

JOURNAL OF

INFORMATION SCIENCE AND TECHNOLOGY

JIST

ISSN: 1906-9553 (Print)

ISSN: 2651-1053 (Online)

Volume 12. No.1

January - June 2022

## Research Papers

|                                                                                                                                                                         |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| การค้นหากฎความสัมพันธ์และวิเคราะห์ข้อมูลเพื่อเพิ่มประสิทธิภาพการขายอาหารญี่ปุ่น.....1<br>นรินทร์ จิวัฒน์                                                                | 1  |
| การพยากรณ์ปริมาณน้ำฝนระยะสั้นในบริเวณพื้นที่สนามบินสุวรรณภูมิด้วยโครงข่ายประสาทแบบย้อนกลับ.....13<br>รักษัศณา ภูสีเชียว และ สุรณพรีร์ ภูมิวุฒิสาริ                      | 13 |
| แบบจำลองการเรียนรู้ท่าทางมนุษย์จากการเคลื่อนไหวด้วยเทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการ<br>และแบบหน่วยความจำระยะสั้นแบบยาว.....27<br>นัศพัชาณัณ ชินปัญชณะ            | 27 |
| โมบายแอปพลิเคชันสำหรับจำแนกสายพันธุ์นกด้วยวิธีการเรียนรู้เชิงลึก.....37<br>ภูมิภักดี พรหมรังกา, สหรัฐ หวานทอง และ ชูพันธุ์ รัตนโกคา                                     | 37 |
| อัลกอริธึมการเรียนรู้ของเครื่องสำหรับการทำนายการคัดแยกผู้ป่วย COVID-19.....47<br>ศิวกร บรรลือทรัพย์ และ วรภาพ จิระพันธุ์ทอง                                             | 47 |
| ระบบวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ.....61<br>เอกรัตน์ สุขสุคนธ์, ชลทิศ สันติวงคังาม, วุชรพล คำแขก และ ศศิชา ปานสุวรรณ                               | 61 |
| แนวทางการออกแบบคู่มือสื่ออารมณ์ที่เป็นมิตรต่อผู้สูงอายุ.....67<br>ภริติพร เลิศรัตนเดชากุล, คณาภาณูจน์ รักไพฑูริย์ และ เกษม ทิพย์ธารัจนัทร                               | 67 |
| การพัฒนาแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว.....81<br>นาถิ เอื้องแสงพระจันทร, ณัฏฐาณิ ศรีวิบูลย์, เจษฎา สิงห์ทองชัย และ อัจฉรา สุ่มเกษตร | 81 |



# JOURNAL OF INFORMATION SCIENCE AND TECHNOLOGY (JIST)

ISSN 2651-1053 (Online), ISSN 1906-9553 (Print)

The Journal of Information Science and Technology (JIST) is an academic journal established by the collaboration of 21 faculties that conduct courses related to Information Technology, namely, Bangkok University, Dhurakij Pundit University, King Mongkut's Institute of Technology Ladkrabang, King Mongkut's University of Technology North Bangkok, King Mongkut's University of Technology Thonburi, Mae Fah Luang University, Mahanakorn University of Technology, Mahasarakham University, Mahidol University, Nakhon Phanom University, Panyapiwat Institute of Management, Prince of Songkla University, Rangsit University, Siam University, Silpakorn University, Sripatum University, Thai-Nichi Institute of Technology, Walailak University, Burapha University, Phayao University and Ubon Ratchathani Rajabhat University. According to the agreement of deans of all faculties (Council of IT Deans of Thailand (CITT)), Mahanakorn University of Technology was appointed as a coordinator of the journal.

The journal was established in 2010 and plans to publish 2 issues per year (JAN – JUNE and JULY – DECEMBER per year). The journal was established first print journal publication in 2010 (Vol 1. No.1) with ISSN 1906-9553 (Print) and plans to publish 2 issues per year on during January - June and July - December. Also the journal was established first online journal publication in 2010 (Vol 1. No.1) with ISSN 2651-1053 (Online) and plans to publish 2 issues per year on during January - June and July - December.

## EDITOR IN CHIEF

Werasak Kurutach, Mahanakorn University of Technology, Thailand

## ADVISORY BOARD

|                                                                                     |                                                                                     |                                                                                          |
|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------|
| Pisit Charnkeitkong<br>Panyapiwat Institute of Management,<br>Thailand              | Krisana Chinnasarn<br>Burapha University,<br>Thailand                               | Sunantha Sodsee<br>King Mongkut's University of<br>Technology North Bangkok,<br>Thailand |
| Adisak Suasaming<br>Thai-Nichi Institute of Technology,<br>Thailand                 | Panavy Pookaiyaudom<br>Mahanakorn University of<br>Technology, Thailand             | Poonpong Boonbrahm<br>Walailak University,<br>Thailand                                   |
| Pattanasak Mongkolwat<br>Mahidol University, Thailand                               | Sasitorn Kaewman<br>Mahasarakham University, Thailand                               | Chetneti Srisaan<br>Rangsit University, Thailand                                         |
| Siridech Boonsang<br>King Mongkut's Institute of<br>Technology Ladkrabang, Thailand | Phattanapon Rhienmora<br>Bangkok University, Thailand                               | Teeravisit Laohapensaeng<br>Mae Fah Luang University,<br>Thailand                        |
| Thana Sukvaree<br>Sripatum University, Thailand                                     | Dechanuchit Katanyutaveetip<br>Siam University, Thailand                            | Chaiyaporn Khemapatapan<br>Dhurakij Pundit University,<br>Thailand                       |
| Nathaporn Karnjnapoomi<br>Silpakorn University, Thailand                            | Aziz Nanthaamornbong<br>Prince Of Songkla University,<br>Thailand                   | Anong Rungsuk<br>Nakhon Phanom University,<br>Thailand                                   |
| Pornthep Rojanavas<br>University of Phayao, Thailand                                | Kriengkrai Porkaew<br>King Mongkut's University of<br>Technology Thonburi, Thailand | Supawee Makdee<br>Ubon Ratchathani Rajabhat<br>University, Thailand                      |

# JOURNAL OF INFORMATION SCIENCE AND TECHNOLOGY (JIST)

ISSN 2651-1053 (Online), ISSN 1906-9553 (Print)

## EDITORIAL BOARD

Werasak Kurutach  
Mahanakorn University of  
Technology, Thailand

Woraphon Lilakiatsakun  
Mahanakorn University of  
Technology, Thailand

Surakarn Duangphasuk  
Mahanakorn University of  
Technology, Thailand

Rattana Wetprasit  
Prince Of Songkla University,  
Thailand

Datchakorn Tancharoen  
Panyapiwat Institute of Management,  
Thailand

Wanvipa Wongvilaisakul  
Panyapiwat Institute of  
Management, Thailand

Pawitra Chiravirakul  
Mahidol University, Thailand

Songsri Tangsripairoj  
Mahidol University, Thailand

Suppat Rungraungsilp  
Walailak University,  
Thailand

Sarayut Nonsiri  
Thai-Nichi Institute of  
Technology, Thailand

Annop Monsakul  
Thai-Nichi Institute of  
Technology, Thailand

Sasitorn Kaewman  
Mahasarakham University,  
Thailand

Nutchanat Buasri  
Mahasarakham University,  
Thailand

Kaboon Thongtha  
Mahanakorn University of Technology,  
Thailand

Sureeluk Weerajong  
Mahanakorn University of  
Technology, Thailand

Mudarmeen Munlin  
Mahanakorn University of  
Technology, Thailand

Chatchai Tubgri  
Mahanakorn University of Technology,  
Thailand

Benjamas Meansamut  
Mahanakorn University of  
Technology, Thailand

## MANAGER

Kaboon Thongtha, Mahanakorn University of Technology, Thailand

## CONTACT ADDRESS

Council of IT Deans of Thailand (CITT),  
Faculty of Engineering and Technology,  
Mahanakorn University of Technology  
140 Moo 1, Cheum-Sampan Road, Nongchok,  
Bangkok, Thailand 10530  
Tel: +(662) 988-3655 ext 4115

# CALL FOR PAPER

## Journal of Information Science and Technology (JIST)

<https://ph02.tci-thaijo.org/index.php/JIST>

### Editor in Chief

Werasak Kurutach (MUT)

### Advisory Board

Panavy Pookaiyaudom (MUT)

Kriengkrai Porkaew (KMUTT)

Sasitorn Kaewman (MSU)

Pattanasak Mongkolwat (MU)

Poonpong Boonbrahm (WU)

Sarayut Nonsiri (TNI)

Pisit Charnkeitkong (PIM)

Chetneti Srisaon (RSU)

Siridech Boonsang (KMUTL)

Phattanapon Rhiemora (BU)

Sunantha Sodsee (KMUTNB)

Teeravisit Laohapensaeng (MFU)

Thana Sukvaree (SPU)

Dechanuchit Katanyutaveetip (SU)

Chaiyaporn Khemapatapan (DPU)

Nathaporn Kamjapoomi (SU)

Aziz Nanthaamornbong (PSU)

Anong Rungsuk (NPU)

Krisana Chinasarn (BUU)

Pornthep Rojanavasut (UP)

Supawee Makdee (UBRU)

### Editorial Board

Mudameen Munlin (MUT)

Sureeluk Weerajong (MUT)

Surakarn Duangphasuk (MUT)

Rattana Wetprasit (PSU)

Datchakorn Tancharoen (PIM)

Wanvipa Wongvilaisakul (PIM)

Pawitra Chiravirakul (MU)

Songsri Tangsripairoj (MU)

Suppat Rungrungsilp (WU)

Sarayut Nonsiri (TNI)

Annop Monsakul (TNI)

Sasitorn Kaewman (MSU)

Nutchanat Buasri (MSU)

Benjamas Meansamut (MUT)

Chatchai Tubgri (MUT)

### Manager

Kaboon Thonghta (MUT)

### Submissions

Online Journal Submission

<https://ph02.tci-thaijo.org/index.php/JIST/>

### Publication Periodicity

Published 2 times a year in

June and December.

(JAN – JUN and JULY – DEC).

**(Indexed by TCI tier 2)**

### JIST Office Address

Council of IT Deans of Thailand  
(CITT), Faculty of Engineering and  
Technology, Mahanakorn

University of Technology 140 Moo  
1, Cheum-Sampan Rd., Nongchok,  
Bangkok, Thailand 10530

Tel: +(662)988-3655 ext 4115,

Fax: +(662)988-4027

### Peer Review Process

All submitted manuscripts must be  
reviewed by at least three expert  
reviewers via the double-blinded  
review system.

### Manuscript Preparation Guide (Publication Charge: Free)

The template for writing the journal is available for downloading (jist\_template\_eng-2020.doc or jist\_template\_thai-2020.doc). Minimum length of the paper should be in between 6-16 pages of A4 size. Text should be typewritten or printed with double-spaced in 11-point of A4 white paper with margins of 1.5" for top, 1.25" for left, and 1" for bottom and right sides. All pages must be numbered sequentially. Here are some guidelines.

- Abstract with length 100-200 words in length.
- Introduction which discusses existing problem and related research
- Materials and methods used for experimentation, Results of the experiment, Discussion and conclusion, References Style is IEEE.

The **Journal of Information Science and Technology (JIST)** aims to be the forum through which researchers, faculties, and experts of the computer and information technology and others technological related fields share and discuss their high quality research work as well as innovation. Original research articles, practical applications and innovations in the broad area of computer and information technology are suitable for publication in JIST.

#### • **Soft Computing:**

Artificial Intelligence, Fuzzy and Neural Computing, Genetic Algorithms, Intelligent Agents, Neural Networks, Natural Language Processing, Robotics and Automation, Image Processing

#### • **Human-Computer Interaction:**

Graphical User Interfaces, Multimedia, Interactive Systems, Computer-Supported Cooperative Work, Human Cognitive Skills, Visualization, and Computer Simulation

#### • **Information Assurance and Security:**

Cryptography, Forensics and Incident Response, Biometrics, Security Policies and Procedures

#### • **Information Systems:**

Databases, Information Retrieval, Transaction Processing, Distributed and Object Databases, Data Warehousing, Knowledge Management, Expert Systems, Multimedia Information Systems, Digital Libraries, Geographical Information Systems

#### • **Networking:**

Advanced Computer Networks, Internet Technology and Applications, Distributed Systems, Wireless and Mobile Computing, Data Compression, Network Security, Enterprise Networking, Digital Communications

#### • **Programming:**

Object-Oriented Programming, Event-Driven Programming, Functional Programming, Logic Programming, XML and other Extensible Languages, Parallel Programming

#### • **Platform Technologies:**

Advanced Computer Architecture, Parallel Architectures, Cluster / Grid Computing, RFID, Embedded Systems

#### • **System Integration and Architecture:**

Software Acquisition and Implementation, System Needs Assessment, Software Economics, Enterprise Systems, Computing Economics

#### • **Social and Professional Issues:**

Professional Practice, Social Context of Computing, Computers Ethics, IT Law, Intellectual Property, Privacy and Civil Rights

#### • **Web Systems and Technologies:**

Programming for the WWW, E-commerce, E-Learning, Content Management Systems, E-Government and E-Service

#### • **Multidisciplinary:**

Bioinformatics, Biomedical Information Systems, Nano Technology

#### • **e-Business and m-Business:**

e-Business Process Aspects, Intelligent e-Business System, m-Business, e-Supply Chain Management & e-Logistics, e-Customer Relationship Management, e-Negotiation, e-Payment, e-Business Design and Developments

#### • **Business and Information System:**

Information management for business applications, Enterprise systems and architecture, Business systems infrastructure design for information integration, Service-oriented architecture, Service-component architecture

#### • **Social and Business Aspects of Convergence IT and Ubiquitous Computing:**

Economics of emerging technologies, Home and community computing, Economic and social complexities in CIT and UC, New forms of media and communications

#### • **Internet of Things (IoT):**

IoT system architecture, IoT enabling technologies, IoT communication and networking protocols such as network coding, and IoT services and applications and technology development in different standard development organizations (SDO).

#### • **Cloud Computing:**

Auditing, monitoring, scheduling, resource registration/discovery, Automatic reconfiguration, self healing/monitoring, Service level agreements, integration, management.

#### • **Fintech and blockchain:**

Development of Blockchain Security Enhancement Technologies, Platform Technology that Supports Safe Transactions, Financial and Economic Structures, Blockchain's Impacts on Workstyles, Fast Fintech for Smartphone Application Service Platform.





การค้นหากฎความสัมพันธ์และวิเคราะห์ข้อมูล  
เพื่อเพิ่มประสิทธิภาพการขายอาหารญี่ปุ่น

**The Discovery of Association Rules and Data Analysis  
to Optimize Japanese Food Sales**

นรินทร์ จิวตัน

*Narin Jiwitan*

สาขาวิชาระบบสารสนเทศทางธุรกิจ คณะบริหารธุรกิจและศิลปศาสตร์

มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา

*Business Information System, Faculty of Business Administration and Liberal Arts*

*Rajamangala University of Technology Lanna*

Received: November 12, 2021; Revised: April 30, 2022; Accepted: May 18, 2022; Published: June 29, 2022

**ABSTRACT** – This research aims to study the association between each food menu sold in a Japanese restaurant by using The FP – Growth Algorithm. The research methodology was based on the CRISP-DM. Data were from 4,254 receipts which were 16,409 food items sold. As a result of data cleaning, there were 13,377 items left to analyze. The result found that the food purchase had eight association rules when using 0.05 as the minimum support and 0.20 as the minimum confidence. With the highest confidence value, it can be concluded that if customers bought Tuna, it was likely that they would purchase Salmon too, with a confidence of 52.94%, a lift of 5.01. There was a dependent relationship between Tuna and Salmon. Additionally, Crab Rangoon was the most sold item in the restaurant. Set Punpla was the most sold set menu. Customers usually dined in during 6-7 PM and paid by cash. The result of this study could be utilized in restaurant promotion and menu suggestions to customers, which would help the restaurant's competitive advantage, increase sales volume, make marketing strategies, and find new business opportunities.

**KEYWORDS:** Japanese Food, Association Rules, Data Mining, FP – Growth Algorithm, Sales Analysis

**บทคัดย่อ** -- งานวิจัยนี้มีวัตถุประสงค์เพื่อค้นหารูปแบบกฎความสัมพันธ์ของรายการสั่งซื้ออาหารญี่ปุ่น โดยใช้อัลกอริทึมเอฟพี – โกรธ และเพื่อวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น กระบวนการวิจัยเป็นไปตามขั้นตอนของ CRISP- DM โดยรวบรวมข้อมูลรายการสั่งซื้อจำนวนใบเสร็จ 4,254 ใบ และจำนวนรายการสั่งอาหาร 16,409 รายการ การเตรียมข้อมูลดำเนินการโดยการคัดเลือกข้อมูล การกลั่นกรองข้อมูล ส่งผลให้ข้อมูลคงเหลือ 13,377 และการแปลงรูปแบบของข้อมูลให้อยู่ในรูปแบบที่เหมาะสมนำไปค้นหากฎ ด้วยเทคนิคความสัมพันธ์ โดยใช้อัลกอริทึมเอฟพี – โกรธ และวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น ผลการวิจัยพบว่าเมื่อกำหนดค่าสนับสนุนขั้นต่ำเท่ากับ 0.05 และค่าความเชื่อมั่นขั้นต่ำเท่ากับ 0.20 จะได้

กฎความสัมพันธ์ของการซื้ออาหารจำนวน 8 กฎ ผลการทดสอบประสิทธิภาพพบว่าค่าความเชื่อมั่นสูงสุด คือ ถ้าลูกค้าซื้อ Tuna แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่าความเชื่อมั่นที่ 52.94% ค่าสหสัมพันธ์ 5.01 แสดงว่า Tuna และ Salmon มีความสัมพันธ์ที่ขึ้นต่อกัน ผลการวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่นพบว่า สินค้าที่ขายดีที่สุด คือ Crab Rangoon อาหารประเภทที่ขายดีที่สุด คือ Set Punpla ลูกค้ามักจะรับประทานอาหารภายในร้าน ช่วงเวลาประมาณ 18.00 – 19.00 น. และชำระด้วยเงินสด จากผลการวิจัยนี้สามารถนำกฎความสัมพันธ์ที่พบไปประยุกต์ใช้ในการจัดโปรโมชั่นหรือแนะนำการขายให้แก่ลูกค้า ช่วยสร้างความได้เปรียบทางการแข่งขัน ช่วยเพิ่มประสิทธิภาพขาย การวางแผนกลยุทธ์ทางการตลาด และหาโอกาสทางธุรกิจต่อไป

**คำสำคัญ:** อาหารญี่ปุ่น, กฎความสัมพันธ์, เหมืองข้อมูล, อัลกอริทึมเอพฟี่ – โกรธ, วิเคราะห์ข้อมูลการขาย

## 1. บทนำ

ธุรกิจร้านอาหารต่าง ๆ ล้วนมีการนำเทคโนโลยีมาช่วยเพิ่มประสิทธิภาพการทำงานและยกระดับการให้บริการแก่ลูกค้า องค์การส่งเสริมการค้าต่างประเทศของญี่ปุ่น (เจโทร กรุงเทพฯ) [1] สำรวจร้านอาหารญี่ปุ่นในประเทศไทย ประจำปี 2563 พบว่ามีจำนวน 4,094 ร้าน เพิ่มขึ้นร้อยละ 12.6 จากปี 2562 ที่มีจำนวน 3,637 ร้าน ขณะเดียวกันมีร้านอาหารญี่ปุ่นที่ปิดตัวลงจำนวน 726 ร้าน ดังนั้นธุรกิจร้านอาหารญี่ปุ่นจึงพยายามหาโอกาสทางธุรกิจและนำเสนอรายการสินค้าที่ตรงกับความต้องการของลูกค้าสูงสุด[2] ธุรกิจจึงมีความต้องการวิเคราะห์ข้อมูลเพื่อส่งเสริมการขาย โดยเฉพาะข้อมูลของรายการสินค้าที่ลูกค้าซื้อไปในแต่ละใบเสร็จ ข้อมูลเหล่านี้สามารถนำมาใช้ประโยชน์ได้ ซึ่งก่อให้เกิดเป็นแนวคิด วิธีการทางธุรกิจเพื่อนำมาใช้ประโยชน์อย่างสูงสุด สร้างองค์ความรู้และสร้างนวัตกรรม ซึ่งถือว่าเป็นสัญญาณของการขับเคลื่อนธุรกิจด้วยข้อมูลขนาดใหญ่[3] อันจะช่วยให้ธุรกิจเติบโตขึ้นและเพิ่มขีดความสามารถในการแข่งขันกับคู่แข่งทางธุรกิจได้จากสถิติธุรกิจอาหารญี่ปุ่นในประเทศไทย [4] ที่มีเพิ่มขึ้นเรื่อย ๆ จนทำให้ประเทศไทยมีร้านอาหารญี่ปุ่นมากที่สุดในอาเซียน เนื่องจากผู้บริโภคคนไทยมีความชื่นชอบอาหารญี่ปุ่น จึงก่อให้เกิดธุรกิจร้านอาหารญี่ปุ่นตั้งแต่ร้านขนาดเล็กข้างทางไปจนถึงร้านระดับสินค้าคุณภาพราคาสูง ทำให้เกิดคู่แข่งทางการค้าเพิ่มขึ้น ผู้บริโภคและกลุ่มลูกค้าส่วนมากจะเป็นกลุ่มลูกค้าที่มีรายได้ระดับกลางและระดับสูง พฤติกรรม

ผู้บริโภคที่รับประทานอาหารญี่ปุ่นมักจะเลือกใช้บริการร้านที่มีรายการสินค้าหลากหลาย [4] การจัดโปรโมชั่นที่ดึงดูดลูกค้า มีรายการสินค้าอื่นนอกจากอาหารญี่ปุ่น ทำให้ร้านอาหารญี่ปุ่นมีเมนูอาหารที่หลากหลาย และลูกค้าที่รับประทานอาหารญี่ปุ่นจะสั่งรายการอาหารมากกว่า 2 รายการ ร้านป็นป่าดำเนินธุรกิจร้านอาหารญี่ปุ่นให้บริการอาหารและเครื่องดื่มแก่ลูกค้าทั้งคนไทยและชาวต่างชาติ ในจังหวัดเชียงใหม่และใกล้เคียง มีเมนูอาหารที่หลากหลายและแปลกใหม่มากกว่า 150 เมนู จากเมนูที่มีจำนวนมากทำให้ทางร้านไม่ทราบว่าคุณค่ามักจะสั่งเมนูอาหารใดพร้อมกันบ้าง ทางร้านจึงมีความสนใจในการทำแบบจำลองในการหาความสัมพันธ์ของรายการอาหาร เพื่อส่งเสริมการขาย อีกทั้งภาวะเศรษฐกิจไม่ดีทำให้ผู้บริโภคใช้จ่ายน้อยลง จึงทำให้ยอดขายของทางร้านลดลง ซึ่งในการที่ลดราคาจะเป็นการดึงดูดกลุ่มลูกค้าที่อ่อนไหวเรื่องราคา แต่หากทางร้านหยุดลดราคากลุ่มลูกค้านี้ก็มักจะไม่กลับมาใช้บริการอีก นั่นเท่ากับว่าทางร้านต้องลดราคาไปเรื่อย ๆ หากมีคู่แข่งลดราคาต่ำกว่าทางร้าน ลูกค้ากลุ่มนี้ก็จะย้ายไปเข้าร้านคู่แข่งแทน ทางร้านต้องลดราคาลงอีกเพื่อดึงลูกค้ากลับมา ซึ่งสุดท้ายทางร้านก็ไม่สามารถได้ประโยชน์ ฉะนั้นจึงต้องเลือกวิธีการจัดโปรโมชั่นพิเศษ การนำเสนอรายการสินค้าที่ตรงกับความต้องการของลูกค้า เพื่อจูงใจลูกค้าและเป็นการเพิ่มยอดขายให้ได้มากขึ้น ดังนั้น งานวิจัยนี้มีวัตถุประสงค์เพื่อค้นหารูปแบบกฎความสัมพันธ์ของรายการสั่งซื้ออาหารญี่ปุ่น โดยใช้อัลกอริทึมเอพฟี่ – โกรธ และเพื่อ

วิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น ให้สามารถนำกฎที่ได้ไปประยุกต์ใช้ในการส่งเสริมการขาย ช่วยสร้างความได้เปรียบทางการแข่งขัน ช่วยเพิ่มประสิทธิภาพขาย การวางแผนกลยุทธ์ทางการตลาด และหาโอกาสทางธุรกิจต่อไป

## 2. ขอบเขตการวิจัย

### 2.1 ขอบเขตด้านข้อมูล


แหล่งข้อมูลในการวิจัยนี้ ได้ศึกษาจากเพิ่มข้อมูลรายละเอียดการสั่งซื้ออาหาร ในฐานข้อมูลร้านปิ้งย่างอาหารญี่ปุ่น ระหว่างวันที่ 1 กันยายน 2563 - 31 พฤษภาคม 2564 จำนวนใบเสร็จ 4,254 ใบ และจำนวนข้อมูลรายการสั่งซื้ออาหาร 16,409 รายการ

### 2.2 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือที่ใช้ในการวิจัยได้นำโปรแกรม Microsoft Excel[5] Microsoft SQL Server[6] ช่วยในการเตรียมข้อมูล และโปรแกรม RapidMiner [7] โปรแกรม Power BI Desktop ช่วยวิเคราะห์และนำเสนอข้อมูล

## 3. กรอบแนวคิดในการวิจัย

ในกระบวนการวิจัยเรื่องการค้นหากฎความสัมพันธ์และวิเคราะห์ข้อมูล เพื่อเพิ่มประสิทธิภาพการขายอาหารญี่ปุ่น มีการทำงานที่สอดคล้องกับขั้นตอนของ CRISP- DM [8] จำนวน 6 ขั้นตอน ดังรูปที่ 1. แสดงกรอบแนวคิดในการวิจัย



รูปที่ 1. แสดงกรอบแนวคิดในการวิจัย

## 4. วิธีดำเนินการวิจัย

ในการวิจัยเรื่องการค้นหากฎความสัมพันธ์และวิเคราะห์ข้อมูล เพื่อเพิ่มประสิทธิภาพการขายอาหารญี่ปุ่นมีวิธีดำเนินการวิจัยดังนี้

### 1. ทำความเข้าใจธุรกิจและโอกาสทางธุรกิจ (Business Understanding)

เป็นกระบวนการที่มุ่งเน้นทำความเข้าใจกระบวนการทางธุรกิจจากร้านปิ้งย่างอาหารญี่ปุ่น ทำความเข้าใจปัญหาให้อยู่ในรูปของการวิเคราะห์ข้อมูล รวมทั้งใช้หลักการของเหมืองข้อมูล พยายามหาโอกาสทางธุรกิจ จากการวิเคราะห์ความต้องการ คือ ทางร้านต้องการจัดโปรโมชั่นหรือแนะนำการขายอาหารให้แก่ลูกค้า วิเคราะห์ข้อมูลเพื่อช่วยเพิ่มยอดขาย รวมทั้งทราบพฤติกรรมผู้บริโภคอาหารญี่ปุ่นจากการสั่งซื้อของลูกค้า

### 2. รวบรวมและทำความเข้าใจข้อมูลรายการสั่งซื้อ (Data Understanding)

ขั้นตอนการจัดเก็บ รวบรวมข้อมูล ตลอดจนการพิจารณาตรวจสอบความถูกต้องของข้อมูลที่ได้รับ โดยเลือกที่จะใช้ ข้อมูลทั้งหมดหรือบางส่วนในการวิเคราะห์ให้สอดคล้องกับวัตถุประสงค์ที่กำหนดไว้ ผู้วิจัยทำการรวบรวมข้อมูลจากร้านปิ้งย่าง เพื่อหาโอกาสทางธุรกิจที่ก่อให้เกิดประโยชน์สูงสุด ดังรูปที่ 2. แสดงตัวอย่างข้อมูลดิบรายการสั่งซื้ออาหารและเครื่องดื่ม

|    | A              | B               | C                 | D           | E                     | F         | G     | H            | I      | J          | K |
|----|----------------|-----------------|-------------------|-------------|-----------------------|-----------|-------|--------------|--------|------------|---|
| 1  | วันที่สั่งซื้อ | เวลาที่สั่งซื้อ | หมายเลขใบ INV. No | รหัสทางเก็บ | ชื่อเมนู              | ประเภทการ | จำนวน | ราคาต่อหน่วย | ยอดรวม | ส่วนต่อหัว |   |
| 2  | 1/9/2020       | 11:56           | ETOM6             | WG9         | คาทามะ Dine-in        | 1         | 55    | 55           | 22     |            |   |
| 3  | 1/9/2020       | 11:56           | ETOM6             | WG9         | Katsudon Dine-in      | 2         | 140   | 280          | 112    |            |   |
| 4  | 1/9/2020       | 11:56           | ETOM6             | WG9         | Bottle Wa Dine-in     | 2         | 15    | 30           | 0      |            |   |
| 5  | 1/9/2020       | 11:56           | ETOM6             | WG9         | เทรียวา Dine-in       | 2         | 90    | 180          | 72     |            |   |
| 6  | 1/9/2020       | 11:56           | ETOM6             | WG9         | เกียวรา Dine-in       | 1         | 90    | 90           | 36     |            |   |
| 7  | 1/9/2020       | 11:56           | ETOM6             | WG9         | Arizona RC Dine-in    | 1         | 140   | 140          | 56     |            |   |
| 8  | 1/9/2020       | 11:56           | ETOM6             | WG9         | Sake Roll Dine-in     | 2         | 80    | 160          | 64     |            |   |
| 9  | 1/9/2020       | 11:56           | ETOM6             | WG9         | California F Dine-in  | 1         | 90    | 90           | 36     |            |   |
| 10 | 1/9/2020       | 17:44           | VB31C             | WG9         | Punpla' B Dine-in     | 1         | 90    | 90           | 18     |            |   |
| 11 | 1/9/2020       | 17:44           | VB31C             | WG9         | Bottle Wa Dine-in     | 1         | 15    | 15           | 0      |            |   |
| 12 | 1/9/2020       | 20:51           | JX3H0             | WG9         | Sushi Mats Dine-in    | 1         | 370   | 370          | 0      |            |   |
| 13 | 1/9/2020       | 20:51           | JX3H0             | WG9         | Green Tea Dine-in     | 2         | 30    | 60           | 0      |            |   |
| 14 | 1/9/2020       | 20:51           | JX3H0             | WG9         | Bottle Wa Dine-in     | 1         | 15    | 15           | 0      |            |   |
| 15 | 1/9/2020       | 20:51           | JX3H0             | WG9         | Caterpillar Dine-in   | 1         | 250   | 250          | 0      |            |   |
| 16 | 1/9/2020       | 20:51           | JX3H0             | WG9         | สตีลพาร์ท Dine-in     | 1         | 210   | 210          | 0      |            |   |
| 17 | 1/9/2020       | 20:58           | CIXIC             | WG9         | Churchy B Dine-in     | 1         | 220   | 220          | 0      |            |   |
| 18 | 1/9/2020       | 20:58           | CIXIC             | WG9         | Salmon B Dine-in      | 1         | 200   | 200          | 0      |            |   |
| 19 | 1/9/2020       | 20:58           | CIXIC             | WG9         | โซหวานผู้ Dine-in     | 2         | 15    | 30           | 0      |            |   |
| 20 | 1/9/2020       | 20:58           | CIXIC             | WG9         | Green Tea Dine-in     | 2         | 30    | 60           | 0      |            |   |
| 21 | 1/9/2020       | 20:58           | CIXIC             | WG9         | Spicy Shit Dine-in    | 1         | 160   | 160          | 0      |            |   |
| 22 | 2/9/2020       | 14:19           | MRV10             | 99D         | Bottle Wa Dine-in     | 1         | 15    | 15           | 0      |            |   |
| 23 | 2/9/2020       | 14:19           | MRV10             | 99D         | Dragon RC Dine-in     | 1         | 350   | 350          | 140    |            |   |
| 24 | 2/9/2020       | 14:19           | MRV10             | 99D         | สัสคัส Dine-in        | 1         | 80    | 80           | 32     |            |   |
| 25 | 2/9/2020       | 16:01           | VEG01             | 99D         | California F Take Awa | 1         | 90    | 90           | 0      |            |   |
| 26 | 2/9/2020       | 16:01           | VEG01             | 99D         | Spicy Tun Take Awa    | 1         | 130   | 130          | 0      |            |   |
| 27 | 2/9/2020       | 17:10           | KZSUJ             | 99D         | ข้าวหน้า Dine-in      | 1         | 280   | 280          | 0      |            |   |
| 28 | 2/9/2020       | 17:26           | T9IRZ             | 99D         | Negi-Ham Delivery     | 1         | 175   | 175          | 0      |            |   |

รูปที่ 2. แสดงตัวอย่างข้อมูลดิบรายการสั่งซื้ออาหารและเครื่องดื่ม

พบว่ามียานวนใบเสร็จ 4,254 ใบ จำนวนแถวข้อมูลรายการสั่ง


อาหาร 16,409 รายการ ประกอบด้วย 22 แอดทริบิวต์ ประกอบด้วย ข้อมูลวันที่ชำระเงิน เวลาที่ชำระเงิน หมายเลขใบเสร็จ / ID INV. No รหัสลดเก็บเงิน ชื่อเมนู ประเภทการสั่งซื้อ จำนวนที่สั่งซื้อ ราคาต่อหน่วย ยอดก่อนลด ส่วนลด เปอร์เซ็นส่วนลดทั้งหมด ราคาสุทธิ ประเภทภาษีของรายการ โ้ตะ ชื่อลูกค้า เบอร์โทรศัพท์ ประเภทการชำระเงิน หมายเหตุ วิธีการสั่งซื้อ ประเภทสินค้า สาขา ซึ่งข้อมูลถูกจัดเก็บด้วยโปรแกรมบริหารจัดการร้านอาหารและใช้ Microsoft SQL Server เป็นฐานข้อมูล

**3. คัดเลือกข้อมูล กลั่นกรองข้อมูลและแปลงรูปแบบข้อมูล (Data Preparation)** ก่อนที่จะนำข้อมูลที่ได้ไปใช้งาน มีการทำความเข้าใจและตรวจสอบคุณภาพของข้อมูล ทำข้อมูลให้อยู่ในรูปแบบที่ถูกต้องหรือปรับเปลี่ยนให้อยู่ในรูปแบบที่เหมาะสม เพื่อให้ข้อมูลอยู่ในลักษณะหรือรูปแบบที่สามารถนำไปใช้งานต่อในขั้นตอนอื่นอย่างมีประสิทธิภาพ [9] ซึ่งเป็นขั้นตอนที่ใช้เวลานานมากที่สุด แบ่งการทำงานออกเป็น 3 ขั้นตอนย่อย ดังนี้

**3.1 ทำการคัดเลือกข้อมูล (Data Selection)** คือ การคัดเลือกข้อมูลที่เหมาะสมเพื่อนำมาใช้ในการวิเคราะห์ข้อมูล ผู้วิจัยคัดเลือกข้อมูลจำนวน 3 แอดทริบิวต์ ได้แก่ หมายเลขใบเสร็จ ชื่อเมนู และประเภทสินค้า ซึ่งเป็นข้อมูลที่จำเป็นในการวิเคราะห์ข้อมูลเพื่อค้นหากฎความสัมพันธ์ของพฤติกรรมกรซื้ออาหารญี่ปุ่น และคัดเลือกข้อมูลจำนวน 8 แอดทริบิวต์ ได้แก่ เวลาที่ชำระเงิน ชื่อเมนู ประเภทการสั่งซื้อ จำนวนที่สั่งซื้อ ส่วนลด ราคาสุทธิ ประเภทการชำระเงิน วิธีการสั่งซื้อ ประเภทสินค้า สำหรับนำไปวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น ตามวัตถุประสงค์ที่ตั้งไว้

**3.2 ทำการกลั่นกรองข้อมูล (Data Cleaning)** คือ การทำความสะอาดข้อมูล เป็นกระบวนการตรวจสอบ แก้ไขหรือลบรายการข้อมูลที่ไม่ถูกต้องออกจากตารางชุดข้อมูลหรือฐานข้อมูล ดังนี้

3.2.1 พบว่ารูปแบบการจัดเก็บข้อมูล เก็บแยกเป็นชื่อประเภทสินค้า\_G เป็นประเภทสินค้าจาก Grab Food และประเภทสินค้า\_LM เป็นประเภทสินค้าจาก Lineman ดังรูปที่ 3 แสดงตัวอย่างข้อมูลประเภทสินค้าก่อนทำความสะอาด



รูปที่ 3. แสดงตัวอย่างข้อมูลประเภทสินค้าก่อนทำความสะอาด

3.2.2 พบว่ารูปแบบการจัดเก็บข้อมูลชื่อรายการสินค้า มีการจัดเก็บที่แตกต่างกันทั้งที่เป็นอาหารชนิดเดียวกัน ดังตารางที่ 1. แสดงตัวอย่างการจัดเก็บข้อมูลชื่อรายการสินค้าที่แตกต่างกันทั้งที่เป็นข้อมูลเดียวกัน

ตารางที่ 1. แสดงตัวอย่างการจัดเก็บข้อมูลชื่ออาหารที่แตกต่างกันก่อนทำความสะอาด

| Appetizers / ของว่าง |                                                                                                                           |
|----------------------|---------------------------------------------------------------------------------------------------------------------------|
| Edamame              | ถั่วแระญี่ปุ่น<br>ถั่วแระญี่ปุ่น_LM<br>Edamame G<br>Edamame                                                               |
| Crab Rangoon         | ปูชีสทอด<br>ปูชีสทอด_LM<br>Crab Rangoon G<br>Crab Rangoon Promotion<br>Half order Crab Rangoon<br>Crab Rangoon Half order |
| ...                  | ...                                                                                                                       |
| Karake               | คารากะ<br>Karake G<br>Karake<br>คารากะ_LM                                                                                 |

หลังการทำความสะอาดข้อมูลประเภทสินค้าและชื่อรายการสินค้า พบว่ามีประเภทสินค้าจำนวน 15 ประเภท สินค้าจำนวน 151 รายการ และเครื่องดื่มจำนวน 20 รายการ



ตารางที่ 2. แสดงข้อมูลหลังการทำความสะอาดข้อมูล

| Product Type             | คำอธิบายประเภทสินค้า      | จำนวนเมนู (รายการ) |
|--------------------------|---------------------------|--------------------|
| อาหาร                    |                           |                    |
| Appetizers               | อาหารเรียกน้ำย่อย         | 13                 |
| Entrée                   | อาหารจานหลัก              | 9                  |
| Maki                     | ข้าวห่อสาหร่าย            | 21                 |
| Set Punpla               | อาหารชุดแนะนำทางร้าน      | 8                  |
| Specially Maki           | ซูชิโรลพิเศษ              | 17                 |
| Salad                    | สลัด                      | 8                  |
| Nigiri/Sashimi           | นิกิริซูชิ/ซาซิมิ         | 18                 |
| Donburi                  | ข้าวหน้าต่าง ๆ            | 3                  |
| Hawaiian Sushi Rice bowl | อาหารพื้นเมือง            | 3                  |
| Side Order               | เครื่องดื่ม               | 13                 |
| Set Sushi/Sashimi        | เซตซูชิ/ซาซิมิ            | 13                 |
| Other                    | อาหารประเภทอื่นๆ          | 25                 |
| เครื่องดื่ม              |                           |                    |
| Beverage                 | เครื่องดื่มไม่มีแอลกอฮอล์ | 11                 |
| Alcoholic beverage       | เครื่องดื่มแอลกอฮอล์      | 9                  |

3.2.3 ลบชื่อรายการสินค้าและประเภทสินค้า ที่ไม่ต้องการนำไปใช้ในการสร้างโมเดล ได้แก่ ไม่รับซื้อสัมพลาสติก, set ploy, 5 pcs, ใช้สิทธิคนละครึ่ง, ใช้สิทธิโครงการรัฐ, Extra charge for tempura roll, Extra, extra และ Extra Charge Beverage สำหรับสินค้าประเภทเครื่องดื่มและเครื่องดื่มแอลกอฮอล์ทางร้านไม่ต้องการนำไปวิเคราะห์และส่งเสริมการขาย ส่งผลให้คงเหลือข้อมูลสำหรับการนำไปวิเคราะห์จำนวน 13,377 รายการ

3.3 แปลงรูปแบบของข้อมูล (Data Transformation) เป็นขั้นตอนการเตรียมข้อมูลให้อยู่ในรูปแบบที่พร้อมนำไปใช้ในการวิเคราะห์เพื่อค้นหาความสัมพันธ์ โดยใช้อัลกอริทึมเอพี – โกรธ ดังรูปที่ 4. แสดงตัวอย่างข้อมูลก่อนการแปลงข้อมูล และทำการแปลงข้อมูลให้อยู่ในรูปแบบตารางมิติ (Pivot Table) โดยให้แถวเป็นหมายเลขใบเสร็จ (OrderNumber) และคอลัมน์เป็นชื่อสินค้า (Item) ดังรูปที่ 5

|    | A           | B                   | C              |
|----|-------------|---------------------|----------------|
| 1  | OrderNumber | Item                | ItemType       |
| 2  | ETOM6       | Karake              | Appetizers     |
| 3  | ETOM6       | Katsudon            | Entree         |
| 4  | ETOM6       | Teriyaki            | Entree         |
| 5  | ETOM6       | Gyoza               | Appetizers     |
| 6  | ETOM6       | Arizona Roll        | Maki           |
| 7  | ETOM6       | Sake Roll           | Maki           |
| 8  | ETOM6       | California Roll     | Maki           |
| 9  | VB31C       | Punpla B            | Set Punpla     |
| 10 | JX3H0       | Sushi Matsu         | Set Punpla     |
| 11 | JX3H0       | Caterpillar Roll    | Specially Maki |
| 12 | JX3H0       | Tako Salad          | Salad          |
| 13 | CJXIC       | Churchy Maguro Roll | Specially Maki |
| 14 | CJXIC       | Salmon Burner Roll  | Specially Maki |
| 15 | CJXIC       | Tamago              | Nigiri/Sashimi |
| 16 | CJXIC       | Spicy Shrimp Roll   | Maki           |
| 17 | MRWIO       | Dragon Roll         | Specially Maki |
| 18 | MRWIO       | Panpa Salad         | Salad          |
| 19 | VEG01       | California Roll     | Maki           |
| 20 | VEG01       | Spicy Tuna Roll     | Maki           |

รูปที่ 4. แสดงตัวอย่างข้อมูลก่อนการแปลงข้อมูล

|    | A           | B                     | C                       | D            | E     | F                   | G | H | I |
|----|-------------|-----------------------|-------------------------|--------------|-------|---------------------|---|---|---|
| 1  | OrderNumber | Aburi Salmoi Acc Roll | Agan Ama El Alaska Roll | Arizona Roll | Asahi | Asparagus R Avocado |   |   |   |
| 2  | 962         | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 3  | 10846       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 4  | 16949       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 5  | 23721       | 1                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 6  | 34699       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 1 |
| 7  | 65209       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 8  | 86187       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 9  | 89977       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 1 | 0 |
| 10 | 90477       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 11 | 95783       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 12 | 00AN3       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 13 | 00FNO       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 14 | 00X4N       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 15 | 01AEC       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 16 | 02PSF       | 0                     | 0                       | 0            | 1     | 0                   | 0 | 0 | 0 |
| 17 | 02R87       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 18 | 02XAK       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 19 | 02YZH       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |
| 20 | 03AH9       | 0                     | 0                       | 0            | 0     | 0                   | 0 | 0 | 0 |

รูปที่ 5. แสดงตัวอย่างการแปลงข้อมูลให้อยู่ในรูปแบบของตารางมิติก่อนนำไปวิเคราะห์

4. สร้างแบบจำลอง (Modeling) เป็นขั้นตอนการสร้างตัวแบบทางคณิตศาสตร์และสถิติเพื่อการวิเคราะห์ข้อมูลโดยใช้เทคนิควิธีการต่าง ๆ [10] การสร้างความสัมพันธ์ (Association rule) เป็นหนึ่งในเทคนิคของการวิเคราะห์ข้อมูลเพื่อค้นหา รูปแบบ กฎ และความสัมพันธ์ของข้อมูลที่ซ่อนอยู่ในชุดข้อมูลนั้น โดยอาศัยหลักสถิติ การรู้จากการเรียนรู้ของเครื่องและหลักคณิตศาสตร์ เป็นต้น ผลลัพธ์ที่ได้จะทำให้เกิดสารสนเทศที่เป็นประโยชน์ [11]

#### 4.1 นิยามศัพท์ที่เกี่ยวข้องกับกฎความสัมพันธ์

เซตรายการ (Itemsets) คือ ความสัมพันธ์ของข้อมูลที่หาได้ในฐานข้อมูล [12] โดยเซตรายการประกอบด้วย ไอเทมที่ k-itemsets เช่น 3 – itemsets ได้แก่ {Karake, Teriyaki, Gyoza}

เซตรายการความถี่ (Frequent Itemsets) คือ เซตรายการที่ผ่านค่าสนับสนุนขั้นต่ำ (Minimum Support) [13] การสร้างกฎความสัมพันธ์จากเซตรายการความถี่ที่หาได้ จะพิจารณาจากเซตรายการความถี่ที่มีความยาวมากกว่า 2 รายการขึ้นไป เช่น {Gyoza, Karake} จะสร้างเป็นกฎความสัมพันธ์ได้เป็น Gyoza => Karake ซึ่งกฎความสัมพันธ์สามารถเขียนได้ดังนี้

LHS => RHS

LHS (Left Hand Side) แสดงรูปแบบของเซตรายการด้านซ้ายของกฎความสัมพันธ์และ RHS (Right Hand Side) แสดงรูปแบบของเซตรายการด้านขวาของกฎความสัมพันธ์

ค่าสนับสนุน (Support) คือ ค่าความน่าจะเป็นของจำนวนเซตรายการที่พบในฐานข้อมูลต่อจำนวนรายการทั้งหมด เช่น คำนวณค่าสนับสนุนของเซตรายการ LHS หาได้จาก

$$\text{Support (LHS)} = \frac{\text{Number of Transactions that contain LHS}}{\text{Number of all Transactions}}$$

Support (LHS) คือ ค่าสนับสนุนของเซตรายการ LHS

Number of Transactions that contain LHS คือ จำนวนรายการข้อมูลของเซตรายการ LHS

Number of all Transactions คือ จำนวนรายการข้อมูลทั้งหมด

#### 4.2 การหาความสัมพันธ์ด้วยอัลกอริทึมเอพี-ไกรธ

ขั้นตอนการหาความสัมพันธ์ด้วยอัลกอริทึมเอพี-ไกรธ [14] มีขั้นตอนคือสร้าง compact data structure หรือที่เรียกว่า FP-tree และสร้างรูปแบบของสินค้าที่ซื้อบ่อยๆ จาก FP-tree โดยในขั้นตอนนี้ผู้วิจัยใช้โปรแกรม MS Excel และ โปรแกรม Rapid Miner [15] ช่วยในการคำนวณข้อมูล พร้อมทั้งตรวจสอบข้อมูลที่ได้อีกจากการคำนวณ

4.2.1 กำหนดเซตรายการและหาค่าเซตรายการความถี่ จากข้อมูลของร้านปิ้งป้ออาหารญี่ปุ่น มีข้อมูลใบเสร็จจำนวน 4,254 ใบ รายการสินค้าไม่รวมเครื่องดื่มจำนวน 151 รายการ นำมาหาความสัมพันธ์ ผลการคำนวณได้ค่าจำนวนที่เกิดขึ้นใน TID และค่า Support ดังตารางที่ 3. แสดงตัวอย่างค่าจำนวนที่เกิดขึ้นใน TID และ ค่า Support

ตารางที่ 3. แสดงตัวอย่างข้อมูลค่าจำนวนที่เกิดขึ้นใน TID และ ค่า Support

| ITEM         | จำนวนที่เกิดขึ้นใน TID | Support          |
|--------------|------------------------|------------------|
| Aburi Salmon | 186                    | 186/2454 = 4.37% |

| ITEM                | จำนวนที่เกิดขึ้นใน TID | Support           |
|---------------------|------------------------|-------------------|
| Alaska Roll         | 252                    | 252/2454 = 5.92%  |
| Avocado Roll        | 161                    | 161/2454 = 3.78%  |
| Bento Box           | 123                    | 123/2454 = 2.89%  |
| California Roll     | 224                    | 224/2454 = 5.27%  |
| Caribbean Roll      | 112                    | 112/2454 = 2.63%  |
| Churchy Maguro Roll | 247                    | 247/2454 = 5.81%  |
| Crab Rangoon        | 704                    | 704/2454 = 16.55% |
| ...                 | ...                    | ...               |

นำข้อมูลดังกล่าวมาเรียงตามค่า support จากมากไปน้อยตามขั้นตอนวิธีของ เอพี – ไกรธ ดังตารางที่ 4. แสดงตัวอย่างข้อมูลที่เรียงลำดับค่า Support จากมากไปน้อย

ตารางที่ 4. แสดงตัวอย่างข้อมูลรายการที่เรียงลำดับค่า Support จากมากไปน้อย

| รายการสินค้า                    | จำนวนที่เกิดขึ้นใน TID | Support |
|---------------------------------|------------------------|---------|
| Crab Rangoon                    | 704                    | 16.55%  |
| Orange Chicken                  | 608                    | 14.29%  |
| Miso Soup                       | 543                    | 12.76%  |
| Stir fried pork with chili      | 542                    | 12.74%  |
| Salmon                          | 469                    | 11.02%  |
| Stir fried pork with miso paste | 462                    | 10.86%  |
| Tako Wasabi                     | 455                    | 10.70%  |
| ...                             | ...                    | ...     |

สร้างรูปแบบของสินค้าที่มักซื้อพร้อมกัน ด้วยขั้นตอนวิธีของ เอพี – ไกรธ สามารถแสดงผลได้ดังตารางที่ 5. แสดงตัวอย่างรูปแบบของรายการสินค้าที่มักซื้อพร้อมกัน

ตารางที่ 5. แสดงตัวอย่างรูปแบบของรายการสินค้าที่มักซื้อพร้อมกัน

| Size | Support | Item 1                     | Item 2 |
|------|---------|----------------------------|--------|
| 1    | 0.165   | Crab Rangoon               |        |
| 1    | 0.143   | Orange Chicken             |        |
| 1    | 0.128   | Miso Soup                  |        |
| 1    | 0.127   | Stir fried pork with chili |        |
| ...  | ...     | ...                        | ...    |

| Size | Support | Item 1                     | Item 2                          |
|------|---------|----------------------------|---------------------------------|
| 2    | 0.029   | Crab Rangoon               | Orange Chicken                  |
| 2    | 0.025   | Stir fried pork with chili | Stir fried pork with miso paste |
| 2    | 0.024   | Crab Rangoon               | Stir fried pork with chili      |
| 2    | 0.022   | Crab Rangoon               | Stir fried pork with miso paste |
| ...  | ...     | ...                        | ...                             |

4.2.2 สร้างกฎความสัมพันธ์ การสร้างกฎความสัมพันธ์ได้มาจากค่าเซตรายการความถี่ที่ทำได้ โดยกำหนดค่าสนับสนุนขั้นต่ำเท่ากับ 0.05 [16] เนื่องจากข้อมูลค่อนข้างมีการกระจายกลุ่มข้อมูลและปริมาณสินค้าภายในร้านที่หลากหลาย หากกำหนดค่ามากกว่า 0.05 จะไม่สามารถหากฎความสัมพันธ์ที่ดีที่สุดได้ ผลลัพธ์จากการคำนวณเมื่อกำหนดค่าสนับสนุนขั้นต่ำเท่ากับ 0.05 และค่าความเชื่อมั่นขั้นต่ำเท่ากับ 0.20 จะได้กฎความสัมพันธ์ของการซื้ออาหารญี่ปุ่น จำนวน 8 กฎ ดังนี้

Alaska Roll => Miso Soup

Salmon Burner Roll => Crab Rangoon

Aburi Salmon => Tamago

Tamago => Salmon

Massago => Tamago

Unagi => Salmon


Aburi Salmon => Salmon

Tuna => Salmon

### 4.3 การวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น

การที่ธุรกิจจะสร้างยอดขายให้ประสบความสำเร็จต้องรู้และเข้าใจกลยุทธ์การขาย (Sales Strategy) [17] ซึ่งเป็นการวางแผนที่จะเข้าถึงกลุ่มลูกค้าเป้าหมายเพื่อขายสินค้า ตลอดจนยอดขายที่ตั้งเป้าเอาไว้และรายละเอียดการดำเนินงานเพื่อให้บรรลุวัตถุประสงค์ โดยกลยุทธ์การขายประกอบด้วยกระบวนการที่ชัดเจน การสำรวจและทำความเข้าใจตลาด การทำความเข้าใจลูกค้าหรือกลุ่มลูกค้าที่จะซื้อสินค้า การเข้าใจเส้นทางของผู้บริโภค (Customer Journey) ที่เข้ามาสัมผัสสินค้าหรือธุรกิจ และการวางแผนปฏิบัติการเพื่อให้ธุรกิจเป็นไปตามเป้าหมายที่วางไว้

ผลการวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น สามารถแสดงสารสนเทศบนหน้ากระดาน (Dashboard) ให้แก่ผู้ใช้งานได้ดังรูปที่ 7. แสดงผลการวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น



รูปที่ 7. แสดงผลการวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น

ผลการวิเคราะห์ข้อมูลพบว่า สินค้าที่ขายดี คือ Crab Rangoon, Orange Chicken, Miso Soup, Stir fried pork with chili sauce, Salmon, Stir fried pork with miso paste, Tako Wasabi, Sesame Chicken และ Set Punpla A ตามลำดับ อาหารประเภทที่ขายดีที่สุด คือ Set Punpla, Entree, Specially Maki, Maki และ Nigiri/Sashimi ตามลำดับ ลูกค้าชำระเงินด้วยเงินสดมากที่สุด 25.65% รองลงมาคือบัตรเครดิตมาสเตอร์การ์ด 21.21% บัตรเครดิตไดเนอร์สคลับอินเตอร์เนชั่นแนล 19.09% ชำระผ่านคิวอาร์โค้ด 18.14% และชำระด้วยช่องทางอื่น 15.91% ช่วงเวลาที่ลูกค้ามาใช้บริการมากที่สุด คือ 18.00 – 19.00 น. รองลงมาคือ 19.00 – 20.00 น. ลูกค้ามักจะทานอาหารที่ร้านมากที่สุด 85.01% สั่งกลับบ้าน 14.22% และใช้บริการจัดส่ง 0.77% ลูกค้ามีพฤติกรรมการใช้บริการที่ร้านด้วยตนเองมากที่สุด 61.76% สั่งผ่านบริการแกร็บฟู้ด 35.46% สั่งผ่านบริการไลน์แมน 1.75% และไม่มีการระบุ 1.02%

## 5. การประเมินผล (Evaluation)

การพิจารณาว่ากฎความสัมพันธ์ที่สร้างขึ้นหรือไม่ จำเป็นจะต้องมีตัววัดประสิทธิภาพของกฎ คือ

**ค่าความเชื่อมั่น (Confidence)** คือ การแสดงค่าความเชื่อมั่นของกฎความสัมพันธ์ [16] เมื่อรูปแบบ LHS ที่อยู่ทางด้านซ้ายของกฎเกิดขึ้นแล้วมีโอกาสเกิดรูปแบบ RHS ที่อยู่ทางด้านขวามากน้อยเท่าใด ซึ่งจะมีค่าอยู่ระหว่าง 0 – 1 ถ้าใกล้เคียง 1 หมายถึงมีความเชื่อมั่นในการหาความสัมพันธ์มาก อาจคำนวณค่าที่จะเกิดขึ้นในรูปแบบเปอร์เซ็นต์ก็ได้ วิธีการคำนวณค่าความเชื่อมั่นได้จาก

$$\text{Confidence (LHS} \Rightarrow \text{RHS)} = \frac{\text{Support(LHS,RHS)}}{\text{Support(LHS)}}$$

Support (LHS, RHS) คือค่าสนับสนุนที่รูปแบบ LHS และ RHS ของกฎความสัมพันธ์เกิดขึ้นพร้อม ๆ กัน [13] ส่วน Support (LHS) คือค่าสนับสนุนรูปแบบที่อยู่ด้านซ้ายของกฎความสัมพันธ์

**ค่าสหสัมพันธ์หรือเรียกว่าค่าลิฟต์ (Lift)** คือค่าที่บ่งบอกว่าการเกิดรูปแบบ LHS และ RHS มีความสัมพันธ์กันมากหรือไม่ [16] โดยถ้าค่าสหสัมพันธ์มีค่ามากกว่า 1 แสดงว่ากฎทั้งสองมีความสัมพันธ์กัน ถ้าค่าสหสัมพันธ์มีค่าเท่ากับ 1 แสดงว่ารูปแบบ LHS และ RHS ไม่ขึ้นต่อกัน (Independent) ค่าลิฟต์คำนวณได้จาก

$$\text{Lift(LHS} \Rightarrow \text{RHS)} = \frac{\text{Support(LHS,RHS)}}{\text{Support(LHS)} \times \text{Support(RHS)}}$$

การหาค่าความเชื่อมั่น (Confidence) และค่าสหสัมพันธ์ (Lift) แสดงได้ดังตารางที่ 6. แสดงค่าสนับสนุน ค่าความเชื่อมั่น และค่าสหสัมพันธ์

