

การวางแผนเพื่อรองรับความต้องการฤๅธรน้ำใจของสถานีกาชาดในหลายพื้นที่สำหรับ สถานีกาชาดไทย

ชิตทิ๑ควัฒน์ เครือวงศ์^{*1} และ เจริญชัย โชมพั๑ตราภรณ์²

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

126 ถนนประชาอุ๑ทิศ แขวงบางม๑ด เขตทุ่งครุ กรุงเทพฯ 10140

Received: 13 March 2026; Revised: 28 April 2026; Accepted: 08 May 2026

บทคัดย่อ

การเตรียมสิ่งของบรรเทาทุ๑ทุกข์ล๑งหน้ามีบทบาทสำคัญต่อการจัดการภัยพิ๑บัติ เนื่องจา๑ความต้องการมักมีความไม่แน่นอนและแตกต่างกันตามพื้นที่ งานวิจัยนี้เสนอแนวทางการวิเคราะห์ข้อมูลและการพยากรณ์ความต้องการฤๅธรน้ำใจของสถานีกาชาดไทย เพื่อสนับสนุนการกำหนดระดับการเตรียมทรัพยากรในระดับกลุ่มสถานีกาชาด ซึ่งช่วยเพิ่มประสิทธิภาพของการจัดเก็บและการกระจายสิ่งของบรรเทาทุ๑ทุกข์ การศึกษาใช้ข้อมูลความต้องการรายเดือนจากสถานีกาชาดและฝ่ายบรรเทาทุ๑ทุกข์ทั่วประเทศในช่วงปี พ.ศ. 2554–2566 โดยชุดข้อมูลมีข้อจำกัดจากช่วงเวลาที่เกิดการบ๑นทึ๑และการเปลี่ยนแปลงพื้นที่รับผิดชอบของสถานีกาชาด จึงมีการปรับโครงสร้างข้อมูลเชิงพื้นที่ด้วยการกระจายข้อมูลย้อนหลังไปยังพื้นที่เดิม เพื่อให้ชุดข้อมูลมีความต่อเนื่องก่อนนำไปวิเคราะห์ การตรวจสอบรูปแบบการกระจายของข้อมูลด้วยการทดสอบ Kolmogorov–Smirnov (KS) พบว่าความต้องการมีลักษณะเบ้ขวาและสอดคล้องกับการแจกแจงแบบ Lognormal จากนั้นจึงนำผลไปใช้ประเมินปริมาณความต้องการที่ระดับความเชื่อมั่นร้อยละ 80 และเปรียบเทียบแนวทางการสำรองระหว่างการจัดเก็บแบบแยกสถานีกาชาดกับการบริหารร่วมในระดับคลัสเตอร์ ซึ่งพบว่าการรวมความต้องการในระดับกลุ่มช่วยลดปริมาณการสำรองรวมของระบบได้ ในขั้นตอนการพยากรณ์ ได้ประยุกต์ใช้เทคนิค Machine Learning หลายรูปแบบ โดยใช้ตัวแปรด้านเวลา พื้นที่ และปริมาณน้ำฝนเป็นข้อมูลนำเข้า ทั้งนี้ปริมาณน้ำฝนถูกใช้เป็นตัวถ่วงน้ำหนักของข้อมูลในกระบวนการฝึกแบบจำลอง เพื่อสะท้อนความเสี่ยงของเหตุการณ์ภัยพิ๑บัติ ผลการทดลองแสดงให้เห็นว่าการบริหารคงคลังในระดับคลัสเตอร์สามารถลดปริมาณการสำรองรวมของระบบได้อย่างมีนัยสำคัญเมื่อเทียบกับการจัดเก็บแบบแยกรายสถานีกาชาด ขณะเดียวกันแบบจำลองการพยากรณ์สามารถประมาณแนวโน้มความต้องการได้ในระดับที่เหมาะสม และเมื่อนำผลพยากรณ์ไปประเมินร่วมกับฟังก์ชันการแจกแจงสะสม (CDF) พบว่าสามารถกำหนดระดับการเตรียมทรัพยากรที่รองรับความต้องการได้ในช่วงประมาณร้อยละ 80–90 ในระดับคลัสเตอร์ และประมาณร้อยละ 60–80 ในระดับสถานีกาชาด

คำสำคัญ: การจัดกลุ่มคลัสเตอร์, การเตรียมการระดับสินค้๑คงคลัง, การพยากรณ์ความต้องการ, การเรียนรู้ของเครื่อง, ฤๅธรน้ำใจ

* Corresponding author. E-mail: chitipuckawut.krue@kmutt.ac.th

¹ นักศึกษา ภา๑ควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

² รองศาสตราจารย์ ภา๑ควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

Multi-warehouse Relief Aid Pre-position Planning for Thai Red Cross

Chitipuckawat Krueawong^{*1} and Charoenchai Khompatraporn²

King Mongkut's University of Technology Thonburi (KMUTT),
126 Pracha Uthit Rd., Bang Mod, Thung Khru, Bangkok 10140, Thailand

Received: 13 March 2026; Revised: 28 April 2026; Accepted: 08 May 2026

Abstract

Relief supply pre-positioning is essential for effective disaster management, particularly when demand is uncertain and varies across regions. This study proposes a data-driven approach to analyze and forecast the demand for relief aid packages of the Thai Red Cross to support resource planning at the cluster level of Red Cross stations and improve the efficiency of storage and distribution. Monthly demand data from Red Cross stations and the Disaster Relief Division during 2011–2023 were analyzed. Due to missing records in certain periods and changes in station service areas, the dataset was restructured by reallocating historical demand to the original coverage areas to maintain data continuity prior to the analysis. Statistical analysis using the Kolmogorov–Smirnov test indicated that the demand exhibited a right-skewed pattern and was best represented by a lognormal distribution. Based on this distribution, demand levels corresponding to an 80% confidence level were estimated and compared between decentralized station-level storage and cluster-based management, showing that demand aggregation at the cluster level reduced the total safety stock required by the system. For forecasting, several Machine Learning techniques were applied with time, location, and rainfall variables serving as model inputs. where rainfall was incorporated as weighting factor during model training to reflect disaster risk conditions. Experimental results indicate that cluster-based inventory planning significantly reduces overall stock requirements compared with independent station storage, while the selected forecasting model provides reliable demand estimates. Evaluation using the cumulative distribution function (CDF) shows that the proposed approach can support demand coverage of approximately 80–90% at the cluster level and about 60–80% at the station level.

Keywords: cluster-based planning, demand distributions, machine learning, pre-positioning inventory level, relief aid packages

* Corresponding author. E-mail: chitipuckawut.kruea@kmutt.ac.th

1 Student in Faculty of Engineering, King Mongkut's University of Technology Thonburi

2 Associate Professor in Faculty of engineering, King Mongkut's University of Technology Thonburi

1. บทนำ

1.1 ความเป็นมา

สภาอากาศไทยเป็นหน่วยงานที่ถูกจัดตั้งขึ้นเพื่อการดำเนินการกิจทางด้านมนุษยธรรม โดยมีวัตถุประสงค์หลักในการช่วยเหลือแก่ผู้ประสบภัยและผู้ที่ได้รับความเดือดร้อน โดยไม่แบ่งแยกเชื้อชาติ ศาสนา หรือฝ่ายใด ๆ ปัจจุบันสภาอากาศได้ดำเนินงานช่วยเหลือด้านมนุษยธรรมอย่างต่อเนื่อง ทั้งในด้านการจัดหาและบริหารโลหิตสำรองให้โรงพยาบาลทั่วประเทศ การให้บริการรักษาพยาบาล ส่งเสริมสุขภาพให้แก่คนในชุมชนและพื้นที่ห่างไกล การพัฒนาคุณภาพชีวิตของผู้ด้อยโอกาส และการช่วยเหลือผู้ประสบภัยพิบัติในทุกภูมิภาค ซึ่งถือเป็นพันธกิจหลักขององค์กร [1]

ประเทศไทยเป็นประเทศที่มีความเสี่ยงต่อการเกิดภัยพิบัติหลายรูปแบบ ทั้งวาตภัย อุทกภัย ภัยแล้ง และภัยหนาว เนื่องจากมีลักษณะภูมิประเทศแบบร้อนชื้น จึงจำเป็นต้องมีมาตรการทั้งเชิงรุกและเชิงรับเพื่อบรรเทาความรุนแรงและลดผลกระทบที่อาจเกิดขึ้นให้ได้มากที่สุด โดยสภาอากาศไทยเป็นหน่วยงานที่ได้รับมอบหมายให้มีบทบาทสำคัญในการเตรียมความพร้อมรับมือกับภัยพิบัติต่าง ๆ ไม่ว่าจะเป็นการเตรียมบุคลากร การฝึกอบรมให้ความรู้แก่เจ้าหน้าที่ อาสาสมัคร และประชาชนทั่วไป เพื่อให้สามารถรับมือกับสถานการณ์ฉุกเฉินได้อย่างทันท่วงที อีกทั้งยังต้องมีการจัดเตรียม “ถุงธารน้ำใจ” ซึ่งประกอบด้วยสิ่งของจำเป็นพื้นฐานสำหรับการดำรงชีวิตเบื้องต้น เพื่อให้เพียงพอต่อความต้องการของผู้ประสบภัยในยามเกิดภัยทุกแบบ [2]

การวางแผนความต้องการถุงธารน้ำใจจึงเป็นกระบวนการที่มีความสำคัญต่อการบริหารจัดการด้านการบรรเทาสาธารณภัย เนื่องจากสิ่งของที่บรรจุอยู่ในถุงธารน้ำใจส่วนใหญ่มีอายุการเก็บรักษาที่จำกัด ซึ่งโดยทั่วไปสามารถจัดเก็บได้ในช่วงประมาณ 1-2 ปี ขึ้นอยู่กับประเภทของสิ่งของแต่ละชนิด ดังนั้น การกำหนดปริมาณถุงธารน้ำใจให้สอดคล้องกับความต้องการในพื้นที่ที่ประสบภัยหรือได้รับผลกระทบจึงนับเป็นประเด็นท้าทายที่สำคัญ ขณะเดียวกันยังส่งผลกระทบต่อค่าใช้จ่ายที่เกี่ยวข้องกับการจัดเก็บ (Holding cost) สิ่งของบรรเทาทุกข์อีกด้วย และเป็นวัตถุประสงค์ของการดำเนินการศึกษาวิจัยนี้ ดังนั้นงานวิจัยนี้ มีวัตถุประสงค์

เพื่อสร้างแนวทางการพยากรณ์ปริมาณถุงธารน้ำใจและการเตรียมการของสถานีสภาอากาศไทยในพื้นที่ต่างๆ ให้มีประสิทธิภาพ เพื่อให้สามารถตอบสนองความต้องการได้อย่างทันท่วงที การพยากรณ์ความต้องการถุงธารน้ำใจจะมีส่วนช่วยในการคาดการณ์ปริมาณสิ่งของบรรเทาทุกข์ที่เหมาะสมในแต่ละช่วงเวลา เพื่อลดการจัดเก็บเกินความจำเป็นหรือการขาดแคลนในยามวิกฤติ

