



กทปส

รายงานฉบับสมบูรณ์

โครงการขอรับการส่งเสริมและสนับสนุนจากเงินกองทุนวิจัยและพัฒนากิจการกระจายเสียง
กิจการโทรทัศน์ และกิจการโทรคมนาคม เพื่อประโยชน์สาธารณะ

โครงการดูแลผู้สูงอายุ Elder Care

ศ.ดร. แมททีว เนลสัน เดลีย์ และคณะ

กันยายน พ.ศ. 2564

กองทุนวิจัยและพัฒนากิจการกระจายเสียง กิจการโทรทัศน์ และกิจการโทรคมนาคม เพื่อประโยชน์สาธารณะ
(สำนักงาน กสทช.)

แบบ กทปส. ME-003

รายงานฉบับสมบูรณ์

ทุนส่งเสริมและสนับสนุนการวิจัยและพัฒนา
สัญญารับทุนเลขที่ BT2-12/161

โครงการดูแลผู้สูงอายุ
Elder Care

คณะนักวิจัย

- | | |
|-------------------------------|------------------------|
| 1. ศ.ดร. แมททิว เนลสัน เดลีย์ | นักวิจัยหัวหน้าโครงการ |
| 2. รศ.ดร. มงคล เอกปัญญาพงศ์ | นักวิจัยร่วม |
| 3. นางสาว อะนิกา นุสราท เซริน | นักวิจัยร่วม |
| 4. นาย อาเมียร์ ราชัก | นักวิจัยร่วม |
| 5. นาย เจตนิพัทธ์ มุลรินดี๊ะ | นักวิจัยร่วม |
| 6. นาย อะนุบินดา กูรุง | นักวิจัยร่วม |

ได้รับทุนอุดหนุนจาก
กองทุนวิจัยและพัฒนากิจการกระจายเสียง กิจการโทรทัศน์ และกิจการโทรคมนาคม เพื่อประโยชน์สาธารณะ
(สำนักงาน กสทช.)

กันยายน พ.ศ. 2564

บทสรุปผู้บริหาร

โครงการดูแลผู้สูงอายุ
กันยายน พ.ศ. 2564

ผู้สูงอายุส่วนใหญ่ชอบใช้ชีวิตอยู่ที่บ้านแต่การใช้ชีวิตอยู่ที่บ้านโดยไม่ได้รับความช่วยเหลือเต็มเวลาอาจมีความเสี่ยงเนื่องจากอาจหกล้มได้ หนึ่งในสามของผู้สูงอายุที่มีอายุมากกว่า 65 ปีเกิดการหกล้มในแต่ละปี ความช่วยเหลือที่ล่าช้าอาจนำไปสู่การบาดเจ็บสาหัส และทำให้สูญเสียความคล่องตัวและความอิสระในการเคลื่อนไหวส่วนต่าง ๆ ของร่างกายในภายหลัง การวิจัยและพัฒนาในปัจจุบันส่วนใหญ่ในการประมวลผลวิดีโอสำหรับการดูแลผู้สูงอายุมุ่งเน้นไปที่การตรวจจับการหกล้มและการตรวจจับและการบันทึกกิจกรรมของผู้สูงอายุในช่วงเวลาหนึ่ง ในทางกลับกัน การแจ้งเตือนพฤติกรรมผิดปกติแบบเรียลไทม์อาจช่วยคาดการณ์และป้องกันการเกิดอุบัติเหตุได้ดีกว่าการให้การช่วยเหลือที่รวดเร็วภายหลังการเกิดอุบัติเหตุ

เป้าหมายของการวิจัยนี้คือ การปรับปรุงพัฒนาเทคโนโลยีวิดีโอสำหรับการดูแลผู้สูงอายุให้ดีขึ้น ทำให้เกิดความยั่งยืนในการดูแลสุขภาพอนามัยสำหรับผู้สูงอายุในครอบครัว และเพิ่มกิจกรรมความเป็นผู้ประกอบการในการใช้ประโยชน์จากเทคโนโลยีวิดีโอสำหรับการดูแลผู้สูงอายุ

ในการวิจัยและพัฒนานี้ ทีมวิจัยนำเสนอต้นแบบอุปกรณ์ประมวลผลวิดีโอแบบ IoT ที่มีโมดูลการตรวจจับ การติดตาม และการจดจำบุคคล และโมดูลสำหรับการตรวจจับการล้มและการสรุปกิจกรรมซึ่งสามารถใช้ในการเฝ้าดูท่าทางการเคลื่อนไหวของผู้สูงอายุ และทำการแจ้งเตือนเมื่อมีพฤติกรรมผิดปกติหรือการเคลื่อนไหวที่ไม่มั่นคงเกิดขึ้น ระบบประกอบด้วยอุปกรณ์ประมวลผลแบบ edge และกรอบการประมวลผลแบบคลาวด์ที่ช่วยให้สามารถจัดทำโปรไฟล์กิจกรรม การแจ้งเตือนการเคลื่อนไหวที่ไม่มั่นคง และการแจ้งเตือนการล้มสำหรับผู้สูงอายุที่อาศัยอยู่ที่บ้านภายใต้การดูแลของครอบครัว โดยระบบต้นแบบความแม่นยำในการตรวจจับการหกล้มอยู่ที่ 95% และ 91.6% สำหรับความแม่นยำโดยรวมในการแยกแยะประเภทท่าทาง ส่วนการแยกแยะการเคลื่อนไหวที่ผิดปกติหรือการเคลื่อนไหวที่ไม่มั่นคงให้ความถูกต้องถึง 79.26% และมีความแม่นยำที่ 97.02%

การสำรวจการใช้งานในภาพรวมของระบบโดยรวมในมุมมองด้านการดูแลสุขภาพโดยนักกายภาพบำบัด แสดงให้เห็นว่าระบบได้รับการออกแบบให้ใช้งานง่ายและปลอดภัยสำหรับการใช้งานระบบในการเฝ้าดูแลผู้สูงอายุ และจะเป็นประโยชน์สำหรับบุคลากรทางการแพทย์ในอนาคตในการพัฒนาการปรับตัวเพื่อทำงานร่วมกับโปรแกรมกายภาพบำบัดระยะไกล เพื่อทำให้การเคลื่อนไหวและการทำงานในส่วนต่าง ๆ ของร่างกายผู้ป่วยดีขึ้น ระบบได้รับการออกแบบให้ทำงานได้อย่างมีประสิทธิภาพ ใช้งานได้ง่าย และมีราคาที่ไม่สูง การทดสอบแต่ละโมดูลและการทดสอบภาคสนามกับครอบครัวอาสาสมัครแสดงให้เห็นว่าระบบต้นแบบพร้อมสำหรับการนำไปใช้ประโยชน์เชิงพาณิชย์ในขั้นต่อไป

โครงการดูแลผู้สูงอายุ
ศ.ดร. แมททิว เนลสัน เดลีย์
สิงหาคม พ.ศ. 2564

ผู้สูงอายุส่วนใหญ่ชอบใช้ชีวิตอยู่ที่บ้านแต่การใช้ชีวิตอยู่ที่บ้านโดยไม่ได้รับความช่วยเหลือเต็มเวลาอาจมีความเสี่ยงเนื่องจากอาจหกล้มได้ หนึ่งในสามของผู้สูงอายุที่มีอายุมากกว่า 65 ปีเกิดการหกล้มในแต่ละปี ความช่วยเหลือที่ล่าช้าอาจนำไปสู่การบาดเจ็บสาหัส และทำให้สูญเสียความคล่องตัวและความอิสระในการเคลื่อนไหวส่วนต่าง ๆ ของร่างกายในภายหลัง การวิจัยและพัฒนาในปัจจุบันส่วนใหญ่ในการประมวลผลวิดีโอสำหรับการดูแลผู้สูงอายุมุ่งเน้นไปที่การตรวจจับการหกล้มและการตรวจจับและการบันทึกกิจกรรมของผู้สูงอายุในช่วงเวลาหนึ่ง ในทางกลับกัน การแจ้งเตือนพฤติกรรมผิดปกติแบบเรียลไทม์อาจช่วยคาดการณ์และป้องกันการเกิดอุบัติเหตุได้ดีกว่าการให้การช่วยเหลือที่รวดเร็วภายหลังการเกิดอุบัติเหตุ ในการวิจัยและพัฒนานี้ ทีมวิจัยนำเสนอต้นแบบอุปกรณ์ประมวลผลแบบ edge และกรอบการประมวลผลแบบคลาวด์ที่ช่วยให้สามารถจัดทำโปรไฟล์กิจกรรม การแจ้งเตือนการเคลื่อนไหวที่ไม่มั่นคง และการแจ้งเตือนการล้มสำหรับผู้สูงอายุที่อาศัยอยู่ที่บ้านภายใต้การดูแลของครอบครัว อุปกรณ์การประมวลผลแบบ edge ประกอบด้วยโมดูลการตรวจจับ การติดตามส่วนโมดูลระบบคลาวด์ และการจดจำบุคคล โมดูลระบบคลาวด์ประกอบด้วยการตรวจจับ จัดตำแหน่ง และรู้จำใบหน้าบุคคล โมดูลการแยกแยะประเภทกิจกรรมท่าทางใช้อัลกอริทึมที่ทีมวิจัยเสนอ อัลกอริทึมการแยกแยะท่าทางแบบที่ละเฟรมแบบลดหลั่น (cascade framewise activity classification) และ โมดูลการแยกแยะท่าทางการเคลื่อนไหวที่ไม่มั่นคงที่ทีมวิจัยเสนอ อัลกอริทึมการแยกแยะการเคลื่อนไหวที่ไม่มั่นคงที่ละหลายเฟรม โดยใช้เทคนิค Long short-term memory Recurrent Neural Network ทีมวิจัยได้เลือกท่าทาง นิ่ง ยืน เดิน เอนตัว/ก้มตัว เป็นประเภทท่าทางหลักเนื่องจากเป็นท่าทางที่พบบ่อยในการเคลื่อนไหวร่างกายในแต่ละวัน รวมทั้งปรบมือ ดุนาฬิกา คุยโทรศัพท์ ชี้ และ โบกมือ เป็นอีกกลุ่มประเภทท่าทางที่พบบ่อยในกิจกรรมสนทนาและการสื่อสารในแต่ละวัน ทีมวิจัยจึงรวบรวมข้อมูลท่าทางกิจกรรมทั้ง 10 ท่าทางจากแหล่งต่าง ๆ และเพิ่มตัวอย่างการจำลองการหกล้มและการเคลื่อนไหวที่ไม่มั่นคง ทีมวิจัยเทรนและทดสอบโมเดลด้วยชุดข้อมูลต่าง ๆ โดยระบบต้นแบบความแม่นยำในการตรวจจับการหกล้มอยู่ที่ 95% และ 91.6% สำหรับความแม่นยำโดยรวมในการแยกแยะประเภทท่าทาง ส่วนการแยกแยะการเคลื่อนไหวที่ผิดปกติหรือการเคลื่อนไหวที่ไม่มั่นคงให้ความถูกต้องถึง 79.26% และมีความแม่นยำที่ 97.02% ระบบได้รับการออกแบบให้ทำงานได้อย่างมีประสิทธิภาพ ใช้งานได้ง่าย และมีราคาที่ไม่สูง การทดสอบแต่ละโมดูลและการทดสอบภาคสนามกับครอบครัวอาสาสมัครแสดงให้เห็นว่าระบบต้นแบบพร้อมสำหรับการนำไปใช้ประโยชน์เชิงพาณิชย์ในขั้นต่อไป

Elder Care Project
Prof. Matthew Nelson Dailey
September 2021

Most elderly people prefer living at home but living at home without full time assistance can be risky due to the possibility of falls; one in three elderly individuals aged over 65 fall each year. Delayed assistance can lead to severe injuries and trigger further loss of mobility and independence. Most of the current research and development in video processing for elder care focuses on detecting falls and detecting and recording elderly peoples' activities over time. On the other hand, real time unusual behavior alerts may help predict and prevent accidents rather than speeding up a reaction after the fact. In this research and development, we introduce an edge processing device and cloud computation framework enabling activity profiling, unstable motion alerts, and fall alerts for elderly people living at home under their families' care. Edge modules include people detection and tracking. Cloud modules include face detection, face alignment using MTCNN, face recognition, activity classification using a new cascaded framewise activity classification module, and unstable movement analysis using a new LSTM-RNN-based unstable movement classification module. We have selected *sit*, *stand*, *walk*, and *bend* indicating daily mobility, as well as *clap*, *check the time*, *talk on the phone*, *point*, and *wave* indicating daily recreational and communication activities. We therefore collected examples of individuals performing these 10 activities from different sources, and we added examples of simulated *falls* and *unstable movement*. We trained and tested the models with various datasets. The activity classification of the prototype system achieves an accuracy of 95% for *fall* and 91.6% for overall accuracy. The stable/unstable motion classifier achieves an accuracy of 79.26% with a recall for unstable motion of 97.02%. The system is designed for accuracy, usability, and cost. Individual module tests and a field test with a volunteer household indicate that the prototype system is ready for the next stage of commercial exploitation.

สารบัญ

บทสรุปผู้บริหาร	ก
บทคัดย่อภาษาไทย	ข
บทคัดย่อภาษาอังกฤษ	ค
สารบัญตาราง	ช
สารบัญภาพ	ฉ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของโครงการ.....	1
1.2 วัตถุประสงค์และขอบเขตของโครงการ	2
1.2.1 วัตถุประสงค์.....	2
1.2.2 ขอบเขตของโครงการ	2
1.3 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.4 ผลผลิตสำคัญ.....	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	5
2.1 ทฤษฎีและแนวความคิด.....	5
2.2 ผลงานวิจัยที่เกี่ยวข้อง.....	8
บทที่ 3 ระเบียบวิธีวิจัย.....	12
3. วิธีการ/ขั้นตอนการดำเนินการวิจัยและพัฒนา	12
3.1 ภาพรวมของระบบ.....	12
3.2 ระบบตรวจจับ ตามรอย และรู้จำบุคคล	13
3.2.1 การตรวจจับและตามรอยบุคคล	13
3.2.2 การรู้จำใบหน้าบุคคล.....	17
3.2.3 การเก็บบันทึกข้อมูลของระบบ	19
3.3 ระบบแยกแยะท่าทางประเภทกิจกรรมต่าง ๆ รวมถึงการหกล้ม	21
3.3.1 การแยกแยะประเภทท่าทางแบบทีละเฟรม (Framework Activity Classification). 22	
3.3.1.a การตรวจจับการหกล้มแบบทีละเฟรม	24
3.3.2 การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่น (Cascade Framework Activity Classification).....	24
3.3.3 การแยกแยะประเภทท่าทางแบบทีละหลายเฟรม (LSTM Activity Classification) . 26	
3.3.3.a การตรวจจับการหกล้มโดยใช้เทคนิค LSTM โดยใช้ข้อมูลที่เป็นลำดับ	27
3.4 ระบบตรวจจับการเคลื่อนไหวที่ไม่มั่นคง	30
3.5 การเก็บรวบรวมชุดข้อมูลเพื่อใช้ในการเทรนโมเดล	31
3.5.1 ชุดข้อมูลผู้สูงอายุผู้เคยมีและไม่มีประวัติการหกล้ม (Mahidol Elder Dataset).....	31
3.5.2 ชุดข้อมูลการหกล้มของมหาวิทยาลัยมหิดล (Mahidol Fall Dataset).....	38
3.5.3 ชุดข้อมูล MOVI.....	42

3.5.4 ชุดข้อมูลมุกกล้อง 360 องศารอบตัวบุคคลในห้องทดลอง ณ สถาบันเทคโนโลยีแห่งเอเชีย (AIC-360)	46
3.5.5 ชุดข้อมูล 360 องศา บ้านอาสาสมัคร จ.กรุงเทพมหานคร ชุดที่ 1 (AIC-Volunteer1-Set1)	52
3.5.6 ชุดข้อมูล 360 องศา บ้านอาสาสมัคร จ.กรุงเทพมหานคร ชุดที่ 2 (AIC-Volunteer1-Set2)	55
3.5.7 ชุดข้อมูลเพิ่มเติมสำหรับเก็บข้อมูลและทดสอบ (AIC Initial Test Dataset)	56
3.6 การวิเคราะห์ข้อมูลดิบของการเคลื่อนที่ที่ไม่มั่นคงซึ่งอาจนำไปสู่การเคลื่อนที่ที่ผิดปกติหรือการหกล้ม	58
3.7 การวิเคราะห์ชุดข้อมูลผู้ที่มีและไม่มีประวัติการหกล้มโดยผู้เชี่ยวชาญด้านศัลยกรรมกระดูก และกายภาพบำบัด	61
3.7.1 รายงานสรุปผลการประมวลผลและแยกแยะประเภทการแสดงออกของบุคคลเป้าหมายจากแพทย์ผู้เชี่ยวชาญด้านศัลยกรรมกระดูกและกายภาพบำบัด	61
3.7.1.1 ผู้เข้าร่วมทดสอบ	61
3.7.1.2 กระบวนการทดสอบ	62
3.7.1.3 การประมวลผลข้อมูล	62
3.7.1.4 ผลจากการวัด	62
3.7.1.5 ผลลัพธ์	62
3.7.1.6 สรุปผล	68
3.8 ระบบประมวลผลส่วนหน้า (Edge processing unit)	69
3.9 ระบบส่วนหลัง (Backend system)	72
3.9.1 เซอร์วิสการประมวลผลภาพ (Video analytics services)	72
3.9.1.a รูปแบบข้อมูลสำหรับการประมวลผลบนเว็บเซอร์วิส	73
3.9.1.b ระบบรู้จำใบหน้าบุคคล	74
3.9.1.c ระบบแยกแยะประเภทท่าทาง และตรวจจับการหกล้ม	74
3.9.1.d ระบบตรวจจับการเคลื่อนไหวที่ไม่มั่นคง	75
3.9.2 เซอร์วิสการแจ้งเตือน (notification services)	75
3.10 โมดูลการสรุปข้อมูลกิจกรรม (ระบบเว็บแอปพลิเคชันดูแลผู้สูงอายุ)	76
3.10.1 ฐานข้อมูลของระบบ	76
3.10.2 หน้าแสดงสมาชิกครอบครัว	77
3.10.3 หน้าแสดงรายการกล้อง	77
3.10.4 หน้าสรุปข้อมูลกิจกรรม (ท่าทาง)	78
3.10.5 การตรวจจับกิจกรรมที่มีการทำซ้ำ	79
3.10.6 การตรวจจับบุคคลในกรณีที่ไม่อยู่ในอาณาบริเวณที่กำหนด	83
3.11 โมดูลการสร้างการแจ้งเตือน	83
3.12 RESTful Elder Care APIs	84
3.12.1 Activity Analysis APIs	85
3.12.1.a Activity Classification Service	85

3.12.1.b Unstable Movement Detection Service	86
3.12.1.c Face Recognition Service	86
3.12.1.d Activity Analysis API Specifications	86
3.12.2 Absence Detection APIs	88
3.12.2.a Absence Detection Service	88
3.12.2.b Absence Detection API Specifications	88
3.13 แผนการฝึกอบรมและรวบรวมข้อคิดเห็นจากผู้ใช้งานและเจ้าหน้าที่	91
3.14 การจดอนุพัทธ์บัตร	94
3.15 การตีพิมพ์บนวารสาร กสทช.	95
บทที่ 4 ผลการวิจัย และการวิจารณ์ผล	96
4.1 ผลการวิจัย และการวิจารณ์ผล	96
4.1.1 การแยกแยะประเภทท่าทาง และการหกล้ม (Activity Classification).....	96
4.1.1.1 การแยกแยะประเภทท่าทางแบบที่ละเฟรม (Frame-wise Activity Classification)	96
4.1.1.1.a การเทรนโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดล	96
4.1.1.2 การแยกแยะประเภทท่าทางแบบที่ละเฟรมแบบลดหลั่น Cascade Frame-wise Activity Classification.....	111
4.1.1.2.a การเทรนโมเดลสำหรับแยกแยะ 10 ท่าทาง บนชุดข้อมูล MoVi	111
4.1.1.3 การแยกแยะประเภทท่าทางแบบที่ละหลายเฟรม LSTM RNN Activity Classification	119
4.1.1.4 อัลกอริทึมสำหรับแยกแยะประเภทท่าทางในการใช้งานจริง	122
4.1.1.4.a โครงสร้างโมเดล.....	123
4.1.1.4.b การเทรนโมเดล	123
4.1.1.4.c โมเดลที่เทรนโดยใช้ชุดข้อมูล AIC-360.....	125
4.1.1.4.d โมเดลที่เทรนโดยใช้ชุดข้อมูล AIC-Volunteer1-set1.....	129
4.1.1.4.e โมเดลที่เทรนโดยใช้ชุดข้อมูลรวม AIC-360 และ AIC-Volunteer1-set1 และ MOVI.....	133
4.1.2 การตรวจจับการเคลื่อนไหวที่ไม่มั่นคง	148
4.1.2.1 การเทรนโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดล	148
4.1.2.2 อัลกอริทึมสำหรับตรวจจับการเคลื่อนไหวที่ไม่มั่นคงในการใช้งานจริง	150
4.1.2.2.a โครงสร้างโมเดล.....	150
4.1.2.2.b การเทรนโมเดล	151
4.1.2.2.c โมเดลที่เทรนโดยใช้ชุดข้อมูล AIC-360.....	152

4.1.2.2.d โมเดลที่เทรนโดยใช้ชุดข้อมูลรวมระหว่างชุดข้อมูล AIC-360 และ AIC-Voluntee1-set1	155
4.1.2.2.e ผลลัพธ์เชิงคุณภาพ	160
4.1.2.2.f การประเมินโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดล (Mahidol dataset).....	168
4.1.3 การตรวจจับบุคคลเมื่อไม่อยู่ในอาณาบริเวณที่กำหนด.....	175
4.1.4 การระบุตัวตน	176
4.1.5 เซอร์วิสการแจ้งเตือน Notification Service.....	178
4.1.6 ผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชัน Elder Care	179
4.1.7 การติดตั้งและใช้งานระบบ.....	187
4.1.7.1 การติดตั้งระบบ ณ บ้านอาสาสมัครหมายเลข 1 จังหวัดชัยนาท.....	187
4.1.7.2 การติดตั้งระบบ ณ บ้านอาสาสมัครหมายเลข 2 จังหวัดกรุงเทพมหานคร	190
4.1.8 ผลการเปรียบเทียบประสิทธิภาพระหว่างหน่วยประมวลผลส่วนหน้า และ คลาวด์	195
4.1.8.1 กระบวนการทดสอบ	195
4.1.8.2 สภาพแวดล้อมการทดสอบ	196
4.1.8.3 ผลการทดสอบ	198
4.1.9 ผลลัพธ์การประเมินผลการใช้งานระบบ	202
4.1.9.1 การประเมินโดยนักกายภาพบำบัดจากมหาวิทยาลัยมหิดล.....	202
4.1.9.2 การประเมินผลโดยกลุ่มตัวแทนจากบ้านอาสาสมัครผู้ติดตั้งระบบ และ ผู้ที่สนใจระบบ	202
4.1.9.3 สรุปการประเมินผลการใช้งานระบบ	207
4.1.10 สรุปผลความแม่นยำของระบบ	208
4.1.11 ประโยชน์จากการใช้งานจริง.....	208
4.1.12 รายงานสรุปผลในส่วนเป้าหมายที่อาจไม่สามารถบรรลุผลตามที่วางแผนไว้.....	210
4.1.13 ข้อจำกัดของระบบทั้งด้านฮาร์ดแวร์และซอฟต์แวร์.....	215
4.1.13.1 ข้อจำกัดทางด้านฮาร์ดแวร์.....	215
4.1.13.2 ข้อจำกัดทางด้านซอฟต์แวร์	215
บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ.....	216
5.1 สรุปผลการวิจัย.....	216
5.2 ข้อเสนอแนะและแนวทางในการพัฒนาต่อระบบในอนาคต	218
5.2.1 การลดต้นทุนในการนำเทคโนโลยีระบบดูแลผู้สูงอายุไปใช้งานจริง.....	218
5.2.2 การพัฒนาต่อยอดในอนาคต.....	219
5.2.3 ความร่วมมือกับภาคอุตสาหกรรมเพื่อสร้างระบบที่มีประสิทธิภาพและราคาไม่สูง	220
5.2.4 การปรับปรุงระบบให้ทำงานได้แม่นยำมากขึ้น	220
บรรณานุกรม.....	221

ภาคผนวก

ภาคผนวก ก รายงานการจัดซื้อครุภัณฑ์ในโครงการ

ประวัติผู้วิจัย

สารบัญตาราง

ตารางที่ 1	เวอร์ชันของระบบประมวลผลภาพที่ทำงานบนอุปกรณ์ประมวลผลส่วนหน้า และเวอร์ชันของ APIs ที่ทำงานบนระบบคลาวด์ Elder Care	16
ตารางที่ 2	ภาพรวมของชุดข้อมูลทั้งหมดที่ใช้ในการออกแบบและพัฒนาระบบ	31
ตารางที่ 3	ตำแหน่งการติดมาร์กเกอร์ทั้ง 41 มาร์กเกอร์	32
ตารางที่ 4	รายละเอียดข้อมูลของอาสาสมัครผู้สูงอายุ	33
ตารางที่ 5	ตัวอย่างข้อมูลท่าทางเพิ่มเติมที่ทีมวิจัยเลือกใช้จากชุดข้อมูล MoVi	43
ตารางที่ 6	ตัวอย่างข้อมูลท่าทางที่ตรงกับประเภทท่าทางเดิมที่ทีมวิจัยเลือกใช้จากชุดข้อมูล MoVi.	44
ตารางที่ 7	รายละเอียดการเก็บข้อมูลท่าทางในห้องทดลอง	46
ตารางที่ 8	รายละเอียดการติดตั้งกล้องและเก็บข้อมูลในแต่ละบ้าน	56
ตารางที่ 9	ข้อมูลที่เกี่ยวข้องกับสถิติประชากรของผู้เข้าร่วมทดสอบ	63
ตารางที่ 10	ข้อมูลท่าทางการเดินแบบผ่อนคลาย	64
ตารางที่ 11	ข้อมูลท่าทางการเดินเร็ว	65
ตารางที่ 12	ข้อมูลท่าทางระหว่างก้าวข้ามสิ่งกีดขวาง	66
ตารางที่ 13	ข้อมูลท่าทางการเดินและหยุดไปด้วย	67
ตารางที่ 14	ข้อมูลท่าทางการเดินและเลี้ยว	68
ตารางที่ 15	RESTful Elder Care APIs version	84
ตารางที่ 16	คำถามสำหรับการประเมินการใช้งานระบบดูแลผู้สูงอายุ	93
ตารางที่ 17	ตารางแสดงตัวอย่างภาพของท่าทางทั้ง 4 ประเภท จากมุมมองที่แตกต่างกัน 4 มุมกล้อง	97
ตารางที่ 18	Confusion matrix ของผลการทดสอบ pre classifier บนชุดข้อมูลทดสอบ	113
ตารางที่ 19	Confusion matrix ของผลการทดสอบ post classifier สำหรับแยกแยะท่าทางขณะนั่งบนชุดข้อมูลทดสอบ	115
ตารางที่ 20	Confusion matrix ของผลการทดสอบ post classifier สำหรับแยกแยะท่าทางขณะยืนบนชุดข้อมูลทดสอบ	116
ตารางที่ 21	Confusion matrix ของผลการทดสอบ post classifier สำหรับแยกแยะท่าทางขณะเดินบนชุดข้อมูลทดสอบ	117
ตารางที่ 22	รายละเอียดจำนวนภาพที่ใช้ในการเทรนโมเดล LSTM RNN สำหรับการแยกแยะประเภทท่าทาง	119
ตารางที่ 23	จำนวนรูปภาพที่มีในแต่ละท่าทางของชุดข้อมูล AIC-360	125
ตารางที่ 24	จำนวนภาพที่ถูกใช้ในการเทรน และความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-360	125
ตารางที่ 25	ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-360	126
ตารางที่ 26	ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1	127

ตารางที่ 27 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1.....	128
ตารางที่ 28 ตัวอย่างท่าทางต่าง ๆ จากมุมมองกล้องในชุดข้อมูล AIC-Volunteer1-set1.....	129
ตารางที่ 29 จำนวนภาพที่ถูกใช้ในการเทรน และความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1.....	129
ตารางที่ 30 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1.....	130
ตารางที่ 31 จำนวนรูปภาพที่มีในแต่ละท่าทางของชุดข้อมูล AIC-Volunteer1-set2.....	131
ตารางที่ 32 ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set2	132
ตารางที่ 33 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set2.....	133
ตารางที่ 34 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC 360 + AIC-Volunteer1-set1.....	134
ตารางที่ 35 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-360 + AIC-Volunteer1-set1 + MoVi.....	136
ตารางที่ 36 ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-360 และ AIC-Volunteer1-set1	137
ตารางที่ 37 ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-360 และ AIC-Volunteer1-set1 และ MoVi.....	137
ตารางที่ 38 จำนวนวิดีโอของแต่ละท่าทางในชุดข้อมูล AIC-Volunteer1-set2.....	139
ตารางที่ 39 ความแม่นยำของโมเดลที่เทรนโดยใช้ชุดข้อมูลรวม 2 ชุดข้อมูล โดยทดสอบบนชุดข้อมูล AIC-Volunteer1-set2	141
ตารางที่ 40 ความแม่นยำของโมเดลที่เทรนโดยใช้ชุดข้อมูลรวม 3 ชุดข้อมูล โดยทดสอบบนชุดข้อมูล AIC-Volunteer1-set2	142
ตารางที่ 41 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางโดยใช้โมเดลที่เทรนโดยชุดข้อมูลรวม 3 ชุดข้อมูล (AIC-360, AIC-Volunteer1-set1 และ MoVi) ในตำแหน่งต่าง ๆ ของมุมมอง.....	143
ตารางที่ 42 รายละเอียดของกลุ่มชุดข้อมูลมหาวิทยาลัยมหิดลที่ใช้ในการเทรนโมเดล.....	148
ตารางที่ 43 ตัวอย่างข้อมูลที่สามารถแยกประเภทได้อย่างถูกต้องบนชุดข้อมูลการเคลื่อนไหวที่ไม่มั่นคงที่ใช้ในการประเมินความแม่นยำของโมเดล.....	160
ตารางที่ 44 ตัวอย่างการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงผิดพลาดจากกิจกรรมอื่น	162
ตารางที่ 45 การแยกแยะการเคลื่อนไหวที่ไม่มั่นคงเป็นการเคลื่อนไหวที่มั่นคง	163
ตารางที่ 46 ตัวอย่างประเภทท่าทางขณะถือสิ่งของ.....	164
ตารางที่ 47 ตัวอย่างการเคลื่อนไหวในท่าทางปกติทั่วไปที่โมเดลแยกประเภทเป็นการเคลื่อนไหวที่มั่นคง	166
ตารางที่ 48 confusion matrix ของการรู้จำใบหน้าบุคคล 5 คน	177
ตารางที่ 49 แสดงมุมมองทั้ง 8 ตัวในบ้านของอาสาสมัครในจ.กรุงเทพมหานคร	192

ตารางที่ 50 ผลการทดสอบการใช้งานทรัพยากรในการประมวลผล (ประมวลผล OpenPose อย่างเดียว).....	198
ตารางที่ 51 อัตราการประมวลผลภาพผ่านการเชื่อมต่อเครือข่ายที่แตกต่างกัน (ประมวลผล OpenPose อย่างเดียว).....	199
ตารางที่ 52 ผลการทดสอบการใช้งานทรัพยากรในการประมวลผล (ประมวลผลกับซอฟต์แวร์ Elder Care v.0.1).....	200
ตารางที่ 53 อัตราการประมวลผลภาพผ่านการเชื่อมต่อเครือข่ายที่แตกต่างกัน (ประมวลผลกับซอฟต์แวร์ Elder Care v0.1).....	201
ตารางที่ 54 ความแม่นยำของระบบเทียบกับเป้าหมาย.....	208
ตารางที่ 55 สถานะการดำเนินการกิจกรรมที่สำคัญ	210

สารบัญญภาพ

รูปที่ 1 แนวคิดการใช้ระบบเฝ้าดูผู้สูงอายุโดยใช้กล้องวิดีโอ รูปจาก Lee และคณะ (2003) [36].....	7
รูปที่ 2 แนวคิดของการใช้กล้องที่เก็บข้อมูลความลึกของวัตถุได้ในระบบเฝ้าดูผู้สูงอายุ รูปจาก Stone และคณะ (2011) [40].....	8
รูปที่ 3 แนวคิดการใช้ระบบรู้จำท่าทางของมนุษย์ รูปจาก Natarajan และคณะ (2008) [45]	9
รูปที่ 4 แนวคิดระบบการรู้จำท่าทางของมนุษย์โดยใช้ชุดข้อมูล MSR-Action3D รูปจาก Wang และคณะ (2012) [49]	10
รูปที่ 5 ภาพรวมของระบบ	12
รูปที่ 6 ตัวอย่างการตรวจจับบุคคลโดยใช้โมเดลการเรียนรู้เชิงลึก	13
รูปที่ 7 ตัวอย่างการตรวจจับและตามรอยใบหน้าและวิเคราะห์เพศอายุ	14
รูปที่ 8 ตัวอย่างของการดึงข้อมูลตำแหน่งจุดโครงร่างของร่างกาย	16
รูปที่ 9 ตัวอย่างการประมาณค่าตำแหน่งกรอบสี่เหลี่ยมจากจุดโครงร่างของร่างกายที่ใช้ในการตามรอย	16
รูปที่ 10 ตัวอย่างการรู้จำใบหน้าโดยใช้ซอฟต์แวร์ที่ทีมวิจัย AIT มีอยู่แล้ว	17
รูปที่ 11 จุดสีแดงแสดงตัวอย่างตำแหน่ง ตา หู และจมูก (ขวา) ซึ่งถูกนำมาพิจารณาในการเลือกเฟรม (ซ้าย) เพื่อใช้ในการรู้จำใบหน้า	18
รูปที่ 12 รูปภาพข้อมูลนำเข้าสู่ระบบรู้จำใบหน้า (ซ้าย) ที่ได้มาระหว่างการตามรอย และภาพใบหน้าที่ตรวจจับและจัดตำแหน่งได้ (ขวา).....	19
รูปที่ 13 ตัวอย่างข้อมูลที่ถูกบันทึกจากการตามรอยบุคคล	19
รูปที่ 14 ตัวอย่างข้อมูลภาพที่ถูกบันทึกในโฟลเดอร์	20
รูปที่ 15 ตัวอย่างภาพเฟรมเมื่อเริ่ม (ซ้าย) และสิ้นสุด (ขวา) การตามรอยบุคคล.....	20
รูปที่ 16 เปรียบเทียบขั้นตอนการทำงานระหว่างการทำงานแบบโพรเซสเดียว และการทำงานแบบแบ่งการประมวลผลร่วมกับระบบเว็บเซอร์วิสบนคลาวด์	21
รูปที่ 17 ขั้นตอนการทำงานของการแยกแยะประเภทท่าทางแบบที่ละเฟรม	23
รูปที่ 18 ตัวอย่างของเฟรมที่ต่อเนื่องกันซึ่งโครงร่างของร่างกายเห็นแค่เพียงบางส่วน.....	25
รูปที่ 19 ขั้นตอนการทำงานของการแยกแยะท่าทางแบบที่ละเฟรมแบบลดหลั่น	26
รูปที่ 20 กระบวนการเทรนและทดสอบโมเดล LSTM สำหรับการแยกแยะประเภทท่าทาง.....	27
รูปที่ 21 ขั้นตอนการทำงานในการเทรนโมเดล LSTM (ซ้าย) และขั้นตอนการทำงานในการทดสอบโมเดล LSTM (ขวา).....	29
รูปที่ 22 โครงสร้างเนกเวิร์ค LSTM RNN สำหรับการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง	30
รูปที่ 23 ตัวอย่างการติดมาร์กเกอร์ลงบนร่างกาย	34
รูปที่ 24 รายละเอียดตำแหน่งที่ติดมาร์กเกอร์ลงบนร่างกาย	34
รูปที่ 25 แสดงตำแหน่งและระยะห่าง ความสูง ในการติดตั้งกล้อง IP เพื่อเก็บข้อมูล.....	35
รูปที่ 26 ตัวอย่างมุมมองที่ทีมวิจัยใช้ในการบันทึกข้อมูลวิดีโอทั้ง 4 กล้อง	35
รูปที่ 27 การติดตั้งกล้องจริง ณ ห้องที่ใช้ในการเก็บบันทึกข้อมูล ณ มหาวิทยาลัยมหิดล	36

รูปที่ 28 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางนั่งแล้วยืน	36
รูปที่ 29 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางเดินช้า.....	36
รูปที่ 30 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางเดินขณะพูด	37
รูปที่ 31 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางการก้าวข้ามสิ่งกีดขวาง	37
รูปที่ 32 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางเดินเลี้ยวกลับ.....	37
รูปที่ 33 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางเดินเร็ว.....	37
รูปที่ 34 ตัวอย่างการล้มจากการนั่งไปด้านหลัง	38
รูปที่ 35 ตัวอย่างการล้มจากการนั่งไปด้านขวา.....	38
รูปที่ 36 ตัวอย่างการล้มจากการนั่งไปด้านซ้าย	39
รูปที่ 37 ตัวอย่างการล้มจากการนั่งไปด้านหน้า.....	39
รูปที่ 38 ตัวอย่างการล้มจากการเดิน	40
รูปที่ 39 ตัวอย่างการล้มไปด้านข้าง.....	40
รูปที่ 40 ตัวอย่างเฟรมที่มีการตรวจพบจุดโครงร่างของร่างกายที่สำคัญ เช่น คอ หัวเข่า ข้อศอก ทรบ	41
รูปที่ 41 ตัวอย่างเฟรมที่มีจุดโครงร่างของร่างกายที่สำคัญ เช่น คอ หัวเข่า ข้อศอก ไม่สามารถ มองเห็นได้.....	41
รูปที่ 42 รูปแบบมุกกล้องที่ใช้บันทึกชุดข้อมูล MoVi (สำเนาจาก Ghorbani และคณะ, 2020)	42
รูปที่ 43 การติดตั้งกล้องเพื่อเก็บข้อมูลในห้องทดลองให้ครอบคลุมมุกกล้อง 360 องศารอบตัวบุคคล	47
รูปที่ 44 ตำแหน่งการยืนของอาสาสมัครเพื่อเก็บข้อมูลประเภทท่าทางต่าง ๆ	48
รูปที่ 45 การติดตั้งกล้องทั้ง 8 ตัวในห้องทดลอง ณ สถาบันเทคโนโลยีแห่งเอเชีย รูป (ก) และ (ข) แสดงการติดตั้งกล้องด้านกว้างของห้องทดลอง รูป (ค) และ (ง) แสดงการติดตั้งกล้องด้านยาวของ ห้องทดลองในมุมมองแบบพาโนรามา.....	49
รูปที่ 46 ตัวอย่างภาพจากมุกกล้อง 3 กล้อง ณ เวลาเดียวกัน.....	50
รูปที่ 47 การเก็บข้อมูลการจำลองการล้มในรูปแบบต่าง ๆ โดยอาสาสมัคร	50
รูปที่ 48 ตัวอย่างการจำลองการเคลื่อนไหวแบบไม่มั่นคงโดยอาสาสมัคร.....	51
รูปที่ 49 ตำแหน่งการติดตั้งกล้อง 8 กล้อง ณ บ้านอาสาสมัคร.....	52
รูปที่ 50 การติดตั้งกล้อง ณ บ้านอาสาสมัคร	53
รูปที่ 51 ตัวอย่างข้อมูลการทำท่าทางต่าง ๆ จากบ้านอาสาสมัครที่มิวิจัยติดตั้งระบบ	53
รูปที่ 52 ภาพตัวอย่างจาก 3 มุกกล้องจากทั้งหมด 8 กล้อง ณ เวลาเดียวกันขณะอาสาสมัครจำลอง การล้มประเภทต่าง ๆ.....	54
รูปที่ 53 ตัวอย่างลำดับเฟรมที่ต่อเนื่องกันของการเคลื่อนไหวที่ไม่มั่นคง	55
รูปที่ 54 แสดงตำแหน่งของมาร์กเกอร์ (จุดสีแดง) ที่แปลงตำแหน่งจากปริภูมิสามมิติ.....	58
รูปที่ 55 ตัวอย่างของโครงร่างของร่างกายที่ได้จากไลบรารี OpenPose บนภาพเฟรมเดียวกัน.....	58
รูปที่ 56 ตัวอย่างข้อมูลดิบจาก VICON โดยแสดงข้อมูลของมาร์กเกอร์ในปริภูมิสามมิติของมาร์กเกอร์ ที่ติดบนร่างกายแต่ละส่วน	59

รูปที่ 57 ตัวอย่างข้อมูลจากมาร์กเกอร์ที่ติดช่วงต้นขาซ้าย (a) และกราฟแสดงการเปลี่ยนแปลงของข้อมูลในแต่ละช่วงเวลา ในการเดินซ้ารอบที่ 1 (b) และเดินซ้ารอบที่ 6 (c).....	60
รูปที่ 58 ระบบต้นแบบเฝ้าคิววิดีโอแบบ IoT สำหรับดูแลผู้สูงอายุ.....	69
รูปที่ 59 การเปรียบเทียบระหว่างระบบต้นแบบเวอร์ชันที่ 1 (ซ้าย) และระบบต้นแบบเวอร์ชันที่ 2 (ขวา).....	70
รูปที่ 60 สถาปัตยกรรมระบบคลาวด์ Elder Care.....	72
รูปที่ 61 ฐานข้อมูลของระบบ Elder Care	76
รูปที่ 62 ตัวอย่างข้อมูลหน้าแสดงสมาชิกในครอบครัว.....	77
รูปที่ 63 ตัวอย่างรายการกล้องที่ใช้ในระบบ	77
รูปที่ 64 ตัวอย่างการแสดงผลของการสรุปข้อมูลกิจกรรมที่ตรวจพบในสองมุกกล้องตามช่วงเวลา ที่ตรวจพบ.....	78
รูปที่ 65 ตัวอย่างการแสดงผลการสรุปข้อมูลกิจกรรมที่ตรวจพบ	79
รูปที่ 66 ตัวอย่างของข้อมูลจำลองของกิจกรรมที่มีการทำซ้ำในแต่ละวันในแต่ละช่วงเวลา	80
รูปที่ 67 ตัวอย่างการแสดงผลกิจกรรมที่ตรวจพบรายชั่วโมง	81
รูปที่ 68 ตัวอย่างการแสดงผลกิจกรรมที่ตรวจพบรายวัน.....	81
รูปที่ 69 ตัวอย่างการแสดงผลรายชื่อกิจกรรมที่ถูกตั้งค่าช่วงเวลาที่มีการอยู่อาศัย.....	82
รูปที่ 70 ตัวอย่างการแสดงผลการตั้งค่าช่วงเวลาที่มีการอยู่อาศัย (Active period) ของมุกกล้องหนึ่ง กล้อง.....	82
รูปที่ 71 การฝึกอบรมให้แก่ทีมผู้เชี่ยวชาญจากคณะกายภาพบำบัด มหาวิทยาลัยมหิดล	92
รูปที่ 72 การฝึกอบรมให้แก่ตัวแทนจากบ้านอาสาสมัครผู้ติดตั้งใช้งานระบบและผู้สนใจใช้งานระบบ	92
รูปที่ 73 แผนภูมิแสดงค่า training และ validation accuracy และ training และ validation loss ของการเทรนโมเดลสำหรับแยกแยะประเภทกิจกรรม 4 ประเภท ยืน เดิน เอนตัว และหกล้ม	99
รูปที่ 74 ผลการแยกแยะประเภทกิจกรรม (ท่าทาง) บนชุดข้อมูลทดสอบ (unseen dataset).....	100
รูปที่ 75 ผลการแยกแยะประเภทกิจกรรม (ท่าทาง) บนชุดข้อมูลทดสอบ (unseen dataset).....	100
รูปที่ 76 แผนภูมิแสดงค่า training และ validation accuracy และ training และ validation loss ของการเทรนโมเดลสำหรับแยกแยะประเภทกิจกรรม 5 ประเภท นั่ง ยืน เดิน เอนตัว และหกล้ม. 101	101
รูปที่ 77 เปรียบเทียบโมเดลที่ใช้การคำนวณค่าพิกัดจุดของโครงร่างของร่างกายในรูปแบบที่แตกต่าง กัน.....	102
รูปที่ 78 รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูล validation บนข้อมูลจากกล้องที่ 1.....	103
รูปที่ 79 แสดงการเปรียบเทียบการใช้ PAF ที่แตกต่างกัน มีผลต่อการแยกแยะประเภทท่าทาง	104
รูปที่ 80 รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูล validation บนข้อมูลจากกล้องที่ 3.....	105
รูปที่ 81 เปรียบเทียบความแม่นยำในการแยกแยะประเภทท่าทางเมื่อกำหนดค่า PAF ที่แตกต่างกัน	105

รูปที่ 82 รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูล validation บนข้อมูลจากกล้องที่ 2.....	106
รูปที่ 83 Confusion matrix ของชุดข้อมูล validation เมื่อใช้ข้อมูลจากกล้องที่ 1 และ 3 ในการ เทรนโมเดล	107
รูปที่ 84 Confusion matrix ของชุดข้อมูล validation เมื่อใช้ข้อมูลจากกล้องที่ 1 2 และ 3 ในการ เทรนโมเดล.....	107
รูปที่ 85 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจาก กล้องที่ 1 (seen data)	108
รูปที่ 86 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจาก กล้องที่ 2 (seen data)	108
รูปที่ 87 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจาก กล้องที่ 3 (seen data)	109
รูปที่ 88 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจาก กล้องที่ 4 (unseen data)	109
รูปที่ 89 ตัวอย่างผลการแยกแยะประเภทท่าทางผิดพลาด (ID-7 และ ID-3 ในรูปซ้าย และ ID-15 ใน รูปขวา) จากข้อมูลวิดีโอจากกล้องที่ติดตั้งในสถาบันเทคโนโลยีแห่งเอเชีย.....	110
รูปที่ 90 ตัวอย่างผลการแยกแยะประเภทท่าทางผิดพลาด (บุคคลที่ยืนไกลสุดในรูปซ้าย และ ID-15 และ ID-2 ในรูปขวา) จากข้อมูลวิดีโอจากกล้องที่ติดตั้งในสถาบันเทคโนโลยีแห่งเอเชีย	110
รูปที่ 91 แสดงความแม่นยำระหว่างการเทรนของ pre classifier กับข้อมูล 5 ท่าทาง (ขวา) ซึ่งให้ ความแม่นยำสูงกว่า classifier แบบ 10 ท่าทาง (ซ้าย).....	111
รูปที่ 92 โครงสร้างโมเดล pre classifier	112
รูปที่ 93 โครงสร้างโมเดล post classifier	114
รูปที่ 94 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทาง Activity-1 และ Activity-2 บนชุดข้อมูล MoVi	118
รูปที่ 95 ผลลัพธ์การแยกแยะประเภทท่าทางโดยใช้โมเดล pre classifier และ post classifier...	119
รูปที่ 96 รายละเอียดโครงสร้างเน็ตเวิร์ก LSTM RNN สำหรับแยกแยะประเภทท่าทาง	120
รูปที่ 97 รายละเอียดในการเทรนโมเดล LSTM RNN สำหรับแยกแยะประเภทท่าทาง	121
รูปที่ 98 ผลลัพธ์การแยกแยะประเภทท่าทางบนชุดข้อมูลที่ไม่เคยเห็นมาก่อน.....	121
รูปที่ 99 Confusion matrix บนชุดข้อมูลทดสอบ	122
รูปที่ 100 ตัวอย่างการตรวจจับการจำลองการหกล้มโดยใช้โมเดล LSTM RNN.....	122
รูปที่ 101 โครงสร้างโมเดล preclass	124
รูปที่ 102 โครงสร้างโมเดล postclass	124
รูปที่ 103 ตัวอย่างการแยกแยะท่าทางผิดพลาด	138
รูปที่ 104 แสดงตำแหน่งของการเคลื่อนไหวระหว่างการก้าวเดิน	139
รูปที่ 105 แสดงตัวอย่างท่าทางการหกล้มที่มีท่าทางการเอนตัว/ก้มตัวก่อนจะล้ม	140
รูปที่ 106 ความแม่นยำขณะเทรนโมเดลบนชุดข้อมูล validation.....	149

รูปที่ 107 Confusion matrix ของโมเดลบนชุดข้อมูลทดสอบ.....	149
รูปที่ 108 ผลลัพธ์การตรวจจับการเคลื่อนไหวที่ไม่มั่นคง	150
รูปที่ 109 ผลลัพธ์การแยกแยะตัวอย่างการเคลื่อนไหวที่มั่นคง	150
รูปที่ 110 โครงสร้างของโมเดล.....	151
รูปที่ 111 โครงสร้างโพลเดอร์ของวิดีโอที่ใช้ในการเทรนของแต่ละบุคคล.....	152
รูปที่ 112 การกระจายตัวของข้อมูลระหว่างจำนวนข้อมูล (a) และชุดเฟรมที่ต่อเนื่องกัน (b) ที่ใช้สำหรับ train, validation และ test ของชุดข้อมูล AIC-360.....	153
รูปที่ 113 ผลการเทรนและทดสอบโมเดล AIC บนชุดข้อมูล train และ test (a) ความแม่นยำของโมเดลบนชุดข้อมูล train และ validation (b) training และ validation loss ของโมเดล (c) confusion matrix ของโมเดลบนชุดข้อมูล test (d) normalized confusion matrix ของโมเดลบนชุดข้อมูล test	154
รูปที่ 114 ประสิทธิภาพของโมเดลที่ทดสอบบนชุดข้อมูล AIC-Volunteer1-set1.....	155
รูปที่ 115 ผลลัพธ์ของโมเดล AIC ที่ทดสอบบนชุดข้อมูล AIC-Volunteer1-set2 (a) confusion matrix (b) normalized confusion matrix.....	156
รูปที่ 116 การกระจายตัวของข้อมูลระหว่างจำนวนข้อมูล (a) และชุดเฟรมที่ต่อเนื่องกัน (b) ที่ใช้สำหรับ train, validation และ test บนชุดข้อมูลรวมระหว่าง AIC-360 และ AIC-Volunteer1-set1	157
รูปที่ 117 โครงสร้างของโมเดล Model-AIC-Site1	158
รูปที่ 118 ผลการเทรนและทดสอบโมเดล Model-AIC-Site1 บนชุดข้อมูล train และ test (a) ความแม่นยำของโมเดลบนชุดข้อมูล train และ validation (b) training และ validation loss ของโมเดล (c) confusion matrix ของโมเดลบนชุดข้อมูล test (d) normalized confusion matrix ของโมเดลบนชุดข้อมูล test	159
รูปที่ 119 ผลลัพธ์ของโมเดล Model-AIC-Site1 ที่ทดสอบบนชุดข้อมูล AIC-Volunteer1-set2 (a) confusion matrix (b) normalized confusion matrix.....	160
รูปที่ 120: การเดินของสมาชิกในครอบครัวขณะมีการทำความสะอาดพื้นบ้าน.....	165
รูปที่ 121 ทำทางการเดินและเลี้ยวกลับในชุดข้อมูลมหาวิทยาลัยมหิดล	169
รูปที่ 122 ทำทางการเดินข้ามสิ่งกีดขวางในชุดข้อมูลมหาวิทยาลัยมหิดล.....	169
รูปที่ 123 จำนวนไฟล์ที่ใช้ในการทดสอบในแต่ละมุกกล้อง.....	170
รูปที่ 124 จำนวนเฟรมเซตที่ใช้ในการทดสอบในแต่ละมุกกล้อง	170
รูปที่ 125 การกระจายความถี่ตามความน่าจะเป็นของการแยกแยะของโมเดล Model-AIC-Site1 บนชุดข้อมูลทดสอบมหาวิทยาลัยมหิดล ตัวเลข (a) - (d) แสดงการกระจายความน่าจะเป็นในการแยกแยะและจำนวนชุดทดสอบ ตัวเลข (e) - (h) แสดงการกระจายฟังก์ชันความหนาแน่นของความน่าจะเป็น (PDF) บนชุดข้อมูลทดสอบโดยใช้เคอร์เนลแบบเกาส์เซียนบนชุดข้อมูล	172
รูปที่ 126 การกระจายความถี่ตามความน่าจะเป็นของการแยกแยะของโมเดลใหม่ที่เทรนบนชุดข้อมูลมหาวิทยาลัยมหิดล และ ทดสอบบนชุดข้อมูลมหาวิทยาลัยมหิดล ตัวเลข (a) - (d) แสดงการกระจายความน่าจะเป็นในการแยกแยะและจำนวนชุดทดสอบ ตัวเลข (e) - (h) แสดงการกระจายฟังก์ชัน	

ความหนาแน่นของความน่าจะเป็น (PDF) บนชุดข้อมูลทดสอบโดยใช้เคอร์เนลแบบเกาส์เขียนบนชุดข้อมูล	174
รูปที่ 127 ตัวอย่างการตรวจจับบุคคลเมื่อไม่อยู่ในอาณาบริเวณที่กำหนดบนเว็บแอปพลิเคชัน Elder Care	175
รูปที่ 128 ตัวอย่างข้อความแจ้งเตือน (ซ้าย) และรูปการแจ้งเตือน (ขวา).....	176
รูปที่ 129 ตัวอย่างภาพต้นฉบับที่ใช้ในการเปรียบเทียบรูจำใบหน้าบุคคล	176
รูปที่ 130 ตัวอย่างภาพข้อมูลนำเข้าของเซอร์วิสรูจำใบหน้าบุคคล (ซ้าย) และภาพตัดเฉพาะส่วนของใบหน้า (ขวา).....	177
รูปที่ 131 ตัวอย่างการส่งข้อความแจ้งเตือนเมื่อระบบตรวจพบการหล่ม	178
รูปที่ 132 ตัวอย่างการส่งข้อความแจ้งเตือนเมื่อระบบตรวจพบการเคลื่อนไหวที่ไม่มั่นคง	178
รูปที่ 133 ตัวอย่างการส่งข้อความแจ้งเตือนเมื่อระบบไม่ตรวจพบการเคลื่อนไหวใด ๆ ในช่วงเวลาอยู่อาศัย.....	179
รูปที่ 134 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชันจากบ้านอาสาสมัคร จ. กรุงเทพมหานคร	180
รูปที่ 135 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชันจากบ้านอาสาสมัคร จ. ชัยนาท	181
รูปที่ 136 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชันจากบ้านอาสาสมัคร จ. กรุงเทพมหานคร บนชุดข้อมูล AIC-Volunteer1-set2	182
รูปที่ 137 ตัวอย่างรูปที่เป็นตัวแทนรูปของการตามรอยบุคคลที่ใช้แสดงบนเว็บแอปพลิเคชัน	182
รูปที่ 138 ตัวอย่างผลลัพธ์การตรวจจับการจำลองการล้ม ณ บ้านอาสาสมัคร ใน จ.กรุงเทพมหานคร บนชุดข้อมูล AIC-Volunteer1-set2 ที่ตรวจจับได้แสดงบนเว็บแอปพลิเคชัน	183
รูปที่ 139 ตัวอย่างรูปที่เป็นตัวแทนรูปของการตามรอยบุคคลของแต่ละการจำลองการล้ม ที่ใช้แสดงบนเว็บแอปพลิเคชัน.....	183
รูปที่ 140 ตัวอย่างข้อความการแจ้งเตือนเมื่อระบบสามารถตรวจจับการหล่มดังกล่าวบนเว็บแอปพลิเคชัน LINE.....	184
รูปที่ 141 ตัวอย่างข้อมูลการแจ้งเตือนการตรวจจับการหล่มดังกล่าวบนเว็บแอปพลิเคชัน	184
รูปที่ 142 ตัวอย่างผลลัพธ์การตรวจจับการจำลองการเคลื่อนไหวที่ไม่มั่นคง ณ บ้านอาสาสมัคร ใน จ. กรุงเทพมหานคร บนชุดข้อมูล AIC-Volunteer1-set2 ที่ตรวจจับได้แสดงบนเว็บแอปพลิเคชัน	185
รูปที่ 143 ตัวอย่างรูปที่เป็นตัวแทนรูปของการตามรอยบุคคลของแต่ละการจำลองการเคลื่อนไหว ที่ไม่มั่นคง ที่ใช้แสดงบนเว็บแอปพลิเคชัน	185
รูปที่ 144 ตัวอย่างข้อความการแจ้งเตือนเมื่อระบบสามารถตรวจจับการเคลื่อนไหวที่ไม่มั่นคงดังกล่าวบนเว็บแอปพลิเคชัน LINE	186
รูปที่ 145 ตัวอย่างข้อมูลการแจ้งเตือนการตรวจจับการหล่มดังกล่าวบนเว็บแอปพลิเคชัน	186
รูปที่ 146 แผนผังแสดงการติดตั้งอุปกรณ์ ณ บ้านอาสาสมัคร	187
รูปที่ 147 อุปกรณ์ที่ติดตั้ง ณ บ้านอาสาสมัครหมายเลข 1 ในจังหวัดชัยนาท	188
รูปที่ 148 ลักษณะการติดตั้งกล่อง IP ทั้ง 4 ตัว	189

รูปที่ 149 ตำแหน่งการติดตั้งกล้องแต่ละตัว	189
รูปที่ 150 ภาพมุมกล้องทั้ง 4 ตัว.....	190
รูปที่ 151 อุปกรณ์ที่ติดตั้ง ณ บ้านอาสาสมัครหมายเลข 2 ในจังหวัดกรุงเทพมหานคร	190
รูปที่ 152 ลักษณะการติดตั้งกล้อง IP ทั้ง 8 ตัว	191
รูปที่ 153 ตำแหน่งการติดตั้งกล้องแต่ละตัว	192
รูปที่ 154 ตัวอย่างเฟรมจากวิดีโอที่ใช้ในการทดสอบและผลลัพธ์จากไลบรารี OpenPose.....	195
รูปที่ 155 ตัวอย่างเฟรมจากวิดีโอสตรีมที่ใช้ในการทดสอบและผลลัพธ์จากซอฟต์แวร์ Elder Care v0.1	196
รูปที่ 156 สัดส่วนจำนวนสมาชิกในครอบครัวของผู้ประเมินระบบ.....	203
รูปที่ 157 สัดส่วนจำนวนผู้สูงอายุที่มีอายุมากกว่า 60 ปี ที่พักอาศัยอยู่ในบ้านของผู้ประเมิน	203
รูปที่ 158 แสดงสัดส่วนหน้าเว็บแอปพลิเคชันที่มีการใช้งานบ่อย	204
รูปที่ 159 ผลประเมินคะแนนความพึงพอใจในการทดสอบใช้งานระบบจากผู้ประเมิน	207

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของโครงการ

หลายประเทศในโลกมีประชากรสูงอายุและประเทศไทยก็เช่นกัน ตามข้อมูลของธนาคารโลก (2016) [1] 11% ของประชากรไทย (7.5 ล้านคน) มีอายุ 65 ปีหรือมากกว่า แต่คาดว่าจะเพิ่มขึ้นเป็น 25% ภายในปี 2583 วัฒนธรรมของชาวเอเชียมักให้ความสำคัญกับความรับผิดชอบในการดูแลผู้สูงอายุในครอบครัว อย่างไรก็ตามที่ระบุไว้โดย Kaneda (2006) [35] ประชากรและแนวโน้มของวัฒนธรรมกำลังทำให้การดูแลผู้สูงอายุของคนในครอบครัวมีความยากมากขึ้น เช่น การที่ผู้สูงอายุมีชีวิตที่ยืนยาวขึ้นและอัตราการเกิดที่ต่ำลง นั้นหมายถึงจำนวนสมาชิกในครอบครัวที่สามารถดูแลพวกเขาก็น้อยลงเช่นกัน คนหนุ่มสาวในชนบทมีการย้ายถิ่นฐานไปอยู่ในเมืองมากขึ้นซึ่งแสดงว่าในทศวรรษที่จะมาถึงนี้ ผู้สูงอายุจะต้องอาศัยอยู่คนเดียวมากขึ้นโดยไม่มีลูกหลานคอยดูแล นอกจากนี้อัตราการแต่งงานโดยรวมที่ลดลงนั้นหมายความว่าในทศวรรษนี้ จะมีผู้สูงอายุจำนวนมากที่พบว่าตัวเองไม่มีบุตรที่จะดูแลพวกเขา

แนวโน้มเหล่านี้จะเป็นแรงกดดันอย่างมหาศาลต่อระบบการดูแลสุขภาพและเศรษฐกิจของประเทศในปีต่อ ๆ ไป ผู้กำหนดนโยบายต้องใช้มาตรการที่ทำให้มั่นใจว่าระบบการรักษาพยาบาลสามารถที่จะตอบสนองความต้องการได้ เพื่อปรับปรุงการประกันสุขภาพและการสนับสนุนเงินบำนาญแก่ผู้สูงอายุและเพื่อสร้างสถาบันที่เป็นทางการและไม่เป็นทางการที่สามารถดูแลผู้สูงอายุโดยไม่ต้องรับการสนับสนุนจากครอบครัว

นอกเหนือจากการเพิ่มการลงทุนในบริการสุขภาพและการสนับสนุนทางการเงินแก่ผู้สูงอายุแล้ว อย่างไรก็ตาม ยังเห็นได้ชัดว่าสังคมในอนาคตของเราจะต้องช่วยเหลือในเรื่องการเพิ่มขึ้นของจำนวนผู้สูงอายุและจำนวนของสมาชิกในครอบครัวที่ลดลง รวมถึงความต้องการแรงงานที่ลดลง เราจึงควรตั้งคำถามว่าต้องทำอะไรจึงจะทำให้นวัตกรรมทางเทคโนโลยีช่วยให้ผู้สูงอายุมีสุขภาพแข็งแรงและสามารถดำรงชีวิตได้ด้วยตัวเองมากขึ้น และเพื่อช่วยให้ครอบครัวและบุคลากรทางการแพทย์สามารถดูแลได้อย่างมีประสิทธิภาพมากขึ้น

1.2 วัตถุประสงค์และขอบเขตของโครงการ

1.2.1 วัตถุประสงค์

1. วัตถุประสงค์หลักของโครงการคือ เพื่อพัฒนาต้นแบบอุปกรณ์เฝ้าดูวิดีโอแบบ IoT (Internet of Things) สำหรับดูแลผู้สูงอายุ ที่ใกล้พร้อมสำหรับการขายในเชิงพาณิชย์
2. เพื่อพัฒนาเทคนิคขั้นสูงสำหรับการคาดการณ์ของอุบัติเหตุเชิงรุก เช่น การวิเคราะห์คนล้ม จากท่าเดินและการจัดทำสถิติข้อมูลพฤติกรรมตลอดเวลา

1.2.2 ขอบเขตของโครงการ

ขอบเขตในการดำเนินโครงการมีดังต่อไปนี้

- ออกแบบและพัฒนาต้นแบบอุปกรณ์เฝ้าดูวิดีโอแบบ IoT (Internet of Things) สำหรับดูแลผู้สูงอายุ พัฒนาโมดูลสำหรับตรวจหาคนขึ้นพื้นฐาน, ติดตาม และการรู้จำรูปแบบพฤติกรรม
- พัฒนาโมดูลการตรวจหาคนล้มและการสรุปกิจกรรมขั้นพื้นฐานไปใช้งาน
- ออกแบบและพัฒนาเฟรมเวิร์กสำหรับการจัดเก็บข้อมูลบนคลาวด์และการวิเคราะห์ข้อมูลพฤติกรรม
- ทำการวิจัยสิ่งบ่งชี้แรกของการเคลื่อนไหวที่ไม่มั่นคงซึ่งจะนำไปสู่การล้มและรูปแบบการพฤติกรรมหรือลักษณะท่าทางอื่น ๆ ที่เป็นอันตราย
- ออกแบบและพัฒนาโมดูลการแจ้งเตือนตั้งแต่เนิ่น ๆ เมื่อผู้สูงอายุมีการเคลื่อนไหวที่ไม่มั่นคง
- ประเมินระบบในสถานการณ์ที่ใช้งานจริง

1.3 ประโยชน์ที่คาดว่าจะได้รับ

โดยผลลัพธ์ของโครงการนี้จะสร้างต้นแบบพื้นฐานที่สามารถพัฒนาต่อเป็นผลิตภัณฑ์เชิงพาณิชย์ การสร้างตลาดใหม่สำหรับอุปกรณ์สมาร์ทโฮมที่จะช่วยครอบครัวในการเฝ้าดูแลผู้สูงอายุผู้เป็นที่เคารพ รัก ผลประโยชน์ที่ตามมาคือการช่วยลดการพึ่งพาซอฟต์แวร์ของต่างชาติซึ่งมีความน่ากังวลเรื่องความเป็นส่วนตัวและความปลอดภัย และลดค่าใช้จ่ายด้านเศรษฐกิจพร้อมกับการเพิ่มขีดความสามารถในการแข่งขันระดับประเทศด้านการดูแลสุขภาพ ด้านอัลกอริทึมการเรียนรู้ของเครื่อง และ คอมพิวเตอร์วิทัศน์ รวมไปถึงปัญญาประดิษฐ์

1.4 ผลผลิตสำคัญ

ลำดับ	ชื่อผลผลิต	หน่วยวัด	ตัวชี้วัด (เชิงคุณภาพ/เชิงคุณภาพ)
1	ต้นแบบผลิตภัณฑ์แบบ IOT สำหรับเฝ้าดูผู้สูงอายุซึ่งคอยเฝ้าดูท่าทางการเดินและกิจกรรมตลอดเวลาเพื่อคอยตรวจจับและทำนายการหกล้ม	1 ระบบ	<p>ด้านวิทยาศาสตร์: อัลกอริทึมที่สามารถเชื่อมโยงข้อมูลกิจกรรมและพฤติกรรมที่ประมวลผลได้จากวิดีโอเพื่อจะตรวจจับการหกล้มหรืออุบัติเหตุอื่น ๆ และ การเฝ้าดูท่าทางการเดินของผู้สูงอายุ อัลกอริทึมที่เสนอสามารถตรวจจับบุคคล ตามรอยบุคคล วิเคราะห์ท่าทางการเดินจากวิดีโอเพื่อคอยตรวจจับการหกล้มและคอยวิเคราะห์ท่าทางการเดินตลอดเวลาโดยใช้เทคนิคการประมวลผลภาพ (image processing) คอมพิวเตอร์วิทัศน์ (computer vision) และการเรียนรู้ของเครื่อง (machine learning) อัลกอริทึมที่เสนออนุญาตออกแบบให้ส่งข้อมูลแจ้งเตือนไปยังผู้ดูแลหรือสมาชิกในครอบครัวเมื่อเกิดการหกล้ม หรือ ความผิดปกติของท่าทางการเดิน</p> <p>ด้านธุรกิจ: ระบบ IOT ที่สามารถเฝ้าดูผู้สูงอายุสำหรับติดตั้งและใช้งานภายในบ้าน หรือ สถานพยาบาล หรือใช้ในการเฝ้าดูแลเด็กทารก ผู้ป่วย หรือ ผู้พิการ</p>
2	ระบบที่สามารถคาดการณ์ความเป็นไปได้ของการเกิดอุบัติเหตุ (การหกล้ม) โดยอ้างอิงจากข้อมูลเชิงสถิติของท่าทางการเดินของผู้สูงอายุ และ ส่งการแจ้งเตือนไปยังผู้ดูแลหรือบุคคลในครอบครัวก่อนที่จะเกิดอุบัติเหตุหกล้ม	1 อัลกอริทึม	<p>ระบบที่เสนอประกอบด้วยองค์ความรู้หลายส่วน ได้แก่ การระบุตัวตนบุคคลในบ้าน การตามรอยบุคคลในมุมมอง การดึงข้อมูลท่าทางการเดินของคุณ การสร้างโมเดลทางสถิติจากข้อมูลลักษณะท่าทางการเดินเพื่อใช้ในการคาดการณ์การหกล้มหรือตรวจจับท่าทางการเดินที่เริ่มผิดปกติ การตรวจจับการหกล้มโดยใช้ภาพพื้นหน้า ความแม่นยำของระบบจะถูกประเมินบนชุดข้อมูลสำหรับทดสอบ โดยจะประเมินความแม่นยำจากค่า precision และ ค่า recall รวมถึงการศึกษาถึงการใช้งานระบบเฝ้าดูผู้สูงอายุบนระบบสมองกลแบบฝังตัว (embedded system boards) หลาย ๆ ประเภท โดยที่ระบบดูแลผู้สูงอายุที่ทีมวิจัยเสนอสามารถใช้งาน</p>

			บนระบบสมองกลแบบฝังตัวและให้ความแม่นยำที่น่าพึงพอใจในการใช้งานจริง
3	นักศึกษาปริญญาโทหรือปริญญาเอก	อย่างน้อย 4 คน	ได้นักเรียนระดับปริญญาโทหรือเอกที่ได้มีประสบการณ์และความสามารถในการวิจัยและพัฒนาในระบบสมองกลแบบฝังตัว IOT และเทคโนโลยีปัญญาประดิษฐ์ที่มีความซับซ้อน และพร้อมที่จะเป็นส่วนสำคัญในการพัฒนาเทคโนโลยีและเศรษฐกิจของประเทศไทยและในภูมิภาค
4	ยื่นคำขอจดสิทธิบัตรหรืออนุสิทธิบัตรไทยก่อนปิดโครงการ หรือ ตีพิมพ์บทความในการประชุมวิชาการระดับนานาชาติที่มีคุณภาพก่อนปิดโครงการ หรือ การตีพิมพ์บทความทางวิชาการระดับนานาชาติจะทำภายหลังจากดำเนินโครงการเสร็จสิ้น	1 สิทธิบัตร หรือ อนุสิทธิบัตร หรือ 1 บทความ	ความคุ้มครองทรัพย์สินทางปัญญา หรือ ผลลัพธ์ทางวิชาการของโครงการจะถูกตีพิมพ์และส่งเสริมผ่านการประชุมวิชาการระดับนานาชาติ หรือ วารสารในระดับนานาชาติ

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีและแนวความคิด

ทั่วโลก 28-35% ของประชากรที่มีอายุ 65 ปีหรืออายุมากกว่านั้นจะเกิดการหกล้มในแต่ละปี [2,3] และอัตราการเกิดการหกล้มเพิ่มขึ้นตามอายุ [4,5] และพบอุบัติการณ์ที่มากขึ้นในสตรี วิถีชีวิตประจำวัน ผู้ที่มีสุขภาพไม่ดี และมีการใช้ยาเรื้อรัง [2, 6-10] ผู้สูงอายุที่อาศัยอยู่ในบ้านพักคนชราเกิดการหกล้มมากกว่าผู้สูงอายุที่อาศัยอยู่ที่บ้าน สำหรับผู้ป่วยระยะยาวประมาณร้อยละ 30-50 จะเกิดการหกล้ม และร้อยละ 40 ของผู้ป่วยระยะยาวนี้จะเกิดการหกล้มซ้ำ [11]

การเปลี่ยนแปลงทางสรีรวิทยาที่เกิดขึ้นเมื่ออายุเพิ่มขึ้นทำให้ประสิทธิภาพของงานส่วนต่าง ๆ ของร่างกายของผู้สูงอายุลดลง [12-16] ความเสี่ยงในการหกล้มของผู้สูงอายุมีความสัมพันธ์กับปัจจัยภายในและปัจจัยภายนอก การเปลี่ยนแปลงความเสื่อมของระบบต่าง ๆ เช่น ระบบหัวใจ กล้ามเนื้อ และกระดูกและระบบประสาทเกี่ยวข้องกับการตอบสนองของร่างกายที่ไม่สมบูรณ์เมื่อเคลื่อนไหวหรือเผชิญกับสถานการณ์ที่ร่างกายและอวัยวะต้องมีการปรับตัว [17-19] การลดลงของระบบหัวใจและปอดส่งผลให้ความสามารถในการทำงานของกล้ามเนื้อเพื่อใช้ออกซิเจนในกระบวนการเมแทบอลิซึมลดลง สัญญาณของการหายใจที่บกพร่องของปอดที่เมื่ออายุมากขึ้นคือจะมีความสามารถในการหายใจลดลง สูญเสียการหดตัวและยืดหยุ่น กล้ามเนื้อระบบทางเดินหายใจอ่อนแอลง กระดูกพรุนออกและผนังทรวงอกลดความยืดหยุ่นลง ประสิทธิภาพการหดตัวของปอดลดลง เกิดอาการกล้ามเนื้ออ่อนแรงได้ง่าย [20] ในภาวะกระดูกพรุนการเปลี่ยนแปลงของระบบกล้ามเนื้อและกระดูกแสดงให้เห็นถึงการลดความแข็งแรงของกล้ามเนื้อและความทนทาน และจะทำให้กระดูกแตกหักและนำไปสู่การเกิดการหกล้ม [21] กล้ามเนื้อและความคล่องตัวในการเคลื่อนไหวลดลงตามอายุโดยเฉพาะในเพศหญิง [19]

การศึกษาก่อนหน้านี้รายงานว่าผู้สูงอายุหกล้มในช่วงกลางวันมากกว่าตอนกลางคืน[22] การหกล้มมักเกิดขึ้นระหว่างที่ผู้สูงอายุทำกิจกรรมประจำวันโดยเฉพาะระหว่างทางไปห้องน้ำ [22] หรือนอกบ้าน [9] รูปแบบต่าง ๆ ของการเคลื่อนไหวต้องการทั้งความมั่นคงและความยืดหยุ่นของร่างกาย ซึ่งใช้ช่วงการเคลื่อนไหวและการออกแรงที่แตกต่างกัน [16] โดยปกติแล้วมนุษย์มีลักษณะการเคลื่อนไหวทั้งในรูปแบบที่เรียบง่ายและซับซ้อนซึ่งควบคุมจากระบบควบคุมส่วนกลางและระบบประสาทที่เชื่อมต่อกับอวัยวะต่าง ๆ ในร่างกาย การเคลื่อนไหวที่ซับซ้อนบางอย่างต้องใช้การรับรู้เพื่อควบคุมการเคลื่อนไหวอย่างเหมาะสม ดังนั้นสถานการณ์บางอย่าง เช่น การเปลี่ยนท่าจากนั่งเป็นยืน การก้าวข้ามสิ่งกีดขวาง การพุดคุยขณะเดิน การเดินด้วยความเร็วสูง การเดินบนพื้นลื่นหรือพื้นผิวที่ขรุขระ การเคลื่อนไหวในลักษณะเหล่านี้ต้องใช้การทำงานร่วมกันของระบบต่าง ๆ ในร่างกายอย่างมีประสิทธิภาพ อย่างไรก็ตามความยากลำบากในการดำเนินการเคลื่อนไหวในรูปแบบเหล่านี้เป็นปัจจัยเสี่ยงของการเกิดการหกล้มในผู้สูงอายุ [23, 24]

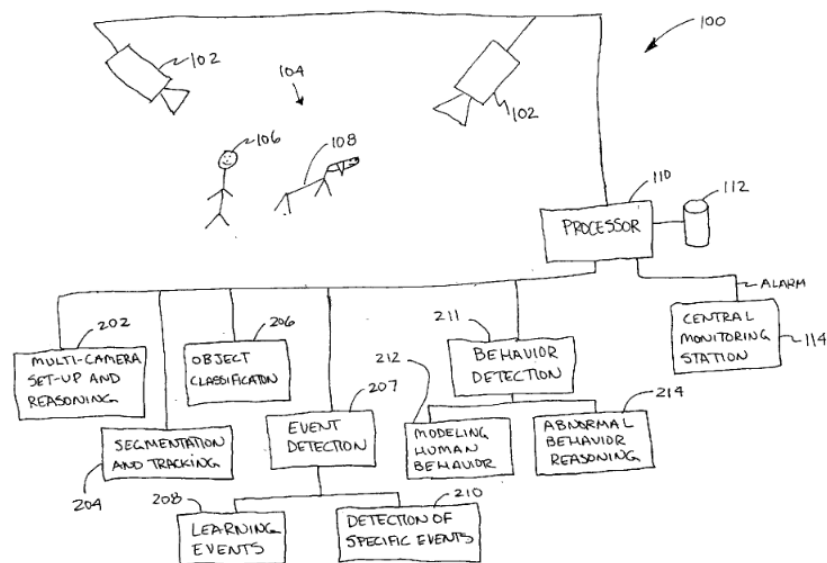
สำหรับการเดินข้ามสิ่งกีดขวาง การลื่นไถล และ การสะดุด เป็นสาเหตุหนึ่งที่ทำให้เกิดการหกล้มซึ่งเกิดขึ้นได้กับทุกคนโดยเฉพาะในผู้สูงอายุที่มีอายุมากกว่า 65 ปี [25] การเพิ่มขึ้นของอายุส่งผลให้ความแข็งแรงของกล้ามเนื้อ ความยืดหยุ่นของร่างกาย การมองเห็น หรือ การปรับตัวให้เข้ากับสภาพแวดล้อมที่เปลี่ยนแปลงลดลง ทำให้เท่าเทียมสัมผัสกับสิ่งกีดขวางและการหกล้ม [26] โดยปกติการก้าวข้ามสิ่งกีดขวางผู้คนจะประมาณลักษณะของสิ่งกีดขวางโดยใช้การรับรู้ภาพ การทรงตัว และหน่วยรับความรู้สึกอื่น ๆ เพื่อปรับลักษณะการเดินของพวกเขา [27-29] การเดินข้ามสิ่งกีดขวางในระหว่างการเดินเป็นการเคลื่อนไหวแบบหลายข้อต่อซึ่งต้องใช้การควบคุมการแกว่งของเท้าที่แม่นยำ และ การทำงานประสานกันระหว่างข้อต่อขาและท่าทางการแกว่งแขนหรือขา ความมั่นคงของร่างกายและลำดับการเคลื่อนไหวที่เป็นปัจจัยสำคัญในการประสานงานซึ่งมีความสำคัญต่อการก้าวข้ามสิ่งกีดขวางได้ [30] ในระหว่างการเคลื่อนไหวนี้ศูนย์รวมของมวลกายจะต้องมีความสมดุลกับเท้าเพียงข้างเดียวและเท้าอีกข้างจะต้องแกว่งเพื่อเคลื่อนไหวนี้เท้าก้าวข้ามเหนือสิ่งกีดขวางพร้อมกัน สำหรับการเดินเร็วหรือหมุนความยากลำบากของการเคลื่อนไหวนี้ส่งผลให้จำนวนขั้นตอนการทำงานของร่างกายมากขึ้น ใช้ระยะเวลายาวขึ้น และระยะก้าวที่ลดลงในผู้สูงอายุโดยเฉพาะอย่างยิ่งในผู้ที่เกิดการหกล้ม [31] การปรับเปลี่ยนเหล่านี้แสดงถึงกลไกการชดเชยเพื่อให้ร่างกายมีความเสถียรภาพในการเดินมากขึ้นสำหรับผู้สูงอายุ [31] เมื่อเปรียบเทียบกับคนที่อายุน้อยพวกเขามักจะใช้การหมุนในการก้าวแต่สำหรับผู้สูงอายุจะใช้การก้าวเร็วแทน [24, 32] เพื่อให้เห็นความแตกต่างของท่าทางการเดิน การเดินเร็วหรือ การมีสิ่งดึงดูดความสนใจระหว่างการเดิน เป็นวิธีการที่ถูกแนะนำเพื่อใช้ในการช่วยวิเคราะห์ท่าทางการเดินเนื่องจากวิธีการดังกล่าวจะช่วยปรับปรุงความไวและความจำเพาะของการทำนายและแยกแยะความเสี่ยงในการเกิดการหกล้ม [33, 34]

