

กรอบแนวคิดการเรียนรู้ของเครื่องแบบอธิบายได้ สำหรับการวิเคราะห์ความรุนแรงของอุบัติเหตุทางถนนช่วงเทศกาล

สุกานดา นาคลำภา¹, ชัชชญา ศรีนวลคำ² และ ศศิประภา หิริโอตบ³
ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร นครปฐม 73000

Received: 03 March 2026; Revised: 22 April 2026; Accepted: 08 May 2026

บทคัดย่อ

อุบัติเหตุทางถนนที่รุนแรงมักเป็นปัญหาสำคัญที่ก่อให้เกิดความสูญเสียต่อชีวิตและทรัพย์สิน โดยเฉพาะอย่างยิ่งในช่วงเทศกาลสงกรานต์ซึ่งมีปริมาณการจราจรที่หนาแน่น และมีปัจจัยแวดล้อมอื่น ๆ ที่ต่างจากช่วงเวลาปกติ งานวิจัยนี้จึงมุ่งเน้นการวิเคราะห์ระดับความรุนแรงของปัญหาดังกล่าวผ่านข้อมูลอุบัติเหตุของกระทรวงคมนาคม (พ.ศ. 2564–2567) โดยนำเสนอกรอบแนวคิดการเรียนรู้ของเครื่องแบบอธิบายได้ (Explainable Machine Learning) เพื่อยกระดับการพยากรณ์ความรุนแรงของอุบัติเหตุให้มีความโปร่งใสและนำไปใช้ประโยชน์ได้จริง คณะผู้วิจัยได้ใช้เทคนิค SMOTE เพื่อแก้ปัญหาความไม่สมดุลของข้อมูล และเปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง แรนดอมฟอเรสต์ (Random Forest) ชัฟฟอรัตเวกเตอร์แมชชีน (Support Vector Machine: SVM) และการถดถอยลอจิสติก (Logistic Regression) ผลการศึกษาพบว่าแบบจำลอง Random Forest ให้ประสิทธิภาพการทำนายภาพรวมดีที่สุด (Accuracy = 0.711 ± 0.006 , AUC = 0.706 ± 0.025) ขณะที่ SVM มีความแม่นยำสูงในการระบุเหตุการณ์ความรุนแรงระดับสูง (Sensitivity = 0.701 ± 0.033) นอกจากนี้การวิเคราะห์ด้วย SHAP (SHapley Additive exPlanations) ยังแสดงให้เห็นว่าการมีรถจักรยานยนต์เกี่ยวข้อง จำนวนยานพาหนะ และการชนที่เกิดจากความประมาทของตนเอง เป็นปัจจัยวิกฤตที่ส่งผลต่อความรุนแรง องค์ความรู้นี้ช่วยให้หน่วยงานที่เกี่ยวข้องเข้าใจสาเหตุเชิงลึกและสามารถกำหนดมาตรการความปลอดภัยเชิงรุกเพื่อลดอุบัติเหตุในช่วงเทศกาลได้อย่างยั่งยืน

คำสำคัญ: ความรุนแรงของอุบัติเหตุทางถนน, กรอบแนวคิดการเรียนรู้ของเครื่องแบบอธิบายได้, เทคนิค SMOTE, การวิเคราะห์ SHAP, ปัจจัยเสี่ยงอุบัติเหตุ

*Corresponding author: E-mail: Hiriote_s@silpakorn.edu

^{1,2} นักศึกษาระดับปริญญาตรี ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร

³ ผู้ช่วยศาสตราจารย์ ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร

An Explainable Machine Learning Framework for Analyzing Road Accident Severity during Festival Periods

Sukanda Naklampa¹, Chatchaya Srinuakham² and Sasiprapa Hirio^{*3}

^{1,2,3}Statistics Department, Faculty of science, Silpakorn university, Nakhon Pathom 73000

Received: 03 March 2026; Revised: 22 April 2026; Accepted: 08 May 2026

Abstract

Severe road traffic accidents are a critical issue causing immense loss of life and property, particularly during the Songkran festival, which is characterized by heavy traffic and unique environmental factors. This study focuses on analyzing accident severity using data from the Ministry of Transport (2021–2024) by proposing an Explainable Machine Learning (XAI) framework to enhance predictive transparency and practical application. To address data imbalance, the SMOTE technique was employed, and the performance of Random Forest, Support Vector Machine (SVM), and Logistic Regression models was compared. Empirical results showed that the Random Forest model achieved the best overall performance (Accuracy = 0.711 ± 0.006 , AUC = 0.706 ± 0.025), while the SVM demonstrated superior capability in identifying high-severity cases (Sensitivity = 0.701 ± 0.033). Furthermore, SHAP (SHapley Additive exPlanations) analysis revealed that motorcycle involvement, the number of vehicles, and self-caused collisions are critical risk factors. These insights provide a data-driven foundation for relevant agencies to develop proactive safety measures and mitigate festival-related accidents sustainably.

Keywords: Road Accident Severity, Explainable Machine Learning (XAI) Framework, SMOTE, SHAP Analysis, Accident Risk Factors

*Corresponding author: E-mail: Hirio_s@silpakorn.edu

^{1,2} Student in Department of Statistics, Faculty of Science, Silpakorn University

³ Assistant Professor in Department of Statistics, Faculty of Science, Silpakorn University

1. บทนำ

อุบัติเหตุทางถนนในช่วงเทศกาลสงกรานต์เป็นวิกฤตการณ์ที่ก่อให้เกิดความเสียหายทั้งชีวิตและทรัพย์สินอย่างต่อเนื่องในทุกปี โดยสถิติสะสมช่วงควบคุมเข้มข้น 7 วันในปีที่ผ่านมา (11-17 เมษายน 2568) พบอุบัติเหตุรวม 1,538 ครั้ง มีผู้เสียชีวิต 253 ราย และผู้บาดเจ็บที่ต้องพักรักษาตัว 1,495 ราย [1] ปัจจัยหลักที่ก่อให้เกิดอุบัติเหตุรุนแรงเกิดจากการขับรถเร็วเกินกำหนด (ร้อยละ 41.68) โดยประเภทรถที่มีสัดส่วนสูงสุดคือ รถจักรยานยนต์ (ร้อยละ 83.34) และมีพฤติกรรมเสี่ยงที่สำคัญ คือ การไม่สวมหมวกนิรภัย (ร้อยละ 63.33) นอกจากนี้ ข้อมูลอุบัติเหตุใหญ่ระบุว่ารถกระบะเป็นพาหนะที่เกี่ยวข้องกับเหตุการณ์รุนแรงมากที่สุด ซึ่งมีปัจจัยร่วมจากการไม่คาดเข็มขัดนิรภัยและอาการหลับใน [1]

แม้ว่างานวิจัยที่ผ่านมาจะมีการศึกษาเกี่ยวกับปัจจัยที่ส่งผลต่อการเกิดอุบัติเหตุ ทั้งปัจจัยด้านบุคคล [2] ปัจจัยด้านสิ่งแวดล้อม และปัจจัยด้านยานพาหนะ [3] แต่ยังขาดการวิเคราะห์เชิงลึกถึงปัจจัยที่ส่งผลต่อระดับความรุนแรงของอุบัติเหตุทางถนน นอกจากนี้ งานวิจัยส่วนใหญ่มีมุมมองเน้นไปที่สถิติในภาพรวม หรือ ใช้เพียงการวิเคราะห์ทางสถิติแบบดั้งเดิม เช่น การถดถอยลอจิสติก (Logistic Regression) เนื่องจากมีความง่ายในการตีความ แต่แบบจำลองพื้นฐานนี้ยังมีข้อจำกัดในการจัดการกับชุดข้อมูลขนาดใหญ่และมีความสัมพันธ์ที่ซับซ้อนระหว่างตัวแปรต่างๆ [4] ส่งผลให้มีการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เช่น ต้นไม้ตัดสินใจ (Decision Tree) แรนดอมฟอเรสต์ (Random Forest) และ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) ร่วมกับแนวคิดปัญญาประดิษฐ์ที่อธิบายได้ (Explainable AI) เช่น SHAP และ LIME ซึ่งมีงานวิจัยพบว่าให้ความแม่นยำสูงกว่าและสามารถจับความสัมพันธ์แบบไม่เป็นเชิงเส้นที่แบบจำลองดั้งเดิมไม่สามารถทำได้ [5]

อย่างไรก็ตาม งานวิจัยส่วนใหญ่มีมุมมองเน้นไปที่สถิติอุบัติเหตุในช่วงเวลาก่อนการระบาดของโรคโควิด-19 ซึ่งอาจไม่สะท้อนถึงพฤติกรรมขับขี่และปัจจัยแวดล้อมที่แท้จริงภายหลังการผ่อนคลายมาตรการควบคุม การวิเคราะห์ความ

รุนแรงของอุบัติเหตุในช่วงปี พ.ศ. 2564-2567 จึงมีความสำคัญอย่างยิ่ง เนื่องจากเป็นช่วงที่ปริมาณการจราจรกลับสู่สภาวะปกติ ซึ่งจะให้ข้อมูลเชิงลึกที่ทันสมัยและสอดคล้องกับบริบทปัจจุบันมากที่สุด

ด้วยเหตุผลดังกล่าว งานวิจัยนี้จึงมีวัตถุประสงค์หลักเพื่อเสนอกรอบแนวคิดการเรียนรู้ของเครื่องแบบอธิบายได้ (Explainable Machine Learning Framework) สำหรับการวิเคราะห์ปัจจัยเสี่ยงและระบุอิทธิพลของตัวแปรที่ส่งผลต่อระดับความรุนแรงของอุบัติเหตุทางถนนในระดับสูง (High Severity) ที่เกิดขึ้นในช่วงเทศกาลสงกรานต์ (พ.ศ. 2564-2567) บนโครงข่ายถนนของกระทรวงคมนาคม โดยการเปรียบเทียบประสิทธิภาพแบบจำลอง 3 รูปแบบที่มีโครงสร้างพื้นฐานแตกต่างกัน ได้แก่ (1) Logistic Regression ซึ่งเป็นแบบจำลองพื้นฐาน (Base line) (2) Random Forest และ (3) Support Vector Machine สำหรับความสัมพันธ์ที่ซับซ้อนและมีมิติสูง เพื่อนำไปสู่การพัฒนาเครื่องมือพยากรณ์ที่มีความแม่นยำควบคู่ไปกับความสามารถในการอธิบายเหตุผลเบื้องหลังการตัดสินใจของแบบจำลอง ผลการวิจัยที่ได้เป็นสารสนเทศเชิงลึกที่มีความทันสมัยสำหรับหน่วยงานที่เกี่ยวข้อง เช่น ศูนย์อำนวยการความปลอดภัยทางถนนและกระทรวงสาธารณสุข ในการวางแผนเชิงยุทธศาสตร์และกำหนดมาตรการป้องกันอุบัติเหตุในช่วงเทศกาลในอนาคตได้อย่างตรงจุด อันจะนำไปสู่การลดความสูญเสียทั้งในชีวิตและทรัพย์สินของประชาชนอย่างยั่งยืนต่อไป