1.2 วัตถุประสงค์

1. เพื่อพัฒนาแบบจำลองพยากรณ์ความต้องการถุงธารน้ำใจในระดับคลัสเตอร์โดยใช้ข้อมูลย้อนหลังและปัจจัยที่เกี่ยวข้อง
2. เพื่อเปรียบเทียบประสิทธิภาพของการกำหนดระดับคงคลังล่วงหน้า ระหว่างการจัดเก็บแบบแยกสถานีและแบบคลัสเตอร์
3. เพื่อกำหนดระดับคงคลังที่เหมาะสมภายใต้ระดับความเชื่อมั่นที่กำหนด และประเมินผลกระทบต่อปริมาณการสำรองโดยรวมของระบบ

1.3 ขอบเขตงานวิจัย

1. ศึกษาความต้องการถุงธารน้ำใจของสภาอากาศไทยจากข้อมูลย้อนหลังปี พ.ศ. 2554-2566 ซึ่งมีช่วงข้อมูลขาดหายไป พ.ศ. 2560-2562 และบางสถานีก่อตั้งภายหลังปี พ.ศ. 2559 จึงมีการปรับโครงสร้างข้อมูล อาจเกิดความคลาดเคลื่อนบางส่วนในการวิเคราะห์แนวโน้มระยะยาว
2. ข้อมูลที่นำมาใช้จะเป็นข้อมูลเฉพาะปริมาณความต้องการถุงธารน้ำใจของสภาอากาศไทยเท่านั้น ไม่ครอบคลุมการช่วยเหลือจากหน่วยงานอื่น
3. การพยากรณ์ใช้ข้อมูลเวลาและปริมาณน้ำฝนเป็นตัวแทนความเสี่ยง โดยไม่ครอบคลุมปัจจัยเชิงสังคมหรือเศรษฐกิจ และไม่ได้วิเคราะห์ต้นทุนเชิงการเงินโดยละเอียด

2. แนวคิดและงานวิจัยที่เกี่ยวข้อง

2.1 ทบทวนวรรณกรรม

Li และ Zabinsky [3] ได้ศึกษาปัญหาการคัดเลือกผู้ส่งมอบภายใต้ความไม่แน่นอนของอุปสงค์และกำลังการผลิตของผู้ส่งมอบ โดยมีเป้าหมายเพื่อกำหนดปริมาณการ


สิ่งของที่เหมาะสมที่สุด เพื่อสร้างสมดุลระหว่างต้นทุนรวม ความเสี่ยงจากการไม่สามารถตอบสนองความต้องการ และ จำนวนผู้ส่งมอบที่เลือกใช้ งานวิจัยดังกล่าวนำเสนอแนวทางการแก้ปัญหาผ่านแบบจำลองเชิงคณิตศาสตร์สอง รูปแบบคือ แบบจำลองการวางแผนเชิงเส้นแบบสองขั้นตอน และแบบจำลองการวางแผนภายใต้ข้อจำกัดเชิงความน่าจะเป็น ผู้วิจัยสรุปแนวทางที่นำเสนอควบคุมความเสี่ยงโดย กำหนดให้ปริมาณสินค้าที่ได้รับต้องไม่น้อยกว่าค่าความต้องการที่ระดับความเชื่อมั่นที่กำหนด ซึ่งช่วยให้มั่นใจได้ว่า ระบบสามารถรองรับอุปสงค์ภายใต้ระดับความเสี่ยงที่ยอมรับได้ และสามารถวิเคราะห์ความสัมพันธ์ระหว่างต้นทุนรวมกับ ระดับความเสี่ยงของระบบได้อย่างเป็นระบบ

Murray, Agard และ Barajas [4] ศึกษาปัญหาการพยากรณ์ความต้องการในห่วงโซ่อุปทานภายใต้บริบทที่ขาด ข้อมูลความร่วมมือจากลูกค้า ซึ่งทำให้การสร้างแบบจำลอง พยากรณ์รายลูกค้ามีความซับซ้อนและไม่สามารถจัดการได้ อย่างมีประสิทธิภาพ งานวิจัยดังกล่าวเสนอแนวทางการใช้ เทคนิคการทำ data mining เพื่อจัดกลุ่มลูกค้าที่มีรูปแบบ ความต้องการคล้ายคลึงกัน โดยอาศัยข้อมูลการใช้งาน ย้อนหลังในการทำ clustering หลังจากแบ่งกลุ่มแล้วจึง พัฒนาแบบจำลองพยากรณ์ในระดับกลุ่มแทนการสร้าง แบบจำลองแยกรายลูกค้า แนวทางดังกล่าวช่วยลดความ ซับซ้อนของระบบ เพิ่มเสถียรภาพของแบบจำลอง และ ปรับปรุงความแม่นยำของการพยากรณ์ในบริบทที่มีหน่วย ย่อยจำนวนมาก แนวคิดนี้ถูกนำมาประยุกต์ใช้ในงานวิจัยนี้ โดยจัดกลุ่มสถานีกาชาดที่มีรูปแบบความต้องการใกล้เคียง กันก่อนดำเนินการพยากรณ์ในระดับคลัสเตอร์ เพื่อสนับสนุน การกำหนดระดับสินค้าคงคลังในภาพรวมของระบบอย่างมี ประสิทธิภาพ

Paramaiah et al. [5] ศึกษาการประยุกต์ใช้ เทคนิค Machine Learning สำหรับการพยากรณ์ ความ ต้องการในบริบทการบริหารห่วงโซ่อุปทาน โดยมี วัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของโมเดล Machine Learning หลายประเภทกับวิธีการพยากรณ์แบบ ดั้งเดิม งานวิจัยดำเนินการตามขั้นตอนตั้งแต่การเตรียมข้อมูล การสร้างแบบจำลอง การฝึกสอน และการประเมินผล โดย

ทดสอบโมเดล เช่น Linear Regression, Random Forest, Gradient Boosting และ Long Short-Term Memory ผล การศึกษาแสดงให้เห็นว่าโมเดลกลุ่ม ensemble และ deep learning โดยเฉพาะ Long Short-Term Memory ให้ค่า ความคลาดเคลื่อนต่ำและค่า R-squared ซึ่งเป็นตัวชี้วัด ความสามารถของแบบจำลองในการอธิบายความแปรปรวน ของข้อมูล มีค่าสูงกว่าวิธีการแบบดั้งเดิมอย่างชัดเจน งาน ดังกล่าวจึงสนับสนุนศักยภาพของ Machine Learning ใน การเพิ่มประสิทธิภาพการพยากรณ์อุปสงค์ ซึ่งสอดคล้องกับ แนวทางของงานวิจัยนี้ที่ประยุกต์ใช้ Deep Learning ในการ พยากรณ์ความต้องการในระดับคลัสเตอร์เพื่อสนับสนุนการ บริหารสินค้าคงคลัง

Leelawan และ Khompatraporn [6] ได้เสนอ แบบจำลองการวางแผนระดับสินค้าคงคลังล่วงหน้า (Pre-positioning stock) สำหรับเครือข่ายการช่วยเหลือของ สภากาชาดไทย ซึ่งประกอบด้วยสถานีกาชาดจำนวน 10 แห่ง โดยมีวัตถุประสงค์เพื่อลดต้นทุนรวมของระบบที่เกิดจาก ต้นทุนการขนส่งและต้นทุนการถือครองสินค้าคงคลังภายใต้ เงื่อนไขของความต้องการสิ่งของบรรเทาทุกข์ที่มีความไม่ แน่นนอน โดยงานวิจัยได้จัดกลุ่มสถานีกาชาดในภูมิภาค ออกเป็นคลัสเตอร์ตามพื้นที่ทางภูมิศาสตร์ได้แก่ ภาคเหนือ ภาคตะวันออกเฉียงเหนือ ภาคกลาง และภาคใต้ ดังแสดงใน รูปที่ 1 และได้กำหนดให้สามารถดำเนินการขนส่งและการ ถ้ายโอนสิ่งของบรรเทาทุกข์ภายในคลัสเตอร์เดียวกันได้ แทน การส่งถาวรน้ำใจจากศูนย์กรุงเทพฯ ไปยังสถานีกาชาด เท่านั้น ทั้งนี้เพื่อใช้ประโยชน์จากระยะทางที่ใกล้กันของสถานี กาชาดภายในคลัสเตอร์กว่าระยะทางการขนส่งจากศูนย์ กรุงเทพฯ ผลการวิเคราะห์เชิงปริมาณสรุปว่า ต้นทุนการ ขนส่งเป็นองค์ประกอบหลักของต้นทุนรวม และการจัดกลุ่ม สถานีกาชาดเป็นคลัสเตอร์ช่วยลดต้นทุนขนส่งและเพิ่มความ ยืดหยุ่นในการตอบสนองต่ออุปสงค์ในพื้นที่



รูปที่ 1 การจัดการยุทธน้ำใจไปยังสถานีภาคต่างๆ ตามกลุ่มคลัสเตอร์

จากการทบทวนวรรณกรรมพบว่า งานส่วนใหญ่ เน้นการพยากรณ์ความต้องการหรือการกำหนดระดับคงคลัง แยกกันเป็นประเด็นอิสระ โดยยังขาดงานที่บูรณาการการ พยากรณ์ด้วย Machine Learning เข้ากับการประเมินระดับ ความเชื่อมั่นเชิงความเสี่ยงในบริบทของการจัดการคงคลัง สิ่งของบรรเทาทุกข์ นอกจากนี้ งานที่ศึกษาการบริหารคงคลัง ในรูปแบบคลัสเตอร์ยังมีจำนวนจำกัดในบริบทขององค์กรที่มี โครงสร้างเชิงพื้นที่ ดังนั้นงานวิจัยนี้จึงมุ่งเติมเต็มช่องว่าง ดังกล่าว โดยเสนอกรอบการบูรณาการการพยากรณ์และการ ประเมินความเสี่ยงเพื่อสนับสนุนการกำหนดระดับคงคลังใน ระดับคลัสเตอร์อย่างเป็นระบบ

2.2 ทฤษฎีที่เกี่ยวข้อง

2.2.1 การแจกแจงแบบล็อกปกติ

การแจกแจงแบบ Lognormal distribution [7] เป็นการแจกแจงความน่าจะเป็นแบบต่อเนื่องที่ใช้กันอย่าง แพร่หลายในการอธิบายข้อมูลที่มีค่าเป็นบวกและมีการ กระจายแบบเบ้ขวา (Right-skewed) ซึ่งการแจกแจงชนิดนี้ มักถูกนำมาใช้ในการวิเคราะห์ข้อมูลที่ไม่สามารถมีค่าเป็น ศูนย์หรือติดลบ เช่น ความต้องการสินค้าในระบบการ ดำเนินงานที่มีความไม่แน่นอนและไม่มีรูปแบบการ ดำเนินงานที่ตายตัว โดย ตัวแปรสุ่ม X จะมีการแจกแจงแบบ Lognormal หากตัวแปร $Y = \ln(X)$ ซึ่งฟังก์ชันความ น่าจะเป็นของการแจกแจงแบบ Lognormal สามารถอธิบาย

