

การประมาณการณ์ล่วงหน้าเพื่อตรวจจับการล้มในบ้าน ด้วยการใช้มีเดียไปป์

พิณญศิกานต์ วงศ์เกียรติขจร¹, วีระ สอิ้ง²

บทคัดย่อ

ปัจจุบันจำนวนผู้สูงอายุในประเทศไทยมีเพิ่มมากขึ้นทุกปี ประกอบกับการใช้ชีวิตในปัจจุบันของสมาชิกในครอบครัวที่มีการทำงานนอกบ้านมากขึ้น จึงส่งผลให้ผู้สูงอายุหลายคนต้องอาศัยที่บ้านเพียงลำพัง ซึ่งมีความเสี่ยงที่อาจจะเกิดอุบัติเหตุกับผู้สูงอายุได้หลายประการ ซึ่งอุบัติเหตุที่เกิดขึ้นมากที่สุดเหตุการณ์หนึ่งคือการล้มในบ้าน ส่งผลไปสู่อุบัติเหตุการบาดเจ็บ หรือถึงขั้นเสียชีวิตได้ถ้าการช่วยเหลือไม่ทันเวลา และมากกว่านั้นจากสถิติพบว่าอุบัติเหตุจากการหกล้มในผู้สูงอายุจะเพิ่มมากขึ้นอีกด้วย เมื่อเกิดเหตุการณ์ของการหกล้มภายในบ้านของผู้สูงอายุ ทำให้บางคนไม่สามารถพยุงตนเองให้ลุกขึ้น จึงทำให้ไม่สามารถติดต่อบุคคลอื่นให้เข้ามาช่วยเหลือได้ จึงทำให้ผู้วิจัยคิดค้นงานวิจัยที่ศึกษาการตรวจจับการล้มโดยใช้มีเดียไปป์เป็นหนึ่งในเครื่องมือ จากชุดข้อมูลวิดีโอคลิป เพื่อศึกษามุมกล้องที่ดีที่สุดในการทดลอง เพื่อนำเสนอตำแหน่งที่เหมาะสมกับการตรวจจับการหกล้มจากระบบที่จะนำเสนอ รวมไปถึงวิธีการตรวจจับการล้มด้วยระบบการมองเห็นของคอมพิวเตอร์ และการตัดสินใจการหกล้มด้วยการนำการเรียนรู้ของเครื่อง ทั้งวิธีแบบใช้ค่าเกณฑ์และไม่ใช้ค่าเกณฑ์ โดยได้แบ่งขั้นตอนการทดลองออกเป็น 2 ส่วนหลัก ในส่วนแรก จะเป็นการทดลองโดยใช้วิดีโอคลิปกับวิธีการตรวจจับการล้มแบบใช้ค่าเกณฑ์ ประกอบด้วย การใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ และ มุมองศาร่างกายมนุษย์ (สะโพก ข้อเท้า เส้นพื้นดิน) และจะใช้ผลลัพธ์ที่ได้ นำมาปรับปรุงหมวดหมู่ และใช้เป็นชุดข้อมูลในการตรวจจับการล้มแบบไม่ใช้ค่าเกณฑ์ (ใช้การเรียนรู้ของเครื่อง) โดยใช้โมเดล Random forest และ K-NN จากการทดลองและการวิเคราะห์ผลลัพธ์พบว่า มุมกล้องที่ดีที่สุดคือมุมกล้องที่ 2 ส่วนผลการตรวจจับการล้มที่ดีที่สุดจะเป็น การตรวจจับการล้มโดยใช้ random forest จากชุดข้อมูลผลลัพธ์การทดลองมุมองศาร่างกายมนุษย์ (สะโพก ข้อเท้า เส้นพื้นดิน) ด้วยความแม่นยำอยู่ที่ 98% ในตรวจจับเหตุการณ์ของการล้มในสถานที่ที่กำหนดได้

คำสำคัญ : การแบ่งกลุ่มลูกค้า, การวิเคราะห์ข้อความ, การเรียนรู้ของเครื่อง

¹ หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

² คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

* Corresponding author: Tel.: 092-6299663 E-mail address: Pinyasigarnne.wongkietkajohn@g.swu.ac.th

POSE ESTIMATION FOR INDOOR FALL DETECTION USING MEDIAPIPE

Pinyasigarnne Wongkietkajohn^{1*}, Vera Sa-ing²

Abstract

The elderly population in Thailand is steadily increasing each year. However, the contemporary lifestyle choices of family members, who are increasingly engaged in work outside the home. Consequently, a significant number of elderly individuals find themselves living alone, exposing them to various risks, with accidents being a primary concern. The most prevalent accidents are falls within the home, leading to injuries, and in severe cases, fatalities, if prompt assistance is not provided. From these problems, this research introduces a novel approach to address fall detection using webcams. The study aims to identify optimal camera positions and angles through video clip datasets for experimentation within the fall detection system. The research integrates computer vision techniques and machine learning-based decision-making to develop a robust and efficient fall detection system for the home environments of elderly individuals. The experimental process is divided into two main parts. The first part involves video clips using a criterion-based fall detection method for considering the ratio of the bounding box around the human body and the angles of the silhouette of a human body, calculated by hips, ankles, and ground line. The obtained results are then refined and used as a dataset for non-criterion-based fall detection using Random Forest (RF) and K-Nearest Neighbor (K-NN) models. From the experimental results and analysis, camera number 2 is the optimal position. The best fall detection results are achieved using the Random Forest model, with an accuracy of 98, based on the experiment using the angles of the silhouette of a human body. These results underscore the potential of the proposed system to effectively and accurately detect falls among the elderly. Therefore, this research contributes to elder care and safety by presenting an innovative fall detection system by combining webcam-based computer vision and machine learning to demonstrate the safety and well-being of elderly individuals within home environments.

Keywords : Human Fall, Fall Detection, Machine Learning

¹ Data Science, Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

² Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

* Corresponding author: Tel.: 092-6299663 E-mail address: Pinyasigarnne.wongkietkajohn@swu.ac.th

บทนำ

ประเทศไทยก้าวเข้าสู่การเป็นสังคมสูงวัย (Aged Society) มาตั้งแต่ปี พ.ศ. 2548 จนถึงปี พ.ศ. 2564 ไทยมีสัดส่วนประชากรกลุ่มผู้สูงอายุหรือมีอายุ 60 ปีขึ้นไปมากกว่า 12 ล้านคน หรือคิดเป็นสัดส่วนราว 1 ใน 6 ของประชากรไทย (กระทรวงมหาดไทย, 2566) สถิตินี้ไม่เพียงแต่เป็นตัวบ่งชี้ถึงการเปลี่ยนแปลงของโครงสร้างอายุ แต่ยังสะท้อนถึงความท้าทายที่เกิดขึ้นในหลายด้าน โดยผู้ที่มีส่วนที่ต้องรับและจัดการกับความท้าทายเหล่านี้ จำเป็นต้องบริหารความเสี่ยงเพื่อรับมือกับผลกระทบรอบด้าน เช่น ผลกระทบต่อระบบสาธารณสุข ระบบเศรษฐกิจ ไปจนถึงผลกระทบในระดับครัวเรือน ไม่ว่าจะเป็นครอบครัว หรือตัวผู้สูงอายุเอง เมื่อจำนวนผู้สูงอายุมีเพิ่มมากขึ้น ความเสี่ยงที่อาจเกิดขึ้น ปัญหาต่างๆ ที่สามารถพบเจอได้ในผู้สูงอายุก็จะมีแนวโน้มเพิ่มสูงขึ้น โดยหนึ่งในปัญหาที่มักเกิดขึ้นกับผู้สูงอายุคือ การหกล้ม โดยอาจจะมีมาจากข้อจำกัดทางด้านร่างกาย สมรรถนะที่ถดถอยลง หรือเป็นเพราะสภาพแวดล้อมรอบข้างไม่เอื้ออำนวยต่อการเดิน ลุก นั่ง หรืออาจจะเกิดจากสาเหตุดังกล่าวร่วมกัน ซึ่งเป็นสาเหตุที่ทำให้เกิดอาการบาดเจ็บ บาดเจ็บเรื้อรัง หรือเสียชีวิตได้

จากปัญหาดังกล่าว จึงทำให้ผู้วิจัย ศึกษาเกี่ยวกับการตรวจจับการล้มและเปรียบเทียบวิธีการตรวจจับการล้ม จากชุดข้อมูลสาธารณะ ดังนั้นงานวิจัยนี้ จึงพัฒนาระบบการตรวจจับการล้มและศึกษาเปรียบเทียบผลลัพธ์ ทั้งแบบ threshold-based และ Machine learning – based เพื่อเป็นประโยชน์และสามารถต่อยอดการศึกษาเรื่องการตรวจจับการล้มได้ในอนาคต และเป็นส่วนเล็กๆ ในการส่งเสริมสังคมผู้สูงอายุที่ปลอดภัย