ตารางที่ 6. แสดงค่าสนับสนุน ค่าความเชื่อมั่น และค่าสหสัมพันธ์

| กฎ | ฟรีเค้นไอเทม           | ค่าสนับสนุน | ค่าความเชื่อมั่น | ค่าสหสัมพันธ์ |
|----|------------------------|-------------|------------------|---------------|
| 1  | Tuna => Salmon         | 0.0165      | 0.5294           | 5.0159        |
| 2  | Aburi Salmon => Salmon | 0.0118      | 0.3825           | 3.6241        |
| 3  | Unagi => Salmon        | 0.0125      | 0.3546           | 3.3597        |

| กฎ | ฟรีเค้นไอเทม                       | ค่าสนับสนุน | ค่าความเชื่อมั่น | ค่าสหสัมพันธ์ |
|----|------------------------------------|-------------|------------------|---------------|
| 4  | Massago => Tamago                  | 0.0162      | 0.3292           | 6.0102        |
| 5  | Tamago => Salmon                   | 0.0122      | 0.2961           | 2.8057        |
| 6  | Aburi Salmon => Tamago             | 0.0127      | 0.2842           | 5.1879        |
| 7  | Salmon Burner Roll => Crab Rangoon | 0.0143      | 0.2488           | 1.5080        |
| 8  | Alaska Roll => Miso Soup           | 0.0165      | 0.2421           | 1.8964        |

2.8 การนำไปใช้ เป็นการนำเอาข้อมูลที่เป็นผลลัพธ์มาทดลองใช้จริงเสนอให้ร้านปั้นป้าอาหารญี่ปุ่นนำผลลัพธ์มาทดลองปฏิบัติงานจริงกับธุรกิจ โดยแปลงผลลัพธ์ของกฎที่มีนำไปใช้งานจริงในการออกโปรโมชันและให้พนักงานต้อนรับนำเสนอรายการสินค้าที่คาดว่าลูกค้าจะซื้อร่วมกันซึ่งเป็นไปตามวัตถุประสงค์ของทางร้านที่เพื่อช่วยเพิ่มยอดขาย โดยพิจารณาค่าความเชื่อมั่นที่ยอมรับได้ โดยเรียงลำดับค่าความเชื่อมั่นจากสูงสุดไปต่ำสุด ค่าสหสัมพันธ์ที่มากกว่า 1 พร้อมทั้งนำผลการวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่นในรูปแบบ สารสนเทศแก่เจ้าของธุรกิจ เพื่อจะได้นำไปปรับปรุงและพัฒนากระบวนการภายในร้านต่อไปในอนาคต

## 6. สรุปผลการวิจัย

ผลการศึกษาข้อมูล รายการสั่งซื้ออาหารร้านปั้นป้าอาหารญี่ปุ่น ข้อมูลระหว่างวันที่ กันยายน 2563 - พฤษภาคม 2564 จำนวน 16,409 รายการ มีวัตถุประสงค์การวิจัยคือเพื่อค้นหารูปแบบกฎความสัมพันธ์ของรายการสั่งซื้ออาหารญี่ปุ่น โดยใช้อัลกอริทึมเอพี – โกรธ และเพื่อวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่นกรณีศึกษาข้อมูลจากร้านอาหารปั้นป้าอาหารญี่ปุ่น ตามกรอบแนวคิดในการวิจัยและขั้นตอนการวิจัย ดังนี้

**6.1 ผลการสร้างกฎความสัมพันธ์** พิจารณาจากค่าเซตรายการความถี่ โดยกำหนดค่าสนับสนุนขั้นต่ำเท่ากับ 0.05 และค่าความเชื่อมั่นขั้นต่ำเท่ากับ 0.20 ได้กฎความสัมพันธ์ของการซื้ออาหารจำนวน 8 กฎ แสดงดังตารางที่ 6. แสดงค่าสนับสนุน ค่าความเชื่อมั่น และค่าสหสัมพันธ์จากกฎความสัมพันธ์

**6.2 ผลการประเมินผล (Evaluation)** เพื่อพิจารณาว่ากฎความสัมพันธ์ที่สร้างได้ดีหรือไม่ ด้วยการคำนวณหาค่าความเชื่อมั่น (Confidence) และค่าสหสัมพันธ์ (Lift) สามารถอธิบายกฎความสัมพันธ์ของการสั่งซื้ออาหารที่เกิดขึ้นทั้ง 8 กฎ ตามตารางที่ 6 ได้ดังนี้

กฎข้อที่ 1 : ถ้าลูกค้าจะซื้อ Tuna แล้ว ลูกค้าจะซื้อ Salmon ด้วย ค่าความเชื่อมั่นที่ 52.94% ค่าสนับสนุนที่ 0.016455 และ ค่าสหสัมพันธ์ 5.015852221

กฎข้อที่ 2 : ถ้าลูกค้าจะซื้อ Aburi Salmon แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่าความเชื่อมั่นที่ 38.25% ค่าสนับสนุนที่ 0.011754 และ ค่าสหสัมพันธ์ 3.624082661

กฎข้อที่ 3 : ถ้าลูกค้าจะซื้อ Unagi แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่าความเชื่อมั่นที่ 35.46% ค่าสนับสนุนที่ 0.012459 และ ค่าสหสัมพันธ์ 3.359711889

กฎข้อที่ 4 : ถ้าลูกค้าจะซื้อ Massago แล้ว ลูกค้าจะซื้อ Tamago ด้วยค่าความเชื่อมั่นที่ 32.62% ค่าสนับสนุนที่ 0.016220 และ ค่าสหสัมพันธ์ 6.010236451

กฎข้อที่ 5 : ถ้าลูกค้าจะซื้อ Tamago แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่าความเชื่อมั่นที่ 29.61% ค่าสนับสนุนที่ 0.012224 และ ค่าสหสัมพันธ์ 2.805719912

กฎข้อที่ 6 : ถ้าลูกค้าจะซื้อ Aburi Salmon แล้ว ลูกค้าจะซื้อ Tamago ด้วยค่าความเชื่อมั่นที่ 28.42% ค่าสนับสนุนที่ 0.012694 และ ค่าสหสัมพันธ์ 5.187926546

กฎข้อที่ 7 : ถ้าลูกค้าจะซื้อ Salmon Burner Roll แล้ว ลูกค้าจะซื้อ Crab Rangoon ด้วยค่าความเชื่อมั่นที่ 24.88% ค่าสนับสนุนที่ 0.014339 และ ค่าสหสัมพันธ์ 1.507975895

กฎข้อที่ 8 : ถ้าลูกค้าจะซื้อ Alaska Roll แล้ว ลูกค้าจะซื้อ Miso Soup ด้วยค่าความเชื่อมั่นที่ 24.21% ค่าสนับสนุนที่ 0.016455 และ ค่าสหสัมพันธ์ 1.896386916

**6.3 ผลการวิเคราะห์ข้อมูลการขาย** ผลการวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่นพบว่า สินค้าที่ขายดีที่สุด คือ Crab Rangoon อาหารประเภทที่ขายดีที่สุด คือ Set Pumpla วิธีการชำระเงินของลูกค้าด้วยเงินสดมากที่สุด 25.65% ช่วงเวลาที่ลูกค้ามาใช้บริการมากที่สุด คือ เวลาประมาณ 18.00 – 19.00 น. ลูกค้ามักจะทาน

อาหารที่ร้านมากที่สุด 85.01% ลูกค้ามีพฤติกรรมการใช้บริการที่ร้านด้วยตนเองมากที่สุด 61.76%

## 7. อภิปรายผลการวิจัย

งานวิจัยนี้เป็นการหาแบบกฎความสัมพันธ์ของรายการสั่งซื้ออาหารญี่ปุ่น ด้วยอัลกอริทึมเอพี – โกรธ โดยออกแบบกรอบแนวคิดในการวิจัยและมีวิธีวิจัยเป็นไปตามขั้นตอนที่สอดคล้องกับ CRISP – DM โดยธุรกิจร้านอาหารป็นป่า มีความพยายามหาโอกาสทางธุรกิจ ด้วยการวิเคราะห์ข้อมูลความต้องการบริโภคอาหารญี่ปุ่น ได้รวบรวมข้อมูลข้อมูลระหว่างวันที่ 1 กันยายน 2563 - 31 พฤษภาคม 2564 จำนวนใบเสร็จ 4,254 ใบ และจำนวนแถวข้อมูลรายการสั่งอาหาร 16,409 รายการ จากกระบวนการเตรียมข้อมูลพบว่ามีรูปแบบการจัดเก็บข้อมูลประเภทสินค้าและชื่อรายการสินค้ามีการจัดเก็บที่แตกต่างกัน ทั้งที่เป็นสินค้าชนิดเดียวกัน จึงได้แก้ไขให้ถูกต้อง หลังจากนั้นได้ลบข้อมูลสินค้าที่ไม่ถูกต้อง รวมทั้งสินค้าประเภทเครื่องดื่มและเครื่องดื่มแอลกอฮอล์ เนื่องจากทางร้านไม่ต้องการนำไปวิเคราะห์และส่งเสริมการขาย ส่งผลให้คงเหลือข้อมูลจำนวน 13,377 รายการทำการแปลงรูปแบบของข้อมูลให้อยู่ในรูปแบบที่พร้อมนำไปใช้ในการสร้างแบบจำลอง โดยหาค่าจำนวนที่เกิดขึ้นใน TID ค่าสนับสนุน ค่าเซตรายการความถี่ ค่าความเชื่อมั่นและค่าสหสัมพันธ์ เพื่อค้นหารูปแบบ กฎ และความสัมพันธ์ของข้อมูลที่ซ่อนอยู่ในชุดข้อมูลที่ดีที่สุด กำหนดค่าสนับสนุนขั้นต่ำเท่ากับ 0.05 และค่าความเชื่อมั่นขั้นต่ำเท่ากับ 0.20

ผลการวิจัยพบว่า กฎความสัมพันธ์ของการสั่งซื้ออาหารที่เกิดขึ้นจำนวน 8 กฎ โดยเรียงลำดับตามความเชื่อมั่นจากมากไปน้อย ดังนี้ ถ้าลูกค้าจะซื้อ Tuna แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่าความเชื่อมั่นที่ 52.94% ถ้าลูกค้าซื้อ Aburi Salmon แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่าความเชื่อมั่นที่ 38.25% ถ้าลูกค้าซื้อ Unagi แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่าความเชื่อมั่นที่ 35.46% ถ้าลูกค้าซื้อ Massago แล้ว ลูกค้าจะซื้อ Tamago ด้วยค่าความเชื่อมั่นที่ 32.62% ถ้าลูกค้าซื้อ Tamago แล้ว ลูกค้าจะซื้อ Salmon ด้วยค่า



ความเชื่อมั่นที่ 29.61% ถ้าลูกค้าจะซื้อ Aburi Salmon แล้ว ลูกค้าจะซื้อ Tamago ด้วยค่าความเชื่อมั่นที่ 28.42% ถ้าลูกค้าซื้อ Salmon Burner Roll แล้ว ลูกค้าจะซื้อ Crab Rangoon ด้วยค่าความเชื่อมั่นที่ 24.88% ถ้าลูกค้าซื้อ Alaska Roll แล้ว ลูกค้าจะซื้อ Miso Soup ด้วยค่าความเชื่อมั่นที่ 24.21% ทุกกฎความสัมพันธ์มีค่าสหสัมพันธ์มากกว่า 1 แสดงว่ารายการสินค้ามีความสัมพันธ์ที่ขึ้นต่อกัน จากการวิเคราะห์พบว่า Tuna และ Salmon มีความสัมพันธ์ที่ขึ้นต่อกันสูงสุดสอดคล้องกับบทความที่บริษัท Noble Mono ซึ่งเป็นผู้นำเข้าวัตถุดิบจากประเทศญี่ปุ่นสู่ร้านอาหารชื่อดังทั่วประเทศไทย ได้ระบุไว้ว่าในประเทศไทย Bluefin Tuna และ Salmon เป็นปลาที่คนไทยได้รับความนิยมรับประทานสูงสุด โดยประเทศญี่ปุ่นเป็นแหล่งคัดคุณภาพที่ดีที่สุดและเป็นแหล่งส่งออกปลาคุณภาพดีอันดับต้นๆ ของโลก[18] สอดคล้องกับงานวิจัยของทิพวรรณ อภิวันท์วรรณ เรื่องมองสำนวนภาษาญี่ปุ่นและธรรมเนียมปฏิบัติจากวัฒนธรรมการกินอาหารของคนญี่ปุ่นได้ระบุว่า วัฒนธรรมการกินอาหารของคนญี่ปุ่น [19] ให้ความสำคัญกับการกินอาหารมิใช่เฉพาะเพียงรสชาติและกลิ่นเท่านั้น แต่เน้นไปถึงหน้าตาหรือรูปลักษณ์ของอาหารที่สะท้อนถึงความใส่ใจต่อรสชาติที่เกิดจากวัตถุดิบตามธรรมชาติ ไม่นิยมการปรุงแต่งรสอาหารจนเกินไป ในมือเช้าจะเน้นผักตองที่คองด้วยเกลือ เช่นหัวไชเท้า ผักกาดขาว แดงกวา นอกจากนั้นที่ขาดไม่ได้ในทุกมือ คือ ซุปมิโซะ (misoshiro) มื้อกลางวันจะทานแบบเรียบง่ายที่เรียกว่า tema no kakaranai mono เช่น ข้าวใส่น้ำชา (Ochazuke) กินคู่กับปลาแซลมอนย่าง หรือสาหร่ายอบแห้ง มือเย็นส่วนใหญ่ คือ มีข้าว ซุปมิโซะ หรือซุปที่ไม่ได้ใส่เต้าเจี้ยว อาหารหลักที่นิยม คือ ข้าวแกงกะหรี่แบบญี่ปุ่น หากเปรียบเทียบกับอาหารไทยในมือเดียวกัน คนญี่ปุ่นกินน้อยชนิดกว่าคนไทย ยกเว้นเมื่อมีโอกาสพิเศษ จะทำอาหารหลากหลายชนิดขึ้น เช่น เทมปุระ ปลาดิบ เป็นต้น ผลการวิเคราะห์ข้อมูลการขายอาหารญี่ปุ่น พบว่า สินค้าที่ขายดีที่สุด คือ Crab Rangoon อาหารประเภทที่ขายดีที่สุด คือ Set Punpla วิธีการชำระเงินของลูกค้าด้วยเงินสดมากที่สุด 25.65%

ช่วงเวลาที่ลูกค้าใช้บริการมากที่สุด คือ เวลาประมาณ 18.00 – 19.00 น. ลูกค้ามักจะทานอาหารที่ร้านมากที่สุด 85.01% ลูกค้ามีพฤติกรรมการใช้บริการที่ร้านด้วยตนเองมากที่สุด 61.76% ซึ่งสอดคล้องกับผลการวิจัยของ ชนสรณ์ ไตรกราน เรื่องพฤติกรรมการบริโภคอาหารญี่ปุ่นของผู้บริโภคในเขตอำเภอเมือง จังหวัดชลบุรี[20] ที่พบว่าปัจจัยด้านประเภทอาหารหรือผลิตภัณฑ์เป็นปัจจัยหลักที่ส่งผลต่อการเลือกรับประทานอาหารญี่ปุ่น เช่น ประเภทชาซิมิ (ปลาดิบ) ปัจจัยด้านราคาที่เหมาะสมกับคุณภาพสินค้าจะส่งผลต่อปริมาณการสั่งซื้อที่มากขึ้น ลูกค้าส่วนใหญ่เป็นพนักงานเอกชนที่มีรายได้มากกว่า 15,000 บาท การรับประทานอาหารญี่ปุ่นมักจะทานช่วงเย็น โดยจะรับประทานภายในร้านตามศูนย์การค้า และปัจจัยการส่งเสริมทางการตลาด ผู้บริโภคให้ความสำคัญโปรโมชั่นตามฤดูกาล ส่วนลดพิเศษสำหรับสมาชิกและส่วนลดจากบัตรเครดิต จากการวิจัยเรื่องการค้าปลีกหากฎความสัมพันธ์และวิเคราะห์ข้อมูลเพื่อเพิ่มประสิทธิภาพการขายอาหารญี่ปุ่นนี้ หวังว่าจะสามารถนำกฎความสัมพันธ์ไปประยุกต์ใช้ในการจัดโปรโมชั่นหรือแนะนำการขายอาหารให้แก่ลูกค้า รวมทั้งวิเคราะห์พฤติกรรมการสั่งอาหารของลูกค้า ช่วยเพิ่มประสิทธิภาพการขาย สร้างความได้เปรียบทางการแข่งขัน การวางแผนกลยุทธ์ทางการตลาด และหาโอกาสทางธุรกิจต่อไป

## 8. ข้อเสนอแนะ

ผู้วิจัยได้จัดทำข้อเสนอแนะ เพื่อเป็นแนวทางปรับปรุงการวิจัยหรือต่อยอดในอนาคต ดังนี้

1. การทำเหมืองข้อมูล ด้วยวิธีการวิเคราะห์หากฎความสัมพันธ์ มีอัลกอริทึมที่หลากหลาย และมีกระบวนการวิจัยที่แตกต่างกันออกไป ดังนั้นในแนวทางการปรับปรุงการวิจัยหรือต่อยอดสามารถปรับเปลี่ยนรูปแบบกระบวนการวิจัยหรืออัลกอริทึม และสามารถนำผลการวิจัยมาเปรียบเทียบและทดลองหาโอกาสทางธุรกิจที่เหมาะสม
2. แบบจำลองกฎความสัมพันธ์ที่ได้สามารถนำไปประยุกต์ใช้ในการพัฒนาระบบ เพื่อแนะนำการสั่งซื้ออาหารให้แก่ลูกค้า

พนักงาน รวมทั้งจัดทำโปรโมชั่น อีกทั้งสามารถนำข้อเสนอแนะจากผู้เชี่ยวชาญ เพื่อหาโอกาสทางธุรกิจรวมทั้งแนวทางความเป็นไปได้ของธุรกิจให้สอดคล้องกับสถานการณ์ที่มีการเปลี่ยนแปลงตลอดเวลา

3. การวิจัยนี้ได้ทดลอง กรณีศึกษาร้านปิ้งป้าอาหารญี่ปุ่นเท่านั้น ซึ่งยังไม่ได้ศึกษาปัจจัยอื่นที่อยู่นอกเหนือจากข้อมูลที่มีอยู่ เช่น ข้อมูลพื้นฐานของผู้บริโภค ได้แก่ เพศ อายุ รายได้ อาชีพ เป็นต้น ที่อาจจะมีผลต่อความสัมพันธ์ของข้อมูลในการตั้งชื่ออาหารของลูกค้า

## เอกสารอ้างอิง

- [1] JETRO Bangkok, “Survey of Japanese restaurants in Thailand 2020,” Japan External Trade Organization (JETRO), pp. 1 – 9, 2020.
- [2] S. Suwanaphokin, “Business Plan for Japanese Restaurant,” Independent research is part of curricular education. M.S. thesis, Business Administration Small and Medium Enterprises Program, Bangkok University, Bangkok, Thailand, 2018.
- [3] L. Tomar, W. Guicheney, H. Kyarisiima, and T. Zimani. Big Data in the Public Sector, 1th ed., Washington, D.C., USA. Inter-American Development Bank. 2016.
- [4] Report on the overall situation of food products in the ASEAN region. Food products in the ASEAN region. Overseas Trade Promotion Office, Myanmar, 2021.
- [5] W. L. Winston, Microsoft Excel 2019: data analysis and business modeling. New York, New York: Published With The Authorization of Microsoft Corporation by Pearson Education, Inc, 2019.
- [6] B. Syverson and J. Murach, Murach’s SQL server 2019 for developers : training and reference. Fresno, Ca: Mike Murach & Associates, Incorporated, 2020.
- [7] C. Helberg, Data mining with confidence. Chicago: SPSS Inc, 2002.
- [8] GarcíaS., Julián Luengo, and F. Herrera, Data preprocessing in data mining. Cham Heidelberg New York Dordrecht London Springer, 2015.
- [9] N. Kaoungku, “A DISCRETIZATION METHOD FOR ASSOCIATION RULE MINING,” M.S. thesis, Computer Engineering., Suranaree University of Technology, Thailand, 2012.
- [10] B. Mahatthanachai, K. Malaivongs, S. Somhom and N. Tantranont, “Association Rule of Subjects Affecting Student Dropout Using Apriori Algorithm,” in Proceeding of 5th Kamphaeng Phet Rajabhat University National Conference, Thailand, pp. 459, 2016.
- [11] P.N. Tan, M. Steinbach and V. Kumar. Introduction to data mining, 1<sup>st</sup>, Pearson Addison-Wesley, 2006
- [12] K. Kongupon, Th. Rakthammanon, K. Waiyamai, “Techniques for collecting frequently occurring set items. by considering the minimum confidence value to support the increase of data,” Information Technology Journal, Vol. 3 No. 2, pp. 7 - 10. 2007.
- [13] S. Kongmaneepon, “Finding association rule from the database of purchasing MYHEALTH supplement to customer using the FP-GROWTH algorithm and customer segmentation according to purchasing behavior of MYHEALTH products with RFM techniques of rapidminer: A case study of a pharmacy chain,” Journal of Information Systems in Business (JISB), Vol. 5, No. 4, pp. 21 – 39. 2021.
- [14] N. Khamwichai, “Association Rules”, in Practical Data Mining with RapidMiner Studio 7, pp.35 – 40. 2016.
- [15] S. Zhang, X. Wu, C. Zhang, and J. Lu, “Computing the minimum-support for mining frequent patterns,” Knowl. Inf. Syst., vol. 15, no. 2, pp. 233–257, 2008.
- [16] prim, “5 Ways to Create a Simple Step-By-Step Sales Strategy,” DEMETER ICT, 21-Jan-2021. [Online]. Available: <https://www.dmit.co.th/th/zendesk-updates-th/5-steps-to-sales-strategy/>. [Accessed: 29-Jan-2022].
- [17] “Bluefin Tuna vs Salmon History Comparison 6 Differences 2 Popular Raw Fish,” NobleMono. [Online].

Available:

<https://www.noblemono.com/blogs/news/bluefin-tuna-vs-salmon-6-2>. [Accessed: 30-Jan-2022].

- [18] T. Apiwanworarat. “Japanese Expressions and practice from Japanese Food Culture,” PANYAPIWAT JOURNAL, vol. 5, no. 2, pp. 265–273, Jul. 2014.
- [19] Ch. Tokran. Consumption Behaviors of Japanese Consumers in Mueang district Chiang Rai Province. M.S. thesis, Business Administration Department, Sripatum University Chonburi Campus, Thailand, 2008.

การพยากรณ์ปริมาณน้ำฝนระยะสั้นในบริเวณพื้นที่สนามบินสุวรรณภูมิด้วยโครงข่าย  
ระบบประสาทแบบย้อนกลับ

## Short Term Precipitation Forecasting using Recurrent Neural Networks, a Case Study of Suvarnabhumi Airport

รักศณา ภูสีเขียว\* และ สุรณพีร์ ภูมิตูฬสาร

*Ragkana Phooseekhiwe\* and Suronapee Phoomvuthisarn*

ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย

*Department of Statistics, Chulalongkorn Business School, Chulalongkorn University*

Received: November 16, 2021; Revised: March 31, 2022; Accepted: April 08, 2022; Published: June 29, 2022

**ABSTRACT** – Rainfall is one of the key important factors affecting human life. Accurate precipitation forecasting allows humans to better prepare for various activities that will happen in the future. However, in some situations, the availability of weather data is limited, making it difficult to make accurate forecasting. Currently, much research has chosen deep neural networks as an algorithm to train forecasting models. The main idea is to come up with relevant features at the architecture level. Based on this paradigm, it has been shown that the appropriate deep neural network architecture can flexibly mix and match features that are relevant in predictions. Consequently, most of the existing research then focuses on some of the techniques to improve the performance of the models without paying much attention on the issues of adding relevant features. However, when the training data is limited, deep neural networks might not scale very well, thus making it difficult to mix and match features for predictions. This imposes a research question of how effective the proposed forecasting models might be when not adding relevant features to the models. The aims of this research are to develop and compare the efficiency of various models for short-term precipitation forecasting with and without adding relevant features. The experiment consists of 2 parts: (1) The experiment by exploring whether the models with relevant featured provided can achieve higher accuracy compared to original models in equivalent environments, and (2) The experiment by comparing accuracy between 5 models (ARIMA, ARIMAX, RNN, LSTM and GRU). The weather dataset, which is very limited in quantity, used in this research was collected from Suvarnabhumi Airport. The results show that adding relevant features can enhance the forecasting performance of the model when the weather data is limited. In addition, the GRU model with relevant featured provided is the most effective prediction.

**KEYWORDS:** Long Short-Term Memory, Predictive analytics, Rainfall prediction, Recurrent Neural Network, Neural Network, Gated Recurrent Unit, Imbalanced data

**บทคัดย่อ** -- ปริมาณน้ำฝนนับเป็นปัจจัยสำคัญอย่างหนึ่งที่มีผลต่อการดำเนินชีวิตของมนุษย์ การพยากรณ์ปริมาณน้ำฝนที่มีความแม่นยำช่วยให้มนุษย์เตรียมพร้อมสำหรับกิจกรรมต่างๆ ที่จะเกิดขึ้นในอนาคตได้ดี อย่างไรก็ตามในบางสถานการณ์ ความพร้อมใช้งานของข้อมูลสภาพอากาศมีจำกัด ทำให้การพยากรณ์ปริมาณน้ำฝนอย่างแม่นยำนั้นเป็นเรื่องที่ยาก ปัจจุบันหลายๆ งานวิจัยที่เกี่ยวข้องได้เลือกโครงข่ายประสาทเทียมเชิงลึกเป็นอัลกอริทึมในการฝึกแบบจำลองเพื่อใช้ในการพยากรณ์

\*Corresponding Author: [ragkana.ph@gmail.com](mailto:ragkana.ph@gmail.com)

แนวคิดหลักคือการสร้างตัวแปรคุณลักษณะ (Feature) ที่เกี่ยวข้องในระดับสถาปัตยกรรม จากหลักการนี้สถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึกที่เหมาะสมสามารถผสมผสานและจับคู่คุณลักษณะที่เกี่ยวข้องในการพยากรณ์ได้อย่างเหมาะสม ผลที่ตามมาจากงานวิจัยที่มีอยู่ส่วนใหญ่จึงมุ่งเน้นไปที่เทคนิคบางอย่างเพื่อปรับปรุงประสิทธิภาพของแบบจำลอง โดยไม่ได้ให้ความสำคัญกับการเพิ่มคุณลักษณะให้กับตัวแบบมากนัก อย่างไรก็ตามเมื่อข้อมูลการฝึกฝนมีจำนวนจำกัด โครงข่ายประสาทเทียมเชิงลึกอาจจะทำงานได้ไม่เต็มประสิทธิภาพมากนัก ทำให้การผสมผสานและจับคู่คุณลักษณะที่เกี่ยวข้องในการพยากรณ์ทำได้ไม่ดีตามไปด้วย สิ่งนี้ทำให้เกิดคำถามงานวิจัยว่าแบบจำลองการพยากรณ์ปริมาณน้ำฝนที่ได้ถูกนำเสนอมีประสิทธิภาพที่ดีเพียงพอรึหรือไม่ เมื่อไม่ได้มีการเพิ่มคุณสมบัติที่เกี่ยวข้องให้กับแบบจำลอง งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองต่างๆ ในการพยากรณ์ปริมาณน้ำฝนสะสมในระยะสั้นที่มีและไม่มี การเพิ่มตัวแปรคุณสมบัติที่เกี่ยวข้อง โดยได้แบ่งการทดลองออกเป็น 2 ส่วนเพื่อวัดประสิทธิภาพ คือ 1) การเปรียบเทียบประสิทธิภาพของตัวแบบที่มีการเพิ่มตัวแปรคุณลักษณะที่เกี่ยวข้องว่ามีความถูกต้องแม่นยำขึ้นหรือไม่เมื่อเทียบกับแบบจำลองที่ไม่ได้มีการเพิ่มตัวแปรคุณลักษณะในสภาพแวดล้อมที่เทียบเท่ากัน และ 2) การเปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมของแบบจำลองที่สนใจศึกษา ได้แก่ ARIMA ARIMAX RNN LSTM และ GRU ข้อมูลที่นำมาใช้ในงานวิจัยนี้เป็นข้อมูลสภาพอากาศและปริมาณน้ำฝนสะสมที่รวบรวมมาจากพื้นที่สนามบินสุวรรณภูมิ จากผลการศึกษาทั้ง 2 ส่วนพบว่า การเพิ่มตัวแปรคุณลักษณะสามารถเพิ่มประสิทธิภาพการพยากรณ์ให้กับตัวแบบได้ในกรณีที่ข้อมูลนำมาฝึกฝนตัวแบบมีจำนวนจำกัด โดย แบบจำลอง GRU ให้ประสิทธิภาพในการพยากรณ์มากที่สุด

**คำสำคัญ:** แบบจำลองหน่วยความจำระยะสั้นแบบยาว, การวิเคราะห์เชิงทำนาย, การพยากรณ์ปริมาณน้ำฝน, โครงข่ายระบบประสาทแบบย้อนกลับ, เครือข่ายระบบประสาทเทียม, โครงข่ายประสาทกลับ, ชุดข้อมูลไม่สมดุล

## 1. บทนำ

### 1.1 ที่มาและความสำคัญ

สภาพอากาศถือเป็นอีกหนึ่งสิ่งที่มีความเกี่ยวข้องกับมนุษย์มาตั้งแต่สมัยอดีต เพราะไม่ว่าจะเป็นการใช้ชีวิตประจำวัน การเดินทาง การประกอบอาชีพ (เช่น การทำการเกษตร ประมง เป็นต้น) หรือแม้แต่ใช้ในการตัดสินใจในการบริหารจัดการทรัพยากรระดับประเทศ ต่างก็มีความเกี่ยวข้องกับสภาพอากาศทั้งสิ้น แต่การจะพยากรณ์ปริมาณน้ำฝนอย่างแม่นยำ และมีประสิทธิภาพยังคงเป็นปัญหาสำคัญที่รัฐบาลหรือแม้แต่ภาคธุรกิจยังคงให้ความสนใจ เพราะนอกจากปัจจัยที่จะทำให้เกิดปรากฏการณ์ฝนตกนั้นจะมีความซับซ้อนแล้ว ตัวปรากฏการณ์ฝนตกเองก็เหมือนเป็นปรากฏการณ์แบบสุ่มที่ไม่อาจคาดเดาได้เช่นกัน เพื่อที่จะสามารถคาดการณ์หรือพยากรณ์ปริมาณน้ำฝนที่จะตกลงมาในช่วงต่างๆ ได้ จึงได้มีการนำเอาศาสตร์ต่างๆ เข้ามาช่วย

ในเริ่มแรก แบบจำลองที่มักถูกนำมาใช้ในการพยากรณ์ข้อมูลปริมาณน้ำฝนก็คือแบบจำลองอาร์มา(ARIMA) ดังเช่นในงานวิจัยของ (Wang et al., 2013) ที่มีการนำตัวแบบ SARIMA มาใช้ในการวิเคราะห์และพยากรณ์ กับงานวิจัยของ (Narayanan et al., 2013) ก็ได้ใช้ตัวแบบจำลอง ARIMA ในการพยากรณ์ปริมาณน้ำฝนในแต่ละสถานี พบว่าตัวแบบ ARIMA นั้นไม่ได้ตอบโจทย์สำหรับทุกสถานี เนื่องจากตัวแบบจำลอง ARIMA นั้นเป็นตัวแบบจำลองที่พิจารณาโดยใช้ตัวแปรเพียงตัวแปรเดียว แต่ในความเป็นจริง ปัจจัยหรือตัวแปรที่ส่งผลกับปริมาณน้ำฝนที่เกิดขึ้นในแต่ละช่วงเวลานั้น ไม่ได้มีเพียงปัจจัยเดียว เพื่อให้สามารถนำปัจจัยร่วมอื่นๆ มาพิจารณาพร้อมกับปริมาณน้ำฝนสะสมได้ ในงานวิจัยของ (Jalalkamali et al., 2015) จึงได้เลือกใช้แบบจำลอง ARIMAX ในการพยากรณ์ปริมาณน้ำฝนเพื่อคาดการณ์ปัญหาภัยแล้ง

ปัจจุบัน หลายๆ งานวิจัยที่เกี่ยวข้องกับการพยากรณ์อากาศหรือการพยากรณ์ปริมาณน้ำฝน ได้เลือกใช้โครงข่ายประสาท

เทียมเข้ามาช่วยในการพยากรณ์ อย่างเช่นในงานวิจัยของ (Hung et al., 2009) ที่ได้มีการนำโครงข่ายประสาทเทียม (ANN) เข้ามาช่วยในการวิเคราะห์นั้น ทำให้สามารถเพิ่มตัวแปรหรือคุณลักษณะด้านสภาพอากาศอื่นๆ เข้าไปเพื่อเพิ่มประสิทธิภาพในการพยากรณ์ ทั้งนี้ การสร้างตัวแบบโดยอาศัยโครงข่ายประสาทเทียมนั้นก็มีเทคนิคหรือวิธีการแตกแขนงแยกย่อยลงไปอีกมากมาย แต่ในการจัดการกับข้อมูลภูมิอากาศนั้น การใช้โครงข่ายระบบประสาทแบบย้อนกลับ (RNNs) จะเป็นตัวเลือกที่เหมาะสมที่สุดเนื่องจากโครงข่ายดังกล่าวนั้นถูกพัฒนามาเพื่อจัดการกับข้อมูลที่มีลักษณะเป็นลำดับ หรืออนุกรมเวลา

ในงานวิจัยของ (Poornima & Pushpalatha, 2019) ได้ทำการพัฒนาแบบจำลอง Intensified LSTM และทำการเปรียบเทียบประสิทธิภาพของแบบจำลองดังกล่าวกับแบบจำลองอาร์ิม่าและโครงข่ายระบบประสาทแบบย้อนกลับ ซึ่งพบว่าแบบจำลองที่เสนอนั้นมีความแม่นยำในการพยากรณ์มากกว่าอีก 2 แบบจำลอง ต่อมา (Yang et al., 2020) ได้ทดลองทำการเปรียบเทียบประสิทธิภาพของแบบจำลองหน่วยความจำระยะสั้นแบบยาวกับโครงข่ายประตูกลับ พบว่า นอกจากประสิทธิภาพของแบบจำลองทั้ง 2 จะดีหรือไม่ขึ้นอยู่กับจำนวนข้อมูลแล้วยังขึ้นกับและประเภทของข้อมูลที่น่าวิเคราะห์ด้วย เช่นเดียวกับในงานวิจัยของ (Aurnhammer & Frank, 2019) และ (Shewalkar, 2019) ได้ทำการศึกษาเปรียบเทียบประสิทธิภาพของโครงข่ายระบบประสาทแบบย้อนกลับกับชุดข้อมูลที่มีความหลากหลาย ซึ่งพบว่า แบบจำลอง GRU และ LSTM นั้น มีความเหมาะสมในการคาดการณ์หรือพยากรณ์กับชุดข้อมูลหลายๆประเภท แต่ทั้งนี้ ขึ้นอยู่กับตัวข้อมูลที่จะนำเข้ามาด้วยเช่นกัน อย่างไรก็ตาม งานวิจัยที่กล่าวมาข้างต้นมุ่งเน้นในเรื่องการปรับปรุงอัลกอริทึมของตัวแบบจำลอง จึงไม่ได้ทำการทดลองเกี่ยวกับการปรับปรุง แก๊ซข้อมูล หรือเพิ่มคุณลักษณะใดๆ เพื่อเพิ่มประสิทธิภาพในการพยากรณ์

งานวิจัยนี้จึงมุ่งเน้นการพัฒนาและวิเคราะห์เปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมล่วงหน้าในระยะสั้นร่วมกับการใช้ข้อมูลหลายตัวแปร โดยตัวแบบที่เหมาะสมจะมาจากผลการศึกษาและเปรียบเทียบใน 2 ประเด็นหลักคือ 1) การเปรียบเทียบประสิทธิภาพในการพยากรณ์ของตัวแบบที่ใช้ชุดข้อมูลที่แตกต่างกัน ระหว่างชุดข้อมูลผ่านการเพิ่มคุณลักษณะพิเศษกับชุดข้อมูลดั้งเดิม 2) เปรียบเทียบ

ประสิทธิภาพในการพยากรณ์ในช่วงเวลาถัดไปของโครงข่ายระบบประสาทแบบย้อนกลับที่สนใจศึกษา กับแบบจำลอง ARIMA และแบบจำลอง ARIMAX ซึ่งเป็นแบบจำลองที่เป็นที่นิยมทางสถิติในการพยากรณ์ข้อมูลประเภทอนุกรมเวลา และสำหรับโครงข่ายระบบประสาทแบบย้อนกลับที่สนใจนำมาศึกษาเปรียบเทียบ จะมีทั้งหมด 3 ตัว ได้แก่ โครงข่ายระบบประสาทแบบย้อนกลับ (RNN) แบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long short-term memory) และโครงข่ายประตูกลับ (Gated Recurrent Unit)

งานวิจัยนี้ได้ใช้ข้อมูลสภาพอากาศรายชั่วโมงจากสถานีตรวจวัดสภาพอากาศสนามบินนานาชาติสุวรรณภูมิ จังหวัดสมุทรปราการ (ข้อมูลดังกล่าวได้รับการสนับสนุนจากกรมอุตุนิยมวิทยา) ชุดข้อมูลดังกล่าวมีการเก็บสะสมตั้งแต่ปี ค.ศ. 2016 ถึงปี ค.ศ. 2020 โดยเราจะนำชุดข้อมูลนี้มาสร้างโครงข่ายระบบประสาทแบบย้อนกลับ เพื่อพยากรณ์ปริมาณน้ำฝนในอีก 3 ชั่วโมงข้างหน้า และเพื่อเพิ่มประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝน จึงจะทำการเพิ่มคุณลักษณะทางสถิติบางอย่างเข้าไปก่อนที่จะนำข้อมูลเข้าไปวิเคราะห์ในโครงข่ายระบบประสาทแบบย้อนกลับ พร้อมทั้งเปรียบเทียบค่าความแม่นยำในการพยากรณ์ที่ได้จากการพัฒนาตัวแบบต่างๆ

ทั้งนี้ จากผลการทดลองเปรียบเทียบประสิทธิภาพในการพยากรณ์ของตัวแบบที่ใช้ชุดข้อมูลที่แตกต่างกัน ระหว่างชุดข้อมูลผ่านการเพิ่มคุณลักษณะพิเศษทางสถิติกับชุดข้อมูลดั้งเดิม พบว่า การเพิ่มคุณลักษณะทางสถิติให้กับข้อมูลช่วยให้ประสิทธิภาพในการพยากรณ์ของแบบจำลองเพิ่มขึ้นกว่าการใช้เพียงคุณลักษณะดั้งเดิม และในบรรดาแบบจำลองทั้งหมดที่นำมาศึกษาเปรียบเทียบประสิทธิภาพในการพยากรณ์ชุดข้อมูลสภาพอากาศชุดนี้ พบว่า แบบจำลองโครงข่ายประตูกลับ (GRU) เป็นแบบจำลองที่มีประสิทธิภาพในการพยากรณ์ชุดข้อมูลนี้มากที่สุด

ซึ่งจากผลการพัฒนาและวิเคราะห์เปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนระยะสั้น องค์ความรู้ใหม่ที่ได้จากงานวิจัยนี้ก็คือการเพิ่มตัวแปรคุณลักษณะสามารถเพิ่มประสิทธิภาพการพยากรณ์ให้กับตัวแบบโครงข่ายระบบประสาทแบบย้อนกลับที่ถูกนำมาใช้อย่างแพร่หลายในปัจจุบันได้ ในกรณีที่ข้อมูลที่น่ามาฝึกฝนตัวแบบมีจำนวนจำกัด ทางผู้วิจัยหวังว่างานวิจัยฉบับนี้จะเป็นประโยชน์ และแนวทางให้กับผู้ที่ต้องการพยากรณ์ ศึกษา หรือต่อยอดเกี่ยวกับการเพิ่มประสิทธิภาพให้กับ



แบบจำลองในการพยากรณ์ปริมาณน้ำฝน หรือสภาพอากาศอื่นๆ แต่มีข้อมูลสภาพอากาศที่ค่อนข้างจำกัดในอนาคตต่อไป

## 2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง


### 2.1 แบบจำลองอนุกรมเวลา (Time series)

แบบจำลอง ARIMA เป็นหนึ่งในแบบจำลองที่ใช้ในการวิเคราะห์ข้อมูลอนุกรมเวลาแบบตัวแปรเดี่ยว(Univariate variable) ซึ่งถูกต้องและมีความแม่นยำสูงโดยพิจารณาจากการวัดค่าความคลาดเคลื่อนของการพยากรณ์ เป็นการสร้างตัวแบบจากข้อมูลที่เก็บรวบรวมในอดีตตามลำดับเวลาอย่างต่อเนื่องเพื่อกำหนดรูปแบบของข้อมูลและพยากรณ์ข้อมูลในอนาคต โดยข้อมูลอนุกรมเวลาที่จะนำมาวิเคราะห์ได้นั้น ต้องมีความคงที่ (Stationary) และไม่มีแนวโน้ม(Trend) องค์ประกอบของแบบจำลอง ARIMA จะประกอบไปด้วยพารามิเตอร์สำคัญ 3 ตัว คือ  $p$ ,  $d$  และ  $q$

### 2.2 โครงข่ายระบบประสาทแบบย้อนกลับ (Recurrent

#### Neural Networks: RNN)

โครงข่ายระบบประสาทแบบย้อนกลับ (RNN) คือ โครงข่ายประสาทเทียม (Artificial Neuron Network : ANN) รูปแบบหนึ่ง ที่ออกแบบมาเพื่อแก้ปัญหาเกี่ยวกับข้อมูลประเภทอนุกรมเวลา (Time Series data) หลักการของ RNN คือการปรับรูปแบบของโครงข่ายประสาทเทียมแบบเดิม เพื่อให้มีชั้นซ่อน (Hidden state) ในการจดจำความรู้หรือข้อมูลก่อนหน้า มารวมเข้ากับข้อมูลตัวใหม่ที่เข้ามา (Input data) เพื่อใช้ในการทำนายหรือพยากรณ์




รูปที่ 1. โครงสร้างของโครงข่ายระบบประสาทแบบย้อนกลับ

### 2.3 แบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM)

แบบจำลองหน่วยความจำระยะสั้นแบบยาว(LSTM) เป็นรูปแบบหนึ่งของโครงข่ายระบบประสาทแบบย้อนกลับ (RNN)

เพื่อแก้ปัญหาการลดลงของเกรเดียนต์ (Vanishing Gradient) เมื่อลำดับของข้อมูลที่ได้รับเข้ามามีจำนวนมากเกินไป โดยการทำงานของ LSTM นั้นจะมีความคล้ายคลึงกับ RNN แต่ในส่วน of ชั้นซ่อน (Hidden state) ที่ใช้สำหรับจดจำลำดับของข้อมูล ก่อนหน้านั้น LSTM จะมีการเรียนรู้ว่า เมื่อใดควรลืม (Forget) เขียน (Write) หรืออนุญาตให้อ่าน (Read) ซึ่งทำให้สามารถรองรับข้อมูลที่มีลำดับปริมาณมากที่เข้ามาได้




รูปที่ 2. แบบจำลองหน่วยความจำระยะสั้นแบบยาว

### 2.4 โครงข่ายประตูกักเก็บ (Gated Recurrent Unit:

#### GRU)

เป็นรูปแบบหนึ่งของโครงข่ายระบบประสาทแบบย้อนกลับ (RNN) มีจุดประสงค์เพื่อแก้ปัญหาการลดลงของเกรเดียนต์ (Vanishing Gradient) หรือเพื่อแก้ปัญหาการมีหน่วยความจำระยะสั้นของ RNN เช่นเดียวกับ LSTM ซึ่งการทำงานภายในของ GRU จะมีความคล้ายคลึงกับ LSTM เช่นกัน แต่จะลดความซับซ้อนของประตู(Gate) ลงเหลือเพียงแค่ 2 ประตูเพื่อให้เกิดความรวดเร็วในการคำนวณ ได้แก่ Update Gate เป็นประตูนำเข้าข้อมูลเพื่อนำไปคำนวณในการปรับสถานะของค่าเซลล์ และ Reset Gate เป็นประตูที่ใช้ในการตัดสินใจว่าจะปรับสถานะเซลล์เมื่อมีข้อมูลใหม่เข้ามาหรือไม่



รูปที่ 3. โครงข่ายประตูกักเก็บ

## 2.5 ปัญหาข้อมูลไม่สมดุล (Imbalanced data)

ปัญหาข้อมูลไม่สมดุล (Imbalanced data) เป็นปัญหาที่เกิดขึ้นในชุดข้อมูลที่มีการแบ่งประเภทของข้อมูลในชุดข้อมูล ออกเป็น 2 กลุ่ม (หรือมากกว่า) แล้วข้อมูลในกลุ่มใดกลุ่มหนึ่งมีจำนวนมากกว่าข้อมูลอีกกลุ่มหนึ่งมากการที่ข้อมูลในชุดข้อมูลหนึ่งๆ มีความไม่สมดุลเกิดขึ้น จะส่งผลกระทบต่อการทำงานของข้อมูลในกลุ่มส่วนน้อย เพราะโดยทั่วไปนั้น วิธีการจำแนกประเภท (Classification) ต่างๆ จะมีประสิทธิภาพสูงก็ต่อเมื่อข้อมูลในแต่ละกลุ่มในชุดข้อมูลนั้นมีจำนวนที่ใกล้เคียงกัน ซึ่งหากชุดข้อมูลมีความไม่สมดุล ก็จะส่งผลให้วิธีการจำแนกประเภทที่ใช้โดยทั่วไปนั้นมีโอกาสที่จะทำนายกลุ่มของชุดข้อมูลออกมาเป็นกลุ่มส่วนมาก อันนำไปสู่ปัญหาการแบ่งกลุ่มข้อมูลผิดกลุ่ม (Misclassification) เนื่องจากตัวแบบจะมองว่าการทำนายออกมาเป็นกลุ่มส่วนมากจะมีความแม่นยำมากกว่า ซึ่งก็จะทำให้ตัวแบบไม่สามารถทำนาย หรือแยกประเภทข้อมูลที่เป็นกลุ่มส่วนน้อยออกมาได้เลย

วิธีการแก้ปัญหาข้อมูลไม่สมดุลนั้น มีด้วยกันหลายวิธี แต่ในที่นี้จะขอยกมาถึงแค่วิธีเดียว ซึ่งเป็นวิธีที่ผู้วิจัยได้เลือกใช้ในการนำมาแก้ปัญหาความไม่สมดุลที่เกิดขึ้นในชุดข้อมูล ซึ่งก็คือวิธีการสุ่มตัวอย่างเพิ่มกลุ่มส่วนน้อยด้วยการสังเคราะห์ (Synthetic Minority Over-sampling Technique: SMOTE) เป็นวิธีที่ถูกเสนอขึ้นในปี 2002 โดย (Chawla et al., 2002) เป็นการสร้างกลุ่มตัวอย่างส่วนน้อยตัวอย่างใหม่ขึ้นมาอย่างสุ่ม โดยใช้หลักการกำหนดจำนวนเพื่อนบ้านที่อยู่ใกล้ที่สุดจำนวน  $k$  ตัว ( $k$ -nearest neighbors: KNN) แล้วทำการสุ่มสร้างข้อมูลขึ้นมาบนแนวเส้นที่เชื่อมต่อระหว่างตัวอย่างกลุ่มส่วนน้อยใดๆ

## 2.6 งานวิจัยที่เกี่ยวข้อง

เนื่องจากตัวข้อมูลสภาพอากาศนั้นเป็นข้อมูลเชิงอนุกรมเวลา ตัวแบบอนุกรมเวลา (Time series) จึงเป็นตัวเลือกลำดับต้นๆ ถูกนำมาใช้ในการพยากรณ์

(Wang et al., 2013) ได้ทำการพยากรณ์ปริมาณน้ำฝนสะสมในเมืองโจวกวัง มณฑลซานตง ประเทศจีน ซึ่งได้พบว่าปริมาณน้ำฝนนั้นมีสหสัมพันธ์อัตโนมัติที่โดดเด่น (Strong autocorrelation) จึงได้เลือกใช้ตัวแบบ SARIMA (Seasonal Autoregressive and Moving Average) ในการวิเคราะห์และพยากรณ์ ซึ่งหลังจากการเตรียมข้อมูล การกำหนดพารามิเตอร์ และเลือกตัวแบบที่ดีที่สุดตามวิธีการของการทำตัวแบบอนุกรม

เวลาแล้ว จากการทดสอบประสิทธิภาพพบว่า ค่าที่พยากรณ์ได้จากตัวแบบมีค่าใกล้เคียงกับปริมาณน้ำฝนสะสมจริง โดยมีค่าความคลาดเคลื่อนเพียงร้อยละ 27.42 เท่านั้น แต่ในงานวิจัยของ Wang และคณะ ไม่ได้กล่าวถึงการเปรียบเทียบแบบจำลอง SARIMA กับแบบจำลองอื่นๆ

(Narayanan et al., 2013) ได้ทำการพยากรณ์ปริมาณน้ำฝนสะสมในช่วงฤดูก่อนมรสุมตะวันตกเฉียงใต้ (ระหว่างเดือนมีนาคมถึงพฤษภาคม) ในภาคตะวันตกของประเทศอินเดีย โดยใช้ข้อมูลสภาพอากาศรายเดือน เฉพาะช่วงเดือนมีนาคมถึงพฤษภาคม จากสถานีวัดสภาพอากาศในประเทศอินเดีย 6 สถานี ในช่วงเวลา 60 ปี โดยมีการใช้ Mann Kendall test ในการทดสอบสหสัมพันธ์ระหว่างตัวแปร และใช้ตัวแบบ ARIMA ในการพยากรณ์ พบว่า ผลการพยากรณ์ทั้ง 6 สถานีมีความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ที่มากน้อยแตกต่างกันไป หมายความว่า การใช้ตัวแบบ ARIMA ในการพยากรณ์ปริมาณน้ำฝนสะสมอาจจะไม่ได้ตอบโจทย์สำหรับทุกสถานี หรือบางสถานีอาจจะต้องการการจัดการกับตัวแปรรับเข้าก่อนที่จะนำไปพยากรณ์ ทั้งนี้ งานวิจัยของ Narayanan และคณะ ก็ไม่ได้กล่าวถึงการเปรียบเทียบแบบจำลอง ARIMA กับแบบจำลองอื่นเช่นกัน

อย่างไรก็ตาม แบบจำลอง ARIMA ก็ยังมีข้อเสีย นั่นคือเป็นแบบจำลองที่พิจารณาโดยใช้ตัวแปรเพียงตัวเดียว ซึ่งในความเป็นจริงนั้น ปัจจัยที่ทำให้เกิดฝนหรือส่งผลต่อปริมาณน้ำฝนสะสมนั้น มีได้หลายปัจจัย และเพื่อเพิ่มประสิทธิภาพในการพยากรณ์จึงควรที่จะเอาปัจจัยสภาพอากาศด้านอื่นๆ มาพิจารณาไปด้วย เพื่อให้ตอบโจทย์ดังกล่าว แบบจำลอง ARIMAX จึงถูกยกขึ้นมาเพื่อทำการเปรียบเทียบกับแบบจำลอง ARIMA

(Wangdi et al., 2010) ได้เปรียบเทียบผลการพยากรณ์การเกิดไข้มาลาเรีย ระหว่างแบบจำลอง ARIMA ที่รับข้อมูลสถิติผู้ป่วยไข้มาลาเรียเพียงตัวแปรเดียว กับตัวแบบ ARIMAX ที่นอกจากจะรับข้อมูลของจำนวนผู้ป่วยแล้ว ยังรับข้อมูลด้านสภาพภูมิอากาศเพิ่มเข้าไปด้วย พบว่า ตัวแบบ ARIMAX ให้ผลการพยากรณ์ที่ดีกว่าตัวแบบ ARIMA

(Jalalkamali et al., 2015) ได้พัฒนาตัวแบบพยากรณ์ปริมาณน้ำฝนเพื่อคาดการณ์การเกิดปัญหายุ้งแล้ง โดยในงานวิจัยได้ทำการเปรียบเทียบผลการพยากรณ์ระหว่างตัวแบบ ARIMAX ตัวแบบโครงข่ายประสาทเทียม และตัวแบบ support-

vector machines (SVM) พบว่าในการพยากรณ์ระยะสั้น ตัวแบบ ARIMAX เป็นตัวแบบที่มีประสิทธิภาพมากที่สุด

นอกจากการใช้ตัวแบบ ARIMA และ ARIMAX การพยากรณ์โดยใช้แบบจำลองการเรียนรู้เชิงลึก โครงข่ายระบบประสาทแบบย้อนกลับ รวมไปถึงการทำ Feature Engineering เพื่อเพิ่มประสิทธิภาพให้กับตัวแบบก็ได้เข้ามามีบทบาทมากขึ้น

(Srachoom, 2007) ได้พัฒนาโครงข่ายประสาทเทียมเพื่อให้สามารถพยากรณ์ปริมาณน้ำฝนสะสมระยะสั้น จากข้อมูลสภาพอากาศย้อนหลังก่อนวันที่ต้องการพยากรณ์ได้ โดยข้อมูลที่ใช้เป็นข้อมูลพื้นที่อำเภอเมือง จังหวัดเชียงใหม่ ได้แก่ ความกดอากาศสูงสุด-ต่ำสุด อุณหภูมิสูงสุด-ต่ำสุด ความชื้นสัมพัทธ์สูงสุด-ต่ำสุด และปริมาณน้ำฝน ย้อนหลัง 9 ปี (พ.ศ. 2541-2549) และเพื่อให้โครงข่ายประสาทได้เรียนรู้แนวโน้มของสภาพอากาศก่อนวันฝนตกได้อย่างชัดเจน จึงได้เพิ่มชุดข้อมูลของสภาพอากาศย้อนหลัง 3 วัน ก่อนวันพยากรณ์ และเพิ่มดัชนีแสดงฤดูกาลเข้าไปด้วย ส่งผลให้มีตัวแปรต้นทั้งหมด 24 ตัว พบว่าโครงข่ายประสาทเทียมที่เหมาะสมมี 1 ชั้นซ่อน มีจำนวน 30 นิวรอน มีความถูกต้องเฉลี่ยร้อยละ 73.36

(Hung et al., 2009) ได้ทำการพยากรณ์ปริมาณน้ำฝนในเขตกรุงเทพมหานครแบบรายงานผลได้ทันที (real time) ด้วยโครงข่ายประสาทเทียม (ANN) โดยทำการเปรียบเทียบระหว่างแบบ Simple multilayer perceptron และแบบ Generalized feedforward ร่วมกับการปรับจูนพารามิเตอร์ ข้อมูลที่นำมาใช้เป็นข้อมูลที่ทำกรเก็บข้อมูลแบบรายชั่วโมงตลอดระยะเวลา 4 ปี จาก 75 สถานีตรวจวัดสภาพอากาศในกรุงเทพมหานคร พบว่า ในการพยากรณ์ปริมาณน้ำฝนในช่วงเวลา 1-6 ชั่วโมงนั้น ยิ่งชั่วโมงเพิ่มขึ้นเท่าไร ค่าความคลาดเคลื่อนของการพยากรณ์ก็จะยิ่งเพิ่มขึ้นเช่นกัน นอกจากนี้ในงานวิจัยนี้ยังได้ทำการหาความสัมพันธ์ระหว่างตัวแปรต้นกับตัวแปรตามเพื่อพิจารณาว่าตัวแปรใดบ้างที่ส่งผลกับปริมาณน้ำฝน พบว่า เมื่อนำข้อมูลสภาพอากาศจากสถานีตรวจวัดใกล้เคียง (ในรัศมี 21 ตารางกิโลเมตร) มาพิจารณาพร้อมกับสถานีตรวจวัดที่สนใจจะพยากรณ์แล้วนั้น ส่งผลให้ค่าความคลาดเคลื่อนลดลงถึงร้อยละ 71.19 เมื่อเทียบกับการพิจารณาข้อมูลจากสถานีตรวจวัดที่สนใจเพียงสถานีเดียว

(Hernández et al., 2016) ได้ศึกษาเรื่องการพัฒนาระบบแบบจำลองการเรียนรู้เชิงลึกเพื่อทำนายปริมาณน้ำฝนสะสมรายวัน โดยใช้ข้อมูลสภาพอากาศรายวันจากสถานีตรวจวัดใน

เมือง Manizales ประเทศ Colombia สิ่งที่น่าสนใจของงานวิจัยนี้คือการสร้างตัวแปรต้นจำนวน 47 ตัว โดยมาจากข้อมูลพื้นฐานที่เก็บรวบรวมมา ได้แก่ อุณหภูมิ ความชื้นสัมพัทธ์ ความกดอากาศ ความเข้มของแสงอาทิตย์ ความเร็วลม และทิศทางลม ในส่วนของข้อมูลที่สร้างขึ้นจะมาจากการข้อมูลพื้นฐานแต่ละตัวอีกที โดยการนำมา 1) วัดย้อนหลังไป 3 วัน 2) ค่าเฉลี่ยในช่วง 5 วันย้อนหลัง 3) ความแตกต่างของอุณหภูมิที่วัดได้ในช่วงเวลา 4:00 น. และ 24:00 น. เป็นต้น เนื่องจากตัวแปรต้นที่มีจำนวนมาก จึงได้มีการนำตัวเข้ารหัสอัตโนมัติ (Autoencoder) มาช่วยในการสกัดคุณลักษณะสำคัญ และทำการหาความสัมพันธ์ของแต่ละตัวแปร ก่อนที่จะส่งต่อไปยัง Multilayer Perceptron (MLP) เพื่อทำหน้าที่ในการพยากรณ์ปริมาณน้ำฝนสะสม