ได้ด้วยพารามิเตอร์สองค่า ได้แก่ ค่าเฉลี่ย (μ) และส่วน เบี่ยงเบนมาตรฐาน (σ) ซึ่งพารามิเตอร์ทั้งสองมีบทบาท สำคัญในการกำหนดลักษณะการกระจายข้อมูล โดยค่าทาง สถิติที่สามารถคำนวณดังนี้

$$\text{ค่าเฉลี่ย} \quad \text{Mean} = e^{((\mu + \sigma^2/2))} \quad (1)$$

$$\text{ค่ามัธยฐาน} \quad \text{Median} = e^{(\mu)} \quad (2)$$

$$\text{ค่าฐานนิยม} \quad \text{Mode} = e^{(\mu - \sigma^2)} \quad (3)$$

$$\text{ค่าความแปรปรวน} \quad \text{Var}(X) = (e^{\sigma^2} - 1)e^{(2\mu + \sigma^2)} \quad (4)$$

โดยที่ μ คือ ค่าเฉลี่ย
 σ คือ ส่วนเบี่ยงเบน มาตรฐาน

2.2.2 การทดสอบ Kolmogorov-Smirnov

เป็นวิธีการทางสถิติที่ถูกพัฒนาโดย Andrey Kolmogorov และ Nikolai Smirnov [8] เพื่อทำการทดสอบ ว่าตัวอย่างทดลองมาจากประชากรที่มีการแจกแจงตามที่ กำหนดหรือไม่ โดยวิธีการทดสอบทางสถิติแบบไม่ขึ้นกับ ประเภทของการแจกแจง และถูกนำมาใช้อย่างแพร่หลายใน การตรวจสอบความเหมาะสมของการแจกแจงทางทฤษฎีกับ ข้อมูลตัวอย่าง โดยเฉพาะในกรณีที่ข้อมูลมีความไม่แน่นอน มี ลักษณะการกระจายแบบเบ้ หรือมีขนาดตัวอย่างไม่มาก การ ทดสอบนี้เหมาะสมกับการวิเคราะห์ข้อมูลด้านโลจิสติกส์และ โซ่อุปทาน เช่น ชุดข้อมูลที่ไม่เป็นไปตามการแจกแจงแบบ ปกติอย่างสมบูรณ์

หลักการทำงานเริ่มจากการเปรียบเทียบฟังก์ชัน การแจกแจงสะสมเชิงประจักษ์ (Empirical Cumulative Distribution Function: ECDF) กับฟังก์ชันการแจกแจง สะสมเชิงทฤษฎี (Cumulative Distribution Function: CDF) หากข้อมูลตัวอย่างมีการแจกแจงสอดคล้องกับการแจก แจงทางทฤษฎี ซึ่งจะสังเกตจากค่าความแตกต่างสูงสุด (Maximum Deviation) ระหว่างการแจกแจงทั้งสอง โดย หากเปรียบเทียบแล้วข้อมูลตัวอย่างมีการแจกแจงสอดคล้อง กับการแจกแจงทางทฤษฎี เส้น ECDF และ CDF จะมี ลักษณะใกล้เคียงกันตลอดช่วงของข้อมูล ในทางตรงกันข้าม

หากการแจกแจงไม่เหมาะสม ความแตกต่างระหว่างเส้นทั้งสองจะมีค่าสูงในบางช่วง

สถิติทดสอบของ KS test ถูกกำหนดเป็นค่าความแตกต่างสัมบูรณ์สูงสุดระหว่าง ECDF และ CDF ดังสมการ

$$D = \max |F_n(x) - F(x)| \quad (5)$$

โดยที่ $F_n(x)$ คือ ฟังก์ชันการแจกแจงสะสมเชิงประจักษ์ของข้อมูลตัวอย่าง

$F(x)$ คือ ฟังก์ชันการแจกแจงสะสมของการแจกแจงทางทฤษฎีที่นำมาทดสอบ

D คือ แทนตัวชี้วัดระดับความแตกต่างระหว่างข้อมูลจริงและแบบจำลองการแจกแจง

ข้อดีที่ของการทดสอบ Kolmogorov-Smirnov คือสามารถตรวจสอบความแตกต่างของการแจกแจงได้ตลอดช่วงของข้อมูล โดยไม่จำกัดเฉพาะช่วงใดช่วงหนึ่ง และไม่จำเป็นต้องแบ่งข้อมูลออกเป็นช่วงๆ (Bins) ที่ใช้ในการทดสอบแบบ Chi-square test นอกจากนี้ KS test ยังสามารถใช้กับข้อมูลที่มีขนาดตัวอย่างไม่มาก อย่างไรก็ตามการทดสอบนี้อาจมีความไวต่ำในกรณีที่ขนาดตัวอย่างมีค่าน้อย หรือในกรณีที่พารามิเตอร์ของการแจกแจงทางทฤษฎีถูกประมาณจากข้อมูลเดียวกัน ซึ่งอาจทำให้ผลการทดสอบมีความเอนเอียง (Bias) ได้

2.2.3 Machine Learning

โดยการเรียนรู้ของเครื่อง [9] คือสาขาหนึ่งของปัญญาประดิษฐ์ที่มุ่งเน้นการพัฒนาแบบจำลองและอัลกอริทึมที่สามารถเรียนรู้รูปแบบจากข้อมูลที่มีอยู่ และปรับปรุงประสิทธิภาพได้โดยไม่ต้องกำหนดกฎอย่างชัดเจนล่วงหน้า ระบบ ML ใช้ข้อมูลในอดีตเพื่อสร้างแบบจำลองสำหรับการพยากรณ์ การจำแนก หรือการสนับสนุนการตัดสินใจในอนาคต โดยในงานวิจัยนี้ได้นำ ML มาประยุกต์ใช้ในการพยากรณ์จำนวนผู้ติดเชื้อที่ควรจัดเก็บ เพื่อให้เพียงพอต่อความต้องการในสถานการณ์ต่างๆ ที่อาจเกิดขึ้นล่วงหน้า โดยภายในงานวิจัยนี้ใช้โมเดลดังนี้

Random Forest [10] เป็นอัลกอริทึมการเรียนรู้แบบกลุ่ม (Ensemble learning) ที่เกิดจากสร้างแบบจำลองจากต้นไม้ตัดสินใจ (Decision trees) หลายต้น โดยแต่ละต้นถูกสร้างจากชุดข้อมูลตัวอย่างแบบสุ่ม (Bootstrap sampling) และสุ่มเลือกตัวแปรบางส่วนในแต่ละโหนด การรวมผลลัพธ์จากต้นไม้หลายต้นช่วยลดปัญหา Overfitting และเพิ่มความแม่นยำของแบบจำลอง วิธีการ Random Forest เหมาะสำหรับข้อมูลที่มีความซับซ้อนและความสัมพันธ์แบบไม่เชิงเส้น

Gradient Boosting Tree [11] เป็นวิธีการเรียนรู้ที่สร้างต้นไม้ตัดสินใจแบบลำดับขั้นโดยแต่ละต้นจะถูกสร้างขึ้นเพื่อแก้ไขข้อผิดพลาดของต้นก่อนหน้า หลักการทำงานอาศัยการปรับปรุงแบบจำลองอย่างต่อเนื่องโดยใช้แนวคิดของ Gradient descent เพื่อลดค่าของ Loss function วิธีนี้สามารถสร้างแบบจำลองที่มีความแม่นยำสูง และเหมาะสำหรับปัญหาการพยากรณ์และการจำแนกข้อมูลที่มีโครงสร้างซับซ้อน

Generalized Linear Model (GLM) [12] เป็นการขยายแนวคิดของการถดถอยเชิงเส้น (Linear regression) เพื่อรองรับตัวแปรตามที่มีการแจกแจงแบบต่าง ๆ เช่น ปกติ (Normal), ปัวซอง (Poisson) หรือไบนอมิเยล (Binomial) โดย GLM ประกอบด้วย 3 ส่วนหลัก ได้แก่ ตัวแปรเชิงเส้น (Linear predictor), ฟังก์ชันเชื่อมโยง (Link function) และการแจกแจงของตัวแปรตาม GLM เหมาะสำหรับการวิเคราะห์ความสัมพันธ์เชิงสถิติและการตีความผลลัพธ์เชิงเหตุผล

Deep Learning [13] เป็นส่วนหนึ่งของ ML โดยมีโครงสร้างเป็นลักษณะโครงข่ายประสาทเทียมเชิงลึก (Deep Neural Networks) ที่มีโครงสร้างภายในหลายชั้น (Multiple Hidden Layers) เพื่อเรียนรู้ความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นจากข้อมูลจำนวนมาก แนวคิดหลักของ Deep Learning คือการให้แบบจำลองสามารถเรียนรู้และสกัดคุณลักษณะ (Feature Learning) จากข้อมูลดิบได้โดยอัตโนมัติ โดยไม่จำเป็นต้องกำหนดควบคุมด้วยมนุษย์มากนัก โครงข่ายประสาทเทียมใน Deep Learning ประกอบด้วยชั้นอินพุต (Input Layer) ชั้นซ่อน (Hidden Layers) และชั้น

เอาต์พุต (Output Layer) โดยแต่ละชั้นจะทำการแปลงข้อมูลผ่านฟังก์ชันกระตุ้น (Activation Function) เช่น ReLU หรือ Sigmoid เพื่อเพิ่มความสามารถในการอธิบายความสัมพันธ์แบบไม่เป็นเชิงเส้น กระบวนการฝึกสอนของแบบจำลองจะใช้วิธีการแพร่ย้อนกลับของความคลาดเคลื่อน (Backpropagation) ร่วมกับอัลกอริทึมการปรับค่าน้ำหนัก เช่น Gradient Descent เพื่อทำให้ค่าความคลาดเคลื่อนระหว่างผลลัพธ์ที่คาดการณ์และค่าจริงมีค่าน้อยที่สุด Deep Learning เป็นหนึ่งในอัลกอริทึมที่ได้รับความนิยมอย่างแพร่หลายในงานวิจัยด้าน โลจิสติกส์และซัพพลายเชน โดยเฉพาะช่วงหลัง เนื่องจากสามารถจัดการกับข้อมูลขนาดใหญ่และความสัมพันธ์ที่ซับซ้อนได้ดี มีการกระจายแบบเบ้ และรูปแบบที่เปลี่ยนแปลงตามเวลาได้อย่างมีประสิทธิภาพ เช่น ข้อมูลความต้องการสินค้า การคาดการณ์ปริมาณการใช้งาน ซึ่งมีลักษณะสอดคล้องกับข้อมูลที่มีการแจกแจงแบบไม่ปกติ

ในงานวิจัยนี้ ได้มีการประยุกต์ใช้แนวคิดของ Machine Learning เพื่อสนับสนุนการวิเคราะห์ข้อมูลความต้องการลูกค้า ซึ่งข้อมูลที่มีความผันผวนสูงและได้รับอิทธิพลจากหลายปัจจัยทั้งด้านเวลา พื้นที่ และสถานการณ์ภัยพิบัติที่แตกต่างกัน การนำเทคนิค Machine Learning มาใช้ช่วยให้สามารถเรียนรู้รูปแบบความสัมพันธ์ที่ซับซ้อนของข้อมูลได้อย่างมีประสิทธิภาพมากกว่าวิธีการทางสถิติแบบดั้งเดิม ส่งผลให้การวิเคราะห์และการพยากรณ์ความต้องการมีความแม่นยำสูงขึ้น โดยเฉพาะในกรณีที่ข้อมูลมีลักษณะไม่เป็นเชิงเส้น