2. แนวคิดและทฤษฎีที่เกี่ยวข้อง

เพื่อให้บรรลุวัตถุประสงค์ในการเสนอกรอบแนวคิดการเรียนรู้ของเครื่องแบบอธิบายได้ สำหรับการวิเคราะห์ปัจจัยเสี่ยงต่ออุบัติเหตุรุนแรงในช่วงเทศกาลสงกรานต์ งานวิจัยนี้จึงได้บูรณาการแบบจำลองการเรียนรู้ของเครื่องที่มีกลไกการจำแนกประเภทแตกต่างกัน เพื่อทดสอบประสิทธิภาพของกรอบแนวคิดผ่านข้อมูลอุบัติเหตุบนโครงข่ายถนนของกระทรวงคมนาคมระหว่างปี พ.ศ. 2564-2567 โดยแบบจำลองที่คัดเลือกมาใช้เป็นแกนกลางของกรอบแนวคิด ได้แก่ Logistic Regression (LR) Random

Forest (RF) และ Support Vector Machine (SVM) ซึ่งมีจุดเด่นและข้อจำกัดที่ต่างกัน ดังแสดงในตารางที่ 1

กรอบแนวคิดที่นำเสนอในงานวิจัยนี้ไม่ได้มุ่งเน้นเพียงความแม่นยำในการพยากรณ์เท่านั้น แต่ยังให้ความสำคัญกับ "ความสามารถในการอธิบาย" (Explanability) เพื่อระบุปัจจัยเสี่ยงสำคัญที่ส่งผลต่อการเกิดอุบัติเหตุรุนแรงได้อย่างเป็นรูปธรรม ผู้วิจัยจึงได้นำเทคนิค SHAP (SHapley Additive exPlanations) มาใช้เป็นเครื่องมือหลักในการแปลผลการตัดสินใจของแบบจำลอง ซึ่งจะช่วยให้หน่วยงานที่เกี่ยวข้องสามารถเข้าใจอิทธิพลของแต่ละปัจจัยเสี่ยงในช่วงเทศกาลสงกรานต์ได้อย่างชัดเจน

ตารางที่ 1 การเปรียบเทียบจุดเด่นและข้อจำกัดเชิงเทคนิคของแบบจำลองภายใต้กรอบแนวคิดการเรียนรู้ของเครื่อง


แบบจำลอง	จุดเด่นในการวิเคราะห์	ข้อจำกัดเชิงเทคนิค
Logistic Regression	เป็นแบบจำลองมาตรฐานที่ให้ค่า Odds Ratio ชัดเจน ช่วยในการระบุทิศทางของปัจจัยเสี่ยงเบื้องต้นได้อย่างแม่นยำ	ไม่สามารถจับความสัมพันธ์ที่ซับซ้อนแบบไม่เป็นเชิงเส้น (Non-linear) ของปัจจัยแวดล้อมได้
Random Forest	มีความแม่นยำสูงในการทำนายอุบัติเหตุรุนแรง จัดการกับข้อมูลที่มีปฏิสัมพันธ์ระหว่างตัวแปรสูง และลดปัญหาการเรียนรู้ที่มากเกินไป (Overfitting)	มีลักษณะเป็นกล่องดำ (Black-box) ซึ่งยากต่อการอธิบายเหตุผลในเชิงลึกหากไม่มีเทคนิคเสริม
Support Vector Machine	มีประสิทธิภาพในการแบ่งแยกคลาสความรุนแรงในปริภูมิข้อมูลมิติสูง และมีความยืดหยุ่นด้วยเทคนิค Kernel	การปรับจูนพารามิเตอร์มีความซับซ้อนสูง และยากต่อการทำความเข้าใจในระดับการปฏิบัติงานจริง

สำหรับรายละเอียดคุณลักษณะเชิงลึกของแต่ละแบบจำลอง เกณฑ์การประเมินประสิทธิภาพในมิติต่าง ๆ (Accuracy, AUC, F1-Score, Recall) และกลไกการคำนวณค่า SHAP จะถูกนำเสนอในหัวข้อย่อยถัดไป เพื่อใช้เป็นฐานสำหรับการนำเสนอกระบวนการทำงานและผัง

โครงสร้างของกรอบแนวคิด (Framework Diagram) ซึ่งจะกล่าวถึงโดยละเอียดในหัวข้อที่ 3

2.1 Random Forest

Random Forest เป็นอัลกอริทึมการเรียนรู้ของเครื่องแบบกลุ่ม (Ensemble Learning) ที่พัฒนาโดย Leo Breiman [6] โดยใช้โครงสร้างพื้นฐานจาก Decision Tree จำนวนมากมาทำงานร่วมกัน หลักการสำคัญคือการใช้หลักการ Bagging (Bootstrap Aggregating) ซึ่งเริ่มต้นจากการใช้เทคนิค Bootstrapping หรือการสุ่มตัวอย่างแบบใส่คืน (Random Sampling with Replacement) เพื่อสร้างชุดข้อมูลย่อยที่แตกต่างกันสำหรับการฝึกสอนต้นไม้แต่ละต้น จากนั้นจึงทำ Aggregating หรือการรวมผลลัพธ์จากต้นไม้ทุกต้นเข้าด้วยกัน นอกจากนี้ Random Forest ยังมีการสุ่มเลือกกลุ่มย่อยของตัวแปรอิสระ (Feature Randomness) ในการแบ่งโหนด เพื่อลดความสัมพันธ์ระหว่างต้นไม้แต่ละต้น ผลลัพธ์สุดท้ายจะได้รับการลงคะแนนเสียงข้างมาก (Majority Voting) สำหรับการจำแนกประเภท ดังแสดงในรูปที่ 1 ซึ่งกระบวนการนี้ช่วยลดปัญหาการเรียนรู้ที่มากเกินไป (Overfitting) ได้อย่างมีประสิทธิภาพมากกว่าต้นไม้ตัดสินใจเดี่ยว นอกจากนี้ยังมีข้อมูลส่วนที่เหลือจากการสุ่ม (Out-of-Bag: OOB) ที่สามารถนำมาใช้ประเมินประสิทธิภาพของแบบจำลองได้โดยไม่ต้องแยกชุดข้อมูลทดสอบเพิ่มเติม




รูปที่ 1 โครงสร้างและการทำงานของอัลกอริทึม Random Forest [7]

2.2 Support Vector Machine

Support Vector Machine (SVM) เป็นอัลกอริทึมที่ใช้หลักการการหาเส้นแบ่งหรือไฮเปอร์เพลน (Hyperplane) ที่เหมาะสมที่สุดในการจำแนกข้อมูลออกเป็น 2 คลาสหรือมากกว่า โดยเน้นการสร้างระยะห่างระหว่างกลุ่มข้อมูลให้กว้างที่สุด (Maximum Margin) [8] หลักการทำงานของ SVM สำหรับปัญหาการจำแนก 2 กลุ่ม ในปริภูมิ 2 มิติ แสดงในรูปที่ 2 จุดข้อมูลที่อยู่ใกล้เส้นแบ่งมากที่สุดจะเรียกว่า ซัพพอร์ตเวกเตอร์ (Support Vector) ในกรณีที่ข้อมูลมีความซับซ้อนเชิงไม่เส้น (Non-linear) และไม่สามารถแบ่งแยกด้วยเส้นตรงในปริภูมิเดิม (Input Space) ได้ SVM จะประยุกต์ใช้เทคนิคที่เรียกว่า เคอร์เนลทริก (Kernel Trick) เพื่อแปลงข้อมูลไปยังปริภูมิคุณลักษณะที่มีมิติสูงขึ้น (High-dimensional Feature Space) ซึ่งช่วยให้สามารถใช้ไฮเปอร์เพลนเชิงเส้น (Linear Hyperplane) ในการแบ่งแยกข้อมูลออกจากกันได้อย่างมีประสิทธิภาพ ฟังก์ชันเคอร์เนลที่นิยมใช้ได้แก่ [6], [8]

1. เคอร์เนลเชิงเส้น (Linear Kernel) เคอร์เนลเชิงเส้นมีความเหมาะสมกับชุดข้อมูลที่มีลักษณะการแยกกันได้ทางเชิงเส้น (Linearly Separable) ในปริภูมิเดิม (Original Space) โดยอาศัยไฮเปอร์เพลน (Hyperplane) เป็นขอบเขตในการจำแนกประเภท ทั้งนี้ มีพารามิเตอร์ที่สำคัญคือ ค่าความสูญเสีย (*Cost*) ซึ่งทำหน้าที่ควบคุมน้ำหนักของบทลงโทษ (Penalty) ต่อความผิดพลาดในการจำแนกข้อมูล (Misclassification) เพื่อสร้างสมดุลระหว่างความกว้างของขอบเขต (Margin) และความแม่นยำของแบบจำลอง

2. เคอร์เนลฟังก์ชันฐานรัศมี (Radial Basis Function Kernel: RBF) เคอร์เนล RBF เหมาะสำหรับชุดข้อมูลที่มีความซับซ้อนและมีลักษณะการแยกกันไม่ได้แบบไม่เชิงเส้น (Non-linear Separability) โดยนอกจากพารามิเตอร์ *Cost* แล้วยังประกอบด้วยพารามิเตอร์แกมมา (γ) ที่มีบทบาทสำคัญในการกำหนดขอบเขตอิทธิพล (Sphere of Influence) ของจุดข้อมูลตัวอย่างแต่ละจุด หากค่า γ มีค่าสูง จะส่งผลให้อิทธิพลของจุดข้อมูลครอบคลุมพื้นที่จำกัด ซึ่งอาจนำไปสู่ปัญหา Overfitting [9]



