป็นตัวแทนข้อมูลพื้นที่ทั่วไป และสถานีโรงพยาบาลจุฬาลงกรณ์เป็นตัวแทนของพื้นที่ริมถนน ซึ่งพิจารณาจากเกณฑ์ความสมบูรณ์ของข้อมูลเพื่อให้ได้ข้อมูลที่ครบถ้วนมากที่สุดในการดำเนินการวิจัย รวมไปถึงข้อมูลสภาพภูมิอากาศที่มีผลต่อความหนาแน่นของฝุ่นพิษ จึงได้คัดเลือกสถานีอุตุนิยมวิทยาที่อยู่ในสถานที่ที่ใกล้เคียง ห่างจากสถานีตรวจวัดคุณภาพอากาศไม่เกิน 3 กิโลเมตร ดังนั้นข้อมูลพื้นที่ทั่วไปได้มาจากสถานีตรวจวัดคุณภาพอากาศที่บางนาและสถานีอุตุนิยมวิทยาบางนา ข้อมูลพื้นที่ริมถนนมาจากสถานีโรงพยาบาลจุฬาลงกรณ์และสถานีอุตุนิยมวิทยาศูนย์ประชุมแห่งชาติสิริกิติ์ โดยข้อมูลดิบที่ได้จากการเก็บรวบรวมจะได้ข้อมูลทั้งในแบบรายชั่วโมง (ข้อมูลคุณภาพอากาศ) ราย 3 ชั่วโมง (ความกดอากาศ ความเร็วลม ทิศทางลม) และรายวัน (อุณหภูมิ ความชื้นสัมพัทธ์ ปริมาณน้ำฝน)

งานวิจัยใช้ข้อมูลรายวัน ข้อมูลที่ไม่ใช่รายวันให้ใช้ค่าเฉลี่ยต่อวันแทนข้อมูลรายวัน ตั้งแต่เดือนมกราคม พ.ศ. 2560 ถึงเดือนธันวาคม พ.ศ. 2563 แบ่งได้ 2 ส่วน ประกอบด้วย ข้อมูลคุณภาพอากาศที่เป็นฝุ่นละอองและสารมลพิษในอากาศได้แก่ ฝุ่น PM2.5 ($\mu\text{g}/\text{m}^3$) ฝุ่น PM10 ($\mu\text{g}/\text{m}^3$) ก๊าซคาร์บอนมอนอกไซด์ (ppm) ก๊าซซัลเฟอร์ไดออกไซด์ (ppb) ก๊าซไนโตรเจนไดออกไซด์ (ppb) และก๊าซโอโซน (ppb) และข้อมูลอุตุนิยมวิทยา ได้แก่ อุณหภูมิ ($^{\circ}\text{C}$) ความชื้นสัมพัทธ์ (%) ปริมาณน้ำฝน (mm) ความกดอากาศ (hPa) ความเร็วลม (knot) และทิศทางลม (degree) ในตารางที่ 1 และตารางที่ 2 สรุปผลข้อมูลคุณภาพอากาศและอุตุนิยมวิทยาพบว่าพื้นที่ริมถนนมีค่าเฉลี่ยมลพิษทางอากาศสูงกว่าพื้นที่ทั่วไป ค่า PM2.5 สูงสุดในแต่ละพื้นที่อยู่ในระดับที่เกินกว่ามาตรฐาน ($50 \mu\text{g}/\text{m}^3$) แต่อย่างไรก็ตามค่าเฉลี่ย 24 ชั่วโมง (รายวัน) ของฝุ่น

PM2.5 ส่วนใหญ่จะต่ำกว่าค่ามาตรฐานของประเทศไทย ดังรูปที่ 1 และ 2

ตารางที่ 1 : ค่าสถิติเบื้องต้นข้อมูลรายวันของพื้นที่ทั่วไป ปี 2560-2563

ข้อมูล (ตัวแปร)	ค่าเฉลี่ย	ค่า	ค่าต่ำสุด/สูงสุด
ฝุ่น PM2.5 (PM2.5)	24.04	14.55	3.50-100.00
ฝุ่น PM10 (PM10)	40.63	19.88	7.42-153.46
คาร์บอนมอนอกไซด์ (CO)	0.47	0.21	0.04-1.40
ซัลเฟอร์ไดออกไซด์ (SO ₂)	1.55	1.06	0.00-6.83
ไนโตรเจนไดออกไซด์	16.27	9.70	0.57-58.22
โอโซน (O ₃)	19.14	9.38	1.68-52.52
อุณหภูมิ (Temp)	29.10	1.56	20.70-33.40
ความชื้นสัมพัทธ์ (Hum)	74.39	7.94	46.00-96.00
ปริมาณน้ำฝน (Rainfall)	6.89	14.67	0.00-119.00
ความกดอากาศ (Press)	1009.4	2.66	1018.99-1018.65
ความเร็วลม (WindSp)	2.83	1.25	0.00-7.00
ทิศทางลม (WindDir)	114.93	58.21	0.00-290.00


ตารางที่ 2 : ค่าสถิติเบื้องต้นข้อมูลรายวันของพื้นที่ริมถนน ปี 2560-2563

ข้อมูล (ตัวแปร)	ค่าเฉลี่ย	ค่า	ค่าต่ำสุด/สูงสุด
ฝุ่น PM2.5 (PM2.5)	26.22	12.92	7.83-92.25
ฝุ่น PM10 (PM10)	51.13	19.81	19.71-141.71
คาร์บอนมอนอกไซด์ (CO)	1.15	0.42	0.11-2.51
ซัลเฟอร์ไดออกไซด์ (SO ₂)	NA	NA	NA
ไนโตรเจนไดออกไซด์	34.77	20.49	8.17-123.30
โอโซน (O ₃)	NA	NA	NA
อุณหภูมิ (Temp)	29.19	1.62	20.60-33.60
ความชื้นสัมพัทธ์ (Hum)	74.68	7.75	47.00-97.00
ปริมาณน้ำฝน (Rainfall)	7.10	15.79	0.00-188.30
ความกดอากาศ (Press)	1008.9	2.65	1001.21-
ความเร็วลม (WindSp)	1.22	0.72	0.00-4.00
ทิศทางลม (WindDir)	71.64	46.27	0.00-290.00


หมายเหตุ: NA หมายถึงไม่มีข้อมูล

3) การดำเนินงานวิจัย

โครงข่ายประสาทเทียมเลียนแบบมาจากการทำงานของสมองมนุษย์ จะเรียนรู้ผ่านข้อมูลตัวอย่างและประมวลผลข้อมูลอื่นโดยอาศัยประสบการณ์ความรู้ที่ได้รับมา ในที่นี่จะใช้โครงข่ายประสาทเทียม LSTM สร้างแบบจำลองทำนาย PM2.5 โดยคัดเลือกตัวแปรสำคัญ (Feature Selection) ที่มีผลต่อตัวแปร ถูกทำนายด้วยสัมประสิทธิ์สหสัมพันธ์ของเพียร์สัน (Pearson Correlation Coefficient) และวัดประสิทธิภาพของแบบจำลองด้วยค่ารากที่สองความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) และเปอร์เซ็นต์ความคลาดเคลื่อนสมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE)



รูปที่ 1 : ปริมาณฝุ่น PM2.5 เฉลี่ย 24 ชั่วโมงของพื้นที่ทั่วไป ปี 2560-2563



รูปที่ 2 : ปริมาณฝุ่น PM2.5 เฉลี่ย 24 ชั่วโมงของพื้นที่ริมถนน ปี 2560-2563

3.1) การเตรียมข้อมูล

ข้อมูลที่น่าสนใจเป็นข้อมูลอนุกรมเวลาลักษณะรายวัน ซึ่งข้อมูลคุณภาพอากาศได้รับจากผลการตรวจวัดโดยสถานีตรวจวัดคุณภาพอากาศบางนาและสถานีโรงพยาบาลจุฬาลงกรณ์ และข้อมูลอุตุนิยมวิทยาจากสถานีอุตุนิยมวิทยาบางนาและสถานีศูนย์ประชุมแห่งชาติสิริกิติ์ โดยใช้ข้อมูลย้อนหลัง 4 ปีล่าสุด (พ.ศ. 2560-2563) ข้อมูลรายวันของแต่ละพื้นที่มีทั้งหมด 1,461 แถว แต่เนื่องจากข้อมูลไม่ครบถ้วนสมบูรณ์ ข้อมูลที่ขาดหายไปอย่างต่อเนื่องติดต่อกันนานจะถูกตัดทิ้งและทดแทนค่าสูญหายกรณีอื่นด้วยค่าเฉลี่ย (Mean) เช่น ในช่วง 9 เดือนหลังของปี 2563 พื้นที่ทั่วไปไม่มีข้อมูล “คาร์บอนมอนนอกไซด์” “ซัลเฟอร์ไดออกไซด์” และ “ไนโตรเจนไดออกไซด์” ค่า “โอโซน” ขาดหายมีมากถึง 92% จึงลบทิ้งแถวข้อมูลของช่วงเวลาดังกล่าว และ “ปริมาณน้ำฝน” ทั้ง 4 ปี ค่าหายไปกว่า 25% จึงตัดปริมาณน้ำฝนออกไปจากตัวแปรที่ทำการศึกษา [13] ดังนั้นพื้นที่ทั่วไปมีขนาดข้อมูลลดลงเหลือเท่ากับ 1,370 แถวและบริเวณพื้นที่ริมถนนมีจำนวนคงเหลือ 1,247 แถว

ข้อมูลข้างต้นถูกจัดแบ่งเป็น 3 ชุดคือข้อมูลชุดสอน (Training Set) นำไปสอนให้โครงข่ายเกิดการเรียนรู้ ข้อมูลชุดตรวจสอบ (Validation Set) เพื่อประเมินการทำงานของแบบจำลองที่สร้างขึ้นและข้อมูลชุดทดสอบ (Test Set) ใช้ในการทดสอบประสิทธิภาพการทำงานของแบบจำลอง ในลำดับแรกทำการแบ่งข้อมูลออกเป็น 2 ส่วน 80% สำหรับสอนและ 20% สำหรับทดสอบโดยให้ข้อมูลล่าสุดเป็นชุดทดสอบ จากนั้นตัดเอาส่วนท้าย 20% ของข้อมูลชุดสอนที่ได้มาไว้เป็นชุดตรวจสอบ ส่วนที่เหลืออยู่จะเป็นข้อมูลชุดสอนที่แท้จริง

3.2) การคัดเลือกตัวแปร


แบบจำลองโครงข่ายประสาทเทียมสำหรับทำนายปริมาณฝุ่น PM2.5 มีตัวแปรผลลัพธ์ (Output Variable) 1 ตัวแปรคือความเข้มข้นของ PM2.5 และตัวแปรป้อนเข้า (Input Variable) ที่ส่งผลต่อตัวแปรผลลัพธ์มีหลายตัว การพิจารณาคัดเลือกตัวแปรป้อนเข้าดูจากค่าสัมประสิทธิ์สหสัมพันธ์ของเพียร์สันที่บ่งชี้ความสัมพันธ์ระหว่างตัวแปรสองตัว ค่ายิ่งสูงแสดงถึงตัวแปรป้อนเข้านั้นจะยังมีบทบาทสำคัญต่อการพยากรณ์ รูปที่ 3 และ 4 แสดงตารางเมทริกซ์สหสัมพันธ์แบบแผนภูมิความร้อน (Heat Map) ใช้ความเข้มของสีในการนำเสนอข้อมูล ยิ่งสีเข้มขนาดความสัมพันธ์ก็จะยิ่งสูงขึ้นและแสดงผลเป็นตัวเลขในแต่ละช่องของตารางด้วย

หลังการจัดการกับข้อมูลสูญหาย ตัวแปร Rainfall ถูกตัดทิ้งไม่อยู่ในขอบข่ายการศึกษา เนื่องจากจำนวนข้อมูลสูญหายมีมากเกินไป ดังนั้นพื้นที่ทั่วไปจึงมีตัวแปร 11 ตัว ได้แก่ PM2.5 PM10 CO SO2 NO2 O3 Temp Hum Press WindSp และ WindDir (ดูตารางที่ 1) จากรูปที่ 3 จะเห็นว่าตัวแปรป้อนเข้าที่มีอิทธิพลต่อตัวแปรผลลัพธ์ (PM2.5) สูงสุด 5 อันดับแรกคือ PM10 NO2 CO O3 และ SO2 ส่วนริมถนนมีตัวแปรเกี่ยวข้อง 9 ตัว ได้แก่ PM2.5 PM10 CO NO2 Temp Hum Press WindSp WindDir และตัวแปรป้อนเข้าสำคัญสุด 5 อันดับคือ PM10 Press Hum CO และ NO2 ดังรูปที่ 4 ตัวแปรป้อนเข้าที่นำมาใช้สร้างแบบจำลองถือเป็นปัจจัยหนึ่งที่มีผลต่อความถูกต้องของการพยากรณ์ งานวิจัยนี้คัดเลือกตัวแปรป้อนเข้าที่แตกต่างกันลงในแบบจำลอง ทำให้ได้แบบจำลอง 8 แบบดังตารางที่ 3 โดยใช้หลักเกณฑ์ดังนี้

- เลือกตัวแปรป้อนเข้าที่มีสัมประสิทธิ์สหสัมพันธ์สูงสุด 5 อันดับ
- ใช้ตัวแปรเช่นเดียวกับเกณฑ์ที่ 1 และเพิ่มตัวแปรค่า PM2.5 ของวันก่อนหน้านั้น (LAGPM2.5)



รูปที่ 3 : แผนภูมิความร้อนเมทริกซ์สหสัมพันธ์สำหรับพื้นที่ทั่วไป



รูปที่ 4 : แผนภูมิความร้อนเมทริกซ์สหสัมพันธ์สำหรับพื้นที่ริมถนน

ตารางที่ 3 : ตัวแปรในแบบจำลอง

แบบจำลอง	ตัวแปรป้อนเข้า	
1	พื้นที่ทั่วไป	PM10 NO2 CO O3 SO2
2		PM10 NO2 CO O3 SO2 LAGPM2.5
3		PM10 NO2 CO O3 SO2 Temp Hum Press WindSp WindDir
4		PM10 NO2 CO O3 SO2 Temp Hum Press WindSp WindDir LAGPM2.5
5	พื้นที่ริมถนน	PM10 Press Hum NO2 CO
6		PM10 Press Hum NO2 CO LAGPM2.5
7		PM10 NO2 CO Temp Hum Press WindSp WindDir
8		PM10 NO2 CO Temp Hum Press WindSp WindDir LAGPM2.5


- รวมเอาตัวแปรทั้งหมดเข้าไว้ในแบบจำลอง
- เลือกใช้ตัวแปรตามเกณฑ์ที่ 3 และเพิ่มตัวแปร LAGPM2.5

3.3) การสร้างแบบจำลองและพยากรณ์

3.3.1) หน่วยความจำระยะสั้นแบบยาว แนวคิดเรื่องโครงข่ายประสาทเทียมถูกกำเนิดขึ้นมาตั้งแต่ต้นทศวรรษ 40 (พ.ศ. 2486) McCulloch และ Pitts [14] นำเสนอโครงข่ายประสาทเทียมอย่างง่ายมีรากฐานมาจากศาสตร์ทางด้านสรีรวิทยาและการทำงานของเซลล์ประสาทในสมองมนุษย์ ซึ่งได้รับความสนใจจากนักวิจัยและเกิดการพัฒนามาอย่างต่อเนื่องเพื่อให้ครอบคลุมปัญหาที่มีความยุ่งยากและซับซ้อน เมื่อราว ๆ 25 ปีก่อน LSTM ซึ่งจัดว่าเป็นโครงข่ายประเภท RNN ได้ถูกคิดค้นขึ้นโดย Hochreiter และ Schmidhuber [15] เพื่อใช้แก้ปัญหาบางอย่างของ RNN โดยที่ RNN เป็นโครงข่ายประสาทเชิงลึก (Deep Neural Network) มีลักษณะการทำงานแบบวนซ้ำ นอกจากจะรับข้อมูลจากข้อมูลขาเข้าแล้วยังนำเอาผลลัพธ์ของเซลล์ประสาทก่อนหน้าเข้ามารวมด้วย ทำให้ RNN สามารถใช้งานได้ดีในข้อมูลแบบเรียงลำดับ (Sequential Data) เช่น คลิปเสียง คลิปวิดีโอ ข้อความตัวอักษรและข้อมูลอนุกรมเวลา รูปที่ 5 ทางซ้ายแสดงโครงสร้าง RNN ที่มีลูปวนกลับนำผลลัพธ์กลับมาใช้ใหม่อีกครั้ง เป็นข้อมูลเข้า ส่วนในรูปด้านขวาเป็นรูปที่คลี่รูปด้านซ้ายออกเพื่อแสดงถึงขั้นตอนการทำงานที่ละเอียดขึ้น ตัวแปร x_t และ h_t แทนข้อมูลนำเข้าและข้อมูลส่งออกที่เวลา t ตามลำดับ และ A หมายถึงชั้นซ่อน (Hidden Layer) แต่บ่อยครั้งพบปัญหาเรื่องค่าเกรเดียนต์ที่น้อยมากในข้อมูลที่มีขนาดยาว หรือที่เรียกว่าปัญหาการสูญหายของเกรเดียนต์ (Vanishing Gradient Problem) จึงยากที่จะเก็บรักษาความจำระยะยาวได้


LSTM ต่อยอดมาจาก RNN เพื่อช่วยแก้ไขข้อจำกัดของ RNN ดังกล่าวข้างต้น ด้วยการออกแบบให้โครงข่ายมีความสามารถในการเรียนรู้และจดจำได้นานขึ้น ใช้ฟังก์ชันที่เปรียบเสมือนประตู (Gate) เป็นตัวคอยควบคุมการไหลของข้อมูลประกอบด้วย ประตูลืม (Forget Gate) ประตูทางเข้า (Input Gate) และประตูทางออก (Output Gate) รูปที่ 6 ตัวอย่างการทำงานภายในเซลล์ของ LSTM ประตูลืม มีหน้าที่กำหนดว่าข้อมูลที่เข้ามาควรเก็บเอาไว้หรือไม่ โดยรับข้อมูลปัจจุบันและข้อมูลจากสถานะซ่อนก่อนหน้าซึ่งใช้เป็นแหล่งข้อมูลเข้าสำหรับประตูอื่น ๆ ด้วยเช่นกันแล้วคำนวณผ่านฟังก์ชันซิกมอยด์ ประตูทางเข้า เพื่อเปิดรับข้อมูลที่เข้ามาใหม่แล้วจึงบันทึกข้อมูลลงในเซลล์ของตัว

มันเอง คำนวณผลด้วยฟังก์ชันซิกมอยด์ ในขณะที่เดียวกันจะปรับค่าของสถานะเซลล์ด้วยฟังก์ชัน $\tanh$ ประติทางออก ใช้กำหนดค่าสถานะที่ซ่อนอยู่ถัดไปรวมถึงส่งผลลัพธ์ไปเป็นข้อมูลออก ข้อมูลเข้าถูกส่งผ่านฟังก์ชันซิกมอยด์และสถานะเซลล์ผ่านฟังก์ชัน $\tanh$



รูปที่ 5 : โครงข่ายประสาทเทียมแบบวนซ้ำ (RNN)

แหล่งที่มา: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>



รูปที่ 6 : หน่วยความจำระยะสั้นแบบยาว (LSTM)

แหล่งที่มา: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

3.3.2) แบบจำลองการพยากรณ์ แบบจำลองโครงข่ายประสาทเทียม LSTM ที่ใช้คาดการณ์ค่าความเข้มข้น PM2.5 มีโครงสร้างเป็นแบบหลายชั้นคือ ชั้นอินพุต (Input layer) มีเพียงชั้นเดียวและจำนวนโหนด (Node) ในชั้นเท่ากับจำนวนตัวแปรป้อนเข้า ชั้นเอาต์พุต (Output Layer) มีชั้นเดียวและจำนวนโหนดมีค่าเท่ากับจำนวนตัวแปรผลลัพธ์ และชั้นซ่อนเป็นชั้นที่อยู่ระหว่างกลางชั้นอินพุตและเอาต์พุต ในการเรียนรู้ของแบบจำลองต้องอาศัยค่าไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งถูกกำหนดไว้ดังนี้

- จำนวนชั้นซ่อน 2 ชั้น เหมาะกับปัญหาที่ไม่ซับซ้อน [16]
- จำนวนโหนดในแต่ละชั้นซ่อน 32 โหนด ซึ่งตามหลักการทั่วไป (Rule of Thumb) จำนวนโหนดในชั้นซ่อนไม่เกินสองเท่าของ จำนวนโหนดชั้นอินพุต การศึกษาวิจัยนี้มีจำนวนโหนดชั้นอินพุตสูงสุดเท่ากับ 11 ดังนั้นจำนวนโหนดชั้นซ่อนควรน้อยกว่า $2 \times 11 = 22$ แต่ใช้จำนวนโหนดที่มากกว่าโดยแก้ปัญหาการจดจำ


รูปแบบของข้อมูลฝึกสอนมากเกินไป (Overfitting) ด้วยการสุ่มลดจำนวน โหนดบางส่วน (Dropout)

- ขนาดข้อมูลที่ใช้เพื่อการปรับค่าน้ำหนัก (Weight) ในแต่ละครั้ง (Batch Size) เท่ากับ 32 เป็นค่าทั่วไปที่ใช้สำหรับกรณีที่มีจำนวนข้อมูลไม่มากนัก (~1,000 รายการ) [17]
- จำนวนรอบที่สอน (Epoch) 100 รอบ ใช้วิธีการลองผิดลองถูก (Trial and Error) ดูจากฟังก์ชันการสูญเสีย (Loss Function) ที่ค่าลดลงไปเรื่อย ๆ จนไม่เปลี่ยนแปลงหรือเปลี่ยนแปลงน้อย
- สุ่มลดจำนวนโหนด 20% เป็นค่าเบื้องต้นที่นำมาพิจารณาการลดด้วยสัดส่วนที่มากหรือน้อยเกินไป จะทำให้ความสามารถในการทำนายผลไม่ดีเท่าที่ควร ตัวอย่างงานวิจัยที่วิเคราะห์การลดจำนวนโหนดอย่างเหมาะสมสำหรับ LSTM เสนอโดย Cheng และคณะ [18]


แบบจำลองการพยากรณ์นี้สร้างขึ้นโดยใช้ Keras และได้นำเอาวิธีการ MinMaxScaler มาปรับขอบเขตของข้อมูลให้อยู่ในช่วงเดียวกัน (Normalization) คือระหว่าง 0 กับ 1 คำนวณจากความแตกต่างของค่าปัจจุบันกับค่าต่ำสุดหารด้วยพิสัย (Range) เหมาะกับข้อมูลไม่เป็นรูประฆังคว่ำ (Normal Distribution) และสอดคล้องกับผลลัพธ์ไม่ติดค่าลบ ซึ่งได้จากฟังก์ชันการกระตุ้นรีลู (ReLU Function) ใช้อัลกอริทึม Adam (Adaptive Moment Estimation) และให้ความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error: MSE) เป็นฟังก์ชันการสูญเสียที่วัดความผิดพลาดจากการทำนาย รูปที่ 7, 8 และ 9 เป็นผลการพยากรณ์ปริมาณ PM2.5 ล่วงหน้า 1 วัน ที่ได้จากแบบจำลองที่ 6 ช่วงเดือนมีนาคมถึงพฤศจิกายนของปี 2563 โดยใช้ข้อมูลย้อนหลัง 1 วัน, 3 วัน และ 5 วัน ตามลำดับ

4) ผลการวิจัย


แบบจำลองโครงข่าย LSTM ทั้ง 8 แบบ (ดูตารางที่ 3) ถูกนำมาใช้พยากรณ์ความหนาแน่นฝุ่นละออง PM2.5 ของวันรุ่งขึ้นบริเวณพื้นที่ทั่วไปและริมถนน โดยอาศัยข้อมูลในอดีตที่ผ่านมา 1 วัน, 3 วัน และ 5 วัน รูปที่ 7-9 กราฟแสดงผลเปรียบเทียบค่าพยากรณ์ PM2.5 กับข้อมูลจริง (Actual Data) จะเห็นได้ว่าค่าพยากรณ์เพิ่มขึ้นหรือลดลงผันแปรตามฤดูกาลที่เปลี่ยนแปลงไปในลักษณะเช่นเดียวกับค่าจริงในวันนั้น ๆ ค่าพยากรณ์ในรูปที่ 7 มีความถูกต้องใกล้เคียงความจริงมากกว่าในรูปที่ 8 และ 9 ที่ซึ่งความแม่นยำของการคาดการณ์หาจากตัวชี้วัดสองตัว คือ RMSE และ MAPE ดังตาราง 4 พบว่าค่า RMSE อยู่ระหว่าง 4.55-9.76



รูปที่ 7 : เปรียบเทียบค่าพยากรณ์และค่าจริง PM2.5 (ข้อมูลย้อนหลัง 1 วัน)



รูปที่ 8 : เปรียบเทียบค่าพยากรณ์และค่าจริง PM2.5 (ข้อมูลย้อนหลัง 3 วัน)



รูปที่ 9 : เปรียบเทียบค่าพยากรณ์และค่าจริง PM2.5 (ข้อมูลย้อนหลัง 5 วัน)

และ MAPE มีค่าในช่วง 20.47-37.28 แบบจำลองที่ให้ค่า RMSE หรือ MAPE ต่ำสุดจัดว่าเป็นแบบจำลองพยากรณ์ที่ดีที่สุดในพื้นที่ทั่วไปพบว่าแบบจำลองที่ 2 ซึ่งใช้ตัวแปรในการศึกษาจากการคัดเลือกตัวแปรสำคัญร่วมกับตัวแปร LAGPM2.5 (ตัวแปรค่า PM2.5 ของวันที่ผ่านมา) เป็นแบบจำลองที่มีความแม่นยำสูงสุด สำหรับพื้นที่ริมถนนพบว่าแบบจำลองที่ 8 ประกอบด้วยตัวแปรทั้งหมดและ LAGPM2.5 ทำนายล่วงหน้าอย่างถูกต้องแม่นยำที่สุด และยังเห็นได้ชัดว่าแบบจำลองบริเวณริมถนน (แบบจำลองที่ 5-8) ให้ความผิดพลาดที่ได้จากการพยากรณ์น้อย

กว่าแบบจำลองในพื้นที่ทั่วไป (แบบจำลองที่ 1-4) และการทำนายด้วยข้อมูลย้อนหลังในระยะเวลาสั้นกว่าจะให้ความแม่นยำที่เพิ่มขึ้น ซึ่งข้อมูลย้อนหลัง 1 วันให้ความคลาดเคลื่อนต่ำสุด

ตารางที่ 4 : ผลเปรียบเทียบความแม่นยำของแบบจำลองพยากรณ์

แบบจำลอง	RMSE			MAPE		
	1 วัน	3 วัน	5 วัน	1 วัน	3 วัน	5 วัน
1	7.98	8.29	9.76	32.68	34.22	33.58
2	7.73	7.89	8.52	27.81	26.28	27.57
3	8.31	8.49	9.36	32.02	33.75	37.28
4	7.82	7.66	8.69	31.43	29.67	29.78
5	5.09	5.71	5.90	24.45	28.42	28.88
6	4.82	5.05	5.36	22.88	24.27	25.57
7	5.02	4.84	6.58	22.96	21.96	30.08
8	4.55	4.75	5.18	20.47	23.11	24.13

5) สรุปและอภิปรายผล

โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาวได้ถูกนำมาประยุกต์ใช้ในการสร้างแบบจำลองการทำนายระดับความเข้มข้นของสารมลพิษอากาศ PM2.5 ในกรุงเทพมหานคร บริเวณพื้นที่ทั่วไปและพื้นที่ริมถนน รวมทั้งสิ้นจำนวน 8 แบบจำลอง โดยเปรียบเทียบประสิทธิภาพการพยากรณ์ด้วยค่าความคลาดเคลื่อน RMSE และ MAPE พบว่าพื้นที่ทั่วไปแบบจำลองที่ 2 สามารถทำนาย PM2.5 ได้แม่นยำที่สุดเพราะเลือกใช้ตัวแปร 5 ตัวที่มีอิทธิพลสูงสุดต่อตัวแปรผลลัพธ์รวมถึง LAGPM2.5 ที่เป็นค่า PM2.5 ของวันก่อนหน้า ในพื้นที่ริมถนนแบบจำลองที่ 8 เป็นตัวแบบพยากรณ์ที่ดีที่สุด ใช้ตัวแปรทุกตัวร่วมกับ LAGPM2.5 อีกทั้งแบบจำลองอื่น (ตารางที่ 4) ที่มี LAGPM2.5 เป็นตัวแปรป้อนเข้าให้ผลการคาดการณ์ได้ดีกว่ากรณีละเลย LAGPM2.5 จึงสรุปได้ว่า LAGPM2.5 เป็นตัวแปรสำคัญที่ควรมีอยู่ในแบบจำลองการพยากรณ์ เมื่อพิจารณาตัวแปรในแบบจำลองที่ 8 จะเห็นว่าตัวแปรบางตัวมีความสัมพันธ์เกี่ยวข้องน้อยมากกับตัวแปรผลลัพธ์ ดังนั้นการคัดเลือกตัวแปรเข้าด้วยค่าสัมประสิทธิ์สหสัมพันธ์อาจเป็นวิธีการที่ไม่ดีเท่าที่ควรกับปัญหาวิจัยนี้ ผลการศึกษาปรากฏว่าการใช้ข้อมูล 1 วันย้อนหลังให้ความถูกต้องแม่นยำของค่าพยากรณ์มากขึ้นด้วยเหตุผลที่ข้อมูลล่าสุดเป็นข้อมูลที่ใกล้เคียงกับปัจจุบันมากที่สุด ในการสร้างแบบจำลองการพยากรณ์นั้นควรคำนึงถึงปัจจัยที่อาจส่งผลกระทบต่อความแม่นยำของการคาดประมาณ ตัวอย่างเช่น การกำหนดค่าไฮเปอร์พารามิเตอร์ และวิธีการประมาณค่าสูญหาย เป็นต้น

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนอุดหนุนการวิจัยจากกองทุนสนับสนุนการวิจัย นวัตกรรมและการสร้างสรรค์ มหาวิทยาลัยศิลปากร ประจำปี 2562 และได้รับความอนุเคราะห์อย่างยิ่งด้านข้อมูลเพื่อการวิจัยจากกองจัดการคุณภาพอากาศและเสียง กรมควบคุมมลพิษ กระทรวงทรัพยากรธรรมชาติและสิ่งแวดล้อม และกรมอุตุนิยมวิทยา กระทรวงดิจิทัลเพื่อเศรษฐกิจและสังคม ผู้วิจัยจึงขอขอบพระคุณอย่างสูงมา ณ โอกาสนี้

REFERENCES

- [1] Coconuts Bangkok. "2 Thai cities cracked world's top 10 worst air pollution list this morning." COCONUTS.co. <https://coconuts.co/bangkok/news/2-thai-cities-cracked-worlds-top-10-worst-air-pollution-list-morning/> (accessed Feb. 28, 2022).
- [2] Prachachat. "PM 2.5 dust pushes Chiang Mai, the world's number 1 toxic air." PRACHACHAT.net. <https://www.prachachat.net/general/news-625935> (accessed Nov. 16, 2021).
- [3] A. Kurt, B. Gulbagci, F. Karaca, and O. Alagha, "An online air pollution forecasting system using neural networks," *Environ. Int.*, vol. 34, no. 5, pp. 592–598, Jul. 2008.
- [4] P. Perez, A. Trier, and J. Reyes, "Prediction of PM2.5 concentrations several hours in advance using neural networks in Santiago, Chile," *Atmos. Environ.*, vol. 34, no. 8, pp. 1189–1196, Jun. 2000.
- [5] D. Voukantsis, K. Karatzas, J. Kukkonen, T. Räsänen, A. Karppinen, and M. Kolehmainen, "Intercomparison of air quality data using principal component analysis, and forecasting of PM10 and PM2.5 concentrations using artificial neural networks, in Thessaloniki and Helsinki," *Sci. Total Environ.*, vol. 409, no. 7, pp. 1266–1276, Mar. 2011.
- [6] M. Opera, M. Popescu, and S. Mihalache, "A neural network based model for PM2.5 air pollutant forecasting," in *20th Int. Conf. Syst. Theory, Control and Comput. (ICSTCC)*, Sinaia, Romania, Oct. 2016, pp. 776–781, doi: 10.1109/ICS TCC.2016.7790762.
- [7] H. Chang-Hoi et al., "Development of a PM2.5 prediction model using a recurrent neural network algorithm for the Seoul metropolitan area, Republic of Korea," *Atmos. Environ.*, vol. 245, Jan. 2021, Art. no. 118021.
- [8] Y.-T. Tsai, Y.-R. Zeng, and Y.-S. Chang, "Air Pollution Forecasting Using RNN with LSTM," in *IEEE 16th Intl. Conf. Dependable, Autonomic and Secure Comput., 16th Intl. Conf. Pervasive Intell. and Comput., 4th Intl. Conf. Big Data Intell. Comput. Cyber Sci. and Technol. Congr. (DASC/PiCom /DataCom/CyberSciTech)*, Athens, Greece, Aug. 2018, pp. 1074–1079.
- [9] Y. Bai, B. Zeng, C. Li, and J. Zhang, "An ensemble long short-term memory neural network for hourly PM2.5 concentration forecasting," *Chemosphere*, vol. 222, pp. 286–294, May 2019.
- [10] K. Thaweephol and N. Wiwatwattana, "Long short-term memory deep neural network model for PM2.5 forecasting in the Bangkok urban area," in *17th Int. Conf. ICT and Knowl. Eng. (ICT&KE)*, Bangkok, Thailand, Nov. 2019, pp. 1–6.
- [11] P. Rong-O and N. Wiwatwattana, "The impact of data imputation and feature extraction on PM2.5 forecasting performance in Bangkok using long short-term memory neural networks," in *11th Int. Conf. Advances Inf. Technol. (IAIT202)*, Bangkok, Thailand, Jul. 2020, pp. 1–10.
- [12] "Bangkok climate," Thai Meteorological Department, Bangkok, Thailand. Accessed: Nov. 18, 2021. [Online]. Available: <https://shorturl.asia/eYHT5>
- [13] D. Berdikulov. "Dealing with missing data." MEDIUM.com. <https://medium.com/@danberdov/dealing-with-missing-data-8b71cd819501> (accessed Jan. 23, 2022).
- [14] D. Andina and D. T. Pham, *Computational intelligence: for engineering and manufacturing*. Dordrecht, Netherlands: Springer, 2007.
- [15] C. Olah. "Understanding LSTM networks." COLAH.GITHUB.io. <http://colah.github.io/posts/2015-08-Understanding-LSTMs> (accessed Feb. 10, 2022).
- [16] J. Heaton. "The number of hidden layers." HEATON RESEARCH.com. <https://www.heatonresearch.com/2017/06/01/hidden-layers.html> (accessed Feb. 10, 2022).
- [17] Y. Bengio, "Practical recommendations for gradient-based training of deep architectures," in *Neural Networks: Tricks of The Trade*, G. Montavon, G. Orr, K. R. Müller, Eds., Heidelberg, Germany: Springer, 2012, pp. 437–478.
- [18] G. Cheng, V. Peddinti, D. Povey, V. Manohar, S. Khudanpur, and Y. Yan, "An exploration of dropout with LSTMs," in *Interspeech 2017*, Aug. 2017, pp. 1586–1590, doi: 10.21437/Interspeech.2017-129.

An Improved Linear Combination of Two Estimators for Reducing the Mean Squared Error in a Sample Survey under Simple Random Sampling

Napattchan Dansawad*

**Department of Mathematics, Faculty of Science, King Mongkut's University of Technology Thonburi, Bangkok, Thailand*

*Corresponding Author. E-mail address: napattchan.dan@kmutt.ac.th

Received: 24 November 2021; Revised: 8 February 2022; Accepted: 9 March 2022

Published online: 27 June 2022

Abstract

The objective of this paper is to improve the efficiency of a linear combination of two estimators for estimating the population mean using auxiliary information in a sample survey. We also study some properties of the new estimator by using the concept of large-sample approximations and comparing them with some existing estimators through the numerical study. To achieve this, three data sets are used to support the performance of the new estimator. It has been shown that the new estimator is equivalent in terms of efficiency as compared to usual linear regression and it is better than other existing estimators under consideration in the terms of Mean Squared Error (MSE) and Percent Relative Efficiencies (PREs).

Keywords: Study variable, Auxiliary variable, Population mean, Sample survey, Estimator

I. INTRODUCTION

It is a well-known fact that several researchers use the information of auxiliary to enhance the efficiency of their estimators in estimating the population parameters. The main aim of studies is to find out more efficient estimators than recently proposed estimators and make inferences about the unknown population parameters such as population total, population mean, population proportion, or population variance. And one of the population parameters that are widely studied and used, is the population means. For this reason, several researchers have proposed ratio, product, exponential, and regression estimators taking the usefulness of the auxiliary information for estimating the population means in recent years.

Consider a finite population $Z = \{Z_1, Z_2, \dots, Z_N\}$ of size N distinct identifiable units. Let Y and X denote the study and auxiliary variables having values y_i and x_i , $i = 1, 2, \dots, N$. Let X is correlated with Y and is used to estimate the unknown population mean $\bar{Y}$. When the mean of auxiliary variable X is available. Therefore, we can calculate the population mean $\bar{X}$. In this paper, we are interested in estimating the population mean $\bar{Y}$ of study variable Y under simple random sampling without replacement (SRSWOR), then we take a sample of size n without replacement from the population Z . We use the notation of $\bar{y}$ and $\bar{x}$ denote the sample means of bivariate (y, x) , which are unbiased estimator of the population means of $\bar{Y}$ and $\bar{X}$. Therefore, the variance or MSE of $\bar{y}$ under SRSWOR is given by

$$Var(\bar{y}) = MSE(\bar{y}) = \lambda \bar{Y}^2 C_y^2 \quad (1)$$

where $\lambda = (1 - f) / n$, $f = n / N$, $\bar{Y} = \sum_{i=1}^N y_i / N$,
 $C_y = S_y / \bar{Y}$, $S_y^2 = (N - 1)^{-1} \sum_{i=1}^N (y_i - \bar{Y})^2$.

In the situation when the correlation between study and auxiliary variables is highly positive and the regression line of study variable on an auxiliary variable

is linear and nearly through or passes the origin, the ratio estimator is suitable. The first well-known ratio estimator proposed by Cochran [1] is defined as:

$$\hat{\bar{y}}_1 = \bar{y} \left[\frac{\bar{X}}{\bar{x}} \right]; \bar{x} \neq 0 \quad (2)$$

where $\bar{y} = \sum_{i=1}^n y_i / n$, $\bar{X} = \sum_{i=1}^N x_i$, $\bar{x} = \sum_{i=1}^n x_i / n$.

On the other hand, the product estimator is preferable in the situation of a highly negative correlation between study and auxiliary variables, while the regression line of its is linear. The initial product estimator defined by Robson [2] and later revisited by Murthy [3] is given by

$$\hat{\bar{y}}_2 = \bar{y} \left[\frac{\bar{x}}{\bar{X}} \right]; \bar{X} \neq 0 \quad (3)$$

However, in many situations, the regression does not pass or pass through a point away from the origin, and in such situations, the regression estimator is generally more efficient than the ratio and product estimators. Watson [4] first applied the highly correlated auxiliary variable and proposed the usual linear regression estimator for estimating the population means, which has a formula as below:

$$\hat{\bar{y}}_3 = \bar{y} + \beta(\bar{X} - \bar{x}) \quad (4)$$

where β is the sample regression coefficient.

Later, Singh *et al.* [5] also extended the estimators of Cochran [1] Robson [2] and Murthy [3] by using the exponentiation method to propose an alternative ratio-cum-product type class of estimators for estimating the population mean. The estimator of Singh *et al.* [5] is given as follows:

$$\hat{\bar{y}}_4 = \bar{y} \left[\frac{a\bar{X} + b}{a\bar{x} + b} \right]^{2g-1} \quad (5)$$

where $a(a \neq 0)$ b and g are real constants or the functions of known parameters of auxiliary variable such as standard deviation (S_x^2), coefficient of variation (C_x), correlation coefficient (ρ_{yx}), and so on.

To the first degree of approximation, the MSEs of $\hat{y}_1$, $\hat{y}_2$, $\hat{y}_3$, and $\hat{y}_4$ are respectively given by

$$MSE(\hat{y}_1) = \lambda \bar{Y}^2 [C_y^2 + C_x^2(1-2C)] \quad (6)$$

$$MSE(\hat{y}_2) = \lambda \bar{Y}^2 [C_y^2 - C_x^2(1-2C)] \quad (7)$$

$$MSE(\hat{y}_3) = \lambda \bar{Y}^2 C_y^2 (1 - \rho_{yx}^2) \quad (8)$$

$$MSE(\hat{y}_4) = \lambda \bar{Y}^2 [C_y^2 + (2g-1)\theta C_x^2 \{(2g-1)\theta - 2C\}] \quad (9)$$

where $C_x = S_x / \bar{X}$, $S_x^2 = (N-1)^{-1} \sum_{i=1}^N (x_i - \bar{X})^2$,
 $K = \bar{X} / \bar{Y}$, $\rho_{yx} = S_{yx} / S_y S_x$, $C = \rho_{yx} C_y / C_x$,
 $\theta = a\bar{X} / (a\bar{X} + b)$,
 $S_{yx} = (N-1)^{-1} \sum_{i=1}^N (x_i - \bar{X})(y_i - \bar{Y})$.

More detailed discussion about the publication on the estimation of the population mean based on auxiliary information in SRSWOR scheme can be found in Khoshnevisan *et al.* [6], Singh and Agnihotri [7] Pandey and Dubey [8], Sisodia and Dwivedi [9], Upadhyaya and Singh [10], Singh and Tailor [11], Kadilar and Cingi [12], Yan and Tian [13], Abid *et al.* [14], Subzar *et al.* [15], Yadav *et al.* [16], Dansawad [17]–[18], Sabo *et al.* [19], Lurdjariyaporn and Dansawad [20]–[21], Ahmad *et al.* [22], Jerajuddin and Kishun [23], and so on.

The enthusiasm behind this paper is to propose a modified ratio-cum-product estimator of a population mean in the form of linear combination of two estimators by extending the estimators of Watson [4] and Singh *et al.* [5] under SRSWOR scheme when some information of auxiliary variables is known. It was also created to be compact and to be easy for calculating. We expect that the new estimator is considerably easier to use than recently other proposed estimators.

II. OBJECTIVES

1. The main objective of this study is to estimate the population mean in the form of linear combination of two estimators by extending the estimators of Watson [4] and Singh *et al.* [5] when some information of auxiliary variables is known under SRSWOR scheme.

2. This study also aims to evaluate some properties of the new estimator in the terms of MSE, and minimum MSE.

3. This study aims to perform a numerical study to assess the performance of the new estimator with the other existing estimators using Mean Squared Error (MSE) and Percent Relative Efficiencies (PREs).

III. METHODOLOGY

In this section, a modified ratio-cum-product estimator in the form of linear combination of two estimators for estimating the population mean can be defined by combining $\hat{y}_3$ in Equation (4) with $\hat{y}_4$ in Equation (5), Therefore the new estimator is given as:

$$\hat{y}_5 = [\bar{y} + \beta(\bar{X} - \bar{x})] \left[\frac{a\bar{X} + b}{a\bar{x} + b} \right]^{2g-1}. \quad (10)$$

To obtain the MSE of the $\hat{y}_5$ in Equation (10), we consider

$$\bar{y} = \bar{Y}(1 + e_0), \text{ and } \bar{x} = \bar{X}(1 + e_1) \quad (11)$$

then, we have $E(e_0) = E(e_1) = 0$, $E(e_0^2) = \lambda C_y^2$, $E(e_1^2) = \lambda C_x^2$, and $E(e_0 e_1) = \lambda C C_x^2$.

Now, rewriting Equation (10) in terms of e_0 and e_1 from (11), then Equation (10) turns into the Equation (12) as follows:

$$\hat{y}_5 = [\bar{Y}(1 + e_0) - \beta \bar{X} e_1] [1 + \theta e_1]^{(2g-1)}. \quad (12)$$

Expanding the right-hand side of Equation (12) to the first degree of approximation and retaining the terms of e_0 and e_1 , up to the second power, we get

$$\begin{aligned} \hat{y}_5 - \bar{Y} \approx \bar{Y} & \left[\frac{1 - (2g-1)\theta e_1 + g(2g-1)\theta^2 e_1^2}{1 + e_0 - (2g-1)\theta e_0 e_1} \right] \\ & - \beta \bar{X} [e_1 - (2g-1)\theta^2 e_1^2] - \bar{Y}. \end{aligned} \quad (13)$$

Squaring both sides of Equation (13) and then taking expectation, therefore the MSE of the $\hat{y}_5$ up to the first degree of approximation, as follows

$$MSE(\hat{y}_5) = \lambda [\bar{Y}^2 C_y^2 + A C_x^2 (A - 2\bar{Y}C)] \quad (14)$$

where $A = \phi K + \bar{Y}(2g-1)\theta$, $\phi = S_{yx} / S_x^2$.

To obtain the value of g that minimizes the MSE, we take partial derivative of Equation (14) with respect to g and equate it to zero as follows:

$$\frac{\partial \text{MSE}(\hat{y}_5)}{\partial g} = \lambda \left[\frac{(\phi K + \bar{Y}(2g - 1)\theta)C_x^2}{((\phi K + \bar{Y}(2g - 1)\theta) - 2\bar{Y}C)} \right] = 0$$

$$\Rightarrow g = \frac{\bar{Y}C - \phi K + \bar{Y}\theta}{2\bar{Y}\theta}. \quad (15)$$

Replacing the value of g in Equation (14) with the optimal value of g in Equation (15), we get the minimum MSE of $\hat{y}_5$ as

$$\min \text{MSE}(\hat{y}_5) = \lambda \bar{Y}^2 C_y^2 (1 - \rho_{yx}^2) = \text{MSE}(\hat{y}_3). \quad (16)$$

From Equation (16), we can see that it is equal to the MSE of usual linear regression based on the auxiliary variable under SRSWOR scheme.

To substitute the values for a , b , and g in the given Equation (5) and (10), a few members of the estimators $\hat{y}_4$ and $\hat{y}_5$ can be displayed as follows in Table 1.