นอกจากการทำ Feature Engineering เพื่อเพิ่มประสิทธิภาพให้กับตัวแบบแล้ว งานวิจัยข้างต้นยังกล่าวถึงการจัดการกับข้อมูลเบื้องต้น เพื่อไม่ให้เกิดแนวโน้มการพยากรณ์ผิดกลุ่ม (Misclassification) เนื่องจากข้อมูลที่นำมาใช้นั้นมีทั้งข้อมูลช่วงที่ฝนตก และข้อมูลในช่วงที่ฝนไม่ตก หากนำข้อมูลในช่วงที่ฝนไม่ตกมาทำนายรวมด้วยก็จะทำให้ไม่สามารถทำนายปริมาณน้ำฝนได้อย่างถูกต้อง โดยงานวิจัย (Srachoom, 2007) ได้แก้ไขปัญหาดังกล่าวด้วยการเพิ่มดัชนีฤดูกาลด้วยเลขไบนารีขนาด 3 บิต เพื่อให้แบบจำลองสามารถรับรู้กลุ่มประเภทของข้อมูลตามฤดูกาลได้ และงานวิจัย (Hung et al., 2009) ได้ทำการศึกษาเปรียบเทียบโดยการนำเข้าสู่ชุดข้อมูลหลายๆแบบ พบว่า นอกจากการใช้ข้อมูลสภาพอากาศจากสถานีตรวจวัดใกล้เคียงมาพิจารณาพร้อมกับสถานีตรวจวัดที่สนใจจะพยากรณ์แล้ว การใส่ข้อมูลนำเข้าที่จะทำการพยากรณ์มีความแม่นยำมากที่สุดก็คือ ใส่ข้อมูลเฉพาะวันที่ฝนตก งานวิจัย (Hernández et al., 2016) จะมีความคล้ายงานวิจัย (Srachoom, 2007) แต่จะแบ่งข้อมูลด้วยการเพิ่มดัชนีรายเดือนด้วยเลขไบนารีขนาด 12 บิต

ในส่วนของการพยากรณ์ปริมาณน้ำฝนสะสมที่เกิดขึ้น นอกจากแบบจำลอง ARIMA และโครงข่ายประสาทเทียมที่ถูกกล่าวถึงในงานวิจัยข้างต้น ในปัจจุบันได้มีการนำความรู้เรื่องแบบจำลองการเรียนรู้เชิงลึกเข้ามาเพื่อช่วยทำนาย โดยแบบจำลองการเรียนรู้เชิงลึกที่นิยมนำมาใช้ในการทำนายปริมาณน้ำฝนคือ แบบจำลองที่มีความเกี่ยวข้องกับอนุกรมเวลา ได้แก่ RNN LSTM และ GRU โดยงานวิจัย (Salman et al., 2018) กับ (Fan et


al., 2020) ได้ทำการทดลองพัฒนาแบบจำลอง LSTM เพื่อพยากรณ์ปริมาณน้ำฝน และนำแบบจำลองที่ได้ไปเปรียบเทียบกับแบบจำลองอื่นๆ และ (Aurnhammer & Frank, 2019) กับ (Yang et al., 2020) ได้ทำการทดลองเพื่อเปรียบเทียบความแม่นยำในการพยากรณ์ระหว่างแบบจำลองโครงข่ายระบบประสาทย้อนกลับ และพบว่า แบบจำลอง LSTM และ GRU มีความโดดเด่น และสามารถให้ผลการพยากรณ์ที่มีความถูกต้องและรวดเร็ว อย่างไรก็ตาม ในด้านความเหมาะสมในการเลือกใช้ตัวแบบจำลองโครงข่ายระบบประสาทแบบย้อนกลับนั้นขึ้นอยู่กับตัว Short-term memory ที่ได้เข้าไปด้วยเช่นกัน โดยทั้ง 2 งานวิจัยพบว่า ในชุดข้อมูลที่มีขนาดเล็ก แบบจำลอง GRU จะมีประสิทธิภาพในการเรียนรู้ที่ดีกว่า แต่สำหรับชุดข้อมูลขนาดใหญ่ แบบจำลอง LSTM จะมีประสิทธิภาพการเรียนรู้ที่ดีที่สุด

จากการศึกษางานวิจัยทั้งงานทางด้านการทำ Feature Engineering และด้านการปรับปรุงตัวแบบโครงข่ายระบบประสาทแบบย้อนกลับพบว่า งานวิจัยทั้ง 2 แบบจะมุ่งเน้นในส่วนของการปรับปรุงไฮเปอร์พารามิเตอร์ให้สามารถพยากรณ์ชุดข้อมูลให้มีความแม่นยำมากที่สุดเป็นหลักอยู่ ไม่ได้กล่าวถึงการทำการ Feature Engineering มากนัก และไม่ได้มีการเปรียบเทียบให้เห็นว่าการเพิ่มคุณลักษณะทางสถิติต่างๆ ให้กับชุดข้อมูลนั้น ทำให้ประสิทธิภาพของการพยากรณ์เพิ่มขึ้นหรือไม่ จึงนำมาสู่จุดมุ่งหมายในการศึกษาข้อแรก คือการเปรียบเทียบประสิทธิภาพในการพยากรณ์ของตัวแบบที่ใช้ชุดข้อมูลที่แตกต่างกัน ระหว่างชุดข้อมูลผ่านการเพิ่มคุณลักษณะพิเศษกับชุดข้อมูลดั้งเดิม เพื่อดูว่าการเพิ่มคุณลักษณะนั้นส่งผลที่ดีกับประสิทธิภาพในการพยากรณ์จริงหรือไม่ และสำหรับจุดมุ่งหมายข้อที่สอง คือ เปรียบเทียบประสิทธิภาพในการพยากรณ์ในช่วงเวลาถัดไปของโครงข่ายระบบประสาทแบบย้อนกลับที่สนใจศึกษากับแบบจำลองอาร์มา จะเป็นการทดลองเพื่อหาแบบจำลองที่มีความเหมาะสมกับประเภทชุดข้อมูลที่นำมาศึกษามากที่สุด

### 3. วิธีดำเนินงานวิจัย

งานวิจัยนี้มีจุดประสงค์ในการพัฒนาแบบจำลองที่เหมาะสมต่อการพยากรณ์ปริมาณน้ำฝนในพื้นที่สนามบินสุวรรณภูมิ ดังนั้นในงานวิจัยนี้จะเน้นไปที่ชั่วโมงที่มีฝนตกเพื่อทำนายปริมาณ

น้ำฝนที่จะเกิดขึ้น ทั้งนี้ ขั้นตอนในการดำเนินการวิจัยจะแบ่งออกได้ดังรูปที่แสดงต่อไปนี้




รูปที่ 4. ขั้นตอนการดำเนินงาน

#### 3.1 รวบรวมและจัดเตรียมข้อมูล

งานวิจัยนี้ได้รับการสนับสนุนข้อมูลสภาพอากาศบริเวณสนามบินสุวรรณภูมีย้อนหลัง 5 ปี (ตั้งแต่ปี 2016 จนถึงปี 2020) จากกรมอุตุนิยมวิทยาประเทศไทย โดยชุดข้อมูลที่ได้จะมีทั้งหมด 4 คุณลักษณะ ได้แก่ อุณหภูมิรายชั่วโมง (Celsius) ความชื้นสัมพัทธ์รายชั่วโมง(Percent) ความกดอากาศรายชั่วโมง(hPa) และปริมาณน้ำฝนสะสม 3 ชั่วโมง (Millimeter)

ทั้งนี้ เนื่องจากข้อมูลทั้ง 4 คุณลักษณะมีความถี่ในการเก็บข้อมูลที่แตกต่างกัน และข้อมูลที่เราสนใจที่จะพยากรณ์ก็คือข้อมูลปริมาณน้ำฝน ดังนั้น ในเบื้องต้นจึงจำเป็นต้องทำการเปลี่ยนข้อมูลอุณหภูมิ ความชื้นสัมพัทธ์ และความกดอากาศที่เป็นข้อมูลรายชั่วโมงให้กลายเป็นข้อมูลราย 3 ชั่วโมงเหมือนกับข้อมูลของปริมาณน้ำฝนสะสมก่อน ซึ่งสามารถทำได้โดยการหาค่าเฉลี่ยของข้อมูลในทุกช่วง 3 ชั่วโมง โดยหลังจากที่ปรับความถี่ของช่วงเวลาของข้อมูลทั้ง 4 คุณลักษณะให้ตรงกันแล้วจะทำให้เรามีข้อมูลทั้งหมด 14,616 จุด แต่ก่อนที่จะนำเข้าแบบจำลองเพื่อพยากรณ์ เราจำเป็นต้องแบ่งข้อมูลออกเป็น 3 ส่วน ดังนี้ 1) ข้อมูลตั้งแต่ปี 2016 ถึงปี 2018 เป็นชุดข้อมูลฝึกสอน (Training data set) 2) ข้อมูลปี

2019 เป็นชุดข้อมูลตรวจสอบ (Validation data set) 3) ข้อมูลปี 2020 เป็นชุดข้อมูลทดสอบ (Test data set)



รูปที่ 5. การกระจายตัวในแต่ละคุณลักษณะของทั้ง 3 ชุดข้อมูล

จากรูปที่ 5 ซึ่งแสดงการกระจายตัวของข้อมูลในแต่ละคุณลักษณะจากแต่ละชุดข้อมูลที่เราได้ทำการแบ่งไว้ เราจะพบว่าข้อมูลอุณหภูมิและความกดอากาศมีลักษณะใกล้เคียงกับการกระจายตัวแบบปกติ (Normal Distribution) ในขณะที่ข้อมูลความชื้นสัมพัทธ์มีลักษณะเบ้ซ้าย (Left skewed) แต่สำหรับข้อมูลปริมาณน้ำฝนนั้น เราจะเห็นได้อย่างชัดเจนเลยว่าข้อมูลนั้นมีความไม่สมดุลเลย เนื่องจากปริมาณชั่วโมงที่ฝนไม่ตกนั้นมีมากกว่าปริมาณชั่วโมงที่ฝนตก และเมื่อมาพิจารณาอย่างละเอียดก็พบว่า ปริมาณชั่วโมงที่ฝนตกนั้น (ปริมาณน้ำฝนสะสมมากกว่า 0.1 มิลลิเมตร) มีเพียงร้อยละ 10 จากข้อมูลทั้งหมด ซึ่งปัญหาข้อมูลไม่สมดุลที่เกิดขึ้นดังกล่าว สามารถส่งผลกับการพยากรณ์ได้ จึงได้เลือกใช้วิธีการสุ่มตัวอย่างเพิ่มกลุ่มส่วนน้อยด้วยการสังเคราะห์ (Synthetic Minority Over-sampling Technique: SMOTE) สุ่มสร้างตัวอย่างชั่วโมงที่มีฝนตกขึ้นมาเพื่อให้แบบจำลองสามารถทำนายปริมาณน้ำฝนสะสมในชั่วโมงที่มีฝนตกได้อย่างแม่นยำมากขึ้น

### 3.2 เพิ่มคุณลักษณะ และวิเคราะห์ความสัมพันธ์ระหว่างคุณลักษณะ


#### 3.2.1 การเพิ่มข้อมูลคุณลักษณะทางสถิติ

เพื่อให้แบบจำลองสามารถเรียนรู้แนวโน้มของสภาพอากาศก่อนฝนจะตกได้ดียิ่งขึ้น จึงได้ทำการเพิ่มค่าคุณลักษณะทางสถิติให้กับชุดข้อมูลก่อนที่จะนำเข้าแบบจำลอง โดยเป็นการเพิ่มความสัมพันธ์ที่เกี่ยวข้องกันในเชิงเวลาให้กับแต่ละคุณลักษณะ

ได้แก่ ค่าสูงสุด เปรียบเทียบช่วงเวลาปัจจุบัน กับ 9 6 และ 3 ชั่วโมงก่อนหน้า ค่าเฉลี่ยในช่วง 15 ชั่วโมง ของทุกคุณลักษณะ อีกทั้งยังเพิ่มคุณลักษณะที่บ่งบอกฤดูกาล เช่น ช่วงเดือน พฤศจิกายนถึงเดือนกุมภาพันธ์จะเป็นฤดูหนาว ช่วงเดือนมีนาคมถึงเดือนมิถุนายนเป็นฤดูร้อน และช่วงเดือนกรกฎาคมถึงเดือนตุลาคมเป็นฤดูฝน ซึ่งทำให้คุณลักษณะที่เราจะนำเข้าแบบจำลองมีทั้งหมด 23 คุณลักษณะ

#### 3.2.2 วิเคราะห์ความสัมพันธ์ระหว่างคุณลักษณะ

ในการเพิ่มประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนในช่วงเวลาที่ถัดไปให้มีความแม่นยำมากยิ่งขึ้น งานวิจัยฉบับนี้จึงได้ทำการเพิ่มคุณลักษณะบางอย่างตามที่ได้กล่าวถึงไปในหัวข้อที่แล้วเข้ามาด้วย หลังจากนั้นจึงได้ทำการวิเคราะห์หาความสัมพันธ์ (Correlation) ระหว่างคุณลักษณะ ซึ่งได้ผลลัพธ์ดังรูปต่อไปนี้



รูปที่ 6. แผนภาพแสดงค่าสหสัมพันธ์ระหว่างแต่ละคุณลักษณะ

อย่างไรก็ตาม การนำคุณลักษณะทั้งหมด 23 คุณลักษณะเข้าสู่แบบจำลองอาจจะไม่ส่งผลให้ประสิทธิภาพของแบบจำลองเพิ่มมากขึ้นกว่าเดิม เนื่องจากบางคุณลักษณะก็ไม่ได้มีความสัมพันธ์กับตัวคุณลักษณะปริมาณน้ำฝนเลย ดังนั้น เพื่อเป็นการเปรียบเทียบให้เห็นผลว่าการเพิ่มคุณลักษณะนั้นสามารถช่วยเพิ่มประสิทธิภาพให้กับแบบจำลองได้จริง จึงได้ทำการแบ่งชุดข้อมูลก่อนจะนำเข้าแบบจำลองออกเป็น 3 ชุด ดังนี้

- 1) ชุดข้อมูลที่มีเพียง 4 คุณลักษณะดั้งเดิม ได้แก่ ปริมาณน้ำฝนสะสม อุณหภูมิ ความกดอากาศ และความชื้นสัมพัทธ์

2) ชุดข้อมูลผ่านการเพิ่มคุณลักษณะทั้งสิ้น 19 คุณลักษณะ และจะรวมกับคุณลักษณะดั้งเดิม ทำให้มีคุณลักษณะรวมทั้งสิ้น 23 คุณลักษณะ

3) ชุดข้อมูลที่เพิ่มเฉพาะคุณลักษณะที่มีความสัมพันธ์กับปริมาณน้ำฝนสะสมเท่านั้น ซึ่งจะมีเพียง 7 คุณลักษณะ ซึ่งทำให้ข้อมูลชุดที่ 3 จะมีคุณลักษณะทั้งหมด 11 คุณลักษณะ โดยคุณลักษณะที่เพิ่มเข้ามาคือ ปริมาณน้ำฝนสูงสุด เปรียบเทียบช่วงเวลาปัจจุบัน กับ 9 6 และ 3 ชั่วโมงก่อนหน้า ค่าเฉลี่ยในช่วง 15 ชั่วโมง และฤดูกาล


### 3.3 พัฒนาตัวแบบจำลองเพื่อพยากรณ์

#### 3.3.1 แบบจำลองกลุ่มอาร์มา

ในกลุ่มนี้จะประกอบไปด้วย 2 แบบจำลอง ได้แก่ แบบจำลอง ARIMA และแบบจำลอง ARIMAX ทั้ง 2 แบบจำลองจะมีขั้นตอนการพัฒนาตัวแบบและการเขียนโปรแกรมที่ค่อนข้างคล้ายกัน ต่างกันแค่เพียงตัวแบบ ARIMA จะมีข้อมูลนำเข้าเพียงข้อมูลเดียว นั่นคือข้อมูลปริมาณน้ำฝน แต่สำหรับตัวแบบ ARIMAX นั้น จะสามารถนำเข้าข้อมูลคุณลักษณะอื่นๆ ที่นอกเหนือจากปริมาณน้ำฝนเข้าแบบจำลองได้ โดยทำให้ข้อมูลคุณลักษณะอื่นๆ อยู่ในรูปแบบของเมทริกซ์ ซึ่งนั่นทำให้เราสามารถทำการทดลองชุดข้อมูลทั้ง 3 ชุดที่เรามีกับแบบจำลอง ARIMAX ได้

จากผลการทดสอบความเหมาะสม พบว่าตัวแบบ ARIMA(1,1,3) เป็นตัวแบบที่มีความเหมาะสมมากที่สุด และสำหรับตัวแบบอนุกรมเวลา ARIMAX พบว่า ตัวแบบที่เหมาะสมที่สุดสำหรับชุดข้อมูลชุดที่ 1 คือ ARIMAX (1,1,4) ตัวแบบที่เหมาะสมที่สุดสำหรับชุดข้อมูลชุดที่ 2 คือ ARIMAX (1,1,2) และตัวแบบที่เหมาะสมที่สุดสำหรับชุดข้อมูลชุดที่ 3 คือ ARIMAX (3,1,2)

สำหรับขั้นตอนการทำงานของโปรแกรมโดยคร่าว สามารถแสดงได้ดังรูปต่อไปนี้



รูปที่ 7. แผนภาพแสดงขั้นตอนการดำเนินการในการพัฒนาตัวแบบอนุกรมเวลา ARIMA และ ARIMAX


#### 3.3.2 แบบจำลองกลุ่มโครงข่ายระบบประสาทแบบ

##### ย้อนกลับ

ในกลุ่มนี้จะประกอบไปด้วย 3 แบบจำลอง ได้แก่ แบบจำลองหน่วยความจำระยะสั้นแบบยาว (LSTM) โครงข่ายระบบประสาทแบบย้อนกลับ (RNN) และโครงข่ายประสาทวนกลับ (GRU) ซึ่งหลังจากที่เราจัดการกับข้อมูลเบื้องต้นเสร็จแล้ว (ในหัวข้อ 3.1 และ 3.2) เราจะทำการการปรับปรุงโครงสร้างข้อมูล (Normalization) ซึ่งจากรูปที่ 3.3 เราจะเห็นได้ว่าชุดข้อมูลในแต่ละคุณลักษณะมีการกระจายตัวที่แตกต่างกัน ดังนั้น จึงจำเป็นต้องปรับปรุงโครงสร้างของข้อมูลเพื่อลดความซับซ้อนและหลีกเลี่ยงความผิดพลาดของข้อมูลก่อนที่จะนำไปในแบบจำลอง โดยจะทำการปรับปรุงโครงสร้างข้อมูลด้วยวิธี Z-Score Normalization หรือ Standardization หลังจากนั้นจึงนำข้อมูลทั้งหมดเข้าแบบจำลองเพื่อทำการฝึกสอนโดยจะทำการ

แปลงข้อมูลนำเข้าให้อยู่ในรูปแบบอาร์เรย์ 3 มิติ คือ [Input, Timestep, Features] โดยที่ Input คือจำนวนข้อมูลที่เราจะนำเข้าแบบจำลอง Timestep คือ จำนวนช่วงเวลาก่อนหน้า ( $t+n$ ) ซึ่งในที่นี้เราได้ใช้ทั้งหมด 80 ช่วงเวลา ( $t+80$ ) หรือ 240 ชั่วโมงก่อนหน้า (10 วัน) เพื่อทำนายปริมาณน้ำฝนสะสมในอีกช่วงเวลาถัดไป

สำหรับขั้นตอนการทำงานของโปรแกรมโดยคร่าวสามารถแสดงได้ดังรูปต่อไปนี้



รูปที่ 8. แผนภาพแสดงกระบวนการทำงานของแบบจำลอง  
โครงข่ายระบบประสาทแบบย้อนกลับ

พารามิเตอร์ที่ใช้ในการฝึกสอน ได้ทำการทดสอบทั้งหมด 500 Epochs และมีการใช้ Adaptive Moment Estimation (ADAM) เป็นตัว Optimizer เพื่อเพิ่มประสิทธิภาพในการทำนายผลของแบบจำลอง ในการวัดประสิทธิภาพของตัวแบบได้ทำการเลือก ฟังก์ชันสูญเสีย (Loss function) คือ Mean Absolute Error (MAE) ซึ่งจะมีความอ่อนไหวกับชุดข้อมูลที่มีค่าผิดปกติ (Outlier) น้อยกว่า Mean Square Error (MSE) และ

Root Mean Square Error (RMSE) เนื่องจากการนำค่าความคลาดเคลื่อน (Error) มาใส่ สัมบูรณ์ (Absolute) เหตุผลที่เลือก MAE เนื่องจากข้อมูลปริมาณน้ำฝนสะสมนั้นจะมีความเอนเอียงเนื่องจากช่วงเวลาที่ฝนตกมีน้อยกว่าช่วงเวลาที่ฝนไม่ตก (ดังที่แสดงในรูปที่ 3.4) อีกทั้ง ปริมาณน้ำฝนสะสมในบางช่วงก็มีปริมาณที่สูงมากกว่าปกติ ซึ่งอาจจะเกิดจากอิทธิพลของพายุหรือปัจจัยอื่นๆ และข้อมูลเหล่านี้เองที่กลายเป็นค่าผิดปกติ (Error) ในชุดข้อมูล การเลือกใช้ MAE ในการประเมินประสิทธิภาพของตัวแบบจึงมีความเหมาะสมกับชุดข้อมูลนี้มากกว่าค่าอื่นๆ

สำหรับเทคนิคการฝึกสอน ได้เลือกใช้เทคนิค Early stopping ซึ่งเป็นเทคนิคในการสร้างความสมดุลระหว่างค่าความเอนเอียง (Bias) และค่าความแปรปรวน (Variation) เพื่อไม่ให้แบบจำลองประสบปัญหา Overfitting (แบบจำลองอิงกับข้อมูลในชุดข้อมูลฝึกสอนมากเกินไป คือมีค่าความถูกต้องในการทำนายข้อมูลฝึกสอนสูง แต่ค่าความถูกต้องในการทำนายข้อมูลชุดทดสอบต่ำ) โดยการสังเกตค่า Validation loss ในทุกๆ Epochs ด้วยเงื่อนไขว่า หากค่าดังกล่าวไม่ลดลงติดต่อกัน 10 Epochs ให้หยุดการฝึกสอน

หลังจากนั้นจึงได้นำแบบจำลองแต่ละตัวมาทำการปรับจูนไฮเปอร์พารามิเตอร์ เพื่อให้ได้ไฮเปอร์พารามิเตอร์ที่มีความเหมาะสมกับแต่ละตัวแบบ และช่วยให้ได้ประสิทธิภาพในการพยากรณ์ที่สูงสุด โดยในการปรับจูนค่าไฮเปอร์พารามิเตอร์ (Hyper-Parameter Tuning) ในแต่ละตัวแบบที่เราเลือกมาใช้นั้น มีการปรับจูนค่าต่างๆ ดังนี้

| แบบจำลอง | ชั้นของแบบจำลอง   | ไฮเปอร์พารามิเตอร์           | ฟังก์ชันกระตุ้น |
|----------|-------------------|------------------------------|-----------------|
| RNN      | SimpleRNN layer 1 | 32                           | Tanh            |
|          | SimpleRNN layer 2 | 64                           |                 |
|          | Dense             | 32                           |                 |
|          | Reshape           | [output, number of features] |                 |



|      |              |                              |      |
|------|--------------|------------------------------|------|
| LSTM | LSTM layer 1 | 64                           | Tanh |
|      | LSTM layer 2 | 256                          |      |
|      | Dense        | 32                           |      |
|      | Reshape      | [output, number of features] |      |
| GRU  | GRU layer 1  | 32                           | Tanh |
|      | GRU layer 2  | 64                           |      |
|      | Dense        | 1                            |      |
|      | Reshape      | [output, number of features] |      |

ตารางที่ 1. แสดงการปรับจูนไฮเปอร์พารามิเตอร์ที่ชั้น (Layer) ต่างๆ ของตัวแบบแต่ละตัว

### 3.4 เปรียบเทียบผลการพยากรณ์ และประเมินความเหมาะสมของตัวแบบ


#### 3.4.1 ผลการทดลองโดยการเปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมในอีก 1 ช่วงเวลาถัดไป

ในส่วนการเปรียบเทียบประสิทธิภาพในการพยากรณ์ของแต่ละแบบจำลอง กับแต่ละชุดข้อมูล จะทำการพิจารณาจากค่า Mean Absolute Error (MAE) และจะเป็นการเปรียบเทียบการทำนายปริมาณน้ำฝนสะสมในอีก 3 ชั่วโมงถัดไป ( $t+3$ )

|          | ARIMA | ARIMAX       | RNN          | LSTM         | GRU          |
|----------|-------|--------------|--------------|--------------|--------------|
| ชุดที่ 1 | 2.195 | 2.371        | 0.283        | 0.215        | <b>0.193</b> |
| ชุดที่ 2 |       | <b>0.216</b> | 0.226        | 0.218        | 0.235        |
| ชุดที่ 3 |       | 0.444        | <b>0.195</b> | <b>0.188</b> | 0.216        |

ตาราง 2. แสดงค่า MAE ใน 1 ช่วงเวลาถัดไป

ค่า MAE ที่ได้ สามารถสรุปได้เป็นแผนภาพดังนี้



รูปที่ 9. แผนภาพแสดงค่า MAE ใน 1 ช่วงเวลาถัดไป

จากการทดลองพบว่า แบบจำลองที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองน้อยที่สุดคือ แบบจำลองหน่วยความจำระยะสั้นแบบยาว


#### 3.4.2 ผลการทดลองโดยการเปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมในอีกหลายช่วงเวลาถัดไป

การพิจารณาจากค่า Mean Absolute Error (MAE) และจะเป็นการเปรียบเทียบการทำนายปริมาณน้ำฝนสะสมในอีก 24 ชั่วโมงถัดไป ( $t+8$ )

|          | ARIMA | ARIMAX       | RNN         | LSTM         | GRU          |
|----------|-------|--------------|-------------|--------------|--------------|
| ชุดที่ 1 | 1.589 | 3.335        | 0.310       | 0.310        | 0.286        |
| ชุดที่ 2 |       | <b>1.349</b> | 0.310       | 0.329        | 0.297        |
| ชุดที่ 3 |       | 1.709        | <b>0.26</b> | <b>0.248</b> | <b>0.242</b> |

ตาราง 3. แสดงค่า MAE ใน 8 ช่วงเวลาถัดไป

ค่า MAE ที่ได้ สามารถสรุปได้เป็นแผนภาพดังนี้



รูปที่ 10. แผนภาพแสดงค่า MAE ใน 8 ช่วงเวลาถัดไป

จากการทดลองในการพยากรณ์ข้อมูลในอีกหลายช่วงเวลาถัดไปพบว่า การเพิ่มเฉพาะคุณลักษณะทางสถิติให้กับชุดข้อมูลก่อนที่จะนำเข้าแบบจำลองส่งผลให้ค่าเฉลี่ยความผิดพลาดกำลังสองลดลง แบบจำลองที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองน้อยที่สุดคือ โครงข่ายประสาทกลับ

#### 4. บทสรุปและการอภิปราย

งานวิจัยนี้มุ่งเน้นการพัฒนาและวิเคราะห์เปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมล่วงหน้าในระยะสั้นร่วมกับการใช้ข้อมูลหลายตัวแปร ข้อมูลที่นำมาใช้ในงานวิจัยนี้เป็นข้อมูลสภาพอากาศและปริมาณน้ำฝนสะสมในพื้นที่สนามบินสุวรรณภูมิที่ได้รับการสนับสนุนจากกรมอุตุนิยมวิทยา ประเทศไทย

ในการพัฒนาตัวแบบ ผู้วิจัยได้เตรียมชุดข้อมูลนำเข้าไว้ 3 ชุด คือ 1) ชุดข้อมูลดั้งเดิม (รวม 4 คุณลักษณะ) 2) ชุดข้อมูลที่เพิ่มคุณลักษณะทางสถิติ (รวม 23 คุณลักษณะ) 3) ชุดข้อมูลที่เพิ่มเฉพาะคุณลักษณะทางสถิติที่เกี่ยวข้องกับปริมาณน้ำฝนสะสม (รวม 11 คุณลักษณะ) เนื่องจากเมื่อลองพิจารณาข้อมูลที่อยู่ในชุดข้อมูลแล้วพบว่า จำนวนชั่วโมงที่มีฝนตกนั้น มีน้อยกว่าจำนวนชั่วโมงที่ไม่มีฝนตก โดยจำนวนชั่วโมงที่มีฝนตกนั้น คิดเป็นร้อยละ 10 จากจำนวนชั่วโมงที่ไม่มีฝนตก ซึ่งก่อให้เกิดปัญหาชุดข้อมูลไม่สมดุลตามมา จึงได้จัดการกับปัญหาดังกล่าวด้วยการเลือกใช้วิธีการสุ่มตัวอย่างเพิ่มกลุ่มส่วนน้อยด้วยการสังเคราะห์ (SMOTE) เพื่อให้มีจำนวนชั่วโมงที่มีฝนตกมากพอที่จะทำให้แบบจำลองสามารถทำนายปริมาณน้ำฝนสะสมได้

จากนั้นจึงได้ทำการพัฒนาตัวแบบจำลองที่เกี่ยวข้องกับการจัดการข้อมูลที่อยู่ในรูปของอนุกรมเวลาขึ้น ได้แก่

1. ตัวแบบ ARIMA เป็นตัวแบบที่รับข้อมูลนำเข้าเฉพาะข้อมูลปริมาณน้ำฝน จากการพัฒนาและคัดเลือกตัวแบบที่ดีที่สุดด้วยวิธีวิธีบอกซ์แอนด์เจนกินส์ พบว่าตัวแบบที่ให้ค่าความคลาดเคลื่อนน้อยที่สุด คือตัวแบบ ARIMA (1,1,3)
2. ตัวแบบ ARIMAX เป็นตัวแบบที่รับข้อมูลคุณลักษณะอื่นๆ มาพิจารณาพร้อมกับข้อมูลปริมาณน้ำฝนที่เราต้องการจะพยากรณ์ จากการพัฒนาและคัดเลือกตัวแบบที่ดีที่สุดด้วยวิธีบอกซ์แอนด์เจนกินส์ จะทำให้เราได้ตัวแบบ ARIMAX ที่ดีที่สุดสำหรับแต่ละชุดข้อมูล ได้แก่

- ข้อมูลชุดที่ 1 ตัวแบบที่ดีที่สุด คือ ตัวแบบ ARIMAX (1,1,4)

- ข้อมูลชุดที่ 2 ตัวแบบที่ดีที่สุด คือ ตัวแบบ ARIMAX (1,1,2)

- ข้อมูลชุดที่ 3 ตัวแบบที่ดีที่สุด คือ ตัวแบบ ARIMAX (3,1,2)

3. แบบจำลองการเรียนรู้เชิงลึก เป็นตัวแบบที่รับข้อมูลนำเข้าหลายตัวแปร โดยในงานวิจัยนี้ได้เลือกใช้ตัวแบบจำลองการเรียนรู้เชิงลึก 3 ตัว มาเพื่อใช้ในการเปรียบเทียบ ได้แก่ โครงข่ายระบบประสาทแบบย้อนกลับ (RNN) แบบจำลองหน่วยความจำระยะสั้นแบบยาว (LSTM) และโครงข่ายประสาทกลับ (GRU)

ในส่วนการทดลอง งานวิจัยนี้ได้แบ่งการทดลองออกเป็น 2 ส่วน ดังนี้

1) การทดลองโดยการเปรียบเทียบประสิทธิภาพระหว่างการพัฒนาตัวแบบโดยการเพิ่มคุณลักษณะทางสถิติ

จากการทดลองในเบื้องต้นพบว่า การเพิ่มเฉพาะคุณลักษณะทางสถิติให้กับชุดข้อมูลก่อนที่จะนำไปทำการพัฒนาตัวแบบนั้น ส่งผลให้ประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมในช่วงเวลาใกล้เคียงเพิ่มขึ้น (ในอีก 8 ช่วงเวลาถัดไป) โดยเฉพาะในชุดข้อมูลชุดที่ 3 ที่มีการเพิ่มเฉพาะคุณลักษณะทางสถิติที่มีความสัมพันธ์กับปริมาณน้ำฝนสะสมให้กับชุดข้อมูลก่อนที่จะนำเข้าแบบจำลองส่งผลให้ Mean Absolute Error (MAE) ลดลงมากกว่าการใช้เพียงคุณลักษณะดั้งเดิมเพียง 4 คุณลักษณะ แต่สำหรับการพยากรณ์ในระยะสั้น (1 ช่วงเวลาถัดไป) การเพิ่มคุณลักษณะทางสถิติให้กับชุดข้อมูลในแบบจำลองโครงข่ายระบบประสาทแบบย้อนกลับยังไม่สามารถเพิ่มประสิทธิภาพในการพยากรณ์ให้ดีขึ้นได้มากนัก ยกเว้น

สำหรับแบบจำลอง ARIMAX ซึ่งเห็นได้อย่างชัดเจนว่า ในการพยากรณ์ระยะสั้นนั้น การเพิ่มคุณลักษณะทางสถิติให้กับชุดข้อมูล ส่งผลให้ประสิทธิภาพในการพยากรณ์ดีขึ้นเกือบเทียบเท่ากับโครงข่ายระบบประสาทแบบย้อนกลับ แต่เมื่อช่วงเวลาไกลออกไป ประสิทธิภาพในการพยากรณ์กลับลดลงอย่างมาก

อย่างไรก็ตาม สำหรับข้อมูลชุดที่ 2 หากสามารถพัฒนาตัวแบบให้มีความซับซ้อนได้มากกว่านี้ อาจจะส่งผลให้การสกัดคุณลักษณะในแต่ละชั้นของแบบจำลองโครงข่ายระบบประสาทแบบย้อนกลับทำได้ดีขึ้น และอาจจะส่งผลให้ประสิทธิภาพของการพยากรณ์เพิ่มขึ้น อีกทั้ง ถึงแม้จะพัฒนาตัวแบบจำลองจนสามารถพยากรณ์ชั่วโมงที่มีฝนตกได้ แต่เมื่อพิจารณาจากผลของการพยากรณ์แล้วก็พบว่ายังคงมีปัญหาในเรื่องที่ไม่สามารถทำนายชั่วโมงที่มีปริมาณน้ำฝนสะสมมากกว่าปกติได้ ซึ่งเป็นส่วนที่ต้องพัฒนาต่อไป

2) การทดลองโดยการเปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมในช่วงเวลาถัดไปของแต่ละแบบจำลอง

การทดลองเปรียบเทียบประสิทธิภาพในการพยากรณ์ของตัวแบบแต่ละตัวในช่วงเวลาที่แตกต่างกัน งานวิจัยได้แบ่งการทดลองส่วนนี้ออกเป็น 2 ส่วนเพื่อวัดประสิทธิภาพ คือ เปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมใน 1 ช่วงเวลาถัดไป (3 ชั่วโมงถัดไป) และเปรียบเทียบประสิทธิภาพในการพยากรณ์ใน 8 ช่วงเวลาถัดไป (24 ชั่วโมง) พบว่า แบบจำลองในกลุ่มโครงข่ายระบบประสาทแบบย้อนกลับให้ประสิทธิภาพในการพยากรณ์ที่ดีกว่าแบบจำลองในกลุ่มอาร์มา โดยในการพยากรณ์ปริมาณน้ำฝนสะสมในอีก 1 ช่วงเวลาถัดไปนั้น แบบจำลอง LSTM ให้ประสิทธิภาพในการพยากรณ์ได้ดีที่สุด แต่ในการพยากรณ์ในอีก 8 ช่วงเวลาถัดไปนั้น พบว่า แบบจำลอง GRU ให้ประสิทธิภาพในการพยากรณ์ได้ดีที่สุด อีกทั้ง เมื่อเปรียบเทียบกับแบบจำลองโครงข่ายประสาทแบบย้อนกลับตัวอื่นๆ แบบจำลอง GRU ยังเป็นแบบจำลองที่มีการประมวลผลที่ไว เนื่องจากมีจำนวนประตุน้อย ดังนั้น สำหรับการเลือกแบบจำลองโครงข่ายระบบประสาทย้อนกลับเพื่อทำนายปริมาณน้ำฝนสะสม แบบจำลอง GRU จึงเป็นตัวเลือกที่น่าสนใจ

## 5. ข้อเสนอแนะ

### 5.1 ข้อจำกัดในงานวิจัย

ในการพัฒนาตัวแบบจำลองเพื่อทำนายปริมาณน้ำฝนสะสมในพื้นที่สนามบินนานาชาติสุวรรณภูมิมีข้อจำกัดดังต่อไปนี้

1. ข้อมูลสภาพอากาศในไทยส่วนมาเป็นข้อมูลที่ไม่ได้เผยแพร่แบบสาธารณะ ทำให้ข้อมูลสภาพอากาศที่นำมาใช้สร้างตัวแบบมีน้อย และจำกัด
2. จำนวนสถานีตรวจวัดสภาพอากาศในประเทศไทยมีจำนวนไม่มาก (เฉลี่ยจังหวัดละ 1 แห่ง) จึงไม่สามารถนำข้อมูลสภาพอากาศจากสถานีใกล้เคียงมาพิจารณาร่วมได้
3. ด้านสมรรถภาพของคอมพิวเตอร์ เนื่องจากทรัพยากรด้านคอมพิวเตอร์ที่จำกัดของผู้วิจัย จึงไม่สามารถพัฒนาตัวแบบที่มีความซับซ้อน หรือนำข้อมูลช่วงเวลาในอดีตได้เข้าไปมากกว่านี้ได้

### 5.2 แนวการวิจัยในอนาคต

ทั้งนี้ เพื่อให้แบบจำลองมีประสิทธิภาพ และความแม่นยำในการพยากรณ์มากยิ่งขึ้น ในอนาคตควรจะมีการเพิ่มเติมในส่วนต่างๆ ดังนี้

- 1) ด้านข้อมูล ควรนำข้อมูลพื้นที่ หรือข้อมูลเกี่ยวกับสภาพอากาศด้านอื่นๆ เช่น ปริมาณแสงแดด ทิศทางลม ความหนาแน่นของเมฆ ฯ มาพิจารณาด้วย เนื่องจากทั้งลักษณะทางภูมิศาสตร์ และปัจจัยด้านสภาพอากาศอื่นๆ ก็มีผลต่อปริมาณน้ำฝนสะสม
- 2) การปรับเปลี่ยนความยาวของช่วงเวลาในอดีต (Timestep) ที่จะนำเข้าแบบจำลองให้มีความยาวเพิ่มขึ้นมากกว่า 80 ช่วงเวลา เพื่อเปรียบเทียบประสิทธิภาพในการพยากรณ์ของแต่ละแบบจำลองกับแต่ละชุดข้อมูลเพื่อดูว่าการเพิ่มคุณลักษณะให้ชุดข้อมูลนั้นจะส่งผลต่อประสิทธิภาพการพยากรณ์จริงๆ หรือไม่ และแบบจำลองใดที่เหมาะสมกับข้อมูลชุดนี้มากที่สุด
- 3) การลองใช้ Optimization Algorithm ตัวอื่นๆ ในการเพิ่มประสิทธิภาพ และเปรียบเทียบผลการพยากรณ์
- 4) การใช้การเรียนรู้แบบกลุ่ม (Ensemble Learning Method) เข้ามาเป็นตัวช่วยในการพัฒนาตัวแบบให้สามารถพยากรณ์ได้อย่างแม่นยำ

## เอกสารอ้างอิง

- [1] Aurnhammer, C., and Frank, S. L., “Comparing gated and simple recurrent neural network architectures as models of human sentence processing”, 2019.
- [2] Chawla, N. V., Bowyer K. W., Hall, L. O., and Kegelmeyer W. P., “SMOTE: synthetic minority over-sampling technique. Journal of artificial intelligence research”, vol. 16, pp. 321-357, 2002.
- [3] Chung, J., Gulcehre, C., Cho, K., and Bengio, Y., “Empirical evaluation of gated recurrent neural networks on sequence modeling”, 2014.
- [4] Fan, H., Jiang, M., Xu, L., Zhu, H., Cheng, J., and Jiang, J., “Comparison of long short-term memory networks and the hydrological model in runoff simulation,” *Water*, vol. 12 no. 1, pp. 175, 2020.
- [5] Hernández, E., Sanchez-Anguix, V., Julian, V., Palanca, J., and Duque, N., “Rainfall prediction: A deep learning approach. International Conference on Hybrid Artificial Intelligence Systems,” 2016.
- [6] Hochreiter, S., and Schmidhuber, J., “Long short-term memory. *Neural Comput*,” vol. 9, no.8, pp. 1735-1780, 1997.
- [7] Hung, N. Q., Babel, M. S., Weesakul, S., and Tripathi, N., “An artificial neural network model for rainfall forecasting in Bangkok, Thailand,” *Hydrology and Earth System Sciences*, vol.13(8), pp. 1413-1425, 2009.
- [8] Jalalkamali, A., Moradi, M., and Moradi, N., “Application of several artificial intelligence models and ARIMAX model for forecasting drought using the Standardized Precipitation Index,” *International journal of environmental science and technology*, vol.12(4), pp. 1201-1210, 2015.
- [9] Manokij, F., “Thailand's Precipitation Forecasting Using Deep Learning Approach,” Chulalongkorn University, Bangkok, 2019.
- [10] Narayanan, P., Basistha, A., Sarkar, S., and Sachdeva, K., “Trend analysis and ARIMA modelling of pre-monsoon rainfall data for western India,” *Comptes Rendus Geoscience*, vol. 345(1), pp. 22-27, 2013.
- [11] Poornima, S., and Pushpalatha, M., “Prediction of rainfall using intensified LSTM based recurrent neural network with weighted linear units,” *Atmosphere*, vol.10(11), pp. 668, 2019.
- [12] Salman, A. G., Heryadi, Y., Abdurahman, E., and Suparta, W., “Weather Forecasting Using Merged Long Short-Term Memory Model (LSTM) and Autoregressive Integrated Moving Average (ARIMA) Model,” *J. Comput. Sci.*, vol. 14(7), pp. 930-938, 2018.
- [13] Sanguansat, P., “Artificial Intelligence with Machine Learning,” IDC Premier Limited, 2019.
- [14] Shewalkar, A., “Performance evaluation of deep neural networks applied to speech recognition: RNN, LSTM and GRU,” *Journal of Artificial Intelligence and Soft Computing Research*, vol. 9(4), pp. 235-245, 2019.
- [15] Srachoom, C., “Application of Artificial Neural Network for Weather Forecast,” Chiang Mai University. Chiang Mai, 2007.
- [16] Sukawat, D., “Weather forecast Knowledge,” [Online], Available: <https://www.tmd.go.th/info/info.php?FileID=1>.
- [17] Wang, S. W., Feng, J., and Liu, G., “Application of seasonal time series model in the precipitation forecast,” *Mathematical and Computer Modelling*, vol. 58(3-4), pp. 677-683, 2013.
- [18] Wangdi, K., Singhasivanon, P., Silawan, T., Lawpool Sri, S., White, N. J., and Kaewkungwal, J., “Development of temporal modelling for forecasting and prediction of malaria infections using time-series and ARIMAX analyses: a case study in endemic districts of Bhutan,” *Malaria Journal*, vol. 9(1), pp. 1-9, 2010.
- [19] Yang, S., Yu, X., and Zhou, Y., “LSTM and GRU neural network performance comparison study: Taking Yelp review dataset as an example,” 2020 International workshop on electronic communication and artificial intelligence (IWECAI), 2020.

แบบจำลองการเรียนรู้ท่าทางมนุษย์จากการเคลื่อนไหวด้วยเทคนิคโครงข่ายประสาท  
เทียมแบบสังวัตนาการและแบบหน่วยความจำระยะสั้นแบบยาว

**Learning Model of Human Body Movement using Convolutional  
Neural Network and Long Short-Term Memory**

นัศพัชฌัน ชินปัญชรณะ

*Nutchanun Chinpanthana*

วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิตย์

*College of Innovative Technology and Engineering, Dhurakij Pundit University*

Received: December 17, 2021; Revised: May 03, 2022; Accepted: May 18, 2022; Published: June 29, 2022

**ABSTRACT** – The recognition and understanding of human activities remain active research in computer vision and it is widely used in computer interaction, human monitoring system, human behavior analysis, and other fields. The problem is challenging due to its various interactions between persons and motion dynamics between human and objects. There are many algorithms to recognize human activity based on deep neural network models was proposed. The deep neural network classifier was constructed to integrate with the human action target, but the results was not classified as action though it should have. To overcome this problem, this paper proposes a combined model of deep learning convolutional network with long short-term memory for recognize human motion pose. The proposed model extracts the key point features in an automated way with OpenPose and categorizes with trajectories of a human body. This paper presents main three steps including (1) data pre-processing and feature extraction, (2) deep learning with convolutional neural network and long short-term memory, and (3) efficiency measurement and evaluation of experimental results. Results we have tested our approach on activities of daily living with URFall datasets. The experimental results indicate that our framework offers performance improvements. The proposed model can achieve significant improvements for activity classification with maximum success rate of 81% and 76.9% with 256, 128 hidden nodes in data set II.

**KEYWORDS:** Image classification, Human recognition, Convolutional Neural Network, Human activity recognition

บทคัดย่อ -- งานวิจัยด้านคอมพิวเตอร์วิชันในส่วนของการรู้จำและเข้าใจกิจกรรมมนุษย์ยังคงวิจัยที่สำคัญสำหรับการมีปฏิสัมพันธ์ระหว่างมนุษย์ ไม่ว่าจะเป็นระบบเฝ้าระวัง การวิเคราะห์พฤติกรรมมนุษย์ เป็นต้น ปัญหาที่เกิดขึ้นเมื่อมีการปฏิสัมพันธ์ระหว่างบุคคลหลายคน การเคลื่อนไหวระหว่างบุคคลและวัตถุที่ซับซ้อน มีหลายอัลกอริธึมที่พยายามรวมคุณลักษณะต่างๆเพื่อนำมาใช้ในการวิเคราะห์การรู้จำท่าทางมนุษย์ด้วยรูปแบบโครงข่ายประสาทเทียมเชิงลึก เทคนิคนี้ถูกสร้างขึ้นสำหรับการจำแนกด้วยท่าทางมนุษย์โดยเฉพาะแต่ผลที่ได้ยังไม่ได้ตามที่กำหนดไว้ ทำให้ยังคงเป็นปัญหา ดังนั้นในงานวิจัยนี้จึงได้นำเสนอการเรียนรู้แบบจำลองที่มีการผสมผสานการเรียนรู้ด้วยเทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการและแบบหน่วยความจำระยะสั้นแบบยาว การสกัดคุณลักษณะตำแหน่งสำคัญด้วย OpenPose เพื่อนำมาใช้ในการจำแนกร่วมกับข้อมูลการเคลื่อนที่ของร่างกาย วิธีการดำเนินงานประกอบด้วย 3 ขั้นตอนหลักดังนี้ (1) การเตรียมข้อมูล และสกัด

ข้อมูล (2) การเรียนรู้เชิงลึกด้วยเทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการและแบบหน่วยความจำระยะสั้นแบบยาว และ (3) การวัดประสิทธิภาพและประเมินผลจากการทดลอง ผลลัพธ์จากการทดลองด้วยกิจกรรมในชีวิตประจำวันในฐานข้อมูล URFall สามารถระบุได้ว่าการใช้แบบจำลองการเรียนรู้เชิงลึกด้วยเทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการและแบบหน่วยความจำระยะสั้นแบบยาวร่วมกับคุณลักษณะการเคลื่อนที่ของมนุษย์สามารถเพิ่มประสิทธิภาพของการจำแนกท่าทางได้ดียิ่งขึ้นถึงร้อยละ 81 และ ร้อยละ 76.5 ด้วยโหนดซ่อน 256 และ 123 ในชุดข้อมูลที่ 2


คำสำคัญ: การจำแนกข้อมูลภาพ, การรู้จำมนุษย์, โครงข่ายประสาทเทียมแบบสังวัตนาการ, การรู้จำกิจกรรมมนุษย์

## 1. บทนำ

การพัฒนาการของเทคโนโลยีของเทคโนโลยีที่เปลี่ยนแปลงไปอย่างรวดเร็วมีผลทำให้ เครื่องมืออุปกรณ์อิเล็กทรอนิกส์ รวมทั้ง อุปกรณ์ถ่ายภาพดิจิทัลถูกพัฒนาอย่างต่อเนื่อง ทำให้มีงานวิจัยในสาขาคอมพิวเตอร์วิชันเกิดขึ้นมากมาย การสร้างแอปพลิเคชันใหม่ๆ [1][2] เพื่อตอบสนองความต้องการของผู้ใช้งานที่หลากหลายตลอดเวลา นักวิจัย Argyle M. [3] ได้ใช้คุณลักษณะข้อมูลพื้นฐานของภาพที่ถูกสกัดขึ้นมาเพื่อจะแปลงข้อมูลเป็นท่าทางของมนุษย์ เช่น นั่ง ยืน เดิน และนอน โดยใช้ความสัมพันธ์กับข้อมูลตำแหน่งของร่างกาย เช่น ศีรษะ แขน ขา ลำตัว และ มุมองศา รวมทั้งการเอนเอียงของร่างกาย ในปัจจุบันการวิเคราะห์ท่าทางมนุษย์ กลายเป็นสิ่งสำคัญที่ถูกนำมาประยุกต์ใช้ในการวิเคราะห์ให้สามารถตีความหมายข้อมูลบนภาพ เช่น การตรวจจับการเคลื่อนไหวของมนุษย์เพื่อรักษาความปลอดภัย [4] การวิเคราะห์โรคด้วยการเคลื่อนไหวท่าทางมนุษย์เพื่อวิเคราะห์การรักษามือผู้ป่วย [5]-[7] การสื่อสารด้วยสัญลักษณ์จากท่าทางการเคลื่อนไหวของมนุษย์สำหรับผู้พิการทางการได้ยิน [8] การโต้ตอบบนเกมส์บนแอปพลิเคชันต่างๆ เป็นต้น แต่อย่างไรก็ตามกระบวนการวิเคราะห์ดังกล่าวนี้ มีความแปรเปลี่ยนไปตามสภาพแวดล้อมและรูปแบบของการสกัดข้อมูล และยังไม่มีการสร้างเป็นแบบจำลองมาตรฐานสำหรับท่าทางจากการเคลื่อนไหวของมนุษย์ในชีวิตประจำวัน เพื่อเป็นมาตรฐานสำหรับรูปแบบการเคลื่อนไหวด้วยแนวการเคลื่อนที่จากจุดสำคัญในตำแหน่งข้อต่อมนุษย์ ดังนั้นในงานวิจัยนี้จึงได้นำเสนอการสร้างแบบจำลองการเรียนรู้ท่าทางมนุษย์จากการเคลื่อนไหวด้วย เทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการร่วมกับ แบบหน่วยความจำระยะสั้นแบบยาวเพื่อให้สามารถนำมาใช้ในการวิเคราะห์ท่าทางร่วมกับงานอื่นๆ ได้อย่างมีประสิทธิภาพ

## 2. งานวิจัยที่เกี่ยวข้อง

การรู้จำท่าทางที่เกิดขึ้นในชีวิตประจำวันเป็นพื้นฐานของการเข้าใจถึงกระทำการกิจกรรมต่างๆของมนุษย์ [9] เช่น การเดิน, การวิ่ง, การรับประทานอาหาร, การรับโทรศัพท์ เป็นต้น สำหรับการเคลื่อนไหวของร่างกายเพื่อทำการกิจกรรมใดกิจกรรมหนึ่ง จะถูกวิเคราะห์จากความแตกต่างกันของลำดับตำแหน่งของร่างกาย รวมทั้งความเร็วที่ร่างกายเคลื่อนไหว Wang et al., [10][11] ได้วิเคราะห์การกระทำของมนุษย์ที่แสดงออกบนภาพ ด้วยวิธีการหาความแตกต่างของคัสเตอร์ท่าทางมนุษย์จากการจับคู่ด้วยการแปลงรูปทรงวัตถุ (Deformable shape matching) งานวิจัยของ Thurnau และ Hlavac [12] ใช้การแทนรูปแบบของท่าทางด้วยฮิสโตแกรมของท่าทางหลักโดยใช้ Nonnegative matrix factorization และกลุ่ม A. Andre Chaaoui et al., [13] ได้พยายามสกัดคุณลักษณะ จากท่าทางมนุษย์จากภาพเงา (Silhouettes) แบบ 1 มิติที่มีการแทนค่าเป็นโปรเจกชันของร่างกายมนุษย์ แขนและขา รวม 6 ส่วนแต่การสกัดพีเจอร์ด้วยภาพเงาในบางครั้งการทับกันของส่วนร่างกายอาจทำให้การสกัดพีเจอร์ได้ไม่ครบ แต่อย่างไรก็ตาม S. Yi [14] ได้พยายามจำแนกท่าทางของมนุษย์ ด้วยวิธี Sparse Granger Causality Graph Model เป็นการแทนตำแหน่งและความสัมพันธ์ของร่างกายด้วยโหนดและเส้นเชื่อมโยงบนกราฟ ร่างกายมนุษย์ถูกสกัดด้วยวิธี canny operator เป็นขอบของโครงร่างกาย การเคลื่อนไหวของร่างกายดูจากค่าความเข้มของสีที่เปลี่ยนแปลงไป และการเปรียบเทียบกันของจำนวนพิกเซลบนภาพดิจิทัลเพื่อใช้บอกระยะห่างและใช้โมเดลการจับคู่ เพื่อบอกตำแหน่งร่างกายของมนุษย์ มีนักวิจัยบางกลุ่มพยายามใช้เซ็นเซอร์ Smart wearable อุปกรณ์พกพาในการตรวจจับกิจกรรมของมนุษย์ เพื่อแยกแยะผู้สูงอายุที่กำลังจะล้ม งานวิจัยกลุ่ม Alzahrani et al. [18] ได้พยายามปรับปรุงการรู้จำท่าทางการเคลื่อนไหวของมนุษย์



รูปที่ 1. ขั้นตอนการเรียนรู้ท่าทางมนุษย์จากการเคลื่อนไหว

ด้วยการแทนโครงสร้างมนุษย์ด้วยโครงร่างกระดูก (skeleton) เพื่อวิเคราะห์ข้อมูลแบบระบบเวลาจริง ด้วย โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation neural network) และ มีนักวิจัยกลุ่ม Ghazal et al. [19] Franco et al. [20] เริ่มใช้กล้อง Kinect เพื่อเก็บข้อมูลในรูปแบบ 3 มิติและพยายามสกัดข้อมูลข้อต่อของมนุษย์เพื่อรู้จำท่าทาง และจำแนกออกเป็นท่าทางพื้นฐาน เช่น นั่ง และ ยืน เป็นต้น ยังมีงานวิจัยที่ทำการตรวจจับวัตถุและการติดตามวัตถุที่มีมากกว่าหนึ่งจุดสนใจด้วยการใช้ลำดับของโครงร่างกระดูก [22][23] เป็นตัวแยกแยะคุณลักษณะสำคัญ เพื่อหาความสัมพันธ์ระหว่างโหนดและจุดที่ใกล้เคียงกันระหว่างเฟรม และความต่อเนื่องกันเพื่อสร้างความสัมพันธ์ที่เกิดขึ้นร่วมกันระหว่างโดเมนเชิงพื้นที่และข้อมูลเวลา แต่อย่างไรก็ตามยังเกิดการรบกวนจากพื้นที่โดยรอบและความหมายที่ได้มีมากจนเกินไปการนำกระบวนการเรียนรู้เข้ามาช่วยเพื่อให้ผลได้เป็นพฤติกรรมมนุษย์ จะเห็นว่าการมีนักวิจัยส่วนใหญ่นำเทคนิคเข้ามาประยุกต์ใช้ผ่านรูปแบบการเรียนรู้ตามกิจกรรมของมนุษย์ที่สนใจ ผลที่ได้สามารถใช้ในการจำแนกท่าทางได้บางส่วน ยังมีข้อจำกัดทั้งในรูปของการสกัดข้อมูลจากภาพ เพื่อปรับปรุงการจำแนกท่าทางมนุษย์จากการเคลื่อนไหวให้มีประสิทธิภาพมากขึ้น ดังนั้นในงานวิจัยนี้ได้นำเสนอการจำแนกท่าทางมนุษย์ในชีวิตประจำวันด้วยการสร้างแนวทางการเคลื่อนที่ จากท่าทางการเคลื่อนไหวด้วยแบบจำลองการเรียนรู้ด้วยเทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการร่วมกับเทคนิคแบบหน่วยความจำระยะสั้นแบบยาว (Convolutional Neural Network and Long Short-Term Memory) เพื่อจำแนกท่าทางการเคลื่อนไหวของร่างกายมนุษย์ในชีวิตประจำวัน

### 3. วิธีการวิจัย


งานวิจัยนี้ได้นำเสนอการจำแนกท่าทางมนุษย์ ด้วยการใช้องค์ประกอบของการเคลื่อนไหวของร่างกายมนุษย์ เพื่อนำมาวิเคราะห์ภาพรวมที่ได้จากท่าทางและความเร็วของการเคลื่อนไหว เป็นทฤษฎีพื้นฐานทางชีววิทยาของมนุษย์ทางด้านกลศาสตร์ ด้วยการสกัดข้อมูลและตำแหน่งจากการเคลื่อนที่ของร่างกาย (Human action movement) จากแต่ละตำแหน่งบนจุดสำคัญบนร่างกาย ด้วยมุมมองที่เกิดขึ้น (Movement trajectory) บนโครงร่างจำลองรูปแบบสองมิติที่เรียกว่า โครงร่างกระดูก แสดงถึงตำแหน่งข้อต่อที่เป็นจุดสนใจทั้งหมด 15 จุด เป็นตำแหน่งอ้างอิง (reference point) ส่วนร่างกายท่อนบน (upper body) และส่วนร่างกายด้านล่าง (lower body) ประกอบด้วย ส่วนหัว (head), คอ (neck), ไหล่ (shoulder), แขนส่วนบน (upper arms), แขนส่วนล่าง (forearms), สะโพก (hip), เข่า (knee) และ ข้อเท้า (ankle) ทั้งด้านซ้ายและขวา มีขั้นตอนการดำเนินงานวิจัยดังนี้ (1) การเตรียมข้อมูล และสกัดข้อมูล (2) การเรียนรู้เชิงลึกด้วยเทคนิคโครงข่ายประสาทเทียมและ (3) การวัดประสิทธิภาพและการประเมินผลการทดลอง ดังแสดงในรูปที่ 1