รูปที่ 2 หลักการทำงานของ SVM ในปริภูมิสองมิติ [10]

2.3 Logistic Regression

Logistic Regression เป็นเทคนิคทางสถิติที่ใช้สำหรับการวิเคราะห์หลายตัวแปร (Multivariate Analysis) ที่มีวัตถุประสงค์เพื่อทำนายโอกาสที่จะเกิดเหตุการณ์ที่สนใจ ภายใต้อิทธิพลของตัวแปรอิสระ โดยแบบจำลอง Logistic Regression จะนำมาใช้ในกรณีที่ตัวแปรตามเป็นตัวแปรเชิงคุณภาพ ซึ่งครอบคลุมทั้งรูปแบบการจำแนกประเภทแบบ Binary (สองกลุ่ม) และแบบ Multiclass (มากกว่าสองกลุ่มขึ้นไป) [11] ในงานวิจัยนี้จะใช้ Binary Logistic Regression เนื่องจากตัวแปรตามมีการกำหนดค่าผลลัพธ์เป็น 2 ระดับ แบบจำลอง Logistic Regression [12] แสดงได้ดังนี้

$$\log \left(\frac{\pi(x)}{1 - \pi(x)} \right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_M x_M \quad (1)$$

โดยที่ $\pi(x)$ แทน ความน่าจะเป็นที่จะเกิดเหตุการณ์ที่สนใจ

x_i แทน ตัวแปรอิสระตัวที่ i

β_0 แทน ค่าคงที่ (intercept)

β_i แทน ค่าสัมประสิทธิ์ของตัวแปรอิสระ

M แทน จำนวนตัวแปรอิสระทั้งหมดในแบบจำลอง

อัตราส่วนออดส์ (Odds Ratio: OR) เป็นดัชนีทางสถิติที่ใช้วัดระดับความสัมพันธ์ระหว่างปัจจัยที่พิจารณา (Exposure) กับโอกาสการเกิดเหตุการณ์ที่สนใจ โดยคำนวณ

จากการเปรียบเทียบอัตราส่วนโอกาสของกลุ่มที่มีปัจจัยเสี่ยง ต่ออัตราส่วนโอกาสของกลุ่มที่ไม่มีปัจจัยเสี่ยง สามารถแสดงความสัมพันธ์ในรูปของสมการได้ดังนี้

$$OR = \frac{\pi(x)}{1 - \pi(x)} = \exp(\beta_i) \quad (2)$$

ถ้า $OR > 1$ แสดงว่าปัจจัยดังกล่าวเป็นปัจจัยเสี่ยง (Risk Factor) ที่มีความสัมพันธ์เชิงบวกต่อการเกิดเหตุการณ์ กล่าวคือ กลุ่มที่มีปัจจัยเสี่ยงมีโอกาสเกิดเหตุการณ์สูงกว่ากลุ่มที่ไม่มีปัจจัยเสี่ยง

ถ้า $OR < 1$ แสดงว่าปัจจัยดังกล่าวเป็นปัจจัยปกป้อง (Protective Factor) ที่มีความสัมพันธ์เชิงลบต่อการเกิดเหตุการณ์ หรือลดโอกาสในการเกิดเหตุการณ์

ถ้า $OR = 1$ แสดงว่าปัจจัยดังกล่าวไม่มีความสัมพันธ์กับการเกิดเหตุการณ์ (No Association)

2.4 Confusion Matrix

Confusion Matrix คือเครื่องมือที่ใช้ในการประเมินประสิทธิภาพของแบบจำลองจำแนกประเภท โดยการเปรียบเทียบผลการทำนายของแบบจำลองกับค่าจริงที่เกิดขึ้น ดังแสดงในตารางที่ 2 ซึ่งประกอบด้วยค่าพื้นฐาน 4 ค่า ได้แก่ จำนวนผลบวกจริง (True Positive: TP) และจำนวนผลลบจริง (True Negative: TN) ซึ่งเป็นจำนวนผลการทำนายที่ถูกต้อง ส่วนการทำนายที่คลาดเคลื่อนประกอบด้วย จำนวนผลบวกเท็จ (False Positive: FP) หรือจำนวนครั้งของการเกิดความคลาดเคลื่อนประเภทที่ 1 (Type I Error) และจำนวนผลลบเท็จ (False Negative: FN) หรือจำนวนครั้งของการเกิดความคลาดเคลื่อนประเภทที่ 2 (Type II Error) [13]

ตารางที่ 2 ตาราง Confusion Matrix

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

สำหรับการวัดประสิทธิภาพของแบบจำลองจำแนกประเภท มีดัชนีชี้วัดที่สำคัญดังนี้

1. ความถูกต้อง (Accuracy) คือ สัดส่วนของผลการทำนายที่ถูกต้องทั้งหมด (ทั้งบวกจริงและลบจริง) เทียบกับจำนวนข้อมูลทั้งหมด เพื่อประเมินประสิทธิภาพโดยรวมของแบบจำลองในการจำแนกข้อมูลได้ถูกต้อง คำนวณได้ดังนี้

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

2. ความเที่ยงตรง (Precision) คือ สัดส่วนของผลการทำนายว่าเป็นบวกที่ถูกต้อง (True Positive) เทียบกับจำนวนข้อมูลที่แบบจำลองทำนายว่าเป็นบวกทั้งหมด เพื่อวัดความน่าเชื่อถือเมื่อแบบจำลองพยากรณ์ว่าข้อมูลนั้นอยู่ในกลุ่มที่สนใจ คำนวณได้ดังนี้

$$Precision = \frac{TP}{(TP + FP)} \quad (4)$$

3. ความไว (Sensitivity หรือ Recall) คือ สัดส่วนของผลการทำนายว่าเป็นบวกที่ถูกต้อง เทียบกับจำนวนข้อมูลที่อยู่ในกลุ่มบวกจริงทั้งหมด เพื่อวัดความสามารถในการตรวจจับหรือครอบคลุมข้อมูลในกลุ่มที่สนใจ คำนวณได้ดังนี้

$$Recall = \frac{TP}{(TP + FN)} \quad (5)$$

4. คะแนน F1 (F1-Score) คือ ค่าเฉลี่ยแบบฮาร์โมนิก (Harmonic Mean) ระหว่างค่าเที่ยงตรง (Precision) และความไว (Recall) เพื่อใช้เป็นดัชนีชี้วัดสมดุลประสิทธิภาพในกรณีที่ข้อมูลแต่ละกลุ่มมีจำนวนไม่เท่ากัน (Imbalanced Data) คำนวณได้ดังนี้

$$F1 - Score = 2 * \frac{(precision * recall)}{(precision + recall)} \quad (6)$$

5. เส้นโค้ง ROC และพื้นที่ใต้เส้นโค้ง (AUC) เส้นโค้ง ROC (Receiver Operating Characteristic Curve) แสดงความสัมพันธ์ระหว่างอัตราผลบวกจริง (True Positive Rate: TPR) และอัตราผลบวกเท็จ (False Positive Rate: FPR) ในระดับเกณฑ์การตัดสินใจต่าง ๆ โดยมีสูตรการคำนวณดังนี้

$$TPR = \frac{TP}{(TP + FN)} \quad (7)$$

$$FPR = \frac{TP}{(FP + TN)} \quad (8)$$

ค่า AUC (Area Under the Curve) คือพื้นที่ใต้เส้นโค้ง ROC ซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 หากค่า AUC เข้าใกล้ 1 หมายถึงแบบจำลองมีประสิทธิภาพในการแยกแยะคลาสได้ดีเยี่ยม หากค่า AUC มีค่าประมาณ 0.5 แสดงว่าแบบจำลองไม่มีความสามารถในการแยกแยะคลาส (ไม่ต่างจากการเดาสุ่ม)

2.5 แนวคิด SHAP (SHapley Additive exPlanations)

แนวคิด SHAP เป็นกรอบการทำงานเชิงทฤษฎีที่ใช้สำหรับอธิบายผลลัพธ์ของแบบจำลองการเรียนรู้ของเครื่อง โดยมีวัตถุประสงค์เพื่อเพิ่มความสามารถในการอธิบายให้แก่แบบจำลองที่มีความซับซ้อนสูง (Black-box Models) เช่น Random Forest หรือ Support Vector Machine โดย SHAP ใช้พื้นฐานจากการกำหนดค่าอิทธิพลของแต่ละคุณลักษณะ (Feature Attribution) เพื่อระบุว่าตัวแปรอิสระแต่ละตัวส่งผลต่อการพยากรณ์อย่างไร [14] โดยกรอบแนวคิดนี้กำหนดให้ฟังก์ชันการอธิบายแบบจำลองอยู่ในรูปของผลรวมเชิงเส้นของคุณลักษณะแบบบวก (Additive Feature Attribution Methods) ดังแสดงในสมการที่ 9

$$g(z') = \phi_0 + \sum_{j=1}^M \phi_j z'_j \quad (9)$$

โดยที่ $g(z')$ แทน แบบจำลองที่ใช้ในการอธิบาย (Explanation Model) ที่ให้ค่าสอดคล้องกับค่าพยากรณ์ของแบบจำลองจริง

ϕ_0 แทน ค่าพื้นฐานหรือค่าพยากรณ์เฉลี่ยของข้อมูลทั้งหมด (Base Value)

ϕ_j แทน ค่าอิทธิพลของตัวแปรอิสระที่ j (SHAP Value)

z'_j แทน ตัวแปรบ่งชี้สถานะของคุณลักษณะ (มีค่าเป็น 1 เมื่อปรากฏคุณลักษณะนั้น และมีค่าเป็น 0 เมื่อไม่ปรากฏ)