3. การทดลอง


3.1 ข้อมูลลูกค้าจากสถานีกาชาด

ข้อมูลที่ใช้ในการวิจัยนี้เป็นข้อมูลความต้องการลูกค้ารายเดือนของฝ่ายบรรเทาทุกข์ (ส่วนกลาง) และสถานีกาชาดจำนวน 14 แห่งทั่วประเทศ ครอบคลุมช่วงปี พ.ศ. 2554–2566 รวมทั้งสิ้น 1,440 รายการ อย่างไรก็ตาม


พบว่าข้อมูลในช่วงปี พ.ศ. 2560–2562 ไม่มีการบันทึก และสถานีกาชาดที่ 2, 5, 9, 11 และ 14 ยังไม่ได้จัดตั้งในช่วงปี พ.ศ. 2554–2559 ส่งผลให้เกิดข้อมูลขาดหาย ซึ่งอาจกระทบต่อความต่อเนื่องของชุดข้อมูล รวมถึงความแม่นยำของการวิเคราะห์เมื่อข้อมูลถูกนำไปใช้ในการพัฒนาแบบจำลอง Machine Learning เนื่องจากข้อมูลที่ขาดหายทำให้ลำดับเวลาของข้อมูลไม่ต่อเนื่อง และบางสถานีมีจำนวนข้อมูลย้อนหลังไม่เพียงพอ ส่งผลให้แบบจำลองไม่สามารถเรียนรู้แนวโน้ม ความผันผวน และรูปแบบความต้องการของแต่ละพื้นที่ได้อย่างครบถ้วน หากนำข้อมูลเดิมมาใช้โดยตรง อาจทำให้ผลการพยากรณ์เกิดความคลาดเคลื่อน ความเอนเอียง หรือทำให้การเปรียบเทียบข้อมูลก่อนและหลังการปรับโครงสร้างองค์กรไม่เหมาะสม ดังนั้น งานวิจัยจึงปรับโครงสร้างข้อมูลโดยอ้างอิงพื้นที่ความรับผิดชอบเดิม[14] และกระจายข้อมูลของสถานีที่จัดตั้งใหม่กลับไปยังพื้นที่เดิมตามสัดส่วนที่เหมาะสม เพื่อให้ชุดข้อมูลมีความต่อเนื่องทั้งเชิงเวลาและเชิงพื้นที่ ลดผลกระทบจากข้อมูลขาดหาย และช่วยให้แบบจำลองสามารถเรียนรู้แนวโน้มได้เสถียรมากขึ้น ส่งผลให้ผลการวิเคราะห์และการพยากรณ์มีความน่าเชื่อถือยิ่งขึ้น ทั้งนี้ รายละเอียดขั้นตอนการจัดการข้อมูลจะแสดงในหัวข้อการจัดการข้อมูล

3.2 แนวทางการดำเนินการ

จากการศึกษาระบบปัจจุบัน พบว่าสถานีกาชาดแต่ละแห่งต้องสำรองถุงธารน้ำใจขั้นต่ำจำนวน 2,000 ถุง [15] เพื่อให้สามารถตอบสนองต่อความต้องการเมื่อเกิดภัยพิบัติได้ทันที อย่างไรก็ตามแนวทางดังกล่าวทำให้สถานีกาชาดต้องมีต้นทุนด้านการจัดเก็บและการเตรียมถุงธารน้ำใจที่สูง และเมื่อเกิดภัยพิบัติรุนแรงเกินขีดความสามารถของสถานี จะต้องร้องขอสนับสนุนจากส่วนกลาง ส่งผลให้เกิดต้นทุนการขนส่งและระยะเวลาการตอบสนองที่เพิ่มขึ้น แสดงในรูปที่ 2



รูปที่ 2 การจัดการสถานีกาชาดแบบแยกสถานี



รูปที่ 3 การจัดการสถานีกาชาดแบบคลัสเตอร์

ด้วยเหตุนี้จึงมีการเสนอแนวคิดในการจัดกลุ่มสถานีกาชาดเป็นคลัสเตอร์ดังรูปที่ 3 เพื่อให้สามารถแบ่งปันทรัพยากรน้ำใจคงคลังร่วมกันตามความเหมาะสม โดยการจะดำเนินแนวทางดังกล่าวจะต้องอาศัยการพยากรณ์ความต้องการในระดับที่สอดคล้องกับระดับความเชื่อมั่นที่กำหนด เพื่อเพิ่มความยืดหยุ่นในการบริหารจัดการธุรการน้ำใจ และช่วยลดปริมาณธุรการน้ำใจที่ต้องจัดเก็บไว้ในคลังสินค้า

โดยกระบวนการดำเนินงานของงานวิจัยนี้สามารถสรุปเป็นลำดับขั้นตอนอย่างเป็นระบบดังนี้

1. รวบรวมข้อมูลความต้องการธุรการน้ำใจรายเดือนย้อนหลัง และตรวจสอบความครบถ้วน ความต่อเนื่อง และความถูกต้องของข้อมูล
2. จัดการข้อมูลที่ขาดหาย โดยปรับโครงสร้างเชิงพื้นที่และกระจายข้อมูลของสถานีที่จัดตั้งใหม่กลับไปยังพื้นที่รับผิดชอบเดิม เพื่อลดความไม่ต่อเนื่องของชุดข้อมูล

3. จัดกลุ่มสถานีกาชาดเป็นคลัสเตอร์ตามภูมิภาค เพื่อรองรับการบริหารจัดการคงคลังร่วมกัน

4. วิเคราะห์ลักษณะการแจกแจงของข้อมูลด้วยภาษา Python โดยทดสอบ Normal, Exponential และ Lognormal distribution และประเมินความสอดคล้องด้วย Chi-square และ KS test เพื่อกำหนดระดับคงคลังที่ระดับความเชื่อมั่นที่กำหนด โดยอาศัยกราฟ PDF และ CDF ประกอบการวิเคราะห์

5. สร้างและเปรียบเทียบแบบจำลอง Machine Learning ด้วยโปรแกรม RapidMiner ได้แก่ Random Forest, Gradient Boosted Trees (GBT), Generalized Linear Model (GLM) และ Deep Learning พร้อมประเมินด้วยค่า R^2 และค่าความคลาดเคลื่อน และกำหนดค่าน้ำหนักข้อมูลตามระดับความเสี่ยง

6. นำผลพยากรณ์ระดับคลัสเตอร์มาคำนวณและจัดสรรระดับคงคลังให้แก่แต่ละสถานีตามสัดส่วนความต้องการ และตรวจสอบระดับความเชื่อมั่นด้วยกราฟ CDF

3.3 การจัดการข้อมูล

งานวิจัยนี้จัดกลุ่มข้อมูลออกเป็น 4 คลัสเตอร์ ได้แก่ ภาคกลาง ภาคเหนือภาคตะวันออกเฉียงเหนือ และภาคใต้ เพื่อสะท้อนลักษณะเชิงพื้นที่ของความต้องการ ดังแสดงในตารางที่ 1

ตารางที่ 1 แบ่งกลุ่มคลัสเตอร์ตามภูมิภาคของแต่ละสถานี

กลุ่ม	สถานีกาชาด
ภาคกลาง	สถานีกาชาดที่ 2, 5, 6, 11 และ ฝ่ายบรรเทาทุกข์
ภาคเหนือ	สถานีกาชาดที่ 3, 13
ภาคตะวันออกเฉียงเหนือ	สถานีกาชาดที่ 1, 4, 7, 9
ภาคใต้	สถานีกาชาดที่ 8, 10, 12, 14



รูปที่ 4 พื้นที่รับผิดชอบ
ของแต่ละสถานีภาค
จนถึงปี พ.ศ. 2559



รูปที่ 5 พื้นที่รับผิดชอบ
ของแต่ละสถานีภาคในปี
พ.ศ. 2563 - ปัจจุบัน


จากการเปรียบเทียบพื้นที่ความรับผิดชอบก่อนและหลังการปรับโครงสร้างองค์กร (รูปที่ 4 และรูปที่ 5) พบว่า สถานีภาคบางแห่งเพิ่งจัดตั้งภายหลังปี พ.ศ. 2559 ส่งผลให้ข้อมูลในช่วงก่อนหน้าขาดความต่อเนื่องเชิงพื้นที่

ดังนั้น งานวิจัยจึงดำเนินการกระจายข้อมูลของ สถานีภาคที่ 2, 5, 9, 11 และ 14 กลับไปยังพื้นที่ รับผิดชอบเดิม โดยอ้างอิงข้อมูลปี พ.ศ. 2554 [14] ตาม ขั้นตอนดังนี้

1. อ้างอิงแผนที่พื้นที่รับผิดชอบก่อนการปรับ โครงสร้าง เพื่อระบุว่าสถานีที่จัดตั้งใหม่เดิมอยู่ภายใต้ความ รับผิดชอบของสถานีใด โดยพบว่า สถานีที่ 2, 5 และ 11 เดิม อยู่ภายใต้ฝ่ายบรรเทาทุกข์ (ส่วนกลาง) สถานีที่ 9 อยู่ภายใต้ สถานีที่ 1, 4 และ 7 ร่วมกัน และสถานีที่ 14 อยู่ภายใต้สถานี ที่ 12

2. รวมข้อมูลความต้องการของสถานีใหม่เข้ากับ พื้นที่เดิม เพื่อคงความสอดคล้องเชิงพื้นที่ของชุดข้อมูล

3. กรณีพื้นที่เดิมอยู่ภายใต้หลายสถานีภาค จะ คำนวณค่าเฉลี่ยความต้องการรายเดือนในช่วงปี พ.ศ. 2554– 2559 เพื่อหาสัดส่วนความต้องการของแต่ละสถานี และใช้ สัดส่วนดังกล่าวในการกระจายข้อมูลกลับไปยังสถานีเดิม อย่างเป็นระบบ



รูปที่ 6 การกระจายข้อมูลสำหรับวิเคราะห์ใน Machine Learning

ลักษณะการกระจายของข้อมูลแสดงในรูปที่ 6 โดย กำหนดสีแทนแต่ละภูมิภาค ได้แก่ สีแดงแทนภาคกลาง สีส้ม แทนภาคตะวันออกเฉียงเหนือ สีเขียวแทนภาคเหนือ และสี น้ำเงินแทนภาคใต้ จากรูปพบว่าข้อมูลในช่วงปี พ.ศ. 2563– 2566 ได้ถูกกระจายกลับไปยังพื้นที่รับผิดชอบเดิมที่มีการ บันทึกรายข้อมูลครบถ้วนมากกว่า ส่งผลให้โครงสร้างชุดข้อมูลมี ความต่อเนื่องเชิงพื้นที่เพิ่มขึ้น และลดช่องว่างของข้อมูลอย่าง เป็นระบบ แนวทางดังกล่าวมีความเหมาะสมสำหรับการ นำไปใช้ในกระบวนการ Machine Learning เนื่องจากช่วย ลดปัญหา missing data และลดความผิดปกติของรูปแบบ เชิงพื้นที่ ทำให้แบบจำลองสามารถเรียนรู้แนวโน้มได้เสถียร มากขึ้น โดยเฉพาะเมื่อข้อมูลถูกแบ่งเป็นชุดฝึก (training set) และชุดทดสอบ (testing set) ตามลำดับเวลา ทำให้การ ขาดข้อมูลในช่วงปี พ.ศ. 2560–2562 จึงไม่ส่งผลกระทบต่อ อย่างมีนัยสำคัญต่อกระบวนการเรียนรู้ เนื่องจากแบบจำลอง ยังคงได้รับข้อมูลก่อนและหลังช่วงเวลาดังกล่าวเพียงพอ สำหรับการประมาณแนวโน้มโดยรวม