งานวิจัยที่เกี่ยวข้อง

ในงานวิจัยนี้ ผู้วิจัยได้ทำการศึกษาเอกสารและงานวิจัยที่เกี่ยวข้องที่นำเสนอการตรวจสอบการหกล้มในรูปแบบต่าง มากไปกว่านั้นผู้วิจัยยังศึกษาถึงการนำเทคโนโลยีทางด้านคอมพิวเตอร์ (Computer vision) มาใช้เพื่อเพิ่มความรวดเร็วและประสิทธิภาพการตรวจสอบการหกล้มให้กับโปรแกรมคอมพิวเตอร์ ซึ่งรวมไปถึงการศึกษาถึงหลักการของการเรียนรู้ของเครื่องหรือที่เรียกกันว่า Machine learning มาใช้ช่วยในการตัดสินใจว่าเหตุการณ์ที่เกิดขึ้นนั้นเป็นการหกล้มหรือไม่ เพื่อจะเพิ่มความถูกต้องให้กับการวิเคราะห์และตัดสินใจให้กับระบบคอมพิวเตอร์อีกด้วย

ในงานวิจัย Research of fall detection and fall prevention technologies: A systematic Review (Ren et al., 2019) ได้แบ่งประเภทการตรวจจับการล้มและการป้องกันการล้มออกเป็น 2 แบบหลัก คือ 1.การจัดประเภทโดยขึ้นอยู่กับเครื่องมือการตรวจจับสัญญาณ และ 2.การจัดประเภทโดยขึ้นอยู่กับอัลกอริธึมที่ใช้ในการวิเคราะห์ โดยการจัดประเภทโดยขึ้นอยู่กับเครื่องมือการตรวจจับสัญญาณ สามารถแบ่งออกเป็นประเภทย่อยได้ 4 ประเภท ได้แก่ 1. การตรวจจับการล้มและป้องกันการล้มที่ใช้เซ็นเซอร์วัดการเคลื่อนไหวและทิศทาง 2. การตรวจจับและป้องกันการล้มโดยอาศัยบริบท 3. การตรวจจับและป้องกันการล้มที่อาศัยคลื่น RF และ 4. การตรวจจับและป้องกันการล้มด้วยเซนเซอร์แบบผสมผสาน ในส่วนของ 2. การจัดประเภทที่ขึ้นอยู่กับอัลกอริธึม ที่ใช้ในการวิเคราะห์ จะแบ่งได้เป็น 2 ประเภท ได้แก่ 1. การตรวจจับและป้องกันการล้มโดยอาศัยการกำหนดเกณฑ์ (Threshold) 2. การตรวจจับและป้องกันการล้มโดยไม่อาศัยการกำหนดเกณฑ์ โดยสำหรับ 1. การตรวจจับและป้องกันการล้มโดยอาศัยการกำหนดเกณฑ์ นั้น การกำหนดค่าเกณฑ์ในอัลกอริธึมจะมีผลต่อประสิทธิภาพของระบบอย่างมาก ค่าเกณฑ์ที่สูงมากจะทำให้เกิดปัญหาผิดพลาดได้มากขึ้นในกรณีที่เกิดการล้ม ในขณะที่ค่าเกณฑ์ที่ต่ำมากก็จะทำให้เกิดการแจ้งเตือนเท็จขึ้น ในปัจจุบัน

วิธีการที่ใช้ค่าเกณฑ์ สามารถแบ่งออกเป็นสองกลุ่ม: วิธีการที่อาศัยการกำหนดค่าเกณฑ์คงที่ (fixed Threshold) และวิธีการอาศัยการกำหนดค่าเกณฑ์แบบปรับตามสถานการณ์ (adaptive Threshold -based methods) เนื่องจากการใช้วิธีการที่ใช้ค่าเกณฑ์คงที่ (fixed Threshold) ซึ่งมีความซับซ้อนในการคำนวณต่ำ วิธีการที่อาศัยการกำหนดค่าเกณฑ์คงที่ ได้รับการนำไปใช้ในการวิจัยที่เกี่ยวกับการตรวจจับและป้องกันการล้มนในปัจจุบันอย่างแพร่หลาย อย่างไรก็ตาม วิธีการที่อาศัยการกำหนดค่าเกณฑ์คงที่ มีความสามารถในการระบุการเกิดเหตุการณ์ที่ต่ำ และมักส่งผลให้เกิดการเตือนเท็จสูง วิธีการตรวจจับและป้องกันการล้มนที่ใช้วิธีการที่ใช้ค่าเกณฑ์แบบพลวัตหรือปรับได้ (dynamic หรือ adaptive) ได้ถูกพัฒนาขึ้นเพื่อแก้ไขปัญหาเหล่านี้ โดยเป็นการปรับค่าเกณฑ์ที่เหมาะสมตามข้อมูลที่มี สำหรับ 2. การตรวจจับและป้องกันการล้มนโดยไม่อาศัยการกำหนดเกณฑ์ นั้น จะเน้นการใช้ อัลกอริทึมที่ซับซ้อนเพื่อแยกแยะหรือทำนายการล้มนจากกิจกรรมในชีวิตประจำวัน โดยใช้ อัลกอริทึม machine learning หรือ อัลกอริทึมกระบวนการสถิติ สำหรับวิธีการที่ใช้ machine learning ในระบบตรวจจับหรือป้องกันการล้มน มีอัลกอริทึมที่นิยมใช้ได้แก่ KNN, Support Vector Machine (SVM), Naïve Bayes, Hidden Markov Model (HMM), random forest, fuzzy logic เป็นต้น

การตรวจจับและป้องกันการล้มนโดยอาศัยการกำหนดเกณฑ์ และไม่อาศัยค่าเกณฑ์ มีข้อดีและข้อเสียของตัวเอง เมื่อเทียบกันแล้ว วิธีการที่ใช้ค่าเกณฑ์ มักเป็นอัลกอริทึมที่ง่ายต่อการนำมาใช้ในอุปกรณ์ตรวจจับการล้มน อย่างไรก็ตาม ความสามารถในการทำงานของวิธีการนี้ให้ผลลัพธ์ที่น่ามั่นใจได้น้อยกว่าวิธีการไม่อาศัยค่าเกณฑ์ ที่สามารถปรับปรุงประสิทธิภาพของระบบได้อย่างมีประสิทธิภาพ แต่จำเป็นต้องใช้ความสามารถในการคำนวณและหน่วยความจำที่มากกว่าวิธีการที่ใช้ค่าเกณฑ์ โดยทั่วไป ในปัจจุบันวิธีการผสมผสาน (fusion method) ระหว่างวิธีการใช้ค่า เกณฑ์ และ/หรือวิธีการไม่ใช้ค่าเกณฑ์ ได้รับความนิยมเพื่อเพิ่มความแม่นยำของระบบ

งานวิจัย Fall Detection Based on Key Points of Human-Skeleton Using Pose (Chen et al., 2020) นำเสนอเรื่องการตรวจจับการล้มนจากพื้นฐานของจุดบนโครงสร้างร่างกายมนุษย์โดยใช้ OpenPose ที่แก้ไขปัญหาการล้มนในผู้สูงอายุ ซึ่งงานวิจัยนี้นำเสนอหลักการตรวจจับการล้มนแบบ Vision-Based โดยนำภาพจากวิดีโอคลิปแต่ละ frame ประกอบการวิเคราะห์และตรวจจับการล้มนของมนุษย์ การดำเนินการของงานวิจัยนี้ ประกอบด้วย 5 ขั้นตอนหลัก ประกอบด้วย

ขั้นตอนที่ 1 คือการใช้ OpenPose ตรวจจับตำแหน่งของจุดสำคัญของโครงสร้างร่างกายมนุษย์ และใช้พารามิเตอร์ที่สัมพันธ์กับพีเจอร์เวกเตอร์กำหนดแผนที่จุดเด่นของข้อต่อที่สำคัญของมนุษย์

ขั้นตอนที่ 2 ของงานวิจัย จะเป็นการตัดสินใจในเงื่อนไขแรก คือความเร็วเมื่อวัดจากจุดสะโพก งานวิจัยนี้กล่าวว่า ในการล้มนแบบฉบับพลัน จุดศูนย์กลางโน้มถ่วงของร่างกายมนุษย์จะเปลี่ยนไปในทิศทางแนวตั้ง ซึ่งจุดกึ่งกลางของสะโพกมนุษย์เป็นจุดแทนของจุดศูนย์กลางโน้มถ่วงของร่างกายมนุษย์และสะท้อนพีเจอร์นี้ออกมา เนื่องจากช่วงเวลาระหว่างตอนยืนและตอนที่ล้มนมีความต่างกันน้อย จึงตรวจจับ 1 ครั้ง ในทุกๆ 5 เฟรม ซึ่งเป็นเวลา 0.25 วินาที เมื่อคำนวณออกมาแล้ว หากความเร็วที่วัดได้จากจุดกึ่งกลางของสะโพกเกินเกณฑ์ความเร็วของการล้มนที่กำหนด ซึ่งในงานวิจัยนี้กำหนดไว้ที่ 0.09 เมตร/วินาที จะสามารถตัดสินใจว่าเกิดการล้มนขึ้นในเงื่อนไขนี้