หลาย ๆ เทคโนโลยีโดยเฉพาะอย่างยิ่งโครงสร้างพื้นฐานของการสื่อสารไร้สาย และการคำนวณ, การประชุมทางวิดีโอ, การคำนวณบนคลาวด์, Internet of Things (IoT) และเทคโนโลยีสมาร์ทโฮม เป็นจุดที่เหมาะสมที่จะทำให้เกิดนวัตกรรมใหม่ๆ เพื่อช่วยให้ผู้สูงอายุยังคงมีสุขภาพที่แข็งแรงและดำรงชีวิตได้ด้วยตัวเองนานขึ้น

แอปพลิเคชันบนสมาร์ทโฟนที่สามารถแจ้งเตือนการรับประทานยาและการนัดหมายของแพทย์ และยังช่วยผู้ดูแลผู้สูงอายุที่บ้านให้สามารถประสานงานกันได้ อุปกรณ์ต่างๆ เช่น เครื่องจ่ายยาที่เชื่อมต่อกับคลาวด์และการแจ้งเตือนส่วนบุคคล สามารถให้ความอุ่นใจแก่สมาชิกในครอบครัวเมื่อผู้สูงอายุในครอบครัวอยู่บ้านคนเดียว ในส่วนของเซ็นเซอร์ที่เชื่อมต่อกับระบบคลาวด์นั้น เทคโนโลยีในด้านนี้มีการใช้งานอยู่แล้วเพื่อใช้สำหรับเฝ้าดูตัวชี้วัดด้านสุขภาพแบบเรียลไทม์ และเพื่อตรวจจับอุบัติเหตุเช่น การหกล้ม อย่างไรก็ตามผู้สูงอายุอาจลืมนำอุปกรณ์เซ็นเซอร์ที่มีการเชื่อมต่ออยู่หรืออาจรู้สึกว่าเป็นสิ่งรบกวน แม้ว่าเซ็นเซอร์แบบสวมข้อมือแบบธรรมดาอาจจะสามารถตรวจจับรูปแบบของข้อมูลการเร่งความเร็วเมื่อเกิดการหกล้มและทำการแจ้งเตือน แต่มันจะมีประสิทธิภาพมากขึ้นหากเราสามารถใช้นวัตกรรมเซ็นเซอร์เพื่อคาดการณ์เมื่อผู้สูงอายุมีพฤติกรรมผิดปกติหรือพฤติกรรมที่มีแนวโน้มจะเกิดอุบัติเหตุได้ก่อนที่อุบัติเหตุจะเกิดขึ้น การคาดการณ์การเกิดอุบัติเหตุนี้ต้องมีการเก็บรวบรวมข้อมูลและติดตามรูปแบบพฤติกรรมต่าง ๆ ที่หลากหลายของผู้สูงอายุตลอดเวลา

กล้องวิดีโอเป็นเซ็นเซอร์ที่ติดตั้งอยู่กับที่ซึ่งให้ข้อมูลที่เป็นประโยชน์มากที่สุดสำหรับการเฝ้าดูพฤติกรรมของบุคคลเป็นระยะเวลานาน ดังนั้นจึงมีความน่าสนใจอย่างมากในการใช้วิดีโอเซ็นเซอร์ในการดูแลผู้สูงอายุ ตัวอย่างแรกเช่น สิทธิบัตรสหรัฐอเมริกาที่ถูกละทิ้งการขอจดสิทธิบัตร Lee et al. (2003) [36] ดังแสดงในรูปที่ 1 ซึ่งมีแนวคิดหลักคือ การติดตั้งกล้องวิดีโอในบ้าน และรวมความสามารถในการติดตามการเคลื่อนไหวของผู้สูงอายุและพฤติกรรมอื่นๆ ตลอดเวลา แม้ว่าแนวคิดนี้ไม่ใช่เรื่องใหม่ แต่ในขณะปัจจุบันนี้ปี พ.ศ. 2561 เทคโนโลยีต่าง ๆ เช่น การสื่อสารผ่านมือถือ, ระบบใยแก้วนำแสงที่บ้าน, ระบบประมวลผลบนคลาวด์, เซ็นเซอร์, ระบบสมองกลฝังตัว, อัลกอริทึมคอมพิวเตอร์วิทัศน์, และอัลกอริทึมทางการเรียนรู้ของเครื่อง ได้มีการพัฒนาขึ้นจนถึงระดับที่ราคา และ ประสิทธิภาพมีความเหมาะสมสำหรับการนำแนวคิดนี้มาใช้งานจริง

ในโครงการนี้เราจึงเสนอแผนที่มุ่งเน้นการวิจัยและพัฒนาเป็นระยะเวลา 1 ปี เพื่อหาแนวทางแก้ไขปัญหานั้นนำมาใช้ได้จริงในการแก้ปัญหาของการติดตามผู้สูงอายุในบ้านโดยใช้ข้อมูลจากกล้องที่ติดตั้งในบ้าน และแก้ปัญหาค่าการเก็บรวบรวมรูปแบบการเคลื่อนไหว การรับประทานอาหาร การนอน ของผู้สูงอายุ การรายงานแนวโน้มของข้อมูลเหล่านี้ให้กับสมาชิกในครอบครัวและแพทย์และมีการแจ้งเตือนเมื่อมีพฤติกรรมผิดปกติเกิดขึ้น



รูปที่ 1 แนวคิดการใช้ระบบเฝ้าดูผู้สูงอายุโดยใช้กล้องวิดีโอ รูปจาก Lee และคณะ (2003) [36]


2.2 ผลงานวิจัยที่เกี่ยวข้อง

การนำระบบประมวลผลภาพที่เป็นไปได้ไปประยุกต์กับสมาร์ตโฮม สามารถเติมเต็มเทคโนโลยีที่มีอยู่ในปัจจุบัน ตัวอย่างเช่น มีการค้นคว้าวิจัยเกี่ยวกับการตรวจจับการล้มโดยใช้ข้อมูลจากวิดีโอ (ตัวอย่างเช่น Anderson et al., 2006 [38]) ซึ่งอาจจะมีประสิทธิภาพมากกว่าการใช้เซ็นเซอร์ที่สวมที่ข้อมือเพื่อวัดความเร่ง, แต่การตรวจจับการล้มจากวิดีโอจะทำงานได้แม้ในขณะที่บุคคลได้สวมใส่หรือปฏิเสธที่จะสวมใส่เซ็นเซอร์ ถึงแม้ว่าการตรวจสอบในเวลากลางคืนเป็นสิ่งที่ยากลำบากสำหรับกล้องวิดีโอทั่วไป แต่การวิจัยเมื่อเร็ว ๆ นี้ ได้ทำการใช้วิธีการประมวลผลบนภาพแบบอินฟราเรด (Zhou et al. 2011) [39]


นอกจากการตรวจจับการล้มแล้วนั้น การประมวลผลภาพยังสามารถนำมาประยุกต์ใช้งานในรูปแบบอื่นที่เทคโนโลยีที่มีอยู่ในปัจจุบันไม่สามารถทำได้ เช่น การใช้การประมวลผลภาพเพื่อแยกแยะและแสดงข้อมูลการเคลื่อนไหวและโครงร่าง (Zhou et al., 2009) [41] และดึงข้อมูลลักษณะกิจกรรมของบุคคลที่ปรากฏในภาพตลอดเวลา (Chung and Liu [42], 2008; Zhou et al., 2008 [43]; Jalal et al., 2014 [44]) นอกเหนือจากการพัฒนาเทคโนโลยีแล้ว สิ่งที่สำคัญประการหนึ่งคือการพิจารณาเรื่องความเป็นส่วนตัวของแต่ละบุคคล ที่คนส่วนใหญ่มีความกังวลเกี่ยวกับการเฝ้าดูพฤติกรรมตลอด 24 ชั่วโมง แต่การวิจัยบางชิ้นบ่งชี้ว่าในบริบทของการเฝ้าติดตามผู้สูงอายุความกังวลเหล่านี้สามารถบรรเทาได้ด้วยการประมวลผลและเก็บโครงร่างแทนที่จะเป็นวิดีโอ (Demiris et al., 2009) [48]

การศึกษาหลาย ๆ งานได้แสดงให้เห็นถึงประโยชน์ของการใช้กล้องราคาไม่แพงที่สามารถประมาณความลึกของวัตถุได้ เช่น Microsoft Kinect สำหรับการบำบัดทางกายภาพ และการประเมินการทำงานของร่างกาย และยังมีการวิจัยอีกหลายงานที่ใช้ Microsoft Kinect เพื่อวัดท่าทางการเดินในเชิงตำแหน่งและเวลาสำหรับการเดินภายในบ้าน [40] ค่าข้อมูลที่ได้จาก Microsoft Kinect และ ระบบตรวจจับการเคลื่อนไหวถูกนำมาเปรียบเทียบเพื่อกำหนดตำแหน่งของเท้าซึ่งส่งผลต่อความเร็วในการเดินซึ่งสามารถนำมาใช้ในการทำนายพฤติกรรมที่ผิดปกติของบุคคลที่เสี่ยงต่อการล้ม ดังแสดงในรูปที่ 2

ตำแหน่งกล้องและเส้นทางการเดิน
ในสภาพแวดล้อมสำหรับการทดสอบ




การเปรียบเทียบความเร็วของการเดิน 18 ลำดับ



รูปที่ 2 แนวคิดของการใช้กล้องที่เก็บข้อมูลความลึกของวัตถุได้ในระบบเฝ้าดูผู้สูงอายุ รูปจาก Stone และคณะ (2011) [40]

งานวิจัยบางงานได้แสดงให้เห็นถึงความก้าวหน้าในการดึงข้อมูลและแสดงการเคลื่อนไหวของภาพขอบเงา (silhouette) ของบุคคลได้ [41] และทำการดึงข้อมูลประเภทกิจกรรมของมนุษย์จากข้อมูลการเคลื่อนไหวจากภาพขอบเงา [42-44]

การรู้จำประเภทกิจกรรมของมนุษย์โดยใช้เทคนิค Conditional Random Fields (CRF) จะสร้างข้อมูลท่าทางจากกล้องหลายมุมมองโดยใช้ชุดข้อมูล Mocap [45] จากนั้นการคำนวณความคล้ายคลึงกันของรูปร่างโดยสังเกตจากความเป็นไปได้และการเปลี่ยนตำแหน่งของจุดฟิกเชลที่มีความคล้ายคลึงกันระหว่างเฟรม ข้อมูลท่าทางจะถูกแสดงในรูปแบบของ two-layer Conditional Random Fields อัลกอริทึมนี้เรียกว่า Shap, Flow, Duration Conditional Random Field (SFD-CRF) ซึ่งสามารถใช้ในการรู้จำประเภทกิจกรรมได้ เช่น การนั่ง การยืน เป็นต้น รูปที่ 3 แสดงแนวคิดการทำงานของระบบดังกล่าว



รูปที่ 3 แนวคิดการใช้ระบบรู้จำท่าทางของมนุษย์ รูปจาก Natarajan และคณะ (2008) [45]

ชุดข้อมูลท่าทางการเคลื่อนไหวที่รู้จักกันดีอีกชุดข้อมูลหนึ่ง คือ ชุดกิจกรรมท่าทางการเคลื่อนไหวของมนุษย์ของฮอลลีวูด (Hollywood human activity dataset) [47, 46] ชุดข้อมูลฮอลลีวูดนี้เป็นชุดข้อมูลท่าทางกิจกรรมของมนุษย์ที่มีความสมจริง ชุดข้อมูลนี้มีความยากมากกว่าชุดข้อมูล Mocap เนื่องจากกล้องมีการเคลื่อนที่ มีการบดบังกันในฉาก และมุมกล้องที่เปลี่ยนไปมา ชุดข้อมูลแรกเผยแพร่ในปี 2551 [47] ประกอบด้วยตัวอย่างวิดีโอประมาณ 663 ตัวอย่าง (452 ตัวอย่างข้อมูลสำหรับเทรน 211 ตัวอย่างข้อมูลสำหรับทดสอบ) ของ 8 ท่าทาง (ออกกำลังกาย, ตอรับโทรศัพท์, จับมือ, กอด, จูบ, ลุกขึ้นนั่ง, นั่งลง, และลุกขึ้นยืน) จากภาพยนตร์ 32 เรื่อง การรู้จำกิจกรรมตามธรรมชาติของมนุษย์ในวิดีโอต่าง ๆ และวิดีโอที่สมจริงได้ถูกกล่าวถึงใน [47] ชุดข้อมูลเพิ่มเติมของฮอลลีวูดถูกสร้างขึ้นในปี 2552 [46] ซึ่งมีกิจกรรมเพิ่มเติมอีก 4 กิจกรรม (การต่อสู้, การวิ่ง, การขับรถยนต์, และการรับประทานอาหาร) และเพิ่มตัวอย่างข้อมูลสำหรับแต่ละประเภทกิจกรรมรวมทั้งหมด 3669 คลิปวิดีโอจากภาพยนตร์ 69 เรื่อง ทั้งประเภทกิจกรรมที่มีการโต้ตอบระหว่างมนุษย์ (เช่น การต่อสู้ การจูบ) และการปฏิสัมพันธ์ระหว่างมนุษย์กับวัตถุ (เช่น การขับรถยนต์ การรับโทรศัพท์) ถูกรวมไว้ในชุดข้อมูลนี้ด้วย Marszalek และคณะ [46] ใช้ประโยชน์จากความสัมพันธ์ระหว่างบริบทของฉากที่มีการเปลี่ยนแปลง และ กิจกรรมของมนุษย์ โดยเทคนิค bag-of-features และใช้ตัวจำแนกประเภท SVM

นอกเหนือจากการพัฒนาเทคโนโลยีปัจจัยหนึ่งที่ต้องคำนึงถึงคือความเป็นส่วนตัวของแต่ละบุคคล คนส่วนใหญ่มีความกังวลเกี่ยวกับการถูกเฝ้าดูตลอด 24 ชั่วโมง แต่งานวิจัยบางงานบ่งชี้ว่าในบริบทของการเฝ้าสังเกตผู้สูงอายุ เราสามารถลดความกังวลเหล่านี้ได้โดยการประมวลผลและจัดเก็บภาพเงาแทนวิดีโอภาพปกติ [48]

ชุดข้อมูล MSR DailyActivity3D เป็นชุดข้อมูลที่ถ่ายโดยอุปกรณ์ Kinect โดยพิจารณาจากภาพขอบเงาและวิดีโอ ชุดข้อมูลนี้มีข้อมูล 3 ประเภท ประกอบด้วย ข้อมูลแผนที่ความลึก ข้อมูลตำแหน่งข้อต่อโครงกระดูก และวิดีโอสี RGB โดยจะมีบุคคล 10 คนทำท่าทาง 16 ท่าทาง (กิน, ดื่ม, อ่านหนังสือ, เขียนบนกระดาน, โทร์โดยใช้โทรศัพท์มือถือ, ใช้แล็ปท็อป, ส่งเสียงเชียร์, ใช้เครื่องดูดฝุ่น, นั่งนิ่ง, เล่นเกม, เล่นกีตาร์, เล่นกีตาร์, โยนกระดาน, นอนโซฟา, เดิน, ยืน, และนั่งลง) Wang และคณะ [49] มีส่วนช่วยในการสร้างข้อมูลที่มีคุณสมบัติใหม่ที่เรียกว่า Local Occupancy Pattern เพื่อแสดงถึง "ลักษณะที่ปรากฏในเชิงลึก" ซึ่งได้ถูกออกแบบมาเพื่อตรวจจับความสัมพันธ์ระหว่างส่วนต่างๆ ของร่างกายมนุษย์ และ วัตถุสิ่งแวดล้อมในฉาก ท่าทาง (actionlet) จะถูกกำหนดให้เป็นข้อมูลรูปแบบเฉพาะที่มีการรวมข้อมูลของข้อต่อต่าง ๆ ซึ่งบ่งบอกถึงโครงสร้างของท่าทางแต่ละท่าทาง อัลกอริทึมการทำเหมืองข้อมูลแบบใหม่ถูกเสนอเพื่อใช้ในการแยกแยะประเภทท่าทางต่าง ๆ โดยประเภทท่าทางกิจกรรมของมนุษย์หนึ่งท่าสามารถตีความได้ว่าเป็นการรวมกันเชิงเส้นของท่าทางต่าง ๆ การใช้ข้อมูลท่าทางเหล่านี้ร่วมกับเทคนิคการเรียนรู้ของเครื่องเป็นวิธีที่มีประสิทธิภาพในการจำแนกประเภทกิจกรรมท่าทางของมนุษย์



รูปที่ 4 แนวคิดระบบการรู้จำท่าทางของมนุษย์โดยใช้ชุดข้อมูล MSR-Action3D รูปจาก Wang และคณะ (2012) [49]

ระบบการติดตามการเคลื่อนไหวในปริภูมิ 3 มิติยังถูกนำมาใช้อย่างกว้างขวางเพื่อรู้จำท่าทางของมนุษย์ งานวิจัยบางงานมีการนำ USRP / GNURadio พร้อมอุปกรณ์แผงวงจรที่ทำหน้าที่เป็นอุปกรณ์เครื่องลูกข่ายทำงานร่วมกัน ซึ่งสามารถตรวจจับการหกล้มของบุคคลได้ [50-51]

หนึ่งในเทคโนโลยีสำหรับการดูแลผู้สูงอายุที่ปัจจุบันยังไม่มีการพัฒนาจนให้ใช้งานได้อย่างมีประสิทธิภาพ คือ การประมวลผลวิดีโอโดยใช้อุปกรณ์รับภาพที่ติดตั้งในบ้านเชื่อมต่อกับระบบ Internet of Things (IoT) ที่เชื่อมต่อกับระบบคลาวด์ ปัจจุบันการวิจัยและพัฒนาในด้านการประมวลผลวิดีโอสำหรับผู้สูงอายุนั้น เน้นการวิจัยด้านดังต่อไปนี้ 1) การตรวจจับการหกล้ม และ 2) การตรวจจับและบันทึกกิจกรรมของผู้สูงอายุตลอดเวลา ปัจจุบันยังไม่พบการวิจัยในส่วนของการเฝ้าดูรูปแบบ

พฤติกรรมของผู้สูงวัยเชิงรุกโดยใช้อุปกรณ์รับภาพ ระบบแจ้งเตือนพฤติกรรมผิดปกติของผู้สูงวัย อาจจะทำนายและช่วยป้องกันการเกิดอุบัติเหตุแทนที่จะช่วยเพิ่มความรวดเร็วในการเข้าถึงตัวผู้สูงอายุหลังเกิดอุบัติเหตุ ในปัจจุบันนี้เรายังไม่พบระบบประมวลผลภาพเชิงพาณิชย์ที่สามารถเฝ้าดูพฤติกรรม และความสม่ำเสมอของพฤติกรรมของผู้สูงอายุ และมีความสามารถในการประมวลผลแบบเรียลไทม์ และสามารถแจ้งเตือนสมาชิกในครอบครัวหรือผู้ดูแลผู้สูงวัยที่บ้านเมื่อเกิดปัญหาขึ้น ในโครงการวิจัยนี้ทีมวิจัยมุ่งหวังที่จะเติมเต็มช่องว่างเหล่านี้เพื่อพัฒนาอุปกรณ์ต้นแบบในการประมวลผลวิดีโอแบบ IoT ที่ใกล้เคียงหรือสามารถใช้ในเชิงพาณิชย์ซึ่งมีความสามารถในการเฝ้าดูพฤติกรรมของสมาชิกผู้สูงอายุในครอบครัวและแจ้งเตือนเมื่อเกิดพฤติกรรมผิดปกติหรือพฤติกรรมที่ไม่สม่ำเสมอ

ระบบที่ทีมวิจัยพัฒนาขึ้นจะถูกทดสอบการใช้งานจริงกับอาสาสมัครผู้ทดสอบใช้งานจริง และทำการเปรียบเทียบประสิทธิภาพของระบบโดยใช้ข้อมูลความจริง (ground truth) ที่เก็บโดยใช้อุปกรณ์ 3D motion ซึ่งให้ข้อมูลในปริภูมิสามมิติ โดยวัดประสิทธิภาพในปัจจัยหลัก ได้แก่ การเคลื่อนที่ ช่วงระยะของการเคลื่อนไหว ทำทางการเดิน เป็นต้น

ดังนั้นทีมวิจัยมุ่งหวังที่จะเก็บรวบรวมข้อมูลการเคลื่อนที่ของกิจกรรมประจำวันของผู้สูงอายุผู้ซึ่งไม่มีประวัติการหกล้ม ข้อมูลเกี่ยวกับความแตกต่างของการเคลื่อนไหวของผู้ที่หกล้มและผู้ที่ไม่หกล้มจะถูกนำมาใช้ในการประมวลผลภาพเพื่อแจ้งเตือนความเสี่ยงที่จะเกิดการหกล้มของผู้สูงอายุ

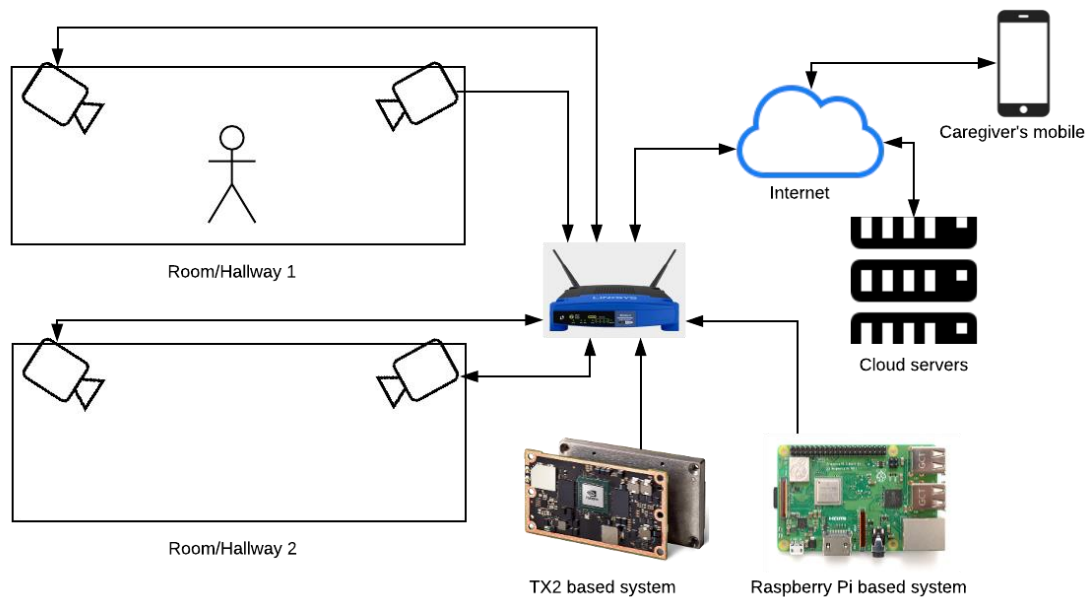
บทที่ 3

ระเบียบวิธีวิจัย

3. วิธีการ/ขั้นตอนการดำเนินการวิจัยและพัฒนา

3.1 ภาพรวมของระบบ

ระบบจะประกอบด้วยระบบย่อย 2 ส่วนหลัก คือ ส่วนการประมวลผลส่วนหน้า และ ระบบคอมพิวเตอร์แม่ข่ายบนคลาวด์ โดยการประมวลผลส่วนหน้าจะทำการประมวลผลจากวิดีโอสตรีมที่ได้จากกล้องที่ติดตั้ง และส่งข้อมูลไปยังคอมพิวเตอร์แม่ข่ายเพื่อทำการวิเคราะห์เพิ่มเติม และส่งการแจ้งเตือนไปยังผู้ดูแลผู้สูงอายุ โดยการติดตั้งและใช้งานระบบโดยกล้องมีมุมกล้อง 2 มุมจะถูกติดตั้งเพื่อให้ครอบคลุมพื้นที่ใช้สอยส่วนใหญ่ แผนผังภาพรวมของระบบ แสดงในรูปที่ 5 รายละเอียดการทำงานของระบบจะถูกอธิบายในหัวข้อ การพัฒนาระบบ IoT สำหรับเฝ้าดูผู้สูงอายุ



รูปที่ 5 ภาพรวมของระบบ

ขั้นตอนการทำงานของระบบประกอบด้วย 5 โมดูลหลัก ดังนี้

- การตรวจจับ ตามรอย และรู้จำบุคคล
- การรู้จำรูปแบบกิจกรรม และการตรวจจับการหกล้ม
- การวิเคราะห์การเคลื่อนไหวที่ไม่มั่นคง/การคาดการณ์การหกล้ม
- การสรุปประเภทกิจกรรมที่ตรวจพบ
- การแจ้งเตือน

รายละเอียดในแต่ละโมดูลจะอธิบายในหัวข้อย่อยถัดไป

3.2 ระบบตรวจจับ ตามรอย และรู้จำบุคคล


3.2.1 การตรวจจับและตามรอยบุคคล

โมดูลการตรวจจับและตามรอยบุคคลถูกใช้ในการตรวจจับบุคคลในแต่ละเฟรมและทำการตามรอยบุคคลนั้น ๆ เพื่อจะเก็บข้อมูลภาพส่วนที่เป็นคน (bounding box) ในแต่ละเฟรมที่ต่อเนื่องกันจากวิดีโอสตรีม ข้อมูลส่วนนี้จะถูกส่งต่อไปยังโมดูลการตรวจจับการทกล้ม การรู้จำรูปแบบกิจกรรม ที่มวิจัยได้ทำการวิจัยและพัฒนาในด้านการพัฒนาปรับปรุงซอฟต์แวร์ Human Analytics ของ AIT ที่มีอยู่แล้วให้สามารถรันแบบเรียลไทม์บนบอร์ด Nvidia Jetson TX2 และ/หรือ Raspberry Pi

ทีมวิจัยทดสอบซอฟต์แวร์ Human Analytics ของ AIT ที่มีอยู่แล้วซึ่งมีความสามารถในการตรวจจับบุคคล ตรวจจับใบหน้า ประมาณค่ามุมใบหน้าโดยใช้จุดสังเกตบนใบหน้า สามารถตามรอยบุคคล/ใบหน้า รวมถึงแยกแยะอายุและเพศ เมื่อทดสอบรันบนบอร์ด Nvidia Jetson TX2 พบว่าสามารถประมวลผลได้ที่เฟรมเรตต่ำ กรณีที่รันการตรวจจับบุคคลเพียงอย่างเดียว (ไม่มีการตามรอย) บนบอร์ด Nvidia Jetson TX2 สามารถประมวลผลได้ 3-4 เฟรม/วินาที และสามารถประมวลผลได้ที่ 1-2 เฟรม/วินาที หากใช้การตรวจจับใบหน้า ตามรอย และวิเคราะห์เพศและอายุ อย่างไรก็ตามทีมวิจัยได้ทดลองใช้โมเดลการเรียนรู้เชิงลึก ที่มีจำนวนเลเยอร์และจำนวนการคำนวณที่น้อยกว่า (tiny-YOLOv4) เพื่อตรวจจับบุคคลเพียงอย่างเดียวบนบอร์ด Nvidia Jetson TX2 พบว่าสามารถรันได้ที่ 16-19 เฟรม/วินาที ผลลัพธ์ตัวอย่างการตรวจจับบุคคล และ การตรวจจับใบหน้าบุคคลแสดงในรูปที่ 6 และ 7 ตามลำดับ



รูปที่ 6 ตัวอย่างการตรวจจับบุคคลโดยใช้โมเดลการเรียนรู้เชิงลึก



รูปที่ 7 ตัวอย่างการตรวจจับและตามรอยใบหน้าและวิเคราะห์เพศอายุ

ทีมวิจัยได้ทำการพัฒนาปรับปรุงอัลกอริทึมเดิมให้ดีขึ้นและหาอัลกอริทึมทางเลือกอื่นที่ใช้ทรัพยากรในการคำนวณที่น้อยกว่า Human Analytics เวอร์ชันปัจจุบัน เพื่อให้การตรวจจับและตามรอยบุคคลสามารถประมวลผลแบบเรียลไทม์ได้บนบอร์ด Nvidia Jetson TX2 และ/หรือ Raspberry Pi โดยใช้โมเดลการเรียนรู้เชิงลึกที่มีจำนวนเลเยอร์ หรือ จำนวน operation ในการคำนวณที่น้อยกว่าโมเดลการเรียนรู้เชิงลึกที่ใช้อยู่ในปัจจุบัน

ภายหลังการศึกษาดังกล่าวข้างต้นส่วนที่ใช้ทรัพยากรในการคำนวณเยอะคือโมดูลการตรวจหาตำแหน่งบุคคลในรูปภาพและการตามรอยบุคคล ทีมวิจัยพบว่าไลบรารี OpenPose สามารถตรวจจับตำแหน่งบุคคลได้เช่นกัน ดังนั้นเพื่อที่จะลดการคำนวณและการทำงานที่ซ้ำซ้อนกันในการตรวจหาตำแหน่งตัวบุคคลในภาพ ทีมวิจัยอาจใช้การตรวจหาตำแหน่งบุคคลจากไลบรารี OpenPose แทนที่โมดูลการตรวจหาตำแหน่งบุคคลในซอฟต์แวร์ Human Analytics ที่ทีมวิจัยใช้อยู่เพื่อลดความซ้ำซ้อนในการทำงานและลดการใช้ทรัพยากรในการประมวลผล ในส่วนของอัลกอริทึมการตามรอยบุคคล อัลกอริทึมเดิมที่ใช้ร่วมกับซอฟต์แวร์ Human Analytics ใช้การคำนวณพื้นที่ซ้อนทับกันระหว่างบุคคลที่ตรวจพบของเฟรมปัจจุบันและเฟรมก่อนหน้าร่วมกับอัลกอริทึม Kernelized Correlation Filter เพื่อทำการตามรอยบุคคล การตามรอยบุคคลโดยอัลกอริทึมนี้อาจไม่แม่นยำในกรณีที่มีการซ้อนทับกันของบุคคลหรือตัวบุคคลถูกบดบังจากองค์ประกอบต่าง ๆ ในมุมมอง ทีมวิจัยได้ทดสอบอัลกอริทึม DeepSort ซึ่งให้ความแม่นยำในการตามรอยได้มากกว่าแต่ใช้ทรัพยากรในการคำนวณมากกว่า ถึงแม้ว่าโมดูลการตรวจจับบุคคลของซอฟต์แวร์ Human Analytics และ OpenPose จะทำการตรวจจับบุคคลได้แต่ในบางมุมมองกล้องและตำแหน่งของบุคคลที่ปรากฏในภาพแตกต่างกันอัลกอริทึมสามารถทำงานได้แตกต่างกัน เช่นเดียวกับกับโมดูลการตามรอยบุคคลซึ่งความสามารถในการทำงานขึ้นอยู่กับลักษณะการเคลื่อนที่ในมุมมองและลักษณะการบดบัง ดังนั้นเพื่อให้ระบบใช้ทรัพยากรในการคำนวณน้อยที่สุดและระบบสามารถใช้งานได้ในการใช้งานจริงเมื่อใช้กับกล้องจำนวนหลายตัว ทีมวิจัยได้เก็บทั้ง 2 อัลกอริทึมการตรวจจับบุคคล และทั้ง 2 อัลกอริทึมการตามรอยไว้เป็นตัวเลือกในการใช้งานจริง ซึ่งขึ้นอยู่กับมุมมอง จำนวนกล้อง และ ฮาร์ดแวร์ที่ใช้ในการประมวลผล

ทีมวิจัยได้พัฒนาระบบประมวลผลภาพ Elder Care Video Analytics จำนวนหลากหลายเวอร์ชัน เพื่อหาเวอร์ชันที่เหมาะสมสำหรับการประมวลผลบน NVIDIA TX-2 และสามารถประมวลผลได้แบบเรียลไทม์ โดยจะต้องสามารถทำงานตรวจจับบุคคลและดึงข้อมูลโครงสร้างของบุคคล และทำ

การตามรอยบุคคลได้แบบเรียลไทม์เนื่องจากข้อมูลลำดับการเคลื่อนที่ของโครงร่างของร่างกายในแต่ละเฟรมจะถูกนำมาวิเคราะห์ ดังนั้นการประมวลผลแบบเรียลไทม์เพื่อประมวลผลให้ได้มาซึ่งข้อมูลทีละก้าวมาทั้งหมดจึงมีความสำคัญ รายละเอียดและฟังก์ชันการทำงานของระบบประมวลผลภาพ Elder Care Video Analytics ที่ทีมวิจัยพัฒนาขึ้นมาทั้งหมดตั้งแต่เริ่มโครงการสามารถแบ่งได้เป็น 3 เวอร์ชันหลัก โดยแสดงรายละเอียดและฟังก์ชันการทำงานในตารางที่ 1 โดยเวอร์ชันล่าสุดที่สามารถประมวลผลและทำงานได้แบบเรียลไทม์บน NVIDIA TX-2 คือ Elder Care Video Analytics v.0.3 ซึ่งปัจจุบันสามารถทำงานร่วมกับ Elder Care APIs v.0.1 ได้ซอฟต์แวร์ทั้งสองเวอร์ชันนี้ทีมวิจัยได้นำไปติดตั้งและใช้งานในบ้านอาสาสมัคร


ระบบ Elder Care Video Analytics v.0.3 ใช้ไลบรารี trt_pose ซึ่งถูกออกแบบมาให้รันบน NVIDIA Jetson Nano และ AGX เพื่อดึงข้อมูลโครงร่างของร่างกายจำนวน 18 จุด ไลบรารี trt_pose สามารถประมวลผลวิดีโอสตรีมขนาด 1920x1080 พิกเซลได้ที่เฟรมเรตสูงกว่าเมื่อเทียบกับ OpenPose (Python) และ LibOpenPose (C++) ดังนั้นทีมวิจัยจึงใช้ trt_pose ในการดึงข้อมูลโครงร่างของร่างกาย และทำการประมาณกรอบสี่เหลี่ยมตำแหน่งของคนที่ตรวจพบแทนที่การใช้เน็ตเวิร์กโมเดลอื่นในการตรวจหาตำแหน่งบุคคลเพื่อลดภาระการประมวลผล ข้อมูลกรอบสี่เหลี่ยมล้อมรอบตัวบุคคลนี้ถูกนำไปใช้ในการตามรอยบุคคลโดยทำการคำนวณค่า IoU (Intersection over Union) ระหว่างกรอบสี่เหลี่ยมที่ตรวจพบในแต่ละเฟรมกับเฟรมก่อนหน้าเพื่อทำการตามรอยบุคคล ทีมวิจัยได้นำส่วนของการประมาณค่าตำแหน่งกรอบสี่เหลี่ยมโดย Kernelized Correlation Filter (KCF) ออกเพื่อลดทรัพยากรการประมวลผล และทำการกำหนดสถานะการตามรอยขึ้นมา 3 สถานะคือ active, loss, และ remove สถานะการตามรอยนี้จะช่วยให้การตามรอยสามารถกลับมาตามรอยได้หากข้อมูลกรอบสี่เหลี่ยมขาดหายไปในช่วงเฟรม เมื่อไหร่ก็ตามที่สถานะของการตามรอยถูกระบุเป็น remove การตามรอยนั้นถือว่าสิ้นสุดข้อมูลที่ถูกระหว่างการตามรอยจะถูกรวบรวมและส่งไปยัง Elder Care APIs เพื่อทำการวิเคราะห์และประมวลผลต่อไปบนระบบคลาวด์ Elder Care ข้อมูลที่ส่งไปยังระบบคลาวด์ประกอบด้วยข้อมูลดังนี้

- รายการข้อมูลตำแหน่งโครงร่างของร่างกาย 18 จุดของแต่ละเฟรมระหว่างการตามรอยบุคคล
- รายการข้อมูลกรอบสี่เหลี่ยมล้อมรอบตัวบุคคลที่ได้ในแต่ละเฟรมระหว่างการตามรอยบุคคล
- ภาพของบุคคลจำนวน 1 ภาพ ซึ่งถูกเก็บระหว่างการตามรอยบุคคล

ข้อมูลเหล่านี้จะถูกส่งไปยังระบบคลาวด์ Elder Care เพื่อทำการแยกแยะประเภทกิจกรรมท่าทาง ตรวจหาการหกล้ม วิเคราะห์การเคลื่อนไหวที่ไม่มั่นคง และรู้จำใบหน้าบุคคล ตัวอย่างของภาพที่ถูกประมวลผลแสดงในรูปที่ 8 และ 9 ตามลำดับ โดยกรอบสี่เหลี่ยมสีเขียวแสดงถึงตำแหน่งบุคคลในเฟรมปัจจุบัน ส่วนกรอบสีแดงแสดงถึงตำแหน่งบุคคลในการตามรอยบุคคลในเฟรมก่อนหน้า ทีมวิจัยลดภาระการตรวจหาตำแหน่งใบหน้าโดยไม่ทำการตรวจหาตำแหน่งใบหน้าบนอุปกรณ์ประมวลผลส่วนหน้า แต่จะทำการตรวจจับใบหน้า และปรับตำแหน่งใบหน้าบนฝั่งระบบคลาวด์ Elder Care



รูปที่ 8 ตัวอย่างของการดึงข้อมูลตำแหน่งจุดโครงสร้างของร่างกาย



รูปที่ 9 ตัวอย่างการประมาณค่าตำแหน่งกรอบสี่เหลี่ยมจากจุดโครงสร้างของร่างกายที่ใช้ในการตามรอย

ตารางที่ 1 เวอร์ชันของระบบประมวลผลภาพที่ทำงานบนอุปกรณ์ประมวลผลส่วนหน้า และเวอร์ชันของ APIs ที่ทำงานบนระบบคลาวด์ Elder Care

ระบบประมวลผลส่วนหน้า (NVIDIA TX-2)						
Video Analytics Version	People detection	Skeleton extraction	Face detection	Tracking algorithm	Activity classification and unstable movement analysis	Suitable deployment hardware
0.1 (Python)	Extract from skeleton keypoints	OpenPose	-	DeepSort	Tensorflow + Keras	GPU PC
0.2 (C++)	Extract from skeleton keypoints	libOpenPose	S3FD	IoU + KCF	-	GPU PC
0.3 (Python)	Extract from	Trt_pose	-	IoU without	-	NVIDIA TX-2

	skeleton keypoints			KCF		
--	-----------------------	--	--	-----	--	--

3.2.2 การรู้จำใบหน้าบุคคล

ในการระบุตัวตนบุคคลเป้าหมายที่มิวิจัยได้ทดสอบใช้ระบบรู้จำใบหน้าบุคคลที่มิวิจัยมีอยู่แล้วในการทำงานร่วมกับระบบ Elder Care v0.1 เพื่อใช้ในการระบุตัวตนบุคคล โดยทำการบันทึกหน้าบุคคลจากเฟรมที่เห็นใบหน้าของบุคคลได้ชัดเจนและอยู่ในตำแหน่งที่มีความละเอียดของภาพใบหน้าเพียงพอเพื่อใช้ในการระบุตัวตนของบุคคลที่ปรากฏในมุมมองดังแสดงในรูปที่ 10 ถึงแม้ระบบรู้จำใบหน้าจะให้ความน่าเชื่อถือในการระบุตัวตนแต่ใช้ทรัพยากรในการคำนวณเยอะที่มิวิจัยอาจจะพิจารณาแยกการทำงานของระบบระบุตัวตนให้รันแยกอีกระบบและทำการส่งข้อมูลกันระหว่างกระบวนการทำงานของระบบ Elder Care v0.1 ผ่านการสื่อสารแบบ socket ผ่านเครือข่ายการเชื่อมต่อ (LAN) ในกรณีที่ต้องรันโมดูลการระบุตัวตนแยกเครื่อง และสื่อสารแบบการสื่อสารกันระหว่างโปรเซส (IPC: Inter process communication) ในกรณีที่ต้องรันโมดูลการระบุตัวตนบนเครื่องเดียวกัน อย่างไรก็ตามในซอฟต์แวร์ประมวลผลภาพเวอร์ชันล่าสุด (Elder Care Video Analytics v.0.3) ที่มิวิจัยได้แยกส่วนการรู้จำใบหน้าบุคคลให้ทำงานบนคลาวด์เนื่องจากต้องการลดภาระการประมวลผลบนอุปกรณ์ประมวลผลส่วนหน้า



รูปที่ 10 ตัวอย่างการรู้จำใบหน้าโดยใช้ซอฟต์แวร์ที่มิวิจัย AIT มีอยู่แล้ว

ระบบประมวลผลภาพ Elder Care Video Analytics v.0.3 ใช้ประโยชน์จากจุดโครงสร้างของร่างกายที่ตรวจจับได้ในการเลือกเฟรมในระหว่างการตามรอยเพื่อจะได้เฟรมที่ดีที่สุดในการนำไปเป็นข้อมูลนำเข้าสู่ระบบรู้จำใบหน้าบุคคล โดยในระหว่างการตามรอยเฟรมจะถูกเลือกเป็นเฟรมตัวแทนของการตามรอยนั้นเมื่อจุดข้อมูลโครงสร้างของร่างกายที่ตรวจจับได้มีจุดของตำแหน่ง ตาซ้าย ตาขวา หูซ้าย หูขวา และจมูก ในกรณีที่การตามรอยบุคคลไม่มีข้อมูลดังกล่าวเฟรมแรกที่ตรวจพบในการตามรอยจะถูกใช้เป็นเฟรมที่ใช้ในการรู้จำใบหน้าบุคคล หากระบบรู้จำใบหน้าบุคคลไม่สามารถตรวจหาตำแหน่งใบหน้าได้ระบบจะทำการระบุว่าเป็น “Unidentified” หรือไม่สามารถระบุตัวตนได้เนื่องจากไม่ตรวจพบใบหน้าบุคคลตลอดการตามรอยบุคคลนั้น นอกเหนือจากนั้นกรอบสี่เหลี่ยมที่ได้

จากข้อมูลจุดโครงร่างของร่างกายจะถูกขยายในแนวตั้งเพื่อให้กรอบสี่เหลี่ยมครอบคลุมพื้นที่บริเวณใบหน้าทั้งหมด ดังแสดงในรูปที่ 11



รูปที่ 11 จุดสี่เหลี่ยมแสดงตัวอย่างตำแหน่ง ตา หู และจมูก (ขวา) ซึ่งถูกนำมาพิจารณาในการเลือกเฟรม (ซ้าย) เพื่อใช้ในการรู้จำใบหน้า

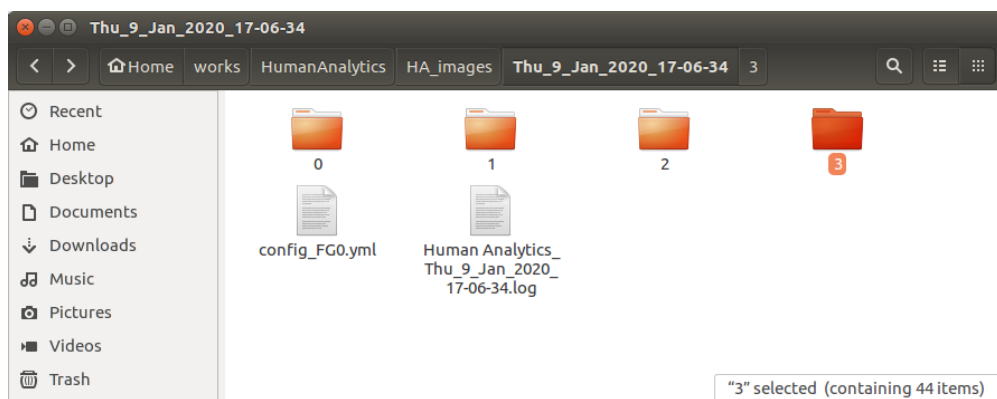
ทีมวิจัยใช้อัลกอริทึม Facenet ในการรู้จำใบหน้าบุคคลในครอบครัว ข้อมูลที่ถูกส่งมาจากอุปกรณ์ประมวลผลส่วนหน้าจะประกอบด้วยภาพที่เห็นใบหน้าบุคคลระหว่างการตามรอย ซึ่งจะถูกนำมาเปรียบเทียบกับภาพที่ผู้ใช้งานลงทะเบียนไว้ในระบบผ่านระบบเว็บแอปพลิเคชัน Elder Care เมื่อข้อมูลมาถึงระบบคลาวด์ Elder Care ภาพดังกล่าวจะถูกตรวจหาตำแหน่งใบหน้าอีกครั้ง และทำการจัดตำแหน่งใบหน้าบุคคล สาเหตุที่ทีมวิจัยเลือกส่งข้อมูลภาพเพียงหนึ่งภาพเพื่อลดภาระงานในการเขียนลงดิสก์และลดขนาดของข้อความที่ต้องส่งมายังระบบคลาวด์ เพื่อให้ระบบประมวลผลภาพบนอุปกรณ์ส่วนหน้ายังสามารถประมวลผลได้แบบเรียลไทม์ ตัวอย่างภาพที่ถูกป้อนเข้าสู่กระบวนการรู้จำใบหน้าและภาพใบหน้าที่ตรวจจับได้แสดงในรูปที่ 12 ข้อมูลการรู้จำใบหน้าบุคคลจะถูกเชื่อมโยง กับข้อมูลประเภทท่าทางที่แยกแยะได้จากการตามรอยบุคคล โดยการตามรอยบุคคลแต่ละครั้งจะประกอบด้วย ชุดข้อมูลจุดโครงร่างของร่างกายที่ตรวจพบในแต่ละเฟรม ข้อมูลภาพเฟรมที่มีการตรวจพบใบหน้าซึ่งจะมีเพียงภาพเดียวซึ่งเป็นเฟรมที่มีภาพใบหน้าบุคคล (ในกรณีที่ตรวจพบใบหน้าระหว่างการตามรอย) หรือ เป็นเฟรมที่ไม่มีภาพใบหน้าบุคคล (ในกรณีที่ระหว่างการตามรอยระบบไม่สามารถตรวจพบใบหน้าบุคคลเลย) ชุดข้อมูลจุดโครงร่างของร่างกายจะถูกนำไปแยกแยะประเภทท่าทาง ส่วนภาพที่ถูกใช้เป็นตัวแทนของการตามรอย (representative frame of tracking) จะถูกนำไปใช้ในการรู้จำใบหน้าบุคคล เพื่อระบุว่าข้อมูลประเภทท่าทางของการตามรายนั้นเป็นสมาชิกครอบครัวคนไหน



รูปที่ 12 รูปภาพข้อมูลนำเข้าสู่ระบบรู้จำใบหน้า (ซ้าย) ที่ได้มาระหว่างการตามรอย และภาพใบหน้าที่ตรวจจับและจัดตำแหน่งได้ (ขวา)

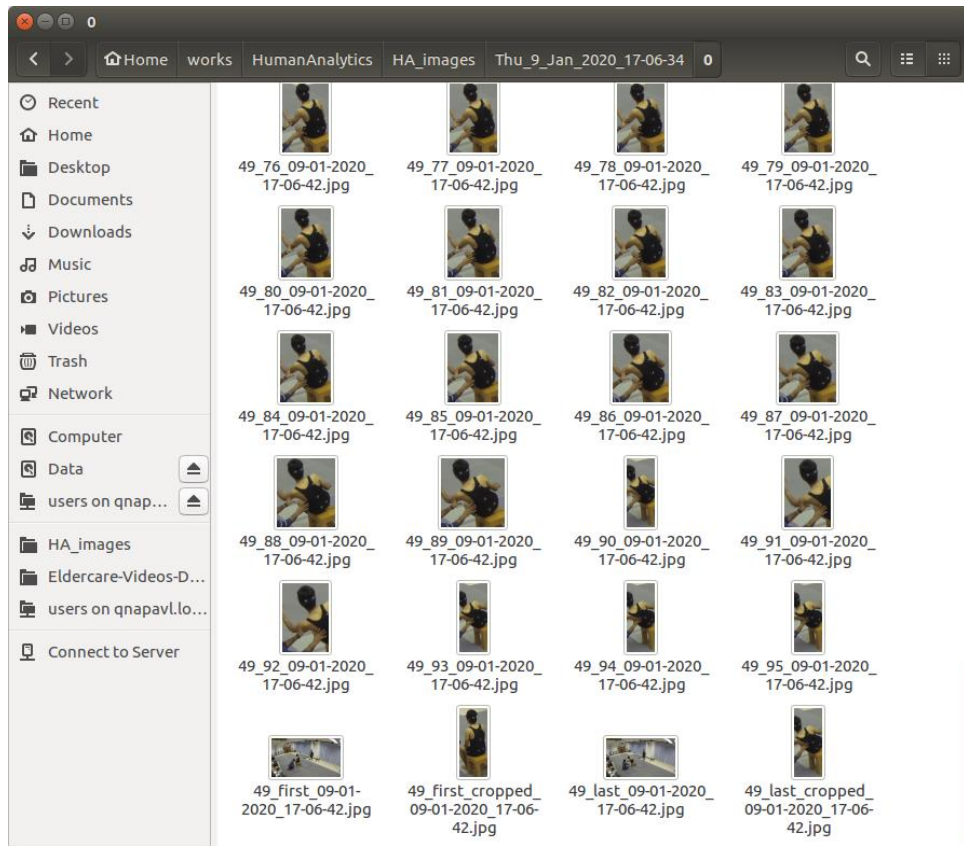
3.2.3 การเก็บบันทึกข้อมูลของระบบ

การเก็บบันทึกข้อมูลของระบบสามารถทำได้โดยแยกตามการตามรอยบุคคลที่ปรากฏและทำการบันทึกข้อมูลของแต่ละการตามรอยแยกตามโพลเดอร์ดังแสดงในรูปที่ 13 ซึ่งมีข้อมูลการตามรอยบุคคลทั้งหมดสี่ครั้งตามจำนวนโพลเดอร์ที่ปรากฏ



รูปที่ 13 ตัวอย่างข้อมูลที่ถูกบันทึกจากการตามรอยบุคคล

ในแต่ละโพลเดอร์จะเก็บข้อมูลบันทึกภาพในลักษณะของลำดับการเคลื่อนที่ของบุคคลตามการตามรอยและภาพต้นฉบับจากกล้อง ณ เฟรมที่เริ่มและสิ้นสุดการตามรอยบุคคล ดังแสดงในรูปที่ 14 และ รูปที่ 15 อย่างไรก็ตามเนื่องจากปัจจุบันยังอยู่ในช่วงของการวิจัยและพัฒนาระบบ ดังนั้นรูปที่บันทึกจึงยังเป็นไฟล์ภาพที่เห็นตัวบุคคล แต่หากการวิจัยและพัฒนาแล้วเสร็จสิ้น การบันทึกรูปภาพเหล่านี้จะบันทึกเฉพาะโครงร่างของร่างกายบนภาพพื้นหลังสีดำเพื่อรักษาความเป็นส่วนตัวของข้อมูลบุคคล หรือเก็บเฉพาะข้อมูลโครงร่างของร่างกายในรูปแบบพิกัดจุดตำแหน่งในรูปแบบของตัวอักษร (text file) เพียงอย่างเดียวในการใช้งานจริง



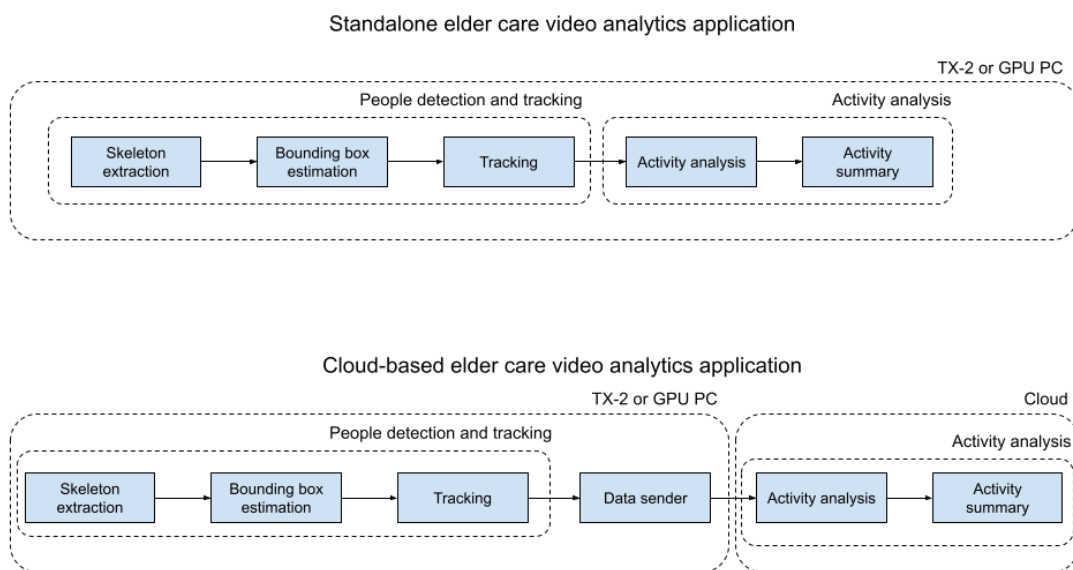
รูปที่ 14 ตัวอย่างข้อมูลภาพที่ถูกบันทึกในโฟลเดอร์



รูปที่ 15 ตัวอย่างภาพเฟรมเมื่อเริ่ม (ซ้าย) และสิ้นสุด (ขวา) การตามรอยบุคคล

3.3 ระบบแยกแยะท่าทางประเภทกิจกรรมต่าง ๆ รวมถึงการหกล้ม

ระบบแยกแยะท่าทางประเภทกิจกรรมต่าง ๆ รวมถึงการหกล้ม เป็นส่วนที่ทำงานต่อจาก การติดตามและตามรอยบุคคล ซึ่งทีมวิจัยพัฒนาให้มทำงานใน 2 รูปแบบหลัก คือ การทำงานแบบโพรเซสเดี่ยว (stand alone application) และ การทำงานแบบแบ่งการประมวลผล ร่วมกับระบบเว็บเซอร์วิสบนคลาวด์ โดยรูปที่ 16 เปรียบเทียบการทำงานระหว่าง 2 การทำงาน



รูปที่ 16 เปรียบเทียบขั้นตอนการทำงานระหว่างการทำงานแบบโพรเซสเดี่ยว และการทำงานแบบแบ่งการประมวลผลร่วมกับระบบเว็บเซอร์วิสบนคลาวด์

การทำงานแบบโพรเซสเดี่ยวจะประกอบด้วย การตรวจจับและติดตามบุคคล และการวิเคราะห์ประเภทท่าทางการเคลื่อนไหวซึ่งจะวิเคราะห์ท่าทางการเคลื่อนไหวของแต่ละบุคคลในแต่ละเฟรมที่ตรวจจับและตามรอยได้และทำการแยกประเภทท่าทางที่ตรวจจับได้ในแต่ละเฟรมและทำการสรุปข้อมูลประเภทท่าทางเมื่อการตามรอยบุคคลเสร็จสิ้น การทำงานแบบโพรเซสเดี่ยวดังกล่าวนี้เหมาะสำหรับการทำงานบนเครื่องคอมพิวเตอร์ที่มีหน่วยประมวลผลกราฟฟิก (GPU) เนื่องจากใช้ทรัพยากรในการประมวลผลมากโดยเฉพาะในส่วนของการแยกแยะประเภทท่าทางต่าง ๆ การประมวลผลแบบโพรเซสเดี่ยวนี้อาจไม่สามารถประมวลผลได้แบบเรียลไทม์บนบอร์ด TX-2 ดังนั้นทีมวิจัยจึงแยกส่วนการประมวลผลวิเคราะห์ประเภทท่าทางให้ทำงานบนคลาวด์

การทำงานแบบแบ่งการประมวลผล ร่วมกับระบบเว็บเซอร์วิสบนคลาวด์ ถูกออกแบบมาให้สามารถทำการประมวลผลแบบเรียลไทม์บนบอร์ด TX-2 ได้ ขั้นตอนการทำงานจะคล้ายกับการทำงานแบบโพรเซสเดี่ยว แต่จะเพิ่มส่วนของ การส่งข้อมูล (Data sender) เพื่อทำการรวบรวมข้อมูลและส่งข้อมูลผ่านระบบเครือข่ายเน็ตเวิร์คไปยัง ElderCare Web services APIs เพื่อทำการประมวลผลวิเคราะห์และสรุปประเภทท่าทางที่ตรวจพบของแต่ละบุคคลบนคลาวด์

ส่วนของการส่งข้อมูลจะทำหน้าที่ในการรวบรวมข้อมูลขณะตามรอยบุคคลและส่งข้อมูลไปยังระบบคลาวด์เพื่อแยกแยะประเภทท่าทางทุก ๆ 40 เฟรม โดยข้อมูลประกอบด้วยข้อมูลโครงร่างของร่างกาย (skeleton list) ข้อมูลหมายเลข การตามรอยบุคคล (track ID) หมายเลขกล้องที่ติดตั้ง (camera ID) และ หมายเลขบ้าน (house ID) การทำงานของการวิเคราะห์ประเภทท่าทาง การเคลื่อนไหวจะทำทุก ๆ 40 เฟรม เพื่อใช้ในการสรุปข้อมูลและบันทึกข้อมูลลงในระบบฐานข้อมูลเพื่อนำข้อมูลส่งต่อไปให้ระบบ แจ้งเตือนในกรณีที่ตรวจพบการหกล้ม หรือการเคลื่อนไหวที่ไม่มั่นคง รายละเอียดของการทำงานการสรุปข้อมูลประเภทท่าทางที่ทำงานบนคลาวด์จะอธิบายในรายละเอียดในหัวข้อ 3.9 ระบบส่วนหลัง (Backend system)

ทีมวิจัยได้ทำการวิจัยและพัฒนาอัลกอริทึมสำหรับการรู้จำประเภทท่าทางโดยแบ่งเป็น 3 อัลกอริทึมหลัก อัลกอริทึมแรกที่ใช้เทคนิคการเรียนรู้เชิงลึกในการแยกแยะประเภทท่าทางโดยอาศัยข้อมูลนำเข้าเป็นตำแหน่งจุดโครงร่างของร่างกายในปริภูมิ 2 มิติบนข้อมูลภาพที่ละเฟรม (Frame-wise activity classification) อัลกอริทึมที่สองใช้เทคนิคคล้ายกับอัลกอริทึมแรกแต่เพิ่มในส่วนการแยกแยะประเภทท่าทางแบบเป็นลำดับชั้น (Cascade frame-wise activity classification) โดยมีโมเดลแยกแยะประเภทท่าทาง pre classifier และ post classifier ส่วนอัลกอริทึมที่สามที่ใช้ Long Short-term Memory (LSTM) ในการแยกแยะประเภทท่าทาง ซึ่งใช้ลำดับข้อมูลของจุดโครงร่างของร่างกายในปริภูมิ 2 มิติเป็นข้อมูลนำเข้าระบบระบบแยกแยะประเภทท่าทางจำนวน 10 ประเภท ได้แก่

- นิ่ง
- ยืน
- เดิน
- ก้มตัว
- ล้ม
- คุนาฬิกา
- โบกมือ
- ชู
- คู้โทรศัพท์
- ประหม้อมือ

รายละเอียดของแต่ละอัลกอริทึมถูกอธิบายในรายละเอียดในหัวข้อต่อไป

3.3.1 การแยกแยะประเภทท่าทางแบบที่ละเฟรม (Frame-wise Activity Classification)

ขั้นตอนการทำงานของระบบจะประกอบด้วยสี่ขั้นตอนหลักดังแสดงในรูปที่ 17 ประกอบด้วย การรับเฟรมเป็นข้อมูลนำเข้า และทำการดึงข้อมูลจุดโครงร่างของร่างกาย ทำการตามรอยบุคคลเพื่อเก็บข้อมูลท่าทางขณะบุคคลเคลื่อนที่ และทำการแยกแยะประเภทท่าทาง การสรุปข้อมูลประเภท

ท่าทางของการตามรอยบุคคล จะยึดตามประเภทท่าทางที่มีการทำนายบ่อยครั้งที่สุดในการตามรอยบุคคล



รูปที่ 17 ขั้นตอนการทำงานของ การแยกแยะประเภทท่าทางแบบทีละเฟรม

- **ภาพข้อมูลนำเข้า:** ระบบจะทำการรับวิดีโอสตรีมจากกล้อง IP ที่มีความละเอียด 1920x1080 พิกเซล และทำการลดขนาดเฟรมเหลือ 656x368 พิกเซล เพื่อให้ตรงกับขนาดของ Convolutional Neural Network ที่ใช้ในการหาตำแหน่งจุดโครงร่างของร่างกายก่อนนำไปประมวลผล
- **การดึงข้อมูลจุดโครงร่างของร่างกายโดยการใช้ OpenPose:** ทีมวิจัยใช้ OpenPose เพื่อแยกจุดโครงร่างของร่างกายในแต่ละเฟรม OpenPose ถูกออกแบบและเทรนโดยใช้ convolutional neural network เพื่อคำนวณ heatmap บนภาพเพื่อหาตำแหน่งจุดโครงร่างของร่างกาย และเชื่อมต่อเข้าด้วยกันโดยใช้คุณลักษณะ Part Affinity Fields (PAFs) ซึ่งจะมีข้อมูลตำแหน่งและทิศทางการวางตัวของข้อต่อต่าง ๆ ของร่างกาย ทีมวิจัยใช้จุดข้อมูลโครงร่างของร่างกายจำนวน 18 จุด โดยใช้โมเดลที่เทรนจากชุดข้อมูล COCO กรอบสี่เหลี่ยมล้อมรอบจุดโครงร่างของร่างกายจะถูกนำมาใช้ในการตามรอยบุคคล
- **การตามรอยบุคคล:** สำหรับการเตรียมข้อมูลเพื่อเทรนโมเดล ทีมวิจัยใช้อัลกอริทึม DeepSORT ในการตามรอยบุคคลเนื่องจากอัลกอริทึม DeepSORT สามารถทำงานได้ดีในกรณีที่มีการบดบังกันของตัวบุคคล หรือมีการบดบังจากวัตถุอื่น ๆ ในมุมมอง แต่สำหรับการใช้งานจริงและประมวลผลบนอุปกรณ์ประมวลผลส่วนหน้านั้น ทีมวิจัยใช้การตามรอยบุคคลโดยคำนวณจากอัตราส่วน Intersection over Union (IOU) แทนเนื่องจากข้อจำกัดในด้านทรัพยากรการประมวลผล ข้อมูลนำออกจากการตามรอยบุคคลจะประกอบด้วยข้อมูลโครงร่างของร่างกายในปริภูมิ 2 มิติในแต่ละเฟรมที่มีการตามรอยบุคคล
- **การแยกแยะประเภทท่าทาง:** ทีมวิจัยใช้ไลบรารี Keras ในการสร้าง sequential model โดยให้ขนาดอินพุตเป็น 36 ซึ่งเป็นขนาดของจำนวนจุดโครงร่างของร่างกายทั้ง 18 จุดโดยแต่ละจุดมีข้อมูลในปริภูมิ 2 มิติของแกน x และ y ในการเทรนโมเดล ทีมวิจัยดึงข้อมูลโครงร่างของร่างกายแต่ละเฟรมที่ได้จากการตามรอยบุคคลและกำหนดประเภทท่าทางของแต่ละเฟรม เพื่อเป็นข้อมูลสำหรับเทรนโมเดล โดยทีมวิจัยได้ออกแบบ sequential model ที่ประกอบด้วย dense layer จำนวน 4 เลเยอร์ แต่ละ dense layer จะตามด้วย batch normalization layer เพื่อที่จะ optimize การเทรนเน็ตเวิร์คและอนุญาตให้ค่า learning rate มีค่าสูงขึ้นได้ ส่วน dense layer ชั้นสุดท้ายจะใช้ Softmax เป็น activation function โดยมีขนาดขึ้นอยู่กับจำนวนประเภทท่าทางที่ต้องการแยกแยะ ในการเทรนโมเดลใช้ Adam optimizer และใช้ categorical entropy เป็น loss function ในการเทรนโมเดล โดยกำหนด batch size ขนาด 32 และเทรน 20 epochs เมื่อเทรนโมเดลเสร็จ โมเดลจะถูก

นำไปใช้ในการแยกแยะประเภทท่าทางโดยใช้ข้อมูลนำเข้าเป็นตำแหน่งจุดโครงร่างของร่างกายในปริภูมิ 2 มิติของแต่ละเฟรมที่ได้จากการตามรอยบุคคล

สำหรับการประมวลผลบนบอร์ด TX-2 การดึงข้อมูลโครงร่างของร่างกายจะใช้ trt-pose ส่วนการตามรอยบุคคลใช้ Intersection over Union (IoU) แทน ส่วนการแยกแยะประเภทท่าทางใช้โมเดลเดียวกันแต่เป็นการรันบนระบบคลาวด์

3.3.1.a การตรวจจับการหกล้มแบบทีละเฟรม

หัวข้อ 3.3.1 การแยกแยะประเภทท่าทาง ได้อธิบายถึงหลักการทำงานและโครงสร้างของเน็ตเวิร์คที่ใช้ในการแยกแยะประเภทท่าทางทีละเฟรม ซึ่งสำหรับการตรวจจับการหกล้มที่มิวิจัยใช้เน็ตเวิร์คเดียวกันในการแยกแยะประเภทท่าทางซึ่ง การหกล้ม ก็เป็นหนึ่งในประเภทท่าทางที่ระบบจะทำการแยกแยะ เนื่องด้วยลักษณะและอัลกอริทึมที่ใช้ในการตรวจจับการล้มคืออัลกอริทึมเดียวกับกับหัวข้อ 3.3.1


3.3.2 การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่น (Cascade Framewise Activity Classification)

การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่นเป็นการพัฒนาต่อยอดจากอัลกอริทึมที่อธิบายในหัวข้อ 3.3.1 การแยกแยะประเภทท่าทางแบบทีละเฟรม

กิจวัตรประจำวันของผู้สูงอายุมีหลากหลายรูปแบบ เช่น กิจกรรมสันทนาการ การพักผ่อน การพูดคุย เป็นต้น การออกกำลังกาย การทำความสะอาด การรับประทานอาหาร การทำอาหาร การอ่านหนังสือ การดูทีวี หรือ การฟังเพลง การสนทนา [54-56] และอื่น ๆ ซึ่งมีลักษณะการวางตำแหน่งตัวและท่าทางมือแตกต่างกัน จากท่าทางหลากหลายประเภทที่มิวิจัยได้เลือกท่าทางหลักของลำตัว (body postures) ที่มีในการเคลื่อนไหวของกิจวัตรประจำวันทั่วไป ได้แก่ นั่ง ยืน เดิน เอนตัว/ก้มตัว ในส่วนของการเคลื่อนไหวที่เกี่ยวกับท่าทางมือ ที่มิวิจัยเลือกท่าทาง การปรบมือ ตูนาฬิกา คุยโทรศัพท์ ชี้ และ โบกมือ สำหรับท่าทางที่เกี่ยวข้องกับกิจกรรม สันทนาการ การพักผ่อน หรือ การพูดคุยติดต่อสื่อสาร รวมถึงท่าทางการล้มซึ่งเป็นคุณลักษณะของระบบที่สำคัญที่สุด ที่มิวิจัยเทรนโมเดลเพื่อตรวจจับท่าทางดังกล่าวทั้งหมด 10 ท่าทาง

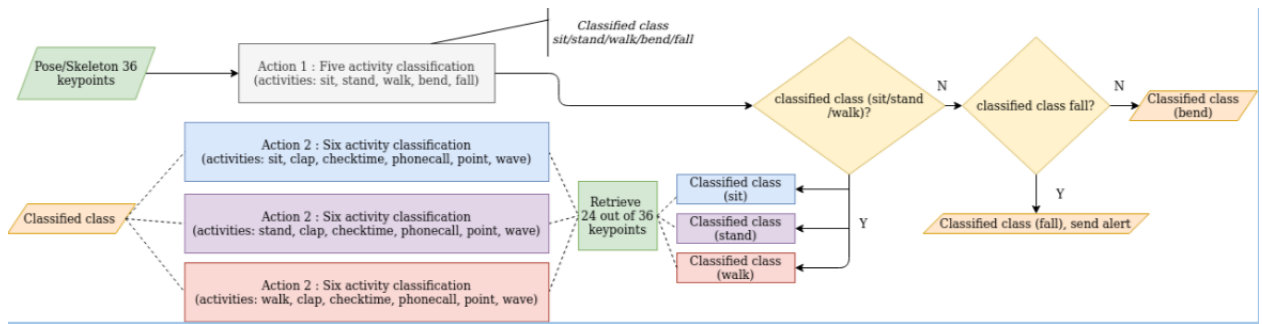
ในการเทรนและทดสอบโมเดลในบางมุมมอง โครงร่างของร่างกายนั้นสามารถมองเห็นได้แค่เพียงบางส่วน ซึ่งทำให้เกิดความกำกวมของโมเดลในการแยกแยะประเภทท่าทางทั้ง 10 ประเภท ดังนั้นการมองเห็นส่วนของแขนทั้งสองจึงมีความสำคัญในการแยกแยะท่าทางที่เกี่ยวข้องกับการใช้มือและแขนเป็นหลัก จากชุดข้อมูลที่มิวิจัยเก็บบันทึก ข้อมูลความหลากหลายของกิจกรรมขณะเดินนั้นมีน้อยมาก ถ้าที่มิวิจัยเทรนโมเดลเฉพาะส่วนบนของร่างกาย โมเดลจะสามารถแยกแยะประเภทท่าทางได้อย่างถูกต้องและไม่ขึ้นกับท่าทางส่วนล่างของลำตัว เช่น นั่ง ยืน เดิน เนื่องจากมีกิจกรรมท่าทางอื่น ๆ นอกเหนือจาก ปรบมือ ตูนาฬิกา คุยโทรศัพท์ ชี้ และ โบกมือ ที่มิวิจัยจึงทำการเทรนโมเดลให้สามารถแยกแยะท่าทางที่เกี่ยวข้องกับการเคลื่อนไหวของแขนและมือ ขณะ นั่ง ยืน และ เดิน

ด้วยเหตุผลดังกล่าวที่มิวิจัยจึงออกแบบอัลกอริทึมให้มีการแยกแยะประเภทท่าทางแบบลดหลั่น โดยออกแบบโมเดลที่เรียกว่า ‘Preclass’ สำหรับการแยกแยะประเภทท่าทางหลักที่เกี่ยวข้องกับตำแหน่งการวางตัวของลำตัว เช่น นั่ง ยืน เดิน เอนตัว/ก้มตัว และหกล้ม ตัวอย่างเช่น ท่า นั่งอาจประกอบด้วยลักษณะการวางตัวของลำตัวหลากหลายแบบ เช่น นั่งบนเก้าอี้ นั่งบนพื้น นั่งบนม้านั่ง ในขณะที่ท่าทางอย่างอื่น เช่น ดูนานฬิกา ปรบมือ ค่อยโทรศัพท์ ชี้ และ โบกมือ หรือในกรณีที่ตัวบุคคลเห็นเฉพาะมุมมองด้านข้างของร่างกายในขณะที่นั่ง ซึ่งโครงสร้างของร่างกายเห็นเพียงเฉพาะส่วนบนของร่างกาย หรือมุมมองด้านหลังของบุคคลขณะนั่งซึ่งเห็นหัวเข้าเพียงข้างเดียว ดังนั้นเมื่อบุคคลกำลังพูดคุยโทรศัพท์แต่ภาพในมุมมองกล้องเห็นเพียงบางส่วนของร่างกาย โมเดลจะทำการแยกแยะท่าทางโดยใช้ข้อมูลจากส่วนบนของโครงสร้างของร่างกายแทนที่จะใช้ข้อมูลทั้งหมด เพื่อไม่ให้แยกแยะท่าทางผิดประเภทเนื่องจากไม่มีข้อมูลโครงสร้างของร่างกายในส่วนที่มองไม่เห็น รูปที่ 18 แสดงตัวอย่างของเฟรมที่ต่อเนื่องกันซึ่งโครงสร้างของร่างกายเห็นแค่เพียงบางส่วนซึ่งโมเดลจะแยกแยะประเภทเป็น ท่าทางการยืน ที่มิวิจัยใช้การทำงานในรูปแบบดังกล่าวกับท่าทางการ ยืน และเดิน โดยโมเดลที่ออกแบบนี้เรียกว่า ‘Postclass’ อย่างไรก็ตามท่าทาง การเอนตัว/ก้มตัว และท่าทางการล้ม ไม่ถูกนำเทรนในรูปแบบของ Postclass เนื่องจากท่าทางสองท่าทางนี้เกิดขึ้นในช่วงเวลาอันสั้น



รูปที่ 18 ตัวอย่างของเฟรมที่ต่อเนื่องกันซึ่งโครงสร้างของร่างกายเห็นแค่เพียงบางส่วน

การทำงานของ การแยกแยะประเภทท่าทาง 10 ประเภท ประกอบด้วย โมเดลสำหรับแยกแยะประเภทท่าทางแบบเป็นลำดับขั้น (hierarchical classifier) เพื่อใช้ในการแยกแยะประเภทท่าทาง หรือเรียกอีกอย่างหนึ่งว่า การแยกแยะประเภทท่าทางที่ละเฟรมแบบลดหลั่น (cascade framewise activity classification) แนวคิดในการแยกแยะประเภทท่าทางทั้ง 10 ได้ถูกอธิบายไว้ข้างต้น ที่มิวิจัยระบุท่าทางหลัก ได้แก่ นั่ง ยืน เดิน เอนตัว/ก้มตัว และล้ม และระบุท่าทางรอง ได้แก่ ดูนานฬิกา ปรบมือ ค่อยโทรศัพท์ ชี้ และ โบกมือ โมเดลสำหรับแยกแยะท่าทางหลัก ใช้ข้อมูลโครงสร้างของร่างกาย 36 จุด ในการเทรนโมเดล โมเดลสำหรับแยกแยะท่าทางรอง มี 3 โมเดลย่อยซึ่งแยกสำหรับแต่ละท่าหลัก (นั่ง, ยืน และ เดิน) ซึ่ง ทั้งสามโมเดลมีข้อมูลโครงสร้างของร่างกายในท่าทาง ปรบมือ ดูนานฬิกา ค่อยโทรศัพท์ ชี้ และ โบกมือ และ ท่าทางหลักหนึ่งท่าทางจากท่าทาง นั่ง ยืน หรือเดิน โดยใช้จุดโครงสร้างของร่างกาย 24 จุด รูปที่ 19 แสดงขั้นตอนการทำงานของ การแยกแยะท่าทางแบบที่ละเฟรมแบบลดหลั่น



รูปที่ 19 ขั้นตอนการทำงานของการทำงานการแยกแยะท่าทางแบบที่ละเฟรมแบบลดหลั่น

โดยทีมวิจัยเทรนโมเดลทั้งหมด 4 โมเดล โดยโมเดลแรก (pre classifier) หรือเรียกอีกอย่างหนึ่งว่า Activity-1 จะแบ่งประเภทท่าทางออกเป็น 5 ประเภท คือ นั่ง ยืน เดิน เอนตัว และ ล้ม เทรนโดยใช้ 36 keypoints ส่วนโมเดลที่สอง (post classifier) หรือเรียกอีกอย่างหนึ่งว่า Activity-2 ซึ่งประกอบด้วย 3 โมเดลย่อยเทรนบน 24 keypoints ดังที่ได้อธิบายไว้ข้างต้น

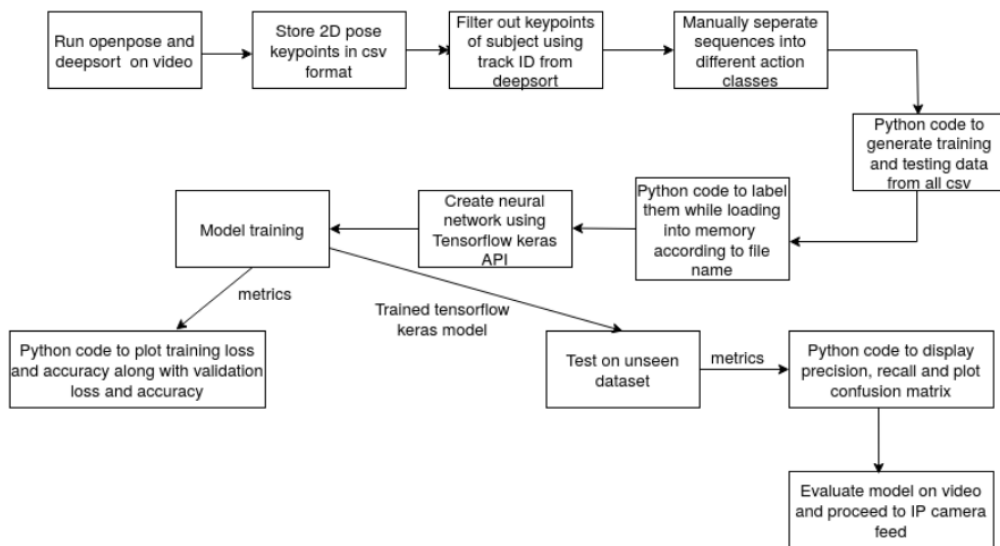
โดยโครงสร้างเน็ตเวิร์กประกอบด้วย dense layer จำนวน 5 เลเยอร์ และตามด้วย batch normalization โดยทั้ง 5 เลเยอร์ใช้ ReLU เป็น activation function ในส่วนของเลเยอร์ output ใช้ softmax เป็น activation function โครงสร้างเน็ตเวิร์กดังกล่าวในการเทรนโมเดลที่แตกต่างกัน 4 โมเดล โดยยึดข้อมูล 2 คลาสเป็นหลัก คือ โมเดลที่เรียกว่า 'preclass' จำนวน 1 โมเดล ซึ่งประกอบด้วยชุดข้อมูล 5 ประเภทหลักได้แก่ นั่ง ยืน เดิน เอนตัว และ ล้ม ส่วนอีกโมเดลเรียกว่า 'postclass' อีก 3 โมเดล ซึ่งประกอบด้วยชุดข้อมูล 5 ประเภทได้แก่ ปรบมือ ดุนาฬิกา ชี้ คูยโทรศัพท์ และ โบกมือ ประกอบกับชุดข้อมูล 3 ประเภทหลัก คือ นั่ง เดิน และ ยืน สำหรับแต่ละโมเดล โมเดล preclass ถูกเทรนโดยใช้โครงสร้างเน็ตเวิร์กดังได้อธิบายไว้ข้างต้น โดย output layer ประกอบด้วย 5 คลาส ส่วนโมเดล postclass ถูกเทรนโดยใช้โครงสร้างเน็ตเวิร์กดังได้อธิบายไว้ข้างต้น โดย output layer ประกอบด้วย 6 คลาส กล่าวคือ ในแต่ละโมเดล postclass เช่น โมเดล postclass-sit จะประกอบด้วยคลาส ปรบมือ ดุนาฬิกา ชี้ คูยโทรศัพท์ โบกมือ และ นั่ง สำหรับโมเดล postclass-stand จะประกอบด้วยคลาส ปรบมือ ดุนาฬิกา ชี้ คูยโทรศัพท์ โบกมือ และ ยืน สำหรับโมเดล postclass-walk จะประกอบด้วยคลาส ปรบมือ ดุนาฬิกา ชี้ คูยโทรศัพท์ โบกมือ และ เดิน

3.3.3 การแยกแยะประเภทท่าทางแบบที่ละหลายเฟรม (LSTM Activity Classification)

การทำท่าทางต่าง ๆ จะประกอบไปด้วยลำดับการเคลื่อนไหวของร่างกายซึ่งมีความสัมพันธ์ในการเคลื่อนที่ส่วนต่าง ๆ ของร่างกาย ท่าทางบางประเภท เช่น ล้ม และ การเดิน ที่มีการเคลื่อนไหวของร่างกายหลายส่วนและเกิดขึ้นรวดเร็ว ซึ่งอาจจะสามารถตรวจพบได้ในเวลาสั้น หรือนอกจากนั้นท่าทางการเดินและยืนในสภาวะคงที่ สามารถจะถูกมองว่าคล้ายกัน เนื่องจากอยู่ในแนวตั้ง แต่หากพิจารณาข้อมูลในรูปแบบลำดับจะสังเกตเห็นความแตกต่างได้อย่างชัดเจน ดังนั้นจึงเป็นที่มาของการประยุกต์ใช้ Long Short-term Memory (LSTM) ซึ่งเป็นเน็ตเวิร์คที่สามารถดึงข้อมูลในเชิงลำดับ ที่มีความเชื่อมโยงกันระหว่างเฟรม รวมถึงคุณลักษณะสำคัญของ LSTM ที่สามารถ

เรียนรู้คุณลักษณะเชิงลำดับเวลาที่มีอยู่ในข้อมูลที่เป็นลำดับ เพื่อใช้ในการแยกแยะประเภทท่าทางต่าง ๆ โดยใช้ข้อมูลนำเข้าเป็นข้อมูลโครงสร้างของร่างกายตามลำดับเวลา ข้อมูลตำแหน่งโครงสร้างของร่างกายในปริภูมิ 2 มิติตามลำดับเวลา (กล่าวคือ ข้อมูลตำแหน่งโครงสร้างของร่างกายจากเฟรมที่ต่อเนื่องกัน) กับข้อมูลการระบุประเภทท่าทางในแต่ละเฟรม จะถูกนำมาใช้ในการเทรนโมเดล LSTM ที่วิจัยใช้เน็ตเวิร์คโมเดลที่ประกอบด้วย LSTM 2 เลเยอร์ โดยเลเยอร์แรกใช้สำหรับการประมวลผลข้อมูลนำเข้า และเลเยอร์ที่สองทำหน้าที่ในการทำนายค่าความน่าจะเป็นของท่าทางประเภทต่าง ๆ กระบวนการเทรนโมเดลและทดสอบโมเดล LSTM เพื่อใช้ในการแยกแยะประเภทท่าทางต่าง ๆ ในรูปที่ 20

LSTM model train and test flow for action classification experiments.