M แทน จำนวนตัวแปรอิสระทั้งหมดในแบบจำลอง การคำนวณค่า SHAP (ϕ_j) จะพิจารณาจากผลกระทบส่วนเพิ่ม (Marginal Contribution) ของตัวแปรอิสระนั้น ๆ เมื่อเทียบกับกลุ่มของตัวแปรอื่นที่เป็นไปได้ทั้งหมด ซึ่งจะช่วยให้

ผู้วิจัยสามารถระบุระดับความสำคัญและทิศทางของอิทธิพลได้

2.5.1 การตีความทิศทางของค่า SHAP


ทิศทางของค่า ϕ_j จะสะท้อนถึงผลกระทบของตัวแปรอิสระที่มีต่อการเปลี่ยนแปลงของค่าพยากรณ์จากค่าเฉลี่ยฐาน ดังนี้

- อิทธิพลเชิงบวก ($\phi_j > 0$) หมายความว่าตัวแปรอิสระนั้นส่งผลให้ค่าพยากรณ์เพิ่มสูงขึ้นกว่าค่าเฉลี่ยฐาน ในบริบทของงานวิจัยนี้ คือ การเพิ่มโอกาสในการเกิดอุบัติเหตุที่มีความรุนแรงระดับสูง (High Severity)
- อิทธิพลเชิงลบ ($\phi_j < 0$) หมายความว่าตัวแปรอิสระนั้นส่งผลในทางตรงกันข้าม คือ การลดโอกาสในการเกิดอุบัติเหตุที่มีความรุนแรงระดับสูง หรือเป็นการผลักดันให้ผลลัพธ์ไปในทางความรุนแรงระดับต่ำ

นอกจากนี้ ขนาดของค่าสัมบูรณ์ของ ϕ_j ยังสามารถสะท้อนถึงระดับความสำคัญ (Importance) ของตัวแปรอิสระนั้นๆ โดยตัวแปรที่มีค่า SHAP ห่างจากศูนย์มาก (ไม่ว่าจะเป็นบวกหรือลบ) จะถูกจัดว่าเป็นตัวแปรที่มีอิทธิพลต่อการกระบวนการตัดสินใจของแบบจำลองสูง ซึ่งผู้วิจัยจะนำความสัมพันธ์นี้ไปวิเคราะห์ร่วมกับตัวแปรอิสระผ่านแผนภาพ Beeswarm Plot ต่อไป

3. วิธีการดำเนินงานวิจัย

ในงานวิจัยนี้ผู้วิจัยเลือกใช้ชุดข้อมูลจริง (Real-World Data) จากฐานข้อมูลอุบัติเหตุทางถนนบนโครงข่ายถนนของกระทรวงคมนาคม ซึ่งได้มาจากเว็บไซต์กระทรวงคมนาคม [15] โดยจะเลือกใช้ข้อมูลในช่วงเทศกาลสงกรานต์ คือวันที่ 11 – 17 เมษายน ของในแต่ละปี ตั้งแต่ปี พ.ศ. 2564 ถึง ปี พ.ศ. 2567 ซึ่งประกอบไปด้วยข้อมูลรายละเอียดการณจำนวน 5,305 เหตุการณ์ และมีจำนวนตัวแปรทั้งหมด 38 ตัวแปร และในงานวิจัยนี้ผู้วิจัยเลือกใช้โปรแกรม Microsoft Excel ในการคัดกรองข้อมูล และใช้โปรแกรม RStudio ในการวิเคราะห์และสร้างแบบจำลอง โดยมีกรอบแนวคิดของการดำเนินงานวิจัยดังรูปที่ 3



รูปที่ 3 กรอบแนวคิดการพัฒนาแบบจำลองและการวิเคราะห์ปัจจัยเสี่ยงในการทำนายความรุนแรงของอุบัติเหตุทางถนน

3.1 การจัดเตรียมและการทำความสะอาดข้อมูล

ในส่วนนี้ผู้วิจัยดำเนินการจัดการชุดข้อมูลเพื่อให้มีความพร้อมและเหมาะสมต่อการวิเคราะห์ โดยมีรายละเอียดกระบวนการดังนี้

1) การรวบรวมและคัดกรองข้อมูล ผู้วิจัยดำเนินการคัดกรองข้อมูลอุบัติเหตุทางถนนในช่วงเทศกาลสงกรานต์ (ระหว่างวันที่ 11 -17 เมษายน) ของปี พ.ศ.2564 ถึง 2567 เพื่อนำมาจัดทำฐานข้อมูลรวม โดยกำหนดตัวแปรตาม คือ ระดับความรุนแรงของอุบัติเหตุ ซึ่งจำแนกเป็น 2 กลุ่ม ได้แก่

- ระดับความรุนแรงสูง (High Severity) หมายถึง อุบัติเหตุที่ส่งผลให้มีผู้บาดเจ็บสาหัสหรือเสียชีวิตอย่างน้อย 1 ราย หรือเป็นอุบัติเหตุหมู่ที่มีจำนวนผู้ประสพภัยรวมตั้งแต่ 10 รายขึ้นไป
- ระดับความรุนแรงต่ำ (Low Severity) หมายถึง อุบัติเหตุที่มีผู้บาดเจ็บเล็กน้อยหรือเกิดความเสียหายต่อทรัพย์สินเพียงอย่างเดียว

2) การทำความสะอาดข้อมูล (Data Cleansing) ผู้วิจัยทำการตรวจสอบความสมบูรณ์ของชุดข้อมูลและดำเนินการคัดข้อมูลที่มีค่าสูญหาย (Missing Values) หรือข้อมูลที่ไม่สมบูรณ์จากการวิเคราะห์ ส่งผลให้เหลือข้อมูลที่ใช้ในการสร้างแบบจำลองทั้งสิ้น 5,295 เหตุการณ์

3) การแปลงค่าตัวแปรและการจัดการข้อมูล (Data Transformation) เพื่อเพิ่มประสิทธิภาพในการทำนาย ผู้วิจัยได้ดำเนินการจัดการตัวแปรบางส่วน ดังนี้

- ตัวแปรเวลาที่เกิดเหตุ ทำการแปลงข้อมูลเวลาที่เกิดเหตุเป็นช่วงเวลากลางวัน (Day) และช่วงเวลากลางคืน (Night)
- ตัวแปรตำแหน่งที่เกิดเหตุ จัดกลุ่มข้อมูลหลักกิโลเมตรที่เกิดเหตุโดยใช้วิธีการแบ่งช่วงตามควอไทล์ (Quantile Binning) พร้อมทั้งดำเนินการยุบรวมระดับตัวแปรที่มีความถี่น้อย (Category Consolidation) เพื่อลดปัญหาความเบาบางของข้อมูล (Data Sparsity)

3.2 การแบ่งข้อมูลสำหรับการพัฒนาแบบจำลองและการประเมินประสิทธิภาพ

กระบวนการแบ่งข้อมูลในการวิจัยนี้ถูกออกแบบมาเพื่อลดความเอนเอียง (Bias) และเพิ่มความแม่นยำในการประเมินประสิทธิภาพของแบบจำลอง โดยเฉพาะอย่างยิ่ง

การจัดการกับชุดข้อมูลที่มีความไม่สมดุลของคลาส แผนการดำเนินงานถูกแบ่งออกเป็น 2 ระยะหลัก [9] ดังนี้

1) ระยะการแบ่งข้อมูลทดสอบ (Hold-out Validation) ข้อมูลทั้งหมดจะถูกแบ่งออกเป็น 2 ชุดหลัก ด้วยเทคนิคการสุ่มตัวอย่างแบบชั้นภูมิ (Stratified Sampling) [16] เพื่อรักษาสัดส่วนของคลาส (Class

2) Distribution) ให้มีความใกล้เคียงกับชุดข้อมูลต้นฉบับ โดยแบ่งเป็นชุดข้อมูลฝึกสอน (Training Set) ร้อยละ 70 (จำนวน 3,708 เหตุการณ์) และชุดข้อมูลทดสอบ (Test Set) ร้อยละ 30 (จำนวน 1,587 เหตุการณ์)

3) ระยะการพัฒนาแบบจำลอง (Model Development) ในขั้นตอนนี้จะนำเฉพาะชุดข้อมูลฝึกสอนมาผ่านวิธีการตรวจสอบแบบไขว้โดยกำหนดจำนวนรอบเท่ากับ 5 (5-fold Cross-validation) [17] เพื่อใช้ในกระบวนการคัดเลือกตัวแปรและการปรับจูนเพื่อหาค่าพารามิเตอร์ที่เหมาะสม (Hyperparameter Tuning) ของแต่ละอัลกอริทึม วิธีการนี้ช่วยให้มั่นใจได้ว่าแบบจำลองที่พัฒนาขึ้นมีความสามารถในการนำไปใช้กับข้อมูลทั่วไป (Generalization) และลดความเสี่ยงในการเกิดปัญหา Overfitting [9] ก่อนที่จะนำแบบจำลองที่เหมาะสมที่สุดไปประเมินผลในขั้นตอนสุดท้ายด้วยชุดข้อมูลทดสอบ (Test Set) ต่อไป

3.3 การพัฒนาแบบจำลองและการประเมินประสิทธิภาพ

ในการวิจัยนี้ ผู้วิจัยดำเนินการพัฒนาแบบจำลองพยากรณ์ความรุนแรงของอุบัติเหตุ โดยใช้ชุดข้อมูลที่ทำความสะอาดแล้วจำนวน 5,295 เหตุการณ์ ซึ่งถูกแบ่งเป็นชุดข้อมูลฝึกสอนร้อยละ 70 (3,708 เหตุการณ์) เพื่อใช้ในการพัฒนาแบบจำลองผ่านวิธีการตรวจสอบแบบ 5-fold Cross-validation และชุดข้อมูลทดสอบร้อยละ 30 (1,587 เหตุการณ์) สำหรับการประเมินประสิทธิภาพขั้นสุดท้าย โดยมีขั้นตอนการดำเนินการดังนี้

3.3.1 การเตรียมข้อมูล (Preprocessing)

ผู้วิจัยดำเนินการแปลงตัวแปรเชิงกลุ่ม (Categorical Variables) ให้อยู่ในรูปตัวเลขเพื่อให้แบบจำลองสามารถประมวลผลได้ด้วยเทคนิค One-Hot Encoding โดยกำหนดให้ความรุนแรงระดับสูง (High Severity) เป็นคลาส