Table 1: A few members of estimators $\hat{y}_4$ and $\hat{y}_5$

A few members of $\hat{y}_4$	Real constants or the functions		
	a	b	g
$\hat{y}_{4(1)} = \bar{y} \left[\frac{\bar{X} + C_x}{\bar{X} + C_x} \right]$ Sisodia and Dwivedi [9]	1	C_x	1
$\hat{y}_{4(2)} = \bar{y} \left[\frac{\bar{X}}{\bar{X}} \right]^{2C_x - 1}$ Singh <i>et al.</i> [5]	1	0	C_x
$\hat{y}_{4(3)} = \bar{y} \left[\frac{\bar{X} + C_x}{\bar{X} + C_x} \right]^{2C_x - 1}$ Singh <i>et al.</i> [5]	1	C_x	C_x
$\hat{y}_{4(4)} = \bar{y} \left[\frac{\bar{X} + \rho_{yx}}{\bar{X} + \rho_{yx}} \right]$ Singh and Tailor [11]	1	ρ_{yx}	1
$\hat{y}_{4(5)} = \bar{y} \left[\frac{\bar{X}}{\bar{X}} \right]^{2\rho_{yx} - 1}$ Singh <i>et al.</i> [5]	1	0	ρ_{yx}
$\hat{y}_{4(6)} = \bar{y} \left[\frac{\bar{X} + \rho_{yx}}{\bar{X} + \rho_{yx}} \right]^{2\rho_{yx} - 1}$ Singh <i>et al.</i> [5]	1	ρ_{yx}	ρ_{yx}
A few members of $\hat{y}_5$	Real constants or the functions		
	a	b	g
$\hat{y}_{5(1)} = [\bar{y} + \beta(\bar{X} - \bar{x})] \left[\frac{\bar{X} + C_x}{\bar{X} + C_x} \right]$ Kadilar and Cingi [12]	1	C_x	1
$\hat{y}_{5(2)} = [\bar{y} + \beta(\bar{X} - \bar{x})] \left[\frac{\bar{X}}{\bar{X}} \right]^{2C_x - 1}$ Singh <i>et al.</i> [5]	1	0	C_x
$\hat{y}_{5(3)} = [\bar{y} + \beta(\bar{X} - \bar{x})] \left[\frac{\bar{X} + C_x}{\bar{X} + C_x} \right]^{2C_x - 1}$ Singh <i>et al.</i> [5]	1	C_x	C_x
$\hat{y}_{5(4)} = [\bar{y} + \beta(\bar{X} - \bar{x})] \left[\frac{\bar{X} + \rho_{yx}}{\bar{X} + \rho_{yx}} \right]$ Kadilar and Cingi [12]	1	ρ_{yx}	1
$\hat{y}_{5(5)} = [\bar{y} + \beta(\bar{X} - \bar{x})] \left[\frac{\bar{X}}{\bar{X}} \right]^{2\rho_{yx} - 1}$ Singh <i>et al.</i> [5]	1	0	ρ_{yx}
$\hat{y}_{5(6)} = [\bar{y} + \beta(\bar{X} - \bar{x})] \left[\frac{\bar{X} + \rho_{yx}}{\bar{X} + \rho_{yx}} \right]^{2\rho_{yx} - 1}$ Singh <i>et al.</i> [5]	1	ρ_{yx}	ρ_{yx}

IV. NUMERICAL STUDY

In this section, we examine the efficiencies of the proposed estimator $\hat{y}_5$ with the other existing

estimators under three natural population data sets.

The descriptions of the parameters and constants under this study are described as follows in Table 2.

Table 2: The population data sets

Population	N	n	$\bar{Y}$	$\bar{X}$	C_y	C_x	ρ_{yx}
I: Murthy [3] y: Fixed capital x: Output	80	20	11.264	51.826	0.750	0.354	0.941
II: Cochran [24] y: The number of persons per block x: The numbers of rooms per block	10	4	101.100	58.800	0.145	0.128	0.652
III Yadav <i>et al.</i> [16] y: Yield of peppermint oil x: Cultivation area	150	40	33.460	4.200	0.760	0.730	0.910

In comparing the efficiency of the proposed estimator over other existing estimators in this present study, we have used the MSE and percent relative

efficiencies (PREs) as criteria for comparison with respect to unbiased the estimator $\bar{y}$ which details are presented in the following Table 3.

Table 3: MSE and PREs of all existing estimators

Estimator	Population					
	I		II		III	
	MSE	PRE	MSE	PRE	MSE	PRE
$\bar{y}$	2.6763	100.0000	10.4574	100.0000	11.8555	100.0000
$\hat{y}_1$	0.8952	298.9715	6.6624	156.9611	2.0682	573.2206
$\hat{y}_2$	4.4575	60.0413	14.2523	73.3730	21.6428	54.7781
$\hat{y}_3$	0.3065	873.2175	6.0119	173.9445	2.0380	581.7336
A few members of $\hat{y}_4$						
$\hat{y}_{4(1)}$	0.9032	296.3017	6.6565	157.1010	2.1377	554.6029
$\hat{y}_{4(2)}$	3.4214	78.2240	24.3060	43.0238	4.6364	255.7075
$\hat{y}_{4(3)}$	3.4160	78.3476	24.2826	43.0654	5.4134	219.0050
$\hat{y}_{4(4)}$	0.9165	292.0167	6.6326	157.6658	2.2102	536.4042
$\hat{y}_{4(5)}$	1.0433	256.5254	7.5059	139.3226	2.2155	535.1198
$\hat{y}_{4(6)}$	1.0643	251.4643	7.5198	139.0648	2.8557	415.1525
A few members of $\hat{y}_5$						
$\hat{y}_{5(1)}$	0.8991	297.6633	6.6617	156.9787	2.1291	556.8415
$\hat{y}_{5(2)}$	3.4119	78.4406	24.2784	43.0727	4.5917	258.1951
$\hat{y}_{5(3)}$	3.4065	78.5647	24.2550	43.1143	5.3624	221.0853
$\hat{y}_{5(4)}$	0.9123	293.3538	6.6377	157.5450	2.1988	539.1745

Table 3: MSE and PREs of all existing estimators (cont.)

Estimator	Population					
	I		II		III	
	MSE	PRE	MSE	PRE	MSE	PRE
A few members of $\hat{y}_5$						
$\hat{y}_{5(5)}$	1.0387	257.6595	7.4980	139.4688	2.2040	537.9200
$\hat{y}_{5(6)}$	1.0596	252.5695	7.5119	139.2111	2.8307	418.8151

It appears from Table 3 that:

(i) The estimator $\hat{y}_3$ (usual linear regression) has the smallest MSE value and the largest PRE value among all estimators considered in the same population groups. And from Equation (16), we can see that the proposed estimator $\hat{y}_5$ (at its optimal value) has MSE values equal to the estimator $\hat{y}_3$. Therefore, the estimators $\hat{y}_3$ and $\hat{y}_5$ (at its optimal value) perform the best among the mentioned estimators as it gives the smallest MSE value and the largest PRE value.

(ii) Moreover, when comparing the performance between all members of $\hat{y}_4$ and $\hat{y}_5$ by pairwise comparison, we found that all members of $\hat{y}_5$ are more efficient than all members of $\hat{y}_4$. Because they gave smaller MSE and bigger PRE in each population groups.

(iii) Besides, the estimators $\hat{y}_3$ and $\hat{y}_5$ (at its optimal value), the estimator $\hat{y}_1$ is also an appropriate choice among the estimators in this population group.

V. RESULTS AND CONCLUSION

When considering the Equation (16), it is observed that the MSE of the proposed estimator in the minimum case has the same expression as the MSE of usual linear regression estimator proposed by Watson [4], which is known to be more efficient than the ratio and product estimators. The numerical results present in Table 3 in the situation of positive correlation between the study and auxiliary variables show that the MSE of the estimators $\hat{y}_3$ (usual linear regression)

and $\hat{y}_5$ (at its optimal value) are consistently less than the other existing estimators under consideration for all three population. While, the value of PRE of the estimators $\hat{y}_3$ and $\hat{y}_5$ (at its optimal value) are persistently higher than other ones and all ratio estimators ($\hat{y}_1, \hat{y}_4, \hat{y}_5$) are consistently better in the terms of MSE and PRE than product estimator ($\hat{y}_2$). Therefore, besides the estimator $\hat{y}_3$, we recommend using the proposed estimator $\hat{y}_5$ as an alternative to the usual linear regression estimator for estimating the population mean. Because it has the same precision as the usual linear regression estimator and routinely outperforms the other existing estimators in terms of MSE and PRE under consideration.

REFERENCES

- [1] W. G. Cochran, "The estimation of the yields of the cereal experiments by sampling for the ratio of grain to total produce," *J. Agric. Sci.*, vol. 30, no. 2, pp. 262–275, Apr. 1940.
- [2] D. S. Robson, "Application of multivariate polykays to the theory of unbiased ratio-type estimation," *J. Am. Stat. Assoc.*, vol. 52, no. 280, pp. 511–522, 1957.
- [3] M. N. Murthy, "Product method of estimation," *Sankhya: Indian J. Stat., Ser. A.*, vol. 26, no. 1, pp. 69–74, 1964.
- [4] D. J. Watson, "The estimation of leaf area in field crops," *J. Agric. Sci.*, vol. 27, no. 3, pp. 474–483, 1937.
- [5] H. P. Singh, R. S. Solanki, and A. K. Singh, "A generalized ratio-cum-product estimator for estimating the finite population mean in survey sampling," *Commun. Statist. Theory Methods*, vol. 45, no. 1, pp. 158–172, 2016.

- [6] M. Khoshnevisan, R. Singh, P. Chauhan, N. Sawan, and F. Smarandache, "A general family of estimators for estimating population mean using known value of some population parameter(s)," *Far East J. Theor. Stat.*, vol. 22, no. 2, pp. 181–191, 2007.
- [7] H. P. Singh and N. Agnihotri, "A general procedure of estimating population mean using auxiliary information in sample surveys," *Stat. Transit.*, vol. 9, no. 1, pp. 71–87, 2008.
- [8] B. N. Pandey and V. Dubey, "Modified product estimator using coefficient of variation of auxiliary variate," *Assam Stat. Rev.*, vol. 2, no. 2, pp. 64–66, 1988.
- [9] B. V. S. Sisodia and V. K. Dwivedi, "A modified ratio estimator using coefficient of variation of auxiliary variable," *J. Indian. Soc. Agric. Statist.*, vol. 33, no. 2, pp. 13–18, 1981.
- [10] L. N. Upadhyaya and H. P. Singh, "Use of transformed auxiliary variable in estimating the finite population mean," *Biom. J.*, vol. 41, no. 5, pp. 627–636, 1999.
- [11] H. P. Singh and R. Tailor, "Use of known correlation coefficient in estimating the finite population mean," *Stat. Transit.*, vol. 61, no. 1, pp. 555–560, 2003.
- [12] C. Kadilar and H. Cingi, "Ratio estimators in simple random sampling," *Appl. Math. Comput.*, vol. 151, no. 3, pp. 893–902, 2004.
- [13] Z. Yan and B. Tian, "Ratio method to the mean estimation using coefficient of skewness of auxiliary variable," presented at the Int. Conf. Inf. Comput. and Appl., Tangshan, China, Oct. 15–18, 2010.
- [14] M. Abid, N. Abbas, H. Z. Nazir, and Z. Lin, "Enhancing the mean ratio estimators for estimating population mean using non-conventional location parameters," *Rev. Colomb. Estad.*, vol. 39, no. 1, pp. 63–79, 2016.
- [15] M. Subzar, S. Maqbool, T. A. Raja, and M. Abid, "Ratio estimators for estimating population mean in simple random sampling using auxiliary information," *Appl. Math. Inf. Sci. Lett.*, vol. 6, no. 3, pp. 123–130, 2018.
- [16] S. K. Yadav, M. K. Dixit, H. N. Dungana, and S. S. Mishra, "Improved estimators for estimating average yield using auxiliary variable," *Int. J. Math. Eng. Manage. Sci.*, vol. 4, no. 5, pp. 1228–1238, 2019.
- [17] N. Dansawad, "A general family of estimators to estimate population mean with two-phase sampling in the presence of non-response," *Int. J. Agricult. Stat. Sci.*, vol. 15, no. 2, pp. 523–527, 2019.
- [18] N. Dansawad, "Ratio-cum-product type of exponential estimator for the population mean in simple random sampling using the information of auxiliary variable," *Burapa Sci. J.*, vol. 25, no. 2, pp. 563–577, 2020.
- [19] S. A. Sabo, I. Z. Musa, and Y. I. Kibiya, "Developed ratio estimator for estimating population mean from a finite population using sample size and correlation," *IJRASET*, vol. 8, no. 6, pp. 904–911, 2020.
- [20] P. Lurdjariyaporn and N. Dansawad, "A general ratio type of exponential estimator for estimating the population mean under simple random sampling using the information of auxiliary variable," *J. Res. Innov. Sci Technol.*, vol. 2, no. 2, pp. 1–15, 2021.
- [21] P. Lurdjariyaporn and N. Dansawad, "Restructured class of ratio estimators for estimating the population mean using the information of auxiliary variable in simple random sampling," *J. Res. Innov. Sci. Technol.*, vol. 2, no. 2, pp. 28–44, 2021.
- [22] S. Ahmad, M. Arslan, A. Khan, and J. Shabbir, "A generalized exponential-type estimator for population mean using auxiliary attributes," *PLoS ONE*, vol. 16, no. 5, pp. 1–29, 2021.
- [23] M. Jerajuddin and M. Kishun, "Modified ratio estimators for population mean using size of the sample, selected from population," *IJSRSET.*, vol. 2, no. 2, pp. 10–16, 2016.
- [24] W. G. Cochran, "Subsampling with Units of Unequal Sizes," in *Sampling techniques*, vol. 1, 3rd ed. South Orleans, MA, USA: John Wiley & Sons, 1977.

An Innovative Virtual Kitchen Partnership-as-a-Service to Improve Efficiency of Healthy and Hygienic Meal Delivery Service Management in Culinary Industry

Metta Ongkasuwan^{1*} Chanasit Thanathawee² Charoen Russametummachot³ Akechai Judkrue⁴

^{1*,2,3,4}*MSME School of Management and Economics, Assumption University, Samut Prakan, Thailand*

*Corresponding Author. E-mail address: drmettaong@yahoo.co.th

Received: 10 December 2021; Revised: 15 February 2022; Accepted: 1 June 2022

Published online: 27 June 2022

Abstract

During COVID-19 pandemic, many food service providers and online delivery providers have changed and partnered into new business model known as virtual kitchen partnership-as-a service providers (VKPaaS) on cloud computing with focus on demand for healthy and hygienic meals with fastest delivery service to customers in health-related isolation environment. However, due to increasing problems of inaccurate delivery services, the VKPaaS attempts to improve its search engine with AI-based technologies in cloud computing and algorithms to determine the proper healthy and hygienic meals with fastest, accurate and economical delivery service from the nearest location to customers. The objective of this study is to study factors affecting new COVID generation customers decision to choose and purchase healthy and hygienic meals that have potential impact on management on efficiency of VKPaaS delivery service in health-related isolation environment. The quantitative survey and qualitative in-depth interview methods were used to collect and analyze data from 554 subjects and 18 food service providers in Thailand, China and USA during 3 months in 2020. The findings suggested a new VKPaaS efficient delivery management model for improvement and advancement of VKPaaS delivery service to new COVID generation customers with five vital variables of performance expectancy, effort expectancy, social influence, perceived trust and price that had significant impact on customers decision to choose and purchase healthy and hygienic meals from online VKPaaS providers. Recommendations for further research include state-of-the art areas of crowdsourcing, artistically design for contactless meals, robotic-mobile vehicles for live visualization service, and compliances in new emerging health-related isolation economy.

Keywords: Virtual kitchen, Isolation economy, Efficiency management, Culinary industry, Healthcare industry

I. INTRODUCTION

During global COVID-19 pandemic, many food service providers (FDP) such as restaurants, street food vendors and homemade kitchens had changed and partnered with online delivery provider (ODP) into new business models known as virtual kitchen partnership to deliver healthy and hygienic meals to locked down customers in isolated residences. The new emerging virtual kitchens partnership included independent-one shot (IO); cloud kitchen using hub and spoke (CK); ghost kitchen (GK); virtual restaurant (VR); aggregator ODP with no driver fleet; consolidator with bulk drop system; aggregator ODP with owned fleet; and aggregator with dark kitchen. Each new business model differs in services, physical requirements, kitchen facility, driver fleet and ownership of database, as shown in table 1. However, the ghost kitchen and virtual restaurant have been hasty and effortlessly adopted to provide delivery only services to take advantages of new demand, overcome shortage of revenue and quickly reduce operating cost problems than other business models [1].

Table 1: Virtual kitchen partnership business models [1]

Business Model	Code	Description	Kitchen Facility	Driver-Fleet	Database Owner
1. Independent-One Shot	IOS	Physical restaurant with delivery	Owned	Owned	Owned
2. Cloud Kitchen-Hub & Spoke	CK	Half-finished cold meals from hub to branches for reheat	Hub/branches	Owned	Owned
3. Ghost Kitchen	GK	Delivery only	Rent	ODP	Owned
4. Virtual Restaurant	VR	Delivery only	Owned	ODP	ODP
5. Consolidator-Bulk Drop System	CBDS	Pre-ordered meals to drop-off point	Rent	ODP/partner	ODP/partner
6. Aggregator ODP-No Driver Fleet	AONF	ODP with all meal menu in App	Rent	ODP	ODP
7. Aggregator ODP-Owned Driver Fleet	AODF	ODP with all hot meal menu in App	Rent	ODP	ODP
8. Aggregator ODP-Dark Kitchen	AODK	ODP rent space in strategic restaurant with all meal menu, coordinate, delivery	Rent	ODP	ODP

ODP = Online Delivery Provider

As the pandemic continued, the global demand for healthy and hygienic meals from virtual kitchen had predicted to grow at CAGR of 43.5% and reached 71 billion USD in 2027 [2]. The COVID generation

customers changing behaviors toward more healthy and hygienic meals with embracing of new technologies, such as AI and AR to design and prescribe healthy and hygienic meals had accelerated growth of virtual kitchen market share in culinary industry worldwide. Many virtual kitchen service providers took advantages of using an innovative virtual kitchen partnership as a service (VKPaaS) providers with AI-based search engine to track consumer behavior, values, tastes, diets, costs and meal-on-demand to more customers in wider areas. However, challenges for VKPaaS providers remain to be constantly advancing their services to meet accelerated demand from hasty changes in new COVID generation customers behaviors [3]. Many customers had reported disadvantages and increasing problems from errors, inaccurate, missing, stealing, no health safety, contactless, no vaccination drivers in delivery services at pick-up point and the residences. Customers demand for more efficient delivery service for COVID-free healthy and hygienic meals to their isolated residences from VKPaaS become essential research question in this study [1], [4].

The objective of this study, therefore, was to study factors affecting new COVID generation customers behavior on making decision to choose and purchase healthy and hygienic meals from virtual kitchen partnership as a service (VKPaaS) providers to their health-related isolation environment. The expected findings of new COVID generation customer behavior model would be used to improve intelligence and advancement of VKPaaS providers delivery services in culinary and related industries.

II. LITERATURE REVIEW

A. Global Virtual Kitchen Market and Culinary Industry

In 2019, many food service providers with takeaway and no dine-in physical facilities to customers using online delivery service providers such as Grubhub and

DoorDash in USA or ele.me in China via major portal provider ordering systems to generate sales and delivery services were known as cloud kitchen, ghost kitchen, dark kitchen and virtual kitchen [2]. The major global portal providers were Microsoft corporation, HTC, IKEA, Samsung Group, LG, DoorDash, Grubhub, Ubereats, Dahmakan, Starbucks, GrabFood, and others. The global virtual kitchens in culinary industry had reached market size estimation of 43.1 billion USD in 2019 with CAGR at 43.5% and predicted to reach 71.4 billion USD in 2027. The Northern America and European regions were the largest global virtual kitchen market size with the fastest expansion rate. On the contrary, Asia Pacific region, such as Japan, China, India and Thailand were under the development of virtual kitchen market with expected growth rate at the highest CAGR in 2027, followed by South America, and Middle East & Africa, as shown in figure 1 [2].




Figure 1: Global virtual kitchen market by region [2]

B. Healthy and Hygienic Customer Segmentation

As global virtual kitchen market continued to grow, customers were segmented into commercial space at approximately 33%, residential at 20%, hospitality at 15% and others at 30% in 2019. However, the hospitality customers were predicted to become the largest global virtual kitchen market segment at 35% of the culinary industry in 2027 [2].

The changing in customers behavior toward easy, fast, cost competitive, accurate healthy and hygienic eating had accelerated the growth of delivery-only with contactless from virtual kitchen business in the big cities. The embracing of technologies such as virtual reality, augmented reality, artificial intelligence and 3-D facial recognition images for customers to easily visualize, activate command and tracking with preview experience had potential to stimulate decision to choose and purchase healthy and hygienic meal online and led to an increasing market share in culinary industry.

C. Artificial Intelligence in Healthy and Hygienic Meal

In 2020, the current state of the art of using artificial intelligence in healthcare industry was valued at 4.49 billion USD and was expected to reach 34.8 billion USD at CAGR of 39.6% in 2026 [2]. The implementation of advance AI technologies in healthcare industry such as facial recognition for online real time massive data collection were advantageous in analyzing health condition and prescribing diets with accurate healthy and hygienic meal selection and efficient delivery service to isolated customers. For example, in April 2019, IBM in Cleveland USA had developed artificial intelligence algorithm for tracking, diagnosis and predicting customer dietary need with higher efficiency than human experts [5].

The relational and heterogeneous databases with advance AI rule-based algorithm were used to manage data from online real time-and-motion transaction to generate accurately design meals with optimal efficiency delivery service to influx of isolated customers in wider distance areas. Examples of attributes collected for AI rule-based data analysis from customers, virtual kitchen, delivery fleet, and suppliers of raw materials are graphically shown in table 2.

Table 2: Examples of data attributes used by AI [2]

AI-Big Data	Attributes
Customer	Demographic: health-related symptom, location, insurance, frequency of orders, facial and voice recognition, income, biometric identities Marketing-Sale: social media usage, favorite brands, music, video, emoji stickers, packaging, point-of-sale, online-customer acquisition Preferences: favorite healthy & hygienic menus, check out, payment, minimum orders, vouchers, discounts, promotion, 24-hour service, delivery charges, nearby restaurant and pick up point with no errors
Virtual Kitchen	Rent, license, kitchen staffs, equipment, robot-in-chef equipment, facilities, computer system, software, high speed internet, menus, inventory, LIVE kitchen studio, on-site cooking vending machine
Delivery Fleet	Vehicles, drivers, GPS, map, location, tracking number, driver license, vaccination, facial and voice recognition, camera, routes, plans
Raw Material Supplier	Fresh ingredients, nearby markets, local farmers, home grown, royal projects, importer, inventory, storage

The use of advance AI rule-based algorithms in virtual kitchen partnership becomes essential tools in predicting isolated individual dietary needs and responses to given meals. However, in health-related isolation environment, only isolated customers with wearable devices, high-speed internet would gain advantageous benefits from health-related AI service providers. The major global AI providers in the healthcare market in 2022 included Intel, Nvidia, Google, IBM, Microsoft, GNS Healthcare, Welltok, Benevolent AI and others [2].

D. Efficiency of Delivery Service Management.

Due to an increasing of influx to delivery and pickup orders from growing number of isolated customers, many virtual kitchens partnerships providers developed and migrated the fulfilling order operation processes to an innovative AI-based search engine in VKPaaS.

The main purposes are to share resources, outsource, share heavy capital expenditures, reduce marginal costs, reduce risk, increase investment and increase profit. More and more business owners in remote areas join VKPaaS to share virtual kitchen facilities, equipment, flexible procurement, human resources, thousands of recipes, health-related legal in

order to provide efficient delivery services to mass customers in geographically wider areas.

The VKPaaS search engine calculates location of targeted customers, matches them with designed healthy and hygienic meals, selects the nearest virtual restaurant, fastest routes, and lowest delivery cost to targeted customers residences.

However, VKPaaS search engine required and used three algorithms together to analyze data and prescribe efficient delivery service to each customer including: (1) central of gravity, (2) factor rating and (3) transportation model algorithms [5]–[8]. See graphical representation of VKPaaS Model in figure 2.




Figure 2: Virtual kitchen partnership as a service model

First, Central of gravity algorithm calculates location of nearest virtual kitchen facilities to targeted customers. See figure 3 for an equation of central of gravity algorithm [7], [9].

$$\bar{X} = \frac{\sum X_i Q_i}{\sum Q_i}$$

$$\bar{Y} = \frac{\sum Y_i Q_i}{\sum Q_i}$$

Where X = X coordinate of destination i
 Y = Y coordinate of destination i
 Q = Quantity to be shipped to destination i
(place of customer or supplier)
 $i = 1, 2, 3, \dots, n$

Figure 3: Central of gravity algorithm [7]

Second, factor rating algorithm uses AI-rule based data analysis to filter and rating variables for vital health related ingredients and designs healthy and hygienic meals that fit with each customer selection and purchased orders. Finally, transportation model algorithm calculates AI-based online real time-location metrics for fastest, easiest and least expensive routes to deliver meals to targeted customers [5]–[8]. In the transportation model, other methods may be used to improve accuracy of the calculation, such as northwest corner, steppingstone and Vogel's approximation method, see graphical representation of transportation model in figure 4 [7].

		Destination						Supply
		1	2	3	4	5	6	
Source	1	13	10	22	29	19	0	5
	2	14	13	16	21	M	0	6
	3	3	0	M	11	6	0	7
	4	18	9	19	23	11	0	4
	5	30	24	34	36	28	0	3
Demand		3	5	4	5	6	2	

Cost = $M + 260$.

Figure 4: Transportation model algorithm [7]

Although there are eight types of VKPaaS business models as shown in table 1, there are four types of VKPaaS hasty adopted and available during COVID pandemic. The four types of VKPaaS included: (1) cloud computing with high-speed internet connection only (e.g., zuul, cloud, Deliveroo, others); (2) virtual kitchen partnership providers with facilities (e.g., McDonalds, Starbucks, Chick-fill-A); (3) virtual restaurants application with artificial intelligence algorithms and delivery providers (e.g., grubhub, doordash, uber eats, whole30); and (4) robotic mobile kitchen on wheels (e.g., Zume Pizza, Ono Food). See figure 5 for graphical representation of VKPaaS in cloud computing environment.




Figure 5: VKPaaS in cloud computing

Example, ele.me one of the largest and fastest growing virtual kitchen partnership providers in Beijing and Shanghai, China owned by Alibaba group had transformed into aggregator of delivery providers without driver fleets business model with capacity of more than 800,000 virtual kitchen partnership providers to 10 million customers. Customers used online food ordering and fulfilling delivery service application every day since the beginning of COVID-19 pandemic. The graphical representation of VPKaaS business model canvas including key partners, key activities, value proposition, customer relationship, customer segments, cost structure and revenue stream is shown in figure 6 below [1].

Virtual Kitchen Partnership-as-a-Service Business Model Canvas				
Key Partners	Key Activities	Value Proposition	Customer Relationship	Customer Segments
1. Fresh ingredients 2. Kitchen Suppliers 3. Food and Beverage Suppliers 4. Operation Processing Partners 5. Logistic Partners 6. Payment Partners	1. Create VKPaaS APP with AI 2. Content creator 3. Create MOU partnerships 4. Create mass customer base 5. Create mass VK partnerships 6. Advertise VKPaaS App Key Resources 1. Capital 2. Kitchen Supplies 3. Chefs 4. Ingredients 5. Staffs 6. App Designer	1. Healthy and Hygienic meal 2. Fast delivery 3. Chef designed 4. High quality 5. Fair prices 6. Fresh ingredients 7. 24 hours service 8. Free delivery 9. No mistakes 10. Covid-19 safety packaging 11. Contactless delivery	1. Fan Club 2. Free delivery redeem point 3. Repeated order gifts 4. Smart order Assistant 5. Free dietary Information Channels 1. Social Media 2. VPKaaS APP 3. Viral Marketing 4. Portals 5. Platform	1. Office workers 2. Work-from-home workers 3. Healthcare workers 4. Eldercare 5. Hospices 6. Inner city residences 7. Millennials with smart phone 8. Smart phone users 9. Public Officers
Cost Structure 1. Marketing and sale costs 2. Kitchen operation costs 3. Healthy and hygienic meal providers costs 4. Delivery fleet management costs		Revenue Stream 1. Healthy and hygienic meals delivery 2. Beverage and other side dishes delivery		

Figure 6: Example of VKPaaS business model canvas

However, the increasing demand for food safety standards, accuracy with no mistakes, and high security standards with contactless packaging at pickup point or no delivery cost if pick up from ready-meal vending machine had accelerated the need for more efficient delivery service of healthy and hygienic meals to customers inside big cities worldwide.

The research question in this study, therefore, became which factors affecting customers decision to choose and purchase healthy and hygienic meals from virtual kitchen service providers (VKPaaS) with potential impact on the efficiency management of delivery services in health-related isolation environment.

III. RESEARCH METHODOLOGY

Due to drastic changes in behaviors of COVID generation customers, the theory of consumer behaviors on consumption values (TCV) with focus on five values of functional, conditional, social, emotional and epistemic values was adopted to develop research model to study changes in customer behavior variables that may impact the intention to purchase healthy and hygienic meals from online VKPaaS providers [1], [3], [10]. However, the specific values from extended studies of food delivery service suggested that functional value (i.e., price, food safety, health conscious), social value (i.e., prestige and social values), condition value (i.e., effort expectancy) and epistemic value (i.e., visibility) may influence customers intention to purchase in isolation [3]. Additional study on variables that may affect the intention to choose and purchase from online application with AI assistance include performance expectancy, social influence, trust, security, timeliness and task-tech fit [6]. The combination of suggested thirteen variables are adopted to develop efficient VKPaaS delivery service management in health-related isolation research model in this study. See graphical representation of

research model in figure 7 and definition with measures for variables in table 3.



Figure 7: Delivery service management research model

Table 3: Research model variables and definitions [3]

Variable	Definition and Measures
1. Performance Expectancy	Accuracy of designed and ordered healthy & hygienic meals
2. Effort Expectancy	Easy and fast to find related health and value information of designed meals
3. Social Influence	Reliable health and hygienic meals promotion
4. Trust	Use health and hygienic certification seal
5. Security	PDPA, GDPR, Cybersecurity Acts
6. Timeliness	Accurate delivery within 30 minutes
7. Task-Tech-Fit	Easy to use smart phone/tablets to order
8. Visibility	Clear picture with legal data visualization
9. Prestige & Social Value	Authentic, Certify, Creative Common, Consent, Plagiarism,
10. Affordance	Fair selection with diversity and choices
11. Price	Fair/competitive price, discount, vouchers
12. Food Safety	Vaccination, contactless, clean delivery
13. Health Conscious	Links to diet, health, risk of covid-19 information

PDPA=Personal Data Protection Act; GDPR=General Data Protection Regulation

The quantitative and qualitative research methodologies were adopted in this study. The research model was used to develop online questionnaires survey using 5-point Likert scale to collect quantitative data from randomly selected 554 subjects using online food delivery service applications during June and August in 2021. Additional 1-hour in-depth interview with 10 open ended questions method was used to collect qualitative data from randomly and conveniently selected 18 international food delivery service providers with online applications to customers facing similar COVID pandemic and health-related isolation environment in Thailand, China, and USA. The statistical analysis using multiple linear regression and

descriptive analysis methods were used to generate results and findings as presented in the next section.

IV. RESULTS AND DISCUSSION

In making decision to choose and purchase healthy and hygienic meals from VKPaaS providers with efficient delivery management, the findings suggested that new COVID generation customers were influenced by five variables including performance expectancy, effort expectancy, perceived trust, social influence, and price, respectively. See graphical representation of VKPaaS efficient delivery management model in figure 8. However, the R squared value of 0.654 in table 4 suggested that only 65% of variation in customer intention to choose and purchase healthy and hygienic meals from VKPaaS with efficient delivery service management could be explained from high correlation values of the following five variables with high Beta values and significant level less than 0.055.

Table 4: Multiple linear regression results

R Square	Std. Error	F Change	df1	df2	Sig. F Change
.654	.51745	56.348	13	387	.000

a. Predictors: (Constant), Visibility, Social Value, Perceived Safety, Social Influence, Food Safety, Performance Expectancy, Timeliness, Price, Health Conscious, Affordance, Effort Expectancy, Perceived Trust, Task-Tech-Fit

Coefficients ^a				
Model	Beta	t	Sig	VIF
(Constant)		.334	.738	
Performance Expectancy	.408	9.381	.000*	2.122
Effort Expectancy	.189	3.896	.000*	2.635
Perceived Trust	.179	3.658	.000*	2.687
Social Influence	.113	2.887	.004*	1.710
Price	.087	1.923	.055*	2.293
Affordance	.086	1.857	.064	2.391
Timeliness	.060	1.198	.232	2.783
Health Conscious	.030	.692	.489	2.141
Food Safety	-.009	-.203	.839	2.076
Visibility	-.020	-.444	.657	2.388
Security	-.041	-1.064	.288	1.647
Social Value	-.050	-1.383	.168	1.486
Task-Tech-Fit	-.056	-1.023	.307	3.311

a = Dependent Variable: Purchase Intention

First, *performance expectancy* variable referring to VKPaaS ability to accurately design, select and order healthy and hygienic meals with efficient delivery service to isolated customer had the highest impact on their decision to choose and purchase from VKPaaS

with highest Beta value of 0.408 or 40.8% influence from high performance expectancy of VKPaaS.




Figure 8: VKPaaS efficient delivery management model

Second, *effort expectancy* variable referring to VKPaaS ability to provide easily search engine in diverse choices, quickly find innovatively designed healthy and hygienic meals, make purchase order, and accurately receive meals at their isolated residence had the second highest impact on customer decision to purchase with high beta value 0.189 or 18.9% influence from effort expectancy provided by VKPaaS.

Third, *perceived trust* variable referring to VKPaaS ability to create trust from certified health and hygienic seals, warranty of accurate and on-time delivery service, compliance to PDPR (Personal Data Protection Act), GDPR (General Data Protection Regulation), cybersecurity laws and regulations on payments had the third impact on their decision with beta value of 0.179 or 17.9% influence from perceive trust on VKPaaS.

Fourth, *social influence* variable referring to VKPaaS ability to influence customer to receive reliable healthy and hygienic meal information, marketing sales and timely promotions from ethical social influencers on social media had the fourth impact on their decision with beta value of 0.113 or 11.3% influence from social influence available on VKPaaS online application.

Fifth, *price* variable referring to fair and competitive price from VKPaaS for customer selected healthy and hygienic meals, delivery cost and time had surprisingly lesser impact than four variables above with beta value of 0.087 or 8.7% influence from fair and competitive price offered by VKPaaS.

The remaining eight variables including affordance, timeliness, health conscious, food safety, visibility, security, social value and task-tech-fit variables had impact on customers decision to purchase from VKPaaS with beta values lesser than 0.87 or 8.7% of influence from VKPaaS and at significant level higher than 0.05.

However, additional findings from Cronbach's alpha coefficient or construct reliability analysis values of all variables are greater than 0.7, except for security variable with value of 0.5, as shown in table 5, suggested unexpected errors or random errors such as missing payments, stealing or infected delivery orders may occur in security of service provided by VKPaaS with beta value of -0.041 or 4.1% influence from security on customer decision with significant level of 0.168.

Although three variables of affordance, timeliness and health conscious variables have lesser impact on customers decision, the findings suggested that VKPaaS should take advantages in providing more affordable choices, thousands of recipes for healthy and hygienic meals selection from many countries and local areas with innovative health-related tastes and diets, accuracy and timely delivery service to more health-conscious customers in health-related isolation environment worldwide to stimulate customer decision to purchase from VKPaaS.

Table 5: Cronbach's Alpha and Estimated Correlation

Factor	Cronbach's Alpha	Estimated Correlation with PI
Performance Expectancy	0.873	0.726
Effort Expectancy	0.872	
Perceived Trust	0.922	
Social Influence	0.915	
Price	0.882	
Affordance	0.911	0.669
Timeliness	0.857	
Health Conscious	0.907	
Food Safety	0.829	0.644
Visibility	0.879	
Security	0.549*	0.323
Social Value	0.924	
Task-Tech-Fit	0.898	

PI = Purchase Intention

The remaining five variables of food safety, visibility, security, social value and task-tech-fit variables with lower beta value and significant levels of influence on customers decision suggested that VKPaaS should (1) add compliances with food safety on vaccination, contactless packaging, and clean delivery; (2) increase visibility with clear, attractive and innovative food-health-related pictures via high quality live AI or AR visualization technology for ease of selection; (3) compliance with health security standards such as Food and Drug Administration (FDA) or hearth association in each country; (4) increase prestige & social values with authenticity, certification, creative common, consent and no plagiarism in innovative recipes and creative packaging; and (5) add easy and fast ordering, tracking and fulfilling systems from any smart phones and AR wearable devices.

Furthermore, security variable had lowest convergent validity AVE value of 0.3785 than expected validity of 0.5 suggested that security variable was not enforced, visibled and complied in delivery services by VKPaaS.

In summary, new COVID generation customers were demanding for higher health and hygienic security standards from VKPaaS delivering service management with contactless packaging, no mistakes, no stealing and mistaken of identity in their delivery services.

Table 6: Convergent validity analysis using AMOS

Factor	AVE
Performance Expectancy	0.6442
Effort Expectancy	0.6372
Perceived Trust	0.7487
Social Influence	0.7840
Price	0.6631
Affordance	0.6760
Timeliness	0.6664
Health Conscious	0.7103
Food Safety	0.7081
Visibility	0.6523
Security	0.3785*
Social Value	0.7161
Task-Tech-Fit	0.6888

In addition, the qualitative analysis using descriptive analysis was conducted to address the challenges and problems facing delivery service management among VKPaaS providers using 1-hour in-depth interview with randomly and conveniently selected 18 international food delivery service providers with online applications to customers in global COVID pandemic and health-related isolation environment in Thailand, China, and USA.

The findings suggested that many VKPaaS providers were remarkably gaining more online sale volumes and dramatically increased in number of customers with market share of 26.9% and 47% increase in revenue year-to-year during the pandemic locked down. See performance increase findings in table 7.

Many VKPaaS providers continued to add state of the art technologies to their surviving strategy and cloud kitchen platforms, such as, intelligent scheduling, AI based-automatic dispatching, local Live with AR platforms for fulfilling order systems with 30 minutes delivery time using diversity of food choices and thousands of recipes to more locked down isolated customers in wider areas.

More needs from isolated customers had emerged and added to their food delivery services including new market-trend platforms for non-catering retail-supermarket takeout, medical errands, flowers, vegetables and fresh ingredients.

Table 7: Emerging customer needs in VKPaaS

Efficiency Issues	Description
Business Purpose	Enhancing corporate image, promote products sales, reduce sale during pandemic, reduce service costs, and want to establish a perfect information release ordering system
Timeline	Since 2018, 12 years of service with 30 minutes delivery service, creating, and adding Local LIVE service platform and AR technology to stimulate more sales
Performance	Sale volume increase, number of users increase dramatically. More restaurants in cooperated with us. Market share of hungry reached 26.9%. Revenue increased by 47% year-to-year
Online Service	Using high technology AI-based facial recognition to provide convenient and fast ordering services for consumers who are busy, do not want to go out. Offering diversity of food choices to consumers for repeated orders for a long time
Customer Needs	Adding new-retail non-catering takeout, i.e., supermarket shopping, flower ordering, medical errands, fresh vegetables, ingredients, and new market-trend platforms.

However, new issues facing VKPaaS were challenges & problems, adaptation, surviving strategy, cloud kitchen platforms, surviving factors, trend on online food and cloud kitchen, as shown in table 8.

Many VKPaaS providers encountered these challenges and problems of vast expansion by searching for more financial resources, crowdsourcing, shared investment, quick conversion from cash-in-flow to costs, compliance to localized food safety, health security of employees, vaccination, disinfection, cleanliness and others emerging issues.

Table 8: Emerging isolated economy issues

Emerging Issues	Description
Challenges Problems	High cash flow and conversion of costs, keep sustainable resources and investment, and team organization management ability
Adaptation	Adapt to surge of customer volumes, different needs, food safety, employee vaccination, disinfection and cleanliness
Surviving Strategy	Set intelligent scheduling system, used AI big data balance algorithm to realize automation dispatch.
Cloud Kitchen Platforms	Yes. Want to diversity services, attract customers, consumers with a novel enterprise model, publicized image of restaurant, gain trust and maximize profits.
Surviving Factors	Food safety, health and hygiene standards, quality and freshness of food.
Trend online Food	Develop and expand to multiple platforms, dimensions, more customers, improvement of takeout system and more diversified choices
Trend on Cloud Kitchen	Health-related "Isolated Economy" accelerated takeout, more sale channels, increase revenue and new business models.

To survive in upcoming new health-related isolation environment, many VKPaaS providers swiftly adopted

food safety, health and hygienic standards, quality and freshness of food to meet the increasing demand for online healthy and hygienic food delivery services in new emerging “Health-related Isolated Economy”.

Finally, to achieve higher efficiency in delivery service management, the findings from in-depth interview suggested that many VKPaaS providers constantly re-invested in advanced state of the art technologies to create innovative recipes with creatively designed packaging for contactless delivery service with automatic cleaning and disinfection robot using intelligence cloud-based VKPaaS software to attract mass new isolated non-sharing individual behavior customers with expected high return on their investments, as shown in table 9.

Extra allocation of funding to support compliances to food safety, health related laws and regulations in each region worldwide beyond the pandemic, such as, Food and Drugs Administration (FDA) and Heart Association were mandatory and incorporated into VKPaaS surviving strategies.

Table 9: Financial issues facing VKPaaS

Financial Issues	Description
Investment	About 500,000-1,000,000 yuan shall be increased or reduced according to medium-term operation and actual operation
Return on Investment	Expected return income of 2,000-5,000 yuan per month according to passenger flow, and provide flow from other extended businesses of the company to drive development
Fee & Cost	Rent, equipment costs, customer traffic, fee to increase business volume to online kitchen
Law & Regulations	On time and efficient food takeout, safety, quality distribution process should abide by relevant laws and regulations

In summary, the new VKPaaS efficient delivery management model for improvement and advancement of delivery service to new COVID generation customers suggested that performance expectancy, effort expectancy, social influence, perceived trust and price had significant impact on

customers with new non-sharing behavior intention to choose and purchase healthy and hygienic meals from online VKPaaS providers. However, the findings were limited to two types of VKPaaS business model with delivery only service (i.e., ghost kitchen and virtual restaurant), as shown in table 1. Therefore, VKPaaS providers are recommended to improve and advance their new VKPaaS efficient delivery management model with remaining six VKPaaS business models. Additional research studies may include VKPaaS sharing capital and resources for expansion of business in wider areas, compliance to state-of-the art of health and hygienic technologies, security standards, laws and regulations in global and local countries for influx of new demand on online innovative healthy and hygienic meals delivery services to customers in health-related isolation environment in culinary and healthcare industries in 2027.

V. CONCLUSION

During global COVID-19 pandemic, many food service providers and online delivery providers had changed their behaviors and partnered into new business known as virtual kitchen partnership as-a-service providers (VKPaaS) on cloud computing with focus on new emerging demand for healthy and hygienic meals in culinary industry with fast, easy and in-expensive delivery service to new COVID generation customers in health-related isolation environment during 2020 and 2026. The VKPaaS used search engine with AI-based technologies in cloud computing and algorithms to determine and innovatively design proper healthy and hygienic meals for customers from the nearest location. This study was conducted to improve and advance VKPaaS efficient delivery management model with vital variables affecting new isolated non-sharing behavior customers decision to choose and purchase healthy and hygienic meals from online

VKPaaS. The quantitative survey research method and qualitative in-depth interview methods collected and analyzed data from randomly selected 554 subjects and 18 food service providers in Thailand, China and USA during 3 months in 2021. The findings suggested performance expectancy, effort expectancy, social influence, perceived trust and price variables had potential impact on isolated customers intention to choose and purchase healthy and hygienic meals with efficient delivery service management to their health-related isolation environment. VKPaaS providers were recommended to comply to state-of-the art in health-related technologies, security standards, laws and regulations in many countries worldwide for efficient delivery service management to influx of new demand for innovatively designed nutrition for healthy and hygienic meals to new generation of changed behaviors customers toward more isolation and no sharing environment in culinary and healthcare industries in the year 2027.

Recommendations for further research and studies may include the research in online crowdsourcing innovation for sharing global financial, facilities, expertise and intelligence resources for advancement of VKPaaS services to new COVID generation customers in isolation economy. The research may focus on artistically design packaging for contactless meals, robotic-mobile vehicles with advanced drone technology for live visualization of automated meals preparation to pick-up-point in geographically wider areas with compliance to healthcare standards, security and regulations for new emerging health-related isolation economy.

ACKNOWLEDGEMENT

This study wishes to acknowledge ABLE-UBI Center at Assumption University, Samut Prakan Province, Thailand for contribution and supports for ongoing

research, data collection and innovative business development in culinary and healthcare industries.

REFERENCES

- [1] GDI Gottlieb Duttweiler Institute. "The food service of tomorrow: eight delivery models." GDI.ch. <https://www.gdi.ch/en/publications/trend-updates/the-food-service-of-tomorrow-eight-delivery-models> (accessed Feb. 15, 2022).
- [2] "Virtual Kitchen Market: Global Industry Analysis and Forecast (2021-2027) Size, Trends, Dynamics, Component, Segmentation, and Region," Maximize Market Research Pvt. Ltd., Pune, India, Rep. 66705, Jul. 2020. Accessed: Mar. 5, 2021. [Online]. Available: <https://www.maximizemarketresearch.com/market-report/global-virtual-kitchen-market/66705/#details>
- [3] P. Kaur, A. Dhir, S. Talwar, and K. Ghuman, "The value proposition of food delivery apps from the perspective of theory of consumption value," *Int. J. Contemp. Hosp. Manag.*, vol. 33, no. 4, pp. 1129–1159, 2021.
- [4] M. McFarland and C. Mossburg. "Thieves in LA are looting freight trains filled with packages from UPS, FedEx and Amazon." EDITION.CNN.com. <https://edition.cnn.com/2022/01/14/economy/la-freight-railroad-theft/index.html> (accessed Feb. 15, 2022).
- [5] J. Marston. "Spoon Market Map: Ghost Kitchens in 2019." THESPOON.tech. <https://thespoon.tech/market-map-ghost-kitchens-in-2019/> (accessed Feb. 5, 2022).
- [6] C. Muangmee, S. Kot, N. Meekaewkunchorn, N. Kassakorn, and B. Khalid, "Factors determining the behavioral intention of using food delivery apps during COVID-19 pandemics," *J. Theor. Appl. Electron. Commer. Res.*, vol. 16, no. 5, pp. 1297–1310, Apr. 2021, doi: 10.3390/jtaer16050073.
- [7] W. J. Stevenson, *Operation Management*, 13th ed. New York, NY, USA: McGraw-Hill, 2018, ch. 8, pp. 338–363.
- [8] J. D. Nunnally, *Psychometric Theory*, 2nd ed. New York, NY, USA: McGraw-Hill, 1978, pp. 45–87.
- [9] E. Bailyn. "The 2021 Google Algorithm Ranking Factors." LINKEDIN.com. <https://www.linkedin.com/pulse/2021-google-algorithm-ranking-factors-evan-bailyn> (accessed Dec. 20, 2021).
- [10] J. N. Sheth, B. I. Newman, and B. L. Gross, "Why we buy what we buy: A theory of consumption values," *J. Bus. Res.*, vol. 22, no. 2, pp. 159–170, Mar. 1991.