รูปที่ 20 กระบวนการเทรนและทดสอบโมเดล LSTM สำหรับการแยกแยะประเภทท่าทาง

3.3.3.a การตรวจจับการทกล้มโดยใช้เทคนิค LSTM โดยใช้ข้อมูลที่เป็นลำดับ

แนวความคิดหลักภายใต้การใช้ LSTM RNN คือการใช้ข้อมูลเชิงลำดับของตำแหน่งโครงสร้างของร่างกายที่มีอยู่ในท่าทางต่าง ๆ ซึ่ง LSTM เป็นอัลกอริทึมที่สามารถสกัดข้อมูลจากลำดับข้อมูลได้ โดยลำดับข้อมูลอาจจะเป็นข้อมูล synchronous หรือ asynchronous ก็ได้ การที่อัลกอริทึมขึ้นอยู่กับเวลาเป็นประโยชน์ในการเรียนรู้รูปแบบหรือคุณลักษณะของจุดข้อมูลโครงสร้างของร่างกาย โดยเฉพาะอย่างยิ่งเมื่อเกิดการทกล้มในขณะยืน หรือ เดิน ข้อมูลของจุดโครงสร้างของร่างกายเชิงลำดับเวลาจะเป็นประโยชน์อย่างมากในการแยกแยะท่าทางประเภทนี้

ความแตกต่างระหว่าง LSTM กับ RNN แบบปกตินั้นมาจากการใช้ลอจิกเกต 3 รูปแบบเพื่อควบคุมการไหลของข้อมูล ลอจิกเกต 3 ประเภทนี้ได้แก่ forget gate, input gate และ output gate ซึ่งช่วยในการแก้ปัญหา vanishing gradient problem ซึ่งเกิดขึ้นเมื่อทำการประมวลผลกับ

ลำดับข้อมูลที่ยาว รูปแบบพื้นฐานของ LSTM คือ single cell ที่ประกอบด้วย 4 neural layer ซึ่งประกอบด้วยเลเยอร์ tanh 1 เลเยอร์ และ sigmoid 3 เลเยอร์ ดังนั้น LSTM จึงสามารถเก็บข้อมูลเพื่อนำมาใช้ได้ในภายหลังโดยการรักษา internal hidden state ซึ่งถูกส่งข้อมูลมาจาก LSTM cell ข้างเคียง

หากให้ x_t เป็นข้อมูลนำเข้าของระบบ ณ เวลา t LSTM cell จะถูกอัปเดต states โดยอ้างอิงจาก states ก่อนหน้า ณ เวลา $t-1$ โดยสมการของ input, forget, และ output gate แสดงดังสมการดังต่อไปนี้

$$\begin{aligned} i_t &= \sigma(W_i[h_{t-1}, X_t] + b_i) \\ f_t &= \sigma(W_f[h_{t-1}, X_t] + b_f) \\ o_t &= \sigma(W_o[h_{t-1}, X_t] + b_o) \\ \tilde{c}_t &= \tanh(W_c[h_{t-1}, X_t] + b_c) \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ h_t &= o_t \odot \tanh(c_t) \end{aligned}$$

ที่ซึ่ง แสดงถึง sigmoid function, tanh แสดงถึง hyperbolic tangent function และแสดงถึงการคูณแบบ element-wise ในเลเยอร์ tanh ค่าจะถูกแปลงให้อยู่ในช่วง -1 และ 1 ในขณะที่ในเลเยอร์ sigmoid ค่าจะถูกแปลงให้อยู่ในช่วง 0 และ 1 ส่วน 'W' หมายถึง weight matrices ของแต่ละเกต ดังนั้น Cell state C_t จึงกำหนดโดยการรวม i_t , f_t และ o_t

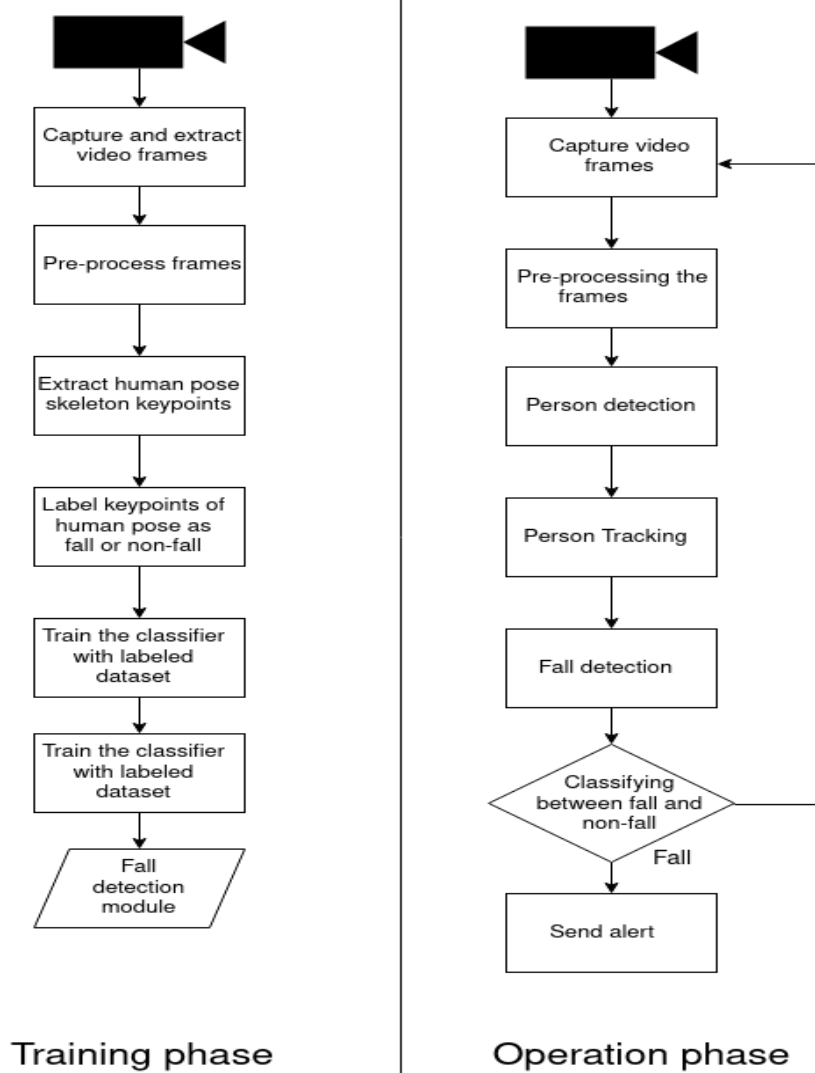
Cell state C_t ทำหน้าที่ในการส่งข้อมูลข้ามช่วงเวลา โดยที่ข้อมูลจาก Cell state จะถูกรวมเข้ากับข้อมูล input และ recurrent โดยทำการ dot product กับ weight matrix และบวกค่า bias b จากนั้นจะถูกส่งต่อไปยัง activation function เพื่อทำการส่งต่อข้อมูลไปยังช่วงเวลาถัดไป

ด้วยคุณลักษณะในการเก็บข้อมูลและส่งต่อข้อมูลตามลำดับเวลาของ LSTM ทำให้โครงสร้างเน็ตเวิร์ครูปแบบดังกล่าวนี้เหมาะสำหรับการนำมาใช้กับข้อมูลเชิงลำดับเวลาของจุดโครงร่างของร่างกายที่สกัดข้อมูลได้จากแต่ละเฟรม นำมาสร้างเป็นลำดับข้อมูลของจุดโครงร่างของร่างกายในปริภูมิ 2 มิติ โดยที่รูปแบบท่าทางกิจกรรมประเภทต่าง ๆ มีลำดับการเคลื่อนที่เป็นลำดับของจุดโครงร่างของร่างกาย ทีมวิจัยจึงประยุกต์ใช้ LSTM ในการแยกแยะประเภทท่าทางโดยที่ใช้ข้อมูลนำเข้าระบบเป็นข้อมูลที่เป็นลำดับตามเวลาของจุดโครงร่างของร่างกายในปริภูมิสองมิติ

ข้อมูลที่เป็นลำดับจะสามารถให้ข้อมูลการเคลื่อนไหวซึ่งสามารถนำมาใช้เป็นหนึ่งคุณลักษณะสำหรับโมเดล LSTM RNN (Long Short-term Memory Recurrent Neural Network) เพื่อใช้ในการทำนายการหกล้มได้ โดยทีมวิจัยได้ใช้ชุดข้อมูลหกล้มของ AIT โดยจัดเตรียมชุดข้อมูลท่าทางการหกล้มโดยดึงภาพแต่ละเฟรมขณะตัวบุคคลกำลังหกล้ม โดยที่ข้อมูลในแต่ละเฟรมจะประกอบด้วยข้อมูลจุดข้อมูลโครงร่างของร่างกายจำนวน 18 จุด ลำดับของข้อมูลจะถูกรวบรวมจากแต่ละเฟรมของวิดีโอจำนวนหลายเฟรมตามลำดับ และทำการระบุประเภทของท่าทางจากแต่ละวิดีโอ และทำการจัดจำนวนเฟรมข้อมูลให้เท่ากัน โดยทีมวิจัยเลือกจำนวนเฟรม 40 เฟรม เนื่องจากเป็นช่วงเวลาที่ครอบคลุมท่าทางการเดินซึ่งใช้เวลานานกว่าท่าทางประเภทอื่น สำหรับท่าทางที่มีจำนวนเฟรมน้อยกว่า 40 เฟรม ข้อมูลที่ขาดหายจะถูกเติมด้วยค่า 0

ในการเทรนโมเดลที่วิจัยใช้ masking layer เป็นเลเยอร์แรกเพื่อให้ LSTM ไม่พิจารณาช่วงเวลาที่ไม่มีข้อมูล และใช้ recurrent dropout เพื่อป้องกันการ overfitting ในขณะที่เทรนโมเดลขั้นตอนในการเทรน LSTM สำหรับการตรวจจับการหกล้มแสดงในรูปที่ 46 (ซ้าย)

ภายหลังจากได้โมเดล LSTM ที่เทรนแล้วในการใช้งานจริงข้อมูลนำเข้าจะต้องอยู่ในรูปแบบของลำดับจุดโครงร่างของร่างกายที่ได้จากแต่ละเฟรมจำนวน 40 เฟรม และส่งเข้าสู่โมเดล LSTM เพื่อทำการแยกแยะว่าเป็นการหกล้มหรือไม่ ขั้นตอนการทำงานแยกแยะการล้มแสดงในรูปที่ 21 (ขวา) อย่างไรก็ตามในการใช้งานจริงการประมวลผลดังกล่าวจะอยู่บนคลาวด์โดยเรียกในรูปแบบ web services ซึ่งข้อมูลนำเข้าจะเป็นข้อมูลรูปแบบเดียวกัน



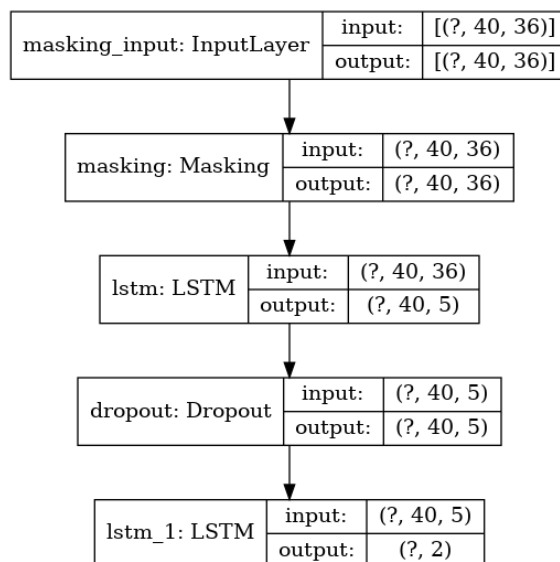
รูปที่ 21 ขั้นตอนการทำงานในการเทรนโมเดล LSTM (ซ้าย) และขั้นตอนการทำงานในการทดสอบโมเดล LSTM (ขวา)

ผลการทดลองและความแม่นยำของการใช้เทคนิค LSTM RNN สำหรับการตรวจจับการหกล้มถูกอธิบายในส่วนของการทดลอง

3.4 ระบบตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

การเคลื่อนไหวที่ส่วนต่าง ๆ ของร่างกายของแต่ละคนในระหว่างการเคลื่อนที่นั้นจะมีลักษณะเฉพาะของการเคลื่อนที่ ซึ่งเป็นสิ่งที่บ่งบอกได้ว่าเป็นการเคลื่อนที่แบบมั่นคงหรือไม่มั่นคง การเคลื่อนที่ส่วนต่าง ๆ ของร่างกายขณะเดินแบบไม่มั่นคงหรือหกล้มจะมีลักษณะที่ผิดปกติต่างไปจากการเคลื่อนไหวแบบปกติ หัวข้อ 3.3.3 ได้อธิบายถึงคุณลักษณะพิเศษของ LSTM RNN ในการเรียนรู้และสกัดข้อมูลความสัมพันธ์ของข้อมูลเชิงลำดับในช่วงเวลาหนึ่ง ๆ ได้ เมื่อพิจารณาการเคลื่อนไหวของบุคคล ณ จุดเวลาใดเวลาหนึ่ง เพื่อที่จะแยกแยะการเคลื่อนไหวที่ไม่มั่นคงข้อมูลจุดโครงร่างของร่างกายในเฟรมก่อนหน้าจึงมีความสำคัญ อัลกอริทึม LSTM จึงเหมาะสมในการนำมาใช้เพื่อสกัดข้อมูลเหล่านี้และรักษาเฉพาะข้อมูลที่มีความสำคัญ และลบข้อมูลที่ไม่มีความสำคัญออกผ่านกระบวนการทำงานของ input, forget และ output gate

ทีมวิจัยใช้ RNN กับ LSTM cells ในการตรวจจับการเคลื่อนไหวแบบไม่มั่นคง โดยโมเดลรับจุดโครงร่างของร่างกายจำนวน 36 จุด จากจำนวนเฟรม 40 เฟรม เป็นข้อมูลนำเข้าของเน็ตเวิร์กเพื่อทำการคาดการณ์การเคลื่อนไหวแบบไม่มั่นคง โดยทีมวิจัยใช้ LSTM layer ที่มี hidden layer จำนวน 5 layer และใช้ dropout 20% เพื่อป้องกันการ overfitting ของโมเดล และใช้ binary crossentropy เป็น loss function เนื่องจากเน็ตเวิร์กดังกล่าวใช้ในการแยกแยะประเภทข้อมูลเพียงสองประเภท คือ การเคลื่อนไหวแบบมั่นคง และการเคลื่อนไหวแบบไม่มั่นคง และใช้การกำหนดค่าน้ำหนักของแต่ละประเภทข้อมูลเพื่อให้ข้อมูลที่ใช้เทรนมีการกระจายตัว (uniform distribution) โครงสร้างเน็ตเวิร์กของโมเดลแสดงในรูปที่ 22



รูปที่ 22 โครงสร้างเน็ตเวิร์ก LSTM RNN สำหรับการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

การจัดเตรียมข้อมูลสำหรับการเทรนโมเดลทำในลักษณะเดียวกับการเตรียมข้อมูลสำหรับเทรนโมเดล LSTM เพื่อแยกแยะการหกล้ม โดยลำดับของข้อมูลจุดโครงร่างของร่างกายจะถูกเตรียมและทำการระบุประเภทท่าทางของแต่ละเฟรมว่าเป็นการเคลื่อนที่แบบมั่นคง หรือ ไม่มั่นคง

3.5 การเก็บรวบรวมชุดข้อมูลเพื่อใช้ในการเทรนโมเดล

ในการดำเนินโครงการวิจัยนี้ทีมวิจัยได้เก็บข้อมูลหลายชุดข้อมูลเพื่อนำมาวิเคราะห์และพัฒนาอัลกอริทึมที่ใช้ในการแยกแยะประเภทท่าทาง ตรวจสอบการหกล้ม รวมถึงตรวจจับการเคลื่อนไหวที่ไม่มั่นคง ข้อมูลภาพรวมของแต่ละชุดข้อมูลแสดงในตารางที่ 2

ตารางที่ 2 ภาพรวมของชุดข้อมูลทั้งหมดที่ใช้ในการออกแบบและพัฒนาระบบ

ลำดับที่	ชื่อชุดข้อมูล	วัตถุประสงค์	สถานที่จัดเก็บข้อมูล	รูปแบบการติดตั้งกล้อง
1	ชุดข้อมูลผู้สูงอายุผู้เคยมีและไม่มีประวัติการหกล้ม (Mahidol Elder Dataset)	เก็บข้อมูลการเคลื่อนไหวของอาสาสมัครผู้สูงอายุที่เคยมีและไม่มีประวัติการหกล้ม เพื่อใช้ในการวิเคราะห์การเคลื่อนไหวที่ไม่มั่นคงของผู้สูงอายุ และใช้ในการเทรนโมเดล	มหาวิทยาลัยมหิดล	ติดตั้งกล้องชั่วคราว 4 กล้อง และใช้เซ็นเซอร์ติดตามตัวอาสาสมัคร
2	ชุดข้อมูลการหกล้มของมหาวิทยาลัยมหิดล (Mahidol Fall Dataset)	เก็บข้อมูลท่าทางการหกล้มรูปแบบต่าง ๆ ในห้องทดลอง	มหาวิทยาลัยมหิดล	เหมือนชุดข้อมูลที่ 1
3	ชุดข้อมูล MoVi	ใช้ในการเทรนโมเดลเพื่อแยกแยะท่าทางต่าง ๆ	ชุดข้อมูลสาธารณะ	-
4	ชุดข้อมูล 360 องศา รอบตัวบุคคล (AIC-360)	ใช้ในการเทรนโมเดลเพื่อแยกแยะท่าทางต่าง ๆ รวมถึงการหกล้มและการเคลื่อนไหวที่ไม่มั่นคง	สถาบันเทคโนโลยีแห่งเอเชีย	ติดตั้งกล้องถาวร 8 กล้องในห้องทดลอง
5	ชุดข้อมูล AIC-Volunteer1-Set1	ใช้ในการเทรนโมเดลและทดสอบใช้งานระบบจริง	บ้านอาสาสมัคร กรุงเทพมหานคร	ติดตั้งกล้องถาวร 8 กล้อง
6	ชุดข้อมูล AIC-Volunteer1-Set2	ใช้ในการประเมินความแม่นยำของโมเดล	บ้านอาสาสมัคร กรุงเทพมหานคร	เหมือนชุดข้อมูลที่ 5
7	ชุดข้อมูล AIC Initial test	เก็บข้อมูลวิดีโอ ลักษณะมุมกล้องในบ้านอาสาสมัครหรือผู้ที่สนใจระบบ เพื่อทำการทดสอบเบื้องต้น และประเมินความแม่นยำของส่วนรู้จำใบหน้าบุคคล	บ้านอาสาสมัคร บ้านผู้ที่สนใจระบบ และออฟฟิศในสถาบันเทคโนโลยีแห่งเอเชีย	ติดตั้งกล้องชั่วคราว จำนวน 1 – 2 กล้อง เพื่อเก็บข้อมูล

ทั้งนี้เนื่องด้วยสถานการณ์การแพร่ระบาดของเชื้อโควิด-19 ทำให้ทีมวิจัยไม่สามารถเดินทางไปเก็บข้อมูลเพิ่มเติมจากบ้านอาสาสมัครในพื้นที่จังหวัดชัยนาท เพื่อนำมาใช้ในการเทรนโมเดล และเก็บข้อมูลเพื่อทดสอบและประเมินความแม่นยำของระบบได้

3.5.1 ชุดข้อมูลผู้สูงอายุผู้เคยมีและไม่มีประวัติการหกล้ม (Mahidol Elder Dataset)

เพื่อที่จะแยกแยะสิ่งที่สังเกตได้ของการเคลื่อนไหวที่ไม่มั่นคงซึ่งอาจจะนำไปสู่การเคลื่อนที่ที่ผิดปกติหรือนำไปสู่การหกล้ม ทีมวิจัยเอโอทีได้มีความร่วมมือกับมหาวิทยาลัยมหิดลเพื่อจัดเตรียมการจัดเก็บข้อมูลจากอาสาสมัครผู้สูงอายุ โดยเก็บข้อมูลที่มหาวิทยาลัยมหิดล ศาลายา

a) หลักเกณฑ์การเก็บข้อมูล

เพื่อให้ได้ข้อมูลที่สมจริง อาสาสมัครจะถูกคัดเลือกจากทีมผู้เชี่ยวชาญจากมหาวิทยาลัยมหิดล โดยคัดกรองจากบุคคลผู้มีประวัติเคยหกล้มและไม่เคยหกล้ม ที่มีอายุระหว่าง 60-75 ปี โดยทำการเก็บข้อมูลจากอาสาสมัครจำนวน 20 คน การเก็บข้อมูลใช้การติดมาร์กเกอร์จำนวน 39 มาร์กเกอร์บนร่างกายของผู้สูงอายุ และติด มาร์กเกอร์จำนวน 2 มาร์กเกอร์ลงบนวัตถุหรือสิ่งกีดขวาง รวมทั้งสิ้น 41 มาร์กเกอร์ ข้อมูลมาร์กเกอร์เหล่านี้จะเก็บโดยระบบ VICON และเป็นข้อมูลในปริภูมิสามมิติ ผู้สูงอายุจะทำการปฏิบัติท่าทาง 6 ท่าทางระหว่างการเก็บข้อมูล ได้แก่ นั่งแล้วยืน เดินแบบสบาย เดินเร็ว พุดขณะเดิน เดินข้ามสิ่งกีดขวาง เดินแล้วเลี้ยวกลับ ในแต่ละกิจกรรมจะให้ผู้สูงอายุปฏิบัติหลายรอบเพื่อให้ได้ข้อมูลที่แม่นยำในการค่าจากตำแหน่งมาร์กเกอร์ รายละเอียดของตำแหน่งในการติดมาร์กเกอร์บนร่างกาย แสดงในตารางที่ 3 และข้อมูลของอาสาสมัครผู้สูงอายุ แสดงในตารางที่ 4

ตารางที่ 3 ตำแหน่งการติดมาร์กเกอร์ทั้ง 41 มาร์กเกอร์

Left Profile	Shoulder to Fingers there are 7 markers Waist to Toe there are 7 markers
Right Profile	Shoulder to Fingers there are 7 markers Waist to Toe there are 7 markers
Front profile	Head: 2 markers Neck: 1 marker Chest: 1 marker
Back profile	Head: 2 markers Neck: 1 marker Back: 1 marker Head: 2 markers Back right side: 1 marker
Sub - Total	39 markers
Obstacle	2 markers
Total	41 markers

ตารางที่ 4 รายละเอียดข้อมูลของอาสาสมัครผู้สูงอายุ


No	Group	Sex	Age	Weight (kg)	Height (cm)
1	Non-Fall	Female	66	60.15	148.6
2	Fall	Female	63	67.15	159.1
3	Non-Fall	Female	63	71.7	154
4	Fall	Female	65	46.85	152.5
5	Fall	Female	63	56	154
6	Fall	Female	61	45.3	146
7	Fall	Female	68	59.05	155.5
8	Non-Fall	Female	66	58.85	153
9	Non-Fall	Female	66	44.05	152
10	Non-Fall	Female	65	47.1	153
11	Fall	Female	69	50.1	143.5
12	Fall	Female	74	57.7	146.1
13	Non-Fall	Female	75	49.02	157
14	Fall	Female	70	60.55	145.5
15	Non-Fall	Female	63	43	143.7
16	Non-Fall	Female	67	58.1	157.8
17	Non-Fall	Female	70	49.7	162
18	Fall	Male	78	71.15	163.9
19	Fall	Female	69	48.5	153.9
20	Non-Fall	Male	75	56.5	158.1

b) การติดตั้งฮาร์ดแวร์เพื่อเก็บข้อมูล


ในการเก็บข้อมูลที่มีวิจัยใช้ทั้งระบบ VICON และมาร์กเกอร์แบบไร้สายติดบนร่างกายอาสาสมัคร และใช้กล้อง IP จำนวนสี่ตัวในการเก็บบันทึกข้อมูลไปพร้อมกันเพื่อจะบันทึกการเคลื่อนที่ของร่างกายของอาสาสมัครผู้สูงอายุขณะกระทำกิจกรรมต่าง ๆ โดยระบบ VICON เก็บข้อมูลในปริภูมิสามมิติ ระบบกล้อง IP เก็บข้อมูลวิดีโอในสี่มุมมอง

การติดตั้งระบบ VICON

แสดงตัวอย่างการติดตั้งมาร์กเกอร์บนร่างกายดังแสดงในรูปที่ 23 และรายละเอียดการติดตั้งมาร์กเกอร์แสดงในรูปที่ 24



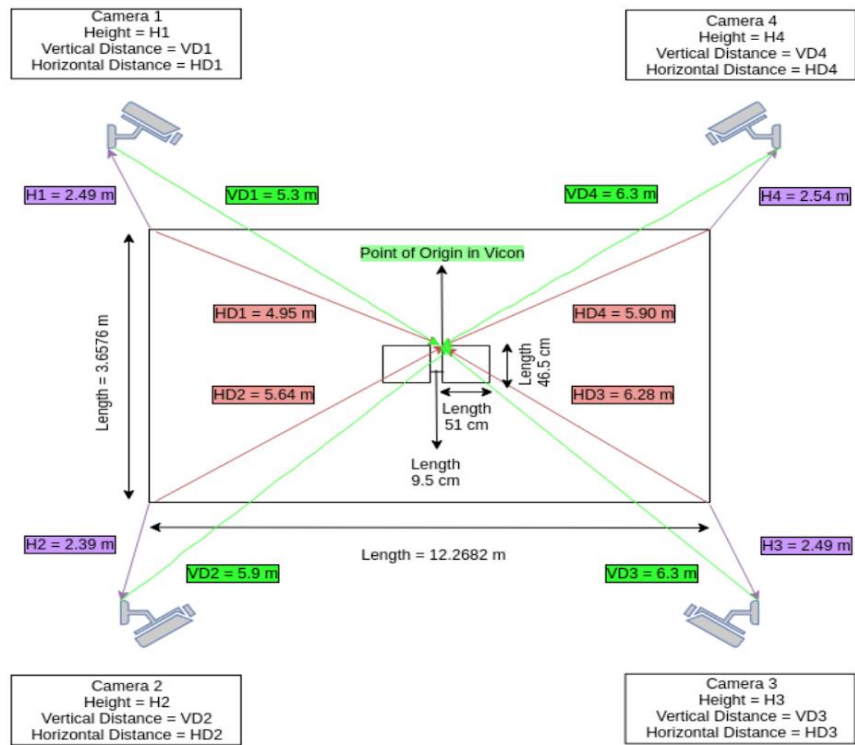
รูปที่ 23 ตัวอย่างการติดมาร์กเกอร์ลงบนร่างกาย



รูปที่ 24 รายละเอียดตำแหน่งที่ติดมาร์กเกอร์ลงบนร่างกาย

การติดตั้งกล้อง IP

ทีมวิจัยใช้กล้องความละเอียด 2 ล้านพิกเซล (เท่ากับความละเอียดกล้องที่จะใช้ใน ตอนติดตั้งใช้งานจริง) และเครื่องบันทึกวิดีโอ (NVR) เพื่อบันทึกวิดีโอไปพร้อม ๆ กัน ขณะอาสาสมัครทำกิจกรรมต่าง ๆ ขณะเก็บข้อมูล ตำแหน่งและรายละเอียดการ ติดตั้งกล้องจำนวน 4 กล้องเพื่อเก็บข้อมูลแสดงในรูปที่ 25 - 27



รูปที่ 25 แสดงตำแหน่งและระยะห่าง ความสูง ในการติดตั้งกล้อง IP เพื่อเก็บข้อมูล



รูปที่ 26 ตัวอย่างมุมกล้องที่ทีมวิจัยใช้ในการบันทึกข้อมูลวิดีโอทั้ง 4 กล้อง



รูปที่ 27 การติดตั้งกล้องจริง ณ ห้องที่ใช้ในการเก็บบันทึกข้อมูล ณ มหาวิทยาลัยมหิดล

ตัวอย่างข้อมูล

ประเภทกิจกรรม: นั่งแล้วยืน แสดงในรูปที่ 28



รูปที่ 28 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางการนั่งแล้วยืน

ประเภทกิจกรรม: เดินช้า แสดงในรูปที่ 29



รูปที่ 29 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางการเดินช้า

ประเภทกิจกรรม: เดินขณะพูด แสดงในรูปที่ 30



รูปที่ 30 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางการเดินขณะพูด

ประเภทกิจกรรม: ก้าวข้ามสิ่งกีดขวาง แสดงในรูปที่ 31



รูปที่ 31 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางการก้าวข้ามสิ่งกีดขวาง

ประเภทกิจกรรม: เดินแล้วเลี้ยวกลับ แสดงในรูปที่ 32



รูปที่ 32 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางการเดินเลี้ยวกลับ

ประเภทกิจกรรม: เดินเร็ว แสดงในรูปที่ 33




รูปที่ 33 ตัวอย่างเฟรมที่ต่อเนื่องกันของท่าทางการเดินเร็ว

3.5.2 ชุดข้อมูลการหกล้มของมหาวิทยาลัยมหิดล (Mahidol Fall Dataset)

ชุดข้อมูลนี้เก็บข้อมูลโดยใช้กล้องและอุปกรณ์ที่ติดตั้งในชุดข้อมูลที่อธิบายในหัวข้อ 3.5.1 โดยในส่วนนี้จึงจะอธิบายถึงการเก็บข้อมูลจำลองการหกล้ม และลักษณะข้อมูลของโครงร่างของร่างกายขณะล้ม ที่มิวิจัยได้ทำการจำลองการเก็บข้อมูลโดยใช้คนหนุ่มในระหว่างการเก็บข้อมูลในท่ากิริยาต่าง ๆ เช่น การเดิน การนั่ง โดยตัวบุคคลที่เป็นตัวอย่างในการเก็บข้อมูลจะถูกติดมาร์กเกอร์ 39 ตำแหน่งบนร่างกาย โดยที่มาร์กเกอร์จะให้ข้อมูลตำแหน่งในปริภูมิสามมิติจากกล้อง VICON หลาย ๆ ตัว นอกจากนี้ที่มิวิจัยได้ติดตั้งกล้อง IP เพิ่มเติมจำนวน 4 กล้องในตำแหน่งและมุมความสูงที่คล้ายคลึงกับการติดตั้งจริง เพื่อเก็บข้อมูลในปริภูมิสองมิติ โดยการเก็บข้อมูลการหกล้มในหลากหลายรูปแบบดังแสดงในรูปที่ 34 - 39 ดังนี้

1. การล้มจากการนั่งจาก

a) ด้านหลัง




รูปที่ 34 ตัวอย่างการล้มจากการนั่งไปด้านหลัง

b) ด้านขวา



รูปที่ 35 ตัวอย่างการล้มจากการนั่งไปด้านขวา

c) ด้านซ้าย



รูปที่ 36 ตัวอย่างการล้มจากการนั่งไปด้านซ้าย
d) ด้านหน้า



รูปที่ 37 ตัวอย่างการล้มจากการนั่งไปด้านหน้า

2) การหล้มจากการเดินช้า และ เร็ว



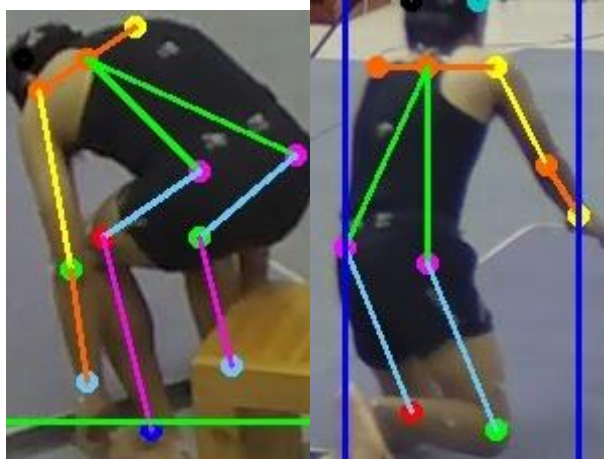
รูปที่ 38 ตัวอย่างการหล้มจากการเดิน

3) การหล้มไปด้านข้าง




รูปที่ 39 ตัวอย่างการหล้มไปด้านข้าง

ทีมวิจัยได้เก็บข้อมูลจำลองการหล้มจากห้องทดลอง Motion Lab มหาวิทยาลัยมหิดล โดยให้อาสาสมัครจำลองการหล้มในรูปแบบต่าง ๆ เช่น หล้มขณะเดิน หล้มขณะนั่ง และหล้มขณะหมุนตัว เป็นต้น ทีมวิจัยพบว่าขณะหล้มบางครั้งข้อมูลจุดโครงร่างของร่างกายบางส่วนจะถูกบดบังในบางมุมกล้อง ดังนั้นทีมวิจัยทำการเลือกเฉพาะเฟรมที่จุดโครงร่างของร่างกายที่สำคัญ เช่น ตำแหน่งคอ หัวเข่า และข้อศอก สามารถตรวจพบได้ ดังแสดงในรูปที่ 40 ส่วนข้อมูลโครงร่างของร่างกายที่มีการบดบังดังแสดงในรูปที่ 41 จะไม่ถูกนำมาใช้ในการเทรนโมเดล



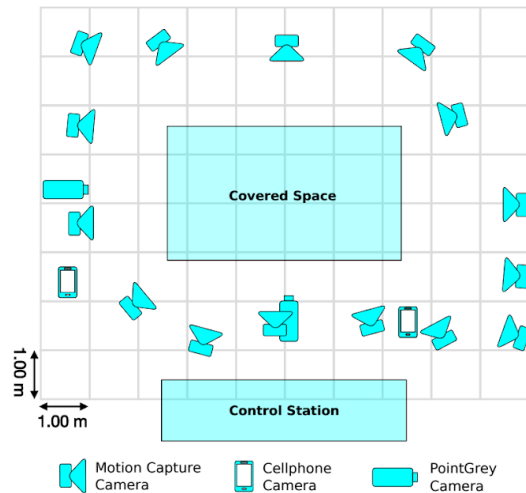
รูปที่ 40 ตัวอย่างเฟรมที่มีการตรวจพบจุดโครงร่างของร่างกายที่สำคัญ เช่น คอ หัวเข่า ข้อศอก ครบ



รูปที่ 41 ตัวอย่างเฟรมที่มีจุดโครงร่างของร่างกายที่สำคัญ เช่น คอ หัวเข่า ข้อศอก ไม่สามารถมองเห็นได้






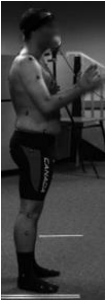














3.5.3 ชุดข้อมูล MOVI

นอกเหนือจากท่าทางที่ทีมวิจัยได้พรรณาข้อมูลก่อนหน้านี้ซึ่งได้แก่ นั่ง ยืน เดิน เอน และ ล้ม ดังได้อธิบายในหัวข้อที่ 3.5.1 และ 3.5.2 ทีมวิจัยได้รวบรวมข้อมูลท่าทางประเภทอื่น ๆ เพิ่มอีกจำนวน 5 ท่าทาง โดยใช้ชุดข้อมูล MoVi ซึ่งเป็นชุดข้อมูลวิดีโอบันทึกการเคลื่อนไหวของมนุษย์ ซึ่งเป็นชุดข้อมูลที่เปิดให้เข้าถึงได้โดยสาธารณะ ชุดข้อมูลนี้ประกอบด้วยผู้หญิง 60 คน และผู้ชาย 30 คน แต่ละคนทำการเคลื่อนไหวร่างกายเป็นจำนวน 20 ท่าทาง ซึ่งมีทั้งท่าทางปกติ ท่าทางการออกกำลังกาย โดยทำการบันทึกข้อมูลการเคลื่อนไหว 5 รอบ โดยใช้อุปกรณ์การบันทึกข้อมูลที่ต่างกัน เช่น motion capture system, กล้องวิดีโอ, การวัดค่าข้อมูลจากเซ็นเซอร์ IMU ในขณะที่บุคคลเคลื่อนไหว ผู้แสดงท่าทางจะถูกบันทึกข้อมูลในขณะที่สวมใส่เสื้อผ้าแบบปกติ สวมใส่เสื้อผ้าแบบน้อยชิ้น ซึ่งชุดข้อมูลประกอบด้วยข้อมูล motion capture เป็นระยะเวลา 9 ชั่วโมง ข้อมูลวิดีโอ ระยะเวลา 17 ชั่วโมงจากมุมมองกล้อง 4 มุมกล้อง (รวมทั้งกล้องถ่ายวิดีโอมือถือ) และข้อมูลเซ็นเซอร์ IMU เป็นระยะเวลา 6 ชั่วโมง จากข้อมูลทั้งหมดที่ทีมวิจัยเลือกข้อมูลท่าทาง 5 ประเภท ซึ่งมีความสอดคล้องกับผู้สูงอายุ ซึ่งได้แก่ ท่าทางคุยโทรศัพท์ ประหม่อมือ คุนาคือกาข้อมือ ซี่ไปที่วัตถุ และโบกมือ ดังแสดงในตารางที่ 5 และมุมมองที่ใช้บันทึกชุดข้อมูลนี้แสดงในรูปที่ 42





รูปที่ 42 รูปแบบมุมมองที่ใช้บันทึกชุดข้อมูล MoVi (สำเนาจาก Ghorbani และคณะ, 2020)

ตารางที่ 5 ตัวอย่างข้อมูลท่าทางเพิ่มเติมที่ทีมวิจัยเลือกใช้จากชุดข้อมูล MoVi

ประเภทท่าทาง	ปรบมือ	ดูนาฬิกาข้อมือ	คุยโทรศัพท์	ชี้	โบกมือ
Camera view 1 (ch-1)					
Camera view 2 (ch-2)					
Camera view 3 (ch-3)					
Camera view 4 (ch-4)					

นอกจากนั้นทีมวิจัยได้เพิ่มข้อมูลท่าทาง 5 ประเภทเดิมที่ทีมวิจัยมีข้อมูลก่อนหน้านี้ ดังแสดงในตารางที่ 6

ตารางที่ 6 ตัวอย่างข้อมูลท่าทางที่ตรงกับประเภทท่าทางเดิมที่ทีมวิจัยเลือกใช้จากชุดข้อมูล MoVi

ประเภทท่าทาง	Camera view 1 (ch-1)	Camera view 2 (ch-2)	Camera view 3 (ch-3)	Camera view 4 (ch-4)
นั่ง				
ยืน				
เดิน				
เอนตัว				
ล้ม				

โดยชุดข้อมูลสำหรับเทรนโมเดลประกอบด้วยภาพจำนวน 13,440 ภาพสำหรับชุดข้อมูลเทรน โดยแบ่งจำนวนตามแต่ละประเภทท่าทางดังนี้

- นิ่ง 1,646 ภาพ
- ยืน 1,815 ภาพ
- เดิน 1,403 ภาพ
- เอนตัว 876 ภาพ
- ล้ม 1,163 ภาพ
- ดุนาฬิกา 1,348 ภาพ
- ประบมือ 1,364 ภาพ
- คู้โทรศัพท์ 1,410 ภาพ
- ชี 1,191 ภาพ
- โบกมือ 1,224 ภาพ


3.5.4 ชุดข้อมูลมุกกล้อง 360 องศารอบตัวบุคคลในห้องทดลอง ณ สถาบันเทคโนโลยีแห่งเอเชีย (AIC-360)

ทีมวิจัยได้ติดตั้งกล้องจำนวน 8 กล้องเพื่อเก็บข้อมูลในห้องทดลองเพื่อให้มีข้อมูลจากมุกกล้องที่หลากหลายครอบคลุม 360 องศา การติดตั้งกล้องแสดงในรูปที่ 43 โดยแต่ละมุกกล้องจะมองมายังตำแหน่งกึ่งกลางของห้อง กล้องทั้ง 8 ตัวจะทำการบันทึกวิดีโอพร้อมกันขณะอาสาสมัครทำท่าทางต่าง ๆ จำนวน 10 ประเภทท่าทาง คือ ยืน เดิน นั่ง เอนตัว ล้ม ปรบมือ ดุนาฬิกา คุยโทรศัพท์ ชี้ โบกมือ โดยการเก็บข้อมูลจะให้อาสาสมัครยืนในตำแหน่งที่ระยะห่างแตกต่างกัน 9 ตำแหน่ง โดยอาสาสมัครแต่ละคนจะทำท่าทาง ณ การยืนแต่ละตำแหน่งดังแสดงในรูปที่ 44 การติดตั้งกล้องทั้ง 8 ตัวในห้องทดลองแสดงในรูปที่ 45 มุกกล้องทั้ง 8 ตัวที่ติดตั้งในห้องทดลองแสดงในตารางที่ 7 ส่วนการเก็บข้อมูลการล้มและการเดินแบบไม่มั่นคง ทีมวิจัยได้จัดเตรียมเบาะรองรับให้อาสาสมัครทำการจำลองการล้ม และการเคลื่อนไหวที่ไม่มั่นคง โดยอาสาสมัครจะทำการจำลองการล้มและการเคลื่อนไหวแบบไม่มั่นคงจำนวนทั้งหมด 15 ครั้ง โดยทำการจำลองการล้มหลากหลายแบบและหลากหลายทิศทางการล้ม เช่น ล้มแบบค่อย ๆ ทรวดตัวลง ล้มแบบรวดเร็ว ล้มแบบลิ้นลิ้ม ล้มแบบสะดุดล้ม

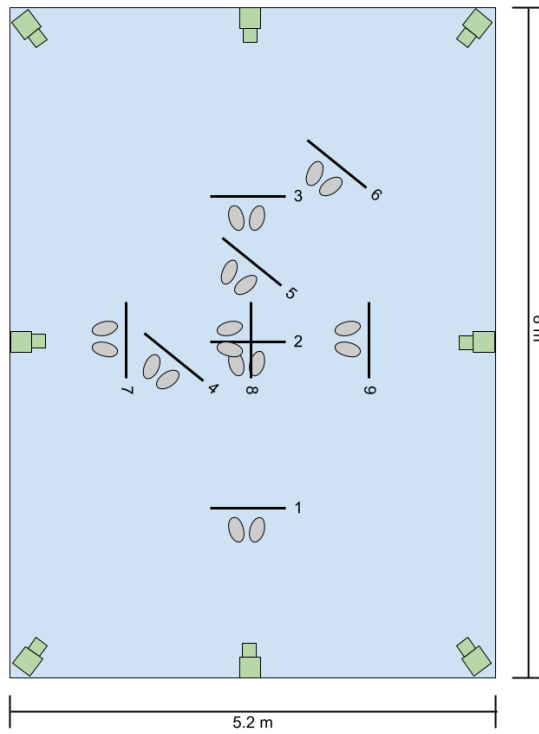
ตารางที่ 7 รายละเอียดการเก็บข้อมูลท่าทางในห้องทดลอง

ท่าทางหลัก	ประเภทท่าทาง	ตำแหน่งการยืน/นั่ง ท่าทาง
ยืน	ปรบมือ	1-9
	ดุนาฬิกาข้อมือ	1-9
	ชี้	1-9
	คุยโทรศัพท์	1-9
	โบกมือ	1-9
นั่ง	ปรบมือ	2, 3, 5, 6, 8, 9
	ดุนาฬิกาข้อมือ	2, 3, 5, 6, 8, 9
	ชี้	2, 3, 5, 6, 8, 9
	คุยโทรศัพท์	2, 3, 5, 6, 8, 9
	โบกมือ	2, 3, 5, 6, 8, 9
ล้ม	ล้มแบบค่อย ๆ ทรวดตัว	2 และ 8


	ลิ้มแบบรวดเร็ว (เป็นลมหมดสติ)	2 และ 8
	ลิ้มแบบสะดุดล้ม	2 และ 8
	ลิ้มแบบถื่นลิ้ม	2 และ 8
เดินแบบไม่มั่นคง	เดินแบบไม่มั่นคงในหลากหลายรูปแบบ	ให้อาสาสมัครจำลองการเดินแบบไม่มั่นคงบริเวณกลางห้องทดลอง



รูปที่ 43 การติดตั้งกล้องเพื่อเก็บข้อมูลในห้องทดลองให้ครอบคลุมมุมกล้อง 360 องศารอบตัวบุคคล



รูปที่ 44 ตำแหน่งการยืนของอาสาสมัครเพื่อเก็บข้อมูลประเภทท่าทางต่าง ๆ



(ค)




(ง)



รูปที่ 45 การติดตั้งกล้องทั้ง 8 ตัวในห้องทดลอง ณ สถาบันเทคโนโลยีแห่งเอเชีย รูป (ก) และ (ข) แสดงการติดตั้งกล้องด้านกว้างของห้องทดลอง รูป (ค) และ (ง) แสดงการติดตั้งกล้องด้านยาวของห้องทดลองในมุมมองแบบพาโนรามา

3.5.4.1 ชุดข้อมูลท่าทางในห้องทดลอง

ในการเก็บข้อมูลท่าทางในห้องทดลอง ทีมวิจัยให้อาสาสมัครยืน และ นั่งเพื่อทำท่าทางต่าง ๆ ณ ตำแหน่งที่กำหนดไว้ทั้งหมด 9 ตำแหน่ง ในขณะที่ทำท่าทางต่าง ๆ กล้องทั้งหมด 8 กล้องจะทำการบันทึกวิดีโอไปพร้อม ๆ กัน ข้อมูลเหล่านี้จะถูกนำไปใช้ในการเทรนและทดสอบโมเดล และทดสอบกับชุดข้อมูลท่าทางที่เก็บจากบ้านอาสาสมัคร ตัวอย่างภาพจาก 3 มุมกล้องจากทั้งหมด 8 มุมกล้องแสดงในรูปที่ 46 โดยแสดงท่าทางที่เห็นจาก 3 มุมกล้องจากทั้งหมด 8 กล้อง






รูปที่ 46 ตัวอย่างภาพจากมุมกล้อง 3 กล้อง ณ เวลาเดียวกัน

3.5.4.2 ชุดข้อมูลจำลองการทกล้มในห้องทดลอง


การจำลองการทกล้มจะแบ่งออกเป็น 4 แบบ คือ การล้มแบบค่อย ๆ ทรวดตัว การล้มแบบรวดเร็ว การสะดุดล้ม และ การลื่นล้ม โดยอาสาสมัครจะทำการจำลองการล้มบริเวณกลางห้อง ในหลากหลายทิศทาง ตัวอย่างการจำลองการล้มโดยอาสาสมัครแสดงในรูปที่ 47 โดยแสดงท่าทางการล้มจาก 3 มุมกล้องจากทั้งหมด 8 กล้อง



รูปที่ 47 การเก็บข้อมูลการจำลองการล้มในรูปแบบต่าง ๆ โดยอาสาสมัคร

3.5.4.3 ชุดข้อมูลจำลองการเคลื่อนไหวแบบไม่มั่นคงในห้องทดลอง

การจำลองการเคลื่อนไหวแบบไม่มั่นคง จะให้อาสาสมัครจำลองการเคลื่อนไหวแบบไม่มั่นคง บริเวณกลางห้อง ในหลากหลายทิศทาง ดังแสดงในรูปที่ 48 ซึ่งแสดงลำดับภาพการเคลื่อนไหวแบบไม่มั่นคงจากมุมกล้องเดียวจากทั้งหมด 8 กล้อง



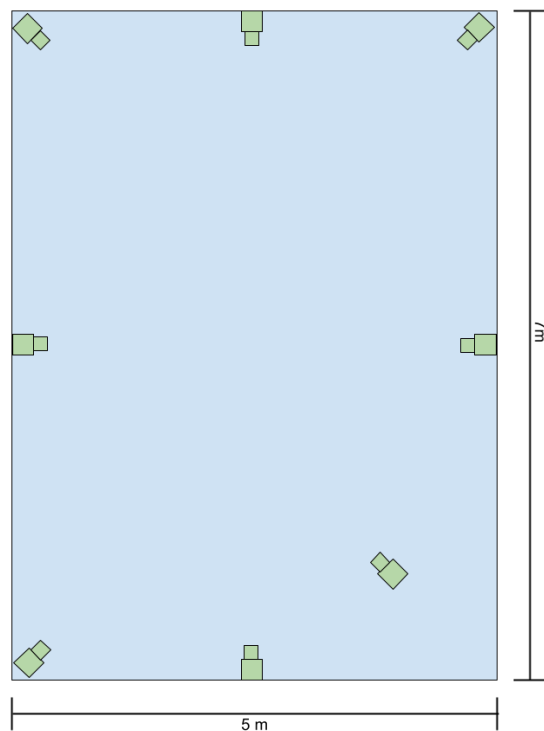
รูปที่ 48 ตัวอย่างการจำลองการเคลื่อนไหวแบบไม่มั่นคงโดยอาสาสมัคร

3.5.4.4 การจัดเตรียมชุดข้อมูล AIC-360 สำหรับการเทรนโมเดล

ในการบันทึกวิดีโอชุดข้อมูลนี้ทีมวิจัยใช้เครื่องบันทึกวิดีโอ (NVR) ในการบันทึกวิดีโอจากกล้องทั้งหมด 8 กล้องพร้อมกัน โดยบันทึกที่ความละเอียด 4 ล้านพิกเซล (2702x1538 พิกเซล) การจัดเตรียมข้อมูลสำหรับเทรนโมเดลจะประกอบด้วยการคัดแยกและตัดวิดีโอเพื่อจัดหมวดหมู่ท่าทางต่าง ๆ เพื่อใช้ในการดึงข้อมูลโครงร่างของร่างกายจากกล้องแต่ละมุมมอง และทำการเทรนโมเดลแยกกันแต่ละมุมมอง ทีมวิจัยจัดเตรียมชุดข้อมูลชุดนี้ ซึ่งใช้เวลาในการเตรียมมานานเนื่องจากต้องใช้เวลาในการระบุประเภทท่าทางในวิดีโอ รวมถึงใช้เวลานานในการตัดคัดแยกวิดีโอ ซึ่งในการใช้งานจริงโมเดลเหล่านี้อาจถูกนำไปใช้ทั้งหมดหรือถูกนำไปใช้เฉพาะกล้องที่มีมุมมองใกล้เคียงกับกล้องที่ติดใช้งานจริง ชุดลำดับข้อมูลโครงร่างของร่างกายที่ได้จากการตามรอยบุคคล จะถูกนำมาแยกแยะประเภทท่าทางโดยใช้โมเดลจากทุกกล้อง หรือเฉพาะกล้องที่มีมุมมองใกล้เคียงกัน เพื่อหาประเภทท่าทางที่มีความน่าเชื่อถือมากที่สุดซึ่งจะถูกเลือกเป็นประเภทท่าทางในการตามรอยของบุคคลนั้น ๆ

3.5.5 ชุดข้อมูล 360 องศา บ้านอาสาสมัคร จ.กรุงเทพมหานคร ชุดที่ 1 (AIC-Volunteer1-Set1)

ทีมวิจัยได้ติดกล้องจำนวน 8 ตัว ให้ครอบคลุมมุม 360 องศารอบตัวบุคคล ณ บ้านอาสาสมัครหมายเลข 2 ในพื้นที่จังหวัดกรุงเทพมหานคร โดยมีลักษณะการติดตั้งกล้องแสดงในรูปที่ 49 เนื่องด้วยโครงสร้างของบ้านและตำแหน่งของเสาบ้านบดบังมุมกล้อง ทำให้ทีมวิจัยต้องขยับตำแหน่งกล้องออกมา การติดตั้งกล้องทั้ง 8 ตัว ณ บ้านอาสาสมัครแสดงในรูปที่ 50 ข้อมูลที่เก็บจากบ้านอาสาสมัครนี้มีวัตถุประสงค์เพื่อจะนำไปใช้ในการทดสอบและประเมินความแม่นยำของระบบการเก็บข้อมูลท่าทางต่าง ๆ การล้มหลากหลายแบบ เช่น ลื่นล้ม ล้มแบบซ้ำ ๆ ล้มแบบสะดุดล้ม จะถูกจำลองบริเวณกลางโถงห้องเป็นหลัก



รูปที่ 49 ตำแหน่งการติดตั้งกล้อง 8 กล้อง ณ บ้านอาสาสมัคร



รูปที่ 50 การติดตั้งกล้อง ณ บ้านอาสาสมัคร

3.5.5.1 ชุดข้อมูลท่าทางในบ้าน

การเก็บข้อมูลท่าทางในบ้านที่วิจัยได้ให้อาสาสมัครทำท่าทางต่าง ๆ ประเภทเดียวกันกับท่าทางที่ทำในห้องทดลอง (ชุดข้อมูล AIC-360) และทำการเก็บข้อมูลวิดีโอทั้ง 8 กล้อง เพื่อนำมาเทรนโมเดลเพิ่มเติมและทดสอบความแม่นยำของโมเดล ตัวอย่างการทำท่าทางแสดงในรูปที่ 51



รูปที่ 51 ตัวอย่างข้อมูลการทำท่าทางต่าง ๆ จากบ้านอาสาสมัครที่ทีมวิจัยติดตั้งระบบ

3.5.5.2 ชุดข้อมูลจำลองการทกล้มในบ้าน

ภายหลังการติดตั้งกล้องเพิ่มเติมเพื่อให้ครอบคลุมมุม 360 องศารอบตัวบุคคล ทีมวิจัยได้ทำการจำลองการล้มในหลากหลายรูปแบบ เช่น ลื่นล้ม ล้มแบบซ้ำ ๆ ล้มแบบสะดุดล้ม ล้มแบบค่อย ๆ ทรุดตัว ดังแสดงในรูปที่ 52 ข้อมูลชุดนี้ถูกนำมาเทรนและทดสอบความแม่นยำของโมเดลที่เทรนจากข้อมูลจากห้องทดลอง



รูปที่ 52 ภาพตัวอย่างจาก 3 มุมกล้องจากทั้งหมด 8 กล้อง ณ เวลาเดียวกันขณะอาสาสมัครจำลองการล้มประเภทต่าง ๆ

3.5.5.3 ชุดข้อมูลจำลองการเคลื่อนไหวแบบไม่มั่นคงในบ้าน

ทีมวิจัยเก็บข้อมูลการจำลองการเคลื่อนไหวแบบไม่มั่นคงภายในบ้านอาสาสมัครในจังหวัดกรุงเทพมหานคร ซึ่งถูกใช้ในการติดตั้งระบบและประเมินผลระบบ ชุดข้อมูลประกอบด้วยข้อมูลการเคลื่อนไหวแบบไม่มั่นคงภายในบ้าน ณ ตำแหน่งที่แตกต่างกัน และลักษณะการเดินที่แตกต่างกัน ดังแสดงในรูปที่ 53



รูปที่ 53 ตัวอย่างลำดับเฟรมที่ต่อเนื่องกันของการเคลื่อนไหวที่ไม่มั่นคง

ภายหลังการติดตั้งกล้องเพิ่มเติมเพื่อให้ครอบคลุมมุม 360 องศารอบตัวบุคคล ทีมวิจัยได้ทำการจำลองการเดินแบบไม่มั่นคงเพิ่ม โดยให้อาสาสมัครทำการจำลองการเดินแบบไม่มั่นคง และบันทึกวิดีโอจากทั้ง 8 กล้องพร้อมกันเช่นเดียวกับชุดข้อมูลจำลองการหกล้ม

3.5.6 ชุดข้อมูล 360 องศา บ้านอาสาสมัคร จ.กรุงเทพมหานคร ชุดที่ 2 (AIC-Volunteer1-Set2)


ข้อมูลชุดนี้ใช้ในการประเมินความแม่นยำของระบบในส่วนของการแยกแยะท่าทาง รวมถึงการหกล้ม และตรวจจับการเคลื่อนไหวที่ไม่มั่นคง เพื่อให้สามารถคำนวณความแม่นยำของระบบได้ทั้ง precision และ recall รวมถึงในการใช้งานจริง กิจวัตรประจำวันและท่าทางต่าง ๆ อาจพบเจอได้น้อย เช่น การเคลื่อนไหวที่ไม่มั่นคง หรือแม้กระทั่งอาจไม่เกิดขึ้นเลย เช่น การหกล้ม ทีมวิจัยจึงต้องทำการเก็บข้อมูลท่าทางต่าง ๆ 10 ท่าทางตามที่ได้อธิบายไว้ในหัวข้อก่อนหน้านี้ และทำการจำลองการเคลื่อนไหวที่ไม่มั่นคง โดยทำการเก็บข้อมูล ณ บ้านอาสาสมัคร จ.กรุงเทพมหานคร โดยชุดข้อมูลนี้จะเป็นชุดข้อมูลที่ไม่ถูกใช้ในกระบวนการเทรนโมเดล (unseen dataset) ตัวอย่างข้อมูลและรายละเอียดสำหรับชุดข้อมูลนี้อธิบายในบทที่ 4 ในส่วนของการประเมินความแม่นยำของระบบ

3.5.7 ชุดข้อมูลเพิ่มเติมสำหรับเก็บข้อมูลและทดสอบ (AIC Initial Test Dataset)

นอกเหนือจากข้อมูลที่ทีมวิจัยเก็บจากห้องทดลองมหาวิทยาลัยมหิดลแล้ว ทีมวิจัยได้เก็บข้อมูลเพิ่มเติมโดยติดตั้งกล้องในบ้านอาสาสมัครในหลายพื้นที่เพื่อเก็บรวบรวมข้อมูลจากบ้านผู้คนเพื่อใช้ในการเทรนโมเดลและทดสอบระบบ รวมถึงการหาข้อมูลประเภทท่าทางที่ควรนำมาใช้เพิ่มเติม โดยทีมวิจัยได้เก็บข้อมูลทั้งหมดจากบ้านจำนวน 2 บ้าน และออฟฟิศจำนวน 1 ออฟฟิศ โดยมีรายละเอียดดังแสดงในตารางที่ 8


ตารางที่ 8 รายละเอียดการติดตั้งกล้องและเก็บข้อมูลในแต่ละบ้าน

บ้าน หมายเลข	สถานที่	มุมมอง	รายละเอียด สมาชิก ครอบครัว	หมายเหตุ
1	เชียงใหม่		ผู้สูงอายุ 2 คน ไม่เคยมีประวัติ การหกล้ม จำนวนสมาชิก ทั้งหมด 8 คน	ติดตั้งชั่วคราว เพื่อเก็บข้อมูล
2	ลำพูน		ผู้สูงอายุ 2 คน ไม่เคยมีประวัติ การหกล้ม จำนวนสมาชิก 6 คน	ติดตั้งชั่วคราว เพื่อเก็บข้อมูล
3	AICenter Lab, AIT		สมาชิกห้อง แล็บจำนวน 15 คน	ติดตั้งชั่วคราว เพื่อเก็บข้อมูล และทดสอบ




3.6 การวิเคราะห์ข้อมูลดิบของการเคลื่อนที่ที่ไม่มั่นคงซึ่งอาจนำไปสู่การเคลื่อนที่ที่ผิดปกติหรือการหกล้ม

ทีมวิจัยพัฒนาอัลกอริทึมสำหรับตรวจจับท่าทางของบุคคลในปริภูมิสามมิติโดยทดสอบบนวิดีโอที่เก็บบันทึกจากมหาวิทยาลัยมหิดล (Mahidol Elder Dataset) ทีมวิจัยได้ทำการทดสอบความแม่นยำของไลบรารี OpenPose ในการประมาณค่าตำแหน่งโครงร่างของร่างกาย โดยทำการเปรียบเทียบกับข้อมูลในปริภูมิสามมิติที่ได้จากมาร์กเกอร์ที่ติดบนร่างกายโดยใช้กล้อง VICON เป็นข้อมูลความจริง (ground truth) ทีมวิจัยได้ทำการพัฒนาการประมาณตำแหน่งโครงร่างของร่างกายในปริภูมิสามมิติลงบนปริภูมิสองมิติ โดยทำการเปรียบเทียบ กล้อง IP ที่ใช้ในการเก็บข้อมูลเพื่อหาตัวแปรกล้อง (intrinsic and extrinsic camera parameters) และใช้เทคนิคการแปลงข้อมูลสามมิติจากกล้อง VICON เป็นข้อมูลในปริภูมิสองมิติลงบนภาพที่ได้จากกล้อง IP เพื่อทดสอบความแม่นยำของไลบรารี OpenPose ในการดึงข้อมูลโครงร่างของร่างกาย รูปที่ 54 แสดงให้เห็นถึงภาพต้นฉบับจากกล้อง โดยที่จุดสีเขียวแสดงถึงจุดกำเนิดของระบบพิกัดของ VICON และจุดสีแดงแสดงถึงตำแหน่งมาร์กเกอร์ที่ติดบนร่างกายที่ถูกฉายจากปริภูมิสามมิติมายังปริภูมิสองมิติ และรูปที่ 55 แสดงให้เห็นถึงโครงร่างของร่างกายที่ได้จากไลบรารี OpenPose



รูปที่ 54 แสดงตำแหน่งของมาร์กเกอร์ (จุดสีแดง) ที่แปลงตำแหน่งจากปริภูมิสามมิติเป็นข้อมูลตำแหน่งมาร์กเกอร์ที่ปรากฏบนมุมมองกล้อง



รูปที่ 55 ตัวอย่างของโครงร่างของร่างกายที่ได้จากไลบรารี OpenPose บนภาพเฟรมเดียวกัน



ข้อมูลตำแหน่งการเคลื่อนที่ของส่วนต่าง ๆ ของร่างกายในปริภูมิสองมิติและสามมิติที่ได้จากการเก็บข้อมูลจากอาสาสมัครผู้สูงอายุ (อธิบายในหัวข้อ 3.5.1) ซึ่งมีทั้งในกลุ่มของผู้ที่มีและไม่มีประวัติการล้มจะถูกนำมาใช้ การวิเคราะห์การเคลื่อนที่ที่ไม่มั่นคง (abnormal activity) จะแตกต่างจากรู้จำประเภทกิจกรรม (ท่าทาง) เนื่องจากการรู้จำประเภทกิจกรรมจะทำการวิเคราะห์และแยกแยะประเภทข้อมูลโครงสร้างของร่างกายที่ละหนึ่งเฟรมและสามารถแยกแยะได้ว่าท่าทางดังกล่าวคือท่าทางลักษณะใด ซึ่งแตกต่างจากการวิเคราะห์การเคลื่อนไหวแบบไม่มั่นคงซึ่งจะต้องมีการวิเคราะห์ลักษณะโครงสร้างของร่างกายระหว่างเฟรมหลายเฟรมที่ต่อเนื่องกันเพื่อสังเกตถึงความผิดปกติในท่าทางต่าง ๆ

ทีมวิจัยได้เก็บข้อมูลการเคลื่อนที่ของผู้สูงอายุซึ่งมีรายละเอียดดังได้อธิบายข้างต้น โดยแบ่งออกเป็นกลุ่มผู้สูงอายุสองกลุ่ม คือ ผู้มีประวัติการหกล้ม และไม่มีประวัติการหกล้ม ทีมวิจัยใช้ไลบรารี OpenPose ในการดึงข้อมูลโครงสร้างของร่างกายและใช้ข้อมูลจาก VICON (ข้อมูล ground truth) ดังแสดงในรูปที่ 56 - 57 เพื่อเปรียบเทียบและใช้เป็นลักษณะการเคลื่อนไหวที่มั่นคง ทีมวิจัยวิเคราะห์ข้อมูลและทำการสรุปรูปแบบข้อมูลการเคลื่อนที่ที่ถือว่าปกติและมั่นคงร่วมกับทีมผู้เชี่ยวชาญจากมหาวิทยาลัยมหิดล การเคลื่อนที่ในรูปแบบใด ๆ ที่ผิดไปจากการเคลื่อนที่แบบมั่นคงจะพิจารณาให้อยู่ในประเภทของการเคลื่อนที่แบบไม่มั่นคง

Toong:RPSI			Toong:LTHI			Toong:LKNE			Toong:LTIB
X	Y	Z	X	Y	Z	X	Y	Z	X
mm	mm	mm	mm	mm	mm	mm	mm	mm	mm
248.779	-2740.68	935.668	22.7903	-2656.15	625.356	59.9415	-2699.26	434.48	57.5923
250.948	-2726.71	934.053	22.8579	-2646.76	624.696	59.6715	-2691.54	433.955	56.7927
252.824	-2712.57	932.435	23.038	-2636.63	623.962	59.4213	-2683.18	433.446	56.7097
254.65	-2698.48	930.829	22.3058	-2627.54	623.447	59.2409	-2673.76	432.837	55.8458
256.348	-2684.14	929.16	22.678	-2615.93	622.666	59.0586	-2663.62	432.169	55.8862
257.851	-2669.62	927.412	24.0594	-2601.86	621.684	59.0086	-2652.75	431.487	55.1561
259.345	-2654.9	925.721	24.748	-2588.83	620.755	59.0313	-2640.71	430.602	54.1051
260.762	-2639.83	924.032	25.5173	-2575.01	619.743	59.1591	-2627.72	429.538	53.7873
262.273	-2624.28	922.378	25.8118	-2561.9	618.636	59.2834	-2613.64	428.183	53.5042
263.889	-2608.31	920.757	27.5514	-2545.53	617.005	59.3218	-2598.52	426.384	53.926
265.927	-2592.26	919.288	28.6455	-2529.59	615.21	59.2385	-2582.31	424.192	53.6863
268.129	-2576.32	918.497	29.9111	-2513.07	613.35	58.9043	-2564.54	421.515	54.0451
270.348	-2560.42	918.891	30.6694	-2496.48	611.33	58.3678	-2545.94	418.551	54.647
272.786	-2544.75	920.408	31.838	-2478.17	609.169	57.1823	-2524.94	415.569	55.0636
274.719	-2529.46	922.367	32.524	-2459.05	607.367	55.4813	-2502.72	412.964	55.8149
276.227	-2514.91	924.122	33.1826	-2439.07	605.873	54.0727	-2479.4	410.649	56.0893
277.331	-2500.74	925.448	33.7162	-2418.82	604.443	53.1836	-2455.93	408.737	56.6251

รูปที่ 56 ตัวอย่างข้อมูลดิบจาก VICON โดยแสดงข้อมูลของมาร์กเกอร์ในปริภูมิสามมิติของมาร์กเกอร์ที่ติดบนร่างกายแต่ละส่วน

Toong:LTHI		
X	Y	Z
mm	mm	mm
22.7903	-2656.15	625.356
22.8579	-2646.76	624.696
23.038	-2636.63	623.962
22.3058	-2627.54	623.447
22.678	-2615.93	622.666
24.0594	-2601.86	621.684
24.748	-2588.83	620.755
25.5173	-2575.01	619.743
25.8118	-2561.9	618.636
27.5514	-2545.53	617.005
28.6455	-2529.59	615.21
29.9111	-2513.07	613.35
30.6694	-2496.48	611.33
31.838	-2478.17	609.169
32.524	-2459.05	607.367
33.1826	-2439.07	605.873
33.7162	-2418.82	604.443



(a)

(b)

(c)

รูปที่ 57 ตัวอย่างข้อมูลจากมาร์กเกอร์ที่ติดช่วงต้นขาซ้าย (a) และกราฟแสดงการเปลี่ยนแปลงของข้อมูลในแต่ละช่วงเวลา ในการเดินซ้ารอบที่ 1 (b) และเดินซ้ารอบที่ 6 (c)

ทีมวิจัยมีข้อมูลภาพ 363,914 รูปจากอาสาสมัครทั้งหมดทั้งที่มีประวัติเคยล้มและไม่เคยล้มซึ่งเป็นข้อมูลจากผู้สูงอายุ 20 คน ที่มีท่าทางการทำกิจกรรมประเภทต่าง ๆ ยกเว้นการจำลองการหกล้ม และ 7,820 รูปซึ่งเป็นข้อมูลจากสมาชิกทีมวิจัยจำนวน 1 คน ที่มีท่าทางการทำกิจกรรมประเภทต่าง ๆ รวมถึงการจำลองการหกล้ม ทีมวิจัยได้วิเคราะห์ข้อมูลตำแหน่งต่าง ๆ ของโครงร่างของร่างกายร่วมกับผลการวิเคราะห์จากผู้เชี่ยวชาญจากมหาวิทยาลัยมหิดลซึ่งอธิบายในหัวข้อ 3.7 เพื่อทดสอบเทรนโมเดลเพื่อใช้ในการแยกแยะท่าทางการเคลื่อนไหวแบบไม่มั่นคง ผลการทดสอบโมเดลดังกล่าวอธิบายในรายละเอียดในบทที่ 4

3.7 การวิเคราะห์ชุดข้อมูลผู้ที่มีและไม่มีประวัติการหกล้มโดยผู้เชี่ยวชาญด้านศัลยกรรมกระดูก และกายภาพบำบัด

การวิเคราะห์ข้อมูลดิบของการเคลื่อนที่ที่ไม่มั่นคงซึ่งอาจนำไปสู่การเคลื่อนที่ที่ผิดปกติหรือการหกล้มโดยทีมแพทย์ผู้เชี่ยวชาญด้านศัลยกรรมกระดูกและกายภาพบำบัด มหาวิทยาลัยมหิดล โดยอธิบายในรายละเอียดดังต่อไปนี้

3.7.1 รายงานสรุปผลการประมวลผลและแยกแยะประเภทการแสดงออกของบุคคลเป้าหมายจากแพทย์ผู้เชี่ยวชาญด้านศัลยกรรมกระดูกและกายภาพบำบัด

รายงานผลการศึกษาข้อมูลดิบโดยทีมผู้เชี่ยวชาญจากมหาวิทยาลัยมหิดล ได้ทำการศึกษาเชิงสังเกตการณ์ของกิจกรรมประจำวันของผู้สูงอายุที่มีและไม่มีประวัติการหกล้มบนตัวแปรการเดินในเชิงพื้นที่-เวลา โดยเป็นการศึกษาที่จุดเวลาใดเวลาหนึ่งเพื่อจะเปรียบเทียบตัวแปรการเดินในเชิงพื้นที่-เวลาระหว่างเงื่อนไขที่แตกต่างกันของท่าทางการเดินระหว่างของผู้ที่เคยมีและไม่มีประวัติการหกล้ม โดยที่ข้อมูลที่ใช้ในการศึกษาถูกเก็บรวบรวมจากห้องปฏิบัติการวิเคราะห์การเคลื่อนไหวแบบสามมิติ (10 กล้องความเร็วสูง, Vicon™ Oxford, UK) ณ มหาวิทยาลัยมหิดล ศาลายา ผู้เข้าร่วมทดสอบรับสมัครจากพื้นที่ตำบลศาลายา และพื้นที่ข้างเคียง ก่อนเก็บข้อมูลผู้เข้าร่วมทุกคนรับทราบถึงรายละเอียดในการวิจัยและถูกขอให้ลงนามในการได้รับทราบถึงการอนุญาตให้วิจัยในคนโดยคณะกรรมการการวิจัยของสถาบัน (COA หมายเลข MU-CIRB 2019/089.2105) และมีรายละเอียดดังต่อไปนี้

3.7.1.1 ผู้เข้าร่วมทดสอบ

ผู้สูงอายุจำนวน 20 คน ที่มีและไม่มีประวัติการหกล้มซึ่งผ่านเงื่อนไขการศึกษา ถูกแบ่งกลุ่มออกเป็น กลุ่มผู้ไม่มีประวัติการหกล้ม ($n=10$) และ กลุ่มผู้ที่มีประวัติการหกล้ม ($n=10$) เพื่อใช้ในการศึกษาวิจัยนี้ คุณสมบัติของกลุ่มตัวอย่างที่เลือกเข้าศึกษา ประกอบด้วย เป็นผู้มีอายุระหว่าง 60 - 80 ปี, เป็นเพศหญิง หรือ ชาย, มีและไม่มีประวัติการหกล้มอย่างน้อยหนึ่งครั้งภายในระยะเวลา 6 เดือน ก่อนการเก็บข้อมูล, สามารถแสดงท่าทางกิจวัตรประจำวันต่าง ๆ ซึ่งประกอบด้วย การนั่งแล้วยืน, การเดิน, และ การเดินเลี้ยว, และสามารถที่จะสื่อสารและทำตามคำสั่งได้ ผู้เข้าร่วมจะไม่ถูกนำมารวมในการศึกษาถ้าหากมีความบกพร่องของร่างกายอย่างร้ายแรงไม่ว่าจะในระบบใด ๆ ของร่างกาย มีปัญหาทางด้านการเดินและการทรงตัวของร่างกาย มีความจำเป็นต้องใช้อุปกรณ์ช่วยเดิน มีอาการคลื่นไส้หรือปวดหัวในวันที่ทำการทดสอบ มีปัญหาทางด้านการมองเห็นซึ่งแก้ไขไม่ได้ด้วยการใส่แว่นตา มีการบาดเจ็บรุนแรงไม่ว่าจะส่วนใดของลำตัว มีปัญหารุนแรงทางด้านการรับรู้ ($MsCA < 18$ คะแนน) นอกเหนือจากนั้น เพื่อที่จะลดผลกระทบของข้อมูลที่เกี่ยวข้องกับสถิติจำนวนประชากร ข้อมูลอายุ น้ำหนัก ส่วนสูงและเพศถูกจับกลุ่มระหว่างกลุ่มประชากรตัวอย่าง

3.7.1.2 กระบวนการทดสอบ

ผู้ทดสอบถูกขอให้เปลี่ยนเครื่องแต่งกายให้ใส่เสื้อแขนกุด และกางเกงขาสั้น และให้ข้อมูลทางด้านประชากร เช่น อายุ, น้ำหนัก, ส่วนสูง, ประวัติการหกล้ม, สถานะการรับรู้, ประเมินอาการกลัวหกล้ม, และระดับ ADL พื้นฐาน

มาร์กเกอร์แบบสะท้อนแสงถูกติดลงบนร่างกายส่วนที่มีกระดูกยื่นตามรูปแบบของ PIG ก่อนการเก็บข้อมูล ระบบและตำแหน่งหยุดนิ่งของผู้ทดสอบจะถูกปรับวัดทำให้เป็นมาตรฐาน ข้อมูลการเดินจะถูกบันทึกที่ความถี่ 100 Hz สำหรับการเคลื่อนที่ และ 1,000 Hz สำหรับข้อมูลนาฬิกา

เงื่อนไข 5 ข้อสำหรับการเดินจะถูกวัดตามลำดับ ดังนี้ 1) การเดินแบบผ่อนคลาย 2) การเดินเร็ว 3) การเดินและก้าวข้ามสิ่งกีดขวาง 4) การเดินและหยุดไปด้วย 5) การเดินและเลี้ยว

สำหรับการเดินแบบผ่อนคลาย การเดินเร็ว และการเดินและหยุดไปด้วย ผู้เข้าทดสอบต้องเดินเป็นระยะทาง 8 เมตร ตามทางเดิน สำหรับการเดินข้ามสิ่งกีดขวาง สิ่งกีดขวางถูกวางไว้ ณ ตำแหน่งกึ่งกลางทางเดิน ผู้เข้าร่วมทดสอบจะถูกจัดตำแหน่งและฝึกให้ใช้ขาขวาในการก้าวข้ามสิ่งกีดขวาง สำหรับการเดินและเลี้ยว ผู้เข้าร่วมทดสอบจะถูกให้ปฏิบัติตามโดยเดินไปถึงจุดกึ่งกลางทางเดิน และทำการเลี้ยวขวา ณ จุดนั้น และเดินกลับมายังจุดเริ่มต้น แต่ละเงื่อนไขจะถูกวัดให้ได้การปฏิบัติที่ถูกต้องขั้นต่ำ 3 รอบ และผลลัพธ์ที่ใกล้เคียงของ 2 จากการปฏิบัติที่ถูกต้อง 3 รอบจะถูกนำมาหาค่าเฉลี่ยและใช้ในการวิเคราะห์ต่อไป