เป้าหมาย (Positive Class) จากนั้นทำการปรับมาตรฐานข้อมูลเชิงปริมาณ (Normalization) ด้วยวิธี Z-score Standardization เพื่อให้ข้อมูลอยู่ในมาตราส่วนเดียวกัน และลดผลกระทบจากความแตกต่างของหน่วยวัด

3.3.2 การจัดการข้อมูลไม่สมดุล

เพื่อแก้ไขปัญหาคือความไม่สมดุลของคลาสในชุดข้อมูลฝึกสอน ผู้วิจัยเลือกใช้เทคนิค SMOTE (Synthetic Minority Over-sampling Technique) [18] โดยกำหนดจำนวนเพื่อนบ้านใกล้เคียง เท่ากับ 5 และสร้างข้อมูลสังเคราะห์ในคลาสส่วนน้อยจนมีสัดส่วนเท่ากับคลาสส่วนมาก เพื่อปรับสมดุลของข้อมูลก่อนนำไปฝึกสอนแบบจำลอง โดยขั้นตอนนี้จะดำเนินการเฉพาะในชุดข้อมูลฝึกสอนเท่านั้น [6]

3.3.3 การคัดเลือกตัวแปร (Feature Selection)

ผู้วิจัยทำการฝึกแบบจำลอง Random Forest [5] ด้วยตัวแปรทั้งหมดเพื่อประเมินความสำคัญของตัวแปร (Feature Importance) โดยพิจารณาจากค่าเฉลี่ยการลดลงของดัชนีจีนิ (Mean Decrease Gini) [19] ซึ่งเป็นมาตรวัดประสิทธิภาพในการลดความไม่บริสุทธิ์ของข้อมูล ในการวิจัยนี้ได้คัดเลือกตัวแปรที่มีความสำคัญสูงสุด 30 อันดับแรก เพื่อนำไปใช้เป็นตัวแปรอิสระในการสร้างแบบจำลองจำแนกประเภททั้ง 3 อัลกอริทึม

3.3.4 การปรับจูนพารามิเตอร์ (Hyperparameter Tuning)

ผู้วิจัยใช้เทคนิค Grid Search ร่วมกับวิธีการตรวจสอบแบบ 5-fold Cross-validation [8] ในการค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุด (Optimal Hyperparameters) จากช่วงค่าที่กำหนด (Search Space) โดยใช้ค่า AUC เป็นเกณฑ์หลักในการตัดสินใจ มีรายละเอียดดังนี้

- Logistic Regression ใช้เทคนิค Elastic Net Regularization เพื่อควบคุมความซับซ้อนของแบบจำลอง โดยกำหนดค่า Alpha (α) ได้แก่ 0 (Ridge), 0.5 (Elastic Net) และ 1 (Lasso) และกำหนดค่า Lambda (λ) ในช่วง 0.0001 ถึง 0.1 [6]

- Random Forest กำหนดค่าพารามิเตอร์ **mtry** หรือจำนวนตัวแปรสุ่มที่ใช้ในการตัดสินใจในแต่ละโหนด ดังนี้

$$mtry = 2, \sqrt{p}, \frac{p}{2}, p$$

เมื่อ p คือจำนวนตัวแปรอิสระทั้งหมด [16]

- Support Vector Machines กำหนดค่าพารามิเตอร์ **Cost** ในช่วง 0.01 ถึง 100 เพื่อควบคุมบทลงโทษของความผิดพลาดและค่า **Gamma (γ)** ในช่วง 0.001 ถึง 0.5 สำหรับการควบคุมรัศมีอิทธิพลของข้อมูล โดยพิจารณาทั้งเคอร์เนลเชิงเส้น และเคอร์เนล RBF [6]

3.3.5 การสร้างและประเมินประสิทธิภาพแบบจำลองขั้นสุดท้าย

ผู้วิจัยนำค่าพารามิเตอร์ที่เหมาะสมที่สุดที่ได้จากขั้นตอนการปรับจูนมาดำเนินการฝึกสอนแบบจำลองขั้นสุดท้ายด้วยชุดข้อมูลฝึกสอนทั้งหมด (ร้อยละ 70) จากนั้นจึงนำแบบจำลองไปทดสอบกับชุดข้อมูลทดสอบที่แยกไว้ (ร้อยละ 30) เพื่อวัดประสิทธิภาพการจำแนกผ่านดัชนีชี้วัด 4 ด้าน ได้แก่ AUC, Recall, Precision และ F1-score ตามที่ปรากฏในผังการดำเนินงานวิจัย

3.3.6 การประเมินและคัดเลือกแบบจำลอง

ผู้วิจัยดำเนินการประเมินประสิทธิภาพและคัดเลือกแบบจำลองที่ดีที่สุด โดยนำแบบจำลองที่ผ่านการฝึกสอนในแต่ละรอบของวิธีการตรวจสอบแบบ 5-Fold Cross-Validation มาทดสอบกับชุดข้อมูลตรวจสอบ (Validation Set) เพื่อคำนวณค่าวัดประสิทธิภาพ 5 ตัว ได้แก่ AUC, Accuracy, F1-Score, Precision และ Recall จากนั้นนำผลลัพธ์จากการทดสอบทั้ง 5 รอบมาคำนวณหาค่าเฉลี่ย (Mean Metrics) ของแต่ละแบบจำลอง และจัดลำดับแบบจำลองโดยใช้ค่าพื้นที่ใต้เส้นโค้ง ROC (AUC) เป็นเกณฑ์หลัก เพื่อให้ได้แบบจำลองที่ดีที่สุดและนำไปฝึกสอนด้วยข้อมูลฝึกสอนทั้งหมด

3.4 การฝึกแบบจำลองขั้นสุดท้าย

เมื่อได้แบบจำลองที่มีประสิทธิภาพสูงสุดจากขั้นตอนที่ 3 แล้ว ผู้วิจัยจะนำแบบจำลองดังกล่าวมาสร้างเป็นแบบจำลองสุดท้าย โดยทำการฝึกสอนด้วยชุดข้อมูลฝึกสอนทั้งหมด จำนวนร้อยละ 70 ของข้อมูลทั้งหมด ซึ่งผ่านกระบวนการเตรียมข้อมูล การจัดการข้อมูลไม่สมดุล และการคัดเลือกตัวแปร เช่นเดียวกับขั้นตอนการพัฒนาแบบจำลอง สำหรับการกำหนดค่าพารามิเตอร์ ผู้วิจัยเลือกใช้ชุดค่าที่เหมาะสมที่สุด (Optimal Hyperparameters) โดยอ้างอิงจากผลของวิธีการตรวจสอบแบบ 5-fold Cross-Validation ในรอบที่ให้ค่าพื้นที่ใต้เส้นโค้ง ROC (AUC) สูงที่สุด

3.5 การประเมินประสิทธิภาพของแบบจำลอง

ในขั้นตอนนี้ ผู้วิจัยจะนำแบบจำลองสุดท้ายมาดำเนินการทดสอบกับชุดข้อมูลทดสอบจำนวนร้อยละ 30 ของข้อมูลทั้งหมด เพื่อประเมินความสามารถในการจำแนกโดยใช้ตาราง Confusion Matrix และพิจารณาค่าวัดประสิทธิภาพ 5 ตัว ได้แก่ AUC, Accuracy, F1-Score, Precision และ Recall

3.6 การทดสอบนัยสำคัญทางสถิติ

ผู้วิจัยดำเนินการวิเคราะห์เปรียบเทียบประสิทธิภาพของแบบจำลอง Machine Learning ทั้ง 4 แบบจำลองผ่านวิธีการตรวจสอบแบบ 5-fold Cross-validation โดยใช้สถิติ Friedman Test ซึ่งเป็นสถิติทดสอบแบบไม่ใช้พารามิเตอร์ (Non-parametric Test) เพื่อทดสอบความแตกต่างของประสิทธิภาพแบบจำลอง [20] โดยกำหนดนัยสำคัญทางสถิติที่ 0.05 และมีสมมติฐานดังนี้

H_0 : ลำดับเฉลี่ยของค่า AUC ของแบบจำลอง Machine Learning ทั้ง 4 แบบจำลอง ไม่มีความแตกต่างกัน

H_1 : มีแบบจำลอง Machine Learning อย่างน้อย 1 คู่ ที่มีลำดับเฉลี่ยของค่า AUC แตกต่างกัน

ในกรณีที่พบความแตกต่างอย่างมีนัยสำคัญทางสถิติ ผู้วิจัยจะดำเนินการทดสอบเปรียบเทียบรายคู่ (Pairwise Comparisons) ด้วยสถิติ Wilcoxon Signed-Rank Test

เพื่อระบุแบบจำลองที่มีประสิทธิภาพแตกต่างกัน และเพื่อควบคุมอัตราความคลาดเคลื่อนสะสมจากการทดสอบหลายครั้ง (Family-wise Error Rate) ผู้วิจัยได้ใช้วิธีการปรับค่าระดับนัยสำคัญด้วยวิธีของ Holm (Holm-Bonferroni Method) [21] ซึ่งเป็นการเรียงลำดับค่า p – $value$ จากน้อยไปมากและปรับเกณฑ์การพิจารณาให้มีความเข้มงวดตามลำดับ เพื่อให้มั่นใจว่าผลการเปรียบเทียบมีความแม่นยำและน่าเชื่อถือ โดยมีสมมติฐานสำหรับการเปรียบเทียบแต่ละคู่ดังนี้

H_0 : ลำดับเฉลี่ยของค่า AUC ของแบบจำลองคู่ที่นำมาเปรียบเทียบไม่มีความแตกต่างกัน

H_1 : ลำดับเฉลี่ยของค่า AUC ของแบบจำลองคู่ที่นำมาเปรียบเทียบมีความแตกต่างกัน

3.7 การวิเคราะห์ความสำคัญของตัวแปรและการอธิบายความหมายของแบบจำลอง

เพื่อสร้างความเข้าใจต่อกระบวนการตัดสินใจของแบบจำลอง ซึ่งมีความซับซ้อนสูง (Complex Models) และสามารถระบุทิศทางความสัมพันธ์ระหว่างตัวแปรอิสระกับระดับความรุนแรงของอุบัติเหตุได้อย่างชัดเจน ผู้วิจัยจึงได้นำเทคนิค SHAP มาประยุกต์ใช้สำหรับอธิบายการทำงานของแบบจำลองภายใต้แนวคิดปัญญาประดิษฐ์ที่สามารถอธิบายได้ (Explainable AI) โดยมีรายละเอียดขั้นตอนดำเนินการดังนี้