การจำแนกอาคารจากภาพถ่ายดาวเทียมโดยการถ่ายโอนความรู้

ปิยะเนตร์ ต่วนพะเอม¹ เอกรัฐ รัชกาญจน์^{2*}

^{1,2*} คณะสถิติประยุกต์ สถาบันบัณฑิตพัฒนบริหารศาสตร์

*ผู้ประพันธ์บรรณกิจ อีเมล : ekarat@as.nida.ac.th

รับต้นฉบับ : 27 ตุลาคม 2564; รับบทความฉบับแก้ไข : 6 ธันวาคม 2564; ตอบรับบทความ : 2 มีนาคม 2565

เผยแพร่ออนไลน์ : 27 มิถุนายน 2565

บทคัดย่อ

เทคโนโลยีภาพถ่ายดาวเทียมมีความสำคัญในงานทางด้านวิเคราะห์พื้นที่ทางภูมิศาสตร์ เช่น Change Detection Real Estate Analysis เนื่องจากภาพมีรายละเอียดสูงและถูกจัดเก็บไว้อย่างครบถ้วน แต่เนื่องจากผู้เชี่ยวชาญทางด้านการวิเคราะห์พื้นที่ทางภูมิศาสตร์มีจำนวนน้อยเมื่อเทียบกับพื้นที่ทางภูมิศาสตร์ของประเทศไทย ทำให้การวิเคราะห์นั้นถูกพัฒนาเป็นระบบอัตโนมัติที่มีประสิทธิภาพสูง ในงานนี้ผู้วิจัยได้สร้างระบบการจำแนกอาคารประเภทต่าง ๆ จากภาพถ่ายดาวเทียม (Buildings Classification from Satellite Images) โดยการสร้างตัวแบบการถ่ายโอนความรู้ (Transfer Learning) ด้วยชุดข้อมูลที่สร้างขึ้นใหม่ 4CateSAT ที่ประกอบด้วยภาพอาคารสถานที่ คือ (1) สนามบิน (2) สนามกีฬา (สนามฟุตบอล) (3) โรงเรียน และ (4) วัดในประเทศไทย ตลอดจนเปรียบเทียบประสิทธิภาพของระบบหลังจากดำเนินการแก้ปัญหา Imbalance Dataset โดยการปรับแต่งข้อมูล (Data Augmentation) ทั้ง 2 แบบ ซึ่งผลการทดลองแสดงค่าความแม่นยำ (Accuracy) ของตัวแบบที่ดีที่สุดเมื่อทดสอบในชุดข้อมูลทดสอบ (Test Dataset) สูงถึง 96.88%

คำสำคัญ : ภาพถ่ายดาวเทียม สโมท การเรียนรู้เชิงลึก การจำแนกประเภทข้อมูลภาพถ่าย การถ่ายโอนความรู้

Buildings Classification from Satellite Images by Transfer Learning

Piyanate Touncha-em¹ Ekarat Rattagan^{2*}

^{1,2*}*Graduate School of Applied Statistics, National Institute of Development Administration, Bangkok, Thailand*

*Corresponding Author. E-mail address: ekarat@as.nida.ac.th

Received: 27 October 2021; Revised: 6 December 2021; Accepted: 2 March 2022

Published online: 27 June 2022

Abstract

Satellite imaging technology is essential for various applications such as real estate analysis, disaster monitoring, and more. However, as satellite data is big data, it is time-consuming and challenging for humans to analyze it, even a simple task such as detecting the types of buildings in a large area. In this paper, we develop a satellite imaging-analytics technique by applying the transfer learning algorithm to learn and classify different types of buildings in Thailand. The proposed model is learnt and tested on our created datasets, namely 4CateSAT, including the images of buildings including (1) airports, (2) stadiums (football fields), (3) schools, and (4) temples in Thailand. We also apply well-known algorithms to handle the imbalanced data, and the experimental results show that the accuracy of the best model is 96.88%.

Keywords: Satellite imagery, SMOTE, Deep learning, Image classification, Transfer learning

1) บทนำ

ปัจจุบันเทคโนโลยีมีความก้าวหน้าและพัฒนาอย่างรวดเร็ว ส่งผลให้การวิเคราะห์และใช้ประโยชน์จากสิ่งต่าง ๆ หันมาพึ่งเทคโนโลยีมากขึ้น สำหรับการวิเคราะห์พื้นที่ทางภูมิศาสตร์ก็ใช้ประโยชน์จากความก้าวหน้าตรงนี้เช่นกัน เช่น การจำแนกประเภทอาคาร การตรวจจัดการใช้ที่ดิน การปรับปรุงแผนที่ทางภูมิศาสตร์

เนื่องจากนักภูมิสารสนเทศของประเทศไทย เช่น เจ้าหน้าที่ของกรมแผนที่ดิน เจ้าหน้าที่ของสำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ มีจำนวนน้อยเมื่อเทียบกับพื้นที่ทางภูมิศาสตร์ของประเทศไทยที่มีขนาดใหญ่และการประยุกต์ใช้ประโยชน์จากภาพถ่ายดาวเทียมทางภูมิศาสตร์ที่ไม่รู้จบ ทำให้เทคโนโลยีในด้านการวิเคราะห์พื้นที่ทางภูมิศาสตร์ เกิดการพัฒนาอย่างต่อเนื่อง ประกอบกับซอฟต์แวร์คอมพิวเตอร์ที่เรียกว่าการเรียนรู้เชิงลึก (Deep Learning) ก็มีบทบาทมาก ดังนั้นการวิเคราะห์ภาพถ่ายดาวเทียมทางภูมิศาสตร์จึงถูกพัฒนาให้เป็นระบบอัตโนมัติที่มีประสิทธิภาพสูง แต่ใช้เวลาและบุคลากรในการวิเคราะห์น้อย

แต่ประสิทธิภาพของระบบอัตโนมัติ นั้น ขึ้นอยู่กับชุดข้อมูลที่มีความเหมาะสม ดังนั้นควรเลือกใช้หรือสร้างชุดข้อมูลใหม่อย่างระมัดระวัง และตรวจสอบอย่างถี่ถ้วน [1] จึงเป็นเหตุผลให้ทางผู้วิจัยสร้างชุดข้อมูลใหม่ที่เรียกว่า 4CateSAT เนื่องจากภาพถ่ายดาวเทียมของประเทศไทยในหมวดหมู่ที่ต้องการศึกษา ยังไม่มีและภาพถ่ายดาวเทียมบางประเภทไม่อนุญาตให้เข้าถึงหรือเข้าถึงได้แต่เสียค่าบริการ

ในงานวิจัยชิ้นนี้ ผู้วิจัยได้สร้างระบบการจำแนกอาคารประเภทต่าง ๆ จากภาพถ่ายดาวเทียม (Buildings Classification from Satellite Images) โดยจัดเป็นหมวดหมู่ดังนี้คือ สนามบิน สนามกีฬา (สนามฟุตบอล) โรงเรียน วัดในประเทศไทย ซึ่งชุดข้อมูลที่ใช้เป็นชุดข้อมูล 4CateSAT ซึ่งผู้วิจัยได้ทำการสร้างขึ้นใหม่ โดยบันทึกภาพถ่ายดาวเทียมความละเอียดสูงจากซอฟต์แวร์กูเกิล เอิร์ธโพร (Google Earth Pro) ที่อนุญาตให้เข้าถึงได้และไม่เสียค่าบริการ ตามหมวดหมู่ที่ต้องการศึกษา แต่เนื่องจากจำนวนข้อมูลในแต่ละประเภทยังมีขนาดไม่เท่ากัน (Imbalance Dataset) ทำให้ต้องแก้ปัญหาดังกล่าวโดยการเพิ่มจำนวนข้อมูลซึ่งทางผู้วิจัยได้แบ่งวิธีการเพิ่มจำนวนข้อมูลออกเป็น 2 การทดลองดังนี้ (1) การปรับแต่งข้อมูล (Data Augmentation) โดยสร้างจากไลบรารี TensorFlow (2) การปรับแต่งข้อมูล (Data

Augmentation) โดยสร้างจากแพ็คเกจ Imblearn ที่ใช้สมิโธ (SMOTE : Synthetic Minority Over-sampling Technique) และดำเนินการสร้างระบบการจำแนกอาคารประเภทต่าง ๆ จากภาพถ่ายดาวเทียม (Buildings Classification from Satellite Images) โดยการสร้างตัวแบบการถ่ายโอนความรู้ (Transfer Learning) และเปรียบเทียบประสิทธิภาพของระบบในแต่ละการทดลอง ตลอดจนแสดงการสร้างภาพนิทัศน์จากข้อมูล (Data Visualization) ว่าตัวแบบที่ดีที่สุดจำแนกภาพว่าเป็นอาคารประเภทนั้น ๆ จากองค์ประกอบใดของภาพด้วย Grad-CAM (Gradient-weighted CAM)

2) วัตถุประสงค์ในการวิจัย

1. สร้างชุดข้อมูลภาพถ่ายดาวเทียมใหม่ 4CateSAT ให้เหมาะสมกับงาน
2. สร้างระบบการจำแนกอาคารประเภทต่าง ๆ จากภาพถ่ายดาวเทียมในประเทศไทยที่มีประสิทธิภาพ โดยจำแนกออกเป็น 4 หมวดหมู่ คือ สนามบิน สนามกีฬา (สนามฟุตบอล) โรงเรียน วัด ซึ่งอาจประยุกต์ใช้ระบบในเรื่องการตรวจจัดการใช้ที่ดิน ปรับปรุงแผนที่ทางภูมิศาสตร์ เป็นต้น

3) เอกสารและงานวิจัยที่เกี่ยวข้อง

การศึกษาครั้งนี้ได้ทบทวนแนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้องกับการพัฒนาระบบการจำแนกอาคารประเภทต่าง ๆ จากภาพถ่ายดาวเทียม โดยมีเนื้อหาเกี่ยวข้องกับการกำหนดค่าจำกัดความในด้านต่าง ๆ รวมถึงชี้ให้เห็นถึงความสำคัญของการเรียนรู้เชิงลึกต่อการวิเคราะห์ภาพ การแก้ปัญหาจำนวนข้อมูลในแต่ละประเภทยังมีขนาดไม่เท่ากัน การสร้างภาพนิทัศน์จากข้อมูลเพื่อดูประสิทธิภาพของตัวแบบ ตลอดจนทบทวนการจำแนกประเภทข้อมูลภาพถ่ายดาวเทียม (Satellite Image Classification) ในวิธีการต่าง ๆ ซึ่งผู้วิจัยได้รวบรวมข้อมูลและทฤษฎีที่เป็นประโยชน์ ต่อการวิจัยครั้งนี้ สามารถแบ่งได้ดังนี้

3.1) ความสำคัญของการเรียนรู้เชิงลึก (Deep Learning) ต่อการวิเคราะห์ภาพ

การเรียนรู้เชิงลึกเป็นศาสตร์ย่อยของการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเป็นการจำลองมาจากโครงสร้างของระบบประสาทในสิ่งมีชีวิต โดยการเรียนรู้ที่มีประสิทธิภาพเกิดจากการสร้างโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network : CNN) ซึ่งเป็นตัวแบบ

โครงข่ายประสาท (Neural Network) ขนาดใหญ่ที่มีหลายชั้น (Layers) โดยแต่ละชั้นจะเกิดการเรียนรู้ที่แตกต่างกัน และจะสกัดค่าคุณลักษณะ (Feature Extraction) อัตโนมัติ ซึ่งโครงสร้างของโครงข่ายประสาทเทียมแบบสั่งวัตนาการแสดงดังรูปที่ 1 ซึ่งสามารถพัฒนาให้เป็นตัวแบบที่มีประสิทธิภาพและนำมาใช้ในงานถ่ายโอนความรู้ (Transfer Learning) โดยมีองค์ประกอบดังนี้

- (1) Input Layer : รูปภาพสี RGB มีขนาดเป็นกว้าง*ยาว*ลึก
- (2) Convolutional Layer : อาศัยหลักการ Convolution คือ ผลคูณสเกลาร์ (Dot Product) ของเคอร์เนลหรือตัวกรอง (Filter) หรือน้ำหนัก (Weight) กับพื้นที่ส่วนย่อยในรูปภาพ เพื่อให้ได้ฟังก์ชันคุณลักษณะ (Feature Map)
- (3) Pooling Layer : การลดขนาดฟังก์ชันคุณลักษณะ โดยจะเลือกบางค่าออกมาจากในแต่ละพื้นที่ส่วนย่อย โดยการคำนวณที่นิยมมี 2 แบบ คือ Max Pooling (เลือกค่าที่สูงที่สุดจากพื้นที่ส่วนย่อยนั้น) และ Average Pooling (เลือกค่าเฉลี่ยของพื้นที่ส่วนย่อยนั้น)
- (4) Fully Connected Layer : ทำหน้าที่ในการเรียนรู้และจำแนกประเภทข้อมูลภาพ
- (5) Output Layer : แสดงประเภทข้อมูลภาพที่ได้จากการเรียนรู้

ในระหว่างการฝึก (Train) นั้น นิวรอนจะปรับปรุงค่าน้ำหนักโดยใช้อัลกอริทึมทางคณิตศาสตร์ที่เรียกว่าการหาค่าเหมาะสม (Optimization) เพื่อให้ตัวแบบเกิดการเรียนรู้มากที่สุดซึ่งหมายความว่าค่าปรับจนกว่าค่าผิดพลาด (Error) จะน้อยที่สุดหรือยอมรับได้

ทำให้เกิดตัวแบบที่มีประสิทธิภาพ จึงเกิดการถ่ายโอนความรู้ (Transfer Learning) [1] จากตัวแบบที่มีประสิทธิภาพนั้นมา

ประยุกต์ใช้กับตัวแบบอีกงานหนึ่งได้ ทำให้งานใหม่มีค่าความแม่นยำ (Accuracy) ที่ดีขึ้น และประหยัดเวลาในการฝึก

3.2) การแก้ปัญหาจำนวนข้อมูลในแต่ละประเภทมีขนาดไม่เท่ากัน (Imbalance Dataset)

3.2.1) การปรับแต่งข้อมูลแบบ TensorFlow เป็นเทคนิคการเพิ่มจำนวนข้อมูล โดยคุณลักษณะหลักยังคงเดิมแต่เกิดภาพที่มีลักษณะแตกต่างกันออกไป เช่น การพลิกภาพ (Flip) การเลื่อนภาพ (Shift) การหมุนภาพ (Rotation) และยังเป็นการเพิ่มความหลากหลายให้กับชุดข้อมูล ตัวแบบก็จะเรียนรู้ได้ดีขึ้นและลดปัญหา Overfit ลง [2]

3.2.2) การปรับแต่งข้อมูลแบบสโมท เป็นเทคนิคการสุ่มเพิ่มจำนวนข้อมูลกลุ่มน้อย ให้มีจำนวนใกล้เคียงกับข้อมูลกลุ่มหลัก (Over-sampling) แต่ข้อมูลใหม่นั้นมาจากการสังเคราะห์ โดยใช้อัลกอริทึมเพื่อนบ้านที่ใกล้ที่สุด (K-nearest neighbor) และดำเนินการตามสมการที่ (1) ซ้ำหลายครั้งจนกระทั่งจำนวนข้อมูลกลุ่มน้อยมีจำนวนใกล้เคียงกับข้อมูลกลุ่มหลัก [3]


$$x_{new} = x_i + \lambda(x_{zi} - x_i) \quad (1)$$

โดยที่ x_{new} หมายถึง ข้อมูลใหม่ที่จะถูกสร้างขึ้นโดยพิจารณาจากเพื่อนบ้านใกล้เคียง k แห่ง

x_i หมายถึง ตัวอย่างข้อมูลในกลุ่มน้อยที่ถูกเลือก (จากการสุ่ม)

x_{zi} หมายถึง เพื่อนบ้านที่ใกล้ที่สุดที่ถูกเลือก

λ หมายถึง ค่า 1 ค่าที่อยู่ระหว่าง 0 ถึง 1 (จากการสุ่ม)



รูปที่ 1 : โครงสร้างของโครงข่ายประสาทเทียมแบบสั่งวัตนาการ (Convolutional Neural Network : CNN)

3.3) การสร้างภาพนิทัศน์จากข้อมูล (Data Visualization)

Grad-CAM (Gradient-weighted CAM) [4] เป็น CNN Visualization ใช้เพื่อบอกว่าตัวแบบจำแนกภาพว่าเป็นประเภทนั้น ๆ จากองค์ประกอบใดของภาพ โดยแสดงผ่านแผนภูมิความร้อน (Heatmap) ซึ่งการทำงานของ Grad-CAM คือ หาเกรเดียนต์ของค่าทำนายก่อนที่จะทำการ Normalize ใน Softmax ของหมวดหมู่นั้น ๆ กับ Feature Map Activation (ผลลัพธ์ของ Conv Layer ชั้นสุดท้าย) แต่ละแผ่น นำค่าเกรเดียนต์ที่ได้มาหา Global Average Pooling ทีละค่าจะได้ค่าแอลฟา และหาผลรวมเชิงเส้น (Linear Combination) ระหว่างค่าแอลฟาและ Feature Map Activation และผ่านฟังก์ชัน ReLU ก็จะได้ Grad-CAM Heatmap ซึ่งการทำงานของ Grad-CAM แสดงดังรูปที่ 2

3.4) การจำแนกประเภทข้อมูลภาพถ่ายดาวเทียม (Satellite Image Classification)

ในงานวิจัย [6] ได้ทำการจำแนกประเภทข้อมูลภาพถ่ายดาวเทียมโดยการเรียนรู้เชิงลึก ซึ่งใช้ชุดข้อมูล Functional Map of the World ของ IARPA ประกอบด้วยภาพถ่ายดาวเทียม 63 หมวดหมู่ (1 ล้านภาพ) มาพร้อมกับข้อมูลรายละเอียดของแต่ละภาพ


สำหรับการฝึกโครงข่ายประสาทเทียมแบบสังวัตนาการฝึก โดยการสร้างตัวแบบถ่ายโอนความรู้จากตัวแบบที่มีประสิทธิภาพ คือ VGG16 InceptionV3 ResNet50 ResNet152 DenseNet161 ทำการปรับแต่งข้อมูลเพียงการพลิกภาพ 90° 180° 270° เพราะพบว่าการเลื่อนภาพ และการหมุนภาพไม่ได้ทำให้ผลลัพธ์ดีขึ้น อีกทั้งยังได้ทดลองฝึกตัวแบบเองแต่ตัวแบบที่ได้จากการถ่ายโอนความรู้มีค่าความแม่นยำ (Accuracy) และประหยัดเวลาในการฝึกมากกว่า ตลอดจนทดลองปรับจูน (Fine-tuning) เข้าไปในชั้นที่ลึกขึ้นแต่ผลลัพธ์ก็ไม่ได้ดีขึ้น จากตัวแบบที่สร้างได้มีค่าความ

แม่นยำ (Accuracy) สูงถึง 83% ในชุดข้อมูลตรวจสอบความถูกต้อง (Validation Dataset)

อีกงานวิจัยที่น่าสนใจคือการจำแนกประเภทที่ดิน (Land Use and Land Cover Classification) โดยการเรียนรู้เชิงลึก [7] ซึ่งใช้ชุดข้อมูลที่ทำกรสร้างใหม่ EuroSAT โดยเลือกข้อมูลมาจากภาพถ่ายดาวเทียม Sentinel-2 ประกอบด้วยภาพถ่ายดาวเทียม 10 หมวดหมู่ (27,000 ภาพ) โดยแบ่งเป็นชุดข้อมูลฝึก (Train Dataset) : ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Dataset) = 80 : 20 และได้ศึกษาจนค้นพบว่าการสร้างตัวแบบที่ได้จากการถ่ายโอนความรู้ เหมาะกับชุดข้อมูลที่เป็นภาพถ่ายดาวเทียม

สำหรับการฝึกสรุปได้ว่าการใช้ภาพถ่ายดาวเทียมเป็นภาพสี RGB ดีกว่า CI และ SWIR อีกทั้งสรุปได้ดีกว่าการฝึกด้วย deepCNN (GoogleNet และ ResNet50) มีประสิทธิภาพดีกว่า shallowCNN และ shallowCNN มีประสิทธิภาพดีกว่า BoVW (SIFT+SVM) จากตัวแบบที่สร้างได้มีค่าความแม่นยำ (Accuracy) สูงถึง 98.57%

ระหว่างการฝึก เพื่อปรับปรุงค่าน้ำหนักมีไฮเปอร์พารามิเตอร์ที่เป็นที่นิยมที่สุดคือ Optimizer ที่ชื่อ Adaptive Moment Estimation (Adam) เพราะจะปรับ อัตราการเรียนรู้ (Learning Rate) ให้อัตโนมัติ งบประมาณ Decaying Learning Rate ของเกรเดียนต์ซึ่งช่วยให้ตัวแบบไม่หยุดการเรียนรู้ และลู่เข้าได้เร็วกว่า Gradient Descent อีกทั้งพารามิเตอร์ไม่แกว่ง เพราะให้ความสำคัญในเรื่องการพุ่งไปยังทิศทางที่ใกล้จุดกลางมากที่สุดก่อน [8] และ ไฮเปอร์พารามิเตอร์อีกตัวที่น่าสนใจคือ kernel_initializer (วิธีการกำหนดน้ำหนักกลุ่มเริ่มต้นของชั้น Keras) ที่ชื่อ HeNormal เนื่องจากมีความเหมาะสมหากฟังก์ชันกระตุ้น (Activation Function) เป็น ReLU เพราะจะช่วยให้ตัวแบบไม่หยุดการเรียนรู้และเรียนรู้ได้รวดเร็วมากขึ้น [9]




รูปที่ 2 : การทำงานของ Grad-CAM (Gradient-weighted CAM) [5]

4) วิธีดำเนินการวิจัย

ในงานวิจัยชิ้นนี้ ผู้วิจัยได้กำหนดวิธีดำเนินการวิจัยไว้ 4 ส่วน แสดงดังต่อไปนี้

4.1) แผนภาพการดำเนินงาน



รูปที่ 3 : แผนภาพการดำเนินงาน

4.2) ชุดข้อมูล (Dataset)

รูปที่ 3 ข้อ (1) แสดงให้เห็นการสร้างชุดข้อมูล 4CateSAT ซึ่งผู้วิจัยได้ทำการสร้างขึ้นใหม่ โดยบันทึกภาพถ่ายดาวเทียมความละเอียดสูงจากซอฟต์แวร์กูเกิล เอิร์ธโพร (Google Earth Pro) เป็นเครื่องมือที่มีประสิทธิภาพสำหรับการดูข้อมูลทางภูมิศาสตร์ โดยมีแหล่งที่มาภาพจากบริษัทดาวเทียมหลายแห่ง (เช่น U.S. public domain, คีย์โฮล, กูเกิลแมพ, ซิตี้เซตส์ (CitySets)) ซึ่งภาพเหล่านี้ถูกรวบรวมกันเป็นภาพโมเสกที่ถ่ายจากหลายระยะเวลา ซึ่งชุดข้อมูลชุดนี้ประกอบด้วย ภาพถ่ายดาวเทียมในหมวดหมู่สนามบิน สนามกีฬา (สนามฟุตบอล) โรงเรียน วัด ซึ่งอยู่ในประเทศไทย จำนวน 1,402 ภาพ โดยได้ดำเนินการเก็บข้อมูลเป็นระยะเวลาประมาณ 2 เดือน ระหว่างเดือน กุมภาพันธ์-มีนาคม 2564 โดยชุดข้อมูลภาพถ่ายทางดาวเทียมในแต่ละประเภท ผู้วิจัยจะเลือกเฉพาะภาพที่มีคุณลักษณะเด่น ๆ ตามที่ผู้วิจัยกำหนดดังแสดงในตารางที่ 1 ดังนั้นหากเป็นภาพที่ไม่มีคุณลักษณะเด่นตามที่ผู้วิจัยกำหนดอาจจำแนกประเภทคลาดเคลื่อน สำหรับตัวอย่างภาพในชุดข้อมูล 4CateSAT จะแสดงในรูปที่ 4 [10]

ตารางที่ 1 : คุณลักษณะเด่นของภาพในแต่ละหมวดหมู่


หมวดหมู่	คุณลักษณะเด่นของภาพ
สนามบิน	ลานบิน (Runway) เครื่องบิน
สนามกีฬา (สนามฟุตบอล)	สนามฟุตบอล
โรงเรียน	อาคาร สนามกีฬาต่าง ๆ
วัด	เจดีย์ หลังคาสีส้มเป็นกลุ่ม ๆ

4.3) การเตรียมข้อมูล

จากรูปที่ 3 ข้อ (2) เนื่องจากภาพถ่ายดาวเทียมในชุดข้อมูล 4CateSAT มีขนาดประมาณ 4800*2600 ผู้วิจัยได้ปรับเป็นขนาด 256*256 (ขนาดภาพที่ใหญ่ที่สุดที่โปรแกรมจะสามารถรัน SMOTE ได้) และดำเนินการแบ่งชุดข้อมูลโดยแยกชุดข้อมูลทดสอบ (Test Dataset) ออกมา 64 ภาพ แล้วจึงแบ่งเป็นชุดข้อมูลฝึก (Train Dataset) : ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Dataset) = 80%(1,073ภาพ) : 20%(265ภาพ) นำเข้าตัวแบบเป็น BatchDataset ทีละ 32 ภาพ ซึ่งจำนวนภาพในแต่ละหมวดหมู่ของชุดข้อมูลฝึก (Train Dataset) ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Dataset) และชุดข้อมูลทดสอบ (Test Dataset) แสดงในรูปที่ 5 แต่เนื่องจากจำนวนข้อมูลในแต่ละประเภทยังมีขนาดไม่เท่ากัน (Imbalance Dataset) ทำให้ต้องแก้ปัญหาดังกล่าวโดยการเพิ่มจำนวนข้อมูล ซึ่งทางผู้วิจัยได้แบ่งวิธีการเพิ่มจำนวนข้อมูลออกเป็น 2 การทดลองดังนี้ (1) การปรับแต่งข้อมูลแบบ TensorFlow เลือกใช้ Flip('horizontal') และ Rotation(0.2) จากไลบรารีสำเร็จรูป TensorFlow โดยคุณลักษณะหลักของภาพยังคงเดิมแต่เกิดภาพที่มีลักษณะแตกต่างกันออกไป ซึ่งตัวอย่างภาพหลังจากทำการปรับแต่งข้อมูลของการทดลองที่ 1 แสดงในรูปที่ 6 (ภาพซ้าย) (2) การปรับแต่งข้อมูลแบบสโมท สร้างจากแพ็คเกจสำเร็จรูป Imblearn ที่ใช้สโมท โดยหลักการ Over-sampling แต่ข้อมูลใหม่นั้นมาจากการสังเคราะห์ สำหรับตัวอย่างภาพหลังจากทำการปรับแต่งข้อมูลของการทดลองที่ 2 แสดงในรูปที่ 6 (ภาพขวา) และจำนวนภาพในแต่ละหมวดหมู่ของชุดข้อมูลฝึก (Train Dataset) และชุดข้อมูลตรวจสอบความถูกต้อง (Validation Dataset) หลังจากดำเนินการตามการทดลองที่ 2 แสดงในรูปที่ 7




รูปที่ 4 : ตัวอย่างภาพในชุดข้อมูล (Dataset) 4CateSAT ที่บันทึกภาพจากซอฟต์แวร์กูเกิล เอิร์ธโพร (Google Earth Pro)
แหล่งที่มา : Google Earth, Image © 2021 Maxar Technologies (ภาพบนซ้าย-ขวา, ภาพล่างขวา) [10], Google Earth, Image © 2021 CNES/Airbus (ภาพล่างซ้าย) [10]



รูปที่ 5 : จำนวนภาพในแต่ละหมวดหมู่ของชุดข้อมูลฝึก (Train Dataset) ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Dataset) และชุดข้อมูลทดสอบ (Test Dataset)



รูปที่ 6 : ตัวอย่างภาพหลังจากทำการปรับแต่งข้อมูล (Data Augmentation) ของการทดลองที่ 1 (ภาพซ้าย)
ตัวอย่างภาพหลังจากทำการปรับแต่งข้อมูล (Data Augmentation) ของการทดลองที่ 2 (ภาพขวา)
แหล่งที่มา : Google Earth, Image © 2021 CNES / Airbus (ภาพซ้าย) [10] และ Google Earth (ภาพขวา) [10]



รูปที่ 7 : จำนวนภาพในแต่ละหมวดหมู่ของชุดข้อมูลฝึก (Train Dataset) และชุดข้อมูลตรวจสอบความถูกต้อง (Validation Dataset) หลังจากดำเนินการตามการทดลองที่ 2

4.4) การวิเคราะห์ข้อมูล

ในส่วนรูปที่ 3 ข้อ (3) สร้างตัวแบบจากการถ่ายโอนความรู้ โดย Pre-Trained Model ที่ใช้คือ VGG16 [11], InceptionV3 [12], ResNet152V2 [13], DenseNet201 [14], Xception [15] ขั้นตอนการวิเคราะห์ข้อมูลมีดังนี้

4.4.1) ปรับขนาดค่าพิกเซลตามที่แต่ละ Pre-Trained Model กำหนด ([0,1] หรือ [-1,1])

4.4.2) ทำการสกัดค่าคุณลักษณะ (Feature extraction) เพื่อแปลงภาพถ่ายทางดาวเทียมภาพสี RGB ขนาด 256*256*3 ให้เป็นเวกเตอร์ที่ผ่านการสกัดค่าคุณลักษณะซึ่งมีขนาดแตกต่างกันไปตามแต่ละ Pre-Trained Model โดยการสร้างโมเดลพื้นฐาน (Base Model) จากคอนเนตต์ (Convnets) ที่ผ่านการฝึกอบรมมาแล้ว (Pre-Trained) โดยเลือกชั้น (Layers) ของ Pre-Trained Model และตรึง Convolutional Base เพื่อใช้เป็นตัวสกัดค่าคุณลักษณะเพราะป้องกันไม่ให้เกิดการโอเวอร์ฟิต น้ำหนักในชั้นที่กำหนดระหว่างการฝึกซึ่งจะแปลงเป็นเวกเตอร์โดยหาค่าเฉลี่ยของแต่ละตำแหน่งเชิงพื้นที่ โดยใช้ชั้น GlobalAveragePooling ซึ่งเวกเตอร์ที่ได้จะมีขนาดแตกต่างกันไปตามแต่ละ Pre-Trained Model (เนื่องจากเวกเตอร์ที่ผ่านการสกัดค่าคุณลักษณะในแต่ละ Pre-Trained Model มีขนาดไม่เท่ากัน ส่งผลให้ ถ้าเราเพิ่ม Fully Connected Layer เข้าไปที่ตัวแบบส่วนบน จะมี Hidden Units ไม่เท่ากัน ซึ่งอาจส่งผลต่อการฝึกเพราะอยู่นอกเหนือการควบคุม)

4.4.3) ทำการจำแนก (Classify) เพื่อแปลงคุณลักษณะเหล่านี้เป็นการคาดคะเนว่าภาพนี้เป็นหมวดหมู่ใด และเพื่อให้ตัวแบบมีการเรียนรู้ที่เพิ่มมากขึ้นจึงเพิ่ม Fully Connected Layers อีก 3 ชั้น Dropout 1 ชั้น และเปลี่ยน Prediction Layer ซึ่งทั้ง 3 ส่วนแสดงดังนี้

Dense(256, activation='relu',kernel_initializer=HeNormal())
Dense(512, activation='relu',kernel_initializer=HeNormal())
Dense(1920, activation='relu',kernel_initializer=HeNormal())
Dropout(0.2) เพื่อลด Overfit Dense(4, activation='softmax')
(มี Hidden Units = 4 ตามหมวดหมู่ที่เรากำหนด)

และมีการปรับจูนไฮเปอร์พารามิเตอร์ ดังนี้ Learning Rate = 0.0001, Optimizer = Adam, Loss = Sparse Categorical Crossentropy, Metrics = Accuracy, Epochs = 100 (ซึ่งเวลาที่ใช้ในการฝึกทดลองครั้งหนึ่งเมื่อ kernel_initializer = HeNormal) สำหรับภาพรวมของการวิเคราะห์ข้อมูลแสดงในรูปที่ 8

5) ผลการวิจัย

5.1) Experimental Setup

ในการทดลองผู้วิจัยได้ใช้ Google Colab Pro System specs: GPUs = [K80, P100, T4], CPUs: 2 x vCPU และ RAM: 24GB ในการรันโมเดล และได้ใช้ Open Source Deep Learning Software Libraries ที่ชื่อ TensorFlow (Version 2.6.0) และ Keras (Version 2.6.0) เข้ามาช่วย

5.2) ประสิทธิภาพของแต่ละตัวแบบ

ตารางที่ 2 แสดงประสิทธิภาพของตัวแบบที่ได้จากการถ่ายโอนความรู้จากตัวแบบ DenseNet201 มีค่าความแม่นยำ (Accuracy) ทดสอบในชุดข้อมูลทดสอบ (Test Dataset) สูงถึง 96.88%

5.3) ประสิทธิภาพตัวแบบ


ตารางที่ 3 แสดงประสิทธิภาพตัวแบบ สรุปได้ว่า จะเลือกใช้ตัวแบบที่ได้จากการถ่ายโอนความรู้มาจากตัวแบบ DenseNet

201 ของการทดลองที่ 2 (การปรับแต่งข้อมูลแบบสโม่ท) เพราะค่า Loss ค่อนข้างไม่ผันผวน ซึ่งหมายความว่าค่าพารามิเตอร์ที่ใช้ในการเรียนรู้ค่อนข้างคงที่ จึงใช้เวลาในการฝึกต่อรอบน้อยกว่า

5.4) ประสิทธิภาพตัวแบบที่ได้จากการถ่ายโอนความรู้มาจากรูปแบบ DenseNet201 ของการทดลองที่ 2

รูปที่ 9 แสดงผลการจำแนกอาคารประเภทต่าง ๆ และการวัดประสิทธิภาพตัวแบบของงานวิจัยชิ้นนี้จะพิจารณาจาก

Confusion Matrix และ ROC Curve ดังแสดงในรูปที่ 10 รูปที่ 11 และตารางที่ 4 จากผลที่ได้สามารถสรุปได้ว่า ตัวแบบสามารถจำแนกได้ดีในหมวดหมู่สนามบินและวัด แต่ยังจำแนกคลาดเคลื่อน (Misclassification) ในหมวดหมู่โรงเรียนและสนามฟุตบอล สำหรับการวิเคราะห์ว่าตัวแบบจำแนกภาพว่าเป็นอาคารประเภทนั้น ๆ จากองค์ประกอบใดของภาพ ผู้วิจัยจะแสดงโดยการสร้างภาพนิทัศน์จากข้อมูลด้วย Grad-CAM ดังแสดงในรูปที่ 12



รูปที่ 8 : ภาพรวมของการวิเคราะห์ข้อมูล



ตารางที่ 2 : ประสิทธิภาพของแต่ละตัวแบบ


การทดลอง	Pre-Trained Model	Train (acc)	Train (loss)	Val (acc)	Val (loss)	Test (acc)	Test (loss)
1	VGG16	0.9907	0.029	0.8943	0.4294	0.8281	0.7305
	InceptionV3	0.9814	0.0503	0.8792	0.5086	0.8594	0.345
	ResNet152V2	0.9953	0.0135	0.9245	0.2751	0.8594	0.4104
	DenseNet201	0.9953	0.0153	0.9396	0.212	0.9688	0.1421
	Xception	0.9823	0.041	0.9094	0.2288	0.875	0.5842

ตารางที่ 2 : ประสิทธิภาพของแต่ละตัวแบบ (ต่อ)

การทดลอง	Pre-Trained Model	Train (acc)	Train (loss)	Val (acc)	Val (loss)	Test (acc)	Test (loss)
2	VGG16	1	1.09E-04	0.9405	0.3554	0.8281	0.8924
	InceptionV3	1	8.55E-06	0.9405	0.3057	0.8281	0.8924
	ResNet152V2	1	4.53E-06	0.9345	0.3546	0.875	0.4277
	DenseNet201	1	5.44E-06	0.9444	0.1874	0.9688	0.1159
	Xception	1	7.79E-06	0.9067	0.3652	0.8594	0.7374

ตารางที่ 3 : ประสิทธิภาพตัวแบบที่ได้จากการถ่ายโอนความรู้ (Transfer Learning) มาจากตัวแบบ DenseNet201

	การทดลองที่ 1	การทดลองที่ 2
กราฟ Accuracy/Loss		
ขนาดตัวแบบ	89.5 MB	89.5 MB
เวลาที่ใช้ในการฝึกต่อรอบ	1 ชั่วโมง 15 นาที	20 นาที




รูปที่ 9 : ตัวอย่างผลการจำแนกอาคารประเภทต่าง ๆ จากตัวแบบที่ได้

แหล่งที่มา : Google Earth [10]

สนามบิน				สนามฟุตบอล			
		Predicted Class				Predicted Class	
Actual		Negative	Positive	Actual		Negative	Positive
	Negative	48	0		Negative	47	1
	Positive	0	16		Positive	1	15

โรงเรียน				วัด			
		Predicted Class				Predicted Class	
Actual		Negative	Positive	Actual		Negative	Positive
	Negative	47	1		Negative	48	0
	Positive	1	15		Positive	0	16


รูปที่ 10 : Confusion Matrix



รูปที่ 11 : ROC Curve

ตารางที่ 4 : Classification Report

	precision	recall	f1-score	support
สนามบิน	1.00	1.00	1.00	16
สนามฟุตบอล	0.94	0.94	0.94	16
โรงเรียน	0.94	0.94	0.94	16
วัด	1.00	1.00	1.00	16
accuracy			0.97	64
macro avg	0.97	0.97	0.97	64
weighted avg	0.97	0.97	0.97	64



รูปที่ 12 : การสร้างภาพนิทัศน์จากข้อมูล (Data Visualization) ด้วย Grad-CAM (Gradient-weighted CAM)

แหล่งที่มา : Google Earth, Image © 2021 Maxar Technologies [10]

จากรูปที่ 3 ข้อ (4) ได้ดำเนินการตามหัวข้อที่ 3.3) เพื่อตรวจสอบประสิทธิภาพของตัวแบบจาก Grad-CAM ซึ่งผลลัพธ์ที่ได้แสดงในรูปที่ 12 เป็นการแสดงผลการวิเคราะห์ตัวแบบจำแนกภาพสนามกีฬาเฉลิมพระเกียรติ 84 พรรษา บางบอน ว่าเป็นอาคารประเภทใด และจากองค์ประกอบใดของภาพ ซึ่งสรุปได้ว่าตัวแบบจำแนกภาพนี้ออกมาเป็นหมวดหมู่สนามกีฬา (สนามฟุตบอล) โดยดูจากองค์ประกอบของภาพ (รูปที่ 12 ภาพซ้ายบน) ดังนั้นในหมวดหมู่สนามกีฬา (สนามฟุตบอล) ตัวแบบดูจากสนามฟุตบอลและสิ่งที่เป็นสีเขียว หมวดยุทธศาสตร์โรงเรียนตัวแบบดูจากสนามฟุตบอลและอาคารต่าง ๆ (รูปที่ 12 ภาพซ้ายล่าง) ด้วยเหตุที่ตัวแบบจำแนกภาพว่าเป็นหมวดหมู่สนามกีฬา (สนามฟุตบอล) หรือโรงเรียนนั้น ตัวแบบดูจากสนามฟุตบอลจึงทำให้จำแนกคลาดเคลื่อนอยู่บ้างในหมวดหมู่นี้ (รูปที่ 12 ภาพซ้าย) ซึ่งคนเองก็อาจเกิดความสับสนเช่นกันหากภาพพิจารณาเฉพาะส่วนสนามฟุตบอล สำหรับหมวดหมู่สนามบิน ตัวแบบดูจากลานบิน (Runway) และต้นไม้จำนวนมาก (รูปที่ 12 ภาพขวาบน) หมวดหมู่วัด ตัวแบบดูจากหลังคาสี่เหลี่ยมเป็นกลุ่ม ๆ (รูปที่ 12 ภาพขวาล่าง) จึงทำให้จำแนกได้ดีในหมวดหมู่นี้ (รูปที่ 12 ภาพขวา)

5.5) การประยุกต์ใช้

5.5.1) *ปรับปรุงแผนที่ทางภูมิศาสตร์* ตัวแบบที่สร้างสามารถนำไปใช้ในเรื่องปรับปรุงแผนที่ทางภูมิศาสตร์ว่าพื้นที่บนแผนที่นี้เป็นสิ่งปลูกสร้างอะไร หรือตรวจสอบพื้นที่นั้น ๆ ว่าติดแท็กใน

แผนที่ถูกต้องหรือไม่ เพื่อประหยัดเวลาและบุคลากรในการวิเคราะห์

5.5.2) *การตรวจจับการใช้ที่ดิน* ตัวแบบที่สร้างสามารถนำไปใช้ในเรื่องการตรวจจับการใช้ที่ดินว่าสิ่งปลูกสร้างนั้นอนุญาตสร้างอย่างถูกต้องหรือลักลอบทำแบบผิดกฎหมาย เพื่อที่จะสามารถตรวจสอบได้อย่างทันทั่วถึง และยังสามารถทำการสำรวจพื้นที่เดียวกันในเวลาที่แตกต่างกัน ดังแสดงในรูปที่ 13 ซึ่งผลการจำแนกจากตัวแบบที่สร้างได้ จำแนกทั้ง 2 ภาพว่าเป็นหมวดหมู่สนามบิน จึงสามารถสรุปได้ว่าตัวแบบสามารถคาดการณ์สิ่งปลูกสร้างได้พอประมาณ

6) สรุปและอภิปรายผลการวิจัย

จากการดำเนินการตามบทวิจัยข้างต้น จะได้ระบบการจำแนกอาคารประเภทต่าง ๆ จากภาพถ่ายดาวเทียมในหมวดหมู่สนามบิน สนามกีฬา (สนามฟุตบอล) โรงเรียนและวัดซึ่งอยู่ในประเทศไทยที่มีประสิทธิภาพและประหยัดเวลาและบุคลากรมากขึ้น ตลอดจนสามารถนำมาประยุกต์ใช้ในเรื่องการตรวจจับการใช้ที่ดิน ปรับปรุงแผนที่ทางภูมิศาสตร์ เป็นต้น แต่ชุดข้อมูลภาพถ่ายทางดาวเทียมในแต่ละประเภท ผู้วิจัยจะเลือกเฉพาะภาพที่มีคุณลักษณะเด่น ๆ ตามที่ผู้วิจัยกำหนด ดังนั้นหากเป็นภาพที่ไม่มีคุณลักษณะเด่นตามที่ผู้วิจัยกำหนดอาจจำแนกประเภทคลาดเคลื่อนได้ นอกจากนี้ผู้วิจัยยังได้แสดงการสร้างภาพนิทัศน์จากข้อมูล ว่าตัวแบบที่ดีที่สุดจำแนกภาพว่าเป็นอาคารประเภทนั้น ๆ จากองค์ประกอบใดของภาพด้วย Grad-CAM ซึ่งทำให้ทราบว่าตัวแบบยังสามารถพัฒนาเพื่อเพิ่มประสิทธิภาพได้ แต่

อาจจะต้องเตรียมชุดข้อมูลในแต่ละหมวดหมู่ให้มีความหลากหลายมากยิ่งขึ้น อาจมีการเตรียมข้อมูลรูปแบบอื่น ๆ ร่วม

ด้วย เช่น การแยกบริเวณรูปภาพ (Image Segmentation) หรือหาวิธีการเพิ่มประสิทธิภาพตัวแบบวิธีใหม่ ๆ ร่วมด้วย



รูปที่ 13 : ภาพถ่ายดาวเทียมท่าอากาศยานนานาชาติเบตงสำรวจเมื่อ 5/8/2016 (ภาพซ้าย)
และภาพถ่ายดาวเทียมท่าอากาศยานนานาชาติเบตงสำรวจเมื่อ 17/4/2019 (ภาพขวา)

แหล่งที่มา : Google Earth, Image © 2021 Maxar Technologies [10], Google Earth, Image © 2021 CNES / Airbus [10]

REFERENCES

- [1] O. Russakovsky *et al.*, “ImageNet Large Scale Visual Recognition Challenge,” *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, 2015.
- [2] *TensorFlow 2.6.0*. (2021). Google.
- [3] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic minority over-sampling technique,” 2011. [Online]. Available: arXiv:1106.1813.
- [4] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: Visual explanations from deep networks via gradient-based localization,” in *Proc. IEEE Int. Conf. Comput. Vis.*, Venice, Italy, Oct. 2017, pp. 618–626, doi: 10.1109/ICCV.2017.74.
- [5] T. Siriborvornratanakul. (2021). CNN Wrap-up [PowerPoint slides]. Available: <https://as.nida.ac.th/~thitirat/homepage/index.html>
- [6] M. Pritt and G. Chern, “Satellite image classification with deep learning,” in *Proc. IEEE Appl. Imagery Pattern Recognit. Workshop (AIPR)*, Washington, DC, USA, Oct. 10–12, 2017, pp. 1–7.
- [7] P. Helber, B. Bischke, A. Dengel, and D. Borth, “EuroSAT: A novel dataset and deep learning benchmark for land use and land cover classification,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 12, no. 7, pp. 2217–2226, 2019.
- [8] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” 2014. [Online]. Available: arXiv:1412.6980.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, “Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification,” in *Proc. IEEE Int. Conf. Comput. Vis.*, 2015, pp. 1026–1034, doi: 10.1109/ICCV.2015.123.
- [10] *Google Earth*. (2015). Google. Accessed: Feb. 1, 2021. [Online]. Available: <https://earth.google.com/web/>
- [11] K. Simonyan, and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” 2014. [Online]. Available: arXiv:1409.1556.
- [12] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” 2015. [Online]. Available: arXiv:1512.00567.
- [13] K. He, X. Zhang, S. Ren, and J. Sun, “Identity mappings in deep residual networks,” 2016. [Online]. Available: arXiv:1603.05027.
- [14] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” in *Proc. IEEE Conf. Comput. Vis. and Pattern Recognit. (CVPR)*, Honolulu, HI, USA, Jul. 2017, pp. 2261–2269, doi: 10.1109/CVPR.2017.243.
- [15] F. Chollet, “Xception: Deep learning with depthwise separable convolutions,” 2016. [Online]. Available: arXiv:1610.02357.