3.7.1.3 การประมวลผลข้อมูล

ข้อมูลจะถูกวิเคราะห์โดยใช้ซอฟต์แวร์ Nexus และคัดกรองข้อมูลโดยใช้ fourth order low pass Butterworth filter ที่ความถี่ 6 Hz และ 30 Hz สำหรับข้อมูลการเคลื่อนและข้อมูลนาฬิกา ในส่วนของจุดกึ่งกลางของทางเดิน หรือ ส่วนของการเดินเลี้ยว และการข้ามสิ่งกีดขวาง จุดเริ่มต้นสัมผัสและการเขย่งของขาซ้ายและขวาถูกระบุโดยใช้ 2 ก้าวของขาซ้ายและขาขวา

3.7.1.4 ผลจากการวัด

ตัวแปรท่าทางการเดินประกอบด้วย left และ right cadence, ความเร็วในการเดิน, stride time, step time, opposite foot off, opposite foot contact, foot off, single support, double support, stride length, และ step width ถูกนำมาเปรียบเทียบในเชิงพื้นที่-เวลา ระหว่างข้อมูลของกลุ่มผู้เคยมีและไม่มีประวัติการหกล้ม

3.7.1.5 ผลลัพธ์

- ข้อมูลที่เกี่ยวข้องกับสถิติประชากรของผู้เข้าร่วมทดสอบ

ข้อมูลเกี่ยวกับสถิติประชากรของผู้เข้าร่วมทดสอบแสดงในตารางที่ 9 ค่าเฉลี่ยอายุของผู้ไม่มีและมีประวัติการหกล้มอยู่ที่ 67.60 ± 4.38 และ 68.00 ± 5.27 ปีตามลำดับ โดยมีผู้ชาย 1 คนและผู้หญิง 9 คนในแต่ละกลุ่มที่ใช้ในการศึกษา

ตารางที่ 9 ข้อมูลที่เกี่ยวกับสถิติประชากรของผู้เข้าร่วมทดสอบ

รายละเอียด	ผู้ไม่มีประวัติการหกล้ม ค่าเฉลี่ย \pm ค่าเบี่ยงเบนมาตรฐาน หรือ n (%)	ผู้มีประวัติการหกล้ม ค่าเฉลี่ย \pm ค่าเบี่ยงเบนมาตรฐาน หรือ n (%)
เพศ: ชาย/ หญิง	1 (10%) / 9 (90%)	1 (10%) / 9 (90%)
อายุ (ปี)	67.60 \pm 4.38	68.00 \pm 5.27
น้ำหนัก (kg)	53.82 \pm 8.87	56.24 \pm 8.66
ส่วนสูง (cm)	153.92 \pm 5.22	152.00 \pm 6.65
MoCA	26.10 \pm 2.38	26.50 \pm 2.37
FES-I	19.50 \pm 3.37	30.90 \pm 14.15
BI	100.00 \pm 0.00	99.00 \pm 2.11

Note: MoCA (Montreal Cognitive Assessment), FES-I (Falls Efficacy Scale International), BI (Barthel index of activities of daily living)

- ผลการเปรียบเทียบข้อมูลเชิงพื้นที่-เวลา ของตัวแปรการเดินของผู้ที่มีและไม่มีประวัติการหกล้ม

ตารางที่ 10 – 14 แสดงให้เห็นถึงการเปรียบเทียบข้อมูลตัวแปรการเดินเชิงพื้นที่-เวลา ระหว่างกลุ่มผู้ไม่มีและมีการหกล้ม โดยมีความแตกต่างอย่างมีนัยสำคัญ ($p < 0.05$) ของตัวแปรการเดินเชิงพื้นที่-เวลา ระหว่างข้อมูลสองกลุ่มนี้ ในสภาพของการเดินก้าวข้ามสิ่งกีดขวาง และการเดินเลี้ยว ในขณะที่สภาพการทดสอบอื่นไม่แสดงให้เห็นถึงความแตกต่างอย่างมีนัยสำคัญ ($p > 0.05$)

สำหรับการข้ามสิ่งกีดขวาง พบความแตกต่างในส่วนของ cadence ($p=0.005$), walking speed ($p=0.017$), และ stride time ($p=0.007$) ของฝั่งซ้าย ในส่วนของการเดินเลี้ยวพบความแตกต่างอย่างมีนัยสำคัญในส่วนของ cadence ($p < 0.001$), stride time ($p < 0.001$), step time ($p < 0.001$), opposite foot off ($p=0.023$), foot off ($p=0.045$), single support ($p=0.006$), และ double support ($p < 0.001$) ของฝั่งซ้าย นอกจากนี้พบความแตกต่างอย่างมีนัยสำคัญใน opposite foot off ($p=0.002$) ของฝั่งขวา

ตารางที่ 10 ข้อมูลท่าทางการเดินแบบพ่นคล้าย

Side	Variable	Unit	Non-faller		Faller		t	df	p-value**
			Mean	SD	Mean	SD			
Left	Cadence	steps/min	120.00	9.29	119.38	10.98	0.138	18	0.892
Left	Walking Speed	m/s	1.19	0.23	1.18	0.21	0.061	18	0.952
Left	Stride Time	s	1.01	0.08	1.02	0.09	-0.217	18	0.831
Left	Step Time	s	0.50	0.06	0.51	0.06	-0.267	18	0.793
Left	Opposite Foot Off	%	10.95	2.86	9.31	3.69	1.114	18	0.280
Left	Opposite Foot Contact	%	50.37	2.12	50.09	2.37	0.281	18	0.782
Left	Foot Off	%	61.98	3.18	59.55	2.57	1.878	18	0.077
Left	Single Support	s	0.40	0.04	0.41	0.05	-0.631	18	0.536
Left	Double Support	s	0.23	0.04	0.19	0.05	1.786	18	0.091
Left	Stride Length	m	1.18	0.17	1.19	0.16	-0.095	18	0.926
Left	Step Length	m	0.57	0.14	0.59	0.09	-0.266	18	0.793
Left	Step Width	m	0.14	0.04	0.10	0.07	1.440	14.457*	0.171
Right	Cadence	steps/min	123.85	7.61	122.80	6.28	0.336	18	0.741
Right	Walking Speed	m/s	1.13	0.34	1.12	0.33	0.067	18	0.947
Right	Stride Time	s	0.97	0.06	0.98	0.05	-0.249	18	0.807
Right	Step Time	s	0.48	0.05	0.47	0.06	0.173	18	0.864
Right	Opposite Foot Off	%	11.94	1.90	9.69	2.10	2.514	18	0.022
Right	Opposite Foot Contact	%	51.40	4.14	52.05	5.34	-0.307	18	0.762
Right	Foot Off	%	61.61	3.12	61.90	3.65	-0.196	18	0.847
Right	Single Support	s	0.38	0.06	0.42	0.05	-1.437	18	0.168
Right	Double Support	s	0.22	0.04	0.19	0.07	0.936	18	0.362
Right	Stride Length	m	1.09	0.29	1.09	0.29	0.000	18	1.000
Right	Step Length	m	0.56	0.10	0.54	0.13	0.410	18	0.687
Right	Step Width	m	0.19	0.06	0.17	0.11	0.423	13.474*	0.679

Note: *Equal variance not assumed, **significant difference testing by the Independent sample t-test at $p < 0.05$

ตารางที่ 11 ข้อมูลท่าทางการเดินเร็ว

Side	Variable	Unit	Non-faller		Faller		t	df	p-value**
			Mean	SD	Mean	SD			
Left	Cadence	steps/min	107.77	12.21	115.46	8.06	-1.662	18	0.114
Left	Walking Speed	m/s	1.02	0.22	1.07	0.21	-0.531	18	0.602
Left	Stride Time	s	1.13	0.13	1.05	0.08	1.762	18	0.095
Left	Step Time	s	0.58	0.07	0.53	0.03	1.890	18	0.075
Left	Opposite Foot Off	%	8.92	1.98	9.98	2.34	-1.095	18	0.288
Left	Opposite Foot Contact	%	49.01	2.39	49.48	0.70	-0.597	10.530*	0.563
Left	Foot Off	%	59.11	3.31	59.41	0.95	-0.274	10.473*	0.789
Left	Single Support	s	0.45	0.06	0.42	0.06	1.411	18	0.175
Left	Double Support	s	0.22	0.04	0.21	0.03	0.539	18	0.597
Left	Stride Length	m	1.12	0.15	1.11	0.21	0.125	18	0.902
Left	Step Length	m	0.56	0.08	0.54	0.13	0.457	18	0.653
Left	Step Width	m	0.15	0.05	0.13	0.05	0.532	18	0.602
Right	Cadence	steps/min	109.31	10.51	117.36	6.89	-2.024	18	0.058
Right	Walking Speed	m/s	1.02	0.26	1.02	0.33	-0.053	18	0.958
Right	Stride Time	s	1.11	0.11	1.03	0.06	2.048	18	0.055
Right	Step Time	s	0.53	0.05	0.50	0.05	1.451	18	0.164
Right	Opposite Foot Off	%	10.36	2.24	10.11	1.15	0.316	18	0.756
Right	Opposite Foot Contact	%	52.03	2.95	51.49	2.92	0.412	18	0.685
Right	Foot Off	%	61.82	2.80	62.43	3.00	-0.465	18	0.648
Right	Single Support	s	0.47	0.08	0.43	0.03	1.442	18	0.166
Right	Double Support	s	0.22	0.04	0.22	0.05	0.290	18	0.775
Right	Stride Length	m	1.10	0.20	1.04	0.31	0.537	18	0.598
Right	Step Length	m	0.56	0.09	0.54	0.13	0.321	18	0.752
Right	Step Width	m	0.18	0.09	0.18	0.10	-0.140	18	0.890

Note: *Equal variance not assumed, **significant difference testing by the Independent sample t-test at $p < 0.05$

ตารางที่ 12 ข้อมูลท่าทางระหว่างก้าวข้ามสิ่งกีดขวาง

Side	Variable	Unit	Non-faller		Faller		t	df	p-value**
			Mean	SD	Mean	SD			
Left	Cadence	steps/min	107.66	5.26	116.94	7.48	-3.207	18	0.005
Left	Walking Speed	m/s	1.07	0.11	1.21	0.13	-2.634	18	0.017
Left	Stride Time	s	1.12	0.05	1.03	0.07	3.038	18	0.007
Left	Step Time	s	0.55	0.04	0.51	0.04	2.096	18	0.051
Left	Opposite Foot Off	%	12.16	4.30	9.01	4.08	1.677	18	0.111
Left	Opposite Foot Contact	%	51.05	2.82	50.53	2.09	0.466	18	0.647
Left	Foot Off	%	60.35	2.38	60.32	2.22	0.021	18	0.983
Left	Single Support	s	0.43	0.05	0.43	0.04	0.285	18	0.779
Left	Double Support	s	0.24	0.05	0.20	0.05	1.989	18	0.062
Left	Stride Length	m	1.20	0.10	1.24	0.10	-1.072	18	0.298
Left	Step Length	m	0.58	0.06	0.60	0.09	-0.538	18	0.597
Left	Step Width	m	0.24	0.33	0.11	0.04	1.223	18	0.237
Right	Cadence	steps/min	99.50	35.18	116.48	12.40	-1.439	18	0.167
Right	Walking Speed	m/s	1.06	0.15	1.09	0.42	-0.190	11.203*	0.853
Right	Stride Time	s	11.74	33.68	1.05	0.15	1.004	9.000*	0.342
Right	Step Time	s	0.60	0.16	0.54	0.15	0.854	18	0.404
Right	Opposite Foot Off	%	8.98	3.23	9.38	1.58	-0.352	18	0.729
Right	Opposite Foot Contact	%	44.78	15.62	49.52	6.74	-0.881	18	0.390
Right	Foot Off	%	56.20	16.12	62.35	3.05	-1.186	18	0.251
Right	Single Support	s	5.37	15.62	0.41	0.04	1.005	9.000*	0.341
Right	Double Support	s	6.28	19.11	0.24	0.13	0.998	9.001*	0.344
Right	Stride Length	m	1.08	0.27	1.09	0.40	-0.059	18	0.953
Right	Step Length	m	0.54	0.13	0.58	0.17	-0.587	18	0.564
Right	Step Width	m	0.15	0.11	0.17	0.08	-0.307	18	0.762

Note: *Equal variance not assumed, **significant difference testing by the Independent sample t-test at $p < 0.05$

ตารางที่ 13 ข้อมูลท่าทางการเดินและหยุดไปด้วย

Side	Variable	Unit	Non-faller		Faller		t	df	p-value**
			Mean	SD	Mean	SD			
Left	Cadence	steps/min	109.87	14.87	114.90	12.63	-0.816	18	0.425
Left	Walking Speed	m/s	0.92	0.29	1.02	0.21	-0.844	18	0.409
Left	Stride Time	s	1.11	0.14	1.06	0.12	0.917	18	0.371
Left	Step Time	s	0.56	0.08	0.53	0.07	0.893	18	0.384
Left	Opposite Foot Off	%	11.13	2.17	10.75	2.69	0.353	18	0.728
Left	Opposite Foot Contact	%	49.71	2.45	50.08	2.14	-0.359	18	0.724
Left	Foot Off	%	59.94	3.84	59.92	3.27	0.008	18	0.994
Left	Single Support	s	0.43	0.06	0.42	0.05	0.513	18	0.614
Left	Double Support	s	0.24	0.06	0.22	0.05	0.861	18	0.401
Left	Stride Length	m	0.99	0.24	1.06	0.14	-0.728	18	0.476
Left	Step Length	m	0.51	0.10	0.52	0.07	-0.335	18	0.742
Left	Step Width	m	0.14	0.08	0.13	0.05	0.350	18	0.731
Right	Cadence	steps/min	113.98	10.54	118.09	16.87	-0.654	18	0.521
Right	Walking Speed	m/s	0.99	0.22	0.99	0.28	-0.009	18	0.993
Right	Stride Time	s	1.06	0.09	1.04	0.19	0.272	18	0.789
Right	Step Time	s	0.53	0.05	0.52	0.13	0.255	18	0.801
Right	Opposite Foot Off	%	9.20	2.16	9.64	2.33	-0.431	18	0.672
Right	Opposite Foot Contact	%	50.43	3.36	50.78	3.32	-0.234	18	0.818
Right	Foot Off	%	62.56	3.45	62.13	2.70	0.304	18	0.764
Right	Single Support	s	0.44	0.06	0.42	0.06	0.529	18	0.603
Right	Double Support	s	0.23	0.05	0.23	0.07	0.107	18	0.916
Right	Stride Length	m	1.04	0.18	0.99	0.20	0.537	18	0.598
Right	Step Length	m	0.52	0.13	0.50	0.10	0.289	18	0.776
Right	Step Width	m	0.15	0.07	0.17	0.07	-0.649	18	0.524

Note: *Equal variance not assumed, **significant difference testing by the Independent sample t-test at $p < 0.05$

ตารางที่ 14 ข้อมูลท่าทางการเดินและก้าว

Side	Variable	Unit	Non-faller		Faller		t	df	p-value**
			Mean	SD	Mean	SD			
Left	Cadence	steps/min	121.71	9.91	96.34	10.00	5.699	18	<0.001
Left	Walking Speed	m/s	1.06	0.21	0.88	0.16	2.095	18	0.051
Left	Stride Time	s	0.99	0.08	1.26	0.12	-5.758	18	<0.001
Left	Step Time	s	0.49	0.04	0.60	0.05	-5.510	18	<0.001
Left	Opposite Foot Off	%	9.77	2.25	13.03	3.49	-2.484	18	0.023
Left	Opposite Foot Contact	%	51.13	1.68	51.92	1.82	-1.003	18	0.329
Left	Foot Off	%	60.25	2.98	62.52	1.15	-2.247	11.610*	0.045
Left	Single Support	s	0.41	0.05	0.49	0.07	-3.110	18	0.006
Left	Double Support	s	0.19	0.04	0.30	0.07	-4.310	18	<0.001
Left	Stride Length	m	1.05	0.17	1.10	0.11	-0.801	18	0.433
Left	Step Length	m	0.51	0.10	0.55	0.07	-1.090	18	0.290
Left	Step Width	m	0.20	0.15	0.16	0.05	0.788	18	0.441
Right	Cadence	steps/min	114.67	21.74	99.26	8.42	2.090	18	0.051
Right	Walking Speed	m/s	1.02	0.28	0.85	0.20	1.620	18	0.123
Right	Stride Time	s	7.01	19.01	1.22	0.10	0.964	9.000*	0.360
Right	Step Time	s	0.54	0.12	0.61	0.05	-1.730	18	0.101
Right	Opposite Foot Off	%	7.81	2.14	10.79	1.49	-3.620	18	0.002
Right	Opposite Foot Contact	%	46.63	8.38	49.68	1.15	-1.141	9.337*	0.282
Right	Foot Off	%	57.68	7.78	62.14	2.08	-1.750	18	0.097
Right	Single Support	s	3.02	8.24	0.47	0.03	0.976	9.000*	0.355
Right	Double Support	s	3.47	10.36	0.29	0.05	0.971	9.000*	0.357
Right	Stride Length	m	0.98	0.22	1.02	0.19	-0.458	18	0.652
Right	Step Length	m	0.52	0.09	0.50	0.09	0.533	18	0.601
Right	Step Width	m	0.19	0.10	0.21	0.10	-0.515	18	0.613

Note: *Equal variance not assumed, **significant difference testing by the Independent sample t-test at p <0.05

3.7.1.6 สรุปผล

ความแตกต่างของตัวแปรการเดินระหว่างกลุ่มผู้ไม่มีและมีประวัติการหกล้มถูกพบในการเดินข้ามสิ่งกีดขวาง และการก้าวเท่านั้น ซึ่งเป็นสิ่งบ่งชี้ความสำคัญของการเดินในสองสภาพนี้ต่อการเปลี่ยนแปลงการเคลื่อนไหวของผู้สูงอายุที่มีประวัติการหกล้มมาก่อน


เมื่อพิจารณาตัวแปรการเดินที่ถูกเปลี่ยนแปลง ซึ่งส่วนใหญ่จะพบในฝั่งซ้าย ตามกระบวนการวิจัย ฝั่งนี้เป็นฝั่งที่ถูกใช้เพื่อปรับเปลี่ยนท่าทางก่อนที่ขาขวาจะก้าวข้ามสิ่งกีดขวางและถูกใช้เพื่อปรับเปลี่ยนก่อนและหลังจากที่ผู้เข้าร่วมทดสอบเดินก้าวขวา ดังนั้นการรับรู้ข้อมูลระหว่างการปรับเปลี่ยนท่าทางอาจเป็นบทบาทสำคัญสำหรับกลุ่มประชากรกลุ่มนี้ การวิเคราะห์เชิงลึกของข้อมูลร่วมกับตัวแปรทางชีวกลศาสตร์อาจจะให้ข้อมูลที่กระจ่างชัดของกลไกที่ถูกใช้ในแต่ละผู้เข้าร่วมทดสอบที่มีประวัติการหกล้ม

3.8 ระบบประมวลผลส่วนหน้า (Edge processing unit)

ทีมวิจัยได้พัฒนาระบบ IoT สำหรับเฝ้าดูผู้สูงอายุซึ่งใช้บอร์ด Nvidia Jetson TX2 ในการประมวลผลหลักสำหรับการตรวจจับและตามรอยบุคคล ส่วนการแยกแยะวิเคราะห์การเคลื่อนไหวจะถูกประมวลผลบนเครื่องคอมพิวเตอร์แม่ข่ายบนคลาวด์ ที่เชื่อมต่อผ่านเครือข่ายอินเทอร์เน็ต ดังได้อธิบายรายละเอียดในหัวข้อ 3.2-3.4 เมื่อระบบตรวจจับการหกล้ม หรือ การเดินที่ไม่มั่นคง ระบบจะส่งการแจ้งเตือนไปยังผู้ดูแล หรือ ผู้รับผิดชอบ

การพัฒนาซอฟต์แวร์การประมวลผลภาพเพื่อให้รันได้บนบอร์ด TX-2 ทีมวิจัยได้พัฒนาซอฟต์แวร์ Elder Care Video Analytics ขึ้นมา 3 เวอร์ชันดังได้อธิบายไว้ก่อนหน้านี้

อุปกรณ์ระบบต้นแบบแสดงในรูปที่ 58 เป็นอุปกรณ์ที่ทีมวิจัยใช้ในช่วงเริ่มต้น มีระบบต้นแบบทั้งหมดจำนวน 2 ชุดเพื่อใช้ในการรันซอฟต์แวร์แอปพลิเคชัน Elder Care v0.1 ในการทดสอบเบื้องต้น โดยยังใช้งาน TX-2 บนบอร์ด Development Kit



รูปที่ 58 ระบบต้นแบบเฝ้าดูวิดีโอแบบ IoT สำหรับดูแลผู้สูงอายุ


ทีมวิจัยได้พัฒนาระบบต้นแบบเวอร์ชันที่สองซึ่งสามารถรันระบบประมวลผลภาพ Elder Care Video Analytics v.0.3 เพื่อใช้ในการนำไปติดตั้งและใช้งานจริงในบ้านอาสาสมัคร ระบบต้นแบบเวอร์ชันที่สองใช้บอร์ดระบบสมองกลฝังตัวขนาดเล็กหรือเรียกอีกอย่างหนึ่งว่า “carrier board” แทนที่ชุดบอร์ด Development Kit ซึ่งมีช่องอุปกรณ์ต่อพ่วงและส่วนติดต่อกับอุปกรณ์อื่นจำนวนมากซึ่งส่วนติดต่อกับอุปกรณ์อื่นบางส่วนไม่ถูกใช้งานในการใช้งานจริงทำให้บอร์ดมีขนาดใหญ่ โดยที่ carrier board นั้นมีเฉพาะส่วนติดต่อกับอุปกรณ์อื่นที่จำเป็นและมีขนาดเล็กทำให้เหมาะแก่การนำไปใช้งานและติดตั้งได้ง่าย รูปที่ 59 แสดงให้เห็นการเปรียบเทียบระหว่างระบบต้นแบบเวอร์ชันที่ 1 เทียบกับระบบต้นแบบเวอร์ชันที่ 2 ซึ่งมีขนาดเล็กลงมาก หน่วยประมวลผลหลักยังคงเป็น NVIDIA TX-2 เหมือนเดิม ส่วน carrier board ทีมวิจัยใช้บอร์ดรุ่น LI-TX1-CB Rev.1.3 ผลิตโดย Leopard Imaging ซึ่งสามารถเชื่อมต่อกับกล้องผ่านอินเตอร์เฟซ MIPI ได้ ซึ่งถือเป็นอีกหนึ่งตัวเลือกในการเพิ่มโมดูลการรับภาพ (image sensor) นอกเหนือจากการประมวลผลจากกล้อง IP รายละเอียดของบอร์ดแสดงดังต่อไปนี้

Model: LI-TX1-CB Rev.1.3

Support: NVIDIA Jetson TX-1 and TX-2

Interfaces:

- 3 MIPI camera interfaces
 - 1 Micro SD card
 - 1 USB3.0 Type A connector
 - 1 HDMI connector
 - 1 Power socket (12V DC)
 - 1 RJ45 connector
 - 1 USB2.0 micro B interface
 - 1 Fan connector (4 pin)
 - 1 UART interface (4 pin)
- Size: 87mm x 87mm



รูปที่ 59 การเปรียบเทียบระหว่างระบบต้นแบบเวอร์ชันที่ 1 (ซ้าย) และระบบต้นแบบเวอร์ชันที่ 2 (ขวา)

หน่วยรับภาพสำหรับระบบ Elder Care Video Analytics จะใช้กล้อง IP เป็นหน่วยรับภาพ และทำการเชื่อมต่อกับระบบต้นแบบผ่านการเชื่อมต่อแบบ LAN ระบบ Elder Care Video

Analytics ใช้วิดีโอสตรีมขนาด 1920x1080 พิกเซล (2 ล้านพิกเซล) เป็นข้อมูลนำเข้าของระบบ โดยสตรีมวิดีโอแบบโปรโตคอล RTSP โดยกล้อง IP ที่ทีมวิจัยใช้มีคุณสมบัติทางเทคนิคดังต่อไปนี้

ขนาดเซ็นเซอร์รับภาพ: 1/2.5” Progressive Scan CMOS

ความละเอียดภาพ: 50Hz: 2688x1520, 2304x1296, 1920x1080 @ 25 fps

60Hz: 2688x1520, 2304x1296, 1920x1080 @ 30 fps

ความยาวระยะโฟกัส: 2.8 mm - 12 mm

มุมมองการมองเห็น: แนวนอน 114 - 32 องศา

แนวตั้ง 59 - 18 องศา

Video Encoding: H.264, H.265 และ MJPEG

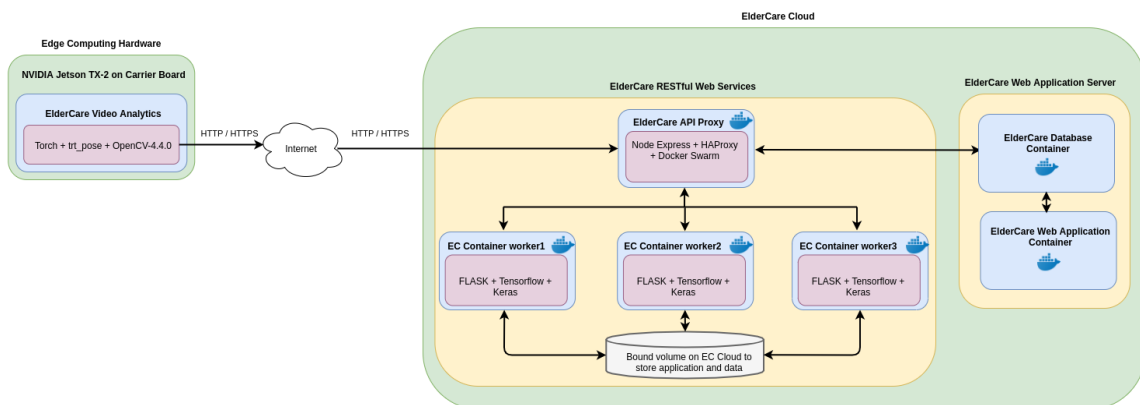
Network protocols: TCP/IP, ICMP, HTTP, HTTPS, RTSP

3.9 ระบบส่วนหลัง (Backend system)

ระบบส่วนหลังเป็นเว็บเซิร์ฟเวอร์ ซึ่งรับข้อมูลจากโมดูลการประมวลผลส่วนหน้าและทำการวิเคราะห์กิจกรรมและการเคลื่อนที่ และส่งการแจ้งเตือนแบบเรียลไทม์ไปยังผู้ดูแล หรือ ผู้รับผิดชอบ ในกรณีที่ระบบตรวจพบการเคลื่อนที่ที่ผิดปกติ หรือ การหกล้ม ทีมวิจัยได้ออกแบบระบบส่วนหลัง ซึ่งประกอบด้วย 2 ระบบหลัก โดยระบบแรกเรียกว่า “เซิร์ฟเวอร์การประมวลผลภาพ (video analytics services)” ซึ่งทำหน้าที่ในการแยกแยะประเภทกิจกรรม (การรู้จำประเภทกิจกรรม) ตรวจจับการหกล้ม ตรวจจับการเคลื่อนที่ที่ผิดปกติ/คาดการณ์การหกล้ม ส่วนระบบที่สองเรียกว่า “เซิร์ฟเวอร์แจ้งเตือน (notification services)” ทำหน้าที่ในการส่งการแจ้งเตือนไปยังผู้ใช้งาน (ผู้ดูแล) และทำหน้าที่ในการแสดงผลการสรุปข้อมูลประเภทกิจกรรมที่ตรวจพบผ่านเว็บแอปพลิเคชัน โดยมีรายละเอียดดังต่อไปนี้

3.9.1 เซิร์ฟเวอร์การประมวลผลภาพ (Video analytics services)

อุปกรณ์ประมวลผลส่วนหน้าประมวลผลภาพจากวิดีโอสตรีมในการตรวจจับและตามรอยบุคคล และทำการส่งข้อมูลดังกล่าวมาวิเคราะห์โดยทำการส่งข้อมูลผ่าน APIs ฝั่งคลาวด์ เซิร์ฟเวอร์ ทีมวิจัยใช้แอปพลิเคชัน Node JS (Node Express) ในการรับ POST request จากหน่วยประมวลผลส่วนหน้าและทำการส่งข้อมูลที่ได้รับไปยังระบบแยกแยะประเภทกิจกรรม, ตรวจจับการหกล้ม, ตรวจจับการเคลื่อนที่ที่ไม่มั่นคง ซึ่งใช้เฟรมเวิร์ก FLASK เป็นหลักร่วมกับ Tensorflow และ Keras ส่วนการกระจายภาระงานทำหน้าที่โดยใช้ HA Proxy ร่วมกับ Docker Swarm รูปที่ 60 แสดงให้เห็นถึงการออกแบบระบบของเซิร์ฟเวอร์การประมวลผลภาพบนระบบคลาวด์ Elder Care



รูปที่ 60 สถาปัตยกรรมระบบคลาวด์ Elder Care

ระบบคลาวด์ Elder Care ประกอบด้วย 3 ส่วนหลัก คือ RESTful Elder Care Web APIs และ Elder Care Web Application และ Elder Care Worker

โดยที่ RESTful Elder Care Web APIs ประกอบด้วย 2 ส่วนย่อย คือ ส่วนที่เป็น API Proxy ซึ่งพัฒนาโดยใช้ Node Express จะทำหน้าที่ในการรับข้อมูลจากระบบประมวลผลส่วนหน้าผ่าน POST request ซึ่งประกอบด้วยข้อมูลโครงร่างของร่างกาย (skeleton keypoints) ตำแหน่งกรอบสี่เหลี่ยมของโครงร่างของร่างกายที่ตรวจพบ และข้อมูลภาพที่ทำหน้าที่จะถูกนำไปใช้ในการรู้จำ

ใบหน้าบุคคล โดยที่ API Proxy นี้จะรันอยู่บน NGINX ซึ่งทำงานร่วมกับ HAProxy และ Docker Swarm เพื่อจะทำการแจกจ่ายภาระงาน โดย Docker Swarm จะควบคุมการทำงานของ Elder Care Worker (EC Worker) ซึ่งรันอยู่บนเครื่องคอมพิวเตอร์ที่มีหน่วยประมวลผลกราฟิกจำนวน 3 เครื่อง เมื่อ API Proxy ได้รับข้อมูลจะทำการบริหารจัดการกับรูปภาพและข้อมูลที่อัปโหลดขึ้นมา จากนั้นส่งต่อไปให้กับ EC Worker เพื่อทำการวิเคราะห์ประเภทกิจกรรม ตรวจสอบการหกล้ม วิเคราะห์การเคลื่อนไหวที่ไม่มั่นคง และทำการรู้จำใบหน้าบุคคล และทำการบันทึกข้อมูลลงไปยังฐานข้อมูล ซึ่งจะถูกนำไปแสดงผลบน Elder Care Web Application หากระบบสามารถตรวจจับการหกล้ม (fall detection) การเคลื่อนไหวที่ไม่มั่นคง (unstable movement detection) รวมไปถึงการตรวจจับบุคคลที่ไม่อยู่ในอาณาบริเวณที่กำหนด (absence detection) ระบบ API Proxy จะทำการแจ้งเตือนผู้ใช้งานโดยการเรียก LINE Notify API เพื่อส่งข้อมูลการแจ้งเตือนไปยังผู้ใช้งานที่ลงทะเบียนไว้ในระบบ

ระบบเซอร์วิสการประมวลผลภาพแบ่งออกเป็น 3 ระบบหลัก ได้แก่

- ระบบรู้จำใบหน้าบุคคล
- ระบบแยกแยะประเภทท่าทาง และตรวจจับการหกล้ม
- ระบบตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

รายละเอียดการวิจัยและพัฒนาเซอร์วิสการประมวลผลภาพ อธิบายในรายละเอียดดังต่อไปนี้

3.9.1.a รูปแบบข้อมูลสำหรับการประมวลผลบนเว็บเซอร์วิส

ในการทำงานของระบบ Elder Care Video Analytics ระบบจะทำการตรวจจับและตามรอยบุคคลตลอดเวลาที่บุคคลปรากฏตัวในมุมมอง โดยทุก ๆ 40 เฟรมของการตามรอยระบบจะส่งข้อมูลในรูปแบบของ JSON ไปยัง RESTful API เพื่ออัปโหลดข้อมูลที่ประกอบด้วย

- หมายเลขบ้าน (house ID)
- หมายเลขกล้อง (camera ID)
- หมายเลขการตามรอย (track ID)
- จำนวนเฟรมที่ตามรอยบุคคลได้
- รายการจุดโครงร่างของร่างกายในแต่ละเฟรมที่ตรวจพบ
- วันและเวลาที่ตรวจพบ
- รูปภาพตัวแทนการตามรอย (track representative frame)

สำหรับการรู้จำใบหน้าบุคคล

ในกรณีที่การตามรอยบุคคลไม่ครบจำนวน 40 เฟรม ซึ่งอาจเกิดจากการตามรอยบุคคลหลุดบุคคลเคลื่อนที่ออกจากมุมมอง ฟังก์ชันเว็บเซอร์วิสจะทำการ padding ข้อมูลที่ขาดหายด้วยค่า 0 สำหรับข้อมูลโครงร่างของร่างกาย สำหรับรูปภาพตัวแทนการตามรอยในกรณีที่ไม่มีตรวจพบใบหน้าบุคคล เฟรมแรกของการตามรอยจะถูกนำมาใช้

ข้อมูลหมายเลขบ้าน หมายเลขกล้อง และ หมายเลขการตามรอย จะถูกนำมาใช้กำหนดเป็น key ในการรวบรวมข้อมูลผลการแยกแยะประเภทท่าทาง และการเคลื่อนไหวที่ไม่มั่นคง ส่วนข้อมูลวันและเวลาที่ตรวจพบจะเป็นข้อมูลที่ถูกนำมาคำนวณเวลา เพื่อให้เว็บเซอร์วิสลบข้อมูลที่

ค้ำใน circular buffer หากแตร็กดังกล่าวไม่มีการส่งข้อมูลอัปเดตเพิ่มภายในระยะเวลาที่กำหนด เพื่อที่จะคืนทรัพยากรในการประมวลผล และทำการสรุปผลการวิเคราะห์ท่าทางและการเคลื่อนไหวที่ไม่มั่นคงและอัปเดตข้อมูลในฐานข้อมูล ดังนั้นผลลัพธ์ที่แสดงบนระบบเว็บแอปพลิเคชัน Elder Care จะแสดงข้อมูลของการตามรอย 40 เฟรมสุดท้าย แต่ในกรณีที่ระบบวิเคราะห์ท่าทางได้ผลลัพธ์เป็นการหกล้ม หรือ ระบบวิเคราะห์การเคลื่อนไหวที่ไม่มั่นคงได้ ระบบจะทำการสร้างข้อความแจ้งเตือนและบันทึกไปยังฐานข้อมูล ก่อนจะเรียก LINE API เพื่อส่งข้อความไปยังผู้ใช้งานเพื่อแจ้งเตือนการหกล้ม หรือ การเคลื่อนไหวที่ไม่มั่นคง

3.9.1.b ระบบรู้จำใบหน้าบุคคล

ระบบรู้จำใบหน้าบุคคลทำการรับรูปภาพตัวแทนการตามรอย เพื่อนำมาใช้ในการรู้จำใบหน้าบุคคล โดยภาพจะถูกนำมาตรวจหาตำแหน่งใบหน้าและจัดตำแหน่งโดยอัลกอริทึม MTCNN ในกรณีที่ตรวจจับใบหน้าบุคคลและจัดตำแหน่งใบหน้าได้ ทีมวิจัยใช้ Facenet ในการดึงข้อมูล face embedding โดยใช้ pretrained weights เพื่อนำ face embedding ที่ได้ไปเปรียบเทียบกับ face embedding ของรูปภาพของใบหน้าบุคคลในครอบครัวตามหมายเลขบ้าน (house ID) ในฐานข้อมูล เพื่อทำการระบุตัวตนและบันทึกลงในฐานข้อมูล ในกรณีที่ตรวจจับหรือจัดตำแหน่งใบหน้าไม่ได้ระบบจะทำการบันทึกค่าเป็น “undefined” ในฐานข้อมูล

3.9.1.c ระบบแยกแยะประเภทท่าทาง และตรวจจับการหกล้ม

การทำงานของระบบแยกแยะประเภทท่าทางและตรวจจับการหกล้ม จะใช้รายการจุดโครงร่างของร่างกาย (skeleton keypoint list) ในแต่ละเฟรมที่ตรวจพบเป็นข้อมูลนำเข้าจำนวน 40 เฟรม เพื่อวิเคราะห์ประเภทท่าทางที่ตรวจพบสำหรับอัลกอริทึมที่แยกแยะท่าทางและตรวจจับการหกล้มแบบทีละเฟรม จะได้ผลลัพธ์การแยกแยะท่าทางเป็นรายเฟรม และผลลัพธ์สุดท้ายจะมาจาก majority vote เพื่อสรุปประเภทท่าทางที่มีจำนวนเยอะที่สุด ต่างจากอัลกอริทึมแบบ LSTM ซึ่งให้ผลลัพธ์ประเภทท่าทางเพียง 1 ผลลัพธ์จากข้อมูลนำเข้าทั้งหมด 40 เฟรม ข้อมูลสรุปประเภทท่าทางจะถูกบันทึกไปยังฐานข้อมูล ในกรณีที่การตามรอยมีมากกว่า 40 เฟรม เว็บเซอร์วิสจะใช้หมายเลขบ้าน หมายเลขกล้อง และหมายเลขการตามรอยในการอัปเดตข้อมูลในฐานข้อมูล และอัปเดตรายการท่าทางที่ตรวจพบของแต่ละการตามรอย หากประเภทท่าทางที่สรุปได้เป็นการหกล้ม ระบบจะทำการสร้างการแจ้งเตือนเพื่อส่งข้อมูลและเรียก LINE API เพื่อส่งข้อความแจ้งเตือนผู้ใช้งาน

3.9.1.d ระบบตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

การทำงานของระบบตรวจจับการเคลื่อนไหวที่ไม่มั่นคง จะใช้รายการจุดโครงร่างของร่างกาย (skeleton keypoint list) ในแต่ละเฟรมที่ตรวจพบ เป็นข้อมูลนำเข้าจำนวน 40 เฟรม เพื่อวิเคราะห์ว่าเป็นการเคลื่อนไหวที่ไม่มั่นคงหรือไม่ โดยลักษณะการทำงานจะคล้ายกับอัลกอริทึมแบบ LSTM ที่ใช้ในการแยกแยะประเภทท่าทาง ซึ่งให้ผลลัพธ์เพียง 1 ผลลัพธ์จากข้อมูลนำเข้าทั้งหมด 40 เฟรม ข้อมูลสรุปว่าลำดับการเคลื่อนไหวที่เป็นข้อมูลนำเข้าเป็นการเคลื่อนไหวแบบไม่มั่นคงหรือไม่นั้น จะถูกบันทึกลงไปยังฐานข้อมูล ในกรณีที่การตามรอยมีมากกว่า 40 เฟรม เว็บเซอร์วิสจะใช้หมายเลขบ้าน หมายเลขกล้อง และหมายเลขการตามรอย ในการอัปเดตข้อมูลในฐานข้อมูล และอัปเดตผลการวิเคราะห์ท่าทางที่ตรวจพบของแต่ละการตามรอย หากประเภทการเคลื่อนไหวที่สรุปได้เป็นการเคลื่อนไหวแบบไม่มั่นคง ระบบจะทำการสร้างการแจ้งเตือนเพื่อส่งข้อมูลและเรียก LINE API เพื่อส่งข้อความแจ้งเตือนผู้ใช้งาน

3.9.2 เซอร์วิสการแจ้งเตือน (notification services)

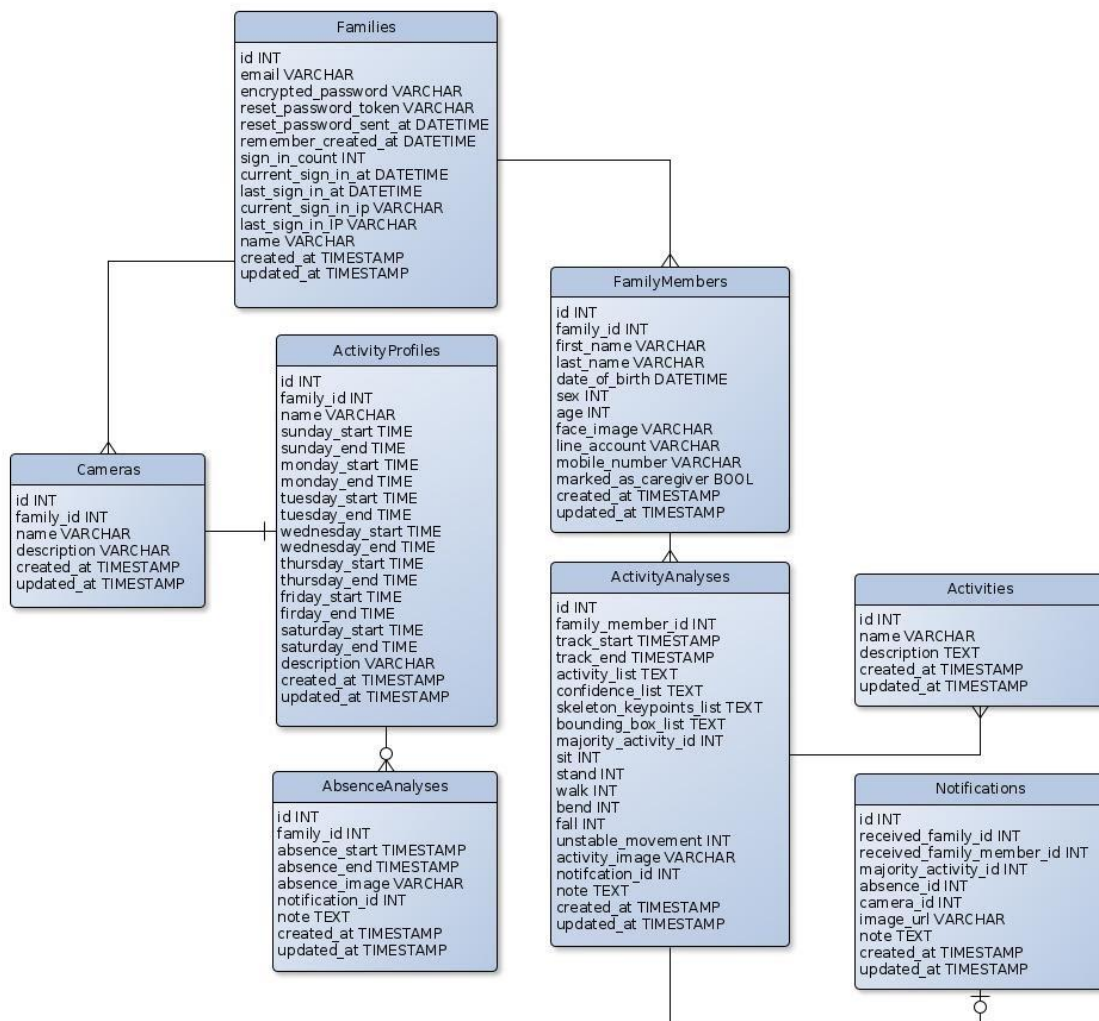
ในส่วนของเซอร์วิสการแจ้งเตือน การทำงานจะอยู่ในรูปแบบของการส่งข้อมูลการแจ้งเตือนแบบเรียลไทม์ไปยังอุปกรณ์โทรศัพท์มือถือของผู้ดูแล หรือผู้รับผิดชอบ ทีมวิจัยใช้ LINE Notify API เนื่องจากสามารถเข้าถึงผู้ใช้งานได้ง่าย และปัจจุบันผู้คนใช้งานแอปพลิเคชัน LINE บนโทรศัพท์มือถือเป็นจำนวนมาก จึงเป็นทางเลือกการส่งข้อความแจ้งเตือนที่เหมาะสม โดยที่ส่วนของ API Proxy ในระบบคลาวด์ Elder Care จะทำหน้าที่ในการรับผิดชอบส่งข้อความแจ้งเตือนซึ่งประกอบด้วยประเภทเหตุการณ์ที่เกิดขึ้น และ URL สำหรับเข้าถึงรูปของเหตุการณ์ที่ตรวจจับได้ เมื่อมีการตรวจจับการหกล้ม การเคลื่อนไหวที่ไม่มั่นคง และการตรวจจับบุคคลในกรณีที่ไม่อยู่ในอาณาบริเวณที่กำหนด

3.10 โมดูลการสรุปข้อมูลกิจกรรม (ระบบเว็บแอปพลิเคชันดูแลผู้สูงอายุ)

โมดูลการสรุปข้อมูลกิจกรรม หรือเรียกอีกอย่างหนึ่งว่า ระบบเว็บแอปพลิเคชันดูแลผู้สูงอายุ จะเป็นเว็บแอปพลิเคชันที่ใช้สำหรับแสดงข้อมูลผลลัพธ์ในการตรวจจับ ตามรอย และแยกแยะข้อมูล ประเภทกิจกรรมที่ตรวจพบ ข้อมูลการหกล้ม และการเคลื่อนที่ที่ไม่มั่นคง/การทำนายการหกล้ม ซึ่งประกอบด้วยส่วนต่าง ๆ ดังต่อไปนี้

3.10.1 ฐานข้อมูลของระบบ

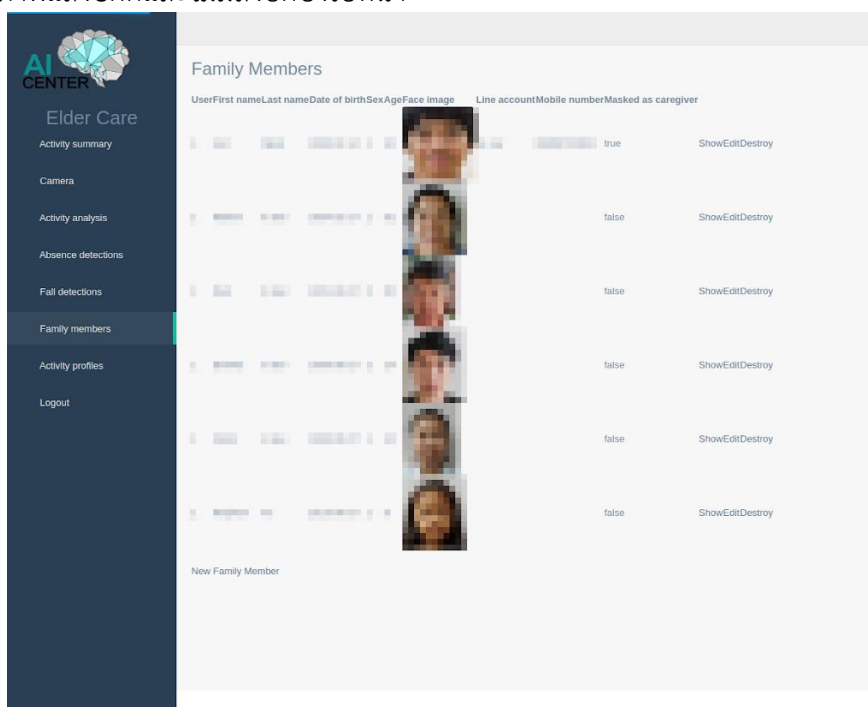
ฐานข้อมูลของระบบประกอบด้วยตารางต่าง ๆ ดังแสดงในรูปที่ 61



รูปที่ 61 ระบบฐานข้อมูลของระบบ Elder Care

3.10.2 หน้าแสดงสมาชิกครอบครัว

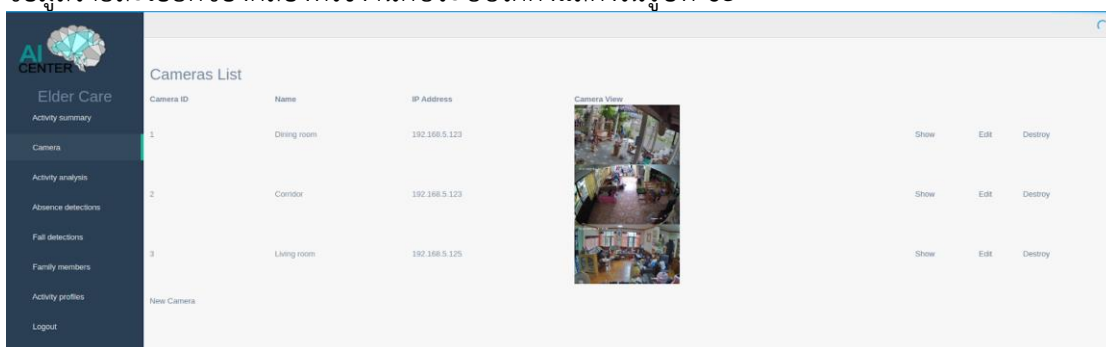
หน้าแสดงสมาชิกครอบครัวจะแสดงข้อมูลและรายละเอียดของสมาชิกครอบครัว โดยผู้ใช้งานสามารถเพิ่มข้อมูลสมาชิกครอบครัวได้จากหน้าเว็บไซต์นี้ดังแสดงในรูปที่ 62 โดยข้อมูลที่ผู้ใช้งานอัปโหลดรูปใบหน้าจะถูกนำมาใช้ในการรู้จำใบหน้า โดยรูปที่ผู้ใช้งานอัปโหลดควรเป็นรูปหน้าตรงและสภาพแสงปกติและไม่มีสิ่งบดบังใบหน้า



รูปที่ 62 ตัวอย่างข้อมูลหน้าแสดงสมาชิกในครอบครัว

3.10.3 หน้าแสดงรายการกล้อง

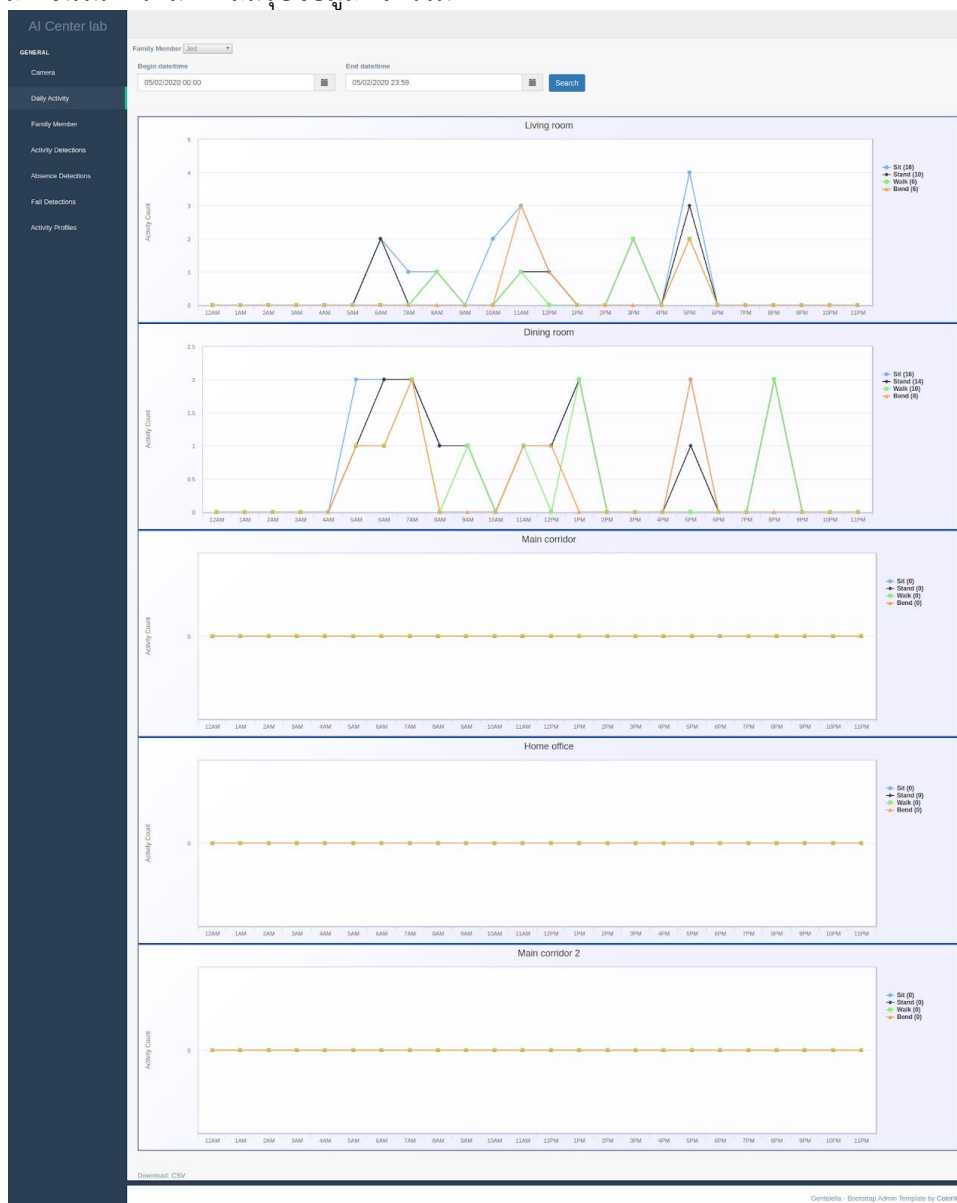
รายการกล้องที่ใช้งานในระบบจะแสดงบนหน้าแสดงรายการกล้อง โดยผู้ใช้งานสามารถเพิ่มข้อมูลรายละเอียดของกล้องที่ใช้งานกับระบบได้ดังแสดงในรูปที่ 63



รูปที่ 63 ตัวอย่างรายการกล้องที่ใช้ในระบบ

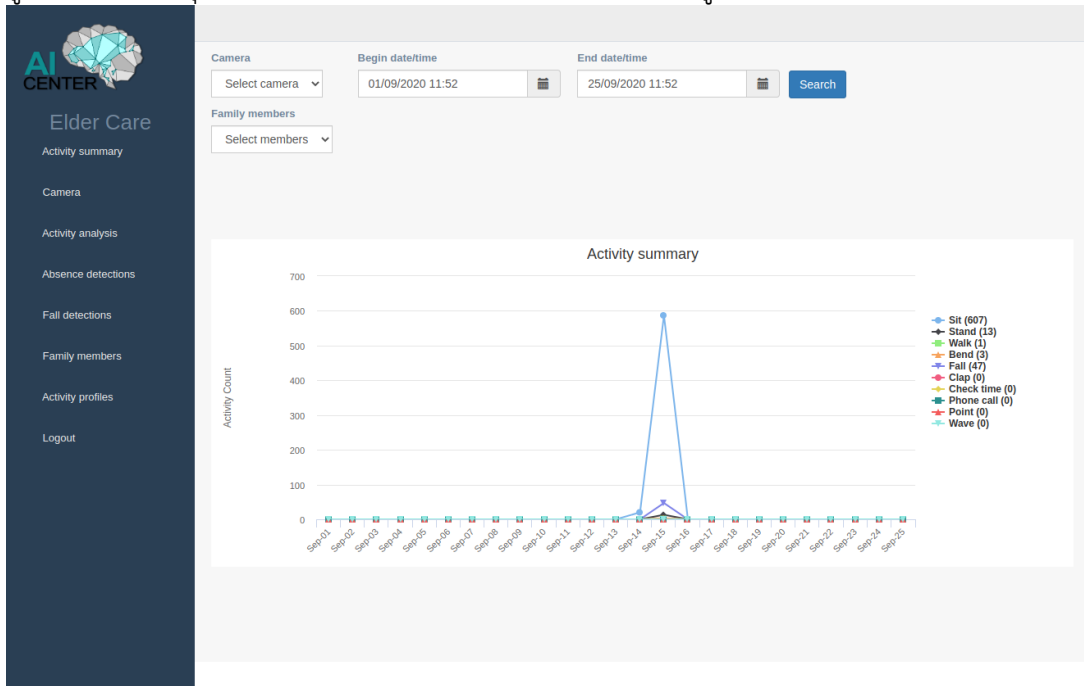
3.10.4 หน้าสรุปข้อมูลกิจกรรม (ท่าทาง)

โมดูลสรุปข้อมูลกิจกรรมจะอ่านข้อมูลที่ถูกบันทึกลงในฐานข้อมูลและทำการแสดงข้อมูลจำนวนครั้งของกิจกรรมที่ตรวจพบในแต่ละวัน โดยผู้ใช้งานสามารถเลือกสมาชิกและช่วงเวลาเพื่อแสดงผลสรุปข้อมูลกิจกรรมได้ โดยระบบจะทำการสรุปข้อมูลกิจกรรมตามวันและเวลาที่ผู้ใช้งานกำหนดบนแผนภูมิเพื่อแสดงสถิติการตรวจพบข้อมูลกิจกรรมท่าทางทั้ง 4 ประเภท คือ นั่ง ยืน เดิน และ เอนตัว ตัวอย่างของการแสดงผลแสดงในรูปแบบที่ 64 ข้อมูลที่ใช้ในการแสดงเป็นข้อมูลจำลองเพื่อแสดงให้เห็นถึงโมดูลสรุปข้อมูลกิจกรรมของระบบประมวลผลภาพ Elder Care v0.1 กับระบบเว็บแอปพลิเคชันในการแสดงผลสรุปข้อมูลกิจกรรม



รูปที่ 64 ตัวอย่างการแสดงผลของการสรุปข้อมูลกิจกรรมที่ตรวจพบในสองมุมมองตามช่วงเวลา
ที่ตรวจพบ

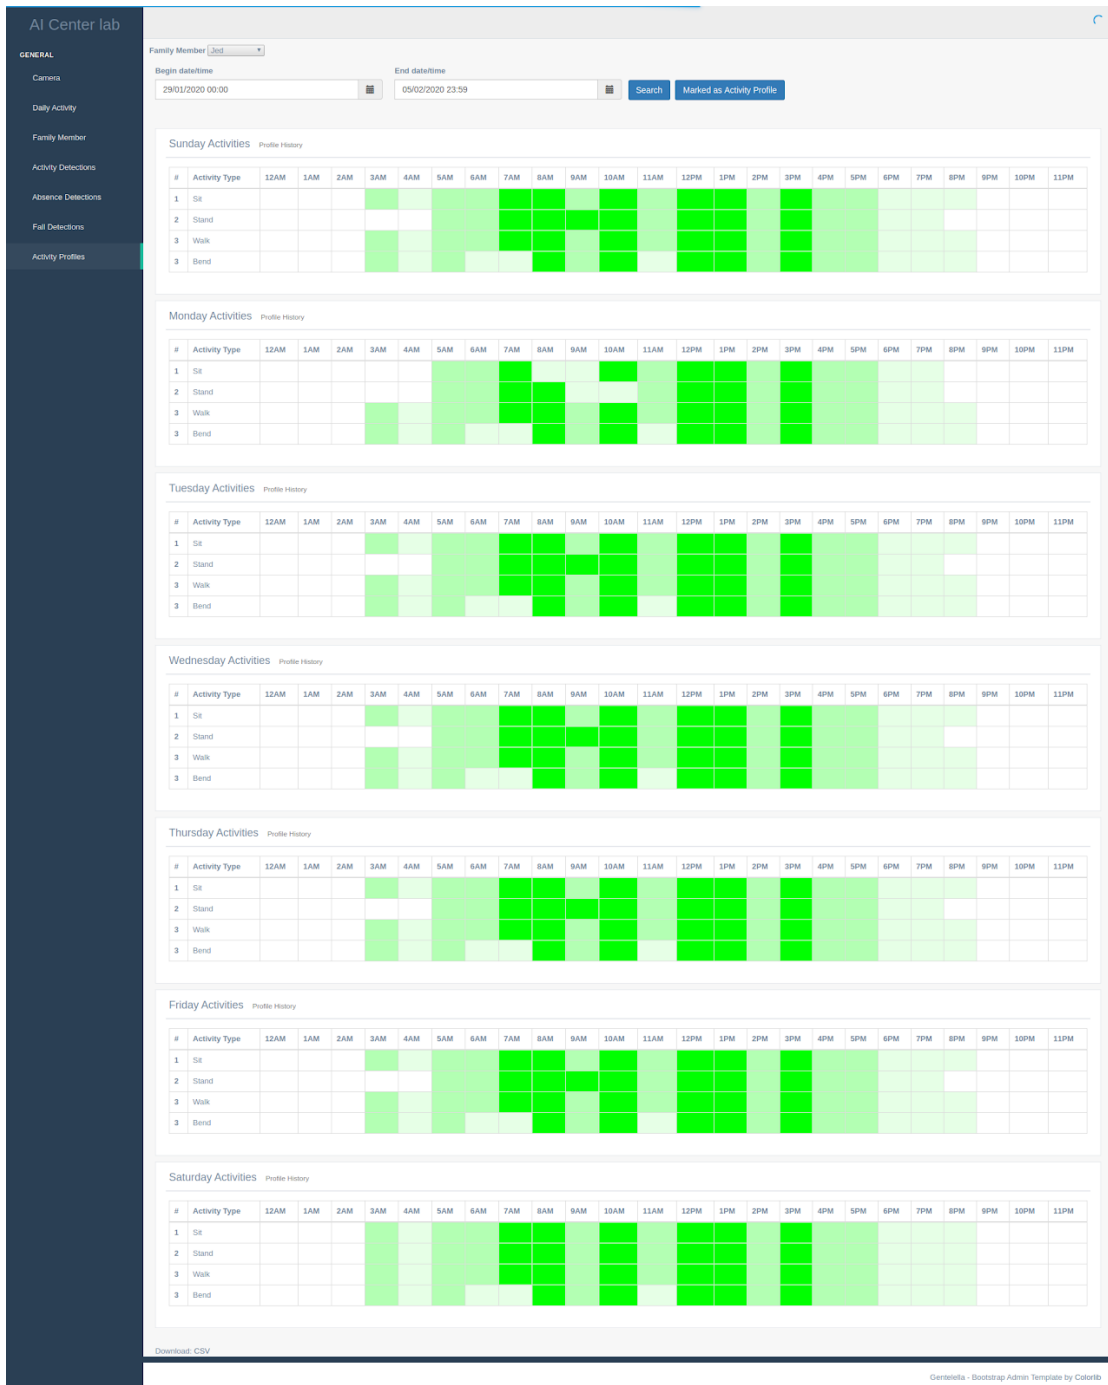
ทีมวิจัยได้ทำการปรับปรุงการแสดงผลในส่วนของหน้าสรุปข้อมูลกิจกรรมเพื่อให้การทำงานสอดคล้องกับซอฟต์แวร์ Elder Care Video Analytics v.0.3 ที่ทำงานบนหน่วยประมวลผลส่วนหน้า และทำงานร่วมกับ Elder Care APIs v.0.1 ซึ่งรองรับการแสดงผลประเภทกิจกรรมทั้งหมด 10 ประเภท ได้แก่ นั่ง ยืน เดิน เอนตัว ล้ม ยกแขนดูนาฬิกาข้อมือ ปรบมือ โทรศัพท ชี้ และโบกมือ ดังแสดงในรูปที่ 65 โดยผู้ใช้งานสามารถเลือกแสดงผลแยกตามกล้อง และ/หรือ สมาชิกครอบครัว หากผู้ใช้ไม่ทำการระบุกล้องและสมาชิกครอบครัว ระบบจะแสดงข้อมูลทั้งหมด



รูปที่ 65 ตัวอย่างการแสดงผลการสรุปข้อมูลกิจกรรมที่ตรวจพบ

3.10.5 การตรวจจับกิจกรรมที่มีการทำซ้ำ

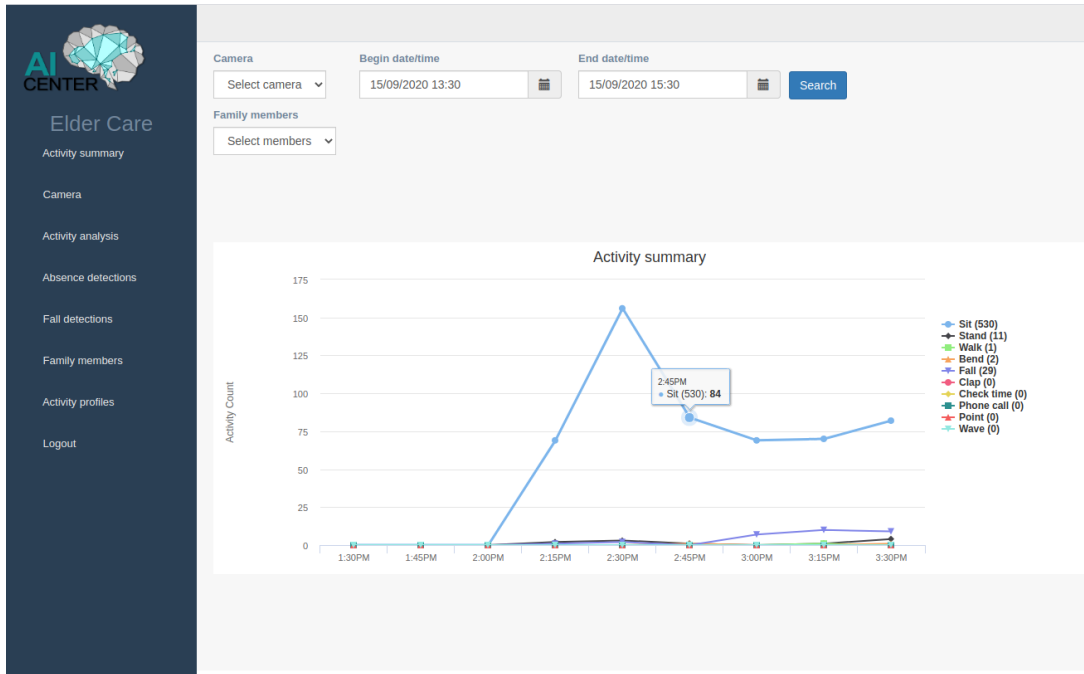
เพื่อที่จะตรวจจับพฤติกรรมที่มีการทำซ้ำของแต่ละบุคคล ระบบจะทำการรวบรวมข้อมูลกิจกรรมในฐานข้อมูลที่บันทึกโดยระบบประมวลผลภาพ Elder Care Video Analytics โดยแยกข้อมูลเป็นแต่ละวันในรายสัปดาห์และทำการแบ่งตามช่วงเวลาในแต่ละชั่วโมงเพื่อที่จะสร้างรูปแบบของกิจกรรมที่ตรวจพบของแต่ละบุคคล โดยค่าเริ่มต้นระบบจะทำการรวบรวมกิจกรรมที่ตรวจพบในหนึ่งสัปดาห์ล่าสุดและผู้ใช้งานสามารถเลือกรูปแบบกิจกรรมที่ตรวจพบเป็นรูปข้อมูลกิจกรรม (activity profile) ของแต่ละบุคคลได้โดยการคลิกที่ปุ่ม “Marked as Activity Profile” เพื่อให้ระบบทราบว่า การตรวจพบรูปแบบกิจกรรมดังกล่าวในแต่ละช่วงเวลาในแต่ละมุมมองเป็นกิจกรรมปกติ ความเข้มของสีที่แตกต่างกันแสดงถึงจำนวนความถี่ที่ตรวจพบโดยสีเขียวเข้มหมายถึงการตรวจพบกิจกรรมดังกล่าวบ่อยครั้ง สีเขียวอ่อนหมายถึงการตรวจพบกิจกรรมดังกล่าวบ่อยครั้งเมื่อเทียบกับจำนวนกิจกรรมที่ตรวจพบทั้งหมด ส่วนสีขาวหมายถึงระบบไม่ตรวจพบกิจกรรมใด ๆ ในช่วงเวลาดังกล่าว ตัวอย่างการแสดงผลของระบบตรวจจับพฤติกรรมที่มีการทำซ้ำแสดงในรูปที่ 66



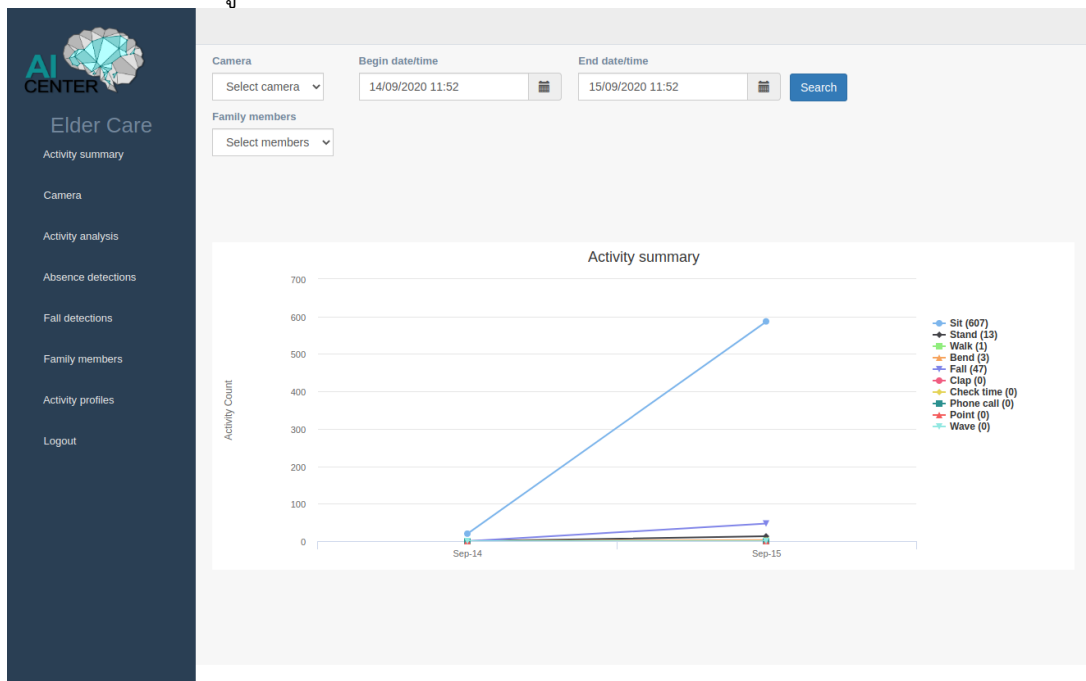
รูปที่ 66 ตัวอย่างของข้อมูลจำลองของกิจกรรมที่มีการทำซ้ำในแต่ละวันในแต่ละช่วงเวลา

เนื่องจากระบบประมวลผลภาพ Elder Care v.0.3 และ Elder Care APIs v.0.2 จะต้องรองรับการแสดงผลของประเภทกิจกรรมทั้งหมดจำนวน 10 ประเภทกิจกรรม การแสดงผลในรูปแบบตารางดังกล่าวทำให้ยากต่อการทำความเข้าใจ ทีมวิจัยจึงปรับการแสดงผลให้อยู่ในรูปแบบกราฟโดยใช้หน้าสรุปข้อมูลกิจกรรมในการแสดงผลกิจกรรมที่ตรวจพบโดยผู้ใช้งานสามารถเลือกช่วงเวลาที่น่าสนใจ ระบบเว็บแอปพลิเคชันจะทำการแสดงผลบนกราฟให้ในรูปแบบต่าง ๆ เช่น รายชั่วโมง รายวัน

รายเดือน รายปี ได้โดยอัตโนมัติ ขึ้นอยู่กับช่วงเวลาที่ผู้ใช้งานกำหนด ดังแสดงในรูปที่ 67 - 68 ผู้ใช้งานสามารถวางตำแหน่งเมาส์เหนือเส้นกราฟเพื่อดูจำนวนกิจกรรมที่เกิดขึ้นได้ตามเวลาที่กำหนดในการค้นหา

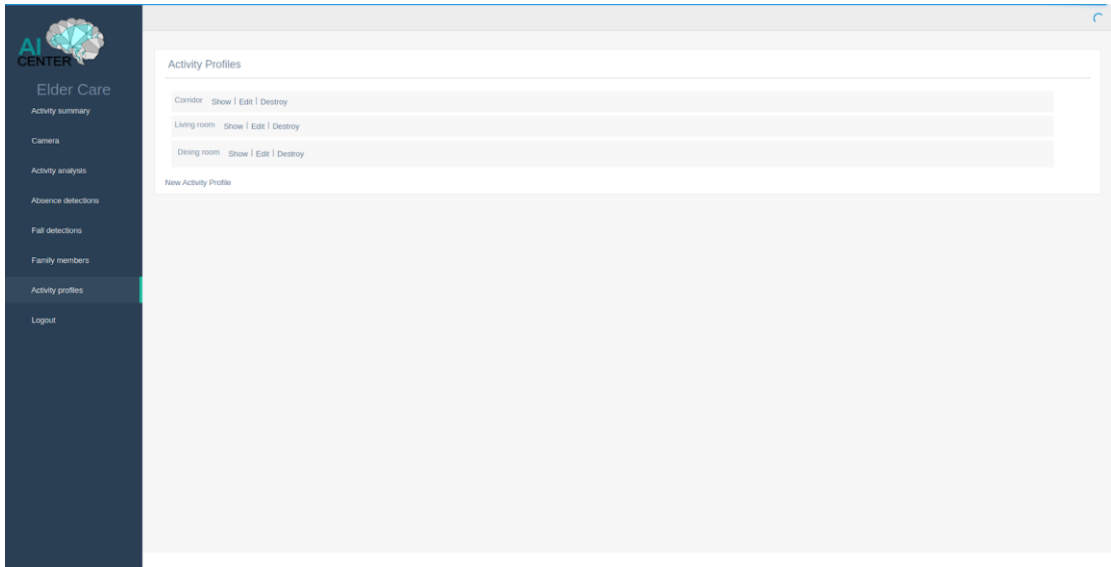


รูปที่ 67 ตัวอย่างการแสดงผลกิจกรรมที่ตรวจพบรายชั่วโมง



รูปที่ 68 ตัวอย่างการแสดงผลกิจกรรมที่ตรวจพบรายวัน

นอกจากนี้ที่มิววิจัยได้ปรับส่วนการสร้างรูปแบบกิจกรรม (Activity Profile) โดยเปลี่ยนให้
 ผู้ใช้งานกำหนดเองว่าช่วงเวลาไหนคือช่วงเวลาที่มีการอยู่อาศัยในบริเวณกล้องแต่ละกล้อง โดยมีหน้า
 หลักแสดงรายชื่อกล้องที่มีการลงทะเบียนไว้ในระบบ ดังแสดงในรูปที่ 63 โดยผู้ใช้งานสามารถกำหนด
 ช่วงเวลาได้โดยการทำงานเลื่อนแถบเพื่อระบุช่วงเวลาที่มีการอยู่อาศัย (Active period) ดังแสดงใน
 รูปที่ 69 – 70



รูปที่ 69 ตัวอย่างการแสดงผลรายชื่อกล้องที่ถูกตั้งค่าช่วงเวลาที่มีการอยู่อาศัย



รูปที่ 70 ตัวอย่างการแสดงผลการตั้งค่าช่วงเวลาที่มีการอยู่อาศัย (Active period) ของมุมกล้องหนึ่ง
 กล้อง

3.10.6 การตรวจจับบุคคลในกรณีที่ไม่อยู่ในอาณาบริเวณที่กำหนด

การตรวจจับบุคคลในกรณีที่ไม่อยู่ในอาณาบริเวณที่กำหนดจะทำงานร่วมกับข้อมูลรูปแบบกิจกรรมที่ตรวจพบ (activity profile) ของแต่ละบุคคล ที่มิวิจัยออกแบบให้การทำงานในการตรวจจับบุคคลในกรณีที่ไม่อยู่ในอาณาบริเวณโดยใช้ข้อมูลรูปแบบกิจกรรมที่ตรวจพบการเคลื่อนที่เป็นข้อมูลหลัก หากในช่วงเวลาดังกล่าวไม่พบการบันทึกข้อมูลใหม่ลงไปยังฐานข้อมูล ระบบจะทำการบันทึกการไม่อยู่ในอาณาบริเวณ โดยบันทึกภาพจากกล้องแต่ละ มุมกล้องเพื่อเป็นข้อมูลการตรวจจับบุคคลในกรณีที่ไม่อยู่ในอาณาบริเวณที่กำหนด หรือการไม่มีการเคลื่อนที่หรือไม่พบกิจกรรมใด ๆ ตามที่รูปแบบกิจกรรมที่ผู้ใช้งานได้ตั้งค่าไว้

ที่มิวิจัยได้ปรับเปลี่ยนขั้นตอนการทำงานของการทำงานของการตรวจจับบุคคลในกรณีที่ไม่อยู่ในอาณาบริเวณโดยระบบประมวลผลส่วนหน้า Elder Care Video Analytics v.0.3 จะทำการส่งข้อมูลไปยัง Elder Care APIs หากภายในระยะเวลาที่กำหนดไม่มีการตรวจพบบุคคลหรือกิจกรรมใด ๆ ระบบจะทำการบันทึกภาพจากกล้อง ณ ขณะนั้น รวมถึงข้อมูลที่เป็นส่งไปยัง Elder Care APIs เมื่อฝั่ง APIs ได้รับข้อมูลแล้วจะทำการตรวจสอบกับช่วงเวลาที่มีการอยู่อาศัยที่ถูกระบุโดยผู้ใช้งาน หากข้อมูลที่ส่งมาไม่อยู่ในช่วงเวลาที่อยู่อาศัยที่กำหนดไว้ ระบบจะทำการสร้างการแจ้งเตือนไปยังบัญชี LINE ของผู้ใช้งานทันที รายละเอียดของข้อมูลที่ส่งถูกอธิบายไว้ในส่วนของ RESTful Elder Care APIs

3.11 โมดูลการสร้างการแจ้งเตือน

ในกรณีที่ตรวจพบการเคลื่อนที่ที่ไม่มั่นคง หรือ การหกล้ม จากโมดูลการประมวลผลส่วนหน้า หรือ เซอร์วิสการประมวลผลภาพ (video analytics services) โมดูลการสร้างการแจ้งเตือนจะทำหน้าที่ในการส่งข้อมูลการแจ้งเตือนไปยังผู้ดูแลหรือผู้รับผิดชอบโดยทันที โดยที่โมดูลนี้จะรันบน cloud ที่มิวิจัยใช้การเรียก API ของ LINE Notify เพื่อการส่งการแจ้งเตือนไปยังบัญชี LINE ของผู้ใช้งานที่ลงทะเบียนไว้ ตัวอย่างของการแจ้งเตือนแสดงในส่วนของผลการทดลอง

3.12 RESTful Elder Care APIs

RESTful Elder Care APIs ถูกออกแบบมาเพื่อใช้ในการรับข้อมูลจากอุปกรณ์ประมวลผล ส่วนหน้า ปัจจุบันที่มวิจัยได้พัฒนา API สองเวอร์ชัน โดยเวอร์ชันแรก Elder Care APIs v.0.1 ประกอบด้วย API หลัก 2 API ได้แก่ Activity Classification Service และ Absence Dtection Service ส่วน Elder Care APIs v.0.2 ประกอบด้วย API หลัก 2 API เหมือนกันแต่มี services ที่เรียกใช้ภายในที่แตกต่าง ดังแสดงในตารางที่ 15

ตารางที่ 15 RESTful Elder Care APIs version

เวอร์ชัน	API หลัก	Services ภายใน
v.0.1	1) Activity Classification Service (5 activities)	1) Framewise Activity Classification - sit - stand - walk - bend - fall 2) Face Recognition
	2) Absence Detection Service	-
v.0.2	1) Activity Classification Service (10 activities)	1) Cascade Framewise Activity Classification - sit - stand - walk - bend - fall - check time - clap - phone call - point - wave 2) LSTM Activity Classification - sit - stand - walk - bend

		<ul style="list-style-type: none"> - fall - check time - clap - phone call - point - wave <p>3) LSTM Unstable Movement Detection</p> <p>4) Face Recognition</p>
	2) Absence Detection Service	-

RESTful Elder Care APIs ใช้สำหรับสร้างเรคอร์ดของประเภทของท่าทางที่แยกแยะได้จากข้อมูลจุดโครงร่างของร่างกายรวมถึงการวิเคราะห์การเคลื่อนไหวของบุคคลว่าเป็นการเคลื่อนไหวที่ไม่มั่นคงหรือไม่จากกล้องที่ติดตั้งในบ้าน การทำงานหลักของ Elder Care APIs ใช้ Node Express ทำหน้าที่เป็น API Proxy ในการจัดการข้อมูลที่ถูกอัปโหลดมาก่อนส่งต่อข้อมูลไปยังเซอร์วิสย่อยภายใน ซึ่งได้แก่ เซอร์วิสการแยกแยะประเภทท่าทาง (Activity Classification Service) ซึ่งถูกพัฒนาขึ้นโดยใช้ Tensorflow, Keras และ FLASK และ เซอร์วิสตรวจจับการไม่อยู่ในอาณาบริเวณในช่วงเวลาที่กำหนด (Absence Detection)

Elder Care APIs ทั้งสองเวอร์ชันได้ถูกพัฒนาเสร็จสิ้นแล้ว เวอร์ชัน v.0.2 เป็นเวอร์ชันที่ให้นำไปใช้งานบนคอมพิวเตอร์แม่ข่ายในการใช้งานจริง

3.12.1 Activity Analysis APIs

API สำหรับการแยกแยะประเภทท่าทางเป็น API หลักซึ่งจะรับข้อมูลรายการจุดโครงร่างของร่างกาย และข้อมูลรอบสี่เหลี่ยมล้อมรอบจุดโครงร่างของร่างกาย และภาพที่ใช้เป็นข้อมูลสำหรับการรู้จำใบหน้าบุคคล ข้อมูลเหล่านี้จะถูกส่งต่อไปยังเซอร์วิสภายใน เรียกว่า Activity Classification Service, Unstable Movement Detection Service และ Face Recognition Service

3.12.1.a Activity Classification Service

Activity Classification Service ใช้รายการจุดข้อมูลโครงร่างของร่างกายและข้อมูลรอบสี่เหลี่ยมเป็นข้อมูลนำเข้า เพื่อใช้ในการแยกแยะประเภทกิจกรรมทั้ง 10 ประเภท (นั่ง ยืน เดิน เอนตัว/ก้มตัว ล้ม ปรบมือ ดุนาฬิกา คุยโทรศัพท์ ชี้ โบกมือ) โดยที่ข้อมูลจุดโครงร่างของร่างกายที่พบในแต่ละเฟรมจะถูกแยกแยะประเภทท่าทางและทำการสรุปประเภทข้อมูลกิจกรรมโดยใช้ majority vote หากตรวจพบการทกล้มจะทำการเรียก LINE Notify API เพื่อส่งข้อมูลการแจ้งเตือนไปยังบัญชี LINE ของผู้ใช้งานที่ลงทะเบียนไว้

3.12.1.b Unstable Movement Detection Service

Unstable Movement Detection Service จะทำงานเช่นเดียวกับ Activity Classification Service โดยใช้รายการจุดข้อมูลโครงสร้างของร่างกายและข้อมูลรอบสี่เหลี่ยมเป็นข้อมูลนำเข้า เพื่อใช้ในตรวจจับว่าลำดับการเคลื่อนที่ดังกล่าวเป็นการเคลื่อนไหวแบบไม่มั่นคงหรือไม่ หากพบว่าเป็นการเคลื่อนไหวที่ไม่มั่นคงระบบจะทำการเรียก LINE Notify API เพื่อส่งข้อมูลการแจ้งเตือนไปยังบัญชี LINE ของผู้ใช้งานที่ลงทะเบียนไว้

3.12.1.c Face Recognition Service

เซอร์วิสการรู้จำใบหน้าบุคคลจะใช้ข้อมูลภาพที่อัปโหลดขึ้นมา โดยทำการตรวจหาตำแหน่งใบหน้าและจัดตำแหน่งใบหน้าโดยใช้ Muti-task Cascaded Convolutional Neural Network (MTCNN) และทำการดึงข้อมูล face embedding vector เพื่อเปรียบเทียบกับ face embedding ของข้อมูลภาพของสมาชิกทุกคนในบ้านที่ลงข้อมูลไว้ในระบบ ทีมวิจัยใช้ pretrained weights ของ Facenet ในการดึงข้อมูล face embedding จากใบหน้าบุคคล โดยระบบจะคืนค่า ID ของสมาชิกในครอบครัวที่มีค่าใน similarity matrix ที่น้อยที่สุด หากไม่สามารถระบุตัวตนได้เซอร์วิสจะคืนค่า -1 ซึ่งจะถูกแสดงผลเป็น “undefined” บนเว็บแอปพลิเคชัน

3.12.1.d Activity Analysis API Specifications

HTTP Request 1: อัปโหลดภาพและข้อมูลเพื่อแยกแยะประเภทท่าทาง

HTTP Type:

HTTP Type	คำอธิบาย
POST	Post method สำหรับการอัปโหลดข้อมูลของโครงสร้างของร่างกาย ข้อมูลรอบสี่เหลี่ยม และภาพสำหรับการรู้จำใบหน้าบุคคล เพื่อทำการแยกแยะประเภทท่าทาง ระบุตัวตน ตรวจจับการหกล้มและตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

Request URL:

URL
http://[API-HOST]/upload

HTTP Header:

HTTP Header	Value
Content-Type	multipart/form-data


```

0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000,
0.000000, 0.000000, 1203.642944, 1084.832886, 1221.281006, 1084.840820, 1200.596436, 1084.855347, 0.000000, 0.000000]",
"boundingbox": "[351, 329, 24, 141]"
},
"frame1": {
"skeleton": "[1221.258057, 1084.826538, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000,
0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000,
0.000000, 0.000000, 1203.642944, 1084.832886, 1221.281006, 1084.840820, 1200.596436, 1084.855347, 0.000000, 0.000000]",
"boundingbox": "[351, 329, 24, 141]"
},
"frame2": {
"skeleton": "[1221.258057, 1084.826538, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000,
0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000, 0.000000,
0.000000, 0.000000, 1203.642944, 1084.832886, 1221.281006, 1084.840820, 1200.596436, 1084.855347, 0.000000, 0.000000]",
"boundingbox": "[351, 329, 24, 141]"
}
}
}
-----589511845530311107071494-----

```

Example Response:

Response Body

```

HTTP/1.1 200 OK
X-Powered-By: Express
Content-Type: text/html; charset=utf-8
Content-Length: 8
ETag: W/"8-J1SMT8ldfH/au335+UoeBcwdfLc"
Date: Fri, 25 Sep 2020 10:33:23 GMT
Connection: keep-alive
Received

```

3.12.2 Absence Detection APIs

3.12.2.a Absence Detection Service

การตรวจจับบุคคลที่ไม่อยู่ในอาณาบริเวณที่กำหนดจะถูกสร้างเมื่อระบบประมวลผลส่วนหน้า ไม่พบการเคลื่อนไหวใด ๆ ในมุมมอง กล้องคือไม่มีข้อมูลการตามรอยเป็นระยะเวลาหนึ่งที่กำหนดไว้ จากนั้นระบบส่วนหน้าจะทำการบันทึกภาพจากกล้องและส่งข้อมูลมายัง API โดยฝั่ง API เมื่อได้รับข้อมูลจะทำการตรวจสอบกับ Activity Profile ที่ผู้ใช้งานตั้งไว้ หากการตรวจจับบุคคลที่ไม่อยู่ในอาณาบริเวณถูกส่งมาในช่วงเวลาที่ถูกกำหนดว่าเป็นช่วงเวลาที่มีการอยู่อาศัยในบริเวณบ้าน (active period) ระบบจะทำการสร้างข้อความแจ้งเตือนและส่งไปยังบัญชี LINE ของผู้ใช้งานที่ลงทะเบียนไว้

3.12.2.b Absence Detection API Specifications

HTTP Request 2: อัปเดตข้อมูลการตรวจจับบุคคลที่ไม่อยู่ในอาณาบริเวณ

HTTP Type:

HTTP Type	คำอธิบาย
POST	Post method สำหรับส่งภาพและข้อมูลการตรวจจับบุคคลที่ไม่อยู่ในอาณาบริเวณ

Request URL:

URL
http://[API-HOST]/upload_absence

HTTP Header:

HTTP Header	Value
Content-Type	multipart/form-data

HTTP Body:

Parameter	Type	คำอธิบาย
photos	File	ไฟล์ข้อมูลภาพจากกล้อง
absence_data	Text	JSON string ที่ประกอบด้วยข้อมูลวัน เวลา ID ครอบครัว และ ID กล้อง

HTTP Status Code:

Code	คำอธิบาย
200 OK	All data is valid.
400 Bad Request	Some data is not valid.