1) การเลือกตัวอย่างข้อมูลสำหรับการวิเคราะห์ ผู้วิจัยดำเนินการสุ่มตัวอย่างข้อมูลจากชุดข้อมูลฝึกสอนที่ผ่านการปรับสมดุลแล้ว (Balanced Training Set) จำนวน 200 ตัวอย่าง เพื่อใช้เป็นข้อมูลตัวแทน (Representative Samples) ในการคำนวณค่า SHAP Value เนื่องจากวิธีการดังกล่าวต้องอาศัยทรัพยากรในการคำนวณสูง

2) วิธีการประมาณค่าทางสถิติ ใช้การจำลองแบบมอนติคาร์โล (Monte Carlo Simulation) ในการประมาณค่าการมีส่วนร่วมของแต่ละคุณลักษณะ (Feature Contribution) โดยกำหนดจำนวนรอบการจำลองที่ 20 รอบ ($nsim = 20$) เพื่อให้ได้ค่า SHAP ที่มีความเสถียรและแม่นยำเชิงสถิติ

3) การวิเคราะห์ผลลัพธ์ ค่า SHAP Value ที่ได้จะถูกนำไปวิเคราะห์ใน 2 มิติหลัก ได้แก่

- ระดับอิทธิพล (Magnitude) เพื่อจัดลำดับความสำคัญของตัวแปรอิสระที่มีผลต่อการทำนายความรุนแรงระดับสูง
- ทิศทางความสัมพันธ์ (Directionality) เพื่อระบุว่าค่าของตัวแปรอิสระที่เพิ่มขึ้นหรือลดลง ส่งผลต่อโอกาสการเกิดความรุนแรงระดับสูงในทิศทางบวกหรือลบอย่างไร

ผลการวิเคราะห์ในส่วนนี้จะถูกนำเสนอผ่านแผนภาพ SHAP Beeswarm Plot ในส่วนของการวิเคราะห์ผลการศึกษา เพื่อนำไปสู่การอภิปรายผลเชิงนโยบายในลำดับถัดไป

4.ผลการวิจัย

4.1 ผลการพัฒนาแบบจำลองผ่านวิธีการตรวจสอบแบบ 5-fold Cross-validation

ผู้วิจัยได้ดำเนินการพัฒนาและปรับจูนค่าพารามิเตอร์ที่เหมาะสม ให้กับแบบจำลอง Machine Learning จำนวน 4 แบบจำลอง ได้แก่ Random Forest, Logistic Regression, Support Vector Machine (Linear Kernel) และ Support Vector Machine (Radial Basis Function Kernel) โดยใช้วิธีการตรวจสอบแบบ 5-fold Cross-validation ในการประเมินประสิทธิภาพ ผู้วิจัยได้นำผลการทดสอบจากทั้ง 5 รอบมาคำนวณหาค่าเฉลี่ยตัววัดประสิทธิภาพ 5 ตัว ได้แก่ AUC, Accuracy, F1-Score, Precision และ Recall เพื่อใช้ในการเปรียบเทียบและคัดเลือกแบบจำลองที่ดีที่สุด ผลที่ได้เป็นดังตารางที่ 3

จากผลการทดสอบประสิทธิภาพของแบบจำลองในตารางที่ 3 พบว่าแบบจำลอง Random Forest มีประสิทธิภาพสูงสุดในด้านความถูกต้อง โดยให้มีความถูกต้อง (Accuracy) อยู่ที่ร้อยละ 71.1 และมีค่าพื้นที่ใต้เส้นโค้ง (AUC) สูงที่สุดที่ร้อยละ 70.6 อย่างไรก็ตาม เมื่อ

พิจารณาถึงความสมดุลในการจำแนกประเภทผ่านค่า F1-score พบว่า แบบจำลอง Support Vector Machine (Linear Kernel) มีค่าสูงสุดที่ร้อยละ 51.0 ซึ่งสอดคล้องกับค่าความไว (Recall) ที่สูงถึงร้อยละ 70.1 แสดงให้เห็นถึงความสามารถในการตรวจจับความรุนแรงของอุบัติเหตุระดับสูงได้อย่างครอบคลุมกว่าแบบจำลองอื่น ในขณะที่แบบจำลอง Support Vector Machine (RBF Kernel) มีประสิทธิภาพต่ำที่สุดในเกือบทุกดัชนีชี้วัด

นอกจากนี้ ผลการวิเคราะห์พบว่าส่วนเบี่ยงเบนมาตรฐานมีค่าค่อนข้างต่ำในทุกดัชนีชี้วัด ซึ่งสะท้อนให้เห็นถึงความเสถียรของผลการจำแนกในทุกแบบจำลอง ซึ่งผลการเปรียบเทียบดังกล่าวแสดงให้เห็นว่า แม้แบบจำลอง Random Forest และ Support Vector Machine (Linear Kernel) จะมีศักยภาพโดดเด่นในมิติที่ต่างกัน แต่เมื่อพิจารณาในบริบทของการนำไปประยุกต์ใช้ร่วมกับเกณฑ์การตัดสินใจเชิงสถิติ ผู้วิจัยจึงตัดสินใจเลือกแบบจำลอง Random Forest เป็นแบบจำลองสุดท้าย (Final Model) เนื่องจากให้ค่าพื้นที่ใต้เส้นโค้ง (AUC) สูงที่สุด ซึ่งเป็นดัชนีชี้วัดหลักที่สะท้อนถึงความสามารถในการจำแนกประเภทโดยรวมได้อย่างมีประสิทธิภาพสูงสุด

ตารางที่ 3 ค่าเฉลี่ยประสิทธิภาพของแบบจำลองจำแนกประเภท (ในวงเล็บเป็นค่าส่วนเบี่ยงเบนมาตรฐาน)

Model	AUC (%)	Accuracy (%)	F1-Score (%)	Precision (%)	Recall (%)
RF	70.6 (0.025)	71.1 (0.006)	38.7 (0.011)	46.8 (0.016)	33.1 (0.020)
LR	69.1 (0.014)	69.2 (0.007)	47.8 (0.030)	44.8 (0.014)	51.3 (0.051)
SVM Linear	69.0 (0.016)	62.8 (0.015)	51.0 (0.015)	40.1 (0.013)	70.1 (0.033)
SVM RBF	63.1 (0.016)	68.0 (0.012)	35.3 (0.019)	40.0 (0.024)	31.6 (0.018)

4.2 ผลการฝึกแบบจำลองขั้นสุดท้ายและการประเมินประสิทธิภาพของแบบจำลอง

จากกระบวนการเปรียบเทียบประสิทธิภาพและคัดเลือกแบบจำลอง ผู้วิจัยได้นำแบบจำลอง Random Forest ซึ่งเป็นแบบจำลองที่มีประสิทธิภาพสูงสุด มาดำเนินการสร้างแบบจำลองสุดท้าย โดยใช้ชุดข้อมูลฝึกสอนจำนวนร้อยละ 70 ร่วมกับค่าพารามิเตอร์ที่เหมาะสมที่สุดที่ได้จากการปรับจูน ได้แก่ จำนวนตัวแปรสุ่มสำหรับการสร้างโหนด (mtry) เท่ากับ 5 และจำนวนต้นไม้ (ntree) เท่ากับ 500 ต้น รวมถึงใช้ชุดตัวแปรอิสระที่ผ่านการคัดเลือกความสำคัญแล้วจำนวน 30 ตัวแปร เพื่อนำไปประเมินประสิทธิภาพกับชุดข้อมูลทดสอบ โดยแสดงผลการทำนายผ่านตาราง Confusion Matrix และค่าดัชนีชี้วัดประสิทธิภาพ ดังรายละเอียดในตารางที่ 4 และ 5

ตารางที่ 4 Confusion Matrix ของการจำแนกความรุนแรงของอุบัติเหตุด้วยแบบจำลอง Random Forest

		ผลลัพธ์จริง	
		high severity	low severity
ผลลัพธ์การจำแนก	high severity	140	129
	low severity	298	1,020

จากผลการวิเคราะห์ในตารางที่ 4 พบว่า แบบจำลอง Random Forest สามารถจำแนกอุบัติเหตุได้อย่างมีประสิทธิภาพ โดยมีรายละเอียดดังนี้

- ระดับความรุนแรงสูง (high severity) แบบจำลอง Random Forest สามารถทำนายได้ถูกต้องจำนวน 140 เหตุการณ์ จากจำนวนเหตุการณ์ที่เกิดขึ้นจริงทั้งหมดในคลาสนี้ คิดเป็นร้อยละ 31.96
- ระดับความรุนแรงต่ำ (Low Severity) แบบจำลอง Random Forest สามารถทำนายได้ถูกต้องจำนวน 1,020 เหตุการณ์ คิดเป็นร้อยละ 88.77
- ประสิทธิภาพโดยรวม เมื่อพิจารณาในภาพรวมแบบจำลอง Random Forest สามารถจำแนกความรุนแรง

ของอุบัติเหตุได้ถูกต้องรวมทั้งสิ้น 1,160 เหตุการณ์ จากทั้งหมด 1,587 เหตุการณ์ คิดเป็นค่าความถูกต้องรวม (Overall Accuracy) เท่ากับร้อยละ 73.09

ตารางที่ 5 ประสิทธิภาพของแบบจำลอง Random Forest เมื่อทดสอบกับชุดข้อมูลทดสอบ (Test Set)

ตัวชี้วัดประสิทธิภาพ	ผลลัพธ์(%)
AUC	69.06
Accuracy	73.09
F1-Score	39.60
Precision	52.04
Recall	31.96
Macro Average	61.15