#### 3.1 การเตรียมข้อมูล และสกัดข้อมูล

การเตรียมข้อมูล เริ่มจากคัดเลือกฐานข้อมูลภาพวิดีโอที่มีมนุษย์เด่นชัดจากฐานข้อมูลที่ได้มาตรฐานในชีวิตประจำวัน ที่มีการควบคุมสภาพแวดล้อมจำนวนบุคคล ที่มีการทับซ้อนกันของวัตถุไม่มากนัก รวมทั้งตำแหน่งกล้องในมุมมองที่เอื้ออำนวยสำหรับการสกัดคุณลักษณะเริ่มต้นของโครงร่างบนร่างกาย ดังนั้นสำหรับงานวิจัยนี้ คัดเลือกข้อมูลจากฐานข้อมูล UR FALL [22] ข้อมูลถูกสกัดคุณลักษณะตามโครงร่างกระดูกในรูปแบบสองมิติด้วย OpenPose [23] ที่สัมพันธ์กับตำแหน่งข้อต่อสำคัญของการเคลื่อนไหวบนร่างกายจากภาพวิดีโอ 25 จุดในแต่ละเฟรม ที่มี 15 จุดสำคัญจากร่างกาย (เริ่มจากตำแหน่ง 0 ถึง



14) ดังแสดงในรูปที่ 2 ก. จะถูกสกัดออกเป็นข้อมูลตามตำแหน่งร่างกายรวมทั้งมุมมองที่ได้จากตำแหน่งสำคัญดังแสดงในรูปที่ 2 ข. ข้อมูลถูกจัดเก็บลงในตัวแปร  $B = \{B_1, B_2, \dots, B_j\}$  กำหนดให้ค่า  $B_j \in \mathbb{R}^{w \times h}, j \in \{1 \dots J\}$  แทนจำนวนรวมทั้งหมดของร่างกายทุกส่วน แต่ละส่วนของร่างกายเป็นชุดข้อมูลแทนด้วยตัวแปร  $P = \{P_1, P_2, \dots, P_c\}$  กำหนดให้ค่าเวกเตอร์ในตำแหน่งต่างๆของร่างกายทั้งซ้าย และขวา สามารถเขียนแทนด้วย  $P_c \in \mathbb{R}^{w \times h \times 2}, c \in \{1 \dots C\}$  เมื่อ  $C$  แทนจำนวนของแขนขาทั้งหมด



ก.กำหนดตำแหน่งบนโครงร่างกระดูก ข.กำหนดมุมบนโครงร่าง  
รูปที่ 2 แบบจำลองแสดงโครงร่างกระดูก OpenPose [23]

### 3.2 การสร้างแนวการเคลื่อนที่บนส่วนร่างกาย

การคำนวณคุณลักษณะท่าทางการเคลื่อนไหวจากตำแหน่งของจุดบนแต่ละเฟรม สามารถสร้างความสัมพันธ์ระหว่างจุดเพื่อหาค่าของมุมบนเส้นที่มีการแบ่งส่วน มีความสัมพันธ์ระหว่างมุมมองดังแสดงในตารางที่ 1 โดยกำหนดให้เวกเตอร์  $\vec{v}$  ที่มาจากจุดสองจุดกำหนดให้เป็น  $p_i = (x_i, y_i)$  และ  $p_j = (x_j, y_j)$  เขียนเป็นสมการได้

$$\vec{v} = (x_j - x_i, y_j - y_i) \quad (1)$$

มุม  $\theta$  ระหว่างสองจุดที่เชื่อมต่อกันบนโครงร่างมนุษย์จะถูกแทนด้วย  $\vec{v}$  และ  $\vec{n}$  เขียนเป็นสมการได้

$$\theta = \arccos((\vec{v} * \vec{n}) / \|\vec{n}\| \|\vec{v}\|) \quad (2)$$

เมื่อ  $\|\vec{v}\|$  แทนค่าความยาวของเวกเตอร์  $\vec{v}$  ดังนั้นแต่ละเฟรมประกอบด้วยคุณลักษณะของมุมที่มีทั้งหมด 14 ค่าจากส่วนต่างๆของร่างกาย สามารถเขียนเป็นสมการได้ดังนี้

$$\beta = (\theta_1, \theta_2, \dots, \theta_{14}) \quad (3)$$

กำหนดทิศทางการเคลื่อนที่ ของโครงร่างกระดูก เมื่อถูกตรวจจับบนภาพวิดีโอ จะวัดจากจุดเริ่มต้นจนถึงจุดสุดท้ายที่มีการเคลื่อนที่ไปเขียนเป็นสมการได้ดังนี้

$$T = (\Delta P_1, \dots, \Delta P_{t+F-1}) \quad (4)$$

เมื่อกำหนดให้ค่าเวกเตอร์การกระจัด (displacement vector)

$$\Delta P_t = (P_{t+1} - P_t) = (x_{t+1} - x_t, y_{t+1} - y_t) \quad (5)$$

ดังนั้นทำการนอร์มอลไลซ์ผลรวมของขนาด (sum of the magnitudes) ของเวกเตอร์การกระจัด เขียนเป็นสมการได้

$$T' = T / \sum_{t=1}^{t+F-1} \|\Delta P_t\| \quad (6)$$

ดังนั้น เมื่อมีการคำนวณทุกจุดบนเฟรม สามารถเขียนเป็นสมการได้ดังนี้

$$T = (T'_1, T'_2, \dots, T'_{15}) \quad (9)$$

ตารางที่ 1. แสดงความสัมพันธ์ระหว่างส่วนของร่างกายที่ 1 และ 2 เพื่อแสดงตำแหน่งของมุมที่ i

| มุมที่ (องศา) | ส่วนร่างกายที่ 1 | ส่วนร่างกายที่ 2 |
|---------------|------------------|------------------|
| 1             | ร่างกายหลัก      | ไหล่ซ้าย         |
| 2             | ร่างกายหลัก      | ไหล่ขวา          |
| 3             | ร่างกายหลัก      | สะโพกซ้าย        |
| 4             | ร่างกายหลัก      | สะโพกขวา         |
| 5             | ไหล่ซ้าย         | คอ               |
| 6             | ไหล่ขวา          | คอ               |
| 7             | ต้นแขนซ้าย       | แขนซ้าย          |
| 8             | แขนซ้าย          | ไหล่ซ้าย         |
| 9             | ต้นแขนขวา        | แขนขวา           |
| 10            | แขนขวา           | ไหล่ขวา          |
| 11            | ต้นขาซ้าย        | สะโพกซ้าย        |
| 12            | ต้นขาซ้าย        | ขาซ้าย           |
| 13            | ต้นขาขวา         | สะโพกขวา         |
| 14            | ต้นขาขวา         | ขาขวา            |

#### 4. การเรียนรู้เชิงลึกด้วยเทคนิคโครงข่ายประสาทเทียม

การสร้างแบบจำลองข้อมูลการเรียนรู้ท่าทางมนุษย์จากการเคลื่อนไหว มีการใช้ข้อมูลตั้งต้นจำนวนมาก ประกอบด้วยข้อมูลจากตำแหน่งสำคัญบนร่างกาย 15 จุด รวมทั้งมุมที่สัมพันธ์กับตำแหน่ง 14 ค่า และทิศทางการเคลื่อนที่ ของโครงร่างกระดูกจากเฟรมไปยังเฟรมถัดไป เป็นข้อมูลตั้งต้นสำหรับการเรียนรู้ด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการร่วมกับหน่วยความจำระยะสั้นแบบยาว ดังนั้นการนำโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาวที่สามารถเรียนรู้ลำดับของข้อมูลได้ดี มาทำงานร่วมกับโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยใช้ข้อมูลตั้งต้นเข้าโครงข่ายประสาทเทียมแบบสังวัตนาการ เพื่อเป็นการแยกคุณลักษณะ CNN เป็นอินพุตของโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว ดังแสดงรายละเอียดไว้ดังนี้

##### 4.1 โครงข่ายประสาทเทียมแบบสังวัตนาการ

โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Networks: CNN) [24] เป็นเพอร์เซ็ปตรอนหลายชั้น (Multi-layer Perceptron) ที่มีโครงสร้างแบบลำดับชั้น (Hierarchical Architectures) ถูกออกแบบมาสำหรับการเรียนรู้ข้อมูลแบบก้าวหน้าในระดับสูงเพื่อใช้ในการจำแนกข้อมูลให้ได้ผลลัพธ์ในขั้นสุดท้าย ข้อดีของการเรียนรู้เชิงลึกจากโครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้นคือ สามารถทำการเรียนรู้ข้อมูลแบบอนุกรมเวลาได้ตามประเภทของกิจกรรมที่มีกรกำหนดไว้ เพื่อสร้างชุดข้อมูลเริ่มต้นสำหรับการอนุมานในขั้นที่ 1 เขียนเป็นสมการได้ดังนี้

$$B^n = \delta^1(X, S^{n-1}, P^{n-1}), \forall n \geq 2, \quad (10)$$

กำหนดให้เป็น  $B^1 = \delta^1(X)$ , สำหรับการแทนค่าข้อมูลชุดข้อมูลภาพลงในตัวแปร  $X$  เป็นลำดับแรก เพื่อสร้าง Confidence map สำหรับการอนุมาน CNN ในขั้นที่ 1 สามารถทำการเขียนสมการของการทำนายได้ดังนี้

$$P^n = \phi^1(X, S^{n-1}, P^{n-1}), \forall n \geq 2, \quad (11)$$

เมื่อ  $P^1 = \phi^1(X)$ , และ  $\delta^n$  และ  $\phi^n$  เป็น CNN สำหรับการอนุมานในขั้นที่  $n$  และการกำหนดค่า Confidence map เพื่อสร้างความสัมพันธ์ระหว่างส่วนต่างๆบนร่างกาย ในการทำนายจะใช้ค่าของ Loss function ของทุกขั้นตอนทำนาย

ร่วมกับค่า ground truth เพื่อกำหนดค่าต่างๆเก็บไว้ ดังนั้นสามารถเขียนค่า Loss function ในแต่ละส่วนบนร่างกายได้ดังนี้

$$\mathcal{L}_B^c = \sum_{j=1}^J \sum_p W(p) \cdot \|S_j^c(p) - S_j^*(p)\|_2^2, \quad (12)$$

เมื่อกำหนดให้  $S_j^*$  เป็นค่า Confidence map ของค่า ground truth ในส่วนต่างๆ

$$\mathcal{L}_L^c = \sum_{c=1}^C \sum_p W(p) \cdot \|P_j^c(p) - P_j^*(p)\|_2^2, \quad (13)$$

และ  $P_j^*$  เป็นค่า ground truth ของเวกเตอร์ของความสัมพันธ์,  $W$  แทนค่าเป็นไบนารีมาสก์ (binary mask) เมื่อกำหนดให้  $W(p) = 0$  และ  $p$  แทนการให้ค่าที่ผิดพลาดบนตำแหน่งภาพ ดังนั้นทุกภาพจะถูกทำนายด้วยค่า

$$\mathcal{L} = \sum_{c=1}^C (\mathcal{L}_B^c + \mathcal{L}_L^c). \quad (14)$$

สำหรับการประเมินค่า  $\mathcal{L}_B$  ระหว่างการเรียนรู้ในสมการที่ 12 จะสร้างค่าจาก ground truth ของ confidence map ของ  $B^*$  โดยใช้ค่าในตำแหน่งสำคัญที่ได้จากการกำหนด ซึ่งแต่ละ confidence map เป็นการแทนค่าของสองมิติที่ถูกแทนเป็นข้อมูลแต่ละส่วนบนร่างกายในแต่ละพิกเซล จากการทดลองในฐานข้อมูลกำหนดให้มีข้อมูลที่สามารถเขียนเป็นสมการเพื่อหาค่า Confidence map ของ

$$B_j^*(p) = \exp\left(-\frac{\|p - g_j\|_2^2}{\sigma^2}\right), \quad (15)$$

กำหนดให้  $g_j \in \mathbb{R}^2$  เป็นตำแหน่งของข้อมูลใน ground truth แต่ละส่วนของร่างกายเป็น  $j$  และค่า  $p \in \mathbb{R}^2$  ใน  $B_j^*$  เมื่อ  $\sigma$  เป็นค่าควบคุมค่าสูงสุด

$$B_j^*(p) = \max(0, B_j^*(p)) \quad (16)$$

##### 4.2 โครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว

โครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory :LSTM) [25] เป็นระบบโครงข่ายประสาทชนิดหนึ่งในประเภทระบบโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network) ที่มีวิธีการสามารถจดจำข้อมูลได้ในช่วงระยะเวลายาวนานกว่าในรูปแบบอื่น


โครงสร้างของ LSTM มีลักษณะเซลล์ที่ประกอบด้วยหลายพารามิเตอร์ในแต่ละ gate จะทำการควบคุมพฤติกรรมของเซลล์หน่วยความจำ ซึ่งในแต่ละเซลล์จะถูกควบคุมด้วยฟังก์ชันกระตุ้นดังแสดงในรูปที่ 3 แสดงรูปแบบของเซลล์หน่วยความจำที่มีระยะเวลาในแต่ละขั้น แต่ละ gate มีการทำงานแตกต่างกันดังนี้

1. Input gate ( $i$ ) เป็นตัวควบคุมข้อมูลเข้าเพื่อทำการพิจารณาชุดข้อมูล ( $d_i$ )
2. Forget gate ( $f$ ) เป็นตัวที่อนุญาตให้ LSTM ลืมความจำก่อนหน้า ( $c_{t-1}$ ) เพื่อเตรียมพื้นที่สำหรับรับข้อมูลใหม่ด้วยการตัดสินใจจากข้อมูลนำเข้าร่วมกับ hidden state ( $h_t$ ) ก่อนหน้า
3. Output gate ( $o$ ) เป็นตัวที่ทำการตัดสินใจว่าข้อมูลในหน่วยความจำจะถูกส่งไปยัง hidden state ( $h_t$ )

สามารถเขียนเป็นสมการได้ดังนี้

$$i_t = \sigma(\omega_{di}d_t + \omega_{hi}h_{t-1}) \quad (15)$$

$$f_t = \sigma(\omega_{df}d_t + \omega_{hf}h_{t-1}) \quad (16)$$



รูปที่ 3. โครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว

$$o_t = \sigma(\omega_{do}d_t + \omega_{ho}h_{t-1}) \quad (17)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \phi(\omega_{dc}d_t + \omega_{hc}h_{t-1}) \quad (18)$$

$$h_t = o_t \odot \phi(c_t) \quad (19)$$

กำหนดให้  $\sigma$  แทน ฟังก์ชันซิกมอยด์ (sigmoidal function),

$\phi$  แทน ไฮเปอร์โบลิคแทนเจนต์ (hyperbolic tangent), และ  $c$  แทน ฟังก์ชันกระตุ้น (activation vector) สำหรับข้อมูลค่าน้ำหนักระหว่างข้อมูลนำเข้าหรือข้อมูลซ่อน (hidden input) ถูกแทนด้วย  $\omega_{di}, \omega_{hi}, \omega_{df}, \omega_{hf}, \omega_{do}, \omega_{ho}, \omega_{dc}$  และ  $\omega_{hc}$  ดังนั้นการปรับปรุงค่าระหว่างขั้นตอนการทำงานจะเป็นการรวมข้อมูลจากขั้นตอนต่างๆเพื่อประกอบการพิจารณาในการปรับปรุงค่าของเซลล์ ซึ่งข้อดีของการใช้ LSTM คือสามารถบอกได้ว่าเมื่อใดจะทำการปรับปรุงเซลล์ อ่านเซลล์หรือเขียนข้อมูลเข้ามาซึ่งตัว gate จะเป็นตัวควบคุมการไหลของข้อมูล ในรูปที่ 3 แสดงโครงสร้างของ LSTM

## 5. การวัดประสิทธิภาพและการประเมินผลการทดลอง

### ทดลอง

งานวิจัยนี้ได้นำเสนอวิธีการการเรียนรู้ท่าทางมนุษย์จากการเคลื่อนไหวด้วยเทคนิค CNN-LSTM โดยใช้ OpenPose [23] เป็นเครื่องมือในการสกัดข้อมูลตำแหน่งข้อต่อจากร่างกายมนุษย์ที่เคลื่อนไหวในสภาพแวดล้อมที่แตกต่างกัน และยังสามารถทำงานได้ดีแม้กระทั่งสภาพแวดล้อมที่มีแสงสว่างน้อย สำหรับการทดลองเพื่อทดสอบวิธีการและทฤษฎีเบื้องต้นได้ทำการทดลองในระบบควบคุมโดยการได้คัดเลือกข้อมูลภาพกิจกรรมประจำวันของมนุษย์ (Activities of Daily Living) [15] จากฐานข้อมูล UR Fall [22] ที่ได้มาตรฐานประกอบด้วยชุดข้อมูล 70 กิจกรรมในชีวิตประจำวันที่มีอัตราความเร็วของวิดีโอ 30 เฟรมต่อวินาที ขนาดภาพ 640x480 พิกเซล ดังนั้นชุดข้อมูลที่นำมาใช้ทดลองจะถูกคัดเลือกตามสภาพแวดล้อมและท่าทางมนุษย์ที่เหมาะสม ประกอบด้วยสภาพแวดล้อม 10 สถานที่ภายในภาพประกอบด้วย กลุ่มตัวอย่างที่มีทั้งชายและหญิงที่มีปฏิสัมพันธ์กันแบบไม่ซับซ้อน สามารถจัดกลุ่มเป็นท่าทางกิจกรรมพื้นฐาน ได้ดังนี้ (1) ยืน (standing), นั่ง (sitting), หมอบลง (crouching down), เก็บวัตถุ (picking up), ล้มลง (falling down) และนอน (lying down) ดังแสดงตัวอย่างจากฐานข้อมูลในรูปที่ 4 การทดลองกำหนดให้เป็นชุดเรียนรู้ 80% และชุดทดสอบ 20% ข้อมูล และทำการทดลองโดยกลุ่มข้อมูลออกเป็น 2 ชุดข้อมูลสำหรับ 6 กลุ่มกิจกรรม และ โดยแต่ละชุด

ข้อมูลจะมีขนาดความยาว 30 และ 60 เฟรม ประกอบด้วย ข้อมูล Synchronization, ข้อมูล Accelerometer, ข้อมูลทิศทาง การเคลื่อนที่ และตำแหน่งข้อต่อสำคัญ 15 จุด กำหนดค่าพื้นฐาน สำหรับ CNN ขนาดของตัวกรอง (filter) เพื่อดึงคุณลักษณะไว้ที่ 3 x 3 stride การเลื่อนของตัวกรองเป็น 1 และค่าขั้นพูลลิง (pooling) เป็น 3 และทำการปรับค่าพารามิเตอร์ค่าน้ำหนัก สำหรับการเรียนรู้ที่รวดเร็ว เพื่อนำไปเปรียบเทียบและทำการ สร้างแบบจำลองและวัดประสิทธิภาพด้วยวิธีการโครงข่ายประสาทเทียมแบบสังวัตนาการร่วมกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Convolutional neural network and long short-term memory network: CNN-LSTM) ที่นำเสนอเพื่อเปรียบเทียบกับวิธี โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Networks: CNN) และ โครงข่ายประสาทเทียมแบบสังวัตนาการ-ซัพพอร์ตเวกเตอร์แมชชีน (Convolutional Neural Network-Support Vector Machines: CNN-SVM) โดยมีการประเมินประสิทธิภาพด้วย ค่าความถูกต้องของแต่ละกลุ่มข้อมูล ประกอบด้วย ค่าความแม่นยำ (Precision: Pre.) และ ค่าความระลึก (Recall.) ดัง แสดงผลการทดลองในตารางที่ 2 ถึง ตารางที่ 5 ตามลำดับ

จากตารางที่ 2 และ 3 แสดงผลการจำแนกข้อมูลกิจกรรม ด้วยค่าความแม่นยำ (Pre.) และ ค่าความระลึก (Recall) ของชุด ข้อมูลที่ 1 โดยกำหนดค่าของโหนดซ่อนเป็น 128 และ 256 ตามลำดับ จากตารางที่ 2 กิจกรรม Falling down มีค่าความแม่นยำสูงที่สุดอยู่ที่ 74.8%, 75.5% และ 76.6% จากวิธี CNN, CNN-SVM และ CNN-LSTM ตามลำดับ แต่เมื่อมีการเพิ่ม

ตารางที่ 2. เปรียบเทียบประสิทธิภาพของการจำแนกท่าทาง กิจกรรมชุดข้อมูลที่ 1 ด้วยโหนดซ่อน 128

| Categories       | Performance (%) |        |         |        |          |        |
|------------------|-----------------|--------|---------|--------|----------|--------|
|                  | CNN             |        | CNN-SVM |        | CNN-LSTM |        |
|                  | Pre.            | Recall | Pre.    | Recall | Pre.     | Recall |
| Standing         | 71.0            | 72.4   | 74.5    | 76.0   | 78.7     | 79.5   |
| Sitting          | 72.6            | 68.3   | 75.3    | 68.6   | 76.0     | 76.8   |
| Crouching down   | 63.2            | 71.3   | 65.2    | 75.0   | 70.7     | 70.7   |
| Picking-up       | 69.1            | 67.1   | 69.7    | 71.0   | 72.3     | 73.1   |
| Falling down     | 74.8            | 64.2   | 75.5    | 67.0   | 76.6     | 72.6   |
| Lying down       | 68.2            | 73.5   | 72.8    | 75.0   | 75.8     | 78.1   |
| Average Accuracy | 69.64           |        | 71.95   |        | 75.04    |        |

ตารางที่ 3. เปรียบเทียบประสิทธิภาพของการจำแนกท่าทาง กิจกรรมชุดข้อมูลที่ 1 ด้วยโหนดซ่อน 256

| Categories       | Performance (%) |        |         |        |          |        |
|------------------|-----------------|--------|---------|--------|----------|--------|
|                  | CNN             |        | CNN-SVM |        | CNN-LSTM |        |
|                  | Pre.            | Recall | Pre.    | Recall | Pre.     | Recall |
| Standing         | 79.0            | 79.8   | 79.0    | 72.3   | 85.2     | 88.2   |
| Sitting          | 79.5            | 72.9   | 76.9    | 73.7   | 77.5     | 74.5   |
| Crouching down   | 67.6            | 74.3   | 71.4    | 77.3   | 77.0     | 77.0   |
| Picking-up       | 70.9            | 70.9   | 73.8    | 78.4   | 75.4     | 76.9   |
| Falling down     | 76.7            | 68.7   | 78.6    | 70.6   | 79.6     | 76.6   |
| Lying down       | 70.8            | 76.2   | 75.8    | 73.5   | 77.7     | 80.0   |
| Average Accuracy | 73.9            |        | 75.1    |        | 78.8     |        |

จำนวนโหนดซ่อนเป็น 256 ในตารางที่ 3 แสดงกิจกรรม Falling down จะมีค่าความแม่นยำเฉลี่ยเพิ่มขึ้นเฉลี่ย 2.67% แต่ค่าความแม่นยำในกิจกรรม Standing มีค่าสูงสุดอยู่ที่ 85.2% และถัดมาจะเป็นกิจกรรม Lying down 77.7% ที่จำแนกด้วยเทคนิค CNN-LSTM สำหรับกิจกรรม Crouching down และ Picking up มีค่าความแม่นยำเป็น 67.6% และ 70.9% และเพิ่มขึ้นเป็น 77% และ 75.4% สำหรับการทดลองด้วย CNN และ CNN-LSTM

จากตารางที่ 4 และ 5 แสดงผลการทดลองด้วยชุดข้อมูลที่ 2 แบ่งตามจำนวนโหนดซ่อน 128 และ 256 ตามลำดับ จะสังเกตเห็นว่ากิจกรรม Standing และ Lying down มีค่าความแม่นยำอยู่ที่ 72.5%, 70.3% และค่าความระลึกอยู่ที่ 77.6% และ 73.6% สำหรับการจำแนกด้วย CNN และเมื่อจำแนกด้วย CNN-LSTM มีค่าความแม่นยำอยู่ที่ 80.8% และ 81.2%

ตารางที่ 4. เปรียบเทียบประสิทธิภาพของการจำแนกท่าทาง กิจกรรมชุดข้อมูลที่ 2 ด้วยโหนดซ่อน 128

| Categories       | Performance (%) |        |         |        |          |        |
|------------------|-----------------|--------|---------|--------|----------|--------|
|                  | CNN             |        | CNN-SVM |        | CNN-LSTM |        |
|                  | Pre.            | Recall | Pre.    | Recall | Pre.     | Recall |
| Standing         | 72.5            | 77.6   | 75.4    | 74.7   | 80.8     | 79.2   |
| Sitting          | 69.8            | 61.2   | 72.5    | 71.8   | 75.2     | 75.2   |
| Crouching down   | 63.5            | 62.2   | 74.5    | 73.1   | 74.5     | 76.7   |
| Picking-up       | 65.0            | 64.4   | 69.1    | 73.2   | 75.0     | 72.9   |
| Falling down     | 67.9            | 70.5   | 71.1    | 71.8   | 75.2     | 78.1   |
| Lying down       | 70.3            | 73.6   | 76.1    | 74.1   | 81.2     | 79.6   |
| Average Accuracy | 68.2            |        | 73.1    |        | 77.0     |        |

ตารางที่ 5. เปรียบเทียบประสิทธิภาพของการจำแนกท่าทาง  
กิจกรรมชุดข้อมูลที่ 2 ด้วยโหนดซ่อน 256

| Categories       | Performance (%) |        |         |        |          |        |
|------------------|-----------------|--------|---------|--------|----------|--------|
|                  | CNN             |        | CNN-SVM |        | CNN-LSTM |        |
|                  | Pre.            | Recall | Pre.    | Recall | Pre.     | Recall |
| Standing         | 76.2            | 72.6   | 79.0    | 75.2   | 83.3     | 82.1   |
| Sitting          | 75.2            | 71.2   | 80.8    | 76.9   | 81.7     | 78.3   |
| Crouching down   | 70.4            | 70.7   | 76.5    | 80.6   | 79.5     | 81.4   |
| Picking-up       | 75.0            | 76.6   | 77.4    | 78.3   | 79.2     | 81.6   |
| Falling down     | 71.4            | 77.3   | 75.5    | 79.8   | 79.8     | 79.8   |
| Lying down       | 76.3            | 71.2   | 77.2    | 75.3   | 82.6     | 81.8   |
| Average Accuracy | 73.7            |        | 77.7    |        | 80.9     |        |

และค่าความระลึกอยู่ที่ 79.2%, 79.6% ตามลำดับ ด้วย 128 โหนดซ่อน แสดงในตารางที่ 4 และเมื่อทำการทดลองด้วยการเพิ่มจำนวนโหนดซ่อนเป็น 256 ในตารางที่ 5 ได้ค่าความแม่นยำ 83.3%, 82.6% และ 81.7% ในกิจกรรม Standing, Lying down และ Sitting ด้วยเทคนิค CNN-LSTM ตามลำดับ จากการทดลองจะเห็นว่ามีความแม่นยำเพิ่มขึ้นเมื่อจำนวนโหนดซ่อนเพิ่มขึ้น และได้แสดงการเปรียบเทียบตามชุดการทดลองในแต่ละเทคนิคในตารางที่ 6 เมื่อทำการทดลองด้วยชุดข้อมูลที่ 1 ด้วยโหนดซ่อน 128 ได้ค่าเฉลี่ยความถูกต้องของ CNN, CNN-SVM และ CNN-LSTM เป็น 69.6%, 72% และ 75% ตามลำดับและเมื่อมีการเพิ่มจำนวนโหนดซ่อนค่าเฉลี่ยความถูกต้องที่ได้

ตารางที่ 6. เปรียบเทียบประสิทธิภาพของการจำแนกท่าทาง  
กิจกรรมระหว่างชุดข้อมูล


| Data Set | Nodes | Model Average Accuracy and Number of Nodes (%) |         |          |
|----------|-------|------------------------------------------------|---------|----------|
|          |       | CNN                                            | CNN-SVM | CNN-LSTM |
| I        | 128   | 69.6                                           | 72.0    | 75.0     |
|          | 256   | 73.6                                           | 74.2    | 78.6     |
| II       | 128   | 68.1                                           | 73.1    | 76.9     |
|          | 256   | 74.1                                           | 77.4    | 81.0     |

เพิ่มขึ้นประมาณ 3.3 % สำหรับชุดข้อมูลแรก และค่าความถูกต้องเฉลี่ยเพิ่มขึ้น 4.8% สำหรับชุดข้อมูลที่สอง และเมื่อมีการใช้เทคนิค LSTM เพิ่มขึ้นจะทำให้ค่าความถูกต้องเพิ่มขึ้นโดยเฉลี่ยจากวิธี CNN-SVM ถึง 3.7% และจากวิธี CNN 6.5% สามารถสรุปได้ว่าเมื่อมีการใช้เทคนิค LSTM ร่วมกับ CNN ด้วยการเพิ่มจำนวนโหนดซ่อน สามารถช่วยในการคัดเลือกคุณลักษณะจาก CNN เข้ามายังลำดับชั้น LSTM เพื่อจำแนกท่าทางได้ด้วยค่าเฉลี่ยสูงสุดถึง 81% สำหรับชุดข้อมูลที่ 2 ด้วยโหนดซ่อน 256 โหนด

## 6. สรุปผลการทดลอง

งานวิจัยนี้ได้นำเสนอการสร้างแบบจำลองท่าทางมนุษย์ด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการร่วมกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาวเพื่อจำแนกท่าทางมนุษย์จากการเคลื่อนไหวในกิจกรรมชีวิตประจำวันเพื่อให้ได้ผลลัพธ์ตามกลุ่มความหมายที่ดีที่สุด ได้มีการใช้ข้อมูลตำแหน่งข้อต่อสำคัญร่วมกับข้อมูลทิศทางและการเคลื่อนไหวที่บนร่างกายสามารถแบ่งกลุ่มตามท่าทางพื้นฐาน 6 กลุ่ม ดังนี้ ยืน, นั่ง, หมอบลง, เก็บวัตถุ, ล้มลง และนอน จากผลการทดลองในการเรียนรู้ด้วยการกำหนดโหนดซ่อนเป็น 256 จะเห็นว่า มีค่าเฉลี่ยความถูกต้องของการจำแนกท่าทางสูงถึง 81% สำหรับการทดลองในชุดข้อมูลที่ 2 และ 78.6% สำหรับการทดลองด้วยชุดข้อมูลที่ 1 แต่อย่างไรก็ตามเมื่อทำการทดลองนั้นยังมีข้อจำกัดของสภาพแวดล้อมที่เปลี่ยนแปลง และจำนวนคนพร้อมวัตถุที่ร่วมเฟรม การทับซ้อนกันของวัตถุเป็นการยากในการสกัดตำแหน่งข้อมูลบนโครงร่างกระดูก ทำให้ยังคงเป็นสิ่งที่ต้องแก้ไขและปรับปรุงวิธีการเพื่อให้ตอบรับกับข้อมูลที่หลากหลายมากขึ้นสำหรับการทดลองต่อไป





(ก) Standing (ข) Sitting (ค) Crouching down (ง) Picking up  
รูปที่ 4. ตัวอย่างภาพ RGB และภาพระดับเทา จากฐานข้อมูล UR  
Fall [22]

## เอกสารอ้างอิง

- [1] C. Galleguillos and S. Belongie, "Context Based Object Categorization: A Critical Survey", Computer Vision and Image Understanding, vol. 114, pp. 712-722, 2010.
- [2] B. Luo, Y. Sun, G. Li, D. Chen, and Z. Ju, "Decomposition algorithm for depth image of human health posture based on brain health," Neural Computing and Applications, vol. 32, no. 10, pp. 6327-6342, 2020.
- [3] J. A. Graham, and M. Argyle, "A cross-cultural study of the communication of extra-verbal meaning by gestures", International Journal of Psychology, vol 10, no.1, pp. 57-67, 1975.
- [4] A. Wilson, Paul and Barbara Lewandowska-Tomaszczyk, "Affective Robotics: Modelling and Testing Cultural Prototypes," Cognitive Computation, vol 6, no.4. pp. 814, 2014.
- [5] S. Vishwakarma and A. Agrawal, "A survey on activity recognition and behavior understanding in video surveillance," The Visual Computer, vol. 29, no.10, pp. 983-1009, 2013.
- [6] H. Mousavi Hondori and M. Khademi. A review on technical and clinical impact of Microsoft kinect on physical therapy and rehabilitation. Journal of Medical Engineering, 2014.
- [7] M. A. Jaffar, M. S. Zia, M. Hussain, A. B. Siddiqui, S. Akram, and U. Jamil, "An ensemble shape gradient features descriptor based nodule detection paradigm: a novel model to augment complex diagnostic decisions assistance," Multimedia Tools and Applications, 2018.
- [8] L. Pigou, S. Dieleman, P.-J. Kindermans, and B. Schrauwen, "Chapter Sign Language Recognition Using Convolutional Neural Networks," European Conference on Computer Vision, pp. 572-578, 2015.
- [9] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," International Conference on Learning Representations, 2015.
- [10] Y. Wang and M. Hoai. "Improving human action recognition by non-action classification," In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2698-2707, 2016.
- [11] Li J., X. Liu, W. Zhang, M. Zhang, J. Song and N. Sebe, "Spatio-Temporal Attention Networks for Action Recognition and Detection," IEEE Transactions on Multimedia, 2020.
- [12] Thureau, C. and Hlaváč, V., "n-grams of action primitives for recognizing human behavior," Computer Analysis of Images and Patterns. Springer Berlin / Heidelberg. of Lecture Notes in Computer Science, vol. 4673, pp. 93-100. 2007.
- [13] Alexandros Andre Chaaoui, Pau Climent-Pérez, and Francisco Flórez-Revuelta, "Silhouette-based human

- action recognition using sequences of key poses,” *Pattern Recognition Letters*, vol. 34, Issue 15, pp. 1799-1807, 2013.
- [14] S. Yi and V. Pavlovic, “Sparse granger causality graphs for human action classification,” *Proceedings of the 21st International Conference on Pattern Recognition*, pp. 3374-3377, 2012.
- [15] O. Ojetola, E. Gaura, and J. Brusey, “Data Set for Fall Events and Daily Activities from Inertial Sensors,” In *Proceedings of the 6th ACM Multimedia Systems Conference*, pp. 18–20, 2015.
- [16] F. Hussain, M. Ehatisham-ul-Haq, M.A. Azam, “Activity-Aware Fall Detection and Recognition Based on Wearable Sensors,” *IEEE Sensors Journal*, pp. 4528–4536, 2019.
- [17] T. Nguyen, M. Cho, and T. Lee, “Automatic Fall Detection Using Wearable Biomedical Signal Measurement Terminal,” In *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 5203–5206, 2009.
- [18] M. S. Alzahrani, S. K. Jarraya, H. Ben-Abdallah, and M. S. Ali, “Comprehensive evaluation of skeleton features-based fall detection from Microsoft Kinect v2,” *Signal, Image and Video Processing*, vol. 13, no. 7, pp. 1431–1439, 2019.
- [19] S. Ghazal, U. S. Khan, M. Mubasher Saleem, N. Rashid, and J. Iqbal, “Human activity recognition using 2D skeleton data and supervised machine learning,” *IET Image Processing*, vol. 13, no. 13, pp. 2572–2578, 2019.
- [20] A. Franco, A. Magnani, and D. Maio, “A multimodal approach for human activity recognition based on skeleton and RGB data,” *Pattern Recognition Letters*, vol. 131, pp. 293–299, 2020.
- [21] Cao, Z.; Simon, T.; Wei, S.E.; Sheikh, Y. Realtime multi-person 2d pose estimation using part affinity fields. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 7291–7299, 2017.
- [22] B. Kwolek and M. Kepski, “Human fall detection on embedded platform using depth maps and wireless Accelerometer,” *Computer Methods Program Biomed*, vol 117, pp. 489–501, 2014.
- [23] Z. Cao, G. Hidalgo, T. Simon, S.-E. Wei, Y. Sheikh, “OpenPose: Realtime multi-person 2D pose estimation using Part Affinity Fields”, *Computer Vision and Pattern Recognition*, 2018.
- [24] K. Simonyan and A. Zisserman. “Very deep convolutional networks for large-scale image recognition,” *Computer Vision and Pattern Recognition*, 2014.
- [25] Je Donahue, Lisa Anne Hendricks, Sergio Guadarrama, Marcus Rohrbach, Subhashini Venugopalan, Kate Saenko, and Trevor Darrell, “Long-term recurrent convolutional networks for visual recognition and description,” *Computer Vision and Pattern Recognition*, 2014.





## โมบายแอปพลิเคชันสำหรับจำแนกสายพันธุ์นกด้วยวิธีการเรียนรู้เชิงลึก Mobile Application for Breeding Bird Classification using Deep Learning Technique

ภูมิภักดิ์ พรหมรังกา, สหรัฐ หวานทอง และ ชูพันธุ์รัตน์ โกคา\*

Phummiphak Promrangka, Saharat Wanthong, and Choopan Rattanapoka\*

วิทยาลัยเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

College of Industrial Technology, King Mongkut's University of Technology North Bangkok

Received: December 27, 2021; Revised: April 11, 2022; Accepted: June 07, 2022; Published: June 29, 2022

**ABSTRACT** – Currently, several bird parks have walk-in aviaries where visitors can see various bird species up close. However, visitors are occasionally unable to identify the bird species they are watching. Because the bird species found in walk-in aviaries are not typically seen in everyday life, and there are no zoo signs inside the walk-in aviaries. Therefore, this article proposes a design and development of a mobile application using the Flutter framework. The application can detect and classify 10 bird species using a deep learning model named EfficientDet Lite, which is created by the TFLite model maker library. The users can use a smartphone camera to examine the birds. Then, when birds are found, the application will provide users the information of the bird. From the experiments, we found that the EfficientDet Lite 0, which is the smallest version of EfficientDet Lite, gave the most suitable results for the application. The model took 62.3 ms for the inference time with the precision, recall, accuracy and F1-score of 0.94, 0.94, 0.99, and 0.94, respectively.

**KEYWORDS:** Mobile application, Flutter, EfficientDet model, TensorFlow Lite, TFLite model maker library

**บทคัดย่อ** -- ปัจจุบันมีสวนนกหลายแห่งที่มีกรงนกเปิด ซึ่งผู้ชมสามารถเข้าไปชมนกสายพันธุ์ต่าง ๆ ได้อย่างใกล้ชิด แต่อย่างไรก็ตามผู้เข้าชมอาจจะไม่สามารถทราบสายพันธุ์ของนกที่กำลังชมอยู่ได้ เนื่องจากเป็นนกสายพันธุ์ที่ไม่ได้พบทั่วไปในชีวิตประจำวัน และการไม่มีป้ายระบุข้อมูลกำกับ ดังนั้นบทความนี้เสนอการออกแบบและพัฒนาโมบายแอปพลิเคชันด้วย Flutter Framework สำหรับตรวจสอบและจำแนกสายพันธุ์นกทั้งหมด 10 สายพันธุ์ ด้วยการใช้แบบจำลองการเรียนรู้เชิงลึก EfficientDet Lite ซึ่งถูกสร้างผ่านไลบรารี TFLite Model Maker ผู้ใช้งานสามารถใช้กล้องของสมาร์ทโฟนส่องไปที่นกเมื่อเจอนกแล้วแอปพลิเคชันจะแสดงข้อมูลของนกตัวนั้นให้ผู้ใช้งาน จากการทดลองพบว่าแบบจำลอง EfficientDet Lite 0 ซึ่งเป็นรุ่นของแบบจำลอง EfficientDet Lite ที่มีขนาดเล็กที่สุด ให้ผลลัพธ์ที่เหมาะสมกับการใช้งานมากที่สุด โดยใช้เวลาแปรผลภาพที่ 62.3 ms และมีค่า Precision, Recall, Accuracy และ F1-Score เท่ากับ 0.94, 0.94, 0.99 และ 0.94 ตามลำดับ

**คำสำคัญ:** โมบายแอปพลิเคชัน, Flutter, แบบจำลอง EfficientDet, TensorFlow Lite, ไลบรารี TFLite model maker

\*Corresponding Author: choopan.r@cit.kmutnb.ac.th

## 1. บทนำ

มนุษย์มีความคุ้นเคยและใกล้ชิดกับนก เนื่องจากนกเป็นทั้งสัตว์เลี้ยงและสัตว์ตามธรรมชาติ อีกทั้งยังมีส่วนช่วยกำจัดศัตรูพืชและขยายพันธุ์พืช [1] ในปัจจุบันมีสวนสัตว์เปิดที่มีนกอยู่หลายสายพันธุ์อาศัยอยู่ด้วยกัน นักท่องเที่ยวบางคนก็ไปเยี่ยมชมไม่สามารถจำแนกชนิดของนกได้ เพราะว่ามีนกแต่ละสายพันธุ์มีลักษณะเฉพาะที่แตกต่างกัน ซึ่งยากต่อการจดจำ ทั้งในเรื่องของลักษณะของรูปร่าง สีขน ลักษณะเฉพาะของขน จะงอยปาก และเป็นนกที่ไม่ค่อยได้พบเจอทั่วไปในเมืองหรือหมู่บ้านที่คนอยู่อาศัย ถ้าหากมีการนำเทคโนโลยีที่น่าสนใจและแปลกใหม่มาช่วยในการจำแนกสายพันธุ์ของนก นอกจากจะทำให้ผู้คนรู้จักนกมากขึ้นแล้ว ยังจะสามารถดึงดูดให้ผู้ใช้ที่เป็นเด็กในช่วงปฐมวัยไปจนถึงวัยประถมศึกษาให้มาสนใจในนก เพราะเด็กในช่วงอายุนี้นักจะให้ความสนใจในเทคโนโลยีที่แปลกใหม่ [2]

โทรศัพท์มือถือแบบสมาร์ตโฟนได้มีบทบาทมากขึ้นในชีวิตประจำวัน ในปัจจุบันมีแพลตฟอร์มที่ขึ้นอย่าง Flutter ที่สามารถพัฒนาแอปพลิเคชันบนมือถือได้สะดวกขึ้น และเป็น Cross-Platform Framework ที่ได้รับความนิยมมากที่สุดในปี 2021 คิดเป็น 42% ของทั้งหมด [3] รวมถึงโทรศัพท์มือถือรุ่นนั้นมีประสิทธิภาพมากพอที่จะประมวลผลได้เทียบเท่ากับคอมพิวเตอร์ขนาดเล็ก ในขณะเดียวกันเทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) ก็มีบทบาทสำคัญมากในการเข้ามาจำแนกชนิดหรือประเภทของวัตถุ หรือจำแนกชนิดหรือสายพันธุ์ของสิ่งมีชีวิตต่างๆ [4],[5] โดยการใช้เทคนิคโครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network: CNN) ในการจำแนกรูปภาพ [6] อีกทั้งโทรศัพท์ยังมีกล้องถ่ายรูปในตัว และสามารถนำไปใช้งานร่วมกับเทคโนโลยีที่กล่าวไว้ข้างต้นอีกด้วย

ดังนั้นบทความนี้จะนำเสนอการพัฒนาโมบายแอปพลิเคชัน ที่ช่วยในการตรวจสอบสายพันธุ์ของนก เพื่อให้ผู้ใช้สามารถศึกษา เรียนรู้ และสามารถจำแนกชนิดต่าง ๆ ได้ โดยมีการใช้งานร่วมกับแบบจำลองการเรียนรู้เชิงลึกที่ใช้เทคโนโลยี CNN ช่วยในการจดจำรูปภาพ แอปพลิเคชันนี้จะพัฒนาด้วย ภาษา Dart บน Flutter Framework ซึ่งจะช่วยให้ผู้ใช้ในการตรวจสอบและดูข้อมูลรายละเอียดเกี่ยวกับนกในสายพันธุ์ต่างๆ ได้อย่างสะดวก และยังช่วยเพิ่มความน่าสนใจในการศึกษาเกี่ยวกับนก

## 2. ทฤษฎีพื้นฐานและงานวิจัยที่เกี่ยวข้อง

### 2.1 Flutter

Flutter [7] คือ Framework ที่เป็นแบบโอเพนซอร์ส พัฒนาโดย Google ใช้สำหรับการสร้างแอปพลิเคชันที่มีความสวยงาม และสามารถทำงานได้บนหลายแพลตฟอร์ม ได้แก่ อุปกรณ์พกพา เว็บ เดสก์ท็อป และอุปกรณ์ฝังตัว ด้วยโค้ดเดียวกัน คุณสมบัติหลักของ Flutter Framework คือ

- ความเร็ว : โค้ดของ Flutter จะถูกคอมไพล์เป็นชุดคำสั่งแบบ ARM หรือ Intel จึงทำให้มีประสิทธิภาพและทำงานได้อย่างรวดเร็วบนอุปกรณ์ทุกชนิด

- ความง่ายในการพัฒนาโปรแกรม : ใน Flutter มีการทำงานของ Hot Reload ซึ่งทำให้ผู้พัฒนาโปรแกรมสามารถ Build และ Run ซ้ำอย่างรวดเร็ว อีกทั้งการเปลี่ยนแปลงของโปรแกรมได้เกือบจะทันทีโดยไม่สูญเสียสถานะของโปรแกรมที่ทำงานอยู่

- ความยืดหยุ่นในการแสดงผล : ผู้พัฒนาโปรแกรมสามารถควบคุมตำแหน่งต่าง ๆ บนหน้าจอได้อย่างละเอียด จึงทำให้มีความหลากหลายและยืดหยุ่นในการออกแบบ

- สามารถใช้งานได้หลายแพลตฟอร์ม : โค้ดของ Flutter นั้นสามารถนำไปใช้กับอุปกรณ์หลายชนิด เช่น อุปกรณ์เคลื่อนที่ เว็บ เดสก์ท็อป และอุปกรณ์ Embedded โดยไม่จำเป็นต้องแก้ไขโค้ด

### 2.2 TensorFlow

TensorFlow [8] คือ ไลบรารีสำหรับสร้างแบบจำลองการเรียนรู้เชิงลึก ซึ่งมีการนำไปประยุกต์เพื่อเพิ่มประสิทธิภาพกับผลิตภัณฑ์หลากหลายประเภท เช่น เครื่องมือค้นหา (Search Engine), การแปลภาษา (Translation), คำบรรยายภาพ (Image Captioning) และ การแนะนำ (Recommendations)

TensorFlow ถูกพัฒนาโดย Google เพื่อให้นักวิจัยและนักพัฒนาทำงานกับแบบจำลอง AI ได้ เมื่อพัฒนาและปรับปรุงซักระยะหนึ่ง TensorFlow ก็ถูกปล่อยออกมาให้คนทั่วไปใช้งานได้ โดยเปิดโอเพนซอร์สในปี 2015 และปล่อยตัวสมบูรณ์ออกมาในปี 2017 พร้อมลิขสิทธิ์แบบ Apache Open Source ให้คนทั่วไปสามารถใช้งาน ดัดแปลง และแจกจ่ายตัวที่ถูกดัดแปลงมาแล้วโดยที่ไม่มีค่าใช้จ่าย

TensorFlow เป็นที่นิยม เนื่องจากถูกสร้างมาเพื่อให้ทุกคนเข้าถึงได้ง่าย TensorFlow ได้รวมเอา API ที่แตกต่างกัน เพื่อสร้างสถาปัตยกรรมแบบ Deep Learning อย่าง Convolutional

Neural Network (CNN) และ Recurrent Neural Network (RNN) TensorFlow ยังมี Graph เป็นตัวคำนวณหลัก เพื่อช่วยให้นักพัฒนาเห็นภาพโครงสร้าง Neural Network รวมทั้งสามารถทำงานร่วมกับ Tensorboard เครื่องมือที่ช่วยให้นักพัฒนาหาข้อผิดพลาดของโปรแกรม และสุดท้าย TensorFlow สามารถทำงานได้ทั้งบน CPU และ GPU

### 2.3 TensorFlow Lite

TensorFlow Lite (TFLite) [9] คือ Tools ที่ช่วยให้นักพัฒนาสามารถรันแบบจำลองของ TensorFlow ทำ Inference บนมือถือ Mobile, Android, iOS, อุปกรณ์ Edge, IoT Device, RaspberryPi, Jetson Nano, Arduino และ Microcontroller ได้ เนื่องจากแบบจำลองของ TFLite มีความซับซ้อนน้อยกว่าแบบจำลองของ Tensorflow ปกติ ทำให้แบบจำลองของ TFLite มีขนาดเล็กลง ทำงานได้เร็วขึ้น แต่อย่างไรก็ตามต้องยอมรับกับความแม่นยำของแบบจำลองที่ลดลง

### 2.4 Convolutional Neural Network

การเรียนรู้เชิงลึกมีพื้นฐานมาจาก Neural Network ซึ่งเป็นสาขาหนึ่งของเทคโนโลยี Artificial Intelligence ที่มีแนวคิดมานานตั้งแต่ปี 1943 คือ การพัฒนาเครือข่ายของอัลกอริทึมให้ทำงานแบบเดียวกับเครือข่ายระบบประสาทของมนุษย์

Convolutional Neural Network (CNN) [10] หรือโครงข่ายประสาทแบบคอนโวลูชัน จะจำลองการมองเห็นของมนุษย์ที่มองเห็นพื้นที่ที่น้อย ๆ และนำกลุ่มของพื้นที่น้อย ๆ มาผสมกัน เพื่อดูว่าสิ่งที่เห็นอยู่เป็นอะไร โดยการใช้ Matrix ชนิดพิเศษ ที่เรียกว่า Convolution Matrix ซึ่งทำหน้าที่สกัดเอาส่วนต่างๆ ของภาพออกมา เช่น เส้นขอบของวัตถุต่างๆ เพื่อให้สามารถเรียนรู้ลักษณะของภาพได้อย่างมีประสิทธิภาพและแม่นยำ

### 2.5 EfficientDet

แบบจำลอง EfficientDet [11] นั้นถูกพัฒนาขึ้นในปี 2020 จาก Google Brain Team ซึ่งมีจุดประสงค์ในการพัฒนาแบบจำลองสำหรับตรวจจับวัตถุ (Object Detection) ที่มีความแม่นยำสูงและยืดหยุ่นตามข้อจำกัดทางด้านทรัพยากร

ภายในแบบจำลอง EfficientDet นั้นจะมี BiFPN หรือ Bi-directional Feature Pyramid Network เป็น Feature Fusion

Network สำหรับการรวม Feature ที่จะถูกสกัดจากแบบจำลองต่างๆ


สถาปัตยกรรมของ EfficientDet แสดงดังรูปที่ 1 ประกอบด้วยแบบจำลอง EfficientNet [12] ทำหน้าที่เป็น Backbone ของแบบจำลอง ซึ่งจะสกัดคุณลักษณะของรูปภาพในขนาดต่าง ๆ ออกมา จากนั้นข้อมูลคุณลักษณะเหล่านั้นจะถูกป้อนเข้าไปใน BiFPN ที่ทำหน้าที่เป็น Feature Fusion Network และท้ายสุดข้อมูลที่สกัดได้จาก BiFPN ก็จะถูกป้อนเข้า Class/Box Prediction Network เพื่อทำนาย Object ต่าง ๆ โดยแบบจำลอง EfficientDet จะมีรุ่นย่อย 5 รุ่นคือ EfficientDet 0 จนถึง EfficientDet 4 โดยแต่ละรุ่นจะมีความซับซ้อนของโครงสร้างที่แตกต่างกัน ดังแสดงในตารางที่ 1

### 2.6 TFLite Model Maker

ไลบรารี TFLite Model Maker [13] เป็นไลบรารีที่ช่วยลดความยุ่งยากในการสร้าง และฝึกแบบจำลองบน TensorFlow Lite โดยใช้ชุดข้อมูลที่กำหนดเอง ใช้การถ่ายโอนการเรียนรู้เพื่อลดจำนวนข้อมูล และระยะเวลาในการฝึกแบบจำลอง โดยในปัจจุบันไลบรารี TFLite Model Maker รองรับงานการเรียนรู้ของเครื่อง ดังต่อไปนี้

- การจำแนกรูปภาพ
- การตรวจจับวัตถุ
- การจัดประเภทข้อความ
- การตอบคำถามกับ BERT
- การจำแนกประเภทเสียง
- คำแนะนำ

สำหรับการตรวจจับวัตถุ TFLite Model Maker มีคลาสคำสั่งสำหรับใช้งานในการสร้าง และฝึกแบบจำลองอยู่หลัก ๆ ทั้งหมด 3 คลาส คือ (1) DataLoader ใช้สำหรับจัดการกับชุดข้อมูลที่ใช้ในการฝึกแบบจำลอง (2) ModelSpec ใช้สำหรับการเลือกรุ่นของแบบจำลอง โดยมีแบบจำลองให้สามารถเลือกใช้ได้ตั้งแต่ EfficientDet Lite 0 ถึง EfficientDet Lite 4 ซึ่งจะเรียงความซับซ้อนของแบบจำลองไปตามลำดับ โดยแบบจำลอง EfficientDet Lite นั้นเป็นแบบจำลอง EfficientDet ที่ลดความซับซ้อนลงมาให้เหมาะกับการใช้งานในอุปกรณ์ IoT โทรศัพท์มือถือ และอุปกรณ์ชนิดอื่น ๆ ที่มีหน่วยประมวลผลขนาดเล็ก [14] และ (3) ObjectDetector ใช้สำหรับการฝึกอบรมแบบจำลอง



รูปที่ 1. สถาปัตยกรรมของแบบจำลอง EfficientDet (ที่มา: จากบทความ [12])


ตารางที่ 1. คุณสมบัติของแบบจำลอง EfficientDet แต่ละประเภท

| แบบจำลอง       | ขนาด Input | Backbone       | BiFPN          |              | จำนวน Layer<br>ของ Box/ Class |
|----------------|------------|----------------|----------------|--------------|-------------------------------|
|                |            |                | จำนวน Channels | จำนวน Layers |                               |
| EfficientDet 0 | 512        | EfficientNet 0 | 64             | 3            | 3                             |
| EfficientDet 1 | 640        | EfficientNet 1 | 88             | 4            | 3                             |
| EfficientDet 2 | 768        | EfficientNet 2 | 112            | 5            | 3                             |
| EfficientDet 3 | 896        | EfficientNet 3 | 160            | 6            | 4                             |
| EfficientDet 4 | 1024       | EfficientNet 4 | 224            | 7            | 4                             |

### 3. วิธีกรวิจัย

#### 3.1 โครงสร้างและหลักการทำงานของแอปพลิเคชัน

โมบายแอปพลิเคชันนี้ถูกพัฒนาด้วยภาษา Dart บน Flutter Framework โดยเมื่อผู้ใช้งานเรียกใช้งานแอปพลิเคชันผ่านทางสมาร์ทโฟน แอปพลิเคชันในส่วนของการจำแนกสายพันธุ์นกจะมีขั้นตอนดังแสดงในรูปที่ 2 ซึ่งเริ่มจากผู้ใช้งานสามารถเปิดกล้องเพื่อส่งไปยังนก หรือเลือกภาพนกที่อยู่ในคลังภาพของสมาร์ทโฟน จากนั้นภาพจะถูกส่งไปยังแบบจำลองการเรียนรู้เชิงลึก EfficientDet Lite ซึ่งเป็นแบบจำลองของ EfficientDet ที่ทำงานผ่าน TensorFlow Lite แทน TensorFlow เพื่อให้มีประสิทธิภาพการทำงานที่รวดเร็ว และเหมาะสมกับบนอุปกรณ์พกพา จากนั้นเมื่อแบบจำลองได้รับภาพนก ก็จะประมวลผลและทำนายสายพันธุ์นก พร้อมติดกรอบรอบนกที่พบในภาพกลับมาแสดงให้กับผู้ใช้งาน หลังจากนั้นถ้าผู้ใช้งานต้องการทราบข้อมูลรายละเอียดเกี่ยวกับนก ก็สามารถใช้นี้วกดบริเวณภายในกรอบที่แอปพลิเคชันได้ตีไว้รอบนกได้



รูปที่ 2. ขั้นตอนการตรวจจับนกของแอปพลิเคชัน

### 3.2 การเลือกสายพันธุ์นกสำหรับสร้างแบบจำลอง

สำหรับการพัฒนาแบบจำลองการเรียนรู้เชิงลึกในบทความนี้ได้กำหนดให้แบบจำลองสามารถรู้จำสายพันธุ์นกได้ทั้งหมด 10 สายพันธุ์ที่พบทั่วไปในกรงนกเปิด และเพื่อเพิ่มความถูกต้องในการตรวจจับมากขึ้น จึงกำหนดกลุ่มของข้อมูลอีกประเภทหนึ่งคือ ไม่ใช่ชนก ดังแสดงในตารางที่ 2


ตารางที่ 2 รายชื่อสายพันธุ์นกในการพัฒนาแบบจำลอง

| ลำดับที่ | ชื่อนกภาษาไทย   | ชื่อนกภาษาอังกฤษ           |
|----------|-----------------|----------------------------|
| 1        | นกสาลิกาเขียว   | Green Javan Magpie (GRJ)   |
| 2        | นกขมิ้น         | Canary (CAN)               |
| 3        | นกหัวโต         | Grey Plover (GRP)          |
| 4        | นกกระดง         | Nicobar Pigeon (NIC)       |
| 5        | นกยูง           | Peacock (PEA)              |
| 6        | นกกระรางหัวขวาน | Hoopoes (HOP)              |
| 7        | นกอีโก้ย        | Whimbrel (WHI)             |
| 8        | นกกระทุง        | Pelican (PEL)              |
| 9        | นกแขกเต้า       | Alexandrine Parakeet (ALE) |
| 10       | นกแสก           | Barn Owl (BAO)             |
| 11       | ไม่ใช่ชนก       | Not Bird (Not)             |