ขั้นตอนที่ 3 ของงานวิจัย จะเป็นการตัดสินใจในเงื่อนไขที่สอง นั่นคือการวัดมุมเส้นกึ่งกลางของร่างกายมนุษย์และพื้นดิน เมื่อเกิดการล้มขึ้น พีเออร์ที่เด่นชัดที่สุดของร่างกายมนุษย์คือ การเอียงของร่างกาย และองศาการเอียงของร่างกายจะเพิ่มขึ้นต่อเนื่องจนล้ม ในส่วนของเส้นกึ่งกลางของมนุษย์ L จะถูกกำหนดไว้ในงานวิจัยนี้ ซึ่งหากในช่วงเวลาหนึ่ง มุมระหว่างเส้นกึ่งกลางของร่างกายมนุษย์และพื้นดินน้อยกว่า 45 องศา จะสามารถตัดสินใจได้ว่า เกิดการล้มขึ้นในเงื่อนไขนี้

ขั้นตอนที่ 4 ของงานวิจัย จะเป็นการตัดสินใจในเงื่อนไขที่สาม โดยดูอัตราส่วนระหว่างความกว้างและความสูงของกรอบสี่เหลี่ยมรอบร่างกายมนุษย์ โดยในงานวิจัยนี้ จะจับพฤติกรรมการล้มผ่านการเปลี่ยนแปลงของอัตราส่วนระหว่างความกว้างและความสูงของกรอบสี่เหลี่ยมที่ล้อมรอบเป้าหมาย โดยแทนอัตราส่วนดังกล่าวเป็น $P = \text{Width/Height}$ เมื่อร่างกายของมนุษย์ล้มลง อัตราส่วนของกรอบสี่เหลี่ยมรอบเป้าหมายจะเปลี่ยนตามไปด้วย โดยในงานวิจัยนี้ได้ตั้งเกณฑ์อัตราส่วนไว้ที่ 1 ($T = 1$) เมื่อ $P \geq T$ จะสามารถตัดสินใจได้ว่า เกิดการล้มขึ้นในเงื่อนไขนี้

ขั้นตอนที่ 5 ของงานวิจัย คือการตัดสินใจว่าผู้ที่ล้มไปแล้วจะสามารถลุกขึ้นมาได้หรือไม่ โดยในงานวิจัยนี้ได้กำหนดไว้ว่า หากบุคคลที่ล้มลงไปแล้วสามารถลุกขึ้นมาได้โดยใช้ระยะเวลาไม่นาน จะไม่มีการแจ้งเตือนใดๆ โดยใช้เกณฑ์การเปลี่ยนแปลงของอัตราส่วนระหว่างความกว้างและความสูงของกรอบสี่เหลี่ยมที่ล้อมรอบเป้าหมาย หากอัตราส่วนน้อยกว่า 1 และใช้เกณฑ์วัดมุมระหว่างเส้นกึ่งกลางมนุษย์กับพื้นดินมากกว่า 45° ในช่วงเวลาหนึ่งหลังจากล้มลง จะสามารถสรุปได้ว่าบุคคลนั้นได้ยืนขึ้น งานวิจัยนี้ได้มีการดำเนินการในขั้นตอนที่ 5 เพื่อลดจำนวนการแจ้งเตือนการล้มที่ไม่จำเป็น เนื่องจากการล้มในบางครั้ง ไม่ได้ก่อให้เกิดอาการบาดเจ็บรุนแรงต่อร่างกาย

งานวิจัยนี้ทำการทดสอบความถูกต้องและความแม่นยำด้วยการหา sensitivity specificity และ Accuracy จากการทดลองเคลื่อนไหว 100 ครั้ง ประกอบด้วย การก้ม การนั่งย่อ การเดิน การนั่ง และการล้ม โดยผลของการทดลองที่บทความวิจัยนี้นำเสนอ คือ Sensitivity 98.3% Specificity 95% และ Accuracy 97%

งานวิจัย Application of google media pose estimation using single camera (Zhang, 2022) นี้แนะนำเรื่องการใช้ MediaPipe ในการประมาณการท่าทางท่าโดยใช้กล้อง 1 ตัว โดย Google Media Pipe คือ Machine learning solution ที่สามารถตรวจจับท่าทางท่าจากรูปภาพหรือวิดีโอ MediaPipe Hands และ MediaPipe Face Mesh เป็นเฟรมเวิร์คแบบ open source ที่ประสบความสำเร็จ โดยใช้ Machine learning pipeline ที่ตรวจจับติดตามแบบ 2 ขั้นตอน ประกอบด้วย การระบุตำแหน่งคนด้วยบริเวณที่สนใจ (Region-of-Interest) โดยจะตรวจจับภายในบริเวณนั้น (RoI) ในส่วนของ MediaPipe Pose จะคืนค่าการทำนายท่าทาง 33 จุดบนร่างกายที่สำคัญ และโดยปกติจะใช้ “จุดบนร่างกายที่สำคัญ 0” (“landmark 0”) ซึ่งอยู่ที่บริเวณจมูก เป็นจุดที่ระบุตำแหน่งของคน Google MediaPipe แสดงผลกราฟของ Pose Landmark ด้วยโมดูลย่อย ของ Pose landmark Google MediaPipe Pose ถูกออกแบบมาให้สามารถปรับแต่งตามแต่ละแบบฟอร์มได้ ซึ่งทำให้สามารถใช้ได้ในหลากหลายสถานการณ์ รวมไปถึงการเลือกโหมดภาพนิ่ง, ความซับซ้อนของโมเดล, ความมั่นใจในการตรวจจับขั้นต่ำ และความมั่นใจในการติดตามขั้นต่ำ และอธิบายถึงกระบวนการใช้ MediaPipe

งานวิจัย Fall Detection Algorithm Based on Inertial Sensor and Hierarchical Decision (Zheng et al., 2023) นี้ใช้เซ็นเซอร์ติดตั้งบริเวณเอวของผู้ทดลองเพื่อเก็บข้อมูลการเคลื่อนไหว และพัฒนาโมเดลตรวจจับการล้มโดยใช้อัลกอริธึม XGBoost ส่วนของข้อมูลความเร่งและความเร็วเชิงมุมของร่างกายของมนุษย์ถูกเก็บรวบรวมโดยเซ็นเซอร์วัดความเฉื่อย จากลักษณะของพฤติกรรมในชีวิตประจำวันและพฤติกรรมล้ม ในงานวิจัยนี้ได้สกัดพีเจอร์ที่ใช้โดยทั่วกัน 44 พีเจอร์ ซึ่งมีจำนวนมาก และจะก่อให้เกิดภาระด้านการคำนวณและการประมวลผล และทำให้ใช้เวลาเรนโมเดลเพิ่มขึ้น ในงานวิจัยนี้ได้ปรับใช้กลยุทธ์ที่อาศัยการวิเคราะห์ความสำคัญของพีเจอร์ (FIA) เพื่อลดจำนวนพีเจอร์จาก 44 มิติเป็น 16 มิติ ซึ่งสามารถลดระยะเวลาในช่วงที่เรนโมเดลได้ และสามารถปรับปรุง accuracy ของโมเดลได้เล็กน้อย การทดลองเปรียบเทียบระหว่างการวิเคราะห์ความสำคัญของพีเจอร์และการวิเคราะห์องค์ประกอบหลัก (PCA) แสดงให้เห็นถึงประสิทธิภาพการทำงานที่ดีกว่าของ FIA งานวิจัยนี้แนะนำแนวคิดของการจัดชั้นมาใช้ในขั้นตอนการจำแนก โดยใช้วิธีการตั้งเกณฑ์เพื่อจำแนกข้อมูลในระดับแรก แล้วอัลกอริธึม XGBoost เพื่อจัดหมวดหมู่ข้อมูลในระดับสองอย่างแม่นยำ และในท้ายที่สุดจะกำหนดทิศทางล้มในระดับที่สาม โดยการใช้แนวคิดของการจัดชั้นนี้ช่วยลดความซับซ้อนและการประมวลผล การใช้ FIA ในการลดจำนวนมิติของพีเจอร์และการตัดสินใจแบบลำดับขั้นเพื่อระบุการล้ม ค่าความแม่นยำในงานวิจัยนี้ได้ 98.19% ความไวต่อการตรวจจับ เป็น 97.5% และความสามารถในการระบุว่าจะไม่ได้เกิดการล้ม (specificity) ได้ถึง 98.63% ผลการทดลองแสดงให้เห็นว่า แบบอัลกอริธึมตรวจจับการล้มและทิศทางล้มแบบการตัดสินใจแบบขั้นเชิงฮายเออร์คี่ที่เสนอในงานวิจัยนี้สามารถใช้ตรวจจับการล้มและทิศทางล้มได้ดี