จากผลการประเมินประสิทธิภาพในตารางที่ 5 พบว่าแบบจำลอง Random Forest มีค่าความถูกต้อง (Accuracy) อยู่ที่ร้อยละ 73.09 และมีค่าพื้นที่ใต้เส้นโค้ง (AUC) ร้อยละ 69.06 สะท้อนถึงขีดความสามารถในการจำแนกความแตกต่างระหว่างอุบัติเหตุที่มีความรุนแรงสูงและต่ำได้ในระดับปานกลาง

เมื่อพิจารณาค่า F1-Score อยู่ที่ร้อยละ 39.60 มีความไว Recall อยู่ที่ร้อยละ 31.96 หมายความว่าในจำนวนอุบัติเหตุรุนแรงที่เกิดขึ้นจริงทั้งหมด แบบจำลองสามารถตรวจจับความถูกต้องได้เพียงประมาณ 1 ใน 3 เท่านั้น ส่วนค่าเที่ยงตรง (Precision) อยู่ที่ร้อยละ 52.04 ซึ่งหมายความว่าเมื่อแบบจำลองทำนายว่าจะเกิดความรุนแรงสูง มีความถูกต้องจริงประมาณกึ่งหนึ่ง อย่างไรก็ตาม เมื่อพิจารณาค่าเฉลี่ยแบบ Macro Average ซึ่งอยู่ที่ร้อยละ 61.15 จะเห็นได้ว่ามีค่าต่ำกว่าความถูกต้องรวม ซึ่งเป็นข้อบ่งชี้ว่าประสิทธิภาพของแบบจำลองได้รับผลกระทบจากความไม่สมดุลของจำนวนข้อมูลระหว่างคลาส (Imbalanced Data) โดยแบบจำลองทำนายคลาสที่มีจำนวนข้อมูลมากกว่าได้ดีกว่าคลาสที่มีจำนวนข้อมูลน้อย

4.3 ผลการทดสอบนัยสำคัญทางสถิติ

จากการทดสอบความแตกต่างของประสิทธิภาพของ Machine Learning ทั้ง 4 แบบจำลองในภาพรวมด้วยสถิติ Friedman Test พบว่า $\chi^2(3) = 12.12$ และ $p =$

0.007 ซึ่งน้อยกว่าระดับนัยสำคัญที่กำหนดไว้ คือ 0.05 ($p < 0.5$) จึงปฏิเสธสมมติฐานหลัก H_0 ผลการวิเคราะห์ดังกล่าวชี้ให้เห็นว่า ลำดับเฉลี่ยของค่าพื้นที่ใต้เส้นโค้ง (AUC) ของ 4 แบบจำลองมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05

ผู้วิจัยจึงดำเนินการทดสอบเปรียบเทียบพหุคูณรายคู่ (Post-hoc Pairwise Comparison) ด้วยสถิติ Wilcoxon Signed-Rank Test และปรับระดับนัยสำคัญด้วยวิธีของ Holm (Holm-Bonferroni Method) เพื่อควบคุมอัตราความคลาดเคลื่อนสะสม โดยมีรายละเอียดผลการทดสอบดังปรากฏในตารางที่ 6

ตารางที่ 6 ผลการเปรียบเทียบประสิทธิภาพรายคู่ (Post-hoc Pairwise Comparisons)

แบบจำลอง	R a n d o m Forest	SVM (Linear)	SVM (RBF)
L o g i s t i c Regression	0.375	1.000	0.375
R a n d o m Forest	-	0.375	0.375
SVM (Linear)	-	-	0.375


จากตารางที่ 6 ผลการทดสอบเปรียบเทียบรายคู่พบว่า ทุกคู่มีค่าระดับนัยสำคัญที่ปรับแล้ว (Adjusted p-value) มากกว่า 0.05 จึงยอมรับสมมติฐานหลักที่ว่า ประสิทธิภาพของแบบจำลอง Machine Learning แต่ละคู่ไม่แตกต่างกันที่ระดับนัยสำคัญ 0.05

4.4 การวิเคราะห์ปัจจัยที่สำคัญต่อการทำนายระดับความรุนแรงของอุบัติเหตุด้วยเทคนิค SHAP

ในการสร้างความเข้าใจต่อกระบวนการทำนายความรุนแรงของอุบัติเหตุระดับสูง (High Severity Prediction) ของแบบจำลอง Random Forest ที่มีความซับซ้อนอย่างมาก ผู้วิจัยได้ประยุกต์ใช้เทคนิค SHAP เพื่อระบุลำดับความสำคัญและทิศทางอิทธิพลของตัวแปรอิสระ จากการวิเคราะห์แผนภาพ SHAP Beeswarm Plot ในรูปที่ 4 พบว่าปัจจัยที่มีค่าอิทธิพลสูงสุด 3 อันดับแรก ได้แก่

1) รถจักรยานยนต์ (Motorcycle) เป็นปัจจัยเสี่ยงที่มีนัยสำคัญสูงสุด โดยเมื่ออุบัติเหตุมีการเกี่ยวข้องกับรถจักรยานยนต์ (จุดสีเหลืองในผังบวก) จะเพิ่มโอกาสการเกิดความรุนแรงระดับสูงอย่างชัดเจน

2) จำนวนยานพาหนะ (Num_Vehicles) มีความสัมพันธ์ในลักษณะแปรผันตามกันกับระดับความรุนแรง กล่าวคือ ยิ่งมีจำนวนรถเกี่ยวข้องมาก โอกาสเกิดอุบัติเหตุรุนแรงระดับสูงจะยิ่งเพิ่มขึ้น (จุดสีเหลืองกระจายตัวในผังบวก)



รูปที่ 4 แผนภาพสรุปค่าอิทธิพลและทิศทางของปัจจัยเสี่ยงต่อความรุนแรงของอุบัติเหตุระดับสูงด้วยเทคนิค SHAP

หมายเหตุ: จุดสีเหลืองแทนค่าปัจจัยที่สูง และจุดสีม่วงแทนค่าปัจจัยที่ต่ำ โดยค่า SHAP ที่เป็นบวกบ่งชี้ถึงการเพิ่มโอกาสเกิดความรุนแรงระดับสูง

3) การชนที่เกิดจากความประมาทของตนเอง (Collision2.SelfCaused) เป็นปัจจัยที่มีอิทธิพลสูงในลำดับถัดมา แม้จะมีความแปรปรวนของผลลัพธ์สูง แต่หากเป็นการเสียหลักปะทะสิ่งกีดขวางด้วยความเร็วจะส่งผลให้ความรุนแรงพุ่งสูงขึ้นทันที

นอกจากนี้ ยังพบปัจจัยสำคัญในลำดับที่ 4 คือ ช่วงเวลากลางวัน (Time.Day) ซึ่งทำหน้าที่เป็นปัจจัยปกป้อง (Protective Factor) อย่างชัดเจน โดยจุดสี่เหลี่ยมกระจายตัวอยู่ในฝั่งลบของแกน SHAP บ่งชี้ว่าการเกิดเหตุในช่วงกลางวันช่วยลดโอกาสการเกิดความรุนแรงระดับสูง

5. สรุปผลการวิจัยและการอภิปรายผล

การศึกษานี้ได้นำเสนอกรอบแนวคิดการเรียนรู้ของเครื่องแบบอธิบายได้ (Explainable Machine Learning Framework) เพื่อวิเคราะห์ความรุนแรงของอุบัติเหตุทางถนนช่วงเทศกาลสงกรานต์ โดยผลการวิจัยสามารถสรุปประเด็นสำคัญเพื่อการนำไปใช้งานจริงได้ดังนี้

5.1 ประสิทธิภาพของแบบจำลองและการตัดสินใจเลือกใช้งาน

จากผลการเปรียบเทียบประสิทธิภาพพบว่า แบบจำลอง Random Forest มีประสิทธิภาพสูงสุดในการทำนายภาพรวม โดยมีค่า Accuracy 0.711(± 0.006) และ AUC 0.706 (± 0.025) เหมาะสำหรับหน่วยงานระดับนโยบายที่ต้องการวางแผนยุทธศาสตร์เชิงพื้นที่ในระยะยาว ในขณะที่แบบจำลอง SVM Linear แม้จะมีค่าความถูกต้องโดยรวมน้อยกว่า แต่มีความโดดเด่นอย่างมากในการตรวจจับกรณีความรุนแรงสูง เนื่องจากมีค่า Recall สูงถึง 0.701 (± 0.033) ซึ่งมีความสำคัญอย่างยิ่งสำหรับระบบสนับสนุนการตัดสินใจในงานกู้ชีพ (Emergency Response) เพื่อให้สามารถเข้าถึงผู้ประสบเหตุวิกฤตได้อย่างรวดเร็วและแม่นยำ

5.2 การระบุปัจจัยเสี่ยงและการนำผลลัพธ์ไปใช้ในทางปฏิบัติ

การประยุกต์ใช้เทคนิค SHAP ช่วยลดข้อจำกัดของแบบจำลองกล่องดำ (Black-box models) ทำให้สามารถระบุทิศทางและระดับอิทธิพลของปัจจัยเสี่ยงได้อย่างชัดเจน

โดยปัจจัยที่มีอิทธิพลสูงสุด 3 อันดับแรก ได้แก่ ประเภทรถจักรยานยนต์ จำนวนยานพาหนะที่เกี่ยวข้อง และลักษณะการชนที่เกิดจากตนเอง นอกจากนี้จากนี้ ผลการวิจัยระบุว่า ช่วงเวลากลางวันทำหน้าที่เป็นปัจจัยปกป้อง (Protective Factor) ที่ช่วยลดโอกาสเกิดความรุนแรง ในขณะที่ช่วงเวลากลางคืนเป็นปัจจัยกระตุ้นความเสี่ยงที่สำคัญ

5.3 ข้อจำกัดและงานวิจัยในอนาคต

แม้ว่ากรอบแนวคิดการเรียนรู้ของเครื่องแบบอธิบายได้จะช่วยระบุปัจจัยเสี่ยงสำคัญได้อย่างมีประสิทธิภาพ แต่การศึกษานี้ยังมีข้อจำกัดบางประการที่สามารถนำไปพัฒนาต่อยอดในอนาคตได้ ดังนี้