3.4 การวิเคราะห์ทางสถิติ

3.4.1 การหาลักษณะการแจกแจง

งานวิจัยนี้ดำเนินการวิเคราะห์ลักษณะการแจกแจงของข้อมูลความต้องการฉุกเฉินน้ำใจ โดยใช้ Python ในการสร้างฟังก์ชันความหนาแน่นความน่าจะเป็น (Probability Density Function: PDF) และฟังก์ชันการแจกแจงสะสม (Cumulative Distribution Function: CDF) ของข้อมูลทั้ง ในระดับสถานีและระดับคลัสเตอร์ เพื่อให้การประมาณค่ามีความเหมาะสม งานวิจัยได้ทดสอบรูปแบบการแจกแจงความ น่าจะเป็นหลายรูปแบบ ได้แก่ Normal distribution,

Exponential distribution และ Lognormal distribution โดยประเมินแบบจำลองผ่านการทดสอบ Chi-square และ Kolmogorov–Smirnov (KS) test ซึ่งใช้ค่า p-value เป็นเกณฑ์ในการเปรียบเทียบ

ตารางที่ 2 ค่า p value ของการแจกแจงความน่าจะเป็นที่แตกต่างกัน

สถานีภาค	จำนวนข้อมูล	Normal distribution		Lognormal distribution		Exponential distribution	
		Chi-square	KS test	Chi-square	KS test	Chi-square	KS test
ฝ่ายบรรเทาทุกข์	110	0.00	0.00	0.11	0.68	0.00	0.00
1	109	0.00	0.00	0.20	0.32	0.00	0.00
2	8	0.17	0.10	0.09	0.40	0.08	0.04
3	105	0.00	0.00	0.69	0.11	0.00	0.00
4	111	0.00	0.00	0.22	1.00	0.00	0.00
5	17	0.28	0.26	0.14	0.69	0.26	0.05
6	104	0.00	0.00	0.05	1.00	0.00	0.02
7	106	0.00	0.00	0.17	0.34	0.00	0.00
8	97	0.00	0.03	0.02	0.75	0.00	0.00
9	9	0.34	0.85	0.09	0.93	0.25	0.67
10	97	0.00	0.00	0.00	0.65	0.00	0.00
11	22	0.01	0.41	0.09	0.78	0.11	0.60
12	96	0.00	0.00	0.22	0.96	0.00	0.00
13	106	0.00	0.00	0.70	0.78	0.00	0.00
14	30	0.00	0.16	0.04	0.20	0.14	0.20

จากผลในตารางที่ 2 เมื่อพิจารณาภาพรวมพบว่าการแจกแจงแบบ Lognormal ให้ค่า p-value จากการทดสอบสูงกว่าการแจกแจงรูปแบบอื่นในสถานีส่วนใหญ่ สะท้อนว่าข้อมูลความต้องการมีลักษณะเป็นค่าบวกและกระจายแบบเบ้ขวา ทั้งนี้ในการพิจารณาผลการทดสอบได้ให้น้ำหนักกับผลจาก Kolmogorov–Smirnov (KS) test มากกว่า Chi-square test เนื่องจาก KS test เปรียบเทียบ

ฟังก์ชันการแจกแจงสะสมโดยตรงโดยไม่ต้องแบ่งข้อมูลเป็นช่วง จึงลดผลกระทบจากการกำหนดช่วงข้อมูลและเหมาะสมกับข้อมูลต่อเนื่องมากกว่า ด้วยเหตุนี้จึงเลือกใช้ Lognormal เป็นแบบจำลองหลักในการวิเคราะห์และกำหนดระดับคงคลังในขั้นตอนถัดไป

3.4.2 การแจกแจงข้อมูล Lognormal


ในการแจกแจงของข้อมูลแบบ Lognormal distribution จะดำเนินการประมาณค่าพารามิเตอร์ที่สำคัญได้แก่ ค่า μ และ σ ซึ่งเป็นค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของข้อมูล จากนั้นนำค่าพารามิเตอร์ที่ได้มาคำนวณค่าเฉลี่ย (Mean) และความแปรปรวน (Variance) ของการแจกแจง โดยจะได้ผลดังแสดงในตารางที่ 3 เพื่อใช้ในการวิเคราะห์ลักษณะความต้องการและเป็นข้อมูลพื้นฐานสำหรับการพยากรณ์ในขั้นตอนถัดไป

ตารางที่ 3 ค่าพารามิเตอร์ของการแจกแจงแบบ Lognormal


สถานีภาค	μ_{log}	σ_{log}	Fitted Mean	Fitted Variance	P value
ฝ่ายบรรเทาทุกข์	7.66	2.08	18,399	2.49×10^{10}	0.680
สถานีที่ 1	6.62	2.21	8,571	9.55×10^9	0.323
สถานีที่ 2	6.93	1.06	1,783	6.51×10^6	0.397
สถานีที่ 3	6.25	2.65	17,507	3.49×10^{11}	0.104
สถานีที่ 4	7.12	2.05	10,061	6.61×10^9	0.997
สถานีที่ 5	4.63	1.51	318	8.75×10^5	0.693
สถานีที่ 6	7.01	1.52	3,512	1.11×10^8	0.997
สถานีที่ 7	6.67	1.83	4,229	4.96×10^8	0.337
สถานีที่ 8	5.64	2.44	5,602	1.23×10^{10}	0.746
สถานีที่ 9	6.93	1.53	3,319	1.05×10^8	0.933
สถานีที่ 10	5.58	1.83	1,400	5.32×10^7	0.652
สถานีที่ 11	6.32	1.60	1,998	4.79×10^7	0.781
สถานีที่ 12	7.35	1.72	6,872	8.66×10^8	0.961
สถานีที่ 13	6.63	1.89	4,512	7.05×10^8	0.776
สถานีที่ 14	6.89	1.59	3,457	1.37×10^8	0.198

เพื่อแสดงลักษณะการกระจายของข้อมูลและตรวจสอบความสอดคล้องระหว่างข้อมูลจริงกับแบบจำลองที่เลือกใช้ จึงนำกราฟฟังก์ชันความหนาแน่นความน่าจะเป็น (Probability Density Function: PDF) และฟังก์ชันการแจกแจงสะสม (Cumulative Distribution Function:


CDF) มาใช้ในการวิเคราะห์ โดยกราฟ PDF ใช้แสดงรูปแบบการกระจาย ของข้อมูลในแต่ละช่วง ส่วนกราฟ CDF แสดงการสะสมของความน่าจะเป็นและใช้ระบุค่าที่ระดับความเชื่อมั่นร้อยละ 80 เพื่อกำหนดปริมาณความต้องการที่ควรเตรียมรองรับ การใช้กราฟทั้งสองประเภทควบคู่กันช่วยประเมินความเหมาะสมของแบบจำลองการแจกแจง เพิ่มความน่าเชื่อถือของผลการวิเคราะห์ ลดความคลาดเคลื่อนในการตีความข้อมูล และสนับสนุนการนำผลไปใช้ในกระบวนการพยากรณ์ได้อย่างเป็นระบบ ทั้งนี้ กราฟ PDF และ CDF ของแต่ละสถานีภาคกลางจะแสดงในรูปที่ 7-14




รูปที่ 7 Probability Density Function ของแต่ละสถานีภายในคลัสเตอร์ภาคกลาง




รูปที่ 8 Cumulative Distribution Function ของแต่ละสถานีภายในคลัสเตอร์ภาคกลาง




รูปที่ 9 Probability Density Function ของแต่ละสถานีภายในคลัสเตอร์ภาคเหนือ




รูปที่ 10 Cumulative Distribution Function ของแต่ละสถานีภายในคลัสเตอร์ภาคเหนือ




รูปที่ 11 Probability Density Function ของแต่ละสถานีภายในคลัสเตอร์ภาคตะวันออกเฉียงเหนือ



รูปที่ 12 Cumulative Distribution Function ของแต่ละสถานีภายในคลัสเตอร์ภาคตะวันออกเฉียงเหนือ




รูปที่ 13 Probability Density Function ของแต่ละสถานีภายในคลัสเตอร์ภาคใต้



รูปที่ 14 Cumulative Distribution Function ของแต่ละสถานีภายในคลัสเตอร์ภาคใต้

เมื่อรวมข้อมูลของสถานีภาคใต้ในแต่ละคลัสเตอร์ สามารถสร้างกราฟฟังก์ชันการแจกแจงสะสม ในระดับคลัสเตอร์ได้ ดังแสดงในรูปที่ 15 กราฟดังกล่าวสะท้อนลักษณะการกระจายของความต้องการพลังงานน้ำในภาพรวมของแต่ละกลุ่ม และใช้กำหนดระดับปริมาณพลังงานขั้นต่ำที่สามารถรองรับความต้องการได้ที่ระดับความเชื่อมั่นร้อยละ 80 เพื่อสนับสนุนการวางแผนและบริหารจัดการคงคลัง



รูปที่ 15 Cumulative Distribution Function ของแต่ละกลุ่มคลัสเตอร์

3.4.3 เปรียบเทียบชุดข้อมูล

ผลการเปรียบเทียบเกณฑ์คงคลังที่ระดับความปลอดภัยร้อยละ 80 ดังแสดงในตารางที่ 4 แสดงให้เห็นความแตกต่างอย่างชัดเจนระหว่างการจัดเก็บแบบแยกรายสถานีกับการบริหารในระดับคลัสเตอร์ โดยพบว่าการจัดกลุ่มสถานีภาคใต้ตามภูมิภาคช่วยลดปริมาณพลังงานน้ำที่ต้องสำรองรวมของระบบได้อย่างมีนัยสำคัญ สะท้อนว่าการบริหารแบบคลัสเตอร์ช่วยลดภาระการสำรองรวมได้โดยยังคงระดับความปลอดภัยตามเกณฑ์ที่กำหนดไว้

ตารางที่ 4 เปรียบเทียบจำนวนพลังงานที่ระดับคงคลัง 80%

สถานี ภาค	ความ ต้อง การ เฉลี่ย	เกณฑ์คง คลังที่ 80%	ปริมาณ รวมที่ 80% เมื่อ จัดเก็บ แยก สถานี	ปริมาณ รวมที่ 80% เมื่อ จัดเก็บ รวมกลุ่ม
ภาคเหนือ				
สถานีที่ 3	3,804	4,837	8,547	4,393
สถานีที่ 13	2,923	3,710		
ภาคตะวันออกเฉียงเหนือ				
สถานีที่ 1	3,692	4,803	19,143	4,742
สถานีที่ 4	6,698	6,927		
สถานีที่ 7	3,079	3,689		
สถานีที่ 9	2,298	3,724		
ภาคกลาง				
ฝ่ายบรรเทา ทุกข์	10,113	12,233	21,200	6,929
สถานีที่ 2	2,164	2,484		
สถานีที่ 5	272	364		
สถานีที่ 6	2,950	3,985		
สถานีที่ 11	1,302	2,134		
ภาคใต้				
สถานีที่ 8	1,523	2,208	13,816	3,090
สถานีที่ 10	2,532	1,229		
สถานีที่ 12	6,430	6,652		
สถานีที่ 14	2,422	3,727		