งานวิจัย Home Camera-Based Fall Detection System for the Elderly (Miguel et al., 2017) นี้แนะนำเสนอเครื่องมือที่ประกอบด้วยคอมพิวเตอร์และกล้อง สำหรับการตรวจจับการล้มโดยมุ่งเป้าหมายไปยังผู้สูงอายุ ซึ่งสามารถติดกับเพดานเพื่อตรวจจับได้ตลอด 24 ชั่วโมง โดยไม่จำเป็นต้องใส่เครื่องมือหรืออุปกรณ์สวมใส่ใดๆ โดยจะทำการลบพื้นหลังออกจากภาพตรวจจับการเคลื่อนไหวและติดตามวัตถุ การใช้ Kalman filter สำหรับการลด noise และระบบ machine learning ที่จำแนกสถานะของผู้ทดลอง โดยมี 3 ตัวแปร คือ มุมระหว่างแกน x กับ แกนหลัก อนุพันธ์ของอัตราส่วน และความสัมพันธ์ระหว่างความกว้างและความสูงของสี่เหลี่ยมล้อมรอบผู้ทดลอง โดยพารามิเตอร์เหล่านี้สามารถแยกพฤติกรรมของผู้ทดลองได้ เช่น การเดิน การยืน การนั่ง และการล้ม โดยใช้ K-NN ในการจัดหมวดหมู่สถานะการล้ม/ไม่ล้ม ผลการทดลองพบว่าอัตราส่วนในการตรวจจับการล้มของเครื่องมือนี้ สูงถึงร้อยละ 96

งานวิจัย Comparative study on Fall Detection using Machine Learning Approaches (Tongskulroongruang et al., 2022) นี้ แนะนำการทำ feature selection เพื่อลดจำนวนพีเจอร์ที่มาจากกรกฎทรีโหวต โดยสนใจชุดข้อมูลที่ประกอบไปด้วยสัญญาณต่างๆ จากเครื่องมือ โดยชุดข้อมูลดังกล่าวได้แบ่งออกเป็น 3 หมวดหมู่ คือ ก่อนล้ม ล้ม และหลังล้ม โดยใช้วิธีการทาง machine learning ที่หลากหลาย ประกอบไปด้วย SVM KNN Decision tree Neural Network และ Random forest เวลาในการคำนวณลดลงอย่างมีนัยยะสำคัญเมื่อใช้กลยุทธ์การโหวตในการทำ feature selection สำหรับอัลกอริธึมแบบ classification

ซึ่งเวลาลดลงไปกว่า 66.67% สำหรับอัลกอริธึม Decision tree โดยค่า Accuracy ในการทำ classification ด้วย neural network สูงถึง 95.17% ในขณะที่ accuracy ที่ได้หลังจากการทำ feature selection ลดลงไม่เกิน 1.50%

งานวิจัย Using Deep Neural Networks for Human Fall Detection Based on Pose Estimation (Salimi et al., 2022) นี้ใช้เทคนิค Computer visions และ Deep learning ในการบ่งชี้เหตุการณ์การล้มและตรวจจับการล้มได้ด้วยค่า Accuracy ที่สูง โดยใช้วิธีการที่ใช้รูปภาพเป็นพื้นฐาน ซึ่งเป็นทางเลือกที่มากกว่าการใส่เครื่องมือติดกับร่างกาย วิธีที่ใช้ งานวิจัยนี้ได้ใช้ Time-Distributed Convolutional Long Short-Term Memory (TD-CNN-LSTM) และ Convolutional Neural Network แบบ 1 มิติ เพื่อแยกประเภทข้อมูลที่สกัดออกมาจากเฟรมภาพ โดยได้ ค่า accuracy ที่สูงถึง 98% สำหรับและ Convolutional Neural Network แบบ 1 มิติ และ 97% สำหรับ Time-Distributed Convolutional Long Short-Term Memory (TD-CNN-LSTM) ดังนั้น การประยุกต์ใช้ Fast Pose Estimation เป็นวิธีการที่มีประสิทธิภาพในการตรวจจับการล้มของมนุษย์ และสามารถใช้กับเครื่องมือได้ เนื่องจากใช้การคำนวณและหน่วยความจำน้อย

งานวิจัย Video-based Fall Detection for Seniors with Human Pose Estimation (Huang et al., 2018) นี้ศึกษาเกี่ยวกับการตรวจจับการล้มของผู้สูงอายุ โดยใช้ video-based แทนวิธีการก่อนๆ เช่น การใส่เครื่องมือติดเซนเซอร์ไว้กับร่างกาย หรือการใช้เซ็นเซอร์แวดล้อม ในการตรวจจับการล้มในบ้าน โดยใช้ไปป์ไลน์วิธีการตรวจจับการล้มแบบ 2 มิติ กับการประมาณการณ์ท่าทาง โดยใช้ Openpose ในการสกัดตำแหน่งของข้อต่อมนุษย์กับข้อมูลดิบ จากนั้นข้อมูลพร้อมกับพีเจอร์ที่เพิ่มเติมแล้วจะกลายเป็น input ให้กับ Convolutional neural network เพื่อให้สามารถสกัดพีเจอร์หลายเลเยอร์ได้

งานวิจัย Video based automatic fall detection in indoor environment (Vaidehi et al., 2011) ได้กล่าวถึงการล้มซึ่งเป็นสาเหตุหนึ่งที่น่าไปสู่การเสียชีวิตของผู้สูงอายุ เนื่องจากการเพิ่มขึ้นของผู้สูงอายุที่อยู่คนเดียว ทำให้มีแนวโน้มที่จะต้องการการตรวจจับการล้มอัตโนมัติเพิ่มมากขึ้น งานวิจัยนี้ได้ศึกษาการตรวจจับการล้มอัตโนมัติสำหรับผู้สูงอายุ โดยใช้วิดีโอ เนื่องจากราคาของกล้องวิดีโอมีราคาถูกลง และความก้าวหน้าของเทคนิคประมวลผลด้วยภาพ จึงได้ศึกษาโดยใช้ static features ในการตรวจจับการล้มโดยการใช้อัตราส่วนของร่างกายมนุษย์ และมุมร่างกาย โดยใช้วิดีโอ เนื่องจากใช้ทรัพยากรการคำนวณที่น้อย โดยใช้ OpenCV เมื่อไม่มีคนอยู่ที่หน้ากล้อง โดยระยะห่างของกล้องจะอยู่ที่ 2 ถึง 8 เมตร จากผู้ทดลอง ทุกพีเจอร์จะถูกรีเซ็ตให้เป็นค่าแรกเมื่อมีคนเดินเข้ามา อัตราส่วนร่างกายมนุษย์และมุมจะถูกคำนวณอย่างต่อเนื่องในทุกๆ วิดีโอเฟรม เมื่อตรวจจับได้จากเงื่อนไขที่ตั้งไว้ ระบบจะยังไม่แจ้งว่าเกิดการล้มขึ้นทันที แต่จะทิ้งช่วงไปเล็กน้อย แล้วจึงแจ้งเตือน เพื่อป้องกันความผิดพลาดเล็กน้อยที่เกิดขึ้น และระบบการตรวจจับการล้มนี้ ยังมีการแจ้งเตือนอีกด้วยว่า บุคคลที่ล้มลงไปสามารถลุกขึ้นมาได้หรือไม่ เพื่อประเมินสถานการณ์ว่าการล้มนั้นรุนแรงหรือไม่ โดยข้อความการแจ้งเตือนการล้มจะหายไปเมื่อผู้ทดลองลุกขึ้นอย่างเต็มตัว ซึ่งผู้ทดลองได้กล่าวถึงผลการทดลองว่า มีความแม่นยำในการตรวจจับการล้มด้านข้าง ล้มด้านหน้า และล้มหงายหลัง

งานวิจัย Multi-Occupancy Fall Detection Using Non-Invasive Thermal Vision Sensor (Zhong et al., 2021) นี้ได้ศึกษาเกี่ยวกับการตรวจจับการล้ม วิธีการทั่วไปที่ใช้กล้องวิดีโอในการตรวจจับการล้มถึงแม้จะแม่นยำ แต่ก็มักจะถูกละเลยว่ารู้ค่าความเป็นส่วนตัว เมื่อใช้ในบ้านพัก วิธีการใช้ภาพความร้อนจึงเป็นทางเลือกที่เหมาะสมกว่าเพราะความเป็นส่วนตัวที่มากขึ้น ทั้งนี้ ถึงแม้จะมีการพัฒนาวิธีการใช้ภาพความร้อนในการตรวจจับการล้ม ส่วนใหญ่ยังคงเน้นไปที่สถานการณ์ที่มีผู้อยู่อาศัยคนเดียวซึ่งไม่ตรงกับสถานการณ์จริงที่มักจะมีผู้อยู่หลายคน โดยผู้วิจัยได้พัฒนาวิธีการตรวจจับการล้มที่ใช้ภาพความร้อนสำหรับสถานการณ์ที่มีผู้อยู่หลายคน โดยที่วิธีการนี้สามารถแยกแยะได้ว่าเป็นการล้มหรือไม่ โดยใช้คุณลักษณะของภาพความร้อนที่ได้จาก Convolutional Neural Network (CNN) การทดลองของเราพบว่าวิธีการนี้ให้ความแม่นยำเฉลี่ยสูงสุดถึง 98.39%

วิธีดำเนินการ

การได้มาของข้อมูล (Data Acquisition)