### 3.3 การสร้างและฝึกแบบจำลอง

ในการพัฒนาแบบจำลองการเรียนรู้เชิงลึกในบทความนี้ ผู้แต่งได้เลือกใช้งานไลบรารี TFLite Model Maker ซึ่งเป็นไลบรารีสำหรับการสร้างแบบจำลองที่ทำงานบน TensorFlow Lite มากไปกว่านั้นในไลบรารีนี้มีแบบจำลอง EfficientDet Lite มาให้เรียบร้อยแล้วพร้อมใช้งานแล้ว

สำหรับการฝึกแบบจำลอง เนื่องจากแบบจำลองนี้ได้ถูกออกแบบไว้เพื่อให้สามารถจดจำสายพันธุ์นกได้ 10 สายพันธุ์และภาพไม่ใช่ชนก ดังนั้นแบบจำลองนี้จะสามารถทำนายผลได้ทั้งหมด 11 ประเภท จึงแบ่งการฝึกแบบจำลองออกเป็น 11 คลาส โดยแต่ละคลาสใช้ภาพในการฝึกประมาณ 500 – 1000 ภาพ และแบ่งภาพที่รวบรวมและเตรียมไว้ออกเป็นภาพสำหรับการฝึกแบบจำลอง 80% และภาพสำหรับการตรวจสอบการทำงานของแบบจำลอง 20% ดังรูปที่ 3



รูปที่ 3. จำนวนภาพที่ใช้ในการฝึกแบบจำลอง

ในไลบรารี TFLite Model Maker มี Method ที่ใช้สำหรับฝึกแบบจำลองอยู่แล้ว โดยใช้คำสั่ง `Object_detector.create` และมีพารามิเตอร์ได้แก่ ไฟล์ข้อมูลการฝึก, ชื่อแบบจำลอง, จำนวนรอบการสอน, ขนาดของ Batch, ทำ Fine Tuning หรือไม่ และไฟล์ข้อมูลการตรวจสอบความถูกต้อง

โดย “ไฟล์ข้อมูลการฝึก” และ “ไฟล์ข้อมูลการตรวจสอบความถูกต้อง” เป็นไฟล์รูปภาพแต่ละคลาสที่จัดเก็บในรูปแบบ TFRecord ซึ่งในบทความนี้ได้ใช้คำสั่ง `DataLoader` ที่มีอยู่ในไลบรารี TFLite Model Maker โหลดรูปภาพจาก Google Cloud Storage ที่ผู้แต่งได้จัดเตรียมไว้ นำมาจะเก็บเป็นรูปแบบ TFRecord เพื่อนำไปใช้ในการฝึก ตรวจสอบความถูกต้อง และทดสอบแบบจำลอง

“ชื่อแบบจำลอง” จะเป็นการเลือกแบบจำลอง แต่ละแบบจำลองจะมีโครงสร้างที่แตกต่างกัน รวมถึงความแม่นยำ และ Latency ที่แตกต่างกัน โดยในบทความนี้ได้เลือกใช้แบบจำลอง EfficientDet Lite ในการรู้จำสายพันธุ์ของนก เพราะมีความแม่นยำที่สูง และรวดเร็ว เหมาะสำหรับการตรวจจับวัตถุที่มีการเคลื่อนไหว [15]

“จำนวนรอบการสอน” (Epoch) คือ จำนวนรอบทั้งหมดที่นำข้อมูลภาพทั้งหมดป้อนเข้าไปสอนแบบจำลอง จนครบ โดยในบทความนี้ได้กำหนดไว้ที่ 85 รอบ

“ขนาดของ Batch” คือจำนวนรายการข้อมูลที่จะให้ Optimiser คำนวณในหนึ่งครั้ง โดยบทความนี้ได้กำหนดขนาดไว้เท่ากับ 16

### 3.4 ข้อมูล และรายละเอียดของนก

ข้อมูลของนกชนิดต่าง ๆ ทางผู้จัดทำได้ทำการสืบค้นข้อมูลมาจากวิกิพีเดีย และสารานุกรมสัตว์ออนไลน์ขององค์การสวนสัตว์แห่งประเทศไทยในพระบรมราชูปถัมภ์ [16] และนำมาเรียบเรียงลงในแอปพลิเคชัน โดยมีรายละเอียดข้อมูลของนกแต่ละสายพันธุ์ดังนี้

- ชื่อภาษาไทย
- ชื่อภาษาอังกฤษ
- ลักษณะทั่วไปของนก
- พฤติกรรมของนก
- อาหารที่กิน
- ถิ่นที่อยู่อาศัย

### 3.5 การประเมินประสิทธิภาพของแบบจำลอง

ในบทความนี้ได้สร้าง และฝึกแบบจำลองทั้งหมด 3 แบบจำลอง คือ EfficientDet Lite 0, EfficientDet Lite 2 และ EfficientDet Lite 4 จากนั้นจะทำการเลือกแบบจำลองที่ดีที่สุดเพื่อนำไปใช้งานกับแอปพลิเคชัน จึงจำเป็นที่จะต้องมีการประเมินประสิทธิภาพของแบบจำลอง ซึ่งแบ่งออกเป็น 2 หมวดหมู่ คือ ความเร็วและความแม่นยำของแบบจำลอง

#### 3.5.1 การประเมินประสิทธิภาพความเร็วของแบบจำลอง

แบบจำลองแต่ละรุ่นมีความเร็วในการทำงานที่แตกต่างกันโดยจะวัดประสิทธิภาพอยู่ 2 ค่าคือ ระยะเวลาความเร็วในการแปรผลของแบบจำลอง (Inference Time) และ FPS ของกล้องวิดีโอ เมื่อนำแบบจำลองไปใช้งานจริงบนสมาร์ตโฟน

#### 3.5.2 การประเมินประสิทธิภาพความแม่นยำของแบบจำลอง

การประเมินประสิทธิภาพความแม่นยำของแบบจำลองสำหรับการจัดหมวดหมู่นั้น ตามปกติมีค่าที่พิจารณาอยู่ 4 ค่า ได้แก่ (1) True Positive (TP) จำนวนที่ทำนายตรงกับข้อมูลจริงในคลาสที่กำลังพิจารณา (2) True Negative (TN) จำนวนที่ทำนายตรงกับข้อมูลจริงในคลาสที่ไม่ได้กำลังพิจารณา (3) False Positive (FP) จำนวนที่ทำนายผิดในคลาสที่กำลังพิจารณา และ (4) False Negative (FN) จำนวนที่ทำนายผิดในคลาสที่ไม่ได้กำลังพิจารณา โดยจะประเมินประสิทธิภาพของแบบจำลอง ด้วยกันทั้งหมด 4 ค่า ได้แก่ Precision, Recall, Accuracy และ F1-score โดยคำนวณได้ดังสมการที่ (1) ถึง สมการที่ (4)

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$F1-score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

สำหรับแบบจำลองแบบหลายคลาส (Multi-Class) นั้น จำเป็นต้องใช้ Confusion Matrix เพื่อมาช่วยในการคำนวณประสิทธิภาพความแม่นยำของแต่ละคลาส โดยแต่ละคลาสสามารถคำนวณค่า Precision ได้จากการนำค่าที่ทำนายตรงกับข้อมูลจริงในคลาสที่กำลังพิจารณา (TP) นำไปหารกับผลรวมของค่าทั้งหมดในแถวของคลาสที่กำลังพิจารณา (TP + FP) และคำนวณค่า Recall ได้จากการนำค่าที่ทำนายตรงกับข้อมูลจริงในคลาสที่กำลังพิจารณา (TP) นำไปหารกับผลรวมของค่าทั้งหมดในคอลัมน์ของคลาสที่กำลังพิจารณา (TP + FN) ยกตัวอย่างเช่น ข้อมูลของ Confusion Matrix ดังภาพที่ 4 สามารถคำนวณ Precision ของคลาส A, B และ C ได้ดังสมการที่ (5) ถึง (7) ตามลำดับ

| Predicted Values | Actual Values |      |      |      |           |
|------------------|---------------|------|------|------|-----------|
|                  | Class         | A    | B    | C    | Precision |
|                  | A             | 20   | 0    | 0    | 1.00      |
|                  | B             | 0    | 18   | 2    | 0.90      |
|                  | C             | 0    | 1    | 19   | 0.95      |
|                  | Recall        | 1.00 | 0.95 | 0.90 |           |

รูปที่ 4. ตัวอย่าง Confusion Matrix

$$Precision_A = \frac{20}{20 + 0 + 0} = 1.00 \quad (5)$$

$$Precision_B = \frac{18}{0 + 18 + 2} = 0.90 \quad (6)$$

$$Precision_C = \frac{19}{0 + 1 + 19} = 0.95 \quad (7)$$

และสามารถคำนวณ Recall ของคลาส A, B และ C ดังสมการที่ (8) ถึง (10) ตามลำดับ

$$Recall_A = \frac{20}{20 + 0 + 0} = 1.00 \quad (8)$$

$$Recall_B = \frac{18}{0 + 18 + 1} = 0.95 \quad (9)$$

$$Recall_C = \frac{19}{0 + 2 + 19} = 0.90 \quad (10)$$

## 4. ผลการทดลอง

### 4.1 ผลการฝึกแบบจำลอง

การฝึกแบบจำลองได้ใช้บริการของ Google Colab ในการฝึก โดยมีหน่วยประมวลผลกลางคือ Intel(R) Xeon(R) หน่วยความจำขนาด 24 GB และมีหน่วยประมวลผลภาพคือ Nvidia K80 / T4/ P100

จากรูปที่ 5 แสดงกราฟค่าการสูญเสียระหว่างการฝึกแบบจำลอง EfficientDet Lite 0 จะเห็นว่าค่าการสูญเสียลงไปต่ำสุดในรอบที่ 78 โดยมีค่าการสูญเสียเท่ากับ 0.05256 จากนั้นจะเห็นว่าหลังจากรอบที่ 78 เป็นไปค่าการสูญเสียจะแกว่งสูง และมีแนวโน้มที่จะเกิด การ Overfit

### 4.2 ประสิทธิภาพของแบบจำลอง

สำหรับการทดสอบแบบจำลอง ได้นำแบบจำลองที่ทำการฝึกเสร็จเรียบร้อยแล้วมาใช้งานกับแอปพลิเคชัน บนสมาร์ตโฟนรุ่น Oneplus 7 Pro ที่มีหน่วยประมวลผลกลาง Snapdragon 855 หน่วยความจำขนาด 8 GB โดยมีหน่วยประมวลผลภาพ Adreno 640 ทำการตรวจจับนกในภาพทั้งหมด 11 คลาส (Class) คลาสละ 20 ภาพ



รูปที่ 5. ค่าความสูญเสียระหว่างการฝึกของแบบจำลอง  
EfficientDet Lite 0

จากนั้นนำผลลัพธ์ที่ได้จากการทำนายผลของแบบจำลองมาสร้าง Confusion Matrix และคำนวณประสิทธิภาพของแบบจำลองได้แก่ค่า Precision และ Recall โดยมีผลลัพธ์ประสิทธิภาพของแบบจำลองดังรูปที่ 6

ขั้นตอนต่อไปคือเลือกรูปภาพจากขั้นตอนก่อนหน้านี้ 10 ภาพ เพื่อหาระยะเวลาในการแปรผล (Inference Time) เฉลี่ย และใช้ Flutter Performance Profiling Mode ในการแสดงค่า FPS เฉลี่ยตอนเปิดหน้ากล้อง ได้ผลลัพธ์ดังตารางที่ 3

จากตารางจะเห็นได้ว่าทั้ง 3 แบบจำลอง จำนวน FPS ของกล้องมีค่าเท่ากันคือ 23 FPS เนื่องจากตัวกล้องและแบบจำลองนั้นทำงานคู่ขนานกัน ทำให้ถึงแบบจำลองจะมีขนาดซับซ้อนมากเท่าไรก็จะไม่ส่งผลต่อค่า FPS ของกล้อง แต่เวลาในการแปรผลของแบบจำลอง (Inference Time) นั้นต่างกันมาก ยิ่งเวลาในการแปรผลมาก ก็จะทำให้แบบจำลองทำการตรวจจับหรือตีกรอบตัวนกไม่ทันหรือเกิดการหน่วง (Delay) ได้

ในขณะที่แบบจำลองกำลังทำการแปรผลอยู่นั้นแบบจำลองจะทำการข้ามเฟรม (Skip Frame) ในระหว่างช่วงเวลานั้นทิ้งไป แล้วจะนำเฟรมหลังจากที่แบบจำลองแปรผลเสร็จ เข้าไปแปรผลในแบบจำลองต่อ ทำให้จำนวน FPS ที่แท้จริงของแบบจำลองหรือ FPS ของกรอบที่ขึ้นมามีจริงนั้น ไม่เท่ากับกล้องวิดีโอ โดย FPS ที่ได้จากการประมวลผลตีกรอบของแต่ละรุ่นแบบจำลองแสดงดังสมการที่ (11) ถึงสมการที่ (13)

$$FPS_{EfficientDet\ Lite\ 0} = \frac{1}{62.3} \times 1000 = 16.05 \quad (11)$$

$$FPS_{EfficientDet\ Lite\ 2} = \frac{1}{152.7} \times 1000 = 6.54 \quad (12)$$

$$FPS_{EfficientDet\ Lite\ 4} = \frac{1}{573.6} \times 1000 = 1.74 \quad (13)$$

เมื่อเทียบ Inference Time ของ EfficientDet Lite 0 กับ EfficientDet Lite 2 และ EfficientDet Lite 4 พบว่า EfficientDet Lite 0 นั้นเร็วกว่าถึง 3 และ 10 เท่าตามลำดับ เนื่องจาก EfficientDet Lite 0 มีจำนวนของชั้นและจำนวนพารามิเตอร์น้อยที่สุดในแบบจำลอง EfficientDet Lite ด้วยกัน ในขณะที่ความแม่นยำนั้นมีค่าใกล้เคียงกันมาก ดังนั้น EfficientDet Lite 0 จึงเหมาะสมมากที่สุด เพราะมีความเร็ว และความแม่นยำที่ค่อนข้างสูงเพียงพอ



|                   | Actual Values |      |      |      |      |      |      |      |      |      |      |      | Precision |
|-------------------|---------------|------|------|------|------|------|------|------|------|------|------|------|-----------|
|                   | Det 0         | PEL  | ALE  | GRJ  | BAO  | CAN  | NIC  | HOP  | PEA  | GRP  | WHI  | Not  |           |
| Predicted Values  | PEL           | 20   | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 1.00      |
|                   | ALE           | 0    | 18   | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 1    | 0.94      |
|                   | GRJ           | 0    | 2    | 19   | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0.90      |
|                   | BAO           | 0    | 0    | 1    | 20   | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0.95      |
|                   | CAN           | 0    | 0    | 0    | 0    | 20   | 0    | 0    | 0    | 0    | 0    | 0    | 1.00      |
|                   | NIC           | 0    | 0    | 0    | 0    | 0    | 20   | 0    | 2    | 0    | 0    | 1    | 0.86      |
|                   | HOP           | 0    | 0    | 0    | 0    | 0    | 0    | 20   | 0    | 0    | 0    | 1    | 0.95      |
|                   | PEA           | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 18   | 0    | 0    | 1    | 0.94      |
|                   | GRP           | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 17   | 2    | 0    | 0.89      |
|                   | WHI           | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 3    | 18   | 0    | 0    | 0.85      |
|                   | Not           | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 16   | 1.00      |
|                   | Recall        | 1.00 | 0.90 | 0.95 | 1.00 | 1.00 | 1.00 | 1.00 | 0.90 | 0.85 | 0.90 | 0.80 |           |
| Precision Average |               |      |      |      |      |      |      | 0.94 |      |      |      |      |           |
| Recall Average    |               |      |      |      |      |      |      | 0.94 |      |      |      |      |           |

รูปที่ 6. Confusion Matrix และค่าประสิทธิภาพจากการทดสอบแบบจำลอง EfficientDet Lite 0

ตารางที่ 3 ประสิทธิภาพของแบบจำลอง

| รุ่นของแบบจำลอง     | ความเร็วของแบบจำลอง  |              | ความแม่นยำของแบบจำลอง |        |          |          |
|---------------------|----------------------|--------------|-----------------------|--------|----------|----------|
|                     | Inferencce Time (ms) | FPS ของกล้อง | Precision             | Recall | Accuracy | F1-score |
| EfficientDet Lite 0 | 62.3                 | 23           | 0.94                  | 0.94   | 0.99     | 0.94     |
| EfficientDet Lite 2 | 153.7                | 23           | 0.94                  | 0.94   | 0.99     | 0.94     |
| EfficientDet Lite 4 | 574.3                | 23           | 0.95                  | 0.95   | 0.99     | 0.95     |

#### 4.3 การใช้งานแอปพลิเคชัน

เมื่อเปิดใช้งานแอปพลิเคชันครั้งแรกจะมีหน้าฝึกสอนการใช้งานให้ผู้ใช้ได้ศึกษา เพื่อเพิ่มความคล่องแคล่วในการใช้งาน และจากนั้นจะเข้าสู่หน้ารายชื่อนก ผู้ใช้จะสามารถดูสายพันธุ์นกทั้งหมดได้ ดังรูปที่ 7(ก) โดยจากหน้านี้ผู้ใช้สามารถแตะที่รูปของนกแต่ละสายพันธุ์ เพื่อดูรายละเอียดข้อมูลของนกได้ ดังแสดงในรูปที่ 7(ข)




(ก)



(ข)

รูปที่ 7. หน้าแอปพลิเคชัน (ก) หน้ารายชื่อนก และ (ข) หน้ารายละเอียดข้อมูลนก



รูปที่ 8. แถบนำทางของแอปพลิเคชัน

ทางด้านล่างของแอปพลิเคชันจะมีแถบนำทาง (Navigation Bar) ดังรูปที่ 8 เพื่อนำทางไปยังหน้าต่าง ๆ ปุ่มแรกไปยังหน้ารายชื่อนก (Home) ปุ่มที่ 2 นำทางไปยังหน้ากล้อง (Camera) และปุ่มที่ 3 นำทางไปยังหน้าเลือกรูปจากคลัง (Pick an Image)

หน้ากล้องเป็นหน้าที่ใช้สำหรับตรวจจับและตรวจสอบสายพันธุ์ของนก เมื่อผู้ใช้นำกล้องไปส่องนก หากแอปพลิเคชันเจอตัวนก ก็จะทำการตีกรอบและระบุชื่อสายพันธุ์ของนกที่เจอ ดังรูปที่ 9 เมื่อผู้ใช้งานสัมผัสหรือกดไปที่กรอบจะเข้าสู่หน้าข้อมูลของนกตัวนั้น



รูปที่ 9. หน้ากล้อง




รูปที่ 10. หน้าเลือกจากคลังรูปภาพ


หน้าเลือกจากคลังรูปภาพ เมื่อเข้าสู่หน้านี้ถ้าต้องการจะเลือกรูปภาพต้องกดปุ่มที่มุมล่างขวา เพื่อเลือกรูปจากคลังรูปภาพ เมื่อแอปพลิเคชันเจอนกในรูปภาพก็จะทำการติกรอบและระบุชื่อพันธุ์ของนกที่เจอ ดังรูปที่ 10 และผู้ใช้สามารถสัมผัสหรือคลิกไปที่กรอบเพื่อเข้าสู่หน้าข้อมูลของนกตัวนั้น

#### 4.4 ตัวอย่างผลลัพธ์จากการจับภาพ

ตัวอย่างผลลัพธ์การตรวจจับภาพนกผ่านหน้ากล้อง และเลือกรูปจากคลัง แสดงผลลัพธ์ดังรูปที่ 11




(ก)



(ข)



(ค)



(ง)

รูปที่ 11 ตัวอย่างผลลัพธ์การตรวจจับนกผ่านกล้อง

(ก) ผลลัพธ์ถูกต้องในกรณีมีนก 1 ตัว

(ข) ผลลัพธ์ถูกต้องในกรณีมีนกมากกว่า 1 ตัว

(ค) ผลลัพธ์ถูกต้องในการจับภาพที่ไม่ใช่ชนก

และ (ง) ผลลัพธ์ผิดพลาดตรวจจับแมวเป็นนก

#### 5. สรุปผลการทดลองและการอภิปราย

บทความนี้เสนอการออกแบบและพัฒนาโมบายแอปพลิเคชันสำหรับตรวจสอบและจำแนกสายพันธุ์นกด้วยวิธีการเรียนรู้เชิงลึก ผู้ใช้สามารถใช้งานแอปพลิเคชันเพื่อทำการตรวจจับและตรวจสอบสายพันธุ์ของนก และสามารถศึกษาข้อมูลของนกที่กำลังทำการตรวจสอบอยู่ได้ แอปพลิเคชันพัฒนาด้วยภาษา Dart บน Flutter Framework และใช้ไลบรารี TFLite Model Maker ในการสร้างแบบจำลอง EfficientDet Lite ในการค้นหาและจดจำรูปภาพนก และจากผลการทดลองจึงได้เลือกแบบจำลอง EfficientDet Lite 0 สำหรับนำไปใช้งานจริงกับแอปพลิเคชัน โดยแบบจำลองที่พัฒนาขึ้นสามารถจดจำสายพันธุ์ของนกได้ทั้งหมด 10 สายพันธุ์ และวัตถุที่ไม่ใช่ชนก ซึ่งรวมทั้งหมดเป็น 11 คลาส จากการสอนด้วยภาพคลาสละ 500 - 1000 ภาพ จำนวนทั้งหมด 78 รอบ แบบจำลองมีประสิทธิภาพด้านความแม่นยำ Precision, Recall, Accuracy และ F1-score เท่ากับ 0.94, 0.94, 0.99 และ 0.94 ตามลำดับ และจากการทดสอบบนโทรศัพท์มือถือจึงพบว่าเวลาในการแปรผลของแบบจำลอง

อยู่ที่ 62.30 ms และไม่ได้มีผลกระทบต่อจำนวนเฟรมของวิดีโอ โดยมีค่า FPS อยู่ที่ 23 FPS

## เอกสารอ้างอิง

- [1] J. Law, "Why we need birds (far more than they need us)", *BirdLife International*, 2021. [Online]. Available: <https://www.birdlife.org/news/2019/01/04/why-we-need-birds-far-more-than-they-need-us/>. [Accessed 15 November 2021].
- [2] P. Chatayapha. "Technology and early childhood in 21st century," *Journal of Graduate Studies Valaya Alongkorn Rajabhat University*, vol. 14, no. 3, 2020.
- [3] "Cross-platform mobile frameworks used by global developers 2021 | Statista", Statista, 2021. [Online]. Available: [https://www.statista.com/statistics/869224/worldwide-software-developer-workinghours/?fbclid=IwAR1QrmP\\_JDP\\_yMdGu\\_C56ami-xPuUniTqCv-D0W1Eyw8cGJNrVK-7ZmfAaU](https://www.statista.com/statistics/869224/worldwide-software-developer-workinghours/?fbclid=IwAR1QrmP_JDP_yMdGu_C56ami-xPuUniTqCv-D0W1Eyw8cGJNrVK-7ZmfAaU). [Accessed 15 November 2021].
- [4] S. B. Kotsiantis, I. Zaharakis, and P. Pintelas, "Supervised machine learning: A review of classification techniques," *Emerging Artificial Intelligence Applications in Computer Engineering*, vol. 160, no. 1, pp. 3-24, 2007.
- [5] M. Tabak, et al, "Machine learning to classify animal species in camera trap images: Applications in ecology," *Methods in Ecology and Evolution*, vol. 10, no. 4, pp. 585-590, 2018.
- [6] R. L. Galvez, A. A. Bandala, E. P. Dadios, R. R. P. Vicerra and J. M. Z. Maningo, "Object detection using convolutional neural networks," *TENCON 2018 - 2018 IEEE Region 10 Conference*, pp. 2023-2027, 2018.
- [7] "Flutter - Beautiful native apps in record Time", Flutter.dev, 2021. [Online]. Available: <https://flutter.dev/>. [Accessed 15 November 2021].
- [8] "TensorFlow", TensorFlow, 2015. [Online]. Available: <https://www.tensorflow.org/>. [Accessed 15 November 2021].
- [9] "TensorFlowLite", TensorFlow, 2018. [Online]. Available: <https://www.tensorflow.org/lite/guide>. [Accessed 15 November 2021].
- [10] S. Albawi, T. A. Mohammed and S. Al-Zawi, "Understanding of a convolutional neural network". In *2017 International Conference on Engineering and Technology (ICET)*, pp. 1-6, 2017.
- [11] M. Tan, R. Pang and Q. V. Le, "EfficientDet: scalable and efficient object detection", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1-10, 2020.
- [12] M. Tan and Q. V. Le, "EfficientNet: rethinking model scaling for convolutional neural networks", *International Conference on Machine Learning*, pp.1-11, 2019.
- [13] "TensorFlow Lite Model Maker", TensorFlow, 2020. [Online]. Available: [https://www.tensorflow.org/lite/guide/model\\_maker](https://www.tensorflow.org/lite/guide/model_maker). [Accessed 15 November 2021].
- [14] "Object Detection with TensorFlow Lite Model Maker", TensorFlow, 2020. [Online]. Available: [https://www.tensorflow.org/lite/tutorials/model\\_maker\\_object\\_detection](https://www.tensorflow.org/lite/tutorials/model_maker_object_detection). [Accessed 15 November 2021].
- [15] M. X. He and P. Hao, "Robust Automatic Recognition of Chinese License Plates in Natural Scenes," in *IEEE Access*, vol. 8, pp. 173804-173814, 2020.
- [16] "The Zoological Park Organization of Thailand", Zoothailand.org, 2021. [Online]. Available: [http://zoothailand.org/animal\\_more.php](http://zoothailand.org/animal_more.php). [Accessed 15 November 2021].

## อัลกอริทึมการเรียนรู้ของเครื่องสำหรับการทำนายการคัดแยกผู้ป่วย COVID-19

### Towards Machine Learning Algorithm for Screening Prediction of COVID-19 Patients

ศิวกอร์ บรรลือทรัพย์\* และ วราพร จิระพันธุ์ทอง

*Siwakorn Banluesapy\* and Waraporn Jirapanthong*

สาขาวิชาวิศวกรรมเว็บและการพัฒนาแอปพลิเคชันบนอุปกรณ์พกพา

วิทยาลัยครีเอทีฟดีไซน์แอนด์เอ็นเตอร์เทนเมนต์เทคโนโลยี มหาวิทยาลัยธุรกิจบัณฑิต

*Department of Web Engineering and Mobile Application Development*

*College of Creative Design and Entertainment Technology Dhurakij Pundit University*

Received: December 27, 2021; Revised: April 11, 2022; Accepted: June 07, 2022; Published: June 29, 2022

**ABSTRACT** – This research aims to develop a web-based application for screening COVID-19 patients by applying with machine learning techniques. We have applied the techniques to classify the data and then compare the algorithm's efficiency in prediction of COVID-19 patient screening. The data on 1,608,923 patients from the Department of Disease Control are accumulated. In particular, the data from January 1, 2020 to October 1, 2021 are learnt by three classification algorithms: Random Forest, Neural network, and Naive Bayes. The performance of predictive techniques between features are compared. The models learnt and generated based on different three algorithms are tested by the Split Test method. The data are randomly divided into two parts: Training Data (80%) and Test Data (20%) by using Orange Canvas. The models are then experimented to determine the performance test results with the highest accuracy. As the results, it is found that the accuracy rates of Random Forest, Neural Network, and Naive Bayes are 93.33%, 92.7%, and 92.1%, respectively. The model based on Random Forest technique with the highest value of accuracy is then applied in the application for screening COVID-19 patients.

**KEYWORDS:** Random forest, Neural network, Naive Bayes, Machine Learning, Covid-19

**บทคัดย่อ** -- งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบทำการคัดแยกผู้ป่วยโควิด-19 ในรูปแบบเว็บแอปพลิเคชันโดยใช้เทคนิคการเรียนรู้ของเครื่องในการจำแนกข้อมูลจากนั้นทำการเปรียบเทียบประสิทธิภาพของอัลกอริทึมในการทำนายการคัดแยกผู้ป่วยโควิด-19 และได้ทำการศึกษาข้อมูลผู้ป่วย จำนวน 1,608,923 ราย จากกรมควบคุมโรค ทำการรวบรวมข้อมูล 1 มกราคม 2563 ถึง วันที่ 1 ตุลาคม 2564 โดยใช้อัลกอริทึมการจำแนกข้อมูลทั้งหมด 3 แบบได้แก่ Random Forest, Neural network และ Naive Bayes ซึ่งทำการเปรียบเทียบประสิทธิภาพรูปแบบเทคนิคทำนายระหว่างคุณลักษณะ การทดสอบประสิทธิภาพตัวแบบทำนายด้วยวิธีการ Split Test คือ การแบ่งข้อมูลด้วยการสุ่มออกเป็น 2 ส่วนคือ Training Data (ร้อยละ 80) และ Test Data (ร้อยละ 20) โดยใช้โปรแกรม Orange Canvas จากนั้นทำการทดลองเพื่อหาผลการทดสอบประสิทธิภาพที่มีค่าความถูกต้องที่สูงที่สุด ผลการวิจัยพบว่า Random Forest มีค่าความถูกต้องเท่ากับ 93.33% Neural

\*Corresponding Author: siwakorn167@gmail.com

network มีค่าความถูกต้องเท่ากับ 92.7% Naive Bayes มีค่าความถูกต้องเท่ากับ 92.1% จากผลการเปรียบเทียบในครั้งนี้จึงนำ Random Forest ที่มีค่าสูงที่สุดไปใช้ในการพัฒนาโปรแกรมระบบในการคัดแยกผู้ป่วยโควิด-19 ได้

คำสำคัญ: ป่าลุ่ม , โครงข่ายประสาทเทียม , นาอ์เบย์ , การเรียนรู้ของเครื่อง , โควิด-19

## 1. บทนำ

โรคโควิด-19 เป็นโรคติดต่อสายพันธุ์ใหม่ และได้มีการคาดการณ์ว่าเป็นการติดเชื้อจากสัตว์สู่คนโดยมีค้างคาวเป็นพาหะเป็นโรคได้ทั้งคนและสัตว์ [1], [2] เชื้อสามารถติดต่อจากคนสู่คนผ่านทางเดินหายใจจากละอองของเสมหะจากการ ไอ จาม น้ำมูก น้ำลายในระยะประมาณ 1-2 เมตร [3]

สำหรับการระบาดของเชื้อไวรัสโควิด-19 รอบแรกในประเทศไทย พบผู้ป่วยต้องสงสัยรายแรกเมื่อวันที่ 21 มกราคม พ.ศ. 2563 เป็นนักท่องเที่ยวหญิงชาวจีนอายุ 74 ปี ซึ่งเดินทางมาถึงกรุงเทพมหานครโดยเที่ยวบินจากนครอู่ฮั่น เมืองหลวงของมณฑลหูเป่ย์ สาธารณรัฐประชาชนจีน และ ณ วันที่ 8 เมษายน พ.ศ. 2563 พบอัตราการติดเชื้อในประเทศไทย จำนวน 2,369 คน [4] หลังจากนั้นพบการระบาดระลอกใหม่ช่วงปลายปี 2563 เริ่มตั้งแต่วันที่ 17 ธันวาคม 2563 พบหญิงไทย อายุ 67 ปี อาชีพค้าขายที่ตลาดกลางกุ้ง ในตำบลมหาชัย อำเภอมหาชัย จังหวัดสมุทรสาคร [5]

กระบวนการตรวจ วินิจฉัยโรคโควิด 19 เป็นการตรวจทางห้องปฏิบัติการ ต้องเสียเวลาในการเตรียมเชื้อและกระบวนการตรวจ เพราะต้องตรวจกับตัวเชื้อจริง ในช่วงแรกของการระบาดต้องใช้เวลานานไม่น้อยกว่า 2 วัน และทำได้เฉพาะในโรงพยาบาลใหญ่หรือโรงพยาบาลศูนย์ ค่าตรวจมีราคาแพง เพราะผลที่ได้ต้องได้ผลชัดเจน และ ทางกระทรวงสาธารณสุขมีข้อจำกัดในเรื่องจำนวนการตรวจ จึงต้องคัดกรองผู้ต้องสงสัยก่อนเก็บเชื้อส่งตรวจ และใช้วิธีนี้ตั้งแต่เริ่มการระบาด คือ ต้องเก็บเชื้อจากสารคัดหลั่งที่โพรงจมูก ดังนั้นในกระบวนการควบคุมโรค การค้นหา การตรวจหาผู้ป่วย จำเป็นต้องมีกระบวนการคัดกรองเพื่อคัดกรองเป็นลำดับในการหาผู้สงสัยก่อน [6] ดังนั้นผู้วิจัยจึงทำการศึกษาและวิเคราะห์ข้อมูลผู้ติดเชื้อ โควิด-19 จากกรมควบคุมโรคตั้งแต่ระลอกที่ 1 – 3 ซึ่งเป็นข้อมูลแบบเปิด โดยทำการรวบรวมข้อมูลตั้งแต่วันที่ 1 มกราคม 2563 ถึง วันที่ 1 ตุลาคม 2564 เป็นจำนวน 1,608,923 ราย [7] เพื่อช่วยคัดแยกประเภทผู้ป่วยได้เร็วขึ้น

การเรียนรู้ของเครื่อง (Machine Learning) [8] คือ การที่สามารถทำให้คอมพิวเตอร์สามารถเรียนรู้ได้ด้วยตนเอง โดยการเขียนโปรแกรมหรือการสร้างอัลกอริทึมที่สามารถเรียนรู้และพยากรณ์ข้อมูลได้ ทั้งนี้อัลกอริทึมจะต้องอาศัยโมเดลที่ได้จากการสร้างชุดของข้อมูลเพื่อพยากรณ์หรือตัดสินใจ

งานวิจัยนี้จึงใช้เทคนิคการเรียนรู้ของเครื่องมาช่วยในดำเนินการ ซึ่งเป็นงานในลักษณะ Classification อยู่ในรูปแบบโมเดลประเภท Supervised ซึ่งมีตัวแปรที่ใช้ในการวัดเป้าหมายโดยการคัดแยกประเภทผู้ป่วย เพื่อคัดกรองผู้ต้องสงสัยได้เร็วขึ้น และได้เตรียมการรักษาได้ทันเวลา

## 2. งานวิจัยและทฤษฎีที่เกี่ยวข้อง

ระบบคัดแยกผู้ป่วยโควิด-19 ด้วยวิธีการนำการเรียนรู้ของเครื่องมาประยุกต์ใช้ในการทำงานวิจัยฉบับนี้ โดยใช้ข้อมูลจากกรมควบคุมโรค [7] ซึ่งรวบรวมตั้งแต่ 1 มกราคม 2563 ถึง วันที่ 1 ตุลาคม 2564 เป็นจำนวน 1,608,923 ราย จากเว็บไซต์ <https://covid19.ddc.moph.go.th/> หรือ DDC Open data

### 2.1 การประยุกต์ใช้การเรียนรู้ของเครื่องสำหรับโรคโควิด-19

ในช่วงเร่งด่วนวาระระดับโลกเมื่อเร็วๆ นี้ มีนักวิทยาศาสตร์ แพทย์ และผู้เชี่ยวชาญด้านการดูแลสุขภาพทั่วโลกยังคงค้นหาเทคโนโลยีใหม่ๆ เพื่อสนับสนุนการแก้ปัญหาการระบาดใหญ่ของโควิด-19 [9] การเรียนรู้ของเครื่อง (machine learning) ก็เป็นเทคโนโลยีที่เข้ามาช่วยในการแก้ปัญหาของโรคโควิด-19 เช่น จีนใช้การวิเคราะห์ข้อมูลขนาดใหญ่ (Big data analytics) เข้ามาควบคุมการแพร่ระบาดให้เกิดประสิทธิผลและเพื่อให้การดำเนินธุรกิจเป็นปกติมากที่สุด

ปัจจุบันมีการพัฒนาอย่างต่อเนื่องในเทคโนโลยีการเรียนรู้ของเครื่องและปัญญาประดิษฐ์ในงานการแพร่ระบาดของโรคโควิด-19 เพื่อวิเคราะห์การใช้ยา การคัดกรอง การคาดการณ์ การติดตามผู้สัมผัส ตลอดจนกระบวนการพัฒนาวัคซีนของโรคโควิด-19 อย่างมีนัยสำคัญ เพื่อลดการแทรกแซงของมนุษย์

ในการปฏิบัติการทางการแพทย์ แต่อย่างไรก็ตามโมเดลส่วนใหญ่ไม่ได้ถูกนำไปใช้งานมากพอที่จะสามารถแสดงการปฏิบัติงานในโลกแห่งความเป็นจริง แต่ก็ยังสามารถใช้รับมือการแพร่ระบาดของโรคโควิด-19 ได้ [10]

## 2.2 สถานการณ์ผู้ติดเชื้อ COVID-19 อพเททรายวัน

### รูปแบบ API (Json/CSV Data Format)

สถานการณ์ผู้ติดเชื้อ COVID-19 อพเททรายวัน รูปแบบ API (Json/CSV Data Format) เป็นข้อมูลแบบเปิดที่รวบรวมโดยกรมควบคุมโรคจากกระทรวงสาธารณสุข สามารถบอกรายละเอียดเป็นพจนานุกรมข้อมูล (Data dictionary) ได้ดังตารางที่ 1

ตารางที่ 1. พจนานุกรมข้อมูลข้อมูลผู้ป่วยโควิด-19

| Colum Name   | Data Type | Comment              |
|--------------|-----------|----------------------|
| txn_date     | date      | วันแถลง              |
| gender       | varchar   | เพศ                  |
| age_number   | varchar   | อายุ                 |
| age_range    | varchar   | ช่วงอายุ             |
| nationality  | varchar   | สัญชาติ              |
| job          | varchar   | อาชีพ                |
| risk         | varchar   | ปัจจัยเสี่ยง         |
| patient_type | text      | ประเภทผู้ป่วย        |
| province     | varchar   | จังหวัด              |
| update_date  | datetime  | วันที่ปรับปรุงข้อมูล |

ตารางที่ 2: Class ในการวิจัย [11], [12]

| ประเภทของผู้ป่วย |                                                                                                                                                      |
|------------------|------------------------------------------------------------------------------------------------------------------------------------------------------|
| Class            | Description                                                                                                                                          |
| 1                | การเฝ้าระวังในกลุ่มผู้ป่วยหรือผู้มีอาการเข้าได้กับนิยามผู้สงสัยติดเชื้อไวรัสโคโรนา 2019 ที่เข้าเกณฑ์สอบสวนโรค<br>(patient under investigation : PUI) |
| 2                | การตรวจคัดกรองในประชากรเสี่ยงตามจุดคัดกรองและด่านเข้าออกระหว่างประเทศ (screening)                                                                    |
| 3                | การเฝ้าระวังในกลุ่มเป้าหมายเฉพาะหรือพื้นที่เฉพาะ<br>(sentinel surveillance)                                                                          |
| 4                | การเฝ้าระวังเหตุการณ์ในสถานที่เสี่ยง เก็บตัวอย่างส่งตรวจเมื่อเข้านิยาม PUI หรือเป็นกลุ่มก้อนของผู้ป่วยทางเดินหายใจ                                   |

## 2.3 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นหนึ่งในประเภทของปัญญาประดิษฐ์ ที่จะช่วยให้แอปพลิเคชัน หรือซอฟต์แวร์เกิดการเรียนรู้จากชุดข้อมูลที่สามารถทำนายผลได้อย่างแม่นยำ โดยหลักการคือจะมีโมเดลทางคณิตศาสตร์และมีอัลกอริทึมในหลากหลายรูปแบบมาเรียนรู้จากชุดข้อมูล (Data set) จนทำให้คอมพิวเตอร์เกิดการเรียนรู้และฉลาดในการตัดสินใจบนข้อมูลที่ไม่เคยได้เห็นมาก่อนได้สำเร็จ

## 2.4 Random Forest

หลักการของ Random Forest คือการสร้าง model จาก Decision Tree หลายๆ model ย่อยๆ (ตั้งแต่ 10 model ถึง มากกว่า 1000 model) โดยแต่ละ model จะได้รับ data set ไม่เหมือนกัน ซึ่งเป็น subset ของ data set ทั้งหมด ตอนทำ prediction จะให้ Decision Tree ทำการ prediction ในแต่ละโหนด และคำนวณผล prediction ด้วยการ vote output ที่ ถูกเลือกโดย Decision Tree มากที่สุด [13]

## 2.5 Naive Bayes

เป็นอีกหนึ่งวิธีที่ได้รับความนิยมเนื่องจากการโมเดลง่ายและไม่ซับซ้อน โดยจะอาศัยทฤษฎีความน่าจะเป็น (probability) เป็นหลักซึ่งถูกใช้ในการทำนายผลจัดเป็นเทคนิคในการแก้ปัญหาแบบ Classification ที่สามารถคาดการณ์ผลลัพธ์ได้และสามารถอธิบายได้ โดยจะทำการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปร เพื่อใช้ในการสร้างเงื่อนไขความน่าจะเป็นสำหรับแต่ละความสัมพันธ์ [14]

## 2.6 Neural network

ลักษณะทั่วไปของโครงข่ายประสาทเทียม คือ โหนดจำลองมาจากรอยประสานประสาท (Synapse) ระหว่างใยประสาทนำเข้า (Dendrite) ของเซลล์ประสาทตัวหนึ่งและแกนประสาทนำออก (Axon) ของเซลล์ประสาทอีกตัวหนึ่ง โดยมีฟังก์ชันการแปลงเป็นตัวกำหนดสัญญาณส่งออก องค์ประกอบในการทำงานของระบบประสาทในสมองมนุษย์กับโครงข่ายประสาทเทียมมีความคล้ายคลึงกัน ในระบบประสาทของมนุษย์การรับกระแสประสาทจะอาศัยเดนไดรต์ (Dendrites) เป็นตัวนำพาเปรียบเทียบกับหน่วยข้อมูลป้อนเข้าในระบบโครงข่าย

ประสาทเทียม ส่วนการนำกระแสประสาทไปยังเซลล์ประสาทอื่นผ่านทางเอกซอน ที่เป็นตัวส่งออกกระแสประสาทเปรียบเทียบกับหน่วยผลลัพท์ในโครงข่ายประสาทเทียม [15]

## 2.7 ตัววัดประสิทธิภาพของโมเดลการจำแนกประเภทข้อมูล (Confusion matrix)

การทำงานของโมเดลไปใช้งานจริงนั้นจะเป็นจะต้องทราบประสิทธิภาพของโมเดลเสียก่อน โดยทั่วไปแล้วจะมีตัววัดที่นิยมใช้กันในงานวิจัยและการทำงานต่างๆ อยู่ 4 ค่า [16], [17] คือ

1. Precision เป็นการวัดความแม่นยำของโมเดล โดยพิจารณาแยกทีละ Class
2. Recall เป็นการวัดความถูกต้องของโมเดล โดยพิจารณาแยกทีละ Class
3. F-measure เป็นการวัดค่า Precision และ Recall พร้อมกันของโมเดลโดยพิจารณาแยกทีละ Class
4. Accuracy เป็นการวัดความถูกต้องของโมเดลโดยพิจารณา รวมทุก Class

แนวคิดเกี่ยวกับ Confusion matrix จากบทความ [14] ได้กล่าวไว้ว่า Confusion matrix คือตารางแบบจัตุรัสโดยมีจำนวนแถวเท่ากับจำนวน Class ดังตัวอย่างในตารางที่ 2 มี Class คำตอบอยู่ 2 คำตอบ คือ yes และ no

ตารางที่ 3. ตัวอย่างแสดงตาราง Confusion matrix

| Predicted / actual | Yes | No |
|--------------------|-----|----|
| Yes                | TP  | FP |
| No                 | FN  | TN |

จากตารางที่ 3 ค่าที่แสดงในช่องต่างๆ ประกอบไปด้วย

- True Positive (TP) คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็น Class ซึ่งกำลังสนใจอยู่
- True Negative (TN) คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็น Class ซึ่งไม่ได้สนใจอยู่
- False Positive (FP) คือ จำนวนข้อมูลที่ทำนายผิดมาเป็น Class ซึ่งกำลังสนใจอยู่
- False Negative (FN) คือ จำนวนข้อมูลที่ทำนายผิดมาเป็น Class ซึ่งกำลังสนใจอยู่

## 2.8 งานวิจัยที่เกี่ยวข้อง

Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks [18] ในงานวิจัยนี้ได้ทำการศึกษาจากผู้ป่วย 108 รายที่เป็นโรคปอดอักเสบจากโควิด-19 จากห้องปฏิบัติการ โดยเป็นชาย 60 คน หญิง 48 คน มีอายุเฉลี่ย  $61.45 \pm 15.04$  ทั้งนี้ชุดข้อมูลได้รวบรวมตั้งแต่ กันยายน 2563 - ธันวาคม 2563 จากโรงพยาบาลในมหาวิทยาลัยที่วิจัย โดยการใช้เทคนิค Deep learning ในการจำแนกคุณลักษณะจากภาพเอกซเรย์คอมพิวเตอร์ เพื่อหาความแตกต่างในการจำแนกผู้ป่วยที่เป็นโควิด-และไม่เป็นโควิด ซึ่งโมเดลที่ใช้จะเป็น ResNet-101 เป็น Deep Convolutional Neural Networks โดยค่า Accuracy อยู่ที่ 99.51% และ Specificity อยู่ที่ 99.0%

Automated detection of COVID-19 cases using deep neural networks with X-ray images [19] งานวิจัยนี้ได้ประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning) ในการทำงานแบบอัตโนมัติ ทั้งนี้ยังได้ใช้ Deep learning ซึ่งเป็นเทคนิคยอดนิยมของปัญญาประดิษฐ์ (AI) โดยชุดข้อมูลเป็นภาพเอกซเรย์ทรวงอก ภาพรังสีวิทยา เป็นชุดข้อมูลแบบเปิดจากเว็บไซต์ <https://github.com/ieee8023/COVID-chestxray-dataset> โดยจะทำการจำแนกระหว่างผู้ป่วยโควิด, โรคปอดอักเสบ และปอดปกติ จากภาพเอกซเรย์ทรวงอก เพื่อลดภาระงานของแพทย์ในการคัดกรองผู้ป่วยและช่วยประหยัดเวลามากขึ้น โดยค่า Accuracy อยู่ที่ 98.08% จากโมเดล neural network

Combination of four clinical indicators predicts the severe/critical symptom of patients infected COVID-19 [20, p. 19] ได้ทำการวิจัยและศึกษาจากตัวอย่างข้อมูลผู้ป่วยทั้งหมด 336 รายที่ติดเชื้อโควิด-19 ในเซี่ยงไฮ้ ประเทศจีน นอกจากนี้ยังรวบรวมการสังเกต / บันทึกทางคลินิกและทางห้องปฏิบัติการ 220 รายการ ตัวบ่งชี้ทางคลินิกสัมพันธ์กับอาการรุนแรง / อาการวิกฤต ได้มีการระบุ และได้มีการพัฒนาแบบจำลองสำหรับการทำนายอาการรุนแรง / วิกฤต โดยใช้ Support Vector Machine (SVM) โดยให้ค่า Accuracy อยู่ที่ 77.5% และ Specificity อยู่ที่ 78.4%

Covid-19 Classification Using Deep Learning in Chest X-Ray Images [21] ได้ทำการวิจัยข้อมูลผู้ป่วยโรคโควิด-19 จากชุดข้อมูลภาพเอกซเรย์ทรวงอก ภาพรังสีวิทยา เป็นชุดข้อมูลแบบเปิด โดยได้ใช้เทคนิค Deep learning ในรูปแบบโมเดล



ResNet-18 (Residual Network) ซึ่งเป็น Deep Convolutional Neural Networks ที่ทาง Microsoft เผยแพร่แก่ผู้สาธารณสุข ตั้งแต่ปี 2015 จากผลการทดลองโดยให้ค่า Accuracy 99.5%


COVID-19 Patient Health Prediction Using Boosted Random Forest Algorithm [22] งานวิจัยนี้ได้นำเสนอโมเดล Random Forest ที่ปรับแต่งอย่างละเอียด โดยใช้ข้อมูลทางภูมิศาสตร์ การเดินทาง สุขภาพ และข้อมูลประชากรของผู้ป่วยโควิด-19 เพื่อคาดการณ์ความรุนแรงของเคสและผลลัพธ์ที่เป็นไปได้ การฟื้นตัว หรือการเสียชีวิต โดยข้อมูลที่ใช้จะเป็นข้อมูลแบบเปิดชื่อ “Novel Corona Virus 2019 Dataset” จากเว็บไซต์ [www.kaggle.com](http://www.kaggle.com) โดยโมเดล Random Forest ได้ให้ค่า Accuracy อยู่ที่ 94%

Rapid and accurate identification of COVID-19 infection through machine learning based on clinical available blood test results [23] ได้ทำการวิจัยและศึกษาจากผลการตรวจเลือดเพื่อประเมินผู้ต้องสงสัยในการติดเชื้อโรคโควิด-19 ในการศึกษานี้ได้รวบรวมตัวอย่างทั้งหมด 253 ตัวอย่าง จากผู้ป่วยต้องสงสัย 169 รายจากในหลายๆ แห่ง รวมทั้งในโรงพยาบาลปอดหกลานใจที่ประเทศจีน โดยทำการตรวจเลือด 49 ราย โดยจะนำค่าจากผลตรวจเลือด 11 ค่ามาวิเคราะห์ผ่านโปรแกรม Covid-19 Assistant Discrimination 2.0 เพื่อทำนายโอกาสการติดโรคโควิด-19 จากการศึกษาได้ใช้โมเดล Random forest โดยให้ค่า Accuracy 95.95% และ Specificity อยู่ที่ 96.95%

อย่างไรก็ตาม งานวิจัยที่ได้กล่าวมาไม่ได้มีวัตถุประสงค์มุ่งเน้นการคัดกรองผู้ป่วยที่มีความเสี่ยงในการติดโรคโควิด-19 ภายใต้ระยะเวลาอันรวดเร็ว งานวิจัยชิ้นนี้จึงนำเสนอการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องเพื่อแยกประเภทของผู้ป่วยและผู้ป่วยในกลุ่มเสี่ยงของโรคโควิด-19 โดยผู้วิจัยได้ทำการสรุปงานวิจัยที่เกี่ยวข้องและแยกเป็น 2 หมวดหมู่ด้วยกันคือ 1. จำแนกผู้ป่วยโรคโควิด-19 จากภาพเอกซเรย์ทรวงอก 2. จำแนกผู้ป่วยโรคโควิด-19 จากชุดข้อมูลหลากหลายฟีเจอร์ (Feature) โดยทุกงานจะมีการใช้อัลกอริทึม (Algorithm) ที่แตกต่างกันออกไป เป็นงานวิจัยเพื่อวัตถุประสงค์ในการคัดแยก - จำแนกผู้ป่วย , ทำนายโอกาสการติดเชื้อโควิดหรือทำนายผู้ต้องสงสัยว่าติดเชื้อหรือไม่ ซึ่งงานวิจัยฉบับนี้ที่ผู้วิจัยได้ให้ความสำคัญกับหลังเหตุการณ์เมื่อพบผู้ติดเชื้อโควิด-19 ในการคัดแยกผู้ป่วยโควิด-19 เพื่อช่วยคัดแยกและกรองผู้ต้องสงสัยได้อย่างรวดเร็ว ซึ่งจะช่วยเหลือเวลาได้เร็วขึ้น [6]

### 3. วิธีดำเนินการวิจัย


แนวคิดหลักการวิจัยนี้คือการนำเทคนิคการเรียนรู้ของเครื่องมาประยุกต์ใช้ในการคัดแยกผู้ป่วยโควิด-19 โดยอัลกอริทึมที่ใช้ในการพัฒนาแบบจำลองจะประกอบไปด้วย 3 เทคนิคคือ Neural Network , Naive bayes และ Random Forest และหาค่าความถูกต้องหรือค่าความแม่นยำมากที่สุดจาก 3 เทคนิค



รูปที่ 1. กรอบแนวคิด

#### 3.1 Data Set (วิธีการรวบรวมข้อมูล)

ทำการรวบรวมข้อมูลจากศูนย์กลางข้อมูลภาครัฐ ซึ่งเป็นข้อมูลแบบเปิดจากกรมควบคุมโรค กระทรวงสาธารณสุข โดยจะเป็นข้อมูลผู้ป่วยโควิด-19 ระลอกที่ 1 ถึงระลอกที่ [7] ตั้งแต่ 1 มกราคม 2563 ถึง วันที่ 1 ตุลาคม 2564 เป็นจำนวน 1,608,923 ราย




รูปที่ 2. ขั้นตอนการพัฒนาส่วนการดาวน์โหลดข้อมูล

#### 3.2 Data Preparation (การเตรียมข้อมูล)

Formatting (การจัดรูปแบบข้อมูล) ขั้นตอนนี้เป็นขั้นตอนที่ทำการแปลงข้อมูลที่ได้ทำการเก็บรวบรวมมา ให้กลายเป็นข้อมูลที่สามารถนำไปวิเคราะห์ในขั้นถัดไปได้ ในการแปลงข้อมูลนี้อาจจะต้องมีการทำข้อมูลให้ถูกต้อง เช่นการแปลงข้อมูลให้อยู่ในช่วง (scale) เดียวกัน โดยจะทำการแปลงข้อมูลจากตัวอักษร (text) เป็น ตัวเลข (numeric) เช่น Attributes และ Values ทั้งหมด รวมทั้งจัดกลุ่ม Attributes ของชุดข้อมูล เช่น gender, age\_range, nationality, risk, patient\_type และ province


Data Cleaning (การทำความสะอาดข้อมูล) เนื่องจากคะแนนหรือข้อมูลบางส่วนไม่สามารถใช้ในการคำนวณได้ เพราะในการแบ่งข้อมูลถูกแบ่งออกเป็นสองส่วนคือข้อมูลที่มี

การซ้อนทับและข้อมูลที่ไม่มีการซ้อนทับนั้นมีการหาระยะห่างระหว่างข้อมูล และข้อมูลที่ใช้จะต้องเป็นข้อมูลที่ไม่มีการสูญหายหรือ Missing Value เพราะข้อมูลดังกล่าวจะไม่สามารถหาระยะห่างระหว่างข้อมูลได้




รูปที่ 3. การกำหนด Label และประเภทข้อมูล

การกำหนดประเภทข้อมูล age\_range , nationality , risk , province และ patient\_type ใน Edit Domain Widget ให้เป็นประเภท Categorical เนื่องจากเป็นข้อมูลที่มีการถูกจัดกลุ่ม จากนั้นจะทำการกำหนด Label ให้กับข้อมูลต่างๆ เพื่อการแสดงผลที่เหมาะสมในการวิเคราะห์ข้อมูลเช่น 1 = ACF , 2 = Cluster เป็นต้น ดังรูปที่ 3



รูปที่ 4. การเลือก Target , Features

ทำการเลือก age\_range , nationality , risk , province และ patient\_type ที่เป็นข้อมูลประเภท Categorical เท่านั้น โดยจะตัดส่วน txn\_date และ update\_date ออกจากการวิเคราะห์เนื่องจากเป็นตัวแปรต่อเนื่องไม่สามารถแยกจากกันได้ ดังรูปที่ 4




รูปที่ 5. การกำจัด Missing value

ทำการกำหนดเงื่อนไข (Condition) ในการคัดกรองข้อมูลที่เป็นค่าว่างหรือข้อมูลที่ไม่สามารถวิเคราะห์ได้ ดังรูปที่ 5

### 3.3 Modeling (การสร้างโมเดล)

กระบวนการนี้ผู้วิจัยได้ใช้โปรแกรม Orange Canvas ในการสร้างตัวแบบข้อมูลสำหรับการเรียนรู้และทดสอบเพื่อเปรียบเทียบโมเดลที่ดีที่สุด ก่อนจะนำโมเดลนั้นไปพัฒนาเว็บแอปพลิเคชันในการคัดแยกผู้ป่วยโควิด-19

จากการตั้งค่าพารามิเตอร์ที่ดีที่สุดสำหรับข้อมูลจากกรมควบคุมโรค กระทรวงสาธารณสุข โดยจะเป็นข้อมูลผู้ป่วยโควิด-19 ระลอกที่ 1 ถึงระลอกที่ 3 และทำงานร่วมกับโมเดลด้วยวิธีการรวมผลลัพธ์ที่ได้ค่าความถูกต้องมากที่สุด ซึ่งอยู่ในรูปแบบของเทคนิคโมเดล Random Forest , Neural network และ Naive Bayes โดยได้ใช้วิธี Split test ในการแบ่งข้อมูลสำหรับเป็นชุดการเรียนรู้ 80% และชุดทดสอบ 20% แล้วนำเข้าโปรแกรม Orange Canvas



รูปที่ 6. โมเดลการวิเคราะห์คัดแยกผู้ป่วยโควิด-19

รูปที่ 6 ขั้นตอนนี้จะทำการสร้างโมเดลด้วยวิธี Naive Bayes , Random Forest และ Neural network โดยแบ่งข้อมูลจำนวน 80% เป็นข้อมูลสำหรับสร้างโมเดลและข้อมูลจำนวน 20% ใช้เป็นข้อมูลสำหรับทดสอบโมเดล ในงานวิจัยนี้ได้สร้างโมเดลแยกตามประเภทผู้ป่วยโดย Class ของข้อมูลสามารถดูได้ตามตารางที่ 2