Design and Prototyping of an Automatic Solar Panel Cleaner Based on Arduino

Patcharin Intamas¹ Promphak Boonraksa^{2*}

¹*Faculty of Industrial Technology, Nakhon Si Thammarat Rajabhat University, Nakhon Si Thammarat, Thailand*

^{2*}*School of Electrical Engineering, Bangkok Thonburi University, Bangkok, Thailand*

*Corresponding Author. E-mail address: promphak.dawan@gmail.com

Received: 24 December 2021; Revised: 4 April 2022; Accepted: 14 June 2022

Published online: 27 June 2022

Abstract

This research paper presents the design and construction of an automatic solar panel cleaner on Arduino. Since dust is an important factor affecting the efficiency of the cell panel, regular washing of the cell panel is necessary for the photovoltaic system to increase its efficiency of the system. This research was tested using an 80 W monocrystalline panel and an Arduino washing control. It is easy to use and cheap to allow the control of the panel to achieve the desired results. In collecting the experimental results, the relationship between the electric power before and after cleaning the panel was collected. In the first case, the solar panel was cleaned every 1 hour. The results showed that the output power of the washed and unwashed panels is approximately the same. Due to too frequent a wash control timer, the dust accumulation is not enough to see the change in power output. Case 2, the solar panel washing time is controlled every 3 months. The results showed that after 3 months of solar panel cleaning intervals, the amount of dust accumulated was about 2.5 grams per square meter. The power was greatly reduced. When cleaning the panel, results in higher power output. Then calculate the efficiency of the panel system increased by automatic panel washing. It was concluded that the calculated efficiency of the panel system was increased to 12.11%.

Keywords: Effect of dust on a solar panel, Efficiency, Automatic

I. INTRODUCTION

Solar energy is the largest natural energy source, it is clean and ubiquitous. Especially Thailand is a country located on the equator of the world. Therefore, it is an area that receives sunlight all day long. Therefore, it is suitable for the use of solar energy [1]–[3]. However, the efficiency of the solar panels will have many variables, including the type of solar cell. Mounting and mounting of panels, temperature, light intensity, dust, etc [4]. Many researchers have studied the effects of dust on the efficiency of solar panels. They found that thick dust on solar panels reduced light transmittance from 88.9% to 69.1% [5], causing a maximum 6.9% reduction in efficiency [6].

The research of the College of Renewable Energy, Naresuan University, Phitsanulok Province, has studied the effects of dust accumulation on solar panels. The study found that, The number of dust results in reduced light transmittance resulting in reduced peak power. In the period of 60 days and 30 days, the electric power was reduced to 2.83% and 6.03%, respectively [7]. Thailand tends to increase the amount of dust accumulated every year[8]. The trend of PM2.5 volume in 2011–2018 Thailand is shown in Figure 1.




Figure 1: The trend of PM2.5 volume in 2011–2018 [8]

Currently, Automation has played a huge role in human life. It is also a working system that tends to develop and grow more and more. The main function of automation is to facilitate human life. Whether it is

a timer in the microwave Using the remote control for turning on and off the car or a room temperature sensor in some air conditioners, etc. If considering the benefits of an automated system. It can be seen that automation can control and reduce the damage caused by human labor. It is convenient and easy to operate [9].

Therefore, this research has designed and built a prototype-based Arduino-controlled automatic solar panel washing machine for cleaning solar panels. This helps reduce dust accumulation on solar panels which increases the efficiency of the photovoltaic system [10], [11]. It also reduces the cost of hiring workers to clean the solar panels for solar power system operators. and reduce the danger of accidents that will occur in the case of washing solar panels on the roof.

II. LITERATURE REVIEW

A. Solar Cell

Basic Solar cell I-V characteristics

The light energy is directly converted to electricity by using solar panels. If the energy stored in the photon is greater than the energy bandgap of the solar panel, Electrons move and release energy in the form of electrical energy to the external circuit [12]–[14]. The process of generating electricity from the Sun is shown in Figure 2.




Figure 2: The process of generating electricity from the sun [15]

The basic Equivalent Circuit of Solar cells is shown in Figure 3 [16]. The model consists of a photocurrent source I_{ph} , a diode, parallel resistor R_{sh} , and series resistor R_s . The mathematical modeling of the I-V characteristic of the solar PV cell can be calculated as in (1) [17].

$$I = I_{ph} - I_0 \left[\exp \left(\frac{V_{ph} + IR_s}{nV_T} \right) - 1 \right] - \left(\frac{V_{ph} - IR_s}{R_{sh}} \right) \quad (1)$$

Where I is the output current, I_{ph} is photocurrent, I_0 is reverse saturation current of diode, V_{ph} is photovoltage, n is diode ideality factor (1 for an ideal diode), V_T is the terminal voltage, series resistance (R_s) Shunt Resistance (R_{sh}), parallel resistance. There are used to calculate power output on a PV system.[18] As shown in Figure 3.




Figure 3: Equivalent circuit of solar cell [16]

The output power is dependent on the solar irradiant and temperature module. As the temperature increases, the open-circuit voltage (Voc) decreases. This in turn decreased the power output. On the other hand, irradiance will also affect power output, with a high of irradiance consequentially an increased power output [19]. The temperature and irradiance affect I-V curves on the solar cell are shown in Figure 4.




Figure 4: The temperature and irradiance affect I-V curves on solar cells [19]

B. Factors Affecting PV Plants Performance

The meteorological effect is the impact of weather events on the atmosphere of the world.

In PV plants, the input is the value of radiation from the sun, and its output is electrical energy. While generating electrical energy, many meteorological factors are affecting the performance of the PV plants. These factors lead to losses in the production of

electrical energy. Investors want to minimize these losses to avoid financial damage. Losses can occur due to meteorological factors as well as the design of solar PV plants. These can be shading, material quality, incompatibilities between parts, and inverter losses [20]. The losses that may occur in a solar power plant are shown in Figure 5.




Figure 5: The factors affecting PV plants performance [20]

C. Effect of Dust on Solar Panel

In many research studies on the effects of dust on solar panels. It was discovered that dust accumulating on the glass sheet reduces the transmission of light. Interestingly, it was found that if the accumulation of fine dust particles was very dense, this would result in a reduction in the solar intensity the solar panels would receive because the dust would obscure the path of the light. For this reason, it can be concluded that dust is a factor affecting the efficiency of solar panels. If there is a lot of dust accumulation, the efficiency of the solar panel will also decrease [21]–[23]. The Examples of potential dust on the solar panels shows in Figure 6.



Figure 6: Examples of potential dust on the solar panels [23]

D. Data Processing and Measurements

In this experiment, it was necessary to use basic

equations to verify the validity of the data with the following parameters to be calculated:

The maximum power factor can be calculated as shown in equation (2).

$$P_{max} = I_{mp} \times V_{mp} \quad (2)$$

where I_{mp} is the current max, V_{mp} is voltage max. To calculate the parameters of standard IEC 61724, which details how to calculate[24].

Solar energy ($E_{i,\tau}$, kWh / m^2)

$$E_{i,\tau} = \tau_r \times \sum \tau P_i \quad (3)$$

Solar energy per unit area ($E_{r,\tau}$, kWh)

$$E_{r,\tau} = E_{i,\tau} \times A_c \quad (4)$$

A_c = solar panel area (m^2)

Electricity from solar panels ($E_{A,\tau}$, kWh)

$$E_{A,\tau} = \tau_r \times \sum \tau P_{DC} \quad (5)$$

Solar panel efficiency ($\eta_{A,\tau}$, %)

$$\eta_{A,\tau} = \frac{E_{A,\tau}}{E_{r,\tau}} \times 100 \quad (6)$$

The performance efficiency loss of the PV module can be calculated through Equation (7) [24].

$$\eta_{loss} = \frac{\eta_{clean} - \eta_{dirty}}{\eta_{clean}} \quad (7)$$

III. RESEARCH METHODOLOGY

In the prototype design, the Arduino-controlled automated solar panel washer aims to increase the efficiency of the photovoltaic system. The method of

operation is as follows:

A. Solar Panel Cleaner Component

1) PV module characteristics

This research uses an 80 W Mono-Crystalline solar panel. which is a high-efficiency panel. The electrical properties are shown in Table 1 and the picture of the cell panels used in this research is shown in Figure 7.

Table 1: PV module characteristics at Standard Test Conditions (STC) (1000 W/m², 25 °C, AM1.5)

Solar Module Type: PRPVM-80	
Maximum power	80 W
Voltages at Pmax	18 V
Current at Pmax	4.44 A
Open-Circuit Voltage	21.6 V
Short-Circuit Current	4.88 A
Power Tolerance	+/- 3%



Figure 7: The 80 W monocrystalline solar panel

2) Design a structure solar panel structure

Design a structure to support the solar panel to receive the most light. In Thailand, 15 degrees in the design use the Sketch-up2018 program to determine the height of solar cells installed on land. The height in front of the cell panel is 33.3 cm, the height behind the cell is 50 cm, the width is 67.1 cm and the length is 74.7 cm, which determines the height of the solar cell installed on the water surface, height 19.2 cm, width

143.1 cm, length 25 cm, as shown. In Figure 8.




Figure 8: Solar panel structure in this research

3) Solar panel cleaner structure

1. A ConFigure a prototype of an automatic solar panel cleaner controlled by Arduino using an aluminum profile size 8 × 8 mm, assembled into a square, size 70 × 30 cm, using a 110 rpm 12 V DC motor. Figure 9 shows the Solar panel cleaner prototype.



Figure 9: Solar panel cleaner prototype

2. In the part of the control of the solar panel washing machine. The panel washer will run in a top-to-bottom manner. Use a rubber squeegee to clean the solar panel. There is a water spray head to spray water to clean the panel. This study divided the test into 2 cases, Case 1 was cleaning time every 1 hour and Case 2 cleaned every 90 days. The solar panel cleaning system operation flow chart is shown in Figure 10.




Figure 10: Solar panels cleaning system operation flow chart

In Figure 10, The power supply is the power source for the microcontroller board. The microcontroller is responsible for controlling the operation of the DC Motor Drive and Stepper Motor. The DC motor moves

on the x-axis and the stepper motor moves on the Y-axis.

IV. RESULTS AND DISCUSSION

Once the design and construction of an automatic solar panel cleaner have been completed. Then experiment to collect the power values obtained when cleaning the panel. Compared to the power without washing the panel. To determine the relationship between panel cleaning that affects the power and efficiency of the solar panel. The results of the experiment were divided into 3 topics as follows:

Table 2: Summarizes the accuracy of the solar panel cleaning machine efficiency test

Machine working case	The total number of times to test	The number of times the machine works accurately.	Accuracy (%)	Error (%)
Set the machine to start working every 15 minutes.	10	10	100	0
Set the machine to start working every 30 minutes.	10	10	100	0
Set the machine to start working every 60 minutes.	10	10	100	0

A. Automatic Solar Panel Cleaner Control

As for the control of the solar panel cleaner, this research uses Arduino. Test the operation by setting the start-up time of the machine to 3 values: 1) Every 15 minutes, 2) Every 30 minutes and 60 minutes, the test results are shown in Table 2.

From Table 2 it can be seen that the solar panel cleaner can work exactly for the set time of 15, 30, and 60 minutes, representing 100 percent.




Figure 11: Solar Irradiation from 8:00 a.m. to 5:00 p.m.

B. Cleaning the Cell Panel and the Solar Cell's Output Power

1) Daily panel cleaning

The researchers collected the results of daily light intensity and daily solar panel temperature. In order to know the fundamental behavior of the solar cell which affects the output power of the solar panel as well. The solar radiation from 8:00 a.m. to 5:00 p.m. and temperature modules from 8:00 a.m. to 5:00 p.m. as shown in Figures 11 and 12.




Figure 12: Temperature Module from 8:00 a.m. to 5:00 p.m.

The Power of solar panels on Daily panel cleaning is shown in Table 3.

Table 3: The power of solar panels on daily panel cleaning

Time	Power (W)		
	Before Dust	During Dust	After Cleaning
08.00 am	2	52	54
09.00 am	52	52	54
10.00 am	58	59	60
11.00 am	63	64	67
12.00 am	65	65	68
1.00 pm	69	70	72
2.00 pm	64	64	65
3.00 pm	54	55	58
4.00 pm	38	38	38
5.00 pm	24	24	25

From Table 2, It was found that when we set the panel cleaning to clean every 1 hour. As a result, the total power was only slightly increased, but from the observation on the panel, there may not be enough dust to accumulate to reduce the power. But the increase in power may be caused by washing the solar panels. With that water, the panel is cooled. During high-temperature times, such as between 11:00 AM and 2:00 PM in Thailand, when washing the panel, the panel temperature decreases. The voltage is, therefore, higher, increasing power accordingly.

2) Monthly panel cleaning

In this section, we will design a 3-month collection of experimental results to see the relationship between dust accumulation affects solar panel efficiency. The amount of dust will be collected before the panel is cleaned and the power quantity is compared before and after cleaning the solar panel. The results of the experiments are shown in Table 4.

Table 4: Power of solar panels on 3 monthly panel cleaning

Months	Dust amount (g/m ²)	Power (W)	
		Before Dust	After Cleaning
January 1, 2020	2.67	67	72.6
March 31, 2020	3.53	64	74.3
June 30, 2020	1.35	58	62
September 30, 2020	2.38	63	69

The results of the experiment can be seen over a period of 3 months. There is a large amount of dust accumulated. As a result, the power that the cell panel produces is less. When the panel is cleaned, the power will increase noticeably. In June 2020, In Thailand is the rainy season. Therefore, the amount of dust accumulation is not much. and resulting in a very small reduction in power.

C. Compare the Efficiency of the Panel Washer

Comparison of the efficiency of solar panel washer with the amount of dust as shown in Figure 13.




Figure 13: The relationship of the efficiency of the solar panel washer with the amount of dust

V. CONCLUSION

Researching the design and construction of an automatic solar panel cleaner on the Arduino. For this reason, dust is an important factor affecting the efficiency of the panel, so washing the panel regularly. Therefore, the photovoltaic system must increase its efficiency of the system. This research was tested using

an 80 W monocrystalline panel and an Arduino washing control. It is easy to use and cheap to allow the control of the panel to achieve the desired results. In collecting the experimental results, the relationship between the electric power before and after cleaning the panel was collected. In the first case, the cell panel was cleaned every 1 hour. The results showed that the output power was close to that. did not wash the panel due to too frequent washing time causing the dust to not accumulate enough. Then the cell panels were washed every 3 months. The results showed that when leaving the cell panel cleaning intervals for 3 months, the amount of dust accumulation was about 2.5 grams per square meter. The power was significantly reduced. when cleaning the panel will result in higher power costs. The efficiency of the increased panel system was then calculated. From the automatic panel washing, it was concluded that the calculated efficiency of the panel system increased to 12.11%.

At present, in Thailand, more solar rooftop systems are installed. On the roof area, cleaning is difficult and poses a risk of accidents to workers. This research has created an automatic cleaning machine to solve this problem on a low-cost basis.

ACKNOWLEDGEMENT

The authors thank the Nakhon Si Thammarat Rajabhat University and Bangkokthonburi University for providing the laboratory and the financial support.

REFERENCES

- [1] A. Tolón-Becerraa, X. Lastra-Bravob, and F. Bienvenido-Bárcenac, "Proposal for territorial distribution of the EU 2020 political renewable energy goal," *Renew. Energy*, vol. 36, no. 8, pp. 2067–2077, Aug. 2011, doi: 10.1016/j.rene.2011.01.033.
- [2] B. Sørensen, "Renewable energy introduction," in *Renewable Energy Origins and Flows*, London, U.K.: Routledge, 2015, ch. 1, sec. 1, pp. 5–10, doi: 10.4324/9781315793245
- [3] B. Zafar, "Design of a renewable hybrid Photovoltaic-Electrolyze-PEM/Fuel cell system using hydrogen gas," *Int. J. Smart Grid*, vol. 3, no. 4, pp. 201–207, 2019. [Online]. Available: <https://www.ijsmartgrid.org/index.php/ijsmartgridnew/article/view/83>
- [4] Department of Alternative Energy Development and Efficiency, "Solar energy generation," (in Thai), Ministry of Energy, Bangkok, Thailand. Accessed: Dec. 20, 2021. [Online]. Available: <https://shorturl.asia/QX15n>
- [5] A. M. Pavan, A. Mellit, and D. de Pieri, "The effect of soiling on energy production for large-scale photovoltaic plants," *Sol. Energy*, vol. 85, no. 5, pp. 1128–1136, May 2011, doi: 10.1016/j.solener.2011.03.006.
- [6] S. Semaoui, A. H. Arab, E. K. Boudjelthia, S. Bacha, and H. Zeraia, "Dust effect on optical transmittance of photovoltaic module glazing in a desert region," *Energy Procedia*, vol. 74, pp. 1347–1357, Aug. 2015, doi: 10.1016/j.egypro.2015.07.781.
- [7] N. Ketjoy and M. Konyu, "Study of dust effect on photovoltaic module for photovoltaic power plant," *Energy Procedia*, vol. 52, pp. 431–437, 2014, doi: 10.1016/j.egypro.2014.07.095.
- [8] S. Nakdilok, "The impact of PM2.5 dust on solar power generation," (in Thai), Division of Solar Energy Development, Department of Alternative Energy Development and Efficiency, Bangkok, Thailand. Accessed: Dec. 22, 2021. [Online]. Available: <https://webkc.dede.go.th/testmax/node/5386>
- [9] S. A. Sulaiman, H. H. Hussain, N. S. H. N. Leh, and M. S. I. Razali, "Effects of dust on the performance of PV panels," *World Acad. Sci. Eng. Technol.*, vol. 58, pp. 588–593, 2011. [Online]. Available: <http://www.alionenergy.com/wp-content/uploads/2016/03/Effects-of-Dust-on-the-Performance-of-PV-Panels.pdf>
- [10] K. Babu, P. Dinesh-kumar, S. Kamala-priya, and P. Kathirvel, "Solar panel cleaning robot," *Int. J. Innov. Sci. Res. Technol.*, vol. 3, no. 3, pp. 196–199 Mar. 2018. [Online]. Available: <https://ijisrt.com/wp-content/uploads/2018/03/Solar-Panel-Cleaning-Robot.pdf>

- [11] N. Maindad, A. Gadhave, S. Satpute, and B. Nanda, "Automatic solar panel cleaning system," in *Proc. 2nd Int. Conf. Commun. Inf. Process. (ICCIP)*, Pune, India, Jun. 2020, pp. 1–8, doi: 10.2139/ssrn.3646147.
- [12] H. Abdel-Aal, M. Bassyouni, M. Abdelkreem, S. Abdel-Hamid, and K. Zohdy, "Feasibility study for a solar-energy stand-alone system: (S.E.S.A.S.)," *Smart Grid Renew. Energy*, vol. 3, no. 3, pp. 204–206, Aug. 2012, doi: 10.4236/sgre.2012.33028.
- [13] A. Padsri, K. Konkeaw, and A. Intaniwet, "Efficiency and performance analysis of a 300 kW grid-tied solar power generation syzstem," (in Thai), presented at the 3rd KU SRC Annu. Conf., Chonburi, Thailand, Aug. 30, 2018, pp. 95–101.
- [14] C. Battaglia, A. Cuevasb, and S. D. Wolfc, "High-efficiency crystalline silicon solar cells: Status and perspectives," *Energy Environ. Sci.*, vol. 9, no. 5, pp. 1552–1576, 2016, doi: 10.1039/C5EE03380B.
- [15] Department of Alternative Energy Development and Efficiency, "Electricity from the sun," (in Thai), 2019. [Online]. Available: https://webkc.dede.go.th/testmax/sites/default/files/Thailand_Alternative_Energy_Situation_2019.pdf
- [16] P. Boonraksa, T. Booraksa, and B. Marungsri, "Comparison of the cuk, sepic, and zeta converters circuit efficiency for improving the maximum power point tracking on photovoltaic systems," in *Proc. Int. Conf. Power, Energy Innov. (ICPEI)*, Nakhon Ratchasima, Thailand, 2021, pp. 150–154, doi: 10.1109/ICPEI52436.2021.9690663.
- [17] N. Jumpasri, K. Pinsuntia, K. Woranetsuttikul, T. Nilsakorn, and W. Khan-ngern, "Comparison of distributed and centralized control for partial shading in PV parallel based on particle swarm optimization algorithm," in *Proc. Int. Elect. Eng. Congr. (IEEECON)*, Chonburi, Thailand, Mar. 2014, pp. 1–4, doi: 10.1109/IEEECON.2014.6925921.
- [18] A. H. Arab *et al.*, "Maximum power output performance modeling of solar photovoltaic modules," *Energy Rep.*, vol. 6, pp. 680–686, Feb. 2020, doi: 10.1016/j.egy.2019.09.049.
- [19] J. G. Durago, "Photovoltaic emulator adaptable to irradiance, temperature and panel specific I-V curves," M.S. thesis, Dept. Elect. Eng., California Polytechnic State Univ., San Luis Obispo, USA, 2011.
- [20] Seven Sensor. "Factors Affecting PV Plants Performance." SEVENSENSOR.com. <https://www.sevensensor.com/factors-affecting-pv-plants-performance> (accessed Apr. 18, 2022).
- [21] F. Mejia, J. Kleissl, and J. L. Bosch, "The effect of dust on solar photovoltaic systems," *Energy Procedia*, vol. 49, pp. 2370–2376, 2014, doi: 10.1016/j.egypro.2014.03.251.
- [22] J. Tanesab, D. Parlevliet, J. Whale, and T. Urmee, "Energy and economic losses caused by dust on residential photovoltaic (PV) systems deployed in different climate areas," *Renew. Energy*, vol. 120, pp. 401–412. May 2018, doi: 10.1016/j.renene.2017.12.076.
- [23] M. R. Maghami, H. Hizam, C. Gomes, M. A. Radzi, M. I. Rezadad, and S. Hajighorbani, "Power loss due to soiling on solar panel: A review," *Renew. Sust. Energ. Rev.*, vol. 59, pp. 1307–1316. Jun. 2016, doi: 10.1016/j.rser.2016.01.044.
- [24] *Photovoltaic System Performance Monitoring — Guidelines for Measurement, Data Exchange and Analysis*, Indian Standard IS/IEC 61724: 1998, Feb. 2010. [Online]. Available: <https://law.resource.org/pub/in/bis/S05/is.iec.61724.1998.pdf>

การพัฒนาและสร้างต้นแบบรวดเร็ว สำหรับผลิตภัณฑ์เซรามิกโดยใช้วิธีการขึ้นรูปทีละชั้น

นพพร บิ๊กแวน¹ ศศิธร คนทน² สุชุมาล เจริญทอง^{3*}

^{1,3*}สาขาเทคโนโลยีอุตสาหกรรมการผลิต คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏพระนคร, กรุงเทพมหานคร, ประเทศไทย

²สาขาเทคโนโลยีเซรามิกส์ คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏพระนคร, กรุงเทพมหานคร, ประเทศไทย

*ผู้ประพันธ์บรรณกิจ อีเมล : bukwanporn@gmail.com

รับต้นฉบับ : 2 ธันวาคม 2564; รับบทความฉบับแก้ไข : 16 กุมภาพันธ์ 2565; ตอบรับบทความ : 1 มีนาคม 2565

เผยแพร่ออนไลน์ : 27 มิถุนายน 2565

บทคัดย่อ

งานวิจัยนี้เพื่อออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็วและหาค่าพารามิเตอร์ที่ใช้ในการขึ้นรูป รวมถึงทดสอบค่าความคลาดเคลื่อนของการสร้างต้นแบบรวดเร็วสำหรับผลิตภัณฑ์เซรามิกโดยใช้วิธีการขึ้นรูปทีละชั้น การดำเนินวิจัยนี้เริ่มจากออกแบบผลิตภัณฑ์เซรามิกแบบสามมิติโดยใช้โปรแกรมยูนิกราฟิกส์เอ็นเอ็กซ์ เวอร์ชัน 6.0 จากนั้นนำไฟล์สามมิติสร้างเส้นภาพตัดขวางตามความสูงของชิ้นงานทีละชั้น ออกแบบและสร้างเครื่องต้นแบบรวดเร็ว โดยเครื่องมีขนาด 300×450×400 มิลลิเมตร ซึ่งมีชุดอุปกรณ์ประกอบด้วย 3 ส่วน คือ 1) ชุดโครงสร้าง 2) ชุดควบคุมอัตราป้อนของหัวฉีด 3) ชุดระบบอิเล็กทรอนิกส์ควบคุมและซอฟต์แวร์ การต่อระบบวงจรอิเล็กทรอนิกส์ ใช้บอร์ดอาร์duinoโมโนบอร์ดแบบยูเอสบี เพื่อใช้ติดต่อสื่อสารกับชุดฮาร์ดแวร์และใช้ซอฟต์แวร์มาคสามซีเอ็นซีคอนโทรลเลอร์ ควบคุมการเคลื่อนที่ของมอเตอร์ให้เคลื่อนที่แบบ 4 แกนคือ แกน X Y Z และแกน A จากนั้นทดสอบหาค่าพารามิเตอร์ที่ส่งผลในการขึ้นรูป ตัวแปรควบคุมได้แก่ ขนาดเส้นผ่านศูนย์กลางของหัวฉีด 2 มิลลิเมตร ใช้ดินสำเร็จรูปชนิดคอมพาวด์พีบี ความชื้นของดินในช่วง 40-45 เปอร์เซ็นต์ ตัวแปรตามคือ อัตราป้อนของชุดหัวฉีด ความเร็วในการเคลื่อนที่และระยะห่างระหว่างชั้นในการขึ้นรูป การทดสอบพบว่าอัตราป้อนของชุดหัวฉีดที่เหมาะสมคือ 5 มิลลิเมตรต่อนาที ค่าความเร็วในการเคลื่อนที่แกน X Y Z คือ 60 มิลลิเมตรต่อนาที ค่าระยะห่างระหว่างชั้นในการขึ้นรูปที่เหมาะสมคือ 0.80 มิลลิเมตร และผลการทดสอบขึ้นรูปผลิตภัณฑ์ แบบรูปทรงกลม แบบรูปทรงสี่เหลี่ยมและแบบรูปทรงอิสระพบว่าสามารถขึ้นรูปชิ้นงานได้ตามแบบและจากการนำผลิตภัณฑ์ที่ได้จากการขึ้นรูปไปเผาที่อุณหภูมิ 1200 องศาเซลเซียส พบว่าผลิตภัณฑ์ที่ได้หลังจากการเผามีความสมบูรณ์ไม่มีรอยแตกร้าวและเสียรูปทรง ในด้านการทดสอบค่าความคลาดเคลื่อนของเครื่องสร้างต้นแบบรวดเร็ว จากการวัดขนาดของชิ้นงานหลังจากขึ้นรูปพบว่ามีความคลาดเคลื่อนได้ไม่เกินค่าบวกและค่าลบเฉลี่ยเท่ากับ 0.2 มิลลิเมตร

คำสำคัญ: การสร้างต้นแบบรวดเร็ว การขึ้นรูปทีละชั้น ผลิตภัณฑ์เซรามิก

Development of Rapid Prototyping for Ceramic Products Using Layer Manufacturing Technique

Nopporn Bukwan¹ Sasitron Khonthon² Sukhuman Rianthong^{3*}

^{1,3*}*Program in Manufacturing Technology, Faculty of Industrial Technology, Phranakorn Rajabhat University, Bangkok, Thailand*

²*Program in Ceramic Technology, Faculty of Industrial Technology, Phranakorn Rajabhat University, Bangkok, Thailand*

*Corresponding Author. E-mail address: bukwanporn@gmail.com

Received: 2 December 2021; Revised: 16 February 2022; Accepted: 1 March 2022

Published online: 27 June 2022

Abstract

This research aims to design and develop a rapid prototyping machine and explore the forming parameters, included the performance evaluation of rapid prototyping machine technology for ceramic products which deploy layer manufacturing technique. Procedural of this research started from 3D ceramic product design in Unigraphics NX version 6.0 program, next created a cross section line in the 3D file base on a height of product at each layer in development a rapid prototyping machine. The machine size is 300x400x500 millimeter which is composed of 3 components, 1) Base structure 2) Injection rate control unit 3) Electronic control system and software. In wiring electronic circuit, RNR Motion board is applied. USB port used as communication port between hardware and Mach3 CNC controller software is used to control the motor moving in 4 axes as X, Y, Z and A. Testing has explored to find the effective parameters to create prototype. The control parameters are diameter size of injector which is fixed at 2 millimeters, and PBB compound clay which contained the moisture range as 40-50%. The dependent parameters are injector rate, velocity and interval of forming level. The testing results shown that the appropriate injection rate is 5 mm/min, the velocity of axes moving in x, y, z is 60 mm/min, the appropriate interval of forming level is 0.80 millimeter and results of circle forming style, rectangle forming style and free style forming production are good performed, after put the forming product into flaming with 1200 Celsius, the forming product is perfect, no rupture and no twisted. The performance of rapid prototyping machine is measured by product size after forming, found that the mean of +/- deviation is 0.2 millimeter.

Keywords: Rapid prototyping, Layer manufacturing, Ceramic products

1) บทนำ

อุตสาหกรรมเซรามิกเป็นอุตสาหกรรมหนึ่งที่สำคัญของประเทศ ซึ่งเป็นพื้นฐานของอุตสาหกรรมต่อเนื่องอีกมากมาย ได้แก่ อุตสาหกรรมเครื่องใช้ไฟฟ้า อุตสาหกรรมยานยนต์ อุตสาหกรรมอิเล็กทรอนิกส์ ส่วนใหญ่ผลิตภัณฑ์เซรามิกที่ผลิตในประเทศแบ่งออกเป็น 5 ประเภทใหญ่ ๆ ได้แก่ เครื่องสุขภัณฑ์ เครื่องใช้บนโต๊ะอาหาร ของที่ระลึก เครื่องประดับ เครื่องปั้นดินเผา ส่วนผลิตภัณฑ์เซรามิกสมัยใหม่ที่ต้องใช้เทคโนโลยีขั้นสูง เช่น ชิ้นส่วนอิเล็กทรอนิกส์ เครื่องมือวิทยาศาสตร์ อุปกรณ์การแพทย์ อุตสาหกรรมเซรามิกยังคงต้องอาศัยการนำเข้าเทคโนโลยีมาจากต่างประเทศ ในด้านเศรษฐกิจและสังคม อุตสาหกรรมเซรามิกจัดเป็นอุตสาหกรรมที่มีบทบาทและความสำคัญต่อการจ้างงาน การกระจายรายได้ การสร้างมูลค่าเพิ่มไปสู่ภาคอุตสาหกรรม วิสาหกิจชุมชน รวมถึงผู้ประกอบการด้านเซรามิกซึ่งมีโรงงานผลิตกระจายอยู่ตามภูมิภาคต่าง ๆ ประมาณ 630 โรงงาน ด้วยเงินลงทุนรวม 17,400 ล้านบาท โดยก่อให้เกิดการจ้างงานประมาณ 63,000 คน เพื่อสร้างรายได้และเป็นสินค้าส่งออกสู่ต่างประเทศสำหรับของชำร่วยและเครื่องประดับมีผู้ผลิตจำนวน 400-500 โรงงาน มีกำลังการผลิต 150,000-200,000 ชิ้นต่อปีและประเทศไทยมีมูลค่าการส่งออกผลิตภัณฑ์เซรามิก 13,653 ล้านบาท [1] ปัจจุบันกระบวนการผลิตเซรามิกเปลี่ยนไปจากแบบดั้งเดิม เช่น เครื่องปั้นดินเผา เป็นการผลิตแบบสมัยใหม่โดยใช้เทคโนโลยีการผลิตขั้นสูงเข้ามาช่วย เนื่องจากผลิตภัณฑ์ที่ลูกค้าต้องการมีความซับซ้อน หากใช้การผลิตแบบเดิมต้องใช้เครื่องมือและอุปกรณ์จำนวนมาก ทำให้บริษัทหรือผู้ประกอบการรายย่อยต้องปฏิเสธการสั่งซื้อผลิตภัณฑ์จากลูกค้า ทำให้เสียโอกาสทางด้านการตลาด เทคโนโลยีการสร้างต้นแบบรวดเร็วเป็นการขึ้นรูปผลิตภัณฑ์แบบรวดเร็วโดยการเติมเนื้อวัสดุต่อ ๆ กันทีละชั้น [2], [3] ตามแบบจำลองสามมิติที่ได้จากการออกแบบโดยใช้เทคโนโลยีคอมพิวเตอร์ช่วยในการออกแบบ (Computer Aided Design: CAD) คอมพิวเตอร์ช่วยในการผลิต (Computer Aided Manufacturing: CAM) [4] หรือการสแกนรูปร่างของวัตถุให้อยู่ในรูปแบบไฟล์สามมิติ (Reverse Engineering) [5] โดยมีขั้นตอนเริ่มจากการสร้างไฟล์แบบจำลองสามมิติโดยใช้โปรแกรมคอมพิวเตอร์ ซึ่งจัดเก็บข้อมูลรูปร่างของวัตถุโดยใช้หลักการนำสามเหลี่ยมมาต่อกันของวัตถุ จากนั้นซอฟต์แวร์สำหรับแบ่งชิ้นวัตถุจะแบ่งรูปร่างของวัตถุเป็นชั้น ๆ ในแนวระดับเพื่อส่ง

ไฟล์ข้อมูลให้เครื่องสร้างต้นแบบรวดเร็วขึ้นรูปวัตถุออกมาตามแบบจำลองสามมิติ ดังนั้นการประยุกต์ใช้เทคโนโลยีการสร้างต้นแบบรวดเร็วจึงมีความสำคัญและจำเป็นต่อผู้ประกอบการขนาดกลางและขนาดย่อม รวมถึงกลุ่มหัตถกรรมเครื่องปั้นดินเผา เพื่อพัฒนารูปแบบของผลิตภัณฑ์ที่มีความซับซ้อน ตลอดจนการปรับปรุงคุณภาพและลดเวลาที่ใช้ในกระบวนการผลิตให้สั้นลง ลดต้นทุนการนำเข้าเครื่องจักรจากต่างประเทศ อีกทั้งทำให้ผู้ประกอบการสามารถเพิ่มทางเลือกในการพัฒนาผลิตภัณฑ์เพื่อตอบสนองความต้องการของผู้บริโภค

จากปัญหาดังกล่าวคณะผู้วิจัยจึงมีแนวคิดในการพัฒนาเทคโนโลยีการสร้างต้นแบบรวดเร็วสำหรับผลิตภัณฑ์เซรามิกโดยใช้วิธีการขึ้นรูปทีละชั้น เพื่อตอบสนองความต้องการของผู้ประกอบการเซรามิก กลุ่มวิสาหกิจชุมชน ในการพัฒนาผลิตภัณฑ์รูปแบบใหม่สู่ตลาดผู้บริโภค และยังสามารถเป็นเครื่องมือสำหรับการเรียนรู้ในสถานศึกษาที่มีการเรียนการสอนทางด้านเทคโนโลยีเซรามิกส์ อีกทั้งทำให้ผู้ประกอบการ สามารถลดต้นทุนการนำเข้าเครื่องจักรและเทคโนโลยีจากต่างประเทศ รวมถึงสร้างการแข่งขันด้านตลาดของอุตสาหกรรมเซรามิกภายในประเทศ

2) วัตถุประสงค์ของการวิจัย

ในบทความนี้มีวัตถุประสงค์เพื่อออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็วและหาค่าพารามิเตอร์ที่ใช้ในการขึ้นรูป รวมถึงทดสอบขึ้นรูปชิ้นงานและหาค่าความคลาดเคลื่อนของการสร้างต้นแบบรวดเร็วสำหรับผลิตภัณฑ์เซรามิกโดยใช้วิธีการขึ้นรูปทีละชั้น

3) ทบทวนวรรณกรรมที่เกี่ยวข้อง

การพัฒนาเทคโนโลยีการสร้างต้นแบบรวดเร็ว ได้มีการพัฒนาตั้งแต่อดีตจนถึงปัจจุบัน เนื่องจากเทคโนโลยีดังกล่าวได้รับความนิยมจากภาคอุตสาหกรรมเป็นจำนวนมาก สามารถนำไปประยุกต์ใช้ในการพัฒนาต้นแบบผลิตภัณฑ์รวมถึงการผลิตของสินค้าเป็นจำนวนมาก ลดระยะเวลาในกระบวนการออกแบบและผลิตให้สั้นลง คือการสร้างต้นแบบรวดเร็ว (Rapid Prototyping) [6], [7] โดยการสร้างชิ้นงานรูปทรง 3 มิติโดยตรงจากโปรแกรมคอมพิวเตอร์ช่วยในการออกแบบและผลิต หรือ การสร้างแบบจำลองสามมิติด้วยการสแกนชิ้นงานจากเครื่องเลเซอร์สแกนแบบสามมิติ ซึ่งมีความจำเป็นด้านการออกแบบ การตรวจสอบ


คุณภาพของผู้ผลิตสินค้า จนถึงการพัฒนาารูปแบบผลิตภัณฑ์ที่มีความซับซ้อน การพัฒนาเทคโนโลยีการสร้างต้นแบบรวดเร็ว นั้นจึงเป็นสิ่งที่สำคัญของผู้คิดค้น ออกแบบ พัฒนาและทดลอง การพัฒนาเทคโนโลยีการสร้างต้นแบบรวดเร็วมีงานวิจัยที่เกี่ยวข้องดังนี้

H. Shao et al. [8] ได้ทำการศึกษาการขึ้นรูปผลิตภัณฑ์สามมิติด้วยใช้วัตถุดิบคือ เซรามิก Zirconia ได้ทำการทดสอบขึ้นรูปผลิตภัณฑ์แบบสามมิติ โดยใช้กระบวนการเอ็กซ์ทรูดขึ้นรูป (Extrude) โดยใช้ระบบขับเคลื่อนหัวฉีดแบบสกรูเดี่ยว (Single Screw) โดยเริ่มจากการสร้างแบบจำลองสามมิติ จากนั้นทำการแบ่งระดับชั้นความสูง โดยค่าตัวแปรที่สนใจคือ ขนาดของเส้นผ่านศูนย์กลางของรูฉีด ความสูงของแต่ละชั้นและความเร็วในการเคลื่อนที่การพิมพ์ของชิ้นงาน โดยกำหนดค่าตัวแปรให้มีค่าเท่ากับ 0.5, 0.4 และ 20 มม.ต่อวินาที ตามลำดับ ผลการทดลองพบว่า การขึ้นรูปโดยใช้กระบวนการเอ็กซ์ทรูดขึ้นรูปแบบสกรูเดี่ยวจะทำให้ค่าความหนาของผิวโดยที่ชิ้นงานก่อนเผามีค่าความหนาที่ผิวงานคือ 8.25 และ 8.90 ไมโครเมตรและวัดค่าความหนาของผิวหลังเผาชิ้นงานที่อุณหภูมิ 1520 องศาเซลเซียสเป็นเวลา 2 ชั่วโมง พบว่าขนาดเส้นผ่านศูนย์กลางของหัวฉีดขนาด 0.05 มม. จะมีความแม่นยำและถูกต้องในการขึ้นรูปชิ้นงานมากกว่าหัวฉีดขนาดใหญ่คือ 5 มม. อีกทั้ง P. Pitayachaval and A. Thongrak [9] ได้ศึกษาความลาดเอียงของชิ้นงานที่สามารถขึ้นรูปจากดินเหนียวด้วยเทคโนโลยีการสร้างต้นแบบรวดเร็ว โดยกำหนดค่าตัวแปรคือความลาดเอียงที่ขึ้นรูป 30, 45, 60 องศา โดยกำหนดขนาดเส้นผ่านศูนย์กลางของหัวฉีด 6 และ 8 มม. และอัตราการป้อนวัสดุ 300 และ 500 เปอร์เซ็นต์ ตัวแปรตามคือความสามารถในการขึ้นรูปได้และไม่ได้และค่าความเอียงขึ้นรูป ตัวแปรควบคุมคือ ความเร็วในการเคลื่อนที่ของแต่ละแกน X, Y, Z ซึ่งมีค่าเท่ากันทุกแกนคือ 8 มม.ต่อวินาทีและชนิดของดินเหนียว ผลการทดลองพบว่าค่าความเอียงที่ 45 องศาและ 60 องศา ด้วยเส้นผ่านศูนย์กลางขนาดหัวฉีด 6 และ 8 มม. สามารถขึ้นรูปชิ้นงานได้ด้วยความสะดวกที่ความสูงไม่เกิน 100 มม.