- **การเปรียบเทียบความแตกต่างระหว่างช่วงเวลา** งานวิจัยในอนาคตควรมีการเปรียบเทียบผลการวิเคราะห์กับข้อมูลอุบัติเหตุนอกช่วงเทศกาล เพื่อตรวจสอบว่าระดับความสำคัญและทิศทางของปัจจัยเสี่ยงมีความแตกต่างกันหรือไม่ ซึ่งจะช่วยให้หน่วยงานที่เกี่ยวข้องสามารถกำหนดนโยบายการป้องกันอุบัติเหตุที่มีความเฉพาะเจาะจงและชัดเจนยิ่งขึ้นระหว่างสภาวะการจราจรปกติและสภาวะการเดินทางหนาแน่นในช่วงเทศกาล
- **การจัดการปัญหาความไม่สมดุลของข้อมูลและการเพิ่มประสิทธิภาพการทำนาย** เนื่องจากค่าความไว (Recall) ในการตรวจจับกรณีความรุนแรงสูงยังมีข้อจำกัด งานวิจัยในอนาคตสามารถพิจารณาใช้เทคนิคการสุ่มตัวอย่างขั้นสูงอื่นๆ เช่น Cost-sensitive Learning หรือ Ensemble Method รูปแบบอื่น เช่น XGBoost หรือ LightGBM ซึ่งอาจช่วยเพิ่มประสิทธิภาพในการจำแนกคลาสที่มีสัดส่วนน้อย (Minority Class) ให้มีความแม่นยำสูงขึ้น
- **การเพิ่มปัจจัยเสี่ยงเชิงลึก** การยกระดับประสิทธิภาพของแบบจำลองสามารถทำได้โดยการนำปัจจัยเสี่ยงที่มีความละเอียดสูงมาพิจารณาเพิ่มเติม เช่น ข้อมูลพฤติกรรมผู้ขับขี่รายบุคคล

ข้อมูลสภาพพื้นผิวจราจรเชิงวิศวกรรม หรือการใช้ข้อมูลภาพถ่ายจากที่เกิดเหตุและพิกัด GPS ที่แม่นยำ เพื่อช่วยให้แบบจำลองสามารถจับความสัมพันธ์ที่ซับซ้อนได้ดีกว่าการใช้ข้อมูลสถิติเพียงมิติเดียว

- **การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning)** นอกเหนือจากแบบจำลองจำแนกประเภทพื้นฐาน การนำโครงข่ายประสาทเทียม (Neural Networks) หรือเทคนิคปัญญาประดิษฐ์อื่นๆ มาใช้ร่วมกับวิธีการอธิบายผลที่ทันสมัย จะช่วยเพิ่มขีดความสามารถในการวิเคราะห์ข้อมูลที่มีมิติสูงและมีความสัมพันธ์ที่ไม่เป็นเชิงเส้นอย่างยิ่ง (Highly Non-linear) ซึ่งจะทำให้ผลการวิจัยมีความน่าสนใจและเป็นประโยชน์ต่อผู้วางนโยบายในเชิงลึกต่อไป

5.4 ข้อเสนอแนะเชิงนโยบายและการนำไปใช้งาน

ผู้วิจัยได้สรุปแนวทางการนำผลการวิจัยไปใช้ประโยชน์ในทางปฏิบัติ เพื่อให้หน่วยงานที่เกี่ยวข้องสามารถตัดสินใจเชิงนโยบายได้อย่างแม่นยำ ดังแสดงในตารางที่ 7

ตารางที่ 7 สรุปปัจจัยสำคัญ 3 อันดับแรกและการนำไปใช้ประโยชน์ในทางปฏิบัติ

ปัจจัยสำคัญ	ทิศทางของอิทธิพลต่อความรุนแรงระดับสูง	แนวทางการนำไปใช้ประโยชน์ในทางปฏิบัติ
1.รถจักรยานยนต์	เพิ่มความเสี่ยงสูงสุดอย่างชัดเจน เนื่องจากมีการมีรถจักรยานยนต์เกี่ยวข้องส่งผลเชิงบวกต่อโอกาสเกิดความรุนแรงระดับสูง	ควรมีการกวดขันวินัยจราจรเรื่องการสวมหมวกนิรภัยอย่างเข้มงวด และจัดช่องทางจราจรพิเศษสำหรับรถจักรยานยนต์ในช่วงเทศกาล
2. จำนวนยานพาหนะ	แปรผันตามกัน กล่าวคือ ยิ่งจำนวนรถที่เกี่ยวข้องมาก	ควรเตรียมทีมกู้ชีพและอุปกรณ์คัดถ่ายประจำจุดเสี่ยงที่มีปริมาณจราจร

	โอกาสเกิดอุบัติเหตุรุนแรงยิ่งขึ้น	หนาแน่น เพื่อรองรับเหตุอุบัติเหตุหมู่
3. การชนที่เกิดจากความประมาทของตนเอง	ลักษณะการชนที่เกิดจากตนเอง (เช่น เสียหลักเอง) ส่งผลเชิงบวกต่อการทำนายความรุนแรงระดับสูง	ควรมีการปรับปรุงสภาพแวดล้อมข้างทาง และติดตั้งอุปกรณ์ลดแรงกระแทกบริเวณเสี่ยงเกิดขวางถาวร เช่น เสาไฟฟ้าหรือต้นไม้

6. เอกสารอ้างอิง

- [1] ศูนย์อำนวยการความปลอดภัยทางถนน, “สถิติอุบัติเหตุทางถนนช่วงเทศกาลสงกรานต์ พ.ศ. 2568,” [Online]. Available: <https://roadsafety.disaster.go.th/roadsafety/download?id=7091>. [วันที่เข้าถึง 17 เมษายน 2568].
- [2] ธิดา ธรรมรักษา, บุษพา ลาภทว, และ อมรพล กันเลิศ, “ปัจจัยที่เกี่ยวข้องกับความรุนแรงของการบาดเจ็บในผู้ประสบอุบัติเหตุจราจร ในหอผู้ป่วย,” *วารสารโรงพยาบาลธรรมศาสตร์เฉลิมพระเกียรติ*, pp. 13-25, 2559.
- [3] พรณี สุรินทชัย, “การเกิดอุบัติเหตุจราจรและปัจจัยที่มีความสัมพันธ์กับระดับความรุนแรงของการบาดเจ็บในเขตอำเภอเมือง จังหวัดพะเยา,” รายงานวิจัย, กลุ่มการพยาบาล โรงพยาบาลพะเยา, พะเยา, 2557, pp. 3-14.
- [4] J. S. Madushani, R. K. Sandamal, D. Meddage, H. Pasindu, and P. I. Ayantha Gomes, “Evaluating expressway traffic crash severity by using logistic regression and explainable & supervised machine learning classifiers,” *Transportation Engineering*, vol. 13, p. 100190, 2022.
- [5] R. Yu and M. Abdel-Aty, “Utilizing support vector machine in real-time crash risk

- evaluation,” *Accident Analysis & Prevention*, vol. 51, no. 0001-4575, pp. 252-259, 2012.
- [6] B. Leo, “Random forests,” *Machine Learning*, vol. 45, pp. 5-32, 2001.
- [7] Q. Zhang, “Deep learning-based surrogate model for flight load analysis,” กรกฎาคม 2564. [Online]. Available: https://www.researchgate.net/figure/The-random-forest-The-data-set-is-divided-into-100-subsets-by-bootstrap-sampling-and_fig4_353520134 [Accessed 19 August 2025].
- [8] V. N. Vapnik, *The Nature of Statistical Learning Theory*, New York: Springer, 1995.
- [9] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*, 2nd ed., New York: Springer, 2009.
- [10] รศรินทร์ เมธาเฉลิมพัฒน์, “การประยุกต์ใช้ Machine Learning กับงานในภาคอุตสาหกรรม,” [ออนไลน์]. แหล่งที่มา : <https://www.nectec.or.th/news/news-public-document/machine-learning-manufact-1.html>. [วันที่เข้าถึง 19 สิงหาคม 2568].
- [11] กาญจน์เชจร ชูชีพ, “การถดถอยโลจิสติก (Logistic Regression),” in *Remote Sensing Technical Note No. 5. Faculty of Forestry*, Kasetsart University, 2561.
- [12] D. W. Hosmer Jr., S. Lemeshow, and R. X. Sturdivant, *Applied Logistic Regression*, 3rd ed., Hoboken, NJ: John Wiley & Sons, 2013.
- [13] P. Gatchalee, “Confusion Matrix เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย ใน Machine learning,” [ออนไลน์]. แหล่งที่มา : <https://medium.com/@pagongatchalee/confusion-matrix-เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย - ใน machine-learning-fba6e3f9508c>. [วันที่เข้าถึง 19 สิงหาคม 2568].
- [14] S. M. Lundberg and S. I. Lee, “A unified approach to interpreting model predictions,” in *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS)*, Long Beach, CA, 2017.
- [15] อุบัติเหตุบนโครงข่ายถนนของกระทรวงคมนาคม, “MOT Data Catalog,” [ออนไลน์]. แหล่งที่มา : <https://datagov.mot.go.th/dataset/roadaccident>. [วันที่เข้าถึง 19 สิงหาคม 2568].
- [16] W. G. Cochran, *Sampling Techniques*, 3rd ed., New York, NY: John Wiley & Sons, 1977.
- [17] R. Kohavi, “A study of cross-validation and bootstrap for accuracy estimation and model selection,” in *Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI)*, New York, 1995.
- [18] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: synthetic minority over-sampling technique,” *Journal of Artificial Intelligence Research*, vol. 16, pp. 321-357, 2002.
- [19] G. Louppe, L. Wehenkel, A. Sutera, and P. Geurts, “Understanding variable importances in forests of randomized trees,” in *Proceedings of the 26th International Conference on Neural Information Processing Systems (NIPS)*, 2013.
- [20] J. Demšar, “Statistical comparisons of classifiers over multiple data sets,” *Journal of Machine Learning Research*, vol. 7, pp. 1-30, 2006.
- [21] S. Holm, “A simple sequentially rejective multiple test procedure,” *Scandinavian Journal of Statistics*, vol. 6, no. 2, pp. 65-70, 1979.