ผู้วิจัยจะทำการแบ่งการได้มาของข้อมูลออกเป็น 2 ส่วน ในส่วนแรกจะเป็นข้อมูลวิดีโอคลิปจาก Multiple cameras fall dataset (E. Auvinet, 2010) โดยนำข้อมูล 5 สถานการณ์มาศึกษา และใน 1 สถานการณ์ จะใช้กล้อง 8 ตัวในการบันทึกการทดลอง ซึ่งกล้องทั้ง 8 ตัว จะถูกติดตั้งไว้ตามมุมต่างๆ ของห้องและใช้ภาพแบบมุมกว้าง โดยกล้องที่ใช้คือ Gadspot IP camera GS4600 และการได้มาของข้อมูลในส่วนที่สอง จะเป็นข้อมูลจากผลการทดลองของส่วนแรก

การเตรียมข้อมูล (Data Preparation)

การเตรียมข้อมูลจะแบ่งออกเป็น 2 ส่วน ในส่วนแรกจะเป็นการเตรียมข้อมูลวิดีโอคลิป ซึ่งจะทำการปรับเตรียมขนาด ช่องสี และคำสั่งที่สนับสนุนการทำงานกับ MediaPipe เพื่ออ่านและเขียนข้อมูลลงไปเป็นวิดีโอคลิป และในส่วนที่ 2 จะเป็นการเตรียมข้อมูลจากไฟล์ csv ซึ่งเป็นข้อมูลผลการทดลองจากข้อมูลวิดีโอคลิป แรก ปรับปรุงหมวดหมู่ว่าล้ม/ไม่ล้ม ให้ถูกต้องในแต่ละเฟรม และรวมข้อมูลดังกล่าวจาก 5 สถานการณ์ 8 มุมกล้องให้เป็นชุดข้อมูลเดียว ตัดคอลัมน์และค่าว่างออก และกำหนดคอลัมน์สำหรับใช้เป็นตัวแปรในการทดลอง

การกำหนดวิธีการวิเคราะห์ข้อมูล (Data analysis method)

การกำหนดวิธีการวิเคราะห์ข้อมูล แบ่งออกเป็น 2 ส่วน คือ การวิเคราะห์ข้อมูลวิดีโอคลิป โดยใช้วิธีการแบบ threshold based และ การวิเคราะห์ข้อมูลจากไฟล์ csv โดยใช้ machine learning

ส่วนที่ 1 การวิเคราะห์ข้อมูลวิดีโอคลิป โดยใช้วิธีการแบบ threshold based ในการตรวจจับการล้มของงานวิจัยนี้ ใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) เป็นเกณฑ์ในการตรวจจับการล้ม และการเปลี่ยนแปลงองศาของร่างกายเมื่อล้ม โดยมีรายละเอียดดังนี้

1.1 การตรวจจับการล้มโดยใช้อัตราส่วนขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) เป็นเกณฑ์ในการตรวจจับการล้ม

(1) เขียนฟังก์ชันเพื่อให้ได้ขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) โดยกำหนดจุด landmarks ที่จับได้จากร่างกายเป็นขอบเขตของสี่เหลี่ยมรอบร่างกายมนุษย์ ซึ่ง landmarks ที่ไม่ได้ใช้ประกอบการสร้างขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ได้แก่ จุดที่ 13 – 22 ซึ่งมีรายละเอียดดังนี้ จุดที่ 13 ข้อศอกซ้าย จุดที่ 14 ข้อศอกขวา จุดที่ 15 ข้อมือซ้าย จุดที่ 16 ข้อมือขวา จุดที่ 17 นิ้วก้อยซ้าย จุดที่ 18 นิ้วก้อยขวา จุดที่ 19 นิ้วชี้ซ้าย จุดที่ 20 นิ้วชี้ขวา จุดที่ 21 นิ้วโป้งซ้าย จุดที่ 22 นิ้วโป้งขวา เพื่อลดความคลาดเคลื่อนของอัตราส่วนขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) เมื่อมีการยกแขนหรือกางแขน โดยมีรายละเอียดเพิ่มเติมดังนี้

(i) สร้างตัวแปร x_coords และ y_coords เพื่อเก็บข้อมูลพิกัด x และ y ของ landmarks ที่แต่ละส่วนของร่างกาย ที่ได้กำหนดไว้ใน 3.3.1.1

(ii) กำหนดตัวแปรเพื่อเก็บพิกัดของ landmarks ที่มีค่ามากที่สุด และค่าน้อยที่สุดของแต่ละแกน (x_min, x_max, y_min, y_max) เพื่อนำมาประกอบการกำหนดความกว้างและความสูงของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) โดยความกว้างจะเท่ากับพิกัด x ที่มากที่สุด ลบพิกัด x ที่น้อยที่สุด และความสูงจะเท่ากับ พิกัด y ที่มากที่สุด ลบพิกัด y ที่น้อยที่สุด โดยสามารถแทนด้วยสมการ

$$\text{width} = x_{\text{max}} - x_{\text{min}} \text{ และ } \text{height} = y_{\text{max}} - y_{\text{min}}$$

(2) เมื่อได้ความกว้างและความสูงของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ขั้นตอนต่อไปคือการเขียนฟังก์ชัน เพื่อหาอัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) เพื่อใช้เป็นเกณฑ์ในการตรวจจับการล้มของมนุษย์

(3) เขียนฟังก์ชันเพื่อวาดขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ลงบนวิดีโอที่จะใส่เข้าไป เพื่อให้สามารถสังเกตระหว่างการวิจัยได้

(4) กำหนดเกณฑ์อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ที่ถูกตัดสินว่าเกิดการล้มขึ้น ให้เท่ากับ 1 โดยคำนวณจาก ความกว้างของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) หารด้วย ความสูงของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) หรือสามารถแทนด้วยสมการ

$$\text{Ratio} = \frac{\text{width}}{\text{height}}$$



ภาพประกอบ 1 การตรวจจับการล้มด้วยอัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box)

1.2 การตรวจจับการล้มโดยใช้การเปลี่ยนแปลงองศาของร่างกาย (มุมสะโพก-ข้อเท้า-เส้นพื้นดิน) เป็นเกณฑ์ในการตรวจจับการล้ม

(1) เขียนฟังก์ชันเพื่อคำนวณมุมจากจุดที่กำหนด โดยใช้มุมจากจุดสะโพก ข้อเท้า และเส้นพื้นดิน โดยมีรายละเอียดเพิ่มเติมดังนี้

(i) คำนวณเวกเตอร์จากข้อเท้าไปยังสะโพก โดยให้พิกัด x ของข้อเท้า ลบกับพิกัด x ของสะโพก และให้พิกัด y ของข้อเท้า ลบกับพิกัด y ของสะโพก โดยสามารถแทนด้วยสมการดังนี้

$$\vec{a} = (x_{hip} - x_{ankle}), (y_{hip} - y_{ankle})$$

โดยกำหนดให้เวกเตอร์จากข้อเท้าไปยังสะโพก ถูกแทนค่าด้วย \vec{a}

(ii) คำนวณ dot product เพื่อนำค่าที่ได้มาประกอบการคำนวณเพื่อหามุมระหว่างเวกเตอร์สะโพก-ข้อเท้า และ เส้นพื้นดิน โดยสามารถแทนด้วยสมการดังนี้

$$\vec{a} \cdot \hat{i} = ((x_{hip} - x_{ankle}) \times 1) + ((y_{hip} - y_{ankle}) \times 0)$$

โดยเส้นพื้นดินเป็น unit vector (1,0) แทนค่าด้วย \hat{i}

(iii) คำนวณ magnitude ของ hip-ankle vector เพื่อนำค่าที่ได้มาประกอบการคำนวณเพื่อหามุมระหว่างเวกเตอร์สะโพก-ข้อเท้า และ เส้นพื้นดิน โดยสามารถแทนด้วยสมการดังนี้

$$|\vec{a}| = \sqrt{(x_{hip} - x_{ankle})^2 + (y_{hip} - y_{ankle})^2}$$

โดย magnitude ของเส้นพื้นดินมีค่าเป็น 1

หาค่า cosine ของมุมระหว่างเวกเตอร์สะโพก-ข้อเท้า และ เส้นพื้นดิน โดยจำกัดค่า cosine ให้อยู่ในระหว่าง -1 ถึง 1 เพื่อป้องกันการปัดเศษจากการคำนวณ โดยสามารถแทนด้วยสมการดังนี้

$$\cos\theta = \frac{\vec{a} \cdot \hat{i}}{|\vec{a}|}$$

(v) เปลี่ยนมุมเรเดียนให้กลายเป็นมุมองศาด้วยสมการ

$$\text{มุมองศา} = \frac{180}{\pi} \times \text{มุมเรเดียน}$$

(2) กำหนดเกณฑ์ตัดสินกำหนดการล้ม โดยใช้มุมที่ได้จากการคำนวณของทั้งสะโพกและข้อเท้าทั้งด้านซ้ายและด้านขวา โดยหากมุมที่ได้จากการคำนวณจากสะโพกและข้อเท้าด้านซ้าย หรือ สะโพกและข้อเท้าด้านขวา มีขนาดมากกว่า 120 องศา หรือน้อยกว่า 60 องศา จะถือว่าเกิดการล้มขึ้น