นอกจากนี้ F. Yang, et al. [10] ได้ศึกษากรรมวิธีการขึ้นรูปแบบเอกซ์ทรูดขึ้นรูปด้วยการขึ้นรูปชิ้นงานแบบเอกซ์ทรูดขึ้นรูปด้วยการขึ้นรูปชิ้นงานกับวัสดุที่มีสถานะกึ่งแข็งกึ่งเหลว วัตถุดิบที่ใช้คือ เจลมะนาว โดยใช้วิธีการขึ้นรูปแบบเอกซ์ทรูดขึ้นรูปที่เคลื่อนที่ได้แรงดันฉีดจากสกรู ซึ่งหัวฉีดมีขนาดเส้นผ่านศูนย์กลางขนาด 0.5, 1.0, 1.5 และ 2.0 มม.และควบคุมอุณหภูมิห้องในการทดลอง 25 องศาเซลเซียสมีค่าบวกและลบได้ไม่เกิน 1 องศาเซลเซียสจากการทดสอบพบว่าความสูงของหัวฉีดไม่ส่งผลต่อคุณภาพของชิ้นงาน แต่ขนาดของหัวฉีดมีความสัมพันธ์กับอัตราป้อนวัสดุและยังส่งผลต่อคุณภาพของชิ้นงาน

4) วิธีดำเนินการวิจัย

การดำเนินงานวิจัยเพื่อออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็วสำหรับขึ้นรูปผลิตภัณฑ์เซรามิกโดยใช้วิธีการขึ้นรูปที่ละชั้น เริ่มจากการออกแบบชิ้นงานที่ใช้ในการขึ้นรูปจำนวน 3 รูปแบบ จากนั้นทำการออกแบบและสร้างเครื่องสร้างต้นแบบรวดเร็ว ขั้นตอนต่อไปการออกแบบการทดลองเพื่อหาความสัมพันธ์ระหว่างตัวแปรต่าง ๆ ที่ส่งผลต่อการขึ้นรูปของชิ้นงาน ซึ่งปัจจัยที่กำหนดให้เป็นตัวแปรควบคุมคือ 1) ชนิดของดินคือ ดินสำเร็จรูปชนิด Compound PBB 2) ความชื้นของดินในช่วง 40-45 เปอร์เซ็นต์ 3) ขนาดเส้นผ่านศูนย์กลางของรูฉีดเท่ากับ 2 มม.และปัจจัยที่กำหนดให้เป็นตัวแปรในการขึ้นรูปคือ อัตราการป้อนของชุดหัวฉีด ความเร็วในการเคลื่อนที่ของแกน X Y Z ระยะห่างระหว่างหัวฉีดกับพื้นผิวรองรับ เมื่อได้ค่าพารามิเตอร์ที่ใช้ในการขึ้นรูปจากนั้นทำการทดลองขึ้นรูปชิ้นงานตัวอย่างจำนวน 3 รูปแบบ โดยทดสอบซ้ำในการขึ้นรูปจำนวน 10 ครั้ง นำชิ้นงานที่ได้จากการขึ้นรูปไปตรวจสอบหาค่าความคลาดเคลื่อนที่ได้จากการขึ้นรูปชิ้นงานละ 3 จุดเปรียบเทียบกับแบบชิ้นงานและหาค่าเฉลี่ยของชิ้นงานที่มีความคลาดเคลื่อนได้ไม่เกินค่าบวกและค่าลบ ขั้นตอนสุดท้ายคือนำชิ้นงานที่ได้จากการขึ้นรูปไปทดสอบเผาโดยใช้วิธีการเผาตามกระบวนการทางเซรามิก ซึ่งมีขั้นตอนในการดำเนินการวิจัยดังนี้




รูปที่ 1 : ขั้นตอนการดำเนินการวิจัย

4.1) ศึกษาข้อมูลเบื้องต้นเพื่อใช้ในการออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็วสำหรับผลิตภัณฑ์เซรามิกโดยใช้วิธีการขึ้นรูปที่ละชั้น

เริ่มจากคณะผู้วิจัยได้ดำเนินการประชุมและทำความเข้าใจถึงขอบข่าย วัตถุประสงค์และเป้าหมายร่วมกันในการพัฒนาเทคโนโลยีการสร้างต้นแบบรวดเร็วและทำการศึกษาค้นคว้ารวบรวมข้อมูล จากเอกสาร งานวิจัยต่าง ๆ นักคิดค้นพัฒนาเทคโนโลยีเพื่อใช้เป็นข้อมูลพื้นฐานสำหรับการพัฒนาเทคโนโลยีดังกล่าว จากนั้นคณะผู้วิจัยได้กำหนดรูปแบบผลิตภัณฑ์ที่ใช้ในการพัฒนาครั้งนี้ โดยกำหนดรูปแบบของชิ้นงานที่ใช้ในการทดสอบขึ้นรูปจำนวน 3 รูปแบบ คือ 1) รูปแบบทรงกลม ซึ่งรูปแบบดังกล่าวในกระบวนการขึ้นรูปทางเซรามิกสามารถทำได้ง่ายและสะดวก 2) รูปแบบทรงสี่เหลี่ยม เป็นรูปแบบที่ใช้ในการทดสอบโดยกระบวนการขึ้นรูปสามารถทำได้ยากกว่ารูปทรงกลม 3) รูปแบบอิสระ เป็นรูปแบบที่กระบวนการทางเซรามิกทำได้ยากจำเป็นต้องใช้เครื่องมือและอุปกรณ์หลายชนิดในการขึ้นรูป รวมถึงศึกษาข้อมูลของดินที่ใช้ขึ้นรูป ซึ่งการวิจัยนี้ใช้ดินสำเร็จรูปของบริษัทคอมพาวด์เคลย์ ชนิด Compound PBB และความชื้นของดินในช่วง 40-45 เปอร์เซ็นต์ เนื่องจากดินชนิดดังกล่าวทางโรงงานหรือผู้ประกอบการ นำดินชนิดดังกล่าวมาใช้ในการขึ้นรูปชิ้นงานเซรามิก ซึ่งดินสำเร็จรูปมีคุณสมบัติด้านความเหนียว แต่ไม่โปร่งแสง สามารถคงรูปได้ดี อีกทั้งเนื้อดินมีความละเอียดและยังสามารถลดการแตกร้าวของเนื้อดินเมื่อทำการอบแห้งรวมถึงการเผาเคลือบ

4.2) ออกแบบผลิตภัณฑ์ต้นแบบเซรามิกโดยใช้คอมพิวเตอร์ช่วยออกแบบ

หลังจากได้ข้อสรุปแนวคิดในการพัฒนารูปแบบของผลิตภัณฑ์เซรามิกโดยใช้การพัฒนาเทคโนโลยีการสร้างต้นแบบรวดเร็ว ขั้นตอนต่อไปคณะผู้วิจัยจึงนำแนวคิดดังกล่าวมาทำการออกแบบผลิตภัณฑ์โดยใช้โปรแกรมยูนิกราฟิกส์ เวอร์ชัน 6.0 เพื่อให้เห็นรูปทรงสามมิติในคอมพิวเตอร์ ซึ่งประกอบด้วยแบบชิ้นงาน 3 รูปแบบ คือ 1) แบบรูปทรงกลม มีขนาดเส้นผ่านศูนย์กลาง 80 มม. ความสูง 100 มม. 2) แบบรูปทรงสี่เหลี่ยม มีขนาดความกว้าง 80 มม. ความยาว 80 มม.และความสูง 100 มม. 3) แบบรูปทรงอิสระ มีขนาดความกว้าง 80 มม. ความยาว 80 มม.และความสูง 100 มม. ดังรูปที่ 2 จากนั้นนำไฟล์แบบชิ้นงานสามมิติ มาแปลงข้อมูลเป็นไฟล์นามสกุล .stl เพื่อแปลงเป็นรูปแบบไฟล์สามเหลี่ยมต่อกัน (Polygon) เพื่อนำไฟล์ที่ได้จากการออกแบบไปกำหนดรูปแบบการขึ้นรูปต่อไป




รูปที่ 2 : ออกแบบผลิตภัณฑ์เซรามิกที่ใช้ในการขึ้นรูป

4.3) การสร้างเส้นภาพตัดขวางตามความสูงของชิ้นงาน

ขั้นตอนต่อไปคณะวิจัยได้นำไฟล์ชิ้นงานสามมิติเข้าสู่โปรแกรม Ultimaker Cura จากนั้นโปรแกรมทำการกำหนดรูปแบบการขึ้นรูปและทำการสร้างเส้นภาพตัดขวางตามความสูงของชิ้นงาน กำหนดค่าตัวแปรที่ส่งผลในการขึ้นรูปได้แก่ ความเร็ว

ในการเคลื่อนที่ อัตราป้อนในการขึ้นรูป ความสูงของระยะห่างระหว่างชั้น ลำดับถัดไปโปรแกรมจะทำการแปลงไฟล์เส้นภาพตัดขวางเป็นโปรแกรมควบคุมเชิงตัวเลขเพื่อใช้ควบคุมให้เครื่องสร้างต้นแบบรวดเร็วเคลื่อนที่ตามพิกัดในแนวแกน X Y Z และแกน A และดำเนินการทดสอบโปรแกรม ดังแสดงรูปที่ 3




รูปที่ 3 : การสร้างเส้นภาพตัดขวางตามความสูงของชิ้นงาน

4.4) การออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็ว

การออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็วแบบอัตโนมัติ ซึ่งคณะวิจัยได้นำข้อมูลสำรวจและข้อมูลจากการสืบค้น จากแหล่งข้อมูล งานวิจัยที่เกี่ยวข้องกับการออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็ว จากนั้นคณะวิจัยได้ดำเนินการวางแผน ออกแบบและปรับปรุงให้เหมาะสมและที่สำคัญเครื่องสร้างต้นแบบรวดเร็วที่พัฒนา วัตถุประสงค์และอุปกรณ์ที่ใช้ประกอบต้องสามารถหาซื้อได้ภายในประเทศ มีราคาถูก มีอายุการใช้งานยาวนาน การออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็วประกอบด้วย 3 ส่วน ดังนี้

4.4.1) การออกแบบชุดโครงสร้างของเครื่องสร้างต้นแบบรวดเร็ว การออกแบบชุดโครงสร้างของเครื่องสร้างต้นแบบรวดเร็ว คณะวิจัยได้ทำการออกแบบชุดโครงสร้าง โดยเครื่องดังกล่าวมีขนาดพื้นที่เท่ากับ 300x450x400 มม.และมีระยะการเคลื่อนที่ในแนวแกน X เท่ากับ 150 มม.แกน Y เท่ากับ 150 มม. และแกน Z เท่ากับ 200 มม.ใช้โครงสร้างเป็นอะลูมิเนียมโปรไฟล์และใช้อะลูมิเนียมแผ่นหนา 10 มม.สำหรับเป็นชิ้นส่วนประกอบ


การออกแบบชุดขับเคลื่อนใช้บอลสกรูทั้ง 3 แกน เพื่อลดความผิดพลาดจากการเคลื่อนที่ โดยบอลสกรูมีขนาดเส้นผ่านศูนย์กลาง 12 มม. มีระยะพิทเท่ากับ 5 มม. การควบคุมการเคลื่อนที่ของแนวแกน X Y และแกน Z ใช้มอเตอร์ควบคุมการเคลื่อนที่ของเครื่องจักรทั้ง 3 แกน ประกอบด้วยดังนี้ 1) ชุดเคลื่อนที่แกน X 2) ชุดเคลื่อนที่แกน Y 3) ชุดเคลื่อนที่แกน Z 4) ชุดโครงสร้างเครื่อง 5) ชุดหัวฉีดแกน A ดังรูปที่ 4



รูปที่ 4 : การออกแบบชุดโครงสร้างของเครื่อง


4.4.2) การออกแบบชุดควบคุมอัตราป้อนของหัวฉีด
คณะผู้วิจัยได้ทำการออกแบบชุดควบคุมอัตราป้อนของหัวฉีด
โดยใช้ชุดบอลสกรูยึดติดกับกระบอกดันฉีดทำหน้าที่ดันเนื้อ
วัตถุดิบคือดินให้ไหลออกมาทางรูหัวฉีด และออกแบบชุด
กระบอกพลาสติกใสสามารถบรรจุหรือเติมวัตถุดิบตามปริมาตร
ของกระบอก บริเวณปลายของกระบอกพลาสติกใสทำเป็นเกลียว
เพื่อสามารถเปลี่ยนขนาดเส้นผ่านศูนย์กลางของรูหัวฉีดและใช้

มอเตอร์ควบคุมการเคลื่อนที่จากโปรแกรม Mach3 CNC
Controller ผ่านชุดคอมพิวเตอร์สั่งงานให้ชุดไดรฟ์ขับมอเตอร์
เพื่อควบคุมการเคลื่อนที่ของชุดบอลสกรู โดยชุดอุปกรณ์
ประกอบด้วย 1) ชุดโครงสร้างใช้วัสดุเป็นอลูมิเนียมแผ่น 2)
กระบอกพลาสติกใสสำหรับเติมวัตถุดิบ 3) ฐานยึดกับเครื่องจักร
4) กระบอกดันฉีด 5) ชุดบอลสกรูสำหรับเคลื่อนที่ดันฉีด โดยมี
ระยะเคลื่อนที่เท่ากับ 150 มม.ดังรูปที่ 5



รูปที่ 5 : การออกแบบชุดควบคุมอัตราป้อนของหัวฉีด

4.4.3) การออกแบบระบบอิเล็กทรอนิกส์ควบคุมและ
ซอฟต์แวร์ ขั้นตอนต่อไปคณะผู้วิจัยได้ออกแบบระบบอิเล็กทรอนิกส์
ควบคุมและซอฟต์แวร์ ซึ่งมีรายละเอียดประกอบด้วยอุปกรณ์ดังนี้
1) ชุดบอร์ดควบคุม RNR Motion Control แบบ USB ดังรูปที่
5(ก) โดยใช้ติดต่อสื่อสารกับอุปกรณ์คอมพิวเตอร์เพื่อแปลงคำสั่ง
จากโปรแกรม Mach3 CNC Controller ดังรูปที่ 5(ข) เพื่อสั่ง
การให้ชุดไดรฟ์ไปขับมอเตอร์ของแต่ละแกน ดังรูปที่ 5(ค) และ
การเชื่อมต่อวงจรอิเล็กทรอนิกส์กับอุปกรณ์ควบคุมในตู้ควบคุม
ดังรูปที่ 5(ง) โดยการเชื่อมต่อชุดบอร์ดควบคุม RNR Motion
Control ผ่านสัญญาณ USB กับอุปกรณ์คอมพิวเตอร์เพื่อแปลง
คำสั่งจากโปรแกรม Mach3 CNC Controller มาสั่งการให้ชุด
ไดรฟ์ขับมอเตอร์แบบสเต็ปมอเตอร์ ชนิด Nema23 ให้เคลื่อนที่
แบบ 4 แกนคือ แกน X Y Z และแกน A โดยที่แกน A ควบคุม
อัตราป้อนของชุดหัวฉีด ดังรูปที่ 6



รูปที่ 6 : การออกแบบระบบอิเล็กทรอนิกส์ควบคุมและซอฟต์แวร์

4.5) การสร้างเครื่องสร้างต้นแบบรวดเร็ว

ขั้นตอนต่อไปคณะผู้วิจัยได้ทำการผลิตชิ้นส่วนและอุปกรณ์
ตามที่ได้ออกแบบไว้ โดยการผลิตชุดอุปกรณ์ต่าง ๆ ใช้เครื่องจักร
ซีเอ็นซีในการผลิตชิ้นส่วนตามแบบ เมื่อได้ชุดอุปกรณ์ที่ผลิต จึง
ทำการประกอบโครงสร้างและประกอบชุดระบบอิเล็กทรอนิกส์
ควบคุมและทำการปรับค่าต่าง ๆ ที่ใช้ในการควบคุมการเคลื่อนที่
ดังแสดงรูปที่ 7



7(ก)



7(ข)

7(ค)

รูปที่ 7 : การสร้างเครื่องสร้างต้นแบบรวดเร็ว;

7(ก): เครื่องสร้างต้นแบบรวดเร็วและชุดควบคุมอัตราป้อนของหัวฉีด, 7(ข): ชุดควบคุม Mach3 CNC Controller, 7(ค): ชุดอิเล็กทรอนิกส์ควบคุม

4.6) การหาค่าพารามิเตอร์ที่ใช้ในการขึ้นรูป

การออกแบบการทดลองเพื่อหาความสัมพันธ์ระหว่างตัวแปรต่าง ๆ ที่ส่งผลต่อการขึ้นรูปของชิ้นงาน ซึ่งปัจจัยที่กำหนดให้เป็นตัวแปรควบคุมคือ 1) ชนิดของดินคือ ดินสำเร็จรูปชนิด Compound PBB 2) ความชื้นของดินในช่วง 40-45 เปอร์เซ็นต์ 3) ขนาดเส้นผ่านศูนย์กลางของรูฉีดเท่ากับ 2 มม.และปัจจัยที่กำหนดให้เป็นตัวแปรในการขึ้นรูปคือ อัตราการป้อนของชุดหัวฉีด ความเร็วในการเคลื่อนที่ของแกน X Y Z ระยะห่างระหว่างหัวฉีดกับพื้นผิวรองรับขั้นตอนการหาค่าพารามิเตอร์เริ่มจากการปรับค่าอัตราป้อนของชุดหัวฉีดตั้งแต่ 3-10 มิลลิเมตร/นาที่ เพื่อให้ดินไหลออกจากรูฉีด โดยพิจารณาจากเส้นดินที่ไหลออกมาจากหัวฉีด ซึ่งเส้นดินที่ไหลค่าอัตราป้อนที่เหมาะสมจึงทำการปรับค่าความเร็วในการเคลื่อนที่ของแกน X Y และแกน Z โดยพิจารณาจากเส้นดินที่ ออกมาต้องมีความยาวต่อเนื่องและไม่เกิดฟองอากาศ เมื่อได้ จำนวน 5 จุดของแนวเส้นดินแล้วนำค่าที่ได้มาหาค่าเฉลี่ยพิจารณาเส้นดินที่มีความสมบูรณ์และไม่ขาดออกจากกัน ลำดับถัดไปนำค่าพารามิเตอร์ที่เหมาะสมของอัตราป้อนของชุดหัวฉีดและความเร็วในการเคลื่อนที่ของแกน X Y Z และทำการปรับค่าระยะห่างระหว่างชิ้นในการขึ้นรูปชิ้นงาน โดย

ทดลองปรับค่าระหว่าง 0.6 – 1.5 มิลลิเมตร จากนั้นทำการเลือกค่าระยะห่างระหว่างหัวฉีดกับพื้นผิวรองรับ โดยพิจารณาจากผิวรอยต่อระหว่างชิ้นที่เรียบและมีผิวที่สม่ำเสมอและสามารถขึ้นรูปได้ต่อเนื่อง จากนั้นนำค่าตัวแปรที่เหมาะสมที่สุดนำไปทดสอบขึ้นรูปชิ้นงานในลำดับต่อไป

4.7) ทดสอบขึ้นรูปผลิตภัณฑ์เซรามิก

ขั้นตอนต่อไปคณะผู้วิจัยทำการทดสอบขึ้นรูปชิ้นงานจำนวน 3 รูปแบบคือ แบบรูปทรงกลม แบบสี่เหลี่ยมและแบบรูปทรงอิสระ โดยมีขั้นตอนคือการเตรียมดินโดยนำดินสำเร็จรูปของบริษัทคอมพาวด์เคลย์ ชนิด Compound PBB ผสมกับน้ำจนเป็นเนื้อเดียวกัน ผ่านตะแกรงกรองขนาด 50 เมช และควบคุมให้ความชื้นของดินในช่วง 40-45 เปอร์เซ็นต์ตามกระบวนการทางเซรามิก นำมาบรรจุลงในกระบอกของชุดหัวฉีด นำไปติดตั้งบนเครื่องสร้างต้นแบบรวดเร็วและทำการไล่อากาศออกจากกระบอกฉีด ลำดับถัดไปทดสอบโปรแกรมขึ้นรูปและทดสอบขึ้นรูปชิ้นงานจำนวน 3 แบบ ดังรูปที่ 8 เพื่อทดสอบการขึ้นรูปชิ้นงานได้หรือขึ้นรูปชิ้นงานไม่ได้และทำการทดลองทำซ้ำ 10 ครั้ง จากนั้นนำชิ้นงานที่ได้จากการขึ้นรูปมาตรวจสอบวัดขนาด

ของชิ้นงานโดยใช้เครื่องมือวัดคือเวอร์เนียคาลิเปอร์ที่มีค่าความละเอียด 0.02 มิลลิเมตร โดยวัดขนาดของชิ้นงานจำนวน 3 แบบ แบบละ 10 ชิ้นและมีจุดวัดจำนวน 3 จุด นำค่าที่ได้มาหาค่าเฉลี่ย

เพื่อหาค่าความคลาดเคลื่อนที่เกิดขึ้นจากการขึ้นรูปโดยใช้เครื่องสร้างต้นแบบรวดเร็ว



รูปที่ 8 : ทดสอบขึ้นรูปผลิตภัณฑ์เซรามิก

4.8) ทดสอบเผาผลิตภัณฑ์เซรามิก

เมื่อได้ผลิตภัณฑ์ที่ขึ้นรูปจากเครื่องสร้างต้นแบบรวดเร็ว ขั้นตอนต่อไปคือจะวิจัยได้นำผลิตภัณฑ์ที่ได้จากการขึ้นรูปทดสอบเผาโดยกระบวนการทางเซรามิกที่ได้จากการทดสอบ เริ่มจากนำชิ้นงานมาผึ่งให้แห้งที่อุณหภูมิ 110 องศาเซลเซียส เป็นเวลา 24 ชั่วโมง จากนั้นนำผลิตภัณฑ์ที่ผ่านการอบแห้ง มาเผาด้วยเตา

ไฟฟ้าที่อุณหภูมิ 850 องศาเซลเซียส เป็นเวลา 6 ชั่วโมง นำผลิตภัณฑ์ที่ผ่านการเผาดิบ มาชุบเคลือบและเผาเคลือบด้วยเตาไฟฟ้าที่อุณหภูมิ 1,200 องศาเซลเซียส เป็นเวลา 8 ชั่วโมง ดังรูปที่ 9 เพื่อทดสอบความสมบูรณ์ของผลิตภัณฑ์ที่ได้จากการขึ้นรูปคือการแตกร้าวและไม่มีความเสียหายของผลิตภัณฑ์หลังจากการเผาขึ้นรูป



รูปที่ 9 : ทดสอบเผาผลิตภัณฑ์เซรามิก

5) ผลการทดลอง

การทดสอบประสิทธิภาพของเทคโนโลยีการสร้างต้นแบบรวดเร็วสำหรับผลิตภัณฑ์เซรามิกได้ทำการแบ่งส่วนการทดลองออกเป็น 3 ส่วนดังนี้

5.1) ผลการทดสอบหาค่าพารามิเตอร์ที่ใช้สำหรับขึ้นรูปผลิตภัณฑ์เซรามิก ซึ่งได้ผลการทดลองดังนี้

5.1.1) ผลการทดสอบอัตราการป้อนของชุดหัวฉีด พบว่าเมื่อปรับค่าอัตราป้อนของชุดแรงดันฉีดโดยปรับค่าที่ 3-4 มิลลิเมตร

ต่อมาที่ ผลลัพธ์ที่ได้คือเส้นดินไม่สามารถไหลออกจากหัวฉีดและเมื่อทดสอบปรับค่าความเร็วอัตราป้อนของชุดหัวฉีดเป็น 5 มิลลิเมตรต่อนาที ผลลัพธ์ที่ได้คือเส้นดินสามารถไหลออกจากหัวฉีด ไม่ขาด มีความยาวต่อเนื่องและเมื่อปรับค่าอัตราป้อนของชุดหัวฉีดเป็น 6-10 มิลลิเมตรต่อนาที ตามลำดับ พบว่าเส้นของดินขาดไม่ต่อเนื่อง จากการทดสอบหาค่าอัตราป้อนของชุดหัวฉีดที่เหมาะสม คือ 5 มิลลิเมตรต่อนาที ดังรูปที่ 10



รูปที่ 10 : การทดสอบหาค่าอัตราการป้อนของชุดหัวฉีด

5.1.2) ผลการทดสอบหาค่าความเร็วในการขึ้นรูป โดยปรับค่าความเร็วในการเคลื่อนที่ของแกน X Y และ Z อยู่ระหว่าง 10-80 มม./นาที จากนั้นทำการทดสอบฉีดขึ้นรูปเส้นดินเป็นแนวเส้นตรงยาว 100 มม. ผลการทดสอบฉีดขึ้นรูปเส้นดินเป็นแนวเส้นตรงยาว 100 มม. จากนั้นทำการวัดระยะของเส้นดิน จำนวน 5 จุดของแนวเส้นดินแล้วนำค่าที่ได้มาหาค่าเฉลี่ย มีดังนี้

ตารางที่ 1 : ผลหาค่าความเร็วที่ใช้ในการขึ้นรูป

ความเร็วในการเคลื่อนที่ (มม./นาที)	ความกว้างเฉลี่ยของเส้นดิน (มม.)	ความสูงเฉลี่ยของเส้นดิน (มม.)
10	3.0	1.5
20	2.8	1.4
30	2.6	1.3
40	2.4	1.2
50	2.2	1.1
60	2.0	1
70	1.8	0.9
80	1.6	0.8


จากตารางที่ 1 พบว่าเมื่อทดลองปรับค่าความเร็วในการเคลื่อนที่ของแกน X Y Z เข้า ส่งผลทำให้เส้นของดินมีขนาดความกว้างมากและความสูงของเส้นดินมาก เมื่อปรับค่าความเร็วในการเคลื่อนที่มากขึ้นเส้นดินจะมีขนาดความกว้างและความสูงจะน้อยลง จากการทดลองค่าความเร็วที่ใช้ในการ

ขึ้นรูปที่เหมาะสมคือ 60 มิลลิเมตรต่อนาที เนื่องจากเส้นดินที่ได้มีความสมบูรณ์และไม่ขาดออกจากกันและสามารถขึ้นรูปได้ ดังรูปที่ 11



รูปที่ 11 : ความเร็วในการเคลื่อนที่ของแกน X Y และแกน Z

5.1.3) ผลการทดสอบหาค่าระยะห่างระหว่างชั้นในการขึ้นรูปชิ้นงาน การทดสอบโดยตัวแปรควบคุมคงที่คืออัตราป้อนของชุดหัวฉีดเท่ากับ 5 มิลลิเมตร/นาที และค่าความเร็วในการเคลื่อนที่ของแกน X Y และแกน Z เท่ากับ 60 มิลลิเมตรต่อนาที และทดลองปรับค่าความสูงในการขึ้นรูปทีละชั้น ตั้งแต่ 0.6 -1.5 มิลลิเมตร ผลการทดลองพบว่าค่าความสูงที่ 0.6-0.7 ไม่สามารถขึ้นรูปทรงชิ้นงานได้และค่าความสูงตั้งแต่ 0.9-1.5 สามารถขึ้นรูปทรงชิ้นงานได้แต่ชิ้นงานเสียรูป โดยค่า ใช้ในการขึ้นรูปที่เหมาะสม คือ 0.80 มิลลิเมตร เนื่องจากรอยต่อระหว่างชั้นที่เรียบและมีผิวที่สม่ำเสมอและสามารถขึ้นรูปชิ้นงานได้แบบต่อเนื่อง ดังรูปที่ 12



รูปที่ 12 : การทดสอบระยะห่างระหว่างชั้นในการขึ้นรูปชิ้นงาน

5.2) ผลทดสอบขึ้นรูปผลิตภัณฑ์เซรามิก

หลังจากได้ออกแบบและพัฒนาเครื่องสร้างต้นแบบรวดเร็วที่ใช้ในการขึ้นรูปผลิตภัณฑ์เซรามิกและหาค่าตัวแปรที่ส่งผลในการขึ้นรูป จากนั้นคณะผู้วิจัยได้ทำการทดลองขึ้นรูปชิ้นงานจำนวน 3 รูปแบบคือ แบบวงกลม แบบสี่เหลี่ยมและแบบรูปทรงอิสระโดยใช้ดินสำเร็จรูปของบริษัทคอมพาวด์เคลย์ ชนิด Compound PBB มีความชื้นในช่วง 40-45 เปอร์เซ็นต์และมีขนาดเส้นผ่าน-

ศูนย์กลางของรูตัดเท่ากับ 2 มม. ใช้อัตราป้อนของชุดหัวฉีดเท่ากับ 5 มม./นาที่ ความเร็วในการเคลื่อนที่ของแกน X Y Z เท่ากับ 60 มม./นาที่ และค่าความสูงที่ใช้ในการขึ้นรูป 0.80 มม. ซึ่งผลการทดสอบขึ้นรูปชิ้นงาน 3 รูปแบบและทำซ้ำจำนวน 10 ครั้ง พบว่าสามารถขึ้นรูปได้ ซึ่งการทดสอบขึ้นรูปชิ้นงาน จำนวน 3 รูปแบบ ดังรูปที่ 13



แบบที่ 1 ผลการขึ้นรูปชิ้นงานแบบรูปทรงกลม



แบบที่ 2 ผลการขึ้นรูปแบบรูปทรงสี่เหลี่ยม



แบบที่ 3 ผลการขึ้นรูปชิ้นงานแบบรูปทรงอิสระ

รูปที่ 13 : ผลทดสอบขึ้นรูปต้นแบบผลิตภัณฑ์เซรามิก

ผลการนำชิ้นงานที่ได้จากการขึ้นรูปชิ้นงานทั้ง 3 แบบ ได้แก่ 1) แบบรูปทรงกลม 2) แบบรูปทรงสี่เหลี่ยม 3) แบบรูปทรงอิสระ นำไปวัดค่าความคลาดเคลื่อนโดยใช้เวอร์เนียคาร์ลิปเปอร์ ได้ผลการวัดดังตารางที่ 2

ตารางที่ 2 : การวัดขนาดของชิ้นงานที่ได้จากการขึ้นรูป

ชิ้นงาน	การวัดขนาดชิ้นงาน (มม.)						เฉลี่ยความกว้าง
	ความกว้าง		ความยาว				
1	80	79.8	1	80	79.8	1	80
2	80	80.2	2	80	80.2	2	80
3	80	79.8	3	80	79.8	3	80

จากตารางที่ 2 นำชิ้นงานที่ได้จากการขึ้นรูป ได้แก่ ชิ้นงานที่ 1 รูปทรงกลม มีขนาดเส้นผ่านศูนย์กลาง 80 มม. ความสูง 100 มม. ชิ้นงานที่ 2 รูปทรงสี่เหลี่ยม มีขนาดความกว้าง 80 มม. ความยาว 80 มม.และความสูง 100 มม. ชิ้นงานที่ 3 รูปทรงอิสระ มีขนาดความกว้าง 80 มม. ความยาว 80 มม.และความสูง 100 มม. ไปวัดค่าความคลาดเคลื่อน จำนวนชิ้นงาน 10 ชิ้น วัดค่าขึ้นละ 3 จุด จากนั้นนำค่าที่ได้มาหาค่าเฉลี่ย พบว่าผลการวัดขนาดของชิ้นงานที่ได้จากการขึ้นรูปทั้ง 3 แบบเปรียบเทียบกับแบบ

ชิ้นงาน มีความคลาดเคลื่อนได้ไม่เกินค่าบวกและค่าลบเฉลี่ยเท่ากับ 0.2 มิลลิเมตร

5.3) ผลการทดสอบเผาผลิตภัณฑ์เซรามิก

หลังจากนำผลิตภัณฑ์ที่ขึ้นรูปมาทดสอบเผาด้วยเตาเผาไฟฟ้าเพื่อทดสอบความสมบูรณ์ของผลิตภัณฑ์เซรามิกที่ได้จากการขึ้นรูป ผลการทดสอบพบว่าผลิตภัณฑ์ที่ได้จากการขึ้นรูปโดยใช้เทคโนโลยีการสร้างต้นแบบรวดเร็ว หลังจากการเผามีความสมบูรณ์ไม่มีรอยแตกร้าวและไม่มีความเสียหายของชิ้นงาน ดังรูปที่ 14



รูปที่ 14 : ผลการทดสอบเผาชิ้นรูปผลิตภัณฑ์เซรามิก

6) สรุปและอภิปรายผล

ผลการวิเคราะห์การขึ้นรูปผลิตภัณฑ์เซรามิก ทั้ง 3 รูปคือ แบบวงกลม แบบสี่เหลี่ยม แบบรูปทรงอิสระ วัตถุดิบที่ใช้คือดิน สำเร็จรูปของบริษัทคอมพาวด์เคลย์ ชนิด Compound PBB ที่มีความชื้นในช่วง 40-45 เปอร์เซ็นต์ โดยใช้ขนาดเส้นผ่านศูนย์กลางของรูฉีดยาเท่ากับ 2 มิลลิเมตร โดยค่าพารามิเตอร์ที่เหมาะสมคือ อัตราป้อนของชุดหัวฉีดเท่ากับ 5 มิลลิเมตรต่อนาที ความเร็วการเคลื่อนที่ เท่ากับ 60 มิลลิเมตรต่อนาที ระยะห่างระหว่างชั้นในการขึ้นรูปขึ้นงาน เท่ากับ 0.80 มิลลิเมตร ผลการทดสอบขึ้นรูปขึ้นงาน 3 รูปแบบ โดยทำซ้ำเป็นจำนวน 10 ครั้ง พบว่า สามารถขึ้นรูปขึ้นงานได้สะดวกและรวดเร็ว ผลิตภัณฑ์ที่ขึ้นรูปมีความสมบูรณ์ นำชิ้นงานที่ได้จากการขึ้นรูปมาวัดค่าชิ้นงานละ 3 จุดเปรียบเทียบกับแบบขึ้นงานและหาค่าเฉลี่ย พบว่ามีความคลาดเคลื่อนเฉลี่ยค่าบวกและค่าลบไม่เกิน 0.2 มิลลิเมตร รวมถึงผลิตภัณฑ์ที่ได้หลังจากการเผาไม่เกิดความเสียหาย สำหรับการพัฒนาเทคโนโลยีการสร้างต้นแบบรวดเร็วที่พัฒนา สามารถนำไปประยุกต์ใช้กับผู้ประกอบการ ด้านเซรามิก ทำให้ลดต้นทุนทางด้านการพัฒนาผลิตภัณฑ์ ลดเวลาในการพัฒนาผลิตภัณฑ์และเครื่องจักรจากต่างประเทศ ตลอดจนนำไปประยุกต์ใช้เป็นเครื่องมือเพื่อพัฒนาต้นแบบผลิตภัณฑ์ของกลุ่มวิสาหกิจชุมชน เครื่องปั้นดินเผา และสถานศึกษาที่มีการเรียนการสอนในสาขาเทคโนโลยีเซรามิก ซึ่งสอดคล้องกับงานวิจัยของ P. Pitayachaval and A. Thongrak [9] เรื่องการศึกษาความคลาดเอียงของชิ้นงานที่สามารถขึ้นรูปจากดินเหนียวด้วยเทคโนโลยีการสร้างต้นแบบรวดเร็วแบบฉีดขึ้นรูป และบทความของ S. Otarawanna [11] เรื่องการนำเทคโนโลยีการพิมพ์สามมิติมาใช้ในอุตสาหกรรมการผลิต ที่กล่าวว่าการนำเทคโนโลยีการพิมพ์สามมิติเข้ามาช่วยในงานอุตสาหกรรมทำให้สามารถสร้างวัตถุที่มีรูปร่างซับซ้อน รวมถึงช่วยลดค่าใช้จ่ายในการออกแบบและผลิตต้นแบบผลิตภัณฑ์

กิตติกรรมประกาศ

คณะวิจัยขอขอบพระคุณสำนักงานคณะกรรมการส่งเสริมวิทยาศาสตร์ วิจัยและนวัตกรรม (สกสว.) ผู้ให้ทุนวิจัย สาขาเทคโนโลยีอุตสาหกรรมการผลิตและสาขาเทคโนโลยีเซรามิก คณะเทคโนโลยีอุตสาหกรรม ที่ให้สถานที่ อุปกรณ์ เครื่องมือที่ใช้ในการค้นคว้า วิจัย ทดลอง อีกทั้งสถาบันวิจัยพัฒนามหาวิทยาลัย

ราชภัฏพระนคร รวมถึงผู้ที่มีส่วนเกี่ยวข้องช่วยให้งานวิจัยนี้สำเร็จ ลุล่วงไปด้วยดี

REFERENCES

- [1] S. Inthaput, *Competitiveness of Thai ceramics industry*. Bangkok, Thailand: Department of Export Promotion, (in Thai), 2003. Accessed: Feb. 16, 2022. [Online]. Available: https://www.ditp.go.th/contents_attach/78351/78351.pdf
- [2] N. Travitzky *et al.*, "Additive manufacturing of ceramic-base materials," *Adv. Eng. Mater.*, vol. 16, no. 6, pp. 729–745, 2014.
- [3] J. Garden, "Additive manufacturing technologies: state of the art and trends," *Int. J. Prod. Res.*, vol. 54, no. 10, pp. 3118–3132, 2016.
- [4] S. B. M. Patzelt, B. C. Spies, and R. J. Kohal, "CAD/CAM-fabricated implant-supported restorations: a systematic review," *Clin. Oral Implants Res.*, vol. 26, no. S11, pp. 77–85, 2015.
- [5] A. Christ, R. Heister, and R. Anderl, "Reverse engineering for the utilization of product model data for CAX workflows in dental technology," in *Proc. 20th Eur. Concurrent Eng. Conf. - 10th Future Bus. Technol. Conf.*, Bruges, Belgium, Apr. 2014, pp. 47–54.
- [6] J.-Y. Lee, J. An, and C. K. Chua, "Fundamentals and applications of 3D printing for novel materials," *Appl. Mater. Today*, vol. 7, pp. 120–133, Jun. 2017.
- [7] Q. Liu, M. C. Leu, and S. M. Schmitt, "Rapid prototyping in dentistry: technology and application," *Int. J. Adv. Manuf. Technol.*, vol. 29, pp. 317–335, Jun. 2006.
- [8] H. Shao, D. Zhao, T. Lin, J. He, and J. Wu, "3D gel-printing of zirconia ceramic parts," *Ceram. Int.*, vol. 43, no. 16, pp. 13938–13942, Nov. 2017.
- [9] P. Pitayachaval and A. Thongrak, "A study of slope edge of technology," in *Proc. 38th Industrial Engineering Network*, Chon Buri, Thailand, 2020, pp. 255–259.
- [10] F. Yang, M. Zhang, B. Bhandari, and Y. Liu, "Investigation on lemon juice gel as food material for 3D printing and optimization of printing parameters," *LWT - Food Sci. Technol.*, vol. 87, pp. 67–76, Jan. 2018.
- [11] S. Otarawanna, "The use of 3D printing technology in manufacturing industry," (in Thai), *J. Mater. Technol.*, vol. 85, pp. 24–28, 2017. [Online]. Available: https://www2.mtec.or.th/th/e-magazine/admin/upload/303_24.pdf

Sightseeing Guidance System to Maximize Satisfaction Using Real-Time Spot Information

Hirotooshi Honma^{1*} Yuya Sato² Yoko Nakajima³

^{1*,3}*Department of Creative Engineering, National Institute of Technology, Kushiro College, Japan*

²*Advanced Course of Electronic and Information Systems Engineering, National Institute of Technology,
Kushiro College, Japan*

*Corresponding Author. E-mail address: honma@kushiro-ct.ac.jp

Received: 24 December 2021; Revised: 6 February 2022; Accepted: 1 March 2022

Published online: 27 June 2022

Abstract

This study proposes a personalized sightseeing planning system that optimizes travel routes to maximize tourist satisfaction considering cost and time constraints. The proposed mathematical model considers the places the tourist wants to visit, cost, and time available and recommends the optimal number of places that can be visited and the shortest routes to these places. The proposed system could successfully suggest local tourist spots that can be visited in the given time and budget. We believe that our study makes a significant contribution to the literature because travelers at present have to rely on information available from websites, guidebooks, social networking sites, or from family and friends to gather information of places they plan to visit. Such information may be brief or need not be up-to-date as real-time factors like weather, seasons, temperature, time of day, and crowding or recent attractions added may not be available. Further the model can be easily adopted by tourism industry worldwide, while the tourists receive reliable and accurate travel advise to enhance the travelling experience.

Keywords: Sightseeing guidance system, Mathematical optimization problem, Operations research

I. INTRODUCTION

Recent developments in transportation networks and modes such as railways and airlines have made it easy to travel worldwide. A reliable and accurate source of information can enhance the experience and satisfaction levels of tourists. While websites, guidebooks, and social networking services may briefly introduce individual spots, their information need not be up-to-date.

In recent years, it has been observed that an increasing number of tourists with similar preferences plan their trips in small groups. The purpose of travel (trip type) can vary between individuals and groups and include nature tourism, outdoor experiences, visiting theme parks, historical and cultural sightseeing, sampling the local cuisines, city sightseeing, relaxing in hot springs, and shopping. However, external factors can affect satisfaction even if a trip is planned and implemented according to personal preferences. For example, in nature tourism, satisfaction depends on factors such as season, weather, temperature, time of day, and crowding. Similarly, when the purpose of a trip is to experience gourmet food, tourists' satisfaction level will be low if the restaurant is closed, the menu is not in season, or the prices are high. Therefore, it is necessary to have a source that provides the latest information on ever-changing sightseeing spots (including facilities and stores) in real-time to maximize satisfaction. Tourists also have various constraints, such as time and cost, within which they expect to maximize their traveling experiences [1]–[3].

Thus far, much research has been conducted on the development of travel guidance systems aimed at optimizing costs and improving satisfaction: In Reference [4], Tsuchiya discusses the information management model using crawling/analyzing technology to retrieve information diffused on the internet and proposes a local information platform that

predominantly collects sightseeing information in the Suwa area of Nagano Prefecture. In Reference [5], Hasuike proposes versatile and interactive route planning for sightseeing under various conditions considering the constraints of required traveling times and the total satisfaction of sightseeing activities, which are time-dependent. In Reference [6], Kourouthanassis presents a mobile augmented reality (MAR) travel guide, which supports personalized recommendations. They reported the development process and devised a theoretical model that explores the adoption of MAR (mobile augmented reality) applications based on the impact of tourists' emotions. Nevertheless, the authors of this study were unable to find research focused on a sightseeing guidance system that uses real-time spot information (weather, temperature, congestion, satisfaction, etc.).

Therefore, this study proposes a sightseeing plan system that optimizes travel routes to maximize tourist satisfaction. Our proposed system has the following functions:

- Present sightseeing routes in line with tourists' preferences
- Present sightseeing plans that maximize tourists' satisfaction within their time and cost constraints
- Present alternate plans in real-time in response to various conditions such as worsening weather, suspension of transport networks, and change in plans due to urgent business

The system takes desired trip type, acceptable time (expected departure and arrival times), and acceptable cost (amount of money they are willing to spend at each tourist spot) as input and presents a sightseeing plan that maximizes user satisfaction within the given constraints. In the event of unforeseen circumstances, such as worsening weather, travel delays, and closure of tourist spot facilities, the system immediately reorganizes the routes in unforeseen circumstances and

suggests a new optimal plan considering the above factors.

The system immediately reorganizes the routes allowing tourists to enjoy vacations even in an unfamiliar place and serves as a tool to support the tourism industry.

II. SYSTEM SPECIFICATIONS

For realizing this system, it is essential to obtain real-time information such as weather, temperature, traffic situation, and congestion at the tourist spot; this study assumes that in the near future, all tourist spots will have sensors to acquire such information and communication networks to disseminate it.

This study used the Doto district in Eastern Hokkaido, Japan, to test the proposed system. Hokkaido is one of the four major islands that constitute the Japanese archipelago and is located in the northern part of Japan (Fig 1). In the "Prefecture Attractiveness Ranking" by the Brand Research Institute [7], it has been selected as number 1 for 13 consecutive years. It ranks first in terms

of popularity of tourism and products, and third in terms of degree of satisfaction with living. Furthermore, it is highly evaluated for motivation.

Doto is in the eastern region of Hokkaido (Areas F, G, and H shown in Figure 2). It is blessed with abundant nature and delicious food. Doto houses world-renowned sites with breathtaking scenery and many attractive tourist spots such as Shiretoko Peninsula and Kushiro Marsh. With two national parks and a World Natural Heritage Site, it is one of the most popular areas in Japan and attracts tourists year-round. In addition, it has abundant scenic beauty year-round, and tourists can enjoy delicious food, hot springs, and the vastness of nature.

However, because it has many famous tourist spots and unexplored locales across its vast area of 31,000 km², planning a trip to Doto can be difficult for beginners; therefore, it was considered a suitable study target. To verify the system's accuracy, we added 100 fictional spots in addition to the existing ones.



Figure 1: The map of Japan




Figure 2: The map of Hokkaido (Doto areas F, G, and H)

Below are some of the popular tourist spots in Doto.




Figure 3: Popular tourist spots in Doto

A. System Overview

Based on the user input information, such as time limit, hobbies, and preferences, and real-time information, such as date and time, weather, and congestion, the route that maximizes the total satisfaction is derived for each tourist spot using a mathematical optimization method. The following is the operation flow of this system.

1. Input user's travel preferences (restrictions and likes)
2. Generate satisfaction and map data based on input data
3. Derive route with maximum satisfaction using a mathematical model
4. Check the integrity of the derived route
5. Output proposed sightseeing route

The following subsections describe the types and structures of the data used and the specific operation of the system.

B. Data Structure

This system requires basic information on tourist spots and map data connecting tourist spots.

Basic information of tourist spots includes the name of the spot, area to which the spot belongs, opening/closing time, gourmet information, average staying time, cost per person, and satisfaction data. Satisfaction data for each tourist spot consists of a base value (attractiveness) that differs across seasons and an attractiveness adjustment coefficient that considers

external factors such as weather, congestion, and user preferences. The attractiveness adjustment coefficient varies significantly depending on the characteristics of

the tourist spot. Table 1 shows an example of the attractiveness of a tourist resort in summer and the attractiveness adjustment coefficient.

Table 1: Example of attractiveness

Tourist spot	Attractiveness	Weather				Purpose of travel				
		Sunny	Cloudy	Rainy	Snowy	Nature	Food	Culture	Shopping	Activity
The Lake Mashu	1.8	2	1.8	1.2	0.8	2	0.7	1	1	0.8
Washo Market	1.4	2	2	2	2	0.1	2	1.2	2	0.1
Ainu village	1.4	2	1.8	1.4	1.6	1	1.2	2	0.3	1.4

Here, the basic attractiveness of each tourist spot in Table 1 was assigned according to the evaluation values of various information magazines that are tourist guides and as per assessments of tourist sites.

The map data are represented by a graph model such that each vertex and edge correspond to each tourist spot, and the road connecting them, respectively. The travel time between tourist spots was weighted on each edge of the map data. The map data consisted of a two-dimensional array data structure.

The two-dimensional array representing an example map in Figure 4 is shown below.




Figure 4: Example of a map data

C. Data Entry

To use this system, the user enters the information by following the steps below:

1. Departure and final arrival points
2. Departure and arrival time
3. Number of tourists
4. Desired plan
5. Desired tourist spot
6. Desired tourist area

The system calculates the time that can be spent sightseeing based on the departure and arrival times. The desired plan lets tourists select all the wishes from the five categories of "nature," "food," "culture," "shopping," and "activity." After Step 4, the systems' users will be presented with a list of popular and representative tourist spots. They can choose any number of places. If the number of tourist spots selected is too large to make a realistic plan, they will be prompted to re-enter their selections. Furthermore, if a small number of tourist spots are selected, the most popular ones are automatically recommended. The desired sightseeing area is specified if tourists want to visit a place far away from the departure point.

D. Determining Satisfaction

The system calculates the degree of satisfaction when visiting tourist spots based on the desired

locations entered by the user and their real-time information. The degree of satisfaction of each tourist spot is obtained by multiplying the attractiveness for each season by the attractiveness adjustment coefficients derived from the real-time tourist spot information. If real-time information shows that the tourist spot is very crowded, the calculated degree of satisfaction is halved. Thus, even if the attractiveness of several tourist spots is the same, their final satisfaction will differ significantly depending on the user's likes and real-time information.

E. Map Generation

The system creates a two-dimensional array graph data using the two-dimensional array map data and the duration of stay from the user information. The map data are updated by integrating the travel time between tourist spots and the stay time at each tourist spot on the map data. In this process, the stay time at the next tourist spot is added to the travel time information between the tourist spots assigned to the edges of the map.

III. OPTIMAL SOLUTION DERIVATION

After receiving basic data from the user and constructing the map data, the optimum solution is derived by solving the following mathematical optimization problem.

A. Mathematical Optimization

In mathematical optimization, a mathematical model comprising a set of mathematical equations is used to determine the most desirable (optimal) solution. A mathematical model consists of three elements: variables, objective functions, and constraints. The objective function is the mathematical equation that should be solved to find the optimal solution. The constraint condition defines the upper and lower limits of the values that the variables can

take. If we imagine these in a vector space, the constraint condition is the point that reaches the farthest in the direction of travel in the space surrounded by the wall.

B. Mathematical Model

The purpose of this study is to maximize traveler satisfaction, and this section describes the formulated mathematical model to achieve this. The mathematical model is expressed using PuLP, which is a module for mathematical optimization problems in Python. For the optimum solution derivation, the CBC solver in PuLP was used [8], [9]. The CBC solver can be applied only to linear optimization problems, in which the objective function and constraints are linear equations. Therefore, the problem of deriving the tourist route that maximizes the satisfaction level is essentially similar to the traveling salesman problem (the problem of finding the shortest path through all vertices). However, it differs from the traveling salesman problem in that the objective function is to maximize satisfaction, and it is not necessary to visit all the vertices.

Thus, this problem is formulated as follows.

$$\text{Maximize} \quad \sum_{i=0}^N \sum_{j=0}^N x_{ij} \times sf_{ij}$$

Here, N is the number of tourist spots, vertex number '1' is the departure point, and N is the final arrival point. When moving from tourist spot i to j , x_{ij} is 1; otherwise, it is 0. sf_{ij} is a two-dimensional array storing the attractiveness of tourist spot j . The inner product of x_{ij} and sf_{ij} are the goals to be maximized.

$$\sum_{j=1}^N x_{1j} = 1 \quad (1)$$

$$\sum_{i=1}^N x_{iN} = 1 \quad (2)$$

Equations 1 and 2 are conditions that set the number of movements from the departure point and

to the final arrival point to exactly one, respectively. Thus, the departure and final arrival points are included in the route.

$$x_{i1} = 0, \quad i = 2, 3, \dots, N-1 \quad (3)$$

$$x_{Nj} = 0, \quad j = 2, 3, \dots, N-1 \quad (4)$$

Equations 3 and 4 satisfies the constraints that travelers do not move to the place of departure and from their final arrival point, respectively.

$$\sum_{i=0}^N \sum_{j=0}^N x_{ij} \times cs_{ij} \leq C \quad (5)$$

$$\sum_{i=0}^N \sum_{j=0}^N x_{ij} \times ts_{ij} \leq T \quad (6)$$

Equation 5 ensures that the total cost of visiting tourist spots does not exceed the upper limit set by the user. Here, cs_{ij} is the sum of the cost of traveling from tourist spot i to j and indicates the cost of visiting tourist spot j .

Equation 6 indicates that the total time required for sightseeing according to the schedule is within the available time set by the user.

$$\sum_{i=1}^N x_{if} = 1, \quad f \in \{2, 3, \dots, N-1\} \quad (7)$$

Equation 7 satisfies the constraint that the user visits the desired tourist spot f .

$$\sum_{j=1}^N x_{ij} = \sum_{j=1}^N x_{ji}, \quad i = 2, 3, \dots, N-1 \quad (8)$$

Equation 8 satisfies the constraint that the number of movements to and from the tourist spot i are equal.

$$q_i - q_j + 1 \leq (N-1)(1 - x_{ij}) \quad (9)$$

Equation 9 satisfies the Miller-Tucker-Zemlin (MTZ) formulation constraint [10]. Here, q_i denotes the order of visiting the tourist spot i ($1 \leq i \leq N$) desired by the user. This is often used in the traveling salesman problem to prevent the selection of routes that include loops [11].

Unlike the traveling salesman problem, the optimal route found in this study does not require visiting all vertices. Therefore, the following constraint is further added.

$$\sum_{i=0}^N \sum_{j=0}^N x_{ij} = q_N - 1 \quad (10)$$

Equation 10 satisfies the constraint that the number of movements between tourist spots is one less than the number of tourist spots that the user intends to visit.

IV. SYSTEM OPERATION EXPERIMENT

This section verifies the performance of the proposed system and the accuracy of the derived solution. In this experiment, 100 tourist spots were assumed in the eastern Hokkaido area, and attractiveness was set for each tourist spot. The map data were created using Google Directions API [8] and travel time between tourist spots acquired.

The input data used in this experiment are presented in Table 2. In this experiment, it was assumed that congestion did not occur in any case.

The output results obtained for the three input cases are listed in Tables 3, 4, and 5.

Table 6 shows the satisfaction and calculation time of each output result. The calculation time may be very long, depending on the input. Therefore, we verified the accuracy of the approximate solution obtained when processing was interrupted for a certain period. We compared the satisfaction of the approximate and optimum solutions obtained when the calculation time was cut off at 10, 20, and 30 s for the processing of Case 1 [12].