### 3.4 Evaluation (การวัดประสิทธิภาพโมเดล)

หลังจากที่แบ่งข้อมูลออกเป็น 2 ส่วนและใช้โมเดลที่สร้างได้จากข้อมูลจำนวน 80% มาทำการคัดแยกผู้ป่วยโควิด-19 กับข้อมูลผู้ป่วยที่อยู่ใน 20% ที่เหลือ และใช้วัดค่าความถูกต้องโดยใช้ Confusion matrix ตามหัวข้อที่ 2.7 เพื่อดูว่าเทคนิควิธี Naive Bayes , Random Forest และ Neural network เทคนิคที่สร้างโมเดลไหนให้ค่าผลทำนายดีมากที่สุดจึงจะนำโมเดลนั้นไปใช้งานต่อไป ค่าความแม่นยำในการจำแนกประเภทข้อมูลของ Positive นั้นสามารถคำนวณได้จากสมการที่ 1

$$\text{True Positive Rate (TPR)} = \frac{TP}{TP + FN} \quad (1)$$

ค่าความแม่นยำในการจำแนกประเภทข้อมูลของ Negative นั้นสามารถคำนวณได้จากสมการที่ 2

$$\text{True Negative Rate (TNR)} = \frac{TN}{FP + TN} \quad (2)$$

ค่า Precision เป็นการวัดความแม่นยำของโมเดล โดยพิจารณาแยกทีละ Class ดังสมการที่ 3

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

ค่า Recall เป็นการวัดความถูกต้องของโมเดล โดยพิจารณาแยกทีละ Class ดังสมการที่ 4

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

ค่า F-measure เป็นการวัดค่า Precision และ Recall พร้อมกันของโมเดลโดยพิจารณาแยกทีละ Class ดังสมการที่ 5


$$\text{F-measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

ค่า Accuray เป็นการวัดความถูกต้องของโมเดลโดยพิจารณา รวมทุก Class คือ จำนวน True Positive (TP) ของทุก Class รวมกัน ดังสมการที่ 6

$$\text{Accuray} = \frac{TP + TN}{TP + FN + FP + TN} \quad (6)$$

### 3.5 Deployment (การนำโมเดลไปใช้งาน)


จากโมเดลที่สร้างโดย Naive Bayes , Random Forest และ Neural network ที่สร้างขึ้นมานั้นสามารถนำไปทำการคัดแยกผู้ป่วยโควิด-19 หลังจากนั้นจะต้องพัฒนา Prediction API ของโมเดลที่สร้างขึ้นมาเพื่อเป็นเว็บเซอร์วิส ในการรองรับการส่งข้อมูลจากเว็บแอปพลิเคชันในการคัดแยกผู้ป่วยโควิด-19 ดังรูปที่ 7



รูปที่ 7. Prediction API ในการคัดแยกผู้ป่วยโควิด-19

## 4. ผลการวิเคราะห์ข้อมูล

งานวิจัยนี้มีข้อมูลจำนวน 1,608,923 เรคคอร์ด หลังจากผ่านกระบวนการ Data Preparation แล้วข้อมูลจะอยู่ที่จำนวน 913,152 เรคคอร์ด ประกอบด้วย คุณลักษณะดังนี้ 1) คำนำนักคุณลักษณะของข้อมูลจำนวน 5 คุณลักษณะ คือ gender , age\_rang, nationality , province , risk และ 2) คลาส (class) ที่ใช้ในการวิจัยประกอบไปด้วย 4 คลาส มีจำนวนข้อมูลในแต่ละคลาสดังนี้ คลาสที่ 1 มีจำนวน 587,079 เรคคอร์ด คลาสที่ 2 มีจำนวน 2,755 เรคคอร์ด คลาสที่ 3 มีจำนวน 52,548 เรคคอร์ด และคลาสที่ 4 มีจำนวน 270,770 ดังตารางที่ 4



รูปที่ 8. การใช้โปรแกรม Orange Canvas เพื่อเปรียบเทียบ โมเดลการเรียนรู้ของเครื่อง

ตารางที่ 4. อัตราส่วนของข้อมูลในแต่ละ Class

| Class | จำนวน   | อัตราส่วน |
|-------|---------|-----------|
| 1     | 587,049 | 64.29%    |
| 2     | 2,755   | 0.30%     |
| 3     | 52,547  | 5.75%     |
| 4     | 270,770 | 29.65%    |

ตารางที่ 5. Information Gain ของฟีเจอร์ในการวิจัย

| ตัวแปรที่ | Feature     | Information Gain |
|-----------|-------------|------------------|
| 1         | gender      | 0.003            |
| 2         | age_rang    | 0.001            |
| 3         | nationality | 0.019            |
| 4         | province    | 0.213            |
| 5         | risk        | 0.816            |

จากตารางที่ 5 พบว่าการคัดเลือกฟีเจอร์ทั้งหมด โดยใช้เทคนิค คำนวณค่าน้ำหนักของฟีเจอร์ต่างๆ โดยฟีเจอร์ที่มีค่าน้ำหนักมากที่สุดคือ risk ค่าน้ำหนักที่ 0.816 และ ฟีเจอร์ที่มีค่าน้ำหนักน้อยที่สุดคือ gender ค่าน้ำหนักที่ 0.003

#### 4.1 ผลการจำแนกข้อมูลด้วย Random Forest

ตารางที่ 6. ตัววัดประสิทธิภาพของอัลกอริทึม Random Forest

| Performance Classification (Random Forest) |         |         |         |         |           |
|--------------------------------------------|---------|---------|---------|---------|-----------|
|                                            | true(1) | true(2) | true(3) | true(4) | Precision |
| pred.(1)                                   | 459329  | 19      | 5254    | 5230    | 97.76%    |
| pred.(2)                                   | 6       | 2176    | 7       | 27      | 98.19%    |
| pred.(3)                                   | 4091    | 16      | 28188   | 9725    | 67.08%    |
| pred.(4)                                   | 20976   | 29      | 3524    | 191925  | 88.66%    |
| Recall                                     | 94.82%  | 97.14%  | 76.23%  | 92.75%  |           |

จากตารางที่ 6 พบว่า Class 1 True Positive เท่ากับ 459,329 ค่า False Positive เท่ากับ 10,053 ค่า คิดเป็น Precision เท่ากับ 97.76% และ Recall เท่ากับ 94.82% Class 2 True Positive เท่ากับ 2,176 ค่า False Positive เท่ากับ 40 ค่า คิดเป็น Precision เท่ากับ 98.19% และ Recall เท่ากับ 94.14% Class 3 True Positive เท่ากับ 28,188 ค่า False Positive เท่ากับ 13,832 ค่า คิดเป็น Precision เท่ากับ 67.08% และ Recall เท่ากับ 76.23% Class 4 True Positive เท่ากับ 191,925 ค่า False Positive เท่ากับ 24,529 ค่า คิดเป็น Precision เท่ากับ 88.66 % และ Recall เท่ากับ 92.75% สรุปเป็นค่า Accuracy ได้ 93.33%

#### 4.2 ผลการจำแนกข้อมูลด้วย Neural Network

ตารางที่ 7. ตัววัดประสิทธิภาพของอัลกอริทึม Neural Network

| Performance Classification (Neural Network) |         |         |         |         |           |
|---------------------------------------------|---------|---------|---------|---------|-----------|
|                                             | true(1) | true(2) | true(3) | true(4) | Precision |
| pred.(1)                                    | 455433  | 19      | 4544    | 9836    | 96.93%    |
| pred.(2)                                    | 12      | 2198    | 0       | 6       | 99.18%    |
| pred.(3)                                    | 3408    | 14      | 24653   | 13945   | 58.66%    |
| pred.(4)                                    | 19387   | 39      | 1932    | 195096  | 90.13%    |
| Recall                                      | 95.23%  | 96.82%  | 79.19%  | 89.13%  |           |

จากตารางที่ 7 พบว่า Class 1 True Positive เท่ากับ 455,433 ค่า False Positive เท่ากับ 14,399 ค่า คิดเป็น Precision เท่ากับ 96.93% และ Recall เท่ากับ 95.23% Class 2 True Positive เท่ากับ 2,198 ค่า False Positive เท่ากับ 18 ค่า คิดเป็น Precision เท่ากับ 99.18% และ Recall เท่ากับ 96.82% Class 3 True Positive เท่ากับ 24,653 ค่า False Positive เท่ากับ 17,367 ค่า คิดเป็น Precision เท่ากับ 58.66% และ Recall เท่ากับ 79.19% Class 4 True Positive เท่ากับ 195,096 ค่า False Positive เท่ากับ 21,449 ค่า คิดเป็น Precision เท่ากับ 90.13% และ Recall เท่ากับ 89.13% สรุปเป็นค่า Accuracy ได้ 92.7%

#### 4.3 ผลการจำแนกข้อมูลด้วย Naive Bayes

ตารางที่ 8. ตัววัดประสิทธิภาพของอัลกอริทึม Naive Bayes

| Performance Classification (Naive Bayes) |         |         |         |         |           |
|------------------------------------------|---------|---------|---------|---------|-----------|
|                                          | true(1) | true(2) | true(3) | true(4) | Precision |
| pred.(1)                                 | 455784  | 14      | 7203    | 6831    | 97%       |
| pred.(2)                                 | 28      | 2113    | 3       | 72      | 95.35%    |
| pred.(3)                                 | 4147    | 7       | 24724   | 13142   | 58.83%    |
| pred.(4)                                 | 21009   | 36      | 5060    | 190349  | 87.93%    |
| Recall                                   | 94.76%  | 97.14%  | 66.83%  | 90.47%  |           |


จากตารางที่ 8 พบว่า Class 1 True Positive เท่ากับ 455,784 ค่า False Positive เท่ากับ 14,048 ค่า คิดเป็น Precision เท่ากับ 97% และ Recall เท่ากับ 94.76% Class 2 True Positive เท่ากับ 2,113 ค่า False Positive เท่ากับ 103 ค่า คิดเป็น Precision เท่ากับ

95.35% และ Recall เท่ากับ 97.14% Class 3 True Positive เท่ากับ 24,724 ค่า False Positive เท่ากับ 17,296 ค่า คิดเป็น Precision เท่ากับ 58.83% และ Recall เท่ากับ 66.83% Class 4 True Positive เท่ากับ 190,349 ค่า False Positive เท่ากับ 26,105 ค่า คิดเป็น Precision เท่ากับ 87.93% และ Recall เท่ากับ 90.47% สรุปเป็นค่า Accuracy ได้ 92.1%

#### 4.4 สรุปผลการเปรียบเทียบค่าความแม่นยำในแต่ละเทคนิค

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อทดลองสร้างโมเดลการทำนายโดยใช้ข้อมูลผู้ป่วยโควิด-19 จากกรมควบคุมโรค ร่วมกับเทคนิคการเรียนรู้ของเครื่องได้แก่ Random Forest , Neural network และ Naive Bayes เพื่อใช้ในการคัดแยกผู้ป่วยโควิด-19 ในการเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนาย โดย Random Forest มีค่า Accuracy 93.33% ส่วน Neural Network มีค่า Accuracy 92.7% และ Naive Bayes มีค่า Accuracy ที่ 92.1%

ผู้วิจัยจึงใช้เทคนิค Random Forest เนื่องจากให้ค่าความถูกต้องและแม่นยำมากที่สุดมาสร้างโมเดลในการทำนายเพื่อคัดแยกผู้ป่วยโควิด-19 ต่อไป ดังรูปที่ 9




รูปที่ 9. การเปรียบเทียบความแม่นยำในแต่ละอัลกอริทึม

#### 4.5 สรุปผลการทำงานของ Random Forest


โมเดล Random Forest Classification ให้ผลการทำนายที่มีความแม่นยำมากที่สุดถึง 93.33 % แต่ก็ขึ้นอยู่กับข้อมูลความเสี่ยงและจังหวัดในการวัดผลด้วย เนื่องจากในแต่ละจังหวัดยังมีความเสี่ยงที่ใกล้เคียงกัน โดยเฉพาะจังหวัดกรุงเทพมหานครและ




ปริมาณผล แต่ในต่างจังหวัดก็จะมีความเสี่ยงที่แตกต่างกัน  
ออกไป ซึ่งจะเห็นได้ว่าการใช้งาน Random Forest  
Classification สามารถใช้งานได้หลากหลายรูปแบบ




รูปที่ 10. Decision Tree ที่ 1




รูปที่ 11. Decision Tree ที่ 2



รูปที่ 12. Decision Tree ที่ 3




รูปที่ 13. Decision Tree ที่ 4



รูปที่ 14. Decision Tree ที่ 5

#### 4.6 การนำโมเดลไปใช้งาน (Deployment)

จากรูปที่ 8 เมื่อได้ผลจากการหาประสิทธิภาพของเทคนิคทั้ง 3  
เทคนิคแล้ว นั่นคือได้ Random Forest จึงมีกระบวนการบันทึก  
โมเดลโดยจะได้ไฟล์ Model.pkcls เพื่อนำไปใช้งาน ดังรูปที่ 15



รูปที่ 15. ขั้นตอนการบันทึกโมเดล

รูปที่ 16. การนำโมเดลไปใช้งานผ่าน GUI

เมื่อมีชุดข้อมูลใหม่สามารถใช้เครื่องมือ Load Model Widget  
ในโปรแกรม Orange Canvas ในการทำนายผลได้ทันทีดังรูปที่

```
1 import pickle
2 # ทำการ Load โมเดลที่เก็บไว้
3 model = pickle.load(open("Model.pkcls", "rb"))
4 # ข้อมูลผู้ป่วยใหม่
5 newdata = [[1, 8, 1, 9, 10]]
6 # ทำนายการคัดแยกผู้ป่วย
7 predict = model.predict(newdata)
8 print(model)
```

รูปที่ 17. การนำโมเดลไปใช้งานด้วย Python

รูปที่ 17 ด้วยผลการทดสอบทั้งหมดจะได้โมเดลด้วยไฟล์ Model.pkcls สำหรับการนำไปพัฒนาระบบคัดแยกผู้ป่วยโควิด 19 ด้วยภาษา Python ต่อไป

#### 4.7 ระบบคัดแยกผู้ป่วยโควิด-19

กระบวนการพัฒนาระบบได้ใช้ FastAPI Framework ด้วยภาษา Python เพื่อสร้าง Web Service API ในการทำนายข้อมูลโดยได้นำโมเดลที่ได้ไป Deployment เข้ากับระบบ และใช้ฐานข้อมูล Postgresql จากนั้นทำการพัฒนาเว็บแอปพลิเคชันในการคัดแยกผู้ป่วยโควิด-19 ดังรูปที่ 18-23

แบบฟอร์มวิเคราะห์ข้อมูลผู้ป่วย

วันที่เริ่มป่วย: 04/01/2022, เพศ: ชาย, อายุ: 28

สัญชาติ: ไทย, ความเสี่ยง: พื้นที่เสี่ยง

จังหวัด: กรุงเทพมหานคร

ทำนายผล


รูปที่ 18. หน้าจอทำนายการคัดแยกผู้ป่วยโควิด-19




รูปที่ 19. ผลการทำนายในการคัดแยก



รูปที่ 20. กราฟแสดงยอดผู้ป่วยในแต่ละเดือน




รูปที่ 21. อัตราส่วนเพศต่อประเภทผู้ป่วย



รูปที่ 22. อัตราส่วนช่วงอายุต่อประเภทผู้ป่วย





รูปที่ 23. จำนวนผู้ป่วยในแต่ละจังหวัด

## 5. บทสรุปและการอภิปราย

การเปรียบเทียบประสิทธิภาพของอัลกอริทึมและการคัดเลือกคุณลักษณะที่เหมาะสมเพื่อการทำนายในการคัดแยกผู้ป่วยโควิด-19 โดยในการดำเนินงานเริ่มต้นได้ทำการศึกษาอัลกอริทึมต่างๆ ของการเรียนรู้ของเครื่อง การรวมรวมข้อมูล วิธีในการ Training Data รูปแบบ Test Data ซึ่งการวิเคราะห์สังเคราะห์จากข้อมูล และเอกสารกำหนดขอบเขต ทำการออกแบบแผนการทดลองโดยใช้โปรแกรม Orange Canvas ในการสร้างโมเดลตามเทคนิคต่างๆ ในการทดลอง และประมวลผลผลลัพธ์ ทำให้ระยะเวลาในการทดลองมีความเร็ว และมีประสิทธิภาพมากยิ่งขึ้น หลังจากรวบรวมข้อมูลและผ่านการค้นคว้าและปรับคุณลักษณะของข้อมูลแล้วก็นำข้อมูลไปทดลองในการทำนายการคัดแยกผู้ป่วยโควิด-19 ได้ทั้ง 3 เทคนิค Naive Bayes , Random Forest และ Neural network ซึ่งทำการเปรียบเทียบเพื่อให้ได้วิธีการที่ได้ค่าความแม่นยำและถูกต้องมากที่สุด จากนั้นหาตัวแบบเทคนิคในการทำนายที่ให้ค่าความถูกต้องมากที่สุดที่เหมาะสมกับการนำไปใช้ในการทำนายการคัดแยกผู้ป่วยโควิด-19 ผลการทดลองในการวิจัยพบว่า Random Forest ให้ค่าความถูกต้องสูงที่สุดที่ร้อยละ 93.30% Neural network ให้ค่าความถูกต้องสูงที่สุดที่ร้อยละ 92.7% และ Naive Bayes ให้ค่าความถูกต้องสูงที่สุดที่ร้อยละ 92.1% ตามลำดับ สามารถบอกได้ว่าผู้ป่วยโควิด-19 มีโอกาสถูกจัดให้อยู่ประเภทใด และสามารถนำไปเขียนโปรแกรมเพื่อพัฒนาระบบให้มีการคัดแยกผู้ป่วยโควิด-19 ได้อย่างถูกต้องมากยิ่งขึ้น และลดข้อผิดพลาดของข้อมูลให้น้อยลง

การทำนายด้วย 3 เทคนิคที่เลือกใช้ในงานวิจัยนี้ นอกจากจะสามารถทำการ Classification ได้ดีแล้ว และยังสามารถทำได้ Regression ได้ดีเช่นกัน

## 6. ข้อเสนอแนะ

ข้อมูลที่ผู้วิจัยรวบรวมจากกรมควบคุมโรคนั้นพบว่าข้อมูลในแต่ละคุณลักษณะยังมีส่วนที่ขาดและไม่ครบข้างในบางราย คือคุณลักษณะ อาชีพของผู้ป่วย ซึ่งเป็นข้อมูลที่ขาดไปมากคิดเป็นร้อยละ 1.72% จากข้อมูลที่รวบรวมได้ทั้งหมด จึงไม่สามารถนำไปวิเคราะห์ได้ อีกทั้งข้อมูลประเทศยังมีการรวบรวมในลักษณะซ้ำซ้อน การใช้คำที่มีความหมายเหมือนกัน แต่ข้อความต่างกันเล็กน้อย จึงทำให้ข้อมูลไม่เป็นระเบียบ ในการวิจัยครั้งต่อไปควรเพิ่มคุณลักษณะของข้อมูลและทดลองอัลกอริทึมอื่นๆ เพิ่มเติม

## เอกสารอ้างอิง

- [1] S. Manmana, S. Iamsirithaworn, and S. Uttayamakul, "Coronavirus Disease-19 (Covid-19)," Journal of Bamrasnaradura Infectious Diseases Institute," vol. 14(2), pp. 124–33, Mar. 2020.
- [2] T. Saowapa, P. Supistra, and R. Ranistha, "Nursing care for patients with COVID-19 in the isolation unit, Siriraj Hospital." Jul. 2020. [Online]. Available: <https://dx.doi.org/10.33192/Simedbull.2020.29>
- [3] T.-N. Rachada, "COVID-19: An Invisible War Against Coronavirus," THAI FOOD AND DRUG JOURNAL, vol. 27(2), May 2020.
- [4] K. Natanwan, "Knowledge, Attitudes, and Preventive Behaviors of COVID-19 among People Living in Amphoe U- thong, Suphanburi Province," Journal of

- Prachomklao College of Nursing, Phetchaburi Province, vol. 4 No.1, Apr. 2021.
- [5] K. L. Trepanning and J. Nammong, “Factors Associated with Preventive Behaviors towards the Coronavirus 2019 (COVID-19) of Employees in a Large Factory Krathumbean District, Samutsakorn Province,” Journal of Nursing, Siam University, 2021.
- [6] Kasetsart university, “Covid-19 and epidemiology,” COVID-19 Course, Jul. 2020. <https://learningcovid.ku.ac.th/course/?c=3&l=1>
- [7] Department of disease control, “DDC OPENDATA Covid19 Thailand,” DDC OPENDATA Covid19 Thailand, 2021. <https://covid19.ddc.moph.go.th/> (accessed Oct. 22, 2021).
- [8] A. Puitrakul, “What is machine learning,” What is machine learning, Jan, 2018. <https://arnondora.in.th/what-is-machine-learning/>
- [9] E. Digest, “Artificial intelligence (AI) -- a catalyst for China’s post-COVID economy,” Kasikorn research center, Jun, 2020. <https://www.kasikornresearch.com/th/analysis/k-social-media/Pages/AI-China-FB300620.aspx> (accessed Oct. 25, 2021).
- [10] S. Lalmuanawma, J. Hussain, and L. Chhakchhuak, “Applications of machine learning and artificial intelligence for Covid-19 (SARS-CoV-2) pandemic: A review,” Chaos, Solitons & Fractals, vol. 139, p. 110059, Oct. 2020, doi: 10.1016/j.chaos.2020.110059.
- [11] Department of disease control, “Coronavirus Disease 2019: COVID-19.” Dec. 2563. [Online]. Available: [https://ddc.moph.go.th/viralpneumonia/file/g\\_srrt/g\\_srrt\\_241263.pdf](https://ddc.moph.go.th/viralpneumonia/file/g_srrt/g_srrt_241263.pdf)
- [12] Department of disease control, “Guideline for disease control in quarantine facilities.” Containment Measures Mission Group (QUARANTINE) Emergency Operations Center ,Department of disease control, Jul. 2020. [Online]. Available: [https://ddc.moph.go.th/viralpneumonia/file/g\\_quarantine/g\\_quarantine\\_state210763n.pdf](https://ddc.moph.go.th/viralpneumonia/file/g_quarantine/g_quarantine_state210763n.pdf)
- [13] C. Patcharachaoenwong, H. Kankawee, and K. Warangkhan, “Arrival Time Prediction Model to a Pier for Public Transportation Boats,” Journal of Science Ladkrabang, vol. 29(2), 2020, [Online]. Available: [https://li01.tci-thaijo.org/index.php/science\\_kmitl/article/download/241105/169801/](https://li01.tci-thaijo.org/index.php/science_kmitl/article/download/241105/169801/)
- [14] E. Pacharawongsakda, An introduction to Data Mining Techniques, vol. 2. 2014.
- [15] A. Thongjit, P. Suksawang, and M. Jatupat, “Development of Data Classification using a Hybrid Method of Adaptive Artificial Neural Networks and Particle Swarm Optimization for Identifying Patients at Risk of Diabetes,” Research Methodology & Cognitive Science, vol. 17(2), Dec. 2019, [Online]. Available: <https://so05.tci-thaijo.org/index.php/RMCS/article/download/243179/165072/>
- [16] P. Duangklang and R. Kruakaew, “Models for automatic aircraft type prediction,” NKRAFA Journal of Science and Technology, 2019.

- [17] “Confusion Matrix - an overview | ScienceDirect Topics.”  
<https://www.sciencedirect.com/topics/engineering/confusion-matrix> (accessed Jun. 08, 2022).
- [18] A. A. Ardakani, A. R. Kanafi, U. R. Acharya, N. Khadem, and A. Mohammadi, “Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks,” *Computers in Biology and Medicine*, vol. 121, p. 103795, Jun. 2020, doi: 10.1016/j.combiomed.2020.103795.
- [19] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, “Automated detection of COVID-19 cases using deep neural networks with X-ray images,” *Computers in Biology and Medicine*, vol. 121, p. 103792, Jun. 2020, doi: 10.1016/j.combiomed.2020.103792.
- [20] L. Sun et al., “Combination of four clinical indicators predicts the severe/critical symptom of patients infected COVID-19,” *Journal of Clinical Virology*, vol. 128, p. 104431, Jul. 2020, doi: 10.1016/j.jcv.2020.104431.
- [21] Z. Karhan and F. Akal, “Covid-19 Classification Using Deep Learning in Chest X-Ray Images,” in *2020 Medical Technologies Congress (TIPTEKNO)*, Antalya, Turkey, Nov. 2020, pp. 1–4. doi: 10.1109/TIPTEKNO50054.2020.9299315.
- [22] C. Iwendi et al., “COVID-19 Patient Health Prediction Using Boosted Random Forest Algorithm,” *Frontiers in Public Health*, vol. 8, p. 357, 2020, doi: 10.3389/fpubh.2020.00357.
- [23] J. Wu et al., “Rapid and accurate identification of COVID-19 infection through machine learning based on clinical available blood test results,” Apr. 2020. doi: 10.1101/2020.04.02.20051136.

## ระบบวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ

### Fruits Ripening Analysis System using Image Processing Technology

เอกรัตน์ สุขสุคนธ์\*, ชลธิศ สันติวงษ์งาม, วัชรพล คำแขก และ ศศิชา ปานสุวรรณ

Aekkarat Suksukont\*, Chonlathis Santingamwong, Watcharaphon Khamkhaek and Sasicha Pansuwan

สาขาเทคโนโลยีคอมพิวเตอร์และนวัตกรรม คณะวิทยาศาสตร์และเทคโนโลยี

วิทยาลัยเซาธ์อีสท์บางกอก

Program in Computer Technology and Innovation, Faculty of Science and Technology,

Southeast Bangkok College

Received: January 21, 2022; Revised: May 06, 2022; Accepted: May 31, 2022; Published: June 29, 2022

**ABSTRACT** – This research presents the fruits ripening analysis system using image processing technology is objective to check the ripeness of the fruit in real time and facilitate farmers. To reduce fruit spoilage problems that may occur. In this research using NI Vision Builder was conjunction with a webcam and image processing technology to assist in analysis. The experiment was found that fruits ripening analysis system using image processing technology able to count the number of fruits accuracy 100% and be able to analyze the ripeness of the fruits accuracy 95%. Allowing farmers and users answer the satisfaction questionnaire about system performance results were in the criteria of very satisfied with the most satisfied, respectively.

**KEYWORDS:** Fruit ripening analysis, Image processing, Fruit, Color model

**บทคัดย่อ** -- งานวิจัยนี้นำเสนอระบบการวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ โดยมีวัตถุประสงค์เพื่อตรวจสอบการสุกของผลไม้ตามระยะเวลาจริงได้และช่วยอำนวยความสะดวกให้แก่เกษตรกร เพื่อลดปัญหาการเน่าเสียของผลไม้ที่อาจจะเกิดขึ้นได้ ในงานวิจัยนี้ใช้ซอฟต์แวร์ NI Vision Builder ทำงานร่วมกับกล้องเว็บแคม และใช้เทคโนโลยีการประมวลผลภาพเข้ามาช่วยในการวิเคราะห์และประมวลผล จากการทดลองพบว่า ระบบการวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพสามารถนับจำนวนของผลไม้มีความถูกต้อง คิดเป็น 100% และสามารถวิเคราะห์การสุกของผลไม้ คิดเป็น 95% โดยให้เกษตรกรและผู้ใช้งานตอบแบบสอบถามความพึงพอใจเกี่ยวกับประสิทธิภาพของระบบอยู่ในเกณฑ์ที่พึงพอใจมากถึงพึงพอใจมากที่สุด ตามลำดับ

**คำสำคัญ:** การวิเคราะห์การสุกของผลไม้, การประมวลผลภาพ, ผลไม้, แบบจำลองสี

\*Corresponding Author: [ekk\\_ele@hotmail.com](mailto:ekk_ele@hotmail.com)

## 1. บทนำ

อุตสาหกรรมการเกษตรทางด้านพืชผักผลไม้ เป็นอุตสาหกรรมที่มีบทบาทสำคัญต่อเศรษฐกิจของประเทศไทย อันเนื่องมาจากความต้องการอาหารของประชากรสูงขึ้นอย่างต่อเนื่อง และในปัจจุบันการผลิตส่งออกพืชผักผลไม้เป็นที่แพร่หลายเป็นอย่างมาก โดยทุกวันนี้การสุกของผลไม้ที่สุกตามธรรมชาติไม่เพียงพอต่อความต้องการของตลาด เนื่องจากเวลาในการสุกของผลไม้ที่สุกตามธรรมชาติใช้เวลานาน และหากนำไปป้อนโดยไม่เวลานานเกินไปก็จะทำให้ผลผลิตที่ออกมาไม่ตรงต่อความต้องการ จึงคิดสร้างสิ่งประดิษฐ์ขึ้นเพื่อความสะดวกในการเก็บเกี่ยวผลไม้ที่สุกแล้ว เพราะการจ้างงานโดยใช้มนุษย์ อาจจะมีค่าใช้จ่ายมากกว่าการนำเครื่องจักรมาทำงาน อีกทั้งเครื่องจักรยังมีความแม่นยำ ทำงานได้ระยะเวลาที่นานกว่าถึง 2-3 เท่า สามารถรับคำสั่งได้ตลอดเวลา ในกรณีที่มีการเปลี่ยนแปลงคำสั่งบ่อย ๆ โดยไม่ต้องคำนึงถึงภาวะทางอารมณ์

จากงานวิจัยของ [1] ได้นำเสนอเกี่ยวกับการพัฒนาเครื่องต้นแบบคัดแยกดอกดาวเรืองโดยการประมวลผลภาพเป็นงานวิจัยที่ได้จากการพัฒนาต่อจากโปรแกรมวิเคราะห์ขนาดของดอกดาวเรืองด้วยวิธีการประมวลผลภาพ โดยการใช้กราฟพื้นฐาน (Shape) ของดอกดาวเรืองและวิธีการจัดกลุ่มด้วยการวัดระยะห่างของข้อมูล (Euclidean Distance) ซึ่งสามารถวิเคราะห์ขนาดของดอกดาวเรืองได้ 4 ขนาด ระบบสายพานคัดแยกดอกดาวเรืองขึ้นโดยประกอบด้วยชุดสายพาน 2 ชุด ได้แก่ ชุดสายพานวางและบีบดอกดาวเรือง และชุดสายพานคัดแยกดอกดาวเรือง โดยควบคุมการทำงานของอุปกรณ์ด้วยบอร์ดราสเบอร์รี่พายรุ่น 3 (Raspberry Pi 3 Model B) และรับส่งข้อมูลระยะไกลหรือโมดูลบลูทูธ (Bluetooth Module) งานวิจัยของ [2] ได้นำเสนอเกี่ยวกับเครื่องคัดแยกขนาดมะนาว โดยมีจุดมุ่งหมายเพื่อสร้างเครื่องคัดแยกขนาดมะนาว เพื่อใช้ในอุตสาหกรรมขนาดเล็ก ช่วยลดต้นทุนและประหยัดเวลาในการคัดแยกขนาดมะนาว จากการทดสอบผลปรากฏว่าเครื่องคัดแยกขนาดมะนาวสามารถทำงานได้อย่างต่อเนื่องสามารถคัดแยกมะนาวได้จริง งานวิจัยของ [3] ได้นำเสนอ ระบบวิเคราะห์และนับจำนวนผลมะนาวอ่อนและผลมะนาวแก่โดยใช้เทคนิคประมวลผลภาพสำหรับนำไปใช้ทดสอบประสิทธิภาพการทำงานของระบบวิเคราะห์สีและนับผลของมะนาวเพื่อช่วยอำนวยความสะดวกให้แก่เกษตรกร โดยเริ่มจากออกแบบระบบและเทรนระบบด้วย

ภาพของผลมะนาวอ่อนและผลมะนาวแก่ จำนวน 574 ภาพ จากการทดลองพบว่า ระบบสามารถวิเคราะห์และนับผลมะนาวอ่อนมีความแม่นยำ 92% มีความผิดพลาด 8% และสามารถวิเคราะห์และนับผลมะนาวแก่มีความแม่นยำ 98% มีความผิดพลาด 2% งานวิจัยที่ [4] ได้นำเสนอ เครื่องคัดแยกสีอัตโนมัติบนระบบสายพานลำเลียงควบคุมด้วยอาคูโน เป็นงานวิจัยที่ได้ออกแบบตัวเครื่องที่สามารถปฏิบัติงานให้แยกชนิดวัตถุที่เป็นสีแดง สีเขียว สีน้ำเงินและสีอื่นๆ และเคลื่อนย้ายวัตถุไปยังถาดที่กำหนดไว้อัตโนมัติโดยอาศัยการควบคุมของอาคูโน จากผลการวิจัย พบว่า สามารถคัดแยกวัตถุสีแดง สีเขียว สีน้ำเงิน และสีอื่นๆ โดยเวลาเฉลี่ยของวัตถุที่ทดสอบปรากฏว่าวัตถุสีแดง 9.96 วินาที วัตถุสีเขียว 13.47 วินาที วัตถุสีน้ำเงิน 16.58 วินาที และวัตถุอื่น ๆ 9.04 วินาที และสามารถหมุนถาดเพื่อรับวัตถุในตำแหน่งที่ต้องการได้ถูกต้อง งานวิจัยที่ [5], [6] ได้นำเสนอ เกี่ยวกับการคัดแยกสีของวัตถุต่างชนิดกัน โดยใช้เทคนิคการสกัดคุณลักษณะเด่นของสีมาใช้เป็นส่วนสำคัญในการระบุชนิดของวัตถุนั้น ๆ ในงานวิจัยที่ [7] และ [8] งานวิจัยเหล่านี้ได้นำเสนอหลักการประมวลผลภาพมาใช้ในการแยกแยะชนิดของผลไม้ชนิดต่าง ๆ เพื่อให้ระบบสามารถระบุชนิดของผลไม้ไม่ว่าจะเป็นชนิดเดียวกันหรือต่างชนิดกัน

งานวิจัยนี้นำเสนอระบบการวิเคราะห์การสุกของผลไม้ โดยใช้หลักการประมวลผลภาพที่สามารถแยกสีของผลไม้สุกเพื่อจำกักระดับการสุกที่ต้องการได้ โดยกำหนดให้สีของผลไม้เพื่อใช้ในการบอกระดับการสุกของผลไม้ได้ตามต้องการที่มีประสิทธิภาพและเพื่อช่วยเหลือเกษตรกรให้มีความสะดวกสบายในการทำเกษตรกรรมได้มากยิ่งขึ้น


## 2. ทฤษฎี

### 2.1 การประมวลผลภาพ (Image Processing)

การประมวลผลภาพ คือ กระบวนการจัดการและวิเคราะห์รูปภาพให้เป็นข้อมูลในแบบดิจิทัล โดยใช้ระบบของคอมพิวเตอร์เพื่อให้ได้ข้อมูลที่เรากำลังต้องการทั้งในเชิงคุณภาพและปริมาณ (ขนาด รูปร่าง และสี) หลังจากนั้นเราสามารถนำข้อมูลไปวิเคราะห์ และสร้างเป็นระบบต่าง ๆ เช่น ระบบดูแลการจราจรบนท้องถนน ระบบตรวจสอบคุณภาพของผลิตภัณฑ์ในกระบวนการผลิต ระบบเก็บข้อมูลที่รถที่เข้าและออกอาคาร ระบบตรวจจับใบหน้า เป็นต้น

## 2.2 แบบจำลองสี (Color Model)

แบบจำลองสี เป็นสิ่งที่ใช้อ้างอิงถึงระดับสีต่างๆ สำหรับคอมพิวเตอร์แล้วเราจะไม่ใช้แบบจำลองที่เป็น Analytical Model เหมือนกับระบบที่ใช้ในทางวิทยาศาสตร์ ซึ่งใช้วิธีการวัดระดับที่อยู่ในรูปของพลังงานช่วงของสเปกตรัม (Spectrum) จากการทดลองที่เป็นการศึกษาแบบ Psychophysical ที่มีการรับรู้ของมนุษย์เข้ามาเกี่ยวข้องกับแบบจำลองสีมีหลายแบบด้วยกัน เช่น แบบจำลองสี RGB แบบจำลองสี HSV และแบบจำลองสี YCbCr เป็นต้น ดังรูปที่ 1 เป็นการตั้งค่าการกำหนดค่าสี RGB เพื่อใช้ในการวิเคราะห์ผล




รูปที่ 1. ตัวอย่างการตั้งสีแบบ RGB

## 3. การดำเนินการทดลอง

### 3.1 การออกแบบ


ในการสร้างระบบจำเป็นต้องมีการศึกษาค้นคว้ารวบรวมข้อมูล และรายละเอียดเกี่ยวกับการใช้งานซอฟต์แวร์ NI Vision Builder 2018 และอุปกรณ์ต่าง ๆ ที่เกี่ยวกับการวิจัย ในการศึกษาหลักการทำงานของซอฟต์แวร์ได้นำมาประยุกต์ใช้และออกแบบการทำงานภายในตู้บ่มผลไม้ โดยเริ่มจากกล้องวิดีโอรับภาพผลไม้เข้ามาในระบบ จากนั้นระบบจะนำค่าสีที่เก็บไว้มาวิเคราะห์และประมวลผล เมื่อได้ค่าที่ตั้งไว้หน้าต่างของโปรแกรมจะแสดงค่าที่วิเคราะห์ได้ออกมา โดยการทำงานของระบบวิเคราะห์การสุกของผลไม้ ดังรูปที่ 2



รูปที่ 2. แผนผังการทำงานของระบบวิเคราะห์การสุกของผลไม้


### 3.2 เครื่องมือที่ใช้ในการทดสอบ

1) เลือกใช้งานซอฟต์แวร์ Vision Builder จาก NI โดยสร้างโปรแกรม Machine Vision ด้วยการเขียนโปรแกรมในรูปแบบ Flow Chart และ Block Diagram ทำให้ผู้ใช้สามารถเรียนรู้ได้อย่างรวดเร็ว พร้อมกับฟังก์ชันเครื่องมือครบครันรองรับทุกการใช้งานในระบบ Vision System ดังรูปที่ 3




รูปที่ 3. หน้าต่างโปรแกรม NI Vision Builder AI

2) สร้างคำสั่ง Acquire Image (Gig E or USB) จะเป็นการกำหนดลักษณะของอุปกรณ์ในการรับภาพ (Input) เข้ามาในระบบเพื่อจะเก็บค่าต่าง ๆ ตามที่กำหนด โดยที่จะรับภาพได้ตามประสิทธิภาพของอุปกรณ์รับภาพ ดังรูปที่ 4




รูปที่ 4. หน้าต่างของ Acquire Image

3) ออกแบบคำสั่ง Detect Objects เป็นชุดคำสั่งที่ทำงานต่อจากคำสั่ง Acquire Image เมื่อรับค่าภาพมาแล้วจึงมากำหนดค่าต่าง ๆ ใน คำสั่ง Detect Objects Setup และคำสั่ง Detect Objects Setup เพื่อทำการกำหนดค่า Threshold จะใช้ในการกำหนดค่าสีที่จะเก็บค่าเพื่อมาประมวลผลโดยสามารถเลือกได้ว่าจะเก็บค่าสีเป็นระบบสีต่าง ๆ ดังรูปที่ 5




รูปที่ 5. หน้าต่าง Detect Objects Setup กำหนดค่า Threshold

4) Detect Objects Setup : Settings จะเป็นการกำหนดค่าพื้นที่เพื่อมาใช้คำนวณ โดยสามารถระบุว่าจะให้รับค่ากี่ต่อเมื่อค่าของวัตถุตรงตามที่เรารวบรวมไว้ ดังรูปที่ 6 และรูปที่ 7




รูปที่ 6. การตั้งค่า Detect Objects Setup



รูปที่ 7. หน้าต่างแสดงผลการสุกของผลไม้

5) ระบบสามารถกำหนดค่าการสุกของผลไม้ได้หลายชนิด โดยทำการกำหนดค่าในส่วนของ Detect Objects Setup และทำการตั้งค่าสี RGB ของผลไม้แต่ละชนิดได้ ดังรูปที่ 8



รูปที่ 8. หน้าต่างสำหรับเลือกชนิดของผลไม้



#### 4. ผลการศึกษา

การทดสอบการทำงานของระบบวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ โดยใช้ตัวอย่างผลไม้ 4 ชนิด คือ แอปเปิ้ลเขียว (Green Apple) แอปเปิ้ลแดง (Red Apple) กกล้วย (Banana) และมะม่วง (Mango) โดยใช้จำนวนผลไม้ชนิดละ 10 ผล ซึ่งได้ผลการทดลอง ดังตารางที่ 1

ตารางที่ 1. ผลการทดลองนับจำนวนผลไม้ 4 ชนิด

| ชนิดผลไม้            | จำนวน (ผล) | จำนวนที่นับ (ผล) | ความถูกต้อง |
|----------------------|------------|------------------|-------------|
| แอปเปิ้ลเขียว        | 10         | 10               | 100%        |
| แอปเปิ้ลแดง          | 10         | 10               | 100%        |
| กล้วย                | 10         | 10               | 100%        |
| มะม่วง               | 10         | 10               | 100%        |
| ค่าเฉลี่ยความถูกต้อง |            |                  | 100%        |

จากตารางที่ 1 เมื่อนำผลไม้ทั้ง 4 ชนิด เข้าทดสอบกระบวนการนับ ผลปรากฏว่า ระบบสามารถนับจำนวนผลไม้ได้ถูกต้องแม่นยำ คิดเป็น 100% โดยที่ไม่มีค่าความผิดพลาดเกิดขึ้นแต่อย่างใด

ตารางที่ 2. ผลการทดลองวิเคราะห์การสุกของผลไม้ 4 ชนิด

| ชนิดผลไม้            | ผลไม้สุก (ผล) | จำนวนที่นับ (ผล) | ความถูกต้อง |
|----------------------|---------------|------------------|-------------|
| แอปเปิ้ลเขียว        | 10            | 10               | 100%        |
| แอปเปิ้ลแดง          | 10            | 10               | 100%        |
| กล้วย                | 10            | 9                | 90%         |
| มะม่วง               | 10            | 9                | 90%         |
| ค่าเฉลี่ยความถูกต้อง |               |                  | 95%         |

จากตารางที่ 2 เมื่อนำผลไม้ทั้ง 4 ชนิด เข้าทดสอบกระบวนการวิเคราะห์การสุกของผลไม้ ผลปรากฏว่า จำนวนการสุกของผลไม้แอปเปิ้ลเขียวและแอปเปิ้ลแดง สามารถวิเคราะห์การสุกได้ถูกต้อง คิดเป็น 100% แต่เมื่อนำมาวิเคราะห์ผลของกล้วยและมะม่วง ผลปรากฏว่าสามารถวิเคราะห์การสุกได้ถูกต้อง คิดเป็น 90% เนื่องจาก ค่าความผิดพลาดในการวิเคราะห์เกิดขึ้นจากค่าสีในการกำหนดค่า RGB ในการตั้งค่า Detect

Objects Setup มีค่าสีที่ใกล้เคียงกัน จนทำให้ระบบไม่สามารถตัดสินใจได้ว่าผลไม้ชนิดนี้มีการสุกมากหรือมีการสุกน้อยเพียงใด

ตารางที่ 3 แบบสอบถามความพึงพอใจของผู้ทดลองใช้ระบบ

| แบบสอบถามความพึงพอใจของผู้ใช้ระบบ    | X    | S.D. | แปลผล            |
|--------------------------------------|------|------|------------------|
| 1. ประสิทธิภาพของระบบ                | 4.80 | 0.95 | พึงพอใจมากที่สุด |
| 2. ความสะดวกของผู้ใช้งาน             | 4.60 | 0.82 | พึงพอใจมากที่สุด |
| 3. ความแม่นยำในการวิเคราะห์ผล        | 4.20 | 0.64 | พึงพอใจมาก       |
| 4. การนำไปใช้ประโยชน์ในชีวิตประจำวัน | 4.20 | 0.64 | พึงพอใจมาก       |
| 5. ความเสถียรของซอฟต์แวร์            | 4.50 | 0.78 | พึงพอใจมาก       |

จากตารางที่ 3 การนำเสนอประสิทธิภาพของระบบวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ ได้สร้างแบบสอบถามโดยใช้หลักการของลิเคิร์ท 5 ระดับ จากการทำแบบสอบถามของผู้เข้าร่วมประเมิน คือ กลุ่มของประชากรที่เป็นเกษตรกรและผู้ประกอบการอาชีพค้าขาย จำนวน 10 ท่าน โดยผู้ตอบแบบสอบถามประเมินประสิทธิภาพของระบบในด้านต่างๆ อยู่ในเกณฑ์ที่พึงพอใจมากถึงพึงพอใจมากที่สุด

#### 5. สรุปและการอภิปราย

ระบบวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ สามารถนับจำนวนของผลไม้ได้มีความถูกต้อง คิดเป็น 100% และสามารถวิเคราะห์การสุกของผลไม้ได้เฉลี่ยคิดเป็น 95% โดยค่าความผิดพลาดในการวิเคราะห์เกิดขึ้นจากค่าสีในการกำหนดค่า RGB ในการตั้งค่า Detect Objects Setup มีค่าสีที่ใกล้เคียงกัน จนทำให้ระบบไม่สามารถตัดสินใจได้ว่าผลไม้ชนิดนี้มีการสุกมากเท่าใด หรืออาจเกิดจากความคมชัดของกล้องและค่าความสว่างภายในตู้เก็บผลไม้

ระบบระบบวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ สามารถนำไปประยุกต์ใช้งานให้สามารถวิเคราะห์จำนวนของผลไม้ให้มากขึ้น โดยการต่อเพิ่มจำนวน

ของกล้องวิดีโอเข้าไปได้อีก หรือนำเทคนิคเกี่ยวกับเทคโนโลยี  
ปัญญาประดิษฐ์ที่ช่วยในการวิเคราะห์และตัดสินใจภาพของ  
ผลไม้ชนิดต่าง ๆ เพื่อความแม่นยำและถูกต้องได้มากยิ่งขึ้น

## เอกสารอ้างอิง

- [1] Tanut Bh. and Kamsuwan N., “A Prototype Development of Marigold Classification by Image Processing,” Journal of Science and Technology Nakhon Sawan Rajabhat University, vol. 11, no. 13, pp. 79-92, 2019.
- [2] Kajornlap W. and Janpho J., “Lemon Size Sorting Machine,” Thesis in Production Techniques, 2015.
- [3] Suksukont A., Chunlahanak J., Buain Ch. and Suwannasin K., “Soft / Mature Lemons Counting and Analysis System with Image Processing Techniques,” The 11<sup>th</sup> Benjamitra Network National and International Conference, May 27, pp. 86-93. 2021.
- [4] Priwthaisong K., “Automatic Color Sorting Machine on Conveyor Systems Controlled by Arduino,” Association of Private Higher Education Institutions of Thailand, vol. 5 no. 1, pp. 15-21, 2016.
- [5] Jing L., Junzheng W. and Jiali M., “Color moving object Detection Method Based on Automatic Color Clustering,” Proceedings of the 33<sup>rd</sup> Chinese Control Conference, July 28-30, pp. 7232-7235, 2014.
- [6] Gokul P.R., Raj S. and Suriyamoorthi P., “Estimation of Volume and Maturity of Sweet Lime Fruit using Image Processing Algorithm,” International Conference on Communications and Signal Processing (ICCSP). April 2-4, pp. 1227-1229, 2015.
- [7] Pandey C., Sethy P.K., Biswas P., Behera S.K. and Khan M.R., “Quality Evaluation of Pomegranate Fruit using Image Processing Techniques”, International Conference on Communication and Signal Processing (ICCSP). July 28-30, pp. 38-40, 2020.
- [8] Sotirov S.I., Zhelyazkov S.P., Marudova M.G., Zsivanovits G., and Tokamkov D.M., “Embedded System for Fruit Image Processing,” International Scientific Conference Electronics, September 16-18, pp. 1-3, , 2020.

## แนวทางการออกแบบคู่สีสื่ออารมณ์ที่เป็นมิตรต่อผู้สูงอายุ Emotional Color Pairing Design Approach Friendly for the Elderly

ฐิติพร เลิศรัตนเดชากุล\*, คณาภาณูญ์ รักไพฑูรย์ และ เกษม ทิพย์ธาราจันทร์

Thitiporn Lertrusdachakul\*, Kanakarn Ruxpaitoon, and Kasem Thiptarajan

คณะเทคโนโลยีสารสนเทศ สถาบันเทคโนโลยีไทย-ญี่ปุ่น

Faculty of Information Technology, Thai-Nichi Institute of Technology

Received: February 10, 2022; Revised: May 14, 2022; Accepted: May 31, 2022; Published: June 29, 2022

**ABSTRACT** – The population of elderly people in Thailand and the world has increased continuously. Collaboration in taking care of the elderly from various aspects will support their safety, happiness and quality of life. One of the problems that accompany physical deterioration and interfere with the elderly's daily life is the difficulty in discerning. Color selection plays an important role in helping for better vision of object seeing, reducing accidents and also helping to communicate information with the elderly effectively. This research further develops colors that are associated with emotion from the “Color Image Scale” to test the paired color vision of the elderly. The results are analyzed with color data, such as contrast ratio, color difference and brightness difference. The explored color combination pairs are grouped by color tone and sorted by lightness, chroma and contrast ratio. The investigation recommends the color pairs that should be avoided and those that are friendly to the elderly. The research consequently presents a design approach of emotional color pairs that are friendly to the elderly for ease in digital media design and various applications.

**KEYWORDS:** Color combination pair, Elderly, Emotional color, Color design, Contrast ratio

**บทคัดย่อ** -- ประชากรผู้สูงอายุไทยและโลกเพิ่มขึ้นอย่างต่อเนื่อง ความร่วมมือกันในการดูแลผู้สูงอายุจากหลากหลายมิติ จะช่วยให้ผู้สูงอายุสามารถดำรงชีวิตได้อย่างมีคุณภาพ มีความสุขและปลอดภัย หนึ่งในปัญหาที่มาพร้อมกับความเสื่อมทางกายภาพและกระบวนการดำเนินชีวิตประจำวันของผู้สูงอายุคือการมองเห็นแยกแยะที่ยากขึ้น ซึ่งการเลือกใช้สีมีส่วนสำคัญในการช่วยทำให้มองเห็นวัตถุได้ดียิ่งขึ้น ลดอุบัติเหตุ และยังช่วยในการสื่อสารข้อมูลกับผู้สูงอายุได้อย่างมีประสิทธิภาพ งานวิจัยนี้ได้พัฒนาต่อยอดการนำสีที่เชื่อมโยงกับอารมณ์ความรู้สึกจาก Color Image Scale มาทดสอบการมองเห็นคู่สีโดยผู้สูงอายุ และนำมาวิเคราะห์ร่วมกับข้อมูลสี ได้แก่ อัตราส่วนความคมชัด (Contrast Ratio), ความแตกต่างของสี (Color Difference), ความแตกต่างของความสว่าง (Brightness Difference) และจัดกลุ่มตามโทนสี เรียงลำดับสีตามความสว่าง ความเข้มสี และอัตราส่วนความคมชัด รวบรวมเป็นคู่สีที่ควรหลีกเลี่ยงและคู่สีที่เป็นมิตรต่อผู้สูงอายุ นำเสนอแนวทางการออกแบบคู่สีสื่ออารมณ์ที่เป็นมิตรต่อผู้สูงอายุ เพื่อง่ายต่อการออกแบบสื่อดิจิทัลและการนำไปประยุกต์ใช้งานด้านต่าง ๆ

**คำสำคัญ:** คู่สี ผู้สูงอายุ สีสื่ออารมณ์ การออกแบบสี อัตราส่วนความคมชัด

\*Corresponding Author: thitiporn@tni.ac.th

## 1. บทนำ

ปัจจุบันโลกก้าวสู่ศตวรรษแห่งผู้สูงอายุ กล่าวคือ มีประชากรอายุ 60 ปีขึ้นไป มากกว่าร้อยละ 10 ของประชากรโลก และประเทศไทยได้เข้าสู่สังคมผู้สูงอายุโดยสมบูรณ์ (Complete Aged Society) ในปี พ.ศ. 2564 ซึ่งมีอัตราส่วนของประชากรผู้สูงอายุเท่ากับหรือมากกว่าร้อยละ 20 [1]-[2] จากการเปลี่ยนแปลงของโครงสร้างประชากรที่มีจำนวนผู้สูงอายุเพิ่มมากขึ้นนี้ การเตรียมความพร้อมเพื่อรองรับสถานการณ์ดังกล่าวจึงเป็นประเด็นที่หลายภาคส่วนให้ความสำคัญและบูรณาการการทำงานร่วมกัน ภาวะเสื่อมถอยตามธรรมชาติของร่างกายทำให้ผู้สูงอายุประสบปัญหาสุขภาพด้านต่าง ๆ และหนึ่งในสิ่งที่ส่งผลกระทบต่อการดำรงชีวิตประจำวันของผู้สูงอายุคือ ปัญหาด้านการมองเห็น ซึ่งพบว่าผู้สูงอายุมากกว่าร้อยละ 50 ป่วยเป็นโรคต้อกระจก (Cataract) [3]-[4] ต้อกระจกเป็นโรคที่เกิดจากเลนส์แก้วตาขุ่น ทำให้แสงผ่านเข้าไปในตาได้น้อยลง จึงทำให้ความสามารถในการมองเห็นลดลง มองเห็นภาพไม่ชัดเจน และอาจเป็นสาเหตุหรือปัจจัยที่ส่งผลให้เกิดโรคตาอื่น ๆ ผู้ป่วยต้อกระจกในระยะเริ่มต้น หากเป็นไม่มากยังไม่จำเป็นต้องผ่าตัด และอาจใช้เวลาเป็นเดือนหรือเป็นปีกว่าอาการของต้อกระจกจะรุนแรงมากขึ้นจนกระทบต่อการมองเห็นและส่งผลกระทบต่อการใช้ชีวิตประจำวัน แพทย์จึงแนะนำให้เข้ารับการผ่าตัด ดังนั้นผู้สูงอายุที่เป็นต้อกระจกจะมีช่วงระยะเวลาก่อนเข้ารับการรักษา ซึ่งอาจยาวนานจากการค่อยเป็นค่อยไปของโรค หรือการรอคิวรับการรักษา หรือความไม่พร้อมของผู้ดูแลและงบประมาณ โดยช่วงเวลาดังกล่าว ผู้สูงอายุจะมีความสามารถในการมองเห็น ความอึดอัดหรือความสับสนของสิ่งแวดล้อมและมองเห็นภาพพรางมัวเนื่องจากแสงสว่างที่ผ่านเข้าสู่ดวงตาน้อยลง ความบกพร่องทางการมองเห็นส่งผลกระทบต่อร่างกายและจิตใจตามระดับความรุนแรงของความเสื่อม ส่งเสริมปัจจัยการเกิดอุบัติเหตุจากสภาพแวดล้อม เช่น การหกล้มเพราะสิ่งกีดขวางทางเดินหรือพื้นต่างระดับ การขึ้นลงบันได การมองเห็นของพื้นและราวบันได เป็นต้น ในปัจจุบันการออกแบบผลิตภัณฑ์และการปรับปรุงสภาพแวดล้อมสำหรับผู้สูงอายุเพื่อส่งเสริมคุณภาพชีวิต จึงเข้ามามีบทบาทสำคัญต่อสังคมผู้สูงอายุเพื่อสร้างสวัสดิภาพและการให้บริการที่มีประสิทธิภาพสามารถตอบสนองการใช้งานของผู้ใช้งานสูงอายุ โดยงานวิจัยนี้มุ่งเน้นศึกษาการมองเห็นคู่สีที่เป็นมิตรต่อผู้สูงอายุ เพื่อการเลือกใช้งานคู่สีสำหรับการออกแบบสื่อดิจิทัล หรือนำมาประยุกต์ใช้กับ

อารยสถาปัตย์ (Universal Design) ซึ่งเป็นการออกแบบเพื่อคนทั้งมวล โดยทดสอบการมองเห็นคู่สีที่เชื่อมโยงกับอารมณ์ความรู้สึกจาก Color Image Scale ร่วมกับการใช้หลักการวิเคราะห์อัตราส่วนความคมชัด ความแตกต่างของสี ความแตกต่างของความสว่าง ความสว่างของสี ความเข้มสี และโทนสี นำเสนอเป็นแนวทางการออกแบบคู่สีสื่ออารมณ์ที่เป็นมิตรต่อผู้สูงอายุ

ในประเทศญี่ปุ่นได้มีการศึกษาเกี่ยวกับสีที่เป็นมิตรต่อผู้สูงอายุมาอย่างยาวนาน โดยที่จังหวัด Nagano ได้ศึกษาจำลองและวิเคราะห์การมองเห็นสีของผู้สูงอายุผ่านตัวกรองแสงแผ่นอะคริลิก (Acrylic) สีต่าง ๆ เพื่อทำการจำลองสภาวะเลนส์แก้วตาขุ่น [6] จากผลการวิจัยพบว่าโทนสีร้อนสามารถรับรู้ได้ง่าย ในขณะที่โทนสีเย็นรับรู้ได้ยากภายใต้สภาวะจำลองการเปลี่ยนแปลงทางสายตาของผู้สูงอายุ โดยโทนสีที่มีความสดต่ำหรือมีความอึดอัดของสีต่ำจะมองเห็นยาก และหากสีมีความสว่างสูงอาจทำให้มองเห็นก่อนไปทางสีขาว แต่หากสีมีความสว่างต่ำก็อาจมองเห็นก่อนไปทางสีดำได้ เมื่อนำผลที่ได้ไปปรับปรุงสีของป้ายแสดงข้อความและสัญลักษณ์ต่าง ๆ ราวบันได เครื่องเรือน พื้น รูปแบบการแบ่งพื้นที่ใช้สอย โดยให้ความสำคัญกับการสร้างความแตกต่างความสว่างของสี ก็จะช่วยให้การรับรู้และการสื่อสารข้อมูลกับผู้สูงอายุดียิ่งขึ้น นอกจากนี้ที่จังหวัด Aichi ได้จัดทำคู่มือการออกแบบการแสดงผลข้อมูลสำหรับการมองเห็น เพื่อการใช้งานของคนทุกกลุ่มในสังคม [7] ซึ่งได้รวบรวมแนวทางการสื่อสารข้อมูลทางการมองเห็น เช่น การพิจารณาเกี่ยวกับสี ขนาดและแบบอักษร การเลือกใช้คำศัพท์ที่เข้าใจง่าย การเน้นข้อความ การใช้ภาพสื่อความหมาย การจัดเรียงโครงสร้างและตำแหน่งของข้อมูล เป็นต้น ซึ่งในส่วนของการเลือกใช้นั้น ควรเลือกสีที่มีความแตกต่างของความสว่าง ความอึดอัดของสีชัดเจน หรือมีความเปรียบต่างสี (Contrast) เพียงพอ เพื่อให้ผู้ที่มีความบกพร่องทางสีหรือผู้สูงอายุที่มีความบกพร่องทางการมองเห็นสามารถแยกแยะและเข้าใจข้อมูลได้ง่าย ในจังหวัดและเมืองต่าง ๆ ของประเทศญี่ปุ่นได้มีการจัดทำคู่มือ Color Universal Design (CUD) หรือการออกแบบโดยคำนึงถึงการถ่ายทอดข้อมูลไปยังผู้ใช้ที่มีความหลากหลายทางการมองเห็นได้อย่างถูกต้อง [8]-[10] เผยแพร่เป็นแนวทางพิจารณาสำหรับการออกแบบ เพื่อการสื่อสารข้อมูลให้สามารถมองเห็นได้ง่ายและเข้าใจง่าย โดยการเลือกชุดสีที่สามารถมองเห็นแยกแยะได้ง่ายสำหรับคนจำนวน