ภาพประกอบ 4 การตรวจจับการล้มโดยใช้การเปลี่ยนแปลงองศาของร่างกาย
(มุมสะโพก-ข้อเท้า-เส้นพื้นดิน)

ส่วนที่ 2 การวิเคราะห์ข้อมูลจากไฟล์ csv

2.1 การใช้ Random forest เพื่อวิเคราะห์การตรวจจับการล้ม โดยจะนำค่าที่ได้จากการตรวจจับการล้มจากอัตราส่วนขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) และ การเปลี่ยนแปลงองศาของร่างกาย (มุมสะโพก-ข้อเท้า-เส้นพื้นดิน) ที่ปรับให้คอลัมน์ผลลัพธ์มีหมวดหมู่ที่ถูกต้องตามเกณฑ์ที่กำหนด นำมาให้โมเดลเรียนรู้และทดสอบ

2.2 การใช้ K-NN เพื่อวิเคราะห์การตรวจจับการล้ม โดยจะนำค่าที่ได้จากการตรวจจับการล้มจาก 1.1 และ 1.2 ที่ปรับให้คอลัมน์ผลลัพธ์มีค่าที่ถูกต้องตามเกณฑ์ที่กำหนด นำมาให้โมเดลเรียนรู้และทดสอบ

การประเมินผล (Evaluation)

ประเมินผลจากการบันทึกผลการตรวจจับการล้ม โดยบันทึกจากวิดีโอนำเข้า 40 คลิป และหาร้อยละจำนวนเฟรมที่มีเดียไปป์สามารถจับผู้ทดลองได้ต่อจำนวนเฟรมทั้งหมดที่ผู้ทดลองปรากฏ และค่า Accuracy Recall Precision และ F-1 score เพื่อประเมินประสิทธิภาพของวิธีการที่กำหนดและประสิทธิภาพของมุมที่กล้องติดตั้งในห้องที่ปรากฏในชุดข้อมูลทั้ง 8 มุม และเปรียบเทียบ Accuracy Recall Precision และ F-1 score ของ 4 วิธีการ โดยค่า accuracy คำนวณโดย แทนค่า

จำนวนเฟรมที่ ความเป็นจริงและการทำนายคือ 'ล้ม' เป็น True Positive (TP)

จำนวนเฟรมที่ ความเป็นจริงและการทำนายคือ 'ไม่ล้ม' เป็น True Negative (TN)

จำนวนเฟรมที่ ความเป็นจริง คือ 'ไม่ล้ม' แต่การทำนายคือ 'ล้ม' เป็น False Positive (FP)

จำนวนเฟรมที่ ความเป็นจริง คือ 'ล้ม' แต่การทำนายคือ 'ไม่ล้ม' เป็น False Negative (FN)
 การคำนวณ ค่า accuracy คำนวณโดย

$$\frac{(TP + TN)}{(TP + TN + FP + FN)}$$

การคำนวณ ค่า recall คำนวณโดย

$$\frac{TP}{TP + FN}$$

การคำนวณ ค่า Precision คำนวณโดย

$$\frac{TP}{TP + FP}$$

การคำนวณ ค่า F1 – score คำนวณโดย

$$\frac{2 \times (recall \times precision)}{(recall + precision)}$$

การประเมินผลจะประเมินผลทั้ง 4 วิธี โดย 2 วิธีแรก จะเป็น 1.การตรวจจับการล้มโดยใช้อัตราส่วนขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) เป็นเกณฑ์ในการตรวจจับการล้ม และ 2.การตรวจจับการล้มโดยใช้การเปลี่ยนแปลงองศาของร่างกายเป็นเกณฑ์ในการตรวจจับการล้ม จะคำนวณค่าเฉลี่ยของ ค่า Accuracy Recall Precision และ F-1 score จากทุกสถานการณ์ของแต่ละกล้องร่วมกัน

และ 2 วิธีหลังจะเป็นการประเมินผลจากวิธี 3. การใช้ Random forest ซึ่งก็คือ อัลกอริทึมใน Machine Learning ที่ใช้ต้นไม้ตัดสินใจ (decision tree) หลายๆ ต้น ทำงานร่วมกัน ต้นไม้แต่ละต้น เรียนรู้จากข้อมูลที่แตกต่างกัน จากชุดข้อมูลที่กำหนด และทำนายออกมา ผลการทำนายที่ได้จากต้นไม้แต่ละต้นจะถูกนำมาโหวต คลาสที่ได้รับการโหวตมากที่สุดจะเป็นผลลัพธ์ ใช้ได้ทั้งกับงาน classification และ regression และ 4. การใช้ K-NN เพื่อวิเคราะห์การตรวจจับการล้ม ซึ่ง K-NN เป็นอัลกอริทึมใน machine learning ว่าจะจัดกลุ่มข้อมูล โดยผู้ใช้จะต้องกำหนดค่า K หรือจำนวนข้อมูลที่ใกล้เคียงที่สุดกับข้อมูลที่จะทำนาย เพื่อให้รู้ว่าข้อมูลจำนวน K ที่ใกล้กับข้อมูลที่ต้องการทำนาย ส่วนใหญ่อยู่ในคลาสใด แล้วจึงทำนายข้อมูลเป้าหมาย โดยจะหาค่า Accuracy Recall Precision และ F-1 score ของผลการทดลองที่ใช้ข้อมูลที่ได้จากการทดลองที่ใช้ Bounding box รวมกันทั้งหมด และมุมมองร่างกาย รวมกันทั้งหมด นำเข้ากระบวนการ Machine learning ดังกล่าว

ผลการวิจัยและอภิปรายผลการวิจัย

จากการทดลองการตรวจจับการล้มจากการตรวจจับการล้มโดยวิธีการใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) เป็นเกณฑ์ในการตรวจจับการล้ม และการเปลี่ยนแปลงองศาของร่างกายเมื่อล้ม (มุมสะโพก-ข้อเท้า-เส้นพื้นดิน) 5 สถานการณ์ โดยมีรายละเอียดของแต่ละสถานการณ์ดังนี้

สถานการณ์ที่ 1 เป็นสถานการณ์ที่ผู้ทดลอง เดินเข้ามาจากประตูทางเข้า หยุดยืนอยู่ที่หน้าเก้าอี้เพื่อหยิบเสื้อคลุมและสวมใส่ ขณะที่กำลังจะสวมใส่เสื้อคลุม ผู้ทดลองได้ล้มหายหลังไปบนฟูก หลังจากนั้นจึงลุกขึ้นยืน หันก้มเก็บสิ่งของ และลุกขึ้นยืนอีกครั้งหนึ่ง

สถานการณ์ที่ 2 เป็นสถานการณ์ที่ผู้ทดลอง เดินเข้ามาจากประตูทางเข้า มายังมุมฟูกกลางห้อง ล้มตะแคงด้านข้าง และพลิกตัวหายหลังบนฟูก แล้วจึงลุกขึ้นยืน

สถานการณ์ที่ 3 สถานการณ์นี้ เป็นสถานการณ์ที่ผู้ทดลอง เดินเข้ามาจากประตูทางเข้า มายังปลายฟูกกลางห้อง หยุดยืนและล้มไปด้านหน้าบนฟูก จากนั้นตั้งท่าในลักษณะคุกเข่า แล้วจึงลุกขึ้นยืน

สถานการณ์ที่ 4 เป็นสถานการณ์ที่ผู้ทดลอง เดินเข้ามาจากประตูทางเข้า มายังมุมฟูกกลางห้อง และล้มตะแคงข้างไปบนฟูก จากนั้นตั้งท่าจะลุกขึ้น และล้มในลักษณะตะแคงข้างอีกครั้งบนพื้นบริเวณข้างฟูก แล้วจึงลุกขึ้นยืน

สถานการณ์ที่ 5 เป็นสถานการณ์ที่ผู้ทดลอง เดินเข้ามาจากประตูทางเข้า มายังขอบฟูกกลางห้อง สะดุดล้มไปด้านหน้าลงบนฟูก แล้วจึงใช้ข้อศอกค้ำยันร่างกายขึ้นมา และนั่งในท่าคุกเข่า

ค่าเฉลี่ยจำนวนร้อยละของเฟรมที่มีเดียไปป์สามารถตรวจจับร่างการมนุษย์ ต่อจำนวนเฟรมทั้งหมดใน 5 สถานการณ์ของกล้อง 8 ตัว และคำนวณค่าเฉลี่ยของ accuracy recall precision และ F1-score พบว่า กล้องตัวที่ 2 และกล้องตัวที่ 7 มีค่าเฉลี่ยใน 5 สถานการณ์ที่สูงใกล้เคียงกัน กล่าวคือ กล้องตัวที่ 2 มีค่าเฉลี่ยจำนวนร้อยละของเฟรมที่มีเดียไปป์สามารถตรวจจับร่างการมนุษย์ ต่อจำนวนเฟรมทั้งหมดใน 5 สถานการณ์ คือ 92.13 accuracy 0.78 recall 0.74 precision 0.99 และ F1-score 0.83 ในขณะที่ กล้องตัวที่ 7 มีค่าเฉลี่ยจำนวนร้อยละของเฟรมที่มีเดียไปป์สามารถตรวจจับร่างการมนุษย์ ต่อจำนวนเฟรมทั้งหมดใน 5 สถานการณ์ คือ 92.54 accuracy 0.69 recall 0.65 precision 0.77 และ F1-score 0.70