The results of the experiment are presented in Table 7. The results show that the tourist route obtained by limiting the processing time had the same degree of satisfaction as the optimum route.

Table 2: Input items in the operation test

Input	Case 1	Case 2	Case 3
Departure point	Kushiro Station	Kushiro Station	Shibecha City
Arrival point	Ainu village	Meiji Park (Nemuro)	Shiretoko Five Lakes
Number of people	1	4	2
Budget	5,000 yen	10,000 yen	10,000 yen
Purpose of travel	Nature, Activity	Nature, Food	Food, Activity, Culture
Departure time	9:00	10:00	10:00
Arrival time	16:00	14:00	15:00
Weather	Sunny	Sunny	Cloudy
Desired tourist spot	None	None	Shibetsu Salmon Museum

Table 3: Output for case 1

Arrival time	Departure time	Tourist spot
-	9:00	Kushiro Station
9:56	10:56	Kottaro Marsh Viewpoints
11:20	11:30	Tancho Sanctuary
11:48	11:58	Tsurumidai Plain
12:29	13:02	Japanese Crane Reserve
13:15	14:15	Akan International Crane Center
13:48	13:58	Yuzuru Station
14:50	15:50	Akan Bokke
15:54	-	Ainu village

Table 4: Output for case 2

Arrival time	Departure time	Tourist spot
-	10:00	Kushiro Station
10:38	10:48	Kottaro Marsh Viewpoints
10:52	11:12	Tancho Sanctuary
12:25	12:45	Tsurumidai Plain
13:14	13:14	Japanese Crane Reserve
13:56	-	Akan International Crane Center

Table 5: Output for case 3

Arrival time	Departure time	Tourist spot
-	10:00	Shibecha City
10:54	11:19	Shibetsu Salmon Museum
11:26	11:56	Shibetsu Local Museum
12:43	12:43	Road to heaven (via)
13:16	13:26	Oronko Rock
13:36	13:56	Waterfall of Oshinkoshin
14:09	14:24	Furepe Falls
14:26	14:46	Shiretoko Nature Center
14:58	-	Shiretoko Five Lakes

Table 6: Satisfaction and processing time

Case	Satisfaction	Processing time [s]
Case 1	33.76	561.2
Case 2	19.86	17.1
Case 3	30.56	18.2

Table 7: Satisfaction with optimal and approximate solutions

Processing time [s]	Satisfaction
561.2	33.76 (Optimal)
10.0	31.86
20.0	32.96
30.0	32.70

V. CONCLUSION

We confirmed that the proposed system could recommend optimal sightseeing routes using real-time information from tourist spots. However, some challenges need to be addressed before the system can be operational.

First, considerable computational time was needed even when the tourist spot was not far from the departure point, which can be problematic when tourists face sudden problems. Though it can be resolved to some extent through approximate solutions, it is necessary to reduce the computation time to improve real-time practical applications.

The second challenge concerns improving the constraints involving meals. We expect the improved system can propose a plan that allows users to arrive at their preferred eatery at the desired time.

Finally, the model should be further developed to allow real-time information from actual sensors. It is necessary to address these challenges to achieve the final goal of operating this system at actual tourist spots.

ACKNOWLEDGEMENT

We express many thanks to anonymous referees for their valuable advices on the theory of our attacks and their helpful editorial comments. This work was partially supported by JSPS KAKENHI Grant Number

20K11093 and 19K11834, and Cooperative Education/Research Project between Toyohashi University of Technology and National Institute of Technology.

REFERENCES

- [1] Y. Matsuda, "An optimal routing problem for sightseeing and its solution," *IEEJ Trans. Electron. Inf. Syst.*, vol. 124, no. 7, pp. 1507–1514, 2004.
- [2] M. Muroya, "The attractiveness of sightseeing areas in japan: An evaluation model," *Transport Policy Studies' Rev.*, vol. 1, no. 1, pp. 014–024, 1998.
- [3] M. Fujimoto, "Tourism informatics: - smart tourism toward tourism informatics - : Gamified participatory sensing for a sightseeing," (in Japanese), *IPSI Magazine*, vol. 62, no. 11, pp. e18–e24, 2021, doi: 10.20729/00213186.
- [4] T. Tsuchiya, H. Hirose, T. Miyosawa, H. Sawano, T. Yamada, and K. Koyanagi, "Information management platform model for local sightseeing and disaster prevention information," *IFAC-PapersOnLine*, vol. 48, no. 1, pp. 667–668, 2015.
- [5] T. Hasuiki, H. Katagiri, H. Tsubaki, and H. Tsudaadd, "Interactive multi-objective route planning for sightseeing on time-expanded networks under various conditions," *Procedia Comput. Sci.*, vol. 22, pp. 221–230, 2013.
- [6] P. Kourouthanassis, "Tourists responses to mobile augmented reality travel guides: The role of emotions on adoption behavior," *Pervasive and Mobile Comput.*, vol. 18, pp. 71–87, 2015.
- [7] Brand Research Institute. "Prefecture Attractiveness Ranking (Regional Brand Survey 2021)." *NEWS.TIiki.jp*. <https://news.tiiki.jp/articles/4698> (accessed Mar. 23, 2022).
- [8] M. Bazargan, "A linear programming approach for aircraft boarding strategy," *Eur. J. Oper. Res.*, vol. 183, pp. 394–411, 2007.
- [9] T. Saito, "How to create an optimized model using a data analysis library," *Commun. Oper. Res. Soc. Japan*, vol. 63, no. 12, pp. 784–790, 2018.
- [10] H. Niitsuma, "Efficient constraints for tour recommendation," *Trans. IPS. Japan (Web)*, vol. 9, no. 2, pp. 34–45, 2016.
- [11] R. J. Wilson, *Introduction to Graph Theory*, 4th ed. London, U.K.: Pearson Education, 1996.
- [12] V. V. Vazirani, *Approximation Algorithms*. Heidelberg, Germany: Springer, 2001.

ตัวแบบการวิเคราะห์ความรู้สึกทางอารมณ์ สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์

พิศิษฐ์ บวรเลิศสุธี¹ วรภัทร ไพรเกรง^{2*}

^{1,2*}สาขาเทคโนโลยีสารสนเทศ วิทยาลัยนวัตกรรมการเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิตย์,
กรุงเทพมหานคร, ประเทศไทย

*ผู้ประพันธ์บรรณกิจ อีเมล : worapat.png@dpu.ac.th

รับต้นฉบับ : 1 พฤศจิกายน 2564; รับบทความฉบับแก้ไข : 21 มกราคม 2565; ตอบรับบทความ : 28 กุมภาพันธ์ 2565
เผยแพร่ออนไลน์ : 27 มิถุนายน 2565

บทคัดย่อ

การตัดสินใจซื้อสินค้าและบริการออนไลน์ ผู้บริโภคส่วนใหญ่จะทำการสืบค้นข้อมูลเกี่ยวกับสินค้าและบริการรวมทั้งพิจารณาจากการแสดงความคิดเห็น (Comments) และบทวิจารณ์ (Reviews) จากผู้ที่เคยซื้อสินค้าไปแล้ว เพื่อเป็นแนวทางในการตัดสินใจเลือกซื้อ อย่างไรก็ตาม ข้อมูลการแสดงความคิดเห็นและบทวิจารณ์ในปัจจุบันนี้มีปริมาณมหาศาลและเกิดขึ้นใหม่อยู่ตลอดเวลา ซึ่งทำให้ผู้บริโภคต้องเสียเวลาในการวิเคราะห์ข้อดีข้อเสียของผลิตภัณฑ์เหล่านี้ด้วยตนเองเพื่อใช้ในการตัดสินใจเลือกซื้อสินค้าและบริการ ซึ่งถ้าหากมีการสร้างตัวแบบเพื่อแจ้งให้ผู้ใช้งานทราบถึงการวิเคราะห์ความรู้สึกได้จะช่วยให้ผู้ซื้อตัดสินใจได้รวดเร็วมากยิ่งขึ้น ดังนั้นงานวิจัยนี้มีวัตถุประสงค์เพื่อนำเสนอ ตัวแบบการวิเคราะห์ความรู้สึกทางอารมณ์สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์โดยใช้เทคนิคส่วนการเรียนรู้ของเครื่อง (Machine Learning) ร่วมกับเทคนิคการตัดคำ (Word Tokenization) และการสร้างคลังคำศัพท์ (Bag of Words) จากนั้นนำเข้ากระบวนการจำแนกประเภทผลการวิเคราะห์ 4 เทคนิค ได้แก่ LSTM, SGD, Logistic Regression และ Support Vector Machines ในการสร้างตัวแบบมีกระบวนการทดลอง 5 ขั้นตอน ได้แก่ 1) การเตรียมข้อมูล 2) การตัดคำ 3) การฝึกอบรมข้อมูล 4) ขั้นตอนการแยกประเภท และ 5) การประเมินตัวแบบ ทำการทดลองโดยใช้ข้อมูลตัวอย่างการแสดงความคิดเห็นต่อสินค้าและบริการออนไลน์ภาษาไทย จำนวน 12,900 ข้อมูล ใช้เป็นข้อมูลในการสร้างตัวแบบ เพื่อช่วยให้ผู้บริโภคใช้ในการตัดสินใจซื้อสินค้าและบริการ และช่วยให้ผู้ประกอบการมีข้อมูลสำหรับการพัฒนาสินค้าและบริการต่อไปในอนาคต จากผลการทดลองสร้างตัวแบบการวิเคราะห์ระดับความรู้สึกทางอารมณ์ 3 ระดับ คือ ความรู้สึกเชิงบวก (Positive) เป็นกลาง (Neutral) และเชิงลบ (Negative) โดยแต่ละตัวแบบให้ค่าความถูกต้องในการทำนายผล ดังนี้ LSTM 81.27%, Logistic Regression 69%, SGD 66%, และ Support Vector Machines 65% สรุปได้ว่าการสร้างตัวแบบโดยใช้เทคนิคการจำแนกประเภทแบบ LSTM ให้คะแนนความถูกต้องสูงที่สุดในการทำนายผลด้วยการเรียนรู้เชิงลึก จึงเหมาะสมแก่การนำไปใช้สร้างตัวแบบในการวิเคราะห์ระดับความรู้สึกกับข้อความที่เป็นภาษาไทยโดยพิจารณาจากค่า F1

คำสำคัญ : การวิเคราะห์อารมณ์ความรู้สึก การเรียนรู้ของเครื่อง การซื้อสินค้าออนไลน์ การตัดคำ

The Model of Sentiment Analysis for Classifying the Online Shopping Reviews

Pisit Bowornlertsutee¹ Worapat Paireekreng^{2*}

^{1,2*}*Information Technology, College of Innovative Technology and Engineering, Dhurakij Pundit University,
Bangkok, Thailand*

*Corresponding Author. E-mail Address: worapat.png@dpu.ac.th

Received: 1 November 2021; Revised: 21 January 2022; Accepted: 28 February 2022

Published online: 27 June 2022

Abstract

Nowadays, users can make a decision to order online goods and services from searching information related to goods and services. These may be based on opinions and reviews from previous purchasers as a guideline for purchasing decisions. Moreover, the current opinions information and reviews are enormous and increased all the time. consumers have to spend time for information analytics. Therefore, the model of sentiment analysis regarding goods and services reviews is needed. This research aims to build a model of Sentiment analysis with 3-level of emotion. they are positive neutral and negative, regarding previous user's reviews and opinions towards online products and services. The techniques used in this research are Machine Learning including Word Segmentation and Bag of Words which compared four categories of sentiment analysis methods: LSTM, SGD, Logistic Regression and Support Vector Machines. There are 5 steps for model building as following: 1) Data Preparation Phase 2) Word Tokenization Phase 3) Training & Streaming Phase 4) Classification phase and 5) Model Evaluation Phase. The consumers' opinions were gathered the datasets from open data with number of 12,900 comments. The model can help consumers to make a decision for purchasing of goods and services, and help entrepreneurs gain the information. This is to improve products and services in the future. This proposed method can classify the opinions into 3 scales which are positive, neutral and negative opinions. In summary, the proposed sentiment analysis model can perform LSTM accuracy is at 81.27%, Logistic Regression accuracy is at 69%, SGD accuracy is at 66% and Support Vector Machines accuracy is at 65%. However, the LSTM shows better performance on the classification compared to other techniques with deep learning approach. It also found that the F1-score can be implemented for Thai text appropriately.

Keywords: Sentiment analysis, Machine learning, Online shopping, Word tokenization

1) บทนำ

ในปัจจุบันประเทศไทยถือเป็นแหล่งซื้อขายสินค้าออนไลน์ที่สำคัญแห่งหนึ่งของโลก สะท้อนได้จากปริมาณการครอบครองโทรศัพท์มือถือและการเข้าถึงอินเทอร์เน็ต ซึ่งมีแนวโน้มขยายตัวอย่างต่อเนื่อง แสดงถึงการตอบรับที่ดีในด้านการซื้อขายสินค้าออนไลน์ในประเทศไทย อีกทั้งยังมีเว็บไซต์ที่เปิดให้บริการในการซื้อขายสินค้าออนไลน์ชื่อดังอยู่เป็นจำนวนมาก เช่น LAZADA.COM SHOPEE.COM เป็นต้น [1] ในการตัดสินใจซื้อสินค้าและบริการผู้บริโภคส่วนใหญ่จะทำการสืบค้นข้อมูลเกี่ยวกับตัวสินค้าและบริการ เช่น การอ่านข้อมูลการแสดงความคิดเห็น และบทวิจารณ์จากผู้ที่เคยซื้อสินค้าไปแล้ว เป็นต้น เนื่องจากเว็บไซต์ที่เปิดให้บริการซื้อขายออนไลน์ส่วนใหญ่จะเปิดให้มีการแสดงความคิดเห็น (Opinion) ต่อตัวสินค้าและบริการดังกล่าว ทำให้ผู้ที่สนใจในผลิตภัณฑ์เข้าไปศึกษาเพื่อใช้เป็นแนวทางในการตัดสินใจเลือกซื้อผลิตภัณฑ์ ซึ่งการแสดงความคิดเห็นเป็นการแสดงถึงความรู้สึกทางอารมณ์ในรูปแบบข้อความที่มีต่อสินค้าและบริการ อีกทั้งข้อมูลการแสดงความคิดเห็นในปัจจุบันนั้นมีปริมาณมหาศาลและเกิดขึ้นใหม่อยู่ตลอดเวลา ซึ่งทำให้ผู้บริโภคต้องเสียเวลาในการวิเคราะห์ข้อมูลข้อดีข้อเสียของผลิตภัณฑ์เหล่านี้ [2] เพื่อใช้ในการตัดสินใจเลือกซื้อสินค้าและบริการ และเนื่องจากยังไม่มีตัวช่วยในการวิเคราะห์การแสดงความคิดเห็นต่อสินค้าและบริการแบบอัตโนมัติที่จะช่วยสรุปข้อดีข้อเสียเพื่อช่วยในการตัดสินใจในการเลือกซื้อสินค้าและบริการได้อย่างสะดวกและรวดเร็ว

การวิเคราะห์ความรู้สึก (Sentiment Analysis) เป็นการนำเอาเทคนิคการประมวลผลภาษาธรรมชาติ (Natural Language Processing : NLP) ที่สามารถใช้วิเคราะห์ความรู้สึกทั้งในระดับเอกสาร ระดับประโยค และในระดับคุณลักษณะของวัตถุ รวมถึงการใช้วิเคราะห์ความคิดเห็นของผู้บริโภคที่มีความรู้สึกต่อสินค้าและบริการต่าง ๆ รวมถึงการทำเหมืองความคิดเห็น (Opinion Mining) โดยมีวัตถุประสงค์ในการสกัดข้อความที่เป็นความคิดเห็นที่มีต่อสิ่งใดสิ่งหนึ่งออกมาจากข้อเท็จจริงเพื่อนำไปสกัดคุณลักษณะและส่วนประกอบของวัตถุที่แสดงความคิดเห็นออกมา เพื่อพิจารณาว่าความคิดเห็นนั้นแสดงความรู้สึกไปในเชิงบวก เชิงลบ หรือเป็นกลาง [3] และเทคนิคการทำเหมืองข้อมูล (Text mining) มาประยุกต์ใช้เพื่อมุ่งเน้นการวิเคราะห์และตรวจสอบความรู้สึก (Opinion) ได้อย่างอัตโนมัติ [4] รวมถึงการแทนค่าในความคิดเห็นให้อยู่ในรูปแบบ

โครงสร้าง เช่น การแทนด้วยถุงคำ (Bag of Words) และค่าความถี่ของคำที่เกิดขึ้น (TF-IDF) [2], [5] และเทคนิคการสกัดคำ (Word Extraction) ซึ่งเป็นกระบวนการของการทำเหมืองข้อความเพื่อใช้ในการวิเคราะห์คำออกจากเอกสาร ข่าวสาร ข้อความ และสารสนเทศต่าง ๆ ที่เป็นตัวอักษร โดยสามารถนำไปทำการแบ่งกลุ่ม (Clustering) จำแนกกลุ่ม และหาความสัมพันธ์ขั้นตอนการแบ่งกลุ่มโดยใช้เทคนิคต่าง ๆ เช่น 1) การตัดคำ (Word Segmentation) เป็นการแยกแต่ละคำจากเอกสารออกจากกัน โดยยังคงมีความหมายที่ถูกต้องสมบูรณ์อยู่ โดยการตัดคำนั้นใช้ฐานข้อมูลพจนานุกรมคำศัพท์ในการแบ่งคำออกมา ในการตัดคำภาษาไทยจะนิยมใช้อัลกอริทึมจาก PyThaiNLP ในการตัดคำภาษาไทยโดยเฉพาะ เช่น อัลกอริทึม NewMM Engine พัฒนาจากเทคนิคการแบ่งส่วนคำศัพท์ภาษาไทยด้วยพจนานุกรม (Dictionary-based) โดยใช้อัลกอริทึมการจับคู่สูงสุดและการจัดกลุ่มอักขระภาษาไทย อัลกอริทึม Longest Engine ซึ่งเป็นอัลกอริทึมพัฒนาจากเทคนิคการแยกคำภาษาไทยที่ยาวที่สุดที่จับคู่กับพจนานุกรม (Dictionary-based) และ อัลกอริทึม AttaCut Engine ซึ่งเป็นอัลกอริทึมที่สามารถตัดคำภาษาไทยได้อย่างรวดเร็วและแม่นยำ โดยใช้อัลกอริทึมการจัดกลุ่ม (Clustering) อักขระภาษาไทย (Rules purposed) [6], [7] 2) การกำจัดคำหยุด (Stop word) เป็นการตัดคำที่ไม่มีความหมายออกจากเอกสารโดยการกำจัดคำหยุดนั้นใช้ฐานข้อมูลคำศัพท์ที่เป็นคำที่ไม่มีความหมายในการนำมาประมวลผล [7], [8] เพื่อช่วยให้การจำแนกประเภท (Classification) มีความถูกต้องมากยิ่งขึ้น [9] ในส่วนของการวิเคราะห์ความรู้สึกและการประมวลผลในภาษาไทยยังมีความยุ่งยากมากกว่าภาษาอังกฤษ เพราะโครงสร้างประโยคและไวยากรณ์มีความซับซ้อน ไม่มีการแบ่งส่วน แบ่งคำ ประโยคติดกัน อักขระที่ไม่มีขอบเขตคำ และไม่มีโครงสร้างที่ชัดเจนทำให้เกิดความกำกวม [3], [10], [11] นอกจากนี้ยังมีการพัฒนาเฟรมเวิร์ค (Framework) ที่เรียกว่า S-Sense (Social Media Sensing) สำหรับวิเคราะห์ความรู้สึกบนโซเชียลมีเดียสำหรับภาษาไทย ตัวแบบจะเปรียบเทียบประสิทธิภาพระหว่างชุดคำศัพท์ที่แตกต่างกัน 2 ชุด คือ คำศัพท์ทั่วไปและคำใบ้ ซึ่งการรวมคำใบ้เข้ากับเวกเตอร์คุณลักษณะสำหรับการสร้างแบบจำลองการจำแนกประเภททำให้มีการปรับปรุงอย่างมีนัยสำคัญในแง่ของความถูกต้อง [12] และในปัจจุบันการใช้เทคนิคการเรียนรู้ด้วยเครื่อง (Machine Learning) จะเป็นที่

นิยมมากกว่า โดยจะอาศัยการสร้างชุดข้อมูลฝึกฝน (Training Set) และนำชุดข้อมูลทดสอบ (Test Set) [8], [13] เข้ากระบวนการจัดกลุ่มหรือจำแนกประเภท (Classification) ในส่วนของการเลือกใช้ตัวจำแนกประเภทที่มีความนิยมในการพัฒนา Sentiment Analysis ภาษาไทย ได้แก่ Logistic Regression, Random Forest, Support Vector Machine, Naive Bayes, K-Nearest Neighbors, และ decision tree เป็นต้น [8], [14], [15] และในการประเมินประสิทธิภาพของตัวแบบที่ได้โดยสรุปจาก Accuracy, Precision, Recall และ F1 Measure [3], [14] นอกจากนี้ การวิเคราะห์ข้อความความรู้สึกส่วนใหญ่จะเป็นการตัดสินเพียง 2 ระดับ คือ เชิงบวกและเชิงลบ อย่างไรก็ตาม จะมีความคิดเห็นที่เป็นกลาง ซึ่งถ้าหากถูกตัดสินเพียง 2 ระดับ อาจจะทำให้ข้อคิดเห็นโดยรวมเกิดอคติได้ ดังนั้น ถ้าหากมีการวิเคราะห์เป็น 3 ระดับ คือ มีระดับเป็นกลางเพิ่มเข้ามาจะทำให้หน้าหน้ของการตัดสินข้อความรู้สึกมีความถูกต้องมากขึ้น [6] อีกทั้งการตัดคำ (Word Segmentation) จะต้องเลือกโมดูล (Module) ที่เหมาะสม ถูกพัฒนาขึ้นเพื่อใช้งานกับภาษาไทยโดยเฉพาะทั้งนี้เพื่อให้การตัดคำถูกต้องและพร้อมใช้งานในการฝึกฝนข้อมูล


การศึกษาค้นคว้าครั้งนี้ผู้วิจัยมีแนวคิดที่จะสร้างตัวแบบการวิเคราะห์ความรู้สึกทางอารมณ์ สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์ (Sentiment Analysis Model) โดยใช้เทคนิคส่วนการเรียนรู้ของเครื่อง (Machine Learning) แบบมีผู้สอน (Supervised Learning) ร่วมกับเทคนิคการทำเหมืองข้อความ (Text Mining) เพื่อให้ตัวแบบสามารถแก้ไขปัญหาในการแบ่งแยกคำภาษาไทยและวิเคราะห์คำจากการแสดงความคิดเห็นได้อย่างมีประสิทธิภาพ นอกจากนั้นจะมีการใช้เทคนิคการจำแนกประเภทโดยมีการเปรียบเทียบผลการวิเคราะห์ 4 รูปแบบ ได้แก่ Long Short-Term Memory (LSTM), Stochastic Gradient Descent (SGD), Logistic Regression (LR) และ Support Vector Machines (SVM) โดยทำการทดลองวิเคราะห์ประโยคเนื้อหาที่เป็นภาษาไทย 3 ระดับ ได้แก่ ความรู้สึกเชิงบวก (Positive) เป็นกลาง (Neutral) และเชิงลบ (Negative) กับชุดข้อมูลจำนวน 12,900 ข้อมูล เพื่อหาตัวแบบที่ดีที่สุดที่สามารถใช้เป็นแนวทางในการพัฒนาตัวแบบการวิเคราะห์ระดับความรู้สึกทางอารมณ์สำหรับบทความแนะนำสินค้าออนไลน์ภาษาไทย ทั้งนี้เพื่อช่วยให้ผู้บริโภคสามารถตัดสินใจเลือกซื้อสินค้าและบริการได้อย่างรวดเร็ว

2) วัตถุประสงค์ของการวิจัย

1. เพื่อสร้างตัวแบบการวิเคราะห์ความรู้สึกทางอารมณ์สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์ภาษาไทย
2. เพื่อเปรียบเทียบประสิทธิภาพของเทคนิคการจำแนกประเภทที่เหมาะสมในการทำ Sentiment Analysis

3) วิธีดำเนินการวิจัย

ขั้นตอนการดำเนินการวิจัย และการออกแบบการทดลอง (Experimental Design) ประกอบด้วย 5 ขั้นตอน โดยแต่ละขั้นตอนใช้เครื่องมือการพัฒนาโปรแกรมภาษาไพทอน (Python) ร่วมกับโมดูล (Module) ต่าง ๆ แสดงดังรูปที่ 1



รูปที่ 1 : แสดงขั้นตอนการดำเนินงานวิจัย และการออกแบบการทดลอง 5 ขั้นตอน

จากรูปที่ 1 สามารถอธิบายขั้นตอนการดำเนินการวิจัย และการออกแบบการทดลองได้ดังต่อไปนี้

3.1) การเตรียมข้อมูล (Data Preparation)

การเก็บข้อมูลเก็บจากชุดข้อมูลที่ให้เข้าถึงสาธารณะจากเว็บไซต์ <https://pythainlp.github.io/> (Wisensight Sentiment Corpus) เข้าถึงเมื่อวันที่ 10 ธันวาคม 2564 จำนวน 12,900 ข้อมูล 257,834 คำ ซึ่งเป็นข้อมูลการแสดงความคิดเห็นต่อสินค้าและบริการภาษาไทยที่มีการติดป้ายกำกับ (Label) ความรู้สึก 3 ระดับ ได้แก่ ความรู้สึกเชิงบวก (Positive) เป็นกลาง (Neutral)

และเชิงลบ (Negative) โดยสามารถแสดงจำนวนข้อมูลแยกตามระดับความรู้สึกได้ดังตารางที่ 1

ตารางที่ 1 : แสดงจำนวนข้อมูลแยกตามระดับความรู้สึก

ความรู้สึก	จำนวนข้อมูล (Rows)
เชิงบวก	4,300
เป็นกลาง	13,105
เชิงลบ	6,140
รวม	23,545

จากตารางที่ 1 พบว่าชุดข้อมูลจะมีการติดป้ายกำกับความคิดเห็น 3 ระดับเรียบร้อยแล้ว จากชุดข้อมูลที่รวบรวมมามีขนาดข้อมูลที่เป็นประเภทของการแสดงความคิดเห็นในแต่ละประเภทไม่เท่ากัน โดยจะมีความคิดเห็นเป็นกลางมากที่สุด ส่วนความคิดเห็นเชิงบวกและเชิงลบมีจำนวนน้อยกว่า ดังนั้นจึงได้มีการปรับขนาดของชุดข้อมูลในแต่ละประเภทความคิดเห็นโดยการทำการสุ่มเลือกความคิดเห็นแบบเป็นระบบ โดยนับเป็นความคิดเห็นเป็นกลาง เชิงบวก และเชิงลบ ให้มีจำนวนเท่า ๆ กัน เพื่อนำไปจัดการการเรียนรู้ข้อมูลเพื่อสร้างตัวแบบ แสดงดังตารางที่ 2

ตารางที่ 2 : แสดงจำนวนข้อมูลที่จะนำไปสร้างตัวแบบ

ความรู้สึก	จำนวนข้อมูล (Rows)
เชิงบวก	4,300
เป็นกลาง	4,300
เชิงลบ	4,300
รวม	12,900

จากตารางที่ 2 จะมีการสุ่มเลือกข้อมูล (Dataset) สำหรับสร้างตัวแบบให้มีขนาดเท่ากันทั้ง 3 ระดับความรู้สึก โดยใช้วิธีการทำ Down sampling เป็นการลดขนาดข้อมูลที่มีจำนวนมาก ทั้งนี้เพื่อป้องกันการเกิดอคติในการสร้างตัวแบบในการวิเคราะห์ผล และสามารถแสดงตัวอย่างการแสดงความคิดเห็นแสดงแยกตามความรู้สึกได้ดังตารางที่ 3

ตารางที่ 3 : ตัวอย่างการแสดงความคิดเห็นแยกตามระดับความรู้สึก

การแสดงความคิดเห็น	ความรู้สึก
บอกเลยว่า Nissan Navara ตัวนี้เข้าใช้มากครับ	เชิงบวก
Nissan Note. ดาวน์เท่าไรคะ	เป็นกลาง
Nissan รถห่วยไม่ทนเลยขายไม่ดี	เชิงลบ

ในขั้นตอนต่อมาคือการนำชุดข้อมูลเข้าสู่กระบวนการทำความสะอาดข้อมูล (Data Cleaning) เพื่อแก้ไข ปรับแต่ง และตัดส่วนที่ไม่ต้องการออกจากชุดข้อมูล เช่น HTML Tag, URL หรือเครื่องหมายคำพูด (Punctuation) เป็นต้น และมีการตรวจสอบและแก้ไขคำที่สะกดผิดโดยใช้ PyThaiNLP Spellchecker เพื่อให้ข้อมูลมีคุณภาพ มีความถูกต้องและเหมาะสมที่จะนำไปใช้ในการสร้างตัวแบบ

3.2) การตัดคำ (Word Segmentation)

คือการแยกคำภาษาไทยที่เป็นประโยคยาว ๆ ออกมาเป็นแต่ละคำ เนื่องจากภาษานั้นไม่มีการใช้ตัวอักษรหรือสัญลักษณ์ที่นำมาใช้คั่นระหว่างคำและการเว้นวรรคเหมือนกับภาษาอังกฤษในการศึกษาวิจัยนี้ใช้กระบวนการประมวลผลภาษาธรรมชาติ (Natural language processing : NLP) หรือโมดูล PyThaiNLP โดยใช้ NewMM Engine พัฒนาจากเทคนิคการแบ่งส่วนคำศัพท์ภาษาไทยด้วยพจนานุกรม (Dictionary-based) โดยใช้อัลกอริทึมการจับคู่สูงสุดและการจัดกลุ่ม (Clustering) ถูกพัฒนาขึ้นเพื่อตัดคำภาษาไทยบนภาษา Python เพื่อหาความสัมพันธ์ระหว่าง "คำ" และ "เอกสาร" ที่มีอยู่ในรูปแบบของเวกเตอร์ (Vector) เพื่อให้คอมพิวเตอร์สามารถแปลผลได้ ทั้งนี้เพื่อให้รูปแบบของคำเป็นแบบมีโครงสร้างและสามารถทำการวิเคราะห์ระดับของคำได้ จากนั้นทำการลบ Stop words คือการตัดคำที่ไม่จำเป็นสำหรับการวิเคราะห์ออก ทั้งนี้เพื่อลดขนาดของข้อมูลที่ใช้ในการประมวลผล [2] และ Punctuation (เครื่องหมายวรรคตอน) ออกจากข้อความและเปลี่ยนข้อความให้มีช่องว่างระหว่างคำเพื่อให้ง่ายต่อการนำไปสร้าง Bag of Words (Bow) ตัวอย่างการตัดคำด้วย NewMM Engine แสดงดังตารางที่ 4


ตารางที่ 4 : ตัวอย่างการตัดคำ

ข้อความต้นฉบับ
บอกเลยว่า Nissan Navara ตัวนี้เข้าใช้มากครับ
ข้อความที่ผ่านการตัดคำโดยใช้ NewMM Engine
['บอก', 'เลย', 'ว่า', 'Nissan', 'Navara', 'ตัว', 'นี้', 'เข้า', 'ใช้', 'มาก', 'ครับ']

3.3) การฝึกอบรมข้อมูล (Training & Streaming)

ในขั้นตอนการสร้างตัวแบบสำหรับการเรียนรู้แบบมีผู้สอน (Supervised Learning) จะทำการแบ่งชุดข้อมูลออกเป็น 2 ชุด (Split Test) คือ ชุดข้อมูลฝึกฝน (Training Set) 10,320 ข้อมูล

หรือ 80% และชุดข้อมูลทดสอบ (Testing Set) 2,580 ข้อมูล หรือ 20% ซึ่งการสร้างแบบจำลองวิเคราะห์ความรู้สึกจากข้อความ จะมีการเพิ่มขั้นตอนการแปลงข้อมูลให้อยู่ในรูปแบบที่มีจำนวนของตัวแปรที่เท่ากัน โดยใช้เทคนิคการสร้างถุงคำ (Bag of Words) เพื่อให้ง่ายต่อการนำไปประมวลผล จากนั้นนำเข้ากระบวนการการเรียนรู้โดยอาศัยข้อมูลที่ป้อนเข้าไปเก็บไว้เป็นตัวอย่างเพื่อให้คอมพิวเตอร์ใช้ในการเปรียบเทียบกับข้อมูลใหม่ที่เข้ามาแล้วทำนายหรือจัดหมวดหมู่ที่มีความใกล้เคียงกันมากที่สุดให้อยู่ในกลุ่มเดียวกัน แสดงขั้นตอนการทำงานได้ดังรูปที่ 2



รูปที่ 2 : แสดงขั้นตอนการฝึกอบรมข้อมูล

3.4) ขั้นตอนการแยกประเภท (Classification)

คือกระบวนการสกัดความคิดเห็นจากการเรียนรู้ของเครื่อง (Machine Learning) แบบมีผู้สอน (Supervise Learning) โดยทดสอบกับชุดข้อมูล (Testing Set) 20% นำเข้ากระบวนการทำนายผล (Prediction) และแยกผลการวิเคราะห์ระดับความรู้สึก (Sentiment Analysis) โดยใช้เทคนิคการแยกประเภทผลการวิเคราะห์ 4 เทคนิค ได้แก่

3.4.1) Long Short-Term Memory (LSTM) คืออัลกอริทึมเรียนรู้เชิงลึก (Deep Learning) ที่ใช้เทคนิคบนพื้นฐานของโครงข่ายประสาทเทียมแบบเกิดซ้ำ (Neural Network) แบบหน่วยความจำระยะสั้น โดยมุ่งเน้นไปที่การเรียนรู้การเป็นตัวแทนที่ซ่อนอยู่ [10]

3.4.2) Stochastic Gradient Descent (SGD) คืออัลกอริทึมที่มีการปรับปรุง (Update) ค่าพารามิเตอร์ในทุก ๆ ชุดข้อมูลฝึกฝน ซึ่งเป็นอัลกอริทึมที่สามารถประมวลผลได้ค่อนข้างไว จะมีการปรับปรุงแค่ครั้งเดียวต่อการฝึกฝน 1 รอบ

3.4.3) Logistic Regression (LR) คืออัลกอริทึมที่ใช้เทคนิคการวิเคราะห์ความสัมพันธ์ของตัวแปร เพื่อทำนายโอกาสความน่าจะเป็น (Probability) ที่จะเกิดเหตุการณ์ที่น่าสนใจ [6], [16]

3.4.4.) Support Vector Machines (SVM) คืออัลกอริทึมใช้ในการวิเคราะห์ข้อมูลและจำแนกข้อมูลโดยอาศัยหลักการของการหาสมมติฐานของสมการเพื่อสร้างเส้นแบ่งแยกกลุ่มข้อมูลที่ถูกต้องเข้าสู่กระบวนการฝึกฝนให้ระบบเรียนรู้ โดยเน้นไปยังเส้นแบ่งแยกและกลุ่มข้อมูล [6]

3.5) การประเมินตัวแบบ (Model Evaluation)

เมื่อผ่านขั้นตอนการแยกประเภท (Classification Phase) เรียบร้อยแล้ว จะนำผลการทำนายเข้ากระบวนการประเมินประสิทธิภาพของตัวแบบโดยพิจารณาจาก ความถูกต้อง (Accuracy) ดังสมการที่ 1 ความแม่นยำ (Precision) ดังสมการที่ 2 ค่าความระลึก (Recall) ดังสมการที่ 3 และค่าเฉลี่ย (F1 Score) ของ Precision และ Recall [13] ดังสมการที่ 4 ซึ่งผลคะแนนการประเมินตัวแบบแสดงดังตารางที่ 4

$$Accuracy = \frac{TN + TP}{TP + FP + TP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

- โดยที่ - TP คือ ข้อมูลที่ทำนายถูกต้องเมื่อเทียบกับเฉลย
- FP คือ ข้อมูลที่ทำนายแล้วไม่ถูกต้องเมื่อเทียบกับเฉลย
- FN คือ ข้อมูลที่อยู่ในเฉลยแต่ไม่มีการทำนาย (ตรงข้ามกับ FN)
- Precision คือ ค่าความแม่นยำ เกิดจากการนำค่า TP มาเทียบกับ FP
- Recall คือ ค่าความระลึก เกิดจากการนำค่า TP มาเทียบกับ FN
- F1 Score คือ ค่าเฉลี่ยของ Precision และ Recall

$$F_1 = 2 * \left(\frac{Precision * Recall}{Precision + Recall} \right) \quad (4)$$

4) ผลการวิจัย

จากการทดลองสร้างตัวแบบการวิเคราะห์ความรู้สึกทางอารมณ์สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์ โดยใช้ชุดข้อมูล จำนวน 12,900 ข้อมูล ซึ่งเป็นข้อมูลการแสดง

ความคิดเห็นต่อสินค้าและบริการภาษาไทยที่มีการติดป้ายกำกับ (Label) ความรู้สึก 3 ระดับ ได้แก่ ความรู้สึกเชิงบวก (Positive) เป็นกลาง (Neutral) และเชิงลบ (Negative) ผ่านกระบวนการพัฒนาตัวแบบ 5 ขั้นตอน ได้แก่ 1) การเตรียมข้อมูล 2) การตัดคำ 3) การฝึกอบรมข้อมูล 4) ขั้นตอนการแยกประเภท 5) การประเมินตัวแบบ และมีการเปรียบเทียบผลการวิเคราะห์จากเทคนิคการจำแนกประเภท 4 รูปแบบ ได้แก่ Long Short-Term Memory (LSTM), Stochastic Gradient Descent (SGD), Logistic Regression (LR) และ Support Vector Machines (SVM) สามารถสรุปผลการทดลองได้ดังตารางที่ 5 ดังนี้

ตารางที่ 5 : แสดงการประเมินประสิทธิภาพของตัวแบบ

Classification	Accuracy (%)	Precision (%)	Recall (%)	F1 (%)
LSTM	81.27	81.27	81.27	81.27
LR	69.00	69.00	69.00	69.00
SGD	66.00	66.00	66.00	66.00
SVM	65.00	65.00	65.00	65.00

จากตารางที่ 5 แสดงการประเมินประสิทธิภาพของตัว จากผลการทดลอง เมื่อพิจารณาจากความถูกต้องสามารถสรุปได้ดังนี้

อันดับที่ 1 การใช้เทคนิคการจำแนกประเภทแบบ Long Short-Term Memory (LSTM) คะแนนความแม่นยำ (Precision) 81.27% ค่าความระลึก (Recall) 81.27% และค่าเฉลี่ย (F1 Score) 81.27% ตัวแบบให้ค่าความถูกต้องในการวิเคราะห์ผล (Accuracy) 81.27% ในการทดลองนี้ได้จำลองการทำงานของเทคนิคการสร้างตัวแบบความรู้สึกทางอารมณ์โดยใช้การจำแนกประเภทแบบ LSTM [17] ซึ่งมีการใช้เทคนิคนี้ในงานวิจัยตามที่ระบุไว้

อันดับที่ 2 การใช้เทคนิคการจำแนกประเภทแบบ Logistic Regression (LR) คะแนนความแม่นยำ (Precision) 69% ค่าความระลึก (Recall) 69% และค่าเฉลี่ย (F1 Score) 69% ตัวแบบให้ค่าความถูกต้องในการวิเคราะห์ผล (Accuracy) 69% ในการทดลองนี้ได้จำลองการทำงานของเทคนิคการสร้างตัวแบบความรู้สึกทางอารมณ์โดยใช้การจำแนกประเภทแบบ Logistic Regression [6] ซึ่งมีการใช้เทคนิคนี้ในงานวิจัยตามที่ระบุไว้

อันดับที่ 3 การใช้เทคนิคการจำแนกประเภทแบบ Stochastic Gradient Descent (SGD) คะแนนความแม่นยำ (Precision) 66% ค่าความระลึก (Recall) 66% และค่าเฉลี่ย

(F1 Score) 66% ตัวแบบให้ค่าความถูกต้องในการวิเคราะห์ผล (Accuracy) 66% ในการทดลองนี้ได้จำลองการทำงานของเทคนิคการสร้างตัวแบบความรู้สึกทางอารมณ์โดยใช้การจำแนกประเภทแบบ Stochastic Gradient Descent [18] ซึ่งมีการใช้เทคนิคนี้ในงานวิจัยตามที่ระบุไว้

อันดับที่ 4 การใช้เทคนิคการจำแนกประเภทแบบ Support Vector Machines (SVM) คะแนนความแม่นยำ (Precision) 65% ค่าความระลึก (Recall) 65% และค่าเฉลี่ย (F1 Score) 65% ตัวแบบให้ค่าความถูกต้องในการวิเคราะห์ผล (Accuracy) 65% ในการทดลองนี้ได้จำลองการทำงานของเทคนิคการสร้างตัวแบบความรู้สึกทางอารมณ์โดยใช้การจำแนกประเภทแบบ Support Vector Machines [4], [6], [17], [19] ซึ่งมีการใช้เทคนิคนี้ในงานวิจัยตามที่ระบุไว้

และเมื่อพิจารณาจากค่าความถูกต้องของตัวแบบ (Accuracy) โดยเปรียบเทียบผลการวิเคราะห์จากเทคนิคการจำแนกประเภท 4 รูปแบบ การสร้างตัวแบบโดยใช้เทคนิคการจำแนกประเภทแบบ LSTM ตัวแบบให้ค่าความถูกต้องมากที่สุด 81.27% เมื่อเทียบกับการจำแนกประเภทแบบ Logistic Regression (LR), Stochastic Gradient Descent (SDG) และ Support Vector Machines (SVM) ทำให้เห็นว่าการนำ Deep Learning มาใช้ในการจำแนกความรู้สึกจะช่วยปรับปรุงความถูกต้องของตัวแบบได้ดียิ่งขึ้น ซึ่งสอดคล้องกับการศึกษาของ [17] ที่มีการนำเสนอตัวแบบไฮบริดโดยใช้ Manhattan LSTM (MaLSTM) วิเคราะห์ข้อมูลการรีวิว (Review) ภาพยนตร์จาก IMDB ภาษาอังกฤษเพื่อเปรียบเทียบกับวิธีการจำแนกประเภทแบบ Recurrent Neural Networks (RNN), Support Vector Machines (SVM) และ [19] ที่มีการนำเสนอตัวแบบการวิเคราะห์ความรู้สึกในโพสต์ Twitter ภาษาไทย เพื่อเปรียบเทียบกับวิธีการจำแนกประเภทแบบ Support Vector Machines และ Naïve Bayes ซึ่งผู้วิจัยนำมาพัฒนาต่อยอดเพื่อสร้างตัวแบบความรู้สึกทางอารมณ์สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์ด้วยเทคนิคการเรียนรู้เชิงลึก (Deep Learning) บนพื้นฐานของโครงข่ายประสาทเทียมแบบเกิดซ้ำรูป (Neural Network) แบบหน่วยความจำระยะสั้น โดยมุ่งเน้นไปที่การเรียนรู้การเป็นตัวแทนที่ซ่อนอยู่ลึกหลายชั้น (hidden Layers) กับชุดข้อมูลที่เป็นภาษาไทย ร่วมกับการตัดคำ (Word Segmentation) โดยใช้ NewMM ที่พัฒนาเพื่อใช้กับภาษาไทย โดยเฉพาะเพื่อตัดคำที่เป็นประโยคยาว ๆ ออกมาเป็นแต่ละคำให้

คอมพิวเตอร์สามารถนำไปประมวลผลได้ และการสร้างคลังคำศัพท์ (Bag of Words) เพื่ออธิบายกลุ่มรวมของคำโดยไม่ได้คำนึงถึงหลักไวยากรณ์ ความถี่ที่พบ และลำดับของคำ โดยนำมาใช้เป็น Feature ในการแทนตัวจัดแบ่งข้อความ Classifier ซึ่งจะช่วยให้ตัวแบบสามารถทำนายผลความรู้สึกเชิงบวก เป็นกลาง และเชิงลบได้มีประสิทธิภาพมากกว่าการใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ร่วมกับเทคนิคการจำแนกประเภท (Classification) ทั่ว ๆ ไป ที่ทำการศึกษา

5) สรุปและอภิปรายผล

ข้อมูลความคิดเห็นการเลือกซื้อสินค้าและบริการออนไลน์มีความหลากหลาย และมีข้อมูลใหม่เกิดขึ้นอยู่ตลอดเวลา ผู้บริโภคต้องเสียเวลาตีความการแสดงความคิดเห็นต่าง ๆ ที่มีอยู่เป็นจำนวนมาก ถ้าหากมีกลไกที่สามารถช่วยในการสรุปความคิดเห็นที่มีอยู่ในตัวสินค้าและบริการจะช่วยประหยัดเวลาและทำให้สามารถนำไปใช้ในตัดสินใจเลือกซื้อผลิตภัณฑ์ได้อย่างรวดเร็ว ดังนั้นงานวิจัยนี้นำเสนอวิธีการสร้างตัวแบบการวิเคราะห์ความรู้สึกทางอารมณ์สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์ โดยใช้เทคนิคส่วนการเรียนรู้ของเครื่อง (Machine Learning) เพื่อตัดสินใจความคิดเห็นต่อสินค้าและบริการ โดยนำเสนอเทคนิคการตัดคำ (Word Segmentation) ที่มีการใช้ไลบรารี (Library) ที่พัฒนาเพื่อใช้กับภาษาไทย โดยเฉพาะ และการลบ Stop Words เพื่อลบคำที่เกิดซ้ำออกซึ่งยังช่วยให้ขนาดของข้อมูลที่จะนำไปฝึกฝนมีขนาดเล็กลงอีกด้วย อีกทั้งยังมีการใช้เทคนิคการสร้างคลังคำศัพท์ (Bag of Words) โดยมีการวิเคราะห์ถึงรูปแบบและเทคนิคที่เหมาะสมที่จะนำมาใช้กับความคิดเห็นที่เป็นภาษาไทย เพื่อช่วยกรองและแบ่งประเภทคำที่เป็นเชิงบวกและเชิงลบ รวมถึงคำกริยา คำนามต่าง ๆ ทำให้เกิดประสิทธิภาพในการตัดคำที่ดีขึ้น ซึ่งผลลัพธ์โดยรวมจะเห็นได้ว่า การใช้เทคนิคที่นำเสนอจะได้ผลลัพธ์ที่ดีกว่าเทคนิคที่ใช้โดยทั่วไป ขั้นตอนการทดลองสำหรับการทดสอบตัวแบบ มีการเปรียบเทียบเทคนิคการแยกประเภท 4 เทคนิค ได้แก่ Long Short-Term Memory (LSTM), Stochastic Gradient Descent (SGD), Logistic Regression (LR) และ Support Vector Machines (SVM) ซึ่งมีกระบวนการสร้างตัวแบบ 5 ขั้นตอน ได้แก่ 1) การเตรียมข้อมูล 2) การตัดคำ 3) การฝึกอบรมข้อมูล 4) ขั้นตอนการแยกประเภท และ 5) การประเมินตัวแบบ เพื่อสร้างตัวแบบในการแยกประเภทระดับความรู้สึกแบบอัตโนมัติ