มากที่สุด ซึ่งอาจเป็นการเปลี่ยนสี หรือการปรับความสว่าง ความอิ่มตัว ความเปรียบต่างสี นอกจากนั้นการเพิ่มพื้นที่สีหรือความหนาของอักษรและเส้น การเพิ่มเส้นแบ่งเขต/เส้นขอบ การเลือกใช้เครื่องหมาย สัญลักษณ์ต่าง ๆ หรือใช้ความแตกต่างของลวดลาย ก็จะช่วยในการสื่อสารข้อมูลไปยังผู้ที่มีความบกพร่องทางการมองเห็นสีได้ และการสื่อสารจะราบรื่นยิ่งขึ้นหากมีการใส่ชื่อสีหรือระบุหมายเลขและข้อมูลแสดงเพิ่มเติม [11]-[12] ซึ่งมหาวิทยาลัยโตเกียวร่วมกับ Color Universal Design Organization (CUDO), Industrial Research Institute of Ishikawa (IRII) และอีกหลายภาคส่วนได้ร่วมมือกันสร้างชุดสีแนะนำสำหรับ Color Universal Design โดยแบ่งเป็น 3 รูปแบบของกลุ่มสี รวมทั้งสิ้น 20 สี ประกอบด้วย [13]

- 9 สีที่เน้นความอิ่มตัวของสีสูง สามารถแยกแยะได้ง่ายแม้ในบริเวณที่ค่อนข้างเล็ก เช่น ตัวอักษรและป้ายสัญลักษณ์ต่าง ๆ
- 7 สีพื้นฐานที่มีความสว่างสูงและความอิ่มตัวของสีต่ำใช้สำหรับพื้นที่ขนาดใหญ่ เช่น แผนที่ทั่วไป แผ่นที่นำทางต่าง ๆ
- 4 โทนไร้สี (Achromatic)

ซึ่งเป็นสีที่คนทั่วไปและคนที่มีความบกพร่องทางการมองเห็นสีสามารถแยกแยะง่าย โดยคัดเลือกสีที่ง่ายต่อการแสดงออกด้วยชื่อสีในชีวิตประจำวัน และอยู่ในขอบเขตสีที่สามารถแสดงได้ เช่น ในจอแสดงภาพ การพิมพ์ การเขียนภาพ โดยยังคงให้ความรู้สึกเป็นสีเดียวกัน

นอกจากนั้นมีการศึกษาวิจัยเกี่ยวกับการมองเห็นสีของผู้สูงอายุในลักษณะต่าง ๆ เช่น ความสามารถในการมองเห็นสีที่เปลี่ยนไปของผู้สูงอายุภายใต้ระดับความสว่างที่แตกต่างกัน [14]-[15] โดยความแตกต่างของความสว่างเป็นปัจจัยที่มีอิทธิพลมากที่สุดต่อการตัดสินใจเลือกชุดสีที่ดีและเห็นได้ชัดเจน [16], ความพร่ามัวและความสามารถในการเห็นความแตกต่างของสีที่ลดลงของผู้สูงอายุส่งผลต่อการใช้ชีวิตประจำวัน โดยเฉพาะอย่างยิ่งความลำบากในการอ่านหนังสือพิมพ์ การขับรถในเวลากลางคืนหรือฝนตก [17], การมองเห็นสีในผู้สูงอายุมีความแตกต่างจากคนหนุ่มสาว โดยในความต่างนี้ทำให้การรับรู้ทางความรู้สึกแตกต่างกันด้วยโดยเฉพาะในโทนไร้สี แต่พบว่ามี ความแตกต่างของการรับรู้ทางความรู้สึกน้อยในสีที่มีความสว่างมาก [18], แบบจำลองความชื่นชอบสีของผู้สูงอายุกับวัยหนุ่มสาว โดยผู้สูงอายุจะจัดอันดับสีตามความเข้มสี (Chroma) และคนวัยหนุ่มสาวจะจัดอันดับสีตามทั้งความสว่าง (Lightness) และความเข้มสี [19]

จากผลการศึกษาวิจัยเกี่ยวกับสีที่เป็นมิตรต่อผู้สูงอายุและการมองเห็นสีของผู้สูงอายุที่ผ่านมาพบว่า ความสว่างของสี (Lightness), ความเปรียบต่างสี (Contrast), ความอิ่มตัวของสี (Saturation), ความเข้มสี (Chroma), โทนสี (Color Tone) สามารถช่วยให้ผู้สูงอายุมองเห็นแยกแยะได้ง่าย ส่งผลต่อการสื่อสารข้อมูลและความเข้าใจที่ถูกต้อง

ซึ่งจากปัญหาความเสื่อมถอยทางการมองเห็นในผู้สูงอายุ การเลือกใช้สี โดยเฉพาะคู่สีที่เหมาะสมต่อการมองเห็นแยกแยะได้ง่ายสำหรับผู้สูงอายุ จะช่วยในการสื่อสารและเพิ่มความปลอดภัยในการดำเนินชีวิตให้กับผู้สูงวัย ซึ่งงานวิจัยนี้ได้นำองค์ความรู้จากการศึกษาวิจัยในอดีต มาพัฒนาต่อยอด โดยเพิ่มความเชื่อมโยงกับอารมณ์ความรู้สึก ด้วยการนำชุดสีจาก Color Image Scale มาประยุกต์ใช้ ผ่านการวิเคราะห์ข้อมูลสี เพื่อสร้างคู่สีที่ง่ายต่อการเชื่อมโยงกับอารมณ์ความรู้สึก และจัดทำเป็นแนวทางในการออกแบบคู่สีที่สื่ออารมณ์ที่เป็นมิตรต่อผู้สูงอายุ เพื่อง่ายต่อการนำไปประยุกต์ใช้งานที่กว้างขวางมากยิ่งขึ้น

## 2. วิธีดำเนินการวิจัย

การดำเนินงานวิจัยแบ่งออกเป็น 3 ขั้นตอน ดังนี้

### 2.1 การออกแบบและจัดทำชุดคู่สีเพื่อการทดสอบ

ในการจัดทำคู่สีที่เป็นมิตรต่อผู้สูงอายุนั้น ชุดสีจาก Color Image Scale [20] จำนวน 180 สี ถูกเลือกเป็นตัวแทนกลุ่มสีที่ใช้ในการศึกษาเนื่องจากมีความครอบคลุมของโทนสีและมีความเชื่อมโยงของการผสมผสานชุดสีกับการถ่ายทอดอารมณ์ความรู้สึก ซึ่งมีทั้งสิ้น 160 คำศัพท์ในการแสดงภาพลักษณะต่างๆ หรือที่เรียกว่า Key Image Word โดยตัวอย่างของ Key Image Word ที่แสดงอารมณ์ความรู้สึก ได้แก่ น่ารัก (Cute), กระตือรือร้น คล่องแคล่ว (Active), มีความสุข ปลื้มปิติ (Joy), เป็นทางการ (Official) ซึ่งในการทดลองเพื่อค้นหาคู่สีที่มองเห็นแยกแยะง่าย ชุดสีจาก Color Image Scale ได้ถูกนำมาออกแบบใหม่ สร้างเป็นชุดคู่สีสำหรับการทดสอบ โดยปรับให้มีความครอบคลุมความหลากหลายของคู่สีและมีจำนวนการทดสอบที่เหมาะสม กล่าวคือ ไม่มากจนทำให้เกิดความเหนื่อยล้าสายตาจนเกินไป โดยมีรายละเอียดของการออกแบบชุดคู่สีสำหรับทดสอบการมองเห็นของผู้สูงอายุดังนี้


- แบ่งกลุ่มคู่สีออกเป็นสีพื้นหลัง 180 สี (รูปที่ 1) และสีพื้นหน้า 180 สี (รูปที่ 2)

- วัตถุที่เป็นพื้นหน้าใช้การเรียงลำดับของตัวเลข 1-180 เพื่อการสื่อสารและเข้าใจง่ายสำหรับผู้สูงอายุ
- คู่มือที่นำมาใช้ในการทดลองคือ สีระดับเทา (Grayscale) 10 ระดับ ประกอบด้วยสีระดับเทาจาก Color Image Scale จำนวน 9 ระดับ (สีพื้นหลังลำดับที่ 169-177 ของรูปที่ 1) และสีเทากลาง หรือ Neutral Gray (Munsell N5) [21] เพื่อให้ครอบคลุมระดับความสว่างที่สามารถนำไปประยุกต์กับคู่มือจริงอื่น ๆ ได้ โดยมีค่าสีแดง (R), สีเขียว (G), สีน้ำเงิน (B) ในระบบสี sRGB และค่าความสว่าง ( $L^*$ ) ในระบบสี CIELAB ของสีระดับเทาทั้ง 10 ระดับตามตารางที่ 1


ตารางที่ 1. ค่าสีระดับเทา 10 ระดับที่ใช้ในการทดลอง

| ระดับที่ | R = G = B (0-255) | $L^*$ (0-100) |
|----------|-------------------|---------------|
| 1        | 0                 | 0.00          |
| 2        | 38                | 15.16         |
| 3        | 81                | 34.45         |
| 4        | 119               | 50.03         |
| 5        | 144               | 59.79         |
| 6        | 167               | 68.49         |
| 7        | 200               | 80.60         |
| 8        | 234               | 92.70         |
| 9        | 255               | 100.00        |
| 10       | 123               | 51.61         |

และจัดทำภาพดิจิทัลชุดคู่มือจำนวนทั้งสิ้น 20 ภาพดังแสดงในรูปที่ 1 และ 2



รูปที่ 1. ภาพชุดคู่มือที่ 1-10 เรียงจากหน้าสุดไปหลังสุด โดยใช้สีพื้นหลัง 180 สี และสีตัวเลขพื้นหน้าเป็นสีระดับเทา 10 ระดับ



รูปที่ 2. ภาพชุดคู่มือที่ 11-20 เรียงจากหน้าสุดไปหลังสุด โดยใช้สีตัวเลขพื้นหน้า 180 สี และสีพื้นหลังเป็นสีระดับเทา 10 ระดับ

## 2.2 การทดสอบการมองเห็นคู่มือของผู้สูงอายุ

การทดสอบการมองเห็นคู่มือของผู้สูงอายุ จัดทำผ่านแบบสอบถามออนไลน์ ด้วยวิธีการเก็บข้อมูลแบบไม่สามารถระบุตัวบุคคลได้ทั้งทางตรงและทางอ้อม โดยผู้สูงอายุสามารถใช้อุปกรณ์การรับชมตามความสะดวกและความถนัด และหากเกิดการปวดเวียนศีรษะ ไม่สบายตาหรืออาการไม่พึงประสงค์ สามารถยุติการตอบแบบสอบถามได้ทันที ซึ่งผู้สูงอายุจะถูกให้เลือกตัวเลขต่าง ๆ ระหว่าง 1-180 ของแต่ละภาพในรูปที่ 1 และ 2 ที่มองเห็นยาก อ่านลำบาก หรือมองไม่เห็น โดยจำนวนผู้สูงอายุที่มองเห็นยาก อ่านลำบาก หรือมองไม่เห็นดังกล่าวนี้ของแต่ละคู่มือ จะถูกคำนวณเป็นอัตราส่วนร้อยละของผู้สูงอายุที่มองเห็นแยกแยะยาก เพื่อศึกษาความสัมพันธ์กับอัตราส่วนความคมชัด(Contrast Ratio) และใช้ประกอบการพิจารณาในขั้นตอนต่อไป

## 2.3 การวิเคราะห์ข้อมูล

ผลการทดสอบการมองเห็นของผู้สูงอายุจะถูกนำมาพิจารณา ร่วมกับการวิเคราะห์ข้อมูลดังต่อไปนี้

1. อัตราส่วนความคมชัด หรืออัตราส่วนความแตกต่างของสีที่สว่างที่สุดกับสีที่มีมืดที่สุด (Contrast Ratio; CR) โดยหากยังมีค่าสูง จะทำให้ความสามารถในการแยกแยะวัตถุออกจากพื้นหลังดีขึ้น ส่งผลต่อการสื่อสารข้อมูลที่ถูกต้องและมีประสิทธิภาพ ทั้งนี้ได้นำ Web Content Accessibility Guidelines (WCAG) 2.1 [22] ซึ่งได้รวบรวมคำแนะนำในการ

จัดทำเนื้อหาของเว็บไซต์ให้สามารถเข้าถึงได้มากยิ่งขึ้นสำหรับผู้ที่มีความบกพร่องทางสายตา การได้ยิน การพูด การเรียนรู้, มีข้อจำกัดทางการเคลื่อนไหว ทางปัญญา, มีความไวต่อการกระตุ้นทางแสง มาร่วมประกอบการพิจารณาเพื่อเสนอแนะข้อดีสำหรับเป็นแนวทางการออกแบบสื่อดิจิทัล โดยเฉพาะอย่างยิ่งสื่อประเภทออนไลน์ ซึ่งค่า Contrast Ratio สามารถคำนวณได้จากสมการที่ (1) [22]

$$CR = (L_1 + 0.05) / (L_2 + 0.05) \quad (1)$$

เมื่อ  $L_1$  คือ ความสว่างสัมพัทธ์ของสีที่สว่างและ  $L_2$  คือ ความสว่างสัมพัทธ์ของสีที่มีด โดยความสว่างสัมพัทธ์หรือ Relative Luminance ( $L$ ) จะมีค่าความสว่างอยู่ในช่วงมาตรฐานระหว่าง 0 (สีดำที่มีดที่สุด) ถึง 1 (สีขาวที่สว่างที่สุด) ซึ่งในระบบสี sRGB ค่าความสว่างสัมพัทธ์สามารถคำนวณได้จากองค์ประกอบของแม่สีดังสมการที่ (2)

$$L = 0.2126 * R + 0.7152 * G + 0.0722 * B \quad (2)$$

โดยกำหนดค่าของ  $R$  (สีแดง),  $G$  (สีเขียว) และ  $B$  (สีน้ำเงิน) ได้ดังนี้

$$\text{ถ้า } R_{sRGB} \leq 0.03928 \text{ แล้ว } R = R_{sRGB} / 12.92 \text{ มิฉะนั้น}$$

$$R = ((R_{sRGB} + 0.055) / 1.055)^{2.4}$$

$$\text{ถ้า } G_{sRGB} \leq 0.03928 \text{ แล้ว } G = G_{sRGB} / 12.92 \text{ มิฉะนั้น}$$

$$G = ((G_{sRGB} + 0.055) / 1.055)^{2.4}$$

$$\text{ถ้า } B_{sRGB} \leq 0.03928 \text{ แล้ว } B = B_{sRGB} / 12.92 \text{ มิฉะนั้น}$$

$$B = ((B_{sRGB} + 0.055) / 1.055)^{2.4}$$

โดยที่  $R_{sRGB}$ ,  $G_{sRGB}$  และ  $B_{sRGB}$  คือค่าสีแดง สีเขียว และสีน้ำเงินในระบบสี sRGB 8 บิต หารด้วย 255 ตามลำดับ ซึ่ง Contrast Ratio มีค่าตั้งแต่ 1 ถึง 21

2. ความแตกต่างของสี (Color Difference;  $CD$ ) คำนวณได้จากสมการที่ (3) [22]

$$CD = (Max(R_1, R_2) - Min(R_1, R_2)) + (Max(G_1, G_2) - Min(G_1, G_2)) + (Max(B_1, B_2) - Min(B_1, B_2)) \quad (3)$$

โดยที่  $R_1$ ,  $G_1$ ,  $B_1$  และ  $R_2$ ,  $G_2$ ,  $B_2$  คือค่าสีแดง สีเขียว และสีน้ำเงินของสีที่ 1 และสีที่ 2 ตามลำดับ มีค่า 0 – 255 ซึ่ง Color Difference มีค่าตั้งแต่ 0 ถึง 765

3. ความสว่างของสี (Color Brightness;  $CB$ ) คำนวณได้จากสมการที่ (4) [22]

$$CB = ((R * 299) + (G * 587) + (B * 114)) / 1000 \quad (4)$$

เมื่อ  $R$ ,  $G$ ,  $B$  คือค่าสีแดง สีเขียว และสีน้ำเงินตามลำดับ มีค่า 0 – 255 ซึ่ง Color Brightness มีค่าตั้งแต่ 0 ถึง 255

4. ความเข้มสี (Chroma;  $C_{ab}^*$ ) คำนวณได้จากค่า  $a^*$  และ  $b^*$  ในระบบสี CIELAB ดังสมการที่ (5)

$$C_{ab}^* = (a^{*2} + b^{*2})^{0.5} \quad (5)$$

5. โทนีส์ ได้แก่ โทนีส์ร้อน โทนีส์เย็น และโทนีส์ไร้สี

โดยผลการประมวลข้อมูลทั้งหมดจะคัดเลือกคู่สีที่เป็นมิตรต่อผู้สูงอายุและคู่สีที่ควรหลีกเลี่ยงเพื่อประกอบการพิจารณาแนวทางการออกแบบคู่มือสำหรับสื่อดิจิทัลและการเลือกใช้สีในงานออกแบบต่าง ๆ เพื่อผู้สูงอายุ

### 3. ผลการวิจัย

จากผลการทดสอบการมองเห็นคู่สีของผู้สูงอายุที่มีอายุ 60 ปีขึ้นไป จำนวน 35 คน โดยมีข้อมูลทั่วไปของกลุ่มผู้ตอบแบบสอบถามดังแสดงในตารางที่ 2 ซึ่งส่วนใหญ่เป็นเพศชาย (68.57%) มีอายุระหว่าง 71-80 ปี (57.14%) และไม่เคยได้รับการผ่าตัดต่อกระจก (88.57%) มีโรคทางสายตาสั้น ๆ รวมด้วยมากที่สุดคือ ต้อลม (28.57%) และส่วนใหญ่ใช้สมาร์ทโฟน (60%) ในการตอบแบบสอบถามออนไลน์ โดยการทดสอบแบ่งคู่สีออกเป็น 2 กลุ่มคือ

กลุ่มที่ 1 ภาพพื้นหลังเป็นชุดสี 180 สี และมีตัวเลขพื้นหน้าเป็นสีระดับเทา (รูปที่ 1)

กลุ่มที่ 2 ภาพตัวเลขพื้นหน้าเป็นชุดสี 180 สี บนพื้นหลังเป็นสีระดับเทา (รูปที่ 2)




ตารางที่ 2. ข้อมูลทั่วไปของผู้ตอบแบบสอบถาม (จำนวน 35 คน)

| ข้อมูลทั่วไป                   | อัตราส่วนร้อยละ |
|--------------------------------|-----------------|
| เพศ                            |                 |
| ชาย                            | 68.57           |
| หญิง                           | 31.43           |
| อายุ (ปี)                      |                 |
| 61-70                          | 42.86           |
| 71-80                          | 57.14           |
| ได้รับการผ่าตัดต่อกระดูก       |                 |
| ไม่เคย                         | 88.57           |
| เคย                            | 11.43           |
| โรคทางสายตาอื่น ๆ              |                 |
| ต้อลม                          | 28.57           |
| ต้อหิน                         | 5.71            |
| วุ้นตาเสื่อม                   | 5.71            |
| ต้อเนื้อ                       | 2.86            |
| ต้อกระจก                       | 0.00            |
| อุปกรณ์ที่ใช้ในการตอบแบบสอบถาม |                 |
| สมาร์ทโฟน                      | 60.00           |
| แล็ปท็อป                       | 22.86           |
| แท็บเล็ต                       | 8.57            |
| คอมพิวเตอร์ตั้งโต๊ะ            | 8.57            |


ผลการตอบแบบสอบถามพบว่าอัตราส่วนของจำนวนผู้สูงอายุที่มองเห็นยาก อ่านลำบาก หรือมองไม่เห็น ส่วนใหญ่มีแนวโน้มลดลงเมื่อ Contrast Ratio เพิ่มขึ้นดังแสดงในตัวอย่างกราฟของชุดสีที่ 2, 6, 12 และ 16 ในรูปที่ 3 ซึ่งมีความสอดคล้องกันทั้งกลุ่มที่ 1 (พื้นหลังเป็นชุดสี 180 สี) และกลุ่มที่ 2 (ตัวเลขพื้นหน้าเป็นชุดสี 180 สี) โดยแต่ละกราฟจะแสดงคู่สีทั้ง 180 คู่ ของภาพชุดสี และแสดงสีของตัวเลขพื้นหน้าด้วยสีภายในวงกลม และสีของพื้นหลังด้วยสีขอบวงกลม

อัตราส่วนร้อยละของจำนวนผู้สูงอายุที่มองเห็นยากและยาก



ชุดสีที่ 2 ตัวเลขพื้นหน้าเป็นสีระดับเทาที่ 2 (R=G=B=38)


อัตราส่วนร้อยละของจำนวนผู้สูงอายุที่มองเห็นยากและยาก




ชุดสีที่ 6 ตัวเลขพื้นหน้าเป็นสีระดับเทาที่ 6 (R=G=B=167)

กลุ่มที่ 1 (พื้นหลังเป็นชุดสี 180 สี และพื้นหน้าเป็นสีระดับเทา)

อัตราส่วนร้อยละของจำนวนผู้สูงอายุที่มองเห็นยากและยาก



ชุดสีที่ 12 พื้นหลังเป็นสีระดับเทาที่ 2 (R=G=B=38)



ชุดคู่สีที่ 16 พื้นหลังเป็นสีระดับเทาที่ 6 (R=G=B=167)  
กลุ่มที่ 2 (พื้นหน้าเป็นชุดสี 180 สี และพื้นหลังเป็นสีระดับเทา)

รูปที่ 3. อัตราส่วนของจำนวนผู้สูงอายุที่มองเห็นแยกแยะยากต่อ  
Contrast Ratio ของตัวอย่างภาพชุดคู่สีในกลุ่มที่ 1 และ 2

เมื่อพิจารณาตามอัตราส่วนของจำนวนผู้สูงอายุที่มองเห็นแยกแยะยาก กำหนดให้มีค่าเท่ากับ D สามารถแบ่งได้เป็น 2 ระดับ คือ


ระดับที่ 1 กลุ่มชุดคู่สีที่ผู้สูงอายุมองเห็นยาก อ่านลำบาก หรือไม่สามารถแยกแยะได้ ( $D \geq 50\%$ )

ระดับที่ 2 กลุ่มชุดคู่สีที่ผู้สูงอายุสามารถอ่านได้ ( $D < 50\%$ )


รูปที่ 4 แสดงคู่สีทั้งหมดในระดับที่ 1 และตัวอย่างคู่สีบางส่วนในระดับที่ 2 โดยเรียงลำดับค่า D จากมากไปน้อย และค่า Contrast Ratio จากน้อยไปมาก กล่าวคือ เรียงจากคู่สีที่อ่านยากมากที่สุด ตัวเลขด้านบนแสดงค่า D และตัวเลขด้านล่างแสดงค่า Contrast Ratio โดยใช้ตัวเลขและสีพื้นหลังตามคู่สีจริงที่ทดสอบ




คู่สีทั้งหมดในระดับที่ 1 (ผู้สูงอายุมองเห็นยาก อ่านลำบาก หรือไม่สามารถแยกแยะได้;  $D \geq 50\%$ )



ตัวอย่างคู่สีในระดับที่ 2 (ผู้สูงอายุสามารถอ่านได้;  $D < 50\%$ )  
กลุ่มที่ 1 (พื้นหลังเป็นชุดสี 180 สี และพื้นหน้าเป็นสีระดับเทา)



คู่สีทั้งหมดในระดับที่ 1 (ผู้สูงอายุมองเห็นยาก อ่านลำบาก หรือไม่สามารถแยกแยะได้;  $D \geq 50\%$ )



ตัวอย่างคู่สีในระดับที่ 2 (ผู้สูงอายุสามารถอ่านได้;  $D < 50\%$ )  
กลุ่มที่ 2 (พื้นหน้าเป็นชุดสี 180 สี และพื้นหลังเป็นสีระดับเทา)  
รูปที่ 4. คู่สีทั้งหมดในระดับที่ 1 และตัวอย่างคู่สีในระดับที่ 2

จากแนวโน้มความสัมพันธ์ระหว่าง Contrast Ratio กับความสามารถในการมองเห็นแยกแยะของผู้สูงอายุ (รูปที่ 3) เมื่อนำมาพิจารณาพร้อมกับระดับการมองเห็น อ่านได้ของคู่สี (รูปที่ 4) และ Web Content Accessibility Guidelines (WCAG) 2.1 [22] จึงได้เป็นข้อเสนอแนะสำหรับคู่สีที่อ่านได้ และคู่สีที่เป็นมิตรต่อผู้สูงอายุของชุดสีจาก Color Image Scale ซึ่งจะช่วยให้ง่ายต่อการประยุกต์ใช้งานที่เชื่อมโยงกับอารมณ์ความรู้สึก โดยข้อเสนอแนะในการเลือกคู่สีสำหรับผู้สูงอายุมีดังนี้

1. คู่สีที่ควรหลีกเลี่ยง เป็นคู่สีที่เข้าเกณฑ์ข้อใดข้อหนึ่งด้านล่างนี้

- Contrast Ratio  $< 3$

- $D \geq 50\%$

2. คู่สีที่อ่านได้ เป็นคู่สีที่เป็นไปตามเกณฑ์ทั้งสองด้านล่างนี้

- Contrast Ratio  $\geq 3$  [22]

- $D < 50\%$

3. คู่สีที่เป็นมิตรต่อผู้สูงอายุ เป็นคู่สีที่แนะนำมากที่สุดเนื่องจากสามารถมองเห็นแยกแยะได้ดีสำหรับผู้สูงอายุ โดยเป็นคู่สีที่เป็นไปตามเกณฑ์ทั้งหมดด้านล่างนี้

- Contrast Ratio  $\geq 3$  [22]

- $D < 50\%$

- Color Difference  $\geq 500$  [22]

- Brightness Difference  $\geq 125$  [22]

จากผลการทดลองการมองเห็นคู่สีของผู้สูงอายุทั้ง 20 ภาพชุดคู่สี พิจารณาพร้อมกับเกณฑ์ในการเลือกคู่สีสำหรับผู้สูงอายุข้างต้นพบว่าคู่สีที่มองเห็นยาก ( $D \geq 50\%$ ) มี Contrast Ratio น้อยกว่า 3 และคู่สีที่เป็นมิตรต่อผู้สูงอายุตามข้อเสนอแนะที่ 3 จากผลการทดลองและการคำนวณค่า Contrast Ratio, Color Difference และ Brightness Difference พบว่าคู่สีที่ผ่านเกณฑ์ของค่าทั้ง 3 นี้มีค่า  $D$  น้อยกว่า 50% ทั้งหมด ดังนั้นจึงเลือกใช้ผลที่ได้จากการคำนวณข้อมูลสี และนำไปจัดกลุ่มตามโทนสีพื้นหลังเพื่อให้ง่ายต่อการนำไปใช้งานดังรูปที่ 5 ซึ่งประกอบด้วยพื้นหลังโทนสีร้อน (W1) โทนสีเย็น (C1) และโทนไร้สี โดยในโทนไร้สีแบ่งย่อยตัวเลขพื้นหน้าออกเป็นโทนสีร้อน (W2) และโทนสีเย็น (C2) โดยในรูปที่ 5 มีการเรียงลำดับคู่สีในแต่ละโทนสีของพื้นหลังด้วยค่าความสว่าง ( $L^*$ ), ค่าความเข้มสี (Chroma) และค่า Contrast Ratio จากมากไปน้อย ตามความง่ายในการมองเห็นของผู้สูงอายุ ตัวเลขด้านบนแสดงค่าความสว่าง ( $L^*$ ) ในระบบสี

CIELAB มีค่า 0-100 และตัวเลขด้านล่างแสดงค่า Contrast Ratio มีค่า 1-21

|      |      |      |      |      |      |      |      |      |      |
|------|------|------|------|------|------|------|------|------|------|
| 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   |
| 20.2 | 16.8 | 14.6 | 14.0 | 13.8 | 12.8 | 12.7 | 12.1 | 11.8 | 11.7 |
| 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   |
| 11.1 | 11.0 | 10.7 | 10.5 | 10.4 | 10.0 | 10.0 | 9.7  | 9.7  | 9.5  |
| 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   | 98   |
| 9.3  | 9.0  | 8.6  | 8.5  | 8.4  | 8.3  | 8.1  | 7.7  | 7.7  | 6.3  |
| 98   | 98   | 98   | 97   | 97   | 97   | 97   | 97   | 97   | 97   |
| 4.8  | 4.3  | 4.1  | 19.3 | 16.0 | 13.9 | 13.3 | 13.2 | 12.2 | 12.1 |
| 97   | 97   | 97   | 97   | 97   | 97   | 97   | 97   | 97   | 97   |
| 11.3 | 11.1 | 10.6 | 10.5 | 10.2 | 10.1 | 9.9  | 9.5  | 9.2  | 9.1  |
| 97   | 97   | 97   | 96   | 96   | 96   | 96   | 96   | 96   | 96   |
| 8.9  | 8.0  | 4.6  | 18.9 | 15.7 | 13.6 | 13.1 | 12.9 | 12.0 | 11.8 |
| 96   | 96   | 96   | 96   | 96   | 96   | 96   | 96   | 96   | 96   |
| 11.1 | 10.9 | 10.4 | 10.3 | 10.0 | 9.9  | 9.7  | 9.3  | 9.1  | 8.9  |
| 96   | 96   | 96   | 96   | 94   | 94   | 94   | 94   | 94   | 94   |
| 8.7  | 8.0  | 7.8  | 4.5  | 18.1 | 15.1 | 13.0 | 12.5 | 12.4 | 11.5 |
| 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   |
| 10.4 | 9.5  | 9.3  | 8.9  | 18.1 | 15.1 | 13.1 | 12.5 | 12.4 | 11.5 |
| 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   |
| 11.4 | 10.6 | 10.5 | 10.0 | 9.9  | 9.6  | 9.5  | 9.3  | 9.0  | 8.7  |
| 94   | 94   | 94   | 94   | 93   | 93   | 93   | 93   | 93   | 93   |
| 8.6  | 8.3  | 7.5  | 4.3  | 17.5 | 14.6 | 12.6 | 10.1 | 17.7 | 14.8 |
| 93   | 93   | 93   | 93   | 93   | 93   | 93   | 93   | 93   | 93   |
| 12.8 | 12.3 | 12.1 | 11.3 | 11.1 | 10.4 | 10.2 | 9.8  | 9.7  | 9.3  |
| 93   | 93   | 93   | 92   | 92   | 92   | 92   | 92   | 92   | 92   |
| 9.1  | 8.8  | 8.5  | 14.3 | 11.9 | 10.9 | 10.3 | 9.9  | 9.7  | 9.2  |
| 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   |
| 8.9  | 8.8  | 8.5  | 7.6  | 7.2  | 6.9  | 5.3  | 4.7  | 4.6  | 17.1 |
| 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   |
| 14.3 | 12.4 | 11.9 | 11.7 | 9.9  | 17.2 | 14.3 | 12.4 | 11.9 | 11.8 |
| 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   |
| 10.9 | 10.8 | 10.1 | 9.9  | 9.5  | 9.4  | 9.0  | 8.8  | 8.5  | 8.2  |
| 92   | 92   | 91   | 91   | 91   | 91   | 91   | 90   | 90   | 90   |
| 8.1  | 7.1  | 16.5 | 13.8 | 11.9 | 11.3 | 9.5  | 16.4 | 13.7 | 11.8 |
| 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   |
| 11.3 | 11.2 | 10.4 | 10.3 | 9.6  | 9.5  | 9.1  | 8.9  | 8.6  | 8.4  |
| 90   | 90   | 90   | 90   | 89   | 89   | 89   | 89   | 89   | 89   |
| 8.1  | 7.9  | 7.7  | 6.8  | 8.5  | 8.3  | 8.1  | 7.8  | 7.0  | 6.6  |
| 89   | 89   | 88   | 88   | 88   | 88   | 88   | 86   | 86   | 86   |
| 6.3  | 4.4  | 15.5 | 15.4 | 12.9 | 11.1 | 8.9  | 14.5 | 12.1 | 10.5 |

|      |      |      |      |      |      |      |      |      |      |
|------|------|------|------|------|------|------|------|------|------|
| 85   | 85   | 85   | 85   | 84   | 84   | 84   | 84   | 83   | 83   |
| 14.3 | 11.9 | 14.1 | 11.7 | 13.8 | 13.7 | 11.4 | 9.9  | 6.0  | 5.7  |
| 83   | 83   | 83   | 82   | 82   | 82   | 81   | 81   | 81   | 81   |
| 13.5 | 11.2 | 9.7  | 13.2 | 13.0 | 13.1 | 12.6 | 10.5 | 9.1  | 12.6 |
| 81   | 81   | 80   | 79   | 79   | 77   | 75   | 74   | 73   | 72   |
| 10.5 | 9.1  | 12.2 | 11.9 | 9.9  | 11.2 | 10.8 | 10.2 | 10.0 | 9.7  |
| 71   | 71   | 71   | 66   | 54   | 52   | 52   | 50   | 50   | 48   |
| 9.6  | 9.4  | 9.5  | 8.2  | 3.9  | 4.2  | 4.1  | 4.5  | 4.3  | 4.8  |
| 47   | 47   | 47   | 47   | 47   | 47   | 47   | 47   | 47   | 47   |
| 5.0  | 5.0  | 4.8  | 4.6  | 4.5  | 4.4  | 4.3  | 4.3  | 4.2  | 4.1  |
| 47   | 44   | 42   | 39   | 37   | 36   | 34   | 34   | 34   | 34   |
| 4.0  | 5.6  | 6.1  | 6.7  | 7.1  | 7.5  | 8.1  | 7.7  | 7.0  | 8.2  |
| 34   | 34   | 34   | 33   | 32   | 32   | 32   | 32   | 32   | 32   |
| 8.0  | 7.7  | 6.9  | 8.4  | 8.7  | 8.3  | 8.0  | 7.8  | 7.5  | 7.5  |
| 32   | 32   | 32   | 32   | 32   | 32   | 29   | 29   | 29   | 29   |
| 7.5  | 7.2  | 7.1  | 7.1  | 7.0  | 6.8  | 9.7  | 9.3  | 8.9  | 8.7  |
| 29   | 29   | 29   | 29   | 29   | 29   | 28   | 28   | 28   | 28   |
| 8.4  | 8.3  | 8.3  | 8.0  | 7.9  | 7.8  | 9.9  | 9.5  | 9.1  | 8.9  |
| 28   | 28   | 28   | 28   | 28   | 28   | 28   | 28   | 27   | 27   |
| 8.6  | 8.6  | 8.5  | 8.2  | 8.1  | 8.1  | 8.0  | 7.7  | 10.4 | 10.0 |
| 27   | 27   | 27   | 24   | 24   | 24   | 24   | 24   | 24   | 24   |
| 9.0  | 8.9  | 8.4  | 11.5 | 11.0 | 10.5 | 10.3 | 9.9  | 9.9  | 9.8  |
| 24   | 24   | 24   | 24   | 24   | 24   | 24   | 24   | 24   | 24   |
| 9.7  | 9.5  | 9.4  | 9.4  | 9.2  | 8.9  | 8.9  | 8.8  |      |      |

พื้นหลังโทนสีร้อน (W1)

|      |      |      |      |      |      |      |      |      |      |
|------|------|------|------|------|------|------|------|------|------|
| 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  |
| 21.0 | 15.1 | 11.5 | 10.4 | 9.9  | 9.7  | 8.7  | 8.4  | 8.2  | 8.1  |
| 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  |
| 8.0  | 7.9  | 7.5  | 7.1  | 6.7  | 6.1  | 5.6  | 5.0  | 5.0  | 4.8  |
| 100  | 100  | 100  | 93   | 93   | 93   | 93   | 93   | 93   | 93   |
| 4.5  | 4.2  | 3.9  | 17.5 | 12.6 | 9.5  | 8.2  | 8.0  | 7.2  | 4.2  |
| 81   | 68   | 34   | 15   | 15   | 15   | 15   | 15   | 15   | 15   |
| 12.6 | 8.7  | 7.9  | 15.1 | 14.6 | 13.9 | 13.6 | 13.1 | 13.0 | 12.8 |
| 15   | 15   | 15   | 15   | 15   | 15   | 15   | 15   | 15   | 15   |
| 12.6 | 12.6 | 12.4 | 12.4 | 11.9 | 11.8 | 11.1 | 10.5 | 9.9  | 9.7  |
| 15   | 15   | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    |
| 9.1  | 9.1  | 21.0 | 20.2 | 19.3 | 18.9 | 18.1 | 18.1 | 17.7 | 17.5 |
| 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    |
| 17.5 | 17.2 | 17.1 | 16.5 | 16.4 | 15.5 | 15.4 | 14.5 | 14.3 | 14.1 |
| 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    |
| 13.8 | 13.7 | 13.5 | 13.2 | 13.1 | 13.0 | 12.6 | 12.6 | 12.6 | 12.2 |
| 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    |
| 11.9 | 11.2 | 10.8 | 10.2 | 10.0 | 9.7  | 9.6  | 9.5  | 9.4  | 8.7  |
| 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    |
| 8.2  |      |      |      |      |      |      |      |      |      |

ตัวเลขพื้นหน้าโทนสีร้อน (W2)



|      |      |      |      |      |      |      |      |      |      |
|------|------|------|------|------|------|------|------|------|------|
| 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  |
| 17.5 | 14.5 | 14.3 | 13.3 | 13.2 | 12.6 | 12.3 | 12.1 | 11.9 | 11.6 |
| 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  |
| 11.3 | 11.1 | 11.0 | 10.8 | 10.4 | 10.1 | 10.1 | 9.8  | 9.3  | 8.9  |
| 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  | 100  |
| 8.8  | 8.8  | 8.7  | 8.6  | 8.4  | 7.8  | 7.6  | 7.6  | 6.5  | 5.8  |
| 93   | 93   | 93   | 93   | 93   | 93   | 93   | 93   | 93   | 93   |
| 14.5 | 12.1 | 11.9 | 11.1 | 10.9 | 10.2 | 10.1 | 9.6  | 9.2  | 9.1  |
| 93   | 93   | 93   | 93   | 15   | 15   | 15   | 15   | 15   | 15   |
| 9.0  | 8.6  | 8.4  | 7.4  | 13.1 | 13.0 | 12.4 | 12.2 | 11.7 | 11.6 |
| 15   | 15   | 15   | 15   | 15   | 15   | 0    | 0    | 0    | 0    |
| 11.0 | 10.8 | 9.7  | 9.7  | 9.5  | 9.0  | 18.2 | 18.1 | 17.3 | 16.9 |
| 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    |
| 16.3 | 16.1 | 15.3 | 15.0 | 13.5 | 13.5 | 13.1 | 12.5 | 12.4 | 12.1 |
| 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    | 0    |
| 11.7 | 11.6 | 11.2 | 10.6 | 10.4 | 9.9  | 9.7  | 8.7  | 8.4  | 7.3  |

ตัวเลขพื้นหน้าโทนีสี่เย็น (C2)

|      |      |      |      |      |      |      |      |      |      |
|------|------|------|------|------|------|------|------|------|------|
| 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   |
| 18.2 | 15.2 | 13.1 | 12.6 | 12.5 | 11.6 | 11.4 | 10.9 | 10.7 | 10.5 |
| 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   |
| 10.1 | 9.9  | 9.6  | 9.5  | 9.4  | 9.0  | 9.0  | 8.7  | 8.6  | 8.4  |
| 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   |
| 8.1  | 7.7  | 7.6  | 7.5  | 7.3  | 7.0  | 6.9  | 4.4  | 18.1 | 15.0 |
| 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   |
| 13.0 | 12.5 | 12.3 | 11.5 | 11.3 | 10.8 | 10.6 | 10.4 | 10.0 | 9.8  |
| 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   | 94   |
| 9.5  | 9.4  | 9.3  | 8.9  | 8.9  | 8.7  | 8.5  | 8.3  | 8.0  | 7.7  |
| 94   | 94   | 94   | 92   | 92   | 92   | 92   | 92   | 92   | 92   |
| 7.5  | 7.2  | 4.3  | 17.3 | 14.4 | 12.4 | 11.9 | 11.8 | 11.0 | 10.8 |
| 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   | 92   |
| 10.3 | 10.1 | 10.0 | 9.5  | 9.4  | 9.1  | 9.0  | 8.9  | 8.5  | 8.3  |
| 92   | 92   | 92   | 92   | 92   | 92   | 91   | 91   | 91   | 91   |
| 8.1  | 7.9  | 7.3  | 7.1  | 6.9  | 4.1  | 16.9 | 14.1 | 12.2 | 11.7 |
| 91   | 91   | 91   | 91   | 91   | 91   | 91   | 91   | 91   | 91   |
| 11.5 | 10.7 | 10.6 | 10.1 | 9.9  | 9.7  | 9.3  | 9.2  | 8.9  | 8.8  |
| 91   | 91   | 91   | 91   | 91   | 91   | 91   | 91   | 91   | 91   |
| 8.7  | 8.4  | 8.3  | 8.1  | 8.0  | 7.8  | 7.2  | 7.0  | 6.8  | 4.0  |
| 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   |
| 16.1 | 13.4 | 11.6 | 11.1 | 11.0 | 10.2 | 10.1 | 9.4  | 9.3  | 8.9  |
| 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   |
| 8.8  | 8.4  | 8.3  | 8.0  | 7.7  | 16.3 | 13.5 | 11.7 | 11.3 | 11.1 |
| 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   | 90   |
| 10.3 | 10.2 | 9.5  | 9.4  | 9.0  | 8.9  | 8.5  | 8.3  | 8.0  | 7.8  |
| 88   | 88   | 88   | 88   | 88   | 87   | 87   | 87   | 87   | 83   |
| 15.3 | 12.7 | 11.0 | 10.4 | 8.8  | 15.0 | 12.5 | 10.8 | 8.7  | 13.5 |
| 83   | 83   | 83   | 83   | 83   | 82   | 82   | 82   | 80   | 80   |
| 11.2 | 9.7  | 13.5 | 11.2 | 9.7  | 13.1 | 10.9 | 9.5  | 12.4 | 10.4 |
| 80   | 80   | 79   | 78   | 78   | 77   | 75   | 74   | 72   | 72   |
| 9.0  | 12.5 | 12.1 | 11.6 | 11.7 | 11.2 | 10.6 | 10.4 | 9.9  | 9.7  |
| 68   | 67   | 63   | 44   | 43   | 43   | 43   | 40   | 40   | 40   |
| 8.7  | 8.4  | 7.3  | 4.6  | 5.8  | 4.7  | 4.4  | 6.5  | 6.3  | 5.3  |
| 36   | 36   | 35   | 33   | 33   | 33   | 33   | 33   | 33   | 33   |
| 7.6  | 7.6  | 7.8  | 8.4  | 8.1  | 7.3  | 7.2  | 6.9  | 6.9  | 6.8  |
| 33   | 32   | 32   | 32   | 32   | 32   | 32   | 32   | 32   | 32   |
| 6.3  | 8.8  | 8.5  | 7.2  | 6.6  | 5.7  | 8.6  | 8.8  | 8.4  | 7.6  |
| 32   | 31   | 31   | 31   | 31   | 31   | 31   | 31   | 31   | 30   |
| 8.7  | 8.9  | 8.6  | 8.0  | 7.7  | 7.7  | 7.4  | 7.3  | 7.2  | 9.3  |

|      |      |      |      |      |      |      |      |      |      |
|------|------|------|------|------|------|------|------|------|------|
| 30   | 30   | 30   | 30   | 30   | 30   | 29   | 28   | 28   | 28   |
| 9.0  | 8.1  | 8.0  | 7.6  | 7.0  | 6.0  | 9.8  | 10.1 | 9.7  | 10.1 |
| 28   | 28   | 28   | 28   | 28   | 28   | 28   | 28   | 28   | 28   |
| 9.7  | 9.2  | 9.1  | 8.7  | 8.7  | 8.7  | 8.5  | 8.4  | 8.3  | 8.2  |
| 28   | 28   | 28   | 28   | 27   | 27   | 27   | 27   | 27   | 27   |
| 8.1  | 7.9  | 7.8  | 7.7  | 10.4 | 10.0 | 9.5  | 9.3  | 9.0  | 9.0  |
| 27   | 27   | 27   | 27   | 27   | 27   | 27   | 27   | 27   | 27   |
| 8.9  | 8.9  | 8.8  | 8.6  | 8.5  | 8.5  | 8.5  | 8.3  | 8.1  | 8.0  |
| 27   | 27   | 26   | 26   | 26   | 26   | 26   | 26   | 26   | 26   |
| 8.0  | 7.8  | 10.8 | 10.4 | 9.9  | 9.7  | 9.4  | 9.3  | 9.3  | 9.3  |
| 26   | 26   | 26   | 26   | 26   | 26   | 26   | 26   | 26   | 26   |
| 9.1  | 9.0  | 8.9  | 8.8  | 8.8  | 8.7  | 8.4  | 8.3  | 8.3  | 8.1  |
| 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   |
| 11.3 | 9.2  | 8.5  | 11.0 | 10.5 | 10.1 | 9.9  | 9.5  | 9.5  | 9.5  |
| 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   |
| 9.4  | 9.3  | 9.1  | 9.0  | 9.0  | 8.9  | 8.8  | 8.6  | 8.5  | 8.4  |
| 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   | 25   |
| 8.3  | 11.1 | 10.7 | 10.2 | 10.0 | 9.6  | 9.6  | 9.5  | 9.2  | 9.1  |
| 25   | 24   | 24   | 24   | 24   | 24   | 24   | 24   | 24   | 24   |
| 8.9  | 11.6 | 11.1 | 10.6 | 10.4 | 10.1 | 10.0 | 10.0 | 9.8  | 9.6  |
| 24   | 24   | 24   | 24   | 24   | 24   | 23   | 23   | 23   | 23   |
| 9.5  | 9.5  | 9.3  | 9.1  | 9.0  | 8.9  | 11.9 | 9.7  | 12.1 | 11.7 |
| 23   | 23   | 23   | 23   | 23   | 23   | 23   | 23   | 23   | 23   |
| 11.1 | 10.9 | 10.5 | 10.5 | 10.4 | 10.4 | 10.2 | 10.1 | 10.1 | 10.0 |
| 23   | 23   | 23   | 23   | 23   | 23   | 23   | 23   | 23   | 23   |
| 9.9  | 9.9  | 9.9  | 9.7  | 9.5  | 9.5  | 9.4  | 9.3  | 8.9  | 8.8  |
| 23   | 22   | 22   | 22   | 22   | 22   | 22   | 22   | 22   | 22   |
| 8.7  | 12.3 | 11.8 | 11.3 | 11.1 | 10.7 | 10.6 | 10.6 | 10.4 | 10.2 |
| 22   | 22   | 22   | 22   | 22   | 22   | 21   | 21   | 21   | 21   |
| 10.1 | 10.1 | 9.9  | 9.6  | 9.5  | 9.4  | 12.6 | 12.1 | 10.9 | 10.8 |
| 21   | 21   | 21   | 20   | 20   | 20   | 20   | 20   | 20   | 20   |
| 10.3 | 10.3 | 10.1 | 13.2 | 12.7 | 12.1 | 11.8 | 11.4 | 11.4 | 11.3 |
| 20   | 20   | 20   | 20   | 20   | 20   | 20   | 20   | 20   | 20   |
| 11.1 | 10.9 | 10.8 | 10.8 | 10.6 | 10.3 | 10.2 | 10.1 | 13.3 | 12.8 |
| 20   | 20   | 20   | 20   | 20   | 20   | 20   | 20   | 20   | 20   |
| 12.2 | 12.0 | 11.6 | 11.5 | 11.5 | 11.5 | 11.3 | 11.1 | 11.0 | 10.9 |
| 20   | 20   | 20   | 20   | 20   | 20   | 17   | 17   | 17   | 17   |
| 10.9 | 10.7 | 10.4 | 10.3 | 10.2 | 14.5 | 14.0 | 13.3 | 13.1 | 12.6 |
| 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   |
| 12.5 | 12.5 | 12.5 | 12.3 | 12.1 | 11.9 | 11.9 | 11.9 | 11.9 | 11.7 |
| 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   |
| 11.3 | 11.3 | 11.1 | 14.3 | 13.8 | 13.2 | 12.9 | 12.5 | 12.4 | 12.4 |
| 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   | 17   |
| 12.3 | 12.1 | 11.9 | 11.8 | 11.8 | 11.7 | 11.5 | 11.3 | 11.2 | 11.1 |
| 17   | 17   | 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    |
| 11.0 | 10.4 | 17.5 | 16.8 | 16.0 | 15.7 | 15.2 | 15.1 | 15.1 | 15.0 |
| 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    |
| 14.8 | 14.6 | 14.5 | 14.4 | 14.3 | 14.3 | 14.3 | 14.1 | 13.8 | 13.7 |
| 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    |
| 13.5 | 13.4 | 12.9 | 12.7 | 12.5 | 12.1 | 11.9 | 11.7 | 11.4 | 11.2 |
| 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    | 9    |
| 11.2 | 11.2 | 10.9 | 10.5 | 10.5 | 10.4 | 9.9  |      |      |      |


พื้นหลังโทนีสี่เย็น (C1)

รูปที่ 5. คู่มือที่เป็นมิตรต่อผู้สูงอายุแบ่งกลุ่มตามโทนีสี่ร้อนและโทนีสี่เย็น

จากผลการทดสอบการมองเห็นของผู้สูงอายุ และข้อเสนอแนะในการเลือกคู่สี การวิเคราะห์ผลข้อมูลสี จึงได้เป็นแนวทางการออกแบบและปรับปรุงคู่สีโดยผสมผสานการสื่อสารอารมณ์ความรู้สึกจาก Color Image Scale เพื่อประยุกต์ใช้งานในด้านต่าง ๆ ดังนี้

#### กรณีที่ 1 การปรับปรุงคู่สีเดิม

นำคู่สีเดิมเข้าสู่กระบวนการตามรูปที่ 6 ด้วยการตรวจสอบ Contrast Ratio (CR) โดยหากมี Contrast Ratio น้อยกว่า 3 จะถูกจัดเป็นคู่สีที่ควรหลีกเลี่ยงและต้องการการปรับปรุง ซึ่งสามารถทำได้โดยการคงสีหลักที่ต้องการสื่ออารมณ์ความรู้สึก และปรับค่าความสว่าง ความเข้มของคู่สีที่เป็นสีรองจนมี Contrast Ratio อย่างน้อย 3 ซึ่งจะได้อ่านได้สำหรับผู้สูงอายุ และหากปรับความสว่าง ความเข้มของสีเพิ่มเติมจนสามารถมีค่า Color Difference (CD) และ Brightness Difference (BD) ไม่น้อยกว่า 500 และ 125 ตามลำดับ ก็จะได้คู่สีที่มองเห็น แยกแยะง่าย เป็นมิตรต่อผู้สูงอายุ นอกจากนั้นยังสามารถเลือกใช้คู่สีจาก Color Image Scale ที่ผ่านการทดสอบและคำนวณตามเกณฑ์ที่กำหนด จัดเป็นกลุ่มตามโทนสีร้อนและโทนสีเย็นดังรูปที่ 5 เพื่อเป็นแนวทางการค้นหาคู่สีรองใหม่หรือปรับสีหลักให้มีความเชื่อมโยงกับอารมณ์ความรู้สึก



รูปที่ 6. กระบวนการปรับปรุงคู่สีเดิม

#### กรณีที่ 2 การออกแบบคู่สีใหม่ แบ่งเป็น


กรณีที่ 2.1 การออกแบบจากแนวคิด (Concept) หรืออารมณ์ความรู้สึก มีขั้นตอนดังนี้

1. เลือกคำศัพท์หรืออารมณ์ความรู้สึกที่ต้องการสื่อสาร โดยอ้างอิงจาก Color Image Scale เช่น เลือกคำศัพท์ที่ 141

“Calm” สื่อถึงความสงบ ใจเย็น ซึ่งมีสีที่เป็นองค์ประกอบทั้งสิ้น 16 สี (รูปที่ 7)

2. เลือกสีหลักโดยการค้นหาสีองค์ประกอบทั้ง 16 สีที่ตรงกับคู่สีที่เป็นมิตรต่อผู้สูงอายุในรูปที่ 5 แนะนำให้เริ่มจากสีที่สื่อความรู้สึกได้ชัดและมีความสว่างสูง ที่ตรงกับสีพื้นหลังของคู่สีในรูปที่ 5 ซึ่งได้แบ่งกลุ่มตามโทนสีไว้เพื่อความสะดวกในการใช้งาน ตัวอย่างเช่น เลือกสีหลักเป็นสีรหัสสี m17 ตรงกับ 6 คู่สีของกลุ่ม W1 ในรูปที่ 5 ดังแสดงในรูปที่ 7

3. เลือกคู่สีที่มีสีตรงตรงหรือใกล้เคียงกับสีองค์ประกอบของอารมณ์ความรู้สึกที่ต้องการสื่อสาร เพื่อเป็นแนวทางคู่สีสำหรับการออกแบบ และอาจมีมากกว่า 1 คู่สีได้ เช่น ในกรณีตัวอย่าง คู่สีที่ 3 และ 6 มีความใกล้เคียงกับสีองค์ประกอบมากที่สุด นอกจากนั้นยังสามารถเลือกคู่สีรองอื่น ๆ เพิ่มเติม หากไม่ส่งผลต่ออารมณ์ความรู้สึกของสีหลักที่เลือกใช้




รูปที่ 7. ตัวอย่างแนวทางการออกแบบคู่สีจากแนวคิดหรืออารมณ์ความรู้สึก


กรณีที่ 2.2 การออกแบบจากคู่สีที่เป็นมิตรต่อผู้สูงอายุของชุดสี Color Image Scale

ชุดสีจาก Color Image Scale จำนวน 180 สีได้ผ่านกระบวนการทดสอบการมองเห็นโดยผู้สูงอายุ และการคำนวณค่า Contrast Ratio, Color Difference, Brightness Difference โดยคู่สีที่ผ่านเกณฑ์ถูกจัดเป็นกลุ่มตามโทนสี และเรียงลำดับในแต่ละโทนจากความสว่าง ความเข้มสี และ Contrast Ratio สูงเพื่อการมองเห็นง่ายสำหรับผู้สูงอายุดังแสดงในรูปที่ 5 ดังนั้นนักออกแบบสามารถเลือกสีจากคู่สีที่ได้จัดเตรียมไว้ สรุปลงในรูปที่ 8 โดยแนะนำให้เลือกใช้ตามลำดับจากกลุ่ม W1, W2, C2, C1 เนื่องจากผู้สูงอายุมองเห็นโทนสีร้อนได้ดีกว่าโทนสีเย็น

จากนั้นนำสีที่ได้ไปเทียบกับแผนผัง Color Image Scale ในรูปที่ 8 ซึ่งประกอบด้วยแกนแนวนอนเป็นโทนสีร้อน-เย็น และแกนแนวตั้งเป็นความสว่าง-มืดของสี มีทั้งสิ้น 23 กลุ่มคำศัพท์ เมื่อได้โซนตำแหน่งของกลุ่มคำศัพท์ในแผนผังแล้ว จึงเข้าไปเลือกคำศัพท์ย่อยที่เหมาะสมต่อการใช้งาน ซึ่งส่วนใหญ่จะมีสีองค์ประกอบจำนวน 16 สี ให้เลือกใช้ในการออกแบบและคัดกรองคู่สีที่เป็นมิตรต่อผู้สูงอายุที่เข้ากับคำศัพท์มากที่สุด ตัวอย่างเช่น เลือกสีเหลือง ชื่อรหัสสี p7 ดังรูปที่ 9 ซึ่งเป็นโทนสีร้อน มีความสว่างอยู่ระดับกลาง เมื่อนำไปเทียบกับแผนผัง Color Image Scale ในรูปที่ 8 ตรงกับกลุ่ม Sporty และ Dynamic มากที่สุด และเมื่อเข้าไปดูคำศัพท์ย่อยของกลุ่มดังกล่าว ในกรณีนี้เลือกคำศัพท์ Active สำหรับการใช้งาน ซึ่งมีสีองค์ประกอบ 16 สี ให้เลือกประยุกต์ใช้ในการออกแบบดังรูปที่ 9 และจากสีองค์ประกอบเหล่านี้ ทำให้คัดกรองได้ 3 คู่สีที่เข้ากับคำศัพท์มากที่สุด (กรอบสีเหลี่ยมสีแดง) โดยอาจเลือกคู่สีแรกไปใช้งาน เนื่องจากมีค่า Contrast Ratio สูงที่สุด (เท่ากับ 8.1)



รูปที่ 8. สรุปการแบ่งโทนสีของคู่สีที่เป็นมิตรต่อผู้สูงอายุและแผนผัง Color Image Scale



รูปที่ 9. ตัวอย่างแนวทางการออกแบบคู่สีจากคู่สีที่เป็นมิตรต่อผู้สูงอายุของชุดสี Color Image Scale

#### 4. บทสรุปและการอภิปราย

งานวิจัยนี้ได้ศึกษาเกี่ยวกับการเลือกใช้คู่สีเพื่อการแยกแยะและรับรู้ได้ง่ายของผู้สูงอายุ โดยนำชุดสีจาก Color Image Scale ที่เชื่อมโยงกับ 160 คำศัพท์แสดงภาพลักษณะและอารมณ์ความรู้สึกต่าง ๆ มาทดสอบการมองเห็นคู่สีโดยผู้สูงอายุ และการประมวลผลวิเคราะห์ข้อมูลสี เพื่อให้ข้อเสนอแนะเกี่ยวกับคู่สีที่ควรหลีกเลี่ยง คู่สีที่อ่านได้ และคู่สีที่เป็นมิตรต่อผู้สูงอายุ โดยมีการจัดเรียงคู่สีแนะนำตามโทนสี ความสว่าง ความเข้มสี และอัตราส่วนความคมชัด เพื่อความสะดวกในการประยุกต์ใช้งาน จัดทำแนวทางการออกแบบคู่สีที่ช่วยกระตุ้น สื่อสารอารมณ์ความรู้สึก ที่สามารถมองเห็นแยกแยะได้ง่ายสำหรับผู้สูงอายุ ซึ่งจะช่วยในการออกแบบคู่สีสำหรับสื่อดิจิทัล และการประยุกต์ใช้งานด้านการออกแบบต่าง ๆ เพื่อผู้สูงอายุ โดยในอนาคตการศึกษาเกี่ยวกับผลการนำคู่สีสื่ออารมณ์ที่เป็นมิตรต่อผู้สูงอายุไปปรับปรุงการออกแบบสีในการดำเนินชีวิตจริงของผู้สูงอายุ ก็จะช่วยในการพัฒนาการออกแบบสีในเชิงจิตวิทยา และการรักษาทางจิตใจของผู้สูงอายุ ซึ่งส่งผลต่อสุขภาพทางกาย การรับรู้ทางกายภาพ เช่น อุณหภูมิ รสชาติ ระยะห่าง อีกด้วย

#### กิตติกรรมประกาศ

ขอขอบคุณทุนสนับสนุนการวิจัยจาก Takahashi Industrial and Economic Research Foundation



## เอกสารอ้างอิง

- [1] National Legislative Assembly of Thailand, “Aged Society: National Agenda,” 2018. [Online]. Available: [https://www.senate.go.th/document/Ext17951/17951564\\_0004.PDF](https://www.senate.go.th/document/Ext17951/17951564_0004.PDF) [Accessed Feb. 10, 2022].
- [2] United Nations, Department of Economic and Social Affairs, Population Division, World Population Prospects 2019: Data Booklet (ST/ESA/SER.A/424). 2019. [Online]. Available: [https://population.un.org/wpp/Publications/Files/WPP2019\\_DataBooklet.pdf](https://population.un.org/wpp/Publications/Files/WPP2019_DataBooklet.pdf) [Accessed Feb. 10, 2022].
- [3] L. Pukkhaow, P. Saenprasarn, and K. Huttrungsri, “Developing model of generosity participatory nursing among cataract surgery patients as of Swanson’s theory, Pathum thani hospital,” *Journal of Health Science*, vol. 29, no. 5, pp. 864–875, Sep. - Oct. 2020.
- [4] Japanese Society for Cataract Research. “Cataract self-diagnosis test.” jscr.net. <http://www.jscr.net/ippan/page-010.html> (accessed Jan. 23, 2022). [Accessed Feb. 10, 2022].
- [5] J. Jeawkok, S. Mudadum, and K. Kammaluan, “Family competency in postoperative care of senile cataracts patients,” *Hatyai Academic Journal*, vol. 13, no. 1, pp. 35–45, Jan. - Jun. 2015.
- [6] Suwa Branch of the Youth Committee of the Architects Association of Nagano Prefecture, “Elderly-friendly Color Plan,” 2001. [Online]. Available: <https://www.arcsuwa.com/wp-content/uploads/2020/03/koureisyaniyasii.pdf> [Accessed Feb. 10, 2022].
- [7] Aichi Prefecture, “Universal Design Guidebook for Visual Information,” 2018. [Online]. Available: [https://www.pref.aichi.jp/uploaded/life/283070\\_1021830\\_misc.pdf](https://www.pref.aichi.jp/uploaded/life/283070_1021830_misc.pdf) [Accessed Feb. 10, 2022].
- [8] Fukushima Prefecture, “Color Universal Design Guidebook,” [Online]. Available: <https://www.pref.fukushima.lg.jp/uploaded/attachment/2574.pdf> [Accessed Feb. 10, 2022].
- [9] Tottori Prefecture, “Color Universal Design Guidebook,” [Online]. Available: [https://www.pref.tottori.lg.jp/secure/954753/CDU01\\_CU D20.pdf](https://www.pref.tottori.lg.jp/secure/954753/CDU01_CU D20.pdf) [Accessed Feb. 10, 2022].
- [10] City of Sapporo, “Color Universal Design,” [Online]. Available: [https://www.city.sapporo.jp/koho/color/documents/02\\_honbun1.pdf](https://www.city.sapporo.jp/koho/color/documents/02_honbun1.pdf) [Accessed Feb. 10, 2022].
- [11] Industrial Research Institute of Ishikawa, Kanazawa College of Art, and NPO Corporation Color Universal Design Organization, “Color Universal Design Guideline,” 2009. [Online]. Available: [https://www.iri.jp/staff/home/mmm/cud/090915\\_cudguide.pdf](https://www.iri.jp/staff/home/mmm/cud/090915_cudguide.pdf) [Accessed Feb. 10, 2022].
- [12] I. Kei, “Color universal design : Towards barrier-free design for diverse color visions,” *Journal of Information Processing and Management*, vol. 55, no. 5, pp. 307–317, Aug. 2012.
- [13] Model Color Palette for Color Universal Design Working Committee, “Model Color Palette for Color Universal Design Guide Book,” 2018. [Online]. Available: [https://jfly.uni-koeln.de/colorset/CUD\\_color\\_set\\_GuideBook\\_2018.pdf](https://jfly.uni-koeln.de/colorset/CUD_color_set_GuideBook_2018.pdf) [Accessed Feb. 10, 2022].
- [14] N. Sungvorawongphana, R. Subgranon, P. Punggrassamee, C. Sumngern, and T. Obama, “The color vision of elderly under difference illuminance,” *The Journal of Faculty of Nursing Burapha University*, vol. 23, no. 1, pp. 13–25, Jan. - Mar. 2015.
- [15] N. Tuaycharoen, W. Kornisranukul, and S. Namanee, “The effect of interior lighting on visibility of Thai elderly,” *Academic Journal of Architecture*, vol. 65, pp. 55–74, Jan. - Dec. 2016.
- [16] K. Maki, N. Tanaka, and M. Todome, “The compatibility of legibility and goodliness of color combination,” *Journal of the Color Science Association of Japan*, vol. 29, no.1, pp. 2–13, 2005.