ผลการเปรียบเทียบแสดงว่า เมื่อรวมความต้องการเป็นกลุ่ม (cluster) ความผันผวนจะลดลง ทำให้ใช้คงคลังสำรองน้อยลงแต่ยังคงความปลอดภัยเท่าเดิมการจัดเก็บแบบรวมจึงช่วยกระจายความเสี่ยง ลดของซ้ำซ้อน และปรับใช้ทรัพยากรได้ยืดหยุ่นขึ้น อีกทั้งยังลดต้นทุนด้านพื้นที่ การจัดการ และการหมุนเวียนสินค้า โดยยังรองรับสถานการณ์ฉุกเฉินได้เหมือนเดิม

3.5 การพยากรณ์ถุน้ำใจโดยวิธี Machine learning

ในขั้นตอนการพยากรณ์ความต้องการถุน้ำใจจะใช้โปรแกรม RapidMiner โดยนำข้อมูลที่ผ่านมาการจัดการตามวิธีที่ได้นำเสนอไว้ข้างต้นไปสร้างแบบจำลองด้วยเทคนิค Machine Learning หลายรูปแบบ เพื่อเปรียบเทียบประสิทธิภาพของแต่ละวิธี การประเมินผลใช้ค่าสัมประสิทธิ์กำหนด (R^2) เป็นเกณฑ์หลัก จากนั้นคัดเลือกแบบจำลองที่ให้ค่า R^2 สูงที่สุด เพื่อนำไปใช้ในการพยากรณ์ความต้องการในปีถัดไป

3.5.1 ค่าน้ำหนักสำหรับข้อมูล

ในขั้นตอนการเตรียมข้อมูล ได้มีการกำหนดค่าน้ำหนักเพิ่มเติมเพื่อสะท้อนระดับความเสี่ยงด้านภัยพิบัติ โดยเนื่องจากถุน้ำใจส่วนใหญ่ถูกจัดสรรให้แก่ผู้ประสบอุทกภัย ปริมาณน้ำฝนจึงถูกใช้เป็นตัวแทนเชิงบริบทของระดับความเสี่ยงในแต่ละช่วงเวลา โดยอ้างอิงข้อมูลปริมาณน้ำฝนเฉลี่ยรายปีของประเทศไทยจากกรมอุตุนิยมวิทยา [16] ดังแสดงในรูปที่ 16



รูปที่ 16 ปริมาณฝนเฉลี่ยของประเทศไทยในคาบ 30 ปี

ค่าน้ำหนักถูกกำหนดในรูปแบบตัวถ่วงน้ำหนัก (Weighting factor) ตามระดับความเสี่ยง ดังแสดงในตาราง

ที่ 5 เพื่อให้ข้อมูลในช่วงที่มีความเสี่ยงสูงมีความสำคัญมากขึ้นในกระบวนการวิเคราะห์ ทั้งนี้ แนวทางดังกล่าวยังช่วยลดผลกระทบจากความไม่แน่นอนที่อาจเกิดจากการปรับโครงสร้างข้อมูลในขั้นตอนก่อนหน้า โดยเฉพาะความคลาดเคลื่อนจากการกระจายข้อมูลย้อนหลัง ซึ่งอาจทำให้ความรุนแรงของบางช่วงเวลาถูกกลบเกลื่อน

ตารางที่ 5 ตัวถ่วงน้ำหนักสำหรับชุดข้อมูล

ระดับความเสี่ยง	ปริมาณน้ำฝนเฉลี่ยภายในเดือน	ค่าถ่วงน้ำหนัก
ความเสี่ยงต่ำ	น้อยกว่า 50	1
ความเสี่ยงปานกลาง	50-100	1.5
ความเสี่ยงสูง	100-200	2
ความเสี่ยงมาก	มากกว่า 200	2.5

ค่าน้ำหนักที่ได้จะถูกนำไปใช้เป็นน้ำหนักของตัวอย่างข้อมูล (sample weight) ในขั้นตอนการฝึกแบบจำลอง Machine Learning เพื่อปรับระดับความสำคัญของข้อมูลรายเดือนที่มีระดับความเสี่ยงแตกต่างกัน กล่าวคือ ข้อมูลในช่วงที่มีปริมาณน้ำฝนสูงจะได้รับน้ำหนักมากกว่าช่วงปกติ ส่งผลให้ความคลาดเคลื่อนในช่วงดังกล่าวมีอิทธิพลต่อกระบวนการเรียนรู้ของแบบจำลองมากขึ้น แนวทางนี้มีวัตถุประสงค์เพื่อให้ผลการพยากรณ์สามารถรองรับสถานการณ์ความเสี่ยงสูงได้เหมาะสมยิ่งขึ้น โดยเฉพาะการลดโอกาสการประเมินความต้องการต่ำกว่าความเป็นจริงในช่วงวิกฤติ ทั้งนี้ ไม่มีการปรับโครงสร้างของแบบจำลองหรือปรับค่าข้อมูลเบื้องต้นเพิ่มเติม นอกเหนือจากการถ่วงน้ำหนักในขั้นตอนการฝึกแบบจำลอง เพื่อให้แนวทางการวิเคราะห์มีความชัดเจนและสอดคล้องกับกรอบการวิจัย

3.5.2 การดำเนินการในโปรแกรม

ในการสร้างแบบจำลองด้วยเทคนิค Machine Learning ได้เลือกใช้โมเดล ได้แก่ Gradient Boosted Trees (GBT), Deep Neural Network (Deep Learning), Generalized Linear Model (GLM) และ Random Forest เพื่อพยากรณ์จำนวนถุน้ำใจจากชุดข้อมูลที่ผ่านมา

จัดการตามแนวทางที่ได้นำเสนอไว้ก่อนหน้านี้ โดยกำหนดตัวแปรเป้าหมาย (Label) คือ จำนวนถูกรางวัลรายเดือน และตัวแปรนำเข้า (Input variables) ประกอบด้วย ปี เดือน สถานีกาชาด ค่าน้ำหนักความเสี่ยง และคลัสเตอร์ของสถานีนั้น โดยโมเดลที่ได้เลือกมานั้นครอบคลุมทั้งแนวทางเชิงเส้นและไม่เชิงเส้น เพื่อให้สามารถเปรียบเทียบความสามารถในการอธิบายและพยากรณ์ข้อมูลได้อย่างรอบด้าน ทั้งในกรณีที่มีความสัมพันธ์ของข้อมูลมีลักษณะเรียบง่ายและในกรณีที่มีความซับซ้อนมากขึ้น ก่อนคัดเลือกวิธีที่ให้ผลเหมาะสมที่สุดตามเกณฑ์การประเมินที่กำหนด

การแบ่งชุดข้อมูลใช้วิธีแบ่งตามลำดับเวลา โดยกำหนดข้อมูลช่วงปี พ.ศ. 2554–2559 เป็นชุดฝึก (Training set) และช่วงปี พ.ศ. 2563–2566 เป็นชุดทดสอบ (Testing set) เนื่องจากช่วงปี พ.ศ. 2560–2562 ไม่มีการบันทึกข้อมูล จึงตัดทิ้งและจัดสอดคล้องกับโครงสร้างของชุดข้อมูล และสะท้อนการพยากรณ์ข้อมูลในช่วงเวลาที่ถัดไปได้อย่างเหมาะสม


กระบวนการทำงานในโปรแกรม RapidMiner แบ่งออกเป็น 3 ส่วนหลัก ได้แก่ ส่วนการนำเข้าและเตรียมชุดข้อมูล ส่วนการสร้างและทดสอบโมเดล และส่วนการประเมินผลการพยากรณ์ ซึ่งในแต่ละส่วนทำหน้าที่แตกต่างกันโดยฟังก์ชันที่นำมาใช้จะมีหน้าที่ดังแสดงในตารางที่ 6

ตารางที่ 6 การทำงานของฟังก์ชันใน RapidMiner


ชื่อฟังก์ชัน	การทำงาน
Retrieve Data	ดึงชุดข้อมูลเข้า process
Generate Attributes	สร้างตัวแปรใหม่หรือปรับค่าข้อมูล
Filter Examples	คัดกรองข้อมูลตามเงื่อนไข
Set Role	กำหนดบทบาทของตัวแปร
Apply Model	นำแบบจำลองที่สร้างแล้วไปใช้กับชุดข้อมูล
Performance	ประเมินประสิทธิภาพโมเดล

ภายหลังจากกำหนดตัวแปรนำเข้า ตัวแปรเป้าหมาย และแบ่งชุดข้อมูลเรียบร้อยแล้ว ขั้นตอนถัดไปคือการสร้างกระบวนการทำงาน (Process) ในโปรแกรม


RapidMiner เพื่อใช้พัฒนา ทดสอบ และเปรียบเทียบประสิทธิภาพของแบบจำลองแต่ละประเภท โดยโครงสร้างการทำงานของแต่ละโมเดลจะแสดงดังรูปที่ 17–20




รูปที่ 17 process โมเดล Random Forest



รูปที่ 18 process โมเดล Deep Learning



รูปที่ 19 process โมเดล Generalized Linear Model



รูปที่ 20 process โมเดล Gradient Boosted Tree

3.5.3 ผลลัพธ์จากโมเดลและวิธีการเลือก

จากตารางที่ 7 พบว่าโมเดล Generalized Linear Model (GLM) ให้ค่า R-squared สูงที่สุด สะท้อนว่าแบบจำลองสามารถอธิบายแนวโน้มเชิงโครงสร้างของข้อมูลได้ค่อนข้างดี อย่างไรก็ตาม เมื่อพิจารณาพร้อมกับค่าความคลาดเคลื่อน (Error) ซึ่งยังอยู่ในระดับสูงในหลายภูมิภาค ดังนั้นแบบจำลองจึงอาจสะท้อนทิศทางได้ดี แต่ยังไม่สามารถทำนายผลได้อย่างเหมาะสม

ในทางตรงกันข้าม แบบจำลอง Deep Learning ให้ค่าความคลาดเคลื่อนต่ำกว่า GLM ในหลายภูมิภาค แต่ยังคงรักษาค่า R-squared อยู่ในระดับที่ยอมรับได้ สะท้อนถึงความสามารถในการเรียนรู้รูปแบบความสัมพันธ์ที่ไม่เป็นเชิงเส้นและโครงสร้างที่ซับซ้อนของข้อมูลได้ดีกว่า ถึงแม้ว่า R-squared จะไม่สูงที่สุด แต่ค่าความคลาดเคลื่อนโดยรวมต่ำกว่าโมเดลอื่นๆซึ่งมีความสำคัญต่อคุณภาพของค่าพยากรณ์ในเชิงปฏิบัติ เมื่อพิจารณาผลในภาพรวมจึงเห็นว่า Deep

Learning มีความสมดุลระหว่างความสามารถในการอธิบายข้อมูลและความแม่นยำในการพยากรณ์มากที่สุด และเหมาะสมสำหรับนำไปใช้ในการพยากรณ์ความต้องการในขั้นตอนถัดไปของงานวิจัยนี้