โดยผลการทดลอง การตรวจจับการล้มจากการตรวจจับการล้มโดยวิธีการใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างการมนุษย์ (Bounding box) เป็นเกณฑ์ในการตรวจจับการล้ม และการเปลี่ยนแปลงองศาของร่างการเมื่อล้ม (มุมสะโพก-ข้อเท้า-เส้นพื้นดิน) ได้ค่าประเมินผลดังนี้ การตรวจจับการล้มโดยใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างการมนุษย์ (Bounding box) ได้ค่าเฉลี่ย accuracy 0.64 recall 0.45 precision 0.93 และ F1-score 0.65 การตรวจจับการล้มโดยใช้มุมมองศาร่างการมนุษย์ (สะโพก ข้อเท้า เส้นพื้นดิน) ได้ค่าเฉลี่ย accuracy 0.74 recall 0.71 precision 0.82 และ F1-score 0.72

ตาราง 1 ค่าเฉลี่ย Accuracy Recall Precision และ F1-score ของการทดลองตรวจจับการล้มของอัตราส่วนขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) และ ตรวจจับการล้มโดยใช้มุมมองศาร่างกายมนุษย์ (สะโพก ข้อเท้า เส้นพื้นดิน) ทั้ง 5 สถานการณ์

| ชุดข้อมูลและวิธีการวิเคราะห์ | Accuracy | Recall | Precision | F1-score |
|------------------------------|----------|--------|-----------|----------|
| Bounding box dataset | 0.64 | 0.45 | 0.93 | 0.65 |
| Angle dataset | 0.74 | 0.71 | 0.82 | 0.72 |

ผลการทดลองในการใช้ Random forest และ K-NN จากชุดข้อมูลที่มาจากการทดลองตรวจจับการล้มของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ปรากฏว่า Random forest ได้ค่า accuracy 0.98 (0.9763) โดยค่าเฉลี่ย (weighted avg) ของ precision คือ 0.98 recall คือ 0.98 F1-score คือ 0.98 ในด้านของ K-NN ได้ค่า accuracy 0.98 (0.9765) โดยค่าเฉลี่ย (weighted avg) ของ precision คือ 0.98 recall คือ 0.98 F1-score คือ 0.98

ผลการทดลองในการใช้ Random forest และ K-NN จากชุดข้อมูลที่มาจากการทดลองตรวจจับการล้มโดยใช้มุมมองศาร่างกายมนุษย์ (สะโพก ข้อเท้า เส้นพื้นดิน) ปรากฏว่า Random forest ได้ค่า accuracy 0.98 (0.9767) โดยค่าเฉลี่ย (weighted avg) ของ precision คือ 0.98 recall คือ 0.98 F1-score คือ 0.98 ในด้านของ K-NN ได้ค่า accuracy 0.85 (0.8478) โดยค่าเฉลี่ย (weighted avg) ของ precision คือ 0.85 recall คือ 0.85 F1-score คือ 0.85

ตาราง 2 ผลการทดลองจากการวิเคราะห์ข้อมูลจากไฟล์ csv ด้วย Machine learning

| ชุดข้อมูลและวิธีการวิเคราะห์ | Accuracy | Recall | Precision | F1-score |
|------------------------------|----------|--------|-----------|----------|
| Bounding box dataset | | | | |
| Random forest | 0.9763 | 0.98 | 0.98 | 0.98 |
| K-NN | 0.9765 | 0.98 | 0.98 | 0.98 |
| Angle dataset | | | | |
| Random forest | 0.9767 | 0.98 | 0.98 | 0.98 |
| K-NN | 0.8478 | 0.85 | 0.85 | 0.85 |

สรุปผลการวิจัย

การหกล้มของมนุษย์มีผลกระทบอย่างมากในการดำเนินชีวิต โดยเฉพาะในผู้สูงอายุ ผู้วิจัยจึงได้ทำการศึกษาและทดลองการตรวจจับการล้มโดยใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) และ การเปลี่ยนแปลงองศาของร่างกาย (มุมสะโพก-ข้อเท้า-เส้นพื้นดิน) เป็นวิธีในการตรวจจับการล้มแบบ threshold-based ซึ่งเมื่อได้ผลลัพธ์มาแล้ว ผู้วิจัยได้ปรับ

หมวดหมู่การตรวจจับการล้มในแต่ละเฟรมให้ถูกต้อง เพื่อเตรียมข้อมูลในการนำไปใช้กับ วิธีแบบ Machine learning – based ด้วยโมเดล random forest และ K-NN

จากผลการทดลอง สามารถสรุปผลการวิจัยได้ดังนี้ผู้วิจัยได้ศึกษามุมกล้องที่เหมาะสมที่สุดในการตรวจจับการล้ม โดยถึงแม้ว่าค่าเฉลี่ยจำนวนร้อยละของเฟรมที่มีเตี้ยไปป์สามารถตรวจจับร่างกายมนุษย์ ต่อจำนวนเฟรมทั้งหมดใน 5 สถานการณ์ ของกล้องตัวที่ 7 จะมีค่ามากกว่ากล้องตัวที่ 2 แต่ค่าเฉลี่ยอื่นๆ กล้องตัวที่ 2 มีค่ามากกว่ากล้องตัวที่ 7 ดังนั้น ผู้วิจัยจึงสรุปผลการวิจัยได้ว่า มุมกล้องที่เหมาะสมที่สุดในการทดลองนี้ คือมุมกล้องที่ได้จาก กล้องตัวที่ 2

ทั้งนี้ทางผู้วิจัยได้สังเกตว่า แม้ว่าตำแหน่งที่ติดตั้งกล้องทั้งสองตัว จะเป็นตำแหน่งที่อยู่ด้านตรงข้ามกัน แต่มุมกล้องที่ 2 จะเอียงไปด้านซ้ายมากกว่าเล็กน้อย ส่งผลให้มุมการรับภาพต่างกัน เมื่อพิจารณาจากการคำนวณค่าเฉลี่ย ปรากฏว่า สถานการณ์ที่ทำให้ค่าเฉลี่ยมุมกล้องที่ 2 และมุมกล้องที่ 7 ต่างกันมาก คือสถานการณ์ที่ 4 ในวิธีการตรวจจับการล้มโดยใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) โดยจะมีการล้ม 2 รอบ ด้วยทิศทางการล้มและมุมกล้องทำให้มองเห็นผู้ทดลอง มีทิศทางการล้มในกล้องที่ 2 ใกล้เคียงกับระนาบด้านซ้าย-ขวา ของภาพมากกว่า ส่งผลให้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ในกล้องตัวที่ 2 มีมากกว่า กล้องตัวที่ 7 โดยกล้องตัวที่ 7 ไม่สามารถทำนายการล้มจริงได้เลยในวิธีและสถานการณ์นี้

ทั้งนี้สำหรับการพิจารณามุมกล้องที่เหมาะสมที่สุดในการทดลองนี้ ยังคงมีข้อจำกัดบางประการ กล่าวคือ การตั้งกล้องที่แม้จะเป็นการตั้งกล้องบริเวณตรงข้ามกัน แต่ก็ติดตั้งให้มีการรับภาพแบบแตกต่างกันเล็กน้อย รวมถึงกล้องที่ใช้ในการทดลอง เป็นกล้องมุมกว้าง ทำให้มี การบิดเบือนของขนาดร่างกายผู้ทดลองอยู่บ้าง จึงไม่อาจสรุปได้ว่า หากเป็นสถานการณ์อื่นๆ กล้องแบบอื่นๆ หรือในห้องอื่นๆ จะให้ผลลัพธ์ที่เหมือนกันหรือไม่ ทั้งนี้การสรุปผลลัพธ์ เป็นเพียงผลสรุปจากการทดลองนี้เท่านั้น

ในส่วนของวิธีการตรวจจับการล้ม จะเห็นได้ว่าวิธีที่ได้ Accuracy มากที่สุดคือ การใช้โมเดล Random forest กับชุดข้อมูล ซึ่งได้ค่าเฉลี่ย accuracy 0.9767 recall 0.98 precision 0.98 และ F1-score 0.98 จากผลการทดลองของการตรวจจับการล้มโดยใช้มุมมองสร้างร่างกายมนุษย์ (สะโพก ข้อเท้า เส้นพื้นดิน) ในส่วนของวิธีการตรวจจับการล้มแบบ threshold-based วิธีที่ได้ค่าเฉลี่ย accuracy recall precision และ F1-score มากกว่าคือการตรวจจับการล้มโดยใช้มุมมองสร้างร่างกายมนุษย์ (สะโพก ข้อเท้า เส้นพื้นดิน) ซึ่งได้ค่าเฉลี่ย accuracy 0.74 recall 0.71 precision 0.82 และ F1-score 0.72 ในขณะที่การตรวจจับการล้มโดยใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ได้ค่าเฉลี่ย accuracy 0.64 recall 0.45 precision 0.93 และ F1-score 0.65