- [17] J. Kawaguchi, S. Shoyama, T. Danno, and Y. Tochihara, “Effect of color discrimination ability and visual acuity in their living environments of the elderly,” *Journal of Human and Living Environment*, vol. 12, no. 1, pp. 21–26, 2005.
- [18] M. Miyamoto, “Color discrimination properties and color image of the elderly and young people,” *Journal of the Color Science Association of Japan*, vol. 30, no. 3, pp. 124–134, 2006.
- [19] S.-M. Gong and W.-Y. Lee, “Colour preference model for elder and younger groups,” *Journal of the International Colour Association*, vol. 18, pp. 33–42, 2017.
- [20] H. Nagumo, *New Color Image Chart*. Tokyo, Japan: Graphic-sha, 2016.
- [21] M. Yamamoto, Y.-H. Lim, N. Aoki, and H. Kobayashi, “On the preferred reproduction of flesh color in Japan and south Korea, investigated for all generation,” *Journal of The Society of Photographic Science and Technology of Japan*, vol. 65, no. 5, pp. 363–368, Sep. 2002.
- [22] World Wide Web Consortium, “Web Content Accessibility Guidelines (WCAG) 2.1,” 2018. [Online]. Available: <https://www.w3.org/TR/WCAG21/>. [Accessed Feb. 10, 2022].

การพัฒนาแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตย  
ประชาชนลาว

**The Development of a Mobile Application to Promote Tourist  
Attractions in LAOS**

นาถิ เอื่องแสงพระจันทร์, ณัฐวุฒิ ศรีวิบูลย์\*, เจษฎา สิงห์ทองชัย และอัจฉรา สุ่มเกษม

*Naly Aeuangsengphachanh, Nattavut Sriwiboon\*, Jatsada Singthongchai and Achara Sumungkaset*

สาขาเทคโนโลยีสารสนเทศและคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยีสุขภาพ

มหาวิทยาลัยกาฬสินธุ์

*Department of Informatics and Computer, Faculty of Science and Health Technology,*

*Kalasin University*

Received: March 06, 2022; Revised: May 22, 2022; Accepted: May 31, 2022; Published: June 29, 2022

**ABSTRACT** –This research aims to design, develop, evaluate performance and study the satisfaction of a mobile application users to promote tourist attractions in LAOS. The population used in this research is a comprehensive group of the experts from information technology perspective and experienced users. There are 15 population this research, selected based on purposive sampling method and there are 100 Users or tourists who use the application, selected based on accidental sampling method. The tools used include (1) a mobile application users to promote tourist attractions in LAOS. (2) Performance Assessment and (3) Satisfaction Questionnaire. The application developed in this work is implemented using a combination of mainstream technologies, i.e., React Naïve Framework, Golang (as API services), and MySQL. The evaluation was performed using a questionnaire method to measure the statistical result, which are frequency distribution, percentage, average, and standard deviation. The results showed show that the application performance in 3 areas included in good level ( $\bar{x}$ = 4.39) is as follows to Capability and accuracy ( $\bar{x}$ = 4.70), Flexibility and ease of use ( $\bar{x}$ = 4.30) and Security ( $\bar{x}$ = 4.16) respectively and application can work smoothly on both Android and iOS operating system.

**KEYWORDS:** Application, Attractions, LAOS, Performance, Satisfaction

บทคัดย่อ -- การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อ ออกแบบ พัฒนา ประเมินประสิทธิภาพ และศึกษาความพึงพอใจของผู้ใช้แอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว ประชากรที่ใช้ในการวิจัยครั้งนี้ ได้แก่ (1) ผู้เชี่ยวชาญด้านเทคโนโลยีสารสนเทศที่มีส่วนในการทดสอบและใช้งานแอปพลิเคชัน จำนวน 15 คน เลือกตัวอย่างแบบเจาะจง (2) ผู้ใช้หรือนักท่องเที่ยวที่ใช้งานแอปพลิเคชัน จำนวน 100 เลือกกลุ่มตัวอย่างแบบบังเอิญ เครื่องมือที่ใช้ ได้แก่ (1) แอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวใน สปป.ลาว (2) แบบประเมินประสิทธิภาพ และ(3) แบบสอบถามความพึงพอใจ การพัฒนาแอปพลิเคชันในงานวิจัยนี้พัฒนาด้วย React Native เป็นเฟรมเวิร์ก และ Golang พัฒนาเป็น API เพื่อเป็นส่วนต่อประสานงานการจัดการข้อมูลในแอปพลิเคชันกับฐานข้อมูล MySQLวิเคราะห์ข้อมูลโดยการแจกแจงความถี่ ร้อยละ ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน ผลการวิจัยพบว่า ประสิทธิภาพของแอปพลิเคชันใน 3 ด้านโดยรวมอยู่ในระดับดี ( $\bar{X}$ = 4.39) ได้แก่ ด้านความสามารถและความถูกต้อง ( $\bar{X}$ = 4.70) ด้านความยืดหยุ่นและง่ายในการใช้งาน ( $\bar{X}$ = 4.30) ด้านการรักษาความปลอดภัย ( $\bar{X}$ = 4.16) และที่สำคัญการพัฒนาแอปพลิเคชันครั้งนี้สามารถแสดงผลการทำงานได้ทั้งระบบ Android และ iOS

คำสำคัญ: แอปพลิเคชัน, แหล่งท่องเที่ยว, สปป.ลาว, ประสิทธิภาพ, ความพึงพอใจ

\*Corresponding Author:nattavut.sri@gmail.com

## 1. บทนำ

เอเชียใต้เป็นภูมิภาคที่มีการเติบโตทางเศรษฐกิจการท่องเที่ยวอย่างต่อเนื่อง ซึ่งประเทศอินเดียมีเศรษฐกิจการท่องเที่ยวใหญ่ที่สุดในภูมิภาค และอีกหนึ่งประเทศในภูมิภาคเอเชียใต้ที่ได้รับคามนิยมนักท่องเที่ยว คือ สาธารณรัฐประชาธิปไตยประชาชนลาว เนื่องจากเป็นจุดศูนย์กลางทางผ่านและจุดเชื่อมต่อของภาคพื้นลุ่มน้ำโขง “เอเชียอาคเนย์” และที่สำคัญ สปป.ลาวมีเสถียรภาพทางการเมืองที่มั่นคง มีสันติภาพและมีการร่วมมือที่ดีกับประเทศในภาคพื้นลุ่มน้ำโขง และประเทศอื่น ๆ ในโลก ประกอบกับเป็นประเทศที่มีประวัติศาสตร์เก่าแก่ด้านความสวยงามทั้งทางธรรมชาติและวัฒนธรรมที่หลากหลาย ประชาชนมีอุปนิสัยเป็นมิตรและมีน้ำใจ ซึ่งสิ่งเหล่านี้เป็นปัจจัยสำคัญในการดึงดูดนักท่องเที่ยวใน สปป.ลาว

สาธารณรัฐประชาธิปไตยประชาชนลาว (สปป.ลาว) มีนโยบายและให้ความสำคัญอันดับแรก คือการพัฒนาและส่งเสริมการท่องเที่ยวให้เกิดเป็นศูนย์กลางการท่องเที่ยวในเอเชียตะวันออกเฉียงใต้ ซึ่งจะเห็นได้จากจำนวนนักท่องเที่ยวทั้งชาวต่างประเทศเดินทางเข้า สปป.ลาว ในแต่ละปีมีจำนวนเพิ่มขึ้นอย่างต่อเนื่อง กล่าวคือจำนวนนักท่องเที่ยวในปี 2008 (พ.ศ. 2551) มีจำนวน 1,736,787 คน ปี 2010 (พ.ศ.2553) มีจำนวนนักท่องเที่ยว 2,513,028 คน ในปี 2017 (พ.ศ.2560) มีจำนวนนักท่องเที่ยว 3,868,838 คน และในปี 2018 (พ.ศ.2561) มีจำนวนนักท่องเที่ยวถึง 4,186,432 คน ตามลำดับ ซึ่ง นายลัดตะนะไต หลวงลาฉบับคิด ผู้เชี่ยวชาญของ ADB ประจำ สปป.ลาว ได้กล่าวว่าการท่องเที่ยวถือเป็นปัจจัยสำคัญของการเติบโตทางเศรษฐกิจของ สปป.ลาว โดย สปป.ลาวมีศักยภาพด้านการท่องเที่ยวทางธรรมชาติ วัฒนธรรม และประวัติศาสตร์ จึงจำเป็นต้องพัฒนาโครงสร้างพื้นฐาน ทำการรณรงค์ด้านการท่องเที่ยว และจัดระเบียบค่าธรรมเนียมเข้าชมสถานที่ท่องเที่ยว อาทิ การสร้างถนนไปยังแหล่งท่องเที่ยว เพื่อความสะดวกในการเดินทาง การสร้างสิ่งอำนวยความสะดวก ขันพื้นฐาน และการเก็บค่าธรรมเนียมเข้าชมสถานที่ควรเก็บครั้งเดียว และสิ่งสำคัญที่สุด คือ รัฐบาลจำเป็นต้องจัดทำกรรณรังค์ด้านการท่องเที่ยวผ่านสื่อโทรทัศน์ที่เป็นที่นิยมในระดับสากล เช่น BBC หรือสื่ออื่น ๆ ที่มีผู้ชมหลายล้านคน อย่างไรก็ตาม รัฐบาล สปป.ลาวได้ทำงานร่วมกับภาคส่วนที่เกี่ยวข้องเพื่อส่งเสริมการท่องเที่ยว โดยในปี 2562 ได้เปิดตัวกิจกรรม Visit Laos – China

Year 2019 โดยมีเป้าหมายเพื่อดึงดูดนักท่องเที่ยวจีน 1 ล้านคน และนักท่องเที่ยวชาติอื่น ๆ รวมประมาณ 4.5 ล้านคน[1]

ปัจจุบันเทคโนโลยีการสื่อสารในปัจจุบันมีความก้าวหน้าไปอย่างมาก ก่อให้เกิดการพัฒนาต่อ ยอดทางเทคโนโลยีอีกทั้งการที่ประเทศไทยเข้าสู่ยุคเครือข่าย 5G ทำให้การใช้อินเตอร์เน็ตในรูปแบบ Mobile Device เป็นเรื่องที่สะดวกสบายมากขึ้น ผู้บริโภคสามารถเข้าถึงข้อมูลข่าวสาร สารสนเทศ ได้รวดเร็ว ผู้บริโภคสามารถใช้เทคโนโลยีได้ตามวิถีชีวิต การใช้เครื่องมือสื่อสารและ คอมพิวเตอร์สามารถใช้ได้ทุกที่ ทำให้เอื้อประโยชน์ต่อการใช้งานและการที่สังคมออนไลน์เข้ามามีบทบาทในการดำเนินชีวิตมากขึ้นทำให้วิถีการดำเนินชีวิตเปลี่ยนไปจากอดีตอย่างเห็นได้ชัด นับตั้งแต่ปี พ.ศ. 2551 ที่ทั้งโลกเริ่มรู้จัก Smart Phone ซึ่งปัจจุบัน Smart Phone เป็นธุรกิจที่มีการแข่งขันที่สูง เนื่องจากสามารถเข้าถึงผู้ใช้ทุกเพศทุกวัย มีการพัฒนาต่อยอดจนเกิดระบบปฏิบัติการใหม่ ๆ เพิ่มขึ้น เช่น Android และ iOS ทำให้เกิดการพัฒนาคือยอดเทคโนโลยีพัฒนาให้สามารถรองรับการใช้งานบน Smart Phone และการตลาดแบบ Mobile Marketing เป็นการตลาดที่สามารถเข้าถึงกลุ่มเป้าหมายโดยตรง และสามารถวัดผลได้รวดเร็ว รวมทั้งเป็นรูปแบบที่ใช้ต้นทุนทางการตลาดต่ำ และได้รับความสนใจจากกลุ่มเป้าหมายสูง

จากความสำคัญที่กล่าวมาข้างต้นผู้วิจัยเป็นประชาชนคนหนึ่งของ สปป.ลาว ที่ได้เข้ามาศึกษาต่อในประเทศไทย หลักสูตรเทคโนโลยีสารสนเทศและดิจิทัลคณะวิทยาศาสตร์และเทคโนโลยีสุขภาพ มหาวิทยาลัยกาฬสินธุ์ มีภูมิสำเนาในเมืองคำ แขวงเชียงขวาง สาธารณรัฐประชาธิปไตยประชาชนลาว ได้เล็งเห็นถึงความสำคัญที่ต้องการเป็นส่วนหนึ่งในการพัฒนาประเทศและมีความสนใจในแนวคิดการพัฒนาแอปพลิเคชันบนสมาร์ตโฟนเพื่อส่งเสริมแหล่งท่องเที่ยวสำคัญ ๆ ที่เป็นมรดกส่นของ สปป.ลาว ทั้งที่เป็นทรัพยากรธรรมชาติ วัฒนธรรม สถานที่ท่องเที่ยวที่เป็นอัตลักษณ์ที่โดดเด่นของประเทศให้มีความน่าสนใจ ผู้ใช้สามารถเข้าถึงข้อมูลสถานที่ท่องเที่ยวได้รวดเร็ว ถูกต้อง และแม่นยำ อีกทั้งเป็นการตอบสนองนโยบายของ สปป.ลาว ในด้านการท่องเที่ยว โดยมีการนำเสนอ ส่งเสริม ประชาสัมพันธ์ด้วยเทคโนโลยีสมัยใหม่มาประยุกต์ใช้ให้เกิดความน่าสนใจยิ่งขึ้น และประเทศมั่งคั่งต่อไป

## 2. วัตถุประสงค์การวิจัย

2.1 เพื่อออกแบบและพัฒนาแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว

2.2 เพื่อประเมินประสิทธิภาพของแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว

## 3. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

C. Xaiyavohan [2] ได้กล่าวถึงภาพรวมและสภาพทั่วไปของสาธารณรัฐประชาธิปไตยประชาชนลาวไว้ว่า สปป.ลาว เป็นประเทศเพื่อนบ้านที่ใกล้ชิดกับไทยทั้งในเชิงประวัติศาสตร์ ที่ตั้งทางภูมิศาสตร์ เชื้อชาติ ศาสนา ภาษา และวัฒนธรรม มีเขตแดนติดต่อกับไทยทั้งทางบกและทางน้ำเป็นแนวยาวถึง 1,810 กิโลเมตร สปป.ลาวเป็นประเทศที่ไม่มีทางออกทางทะเล แต่สามารถเป็นจุดเชื่อมต่อ (land link) ด้านการคมนาคมขนส่งจากไทย ไปประเทศที่สามในอนุภูมิภาค ผ่านสะพานมิตรภาพไทย-ลาว ข้ามแม่น้ำโขงทั้ง 4 แห่ง ได้แก่หนองคาย-เวียงจันทน์(8 เมษายน 2537) มุกดาหาร-สะหวันนะเขต(20 ธันวาคม 2549) นครพนม-คำม่วน(11 พฤศจิกายน 2554) เชียงราย-บ่อแก้ว (11 ธันวาคม 2556) และในอนาคตอันใกล้จะมีสะพานแห่งที่ 5 ที่บึงกาฬ-บอลิคำไซ และแห่งที่ 6 ที่อุบลราชธานี-สาละวัน ซึ่ง สปป.ลาวมีรายได้จากทรัพยากรธรรมชาติที่อุดมสมบูรณ์ โดยเฉพาะป่าไม้และแร่ธาตุ เช่น ทองคำ ทองแดง และบ็อกไซต์ จุดเด่นของสปป.ลาว คือ ธรรมชาติที่ยังบริสุทธิ์และวัฒนธรรมประเพณี สถานที่ท่องเที่ยวที่สำคัญ เช่น พระธาตุหลวง ปะตูไซ ในนครหลวงเวียงจันทน์ บูลู ลาถุน วังเวียง และ น้ำตกตาดหลวงสี หลวงพระบาง เป็นต้น

React Native เป็นเฟรมเวิร์กที่ได้รับความนิยมมากในปัจจุบันที่สามารถสร้างลำดับชั้นของส่วนประกอบ UI เพื่อสร้างรหัส JavaScript มีชุดส่วนประกอบสำหรับแสดงผลบนระบบปฏิบัติการใน iOS และ Android เพื่อสร้างแอปพลิเคชันมือถือที่มีรูปลักษณ์และความรู้สึก นอกจากนี้ยังมี ReactJS เป็นไลบรารี JavaScript แบบโอเพ่นซอร์สเพื่อสร้างส่วนต่อประสานผู้ใช้ได้อย่างสะดวก จึงเป็นเหตุผลสำคัญที่บริษัท ยักษ์ใหญ่ออย่าง Facebook, Instagram, Skype, Airbnb, Tesla, Walmart, Baidu Mobile, Bloomberg, UberEATS Vogue และอีกมากมายได้เปลี่ยนเป้าหมายมาใช้ในการพัฒนาแบบ Cross Platform[3]

การศึกษาประสิทธิภาพระบบเทคโนโลยีสารสนเทศ หรือแอปพลิเคชันที่พัฒนาขึ้น ปัจจุบันนิยมใช้การวัดจากความสามารถในการใช้งานของระบบหรือคุณสมบัติของระบบนั้น ๆ โดยใช้ผู้เชี่ยวชาญเฉพาะด้านการประเมิน 5 ด้าน [4] ได้แก่ (1) การประเมินความสามารถ (Functional Requirement Test) (2) การประเมินความถูกต้อง (Functional Test) (3) การประเมินความยืดหยุ่น ง่ายต่อการใช้งาน (Usability Test) (4) การประเมินประสิทธิภาพ (Performance Test) และ (5) การประเมินด้านการรักษาความปลอดภัย (Security Test) ซึ่ง J. Nielsen และ L. Mack[5] ได้กล่าวว่าจำนวนของผู้เชี่ยวชาญที่เหมาะสมสำหรับการประเมินประสิทธิภาพระบบ คือ 15 คน

ความพึงพอใจ (ต่อแหล่งท่องเที่ยว) คือ ความรู้สึกหรือทัศนคติของบุคคลต่อสิ่งใดสิ่งหนึ่ง โดยอาจเป็นไปในเชิงประเมินค่าความรู้สึกหรือทัศนคตินั้นเป็นไปในทางบวกหรือทางลบ ซึ่งความพึงพอใจอาจเปลี่ยนแปลงไปได้ตามกาลเวลา และสถานการณ์แวดล้อมอื่น ๆ ที่เปลี่ยนแปลงไป [2] ได้อธิบายไว้ว่าบุคคลใช้การค้นหาเป้าหมายของชีวิต โดยที่มีความจำเป็น ความปรารถนา และความอยากได้รับสิ่งที่มีความหมายต่อตนเองเพื่อให้เกิดความพึงพอใจ ซึ่งมนุษย์เป็นสัตว์ที่มีความต้องการ เป็นการยากที่จะไปถึงจุดที่เกิดความพึงพอใจอย่างสมบูรณ์ เนื่องจากว่าเมื่อบุคคลได้รับความพึงพอใจในสิ่งหนึ่งแล้ว ก็ยังเรียกร้องความพึงพอใจอื่นต่อไปไม่จบสิ้น นอกจากนี้ [6] ได้อธิบายความพึงพอใจโดยใช้ทฤษฎีความคาดหวัง (Expectancy theory) บุคคลแต่ละคนจะแสดงพฤติกรรมก็ต่อเมื่อเขามองเห็นโอกาสความน่าจะเป็นไปได้ค่อยข้างชัดเจน หากความพึงพอใจของบุคคลนั้นเกิดจากการให้บริการที่คุณภาพ บุคคลนั้นก็จะใช้เข้าใช้บริการ เพราะตรงกับความต้องการและผลลัพธ์ที่บุคคลนั้นปรารถนา ดังนั้น ความพึงพอใจ (ต่อแหล่งท่องเที่ยว) เกิดจากที่บุคคลนั้นได้ชื่นชม สภาพแวดล้อม การรับรู้ข้อมูลที่ครบถ้วนสมบูรณ์ รวดเร็ว ถูกต้องของแหล่งท่องเที่ยว นั้นมากกว่า ซึ่งงานวิจัยนี้ได้มีการนำเสนอข้อมูลแหล่งท่องเที่ยวบน สมาร์ทโฟน อุปกรณ์เคลื่อนที่ เช่น แท็บเล็ต แสดงผลผ่านระบบปฏิบัติการ Android และ iOS เพื่อให้ผู้ใช้งานได้รับข้อมูลที่สะดวก รวดเร็ว ถูกต้องและส่งผลกระทบต่อความพึงพอใจของผู้ใช้

#### 4. ขอบเขตของการวิจัย

4.1 ประชากรและกลุ่มตัวอย่าง ได้แก่ (1) ผู้เชี่ยวชาญด้านเทคโนโลยีสารสนเทศที่มีส่วนในการทดสอบ และใช้งานแอปพลิเคชันที่พัฒนาขึ้น จำนวน 15 คน [5] โดยการเลือกใช้กลุ่มตัวอย่างแบบเจาะจง (Purposive Sampling) (2) ผู้ใช้หรือนักท่องเที่ยวที่ใช้งานแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาวที่ผู้วิจัยพัฒนาขึ้น จำนวน 100 คน ซึ่งกำหนดกลุ่มตัวอย่างจากการเปิดตาราง ทาโร ยามาเน่ โดยการเลือกกลุ่มตัวอย่างแบบบังเอิญ (Accidental Sampling)

4.2 ตัวแปรที่วิจัย ได้แก่ 1) ตัวแปรต้น คือ แอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว 2) ตัวแปรตาม คือ ประสิทธิภาพของส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว และความพึงพอใจของประชาชนหรือนักท่องเที่ยวที่มีต่อการใช้งานแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว

4.3 ขอบเขตการวิจัย การวิจัยครั้งนี้ได้ศึกษาแหล่งท่องเที่ยวที่สำคัญอันเป็นมนต์เสน่ห์ของ สปป.ลาว

เมื่อนักท่องเที่ยวไปเยือนที่ สปป.ลาวไม่ควรพลาด มี 15 สถานที่สวยที่สุด ได้แก่ (1) หอพระแก้ว เวียงจันทน์ (2) พระธาตุหลวง นครหลวงเวียงจันทน์ (3) ปะดู่ไซ หรือ ประตูล้านหลวงเวียงจันทน์ (4) หุ่นไหหิน เชียงขวาง (5) พระราชวังหลวงพระบาง (6) วัดเชียงทอง หลวงพระบาง (7) น้ำตกตาดแก้วสีหลวงพระบาง (8) น้ำตกตาดแก้ว หลวงพระบาง (9) บ้านดั้นไม้ที่สูงที่สุดในโลก เขตรักษาพันธุ์ธรรมชาติบ่อแก้ว (10) ถ้ำกองลอ ท่าแขก (11) ปราสาทหินวัดพู แขวงจำปาสัก (12) ลีพันดอน หมู่เกาะตอนใต้ของลาว (13) บลูลาถุน วังเวียง (14) สะพานสิม วังเวียง (15) ถ้ำจิง วังเวียง

#### 5. วิธีดำเนินการวิจัย

การวิจัยนี้เป็นการวิจัยที่ผสมผสานการวิจัยแบบมีส่วนร่วมกับการวิจัยเชิงพัฒนา ซึ่งประยุกต์ขั้นตอนการวิจัยจากวงจรพัฒนาระบบ (System Development Life Cycle: SDLC) มีวิธีการดำเนินการวิจัยดังนี้

5.1 การศึกษาปัญหาและบริบทแหล่งท่องเที่ยวที่ จำนวน 15 แหล่ง โดยรวบรวมข้อมูลสังเคราะห์เกี่ยวกับสาระต่าง ๆ ของ

แหล่งท่องเที่ยว เช่น เนื้อหาสาระสำคัญ ความเป็นมา พิกัด ที่พัก ร้านอาหาร และศึกษาเทคโนโลยีรีแอคทีฟ เนทีฟ (React Native) และภาษา Go (Golang) เพื่อนำมาวิเคราะห์ออกแบบพัฒนาแอปพลิเคชัน ตลอดจนการศึกษาถึงเอกสารงานวิจัยที่เกี่ยวข้องกับการพัฒนาแอปพลิเคชันในปัจจุบัน และทำการปฏิบัติการเก็บข้อมูลภาคสนามที่เกี่ยวข้องกับแหล่งท่องเที่ยว

5.2 วิเคราะห์และออกแบบแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว ผู้วิจัยได้ดำเนินการวิเคราะห์และออกแบบแผนภาพที่ใช้แสดง Class และความสัมพันธ์ในแง่ต่าง ๆ (Relation) ระหว่าง Class เหล่านั้น ซึ่งงานวิจัยนี้ใช้ UML (Unified Modelling Language) เป็นตัวอธิบายการทำงาน โดยแบ่งเป็น 3 ส่วนคือ Use Case Diagram, Activity Diagram, Class Diagram และออกแบบ E-R Diagram, Data Table Description, Input Design และ Output Design

5.3 การพัฒนาและทดสอบแอปพลิเคชัน สำหรับงานวิจัยนี้ได้พัฒนาโดยใช้ React Native ที่สามารถแสดงผลได้ทั้งระบบปฏิบัติการ iOS และ Android และหลังบ้าน หรือ Black End พัฒนาด้วยภาษา Go (Golang) เพื่อใช้เป็น API ทำหน้าที่เป็นส่วนต่อประสานงานการจัดการข้อมูลภายในแอปพลิเคชันกับฐานข้อมูล MySQL

5.4 ทดสอบแอปพลิเคชันได้โดยวิธี export app.apk file และติดตั้งบนเครื่องบนระบบปฏิบัติการ Android และ iOS ทดลองใช้กับกลุ่มตัวอย่างโดยให้ผู้เชี่ยวชาญประเมินประสิทธิภาพของแอปพลิเคชัน พร้อมปรับปรุงแก้ไขตามคำแนะนำ ซึ่งการประเมินความสามารถของแอปพลิเคชันที่พัฒนาขึ้น ผู้วิจัยได้ทำการสร้างแบบประเมินที่ใช้ในการวิจัยครั้งนี้ ดังนี้

5.4.1 สร้างแบบประเมินซึ่งเป็นแบบสอบถาม (Questionnaire) แบ่งออกเป็น 2 ตอน ดังนี้

ตอนที่ 1 ข้อมูลทั่วไปของผู้ตอบแบบสอบถาม ลักษณะแบบสอบถามเป็นแบบตรวจสอบรายการ (Checklist) จำนวน 2 ข้อ ประกอบด้วย เพศ และ ระดับการศึกษา

ตอนที่ 2 ความคิดเห็นเกี่ยวกับความสามารถของแอปพลิเคชัน ลักษณะแบบสอบถามเป็นแบบมาตราส่วนประมาณค่า (Rating Scale) จำนวน 15 ข้อ โดยมีเกณฑ์การให้คะแนนตามวิธีการของ ลิเคอร์ท (Likert) มี 5 ระดับ [7] ซึ่งงานวิจัยนี้ประเมินประสิทธิภาพของแอปพลิเคชันใน 3 ด้าน โดยประยุกต์



การประเมินมาจากงานวิจัย [4] ได้แก่ 1) ด้านความสามารถและถูกต้อง จำนวน 6 ข้อ 2) ด้านความยืดหยุ่นและง่ายต่อการใช้งาน จำนวน 4 ข้อ 3) ด้านความปลอดภัย จำนวน 3 ข้อ

5.4.2 นำแบบประเมินที่สร้างขึ้นเสนอต่อผู้เชี่ยวชาญตรวจสอบความสอดคล้องระหว่างข้อคำถามกับจุดประสงค์ของการประเมิน โดยประเมินค่าดัชนีความสอดคล้อง (Item-Objective Congruence Index: IOC) จำนวน 5 ท่าน

5.4.3 วิเคราะห์ข้อมูลการหาค่าดัชนี ความสอดคล้องระหว่างข้อคำถามของแบบประเมินกับจุดประสงค์ในการประเมินความสามารถของแอปพลิเคชัน ค่าเฉลี่ยอยู่ระหว่าง 0.67-1.00 จากนั้นนำไปให้ผู้เชี่ยวชาญทำการประเมินประสิทธิภาพแอปพลิเคชันที่พัฒนาขึ้น จำนวน 15 คน

5.4.4 ผู้วิจัยนำแบบประเมินประสิทธิภาพของแอปพลิเคชันที่พัฒนาขึ้นที่ได้จากผู้เชี่ยวชาญ จำนวน 15 คน มาวิเคราะห์ระดับความเหมาะสมโดยใช้สถิติค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐาน และสำหรับการวิเคราะห์จะใช้ค่าเฉลี่ยเทียบกับเกณฑ์การประเมินใน [7] คือ 4.51-5.00, 3.51-4.50, 2.51-3.00, 1.51-2.50, 1.00-1.50 หมายถึง แอปพลิเคชันมีความสามารถอยู่ในระดับดีมาก ดี ปานกลาง น้อย และน้อยที่สุด ตามลำดับ

5.5 อัปโหลดแอปพลิเคชันบน App store เพื่อติดตั้งบนระบบปฏิบัติการ iOS และ Play store เพื่อติดตั้งบนระบบปฏิบัติการ Android

5.6 ให้ผู้ใช้หรือนักท่องเที่ยวโหลดทดลองใช้แอปพลิเคชันโดยการสแกนบาร์โค้ด และประเมินความพึงพอใจที่มีต่อแอปพลิเคชันที่พัฒนาขึ้น ซึ่งการสร้างและหาประสิทธิภาพแบบสอบถามความพึงพอใจ ดังนี้

5.6.1 ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้องกับการสร้างแบบสอบถามความพึงพอใจและวิธีการสร้างแบบประเมินจากหนังสือการศึกษาเบื้องต้น และหนังสือการวัดผลและประเมินผลการศึกษา และกำหนดกรอบที่จะประเมิน โดยแบ่งประเด็นที่จะประเมิน จำนวน 15 ข้อ แล้วคัดเลือกเอาข้อคำถาม 10 ข้อ

5.6.2 สร้างแบบสอบถามความพึงพอใจเป็นแบบประเมินมาตราส่วนประมาณค่า (Rating Scale) ตามวิธีการของลิเคิร์ต (Likert) ซึ่งมี 5 ระดับ โดยใช้เกณฑ์ใน [7] จากนั้นนำแบบสอบถามความพึงพอใจเสนอผู้เชี่ยวชาญ 5 ท่าน เพื่อประเมินตรวจสอบความถูกต้อง


5.6.3 วิเคราะห์ข้อมูลการหาค่าดัชนีความสอดคล้องระหว่างข้อคำถามกับพฤติกรรมความเห็น (IOC) ซึ่งมีเกณฑ์การเลือกค่า IOC รายข้อ ตั้งแต่ 0.60 ขึ้นไป โดย IOC อยู่ระหว่าง 0.67-1.00 ขึ้นไป จากนั้นนำแบบสอบถามความพึงพอใจไปทดลอง (Try-out) กับกลุ่มตัวอย่างที่ 2 จำนวน 30 คน ที่ไม่ใช่กลุ่มตัวอย่าง

5.6.4 นำผลที่ได้จากแบบสอบถามความพึงพอใจมาหาความเที่ยงโดยวิธีสัมประสิทธิ์อัลฟาของครอนบาค ได้ค่าความสัมประสิทธิ์ความเที่ยง เท่ากับ 0.886 จากนั้นจัดพิมพ์แบบสอบถามความพึงพอใจเป็นฉบับสมบูรณ์ และทำการเก็บรวบรวมแบบสอบถามที่ตอบเสร็จเรียบร้อยแล้ว และตรวจสอบความสมบูรณ์ของการตอบแบบสอบถาม

## 6. ผลการวิจัย

### 6.1 ผลการวิเคราะห์ ออกแบบ และพัฒนาแอปพลิเคชัน

6.1.1 Use Case Diagram ของการพัฒนาแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว ดังภาพที่ 1



รูปที่ 1. Use Case Diagram ของแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวใน สปป.ลาว

จากภาพที่ 1 ผู้ใช้งานทั่วไปสามารถเข้าใช้งานแอปพลิเคชันดูเนื้อหาข้อมูลแหล่งท่องเที่ยวใน สปป.ลาว ได้ และจะได้รับข้อมูลเกี่ยวกับ เนื้อหาของแหล่งท่องเที่ยว นั้น ๆ ตำแหน่งที่พัก แหล่งท่องเที่ยว ร้านอาหาร และที่พักบริเวณใกล้เคียงกับแหล่งท่องเที่ยว นั้น ๆ ได้ สำหรับผู้ดูแลระบบสามารถเข้าไปจัดการข้อมูลต่าง ๆ ได้แก่ การจัดการข้อมูลสิทธิ์การเข้าถึง จัดการข้อมูลแหล่งท่องเที่ยว การจัดการข้อมูลตำแหน่ง ที่พัก จัดการ


ข้อมูลร้านอาหาร และจัดการข้อมูลที่พัก ซึ่งการเข้าไปจัดการข้อมูลดังกล่าวผู้ดูแลระบบต้องมีการยืนยันตัวตนทุกครั้ง

### 6.1.2 ผลการพัฒนาแอปพลิเคชัน

ผลการพัฒนาแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว เมื่อนักท่องเที่ยวไปยื่นหรือเที่ยวที่ สปป.ลาว แหล่งท่องเที่ยว 15 แห่งที่ทุกคนสักครั้งต้องไป สัมผัสได้ โดยผู้วิจัยได้ทดสอบแอปพลิเคชันด้วยวิธี export app.apk file และติดตั้งบนเครื่องระบบปฏิบัติการ Android และ iOS ในชื่อว่า “มนต์เสน่ห์เมืองลาว” ปรากฏหน้าต่างดังภาพที่ 2-3



รูปที่ 2. ไอคอนและตัวอย่างแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวใน สปป.ลาว




รูปที่ 3. ตัวอย่างแอปพลิเคชันที่นำเสนอข้อมูล และแสดงตำแหน่งพิกัดแหล่งท่องเที่ยวใน สปป.ลาว

## 6.2 ผลการประเมินประสิทธิภาพ

6.2.1 ผลการวิเคราะห์ประเมินประสิทธิภาพ ซึ่งผู้วิจัยได้ทำการประเมินความสามารถของแอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวใน สปป.ลาว จากผู้เชี่ยวชาญ 15 ท่าน จากข้อมูลพื้นฐานของผู้ประเมิน พบว่า ส่วนใหญ่เป็นเพศชาย (ร้อยละ 66.67) ระดับการศึกษาปริญญาโท (ร้อยละ 60.00) รองลงมา

ปริญญาเอก (ร้อยละ 40.00) ประสิทธิภาพโดยรวมของแอปพลิเคชันที่พัฒนาขึ้น แสดงดังภาพที่ 4



รูปที่ 4. ประสิทธิภาพของแอปพลิเคชัน

จากภาพที่ 4 ประสิทธิภาพของแอปพลิเคชันโดยรวม อยู่ในระดับดี ( $\bar{X} = 4.39$ ) เมื่อพิจารณาเป็นรายด้านอยู่ในระดับดีจำนวน 3 ด้าน โดยเรียงลำดับค่าเฉลี่ยจากมากไปหาน้อย ดังนี้ ด้านความสามารถและความถูกต้อง ( $\bar{X} = 4.70$ ) ด้านความยืดหยุ่นและง่ายในการใช้งาน ( $\bar{X} = 4.30$ ) และ ด้านการรักษาความปลอดภัย ( $\bar{X} = 4.16$ )

ผู้เชี่ยวชาญมีความคิดเห็นเกี่ยวกับความสามารถของแอปพลิเคชันทั้ง 3 ด้าน ดังนี้

1) ด้านความสามารถ และถูกต้อง แอปพลิเคชันมีประสิทธิภาพโดยรวมอยู่ในระดับดีมาก ( $\bar{X} = 4.70$ ) โดยเรียงลำดับค่าเฉลี่ยจากมาก ไปหาน้อย 3 ลำดับแรก ดังนี้ การแสดงข้อมูลแหล่งท่องเที่ยวถูกต้อง และรวดเร็ว ( $\bar{X} = 4.92$ ) การค้นหาข้อมูลแหล่งท่องเที่ยวได้ถูกต้อง รวดเร็ว ( $\bar{X} = 4.80$ ) และการเข้าถึงตำแหน่งสถานที่ท่องเที่ยวได้อย่างถูกต้อง ( $\bar{X} = 4.73$ )

2) ด้านความยืดหยุ่นและง่ายในการใช้งาน แอปพลิเคชันมีประสิทธิภาพโดยรวมอยู่ในระดับดีมาก ( $\bar{X} = 4.30$ ) โดยเรียงลำดับค่าเฉลี่ยจากมาก ไปหาน้อย 3 ลำดับแรก ดังนี้ การใช้งานระบบมีความสะดวก และง่ายต่อการใช้งานแอปพลิเคชัน ( $\bar{X} = 4.72$ ) การเชื่อมโยงข้อมูล และการแสดงข้อมูลมีความเหมาะสม ( $\bar{X} = 4.31$ ) และขนาดของสีและตัวอักษรมีความเหมาะสมในการนำเสนอ ( $\bar{X} = 4.17$ )

3) ด้านความปลอดภัย แอปพลิเคชันมีประสิทธิภาพโดยรวมอยู่ในระดับดีมาก ( $\bar{X} = 4.16$ ) โดยเรียงลำดับค่าเฉลี่ยจากมาก ไปหาน้อย 3 ลำดับแรก ดังนี้ การตรวจสอบสิทธิ์หรือระบุตัวตน ( $\bar{X} = 4.19$ ) การติดตามตัวตนของสิทธิ์ผู้ดูแลระบบเข้าใช้งาน ( $\bar{X} = 4.17$ ) การป้องกันการสัมผัสของข้อมูล ( $\bar{X} = 4.11$ )

6.2.2 ผลการประเมินความพึงพอใจของนักท่องเที่ยวที่มีต่อการใช้งานแอปพลิเคชันที่พัฒนาขึ้น พบว่า ผู้ใช้มีความพึงพอใจต่อแอปพลิเคชันโดยรวมอยู่ในระดับมาก โดยรวมอยู่ในระดับมาก ( $\bar{X}=3.97$ ) โดยเรียงลำดับค่าเฉลี่ยจากมากไปหาน้อย 3 ลำดับแรก ดังนี้ เมนูต่าง ๆ ในแอปพลิเคชันใช้งานและสื่อสารเข้าใจง่าย ( $\bar{X}=4.60$ ) ภาษาที่ใช้มีความถูกต้อง สามารถสื่อความเข้าใจได้ถูกต้อง ( $\bar{X}=4.23$ ) และแอปพลิเคชันมีการออกแบบนำเสนอเนื้อหา สวยงาม และน่าดึงดูดใจ ( $\bar{X}=4.18$ )

## 7. อภิปรายผลการวิจัยและข้อเสนอแนะ

แอปพลิเคชันส่งเสริมแหล่งท่องเที่ยวในสาธารณรัฐประชาธิปไตยประชาชนลาว ครั้งนี้ผู้วิจัยได้ศึกษา รวบรวม และเก็บข้อมูลแหล่งท่องเที่ยวที่เป็นมนต์เสน่ห์ของ สปป.ลาว เพื่อนำมาวิเคราะห์ ออกแบบ พัฒนาแอปพลิเคชันด้วยเทคโนโลยีที่นิยมใช้ในปัจจุบันได้แก่ เนทีฟ (React Native) และภาษา Go (Golang) ผลการประเมินประสิทธิภาพของผู้เชี่ยวชาญ 3 ด้านพบว่า แอปพลิเคชันมีประสิทธิภาพโดยรวมอยู่ในระดับดี ได้แก่ (1) ด้านความสามารถ และถูกต้อง อยู่ในระดับดีมาก (2) ด้านความยืดหยุ่นและง่ายในการใช้งาน และ (3) ด้านความปลอดภัยอยู่ในระดับดี และผลการประเมินความพึงพอใจของผู้ใช้หรือนักท่องเที่ยวที่มีต่อแอปพลิเคชันอยู่ในระดับมาก สอดคล้องกับการศึกษาในงานวิจัยของ J. Tantai[8] ที่เป็นเช่นนี้อาจเป็นเพราะผู้วิจัยได้ศึกษาวิธีดำเนินการสร้างและหาประสิทธิภาพเครื่องมือที่เหมาะสม และดำเนินการวิจัยให้มีระเบียบแบบแผน โดยประยุกต์ขั้นตอนการวิจัยจากวงจรการพัฒนาระบบ (System Development Life Cycle: SDLC) สอดคล้องกับการการวิจัยของ[9]ได้พัฒนาแอปพลิเคชันสำหรับอุตสาหกรรมท่องเที่ยวจังหวัดสุรินทร์ พบว่าแอปพลิเคชันมีประสิทธิภาพร้อยละ 96 นอกจากนี้ผู้ใช้งานยังมีความพึงใจในแอปพลิเคชันอุตสาหกรรมท่องเที่ยวจังหวัดสุรินทร์ โดยรวมทั้ง 4 ด้าน อยู่ในระดับมากที่สุด คือ ด้านการทำงานของแอปพลิเคชัน ด้านความทันสมัยของแอปพลิเคชัน ด้านกราฟิกของแอปพลิเคชัน และด้านสิ่งอำนวยความสะดวกของแอปพลิเคชัน และตอบสนองการใช้งานของนักท่องเที่ยวได้เป็นอย่างดี นอกจากนี้ยังสอดคล้องกับงานวิจัย [10-11] ได้พัฒนาโมบายแอปพลิเคชันส่งเสริมการท่องเที่ยวชุมชนอำเภอเมือง จังหวัดกำแพงเพชร การประเมินประสิทธิภาพในภาพรวมของผู้ใช้งานต่อ

แอปพลิเคชันส่งเสริมการท่องเที่ยวชุมชน อำเภอเมือง จังหวัดกำแพงเพชร โดยรวมอยู่ในเกณฑ์มาก

อย่างไรก็ตามการพัฒนาแอปพลิเคชันแหล่งท่องเที่ยวครั้งนี้ถึงแม้ว่าผู้วิจัยจะนำเทคโนโลยีสมัยใหม่มาเป็นเครื่องมือสำหรับการพัฒนาแอปพลิเคชันที่สามารถรองรับการแสดงผลการทำงานได้ทั้งบนระบบปฏิบัติการ Android และ iOS แต่ด้วยข้อมูลเนื้อหา ตำแหน่งพิกัด ที่พัก ร้านอาหารของแหล่งท่องเที่ยวที่จัดเก็บอาจยังน้อย ซึ่งงานวิจัยนี้ได้จัดเก็บแหล่งท่องเที่ยวที่สำคัญใน สปป.ลาว 15 สถานที่ ที่พัก 20 แห่ง และร้านอาหาร 20 ร้าน ซึ่งข้อมูลที่จัดเก็บอาจยังไม่ครอบคลุมแหล่งท่องเที่ยวใน สปป.ลาวทั้งหมด ซึ่งการวิจัยครั้งต่อไปควรมีการศึกษา 1) รวบรวม จัดเก็บข้อมูลแหล่งท่องเที่ยวใน สปป.ลาว ให้ครอบคลุมทั่วประเทศ และรวมไปถึงแหล่งท่องเที่ยวที่เกิดขึ้นใหม่ เป็นที่นิยมของนักท่องเที่ยวในปัจจุบัน และควรมีการเพิ่มฟังก์ชันการแจ้งเตือน SMS เมื่อผู้ดูแลระบบมีการเพิ่มข้อมูลแหล่งท่องเที่ยวใหม่ ๆ เข้ามาในแอปพลิเคชัน 2) ออกแบบโมเดลการค้นคืนข้อมูลแหล่งท่องเที่ยวให้ตรงกับลักษณะปัจเจกบุคคล 3) การออกแบบและพัฒนาระบบสักรัดและค้นคืนความรู้ผ่านระบบสารสนเทศทางภูมิศาสตร์ออนไลน์สำหรับธุรกิจท่องเที่ยวใน สปป.ลาว หรือประเทศไทย

งานวิจัยในอนาคตจะมีการทดสอบประสิทธิภาพเปรียบเทียบแอปพลิเคชันกับงานวิจัยที่เกี่ยวข้องโดยการทำ Load Testing และRegression Testingรวมถึงต่อยอดเพิ่มเติมการแนะนำสถานที่ เช่นร้านอาหารท้องถิ่น ตลาด เส้นทางด้านวัฒนธรรม เพิ่มส่งเสริมการพัฒนาด้านธุรกิจต่อไป

## เอกสารอ้างอิง

- [1] V. ROYAL THAI EMBASSY, LAO PDR. "Tourism Development of Laos," [Online]. Available: <https://globthailand.com/laos-21102019/> [Accessed 2021].
- [2] C. Xaiyavohan, "Tourist satisfaction toward Nang-ane cave, Thakaek District, Khammoune Province," LAO PDR. Dhurakij Pundit University, 2019.
- [3] C. Xaiyavohan. "Create Cross-Platform Mobile Application with React Native and Expo," [Online]. Available: <https://medium.com/@sirawit/> [Accessed 2021].

- [4] S. Niwattanakul, Access to Agricultural Knowledge by Semantic Web Technologies. Suranaree University of Technology, 2013.
- [5] J. Nielsen and L. Mack, Usability Inspection Methods. New York: John Wiley & Sons, 1994.
- [6] J. McCormick, "A multilevel investigation of relationships between Australian teachers' career stages and locus of control," Journal of Educational Administration, vol. 46, no. 1, 2008.
- [7] B. Srisa-ard, Basic Research. Bangkok: Suweeriyasan, 2000.
- [8] J. Tantai, The Study of Privileges Application Effectiveness on Customer Loyalty Case Study: Application Galaxy Gift. Thammasat University, 2015.
- [9] N. Jungsaman, N. Lonkuntod, S. Wongchaipatoom, and S. Doornin, "Developing Application for Tourism Industry of Surin Province," Journal of MCU Nakhondhat, vol. 7, no. 7, pp. 410-424, 2006.
- [10] C. Intraprapan and Y. Kanhaming, "The Development of Mobile Application for Promoting Community-Based Tourism in Muang District, Kamphaeng-Phet," in The Academic Management Sciences, pp. 1264-1273, 2020.
- [11] A. Wannakayont, N. Lonkuntosh, T. Sittichantasen, W. Bunpok, T. Chuachan, S. Vongchaipratoom, S. Dumnail, C. Mondub, and P. Chidchon, "Mobile Phone Application Development for Communitybased Economic Tourism and OTOP Products in Surin Province," Journal of Koch Cha Sarn Journal of Science, vol. 40, no. 1, 2018.

# CONTRIBUTORS' FORM

*(to be modified as applicable and one signed copy attached with the manuscript)*

**Manuscript Title:**

**Author(s):**

I/we certify that I/we have participated sufficiently in the intellectual content, conception and design of this work or the analysis and interpretation of the data (when applicable), as well as the writing of the manuscript, to take public responsibility for it and have agreed to have my/our name listed as a contributor. I/we believe the manuscript represents valid work. Neither this manuscript nor one with substantially similar content under my/our authorship has been published or is being considered for publication elsewhere, except as described in the covering letter. I/we certify that all the data collected during the study is presented in this manuscript and no data from the study has been or will be published separately. I/we attest that, if requested by the editors, I/we will provide the data/information or will cooperate fully in obtaining and providing the data/information on which the manuscript is based, for examination by the editors or their assignees. Financial interests, direct or indirect, that exist or may be perceived to exist for individual contributors in connection with the content of this paper have been disclosed in the cover letter. Sources of outside support of the project are named in the cover letter.

I/We hereby transfer(s), assign(s), or otherwise convey(s) all copyright ownership, including any and all rights incidental thereto, exclusively to the Journal, in the event that such work is published by the Journal. The Journal shall own the work, including 1) copyright; 2) the right to grant permission to republish the article in whole or in part, with or without fee; 3) the right to produce preprints or reprints and translate into languages other than English for sale or free distribution; and 4) the right to republish the work in a collection of articles in any other mechanical or electronic format.

We give the rights to the corresponding author to make necessary changes as per the request of the journal, do the rest of the correspondence on our behalf and he/she will act as the guarantor for the manuscript on our behalf.

All persons who have made substantial contributions to the work reported in the manuscript, but who are not contributors, are named in the Acknowledgment and have given me/us their written permission to be named. If I/we do not include an Acknowledgment that means I/we have not received substantial contributions from non-contributors and no contributor has been omitted.

|   | <b>Name</b> | <b>Signature</b> | <b>Date signed</b> |                                                      |
|---|-------------|------------------|--------------------|------------------------------------------------------|
| 1 | _____       | _____            | _____              |                                                      |
| 2 | _____       | _____            | _____              |                                                      |
| 3 | _____       | _____            | _____              |                                                      |
| 4 | _____       | _____            | _____              | (up to 4 contributors for case report/images/review) |
| 5 | _____       | _____            | _____              |                                                      |
| 6 | _____       | _____            | _____              | (up to 6 contributors for original studies)          |



## INFORMATION FOR AUTHORS

The Journal of Information Science and Technology (JIST) aims to be the forum through which researchers, faculties, graduate students and experts of the computer and information technology and other technological related fields share and discuss their high quality research work as well as innovation. Original research articles, practical applications and innovations in the broad area of computer and information technology are suitable for publication in JIST. Periodicity (Publication) is 2 issues per year (JAN - JUN and JULY - DECEMBER).

Accepted papers will be Double-blind peer reviewed by minimum 3 reviewers with "Accept" result.

1. Soft Computing
2. Human-Computer Interaction
3. Information Assurance and Security
4. Information Systems
5. Networking
6. Programming
7. Platform Technologies
8. System Integration and Architecture
9. Social and Professional Issues
10. Web Systems and Technologies
11. Multidisciplinary
12. e-Business and m-Business
13. Business and Information System
14. Social and Business Aspects of Convergence IT and Ubiquitous Computing
15. Internet of Things (IoT)
16. Cloud Computing
17. Fintech and blockchain

### Manuscript Preparation Guide

The template for writing the journal is available for downloading (<https://ph02.tci-thaijo.org/index.php/JIST/>). Length of the paper should be in between 8-12 pages of A4 size. Text should be typewritten or printed with double-spaced in 11-point of A4 white paper with margins of 1.5" for top, 1.25" for left, and 1" for bottom and right sides. All pages must be numbered sequentially. Here are some guidelines.

- Abstract which length 100-200 words.
- Introduction which talks about the problem and related research.
- Materials and methods use for experimentation.
- Results of the experiment.
- Discussion and Conclusion, References

### Submissions (Publication Charge: Free) (Indexed by TCI tier 2)

Please submit paper in MS Word via <https://ph02.tci-thaijo.org/index.php/JIST/> (Online Journal Submission)

### Contact Address

The Association of Council of IT Deans (CITT)  
140 Moo 1, Cheumsampan Road, Nongchok  
Bangkok, Thailand 10530  
Tel: 02-988-3655 ext 4115 Fax: 02-988-4027  
E-mail: [jist@citt.or.th](mailto:jist@citt.or.th)