ตารางที่ 7 ผลการเปรียบเทียบประสิทธิภาพของแต่ละโมเดล


ข้อมูล 10 ปีภาคกลาง (สถานีอากาศที่ 2,6)				
Model	Prediction 80%CDF	RMSE	Absolute Error	R ²
Generalized Linear Model	15,850.85	16,144.3 7	22,992.85	0.99
Deep Learning	18,088.34	4,917.13	6,300.47	0.93
Random Forest	9,972.61	4,488.19	9,045.16	0.96
Gradient Boosted	16,386.39	9,606.62	14,892.04	0.89
ข้อมูล 10 ปีภาคเหนือ (สถานีอากาศที่ 3,13)				
Generalized Linear Model	4,796.30	4,236.39	6,863.24	1
Deep Learning	6,411.15	3,579.64	4,372.15	0.85
Random Forest	4,116.81	2,404.05	4,833.77	0.77
Gradient Boosted	5,581.60	2,843.69	4,312.12	0.88
ข้อมูล 10 ปีภาคตะวันออกเฉียงเหนือ (สถานีอากาศที่ 1,4,7)				
Generalized Linear Model	4,086.55	7,033.63	19,209.71	1
Deep Learning	9,576.75	3,549.89	5,780.98	0.96
Random Forest	3,672.48	2,694.27	9,319.20	0.9
Gradient Boosted	5,590.76	4,678.95	14,973.77	0.76
ข้อมูล 10 ปีภาคใต้ (สถานีอากาศที่ 8,10,12)				
Generalized Linear Model	5,590.76	5,684.57	11,191.01	1
Deep Learning	17,461.95	4,827.88	5,679.33	0.93
Random Forest	3,031.14	3,806.78	9,793.21	0.51
Gradient Boosted	7,520.65	3,874.94	6,912.37	0.62

3.6 ประเมินผลจากการพยากรณ์โดรนวิธี Machine Learning ร่วมกับกราฟ CDF

จากตารางที่ 8 และรูปที่ 21 พบว่าค่าความต้องการอุทธรณ์น้ำที่ได้จากแบบจำลอง Deep Learning เมื่อนำไปเทียบกับกราฟ CDF ของแต่ละคลัสเตอร์ อยู่ในช่วงระดับความเชื่อมั่นประมาณ 80–90% ซึ่งใกล้เคียงกับระดับความปลอดภัยที่กำหนดไว้

ตารางที่ 8 ระดับความเชื่อมั่นของค่าที่พยากรณ์ได้

กลุ่ม	จำนวน พยากรณ์	ระดับ ความเชื่อมั่น
ภาค กลาง	18,08	90.63
ภาคเหนือ	6,411	84.24
ภาคตะวันออกเฉียงเหนือ	9,577	88.37
ภาคใต้	17,46	95.34



รูปที่ 21 กราฟ CDF แสดงระดับความเชื่อมั่นของค่าความต้องการอุทธรณ์น้ำจากการพยากรณ์ในแต่ละกลุ่ม

ผลดังกล่าวสะท้อนว่าแบบจำลองสามารถประมาณค่าความต้องการได้ในช่วงที่มีความน่าเชื่อถือและสอดคล้องกับเกณฑ์ความปลอดภัยของระบบ โดยเฉพาะภาคกลางและภาคใต้ที่ให้ระดับความเชื่อมั่นมากกว่าร้อยละ 90 และสำหรับภาคตะวันออกเฉียงเหนือและภาคเหนืออยู่ในช่วงมากกว่าร้อยละ 80 ซึ่งยังถือว่าอยู่ในระดับที่ยอมรับได้สำหรับการวางแผนคลัง ดังนั้นการใช้ผลพยากรณ์ร่วมกับกราฟ

CDF สามารถใช้เป็นเครื่องมือสนับสนุนการกำหนดระดับคงคลังได้อย่างเหมาะสมภายใต้ระดับความปลอดภัยที่ตั้งไว้

4. ผลการทดลอง

เมื่อพิจารณาว่าแบบจำลองการพยากรณ์ให้ผลลัพธ์อยู่ในระดับที่ยอมรับได้ จึงนำค่าพยากรณ์ดังกล่าวมาใช้เป็นฐานในการกำหนดปริมาณถุนาหรน้ำใจที่ควรจัดเก็บในระดับคลังสตอร์ ก่อนกระจายกลับไปยังแต่ละสถานีด้วยวิธีการจัดสรรตามสัดส่วนความต้องการ โดยกำหนดให้ค่าเฉลี่ยความต้องการของแต่ละสถานีจากชุดข้อมูลดิบเป็นเกณฑ์อ้างอิง และคำนวณเป็นร้อยละของความต้องการรวมภายในคลังสตอร์นั้นๆ เพื่อสะท้อนโครงสร้างความต้องการเชิงพื้นที่อย่างเหมาะสม โดยผลการคำนวณสัดส่วนความต้องการแสดงไว้ในตารางที่ 9–12

ตารางที่ 9 อัตราส่วนของน้ำหนักความต้องการของแต่ละสถานี ภายในคลังสตอร์ภาคเหนือ

สถานีภาคที่	3	13	รวม
ค่าเฉลี่ย	2,138	1,544	3,682
ร้อยละ	58	42	100

ตารางที่ 10 อัตราส่วนของน้ำหนักความต้องการของแต่ละสถานี ภายในคลังสตอร์ภาคกลาง

สถานีภาค	2	5	6	11	ฝ่ายบรรเทาทุกข์	รวม
ค่าเฉลี่ย	1,623	192	1,248	1,184	9,654	13,900
ร้อยละ	12	1	9	9	69	100

ตารางที่ 11 อัตราส่วนของน้ำหนักความต้องการของแต่ละสถานี ภายในคลังสตอร์ภาคตะวันออกเฉียงเหนือ

สถานีภาคที่	1	4	7	9	รวม
ค่าเฉลี่ย	1,524	2,595	2,063	1,787	3,682
ร้อยละ	19	33	26	22	100

ตารางที่ 12 อัตราส่วนของน้ำหนักความต้องการของแต่ละสถานี ภายในคลังสตอร์ภาคกลาง

สถานีภาคที่	8	10	12	14	รวม
ค่าเฉลี่ย	487	1,357	2,679	2,099	3,682
ร้อยละ	7	21	40	32	100

เมื่อทราบสัดส่วนร้อยละของความต้องการของแต่ละสถานีภายในกลุ่มคลังสตอร์แล้ว จึงนำค่าปริมาณถุนาหรน้ำใจที่ได้จากการพยากรณ์ในระดับคลังสตอร์มากระจายกลับไปยังแต่ละสถานีตามสัดส่วนดังกล่าว เพื่อให้การจัดเตรียมทรัพยากรสะท้อนระดับความต้องการของพื้นที่รับผิดชอบอย่างเหมาะสม แนวทางนี้ช่วยให้การกำหนดปริมาณสำรองในระดับสถานีมีความสอดคล้องกับโครงสร้างความต้องการเชิงพื้นที่ โดยผลการคำนวณจำนวนถุนาหรน้ำใจที่เหมาะสมสำหรับแต่ละสถานีภายในคลังสตอร์ได้นำเสนอไว้ในตารางที่ 13–16

ตารางที่ 13 ผลการจัดสรรจำนวนถุนาหรน้ำใจตามสัดส่วนความต้องการของสถานีภาคในคลังสตอร์ภาคเหนือ

ภาคเหนือ มีการพยากรณ์จำนวนถุนาหรน้ำใจที่ 6,411 ถัง		
สถานีภาค	ร้อยละ	จำนวนถุนาหรน้ำใจที่ต้องการ
สถานีภาคที่ 3	58%	3,718
สถานีภาคที่ 13	42%	2,692

ตารางที่ 14 ผลการจัดสรรจำนวนถุนาหรน้ำใจตามสัดส่วนความต้องการของสถานีภาคในคลังสตอร์ภาคกลาง

ภาคกลาง มีการพยากรณ์จำนวนถุนาหรน้ำใจที่ 18,088 ถัง		
สถานีภาค	ร้อยละ	จำนวนถุนาหรน้ำใจที่ต้องการ
ฝ่ายบรรเทาทุกข์	69%	12,481
สถานีภาคที่ 2	12%	2,171
สถานีภาคที่ 5	1%	181
สถานีภาคที่ 6	9%	1,628
สถานีภาคที่ 11	9%	1,628

ตารางที่ 15 ผลการจัดสรรจำนวนถุธารน้ำใจตามสัดส่วนความต้องการของสถานีกาชาดในคลัสเตอร์ภาคตะวันออกเฉียงเหนือ

ภาคตะวันออกเฉียงเหนือมีการพยากรณ์จำนวนถุธารน้ำใจที่ 9,577 ถุ		
สถานีกาชาด	ร้อยละ	จำนวนถุธารน้ำใจที่ต้องการ
สถานีกาชาดที่ 1	19%	1,820
สถานีกาชาดที่ 4	33%	3,160
สถานีกาชาดที่ 7	26%	2,490
สถานีกาชาดที่ 9	22%	2,107

ตารางที่ 16 ผลการจัดสรรจำนวนถุธารน้ำใจตามสัดส่วนความต้องการของสถานีกาชาดในคลัสเตอร์ภาคใต้

ภาคใต้ มีการพยากรณ์จำนวนถุธารน้ำใจที่ 17,462 ถุ		
สถานีกาชาด	ร้อยละ	จำนวนถุธารน้ำใจที่ต้องการ
สถานีกาชาดที่ 8	7%	1,222
สถานีกาชาดที่ 10	21%	3,667
สถานีกาชาดที่ 12	40%	6,985
สถานีกาชาดที่ 14	32%	5,588

หลังการจัดสรรปริมาณถุธารน้ำใจให้แต่ละสถานีได้ประเมินความเพียงพอโดยเปรียบเทียบกับฟังก์ชันการแจกแจงสะสม (CDF) และคำนวณระดับความเชื่อมั่นในรูปแบบของร้อยละจากความน่าจะเป็นสะสม วิธีนี้สะท้อนความสามารถในการรองรับความต้องการตามข้อมูลในอดีต โดยสรุปผลไว้ในตารางที่ 17

ตารางที่ 17 ระดับความเชื่อมั่นของค่าที่พยากรณ์

สถานีกาชาด	จำนวนถุธารน้ำใจที่ต้องการหลังจากการจัดกลุ่ม	ระดับความเชื่อมั่น
ภาคเหนือ		
สถานีที่ 3	3,718	77.11
สถานีที่ 13	2,692	74.92
ภาคกลาง		
ฝ่ายบรรเทาทุกข์	12,481	80.27
สถานีกาชาดที่ 2	2,171	76.24
สถานีกาชาดที่ 5	181	64.70
สถานีกาชาดที่ 6	1,628	59.92
สถานีกาชาดที่ 11	1,625	74.91
ภาคตะวันออกเฉียงเหนือ		
สถานีกาชาดที่ 1	1,820	65.62
สถานีกาชาดที่ 4	3,610	69.97
สถานีกาชาดที่ 7	2,490	73.47
สถานีกาชาดที่ 9	2,107	68.09
ภาคใต้		
สถานีกาชาดที่ 8	1,222	72.56
สถานีกาชาดที่ 10	3,667	92.51
สถานีกาชาดที่ 12	6,985	80.78
สถานีกาชาดที่ 14	5,588	86.36

จากผลในตารางที่ 17 พบว่าระดับความเชื่อมั่นของปริมาณถุธารน้ำใจที่จัดสรรภายหลังการจัดกลุ่มมีความแตกต่างกันระหว่างสถานี โดยส่วนใหญ่มีค่าอยู่ในช่วงประมาณ 70–85% ซึ่งสะท้อนว่าปริมาณที่กำหนดสามารถรองรับความต้องการได้ในระดับใกล้เคียงกับเป้าหมายที่ตั้งไว้ ขณะที่บางสถานี เช่น สถานีกาชาดที่ 10 และสถานีกาชาดที่ 12 ในภาคใต้ มีระดับความเชื่อมั่นสูงกว่า 80% อย่างชัดเจน แสดงถึงความเพียงพอของปริมาณที่จัดสรร