Example Request:

URL
http://192.168.5.180:3000/upload_absence

Request body

```
POST http://192.168.5.180:3000/upload_absence
200
16 ms
POST /upload_absence HTTP/1.1
User-Agent: PostmanRuntime/7.26.5
Accept: */*
Cache-Control: no-cache
Postman-Token: 4c17a745-4afc-4a6c-9622-25070d02666c
Host: 192.168.5.180:3000
Accept-Encoding: gzip, deflate, br
Connection: keep-alive
Content-Type: multipart/form-data; boundary=-----532924955497345472861871
Content-Length: 1239215
-----532924955497345472861871
Content-Disposition: form-data; name="photos"; filename="2020-09-20-08h57m11s721.jpg"
<2020-09-20-08h57m11s721.jpg>
-----532924955497345472861871
Content-Disposition: form-data; name="absence_data"
{
  "date_time": "2020-09-27 14:00:00",
  "family_id": "1",
  "camera_id": "1"
}
-----532924955497345472861871--
```

Example Response:

Response Body

```
HTTP/1.1 200 OK
X-Powered-By: Express
Content-Type: text/html; charset=utf-8
Content-Length: 8
ETag: W/"8-J1SMT8ldff/au335+UoeBcwdfLc"
Date: Mon, 28 Sep 2020 06:20:22 GMT
Connection: keep-alive
Received
```

3.13 แผนการฝึกอบรมและรวบรวมข้อคิดเห็นจากผู้ใช้งานและเจ้าหน้าที่

ในการดำเนินโครงการในช่วง 2 เดือนสุดท้าย ทีมวิจัยจะทำการนำเสนอการใช้งานระบบดูแลผู้สูงอายุให้กับผู้ใช้งานและสมาชิกในครอบครัว ณ บ้านอาสาสมัคร เพื่อสอนการใช้งานระบบและรับฟังข้อเสนอแนะและความคิดเห็นจากผู้ใช้งานจริง รวมถึงการนำเสนอระบบดูแลผู้สูงอายุให้กับผู้ที่มีความสนใจ หรือ บริษัทที่สนใจในเทคโนโลยีการดูแลผู้สูงอายุ หรือ เจ้าหน้าที่สาธารณสุขที่มีประสบการณ์ หรือทีมแพทย์หรือเจ้าหน้าที่จากทีมมหาวิทยาลัยมหิดล เพื่อนำข้อเสนอแนะมาปรับปรุงหรือต่อยอดในการพัฒนาระบบ ทีมวิจัยได้จัดทำคู่มือการใช้งานระบบดูแลผู้สูงอายุเพื่อเตรียมใช้ในการอบรมผู้ใช้งานระบบ

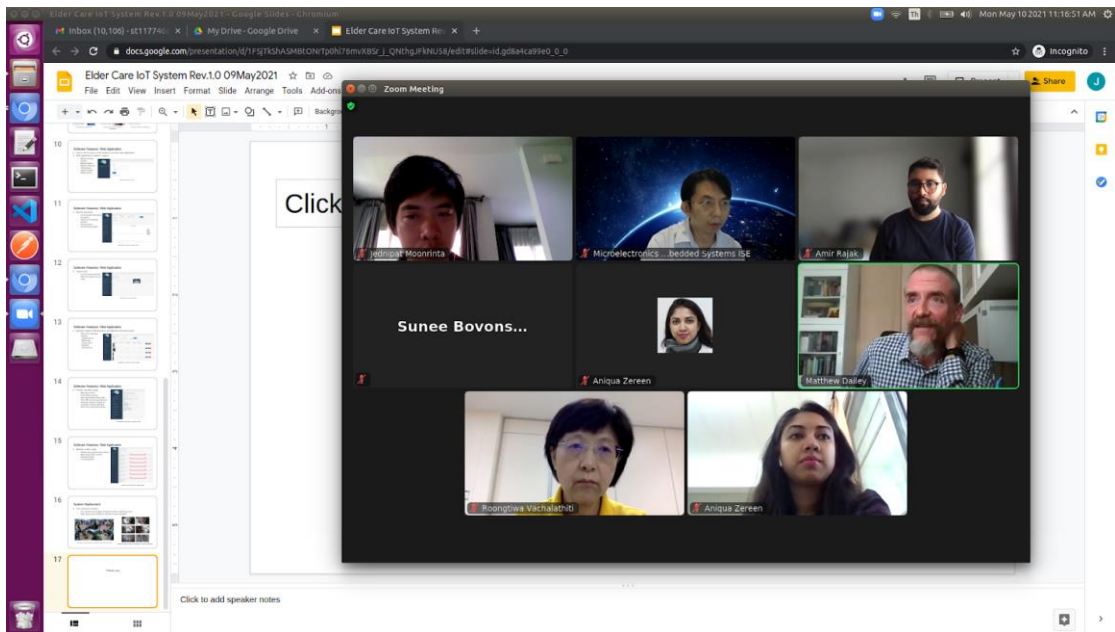
เนื่องด้วยสถานการณ์การแพร่ระบาดโควิด-19 ทำให้ทีมวิจัยไม่สามารถจัดการฝึกอบรม ณ สถานที่ติดตั้งใช้งานจริง การประชุมเพื่อนำเสนอระบบดูแลผู้สูงอายุและฝึกอบรมจึงต้องทำผ่านระบบประชุมออนไลน์ทั้งหมด โดยการอบรมแบ่งเป็นสองรอบ

การฝึกอบรมรอบแรกเป็นการนำเสนอระบบให้แก่ทีมผู้เชี่ยวชาญจากคณะกายภาพบำบัด มหาวิทยาลัยมหิดล เพื่อขอคำแนะนำ และความเห็นในการนำระบบดูแลผู้สูงอายุไปใช้ในทางด้านการรักษา และให้ความเห็นต่อระบบที่ทีมวิจัยพัฒนาขึ้น

การฝึกอบรมรอบสองเป็นการนำเสนอระบบให้แก่ตัวแทนจากบ้านอาสาสมัครที่ติดตั้งและใช้งานทดสอบระบบ และผู้สนใจในเทคโนโลยีระบบดูแลผู้สูงอายุ

การฝึกอบรมแยกกลุ่มกัน กลุ่มแรกเป็นการฝึกอบรมให้กับแพทย์ผู้เชี่ยวชาญจากคณะกายภาพบำบัด มหาวิทยาลัยมหิดล ทีมวิจัยได้จัดการฝึกอบรม ณ วันที่ 10 พฤษภาคม พ.ศ. 2564 ดังแสดงในรูปที่ 71 และ กลุ่มที่สองเป็นการฝึกอบรมให้กับอาสาสมัครผู้ติดตั้งระบบและใช้งานและผู้สนใจใช้งานระบบ ทีมวิจัยได้จัดการฝึกอบรม ณ วันที่ 11 มิถุนายน พ.ศ. 2564 ดังแสดงในรูปที่ 72 โดยการฝึกอบรมเน้นในการอธิบายรูปแบบการทำงานของระบบดูแลผู้สูงอายุเพื่อรวบรวมความคิดเห็น คำแนะนำ และสาธิตการใช้งานระบบเว็บแอปพลิเคชันดูแลผู้สูงอายุ เนื้อหาที่ใช้ในการอบรมประกอบด้วย

1. ภาพรวมของระบบ
2. การทำงานของระบบ
3. คุณลักษณะของระบบ
4. การติดตั้งและใช้งานระบบ



รูปที่ 71 การฝึกอบรมให้แก่ทีมผู้เชี่ยวชาญจากคณะกายภาพบำบัด มหาวิทยาลัยมหิดล



รูปที่ 72 การฝึกอบรมให้แก่ตัวแทนจากบ้านอาสาสมัครผู้ติดตั้งใช้งานระบบและผู้ที่สนใจใช้งานระบบ

ในการฝึกอบรมที่มวิจัยได้จัดเตรียมระบบเว็บแอปพลิเคชันสำหรับดูแลผู้สูงอายุเพื่อให้ผู้เข้าฝึกอบรม ทดสอบการใช้งานระบบ และประเมินการทำงานของระบบโดยการประเมินการใช้งานระบบโดย ทีมวิจัยเตรียม คำถามสำหรับการประเมินใน Google Form โดยคำถามที่ใช้ในการประเมินระบบแสดงในตารางที่ 16

ตารางที่ 16 คำถามสำหรับการประเมินการใช้งานระบบดูแลผู้สูงอายุ

ID	Questions - Thai	Questions - Eng	Answer
System Usability			
1	คุณใช้ระบบเพื่ออะไร? บ่อยแค่ไหน?	What do you use the system for? How often?	
2	คุณใช้หน้าเว็บแอปพลิเคชันใดบ่อยครั้งมากที่สุด?	Which web application page do you use most?	
3	คุณใช้ระบบครั้งสุดท้ายเมื่อใด?	When was the last time you used the system?	
4	คุณใช้เวลาในการใช้ระบบนานเท่าไรในแต่ละวัน/สัปดาห์?	How long do you spend using the system each day / week?	
User experience			
5	คุณรู้สึกอย่างไรก่อนที่คุณจะเริ่มใช้งานระบบ? มีข้อกังวลเรื่องใดไหม?	How did you feel before you started using the system? Are there any concerns?	
6	คุณรู้สึกอย่างไรหลังจากที่คุณใช้งานระบบ? มีอะไรแตกต่างจากก่อนได้ลองใช้งานระบบไหม?	How do you feel after you use the system? Is there anything different from before trying to use the system?	
7	คุณพอใจกับวิธีการใช้งานระบบมากน้อยเพียงใด?	How satisfied are you with the workflows?	
8	เมื่อคุณเข้าสู่ระบบสิ่งแรกที่คุณทำคืออะไร?	When you log on, what's the first thing you do?	
9	คุณคิดอย่างไรกับการทำงานของระบบตรวจจับและแจ้งเตือนการเคลื่อนไหวที่ผิดปกติ และการหกล้ม? ระบบใช้งานง่ายไหม?	What do you think of unstable movement detection, fall detection, and alert notification? How easy is it to use?	
10	คุณคิดอย่างไรเกี่ยวกับวิธีการจัดวางและแสดงข้อมูลของระบบ?	What do you think about how information is laid out and visualized?	
11	คุณใช้งานส่วนใดของระบบมากที่สุด? เมื่อใช้แล้วรู้สึกอย่างไร?	What parts of the system do you use the most? How do you feel	

		when use it?	
12	คุณใช้งานส่วนใดของระบบน้อยที่สุด? เมื่อใช้แล้วรู้สึกอย่างไร?	What parts of the system do you use the least? How do you feel when use it?	
13	คุณชอบการออกแบบ การจัดวาง (เช่น ปุ่มกด, กล่องข้อความ, แผนภูมิ, ฯลฯ) การแสดงข้อมูล ของเว็บแอปพลิเคชัน หรือไม่? เว็บแอปพลิเคชันใช้งานง่ายหรือไม่? เว็บแอปพลิเคชันเข้าใจง่ายหรือไม่?	Do you like the design, layout (e.g. button, text box, graph), and data visualization of web application? Is the web application easy to use? Is the web application easy to understand?	
14	โดยรวมแล้วคุณมีความรู้สึกอย่างไรในการใช้งานระบบ?	What's your experience been with the system in overall?	
User Feedback			
15	มีอะไรที่ทำให้คุณติดขัดในการใช้งานระบบ?	Is there anything caused you frustration?	
16	หากคุณสามารถเปลี่ยนแปลงสิ่งหนึ่งในระบบได้จะเป็นอะไร และเพราะอะไร?	If you could change one thing about the system, what would it be? and Why?	
17	คุณรู้สึกตื่นเต้นกับอะไรของระบบมากที่สุด? และเพราะอะไร?	What one thing are you most excited about with the system? Why?	
18	คุณจะใช้ระบบนี้ต่อไปไหม? และอะไรจะทำให้คุณหยุดใช้ระบบนี้ในอนาคต?	Why will you continue to use this system? What will stop you from using this system in the future?	
19	คุณชอบระบบนี้มากน้อยแค่ไหน (คะแนน: น้อย 1 - 10 มาก)	How much do you like this system? (Rating: min 1 - 10 max)	

ผลการประเมินการใช้งานระบบอธิบายใน บทที่ 4 ผลการวิจัยและวิจารณ์ผล

3.14 การจดอนุสิทธิบัตร

ทีมวิจัยได้จัดเตรียมอนุสิทธิบัตร “ระบบตรวจจับการล้มและการเคลื่อนไหวที่ไม่มั่นคงอัตโนมัติด้วยอุปกรณ์รับภาพและ/หรือภาพเคลื่อนไหว” สำหรับการยื่นจดอนุสิทธิบัตร

3.15 การตีพิมพ์นวารสาร กสทช.

ทีมวิจัยได้จัดเตรียมเอกสารวิชาการ “Automatic elderly fall and unstable movement detection system using video analytic device” สำหรับตีพิมพ์นวารสาร กสทช.

บทที่ 4

ผลการวิจัย และการวิจารณ์ผล

4.1 ผลการวิจัย และการวิจารณ์ผล

ผลการวิจัยแบ่งออกเป็น ผลการวิจัยในด้านความแม่นยำของระบบ ผลจากการติดตั้งและใช้งานระบบ และ ผลจากการฝึกอบรมใช้งานระบบ

ผลการวิจัยในส่วนของความแม่นยำของระบบถูกอธิบายในรายละเอียดแยกตามอัลกอริทึม โดยมีรายละเอียดประกอบด้วย โครงสร้างเน็ตเวิร์คที่ใช้ในการ เทรนโมเดล ตัวแปรและค่าต่าง ๆ ที่เกี่ยวข้องกับการเทรนโมเดล รวมถึงชุดข้อมูลที่ใช้ ในการเทรนโมเดล การจัดเตรียมชุดข้อมูลที่ใช้ในการเทรน ความแม่นยำของแต่ละอัลกอริทึมอธิบายแยกตามอัลกอริทึมสำหรับการประเมินความแม่นยำ ของระบบที่มิวิจัยใช้ข้อมูลที่ไม่เคยเห็นมาก่อน (unseen dataset) และไม่ถูกใช้ในการเทรนโมเดล เพื่อประเมินความแม่นยำของระบบ

ผลจากการติดตั้งและใช้งานอธิบายถึงรูปแบบการติดตั้งระบบ ณ บ้านอาสาสมัคร และผลลัพธ์จากการทดสอบใช้งานระบบ ส่วนผลจากการฝึกอบรมอธิบายผลการประเมินระบบโดยแพทย์ผู้เชี่ยวชาญ อาสาสมัครผู้ใช้งาน และ ผู้ที่สนใจในระบบ

4.1.1 การแยกแยะประเภทท่าทาง และการหกล้ม (Activity Classification)

ทีมวิจัยได้วิจัยพัฒนาอัลกอริทึมสำหรับแยกแยะประเภทท่าทาง โดยแบ่งออกเป็น 3 อัลกอริทึมหลัก ได้แก่ การแยกแยะประเภทท่าทางแบบทีละเฟรม การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่น และ การแยกประเภทท่าทางโดยใช้เทคนิค LSTM

4.1.1.1 การแยกแยะประเภทท่าทางแบบทีละเฟรม (Framewise Activity Classification)

ความแม่นยำของแต่ละอัลกอริทึมแสดง และการใช้ชุดข้อมูลในการเทรนโมเดล รวมถึงโครงสร้างเน็ตเวิร์ค จะถูกอธิบายในรายละเอียดสำหรับ แต่ละอัลกอริทึม ซึ่งมีประเภทท่าทางทั้งหมด 5 ประเภทท่าทาง คือ นั่ง ยืน เดิน เอนตัว หกล้ม โดยทีมวิจัยได้เทรนข้อมูลหลายโมเดลโดยใช้ชุดข้อมูลในการเทรนโมเดลที่แตกต่างกัน เพื่อทำการเปรียบเทียบว่าโมเดลใดให้ความแม่นยำสูงสุด

4.1.1.1.a การเทรนโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดล

ทีมวิจัยได้เก็บข้อมูลจากผู้สูงอายุที่มีและไม่มีประวัติการหกล้ม โดยมีข้อมูลท่าทางทั้งหมด 6 ท่าทาง ได้แก่ เดินแบบสบาย เดินเร็ว เดินแล้วเลี้ยว เดินข้ามสิ่งกีดขวาง ยืน และนั่ง ข้อมูลทั้งหมดถูกบันทึกเป็นวิดีโอซึ่งรายละเอียดในการเก็บและวิเคราะห์ข้อมูลถูกอธิบายไว้ในหัวข้อ 3.5 – 3.7 รวมถึงเก็บข้อมูลจากสมาชิกในทีมวิจัยในท่าทางเอนตัว และ หกล้ม โดยข้อมูลเหล่านี้ทีมวิจัยจัดกลุ่มออกเป็น 5 กลุ่มท่าทาง คือ เดิน นั่ง ยืน เอนตัว และหกล้ม เพื่อใช้ในการเทรนโมเดลเพื่อใช้ในการรู้จำประเภทกิจกรรม (ท่าทาง) ทีมวิจัยสร้างชุดข้อมูลสำหรับเทรนโมเดลโดยโปรแกรมสร้างชุดข้อมูลที่ทีมวิจัยสร้างขึ้น อย่างไรก็ตามทีมวิจัยไม่ได้รวมท่าทางนั่งเข้ากับชุดข้อมูลที่ใช้ในการเทรนโมเดลเนื่องจากชุด

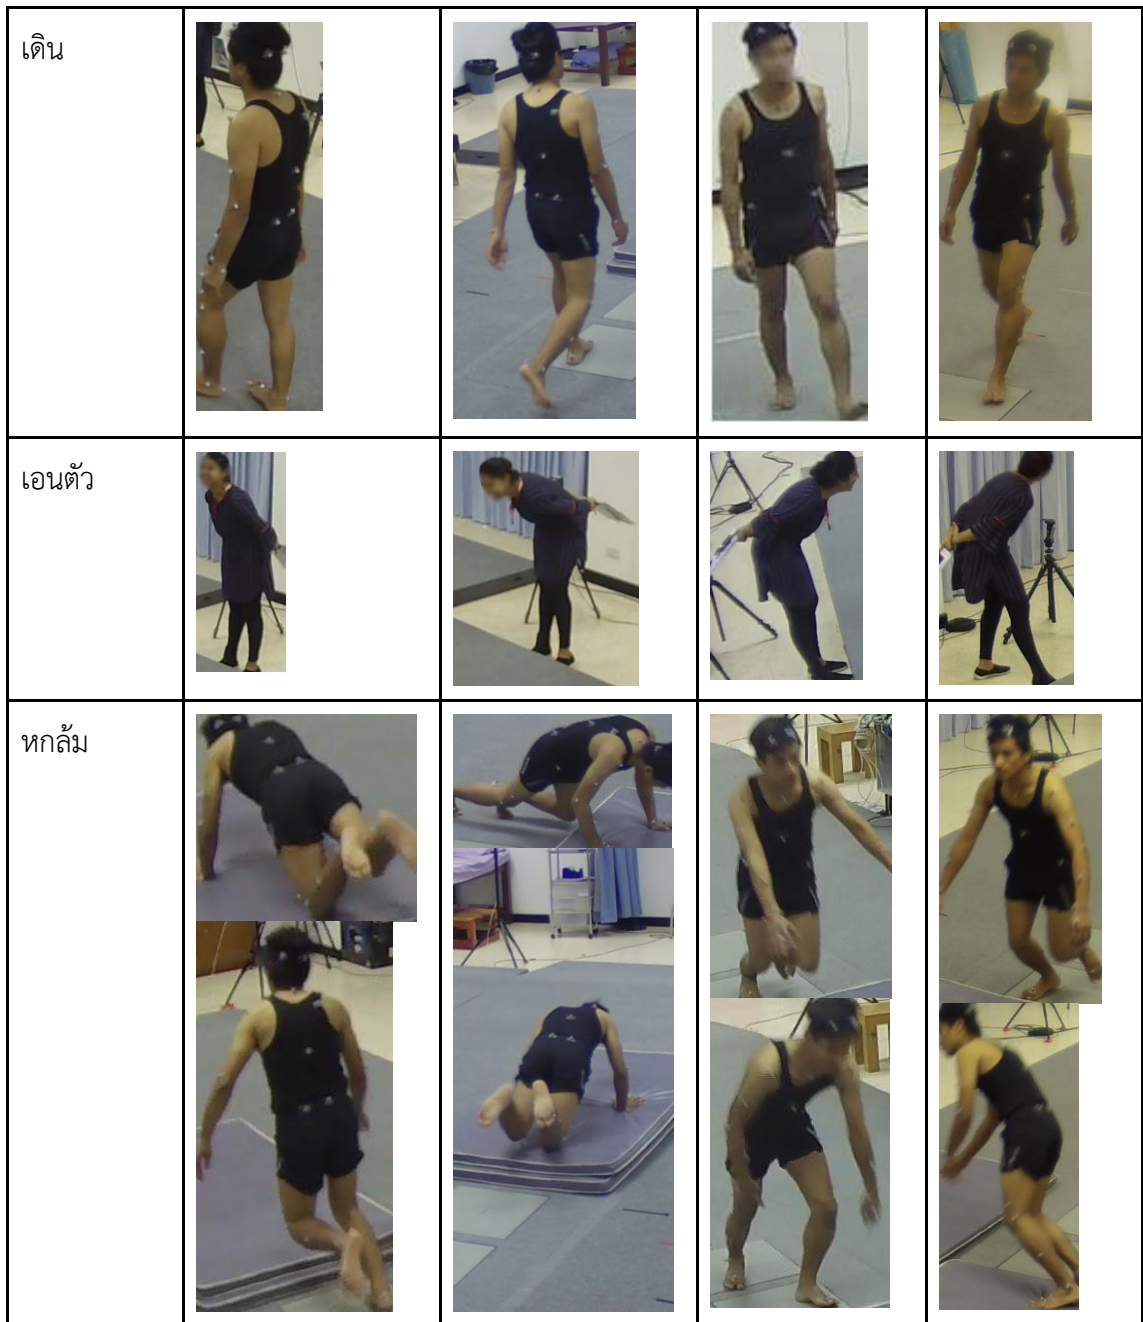
ข้อมูลภาพท่าทางนั่งซึ่งถูกสร้างจากโปรแกรมสร้างชุดข้อมูลตัดบางส่วนของขาของตัวบุคคลไปทำให้ไม่สามารถดึงข้อมูลโครงร่างของร่างกายส่วนที่เป็นขาออกมาได้ ดังนั้นทีมีวิจัยจึงต้องตัดภาพในท่าทางนั่งด้วยมือเพื่อให้ได้ส่วนของขาทั้งหมดที่ปรากฏในภาพ ภายหลังจากปรับปรุงชุดข้อมูลสำหรับการเทรนทีมีวิจัยจะรวมท่าทางนั่งเข้าไปในการเทรนโมเดลใหม่อีกครั้ง

1) การเทรนโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดลโดยใช้มุมมองเดียว

โมเดลที่ทีมีวิจัยเทรนใช้ข้อมูลโครงร่างของร่างกายจำนวน 18 จุด (key-points) เพื่อที่จะแยกแยะท่าทางการเดิน ยืน เอนตัว และทก้ม ทั้งหมดจำนวน 4 ประเภทกิจกรรม ข้อมูลที่ใช้เทรนทั้งหมดมีจำนวน 1,312 ภาพ จากมุมมอง 1 มุม (มุมมองที่ 1) จากบุคคล 1 คน โดยจำแนกออกเป็น ท่าทางการเดิน 1,115 ภาพ ยืน 33 ภาพ เอนตัว 13 ภาพ และ ทก้ม 151 ภาพ ข้อมูลภาพทั้งหมดจะถูกปรับขนาดเป็นขนาด 253x318 พิกเซล ตัวอย่างภาพข้อมูลที่ใช้ในการเทรนโมเดลแสดงในตารางที่ 17

ตารางที่ 17 ตารางแสดงตัวอย่างภาพของท่าทางทั้ง 4 ประเภท จากมุมมองที่แตกต่างกัน 4 มุมมอง

ประเภทกิจกรรม (ท่าทาง)	มุมมองกล้องที่ 1 (ch1)	มุมมองกล้องที่ 2 (ch2)	มุมมองกล้องที่ 3 (ch3)	มุมมองกล้องที่ 4 (ch4)
นั่ง				
ยืน				



หมายเหตุ: สำหรับรูปบุคคลที่ถูกตัดโดยโปรแกรมที่ใช้สร้างชุดข้อมูลสำหรับการเทรนไม่ครอบคลุมทุก ส่วนของตัวบุคคล เช่น ทำยีนในมุกกล้องที่ 2 จะไม่ถูกนำมาใช้ในชุดข้อมูลสำหรับการเทรน


ทีมวิจัยใช้ Keras เป็นเครื่องมือในการเทรนโมเดลโดยมีรายละเอียดดังต่อไปนี้
 จำนวนรูปที่ใช้เป็นชุดข้อมูลเทรน (training dataset): 1,312 รูป
 จำนวนรูปที่ใช้เป็นชุดข้อมูลตรวจสอบ (validation dataset): 132 รูป
 จำนวน epochs: 20 epochs
 รูปที่ 73 แสดงค่า loss ในระหว่างการเทรนโมเดล
 โดยมีรายละเอียดโครงสร้างเน็ตเวิร์กแต่ละเลเยอร์ดังต่อไปนี้

Layer (type)	Output shape	Param #
dense_1 (Dense)	(None, 128)	4736
batch_normalization_1 (Batch)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch)	(None, 64)	256
dense_3 (Dense)	(None, 16)	1040
batch_normalization_3 (Batch)	(None, 16)	64
dense_4 (Dense)	(None, 4)	68

Total params: 14,932


Trainable params: 14,516

Non-trainable params: 416



รูปที่ 73 แผนภูมิแสดงค่า training และ validation accuracy และ training และ validation loss ของการเทรนโมเดลสำหรับแยกแยะประเภทกิจกรรม 4 ประเภท ยืน เดิน เอนตัว และหกล้ม

ทีมวิจัยทดสอบโมเดลที่ทีมวิจัยเทรนบนชุดข้อมูลทดสอบ (unseen dataset) เพื่อดูผลการแยกแยะประเภทกิจกรรม (ท่าทาง) และได้ผลแสดงในรูปที่ 74 และ 75




รูปที่ 74 ผลการแยกแยะประเภทกิจกรรม (ท่าทาง) บนชุดข้อมูลทดสอบ (unseen dataset)



รูปที่ 75 ผลการแยกแยะประเภทกิจกรรม (ท่าทาง) บนชุดข้อมูลทดสอบ (unseen dataset)
ในมุมกล้องวงจรปิดที่ติดตั้งอยู่แล้วในบ้านของทีมวิจัย

ภายหลังการปรับปรุงชุดข้อมูลทำนอง ทีมวิจัยได้ทดสอบเทรนโมเดลโดยเพิ่มข้อมูลประเภทกิจกรรมเป็น 5 ประเภท คือ นั่ง การเดิน ยืน เอนตัว และหกล้ม โดยใช้ข้อมูลทั้งหมด 1,912 รูป และใช้เน็ตเวิร์กโมเดลเดียวกันกับการเทรนโมเดลประเภทกิจกรรม 4 ประเภท แต่ใช้จำนวน epochs ต่างกันโดยใช้ 40 epochs ในการเทรนโมเดล แผนภูมิแสดงค่า training และ validation accuracy และ training และ validation loss ระหว่างการเทรนโมเดลแสดงดังรูปที่ 76 ค่า training accuracy และ validation accuracy ที่ epochs 20 มีค่าประมาณ 0.6 ซึ่งมีค่าสูงเมื่อเทียบกับการเทรนโมเดลที่ใช้กับ 4 ประเภทกิจกรรม รวมถึงค่า training loss และ validation loss ที่เริ่มคงที่ที่ epochs 30 ทีมวิจัยได้ทดสอบโมเดลประเภทกิจกรรม 5 ประเภท พบว่าให้ความแม่นยำต่ำกว่าโมเดลประเภทกิจกรรม 4 ประเภท



รูปที่ 76 แผนภูมิแสดงค่า training และ validation accuracy และ training และ validation loss ของการเทรนโมเดลสำหรับแยกแยะประเภทกิจกรรม 5 ประเภท นั่ง ยืน เดิน เอนตัว และหกล้ม

จากผลการทดสอบโมเดลประเภทกิจกรรม 4 ประเภทที่เทรนโดยใช้ข้อมูลดังกล่าวสามารถทำงานได้บนชุดข้อมูลทดสอบ (unseen dataset) แต่เมื่อเพิ่มจำนวนประเภทกิจกรรมเป็น 5 ประเภทกิจกรรมที่มิวิจัยพบว่าการเสื่อมถอยของโมเดล ที่มิวิจัยได้ทดสอบใช้ข้อมูลจากหลายมุมมองเพื่อให้โมเดลสามารถทำงานได้ดีขึ้น รายละเอียดอธิบายในหัวข้อถัดไป (การเทรนโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดลโดยใช้มุมมองหลายมุมมอง)

2) การเทรนโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดลโดยใช้มุมมองหลายมุมมอง



ที่มิวิจัยจึงทำการทดสอบเพิ่มเติมโดยการเพิ่มจำนวนภาพในชุดข้อมูลสำหรับการเทรนโมเดล และพิจารณาการเพิ่มจำนวนเลเยอร์ของเน็ตเวิร์กที่ใช้ในการเรียนรู้เชิงลึก รวมถึงทดสอบปรับค่าตัวแปรที่ใช้ในกระบวนการเทรนโมเดล เพื่อให้ได้โมเดลประเภทกิจกรรม 5 ประเภทที่ให้ความแม่นยำสูงจากข้อมูลวิดีโอที่มิวิจัยมีอยู่ ที่มิวิจัยมีรูปชุดข้อมูลที่ใช้เทรนที่ถูกตัดโดยโปรแกรมสร้างชุดข้อมูลสำหรับการเทรนอีกจำนวน 363,914 รูป ซึ่งเป็นข้อมูลจากผู้สูงอายุ 20 คน ที่มีท่าทางการทำกิจกรรมประเภทต่าง ๆ ยกเว้นการจำลองการหกล้ม และ 7,820 รูปซึ่งเป็นข้อมูลจากสมาชิกที่มิวิจัยจำนวน 1 คน ที่มีท่าทางการทำกิจกรรมประเภทต่าง ๆ รวมถึงการจำลองการหกล้ม โดยแบ่งเป็นรูปจากมุมมองที่ 1 จำนวน 1,899 รูป มุมมองที่ 2 จำนวน 1,524 รูป มุมมองที่ 3 จำนวน 3,015 รูป มุมมองที่ 4 จำนวน 1,382 รูป ข้อมูลรูปทั้งหมดนี้ต้องใช้คนในการคัดกรองภาพ และเลือกเฉพาะภาพที่เหมาะสมนำมาใช้ในกระบวนการเทรนโมเดล การเตรียมชุดข้อมูลสำหรับการเทรนโมเดล และผลการเปรียบเทียบโมเดลมุมมอง 1, โมเดลมุมมอง 2, โมเดลมุมมอง 3 และ โมเดลจากกล้องหลายมุมมอง อธิบายในรายละเอียดดังต่อไปนี้

การเตรียมชุดข้อมูลสำหรับการเทรนโมเดล:


ภาพจะถูกตัดจากเฟรมต้นฉบับและทำการแบ่งกลุ่มข้อมูล training และ validation ที่วิจัยใช้ OpenPose เพื่อดึงข้อมูลโครงร่างของร่างกายจำนวน 18 จุด จุดโครงร่างของร่างกายที่ถูกบดบังหรือไม่ถูกตรวจพบจะถูกตั้งค่าเป็น 0 ในทั้งแกน x และแกน y จุดทุกจุดจะถูกนำมา normalize โดยใช้จุดโครงร่างของร่างกายตำแหน่งคอเป็นจุดอ้างอิง แต่ข้อมูลของจุดโครงร่างของร่างกายที่มีเฉพาะส่วนบนของร่างกายข้อมูลโครงร่างของร่างกายนั้นจะไม่ถูกนำมาเทรน

โมเดลมุกกล้อง 1:


โมเดลนี้ถูกเทรนโดยใช้ข้อมูลจากมุกกล้องที่ 1 โดยที่วิจัยได้ทดสอบกับรูปแบบคุณลักษณะของจุดโครงร่างของร่างกายหลายรูปแบบเพื่อศึกษาว่าลักษณะของจุดโครงร่างของร่างกายแบบไหนให้ความแม่นยำที่ดีที่สุด



(a)



(b)



(c)

รูปที่ 77 เปรียบเทียบโมเดลที่ใช้การคำนวณค่าพิกัดจุดของโครงร่างของร่างกายในรูปแบบที่แตกต่างกัน

ในรูปที่ 77 โมเดล (a) พิจารณาจุดโครงร่างของร่างกายตำแหน่งคอใช้เป็นจุดอ้างอิง และเพิ่มค่า -1 ให้กับจุดโครงร่างของร่างกายที่ตรวจไม่พบ และทำการลบค่าพิกัดจุดอื่น ๆ ที่ตรวจพบด้วยจุดอ้างอิงตำแหน่งคอ และคำนวณค่าสัมบูรณ์ที่เป็นระยะห่างระหว่างจุดอื่น ๆ กับตำแหน่งคอ โมเดลนี้ให้ผลลัพธ์การแยกแยะประเภทท่าทางเป็น ยืน และ เดิน สำหรับบุคคล ID-4 และ ID-2 ตามลำดับ เมื่อพิจารณาโมเดล (b) ซึ่งใช้ค่าจุดของโครงร่างของร่างกายทั้งหมดหารด้วยขนาดความกว้างและความสูงตามข้อแกน x และแกน y โมเดล (b) ให้ผลลัพธ์การแยกแยะท่าทางเป็น เดิน และ เอนตัว สำหรับ ID-4 และ ID-2 ตามลำดับ โมเดล (c) พิจารณาใช้จุดตำแหน่งคอเป็นจุดอ้างอิงและทำการกำหนดค่า 0 ให้กับจุดโครงร่างของร่างกายอื่นที่ตรวจไม่พบ และทำการลบพิกัดจุดอื่น ๆ ด้วยพิกัดตำแหน่งของคอและทำการหารด้วยความกว้างและสูงของรูปภาพ โมเดล (c) ใช้จำนวนเลเยอร์ของเน็ตเวิร์กเยอะกว่าโมเดลอื่นที่กล่าวมาข้างต้นแต่สามารถแยกแยะประเภทท่าทางเป็น ยืน และ ล้ม สำหรับ ID-2 และ ID-1 ได้อย่างถูกต้อง

รายละเอียดเน็ตเวิร์กของโมเดลที่ใช้ข้อมูลจากกล้องที่ 1:

- จำนวนภาพที่ใช้ในการเทรน (training dataset) รวม 3,610 ภาพ โดยแบ่งเป็น


- นั่ง 784 ภาพ
- ยืน 729 ภาพ
- เอนตัว 730 ภาพ
- เดิน 664 ภาพ
- หกกล้ม 703 ภาพ
- จำนวนภาพที่ใช้ในตรวจสอบความถูกต้อง (validation dataset) รวม 361 ภาพ โดยแบ่งเป็น
 - นั่ง 87 ภาพ
 - ยืน 77 ภาพ
 - เอนตัว 71 ภาพ
 - เดิน 63 ภาพ
 - หกกล้ม 63 ภาพ

รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูลทดสอบแสดงในรูปที่ 78

```

Model: "sequential_1"
-----
Layer (type)                Output Shape              Param #
-----
dense_1 (Dense)             (None, 128)               4736
batch_normalization_1 (Batch Normalization) (None, 128)              512
dense_2 (Dense)             (None, 64)                8256
batch_normalization_2 (Batch Normalization) (None, 64)              256
dense_3 (Dense)             (None, 32)               2080
batch_normalization_3 (Batch Normalization) (None, 32)              128
dense_4 (Dense)             (None, 16)                528
batch_normalization_4 (Batch Normalization) (None, 16)              64
dense_5 (Dense)             (None, 5)                 85
-----
Total params: 16,645
Trainable params: 16,165
Non-trainable params: 480
-----
Test:
361/361 [=====] - 0s 48us/step
Test Score:0.0543
Test accuracy:0.986

```



		Preditd label				
		sit	stand	walk	bend	fall
True label	sit	87	0	0	0	0
	stand	0	76	1	0	0
	walk	1	1	68	0	1
	bend	0	0	0	62	1
	fall	0	0	0	0	63

รูปที่ 78 รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูล validation บนข้อมูลจากกล้องที่ 1


โมเดลมุกกล้อง 3:

รายละเอียดเน็ตเวิร์กของโมเดลที่ใช้ข้อมูลจากกล้องที่ 3 มีรายละเอียดดังนี้

- จำนวนภาพที่ใช้ในการเทรน (training dataset) รวม 2,700 ภาพ โดยแบ่งเป็น

- นั่ง 520 ภาพ
- ยืน 562 ภาพ
- เอนตัว 511 ภาพ
- เดิน 530 ภาพ
- หกล้ม 577 ภาพ
- จำนวนภาพที่ใช้ในตรวจสอบความถูกต้อง (validation dataset) รวม 318 ภาพ โดยแบ่งเป็น
 - นั่ง 58 ภาพ
 - ยืน 49 ภาพ
 - เอนตัว 47 ภาพ
 - เดิน 61 ภาพ
 - หกล้ม 55 ภาพ

ในการทดสอบโมเดลที่เทรนที่มวิจัยได้ทำการปรับจูนค่า Part Affinity Field (PAF) จากค่า 0.2 เป็น 0.3 เนื่องจากส่งผลต่อความแม่นยำที่ดีกว่าดังแสดงในรูปที่ 79 การใช้ค่า PAF ที่ 0.2 ทำให้การตรวจจับโครงร่างของร่างกายของบุคคลที่ยืนอยู่ใกล้กันผิดพลาด การเพิ่มค่า PAF เป็น 0.3 สามารถลดการตรวจจับโครงร่างของร่างกายผิดพลาดได้



Network configuration channel 3 PAF 0.2

Network configuration channel 3 PAF 0.3

รูปที่ 79 แสดงการเปรียบเทียบการใช้ PAF ที่แตกต่างกัน มีผลต่อการแยกแยะประเภทท่าทาง


รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูลทดสอบแสดงในรูปที่ 80 และรูปที่ 81 แสดงการเปรียบเทียบความแม่นยำในการแยกแยะประเภทท่าทางเมื่อใช้ค่า PAF ที่แตกต่างกัน

Model: "sequential_1"

Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	4736
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 5)	85

Total params: 16,645
Trainable params: 16,165
Non-trainable params: 480

Test: 270/270 [=====] - 0s 43us/step
Test Score: 0.0744
Test accuracy: 0.989



		Preditd label				
		sit	stand	walk	bend	fall
True label	sit	58	0	0	0	0
	stand	0	49	0	0	0
	walk	0	0	46	1	0
	bend	0	0	0	61	0
	fall	1	0	0	1	53

รูปที่ 80 รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูล validation บนข้อมูลจากกล้องที่ 3

Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	4736
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 5)	85

Total params: 16,645
Trainable params: 16,165
Non-trainable params: 480

Test: 361/361 [=====] - 0s 48us/step
Test Score: 0.8543
Test accuracy: 0.986

Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	4736
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 5)	85

Total params: 16,645
Trainable params: 16,165
Non-trainable params: 480

Test: 361/361 [=====] - 0s 60us/step
Test Score: 0.8472
Test accuracy: 0.992

Model accuracy PAF 0.2 vs PAF 0.3

		Preditd label					Total
		sit	stand	walk	bend	fall	
True label	sit	87	0	0	0	0	87
	stand	0	76	1	0	0	77
	walk	1	1	68	0	1	71
	bend	0	0	0	62	1	63
	fall	0	0	0	0	63	63
Total		88	77	69	62	65	361

		Preditd label					Total
		sit	stand	walk	bend	fall	
True label	sit	87	0	0	0	0	87
	stand	0	76	1	0	0	77
	walk	1	0	70	0	0	71
	bend	0	0	0	62	1	63
	fall	0	0	0	0	63	63
Total		88	76	71	62	64	361

รูปที่ 81 เปรียบเทียบความแม่นยำในการแยกแยะประเภทท่าทางเมื่อกำหนดค่า PAF ที่แตกต่างกัน

โมเดลมุกห้อง 2:

รายละเอียดเน็ตเวิร์กของโมเดลที่ใช้ข้อมูลจากกล่องที่ 2 มีรายละเอียดดังนี้

- จำนวนภาพที่ใช้ในการเทรน (training dataset) รวม 3,176 ภาพ โดยแบ่งเป็น
 - นิ่ง 628 ภาพ
 - ยืน 636 ภาพ
 - เอนตัว 622 ภาพ
 - เดิน 504 ภาพ
 - หกล้ม 786 ภาพ
- จำนวนภาพที่ใช้ในตรวจสอบความถูกต้อง (validation dataset) รวม 318 ภาพ โดยแบ่งเป็น
 - นิ่ง 56 ภาพ
 - ยืน 60 ภาพ
 - เอนตัว 67 ภาพ
 - เดิน 59 ภาพ
 - หกล้ม 76 ภาพ


รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูลทดสอบแสดงในรูปที่ 82

Model: "sequential_1"

Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	4736
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 5)	85

Total params: 16,645
Trainable params: 16,165
Non-trainable params: 480

Test:
318/318 [=====] - 0s 46us/step
Test Score:0.0616
Test accuracy:0.997




		Preditd label				
		sit	stand	walk	bend	fall
True label	sit	56	0	0	0	0
	stand	0	60	0	0	0
	walk	1	0	66	0	0
	bend	0	0	0	59	0
	fall	0	0	0	0	76

รูปที่ 82 รายละเอียดโครงสร้างเน็ตเวิร์ก การเทรนโมเดล และ confusion matrix บนชุดข้อมูล validation บนข้อมูลจากกล่องที่ 2


โมเดลจากกล้องหลายมุมมอง:

ทีมวิจัยทดสอบเทรนโมเดลโดยใช้ข้อมูลภาพจากกล้องทั้งสามตัว โดยแบ่งเป็น โมเดลที่เทรนโดยใช้ข้อมูลจากกล้องสองตัวคือกล้องที่ 1 และ 3 และโมเดลที่ใช้ข้อมูลจากกล้องทั้งสามตัว ค่าความแม่นยำระหว่างการเทรนโมเดลเมื่อใช้ข้อมูลจากกล้อง 1 และ 3 อยู่ที่ 0.986 โดยใช้จำนวนรูปทั้งหมด 6,310 ภาพ และเป็นภาพสำหรับชุดข้อมูล validation 631 ภาพ และตาราง confusion matrix บนชุดข้อมูล validation แสดงในรูปที่ 83 โมเดลที่เทรนโดยใช้ข้อมูลจากกล้องสามตัวคือกล้องที่ 1 2 และ 3 และโมเดลที่ใช้ข้อมูลจากกล้องทั้งสามตัว ค่าความแม่นยำระหว่างการเทรนโมเดลเมื่อใช้ข้อมูลจากกล้อง 1 2 และ 3 อยู่ที่ 0.993 โดยใช้จำนวนรูปทั้งหมด 9,486 ภาพ และเป็นภาพสำหรับชุดข้อมูล validation 949 ภาพ และตาราง confusion matrix บนชุดข้อมูล validation แสดงในรูปที่ 84



		Preditd label				
		sit	stand	walk	bend	fall
True label	sit	125	0	0	0	0
	stand	1	135	0	0	0
	walk	0	1	119	1	1
	bend	0	0	0	117	1
	fall	1	0	1	2	126

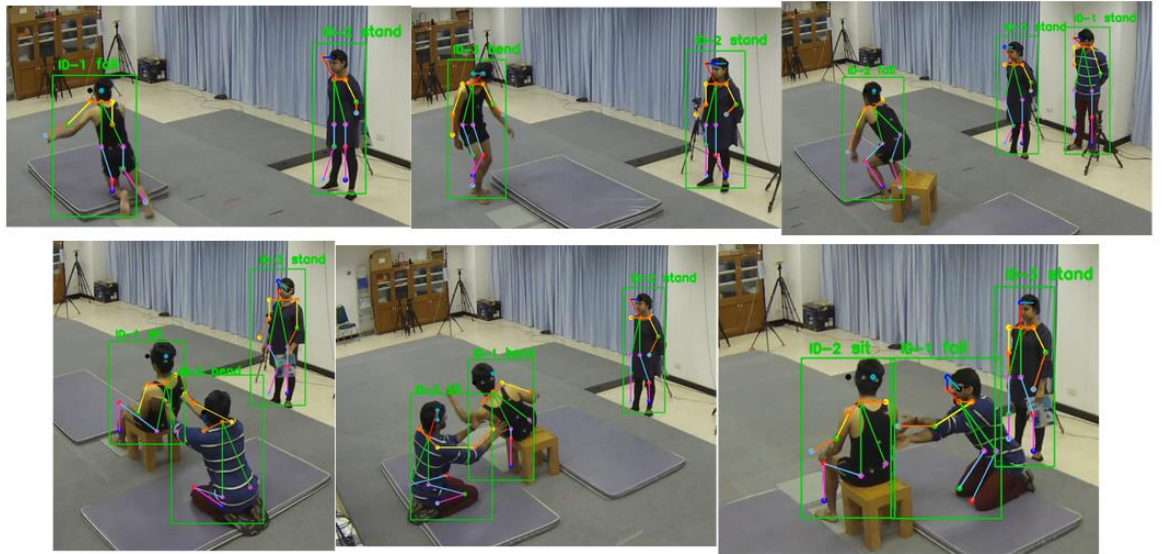
รูปที่ 83 Confusion matrix ของชุดข้อมูล validation เมื่อใช้ข้อมูลจากกล้องที่ 1 และ 3 ในการ เทรนโมเดล




		Preditd label				
		sit	stand	walk	bend	fall
True label	sit	193	0	0	0	0
	stand	0	193	0	0	0
	walk	0	0	184	1	0
	bend	0	0	0	163	1
	fall	3	0	0	2	209

รูปที่ 84 Confusion matrix ของชุดข้อมูล validation เมื่อใช้ข้อมูลจากกล้องที่ 1 2 และ 3 ในการ เทรนโมเดล


ผลลัพธ์การทดสอบโมเดลที่เทรนโดยข้อมูลจากกล้องที่ 1 2 และ 3 กับ seen dataset แสดงในรูปที่ 85 - 87 และการทดสอบกับ unseen dataset แสดงในรูปที่ 88




รูปที่ 85 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจากกล้องที่ 1 (seen data)



รูปที่ 86 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจากกล้องที่ 2 (seen data)




รูปที่ 87 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจากกล้องที่ 3 (seen data)




รูปที่ 88 ผลลัพธ์การแยกแยะประเภทท่าทางโดยโมเดลที่เทรนจากข้อมูลทั้ง 3 กล้อง บนชุดข้อมูลจากกล้องที่ 4 (unseen data)

ถึงแม้ว่าโมเดลจะให้ผลลัพธ์การแยกแยะประเภทท่าทางที่ถูกต้องบนชุดข้อมูลจากกล้องที่ 4 ซึ่งเป็น unseen dataset แต่โมเดลดังกล่าวยังไม่สามารถแยกแยะประเภทท่าทางจากกล้องมุมมองอื่นได้ดี โดยที่มวิจัยทดสอบโมเดลดังกล่าวกับกล้องที่ติดตั้งภายในสถาบันเทคโนโลยีแห่งเอเชีย พบว่ายังมีการแยกแยะประเภทท่าทางผิดอยู่บ้างซึ่งเกิดจากการบดบังตัวบุคคล ดังแสดงในรูปที่ 89 - 90



รูปที่ 89 ตัวอย่างผลการแยกแยะประเภทท่าทางผิดพลาด (ID-7 และ ID-3 ในรูปซ้าย และ ID-15 ในรูปขวา) จากข้อมูลวิดีโอจากกล้องที่ติดตั้งในสถาบันเทคโนโลยีแห่งเอเชีย



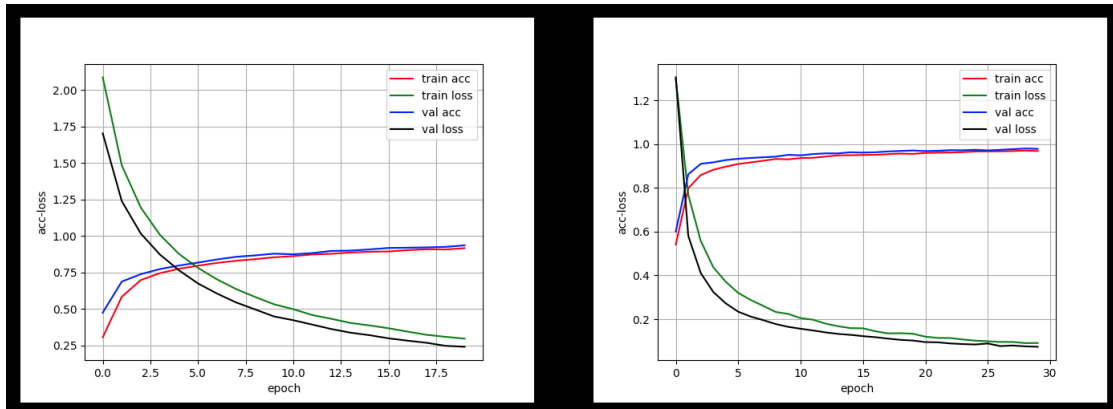
รูปที่ 90 ตัวอย่างผลการแยกแยะประเภทท่าทางผิดพลาด (บุคคลที่ยืนไกลสุดในรูปซ้าย และ ID-15 และ ID-2 ในรูปขวา) จากข้อมูลวิดีโอจากกล้องที่ติดตั้งในสถาบันเทคโนโลยีแห่งเอเชีย

4.1.1.2 การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่น Cascade Framewise Activity Classification

การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่น เทรนโดยใช้ชุดข้อมูล MOVI เป็นหลัก เพื่อให้อัลกอริทึมสามารถแยกแยะท่าทางได้หลากหลายประเภทมากขึ้น

4.1.1.2.a การเทรนโมเดลสำหรับแยกแยะ 10 ท่าทาง บนชุดข้อมูล MoVi

ทีมวิจัยได้เทรนโมเดลโดยใช้ข้อมูลทั้งหมด 10 ท่าทาง อย่างไรก็ตามทีมวิจัยพบว่าท่าทางบางประเภทถูกแยกแยะว่าเป็นเซ็ดย่อยของท่าทางบางประเภท เช่น ท่าทางการโบกมือถูกแยกแยะเป็นท่าทางกรีน ดังนั้นทีมวิจัยจึงเทรนข้อมูลในรูปแบบของท่าทางกิจกรรมหลัก (pre classifier) และท่าทางกิจกรรมรอง (post classifier) โดย pre classifier จะแยกแยะ 5 ท่าทางหลัก (ยืน เดิน เอน นั่ง ล้ม) และ post classifier จำนวน 3 โมเดล เพื่อใช้แยกแยะประเภทกิจกรรมใหม่ 5 ท่าทาง (ดูนาฬิกาข้อมือ, ปรบมือ, ค่อยโทรศัพท์, ซี่, โบกมือ) ระหว่าง นั่ง ยืน และ เดิน ส่วนท่าทางการเอน และล้ม เป็นท่าทางที่เกิดขึ้นในระยะเวลาอันสั้นที่ทีมวิจัยจึงไม่มี post classifier ของท่าทางใหม่ 5 ท่าทาง ดังกล่าว รูปที่ 91 แสดงความแม่นยำระหว่างการเทรนข้อมูล pre classifier เปรียบเทียบกับการเทรนโมเดลแบบ 10 ท่าทาง



รูปที่ 91 แสดงความแม่นยำระหว่างการเทรนของ pre classifier กับข้อมูล 5 ท่าทาง (ขวา) ซึ่งให้ความแม่นยำสูงกว่า classifier แบบ 10 ท่าทาง (ซ้าย)

ข้อมูลรายละเอียดการเทรน pre classifier:

ข้อมูลของท่าทาง 5 กิจกรรมใหม่ (ดูนาฬิกาข้อมือ, ปรบมือ, ค่อยโทรศัพท์, ซี่, โบกมือ) ถูกเพิ่มลงไปยังข้อมูลท่าทางยืน และสร้างชุดข้อมูลใหม่จำนวน 5 ท่าทาง โดยมีจำนวนภาพในแต่ละประเภทดังนี้

นั่ง 1,646 ภาพ

ยืน 8,352 ภาพ

เดิน 1,403 ภาพ

เอนตัว 876 ภาพ

ล้ม 1,162 ภาพ

โครงสร้างเน็ตเวิร์กของโมเดล pre classifier มีรายละเอียดแสดงในรูปที่ 92

Model: "sequential_1"

Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	4736
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 5)	85

=====
Total params: 16,645
Trainable params: 16,165
Non-trainable params: 480
=====
Test:
1344/1344 [=====] - 0s 40us/step
Test Score:0.074
Test accuracy:0.978

รูปที่ 92 โครงสร้างโมเดล pre classifier

ความแม่นยำของ pre classifier เทรนโดยใช้ 30 epochs ให้ความแม่นยำบนชุดข้อมูลทดสอบที่ 97.8% โดย confusion matrix แสดงในตารางที่ 18

ตารางที่ 18 Confusion matrix ของผลการทดสอบ pre classifier บนชุดข้อมูลทดสอบ

GT\Prediction	นั่ง	ยืน	เดิน	เอนตัว	ล้ม
นั่ง	157	0	0	1	2
ยืน	0	843	6	0	0
เดิน	0	13	119	1	0
เอนตัว	0	1	2	85	1
ล้ม	0	1	1	0	111

ทีมวิจัยได้เทรนโมเดลเพิ่ม 3 โมเดล (post classifier) เพื่อแยกแยะประเภทท่าทางขณะ นั่ง ยืน หรือ เดิน โดยใช้ข้อมูลโครงร่างของร่างกายเฉพาะส่วนบนเนื่องจากท่าทางใหม่ 5 ประเภท (ดูนาฬิกาข้อมือ, ประบมือ, คุยโทรศัพท์, ซี่, โบกมือ) นั้นส่วนใหญ่เกี่ยวข้องกับการเคลื่อนไหวของแขนเป็นหลัก ทีมวิจัยจึงเทรนโมเดลโดยใช้ตำแหน่งจุดโครงร่างของร่างกายเฉพาะส่วนบนซึ่งมี 12 จุด ตัวอย่างเช่น ถ้าบุคคลกำลังยืนและทำท่าทางอื่น ๆ โมเดลแต่ละโมเดลจะประกอบด้วยข้อมูลท่าทางส่วนบนของร่างกาย 5 ประเภท โดยที่ในการเทรน post classifier ของท่านั่ง ข้อมูลที่ใช้ในการเทรน จะถูกจัดกลุ่มเป็น 6 กลุ่ม โดย 5 กลุ่มแรกเป็นกลุ่มของท่าทาง ดูนาฬิกาข้อมือ ประบมือ คุยโทรศัพท์ ซี่ โบกมือ ส่วนกลุ่มสุดท้ายจะเป็นท่าทางอื่น ๆ ที่ไม่ใช่ 5 ท่าทางดังกล่าว ซึ่งโมเดล post classifier จะถูกนำมาใช้ภายหลังได้ข้อมูลการแยกแยะประเภทท่าทางจาก pre classifier แล้ว การเทรนโมเดล post classifier ของ 5 ท่าทางระหว่างยืน และ เดินก็จะเตรียมข้อมูลในลักษณะเดียวกัน ดังนั้นแต่ละ post classifier โมเดลจะมีจำนวนคลาสทั้งหมด 6 คลาส

โครงสร้างเน็ตเวิร์กสำหรับโมเดล post classifier มีรายละเอียดแสดงในรูปที่ 93

Model: "sequential_1"

Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	3200
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 6)	102

รูปที่ 93 โครงสร้างโมเดล post classifier

Post classifier สำหรับแยกแยะท่าทางขณะนั่ง:

ประกอบด้วยชุดข้อมูลภาพสำหรับเทรนจำนวน 8,183 ภาพ จากท่าทาง 6 ประเภท

อื่น ๆ 1,646 ภาพ

ดูนาฬิกาข้อมือ 1,348 ภาพ

ปรบมือ 1,364 ภาพ

คุยโทรศัพท์ 1,410 ภาพ

ชี้ 1,191 ภาพ

โบกมือ 1,224 ภาพ

ความแม่นยำของ post classifier สำหรับแยกแยะท่าทางขณะนั่ง ให้ความแม่นยำบนชุดข้อมูลทดสอบที่ 99% โดย confusion matrix แสดงในตารางที่ 19

ตารางที่ 19 Confusion matrix ของผลการทดสอบ post classifier สำหรับแยกแยะท่าทางขณะนั่งบนชุดข้อมูลทดสอบ

GT\Prediction	อื่น ๆ	ดูนาฬิกาข้อมือ	ปรบมือ	คุยโทรศัพท์	ชี้	โบกมือ
อื่น ๆ	158	0	0	0	0	0
ดูนาฬิกาข้อมือ	0	135	0	1	1	0
ปรบมือ	0	0	135	0	0	0
คุยโทรศัพท์	0	0	0	126	0	0
ชี้	0	0	0	0	126	0
โบกมือ	0	0	0	0	0	137

Post classifier สำหรับแยกแยะท่าทางขณะยืน:

ประกอบด้วยชุดข้อมูลภาพสำหรับเทรนจำนวน 8,352 ภาพ จากท่าทาง 6 ประเภท

อื่น ๆ 1,815 ภาพ

ดูนาฬิกาข้อมือ 1,348 ภาพ

ปรบมือ 1,364 ภาพ

คุยโทรศัพท์ 1,410 ภาพ

ชี้ 1,191 ภาพ

โบกมือ 1,224 ภาพ

ความแม่นยำของ post classifier สำหรับแยกแยะท่าทางขณะยืน ให้ความแม่นยำบนชุดข้อมูลทดสอบที่ 99% โดย confusion matrix แสดงในตารางที่ 20

ตารางที่ 20 Confusion matrix ของผลการทดสอบ post classifier สำหรับแยกแยะท่าทางขณะยืน บนชุดข้อมูลทดสอบ

GT\Prediction	อื่น ๆ	ดูนาฬิกาข้อมือ	ปรบมือ	คุยโทรศัพท์	ชี้	โบกมือ
อื่น ๆ	181	0	1	1	1	3
ดูนาฬิกาข้อมือ	0	141	0	1	1	0
ปรบมือ	0	0	132	0	0	0
คุยโทรศัพท์	0	0	0	135	0	0
ชี้	0	0	0	0	109	0
โบกมือ	1	0	0	0	0	131

Post classifier สำหรับแยกแยะท่าทางขณะเดิน:

ประกอบด้วยชุดข้อมูลภาพสำหรับเทรนจำนวน 7,940 ภาพ จากท่าทาง 6 ประเภท

อื่น ๆ 1,403 ภาพ

ดูนาฬิกาข้อมือ 1,348 ภาพ

ปรบมือ 1,364 ภาพ

คุยโทรศัพท์ 1,410 ภาพ

ชี้ 1,191 ภาพ


โบกมือ 1,224 ภาพ

ความแม่นยำของ post classifier สำหรับแยกแยะท่าทางขณะเดิน ให้ความแม่นยำบนชุดข้อมูลทดสอบที่ 99% โดย confusion matrix แสดงในตารางที่ 21

ตารางที่ 21 Confusion matrix ของผลการทดสอบ post classifier สำหรับแยกแยะท่าทางขณะเดินบนชุดข้อมูลทดสอบ

GT\Prediction	อื่น ๆ	คานาฬิกาข้อมือ	ปรบมือ	คุยโทรศัพท์	ชี้	โบกมือ
อื่น ๆ	127	0	0	1	1	1
คานาฬิกาข้อมือ	0	145	0	1	1	0
ปรบมือ	0	0	143	0	0	0
คุยโทรศัพท์	0	0	0	145	0	0
ชี้	0	0	0	0	107	0
โบกมือ	1	0	0	0	0	123

ทีมวิจัยใช้ข้อมูลจาก Motion Lab มหาวิทยาลัยมหิดล รวมกับข้อมูลที่ได้จากการติดตั้งระบบ ณ บ้านอาสาสมัคร และข้อมูลจากกล้องที่ติดตั้งในสถาบันเทคโนโลยีแห่งเอเชีย และชุดข้อมูล MoVi มาใช้ในการเทรนโมเดลสำหรับแยกแยะประเภทท่าทาง 10 ประเภท โดยทีมวิจัยเทรนโมเดลทั้งหมด 4 โมเดล โดยโมเดลแรก (pre classifier) หรือเรียกอีกอย่างหนึ่งว่า Activity-1 จะแบ่งประเภทท่าทางออกเป็น 5 ประเภท คือ นั่ง ยืน เดิน เอนตัว และ ล้ม เทรนโดยใช้ 36 keypoints ส่วนโมเดลที่สอง (post classifier) หรือเรียกอีกอย่างหนึ่งว่า Activity-2 ซึ่งประกอบด้วย 3 โมเดลย่อยเทรนบน 24 keypoints ดังที่ได้อธิบายไว้ข้างต้น ทีมวิจัยได้ทดสอบบนชุดข้อมูล MoVi โดยผลลัพธ์แสดงในรูปที่ 94



รูปที่ 94 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทาง Activity-1 และ Activity-2 บนชุดข้อมูล MoVi

ทีมวิจัยได้ทดสอบการแยกแยะประเภทท่าทางบนชุดข้อมูลจำลองการล้มที่บ้านที่กจากบ้านอาสาสมัคร โดยผลลัพธ์แสดงในรูปที่ 95



รูปที่ 95 ผลลัพธ์การแยกแยะประเภทท่าทางโดยใช้โมเดล pre classifier และ post classifier

4.1.1.3 การแยกแยะประเภทท่าทางแบบทีละหลายเฟรม LSTM RNN Activity Classification

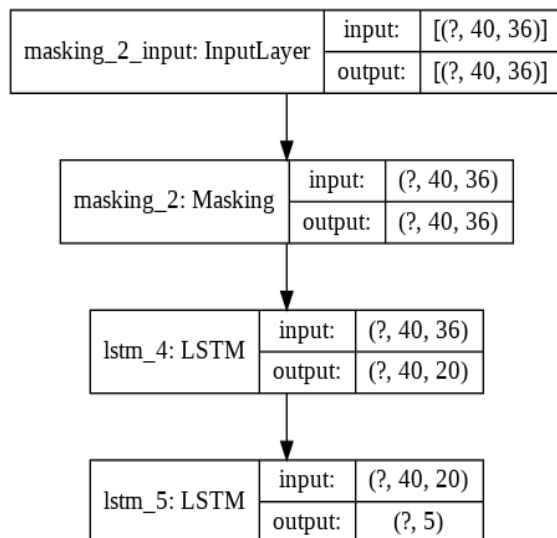
เนื่องด้วยเทคนิค Framewise Classification ยังมีการแยกแยะประเภทท่าทางผิดบนชุดข้อมูล unseen dataset หรือจากมุมมองที่แตกต่างกัน ทีมวิจัยจึงได้ทดสอบใช้โมเดล LSTM RNN ในการแยกแยะประเภทท่าทางทั้ง 5 (นั่ง ยืน เดิน เอนตัว และ หกล้ม) โดยที่ชุดข้อมูลสำหรับเทรนจะเป็นลำดับของข้อมูลของโครงสร้างของร่างกาย โดยใช้ชุดข้อมูลจากการเก็บข้อมูล ณ มหาวิทยาลัยมหิดล โดยตัวอย่างข้อมูลจากอาสาสมัครคนที่ 3 ถูกใช้สำหรับชุดข้อมูลเพื่อการเทรน ชุดข้อมูลจากอาสาสมัครคนที่ 5 เป็นชุดข้อมูล validation และ ชุดข้อมูลจากอาสาสมัครคนที่ 7 เป็นชุดข้อมูลเพื่อการทดสอบ ข้อมูลจากทุกมุมมองถูกนำมาใช้ 7 ในการเทรนและทดสอบความแม่นยำ รายละเอียดของจำนวนภาพที่ใช้ในการเทรนมีรายละเอียดแสดงในตารางที่ 22

ตารางที่ 22 รายละเอียดจำนวนภาพที่ใช้ในการเทรนโมเดล LSTM RNN สำหรับการแยกแยะประเภทท่าทาง

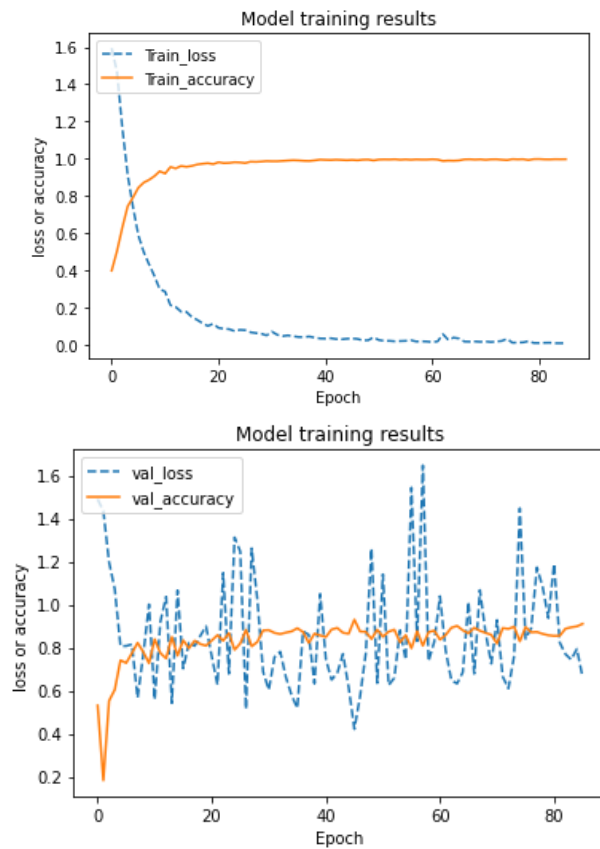
class	Train(subject 3 and fall)	Validation(subject 5 and fall)	Test (subject 7 and fall)

no. of samples	2528	1376	1270
sit	620	114	166
stand	575	149	79
walk	907	911	990
bend	39	8	8
fall	387	88	133

ดังที่ได้กล่าวข้างต้นจุดตำแหน่งโครงร่างของร่างกายจะถูกลบกับตำแหน่งคอ และอาหารด้วยขนาดความกว้างและสูงของภาพ รายละเอียดโครงสร้างเน็ตเวิร์กแสดงในรูปที่ 96 และรายละเอียดในการเทรนโมเดลแสดงในรูปที่ 97




รูปที่ 96 รายละเอียดโครงสร้างเน็ตเวิร์ก LSTM RNN สำหรับแยกแยะประเภทท่าทาง




รูปที่ 97 รายละเอียดในการเทรนโมเดล LSTM RNN สำหรับแยกแยะประเภทท่าทาง

ทีมวิจัยใช้ลำดับเฟรมจำนวน 40 เฟรมเพื่อทดสอบการแยกแยะประเภทท่าทางบน unseen dataset โดยข้อมูลโครงร่างของร่างกายจะถูกส่งเข้าไปยัง LSTM RNN โมเดลเพื่อทำการแยกแยะประเภทท่าทาง ผลจากการแยกแยะประเภทท่าทางแสดงในรูปที่ 98




รูปที่ 98 ผลลัพธ์การแยกแยะประเภทท่าทางบนชุดข้อมูลที่ไม่เคยเห็นมาก่อน

โมเดล LSTM RNN ดังกล่าวนี้เทรนโดยใช้ข้อมูลจากกล้อง 2-3 ตัวให้ผลลัพธ์ที่มีความเป็นไปได้ในการนำไปใช้งานกับมุมมองกล้องอื่น ๆ ความแม่นยำบนชุดข้อมูลทดสอบอยู่ที่ 71.31% ดังแสดงใน confusion matrix รูปที่ 99 ปัจจุบันทีมวิจัยได้ทำการเก็บรวบรวมข้อมูลเพิ่มเติมจากบ้านอาสาสมัครและเตรียมข้อมูลในรูปแบบโครงร่างของร่างกายตามลำดับภาพ เพื่อนำมาใช้เทรนโมเดล LSTM RNN เพิ่มเติม



รูปที่ 99 Confusion matrix บนชุดข้อมูลทดสอบ

ทีมวิจัยได้ทดสอบการแยกแยะประเภทท่าทางโดยใช้โมเดล LSTM RNN กับชุดข้อมูลจำลองการล้ม (unseen data) โดยผลลัพธ์แสดงในรูปที่ 100



รูปที่ 100 ตัวอย่างการตรวจจับการจำลองการหกล้มโดยใช้โมเดล LSTM RNN

4.1.1.4 อัลกอริทึมสำหรับแยกแยะประเภทท่าทางในการใช้งานจริง

ถึงแม้ทีมวิจัยได้ออกแบบและพัฒนาอัลกอริทึม 3 แบบ เพื่อใช้ในการแยกแยะประเภทท่าทางจากการเทรนโมเดลและทดสอบบนชุดข้อมูลหลากหลายชุด ทีมวิจัยพบว่าอัลกอริทึมที่ให้ความแม่นยำดีที่สุดและสามารถทำงานได้ดีคือ อัลกอริทึมการแยกแยะประเภทท่าทางที่ละเฟรมแบบลดหลั่น