ทั้งนี้ ผู้วิจัยได้พิจารณาจากวิธีการทั้งอัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) และการเปลี่ยนแปลงองศาของร่างกาย (มุมสะโพก-ข้อเท้า-เส้นพื้นดิน) โดยมีข้อสังเกตว่า เนื่องจากวิธีการใช้อัตราส่วนของขอบเขตสี่เหลี่ยมรอบร่างกายมนุษย์ (Bounding box) ต้องใช้จุดบนร่างกายที่มีเตี้ยไปป์จับได้ ทั้งร่วมกัน 4 จุด ซึ่งเป็นจุดร่วมในการวาด Bounding box รอบตัวผู้ทดลอง เพื่อหาอัตราส่วนที่เปลี่ยนแปลงของร่างกายเมื่อทำกิจกรรมต่างๆ รวมถึงการล้ม จึงต้องอาศัยข้อมูลจากหลายจุด เพื่อนำมาประมวลผลในการทำนายค่าตอบเดียว รวมถึงหาก Mediapipe ไม่สามารถจับจุดใดจุดหนึ่งได้ ก็จะไม่สามารถคำนวณตามวิธีการที่ตั้งไว้ได้ อย่างไรก็ตาม การตรวจจับการล้มด้วยวิธีการเปลี่ยนแปลงองศาของร่างกาย (มุมสะโพก-ข้อ

เท้า-เส้นพื้นดิน) สามารถทำได้จากมุมสะโพก-ข้อเท้า-เส้นพื้นดิน ทั้งจากด้านซ้ายและด้านขวา ซึ่งจะมีโอกาสตรวจจับการล้มได้มากกว่า

อย่างไรก็ตาม งานวิจัยนี้ยังคงมีข้อสังเกตคือ ระยะห่างระหว่างผู้ทดลอง กับกล้อง โดยระยะห่างที่แตกต่างกัน จะนำไปสู่ผลลัพธ์ที่แตกต่างกัน หากมีระยะห่างขนาดพอดี ที่สามารถมองเห็นได้ตั้งแต่ศีรษะถึงเท้า ก็จะมีโอกาสที่ Mediapipe จะตรวจจับร่างกายผู้ทดลองได้มากกว่า

ทั้งนี้ ผู้วิจัยมีความเห็นว่า งานวิจัยนี้สามารถปรับปรุงและนำไปต่อยอดได้ โดยสามารถทำร่วมกับ Object detection เพื่อตรวจจับเฟอร์นิเจอร์ เช่น เตียง โซฟา เก้าอี้เอนหลัง โดยจะช่วยลดการแจ้งเตือนผิด (false alarm) เมื่อผู้ทดลองมีปฏิสัมพันธ์กับเฟอร์นิเจอร์เหล่านี้ เช่น นั่ง เอนหลัง นอน เป็นต้น รวมถึงสามารถปรับใช้การทำนายการล้มด้วยวิธีแบบ threshold-based หลากหลายวิธีร่วมกัน หรือสามารถใช้การทำนายการล้มด้วยวิธีแบบ threshold-based ร่วมกับวิธี Machine learning-based ได้เช่นกัน รวมไปถึงการสร้างระบบแจ้งเตือนโดยการเชื่อมต่อ API จากแพลตฟอร์มต่างๆ เช่น Line Notify เพื่อแจ้งเตือนเมื่อมีการตรวจจับการล้มเกิดขึ้น

กิตติกรรมประกาศ

ขอขอบคุณอาจารย์ ดร.วีระ สอิ้ง ที่สนับสนุนการทำสารนิพนธ์ครั้งนี้ ทั้งด้านความรู้และกำลังใจ ขอขอบคุณอาจารย์คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ที่ให้ความรู้ที่จำเป็นต่อการทำสารนิพนธ์นี้ ขอคุณ รศ. ดร. สุปัทมา เอื้อทวีเกียรติ ประธานกรรมการสอบปากเปล่าสารนิพนธ์ ผศ.ดร.ศิริสรรพ เหล่าหะเกียรติ ประธานกรรมการสอบเค้าโครงสารนิพนธ์ และกรรมการสอบปากเปล่าสารนิพนธ์ ผศ.ดร.นุรีย์ วิวัฒน์วัฒนา กรรมการสอบเค้าโครงสารนิพนธ์ ที่ช่วยพิจารณาและชี้แจงและเพิ่มเติมให้สารนิพนธ์นี้ และ ขอขอบคุณครอบครัว คุณแม่เล็ก และพี่เอ ที่เข้าใจและคอยอยู่เคียงข้างเสมอ รวมไปถึงการสนับสนุนผู้ทำสารนิพนธ์นี้ในทุกๆ ด้าน โดยเฉพาะด้านกำลังใจ ผู้ทำสารนิพนธ์มีความตั้งใจอยากให้สารนิพนธ์นี้เป็นประโยชน์ต่อสังคม และต่อยอดเพื่อลดความเสี่ยงของผู้สูงอายุของการหกล้มในบ้าน

เอกสารอ้างอิง

- [1] Chen, W., Jiang, Z., Guo, H., & Ni, X. (2020). Fall Detection based on key points of human-skeleton using openpose. 12. <https://doi.org/10.3390/SYM12050744>
- [2] E. Auvinet, C. Rougier, J.Meunier, A. St-Arnaud, J. Rousseau, "Multiple cameras fall dataset", Technical report 1350, DIRO - Université de Montréal, July 2010.
- [3] Huang, Z., Liu, Y., Fang, Y., & Horn, B. K. P. (2018). Video-based Fall Detection for Seniors with Human Pose Estimation. *2018 4th International Conference on Universal Village (UV)*, 1-4. <https://doi.org/10.1109/UV.2018.8642130>

- [4] Miguel, K., Brunete, A., Hernando, M., & Gambao, E. (2017). Home Camera-Based Fall Detection System for the Elderly. *Sensors*, 17, 2864. <https://doi.org/10.3390/s17122864>
- [5] Ren, L., Peng, Y., & (2019). Research of fall detection and fall prevention technologies: A systematic review. *IEEE Access*, 7, 77702-77722. <https://doi.org/10.1109/ACCESS.2019.2922708>
- [6] Salimi, M., Machado, J. J. M., & Tavares, J. (2022). Using Deep Neural Networks for Human Fall Detection Based on Pose Estimation. *Sensors (Basel)*, 22(12). <https://doi.org/10.3390/s22124544>
- [7] Tongskulroongruang, T., Wiphunawat, P., Jutharee, W., Kaewmahanin, W., Rassameecharoenchai, T., Jennawasin, T., & Kaewkamnerdpong, B. (2022). Comparative Study on Fall Detection using Machine Learning Approaches. *2022 19th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 1-4. <https://doi.org/10.1109/ECTI-CON54298.2022.9795445>
- [8] University, C. M. (2016). *Researchers develop fall-prevention sensors*. <https://www.ece.cmu.edu/news-and-events/story/2016/04/fall-prevention-sensors.html>
- [9] Vaidehi, V., Ganapathy, K., Mohan, K., Aldrin, A., & Nirmal, K. (2011). Video based automatic fall detection in indoor environment. *2011 International Conference on Recent Trends in Information Technology (ICRTIT)*, 1016-1020. <https://doi.org/10.1109/ICRTIT.2011.5972252>
- [10] Zhang, Y. (2022). APPLICATIONS OF GOOGLE MEDIAPIPE POSE ESTIMATION USING A SINGLE CAMERA A Project.
- [11] Zheng, L., Zhao, J., Dong, F., Huang, Z., & Zhong, D. (2023). Fall Detection Algorithm Based on Inertial Sensor and Hierarchical Decision. 23. <https://doi.org/10.3390/s23010107>
- [12] Zhong, C., Ng, W. W. Y., Zhang, S., Nugent, C. D., Shewell, C., & Medina-Quero, J. (2021). Multi-Occupancy Fall Detection Using Non-Invasive Thermal Vision Sensor. *IEEE Sensors Journal*, 21(4), 5377-5388. <https://doi.org/10.1109/JSEN.2020.3032728>
- [13] กระทรวงมหาดไทย, ก. (2566, 4). สถิติผู้สูงอายุไทย ปี 2565 โดยกลุ่มนโยบายและยุทธศาสตร์ กรมกิจการผู้สูงอายุ. <https://www.dop.go.th/th/know/side/1/1/1962>

- [14] รศสีดา, ป. (2561). การป้องกันการหกล้มของผู้สูงอายุในชุมชน: บทบาทพยาบาลกับการดูแลสุขภาพที่บ้าน. 11.
- [15] เอกกิตติ์ สุรการ, เอกจิต ศิขรินกุล, ธีรยาภรณ์ ตันสกุล, & วัฒนพนม, พ. (2564). อย่าให้สูงวัยล้ม เดียวไม่ลูก. <https://www.bangkokhospital.com/content/beware-of-elderly-people-falling>