อย่างไรก็ตาม บางสถานที่มีระดับความเชื่อมั่นต่ำกว่า 70% เช่น สถานีกาชาดที่ 5 และสถานีกาชาดที่ 6 ในภาคกลาง ซึ่งสะท้อนว่าการจัดสรรตามสัดส่วนเฉลี่ยอาจยังไม่ครอบคลุมความผันผวนเฉพาะพื้นที่ได้ทั้งหมด ผลดังกล่าวชี้ให้เห็นว่าแม้แนวทางการจัดกลุ่มจะช่วยเพิ่มประสิทธิภาพในภาพรวม แต่เมื่อพิจารณาในระดับสถานีอาจยังมีความแตกต่างของความเสี่ยงที่ต้องบริหารเพิ่มเติม

ในด้านข้อจำกัด วิธีการนี้ตั้งอยู่บนสมมติฐานว่าข้อมูลมีการแจกแจงแบบ Lognormal และใช้ค่าเฉลี่ยเป็นฐานในการคำนวณสัดส่วน ซึ่งอาจไม่สะท้อนเหตุการณ์รุนแรงที่เกิดขึ้นไม่บ่อยแต่ส่งผลกระทบสูงได้อย่างครบถ้วน นอกจากนี้ ชุดข้อมูลมีช่วงเวลาที่ขาดหาย และได้มีการปรับโครงสร้างข้อมูลย้อนหลังเพื่อให้เกิดความต่อเนื่อง แม้วิธีดังกล่าวช่วยให้สามารถวิเคราะห์ได้ แต่ก็อาจก่อให้เกิดความคลาดเคลื่อนบางส่วนและในส่วนของพยากรณ์ด้วยแบบจำลอง Machine Learning ได้ใช้ปริมาณน้ำฝนเป็นตัวแทนของระดับความเสี่ยงด้านภัยพิบัติ ซึ่งเป็นการประมาณในเชิงภาพรวม และอาจไม่ครอบคลุมปัจจัยอื่นที่มีผลต่อความต้องการ เช่น ประเภทของภัยพิบัติ ความรุนแรงของเหตุการณ์ หรือโครงสร้างประชากรของแต่ละพื้นที่

ดังนั้น ผลการวิเคราะห์ควรถูกพิจารณาภายใต้ข้อจำกัดเหล่านี้ และสามารถพัฒนาเพิ่มเติมได้โดยเพิ่มตัวแปรด้านความเสี่ยงอื่นในอนาคต

5. สรุป

ในงานวิจัยนี้มีความต้องการที่จะพัฒนาแนวทางการพยากรณ์ความต้องการฉุกเฉินน้ำใจของสภากาชาดไทย เพื่อให้การบริหารจัดการเกิดความยืดหยุ่นและสามารถตอบสนองต่อเหตุการณ์ภัยพิบัติได้อย่างรวดเร็ว โดยใช้ข้อมูลรายเดือนช่วงปี พ.ศ. 2554–2566 จากฝ่ายบรรเทาทุกข์และสถานีกาชาด 14 แห่ง และจัดกลุ่มเป็น 4 คลัสเตอร์ตามภูมิภาค เพื่อเปลี่ยนแนวคิดจากการจัดเก็บแยกรายสถานีสู่การบริหารคงคลังร่วมกันในระดับกลุ่ม

ในขั้นตอนการวิเคราะห์ข้อมูล ได้ประเมินลักษณะการแจกแจงด้วย Chi-square และ Kolmogorov-Smirnov (KS) test พบว่าข้อมูลมีความสอดคล้องกับ Lognormal distribution มากที่สุด จึงนำมาใช้เป็นฐานในการกำหนด

ระดับคงคลังที่ระดับความปลอดภัย 80% ผลการเปรียบเทียบแสดงให้เห็นว่าการบริหารในระดับคลัสเตอร์สามารถลดปริมาณคงคลังที่ต้องสำรองเมื่อเทียบกับการรวมผลแบบแยกรายสถานี สะท้อนถึงการลดความแปรปรวนรวมของระบบและเพิ่มประสิทธิภาพการใช้ทรัพยากร

ในส่วนของพยากรณ์ ได้พัฒนาแบบจำลอง Machine Learning หลายรูปแบบและประเมินด้วยค่า R^2 และค่าความคลาดเคลื่อน ถึงแม้โมเดล Generalized Linear Model (GLM) จะให้ค่า R^2 สูงในบางกรณี แต่มีความคลาดเคลื่อนสูงกว่าโมเดลอื่น จึงเลือกใช้ Deep Learning ซึ่งให้ความสมดุลระหว่างความแม่นยำและความเสถียรของผลลัพธ์มากกว่า จากนั้นนำค่าพยากรณ์ไปประเมินร่วมกับกราฟ CDF ของแต่ละคลัสเตอร์ เพื่อแปลงผลเชิงสถิติให้เป็นระดับความเชื่อมั่นเชิงความเสี่ยง พบว่าระดับความเชื่อมั่นอยู่ในช่วงประมาณ 85–95% ซึ่งสอดคล้องกับระดับความปลอดภัยที่กำหนด

เมื่อกระจายผลพยากรณ์จากระดับคลัสเตอร์ไปยังแต่ละสถานี พบว่าระดับความเชื่อมั่นรายสถานีอยู่ในช่วงประมาณ 60–80% ซึ่งต่ำกว่าระดับคลัสเตอร์ แต่ยังคงอยู่ในช่วงที่ยอมรับได้ในทางปฏิบัติ สะท้อนว่าความแปรปรวนของความต้องการในแต่ละพื้นที่และความไม่สม่ำเสมอของเหตุการณ์ภัยพิบัตียังคงส่งผลกระทบต่อความไม่แน่นอนของการจัดสรรในระดับสถานี

โดยงานวิจัยนี้ได้เสนอการบูรณาการระหว่างพยากรณ์ด้วย Machine Learning และการประเมินความเสี่ยงผ่านกราฟ CDF เพื่อแปลงผลพยากรณ์เชิงสถิติให้เป็นระดับความเชื่อมั่นที่สามารถนำไปใช้กำหนดระดับคงคลังในระดับคลัสเตอร์ได้อย่างชัดเจน ซึ่งแนวทางดังกล่าวช่วยเชื่อมโยงการวิเคราะห์เชิงปริมาณกับการตัดสินใจเชิงบริหาร ทำให้ผลการพยากรณ์สามารถนำไปใช้จริงภายใต้ระดับความปลอดภัยที่กำหนด

อย่างไรก็ตาม งานวิจัยยังมีข้อจำกัดจากสมมติฐานการแจกแจงข้อมูล การปรับโครงสร้างข้อมูลย้อนหลัง และการใช้ปริมาณน้ำฝนเป็นตัวแทนความเสี่ยงในภาพรวม ซึ่งอาจไม่ครอบคลุมความแตกต่างด้านประเภทและความรุนแรงของภัยพิบัติในแต่ละพื้นที่ ดังนั้น ผลลัพธ์ควรถูกตีความ

ภายใต้กรอบข้อจำกัดดังกล่าว และในอนาคตอาจพิจารณา
บูรณาการตัวแปรด้านความเสี่ยงที่สะท้อนมิติเชิงพื้นที่และ
เชิงเวลาได้ละเอียดมากขึ้น เช่น ความถี่และความรุนแรงของ
ภัยพิบัติ เพื่อเพิ่มความแม่นยำและยกระดับความเชื่อมั่นของ
ผลการจัดสรร

6. เอกสารอ้างอิง

- [1] สภากาชาดไทย, “วิสัยทัศน์ พันธกิจ และยุทธศาสตร์,” สภากาชาดไทย. [Online]. Available: <https://redcross.or.th/aboutus/vision/>. [วันที่เข้าถึง 10 เมษายน 2568].
- [2] สภากาชาดไทย, “การให้ความช่วยเหลือ (relief),” สภากาชาดไทย. [Online]. Available: <https://redcross.or.th/mission/relief/>. [วันที่เข้าถึง 12 เมษายน 2568].
- [3] L. Li and Z. B. Zabinsky, “Incorporating uncertainty into a supplier selection problem,” *International Journal of Production Economics*, vol. 134, no. 2, pp. 344–356, 2011.
- [4] P. W. Murray, B. Agard, and M. A. Barajas, “Forecasting supply chain demand by clustering customers,” *IFAC-PapersOnLine*, vol. 48, no. 3, pp. 1834–1839, 2015.
- [5] C. H. Paramaiah, M. Jayanth, M. Sharma, M. P. Dande, K. D. Pipalia, and S. Kumar, “Machine learning in demand forecasting for supply chain management,” in *2025 International Conference on Technology Enabled Economic Changes (InTech)*, 2025.
- [6] W. Leelawan and C. Khompatraporn, “Multi-period pre-positioning stock model with fuzzy demands of humanitarian relief aids network,” in *Asia Pacific Industrial Engineering and Management Systems Conference (APIEMS 2019)*, Bangkok, Thailand, 2019.
- [7] A. Yariv, *Optical Electronics in Modern Communications*, New York: Oxford University Press, 1997.
- [8] F. J. Massey, Jr., “The Kolmogorov–Smirnov test for goodness of fit,” *Journal of the American Statistical Association*, vol. 46, no. 253, pp. 68–78, 1951.
- [9] T. M. Mitchell, *Machine Learning*, New York: McGraw-Hill, 1997.
- [10] L. Breiman, “Random forests,” Univ. California, Berkeley, CA, USA, Tech. Rep., 2001. [Online]. Available: <https://www.stat.berkeley.edu/~breiman/randomforest2001.pdf>. [Accessed 25 August 2025].
- [11] J. H. Friedman, “Greedy function approximation: A gradient boosting machine,” *The Annals of Statistics*, vol. 29, no. 5, pp. 1189–1232, 2001.
- [12] J. Nelder and R. W. M. Wedderburn, “Generalized linear models,” *Journal of the Royal Statistical Society: Series A*, vol. 135, no. 3, pp. 370–384, 1972.
- [13] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [14] The Thai Red Cross Society, “Relief supply warehouse guidelines,” [Online]. Available: https://rtrc.redcross.or.th/ewt/rtrc_web/article_attach/article_20141016161806.pdf. [Accessed 20 April 2025].
- [15] สำนักงานบรรเทาทุกข์และประชานามัยพิทักษ์ สภากาชาดไทย, “รายงานการดำเนินงานด้านการบรรเทาทุกข์และประชานามัย,” สภากาชาดไทย, 2567. [ออนไลน์]. แหล่งที่มา: https://rtrc.redcross.or.th/ewt/rtrc_web/downl

oad/article/article_20240521163713.pdf. [วันที่
เข้าถึง 19 เมษายน 2568].

- [16] Thai Meteorological Department, “Average monthly rainfall in Thailand (mm) over a 30-year period (1991–2020),” [Online]. Available: <https://www.tmd.go.th/ClimateChart/monthly-mean-rainfall-in-thailand-mm-30-years> [Accessed 25 August 2025].