(Cascade Framework Activity Classification) อัลกอริทึมดังกล่าวถูกใช้ในการใช้งานจริง และใช้ในการประเมินความแม่นยำของระบบแยกแยะประเภทท่าทางบนชุดข้อมูลทดสอบ AIC-Volunteer1-Set2 ซึ่งเป็นชุดข้อมูลที่ไม่ถูกใช้ในการเทรนโมเดล

4.1.1.4.a โครงสร้างโมเดล

ทีมวิจัยเทรนโมเดลใหม่โดยประกอบด้วย dense layer จำนวน 5 เลเยอร์ และตามด้วย batch normalization โดยทั้ง 5 เลเยอร์ใช้ ReLU เป็น activation function ในส่วนของเลเยอร์ output ใช้ softmax เป็น activation function ทีมวิจัยใช้ categorical cross entropy เป็น loss function และ Adam optimizer ตั้งค่าเริ่มต้นที่ 0.001 ในส่วนของ batch size เป็น 32 และเทรนเป็นจำนวน 40 epochs โดยพิจารณาค่าน้ำหนักข้อมูลแต่ละประเภทเพื่อให้เป็นชุดข้อมูลการเทรนที่สมดุล ชุดข้อมูลที่ใช้ในการเทรนโมเดลถูกแบ่งออกเป็น 10% สำหรับ validation และ 20% สำหรับข้อมูลทดสอบ เพื่อประเมินความแม่นยำของโมเดล ส่วนที่เหลือถูกใช้เป็นชุดข้อมูล training

ทีมวิจัยใช้โครงสร้างเน็ตเวิร์กดังกล่าวในการเทรนโมเดลที่แตกต่างกัน 4 โมเดล โดยยึดข้อมูล 2 คลาสเป็นหลัก คือ โมเดลที่เรียกว่า ‘preclass’ จำนวน 1 โมเดล ซึ่งประกอบด้วยชุดข้อมูล 5 ประเภทหลักได้แก่ นิ่ง ยืน เดิน เอนตัว และ ล้ม ส่วนอีกโมเดลเรียกว่า ‘postclass’ อีก 3 โมเดล ซึ่งประกอบด้วยชุดข้อมูล 5 ประเภทได้แก่ ปรบมือ ดุนาฬิกา ชี้ คู่โทรศัพท์ และ โบกมือ ประกอบด้วยชุดข้อมูล 3 ประเภทหลัก คือ นิ่ง เดิน และ ยืน สำหรับแต่ละโมเดล

4.1.1.4.b การเทรนโมเดล

โมเดล preclass ถูกเทรนโดยใช้โครงสร้างเน็ตเวิร์กดังได้อธิบายไว้ข้างต้น โดย output layer ประกอบด้วย 5 คลาส ส่วนโมเดล postclass ถูกเทรนโดยใช้โครงสร้างเน็ตเวิร์กดังได้อธิบายไว้ข้างต้น โดย output layer ประกอบด้วย 6 คลาส รูปด้านล่างแสดงจำนวนพารามิเตอร์และรายละเอียดของแต่ละเลเยอร์ที่ใช้ในแต่ละโมเดลแสดงในรูปแบบที่ 101 และ 102

Model: "sequential_1"		
Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	4736
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 8)	136
batch_normalization_5 (Batch Normalization)	(None, 8)	32
dense_6 (Dense)	(None, 5)	45
Total params: 16,773		
Trainable params: 16,277		
Non-trainable params: 496		

รูปที่ 101 โครงสร้างโมเดล preclass

Model: "sequential_1"		
Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 128)	3200
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
batch_normalization_2 (Batch Normalization)	(None, 64)	256
dense_3 (Dense)	(None, 32)	2080
batch_normalization_3 (Batch Normalization)	(None, 32)	128
dense_4 (Dense)	(None, 16)	528
batch_normalization_4 (Batch Normalization)	(None, 16)	64
dense_5 (Dense)	(None, 8)	136
batch_normalization_5 (Batch Normalization)	(None, 8)	32
dense_6 (Dense)	(None, 6)	54
Total params: 15,246		
Trainable params: 14,750		
Non-trainable params: 496		

รูปที่ 102 โครงสร้างโมเดล postclass

4.1.1.4.c โมเดลที่เทรนโดยใช้ชุดข้อมูล AIC-360

ทีมวิจัยเก็บข้อมูลชุดข้อมูล AIC lab โดยใช้กล้องทั้งหมดจำนวน 8 กล้องเพื่อให้ครอบคลุมมุมมอง 360 องศารอบตัวบุคคล โดยให้อาสาสมัครแต่ละคนทำท่าทาง 10 ประเภท รวมถึงการจำลองการทักท้วงโดยแต่ละบุคคล ตารางที่ 23 แสดงให้เห็นถึงจำนวนรูปภาพที่มีในแต่ละท่าทาง รวมทั้งสิ้น 82,754 รูป

ตารางที่ 23 จำนวนรูปภาพที่มีในแต่ละท่าทางของชุดข้อมูล AIC-360

นั่ง	9,669
ยืน	12,779
เดิน	2,604
เอนตัว	2,186
ก้ม	968
ปรบมือ	6,539
คานาฬิกา	7,168
ชี้	20,311
คุยโทรศัพท์	6,358
โบกมือ	14,172
รวมทั้งหมด	82,754

ตารางที่ 24 แสดงให้เห็นจำนวนภาพที่ถูกใช้ในการเทรนโมเดลแต่ละโมเดล โดยชุดข้อมูล validation เป็น 10% และชุดข้อมูลสำหรับทดสอบ (testing set) เป็น 20% ความแม่นยำโดยรวมในการเทรนโมเดลทั้งหมดอยู่ที่ 96%

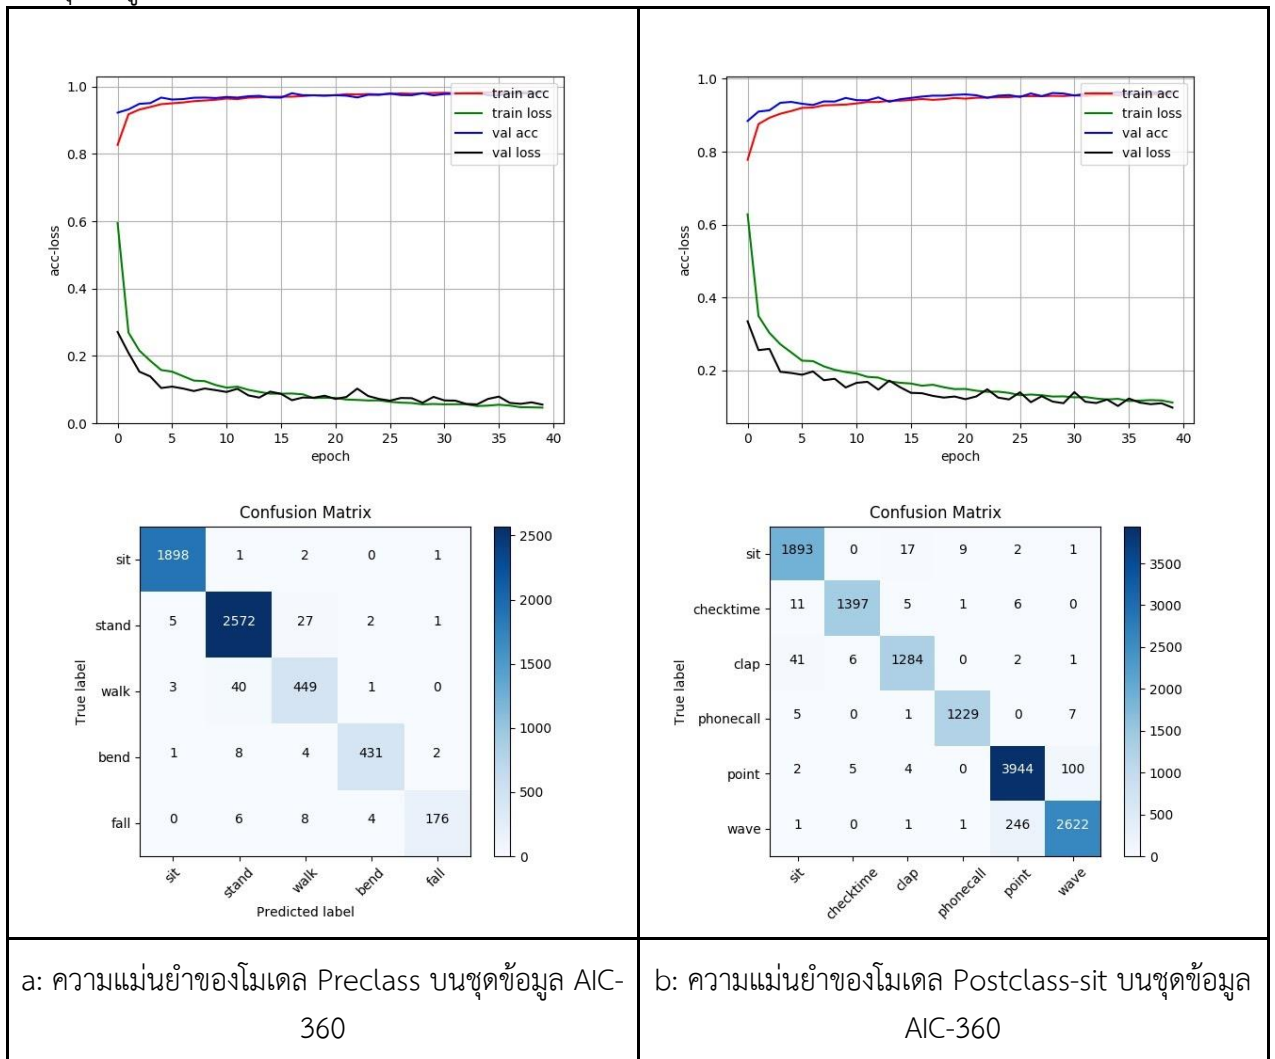
ตารางที่ 24 จำนวนภาพที่ถูกใช้ในการเทรน และความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-360

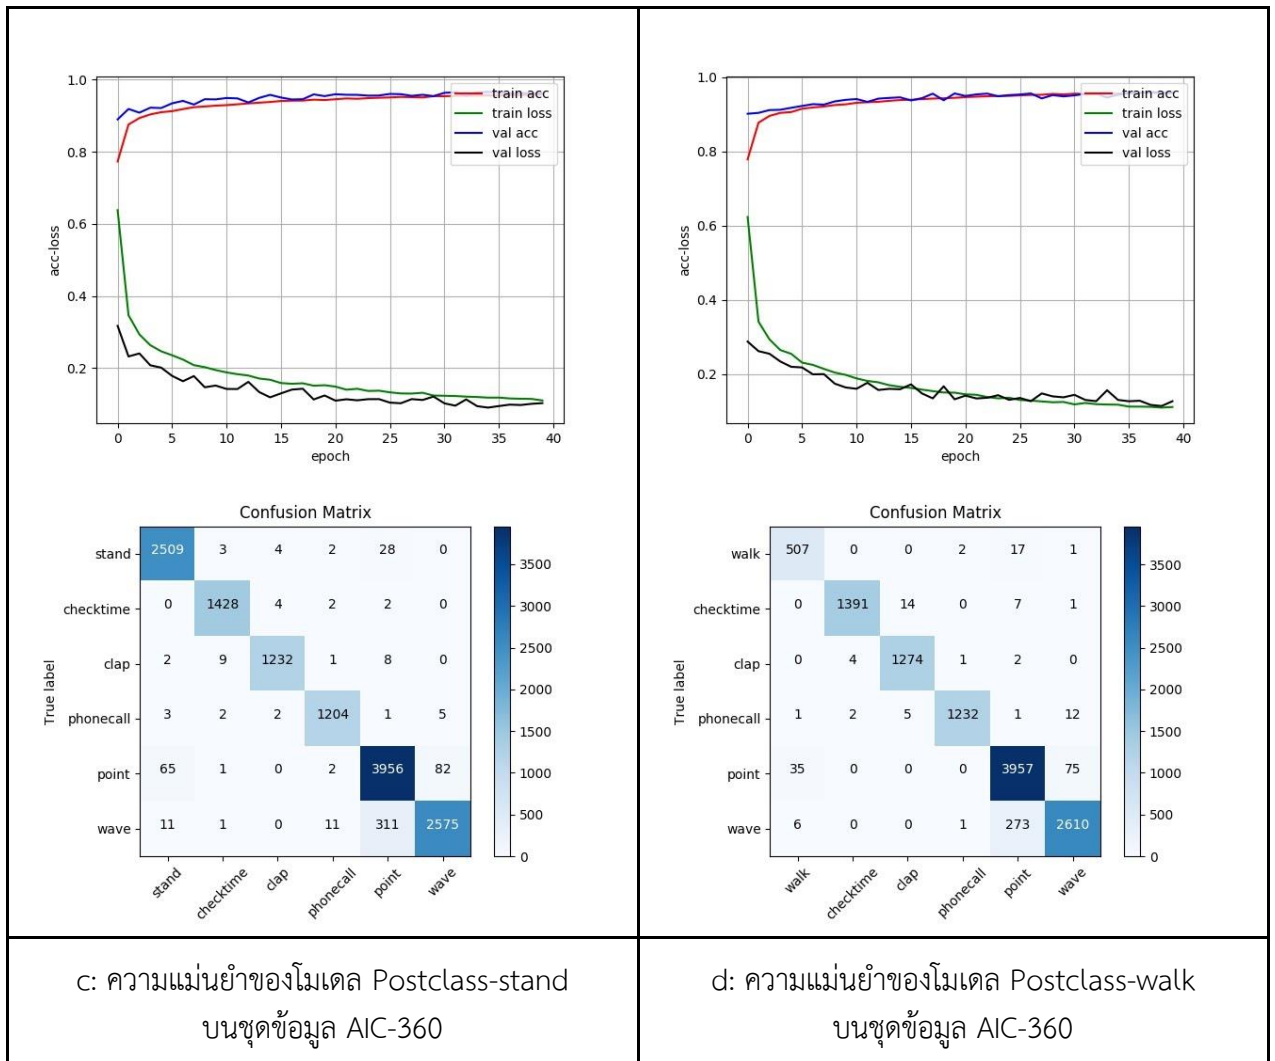
Model	Train dataset	Validation dataset	Test dataset	Test Accuracy	Precision	Recall	F1
Preclass	20,307	2,257	5,642	0.98	0.97	0.95	0.96
Postclass-sit	46,235	5,138	12,844	0.96	0.97	0.97	0.97
Postclass-stand	48,474	5,387	13,466	0.96	0.97	0.97	0.97

Postclass-							
walk	41,148	4,573	11,431	0.96	0.97	0.97	0.97

ค่าความแม่นยำและ confusion matrix ของทั้งสี่โมเดลแสดงในตารางที่ 25

ตารางที่ 25 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-360





ทีมวิจัยทดสอบโมเดลที่เทรนบนชุดข้อมูล AIC-360 และทดสอบบนชุดข้อมูล AIC-Volunteer1-Set1 ที่เก็บจากสถานที่ติดตั้งใช้งานจริง ซึ่งเป็นชุดข้อมูลที่ไม่เคยเห็นมาก่อน และมูมกล้องแตกต่างกันกับกล้องที่ติดตั้งเพื่อเก็บข้อมูลในชุดข้อมูล AIC-360 ตารางด้านล่างแสดงจำนวนตัวอย่างภาพที่ใช้ในการทดสอบประเมินความแม่นยำของโมเดลในการใช้งานจริง โดยให้ความแม่นยำโดยรวมอยู่ที่ 43-57% ดังแสดงในตารางที่ 26

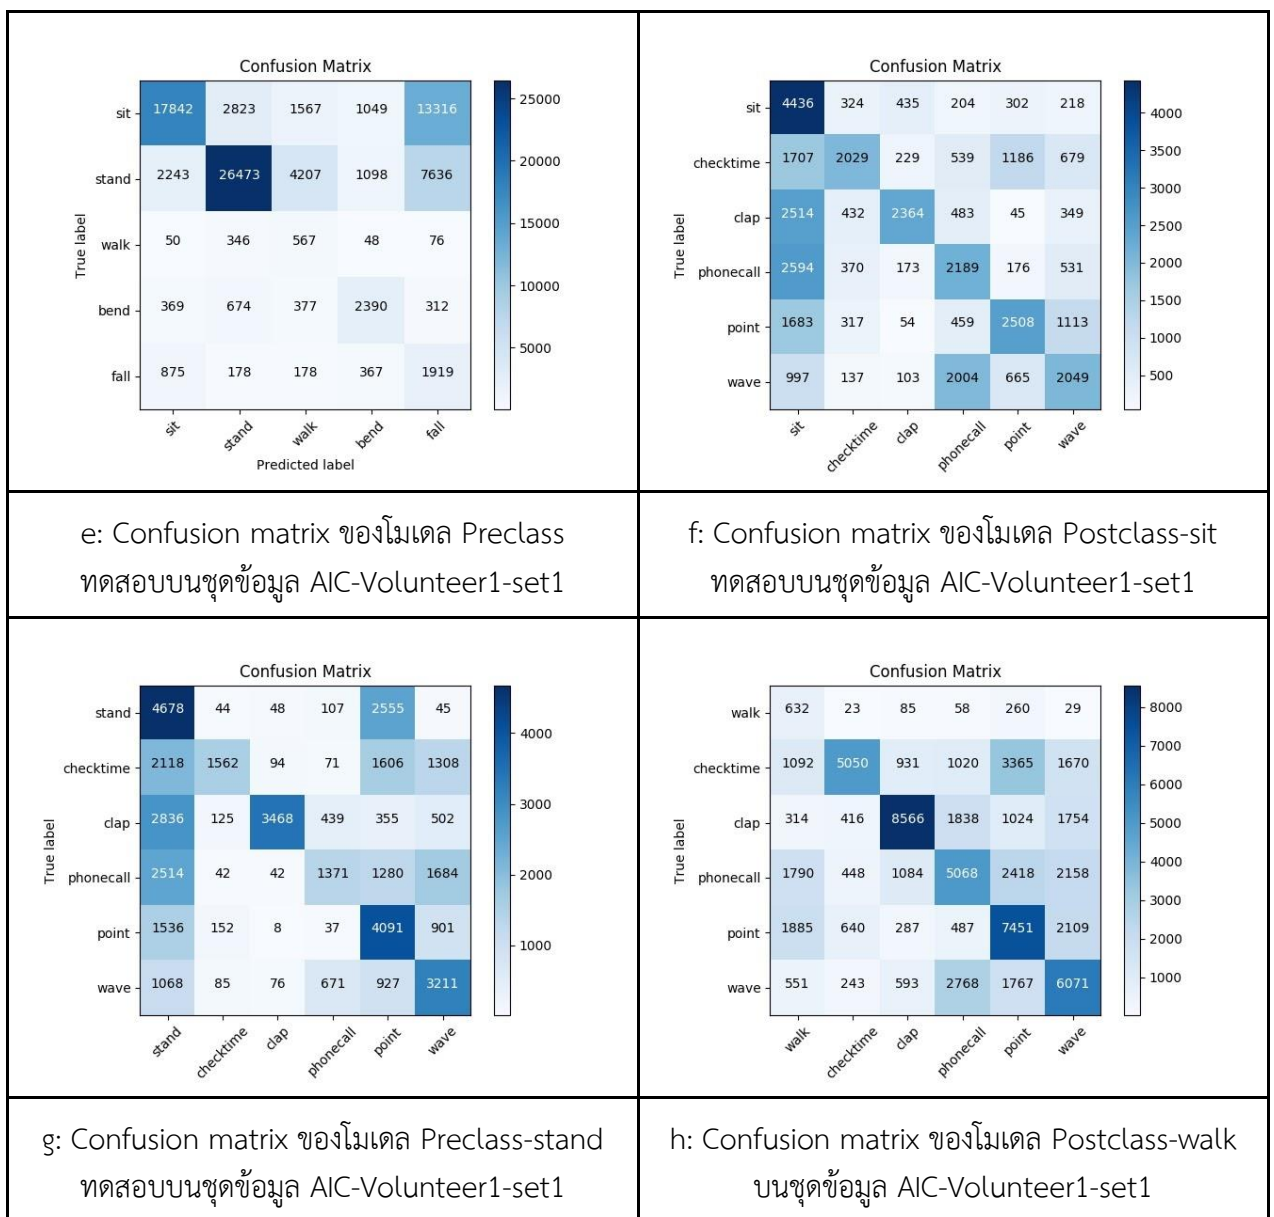
ตารางที่ 26 ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1

Model	Test dataset	Accuracy	Precision	Recall	F1
Preclass	86,980	0.57	0.47	0.55	0.43
Postclass-sit	36,597	0.43	0.48	0.43	0.42

Postclass-stand	41,657	0.44	0.55	0.44	0.43
Postclass-walk	65,945	0.5	0.49	0.51	0.46

ตารางที่ 27 แสดง confusion matrix ของการทดสอบโมเดลที่เทรนบนชุดข้อมูลที่เก็บรวบรวมจากสถานที่ติดตั้งใช้งานจริงโดยที่โมเดลเทรนบนชุดข้อมูล AIC-360 เพียงอย่างเดียว

ตารางที่ 27 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1



4.1.1.4.d โมเดลที่เทรนโดยใช้ชุดข้อมูล AIC-Volunteer1-set1

ทีมวิจัยได้เก็บข้อมูลเพิ่มเติมจากสถานที่ติดตั้งใช้งานจริง และ ทดสอบโมเดลที่เทรนใหม่ซึ่งเทรนโดยใช้ข้อมูลจากชุดข้อมูล AIC-Volunteer1-set1 ที่เก็บจากสถานที่ติดตั้งใช้งานจริง

ตัวอย่างชุดข้อมูลที่ใช้ในการเทรนโมเดล:

รูปด้านล่างแสดงตัวอย่างรูปที่ใช้ในการเทรนโมเดลจากชุดข้อมูล AIC-Volunteer1-set1 ชุดข้อมูลนี้มีกล้อง ทั้งหมด 8 กล้อง ติดในมุมมองที่แตกต่างกันเพื่อให้ครอบคลุมพื้นที่ 360 องศา รอบตัวบุคคล ทีมวิจัยได้เลือก มุมกล้องที่แตกต่างกันโดยเลือกจากมุมกล้องที่ครอบคลุมตำแหน่งที่สมาชิกในครัวเรือนใช้พื้นที่เป็นประจำ ทีมวิจัยได้ทำท่าทางต่าง ๆ 9 ท่าทางยกเว้นการหกล้ม ในแต่ละตำแหน่งพื้นที่โดยทำท่าทางขณะหันหน้าไปยังกล้องแต่ละกล้องทั้งหมด 8 กล้อง สำหรับท่าทางการหกล้มทีมวิจัยเลือกตำแหน่งกล้องหนึ่งตำแหน่งและทำการจำลองการหกล้มในสองทิศทางที่แตกต่างกัน ดังแสดงในตารางที่ 28

ตารางที่ 28 ตัวอย่างท่าทางต่าง ๆ จากมุมกล้องในชุดข้อมูล AIC-Volunteer1-set1



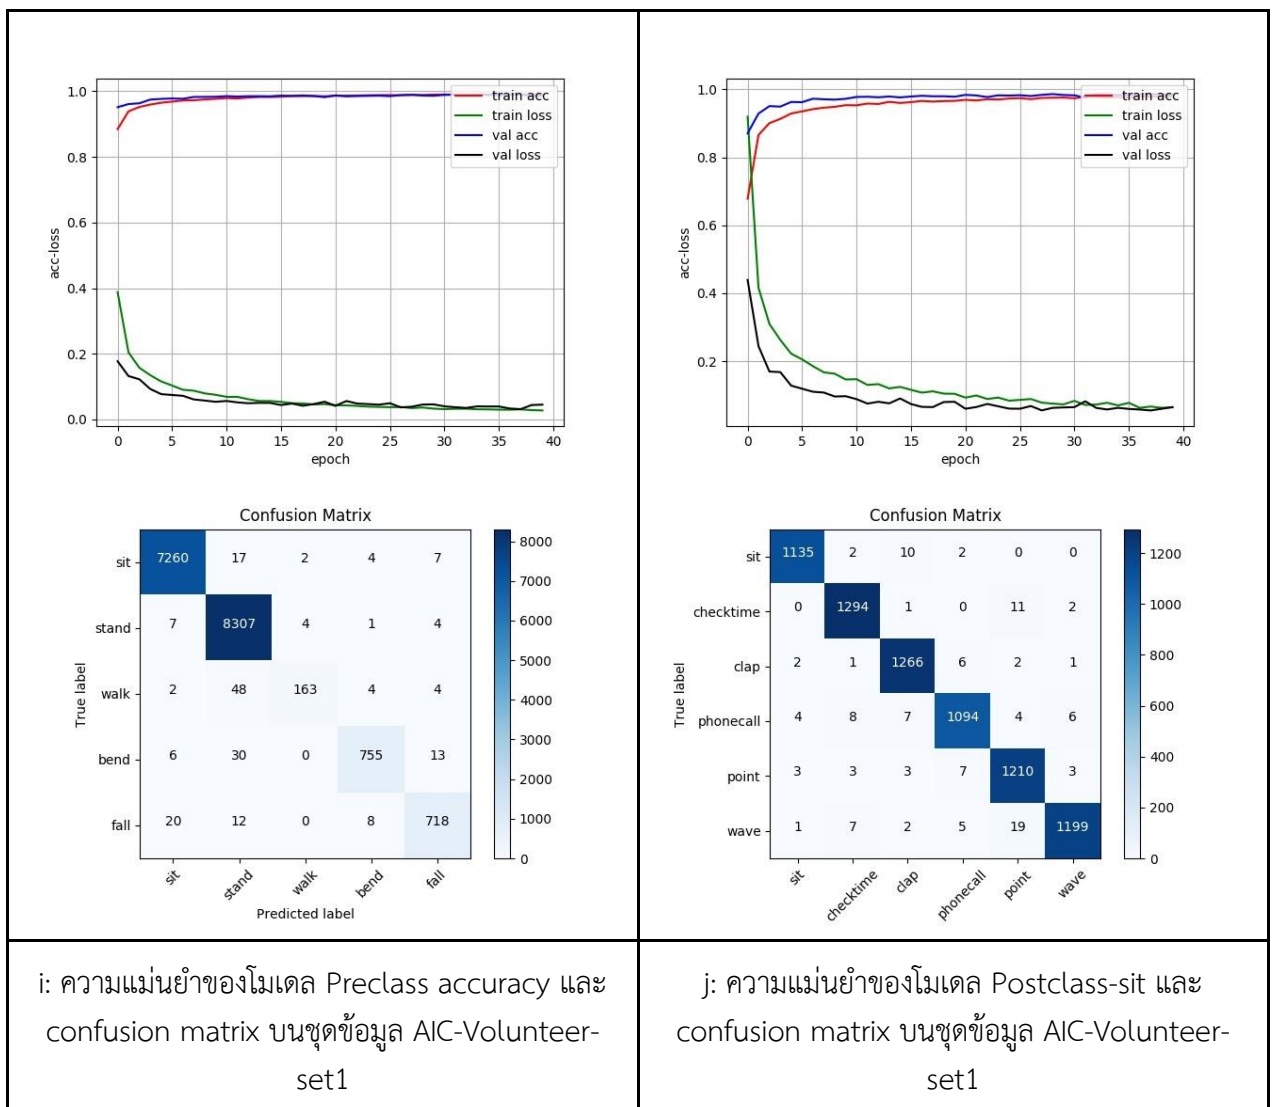
ทีมวิจัยใช้โครงสร้างเน็ตเวิร์กแบบเดิมในการเทรนโมเดลแต่ใช้ชุดข้อมูลจากสถานที่ติดตั้งใช้งานจริงในการเทรนโมเดล ซึ่งสามารถทำให้โมเดลทำงานได้ดีขึ้นกว่าเดิมบนชุดข้อมูลทดสอบ (test dataset) จากสถานที่ติดตั้งใช้งานจริง ที่เป็นสัดส่วน 20% ของชุดข้อมูลที่ใช้ในการเทรน ตารางที่ 29 แสดงความแม่นยำ และ ตารางที่ 30 แสดง confusion matrix ของโมเดลที่เทรนโดยใช้ชุดข้อมูลที่เก็บจากสถานที่ติดตั้งใช้งานจริง

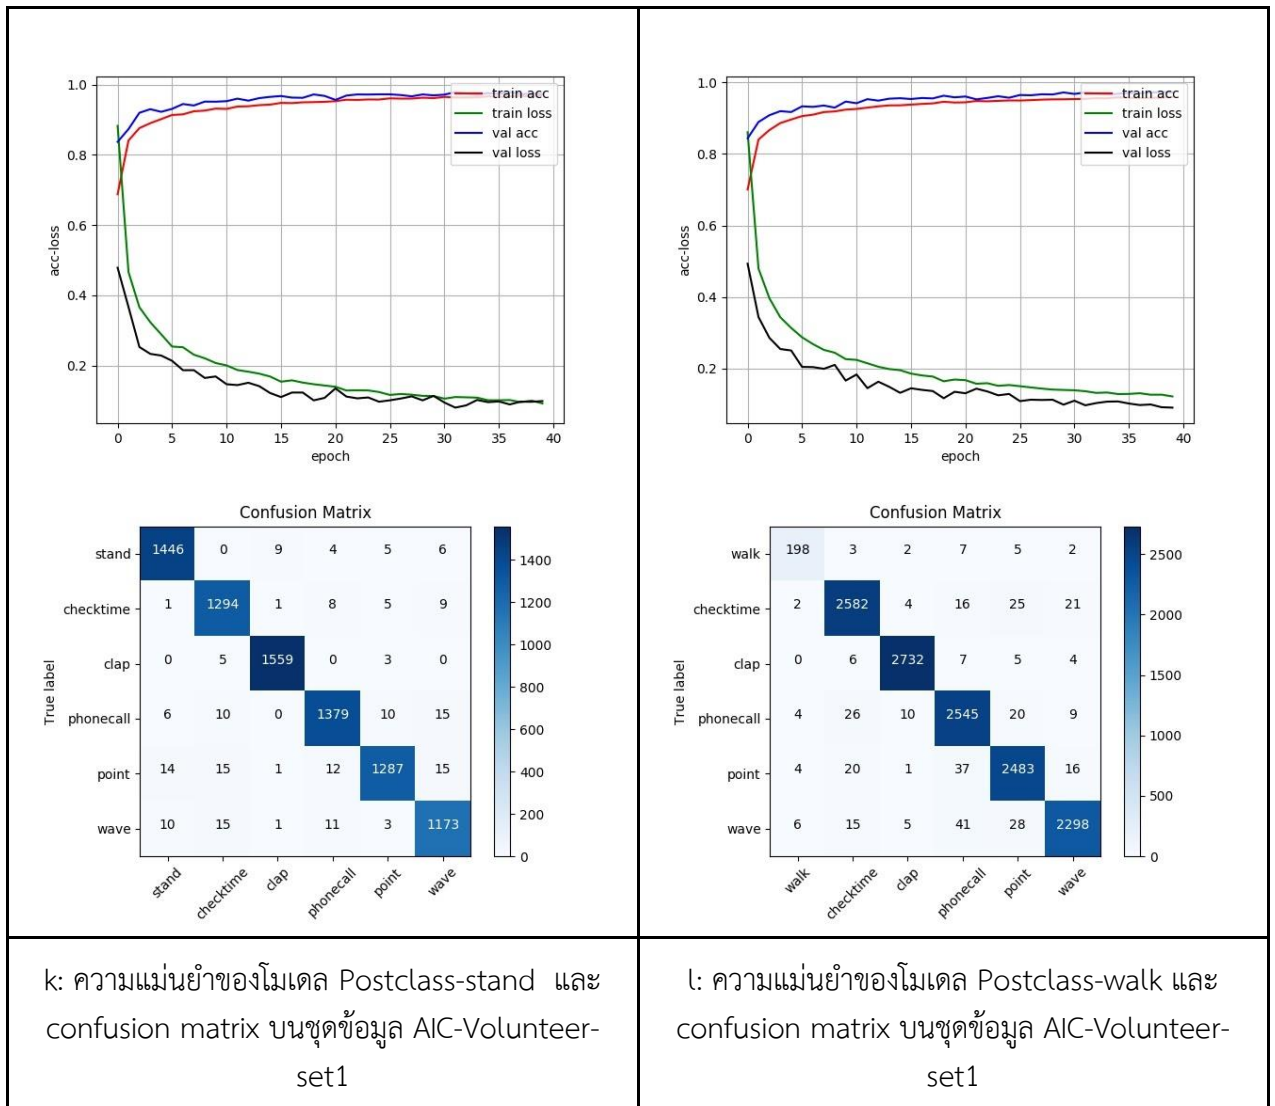
ตารางที่ 29 จำนวนภาพที่ถูกใช้ในการเทรน และความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1

Model	Train dataset	Validation dataset	Test dataset	Test Accuracy	Precision	Recall	F1
Preclass	62,625	6,959	17,396	0.99	0.98	0.92	0.95

Postclass-sit	26,349	2,928	7,320	0.98	0.98	0.98	0.96
Postclass-stand	29,992	3,333	8,332	0.98	0.98	0.98	0.98
Postclass-walk	47,480	5,276	13,189	0.97	0.97	0.96	0.98

ตารางที่ 30 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set1





ทีมวิจัยได้รวบรวมข้อมูลสำหรับใช้ทดสอบจากสถานที่ติดตั้งเดียวกันเพื่อประเมินความแม่นยำของโมเดล โดยชุดข้อมูล AIC-Volunteer1-set2 นี้เป็นชุดข้อมูลทดสอบที่ใช้ในการประเมินผล ซึ่งประกอบด้วยท่าทางต่าง ๆ 10 ท่าทาง ข้อมูลของแต่ละบุคคลถูกแยกตามประเภทท่าทาง 10 ท่าทางเพื่อประเมินความแม่นยำของโมเดล ตารางที่ 31 แสดงจำนวนตัวอย่างรูปภาพของแต่ละกิจกรรม และความแม่นยำของโมเดล

ตารางที่ 31 จำนวนรูปภาพที่มีในแต่ละท่าทางของชุดข้อมูล AIC-Volunteer1-set2

นั่ง	523
ยืน	110
เดิน	746

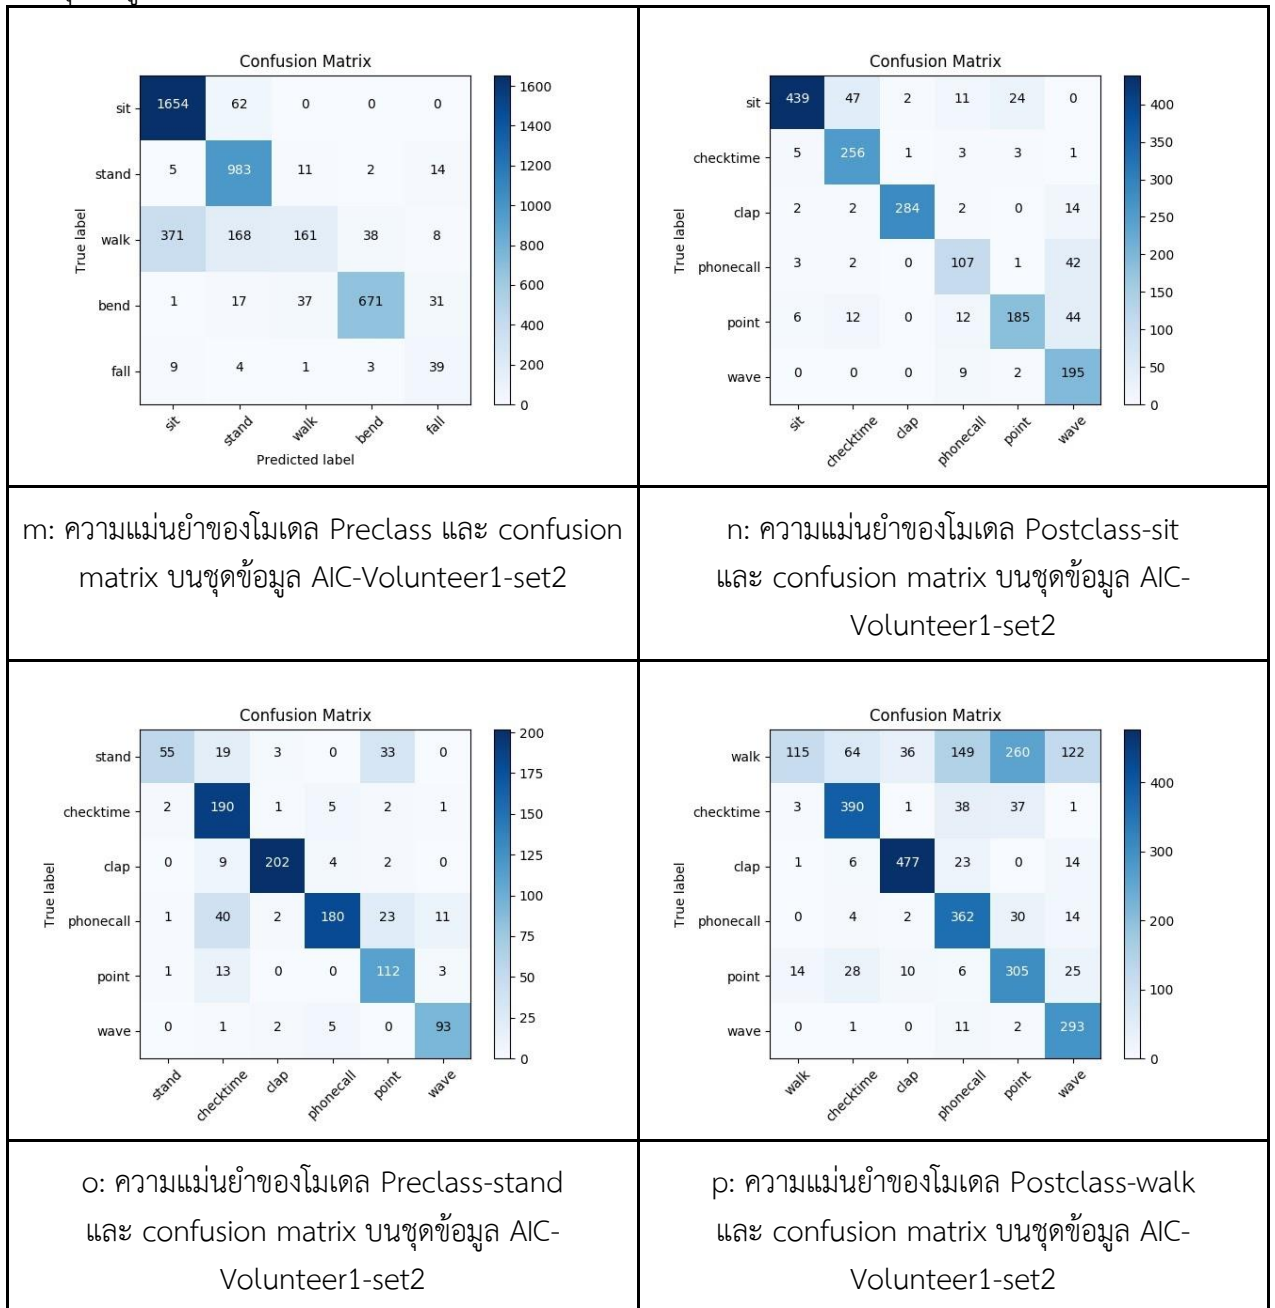
เอนตัว	757
ก้ม	56
ปรบมือ	521
ดูนาฬิกา	470
ชี้	388
คุยโทรศัพท์	412
โบกมือ	307
รวมทั้งหมด	4,290

ตารางที่ 32 และ ตารางที่33 แสดงค่าความแม่นยำ และ confusion matrix ของผลทดสอบบนชุดข้อมูล AIC-Volunteer1-set2 ซึ่งโมเดลถูกเทรนจากชุดข้อมูลที่เก็บมาจากสถานที่เดียวกันกับชุดข้อมูล AIC-Volunteer1-set1 ทีมวิจัยพบว่าโมเดล postclass-walk ให้ความแม่นยำที่ 68% ซึ่งประกอบด้วยรูปภาพที่มีความคล้ายคลึงน้อยกว่ารูปที่ใช้ในการเทรนโมเดล ดังนั้นทีมวิจัยจึงรวมชุดข้อมูลให้มีข้อมูลมากขึ้นเพื่อใช้ในการเทรนโมเดลใหม่เพื่อเปรียบเทียบผลลัพธ์

ตารางที่ 32 ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set2

Model	Test dataset	Accuracy	Precision	Recall	F1
Preclass	4,290	0.82	0.75	0.75	0.71
Postclass-sit	1,716	0.85	0.84	0.85	0.83
Postclass-stand	1,015	0.82	0.84	0.81	0.81
Postclass-walk	2,844	0.68	0.71	0.75	0.68

ตารางที่ 33 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-Volunteer1-set2

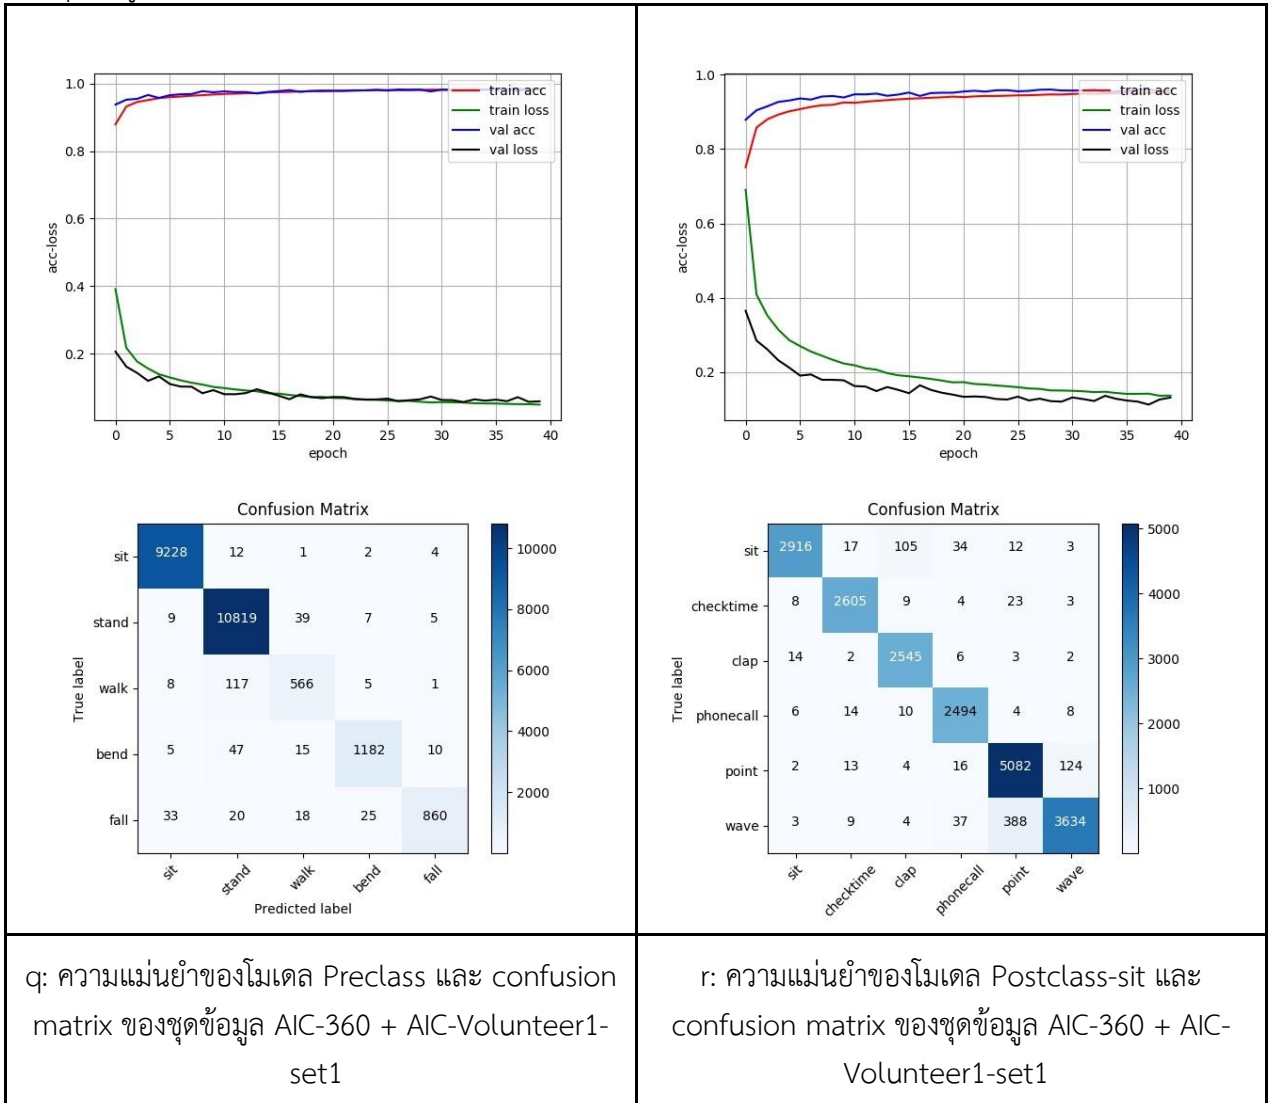




4.1.1.4.e โมเดลที่เทรนโดยใช้ชุดข้อมูลรวม AIC-360 และ AIC-Volunteer1-set1 และ MOVI

ทีมวิจัยได้สร้างชุดข้อมูลสำหรับเทรนใหม่โดยใช้ชุดข้อมูลจาก 2 ชุดข้อมูล AIC-360 และ AIC-Volunteer1-set1 เพื่อเทรนโมเดล และสร้างชุดข้อมูลอีกหนึ่งชุดโดยรวมข้อมูลจาก 3 ชุดข้อมูล AIC-360 และ AIC-Volunteer1-set1 และ MOVI เพื่อเปรียบเทียบผลลัพธ์ระหว่างการเทรนโมเดล



โดยใช้ชุดข้อมูลทั้งสอง ตารางที่ 34 – 37 แสดงจำนวนข้อมูลที่ใช้ในการเทรนโมเดล และผลลัพธ์ความแม่นยำของแต่ละโมเดล

ตารางที่ 34 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC 360 + AIC-Volunteer1-set1



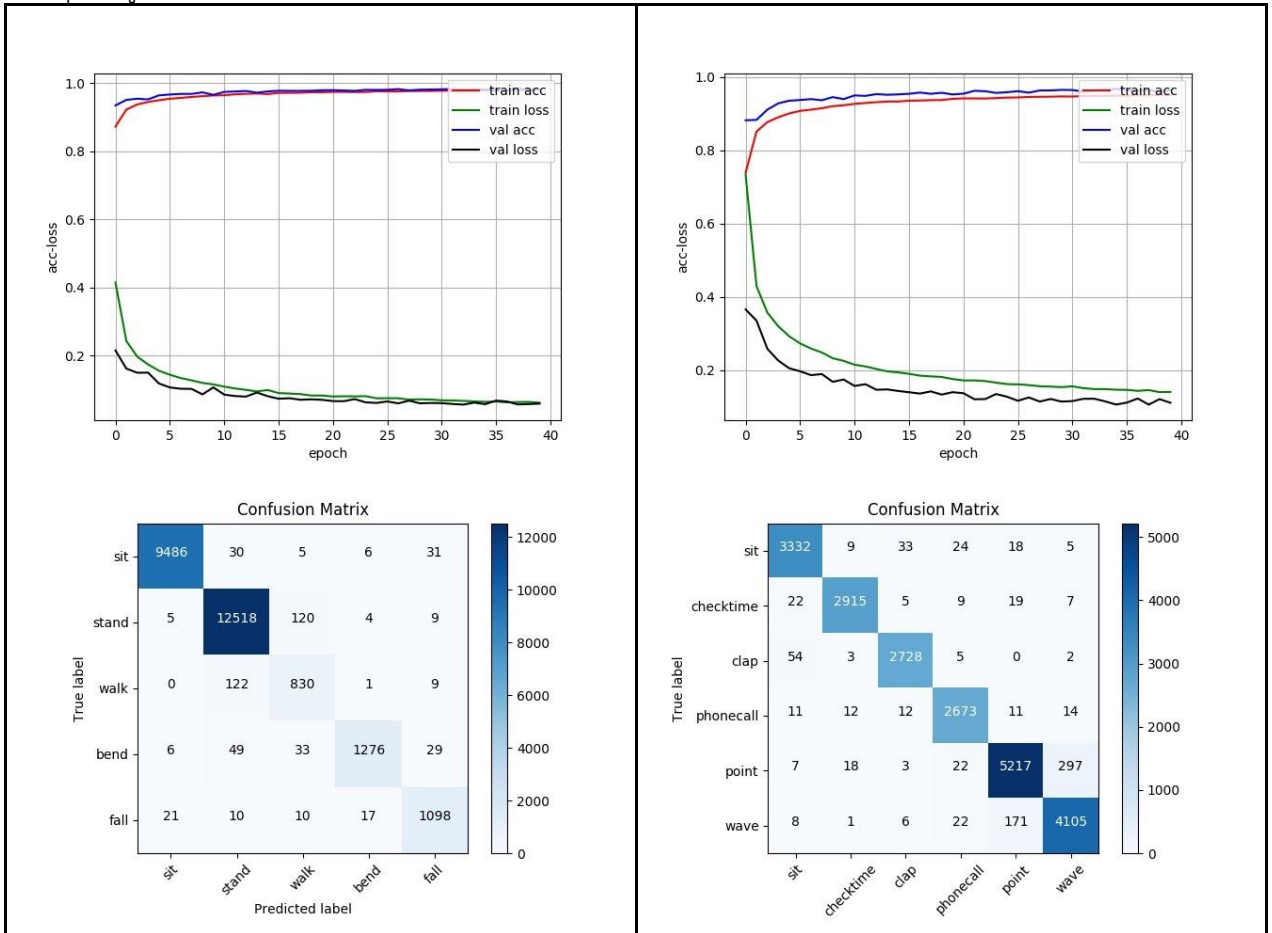


s: ความแม่นยำของโมเดล Postclass-stand และ confusion matrix ของชุดข้อมูล AIC-360 + AIC-Volunteer1-set1




t: ความแม่นยำของโมเดล Postclass-walk และ confusion matrix ของชุดข้อมูล AIC-360 + AIC-Volunteer1-set1


ตารางที่ 35 ค่าความแม่นยำและ confusion matrix ของโมเดล preclass และ postclass บนชุดข้อมูล AIC-360 + AIC-Volunteer1-set1 + MoVi



u: ความแม่นยำของโมเดล Postclass-stand และ confusion matrix ของชุดข้อมูล AIC-360 + AIC-Volunteer1-set1 + MoVi

v: Postclass-stand model accuracy and confusion matrix of AIC-360 + AIC-Volunteer-set1 + MoVi





ตารางที่ 36 ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-360 และ AIC-Volunteer1-set1

Model	Test dataset	Accuracy	Precision	Recall	F1
Preclass	4,290	0.84	0.83	0.8	0.79
Postclass-sit	1,716	0.77	0.77	0.79	0.77
Postclass-stand	1,015	0.83	0.81	0.85	0.82
Postclass-walk	2,844	0.73	0.75	0.78	0.73

ตารางที่ 37 ความแม่นยำของแต่ละโมเดล preclass และ postclass บนชุดข้อมูล AIC-360 และ AIC-Volunteer1-set1 และ MoVi

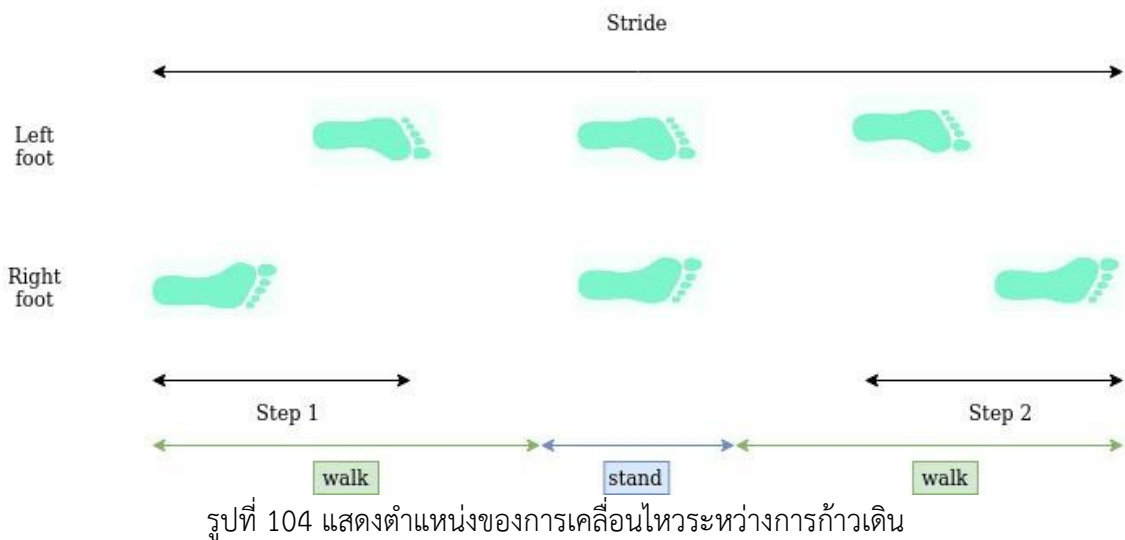
Model	Test dataset	Accuracy	Precision	Recall	F1
Preclass	4,290	0.82	0.8	0.79	0.76
Postclass-sit	1,716	0.7	0.75	0.76	0.72
Postclass-stand	1,015	0.84	0.82	0.85	0.83
Postclass-walk	2,844	0.73	0.74	0.78	0.73

เปรียบเทียบกับผลลัพธ์จากทั้งสองโมเดลที่เทรนโดยชุดข้อมูลที่แตกต่างกัน ทีมวิจัยพบว่าชุดข้อมูลที่รวมชุดข้อมูล AIC-360 และ AIC-Volunteer1-Set1 ให้ค่า precision และ recall สูงกว่าโมเดลที่เทรนโดยชุดข้อมูล AIC-360 และ AIC-Volunteer1-Set1 และ MOVI อย่างไรก็ตามหาก

พิจารณาความแม่นยำแยกในแต่ละโมเดลจะพบว่ามีความแตกต่างกัน เช่น โมเดล Postclass-stand ที่เทรนโดยใช้ชุดข้อมูลรวมระหว่าง AIC-360 และ AIC-Volunteer1-Set1 ให้ความแม่นยำต่ำกว่า โมเดลPostclass-stand ที่เทรนโดยใช้ชุดข้อมูลรวมระหว่าง AIC-360 และ AIC-Volunteer1-Set1 และ MOVI สาเหตุหนึ่งเนื่องจากโมเดลที่ทีมวิจัยเสนอนี้ทำการแยกแยะประเภทท่าทางที่ละเฟรม จึงมี ตัวอย่างข้อมูลที่ใช้ในการเทรน เช่น การเดิน ดังแสดงในรูปที่ 104 แสดงซึ่งขณะก้าวเดินระหว่างก้าว โครงร่างของร่างกายมีลักษณะเหมือนท่าทางการยืนในเฟรมเหล่านั้น รูปที่ 103 แสดงตัวอย่างการแยกแยะท่าทางผิดประเภท ดังนั้นเพื่อเพิ่มความแม่นยำของโมเดลที่ทีมวิจัยจึงใช้การ รวบรวมผลการแยกแยะประเภทท่าทางและสรุปประเภทท่าทางโดยใช้ majority vote ที่ทีมวิจัยได้ ทดสอบโมเดลล่าสุดบนชุดข้อมูลทดสอบ AIC-Volunteer1-Set2 เพื่อประเมินความแม่นยำของ โมเดล



รูปที่ 103 ตัวอย่างการแยกแยะท่าทางผิดประเภท



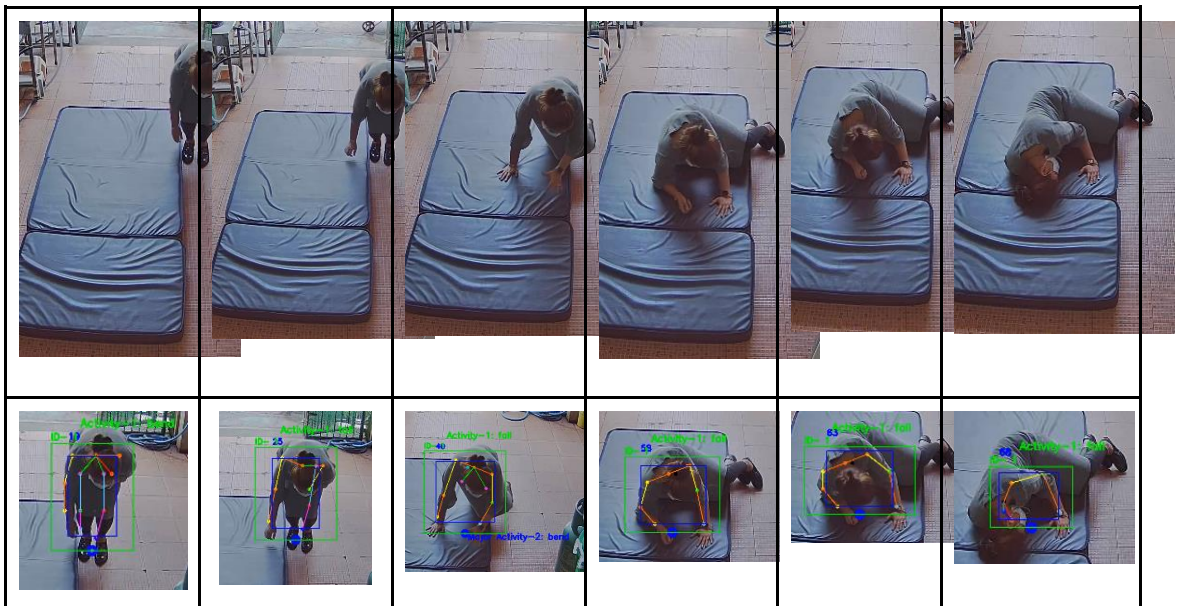
จำนวนชุดข้อมูล AIC-Volunteer1-set2 ที่ใช้ในการประเมินความแม่นยำของระบบ
แยกตามท่าทางมีรายละเอียดแสดงในตารางที่ 38

ตารางที่ 38 จำนวนวิดีโอของแต่ละท่าทางในชุดข้อมูล AIC-Volunteer1-set2

นั่ง	10
ยืน	4
เดิน	14
เอนตัว	16
ก้ม	19
ปรบมือ	16
ดูนาฬิกา	15
ชี้	15
คุยโทรศัพท์	12
โบกมือ	11
รวมทั้งหมด	132

ตารางที่ 39 แสดง confusion matrix บนผลจากการทดสอบบน 132 วิดีโอ
บนชุดข้อมูลทดสอบ AIC-Volunteer1-set2 โดยใช้โมเดลที่เทรนโดยชุดข้อมูล AIC-360 และ AIC-
Volunteer1-Set1 ความแม่นยำของโมเดล Postclass ให้ความแม่นยำสูงเมื่อวิดีโอมีท่าทางการ
ปรบมือ ดูนาฬิกา ชี้ โดยให้ความแม่นยำในการแยกแยะประเภทท่าทางที่ 100% สำหรับท่าทางการ
ยืน ล้ม และท่าทางประเภทอื่น ๆ ความแม่นยำของโมเดลมากกว่า 80% สำหรับวิดีโอที่มีท่าทางการ

ทกล้ม ท่าทางขณะล้มมีลักษณะคล้ายการเอนตัว ก้มตัว ก่อนล้มลง รูปที่ 105 แสดงลำดับเฟรมที่ต่อเนื่องกันจากวิดีโอที่มีท่าทางการทกล้มซึ่งมีท่าทางการเอนตัว/ก้มตัวปรากฏอยู่ก่อนจะล้ม โครงร่างของร่างกายของท่าทางการทกล้มมีความคล้ายคลึงกับการเอนตัว ก้มตัว ส่งผลให้ผลลัพธ์จากวิดีโอที่มีการทกล้ม 19 วิดีโอ มีการแยกแยะประเภทท่าทางเป็นการเอนตัว ก้มตัว 3 วิดีโอ ทำให้ค่าความแม่นยำของโมเดล Preclass ในการตรวจจับการทกล้มอยู่ที่ 79% และค่าเฉลี่ยความแม่นยำในการทดสอบทั้งหมดอยู่ที่ 90.53% โดยใช้โมเดลที่เทรนจากชุดข้อมูล AIC Lab และ AIC-Volunteer1-Set1



รูปที่ 105 แสดงตัวอย่างท่าทางการทกล้มที่มีท่าทางการเอนตัว/ก้มตัวก่อนจะล้ม

ตารางที่ 39 ความแม่นยำของโมเดลที่เทรนโดยใช้ชุดข้อมูลรวม 2 ชุดข้อมูล โดยทดสอบบนชุดข้อมูล AIC-Volunteer1-set2

AIC-Volunteer-set2 test												Total	Accuracy
Actual	sit	9	0	0	0	0	0	0	1	0	0	10	90
	stand	0	3	0	0	0	1	0	0	0	0	4	75
	walk	0	1	12	0	0	0	0	1	0	0	14	87
	bend	0	0	0	16	0	0	0	0	0	0	16	100
	fall	0	0	0	3	15	0	0	1	0	0	19	79
	clap	0	0	0	0	0	16	0	0	0	0	16	100
	checktime	0	0	0	0	0	0	15	0	0	0	15	100
	point	0	0	0	0	0	0	0	15	0	0	15	100
	phonecall	0	1	0	0	0	0	0	0	10	1	12	83.33
	wave	0	0	0	0	0	0	0	1	0	10	11	91
		sit	stand	walk	bend	fall	clap	checktime	point	phonecall	wave	132	90.533
	Prediction												

ในส่วนของชุดข้อมูล AIC-360 และ AIC-Volunteer1-Set1 และ MoVi สามารถทำงานได้ดีกว่าโมเดลก่อนหน้านี้เนื่องจากโมเดลนี้เทรนบนชุดข้อมูลที่มีจำนวนข้อมูลมากกว่าและมีชุดข้อมูลท่าทางการเอนตัว/ก้มตัว และล้มที่หลากหลาย จากวิดีโอทั้งหมด 19 วิดีโอ 18 วิดีโอสามารถแยกแยะได้อย่างถูกต้อง วิดีโอที่มีการแยกแยะประเภทผิดเป็นการเอนตัว/ก้มตัว ซึ่งให้ความแม่นยำ 95% ในการแยกแยะท่าทางการล้ม ความแม่นยำโดยรวมบนชุดข้อมูลทดสอบเพิ่มขึ้นเป็น 91.56% จาก 90.53% ความแม่นยำในการแยกแยะประเภทท่าทางทั้งหมดมีความแม่นยำมากกว่า 83% แสดงในตารางที่ 39 ผลลัพธ์การแยกแยะประเภทท่าทางโดยใช้โมเดลที่เทรนโดยชุดข้อมูลรวม 3 ชุดข้อมูล (AIC-360, AIC-Volunteer1-set1 และ MoVi) ในตำแหน่งต่าง ๆ ของมุกกล้องแสดงในตารางที่ 41

โดยที่ตารางที่ 40 แสดง confusion matrix จากวิดีโอทั้งหมดจำนวน 132 วิดีโอ จากโมเดลที่เทรนโดยชุดข้อมูล AIC และ ชุดข้อมูล AIC-Volunteer1-Set1 และชุดข้อมูล MoVi ทีมวิจัยใช้ข้อมูลประเภทท่าทาง 5 ประเภท ได้แก่ ปรบมือ ดุนาฬิกาข้อมือ ชี้นิ้ว โทรศัพท์ และโบกมือ ซึ่งอ้างอิงจากจุดโครงร่างของร่างกายในลำตัวส่วนบน และแบ่งประเภทท่าทางหลักเป็น นั่ง ยืน และ เดิน เนื่องจากในการใช้งานจริงมีประเภทท่าทางในชีวิตประจำวันมีความหลากหลาย ประเภทท่าทางที่โมเดลไม่เคยเห็นบางประเภทอาจถูกแยกแยะผิดดังแสดงใน confusion matrix เช่น ทำนั่งถูกแยกแยะเป็นทำชี้และโทรศัพท์ ทำเดินถูกแยกแยะเป็นทำปรบมือ ทำปรบมือถูกแยกแยะเป็นทำนั่ง

ท่าคานาฬิกาข้อมือถูกแยกแยะเป็นท่าชี้ ท่าชี้ถูกแยกแยะเป็นท่าทางคุยโทรศัพท์และโบกมือ นอกจากนี้ท่าทางการยืนมีความคล้ายคลึงกับท่าทางในระหว่างการก้าวเดินจึงทำให้มีการแยกแยะท่าทางการเดินผิดเป็นท่าทางการยืน เช่นเดียวกับท่าทางการก้มตัวซึ่งมีท่าทางคล้ายท่าทางขณะล้ม ดังนั้นท่าทางการล้มในบางครั้งจึงถูกแยกแยะเป็นท่าทางการก้มตัว อย่างไรก็ตามถึงแม้จะมีการแยกแยะท่าทางผิดโมเดลที่ทีมวิจัยเทรนยังให้ความแม่นยำที่ 91.6% จากการแยกแยะประเภทท่าทางทั้งหมด 10 ประเภท และความแม่นยำที่ 95% สำหรับความแม่นยำในการตรวจจับการทกล้ม

ตารางที่ 40 ความแม่นยำของโมเดลที่เทรนโดยใช้ชุดข้อมูลรวม 3 ชุดข้อมูล โดยทดสอบบนชุดข้อมูล AIC-Volunteer1-set2

AIC-Volunteer-set2 test												Total	Accuracy
Actual	sit	8	0	0	0	0	0	0	1	1	0	10	80
	stand	0	4	0	0	0	0	0	0	0	0	4	100
	walk	0	1	12	0	0	1	0	0	0	0	14	86
	bend	0	0	0	16	0	0	0	0	0	0	16	100
	fall	0	0	0	1	18	0	0	0	0	0	19	95
	clap	1	0	0	0	0	15	0	0	0	0	16	94
	checktime	0	0	0	0	0	0	14	1	0	0	15	93.33
	point	0	0	0	0	0	0	0	14	0	1	15	93.33
	phonecall	0	0	0	0	0	0	0	0	10	2	12	83.33
	wave	0	0	0	0	0	0	1	0	0	10	11	91
		sit	stand	walk	bend	fall	clap	checktime	point	phonecall	wave	132	91.599
	Prediction												

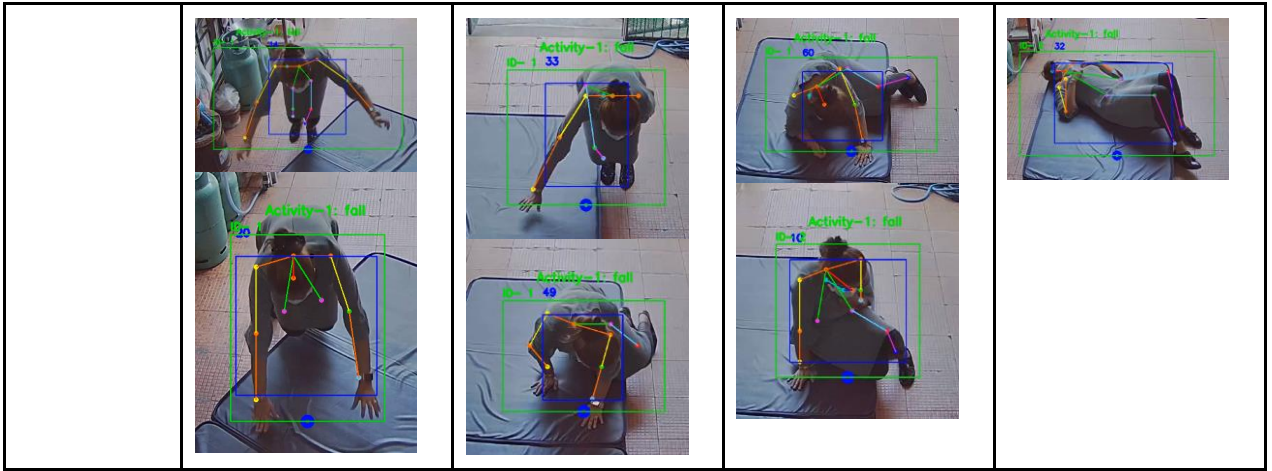
ตารางที่ 41 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางโดยใช้โมเดลที่เทรนโดยชุดข้อมูลรวม 3 ชุดข้อมูล (AIC-360, AIC-Volunteer1-set1 และ MoVi) ในตำแหน่งต่าง ๆ ของมุมกล้อง

	กลางมุมกล้อง-1	มุมด้านขวา	มุมด้านซ้าย	กลางมุมกล้อง-2
นั่ง	-			-
ยืน				-
เดิน	-			-
เอนตัว/ก้มตัว				-

<p>ปรบมือ</p>				<p>-</p>
<p>ดูนาฬิกา</p>				<p>-</p>

<p>คุยโทรศัพท์</p>				<p>-</p>
<p>ชี้</p>				<p>-</p>

<p>โหมมือ</p>				
<p>ล้ม</p>				



4.1.2 การตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

การตรวจจับการเคลื่อนไหวที่ไม่มั่นคงที่มิวิจัยได้ออกแบบและพัฒนาอัลกอริทึมที่ใช้ในการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงโดยใช้ LSTM RNN โดยทดลองเทรนโมเดลกับชุดข้อมูลหลากหลายประเภท

4.1.2.1 การเทรนโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดล


ที่มิวิจัยใช้ชุดข้อมูลที่เก็บข้อมูลจากมหาวิทยาลัยมหิดลเพื่อใช้ในการเทรนโมเดลสำหรับการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง โดยมีรายละเอียดแสดงในตารางที่ 42

ตารางที่ 42 รายละเอียดกลุ่มของชุดข้อมูลมหาวิทยาลัยมหิดลที่ใช้ในการเทรนโมเดล


	กลุ่มที่มีการเคลื่อนไหวที่มั่นคง (Non-Fall)	กลุ่มที่มีการเคลื่อนไหวที่ไม่มั่นคง (Fall)
Training	Subject_1	Subject_2
	Subject_10	Subject_7
	Subject_13	Subject_11
	Subject_15	Subject_14
	Subject_16	Subject_19
		Subject_4
Validation	Subject_20	Subject_18
Test	Subject_3	Subject_5

ที่มิวิจัยเทรน RNN โดยใช้ข้อมูลลำดับโครงร่างของร่างกายจำนวน 363,437 ชุด แต่ละชุดประกอบด้วยข้อมูลลำดับการเคลื่อนไหวของโครงร่างของร่างกายจำนวน 40 เฟรม แต่ละเฟรมประกอบด้วย 36 จุดบนโครงร่างของร่างกาย และใช้ชุดข้อมูล validation จำนวน 135,146 ชุด และทดสอบบนข้อมูลทดสอบจำนวน 124,114 ชุด

ที่มิวิจัยพบว่าโมเดลที่เทรนได้ยังไม่สามารถทำงานให้ได้ความแม่นยำที่น่าพึงพอใจ รูปที่ 106 แสดงความแม่นยำขณะเทรนโมเดล โดยที่มิวิจัยพบว่าโมเดลเกิดการ overfit ตาราง confusion matrix ของการทดสอบโมเดลบนชุดข้อมูลทดสอบแสดงในรูปที่ 107 โดยมีความแม่นยำอยู่ที่ 54.18% และค่า F1-score อยู่ที่ 53.64%




รูปที่ 106 ความแม่นยำขณะเทรนโมเดลบนชุดข้อมูล validation



รูปที่ 107 Confusion matrix ของโมเดลบนชุดข้อมูลทดสอบ

ทีมวิจัยได้ปรับปรุงโมเดลดังกล่าวโดยใช้เทคนิคต่าง ๆ เช่น การเพิ่มจำนวนข้อมูลสำหรับการเทรน การเพิ่มความหลากหลายของข้อมูลที่ใช้เทรน และ regularization พารามิเตอร์ต่าง ๆ เป็นต้น อย่างไรก็ตามทีมวิจัยได้ทดลองกับวิธีจำลองการเคลื่อนไหวที่ไม่มั่นคงโดยได้ผลลัพธ์แสดงในรูปที่ 108 และผลลัพธ์การตรวจจับการเคลื่อนไหวที่มั่นคงดังแสดงในรูปที่ 109 ถึงแม้โมเดลจะสามารถแยกแยะการเคลื่อนไหวแบบไม่มั่นคงได้ แต่ยังมี การตรวจจับผิดพลาดอยู่ ทีมวิจัยทดสอบจำลองการเดินแบบไม่มั่นคงในหลากหลายรูปแบบมากขึ้น และในมุมมองที่หลากหลายเพื่อนำมาใช้ในการเทรนโมเดล



รูปที่ 108 ผลลัพธ์การตรวจจับการเคลื่อนไหวที่ไม่มั่นคง



รูปที่ 109 ผลลัพธ์การแยกแยะตัวอย่างการเคลื่อนไหวที่มั่นคง

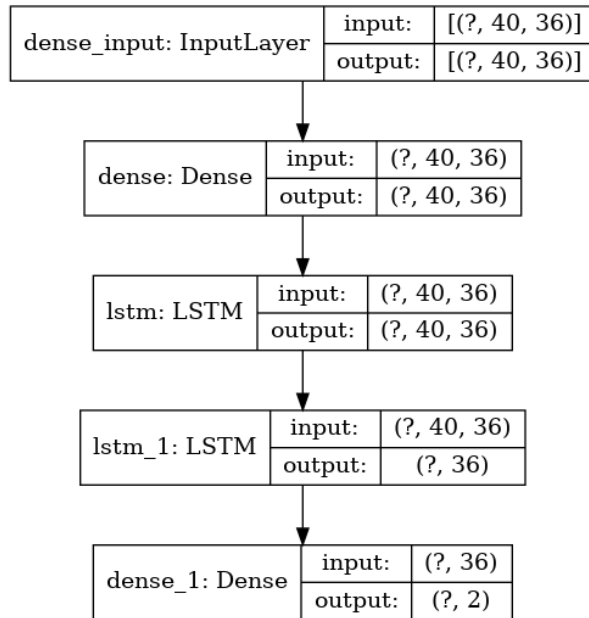
4.1.2.2 อัลกอริทึมสำหรับตรวจจับการเคลื่อนไหวที่ไม่มั่นคงในการใช้งานจริง

ในการใช้งานจริงที่มิวิจัยได้ใช้อัลกอริทึม LSTM RNN ดังได้อธิบายไว้ก่อนหน้านี้ สำหรับการใช้งานจริง โดยมีรายละเอียดโครงสร้างโมเดล และ การใช้ชุดข้อมูลสำหรับเทรนโมเดล อธิบายดังต่อไปนี้

4.1.2.2.a โครงสร้างโมเดล

รูปที่ 110 แสดงให้เห็นถึงสถาปัตยกรรมของโมเดล RNN ที่ใช้ในการแยกแยะการเคลื่อนไหวที่ไม่มั่นคง ที่มิวิจัยใช้ LSTM cells ในการเก็บข้อมูลระหว่างเฟรมที่ต่อเนื่องกัน ข้อมูลนำเข้าของ

โมเดลคือชุดข้อมูล จุดโครงร่างของร่างกาย 36 จุด โดยชุดข้อมูลนำเข้าจะเป็นข้อมูลของจุดโครงร่างของร่างกายที่ตรวจพบในลำดับเฟรมที่ต่อเนื่องกันเป็นจำนวน 40 เฟรม



รูปที่ 110 โครงสร้างของโมเดล

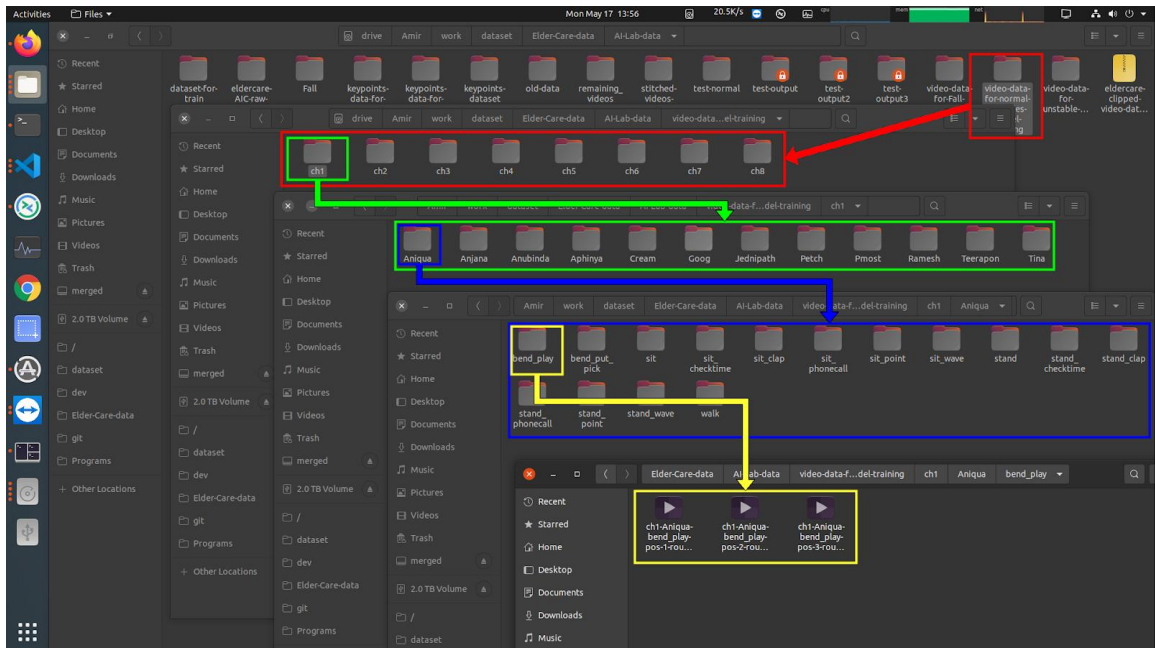
4.1.2.2.b การเทรนโมเดล

โมเดลที่ทีมวิจัยใช้ประกอบด้วยอินพุตเลเยอร์ขนาด 40x36 ที่ตามด้วย dense layer ที่ใช้ ReLU เป็น activation function เลเยอร์ถัดไปใช้ LSTM เลเยอร์ที่มี 36 hidden units และมีเลเยอร์ output ที่มี 2 คลาสและใช้ softmax function เป็น activation function เพื่อพัฒนาให้โมเดลสามารถทำงานได้ดี (generalization) ทีมวิจัยใช้ kernel และ bias L2 regularization ในส่วนของเลเยอร์สุดท้าย และใช้ categorical crossentropy loss ในการเทรนโมเดล และใช้ batch size ที่ 1,024 และ learning rate ที่ 0.005