ออกเป็น 3 ระดับคือ ความรู้สึกเชิงบวก (Positive) เป็นกลาง (Neutral) และเชิงลบ (Negative) จากการทดลองสร้างตัวแบบการสร้างตัวแบบโดยใช้เทคนิคการจำแนกประเภทแบบ LSTM ซึ่งสูงกว่าเทคนิคทั้งหมดที่ทำการศึกษา และเหมาะสมที่สุดที่จะนำไปประยุกต์ใช้ในการสร้างตัวแบบการวิเคราะห์ความรู้สึกทางอารมณ์สำหรับจำแนกประเภทบทความแนะนำสินค้าออนไลน์ที่เป็นภาษาไทย และจากกระบวนการสร้างตัวแบบที่นำเสนอข้างต้นยังสามารถนำไปประยุกต์ใช้ในการวิเคราะห์ความเห็นโดเมนอื่น ๆ ได้อีกด้วย เช่น ข้อมูลความคิดเห็นโรงแรมและที่พัก ข้อมูลความคิดเห็นการซื้อสินค้าและบริการทั่ว ๆ ไป และข้อมูลความคิดเห็นร้านอาหาร เป็นต้น

6) ข้อจำกัด

ข้อจำกัดของการศึกษาวิจัยในครั้งนี้ ได้แก่ ตัวแบบยังไม่สามารถวิเคราะห์คำประชดประชัน (Sarcasm) ได้เนื่องจากชุดข้อมูลที่นำมาใช้ยังไม่มีคำประเภดังกล่าว ซึ่งต้องอาศัยตัวแบบในการเรียนรู้แยกต่างหากและอาศัยเหมือนข้อความ (Text mining) แบบใช้กฎ (Rule-based) เข้ามาช่วย แต่ถ้าสามารถนำแนวทางของงานวิจัยมาเชื่อมต่อได้ในอนาคต

7) ข้อเสนอแนะ

สำหรับการวิจัยต่อ จะมีกระบวนการเพิ่มประสิทธิภาพของตัวแบบเพื่อให้ผลการทำนายมีประสิทธิภาพขึ้น โดยนำเทคนิคอื่น ๆ รวมในกระบวนการจัดเตรียมข้อมูล เช่น การเพิ่มจำนวนคำศัพท์ เพิ่มเทคนิคการแบ่งชนิดของคำ (Named-Entity Tagging) เพื่อช่วยให้การแยกคำมีความชัดเจนมากขึ้น รวมทั้งการเพิ่มชุดข้อมูลคำแสดงเพื่อทำให้ตัวแบบสามารถวิเคราะห์คำประชดประชันได้ และกลไกการเรียนรู้เป็นไปอย่างมีประสิทธิภาพ รวมถึงเพิ่มข้อมูลของคำ ประโยค ที่เป็นการคัดเลือกคำบอกความรู้สึก บวก ลบ และเป็นกลาง (Sentiment Word level) และสามารถนำเทคนิคการวิเคราะห์ระดับความรู้สึกด้วยการเรียนรู้เชิงลึก (Deep Learning) เข้ามาใช้เพื่อให้ผลลัพธ์การทำงานของตัวแบบดียิ่งขึ้น

กิตติกรรมประกาศ

งานศึกษานี้สำเร็จลุล่วงไปได้ ต้องขอขอบพระคุณผู้เชี่ยวชาญในการระบุและนิยามข้อมูลในแต่ละชุด

REFERENCES

- [1] P. Bowornlertsutee and W. Paireekreng, "The model of sentiment analysis for online shopping review using false detection technique," (in Thai), in *Proc. 14th Nat. Conf. Digit. Technol. Sustain. Wellbeing and Smart Soc.*, Bangkok, Thailand, Jun. 21, 2019, pp. 477–486.
- [2] P. Laowsungsuk, A. Jinda, and S. Sitthisarn, "Sentiment analysis of restaurant reviews on review web sites," (in Thai), *Thaksin Univ. J.*, vol. 20, no. 1, pp. 39–47, 2017.
- [3] M. Masdisornchote, "Constructing Thai opinion mining," (in Thai), *J. Sripatum Rev. Sci. Technol.*, vol. 6, no. 1, pp. 120–128, 2014.
- [4] P. Kasemmetheekarun, P. Meesut, and S. Nuanmeesri, "Sentiment analysis system of Thai video on social media using support vector machine," (in Thai), *CRMA J.*, vol. 14, no. 1, pp. 21–33, 2016.
- [5] B. Chiraratanasopha, "Sentimental analysis and keyword extraction from Thai users of Facebook in COVID-19 period," *Prog. Appl. Sci. Technol.*, vol. 11, no. 1, pp. 66–72, 2021.
- [6] P. Bowornlertsutee and W. Paireekreng, "Thai sentiment analysis techniques for online customer reviews," (in Thai), *RMUTSV Res. J.*, vol. 14, no. 3, 2022, Art. no. 245470.
- [7] M. Manhem, S. Dolah, S. Chunkaew, and S. Mak-on, "Model for the classification of feelings of reviews using techniques decision tree case studies hotel reservation web site," (in Thai), *J. Sci. Technol. Songkhla Rajabhat Univ.*, vol. 1, no. 2, pp. 69–79, 2020.
- [8] S. Srisawakarn and S. Srisuay, "Sentiment analysis opinion mining using text extraction," (in Thai), *J. Educational Technol. Commun. Fac. Educ. Mahasarakham Univ.*, vol. 6, no. 2, pp. 95–104, 2020.
- [9] X. Fan, X. Li, F. Du, X. Li, and M. Wei, "Apply word vectors for sentiment analysis of APP reviews," in *Proc. 3rd Int. Conf. Syst. and Inform. (ICSAI)*, Shanghai, China, Nov. 2016, pp. 1062–1066, doi: 10.1109/ICSAI.2016.7811108.
- [10] T. Chumwatana, "Using sentiment analysis technique for analyzing Thai customer satisfaction from social media," in *Proc. 5th Int. Conf. Comput. and Inform.*, Istanbul, Turkey, Aug. 2015, pp. 659–664.
- [11] N. Sornjapo, "Thai text automatic clustering model using machine learning by unsupervised learning with natural language processing," (in Thai), *Sripatum Chonburi J.*, vol. 14, no. 4, pp. 95–106, 2018.
- [12] C. Haruechaiyasak, A. Kongthon, P. Palingoon, and K. Trakultaweekoon, "S-Sense: A sentiment analysis framework for social media monitoring applications," *Inf. Technol. J.*, vol. 14, no. 1, pp. 11–22, 2018.
- [13] I. Lorattanachaiyong, "Generating Thai sentiment lexicon from online reviews," M.A. thesis, Dept. Arts, Chulalongkorn Univ., Bangkok, Thailand, 2017.
- [14] P. Promla and C. Sanrach, "The comparison of efficiency on the analysis of satisfaction on teaching performance using sentiment analysis by ensemble technique," *KKU Res. J. (Graduate Studies)*, vol. 20, no. 4, pp. 104–149, 2020.
- [15] W. Fongngen and S. Pethan, "Sentiment analysis opinion mining from Facebook comments using data mining technique," (in Thai), *J. Ind. Technol. Ubon Ratchathani Rajabhat Univ.*, vol. 11, no. 1, pp. 121–132, 2021.
- [16] O. Pravattorisut, *Python for data science data visualization and machine learning*. Bangkok, Thailand: Provision (in Thai), 2021.
- [17] S. Hiriyannaiah, S. G. Matt, and S. K. Gopalayengar, "A hybrid model using MaLSTM based on recurrent neural networks with support vector machines for sentiment analysis," *Eng. Appl. Sci. Res.*, vol. 47, no. 3, pp. 232–240, 2020.
- [18] S. Diab, "Optimizing stochastic gradient descent in text classification base on fine- tuning hyper- parameters approach," *Int. J. Comput. Sci. Inf. Secur.*, vol. 16, no. 12, pp. 155–160, 2018.
- [19] X. Xie, K. Neelora, and S. Laohakiat, "Sentimental analysis using Twitter data," M.S. thesis, Dept. Comput. Sci., Srinakharinwirot Univ., Bangkok, Thailand, 2018.

การศึกษาผลกระทบของสิ่งกีดขวางทางน้ำต่อการเกิดน้ำท่วมในลำน้ำ

พงศ์พันธุ์ กาญจนการณ^{1*} ชูโชค อายุพงศ์² สุรัชย์ อำนวยพรเลิศ³ พรยมล เนตรนภากร⁴ วิชัย นามแก้ว⁵

^{1*,3,4,5}หลักสูตรวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา เชียงราย, จังหวัดเชียงราย, ประเทศไทย

²ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่, จังหวัดเชียงใหม่, ประเทศไทย

*ผู้ประพันธ์บรรณกิจ อีเมล : pongpank@gmail.com

รับต้นฉบับ : 11 ตุลาคม 2564; รับบทความฉบับแก้ไข : 30 ธันวาคม 2564; ตอบรับบทความ : 9 มีนาคม 2565

เผยแพร่ออนไลน์ : 27 มิถุนายน 2565

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาผลกระทบของสิ่งกีดขวางทางน้ำเพื่อตรวจสอบว่าสิ่งกีดขวางทำให้เพิ่มของน้ำท่วมในลำน้ำแบบจำลอง HEC-RAS ได้นำมาใช้ในการจำลองการไหลและระดับน้ำกรณีมีและไม่มีสิ่งกีดขวางในลำน้ำ ค่าระดับน้ำและความสูงของตลิ่งถูกนำมาวิเคราะห์เพื่อหาระยะทางที่เกิดน้ำท่วมตลอดแนวลำน้ำทั้งสองกรณี จากผลการศึกษาพบว่า ผลกระทบต่อระดับน้ำหน้าสิ่งกีดขวางประเภทฝายและท่อลอดมีความแตกต่างกัน ระดับน้ำหน้าท่อลอดจะต่ำกว่าระดับน้ำหน้าฝายที่อัตราการไหลต่ำ อย่างไรก็ตามเมื่ออัตราการไหลสูงเกินกว่าความจุการไหลของท่อลอด ระดับน้ำหน้าท่อลอดจะมีค่าสูงกว่าเนื่องจากข้อจำกัดของหน้าตัดท่อลอดในการรับการไหลของน้ำ ระยะน้ำท่วมและระดับน้ำตลอดแนวลำน้ำที่อัตราการไหลสูงแสดงให้เห็นว่าระยะน้ำท่วมตลอดแนวลำน้ำลดลงเหลือ 580.6 เมตร จาก 953.4 เมตร เมื่อไม่มีสิ่งกีดขวางการไหล การมีสิ่งกีดขวางทางน้ำจะทำให้ระดับผิวน้ำสูงขึ้นมากกว่าปกติซึ่งทำให้ระยะน้ำท่วมเพิ่มขึ้นไปทางด้านเหนือของสิ่งกีดขวางในขณะที่ไม่มีการท่วมเกิดขึ้นที่บริเวณท้ายน้ำของสิ่งกีดขวาง งานวิจัยนี้แสดงให้เห็นว่าท่อลอดมีแนวโน้มที่จะก่อให้เกิดน้ำท่วมมากกว่าฝายในช่วงเหตุการณ์ฝนตกหนัก

คำสำคัญ : สิ่งกีดขวางทางน้ำ แบบจำลอง HEC-RAS ฝาย ท่อลอด

The Study of the Effect of Channel Obstacles on Stream Flooding

Pongpan Kanjanakaroon^{1*} Chuchoke Aryupong² Surachai Amnuaypornlert³

Pornyamol Natenapakorn⁴ Wichai Namkaew⁵

^{1*,3,4,5}*Department of Civil Engineering, Faculty of Engineering, Rajamangala University of Technology Lanna
(Chiang Rai Campus), Chiang Rai, Thailand*

²*Department of Civil Engineering, Faculty of Engineering, Chiang Mai University, Chiang Mai, Thailand*

*Corresponding Author. E-mail address: pongpank@gmail.com

Received: 11 October 2021; Revised: 30 December 2021; Accepted: 9 March 2022

Published online: 27 June 2022

Abstract

The purpose of this research is to study the effect of obstacles across channels to determine if they increase flooding of the stream. The HEC-RAS model was used to simulate water flow and levels with and without obstructions across streams. The level of water and the height of the stream bank were analyzed to determine the distance of flooding along the stream in both cases. The results showed that the effect on the water level in front of the obstacles such as a weir or a culvert is different. The water level in front of the culvert is lower than the water level in front of the weir at low flow. However, when the stream flow exceeds the flow capacity of the culvert, the water level in front of the culvert will be higher due limited by the cross-section of the culvert receiving the water flow. The flood distances and water levels along the stream under high flow show that the flood distances decrease to 580.6 meters from 953.4 meters along the channel when no obstacles restrict the flow. The existence of obstructions in the channel causes the water level to rise higher than usual thus causing the flood distances to increase along the upstream side of the obstruction while flooding does not occur downstream of the obstruction. This research shows that culverts are prone to causing greater flooding than weirs during heavy rainfall events.

Keywords: Channel obstruction, HEC-RAS model, Weir, Culvert

1) บทนำ

ปัจจุบันในเรื่องของน้ำท่วมเป็นปรากฏการณ์ที่เกิดขึ้นอยู่ทั่วไป โดยเฉพาะการท่วมจากน้ำล้นตลิ่ง ซึ่งส่วนใหญ่เกิดจากฝนตกต่อเนื่องเป็นเวลานานจนก่อให้เกิดปริมาณน้ำที่มากไหลลงสู่ลำน้ำจนทำให้ระดับน้ำสูงกว่าตลิ่งส่งผลให้เกิดน้ำท่วมขังในพื้นที่ลุ่มต่ำหรือชุมชน เกิดความเสียหายต่อพื้นที่ทางเกษตรกรรมและอาคารบ้านเรือน ถ้าน้ำท่วมแม่ไร่ ตำบลแม่ไร่ อำเภอมะจัน จังหวัดเชียงราย เป็นพื้นที่ประสบปัญหาน้ำท่วมเป็นประจำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่ [1] ได้พัฒนาระบบสารสนเทศเตรียมความพร้อมเพื่อรับมือภัยน้ำท่วมและดินถล่ม จังหวัดเชียงราย โดยข้อมูลจากการสำรวจพบว่าบริเวณพื้นที่ดังกล่าวมีสิ่งกีดขวางทางน้ำเป็นจำนวนมาก ประกอบไปด้วยตอม่อสะพาน ฝาย ท่อลอด ตลอดจนเศษวัสดุทั่วไปที่กีดขวางทางน้ำ ทั้งนี้ผลของสิ่งกีดขวางทางน้ำจะทำให้เกิดผลกระทบต่อน้ำในลำน้ำที่เพิ่มสูงมากขึ้น สิ่งกีดขวางประเภทตอม่อสะพานและท่อลอดจะทำให้ทางเข้าของน้ำโดยปกติมีขนาดที่ลดลงส่งผลให้เกิดการเอ่อล้นหน้าทางเข้า สำหรับฝายจะยกระดับน้ำขึ้นซึ่งหากเป็นฝายที่ไม่มีการจัดการที่ดีพอ จะทำให้ระบายน้ำออกไม่ทันกับระดับน้ำที่สูงขึ้นเหนือฝายจนเกินระดับตลิ่ง ปัญหาน้ำท่วมจากสิ่งกีดขวางทางน้ำเหล่านี้ล้วนเป็นเหตุการณ์ที่เกิดขึ้นกับลำน้ำห้วยแม่ไร่ในปัจจุบัน [2], [3] ซึ่งปริมาณน้ำที่เข้าสู่พื้นที่ดังกล่าวเกิดจากสภาวะฝนตกหนักบนดอยสูงรอบพื้นที่ โดยเฉพาะอย่างยิ่งบริเวณดอยตุง ปริมาณน้ำจากต้นน้ำได้ไหลผ่านพื้นที่รอยต่อระหว่างตำบลแม่ไร่ อำเภอมะจัน กับ ตำบลห้วยไคร้ อำเภอมะสา และไหลเข้าสู่ลำน้ำห้วยแม่ไร่ต่อไป

แนวทางในการแก้ปัญหาเหล่านี้จึงต้องทำการหาระดับน้ำที่เกิดขึ้นเนื่องจากการมีสิ่งกีดขวางทางน้ำเหล่านี้ อย่างไรก็ตามในช่วงที่เกิดอุทกภัย ไม่สามารถที่จะตรวจสอบระดับน้ำที่เกิดขึ้นได้ จึงต้องทำการจำลองเหตุการณ์ดังกล่าวด้วยแบบจำลองคณิตศาสตร์ที่น่าเชื่อถือได้แทน โดยแบบจำลองที่จะนำมาใช้ในการวิจัยนี้คือ แบบจำลอง Hydrologic Engineering Center River Analysis System (HEC-RAS) ซึ่งพัฒนาโดย US Army Corps of Engineers มีความสามารถในการจำลองระบบชลศาสตร์ของการไหลของน้ำผ่านแม่น้ำธรรมชาติและช่องทางอื่น ๆ [4] แบบจำลองดังกล่าวถูกใช้ในการศึกษาและจำลองเหตุการณ์ที่เกิดขึ้นใกล้เคียงกัน อาทิเช่น สมบัติ ชื่นชุกกลิ่น [5] ได้ใช้แบบจำลองดังกล่าวเพื่อวิเคราะห์การไหลหลากของแม่น้ำกับการวางแผนคลองผันน้ำเพื่อลดอุทกภัย กรณีศึกษาแม่น้ำป่าสัก


จังหวัดเพชรบูรณ์ เพื่อประกอบการวางแผนบรรเทาปัญหาอุทกภัยในท้องที่อำเภอเมืองเพชรบูรณ์ ผลการใช้แบบจำลอง HEC-RAS ในการหาแนวเส้นทางของคลองผันน้ำที่เหมาะสมแสดงให้เห็นว่า ระดับน้ำท่วมและจำนวนวันน้ำท่วมลดลงเมื่อมีคลองผันน้ำ ทั้งนี้ในการจำลองดังกล่าวไม่มีการพิจารณาหรือมุ่งประเด็นถึงสิ่งกีดขวางทางน้ำที่มีอยู่ในแม่น้ำป่าสัก ปรีวัตร น้ำค้าง [6] ได้ใช้แบบจำลองในการวิเคราะห์และศึกษาพฤติกรรมการไหลของแม่น้ำแม่กลอง จำลองเหตุการณ์ที่น่าจะเกิดขึ้นในอนาคต จากผลการวิเคราะห์พบว่า แบบจำลองสามารถหาจุดวิกฤตที่เกิดขึ้นในกรณีที่แม่น้ำแม่กลองขาดน้ำได้เป็นอย่างดี อย่างไรก็ตามงานวิจัยนี้ยังไม่ได้มีการจำลองสิ่งกีดขวางทางน้ำลงไปในในการจำลอง

บทความวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาผลกระทบของระดับน้ำบริเวณสิ่งกีดขวางทางน้ำที่อัตราการไหลแตกต่างกัน และศึกษาผลกระทบของสิ่งกีดขวางทางน้ำต่อระดับน้ำในลำน้ำ ตำแหน่งการเกิดน้ำท่วม และระยะน้ำท่วมตลอดแนวลำน้ำ โดยเลือกใช้ปริมาณน้ำหลากสูงสุดในลำน้ำรอบปีการเกิดซ้ำ 10 ปี ซึ่งเป็นค่าแนะนำของคณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่ [1] มาใช้ในการวิเคราะห์ผลกระทบกรณีมีและไม่มีสิ่งกีดขวางทางน้ำ ทั้งนี้จะพิจารณาสิ่งกีดขวางทางน้ำประเภทฝายและท่อลอดเป็นหลักเนื่องจากเป็นโครงสร้างทางชลศาสตร์ที่ติดตั้งถาวรในลำน้ำ ทำการหาระดับน้ำที่เกิดขึ้นทั้งสองกรณีเพื่อนำมาเปรียบเทียบหาตำแหน่งและระยะการเกิดน้ำท่วมตลอดแนวลำน้ำ ผลที่ได้นี้สามารถใช้เป็นแนวทางในการหาวิธีแก้ไขเบื้องต้นให้กับพื้นที่ประสบปัญหาในอำเภอมะจันและพื้นที่ใกล้เคียงต่อไป

2) วิธีการดำเนินงานวิจัย

2.1) กรอบแนวความคิดในงานวิจัย

งานวิจัยนี้มีกรอบแนวคิด แสดงได้ดังรูปที่ 1 โดยต้องการหาผลกระทบของสิ่งกีดขวางทางน้ำต่อการเกิดน้ำท่วม เริ่มต้นวิเคราะห์โดยทำการแบ่งการศึกษาออกเป็น 2 กรณี ได้แก่ กรณีศึกษาผลกระทบต่อน้ำที่ที่เกิดขึ้นบริเวณที่มีสิ่งกีดขวางทางน้ำ และกรณีศึกษาระดับน้ำในลำน้ำ ตำแหน่งการเกิดน้ำท่วม และระยะการท่วม โดยมีตัวแปรต้นทั้งสองกรณีคล้ายคลึงกัน จากนั้นจะได้ค่าตัวแปรตามคือหน้าตัดระดับผิวน้ำ ตำแหน่งการเกิดน้ำท่วมและระยะการท่วม โดยกรณีแรกจะวิเคราะห์หน้าตัดระดับผิวน้ำเป็นหลัก กรณีสองจะวิเคราะห์จากตัวแปรตามทั้งสองที่ร่วมกัน



รูปที่ 1 : กรอบแนวคิดในการวิจัย


2.2) พื้นที่ศึกษา

พื้นที่ในการศึกษานี้ได้แก่ลำน้ำห้วยแม่ไร่ อยู่ในพื้นที่ของตำบลแม่ไร่ อำเภอแม่จัน จังหวัดเชียงราย เริ่มพิจารณาตั้งแต่บริเวณ N 2242479 E 586885 จนถึง N 2239476 E 590134 โดยลำน้ำในพื้นที่ดังกล่าวประกอบด้วยลำน้ำย่อย 7 สาย ดังแสดงในรูปที่ 2 และมีคุณสมบัติต่าง ๆ แสดงได้ดังตารางที่ 1 ซึ่งลำน้ำดังกล่าวประกอบด้วยฝายและตลอดเป็นจำนวนมาก การเก็บข้อมูลหน้าตัดลำน้ำจะเก็บทุกระยะไม่เกิน 50 เมตร และในบริเวณที่มีสิ่งกีดขวางทางน้ำจะเก็บข้อมูลหน้าตัดเพิ่มเติม

ลักษณะการใช้พื้นที่ประกอบด้วยพื้นที่เกษตรกรรมและพื้นที่ชุมชนหนาแน่นน้อยถึงปานกลางบริเวณต้นน้ำและกลางน้ำ ส่วนบริเวณท้ายน้ำจะเป็นพื้นที่ชุมชนหนาแน่นเป็นหลัก การเกิดน้ำท่วมจะเกิดเป็นประจำทุกปีโดยเฉพาะบริเวณท้ายน้ำ

ตารางที่ 1 : คุณสมบัติของลำน้ำ

ลำน้ำ	จำนวนสิ่งกีดขวาง		ระยะ (ม.)	จำนวนหน้าตัด
	ฝาย	ตลอด		
MAERAI 1 LINE 1	-	-	200	6
MAERAI 1 LINE 2	7	2	1,400	34
MAERAI 1 LINE 3	-	2	900	17
MAERAI 1 LINE 4	1	3	900	20
MAERAI 2 LINE 1	4	14	2,450	95
MAERAI 3 LINE 1	-	2	400	15
MAERAI 4 LINE 1	1	1	750	34




รูปที่ 2 : ลำน้ำห้วยแม่ไร่ ตำบลแม่ไร่ อำเภอแม่จัน จังหวัดเชียงราย

2.3) แบบจำลอง HEC-RAS

โปรแกรม HEC-RAS เป็นแบบจำลองสำหรับวิเคราะห์ด้านชลศาสตร์ เพื่อใช้คำนวณหน้าข้างการไหลของผิวน้ำที่คงที่ การไหลที่ผันแปรที่ละน้อยในช่องทาง และการระบายน้ำในพื้นที่ลุ่มน้ำ แบบจำลอง HEC-RAS มีประสิทธิภาพในการจำลองสภาพการเกิดผลกระทบของลำน้ำ คำนวณระดับน้ำในลำน้ำโดยมีความถูกต้องในการคำนวณสูง สามารถจำลองการไหลแบบ 1 มิติ และ 2 มิติ สามารถคำนวณขอบเขตการเคลื่อนที่ของตะกอน การกระจายตัวของคุณภาพน้ำ คำนวณการไหลของน้ำแบบ Steady และ Unsteady Flow [7]–[9]

การคำนวณหน้าข้างการไหลในแบบจำลอง HEC-RAS ใช้หลักการพลังงานระหว่าง 2 หน้าตัด ดังสมการ (1) และ (2) และรูปที่ 2 แสดงได้ดังนี้



รูปที่ 3 : ความสัมพันธ์ของตัวแปรในสมการพลังงาน [9]

$$Z_2 + Y_2 + \frac{\alpha_2 V_2^2}{2g} = Z_1 + Y_1 + \frac{\alpha_1 V_1^2}{2g} + h_e \quad (1)$$

$$h_e = L\bar{S}_f + C \left[\frac{\alpha_2 V_2^2}{2g} + \frac{\alpha_1 V_1^2}{2g} \right] \quad (2)$$

Y_1, Y_2 = ระดับน้ำทางด้านเหนือและท้ายน้ำของ
ช่วงที่พิจารณา
 V_1, V_2 = ความเร็วของน้ำที่ด้านทั้งสอง
 α_1, α_2 = สัมประสิทธิ์ความเร็วการไหล
 g = ความเร่งเนื่องจากแรงโน้มถ่วงของโลก
= 9.81 ม./วินาที²
 h_e = Energy Head Loss
 L = ความยาวของช่วงทางน้ำที่พิจารณา
 $\bar{S}_f$ = ความลาดชันของเส้นพลังงานเฉลี่ย
 C = ค่าสัมประสิทธิ์การสูญเสียของการบีบและขยาย
ทางน้ำ

2.4) ขั้นตอนการศึกษา

2.4.1) การรวบรวมข้อมูลและวิเคราะห์ ข้อมูลที่ใช้นำมาจากรายงานโครงการพัฒนาระบบสารสนเทศเตรียมความพร้อมเพื่อรับมือภัยน้ำท่วมและดินถล่ม จังหวัดเชียงราย [1] ประกอบด้วย อัตราการไหลหลากสูงสุดที่รอบปีการเกิดซ้ำ 10 ปี ค่าหน้าตัดลำน้ำ และข้อมูลสิ่งกีดขวางทางน้ำ

2.4.2) การตรวจสอบข้อมูล การตรวจสอบตัวแปรและค่าที่ใช้ในการนำไปใช้ในแบบจำลอง HEC-RAS ประกอบไปด้วย การตรวจสอบค่าหน้าตัดลำน้ำ ข้อมูลสะพานตอม่อ ฝาย ท่อลอด โดยทำการตรวจสอบหน้าตัดลำน้ำที่ไม่สอดคล้องกับความเป็นจริง เช่น หน้าตัดลำน้ำมีการขุดลอก สภาพทางน้ำบางช่วงถูกกีดขวาง และการทับถมของตะกอนบริเวณสิ่งกีดขวางทางน้ำ เป็นต้น การสำรวจหน้าตัดดังกล่าวใช้หลักการของวิศวกรรมสำรวจด้วยกล้องสำรวจประมวลผลรวมเป็นหลัก

2.4.3) การนำเข้าข้อมูล ข้อมูลที่ผ่านการตรวจสอบในหัวข้อ 2.4.2 แล้วจะถูกนำเข้าลงในโปรแกรม HEC-RAS ได้แก่ เส้นแนวลำน้ำ ตลิ่งของลำน้ำ หน้าตัดลำน้ำ ฝาย ท่อลอด สะพาน อัตราการไหล

2.4.4) การเปรียบเทียบ ข้อมูลระดับน้ำที่ได้จากการจำลองจะถูกนำมาเปรียบเทียบกับระดับน้ำในลำน้ำจริงเพื่อหาค่าสัมประสิทธิ์ความขรุขระที่ทำให้ได้ระดับน้ำแบบจำลองเท่ากับระดับน้ำจริงในสนาม ตำแหน่งระดับน้ำจริงที่ใช้ในการเปรียบเทียบมี 8 ตำแหน่งในลำน้ำ แสดงได้ดังรูปที่ 4 ค่าระดับน้ำที่ทำการเปรียบเทียบจะนำไปตรวจสอบด้วยประสิทธิภาพแนช-ซัทคลีฟ [10] แสดงได้ดังสมการ (3) ทั้งนี้ ค่าของ NSE ที่ได้จะต้องมีค่ามากกว่า 0.65 ตามข้อเสนอแนะของ Moriasi *et al.* [11] และหากใกล้กับ 1 จะ

ให้ค่าการยอมรับที่สูงมาก ในกรณีที่ปรับเทียบแล้วได้ค่า NSE ต่ำกว่า 0.65 จะต้องพิจารณาปรับแก้ใหม่อีกครั้ง


$$NSE = 1 - \frac{\sum_{i=1}^n (W_r - W_{s_r})^2}{\sum_{i=1}^n (W_r - \bar{W}_r)^2} \quad (3)$$

เมื่อ NSE คือ ประสิทธิภาพแนช-ซัทคลีฟ

W_r คือ ระดับน้ำพื้นที่จริง

W_{s_r} คือ ระดับน้ำแบบจำลอง

$\bar{W}_r$ คือ ระดับน้ำพื้นที่จริงเฉลี่ย



รูปที่ 4 : ตำแหน่งที่ใช้ในการเปรียบเทียบ

2.4.5) การจำลองการไหลเพื่อวิเคราะห์การไหลผ่านสิ่งกีดขวางทางน้ำ อัตราการไหลที่ต่ำจนถึงสูงประกอบด้วยอัตราการไหล 3, 5, 10, 13, 23.34 m³/s ถูกนำมาใช้เพื่อจำลองผลกระทบของการไหลผ่านฝายและท่อลอด โดยอัตราการไหล 3 m³/s เป็นอัตราการไหลที่ระดับน้ำไหลภายในฝายและท่อลอด อัตราการไหลที่ 5 m³/s เป็นอัตราการไหลที่ระดับน้ำเริ่มล้นฝาย อัตราการไหลที่ 10 m³/s เป็นอัตราการไหลที่ระดับน้ำเริ่มไหลล้นขอบบนของท่อลอด อัตราการไหลที่ 13 m³/s เป็นอัตราการไหลที่ระดับน้ำล้นขอบบนท่อลอด และอัตราการไหลที่ 23.34 m³/s เป็นระดับน้ำสูงสุดที่รอบปีการเกิดซ้ำ 10 ปี

2.4.6) การจำลองการไหลกรณีไม่มีสิ่งกีดขวางทางน้ำ การตรวจสอบผลกระทบที่เกิดขึ้นในลำน้ำทั้งหมดเมื่อมีและไม่มีสิ่งกีดขวางทางน้ำจะพิจารณาผลกระทบที่มีต่อระดับน้ำในลำน้ำ ตำแหน่งการเกิดน้ำท่วม และระยะทางน้ำท่วมล้นตลิ่ง จากการ

จำลองอัตราการไหลที่ 23.34 ลบ.ม./วินาที ซึ่งเป็นปริมาณน้ำหลากสูงสุดที่รอบปีการเกิด 10 ปี ที่ส่งผลกระทบต่อลำน้ำมากที่สุดตามการแนะนำของโครงการพัฒนาระบบสารสนเทศเตรียมความพร้อมเพื่อรับมือภัยน้ำท่วมและดินถล่ม จังหวัดเชียงราย [1]

3) ผลการดำเนินงาน

3.1) ผลการเปรียบเทียบความถูกต้องของแบบจำลอง

ตารางที่ 2 แสดงผลลัพธ์ที่ได้จากการเปรียบเทียบค่าสัมประสิทธิ์ความขรุขระของแบบจำลอง โดยมีความแตกต่างของระดับผิวน้ำจริงและจำลองไม่เกินร้อยละ 3.28 และมีค่าสัมประสิทธิ์ความขรุขระในช่วง 0.028–0.032 ค่าระดับน้ำที่ได้จะถูกนำไปตรวจสอบความถูกต้องโดยประสิทธิภาพแนช-ซีทคลีฟ ได้เท่ากับ 0.99 ซึ่งถือว่าดีมาก ดังนั้นจึงทำให้การจำลองการไหลในโปรแกรม HEC-RAS มีความเป็นไปได้ที่จะนำไปจำลองระดับน้ำและอัตราการไหลในลำน้ำให้แสดงผลได้ใกล้เคียงกับสภาพพื้นที่จริง ถึงแม้ว่าข้อจำกัดของการเก็บข้อมูลภาคสนามทำให้ไม่สามารถเปรียบเทียบที่ระดับน้ำความลึกเกินกว่า 0.63 เมตรได้ แต่ลักษณะของตลิ่งที่ความลึกเกินกว่า 0.63 เมตรมีลักษณะแบบเดียวกัน จึงสามารถใช้ค่าสัมประสิทธิ์ความขรุขระที่ได้จากการเปรียบเทียบได้

3.2) ผลกระทบของระดับน้ำบริเวณฝายและท่อดูดเมื่ออัตราการไหลแตกต่างกัน


ถึงแม้ฝายและท่อดูดจะเป็นสิ่งกีดขวางทางน้ำเหมือนกัน แต่ผลกระทบที่เกิดขึ้นต่อการเปลี่ยนแปลงระดับน้ำไม่เหมือนกันเนื่องจากฝายมีโครงสร้างเพื่อยกกระแสน้ำให้สูงขึ้นและหน้าตัดการไหลผ่านจะขึ้นอยู่กับระดับความสูงของน้ำเหนือฝาย แต่ท่อดูดจะยอมให้น้ำไหลผ่านตามขนาดหน้าตัดที่มีอยู่ ผลกระทบต่อระดับและความลึกน้ำบริเวณหน้าโครงสร้างทั้งสอง แสดงได้ดังรูปที่ 5 โดยที่อัตราการไหลต่ำ ($Q = 3$ ลบ.ม./วินาที) ระดับและ

ความลึกน้ำหน้าฝายจะสูงเนื่องจากน้ำสามารถไหลล้นออกได้บริเวณสันเท่านั้น ในขณะที่ระดับและความลึกน้ำหน้าท่อดูดจะต่ำเนื่องจากน้ำสามารถไหลผ่านท่อที่อยู่ด้านล่างได้โดยตรง แต่เมื่ออัตราการไหลเริ่มสูงขึ้น ($Q = 5$ ลบ.ม./วินาที) ระดับน้ำและ


ตารางที่ 2 : ความลึกของระดับน้ำที่เก็บได้จากพื้นที่ศึกษา

ลำน้ำ	ตำแหน่ง	สัมประสิทธิ์ความขรุขระ	ระดับความลึก (ม.)	
			พื้นที่จริง	แบบจำลอง
MAERAI 1 LINE 1	0+000	0.03	0.63	0.65
	0+222	0.03	0.59	0.58
MAERAI 1 LINE 2	0+500	0.03	0.63	0.61
MAERAI 1 LINE 3	1+700	0.03	0.6	0.61
MAERAI 1 LINE 4	3+050	0.032	0.59	0.59
MAERAI 2 LINE 1	0+025	0.028	0.52	0.52
MAERAI 3 LINE 1	0+025	0.033	0.62	0.63
MAERAI 4 LINE 1	0+600	0.031	0.56	0.56

ความลึกน้ำบริเวณหน้าฝายและท่อดูดจะใกล้เคียงกันเนื่องจากเป็นอัตราการไหลที่ใกล้เคียงกับประสิทธิภาพสูงสุดของการระบายน้ำผ่านท่อดูด และเมื่ออัตราการไหลสูงมากขึ้นจนเกินประสิทธิภาพการระบายของท่อดูดแล้ว ($Q = 10, 13$ และ 23.34 ลบ.ม./วินาที) ระดับและความลึกน้ำหน้าท่อดูดจะสูงกว่าเมื่อเทียบกับฝาย ซึ่งจะเป็นสาเหตุให้เกิดการท่วมของน้ำบริเวณท่อดูดง่าย โดยเฉพาะอย่างยิ่งที่อัตราการไหลสูงผลกระทบดังกล่าวจะยิ่งรุนแรงดังแสดงให้เห็นในหัวข้อต่อไป



ก) หน้าตัดฝาย ตำแหน่ง 1+728.53




ข) หน้าตัดท่อดูด ตำแหน่ง 2+314.88

รูปที่ 5 : ตัวอย่างระดับน้ำท่อดูดและฝายที่อัตราการไหลที่เปลี่ยนแปลง


3.3) ผลเปรียบเทียบระดับน้ำในลำน้ำกรณีมีและไม่มีสิ่งกีดขวางทางน้ำ

ผลการจำลองระดับน้ำที่อัตราการไหลรอบปีการเกิดซ้ำ 10 ปี (23.34 ลบ.ม/วินาที) พบว่า การมีสิ่งกีดขวางทางน้ำส่งผลให้ระดับผิวน้ำเพิ่มสูงขึ้นจากกรณีไม่มีสิ่งกีดขวาง ดังแสดงในรูปที่ 6 โดยมีระดับน้ำแตกต่างกันเป็นระยะทาง 1,875 เมตร ตลอดแนว 7 ลำน้ำย่อย ตัวอย่างระดับน้ำที่ไหลผ่านฝายที่ตำแหน่ง 0+284.86 ของลำน้ำ MAERAI 4 LINE 1 (รูปที่ 6ง) แสดงให้เห็นถึงระดับน้ำที่ยกตัวสูงขึ้นโดยมีความต่างระดับน้ำ 0.21 เมตร


สำหรับการไหลผ่านท่อดูด ระดับน้ำหน้าท่อดูดจะยกตัวสูงขึ้นอย่างมากและเกิดผลกระทบของปรากฏการณ์น้ำย้อนไปทางด้านเหนือน้ำเป็นระยะทางยาวกว่าการมีฝาย ตัวอย่างระดับน้ำที่ไหลผ่านท่อดูดที่ตำแหน่ง 2+314.88 ในลำน้ำ MAERAI 2 LINE 1 (รูปที่ 6ข) แสดงให้เห็นถึงระยะทางของปรากฏการณ์น้ำย้อนไปทางด้านเหนือน้ำ โดยมีระยะทางที่ระดับน้ำย้อนกลับไป 93 เมตร และที่ตำแหน่ง 0+185.5 ในลำน้ำ MAERAI 3 LINE 1 (รูปที่ 6ค) มีระดับผิวน้ำสองกรณีต่างกัน 1.34 เมตร และมีความยาวระดับน้ำไหลย้อนไปเหนือน้ำ 125 เมตร



ก) ลำน้ำ MAERAI 1 LINE 1-4




ข) ลำน้ำ MAERAI 2 LINE 1



ค) ลำน้ำ MAERAI 3 LINE 1

รูปที่ 6 : ระดับน้ำกรณีมีและไม่มีสิ่งกีดขวาง




ง) ลำน้ำ MAERAI 4 LINE 1

รูปที่ 6 (ต่อ) : ระดับน้ำกรณีมีและไม่มีสิ่งกีดขวาง


3.4) ผลเปรียบเทียบระยะการท่วมกรณีมีและไม่มีสิ่งกีดขวางทางน้ำ

ผลการวิเคราะห์ระยะการท่วมกรณีมีและไม่มีสิ่งกีดขวางของลำน้ำ พบว่าเมื่อนำสิ่งกีดขวางออกจากลำน้ำส่งผลให้เกิดระยะการท่วมลดลงจากกรณีมีสิ่งกีดขวาง นั่นคือจากระยะการท่วมทั้งหมด 953.4 เมตร ลดลงเหลือ 580.59 เมตร โดยมีสิ่งกีดขวางหลักที่ทำให้เกิดน้ำท่วมอยู่ที่ตำแหน่ง 1+300 – 1+400 ในลำน้ำ MAERAI 2 LINE 1 ดังแสดงในรูปที่ 7 และ ตำแหน่ง 0+175 –

0+275 ที่ลำน้ำ MAERAI 4 LINE 1 ดังแสดงในรูปที่ 8 ภาพถ่ายจากดาวเทียมถูกนำมาใช้เพื่อแสดงให้เห็นตำแหน่งที่น้ำท่วมในลำน้ำห้วยไรทั้ง 7 สาย แสดงได้ดังรูปที่ 9 ซึ่งจะเห็นได้ว่าการท่วมเกิดขึ้นบริเวณที่เป็นชุมชนที่อยู่ท้ายน้ำมากกว่าบริเวณต้นน้ำที่เป็นพื้นที่เกษตรกรรม เนื่องจากลำน้ำที่ไหลผ่านชุมชนมีสิ่งกีดขวางทางน้ำประเภททอลอดเป็นหลัก ประกอบกับหน้าตัดลำน้ำบริเวณท้ายน้ำมีขนาดที่เล็กทำให้ไม่สามารถรองรับปริมาณน้ำ




ก) กรณีมีสิ่งกีดขวาง




ข) กรณีไม่มีสิ่งกีดขวาง

รูปที่ 7 : ตำแหน่งการท่วม ลำน้ำ MAERAI 2 LINE 1




ก) กรณีมีสิ่งกีดขวาง




ข) กรณีไม่มีสิ่งกีดขวาง

รูปที่ 8 : ตำแหน่งการท่วม ลำน้ำ MAERAI 4 LINE 1



ก) ตำแหน่งการท่วมกรณีมีสิ่งกีดขวางทางน้ำจากภาพถ่ายดาวเทียม



ข) ตำแหน่งการท่วมกรณีไม่มีสิ่งกีดขวางทางน้ำจากภาพถ่ายดาวเทียม

รูปที่ 9 : ภาพถ่ายดาวเทียมตำแหน่งที่น้ำท่วม

จากปัญหาของสิ่งกีดขวางที่กล่าวมา สามารถแสดงตำแหน่งของสิ่งกีดขวางที่ส่งผลกระทบต่อลำน้ำทั้งหมดได้ดังตารางที่ 3 ซึ่งพบว่าปัญหาส่วนใหญ่เกิดจากท่อดูดเป็นหลัก แนวทางในการแก้ปัญหาโดยภาพรวมควรทำการขุดลอกหรือนำสิ่งกีดขวางทางน้ำออกไป อย่างไรก็ตามจะเห็นได้จากรูปที่ 7ข และ 8ข ที่แสดงว่ายังคงมีการท่วมในลำน้ำถึงแม้ว่าจะนำสิ่งกีดขวางออกไป ดังนั้นมาตรการระยะยาวที่จำเป็นคือ การปรับเปลี่ยนหน้าตัดลำน้ำให้มีขนาดใหญ่ขึ้นเพื่อรองรับอัตราการไหลที่มากขึ้นได้

ตารางที่ 3 : ตำแหน่งและลักษณะของสิ่งกีดขวางทางน้ำที่ทำให้เกิดการท่วม

ลำน้ำ	ตำแหน่ง	ลักษณะ	พิกัด	
			N	E
MAERA1 LINE 1	0+989	ฝาย	2240551	588730.6
	1+277.05	ท่อดูด	2240404	588798.9
	1+409.41	ท่อดูด	2240276	588828.5
	2+314.88	ท่อดูด	2239772	589377.8
MAERA1 LINE 3	0+185.56	ท่อดูด	2241994	587414.9
MAERA1 LINE 4	0+284.86	ฝาย	2240629	589012.4

4) สรุปและอภิปรายผล

งานวิจัยนี้แสดงให้เห็นถึงผลกระทบของสิ่งกีดขวางทางน้ำที่มีผลต่อการเกิดน้ำท่วมในลำน้ำ เลือกลำน้ำห้วยแม่ไร่ซึ่งมีสิ่งกีดขวางทางน้ำประเภทฝายและท่อดูดอยู่จำนวนมากเพื่อทำการจำลองการไหลในลำน้ำด้วยแบบจำลอง HEC-RAS ทำการเปรียบเทียบแบบจำลองด้วยข้อมูลภาคสนามของระดับน้ำจำนวน 8 ตำแหน่ง โดยได้ค่าสัมประสิทธิ์ความขรุขระจากการเปรียบเทียบอยู่ที่ 0.028-0.033 ซึ่งค่าดังกล่าวจะถูกใช้เป็นตัวแทนความขรุขระของน้ำลักษณะเดียวกันในการจำลองการไหลที่ 3, 5, 10, 13 และ 23.34 ลบ.ม./วินาที ต่อไป

ผลการศึกษาชี้ให้เห็นถึงผลกระทบของฝายและท่อดูด 2 อย่าง ได้แก่

1. ผลกระทบที่เกิดขึ้นต่อระดับน้ำหน้าท่อดูดและฝาย เมื่อพิจารณาที่อัตราการไหลต่ำ ระดับน้ำหน้าท่อดูดจะมีระดับที่ต่ำ ในขณะที่ระดับน้ำหน้าฝายจะสูงเนื่องจากคุณสมบัติฝายที่ต้องการยกระดับน้ำขึ้น และที่อัตราการไหลสูง ระดับน้ำหน้าท่อดูดจะมีค่าสูงกว่าระดับน้ำหน้าฝายเนื่องจากข้อจำกัดของปริมาณน้ำที่สามารถไหลผ่านท่อดูดได้ ทำให้น้ำถูกยกระดับขึ้นจนกว่าจะไหลล้นสะพานหรือถนนที่อยู่บนท่อดูด ในขณะที่ระดับน้ำไหลผ่านฝายจะกระจายตัวเป็นบริเวณกว้างตามความยาวฝายทำให้ระดับน้ำไม่สูง

2. ผลกระทบที่เกิดขึ้นต่อระดับน้ำในลำน้ำและระยะน้ำท่วม โดยจะเห็นได้ว่าสิ่งกีดขวางทางน้ำเป็นหนึ่งในสาเหตุหลักที่ทำให้เกิดน้ำท่วมฉับพลัน เนื่องจากการมีสิ่งกีดขวางทางน้ำทำให้น้ำตัดทางน้ำลดขนาดลงหรือมีการยกระดับของผิวน้ำขึ้น ซึ่งระดับผิวน้ำที่สูงขึ้นมิได้เกิดเพียงบริเวณที่มีสิ่งกีดขวางเท่านั้นแต่จะขยายระยะไปยังด้านเหนือน้ำของสิ่งกีดขวางและไหลล้นตลิ่งออกสองข้างทาง

อย่างไรก็ตาม ผลการจำลองระดับน้ำและการท่วมฉับพลันของการไหลเมื่อไม่มีสิ่งกีดขวางก็ยังแสดงให้เห็นว่าปัญหาน้ำท่วมยังคงมีอยู่ ซึ่งปัญหาเหล่านี้มาจากสภาพหน้าตัดลำน้ำที่เล็กในบางช่วง ดังนั้นเพื่อให้สามารถแก้ปัญหาที่น้ำท่วมได้อย่างสมบูรณ์ควรมีการศึกษาแนวทางการแก้ไขปัญหาน้ำท่วมให้ครอบคลุมต่อไป

5) ข้อเสนอแนะ

1. งานวิจัยนี้ต้องการนำเสนอในเรื่องของผลกระทบของสิ่งกีดขวางทางน้ำต่อการเกิดน้ำท่วม ควรที่จะมีการศึกษาเพิ่มเติมในเรื่องการกัดเซาะตลิ่งน้ำเมื่อไม่มีสิ่งกีดขวางทางน้ำ ตลอดจน

แนวทางการแก้ไขปัญหาน้ำท่วมเพื่อให้เกิดประโยชน์ในการนำไปใช้งานมากขึ้น

2. สิ่งกีดขวางทางน้ำที่นำมาพิจารณาในการศึกษานี้ได้แก่ฝายและท่อลอดเท่านั้น งานในอนาคตควรทำการศึกษาปัจจัยของเศษวัสดุที่มาอุดตันทางน้ำหรือสิ่งกีดขวางประเภทอื่น ๆ เพิ่มขึ้น

3. เนื่องจากข้อจำกัดของข้อมูลทำให้ไม่สามารถวิเคราะห์การเกิดน้ำท่วมที่รอบปีการเกิดซ้ำอื่น ๆ ได้ ควรมีการศึกษาเพื่อสังเคราะห์ปริมาณน้ำหลากที่รอบปีการเกิดซ้ำอื่น ๆ และนำมาพิจารณาเพิ่มเติมได้จะเป็นประโยชน์เพิ่มขึ้น

กิตติกรรมประกาศ

ขอขอบคุณโครงการบริหารจัดการน้ำแบบบูรณาการกิจกรรมพัฒนาระบบสารสนเทศเตรียมความพร้อมเพื่อรับมือภัยพิบัติน้ำท่วมและดินถล่มจังหวัดเชียงราย ระยะที่ 1 ที่สนับสนุนข้อมูลที่ใช้ในการวิจัย

REFERENCES

- [1] Faculty of Engineering, "Integration of water resources management project: The development activities of information system for prepare to flood disaster and landslides in Chiang Rai Province," Chiang Mai Univ., Chiang Mai, Thailand, Final Rep., Mar. 2020.
- [2] Post Today. "Forest water floods villages in the area at Mae Chan District and Mae Sai District over 500 houses." (in Thai), POSTTODAY.com. <https://www.posttoday.com/social/local/456586> (accessed Oct. 15, 2021).
- [3] Thairath. "Heavy rain, forest water from Doi Tung floods 7 villages in Chiang Rai." (in Thai), THAIRATHONLINE.co.th. <https://www.thairath.co.th/news/local/north/1353969> (accessed Sep. 10, 2021).
- [4] HEC-RAS, *River Analysis System Hydraulic Reference Manual*, USACE, Davis, CA, USA, 2018.
- [5] S. Chuenchuoklin, "River analysis simulation model of main river and diversion channel planning for flood delineation: Case study for Pasak River, Phetchabun Province," (in Thai), *Naresuan Univ. Eng. J.*, vol. 1, no. 1, pp. 9–18, 2006.
- [6] P. Numkhang, "Analysis of Flow in Mae Klong River by HEC-RAS Model," (in Thai), B.E. thesis, Dept. Irrigation Eng., Kasetsart Univ., Nakhon Pathom, Thailand, 2007.
- [7] HEC-RAS *River Analysis System User's Manual Version 5.0*, USACE, Davis, CA, USA, 2016.
- [8] HEC-RAS, *River Analysis System Application Guide*, USACE, Davis, CA, USA, 2018.
- [9] HEC-RAS *River Analysis System, Hydraulics Reference Manual Version 4*, USACE, Davis, CA, USA, 2010.
- [10] J. E. Nash and J. V. Sutcliffe, "River flow forecasting through conceptual models; Part I-A discussion of principles," *J. Hydrol.*, vol. 10, no. 3, pp. 282–290, Apr. 1970, doi: 10.1016/0022-1694(70)90255-6.
- [11] D. N. Moriasi, J. G. Arnold, M. W. van Liew, R. L. Bingner, R. D. Harmel, and T. L. Veith, "Model evaluation guidelines for systematic quantification of accuracy in watershed simulations," *Trans. ASABE*, vol. 50, no. 3, pp. 885–900, 2007, doi: 10.13031/2013.23153.

Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System

Amonpan Chomklin^{1*} Nuttareepan Nittayoosakulchot²

^{1*}*Faculty of Information Technology, Thai-Nichi Institute of Technology, Bangkok, Thailand*

²*Developer, Lega Corporation Company Limited, Bangkok, Thailand*

*Corresponding Author. E-mail address: amonpan@tni.ac.th

Received: 16 August 2021; Revised: 4 October 2021; Accepted: 22 November 2021

Published online: 27 June 2022

Abstract

Today every country in the world faces a COVID-19 situation, making life different from daily life or work life. Therefore, organizations or companies adopt a primary diagnostic method for COVID-19 by having a system to scan an individual facial temperature using a thermal imaging camera to check if that person has initial symptoms of COVID-19 or not. This research focuses on the development of an attendance record system with a thermal imaging camera combination with Deep Learning to optimize the collection and processing of data to classify or identify employees precisely and reduce step to record the working hours of employees. The experiment found an average of face recognition the mean accuracy was 81.85%, and the mean processing time was 0.26 seconds. The research was satisfying when compared the research on the development of a time recording system with face detection and recognition using the Haar-Like Feature technique to detect faces and using the Local Binary Patterns Histogram to recognize faces with accurate of facial recognition at 48%. According to the experiment, the result was highly satisfying in terms of accurate data and processing time. Moreover, the developed system produces accurate and precise information with convenience and safety.

Keywords: Employee attendance system, Deep learning, Thermal imaging camera

I. INTRODUCTION

The coronavirus disease-2019 (COVID-19) pandemic [1] caused by the new coronavirus SARS-CoV-2, has spread around the globe with unprecedented consequences for the health of millions of people. While the pandemic is still in progress, with new incidents being reported every day, the resilience of the global society is constantly being challenged. Under these circumstances, the future seems uncertain. SARS-CoV-2 coronavirus has spread panic among civilians and insecurity at all socio-political and economic levels, dramatically disrupting everyday life, global economy, international travel and trade. The disease has also been linked to the onset of depression in many individuals due to the extreme restriction measures that have been taken for the prevention of the rapid spreading of COVID-19. In Thailand [2], Thai Ministry of Public Health announced on January 12, 2020, that a 61-year-old female tourist of Chinese nationality, domiciled in Wuhan, China, was infected with COVID-19. It was the first confirmed case outside China. As a result, the Thai government has declared a state of emergency in all local areas throughout the Kingdom. As a result, people have to change their way of life, work, and live in the New Normal style, which is caused by applying advice on preventing infection and spreading the infection to others in their daily lives. Wash hands when appropriate. Avoid unnecessary exposure and travel. Social distancing, wearing masks in public places, and checking body temperature in various places if any person whose temperature exceeds the standard value may risk developing a fever. A body temperature of more than 37.5 degrees Celsius is considered a person at risk of getting or transmitting the virus.

The spread of the COVID-19 virus in the world has urged governments to make rules to prevent the spread of the deadly virus, such as curfews, lockdowns,

and physical distancing measures in society (social distancing). The way to defeat the virus is to initially screen people who have a fever and show symptoms of COVID-19 or not. It will be isolated to prevent the spread of the virus. From such outbreaks Wearing a mask at all times in public and checking body temperature before entering the service is essential to prevent the spread. There are several methods for measuring body temperature. Depending on the equipment used, such as thermometers, digital thermometer, infrared body thermometer, or thermal imaging camera, etc., that depends on the company which type of equipment to use to be the most suitable.

In normal circumstances, the employee's working hours using the fingerprint scanning to the employee attendance system. But with the coronavirus outbreak, the company came up with the idea of using thermal imaging cameras to check if that person has initial symptoms of COVID-19 or not and apply the technology of thermal imaging cameras to record the working hours of employees to reduce the work process and provide accurate and precise information.

Presently, the 21st century is called the era of information technology where technological advances have made information, news, knowledge in various sciences and fields widely applied from the general public to industrial, social and economic levels, such as the introduction of face detection technology. It can be applied to personnel management, employee attendance record, or development of identity verification system for various documents such as fingerprints, car license plate inspection systems, and a face detection system to identify people identify people. By the way, face detection is a difficult and complicated method. But nowadays, methods for detecting faces in various programs have been developed to be more accurate and easier to use [3].

II. LITERATURE REVIEW

This section discusses the relevant knowledge of “Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System” and presenting relevant literature reviews.

A. Face Recognition

Facial recognition technology is a technology part of artificial intelligence technology that recognizes a person's facial features by taking image data to look for special effects, saving the information to a database, and then identifying the person through the comparison of facial data processing. Of the person recorded in the database. An example of the current face recognition technique and will be discussed is the Local Binary Pattern Histograms (LBPH) technique [4].

Local Binary Pattern Histograms (LBPH) recognition is a local binary pattern identification technique that is a technique for distinguishing patterns in images by applying the LBP values calculated in each pixel. Histogram for identifying special characteristics in the face. The work is divided into 2 steps as with Eigenfaces recognition: Pre-processing and testing procedures.

For the testing process in the Local Binary Pattern recognition technique, it takes the image to be tested to calculate the LBP value and divide the image into parts together with calculating the histogram of each area. Then, calculate the Chi-square between the images to be tested and every practice image.

B. Face Detection

Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System uses the Harr cascades. [5] face detection technique, a technique that has high face detection speed and accuracy compared to traditional face detection techniques. The concept of this technique is an examination of the pixel groups on images is similar to the Harr-like feature, as

illustrated in Figure 1, to determine whether the pixel group is a human face.




Figure 1: Harr-like feature

C. Deep Learning Model [6]

Deep Learning is an automated learning method that mimics the functions of the human neurons by bringing the neural network system overlaying multiple layers and learning sample data. It is used to detect the pattern or classify the data.

Generally, the neural network system only learns a few levels because there is no training data or not enough computer ability. However, over the years, technology has evolved more and more, making it easier and more accessible to the layers of the network. The more layers, the more complex and deeper the network becomes, which is the origin of the term “Deep Learning”. According to the model of Machine Learning, in general, when raw data is entered, it will not be processed automatically, but requires domain knowledge for a feature to categorize Hand-Craft Features. However, if it is deep learning, it receives raw data immediately and automatically processes it to obtain the sample data needed to detect patterns or categorize the data. The learning ability, automation features make Deep Learning very useful for use in

different situations. Challenges to be faced are finding suitable neural networks and finding variables affecting the network's training performance. It is still difficult to know what features Deep Learning can learn. In addition, Deep Learning is similar to machine learning, that is, it is unable to handle carefully crafted input, so it may lead to wrong inferences on the model.

From relevant studies found that Shireesha Chintalapati and M. V. Raghunadh [7] developed a system for checking enrollment students using face recognition techniques to identify and send a summary of attendance to the teacher's email at the end of the class. The operation of the system is initiated by taking each frame of the camera image and converting it to a black and white level to detect faces within the image. When a face image is obtained, it is memorized through histogram equalization process and resized to a size of 100 x 100 pixels, which is then used in the grouping process for identification purposes, with face recognition techniques. Eigenfaces recognition, Fisherface recognition and Local Binary Pattern Histogram recognition are available. The results of the experiments using the system showed that the Fisherface recognition technique was the most accurate for both still image and video identification with 95% and 78% accuracy, respectively. This research had problems with accuracy when used in rooms where the amount of light was not the same as in the recognition images, and there was no system for correcting the identification results because the results are sent to Email only at the end of the class.

J. Sanuksan and O. Surinta [8] examines a deep convolutional neural network (Deep CNN) for plant recognition in the natural environment. The primary objective was to compare 4 CNN architectures including LeNet-5, AlexNet, Google Net, and VGGNet on three plant datasets; PNE, 102 Flower, and Folio. The images in the PNE and 102 Flower datasets include a complicated background because they were taken in a natural environment. On the other hand, the images in the Folio dataset are only leaf images that were taken in a laboratory environment using a white background. The comparison of deep CNN using Google Net and VGGNet Architecture show that Google Net outperformed while working on the PNE and 102 Flower datasets when using a training time with iterations of 10,000 epochs. Google Net also faster than the VGGNet architecture. However, the experiment showed that the VGGNet architecture outperforms the other CNN architectures on the Folio dataset and used only 1,000 epochs for training. In our experiment, we can create a model from the deep CNN using Google Net architecture, and this is because it showed better results with the plant images that were taken in the natural environment.

III. RESEARCH METHODOLOGY

A. Theoretical framework

This section provides an overview of the function and design of "Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System" in Figure 2.




Figure 2: Theoretical framework

The framework consists of 3 modules as follows:

Part I: was the initial data preparation and recording process for a test on 20 employees, whose working principle was based on the Flowchart in Figure 3.

Part II: Design of Temperature Sensing Procedures and Facial Detection Processing. This research using the Haar cascade technique for verification as it is a highly accurate and less time-consuming technique, so it was suitable for real-time detection of human faces. When the detection system detected a human face, it would be framed by a developed system capable of simultaneously detecting multiple faces. The installed system with a thermal imaging camera was at the company's door and gate for one month for the temperature sensing and recognition processing and examining the results. The temperature sensing and recognition processing were held at the company's door and gate for a period of 1 month, based on the flowchart principle in Figure 4.



Figure 3: Flowchart for prepare and record data




Figure 4: Facial Recognition Processing




Figure 5: Attendance record system and display of employee attendance data

Part III: Face Recognition. The record-keeping to connect with attendance record system and display of employee attendance data. For recording data to connect to the attendance recording system, the data is stored in CSV format, where data was stored, which was displayed according to the Flowchart in Figure 5.

Analysis result or a design of the conceptual framework of “Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System” – the system divides its operations into 3 parts:

Part I: Training Dataset – Test of the 20 employees. First, encoded data and names of employees were keyed in and clicked the record button for taking five pictures of each employee. This research selected 1 to 5 pictures to represent one employee to find appropriate pictures for individual classification. Each picture contains a straight face picture, 15-degree left side face picture, 15-degree right side face picture, face down picture, and face-up picture.

They then conducted face detection from the pictures and training a face recognition model in Figure 6.




Figure 6: The screen shows the employee's input

As soon as the process of face encoding finished, all data were recorded in a database to prepare the data for face detection accordingly.

Part II: Face Detection – It is the process of searching for individual faces from pictures. An obtained face was processed for the following procedure to ensure the detected picture is easy to classify by using Haar Cascade algorithm since it has high accuracy and time spent on the processing is so tiny that it is suitable for real-time face detection. When the system detects a human face, a square will appear. The developed system can detect many humans faces at the same time. A thermal imaging camera is checking the results of temperature scanning and the recognition processing at the entry gate of the company for one month.

Temperature scans the face recognition processing starts from detecting face, measuring temperature on the face, processing face recognition results, checking face recognition accuracy, checking temperature, and recording data in the database. The researcher studied the working process of a thermal imaging camera and the process of face recognition. Therefore, the developed the script using Python language to communicate with the thermal imaging camera, acquired temperature values through protocol Modbus TCP of the camera, transferred pictures from the

thermal imaging camera in the form of visual image using protocol RTSP, and processed face recognition results from the original database in Figure 7.




Figure 7: Example of a screen for scan temperature and processing face recognition

Part III: Face recognition is when the detected faces are processed with LBPH algorithm and compared to the face database to identify that the detected face matches someone. For example, the system shall analyze the detected face while a person is walking past the camera. Compared the detected face to pictures stored in the existing database for data recording that connects to the employee time attendance system—stored the data in CSV files.

For connecting devices used with thermal imaging attendance systems, the following:

- 1) Thermal imaging camera
- 2) Gigabit PoE Injector
- 3) Ethernet cable M12 to RJ45
- 4) Ethernet cable
- 5) Jetson Nano
- 6) Monitor & HDMI Cable

The first step is to connect the thermal imaging camera to Gigabit PoE with Ethernet cable M12 to RJ45. After that, connect the Gigabit PoE and Jetson Nano with Ethernet cable and connect the HDMI cable to Jetson Nano and Monitor to display the image. Next, the plugged-in all devices of the system. The system

will start automatically. Then, the user can place the device in the correct position. Things to consider are the optimal distance for detecting human faces and the distance at which detect the temperature.

IV. RESULTS AND DISCUSSION

Based on “Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System” with LBPH algorithm, time spent on testing the system in conjunction with a thermal imaging camera was one month (20 working days) to ensure accuracy of collected data. The fastness and safety of face recognition and face recognition processing time among 20 employees. Data in CSV files for being processed accurately and precisely. The obtained data for other approach management. The research result can be summarized as follow Table 1:

Table 1: Average of accuracy and time spent to processing

Average Data	Accuracy	Time processing
Dataset1	83.51	0.25
Dataset2	80.46	0.26
Dataset3	81.84	0.31
Dataset4	80.29	0.27
Dataset5	81.54	0.26
Dataset6	82.41	0.26
Dataset7	81.93	0.26
Dataset8	82.19	0.27
Dataset9	81.24	0.25
Dataset10	82.07	0.25
Dataset11	81.25	0.24
Dataset12	82.34	0.25
Dataset13	82.23	0.23

Table 1: Average of accuracy and time spent to processing (cont.)

Average Data	Accuracy	Time processing
Dataset14	80.88	0.29
Dataset15	81.67	0.25
Dataset16	83.24	0.23
Dataset17	81.20	0.28
Dataset18	82.47	0.29
Dataset19	81.77	0.23
Dataset20	82.54	0.24
Grand Total	81.85	0.26

Meanwhile, the LBPH is the most accurate algorithm in the acceptance criteria compared to the time spent on the processing. It will test the system with 20 employees and compare the results each week, various 100,200,300 and 400 data processing. The total data of one month (20 business days) to test the system within Table 2.

Table 2: The table present the time processing times and data accuracy

Week	Data Processing	LBPH	
		Data Accuracy	Time Processing
1	100	82.06	0.26
2	200	81.52	0.25
3	300	81.37	0.26
4	400	82.49	0.25
Average		81.85	0.26

The experimental result based on collecting data of face recognition accuracy using the LBPH algorithm found that accuracy values ranged from 80-85%, as shown in Figure 8 and Figure 9:




Figure 8: Data accuracy of LBPH algorithm




Figure 9: Average data accuracy of LBPH algorithm

Moreover, the experimental result found that the time spent on the processing ranged from 0.1 to 0.4 seconds per 1 time of face processing, as shown in Figure 10 and Figure 11:




Figure 10: Time processing of LBPH algorithm




Figure 11: Average time processing face recognition of LBPH algorithm

A one-month trial to determine the mean accuracy of facial recognition using LBPH technique with 20 employees found that the mean accuracy of LBPH technique was 81.86 percent and the average processing time is 0.25 seconds, which compatible the paper of Attendance monitoring system with face recognition technologies [9] has been proposed to improve the accuracy of face detection and solve the conventional problems. The experiments were conducted on the accuracy of Eigenface recognition, Fisherface recognition, and Local Binary Pattern Histogram (LBPH) recognition to select the best face recognition technology for the proposed system. Experimental results show that LBPH recognition has the highest accuracy of 94.21%.

V. CONCLUSION

From the research “Using Deep Learning with Thermal Imaging Camera to Record Employee Attendance System” time spent on processing and data accuracy working with a thermal imaging camera, the LBPH algorithm used with the thermal imaging camera.

In terms of time processing and accuracy suitable for working with a thermal imaging camera, it is found that LBPH algorithm used with the thermal imaging camera enables the system to be convenient, fast and safe. The obtained data are accurate and precise.

Employees could check data in real time. The system gains more efficiency and is convenient for searching for data and checking time attendance statistics, helping reduce errors and delay and helping solve problems related to an increase in the number of documents [3]. Meanwhile, LBPH algorithm is advantageous as it withstands changes in levels of illumination and it is the most accurate algorithm [10]. Based on this study, LBPH algorithm is considered the most accurate algorithm in the acceptance criteria when compared to the time spent on the processing.

Regarding time processing and accuracy, this research is suitable for working with a thermal imaging camera using the LBPH algorithm to develop record employee attendance system using temperature and face recognition using a thermal imaging camera—advantage in terms of time spent on processing and ability to withstand changes in levels of illumination. However, in the light coming in different positions, it will decrease facial recognition accuracy. Therefore, it is necessary to develop the process of making a picture database to increase the algorithm's efficiency for being used in an actual situation accordingly.

This research uses the FLIR thermal imaging camera model AX8, a relatively inexpensive thermal imaging camera, easy to use, and a protocol to connect to system development with Python language. In the

market with a high resolution and frame rate, when applying the technique of Face detection and Face recognition to process with the thermal imaging camera, it has been chosen. The results in processing results that for specific applications. If choosing to use other thermal imaging cameras with higher resolution and frame rate, appropriate use may vary. Therefore, in order to find suitable techniques for other devices, it is best to compare techniques. To find the efficiency of the processing time and additional accuracy values to verify that the results are suitable and within the recipient criteria.

Moreover, for the techniques in this research, users want a system that can be processed quickly. The accuracy is within acceptable criteria. Choose to consider using the LBPH technique in system development based on the results from the research. The choice of technique depends on the purpose for which the system is in the future.

REFERENCES

- [1] V. Zoumpourlis, M. Goulielmaki, E. Rizos, S. Baliou, and D. Spandidos, "The COVID-19 pandemic as a scientific and social challenge in the 21st century," *Mol. Med. Rep.*, vol. 22, no. 4, pp. 3035–3048, Oct. 2020, doi: 10.3892/mmr.2020.11393.
- [2] J. Sricham. "The day that Thailand knows COVID-19." (in Thai), THAIPBS.com. <https://news.thaipbs.or.th/content/290347> (accessed Sep. 9, 2020).
- [3] W. Yawai, K. Sirijinda, and P. Banjongrot, "Mobile application for time attendance system using facial recognition," *J. Project Comp. Sci. Inf. Technol.*, vol. 4, no. 1, pp. 29–36, 2018.
- [4] T. Ahonen, A. Hadid, and M. Pietikainen, "Face description with local binary patterns: Application to face recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 28, no. 12, pp. 2037–2041, 2006, doi: 10.1109/TPAMI.2006.244.
- [5] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," in *Proc. IEEE Comput. Soc. Conf. Comput. Vis. and Pattern Recognit.*, Kauai, HI, USA, 2001, pp. I-511–I-518, doi: 10.1109/CVPR.2001.990517.
- [6] D. Sheel. "What is Deep Learning?." NEW.ABB.com. <https://new.abb.com/news/detail/58004/deep-learning> (accessed Sep. 11, 2020).
- [7] S. Chintalapati and M. V. Raghunadh, "Automated attendance management system based on face recognition algorithms," in *IEEE Int. Conf. Comp. Intell. and Comp. Res.*, Enathi, India, Dec. 2013, pp. 1–5, doi: 10.1109/ICCIC.2013.6724266.
- [8] J. Sanuksan and O. Surinta, "Deep convolutional neural networks for plant recognition in natural environment," (in Thai), *J. Sci. Technol. Mahasarakham Univ.*, vol. 38, no. 2, pp. 113–124, 2019.
- [9] K. Treeprapin, P. Na-udom, and P. Kongchai, "Developing a system to verify student enrollment with facial recognition method," (in Thai), *J. Sci. Technol., Ubon Ratchathani Univ.*, vol. 20, no. 2, pp. 92–105, 2018.
- [10] P. Jaturawat, P. Pongmanawut, and M. Phankokkrud, "Development of a learning record system with face detection and recognition," (in Thai), *KMITL J. Inf. Technol.*, vol. 5, no. 1, pp. 1–11, 2017.

คำแนะนำสำหรับผู้เขียนบทความเพื่อลงตีพิมพ์

วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล เป็นวารสารวิชาการทางด้านวิศวกรรมศาสตร์และเทคโนโลยี ของสถาบันเทคโนโลยีไทย-ญี่ปุ่น บทความที่นำเสนอจะต้องพิมพ์เป็นภาษาไทย หรือภาษาอังกฤษตามรูปแบบที่กำหนด และพร้อมที่จะนำไปตีพิมพ์ได้ทันที การเสนอบทความเพื่อพิจารณาตีพิมพ์ในวารสาร มีรายละเอียดดังนี้

1. หลักเกณฑ์การพิจารณาบทความเพื่อตีพิมพ์

1.1 เป็นบทความที่ไม่ได้อยู่ระหว่างการพิจารณาตีพิมพ์ หรือไม่ได้อยู่ระหว่างการพิจารณาของสื่อสิ่งพิมพ์อื่น ๆ และไม่เคยตีพิมพ์ในวารสารหรือรายงานการสืบเนื่องจากการประชุมวิชาการใดมาก่อนทั้งในประเทศและต่างประเทศ หากตรวจสอบพบว่ามีงานตีพิมพ์ซ้ำซ้อน ถือเป็นความรับผิดชอบของผู้เขียนแต่เพียงผู้เดียว

1.2 เป็นบทความที่แสดงให้เห็นถึงความคิดริเริ่มสร้างสรรค์ มีคุณค่าทางวิชาการ มีความสมบูรณ์ของเนื้อหา และมีความถูกต้องตามหลักวิชาการ

1.3 บทความที่ได้รับการตีพิมพ์จะต้องผ่านการประเมินคุณภาพจากผู้ทรงคุณวุฒิ (Peer reviewer) อย่างน้อย 2 ท่านต่อบทความ ซึ่งผู้ทรงคุณวุฒิอาจให้ผู้เขียนแก้ไขเพิ่มเติมหรือปรับปรุงบทความให้เหมาะสมยิ่งขึ้น

1.4 กองบรรณาธิการขอสงวนสิทธิ์ในการตรวจแก้ไขรูปแบบบทความที่ส่งมาตีพิมพ์ตามที่เห็นสมควร

1.5 บทความ ข้อความ ภาพประกอบ และตารางประกอบ ที่ตีพิมพ์ลงวารสารเป็นความคิดเห็นส่วนตัวของผู้เขียน กองบรรณาธิการไม่มีส่วนรับผิดชอบใด ๆ ถือเป็นความรับผิดชอบของผู้เขียนแต่เพียงผู้เดียว

1.6 ต้องเป็นบทความที่ไม่ละเมิดลิขสิทธิ์ ไม่ลอกเลียน หรือคัดลอกข้อความของผู้อื่นโดยไม่ได้รับอนุญาต

1.7 หากเป็นงานแปลหรือเรียบเรียงจากภาษาต่างประเทศ ต้องมีหลักฐานการอนุญาตให้ตีพิมพ์เป็นลายลักษณ์อักษรจากเจ้าของลิขสิทธิ์

1.8 ต้องมีการอ้างอิงที่ถูกต้อง เหมาะสมก่อนการตีพิมพ์ ซึ่งเป็นความรับผิดชอบของเจ้าของผลงาน

1.9 บทความที่ส่งถึงกองบรรณาธิการ ขอสงวนสิทธิ์ที่จะไม่ส่งคืนผู้เขียน

2. รูปแบบการกลั่นกรองบทความก่อนลงตีพิมพ์ (Peer-review)

ในการประเมินบทความโดยผู้ทรงคุณวุฒิเป็นการประเมินแบบ Double-blind peer review คือ ผู้ทรงคุณวุฒิไม่ทราบชื่อและรายละเอียดของผู้เขียนบทความ และผู้เขียนบทความไม่ทราบชื่อและรายละเอียดของผู้ทรงคุณวุฒิ

3. ประเภทของบทความที่รับพิจารณาตีพิมพ์

นิพนธ์ต้นฉบับต้องเป็นบทความวิจัย ประกอบด้วย บทคัดย่อ บทนำ วัตถุประสงค์ของการวิจัย วิธีดำเนินการวิจัย ผลการวิจัย สรุปและอภิปรายผล และเอกสารอ้างอิง

หมายเหตุ : บทความภาษาไทยต้องมีบทคัดย่อภาษาไทยและภาษาอังกฤษ โดยให้หน้าบทคัดย่อภาษาไทยอยู่ก่อนหน้าบทคัดย่อภาษาอังกฤษ สำหรับบทความภาษาอังกฤษไม่ต้องมีบทคัดย่อภาษาไทย

* เอกสารอ้างอิง เป็นการบอกรายการแหล่งอ้างอิงที่มีการอ้างอิงในเนื้อหาของงานเขียน

4. จริยธรรมในการตีพิมพ์ผลงานวิจัยในวารสารวิชาการ

วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล ได้คำนึงถึงจริยธรรมในการตีพิมพ์บทความ โดยจริยธรรมและบทบาทหน้าที่ของผู้เกี่ยวข้อง มีดังนี้

จริยธรรมและหน้าที่ของผู้เขียน

1. ผู้เขียนต้องเขียนบทความให้เป็นไปตามรูปแบบที่วารสารกำหนดไว้ในคำแนะนำสำหรับผู้เขียน
2. หากมีการนำข้อมูลของผู้อื่นหรือข้อมูลของผู้เขียนที่เคยตีพิมพ์ในวารสารฉบับอื่นมาใช้ ผู้เขียนต้องอ้างอิงแหล่งที่มาของข้อมูลนั้น โดยไม่ทำให้ผู้อื่นเข้าใจผิดว่าข้อมูลนั้นเป็นผลงานใหม่ของผู้เขียน
3. ผู้เขียนต้องไม่ดัดแปลงหรือบิดเบือนข้อมูล
4. ผู้เขียนต้องระบุแหล่งทุนที่สนับสนุนในการทำวิจัย (ถ้ามี)
5. ผู้เขียนต้องเปิดเผยข้อมูลเกี่ยวกับผลประโยชน์ทับซ้อนอย่างชัดเจน (ถ้ามี)

จริยธรรมและหน้าที่ของบรรณาธิการ

1. บรรณาธิการต้องดำเนินการเผยแพร่วารสารให้ตรงตามเวลา
2. บรรณาธิการต้องคัดเลือกบทความ โดยพิจารณาจากคุณภาพและความสอดคล้องของเนื้อหาบทความกับขอบเขตของวารสาร
3. บรรณาธิการต้องดำเนินการประเมินบทความอย่างเป็นธรรม ไม่ปฏิเสธการตีพิมพ์บทความโดยใช้อคติ
4. บรรณาธิการต้องไม่เปิดเผยข้อมูลของผู้เขียนบทความ และผู้ประเมินบทความแก่บุคคลอื่นที่ไม่เกี่ยวข้อง
5. บรรณาธิการต้องไม่มีผลประโยชน์ทับซ้อนกับผู้เขียน และผู้ประเมินบทความ
6. บรรณาธิการต้องใช้โปรแกรมในการตรวจสอบการคัดลอกผลงาน เพื่อป้องกันการตีพิมพ์ผลงานซึ่งคัดลอกมาจากผลงานผู้อื่น หากพบการคัดลอกผลงานของผู้อื่น บรรณาธิการต้องหยุดกระบวนการพิจารณาบทความทันที และติดต่อผู้เขียนเพื่อขอคำชี้แจง

จริยธรรมและหน้าที่ของผู้ประเมินบทความ

1. ผู้ประเมินบทความ ควรพิจารณาตอบรับการประเมินเฉพาะบทความที่สอดคล้องกับความเชี่ยวชาญของตนเองเท่านั้น เพื่อให้บทความที่ตีพิมพ์มีคุณภาพ
2. ผู้ประเมินบทความควรประเมินบทความให้แล้วเสร็จตามระยะเวลาที่กำหนด เพื่อไม่ให้บทความที่ผ่านการพิจารณาตีพิมพ์ล่าช้า
3. ผู้ประเมินควรประเมินบทความโดยให้ข้อเสนอแนะตามหลักวิชาการเท่านั้น ไม่ควรใช้ความคิดเห็นส่วนตัวที่ไม่มีเหตุผลหรือไม่มีข้อมูลรองรับ
4. ผู้ประเมินควรปฏิเสธการประเมินบทความ หากเห็นว่าตนเองอาจมีผลประโยชน์ทับซ้อนกับผู้เขียน
5. ผู้ประเมินต้องไม่เปิดเผยเนื้อหาภายในบทความให้ผู้ที่ไม่เกี่ยวข้องทราบ
6. หากผู้ประเมินเห็นว่ามีความเห็นที่ผู้เขียนไม่ได้กล่าวอ้างถึง แต่เป็นบทความที่สำคัญและเกี่ยวข้องกับบทความ ผู้ประเมินควรแจ้งให้ผู้เขียนกล่าวอ้างถึงบทความนั้น

5. ข้อกำหนดการจัดพิมพ์ต้นฉบับบทความ

ผู้เขียนต้องจัดพิมพ์บทความตามข้อกำหนดเพื่อให้มีรูปแบบการตีพิมพ์เป็นมาตรฐานแบบเดียวกัน ดังนี้

5.1 ขนาดของกระดาษ ให้ใช้ขนาด A4

5.2 กรอบของข้อความ ระยะห่างของขอบกระดาษ

ด้านบน 2.5 ซม. (0.98")

ด้านล่าง 2 ซม. (0.79")

ด้านซ้าย 2 ซม. (0.79")

ด้านขวา 2 ซม. (0.79")

5.3 ระยะห่างระหว่างบรรทัด หนึ่งช่วงบรรทัดของเครื่องคอมพิวเตอร์ (Single)

5.4 ตัวอักษร รูปแบบของตัวอักษรให้ใช้ TH Sarabun New

5.5 รายละเอียดต่าง ๆ ของบทความ กำหนดดังนี้

ชื่อเรื่อง (Title) ขนาด 22 ตัวหนา กำหนดกึ่งกลาง

ชื่อผู้เขียน (Author) ขนาด 16 ตัวธรรมดา กำหนดกึ่งกลาง ไม่ต้องใส่คำนำหน้า

ที่ติดต่อผู้เขียน ขนาด 14 ตัวเอน กำหนดกึ่งกลาง

E-mail ผู้นิพนธ์ประสานงาน ขนาด 12 ตัวธรรมดา กำหนดกึ่งกลาง

บทคัดย่อ (Abstract) จัดรูปแบบการพิมพ์เป็นแบบ 1 คอลัมน์ ชื่อหัวข้อ ขนาด 14 **ตัวหนาและเอน** กำหนดกึ่งกลาง ข้อความในบทคัดย่อ ขนาด 14 ตัวธรรมดา

คำสำคัญ (Keywords) ให้ใส่คำสำคัญ 4-5 คำ ซึ่งเกี่ยวข้องกับบทความที่นำเสนอ โดยให้จัดพิมพ์ได้บทคัดย่อ ขนาด 12 **ตัวหนาและเอน** กำหนดชิดซ้าย ข้อความในคำสำคัญ ขนาด 12 ตัวธรรมดา

รูปแบบการพิมพ์เนื้อหาของบทความ

- รูปแบบการพิมพ์เป็นแบบ 2 คอลัมน์ แต่ละคอลัมน์ กว้าง 8.2 ซม. (3.23") ระยะห่างระหว่างคอลัมน์ 0.6 ซม. (0.24")

- หัวข้อหลัก ประกอบด้วย บทนำ (INTRODUCTION) วัตถุประสงค์ของการวิจัย (OBJECTIVES) วิธีดำเนินการวิจัย (METHODS) ผลการวิจัย (RESULTS) สรุปและอภิปรายผล (CONCLUSIONS AND DISCUSSION) เอกสารอ้างอิง (REFERENCES) ขนาด 14 ตัวธรรมดา กำหนดกึ่งกลาง และมีเลขกำกับ เช่น 1) บทนำ และ I. INTRODUCTION เป็นต้น

- หัวข้อรอง ระดับที่ 1 ขนาด 14 ตัวเอน กำหนดชิดซ้าย

- หัวข้อรอง ระดับที่ 2 ขนาด 14 ตัวเอน กำหนดชิดซ้ายและเลื่อนเข้ามา 0.5 cm

- เนื้อเรื่อง ขนาด 14 ตัวธรรมดา

- ชื่อตาราง ขนาด 12 ตัวธรรมดา กำหนดกึ่งกลาง และใส่ชื่อเหนือตาราง

- หัวข้อในตาราง ขนาด 12 ตัวหนา กำหนดกึ่งกลาง เนื้อหาในตาราง ขนาด 12 ตัวธรรมดา

- ชื่อภาพประกอบ ขนาด 12 ตัวธรรมดา กำหนดกึ่งกลาง และใส่ชื่อใต้ภาพ

- เนื้อหาในภาพประกอบ ขนาด 12 ตัวธรรมดา

วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล

ปีที่ 10 ฉบับที่ 1 มกราคม – มิถุนายน 2565

5.6 เอกสารอ้างอิง

1. การอ้างอิงในเนื้อหาบทความใช้การอ้างอิงแบบตัวเลข ตามมาตรฐานสากล โดยใช้หมายเลขในเครื่องหมายก้ามปู [] และเรียงลำดับการอ้างอิงตามเนื้อหา โดยมีตัวอย่างการเขียน เช่น [1] หรือ [2] หรือ [1], [2] หรือ [1], [3]–[8] หรือ [9], [10], [15], [16] หากมีการอ้างอิงซ้ำบทความเดิมให้ใช้หมายเลขเดิม ตัวอย่างเช่น by Brown [4], [5]; as mentioned earlier [2], [4]–[7], [9]; Smith [4] and Brown and Jones [5]; Wood *et al.* [7]
2. รูปแบบของชื่อหัวข้อใช้รูปแบบตัวอักษร TH Sarabun New ขนาด 14 ตัวธรรมดา ในเนื้อหาขนาด 12 ตัวธรรมดา
3. การอ้างอิงท้ายบทความ จะต้องเรียงตามลำดับบทความที่เขียนอ้างอิงในเนื้อเรื่อง และใช้การอ้างอิงตามรูปแบบการอ้างอิง IEEE ซึ่งผู้เขียนสามารถศึกษาวิธีการเขียนเอกสารอ้างอิงตามรูปแบบที่กำหนดได้ที่ <http://journals.ieeeauthorcenter.ieee.org/wp-content/uploads/sites/7/IEEE-Reference-Guide.pdf> โดยจะต้องเขียนเป็นภาษาอังกฤษเท่านั้น หากบทความอ้างอิงมาจากบทความภาษาไทย ต้องแปลเป็นภาษาอังกฤษให้ถูกต้อง
4. กรณีที่เอกสารที่นำมาอ้างอิงเขียนเป็นภาษาไทยให้เติมคำว่า “(in Thai)” เข้าไปในเอกสารอ้างอิง ดังเช่นตัวอย่างต่อไปนี้

ตัวอย่างการแปลเอกสารอ้างอิงภาษาไทยเป็นภาษาอังกฤษ

ตัวอย่างที่ 1 การอ้างอิงจากหนังสือ(Books)

Basic Format:

- [Number] J. K. Author, *Title of His Published Book*, xth ed. City of Publisher, State (only U.S.), Country: Abbrev. of Publisher, year.
- [Number] J. K. Author, “Title of chapter in the book,” in *Title of His Published Book*, xth ed. City of Publisher, State (only U.S.), Country: Abbrev. of Publisher, year, ch. x, sec. x, pp. xxx–xxx.

Examples:

- [1] V. Rijiravanich, *Work study: principles and case studies*, 4th ed. Bangkok, Thailand: Chulalongkorn University Press (in Thai), 2005.
- [1] วันชัย ริจิรวนิช, *การศึกษาการทำงาน: หลักการและกรณีศึกษา*, พิมพ์ครั้งที่ 4, กรุงเทพฯ, ประเทศไทย: สำนักพิมพ์จุฬาลงกรณ์มหาวิทยาลัย, 2548.

ตัวอย่างที่ 2 การอ้างอิงจากวารสาร (Periodicals)

Basic Format:

- [Number] J. K. Author, “Name of paper,” *Abbrev. Title of Periodical*, vol. x, no. x, pp. xxx–xxx, Abbrev. Month, year.

Examples:

- [2] N. Dechampai and K. Sethanan, “An application of lean manufacturing system in the textile of lean manufacturing system in the textile and garment industry case study: Wacoal Kabinburi Co., Ltd,” (in Thai), *MBA-KKU Journal*, vol. 7, no. 2, pp. 13–27, 2014.
- [2] นิวัฒน์ เดชอำไพ และกาญจนา เศรษฐนันท์, “การเพิ่มประสิทธิภาพกระบวนการผลิตชุดชั้นในสตรีโดยประยุกต์ใช้แนวคิดการผลิตแบบลีน,” *วารสารวิทยาลัยบัณฑิตศึกษาการจัดการมหาวิทยาลัยขอนแก่น*, ปีที่ 7, ฉบับที่ 2, หน้า 13–27, 2557.

ตัวอย่างที่ 3 การอ้างอิงจากการประชุมทางวิชาการ (Conferences and Conference Proceedings)

Basic Format:

- [Number] J. K. Author, “Title of paper,” in *Abbrev. Name of Conf.*, City, State (only U.S.), Country, Month and day(s), year, pp. xxx–xxx.

Examples:

- [3] N. Kriengkorakot, P. Kriengkorakot, S. Duan P. Thung, and W. Piromsuk, “Repair work reduction in sewing process of the apparel factory,” (in Thai), in *Proc. 10th Ubon Ratchathani Univ. Nat. Res. Conf.*, Ubon Ratchathani, Thailand, Jul. 7-8, 2016, pp. 87–96.
- [3] นุชสรา เกรียงกรกฎ, ปรีชา เกรียงกรกฎ, สกาวเดือน พรหมทุ่ง และวิจิตรา ภิรมย์สุข, “งานวิจัยการลดชิ้นส่วนงานซ่อมในขั้นตอนการเย็บของโรงงานผลิตเสื้อผ้าสำเร็จรูป,” *การประชุมวิชาการระดับชาติ มอบ. วิจัยครั้งที่ 10*, อุบลราชธานี, ประเทศไทย, 7-8 กรกฎาคม, 2559, หน้า 87–96.

6. วิธีการจัดส่งบทความ

ผู้เขียนส่งบทความออนไลน์ได้ที่ <https://ph01.tci-thaijo.org/index.php/TNIJournal>

เมื่อกองบรรณาธิการได้รับบทความจะดำเนินการส่งบทความเสนอผู้ทรงคุณวุฒิพิจารณาบทความและแจ้งผลการพิจารณาให้ผู้เขียนบทความทราบ สำหรับบทความที่ผ่านการประเมินโดยผู้ทรงคุณวุฒิแล้วจะได้รับการตีพิมพ์ลงในวารสารเพื่อเผยแพร่ต่อไป

วารสารวิศวกรรมศาสตร์และเทคโนโลยีดิจิทัล

ปีที่ 10 ฉบับที่ 1 มกราคม – มิถุนายน 2565

“สร้างนักคิด ผลิตนักปฏิบัติ สร้างนักประดิษฐ์ ผลิตนักบริหาร”

คณะวิศวกรรมศาสตร์

หลักสูตรระดับปริญญาตรี

- หลักสูตรวิศวกรรมยานยนต์ (Automotive Engineering, B.Eng. : AE)
- หลักสูตรวิศวกรรมหุ่นยนต์และระบบอัตโนมัติแบบลีน (Robotics and Lean Automation Engineering, B.Eng. : RE)
- หลักสูตรวิศวกรรมคอมพิวเตอร์และปัญญาประดิษฐ์ (Computer Engineering and Artificial Intelligence, B.Eng. : CE)
- หลักสูตรวิศวกรรมอุตสาหกรรม (Industrial Engineering, B.Eng. : IE)
- หลักสูตรวิศวกรรมไฟฟ้า (Electrical Engineering, B.Eng. : EE)

หลักสูตรระดับปริญญาโท

- หลักสูตรเทคโนโลยีวิศวกรรม (Engineering Technology, M.Eng. : MET)

คณะเทคโนโลยีสารสนเทศ

หลักสูตรระดับปริญญาตรี

- หลักสูตรเทคโนโลยีสารสนเทศ (Information Technology, B.Sc. : IT)
- หลักสูตรเทคโนโลยีมัลติมีเดีย (Multimedia Technology, B.Sc. : MT)
- หลักสูตรเทคโนโลยีสารสนเทศทางธุรกิจ (Business Information Technology, B.Sc. : BI)
- หลักสูตรเทคโนโลยีดิจิทัลทางสื่อสารมวลชน (Digital Technology in Mass Communication, B.Sc. : DC)

หลักสูตรระดับปริญญาโท

- หลักสูตรเทคโนโลยีสารสนเทศ (Information Technology, M.Sc. : MIT)

คณะบริหารธุรกิจ

หลักสูตรระดับปริญญาตรี

- หลักสูตรการจัดการเทคโนโลยีและนวัตกรรม (Management of Technology and Innovation, B.B.A. : MI)
- หลักสูตรบริหารธุรกิจญี่ปุ่น (Japanese Business Administration, B.B.A. : BJ)
- หลักสูตรการจัดการธุรกิจระหว่างประเทศ (International Business Management, B.B.A. : IB)
- หลักสูตรการบัญชี (Accountancy, B.Acc. : AC)
- หลักสูตรการจัดการทรัพยากรมนุษย์แบบญี่ปุ่น (Japanese Human Resources Management, B.B.A. : HR)
- หลักสูตรการจัดการโลจิสติกส์และโซ่อุปทาน (Logistics and Supply Chain Management, B.B.A. : LM)
- หลักสูตรการตลาดดิจิทัล (Digital Marketing, B.B.A. : DM)
- หลักสูตรการจัดการการท่องเที่ยวและการบริการเชิงนวัตกรรม (Innovative Tourism and Hospitality Management, B.B.A. : TH)

หลักสูตรระดับปริญญาโท

- หลักสูตรบริหารธุรกิจญี่ปุ่น (Japanese Business Administration, M.B.A. : MBJ)
- หลักสูตรนวัตกรรมจัดการธุรกิจและอุตสาหกรรม (Innovation of Business and Industrial Management, M.B.A. : MBI)
 - กลุ่มวิชา การวางแผนกลยุทธ์สำหรับผู้ประกอบการ (Strategic Planning and Management Entrepreneur : SME)
 - กลุ่มวิชา การจัดการระบบการผลิต และโลจิสติกส์แบบลีน (Lean Manufacturing System and Logistics Management : LMS)

Thai-Nichi International College (TNIC)

Bachelor's Degree Programs

- Digital Engineering (DGE)
- Data Science and Analytics (DSA)
- Global Business Management (GBM)
- Japanese for International Business (JIB)

Thai-Nichi Institute of Technology

1771/1 Pattanakarn Road, Suanluang, Bangkok 10250, Thailand

Tel: 0-2763-2600 Fax: 0-2763-2700

Website: <https://ph01.tci-thaijo.org/index.php/TNIJournal> E-mail: JEDT@tni.ac.th