ทีมวิจัยจัดเตรียมชุดข้อมูลโดยการตัดคลิปวิดีโอที่เก็บรวบรวมเพื่อสร้างเป็นคลิปที่สั้นลงโดยแยกตามแต่ละประเภทท่าทางของแต่ละบุคคล รูปที่ 111 แสดงให้เห็นโครงสร้างของไฟล์คลิปวิดีโอของแต่ละท่าทาง จากชุดข้อมูลวิดีโอเหล่านี้ทีมวิจัยสกัดข้อมูลโครงร่างของร่างกายของแต่ละบุคคลในแต่ละวิดีโอเพื่อทำการจัดเตรียมชุดข้อมูลสำหรับการเทรนและประเมินโมเดล

สำหรับชุดข้อมูล AIC-360 ประกอบด้วยข้อมูลของอาสาสมัคร 12 คนทำการจำลองการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบต่าง ๆ 5 รูปแบบ ส่วนชุดข้อมูล AIC-Volunteer1-set1 เป็นการเก็บข้อมูลเพิ่มเติมประกอบด้วยข้อมูลของอาสาสมัคร 3 คน ณ บ้านอาสาสมัคร จ.กรุงเทพมหานคร ชุดข้อมูลทั้งสองถูกนำไฟล์วิดีโอมาแบ่งออกเป็น 2 ประเภท คือ การเคลื่อนไหวแบบไม่มั่นคง และการเคลื่อนไหวแบบมั่นคง (การเคลื่อนไหวในอวกาศปิดกั้นทุกทิศทาง) ข้อมูลวิดีโอทั้งหมดจะถูกนำมาตั้ง


ข้อมูลโครงร่างของร่างกาย ข้อมูลโครงร่างของร่างกายจะถูกบันทึกลงไฟล์ CSV เพื่อใช้ในการเทรน ทดสอบ และตรวจสอบความถูกต้องของโมเดล




รูปที่ 111 โครงสร้างโฟลเดอร์ของวิดีโอที่ใช้ในการเทรนของแต่ละบุคคล

4.1.2.2.c โมเดลที่เทรนโดยใช้ชุดข้อมูล AIC-360

ทีมวิจัยเทรนโมเดลโดยใช้ข้อมูล 70% จากข้อมูลที่เก็บจาก AI Center Lab (ชุดข้อมูล AIC-360) และใช้ 10% สำหรับเป็นข้อมูล validation และ 20% สำหรับเป็นข้อมูลทดสอบ ข้อมูลจากกล้องทั้ง 8 กล้องถูกแบ่งเป็นชุดข้อมูลสำหรับเทรน validation และ ทดสอบ จำนวนข้อมูลของแต่ละกลุ่มแสดงในรูปที่ 112(a) และจำนวนชุดเฟรมที่ต่อเนื่องกัน (40 เฟรม ต่อ หนึ่งชุด) แสดงในรูปที่ 112(b)




(a)




(b)

รูปที่ 112 การกระจายตัวของข้อมูลระหว่างจำนวนข้อมูล (a) และชุดเฟรมที่ต่อเนื่องกัน (b) ที่ใช้สำหรับ train, validation และ test ของชุดข้อมูล AIC-360


ทีมวิจัยเทรนโมเดล (โมเดล AIC) บนชุดข้อมูล AIC-360 โดยเทรนเป็นจำนวน 165 epochs จนกระทั่งค่า loss ลู่เข้าและมีค่า training loss สุดท้ายที่ 0.0408 ณ การเทรนรอบที่ 165 epochs โมเดลให้ความแม่นยำ (training accuracy) ที่ 98.44% และ validation accuracy ที่ 94.67% และความแม่นยำบนชุดข้อมูลทดสอบอยู่ที่ 95.78% รายละเอียดแสดงในรูปที่ 113 (a) – (d)




(a)



(b)



(c)




(d)

รูปที่ 113 ผลการเทรนและทดสอบโมเดล AIC บนชุดข้อมูล train และ test (a) ความแม่นยำของโมเดลบนชุดข้อมูล train และ validation (b) training และ validation loss ของโมเดล (c) confusion matrix ของโมเดลบนชุดข้อมูล test (d) normalized confusion matrix ของโมเดลบนชุดข้อมูล test

ชุดข้อมูลที่ทีมวิจัยใช้มีจำนวนข้อมูลไม่สมดุลอย่างมาก จำนวนชุดข้อมูลการเดินทางแบบมั่นคงมีจำนวนห้าเท่าของจำนวนชุดข้อมูลการเดินทางที่ไม่มั่นคง ซึ่งสอดคล้องกับสถานการณ์จริงเนื่องจากการเดินทางแบบไม่มั่นคงจะมีจำนวนน้อยมากเมื่อเทียบกับการเดินทางแบบปกติ ดังนั้นทีมวิจัยใช้ค่า recall เป็นเกณฑ์สำคัญในการประเมินโมเดลที่เทรน จากชุดข้อมูลทดสอบโมเดลได้อัตรา recall ที่ 91.82% สำหรับคลาสการเดินทางที่ไม่มั่นคง

ทีมวิจัยทดสอบโมเดลบนชุดข้อมูลจากบ้านอาสาสมัครในกรุงเทพฯ อย่างไรก็ตาม ทีมวิจัยไม่พบการหกล้มและการเคลื่อนไหวที่ไม่มั่นคงในช่วงระหว่างการเก็บข้อมูลทดสอบประเมินระบบ ทีมวิจัยต้องจำลองการเคลื่อนไหวที่ไม่มั่นคงและเก็บข้อมูลจากสถานที่ติดตั้งใช้งานจริงและทดสอบโมเดลบนชุดข้อมูลนี้


ในเบื้องต้นทีมวิจัยทดสอบโมเดล AIC บนชุดข้อมูลสำหรับทดสอบจากบ้านอาสาสมัครในกรุงเทพฯ (AIC-Volunteer1-set1) แต่โมเดลไม่สามารถให้ความแม่นยำได้ตามที่ต้องการ เนื่องจากเหตุผลหลักสองประการ ประการแรกโมเดลถูกเทรนบนชุดข้อมูลที่มีมุกกล้องแตกต่างกันอย่างสิ้นเชิงกับชุดข้อมูลที่ใช้ในการทดสอบ ประการที่สอง มุกกล้องที่ติดตั้งในบ้านอาสาสมัครมีมุกกล้องที่แตกต่างกันจนเกินไป รูปที่ 114 แสดงค่า precision, recall และ F1-score ของโมเดลที่ทดสอบบนชุดข้อมูลจากสถานที่ติดตั้งชุดแรก (AIC-Volunteer1-set1) ค่า recall ที่ได้สำหรับกล้องที่ 3 อยู่ที่ 88.85%



รูปที่ 114 ประสิทธิภาพของโมเดลที่ทดสอบบนชุดข้อมูล AIC-Volunteer1-set1


4.1.2.2.d โมเดลที่เทรนโดยใช้ชุดข้อมูลรวมระหว่างชุดข้อมูล AIC-360 และ AIC-Volunteer1-set1


เพื่อที่จะเพิ่มประสิทธิภาพของโมเดลบนชุดข้อมูลจากสถานที่ติดตั้งใช้งานจริง ทีมวิจัยเทรนโมเดลบนชุดข้อมูลที่ใหญ่ขึ้นซึ่งประกอบด้วยชุดข้อมูล AIC-360 และชุดข้อมูล AIC-Volunteer1-set1 และใช้ชุดข้อมูล AIC-Volunteer1-set2 ในการประเมินความแม่นยำของโมเดล เนื่องจากภาพจากกล้องที่ 3 มีความคล้ายคลึงกับมุกกล้องที่ใช้ในการเก็บข้อมูลในห้องปฏิบัติการ ในทั้งมุมก้ม มุมเงย และมุมหมุน ทีมวิจัยใช้ข้อมูลจากมุกกล้องนี้ในการประเมินผลความแม่นยำของโมเดล โมเดล AIC ให้ค่า recall ที่ 76.62% สำหรับการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงในชุดข้อมูลสำหรับทดสอบความแม่นยำ โมเดล AIC ให้ค่า F1-score ที่ 80.05% สำหรับการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงบนชุดข้อมูลทดสอบ รูปที่ 115 แสดงผลลัพธ์ของโมเดล AIC บนชุดข้อมูลทดสอบ AIC-Volunteer1-set2



รูปที่ 115 ผลลัพธ์ของโมเดล AIC ที่ทดสอบบนชุดข้อมูล AIC-Volunteer1-set2 (a) confusion matrix (b) normalized confusion matrix

รูปที่ 116 แสดงให้เห็นถึงการกระจายตัวของจำนวนข้อมูลที่ใช้ในการเทรน validation และทดสอบ



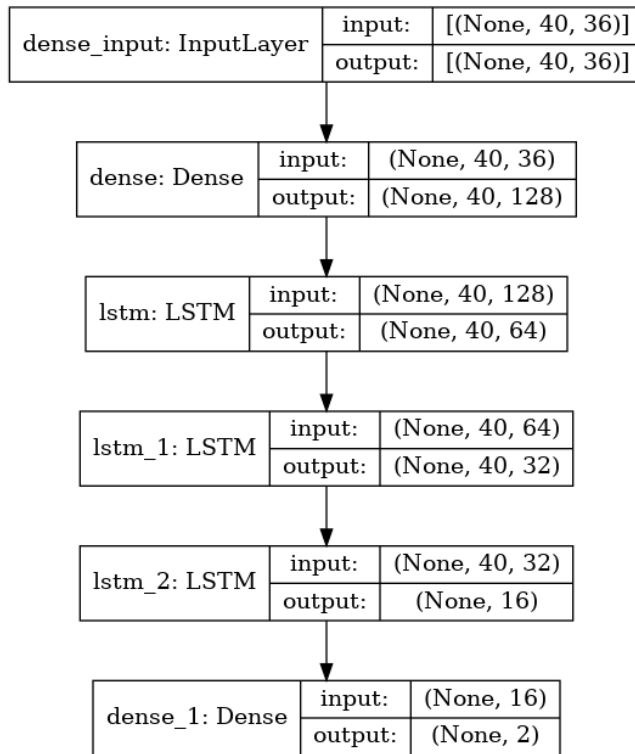


(b)


รูปที่ 116 การกระจายตัวของข้อมูลระหว่างจำนวนข้อมูล (a) และชุดเฟรมที่ต่อเนื่องกัน (b) ที่ใช้สำหรับ train, validation และ test บนชุดข้อมูลรวมระหว่าง AIC-360 และ AIC-Volunteer1-set1

ทีมวิจัยเทรนโมเดลอีกโมเดลหนึ่ง (Model-AIC-Site1) บนชุดข้อมูลที่มีขนาดใหญ่ขึ้น โครงสร้างของโมเดลแสดงในรูปที่ 117 โดยมีเลเยอร์ LSTM ทั้งหมด 3 เลเยอร์ อยู่ระหว่างเลเยอร์ dense 2 เลเยอร์ โดยแต่ละเลเยอร์มีขนาดลดลงครึ่งหนึ่งจากเลเยอร์ด้านบนลงไปยังเลเยอร์ด้านล่าง เพื่อให้โมเดลทำงานได้ดีและลดการ overfit ทีมวิจัยใช้ค่า dropout 40% ในเลเยอร์ LSTM ชั้นที่สอง และ recurrent dropout 50% ในเลเยอร์ LSTM ชั้นสุดท้าย นอกจากนี้ทีมวิจัยใช้ kernel และ bias L2 regularization เพื่อลดการ overfit บนชุดข้อมูลสำหรับเทรนโมเดล ค่า batch size ถูกตั้งค่าที่ 2,000 และอัตราการเรียนรู้ (learning rate) ถูกตั้งค่าที่ 0.0005 ในการเทรนโมเดล และเช่นเดียวกันกับโมเดลก่อนหน้าทีมวิจัยใช้ categorical crossentropy loss กับ Adam optimizer ในการเทรนโมเดล


ทีมวิจัยเทรนโมเดลโดยใช้ 119 epochs จนกระทั่งโมเดลลู่เข้า โดยมี training loss ที่ 0.04252 อย่างไรก็ตามโมเดลให้ค่าความแม่นยำที่ดีที่สุดขณะเทรนที่ 26 epochs โดยมี training accuracy ที่ 96.06% และ validation accuracy ที่ 94.32% และมีค่าความแม่นยำบนชุดข้อมูลทดสอบที่ 94.72% รายละเอียดแสดงในรูปที่ 118 (a) – (d)




รูปที่ 117 โครงสร้างของโมเดล Model-AIC-Site1



(a)




(b)



รูปที่ 118 ผลการเทรนและทดสอบโมเดล Model-AIC-Site1 บนชุดข้อมูล train และ test (a) ความแม่นยำของโมเดลบนชุดข้อมูล train และ validation (b) training และ validation loss ของโมเดล (c) confusion matrix ของโมเดลบนชุดข้อมูล test (d) normalized confusion matrix ของโมเดลบนชุดข้อมูล test

นอกเหนือไปจากนั้นที่วิจัยได้ทดสอบโมเดล Model-AIC-Site1 บนชุดข้อมูลทดสอบที่ใช้ในการประเมินความแม่นยำ (AIC-Volunteer1-set2) โมเดลดังกล่าวสามารถให้ค่า recall ในการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงที่ 97.02% สำหรับคลาสการเคลื่อนไหวแบบไม่มั่นคง ดังแสดงในรูปที่ 119 (a) – (b) เป็นผลความแม่นยำของโมเดล Model-AIC-Site1 บนชุดข้อมูลทดสอบที่ใช้ในการประเมินความแม่นยำ

แม้ว่าชุดข้อมูลที่ใช้ในการทดสอบความแม่นยำจะมีขนาดเล็ก โมเดล Model-AIC-Site1 แสดงให้เห็นว่าโมเดลดังกล่าวทำงานได้ดีกว่าโมเดล Model-AIC ค่า recall สำหรับการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงเพิ่มขึ้น 25% และค่า F1-score ของโมเดลเพิ่มขึ้นจาก 80.05% เป็น 87.80%



(a)

รูปที่ 119 ผลลัพธ์ของโมเดล Model-AIC-Site1 ที่ทดสอบบนชุดข้อมูล AIC-Volunteer1-set2 (a) confusion matrix (b) normalized confusion matrix

4.1.2.2.e ผลลัพธ์เชิงคุณภาพ

ตารางด้านล่างแสดงตัวอย่างผลลัพธ์จากโมเดลที่สามารถทำงานได้ดีที่สุด Model-AIC-Site1 บนชุดข้อมูลที่ใช้ในการประเมินความแม่นยำ (AIC-Volunteer1-set2) ตารางที่ 43 แสดงตัวอย่างการตรวจจับที่ถูกต้องบนชุดข้อมูลวิดีโอทดสอบ โมเดลสามารถแยกแยะการเคลื่อนไหวที่ไม่มั่นคง ซึ่งแบ่งเป็น 5 ประเภทของการเคลื่อนไหวที่ไม่มั่นคง โมเดลสามารถตรวจจับการเคลื่อนไหวที่ไม่มั่นคงได้ เช่น การล้มลง การเคลื่อนไหวแบบไม่มั่นคงจากอาการหัวใจวาย การเคลื่อนไหวแบบไม่มั่นคงจากการวิ่งเวียนศีรษะ และการเคลื่อนไหวแบบไม่มั่นคงภายหลังจากการสะดุดหรือลื่นล้ม ตารางที่ 44 แสดงผลลัพธ์ที่แยกแยะการเคลื่อนไหวแบบไม่มั่นคงผิด โดยการเคลื่อนไหวแบบมั่นคง เดิน เอนตัว/ก้มตัว ถูกแยกแยะผิดเป็นการเคลื่อนไหวที่ไม่มั่นคง



ตารางที่ 43 ตัวอย่างข้อมูลที่สามารถแยกประเภทได้อย่างถูกต้องบนชุดข้อมูลการเคลื่อนไหวที่ไม่มั่นคงที่ใช้ในการประเมินความแม่นยำของโมเดล

ลำดับ	ประเภทของการจำลองการเคลื่อนไหวที่ไม่มั่นคง	ตัวอย่างผลลัพธ์
1	การทรุดตัวลง (Collapsing Movement)	

<p>2</p> <p>การทรุดตัวลง (Collapsing Movement)</p>		
<p>3</p> <p>เวียนศีรษะ (Dizzy)</p>		
<p>4</p> <p>หัวใจล้มเหลว (Heart Attack)</p>		

5	การเคลื่อนไหวแบบไม่มั่นคงภายหลังการหกล้ม (Unstable after fall)	
---	---	--

ตารางที่ 44 ตัวอย่างการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงผิดพลาดจากกิจกรรมอื่น

ลำดับ	ประเภทของการเคลื่อนไหวที่มั่นคง	ตัวอย่างผลลัพธ์
1	เดิน	
2	ก้มตัวและกวาดพื้น	

โมเดลที่ทีมวิจัยเทรนในบางครั้งมีการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงผิดพลาดดังแสดงในตารางที่ 45 ซึ่งการตรวจจับผิดพลาดส่วนใหญ่จะเป็นท่าทางที่ประกอบด้วยการก้มตัวเป็นระยะเวลาสั้น ๆ

ตารางที่ 45 การแยกแยะการเคลื่อนไหวที่ไม่มั่นคงเป็นการเคลื่อนไหวที่มั่นคง

ลำดับ	ประเภทของการเคลื่อนไหวที่ไม่มั่นคง	ตัวอย่างผลลัพธ์
1	การเคลื่อนไหวที่ไม่มั่นคงภายหลังการลื่นล้ม	

ในการทดสอบ ณ บ้านอาสาสมัคร การตรวจจับผิดพลาดส่วนใหญ่เกิดจากท่าทางหรือกิจกรรม เช่น การเดินถือถังน้ำ ถือเสื้อผ้า ถือจาน ถูหรือกวาดพื้น จุ่มมอเตอร์ไซค์ เป็นต้น ตัวอย่างด้านล่างแสดงตัวอย่างท่าทางการเคลื่อนไหวดังกล่าว ข้อสังเกตหนึ่งที่ทีมวิจัยพบคือการเดินและถือสิ่งของขณะเดินในมือ ลักษณะท่าทางการเคลื่อนไหวค่อนข้างจะแตกต่างจากการเดินแบบปกติ โดยเฉพาะเมื่อวัตถุที่ถือมีน้ำหนัก ข้อมูลประเภทท่าทางดังกล่าว ดังแสดงในตารางที่ 46 สามารถนำมาใช้เป็นชุดข้อมูลสำหรับเทรนเพื่อปรับจูนโมเดลให้สามารถทำงานได้ดีขึ้นลดการแยกแยะการเคลื่อนไหวที่ไม่มั่นคงผิดพลาด

ตารางที่ 46 ตัวอย่างประเภทท่าทางขณะถือสิ่งของ





จากช่วงเวลาที่ทีมวิจัยได้ทดสอบการใช้งานจริง ณ บ้านอาสาสมัคร ผลลัพธ์การแยกแยะการเคลื่อนไหวที่ไม่มั่นคงที่ดีที่สุดคือ ข้อมูลในช่วงวันที่ 8 ซึ่งระบบตรวจจับการเคลื่อนไหวที่ไม่มั่นคงได้ทั้งหมด 8 ครั้ง แต่มีการตรวจจับผิดพลาดเพียงหนึ่งครั้ง ส่วนผลลัพธ์ที่มีการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงผิดพลาดเยอะที่สุด คือ ข้อมูลในช่วงวันที่ 7 ซึ่งมีการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงผิดพลาด 33 ครั้งจากการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงทั้งหมด 34 ครั้ง สาเหตุเกิดจากในวันดังกล่าว บ้านอาสาสมัครมีการทำความสะอาดพื้นบ้านทำให้พื้นเปียกและลื่น ดังแสดงในรูปที่ 120 ดังนั้นสมาชิกในครอบครัวจึงเดินอย่างระมัดระวังซึ่งเป็นสาเหตุทำให้เกิดท่าทางการเคลื่อนไหวที่ผิดปกติไปจากเดิม






รูปที่ 120 การเดินของสมาชิกในครอบครัวขณะมีการทำความสะอาดพื้นบ้าน


เช่นเดียวกัน ตารางที่ 47 แสดงให้เห็นถึงการแยกแยะท่าทางประเภทอื่นให้เป็นการเคลื่อนไหวแบบมั่นคงได้อย่างถูกต้อง เนื่องจากรูปแบบท่าทางอื่น ๆ ที่เป็นท่าทางกิจวัตรประจำวัน

ทั่วไปถูกพิจารณาเป็นการเคลื่อนไหวที่มั่นคงในการเทรนโมเดล ทำทางปกติทั่วไปถูกแยกแยะให้เป็น การเคลื่อนไหวที่มั่นคงได้อย่างถูกต้องโดยโมเดล Model-AIC-Site1

ตารางที่ 47 ตัวอย่างการเคลื่อนไหวในท่าทางปกติทั่วไปที่โมเดลแยกประเภทเป็นการเคลื่อนไหวที่มั่นคง

ลำดับ	ประเภทของ การเคลื่อนไหวที่มั่นคง	ตัวอย่างผลลัพธ์
1	นั่งและคุยโทรศัพท์	
2	เดิน	
3	นั่งและโบกมือ	

<p>4</p> <p>นั่งและดูนาฬิกาข้อมือ</p>	
<p>5</p> <p>ยืนปรบมือ</p>	



4.1.2.2.f การประเมินโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดล (Mahidol dataset)

เพื่อที่จะทดสอบความสามารถของโมเดลที่ทีมวิจัยเทรนในการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง ทีมวิจัยได้ทำการทดลองบนชุดข้อมูลวิดีโอที่เก็บมาจากมหาวิทยาลัยมหิดล ซึ่งประกอบด้วยข้อมูลการเคลื่อนไหวต่าง ๆ ของผู้สูงอายุ เช่น นั่ง ยืน เดิน การก้าวข้ามสิ่งกีดขวาง การเดินแล้วหมุนตัว เป็นต้น ข้อมูลชุดนี้ไม่มีการเคลื่อนไหวที่ไม่มั่นคง อย่างไรก็ตามข้อมูลชุดนี้เป็นการเก็บรวบรวมข้อมูลจากอาสาสมัครผู้สูงอายุ 20 คน ซึ่ง 10 คน

เมื่อพิจารณาจากสมมติฐานที่ว่าผู้สูงอายุที่เคยหกล้มมีการเคลื่อนไหวที่ค่อนข้างแตกต่างและมีการเคลื่อนไหวที่ไม่มั่นคงเทียบกับผู้สูงอายุคนที่ไม่เคยหกล้ม ทีมวิจัยจัดประเภทการเคลื่อนไหวของบุคคลที่เคยหกล้มว่าเป็นการเคลื่อนไหวที่ไม่มั่นคงและส่วนที่เหลือเป็นการเคลื่อนไหวที่มั่นคง นอกจากนี้ทีมวิจัยพิจารณาเพียงสองกิจกรรมสำหรับการทดสอบโมเดลที่ทีมวิจัยเทรนเพื่อใช้ในการแยกแยะการเคลื่อนไหวที่ไม่มั่นคง ได้แก่ การข้ามสิ่งกีดขวางและ การเดินแล้วหันหลังกลับ สาเหตุที่ทีมวิจัยเลือกทดสอบในสองประเภทกิจกรรมนี้เนื่องจากตามผู้เชี่ยวชาญทางการแพทย์ (นักกายภาพบำบัด) ระบุและวิเคราะห์ผลความแตกต่างระหว่างรูปแบบการเคลื่อนไหวของผู้ที่เคยล้มและไม่เคยล้มนั้นมีความโดดเด่นกว่าในกิจกรรมท่าทางอื่น ๆ ที่ใช้ในการเก็บข้อมูล รูปที่ 121 แสดงกิจกรรมการเดินและเลี้ยวกลับ และรูปที่ 122 แสดงกิจกรรมการข้ามสิ่งกีดขวาง




รูปที่ 121 ท่าทางการเดินและเลี้ยวกลับในชุดข้อมูลมหาวิทยาลัยมหิดล




รูปที่ 122 ท่าทางการเดินข้ามสิ่งกีดขวางในชุดข้อมูลมหาวิทยาลัยมหิดล

ทีมวิจัยใช้ 20% ของชุดข้อมูลมหาวิทยาลัยมหิดลเพื่อทดสอบโมเดลที่ทีมวิจัยเทรน ทีมวิจัยทดสอบโมเดลบนชุดข้อมูลมหาวิทยาลัยมหิดลในทั้ง 4 มุมกล้อง รูปที่ 123 และ 124 แสดงการกระจายตัวของข้อมูลที่ใช้ในการทดสอบ



รูปที่ 123 จำนวนไฟล์ที่ใช้ในการทดสอบในแต่ละมุกกล้อง

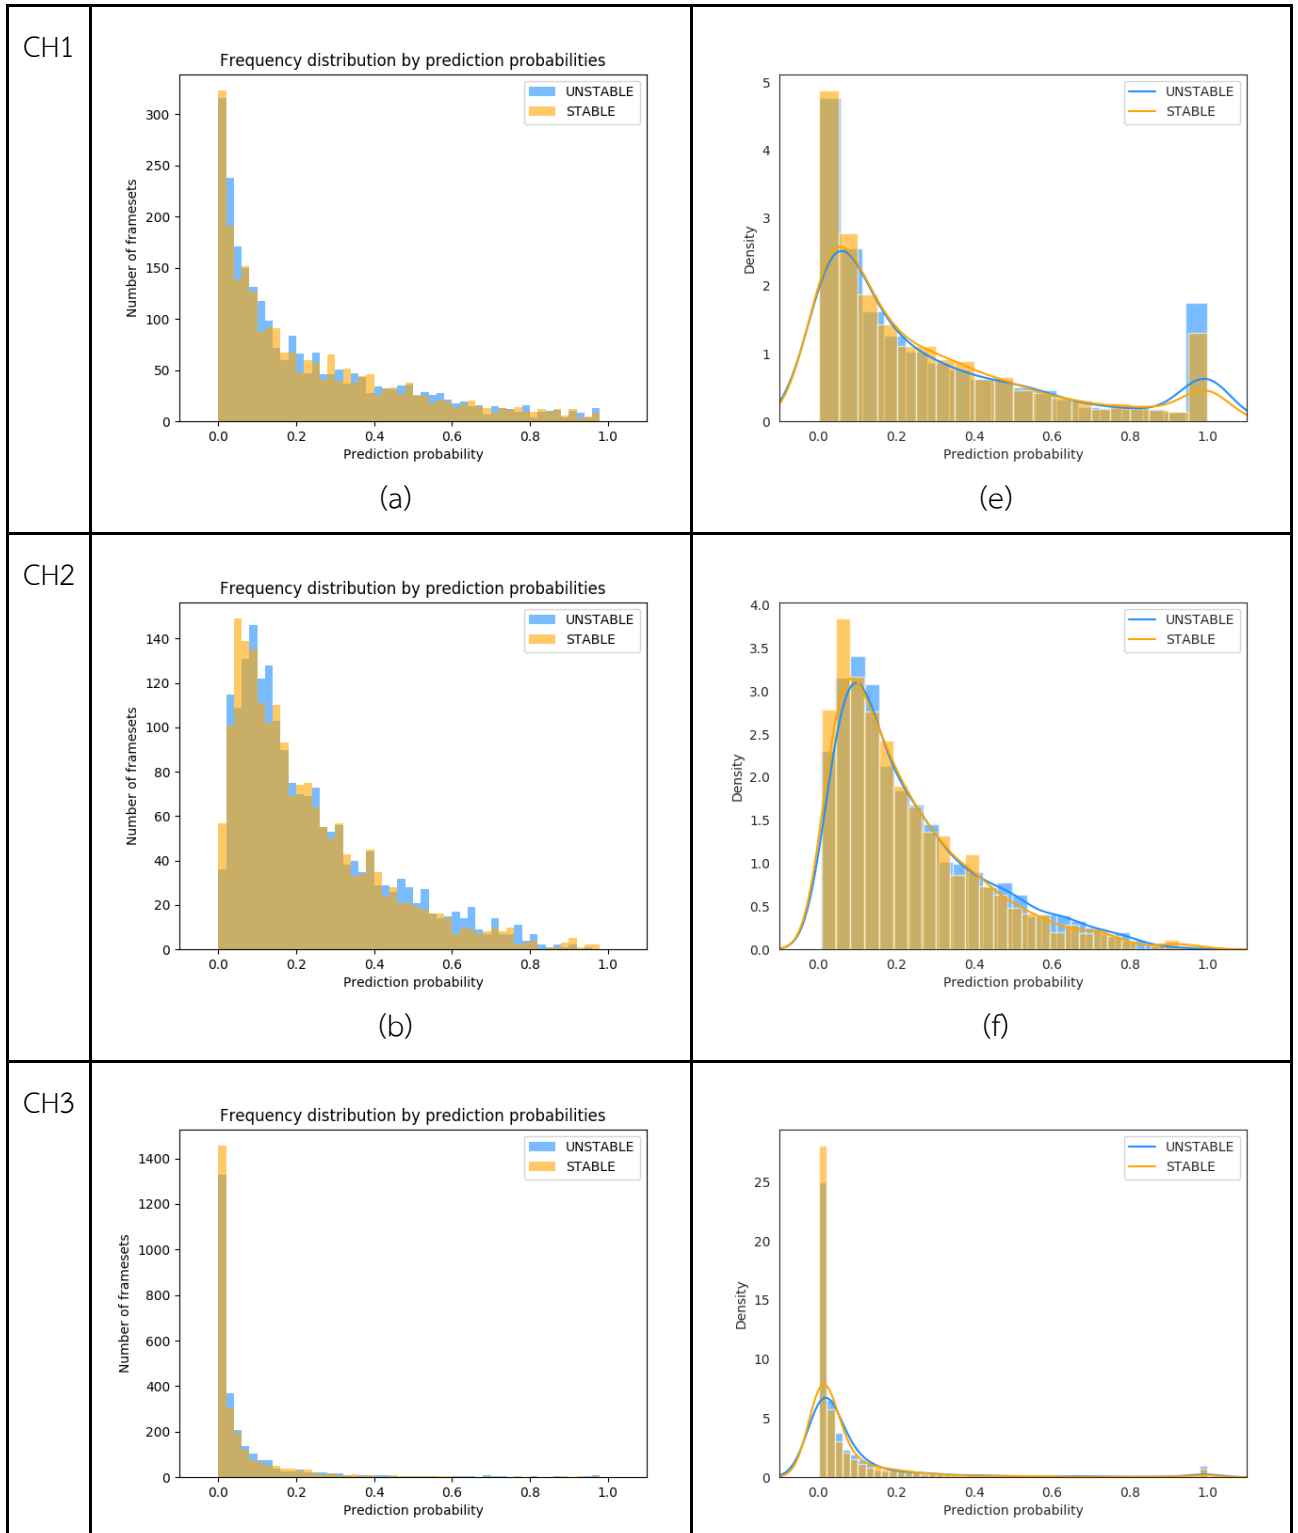


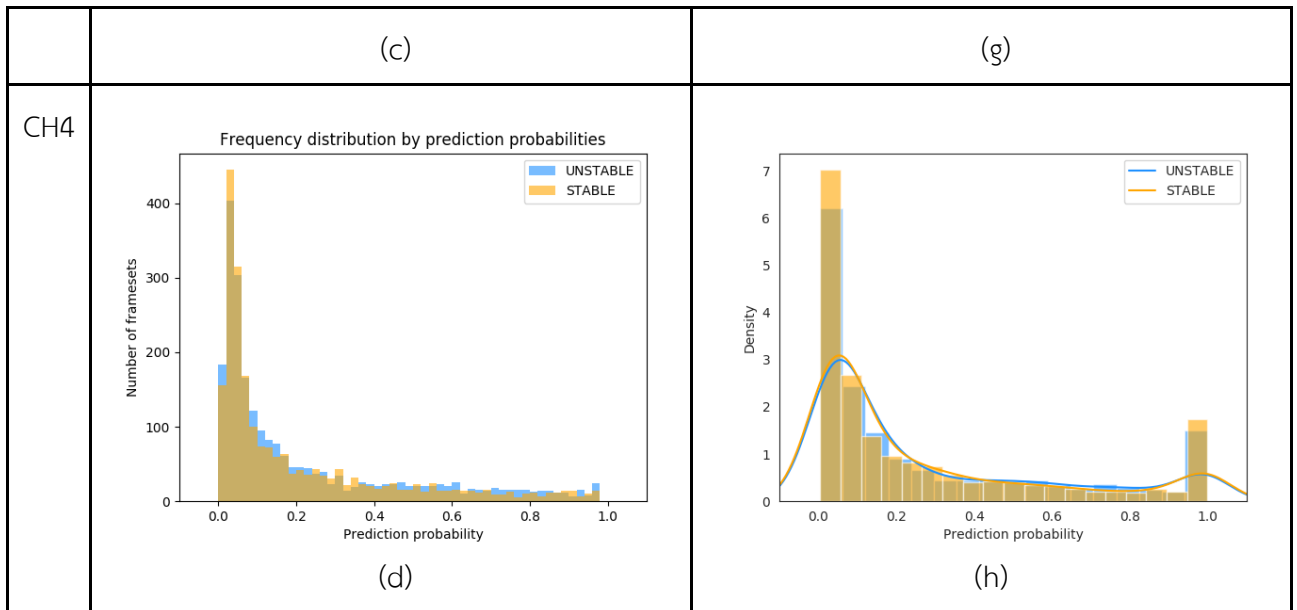
รูปที่ 124 จำนวนเฟรมเซตที่ใช้ในการทดสอบในแต่ละมุกกล้อง

ทีมวิจัยทดสอบโมเดล Model-AIC-Site1 บนชุดข้อมูลมหาวิทยาลัยมหิดล การกระจายตัวของความน่าจะเป็นในการแยกแยะระหว่างการเคลื่อนไหวที่ไม่มั่นคงและการเคลื่อนไหวที่มั่นคงบนชุดข้อมูลมหาวิทยาลัยมหิดล แสดงในคอลัมน์ที่สอง โดยตัวเลขค่าความน่าจะเป็นได้จากเลเยอร์ softmax สุดท้าย รูปในคอลัมน์ที่หนึ่งแสดงความน่าจะเป็นจากโมเดลและจำนวนเฟรมเซตที่สอดคล้องกัน

ตามหลักการแล้ว ตัวอย่างการทดสอบที่เป็นการเคลื่อนไหวที่ไม่มั่นคงทั้งหมดควรมีความน่าจะเป็นน้อยกว่า 0.5 ในขณะที่ตัวอย่างการทดสอบที่เป็นการเคลื่อนไหวที่มั่นคงทั้งหมดควรมีค่าความน่าจะเป็นที่สูงกว่า 0.5 แต่ตัวเลขที่แสดงในรูปที่ 125 (a) - (h) แสดงให้เห็นว่าตัวอย่างการ

เคลื่อนไหวที่มั่นคงและไม่มั่นคงนั้นกระจายไปทั่วแกน X ซึ่งบ่งชี้ว่าแบบจำลองไม่สามารถทำงานได้ดี ในชุดข้อมูลดังกล่าว โมเดลไม่สามารถจำแนกชุดข้อมูลได้อย่างถูกต้อง ความแม่นยำของโมเดล Model-AIC-Site1 บนชุดข้อมูลมหาวิทยาลัยมหิดลอยู่ที่ประมาณ 50%






รูปที่ 125 การกระจายความถี่ตามความน่าจะเป็นของการแยกแยะของโมเดล Model-AIC-Site1 บนชุดข้อมูลทดสอบมหาวิทยาลัยมหิดล ตัวเลข (a) - (d) แสดงการกระจายความน่าจะเป็นในการแยกแยะและจำนวนชุดทดสอบ ตัวเลข (e) - (h) แสดงการกระจายฟังก์ชันความหนาแน่นของความน่าจะเป็น (PDF) บนชุดข้อมูลทดสอบโดยใช้คอร์เนลแบบเกาส์เซียนบนชุดข้อมูล

มีเหตุผลบางประการที่ทำให้ประสิทธิภาพของโมเดลดังกล่าวทำงานได้ไม่ดี ดังนี้


1. แม้จะความแตกต่างระหว่างรูปแบบการเคลื่อนไหวของผู้สูงอายุที่เคยล้มและผู้ไม่เคยล้มจะเด่นชัดกว่าในกิจกรรม การเดินและเลี้ยวกลับ และ การเดินข้ามสิ่งกีดขวาง ความแตกต่างเหล่านี้ละเอียดอ่อนมากต่อการรับรู้จากการมองเห็น
2. โมเดล Model-AIC-Site1 ได้รับเทรนโดยใช้ข้อมูลจำลองการเคลื่อนไหวที่ไม่มั่นคงจากห้องปฏิบัติการ AIC (ชุดข้อมูล AIC-360) ซึ่งรูปแบบการเคลื่อนไหวของการเคลื่อนไหวแบบไม่มั่นคงแสดงออกถึงความแตกต่างอย่างมีนัยสำคัญเมื่อเทียบกับการเคลื่อนไหวแบบมั่นคงหรือ การเคลื่อนไหวแบบปกติ

ทีมวิจัยเทรนโมเดลใหม่บนชุดข้อมูลมหาวิทยาลัยมหิดล โดยโมเดลใหม่เทรนโดยใช้ข้อมูล 70% ของชุดข้อมูลมหาวิทยาลัยมหิดลเป็นชุดข้อมูลสำหรับเทรน และ 10% สำหรับชุดข้อมูลตรวจสอบความถูกต้อง ทีมวิจัยทดสอบโมเดลนี้ในชุดข้อมูลสำหรับทดสอบเดียวกันกับที่กล่าวถึงก่อนหน้านี้ รูปที่ 126 แสดงประสิทธิภาพของโมเดล ซึ่งแสดงให้เห็นว่าโมเดลนี้ทำงานได้ดีกว่าโมเดล Model-AIC-Site1 เนื่องจากสามารถแยกการเคลื่อนไหวที่ไม่มั่นคงและมั่นคงได้ โมเดลได้เรียนรู้รูปแบบของการเคลื่อนไหวที่ไม่มั่นคงและมั่นคงในระดับหนึ่ง รูปที่ 126 (a) - (d) แสดงให้เห็นถึงข้อมูลการเคลื่อนไหวที่ไม่มั่นคงส่วนใหญ่มีความน่าจะเป็นน้อยกว่า 0.5 ในขณะที่ข้อมูลการเคลื่อนไหวที่มั่นคงมีความน่าจะเป็นมากกว่า 0.5

CH1




(a)




(e)

CH2




(b)




(f)

CH3




(c)




(g)

CH4



(d)

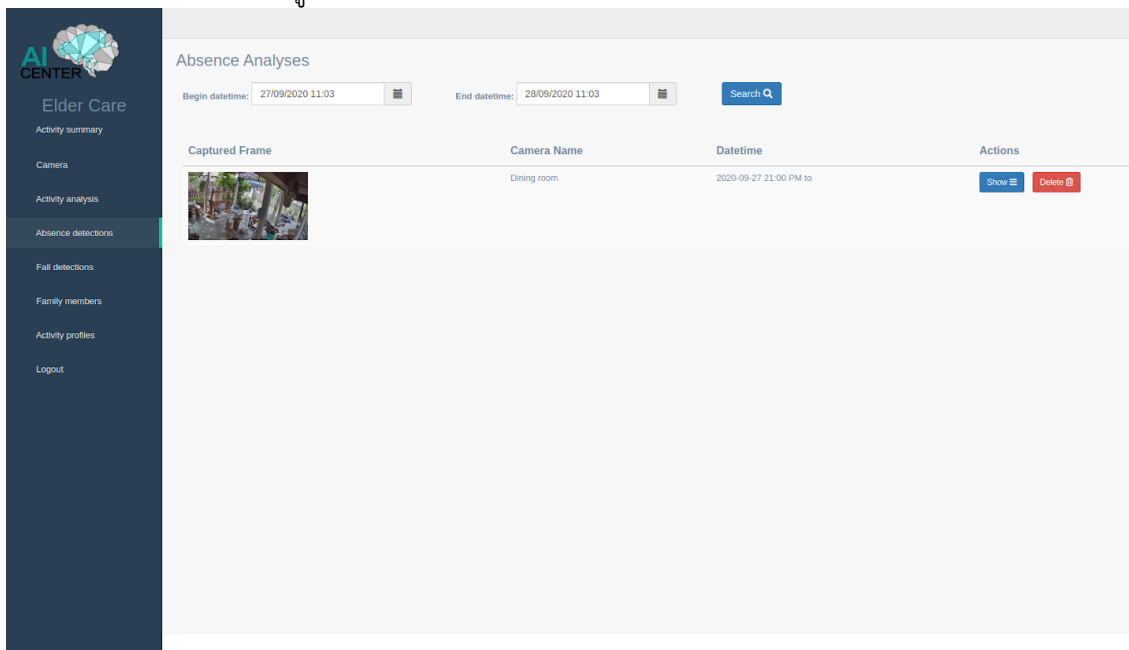


(h)


รูปที่ 126 การกระจายความถี่ตามความน่าจะเป็นของการแยกแยะของโมเดลใหม่ที่เทรนบนชุดข้อมูลมหาวิทยาลัยมหิดล และ ทดสอบบนชุดข้อมูลมหาวิทยาลัยมหิดล ตัวเลข (a) - (d) แสดงการกระจายความน่าจะเป็นในการแยกแยะและจำนวนชุดทดสอบ ตัวเลข (e) - (h) แสดงการกระจายฟังก์ชันความหนาแน่นของความน่าจะเป็น (PDF) บนชุดข้อมูลทดสอบโดยใช้คอร์เนลแบบเกาส์เซียนบนชุดข้อมูล

4.1.3 การตรวจจับบุคคลเมื่อไม่อยู่ในอาณาบริเวณที่กำหนด

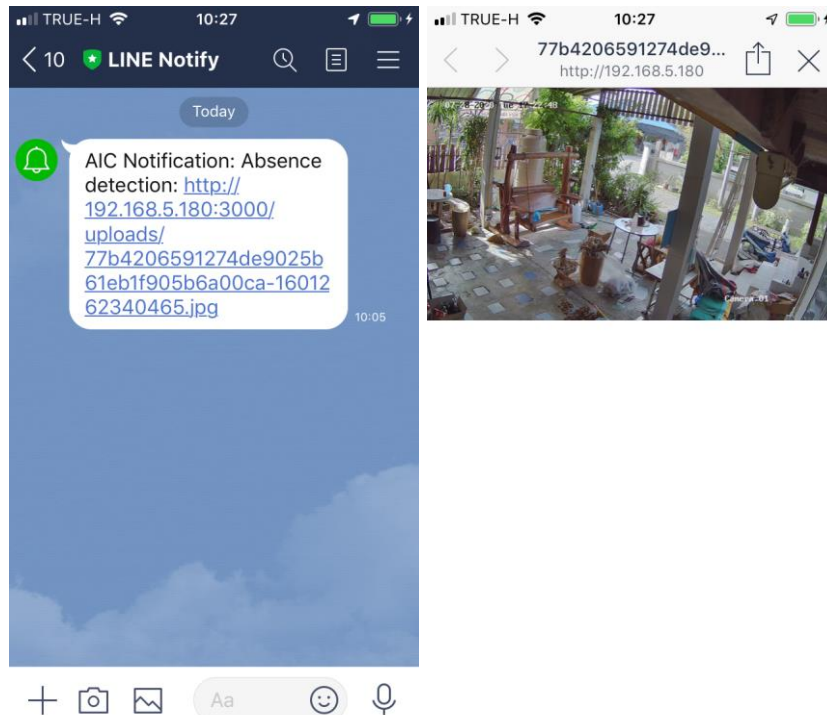
การตรวจจับบุคคลเมื่อไม่อยู่ในอาณาบริเวณที่กำหนด (absence detection) นี้จะถูกส่งข้อมูลมาจากหน่วยประมวลผลส่วนหน้าและตรวจสอบกับ Activity Profile หากข้อมูลที่ส่งมาไม่อยู่ในช่วงเวลาการอยู่อาศัยที่ผู้ใช้งานกำหนดไว้ระบบจะทำการบันทึกข้อมูลและส่งข้อความแจ้งเตือนไปยังผู้ใช้งานทันที โดยผลลัพธ์แสดงบนเว็บแอปพลิเคชัน Elder Care ดังแสดงในรูปที่ 127 และข้อความแจ้งเตือนแสดงในรูปที่ 128



The screenshot shows the 'Absence Analyses' section of the Elder Care web application. On the left is a dark blue sidebar with the 'AI CENTER' logo and navigation menu items: 'Elder Care', 'Activity summary', 'Camera', 'Activity analysis', 'Absence detections' (highlighted), 'Fall detections', 'Family members', 'Activity profiles', and 'Logout'. The main content area has a light gray header with the title 'Absence Analyses'. Below the header are two date input fields: 'Begin datetime: 27/09/2020 11:03' and 'End datetime: 28/09/2020 11:03', followed by a 'Search' button. Below this is a table with the following structure:

Captured Frame	Camera Name	Datetime	Actions
	Dining room	2020-09-27 21:00 PM to	Show Delete

รูปที่ 127 ตัวอย่างการตรวจจับบุคคลเมื่อไม่อยู่ในอาณาบริเวณที่กำหนดบนเว็บแอปพลิเคชัน Elder Care



รูปที่ 128 ตัวอย่างข้อความแจ้งเตือน (ซ้าย) และรูปการแจ้งเตือน (ขวา)

4.1.4 การระบุตัวตน

การระบุตัวตนบุคคลที่ปรากฏในภาพใช้การรู้จำใบหน้าบุคคล ที่มีวิจัยประเมินความแม่นยำในบ้านอาสาสมัครในชุดข้อมูล AIC-Initial-Test เนื่องจากมีผู้อยู่อาศัยจำนวนมากกว่า 5 คน ตัวอย่างของข้อมูลภาพใบหน้าบุคคลที่ใช้เปรียบเทียบมาจากข้อมูลภาพใบหน้าบุคคลที่ผู้ใช้งานลงทะเบียนไว้ผ่านเว็บแอปพลิเคชันดังแสดงในรูปที่ 129 และภาพข้อมูลนำเข้าของเซอร์วิสรู้จำใบหน้าบุคคลแสดงในรูปที่ 130



รูปที่ 129 ตัวอย่างภาพต้นฉบับที่ใช้ในการเปรียบเทียบรู้จำใบหน้าบุคคล



รูปที่ 130 ตัวอย่างภาพข้อมูลนำเข้าของเซอร์วิสรู้จำใบหน้าบุคคล (ชาย) และภาพตัดเฉพาะส่วนของใบหน้า (ขวา)

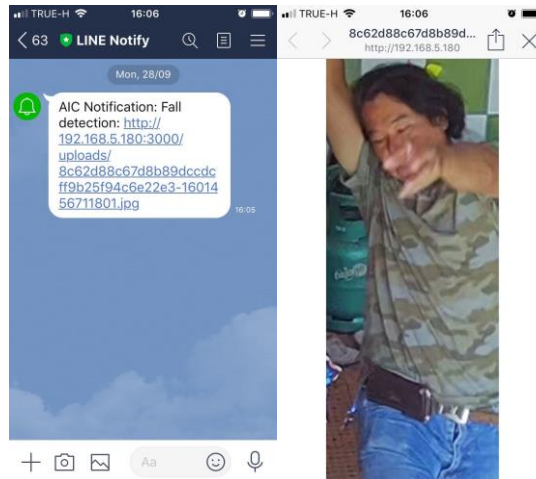
ทีมวิจัยใช้ Pretrained weights ของ Facenet ในการดึงข้อมูล face embeddings vector และทำการทดสอบโดยใช้สมาชิกในครอบครัว 5 คนโดยพิจารณาเฉพาะการตามรอยที่มีภาพหน้าตรงของบุคคลนั้น ๆ และภาพใบหน้าบุคคลมีสภาพแสงปกติ และเห็นหน้าตรง หรือมีมุมก้มเงยเพียงเล็กน้อย ทดสอบกับภาพจำนวน 126 ภาพ ค่าความแม่นยำในการรู้จำใบหน้าบุคคลอยู่ที่ 85.71% โดย confusion matrix แสดงในตารางที่ 48

ตารางที่ 48 confusion matrix ของการรู้จำใบหน้าบุคคล 5 คน

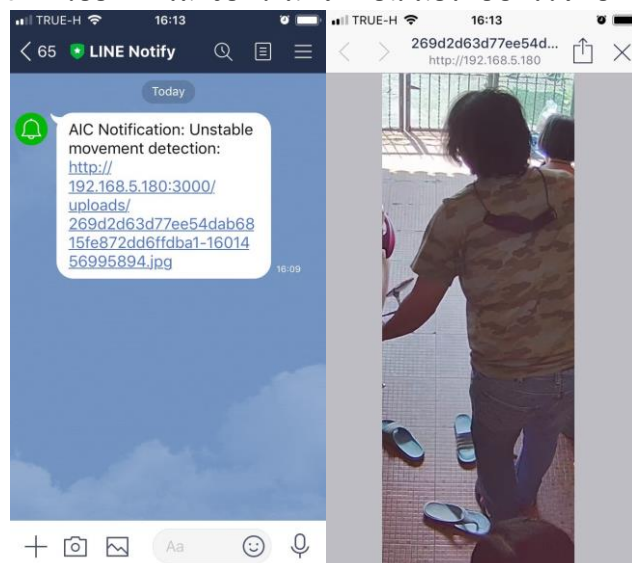
Template \ Probe	ID1	ID2	ID3	ID4	ID5
ID1	14	2	1		
ID2		10			
ID3	5	2	23		4
ID4			3	21	1
ID5					40

4.1.5 เซอร์วิสการแจ้งเตือน Notification Service

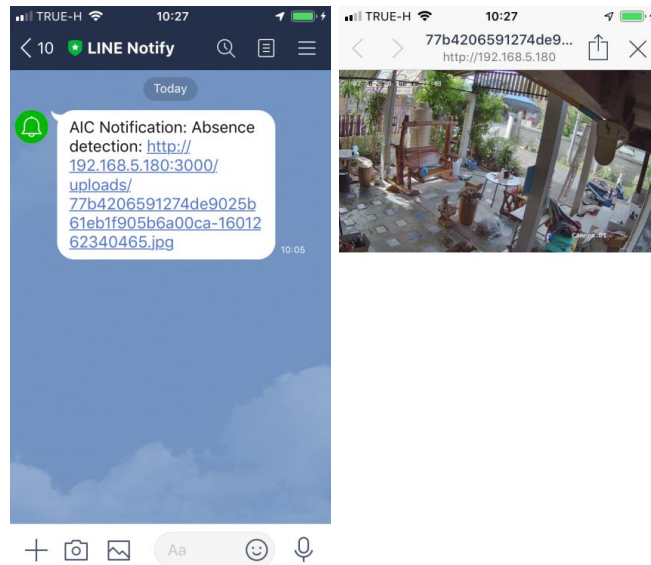
ผลลัพธ์การแจ้งเตือนผ่าน LINE Notify API จะทำการส่งประเภทเหตุการณ์ที่ตรวจจับได้ และ URL สำหรับเข้าถึงภาพเหตุการณ์ ไปยังบัญชี LINE ของผู้ใช้งานแบบเรียลไทม์ โดยผู้ใช้งานสามารถคลิก URL ที่ส่งไปในข้อความเพื่อเข้าถึงภาพเหตุการณ์ที่ระบบตรวจจับได้ ดังแสดงในรูปแบบที่ 131 – 133



รูปที่ 131 ตัวอย่างการส่งข้อความแจ้งเตือนเมื่อระบบตรวจพบการหกล้ม



รูปที่ 132 ตัวอย่างการส่งข้อความแจ้งเตือนเมื่อระบบตรวจพบการเคลื่อนไหวที่ไม่มั่นคง



รูปที่ 133 ตัวอย่างการส่งข้อความแจ้งเตือนเมื่อระบบไม่ตรวจพบการเคลื่อนไหวใด ๆ ในช่วงเวลาอยู่อาศัย

ในกรณีที่ผู้ใช้งานไม่ต้องการรับการแจ้งเตือนในแอปพลิเคชัน LINE ทีมวิจัยได้เพิ่มหน้าการแจ้งเตือนบนเว็บแอปพลิเคชัน เพื่อให้ผู้ใช้งานสามารถดูรายการการแจ้งเตือนได้โดยตรงบนเว็บแอปพลิเคชัน โดยผลลัพธ์การแจ้งเตือน จะเป็นข้อมูลชุดเดียวกันกับข้อมูลที่ส่งไปแสดงบนแอปพลิเคชัน LINE ตัวอย่างผลลัพธ์แสดงบนเว็บแอปพลิเคชันแสดงในหัวข้อถัดไป

4.1.6 ผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชัน Elder Care

ผลลัพธ์จากการแยกแยะประเภทท่าทางจะถูกแสดงบนเว็บแอปพลิเคชัน Elder Care เพื่อให้ผู้ใช้งานสามารถดูและค้นหาประเภทกิจกรรมที่ตรวจพบในแต่ละช่วงเวลาตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชันจากบ้านอาสาสมัคร จ.กรุงเทพมหานคร และ จ.ชัยนาท แสดงในรูปที่ 134 และ 135 ตามลำดับ

Activity Analysis						
Begin datetime:	19/07/2021 12:33	End datetime:	28/07/2021 12:33	Search Q		
ID	Captured Frame	Activity Type	Camera Name	Family ID	Datetime	Actions
121931		Stand	Exit	N/A	2021-07-19 12:33 PM	Show Delete
121932		Stand	Exit	N/A	2021-07-19 12:33 PM	Show Delete
121933		Stand	Exit	N/A	2021-07-19 12:33 PM	Show Delete
121934		Sit	Exit	N/A	2021-07-19 12:33 PM	Show Delete
121935		Stand	Exit	N/A	2021-07-19 12:33 PM	Show Delete
121936		Walk	Exit	N/A	2021-07-19 12:33 PM	Show Delete
121937		Stand	Exit	N/A	2021-07-19 12:33 PM	Show Delete
121938		Bend	Exit	N/A	2021-07-19 12:34 PM	Show Delete
121939		Bend	Exit	N/A	2021-07-19 12:34 PM	Show Delete
121940		Stand	Exit	N/A	2021-07-19 12:34 PM	Show Delete

Navigation: Previous 1 2 3 4 5 6 7 8 9 ... 953 954 Next

รูปที่ 134 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชันจากบ้านอาสาสมัคร
จ.กรุงเทพมหานคร










ID	Captured Frame	Activity Type	Camera Name	Family ID	Datetime	Actions
123999		Sit	Living room camera 1	N/A	2021-07-20 04:19 AM	Show Delete
124004		Sit	Living room camera 1	N/A	2021-07-20 05:06 AM	Show Delete
124005		Walk	Living room camera 1	N/A	2021-07-20 05:06 AM	Show Delete
124006		Walk	Living room camera 1	N/A	2021-07-20 05:07 AM	Show Delete
124015		Bend	Living room camera 1	N/A	2021-07-20 05:14 AM	Show Delete
124050		Bend	Living room camera 1	N/A	2021-07-20 05:18 AM	Show Delete
124054		Sit	Living room camera 1	N/A	2021-07-20 05:19 AM	Show Delete
124066		Sit	Living room camera 1	N/A	2021-07-20 05:20 AM	Show Delete
124068		Sit	Living room camera 1	N/A	2021-07-20 05:20 AM	Show Delete
124073		Sit	Living room camera 1	N/A	2021-07-20 05:20 AM	Show Delete

รูปที่ 135 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชันจากบ้านอาสาสมัคร จ.ชัยนาท

สำหรับผลลัพธ์จากการประเมินความแม่นยำของระบบโดยใช้ชุดข้อมูล AIC-Volunteer1-set2 ผลลัพธ์การตรวจจับท่าทางต่าง ๆ แสดงบนเว็บแอปพลิเคชันในรูปที่ 136 – 137 และผลลัพธ์การตรวจจับการหกล้ม แสดงในรูปที่ 138 – 139 และการเคลื่อนไหวที่ไม่มั่นคง แสดงในรูปที่ 142 – 143 สำหรับตัวอย่างผลลัพธ์การแจ้งเตือนบนแอปพลิเคชัน LINE และการแสดงผลการแจ้งเตือนบนเว็บแอปพลิเคชันของการตรวจจับการหกล้มแสดงในรูปที่ 140 และ 141 ตามลำดับเช่นเดียวกันกับผลลัพธ์การแจ้งเตือนการเคลื่อนไหวที่ไม่มั่นคงแสดงในรูปที่ 144 และ 145 สำหรับการแจ้งเตือนบนแอปพลิเคชัน LINE และเว็บแอปพลิเคชัน

Activity Analysis

Begin datetime: 31/07/2021 16:00 End datetime: 31/07/2021 16:55 Search

ID	Captured Frame	Activity Type	Camera Name	Family ID	Datetime	Actions
151369		Clap	Front yard	N/A	2021-07-31 16:00 PM	Show Delete
151370		Sit	Front yard	N/A	2021-07-31 16:00 PM	Show Delete
151371		Wave	Front yard	N/A	2021-07-31 16:01 PM	Show Delete
151375		Bend	Front yard	N/A	2021-07-31 16:01 PM	Show Delete
151387		Check time	Front yard	N/A	2021-07-31 16:01 PM	Show Delete
151388		Phone call	Front yard	N/A	2021-07-31 16:01 PM	Show Delete
151389		Point	Front yard	N/A	2021-07-31 16:01 PM	Show Delete
151396		Walk	Front yard	N/A	2021-07-31 16:02 PM	Show Delete
151399		Stand	Front yard	N/A	2021-07-31 16:02 PM	Show Delete

รูปที่ 136 ตัวอย่างผลลัพธ์การแยกแยะประเภทท่าทางบนเว็บแอปพลิเคชันจากบ้านอาสาสมัคร
จ.กรุงเทพมหานคร บนชุดข้อมูล AIC-Volunteer1-set2



รูปที่ 137 ตัวอย่างรูปที่เป็นตัวแทนรูปของการตามรอยบุคคลที่ใช้แสดงบนเว็บแอปพลิเคชัน

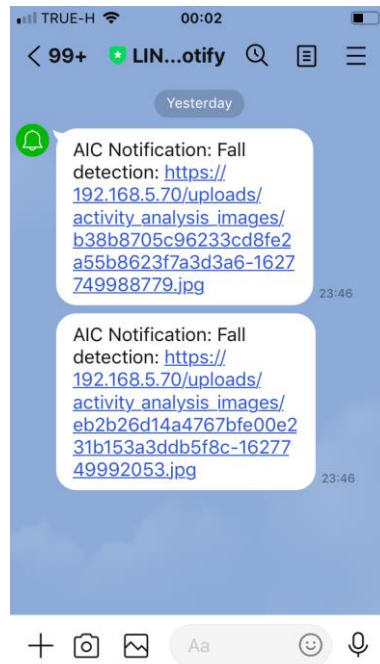
Begin datetime: 31/07/2021 23:45 End datetime: 01/08/2021 00:00 Search

ID	Captured Frame	Camera Name	Family Member	Datetime	Actions
151548		Front yard	N/A	2021-07-31 23:46 PM	Show Delete
151549		Front yard	N/A	2021-07-31 23:46 PM	Show Delete

รูปที่ 138 ตัวอย่างผลลัพธ์การตรวจจับการจำลองการล้ม ณ บ้านอาสาสมัคร ใน จ.กรุงเทพมหานคร บนชุดข้อมูล AIC-Volunteer1-set2 ที่ตรวจจับได้แสดงบนเว็บแอปพลิเคชัน







รูปที่ 139 ตัวอย่างรูปที่เป็นตัวแทนรูปของการตามรอยบุคคลของแต่ละการจำลองการล้ม ที่ใช้แสดงบนเว็บแอปพลิเคชัน



รูปที่ 140 ตัวอย่างข้อความการแจ้งเตือนเมื่อระบบสามารถตรวจจับการหกล้มดังกล่าวบนแอปพลิเคชัน LINE

The screenshot shows a web dashboard for 'Elder Care' with a sidebar menu. The main content area is titled 'Alert Notifications' and contains a table with the following data:

ID	Camera	Majority activity	Captured frame	Datetime	Note
134010	Front yard	Fall		2021-07-31 23:46:28 +0700	Show [icon] Delete [icon]
134011	Front yard	Fall		2021-07-31 23:46:22 +0700	Show [icon] Delete [icon]
134046	Front yard	Unstable Movement		2021-08-01 00:44:33 +0700	Show [icon] Delete [icon]
134049	Front yard	Unstable Movement		2021-08-01 00:44:41 +0700	Show [icon] Delete [icon]

รูปที่ 141 ตัวอย่างข้อมูลการแจ้งเตือนการตรวจจับการหกล้มดังกล่าวบนเว็บแอปพลิเคชัน

Unstable Movement Detections

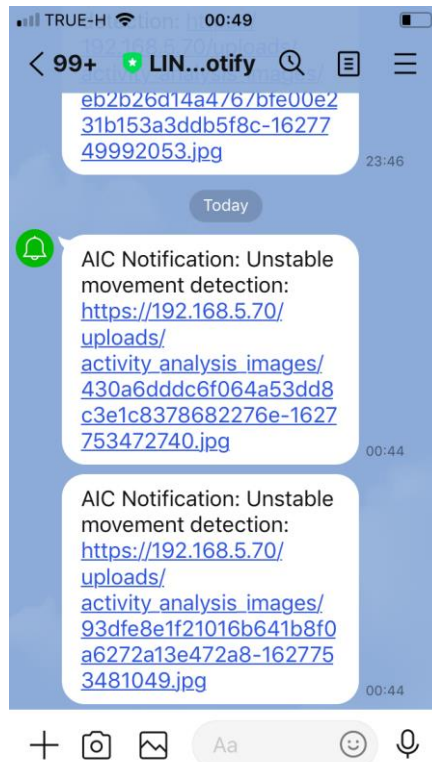
Begin datetime: 01/08/2021 00:40 End datetime: 01/08/2021 00:50 Search

ID	Captured Frame	Camera Name	Family Member	Datetime	Actions
151584		Front yard	N/A	2021-08-01 00:44 AM	Show Delete
151587		Front yard	N/A	2021-08-01 00:44 AM	Show Delete

รูปที่ 142 ตัวอย่างผลลัพธ์การตรวจจับการจำลองการเคลื่อนไหวที่ไม่มั่นคง ณ บ้านอาสาสมัคร ใน จ.กรุงเทพมหานคร บนชุดข้อมูล AIC-Volunteer1-set2 ที่ตรวจจับได้แสดงบนเว็บแอปพลิเคชัน



รูปที่ 143 ตัวอย่างรูปที่เป็นตัวแทนรูปของการตามรอยบุคคลของแต่ละการจำลองการเคลื่อนไหวที่ไม่มั่นคง ที่ใช้แสดงบนเว็บแอปพลิเคชัน



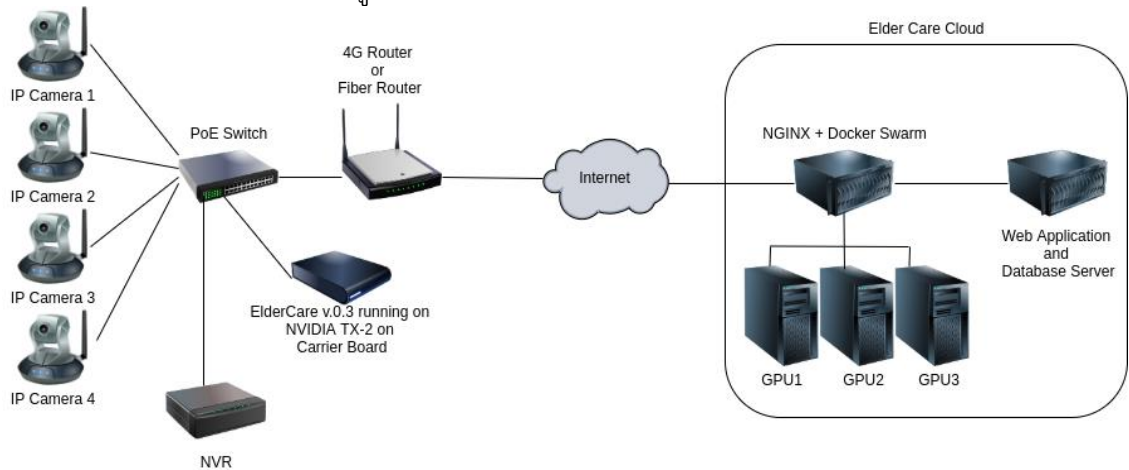
รูปที่ 144 ตัวอย่างข้อความการแจ้งเตือนเมื่อระบบสามารถตรวจจับการเคลื่อนไหวที่ไม่มั่นคงดังกล่าวบนแอปพลิเคชัน LINE

ID	Camera	Majority activity	Captured frame	Datetime	Note
134010	Front yard	Fall		2021-07-31 23:46:28 +0700	Show [icon] Delete [icon]
134011	Front yard	Fall		2021-07-31 23:46:32 +0700	Show [icon] Delete [icon]
134046	Front yard	Unstable Movement		2021-08-01 00:44:33 +0700	Show [icon] Delete [icon]
134049	Front yard	Unstable Movement		2021-08-01 00:44:41 +0700	Show [icon] Delete [icon]

รูปที่ 145 ตัวอย่างข้อมูลการแจ้งเตือนการตรวจจับการหกล้มดังกล่าวบนเว็บแอปพลิเคชัน

4.1.7 การติดตั้งและใช้งานระบบ

ทีมวิจัยติดตั้งระบบ ณ บ้านอาสาสมัครจำนวน 2 หลัง โดยเลือกสองหลังนี้เนื่องจากมีผู้สูงอายุอาศัยอยู่ และอยู่ไม่ไกลจากสถาบันเทคโนโลยีแห่งเอเชีย รวมถึงได้รับอนุญาตจากอาสาสมัครให้ติดตั้งกล้องภายในบริเวณบ้านเพื่อเก็บข้อมูล และทดสอบระบบได้ โดยทีมวิจัยได้ติดตั้งอุปกรณ์ดังแสดงในรูปที่ 146 ซึ่งประกอบด้วย อุปกรณ์ประมวลผลส่วนหน้า (NVIDIA TX-2) เครื่องบันทึกวิดีโอ (NVR) กล้อง IP เน็ตเวิร์กสวิตช์ และ เน็ตเวิร์กเราท์เตอร์ เพื่อเชื่อมต่อกับอินเทอร์เน็ต ณ ปัจจุบันทีมวิจัยใช้การตั้งค่า VPN เพื่อส่งข้อมูลกลับมายังสถาบันเทคโนโลยีแห่งเอเชีย



รูปที่ 146 แผนผังแสดงการติดตั้งอุปกรณ์ ณ บ้านอาสาสมัคร

ซอฟต์แวร์ Elder Care Video Analytics v.0.3 ถูกรันบน NVIDIA TX-2 โดยปัจจุบันบอร์ด TX-2 สามารถทำการประมวลผลได้หนึ่งกล้อง ทีมวิจัยติดตั้งระบบ ณ บ้านอาสาสมัครหมายเลข 1 ในจังหวัดชัยนาท และบ้านอาสาสมัครหมายเลข 2 ในกรุงเทพมหานคร รายละเอียดการติดตั้งอุปกรณ์มีดังต่อไปนี้

4.1.7.1 การติดตั้งระบบ ณ บ้านอาสาสมัครหมายเลข 1 จังหวัดชัยนาท


ทีมวิจัยเลือกติดตั้งระบบ ณ บ้านหลังนี้เนื่องจากมีผู้สูงอายุอาศัยอยู่ด้วยกัน 2 คน โดยที่ผู้สูงอายุคนหนึ่งมีประวัติการหกล้ม และอีกคนหนึ่งไม่มีประวัติการหกล้ม ทีมวิจัยติดตั้งกล้อง IP ทั้งหมดจำนวน 4 กล้องเพื่อเก็บข้อมูล และทดสอบระบบ โดยอุปกรณ์ที่ติดตั้งแสดงในรูปที่ 147





รูปที่ 147 อุปกรณ์ที่ติดตั้ง ณ บ้านอาสาสมัครหมายเลข 1 ในจังหวัดชัยนาท

โดยมีลักษณะการติดตั้งกล้องแสดงในรูปที่ 148 - 149 โดยทำการติดตั้งกล้องให้ครอบคลุมพื้นที่การอยู่อาศัยเฉพาะบริเวณที่ไม่เป็นพื้นที่ส่วนตัว ภาพจากมุกกล้องทั้ง 4 ตัวแสดงในรูปที่ 150



รูปที่ 148 ลักษณะการติดตั้งกล้อง IP ทั้ง 4 ตัว



รูปที่ 149 ตำแหน่งการติดตั้งกล้องแต่ละตัว




รูปที่ 150 ภาพมุมกล้องทั้ง 4 ตัว

4.1.7.2 การติดตั้งระบบ ณ บ้านอาสาสมัครหมายเลข 2 จังหวัดกรุงเทพมหานคร

ทีมวิจัยเลือกติดตั้งระบบ ณ บ้านหลังนี้เนื่องจากมีผู้สูงอายุอาศัยอยู่ 1 คน โดยที่ผู้สูงอายุไม่มีประวัติการหกล้ม และอาศัยอยู่กับสมาชิกในครอบครัวอีก 4 คน ทีมวิจัยติดตั้งกล้อง IP ทั้งหมดจำนวน 8 กล้องเพื่อเก็บข้อมูล และทดสอบระบบ โดยอุปกรณ์ที่ติดตั้งแสดงในรูปที่ 151 – 153 และมุมกล้องแสดงในตารางที่ 49



รูปที่ 151 อุปกรณ์ที่ติดตั้ง ณ บ้านอาสาสมัครหมายเลข 2 ในจังหวัดกรุงเทพมหานคร



รูปที่ 152 ลักษณะการติดตั้งกล้อง IP ทั้ง 8 ตัว



รูปที่ 153 ตำแหน่งการติดตั้งกล้องแต่ละตัว

ในการดำเนินโครงการช่วงที่เหลือที่มิวิจัยจะทำการติดตั้งบอร์ด TX-2 เพิ่ม ณ บ้านทั้งสองหลัง และภายในสถาบันเทคโนโลยีแห่งเอเชียเพิ่มเติมเพื่อเก็บข้อมูล และประเมินผลความแม่นยำในการทำงานของระบบร่วมกับ RESTful Elder Care API v.0.2

ตารางที่ 49 แสดงมุมมองทั้ง 8 ตัวในบ้านของอาสาสมัครในจ.กรุงเทพมหานคร

กล้องหมายเลข	มุมมอง
CH1	

CH2	
CH3	
CH4	
CH5	
CH6	

CH7	
CH8	

หมายเหตุ: หมายเลขกล้องไม่ตรงกับชื่อกล้องที่แสดงในรูปเนื่องจากหมายเลขกล้องเรียงตามลำดับ การตั้งค่าในเครื่องบันทึกวีดีโอ (NVR)

4.1.8 ผลการเปรียบเทียบประสิทธิภาพระหว่างหน่วยประมวลผลส่วนหน้า และ คลาวด์

เพื่อที่จะเปรียบเทียบประสิทธิภาพการประมวลผลของระบบต้นแบบในการรันซอฟต์แวร์ Elder Care v0.1 บนสองระบบคือ หน่วยประมวลผลส่วนหน้า (local processing) และ คลาวด์ (เครื่องคอมพิวเตอร์ประสิทธิภาพสูงที่ประกอบด้วยหน่วยประมวลผลกราฟิก) ทีมวิจัยได้ออกแบบสถาปัตยกรรมของระบบเป็นสองรูปแบบ โดยสถาปัตยกรรมระบบแบบแรกจะใช้ซอฟต์แวร์ Elder Care v0.1 ซึ่งจะทำให้การตรวจจับบุคคล ตามรอยบุคคล และทำการแยกแยะประเภทท่าทางของบุคคลในแต่ละเฟรมบนโพรเซสเซอร์ทั้งหมด ในส่วนของสถาปัตยกรรมแบบที่สองจะเป็นการพัฒนาต่อยอดจากซอฟต์แวร์ Elder Care v0.1 โดยแยกส่วนของการแยกแยะประเภทท่าทางมาประมวลผลบนคลาวด์ โดยที่ส่วนประมวลผลส่วนหน้าจะทำหน้าที่ในการตรวจจับและตามรอยบุคคลและส่งข้อมูลมายังคลาวด์เพื่อประมวลผลต่อไป การเปรียบเทียบประสิทธิภาพการทำงานของหน่วยประมวลผลส่วนหน้า และ คลาวด์ โดยทำการรันซอฟต์แวร์ Elder Care v0.1 เวอร์ชันเดียวกันบนอุปกรณ์ประมวลผลที่แตกต่างกัน เพื่อที่จะวัดความสามารถในการประมวลผลภาพ และเปรียบเทียบประสิทธิภาพในการทำงานของซอฟต์แวร์เวอร์ชันเดียวกันบนทั้งสองระบบ

4.1.8.1 กระบวนการทดสอบ

a) การใช้งานทรัพยากรเครื่องในการประมวลผลบนไฟล์วิดีโอ

เพื่อที่จะวัดการใช้ทรัพยากรเครื่องในการประมวลผล ซอฟต์แวร์จะถูกรันโดยระบุจำนวนหน่วยประมวลผล (CPU core) และจำนวนหน่วยประมวลผลกราฟิกที่จะใช้ ทีมวิจัยใช้ไฟล์วิดีโอเดียวกันในการทดสอบทั้งบนหน่วยประมวลผลส่วนหน้า และ คลาวด์ รูปที่ 154 แสดงตัวอย่างเฟรมจากวิดีโอที่ใช้ในการทดสอบ




รูปที่ 154 ตัวอย่างเฟรมจากวิดีโอที่ใช้ในการทดสอบและผลลัพธ์จากไลบรารี OpenPose ไม่มีการตามรอยและแยกแยะประเภทท่าทาง

b) อัตราการประมวลผลภาพผ่านการเชื่อมต่อเครือข่าย

ในการทดสอบนี้ทีมวิจัยใช้ซอฟต์แวร์ชุดเดียวกันและรันซอฟต์แวร์โดยระบุจำนวนหน่วยประมวลผล (CPU core) และจำนวนหน่วยประมวลผลกราฟิกเช่นเดียวกันกับการทดสอบ a) แต่ใน

การทดสอบนี้จะใช้การประมวลผลบนวิดีโอสตรีมจากกล้อง IP เป็นหลักโดยวัดอัตราการประมวลผล ภาพบนวิดีโอสตรีมที่มีความละเอียดเท่ากันในแต่ละการทดสอบเปรียบเทียบ รูปที่ 155 แสดงตัวอย่างเฟรมจากวิดีโอสตรีมที่ใช้ในการทดสอบ



รูปที่ 155 ตัวอย่างเฟรมจากวิดีโอสตรีมที่ใช้ในการทดสอบและผลลัพธ์จากซอฟต์แวร์ Elder Care v0.1

4.1.8.2 สภาพแวดล้อมการทดสอบ

- a) หน่วยประมวลผลส่วนหน้า (NVIDIA Jetson TX2)
 หน่วยประมวลผลส่วนหน้ามีคุณลักษณะทางเทคนิคดังต่อไปนี้
 คุณลักษณะทางเทคนิค

Operating system	Ubuntu 16.04LTS 64-bit
Memory	8 GB
CPU	ARMv8 Processor rev 3 (v8l) x 4 ARMv8 Processor rev 0 (v8l) x 2
GPU	NVIDIA Tegra X2 (nvgpu)/integrated NVIDIA Pascal GPU with 256 cuda cores
HDD	32 GB

- b) หน่วยประมวลผลกลาง (เครื่องคอมพิวเตอร์ประสิทธิภาพสูงที่ประกอบด้วยหน่วยประมวลกราฟิก)
 หน่วยประมวลผลกลางมีคุณลักษณะทางเทคนิคดังนี้

คุณลักษณะทางเทคนิค

Operating system	Ubuntu 16.04LTS 64-bit
Memory	64 GB
CPU	AMD Ryzen Threadripper 2950 (16-Core Processor 32 Threads)
GPU	2 x GeForce GTX 1080 Ti 11GB with 3584 cuda cores
HDD	500 GB

โครงการดูแลผู้สูงอายุ

4.1.8.3 ผลการทดสอบ

a) การใช้งานทรัพยากรในการประมวลผล (ประมวลผล OpenPose อย่างเดียว)
รายละเอียดผลการทดสอบแสดงในตารางที่ 50

ตารางที่ 50 ผลการทดสอบการใช้งานทรัพยากรในการประมวลผล (ประมวลผล OpenPose อย่างเดียว)

ลำดับที่	ไฟล์วิดีโอ	ความละเอียดวิดีโอ (กว้าง x สูง)	จำนวนเฟรมที่ถูกประมวลผล	หน่วยประมวลผลส่วนหน้า (Nvidia Jetson TX2)					หน่วยประมวลผลคลาวด์ (เครื่องคอมพิวเตอร์ประสิทธิภาพสูงที่ประกอบด้วยหน่วยประมวลผลกราฟิก)				
				จำนวนหน่วยประมวลผลที่ใช้ (จาก 6 CPU cores)	ค่าเฉลี่ยร้อยละการใช้งาน CPU	ค่าเฉลี่ยร้อยละการใช้งานหน่วยประมวลผลกราฟิก	ค่าเฉลี่ยอัตราการประมวลผล (เฟรมต่อวินาที)	เวลาที่ใช้ในการประมวลผลทั้งหมด (วินาที)	จำนวนหน่วยประมวลผลที่ใช้ (จาก 32 CPU cores)	ค่าเฉลี่ยร้อยละการใช้งาน CPU	ค่าเฉลี่ยร้อยละการใช้งานหน่วยประมวลผลกราฟิก GPU1/GPU2	ค่าเฉลี่ยอัตราการประมวลผล (เฟรมต่อวินาที)	เวลาที่ใช้ในการประมวลผลทั้งหมด (วินาที)
1	CH4/fast_walk/round1.mp4	1920x1080	377	1	7	99	0.6	611.73	1	3	75/81	16	28.38
2	CH4/fast_walk/round1.mp4	1920x1080	377	6	2	99	0.6	609.99	6	8	90/93	20.70	21.03

b) อัตราการประมวลผลภาพผ่านการเชื่อมต่อเครือข่ายที่แตกต่างกัน (ประมวลผล OpenPose อย่างเดียว)
 รายละเอียดผลการทดสอบแสดงในตารางที่ 51

ตารางที่ 51 อัตราการประมวลผลภาพผ่านการเชื่อมต่อเครือข่ายที่แตกต่างกัน (ประมวลผล OpenPose อย่างเดียว)

ลำดับ ที่	กล้อง IP	ความ ละเอียด วิดีโอ (กว้าง x สูง)	จำนวน hops ไป ถึง IP address ปลายทาง	หน่วยประมวลผลส่วนหน้า (Nvidia Jetson TX2)						หน่วยประมวลผลคลาวด์ (เครื่องคอมพิวเตอร์ประสิทธิภาพสูงที่ประกอบด้วย หน่วยประมวลกราฟิค)					
				จำนวน เฟรมที่ถูก ประมวลผล	จำนวน หน่วย ประมวลผล ที่ถูกใช้ (จาก 6 CPU cores)	ค่าเฉลี่ย ร้อยละ การใช้ งาน หน่วย ประมวล ผล กราฟิค	ค่าเฉลี่ย ร้อยละ การใช้ งาน หน่วย ประมวล ผล กราฟิค	ค่าเฉลี่ย อัตราการ ประมวลผล (เฟรมต่อ วินาที)	เวลาที่ใช้ ในการ ประมวลผล ทั้งหมด (วินาที)	จำนวน เฟรมที่ ถูก ประมวล ผล	จำนวน หน่วย ประมวลผล ที่ถูกใช้ (จาก 6 CPU cores)	ค่าเฉลี่ย ร้อยละ การใช้ งาน CPU	ค่าเฉลี่ย ร้อยละการ ใช้งาน หน่วย ประมวล ผลกราฟิค	ค่าเฉลี่ย อัตราการ ประมวลผล (เฟรมต่อ วินาที)	เวลาที่ใช้ ในการ ประมวลผล ทั้งหมด (วินาที)
1	AIT Cafeteria	1920x1080	2	50	1	3	99	0.6	92.03	130	1	3	68/80	15.5	8.73
1	AIT Cafeteria	1920x1080	2	50	6	3	99	0.6	90.33	320	6	8	93/93	21.5	15.18
2	AIC laboratory	1920x1080	3	78	1	3	99	0.6	139.16	120	1	3	74/64	15.9	7.84
2	AIC laboratory	1920x1080	3	78	6	3	99	0.6	138.34	260	6	8	91/94	20.3	12.94

c) การใช้งานทรัพยากรในการประมวลผล (ประมวลผลกับซอฟต์แวร์ Elder Care v0.1)
 รายละเอียดผลการทดสอบแสดงในตารางที่ 52

ตารางที่ 52 ผลการทดสอบการใช้งานทรัพยากรในการประมวลผล (ประมวลผลกับซอฟต์แวร์ Elder Care v.0.1)

ลำดับ ที่	ไฟล์วิดีโอ	ความละเอียด วิดีโอ (กว้าง x สูง)	จำนวน เฟรมที่ถูก ประมวลผล	หน่วยประมวลผลส่วนหน้า (Nvidia Jetson TX2)					หน่วยประมวลผลคลาวด์ (เครื่องคอมพิวเตอร์ประสิทธิภาพสูงที่ประกอบด้วย หน่วยประมวลผลกราฟิก)				
				จำนวนหน่วย ประมวลผลที่ ถูกใช้ (จาก 6 CPU cores)	ค่าเฉลี่ย ร้อยละ การใช้ งาน CPU	ค่าเฉลี่ยร้อย ละการใช้ งานหน่วย ประมวล ผลกราฟิก	ค่าเฉลี่ยอัตรา การ ประมวลผล (เฟรมต่อ วินาที)	เวลาที่ใช้ใน การ ประมวลผล ทั้งหมด (วินาที)	จำนวนหน่วย ประมวลผลที่ ถูกใช้ (จาก 32 CPU cores)	ค่าเฉลี่ย ร้อยละ การใช้ งาน CPU	ค่าเฉลี่ยร้อยละ การใช้งานหน่วย ประมวลผล กราฟิก GPU1/GPU2	ค่าเฉลี่ยอัตรา การ ประมวลผล (เฟรมต่อ วินาที)	เวลาที่ใช้ใน การ ประมวลผล ทั้งหมด (วินาที)
1	CH4/fast_walk/round1.mp4	1920x1080	377	1	12	99	2.80	146.25	1	3	62/2	7.91	48.14
2	CH4/fast_walk/round1.mp4	1920x1080	377	6	15	99	3.09	125.50	6	12	65/1	7.86	47.53

d) อัตราการประมวลผลภาพผ่านการเชื่อมต่อเครือข่ายที่แตกต่างกัน (ประมวลผลกับซอฟต์แวร์ Elder Care v0.1)
 รายละเอียดผลการทดสอบแสดงในตารางที่ 53

ตารางที่ 53 อัตราการประมวลผลภาพผ่านการเชื่อมต่อเครือข่ายที่แตกต่างกัน (ประมวลผลกับซอฟต์แวร์ Elder Care v0.1)

ลำดับที่	กล้อง IP	ความละเอียดวิดีโอ (กว้าง x สูง)	จำนวน hops ไปถึง IP address ปลายทาง	หน่วยประมวลผลส่วนหน้า (Nvidia Jetson TX2)						หน่วยประมวลผลคลาวด์ (เครื่องคอมพิวเตอร์ประสิทธิภาพสูงที่ประกอบด้วยหน่วยประมวลผลกราฟิก)					
				จำนวนเฟรมที่ถูกประมวลผล	จำนวนหน่วยประมวลผลที่ใช้ (จาก 6 CPU cores)	ค่าเฉลี่ยร้อยละการใช้งาน CPU	ค่าเฉลี่ยร้อยละการใช้งานหน่วยประมวลผลกราฟิก	ค่าเฉลี่ยอัตราการประมวลผล (เฟรมต่อวินาที)	เวลาที่ใช้ในการประมวลผลทั้งหมด (วินาที)	จำนวนเฟรมที่ถูกประมวลผล	จำนวนหน่วยประมวลผลที่ใช้ (จาก 6 CPU cores)	ค่าเฉลี่ยร้อยละการใช้งาน CPU	ค่าเฉลี่ยร้อยละการใช้งานหน่วยประมวลผลกราฟิก	ค่าเฉลี่ยอัตราการประมวลผล (เฟรมต่อวินาที)	เวลาที่ใช้ในการประมวลผลทั้งหมด (วินาที)
1	AIT Cafeteria	1920x1080	3	102	1	13	99	2.4	42.38	99	1	3	46/2	7.02	14.25
1	AIT Cafeteria	1920x1080	3	102	6	16	99	2.5	40.40	93	6	4	49/3	6.78	13.74
2	AIC laboratory	1920x1080	2	51	1	16	99	3.2	15.81	100	1	3	40/2	6.26	16.50
2	AIC laboratory	1920x1080	2	51	6	16	99	3.3	15.58	107	6	4	42/1	6.53	15.83

4.1.9 ผลลัพธ์การประเมินผลการใช้งานระบบ

4.1.9.1 การประเมินโดยนักกายภาพบำบัดจากมหาวิทยาลัยมหิดล

ผลการประเมินระบบโดยนักกายภาพบำบัด จากมหาวิทยาลัยมหิดล ให้ความเห็นว่าระบบที่พัฒนาขึ้นเป็นประโยชน์ในการช่วยเหลือสมาชิกในครอบครัวหรือผู้ดูแลผู้สูงอายุในสภาพสังคมปัจจุบัน ผลจากการประมวลผลภาพใช้ภาพจากกล้องวงจรปิดในการประมวลผลและติดตามการเคลื่อนไหว และสามารถแยกแยะประเภทท่าทางต่าง ๆ ของผู้สูงอายุได้ รวมถึงสามารถตรวจจับการเคลื่อนไหวที่ไม่มั่นคงและการหกล้มซึ่งท้ายที่สุดจะนำมาซึ่งปัญหาสุขภาพ เช่น การเจ็บปวด กระดูกแตกหัก หรือ ผิดรูป และต้องการการดูแลรักษา นอกจากนี้ระบบยังสามารถส่งการแจ้งเตือนทางแอปพลิเคชัน LINE ในกรณีที่เกิดการหกล้ม และตรวจนับจำนวนท่าทางต่าง ๆ เช่น นั่ง ยืน เดิน และอื่น ๆ ตามช่วงเวลาที่กำหนด ซึ่งข้อมูลจากระบบเหล่านี้สามารถนำมาใช้เป็นข้อมูลสำคัญในการวางแผนอีกระดับทางด้านสาธารณสุขและการส่งเสริม ในด้านความปลอดภัยของข้อมูลระบบให้ผู้ใช้งานล็อกอินการใช้งานก่อนเข้าสู่ข้อมูล ระบบสามารถตรวจจับเหตุการณ์ต่าง ๆ ได้แม่นยำ และสามารถแสดงผลจากแต่ละกล้อง อย่างไรก็ตามความน่าเชื่อถือและความแม่นยำของระบบอาจต้องการตรวจสอบให้มากขึ้น การเก็บรวบรวมข้อมูลจากกล้องแต่ละกล้องเข้าสู่กระบวนการประมวลผลมีความสำคัญในการเพิ่มความแม่นยำของระบบ ในมุมมองทางด้านสาธารณสุขการใช้เทคโนโลยีปัญญาประดิษฐ์ที่ทันสมัยในการช่วยเหลือการดูแลผู้สูงอายุเป็นสิ่งจำเป็น ดังนั้นจึงมีความสำคัญในการพัฒนาและปรับปรุงประสิทธิภาพระบบเพื่อช่วยเหลือผู้สูงอายุ นอกเหนือจากการใช้ระบบในการเฝ้าดูผู้สูงอายุ ระบบสามารถนำไปพัฒนาและประยุกต์ใช้เพื่อเสริมการทำงานร่วมกับโปรแกรมกายภาพบำบัดทางไกล (remote physical therapy program) ในอนาคตได้


4.1.9.2 การประเมินผลโดยกลุ่มตัวแทนจากบ้านอาสาสมัครผู้ติดตั้งระบบ และ ผู้ที่สนใจระบบ

ผลการประเมินการทดสอบใช้งานระบบมีรายละเอียดดังนี้

1) จำนวนสมาชิกในครอบครัวทั้งหมดที่พักอาศัยอยู่ด้วยกัน

สัดส่วนจำนวนสมาชิกในครอบครัว (แกนนอน) และจำนวนผู้ประเมิน (แกนตั้ง)


แสดงในรูปที่ 156



รูปที่ 156 สัดส่วนจำนวนสมาชิกในครอบครัวของผู้ประเมินระบบ

2) จำนวนผู้สูงอายุที่พักอาศัยอยู่ในบ้าน

สัดส่วนจำนวนผู้สูงอายุที่มีอายุมากกว่า 60 ปี ที่พักอาศัยอยู่ในบ้าน (แกนนอน) และจำนวนผู้ประเมิน (แกนตั้ง) แสดงในรูปที่ 157



รูปที่ 157 สัดส่วนจำนวนผู้สูงอายุที่มีอายุมากกว่า 60 ปี ที่พักอาศัยอยู่ในบ้านของผู้ประเมิน


3) วัตถุประสงค์การใช้ระบบ และความถี่ในการใช้งาน

วัตถุประสงค์การใช้งานของผู้ประเมินระบบแบ่งออกเป็น 2 กลุ่ม คือ

- ติดตามดูพฤติกรรมคนในบ้านรวมถึงผู้สูงอายุ หากเกิดความผิดปกติจะได้แก้ไข
ปัญหาได้ทัน
- ตรวจสอบข้อมูลเฉพาะการเดินทางและการล้มในแต่ละสัปดาห์

4) หน้าเว็บแอปพลิเคชันที่ผู้ประเมินใช้งานบ่อยครั้งที่สุด

สัดส่วนการใช้งานหน้าเว็บแอปพลิเคชันที่ผู้ใช้งานใช้บ่อยครั้งมากที่สุด คือ หน้าดูข้อมูลสถิติ (Activity summary) คิดเป็น 37.5% ส่วนหน้าที่เหลือที่ผู้ประเมินใช้งานบ่อยได้แก่ หน้าการแจ้งเตือน (Alert notifications) หน้าการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง (Unstable movement detections) หน้าการตรวจจับการหกล้ม (Fall detections) หน้าการตรวจจับกิจกรรมต่าง ๆ (Activity analysis) และ หน้ากล้อง (Camera) ทั้ง 5 หน้า คิดเป็นสัดส่วนเท่ากัน 12.5% ดังแสดงในรูปที่ 158



รูปที่ 158 แสดงสัดส่วนหน้าเว็บแอปพลิเคชันที่มีการใช้งานบ่อย

5) ระยะเวลาในการใช้งานระบบ

ผู้ประเมินใช้งานระบบเป็นระยะเวลาแตกต่างกัน โดยแบ่งออกเป็น 2 กลุ่ม กลุ่มผู้ประเมินที่ใช้ระยะเวลาในการใช้งานระบบเว็บแอปพลิเคชันน้อยกว่า 5 นาที จำนวน 4 คน และใช้เวลา 10-15 นาที จำนวน 2 คน และ 30 นาที 1 คน และไม่ระบุระยะเวลา 1 คน

6) ความกังวลก่อนเริ่มใช้งานระบบ

ความกังวลของผู้ประเมินก่อนใช้งานระบบ แบ่งออกเป็นกลุ่ม ๆ ดังนี้

- เรื่องความเป็นส่วนตัวของข้อมูล และความปลอดภัยของข้อมูล
- ความแม่นยำของระบบ และการทำงานผิดพลาด
- ความยากง่ายในการใช้งานระบบเพื่อดูข้อมูลการตรวจจับ
- ไม่มี ความกังวลในการใช้งาน

7) ความรู้สึกหลังจากใช้งานระบบ

ความรู้สึกหลังจากผู้ประเมินได้ทดลองใช้งานระบบ มีรายละเอียดดังต่อไปนี้

- ความรู้สึกเชิงบวก
 - มีข้อมูลที่สามารถเรียกดูย้อนหลัง
 - รู้สึกสะดวกและไม่ต้องคอยกังวลว่าจะเกิดอุบัติเหตุกับผู้สูงอายุที่บ้าน
 - มีฟังก์ชันการใช้งานที่น่าสนใจมากกว่าที่คิดไว้ เช่น กราฟสรุปกิจกรรมรายบุคคล การเลือกเวลาที่เฉพาะเจาะจงในการเฝ้าระวัง
 - มีความแตกต่างจากระบบอื่น เนื่องจากมีการแสดงบันทึกกิจกรรมการที่ตรวจพบของผู้สูงอายุที่บ้านไว้คอยดู
 - ระบบมีประโยชน์ แต่การหาข้อมูลที่เป็นประโยชน์ใช้ระยะเวลานานในการค้นหา
- ความรู้สึกเชิงลบ
 - การโหลดหน้าเว็บช้า ไม่สามารถดูวิดีโอได้ ดูได้แต่ภาพนิ่ง

- ยังคงกังวลเรื่องความแม่นยำของการตรวจจับการเคลื่อนไหวผิดปกติ และการหลอ้

8) สิ่งแรกที่ทำเมื่อเข้าสู่ระบบ

สิ่งแรกที่ผู้ประเมินทำเมื่อเข้าสู่ระบบ แบ่งออกเป็นกลุ่ม ๆ ดังนี้

- ดูข้อมูลสรุปภาพรวมการตรวจจับ (Activity summary)
- เช็คข้อมูลการตรวจจับท่าทาง (Activity detections)
- ดูหน้าการแจ้งเตือน (Alert notifications)
- ดูหน้ากล้อง

9) ความคิดเห็นต่อการทำงานของระบบตรวจจับและแจ้งเตือนการเคลื่อนไหวที่ผิดปกติ และการหลอ้ และระบบใช้งานง่ายหรือไม่

ความคิดเห็นจากผู้ประเมิน แบ่งออกเป็น 2 กลุ่ม มีรายละเอียดดังนี้

- ความคิดเห็นเชิงบวก
 - ในด้านการแจ้งเตือนทำให้การช่วยเหลือสามารถทำได้ทันท่วงที และมีการแยกการแสดงผลแยกกันสำหรับการหลอ้และการเดินไม่ปกติ
 - ใช้งานง่าย
- ความคิดเห็นเชิงลบ
 - ยังใช้งานไม่ค่อยสะดวก
 - การแสดงรูปภาพทำให้เข้าใจได้ยาก หากสามารถแสดงเป็นคลิปวิดีโอจะสามารถเข้าใจได้ง่ายกว่า

10) ความคิดเห็นเกี่ยวกับวิธีการจัดวางและแสดงข้อมูลของระบบ

ความคิดเห็นจากผู้ประเมิน แบ่งออกเป็น 2 กลุ่ม มีรายละเอียดดังนี้

- ความคิดเห็นเชิงบวก
 - เป็นไปตามมาตรฐานของเว็บทั่วไป
 - ส่วนแสดงผลเข้าใจง่ายชัดเจน ใช้งานง่าย เข้าใจง่าย ดูข้อมูลได้ง่าย
- ความคิดเห็นเชิงลบ
 - มีปุ่มให้คลิกมากเกินไป
 - บางหน้าอาจไม่จำเป็น เช่น หน้าแสดงผลเวลาไม่มีคนอยู่

11) ระบบส่วนที่ใช้งานน้อยที่สุด

รายละเอียดของระบบส่วนที่ผู้ประเมินใช้งานน้อยที่สุด มีดังนี้

- ข้อมูลสถิติที่เก็บย้อนหลังไว้นานมาก ๆ
- หน้าแสดงผลเวลาไม่มีคนอยู่
- หน้าตั้งค่ากล้อง
- หน้าตั้งค่าการใช้งาน
- หน้าตั้งค่าสมาชิกในครอบครัว

12) ความคิดเห็นเกี่ยวกับการจัดวางและแสดงข้อมูลของเว็บแอปพลิเคชัน
ความคิดเห็นจากผู้ประเมิน แบ่งออกเป็น 3 กลุ่ม มีรายละเอียดดังนี้

- ความคิดเห็นเชิงบวก
 - ใช้งานง่าย
- ความคิดเห็นเชิงลบ
 - การแสดงผลภาพเล็กไป
 - หน้ารวมข้อมูลสถิติดูยาก
- ข้อเสนอแนะ
 - ควรมีเฟรมภาพหรือคลิปวิดีโอสั้น ๆ ประกอบ
 - การแสดงข้อความอาจทดแทนได้ด้วยการ
 - มีข้อมูลบางส่วนที่น่าเสนอออกมาไม่น่าสนใจ เช่น ถ้ามีรูปภาพหรือไอคอน จะทำให้ข้อมูลดูน่าสนใจมากขึ้น

13) สิ่งที่ทำให้ติดขัดในการใช้งานระบบ

ผู้ประเมินส่วนใหญ่ไม่มีสิ่งที่ทำให้ติดขัดในการใช้งาน แต่มีผู้ประเมินบางส่วนมีสิ่งที่ทำให้ผู้ประเมินติดขัดในการใช้งานระบบ แบ่งออกเป็น 2 กลุ่ม มีรายละเอียดดังต่อไปนี้

- หน้าเว็บแอปพลิเคชันโหลดช้าในบางครั้ง
- การแสดงผลการตรวจจับไม่สามารถรู้ได้โดยง่ายว่าเกิดการตรวจจับ ณ ช่วงเวลาใดบ้าง การแสดงผลในรูปแบบของไทม์ไลน์ อาจจะช่วยให้เห็นการมีข้อมูลการตรวจจับว่าเกิดขึ้นในช่วงเวลาใดได้ง่าย

14) สิ่งที่ผู้ประเมินอยากเปลี่ยนแปลงสิ่งหนึ่งในระบบหากสามารถเปลี่ยนแปลงได้ และสาเหตุของการเปลี่ยนแปลง

ผู้ประเมินระบุการเปลี่ยนแปลงที่อยากเปลี่ยนแปลงระบบที่ทดสอบใช้งาน มีรายละเอียดดังนี้

- การแสดงข้อมูลสถิติ เนื่องจากการแสดงผลใช้แผนภูมิเส้น ทำให้ดูไม่น่าสนใจ หากมีไอคอนประกอบ หรือภาพประกอบจะทำให้การแสดงผลน่าสนใจกว่านี้
- การแสดงผลการตรวจจับ เนื่องจากผู้ประเมินอยากให้มีคลิปวิดีโอสั้น ๆ ประกอบการใช้งาน
- การรวบรวมผลการตรวจจับเพื่อแสดงผลให้มีความน่าสนใจดึงดูด และง่ายต่อการวิเคราะห์
- การแสดงวิดีโอสตรีม
- ระบบแอปพลิเคชันบนมือถือ เพื่อให้ผู้ใช้งานสามารถเข้าใช้งานได้โดยตรงโดยไม่ต้องใช้เว็บเบราว์เซอร์
- ระบบสามารถประเมินพฤติกรรมรายบุคคลได้ว่าใครเริ่มมีพฤติกรรมที่เปลี่ยนแปลงไปหรือไม่ปกติ

15) สิ่งที่ทำให้ผู้ประเมินรู้สึกตื่นเต้น และสาเหตุ

สิ่งที่ทำให้ผู้ประเมินรู้สึกตื่นเต้นกับระบบ มีรายละเอียดดังต่อไปนี้

- ระบบสามารถแจ้งเตือนไปยังแอปพลิเคชัน LINE ได้ ทำให้ไม่ต้องคอยตรวจสอบจากหน้าเว็บไซต์
- ความสามารถในการประมวลผลภาพของระบบและการใช้เทคโนโลยีปัญญาประดิษฐ์
- การตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

16) ผู้ใช้งานจะใช้ระบบนี้ต่อไปหรือไม่ และสาเหตุที่จะทำให้ผู้ใช้งานหยุดใช้ระบบนี้ในอนาคต


ผู้ประเมินทั้งหมดใช้งานต่อ มีผู้ประเมินบางส่วนให้เหตุผลการใช้งานต่อโดยมีรายละเอียดดังต่อไปนี้

- ใช้งานต่อเฉพาะบางส่วน เช่น ดูกล้องและการแจ้งเตือนสำหรับบางกิจกรรมที่ต้องการเท่านั้น
- ใช้งานต่อถ้าได้ผลลัพธ์การแจ้งเตือนที่ดี หากมีการแจ้งเตือนผิดพลาดจำนวนมาก อาจจะทำให้ผู้ใช้งานเลิกสนใจการแจ้งเตือน

และมีข้อเสนอแนะด้านการมีแอปพลิเคชันบนโทรศัพท์มือถือ เหมือนกล้องวงจรปิดที่มีแอปพลิเคชันสำหรับดูกล้องและแจ้งเตือนการตรวจจับการเคลื่อนไหว

17) การให้คะแนนความพึงพอใจของระบบ

สัดส่วนคะแนนความพึงพอใจ จากคะแนนน้อยที่สุด 1 ไปถึงคะแนนมากที่สุด 10 (แกนนอน) และ จำนวนผู้ประเมินในแต่ละคะแนน (แกนตั้ง) โดยคะแนนโดยรวมความพึงพอใจเฉลี่ยอยู่ที่ 8.25 คะแนน รายละเอียดแสดงในรูปที่ 159



รูปที่ 159 ผลประเมินคะแนนความพึงพอใจในการทดสอบใช้งานระบบจากผู้ประเมิน

4.1.9.3 สรุปการประเมินผลการใช้งานระบบ

ผลการประเมินโดยผู้ประเมินจากทั้งสองกลุ่มผู้เข้าร่วมการอบรม เห็นว่าระบบมีประโยชน์ในการใช้เฝ้าดูผู้สูงอายุหรือสมาชิกในครอบครัว โดยเฉพาะการตรวจจับการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคง รวมถึงการแจ้งเตือนไปยังแอปพลิเคชัน LINE ซึ่งเป็นประโยชน์ในการช่วยให้สังเกตเห็นความผิดปกติได้แต่เนิ่น ๆ และสามารถแจ้งผู้ดูแลหรือสมาชิกในครอบครัวได้ทันที่ สำหรับประโยชน์ด้านสาธารณสุข ระบบสามารถนำไปประยุกต์ใช้และพัฒนาเพิ่มเติมเพื่อใช้ในโปรแกรมกายภาพบำบัดทางไกลในการดูแลผู้ป่วย อย่างไรก็ตามทั้งสองกลุ่มผู้ประเมินให้ความกังวลในเรื่องความแม่นยำของ

ระบบซึ่งอาจจะต้องมีการศึกษาเพิ่มเติม สำหรับในมุมมองผู้ใช้งานผู้ใช้งานส่วนใหญ่จะดูข้อมูลจากหน้าสรุปรวมกิจกรรมต่าง ๆ ที่ตรวจพบ และให้ความเห็นว่าระบบใช้งานง่าย แต่ยังมีส่วนที่สามารถปรับปรุงได้อีก เช่น การแสดงผลการตรวจจับควรมีข้อมูลเป็นคลิปวิดีโอประกอบ หรือการพัฒนาแอปพลิเคชันบนโทรศัพท์มือถือ เพื่อให้ใช้งานได้ง่าย รวมถึงการแสดงผลในรูปแบบใหม่ไลน์อาจทำให้การหาข้อมูลเข้าใจง่ายมากขึ้น นอกจากนี้จากผลการประเมินพบว่าผู้ประเมินกล่าวถึงเรื่องการทำงานบางรูปแบบซึ่งอาจไม่จำเป็นในการใช้งานจริง เช่น การแสดงผลเมื่อไม่มีคนอยู่ในช่วงเวลาที่กำหนด (absence detection) รวมถึงการตั้งค่ากล้อง และตั้งค่าสมาชิกในครอบครัว ซึ่งหน้าเหล่านี้เป็นหน้าเว็บที่เข้าใช้งานไม่บ่อย สำหรับคะแนนความพึงพอใจในการใช้ระบบจากผู้ประเมินผลทั้งหมด 8 คน ไม่รวมนักกายภาพบำบัดจากมหาวิทยาลัย 2 คน มีคะแนนความพึงพอใจเฉลี่ยอยู่ที่ 8.5 คะแนน ความคิดเห็นและข้อเสนอแนะต่าง ๆ จากการประเมินผลระบบนี้สามารถนำไปพัฒนาต่อยอดในอนาคต เพื่อให้ระบบมีความสมบูรณ์ และตอบสนองความต้องการของผู้ใช้งาน

4.1.10 สรุปผลความแม่นยำของระบบ

สรุปผลความแม่นยำของระบบเมื่อเทียบกับเป้าหมายที่กำหนดไว้มีรายละเอียดดังแสดงในตารางที่ 54

ตารางที่ 54 ความแม่นยำของระบบเทียบกับเป้าหมาย

ระบบ	เป้าหมาย	ความแม่นยำที่ได้
การแยกแยะประเภทท่าทาง	ความแม่นยำ 80%	91.59% จาก 10 กิจกรรม
การตรวจจับการหกล้ม	ความแม่นยำ 95%	95.00%
การตรวจจับการเคลื่อนไหวที่ไม่มั่นคง	ความแม่นยำ 95%	97.02%
การระบุตัวตน	ความแม่นยำ 80%	85.71% จากผู้ร่วมอาศัย 5 คนในบ้าน

4.1.11 ประโยชน์จากการใช้งานจริง

จากการติดตั้งและทดสอบใช้งานระบบในบ้านอาสาสมัครที่มิวิจัยพบว่าระบบสามารถแยกแยะประเภทท่าทางต่าง ๆ ได้ โดยหากพิจารณาจากการประเมินผลความแม่นยำของระบบพบว่าความแม่นยำในการแยกแยะประเภทท่าทางทั้ง 10 ประเภท มีความแม่นยำอยู่ที่ 91.59% หากพิจารณาเฉพาะความแม่นยำในการแยกแยะประเภทท่าทางการหกล้มอยู่ที่ 95.00% สำหรับการแยกแยะการเคลื่อนไหวที่ไม่มั่นคงมีความแม่นยำอยู่ที่ 97.02% ซึ่งมีความแม่นยำเพียงพอในการใช้งานจริงสำหรับมุมมองที่เหมาะสม ในส่วนของการดำเนินงานตั้งแต่ระบบประมวลผลภาพของอุปกรณ์การส่งข้อมูลมายังระบบประมวลผลคลาวด์ และการแจ้งเตือนเมื่อตรวจพบการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคง ระบบดูแลผู้สูงอายุทั้งอุปกรณ์ประมวลผลส่วนหน้า ระบบคลาวด์สำหรับประมวลผลวิเคราะห์การเคลื่อนไหวของร่างกาย และระบบเว็บแอปพลิเคชัน สามารถทำงานร่วมกันได้อย่างสมบูรณ์ และสามารถส่งข้อมูลการแจ้งเตือนได้แบบเรียลไทม์ในกรณีที่ตรวจพบการหกล้ม

หรือการเคลื่อนไหวแบบไม่มั่นคง ซึ่งจะเป็นประโยชน์ต่อสมาชิกในครอบครัวหรือผู้ดูแลให้สามารถสังเกตความผิดปกติได้แต่เนิ่น ๆ หรือให้การช่วยเหลือได้ทันเวลาที่ระบบที่วิจัยและพัฒนาขึ้นนี้สามารถนำไปวิจัยและพัฒนาต่อยอดเพื่อใช้ประโยชน์ในเชิงพาณิชย์ได้ รวมถึงสามารถนำไปประยุกต์ใช้งาน ในด้านกายภาพบำบัดและดูแลผู้ป่วย

4.1.12 รายงานสรุปผลในส่วนเป้าหมายที่อาจไม่สามารถบรรลุผลตามที่วางแผนไว้

ทีมวิจัยได้ดำเนินการวิจัยและพัฒนาบรรลุตามแผนที่วางไว้ทั้งหมด ดังแสดงในตารางที่ 55
 ตารางที่ 55 สถานะการดำเนินการกิจกรรมที่สำคัญ

ลำดับ	กิจกรรมที่สำคัญ	น้ำหนัก (%)	สถานะการดำเนินการ	รายละเอียดการดำเนินการ
1	พัฒนาต้นแบบอุปกรณ์เฝ้าดูวิถีโอแบบ IoT (Internet of Things) สำหรับดูแลผู้สูงอายุ	15	เสร็จสิ้น	<p>ทีมวิจัยได้ออกแบบและพัฒนาระบบต้นแบบโดยมีรายละเอียดดังต่อไปนี้</p> <ul style="list-style-type: none"> - ระบบประมวลผลแบบ edge-cloud ประกอบด้วยอุปกรณ์ประมวลผลแบบ edge ทำงานร่วมกับระบบคลาวด์ โดยทำการประมวลผลจากกล้อง IP และส่งข้อมูลไปยังระบบคลาวด์เพื่อประมวลผลวิเคราะห์เพิ่มเติมสำหรับการแยกแยะท่าทาง ตรวจสอบการล้ม ตรวจสอบการเคลื่อนไหวที่ไม่มั่นคง - ระบบประมวลผลแบบ edge จะเชื่อมต่อกับอินเทอร์เน็ตเร้าท์เตอร์ของผู้ใช้งานเพื่อส่งข้อมูลมายังระบบคลาวด์ - ระบบประมวลผลแบบ edge จะรันระบบประมวลผลภาพตลอดเวลาเพื่อทำการตรวจจับและตามรอยบุคคลและดึงข้อมูลจุดโครงร่างของร่างกายเพื่อส่งไปยังระบบคลาวด์เพื่อใช้ในการประมวลผลในการแยกแยะประเภทท่าทาง และการเคลื่อนไหวที่ไม่มั่นคง - ระบบถูกติดตั้งในบ้านอาสาสมัครโดยไม่ละเมิดความเป็นส่วนตัวของผู้ใช้งาน
2	พัฒนาโมดูลการตรวจจับบุคคล ตามรอย และรู้จำรูปแบบกิจกรรมหรือพฤติกรรม	15	เสร็จสิ้น	<p>ทีมวิจัยได้พัฒนาอัลกอริทึมสำหรับตรวจจับ ตามรอย และรู้จำบุคคลโดยมีรายละเอียดดังต่อไปนี้</p> <ul style="list-style-type: none"> - ระบบประมวลผลแบบ edge ทำการตรวจจับบุคคลโดยใช้ไลบรารี OpenPose หรือ TRT-Pose (โดยทำการขยายกรอบล้อมรอบตัวบุคคลจากจุดโครงร่างของ

				<p>ร่างกายที่ตรวจจับได้) และทำการตามรอยโดยใช้อัลกอริทึม Intersection over union (IOU) หรือ DeepSORT</p> <p>- สำหรับการแยกแยะประเภทท่าทางของแต่ละบุคคล ทีมวิจัยได้พัฒนาโมดูลสำหรับการรู้จำใบหน้าบุคคลซึ่งประกอบด้วย</p> <ul style="list-style-type: none"> • การตรวจจับใบหน้า • การจัดตำแหน่งใบหน้าโดยใช้อัลกอริทึม MTCNN • การรู้จำใบหน้าบุคคลโดยใช้อัลกอริทึม Facenet <p>- โมดูลการแยกแยะประเภทท่าทาง</p> <p>- โมดูลการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง</p>
3	พัฒนาโมดูลการตรวจจับคนล้มและโมดูลการสรุปกิจกรรม	10	เสร็จสิ้น	<p>- ทีมวิจัยพัฒนาโมดูลการตรวจจับการหกล้มและการสรุปรวมประเภทท่าทางที่ตรวจพบ</p> <p>- สำหรับการแยกแยะประเภทท่าทาง ทีมวิจัยได้พัฒนาอัลกอริทึมหลัก 3 อัลกอริทึม ได้แก่</p> <ol style="list-style-type: none"> 1) การแยกแยะประเภทท่าทางแบบทีละเฟรม (framewise activity classification) 2) การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่น (Cascaded framewise activity classification) 3) การแยกแยะประเภทท่าทางโดยใช้ Long Short-Term Memory (LSTM) เพื่อแยกแยะประเภทท่าทางทั้งหมด 10 ประเภท คือ ยืน เดิน ก้ม เดิน ล้ม ซู้ โบกมือ คู้โทรศัพท์ ดูนาฬิกา ปรบมือ <p>- การแยกแยะประเภทท่าทางโดยใช้อัลกอริทึมการแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่นให้ความแม่นยำสูงสุดในชุดข้อมูลที่ใช้ในการประเมินผล</p>

4	พัฒนาการจัดเก็บข้อมูลด้วยระบบคลาวด์ และเฟรมเวิร์คสำหรับการวิเคราะห์ข้อมูลบนคลาวด์	15	เสร็จสิ้น	<p>- ประเภททำทางในแต่ละเฟรมถูกรวบรวมและสรุปโดยใช้ majority vote</p> <p>- ทีมวิจัยพัฒนา RESTful web services เพื่อใช้ในการรับข้อมูลที่ส่งมาจากอุปกรณ์ประมวลผลแบบ edge เมื่อ RESTful web services ได้รับข้อมูลจะทำการบันทึกข้อมูลลงไปยังระบบฐานข้อมูลและส่งข้อมูลไปยังระบบประมวลผลส่วนหลังซึ่งได้แก่ การแยกแยะประเภททำทาง การรู้จำใบหน้าบุคคล และการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง เมื่อการประมวลผลในระบบส่วนหลังเสร็จสิ้นข้อมูลทั้งหมดจะถูกรวบรวมและอัปเดตข้อมูลในระบบฐานข้อมูลเพื่อใช้ในการแสดงผลบนเว็บแอปพลิเคชัน</p> <p>- ในกรณีที่ระบบตรวจจับการหกล้มหรือการเคลื่อนไหวที่ไม่มั่นคงได้ ระบบจะสร้างการแจ้งเตือนผ่านโดยสร้างข้อความแจ้งเตือนและเรียกไปยังระบบ LINE Notificaiton API เพื่อส่งข้อมูลไปยังสมาชิกในครอบครัว ผู้ดูแลผู้สูงอายุ ในกรณีที่ระบบไม่ตรวจพบการอยู่อาศัยในช่วงเวลาที่ผู้ใช้งานกำหนดระบบจะทำการส่งข้อความแจ้งเตือนเช่นกัน สำหรับการตรวจพบทำทางประเภทอื่น ๆ จะถูกบันทึกข้อมูลลงในฐานข้อมูลและรวบรวมเพื่อแสดงผลการตรวจพบทำทางต่าง ๆ ของแต่ละบุคคลในครอบครัว</p>
5	แยกแยะลักษณะที่สามารถมองเห็นได้ที่เป็นสัญญาณของการเคลื่อนไหวที่มีลักษณะของความเจ็บปวด ความไม่มั่นคง และความไม่ปกติที่จะนำไปสู่การล้มหรืออุบัติเหตุอื่น ๆ	15	เสร็จสิ้น	<p>- ทีมวิจัยได้เก็บรวบรวมชุดข้อมูลหลากหลายชุดข้อมูลจากแหล่งต่าง ๆ รวมถึงเก็บข้อมูลในห้องปฏิบัติการมหาวิทยาลัยมหิดล และสถาบันเทคโนโลยีแห่งเอเชีย บ้านอาสาสมัคร โดยมีรายละเอียดดังนี้</p> <p>1) ชุดข้อมูลมหาวิทยาลัยมหิดล (Mahidol dataset) เก็บข้อมูลจากอาสาสมัครผู้สูงอายุในห้องปฏิบัติการคณะกายภาพบำบัด มหาวิทยาลัยมหิดลโดยมีอาสาสมัครผู้สูงผู้ที่เคยหกล้มและไม่เคยหกล้มร่วมเก็บข้อมูล</p> <p>2) ชุดข้อมูลหกล้มมหาวิทยาลัยมหิดล (Mahidol fall dataset) เก็บข้อมูลใน</p>

			<p>ห้องปฏิบัติการคณะกายภาพบำบัด มหาวิทยาลัยมหิดล โดยให้อาสาสมัคร คนวัยหนุ่มจำลองการหกล้มเพื่อเก็บข้อมูลท่าทางการหกล้ม</p> <p>3) ชุดข้อมูล AIC-360 ซึ่งเก็บข้อมูล ในห้องปฏิบัติการ สถาบันเทคโนโลยีแห่งเอเชีย โดยให้อาสาสมัครเก็บข้อมูลในห้องปฏิบัติการที่มีการ ติดตั้งกล้องทั้งหมดจำนวน 8 ตัวครอบคลุมมุม 360 องศารอบตัวบุคคล โดยอาสาสมัครทำท่าทางต่าง ๆ 10 ท่าทาง รวมถึงการจำลองการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบต่าง ๆ</p> <p>4) ชุดข้อมูล AIC-Volunteer1-set1 ซึ่งเก็บข้อมูลจากบ้านอาสาสมัครในจังหวัด กรุงเทพมหานคร โดยอาสาสมัคร ทำท่าทางต่าง ๆ 10 ท่าทาง รวมถึงการจำลองการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบ ต่าง ๆ</p> <p>5) ชุดข้อมูล AIC-Volunteer1-set2 ซึ่งเก็บข้อมูลจากบ้านอาสาสมัครเดียวกันกับชุดข้อมูล AIC-Volunteer1-set1 โดยอาสาสมัคร ทำท่าทางต่าง ๆ 10 ท่าทาง รวมถึงการจำลองการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบต่าง ๆ ข้อมูลชุดนี้ใช้เป็นชุดข้อมูล สำหรับการประเมินความแม่นยำของโมเดลที่ทีมวิจัยเทรน นอกจากนี้ทีมวิจัยยังปรึกษาทีมผู้เชี่ยวชาญจากคณะกายภาพบำบัด มหาวิทยาลัยมหิดลในการระบุข้อบ่งชี้ของการเคลื่อนไหวที่ไม่มั่นคงซึ่งอาจนำไปสู่การหกล้มได้</p>	
6	พัฒนาอัลกอริทึมคอมพิวเตอร์วิทัศน์เพื่อระบุลักษณะของการเคลื่อนไหวที่ไม่มั่นคงตามทีระบุข้างต้น	15	เสร็จสิ้น	<p>- ทีมวิจัยได้พัฒนาอัลกอริทึมใหม่ที่ใช้เทคนิค LSTM RNN ในการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง โดยอัลกอริทึมที่เสนอถูกทดสอบบนชุดข้อมูลจำลองการเคลื่อนไหวที่ไม่มั่นคง 5 ประเภท ได้แก่ การล้มลง การเคลื่อนไหวแบบไม่มั่นคงจากอาการหัวใจวาย การเคลื่อนไหวแบบไม่มั่นคงจากการเวียนศีรษะ และการเคลื่อนไหวแบบไม่มั่นคงภายหลังจากการสะดุดหรือลื่นล้ม</p>

7	<p>ประเมินผลลัพธ์ต้นแบบโมดูลของฮาร์ดแวร์ และซอฟต์แวร์ที่ใช้ในสถานการณ์จริง</p> <p>อบรมผู้ใช้งานระบบและนำเสนอระบบให้กับ ผู้ที่สนใจหรือผู้มีความชำนาญในการดูแล ผู้สูงอายุหรือเจ้าหน้าที่สาธารณสุขผู้มี ประสบการณ์ เพื่อรับฟังความคิดเห็นเพื่อ ปรับปรุงและพัฒนาต่อยอดระบบ</p>	15	เสร็จสิ้น	<p>โดยอัลกอริทึมที่ทีมวิจัยเสนอให้ความแม่นยำที่ 97.02%</p> <ul style="list-style-type: none"> - ทีมวิจัยได้ติดตั้งและทดสอบใช้งานระบบ ณ บ้านอาสาสมัครจำนวน 2 หลัง ใน จังหวัดกรุงเทพมหานคร และ ชัยนาท - ทีมวิจัยได้ประเมินระบบซึ่งให้ความแม่นยำในการตรวจจับการหลั่งที่ 95.00% ความแม่นยำในการแยกแยะประเภทท่าทาง 10 ประเภทที่ 91.59% และความแม่นยำในการตรวจจับการเคลื่อนไหวที่ไม่มั่นคงที่ 97.02% - ทีมวิจัยได้จัดการฝึกอบรมแบ่งออกเป็น 2 กลุ่ม กลุ่มแรกเป็นผู้เชี่ยวชาญทางด้าน กายภาพบำบัดจากมหาวิทยาลัยมหิดลเพื่อจะรับฟังความคิดเห็นและข้อเสนอแนะ กลุ่มที่สองเป็นกลุ่มผู้ใช้งานระบบ และผู้สนใจในเทคโนโลยีกลุ่มที่สองจะเน้นใน การประเมินการใช้งานของระบบและรับฟังข้อเสนอแนะเพื่อการพัฒนาปรับปรุงให้ ระบบดีขึ้นในอนาคต
รวม		100		

4.1.13 ข้อกำหนดของระบบทั้งด้านฮาร์ดแวร์และซอฟต์แวร์

4.1.13.1 ข้อกำหนดทางด้านฮาร์ดแวร์

ข้อกำหนดทางด้านฮาร์ดแวร์จะเกี่ยวข้องข้องกับการติดตั้งกล้อง และมุกกล้องที่เหมาะสม เพื่อให้ระบบประมวลผลวิดีโอได้อย่างแม่นยำ โดยมีรายละเอียดดังต่อไปนี้

1. มุกกล้องควรติดตั้งในตำแหน่งที่ไม่สูง และมีมุกกม้น้อย เพื่อให้เห็นตัวบุคคลในแนวระนาบ ไม่เห็นตัวบุคคลในลักษณะมุกกด เพื่อให้ระบบวิเคราะห์การเคลื่อนไหวทำงานได้แม่นยำ ตำแหน่งความสูงของมุกกล้องควรติดตั้งที่ระยะความสูงระหว่าง 2.0-2.5 เมตร และมีมุกกม้นไม่เกิน 35 องศา
2. มุกกล้องควรมีการบดบังที่น้อยเพื่อลดการบดบังของโครงร่างของร่างกาย

4.1.13.2 ข้อกำหนดทางด้านซอฟต์แวร์

1. ในกรณีที่พื้นหลังมีความซับซ้อนเยอะ ระบบประมวลผลภาพจะต้องทำการกำหนดพื้นที่สำหรับการประมวลผลเพื่อลดการตรวจจับผิดพลาด
2. ข้อมูลเชิงพื้นที่และข้อมูลโครงร่างของร่างกายสามารถนำมาใช้เทรนโมเดลเพื่อพัฒนาโมเดล และทำให้โมเดลสามารถใช้งานได้หลากหลาย อย่างไรก็ตามการเพิ่มความซับซ้อนของโมเดล อาจต้องใช้ทรัพยากรในการประมวลผล (หน่วยประมวลผลกราฟฟิก) ที่มีประสิทธิภาพมากขึ้น
3. การสลับของการตามรอยบุคคลอาจอาจทำให้ผลการวิเคราะห์ท่าทางผิดพลาดได้
4. การเชื่อมโยงข้อมูลวิดีโอและการตรวจจับจะเป็นประโยชน์สำหรับผู้ใช้งานในการดูข้อมูลและตรวจสอบผลลัพธ์จากการตรวจจับ
5. การใช้โครงร่างของร่างกายแบบเต็มตัวจะช่วยให้ระบบสามารถวิเคราะห์การแยกแยะประเภทท่าทาง และ การเคลื่อนไหวที่ไม่มั่นคงได้อย่างแม่นยำ

บทที่ 5

สรุปผลการวิจัย และข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ทีมวิจัยได้พัฒนาต้นแบบอุปกรณ์เฝ้าดูวิดีโอแบบ IoT (Internet of Things) สำหรับดูแลผู้สูงอายุ ซึ่งทำงานร่วมกับระบบคลาวด์ที่ใช้ในการวิเคราะห์การเคลื่อนไหวที่ใกล้พร้อมสำหรับการขายในเชิงพาณิชย์ ต้นแบบอุปกรณ์เฝ้าดูวิดีโอแบบ IoT สำหรับดูแลผู้สูงอายุ ใช้บอร์ด TX-2 บน carrier board ในการประมวลผลวิดีโอจากกล้องวงจรปิดที่ติดตั้งไว้ในบ้าน โดยมีซอฟต์แวร์ที่คอยประมวลผลวิดีโอ เพื่อตรวจจับและตามรอยบุคคลโดยใช้การสกัดข้อมูลโครงร่างของร่างกายที่ตรวจจับ และทำการส่งข้อมูลไปยังระบบวิเคราะห์การเคลื่อนไหวโครงร่างของร่างกายซึ่งทำงานในลักษณะ web services โดยทีมวิจัยออกแบบ RESTful APIs เพื่อรับข้อมูลจากอุปกรณ์เฝ้าดูวิดีโอแบบ IoT และทำการวิเคราะห์ข้อมูลการเคลื่อนไหวส่วนต่าง ๆ ของร่างกาย

สำหรับการวิเคราะห์การเคลื่อนไหวส่วนต่าง ๆ ของร่างกาย ทีมวิจัยได้วิจัยและพัฒนาเทคนิคในการแยกแยะประเภทท่าทางต่าง ๆ 10 ประเภท ได้แก่ นั่ง ยืน เดิน ก้มตัว/เอนตัว ล้ม ประหม้อมือ ดุนาฬิกาข้อมือ คุยโทรศัพท์ ชี และ โบกมือ รวมถึงพัฒนาเทคนิคในการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง สำหรับการแยกแยะประเภทท่าทางต่าง ๆ ทั้ง 10 ประเภท ข้างต้น ทีมวิจัยได้ออกแบบอัลกอริทึม 3 อัลกอริทึม ได้แก่ การแยกแยะประเภทท่าทางแบบทีละเฟรม (framewise activity classification) การแยกแยะประเภทท่าทางแบบทีละเฟรมแบบลดหลั่น (cascade framewise activity classification) และ การแยกแยะประเภทท่าทางทีละหลายเฟรม (Long short-term memory activity classification) โดยทีมวิจัยได้ทดสอบความแม่นยำของแต่ละอัลกอริทึมพบว่า อัลกอริทึมการแยกแยะประเภทท่าทางทีละเฟรมแบบลดหลั่น (cascade framewise activity classification) ให้ความแม่นยำสูงสุดในการทำงานจริง ส่วนอัลกอริทึมสำหรับการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง ทีมวิจัยใช้เทคนิค Long short-term Memory เพื่อแยกแยะระหว่างการเคลื่อนไหวที่ไม่มั่นคง และการเคลื่อนไหวที่มั่นคงในการทำงานจริงระบบการวิเคราะห์การเคลื่อนไหวทั้งการแยกแยะประเภทท่าทาง และการเคลื่อนไหวที่ไม่มั่นคงจะทำงานบนคลาวด์เพื่อประมวลผลข้อมูลจากอุปกรณ์เฝ้าดูวิดีโอแบบ IOT ภายหลังการประมวลผลเสร็จสิ้น ผลลัพธ์การวิเคราะห์การเคลื่อนไหวของร่างกายจะถูกบันทึกลงในระบบฐานข้อมูลเพื่อใช้ในการแสดงผลบนเว็บแอปพลิเคชัน หรือส่งข้อความแจ้งเตือนผู้ใช้งาน

อัลกอริทึมสำหรับการแยกแยะประเภทท่าทาง และการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง ถูกเทรนโดยใช้ชุดข้อมูลต่าง ๆ ประกอบด้วย ข้อมูลที่ทีมวิจัยเก็บข้อมูลเอง ได้แก่ 1) ชุดข้อมูลมหาวิทยาลัยมหิดล (Mahidol dataset) เป็นชุดข้อมูลที่เก็บข้อมูลจากอาสาสมัครผู้สูงอายุในห้องปฏิบัติการคณะกายภาพบำบัด มหาวิทยาลัยมหิดลโดยมีอาสาสมัครผู้สูงวัยที่เคยหกล้มและไม่เคยหกล้มร่วมเก็บข้อมูล 2) ชุดข้อมูลหกล้มมหาวิทยาลัยมหิดล (Mahidol fall dataset) เก็บข้อมูลในห้องปฏิบัติการคณะกายภาพบำบัด มหาวิทยาลัยมหิดล โดยให้อาสาสมัครคนวัยหนุ่มจำลองการหกล้มเพื่อเก็บข้อมูลท่าทางการหกล้ม 3) ชุดข้อมูล AIC-360 ซึ่งเก็บข้อมูล

ในห้องปฏิบัติการ สถาบันเทคโนโลยีแห่งเอเชีย โดยให้อาสาสมัครเก็บข้อมูลในห้องปฏิบัติการที่มีการติดตั้งกล้องทั้งหมดจำนวน 8 ตัวครอบคลุมมุม 360 องศารอบตัวบุคคล โดยอาสาสมัครทำท่าทางต่าง ๆ 10 ท่าทาง รวมถึงการจำลองการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบต่าง ๆ 4) ชุดข้อมูล AIC-Volunteer1-set1 ซึ่งเก็บข้อมูลจากบ้านอาสาสมัครในจังหวัดกรุงเทพมหานคร โดยอาสาสมัคร ทำท่าทางต่าง ๆ 10 ท่าทาง รวมถึงการจำลองการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบต่าง ๆ 5) ชุดข้อมูล AIC-Volunteer1-set2 ซึ่งเก็บข้อมูลจากบ้านอาสาสมัครเดียวกันกับชุดข้อมูล AIC-Volunteer1-set1 โดยอาสาสมัคร ทำท่าทางต่าง ๆ 10 ท่าทาง รวมถึงการจำลองการหกล้ม และการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบต่าง ๆ เช่นกัน ข้อมูลชุดนี้ใช้เป็นชุดข้อมูล สำหรับการประเมินความแม่นยำของโมเดลที่ทีมวิจัยเทรน สำหรับชุดข้อมูลสาธารณะ ที่ทีมวิจัยใช้ในการเทรนโมเดลมีเพียง 1 ชุดข้อมูล คือ ชุดข้อมูล MoVi ซึ่งประกอบด้วย ท่าทางการเคลื่อนไหว 10 ท่าทาง ชุดข้อมูลที่ทีมวิจัยเก็บถูกนำมาใช้ในการเทรนโมเดลสำหรับการ แยกแยะประเภทท่าทาง และการเคลื่อนไหวที่ไม่มั่นคง และทดสอบบนชุดข้อมูล AIC-Volunteer1-set2 ซึ่งเป็นข้อมูลที่ไม่เคยเห็นมาก่อน ความแม่นยำของระบบโดยได้ความแม่นยำในการแยกแยะประเภทท่าทางต่าง ๆ มีความแม่นยำอยู่ที่ 91.59% หากพิจารณาเฉพาะความแม่นยำในการแยกแยะประเภทท่าทางการหกล้มอยู่ที่ 95.00% สำหรับการแยกแยะการเคลื่อนไหวที่ไม่มั่นคงมีความแม่นยำอยู่ที่ 97.05% ซึ่งมีความแม่นยำเพียงพอในการใช้งานจริงสำหรับมุมกล้องที่เหมาะสม

สำหรับการทดสอบการใช้งานระบบที่ทีมวิจัยได้เลือกบ้านอาสาสมัครที่มีผู้สูงอายุอาศัยอยู่ในพื้นที่จังหวัดกรุงเทพมหานคร และจังหวัดชัยนาท และทำการติดตั้งกล้องวงจรปิดและติดตั้งต้นแบบอุปกรณ์เพื่อเก็บข้อมูลและทดสอบการทำงานของระบบ และทำการเก็บข้อมูลเพื่อประเมินความแม่นยำของระบบ ในระหว่างการทดสอบการใช้งานระบบไม่พบการหกล้มและการเคลื่อนไหวที่ไม่มั่นคงเกิดขึ้น ทำให้ทีมวิจัยต้องทำการจำลองการหกล้มในรูปแบบต่าง ๆ และจำลองการเคลื่อนไหวที่ไม่มั่นคงในรูปแบบต่าง ๆ (ชุดข้อมูล AIC-Volunteer1-set2) เพื่อนำมาทดสอบความแม่นยำของระบบ อย่างไรก็ตามเนื่องด้วยสถานการณ์การแพร่ระบาดของเชื้อโควิด-19 ทำให้ทีมวิจัยไม่สามารถเดินทางไปเก็บข้อมูลเพื่อใช้ในการประมวลผลจากบ้านอาสาสมัครในจังหวัดชัยนาทได้ จึงมีเฉพาะชุดข้อมูลจากบ้านอาสาสมัครในจังหวัดกรุงเทพ (ชุดข้อมูล AIC-Volunteer1-set2) สำหรับใช้ในการประเมินความแม่นยำของระบบดังได้กล่าวมาข้างต้น

ทีมวิจัยได้พัฒนาเว็บแอปพลิเคชันสำหรับผู้ใช้งานเพื่อให้ผู้ใช้งานสามารถดูข้อมูลการวิเคราะห์การเคลื่อนไหวของร่างกาย การตรวจจับท่าทางต่าง ๆ ที่ปรากฏในมุมกล้องวงจรปิดที่ติดตั้งเพื่อใช้ร่วมงานกับต้นแบบอุปกรณ์เฝ้าดูวิดีโอแบบ IoT (Internet of Things) สำหรับดูแลผู้สูงอายุ ระบบเว็บแอปพลิเคชันออกแบบให้ผู้ใช้งานต้องล็อกอินก่อนเข้าใช้งานระบบเพื่อความปลอดภัยของข้อมูล โดยระบบเว็บแอปพลิเคชันสามารถแสดง 1) ข้อมูลสถิติของจำนวนท่าทางต่าง ๆ ที่ตรวจพบในแต่ละวัน 2) รายละเอียดการตรวจพบท่าทางต่าง ๆ 3) รายละเอียดการตรวจพบการหกล้ม 4) รายละเอียดการตรวจพบการเคลื่อนไหวที่ไม่มั่นคง 5) การตรวจพบการไม่อยู่ในอาณาบริเวณในช่วงเวลาที่กำหนด 6) การแจ้งเตือนการตรวจจับการหกล้ม การเคลื่อนไหวที่ไม่มั่นคง 7) การตั้งค่าต่าง ๆ เช่น กล้อง ช่วงเวลาที่ควรมีการปรากฏตัวของสมาชิกในครอบครัวแต่ละกล้อง และ

รายละเอียดของสมาชิกในครอบครัว นอกเหนือจากเว็บแอปพลิเคชันที่มิวิจัยได้พัฒนาการแจ้งเตือนแบบเรียลไทม์ไปยังแอปพลิเคชัน LINE บนโทรศัพท์มือถือ ในกรณีที่มีการตรวจพบการหกล้ม การเคลื่อนไหวที่ไม่มั่นคง และการตรวจพบการไม่อยู่ในอาณาบริเวณในช่วงเวลาที่กำหนด ผู้ใช้งานสามารถดูผลลัพธ์จากการประมวลผลได้บนเว็บแอปพลิเคชันนี้

ในการดำเนินโครงการช่วงสุดท้ายที่มิวิจัยได้ทำการฝึกอบรมตัวแทนจากบ้านอาสาสมัครที่ทำการติดตั้งและทดสอบ ผู้ที่สนใจระบบ และ ผู้เชี่ยวชาญด้านกายภาพบำบัด เพื่อประเมินการใช้งานของระบบรวมถึงรับฟังข้อคิดเห็นและเสนอแนะ จากผู้เข้าฝึกอบรมภายหลังการทดสอบใช้งานระบบ ผลการประเมินความพึงพอใจในการใช้งานระบบอยู่ที่ 8.25 คะแนนจาก 10.0 คะแนน และที่มิวิจัยได้จัดเตรียมเอกสารรายละเอียดการประดิษฐ์สำหรับยื่นคำขอจดอนุสิทธิบัตร “ระบบตรวจจับการล้มและการเคลื่อนไหวที่ไม่มั่นคงอัตโนมัติด้วยอุปกรณ์รับภาพและ/หรือภาพเคลื่อนไหว” นอกจากนี้ที่มิวิจัยได้จัดเตรียมเอกสารวิชาการหัวข้อ “Automatic elderly fall and unstable movement detection system using video analytic device” สำหรับลงตีพิมพ์ในวารสารสำนักงาน กสทช.

ที่มิวิจัยหวังเป็นอย่างยิ่งว่าต้นแบบอุปกรณ์เฝ้าดูวิดีโอแบบ IoT (Internet of Things) สำหรับผู้ดูแลผู้สูงอายุ ซึ่งทำงานร่วมกับระบบคลาวด์ที่ใช้ในการวิเคราะห์การเคลื่อนไหวที่ใกล้เคียง สำหรับการขายในเชิงพาณิชย์ที่มิวิจัยได้วิจัยและพัฒนาขึ้นนี้จะเป็นประโยชน์ในการช่วยเหลือดูแลผู้สูงอายุ โดยตรวจจับการเคลื่อนไหวแบบไม่มั่นคงได้แต่เนิ่น ๆ เพื่อลดความเสี่ยงในการเกิดการหกล้มและสมาชิกในครอบครัวสามารถรู้ได้แต่เนิ่น ๆ จากการแจ้งเตือนแบบเรียลไทม์ของระบบ ซึ่งจะช่วยลดการบาดเจ็บหนักจากการล้ม หรือในกรณีที่เกิดการหกล้มขึ้นสมาชิกในครอบครัวหรือผู้ดูแลสามารถรับรู้และให้การช่วยเหลือได้อย่างทันท่วงที

5.2 ข้อเสนอแนะและแนวทางในการพัฒนาต่อระบบในอนาคต

ขั้นตอนต่อไปของการวิจัยและพัฒนาจะมุ่งเน้นในการหาจุดสมดุลระหว่างต้นทุนของระบบและประโยชน์ที่ผู้สูงอายุและครอบครัวรวมถึงผู้ดูแลผู้สูงอายุจะได้รับ แนวทางการปรับปรุงและพัฒนา ระบบให้ดีขึ้นที่มิวิจัยแบ่งออกเป็นด้านต่าง ๆ ดังต่อไปนี้

5.2.1 การลดต้นทุนในการนำเทคโนโลยีระบบดูแลผู้สูงอายุไปใช้งานจริง

ต้นทุนการใช้งานระบบแบ่งออกเป็นสองส่วน คือ 1) ต้นทุนด้านการใช้ บริการอินเทอร์เน็ต และระบบคลาวด์ 2) ต้นทุนอุปกรณ์ประมวลผลแบบ edge

a) ต้นทุนด้านการใช้บริการอินเทอร์เน็ตและระบบคลาวด์

ต้นทุนด้านการใช้งานอินเทอร์เน็ตที่ไม่สูงมาก รวมถึงค่าบริการคลาวด์ที่ไม่สูงจนเกินไป จะทำให้ครัวเรือนที่ต้องการใช้งานระบบดังกล่าวสามารถเข้าถึงการใช้งานระบบได้มากขึ้น การกำจัดคอขวดด้านแบนด์วิธในการส่งข้อมูลจากกล้องไปยังระบบคลาวด์จากผู้ให้บริการอินเทอร์เน็ตจะช่วยให้ระบบสามารถถูกนำไปใช้งานจริงบนเครือข่าย 5G หรือเครือข่ายไฟเบอร์ ซึ่งจะช่วยลดต้นทุนในด้านอุปกรณ์การประมวลผลแบบ edge เนื่องจากหากมีแบนด์วิธในการส่งข้อมูลวิดีโอไปยังระบบคลาวด์ได้โดยตรง อัลกอริทึมสำหรับการทำงานทั้งหมดสามารถย้ายไปทำงานบนระบบคลาวด์ซึ่งให้ความคุ้มค่าในด้านการใช้งานเมื่อต้องการสเกลระบบตามจำนวนกล้องและจำนวนผู้ใช้งาน

b) ต้นทุนอุปกรณ์ประมวลผลแบบ edge

ถึงแม้ว่าต้นแบบระบบที่ทีมวิจัยวิจัยและพัฒนาขึ้นจะใช้บอร์ด NVIDIA TX-2 เป็นหน่วยประมวลผลหลัก แต่ราคาของบอร์ดดังกล่าวหากเทียบกับบริบทภาคครัวเรือนของประเทศไทยนั้นยังถือว่าเป็นราคาที่ค่อนข้างสูง อย่างไรก็ตาม ณ ปัจจุบัน NVIDIA ได้ผลิตบอร์ดรุ่นใหม่ เช่น NVIDIA Jetson Nano ซึ่งมีความสามารถในการประมวลผลเพื่อดึงข้อมูลจุดโครงร่างของร่างกายที่เพียงพอ และมีราคาถูกกว่า ซึ่งจะช่วยให้ราคาของระบบดูแลผู้สูงอายุถูกลงได้ รวมถึงการลดการประมวลผลบนอุปกรณ์ประมวลผลแบบ edge (ดังอธิบายในหัวข้อที่ 5.2.2.b) จะช่วยลดต้นทุนอุปกรณ์ประมวลผลแบบ edge ได้เช่นกัน

5.2.2 การพัฒนาต่อยอดในอนาคต

a) ความเป็นไปได้ในการใช้อุปกรณ์เซ็นเซอร์ชนิดอื่นเพื่อช่วยในการตรวจจับการหกล้ม

มีความเป็นไปได้ในการใช้อุปกรณ์เซ็นเซอร์ชนิดอื่นเพื่อช่วยในการตรวจจับการหกล้ม มีงานวิจัยและสิทธิบัตรหลายงานที่ใช้อุปกรณ์สวมใส่ หรือ WiFi เซ็นเซอร์ในการตรวจจับและระบุตำแหน่งการหกล้มภายในอาคาร รวมถึงการเฝ้าดูรูปแบบ RSSI ในการระบุการหกล้ม ทีมวิจัยได้ทำงานกับผู้เชี่ยวชาญด้าน Wireless Sensor Networks ของสถาบันเทคโนโลยีแห่งเอเชีย และยื่นข้อเสนอโครงการไปยัง กสทช. ในเดือนเมษายน พ.ศ.2564 เพื่อต่อยอดโครงการวิจัยนี้โดยการประยุกต์ใช้การวิเคราะห์การแพร่กระจายของสัญญาณ (Wireless signal propagation analysis) เพื่อใช้ในการดูแลผู้สูงอายุเช่นกัน

b) การลดการประมวลผลในการดึงข้อมูลจุดโครงร่างของร่างกาย

เนื่องจากการดึงข้อมูลจุดโครงร่างของร่างกายใช้ทรัพยากรในการประมวลผลเยอะ การลดการประมวลผลในโมดูลดังกล่าวโดยย้ายไปประมวลผลบนคลาวด์แทน จะช่วยลดการประมวลผลบนอุปกรณ์ประมวลผลแบบ edge ได้ ซึ่งจะทำให้การประมวลผลวิดีโอบนอุปกรณ์ประมวลผลแบบ edge ทำหน้าที่เฉพาะการตรวจจับและตามรอยบุคคล โมเดล deep learning ที่ออกแบบมาเฉพาะเพื่อให้ใช้งานบน Raspberry Pi4 เช่น NanoDet¹ สามารถทำงานตรวจจับวัตถุได้ที่ 13 เฟรม/วินาทีบนบอร์ด Raspberry Pi4 ซึ่งเพียงพอในการตรวจจับและตามรอยบุคคล รวมถึงโมเดล deep learning เช่น โมเดล SSD-mobilenet หรือ SSD-inception หรือ SSD-ResNet เป็นต้น สำหรับรันบน NVIDIA Jetson Nano ซึ่งสามารถทำการตรวจจับบุคคลได้แบบเรียลไทม์²

อย่างไรก็ตามการลดการประมวลผลบนฝั่งอุปกรณ์ประมวลผลแบบ edge อาจจะต้องการแบนด์วิธของเครือข่ายมากขึ้นในการส่งข้อมูลไปยังระบบคลาวด์เนื่องจากต้องส่งรูปภาพพื้นที่ที่ตรวจจับบุคคลได้ในแต่ละเฟรมไปยังระบบคลาวด์เพื่อทำการดึงข้อมูลจุดโครงร่างของร่างกายในแต่ละเฟรมซึ่งเป็นข้อมูลนำเข้าสำหรับการแยกแยะประเภทท่าทางและการตรวจจับการเคลื่อนไหวที่ไม่มั่นคง

ถึงแม้จะมีงานวิจัยบางงานพยายามลดการประมวลผลเพื่อตรวจจับและตามรอยบุคคลเพื่อให้สามารถทำการประมวลผลบนบอร์ดที่มีทรัพยากรการประมวลผลไม่มาก โดยเสนอการตรวจจับการหกล้มโดยใช้อัลกอริทึมการแยกภาพพื้นหน้าออกจากภาพพื้นหลังเพื่อหาส่วนที่มีการ

¹ <https://github.com/Qengineering/NanoDet-ncnn-Raspberry-Pi-4>

² <https://developer.nvidia.com/embedded/jetson-nano-dl-inference-benchmarks>

เคลื่อนไหวในวิดีโอเพื่อตรวจจับและตามรอยบุคคล และทำการตรวจจับการหลัดม อยางไรก็ตามทีมวิจัยมีประสบการณในการใช้เทคนิคการแยกภาพพื้นหนาออกจากภาพพื้นหลังในการดำเนินโครงการวิจัยอื่น ๆ ก่อนหน้า พบว่าอัลกอริทึมดังกล่าวมีความไวต่อการเปลี่ยนแปลงของแสง และไม่แม่นยำในกรณีที่ภาพพื้นหลังมีความซับซ้อน นอกจากนี้ในส่วนของการทำงานวรรณกรรมที่ทีมวิจัยพบว่าการแยกแยะประเภทท่าทางโดยใช้ข้อมูลจุดโครงร่างของร่างกายนั้นให้ความแม่นยำมากกว่าการใช้อัลกอริทึมอื่น ๆ

5.2.3 ความร่วมมือกับภาคอุตสาหกรรมเพื่อสร้างระบบที่มีประสิทธิภาพและราคาไม่สูง

ความร่วมมือกับภาคอุตสาหกรรม เช่น บริษัทผู้ผลิตอุปกรณ์เน็ตเวิร์ค หรือกล้องวงจรปิด จะช่วยลดต้นทุนด้านอุปกรณ์และช่วยสร้างมาตรฐานให้ระบบเป็นระบบที่สามารถใช้งานในเชิงพาณิชย์ การร่วมมือกับภาคอุตสาหกรรมดังกล่าวจะช่วยเร่งกระบวนการในการผลักดันงานวิจัยไปสู่ผลิตภัณฑ์ ด้วยต้นทุนที่ต่ำลงและความสามารถในการแข่งขันกับผลิตภัณฑ์ในตลาดที่มากขึ้น ปัจจุบันศูนย์วิจัยปัญญาประดิษฐ์ (AI Center) สถาบันเทคโนโลยีแห่งเอเชีย (AIT) กำลังเจรจาในการจัดทำบันทึกความเข้าใจ (Memorandum of Understanding) กับบริษัท Cisco โดยบริษัท Cisco จะสนับสนุนอุปกรณ์ และ ซอฟต์แวร์สำหรับการบริหารจัดการคลาวด์สำหรับการใช้งานจริงเพื่อใช้งานกับระบบ หากบริษัท CISCO ตกลง จะมีการเจรจา 4 ฝ่าย ระหว่าง สถาบันเทคโนโลยีแห่งเอเชีย มหาวิทยาลัยมหิดล บริษัท CISCO และ กสทช. ในเรื่องทรัพย์สินทางปัญญา และการอนุญาตให้ใช้สิทธิ์ (licensing)

5.2.4 การปรับปรุงระบบให้ทำงานได้แม่นยำมากขึ้น

จากข้อจำกัดด้านฮาร์ดแวร์และซอฟต์แวร์ที่ได้กล่าวมาในหัวข้อที่ 4.1.1.3 แนวทางการแก้ไขปรับปรุงให้ระบบสามารถทำงานได้ดีขึ้นมีรายละเอียดดังต่อไปนี้

1. การพิจารณามุมกล้องให้มองเห็นตัวบุคคลทั้งตัว
2. การระบุพื้นที่สำหรับการประมวลผลเพื่อลดการบดบังจากวัตถุอื่น ๆ
3. การปรับปรุงประสิทธิภาพอัลกอริทึมการตามรอยเพื่อลดการสลับตำแหน่งการตามรอย
4. พิจารณาเฉพาะจุดโครงร่างของร่างกายเฉพาะลำตัวโดยไม่พิจารณาส่วนแขนอาจช่วยให้อัลกอริทึมการแยกแยะประเภทท่าทางและการเคลื่อนไหวที่ไม่มั่นคงมีความแม่นยำมากขึ้น

บรรณานุกรม

1. World Bank (2016), Thailand Economic Monitor - June 2016: Aging Society and Economy. <http://www.worldbank.org/en/country/thailand/publication/thailand-economic-monitor-june-2016-aging-society-and-economy>.
2. Blake AJ, Morgan K, Bendall MJ, Dallosso H, Ebrahim SB, Arie TH, Fentem PH, Bassey EJ: Falls by elderly people at home: prevalence and associated factors. Age Ageing 1988, 17(6):365- 372.
3. Prudham D, Evans JG: Factors associated with falls in the elderly: a community study. Age Ageing 1981, 10(3):141-146.
4. Fleming J, Matthews FE, Brayne C, Cambridge City over-75s Cohort study c: Falls in advanced old age: recalled falls and prospective follow-up of over-90-year-olds in the Cambridge City over-75s Cohort study. BMC Geriatr 2008, 8:6. doi:10.1186/1471-2318-8-6
5. Downton JH, Andrews K: Prevalence, characteristics and factors associated with falls among the elderly living at home. Aging (Milano) 1991, 3(3):219-228.
6. Varas-Fabra F, Castro Martin E, Perula de Torres LA, Fernandez Fernandez MJ, Ruiz Moral R, Enciso Berge I: Falls in the elderly in the community: prevalence, consequences, and associated factors. Aten Primaria 2006, 38(8):450-455.
7. Siqueira FV, Facchini LA, Piccini RX, Tomasi E, Thume E, Silveira DS, Vieira V, Hallal PC: Prevalence of falls and associated factors in the elderly. Rev Saude Publica 2007, 41(5):749-756.
8. Sharif SI, Al-Harbi AB, Al-Shihabi AM, Al-Daour DS, Sharif RS: Falls in the elderly: assessment of prevalence and risk factors. Pharm Pract (Granada) 2018, 16(3):1206. doi:10.18549/PharmPract.2018.03.1206
9. Jitapunkul S, Songkhla MN, Chayovan N, Chirawatkul A, Choprapawon C, Kachondham Y, Buasai S: Falls and their associated factors: a national survey of the Thai elderly. J Med Assoc Thai 1998, 81(4):233-242.
10. Bath PA, Morgan K: Differential risk factor profiles for indoor and outdoor falls in older people living at home in Nottingham, UK. Eur J Epidem 1999, 15:65-73.
11. Tinetti ME: Factors associated with serious injury during falls by ambulatory nursing home residents. J Am Geriatr Soc 1987, 35(7):644-648.

12. Kerrigan DC, Todd MK, Croce UD, Lipsitz LA, Collins JJ: Biomechanical gait alterations independent of speed in the healthy elderly: Evidence for specific limiting impairments. *Arch Phys Med Rehabil* 1998, 79:317-322.
13. Lindemann U, Najafi B, Zijlstra W, Hauer K, Mucche R, Becker C, Aminian K: Distance to achieve steady state walking speed in frail elderly persons. *Gait Posture* 2008, 27:91-96.
14. Prince F, Corriveau H, Hebert R, Winter DA: Gait in the elderly. *Gait Posture* 1997, 5:128- 135.
15. Watelain E, Barbier F, Allard P, Thevenon A: Gait pattern classification of healthy elderly men based on biomechanical data. *Arch Phys Med Rehabil* 2000, 81:579-586.
16. Nutt JG, Marsden CD, Thompson PD: Human walking and higher-level gait disorders, particularly in the elderly. *Neurology* 1993, 43:268-279.
17. Snijders AH, van de Warrenburg BP, Giladi N, Bloem BR: Neurological gait disorders in elderly people: clinical approach and classification. *Lancet* 2007, 6:63-74.
18. Nashner LM: Physiology of balance, with special reference to the healthy elderly. In: *Gait disorders of aging falls and therapeutic strategies*. edn. Edited by Masdeu JC, Sudarsky L, Wolfson L. Philadelphia: Lippincott-Raven; 1997: 37-54.
19. Samson MM, Meeuwssen IBAE, Crowe A, Dessens JAG, Duursma SA, Verhaar HJJ: Relationships between physical performance measures, age, height and body weight in healthy adults. *Age Ageing* 2000, 29:235-242.
20. Timiras PS, De Martinis M: The Pulmonary Respiration, Hematopoiesis, and Erythrocytes In: *Physiological Basis of aging and geriatrics*. 4th edn. Edited by Timiras PS. New York: Informa Healthcare 2007: 277-296.
21. Khazzani H, Allali F, Bennani L, Ichchou L, Mansouri LE, Abourazzak FE, Abouqal R, Hajjaj- Hassouni N: The relationship between physical performance measures, bone mineral density, falls, and the risk of peripheral fracture: a cross-sectional analysis. *BMC Public Health* 2009, 9:297.
22. Goto Y, Otaka Y, Suzuki K, Inoue S, Kondo K, Shimizu E: Incidence and circumstances of falls among community-dwelling ambulatory stroke survivors: A prospective study. *Geriatr Gerontol Int* 2019. doi:10.1111/ggi.13594

23. Pavol MJ, Owings TM, Foley KT, Grabiner MD: Mechanisms leading to a fall from an induced trip in healthy older adults. *J Gerontol A Biol Sci Med Sci* 2001, 56(7):M428-437.
24. Akram SB, Frank JS, Chenouri S: Turning behavior in healthy older adults: Is there a preference for step versus spin turns? *Gait Posture* 2010, 31(1):23-26. doi:10.1016/j.gaitpost.2009.08.238
25. Fuller GF: Falls in the elderly. *Am Fam Physician* 2000, 61:2159-2168.
26. Galna B, Peters A, Murphy AT, Morris ME: Obstacle crossing deficits in older adults: a systematic review. *Gait Posture* 2009, 30(3):270-275.
27. Reynolds RF, Day BL: Visual guidance of the human foot during a step. *J Physiol* 2005, 569(Pt 2):677-684.
28. McFadyen BJ, Bouyer L, Bent LR, Inglis JT: Visual-vestibular influences on locomotor adjustments for stepping over an obstacle. *Exp Brain Res* 2007, 179(2):235-243.
29. Deshpande N, Patla AE: Visual-vestibular interaction during goal directed locomotion: effects of aging and blurring vision. *Exp Brain Res* 2007, 176(1):43-53.
30. Yen HC, Chen HL, Liu MW, Liu HC, Lu TW: Age effects on the inter-joint coordination during obstacle-crossing. *J Biomech* 2009, 42(15):2501-2506.
31. Dite W, Temple VA: Development of a clinical measure of turning for older adults. *Am J Phys Med Rehabil* 2002, 81(11):857-866.
32. Thigpen MT, Light KE, Creel GL, Flynn SM: Turning difficulty characteristics of adults aged 65 years or older. *Phys Ther* 2000, 80(12):1174-1187.
33. Schwenk M, Howe C, Saleh A, Mohler J, Grewal G, Armstrong D, Najafi B: Frailty and technology: a systematic review of gait analysis in those with frailty. *Gerontology* 2014, 60(1):79- 89. doi:10.1159/000354211
34. Eeles E, Low Choy N: Frailty and Mobility. *Interdiscip Top Gerontol Geriatr* 2015, 41:107- 120. doi:10.1159/000381200
35. Kaneda, Toshiko (2006), A critical window for policymaking on population aging in developing countries. Population Reference Bureau.

<http://www.prb.org/Publications/Articles/2006/>

[ACriticalWindowforPolicymakingonPopulationAginginDevelopingCountries.aspx](#).

36. Lee, M-Suen, Trajkovic, Miroslav, Dagtas, Serhan, Gutta, Srinivas, Brodsky, Tomas, Philomin, Vasanth, Lin, Yun-Ting, Strubbe, Hugo, and Cohen-Solal, Eric (2003), Computer vision based elderly care monitoring system. US Patent Application 10/189,272 (Abandoned).

37. T. H. Lin, C. Y. Yang, and W. P. Shih, "Fall prevention shoes using camera-based line-laser obstacle detection system," *Journal of Healthcare Engineering*, vol. 2017, Article ID 8264071, 11 pages, 2017.

38. Anderson, Derek, Keller, James M., Skubic, Marjorie, Chen, Xi, and He, Zhihai (2006), Recognizing falls from silhouettes. In *International Conference of the IEEE Engineering in Medicine and Biology Society*.

39. Zhou, Zongna, Stone, Erik Edward, Skubic, Marjorie, Keller, James M., and He, Zhihai (2011), Nighttime in-home action monitoring for Elder Care. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 5299-5302.

40. E. E. Stone and M. Skubic, "Evaluation of an inexpensive depth camera for passive in-home fall risk assessment," in *PervasiveHealth*, pp. 71–77, 2011.

41. Zhou, Zhongna, Dai, Wenqing, Eggert, Jay, Giger, Jarod T., Keller, James, Rantz, Marilyn, and He, Zhihai (2009), A real-time system for in-home activity monitoring of elders. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 6115-6118.

42. Chung, Pau-Choo and Liu, Chin-De (2008), A daily behavior enabled hidden Markov model for human behavior understanding. *Pattern Recognition*, 41(5), pp. 1572-1580.

43. Zhou, Zhongna, Chen, Xi, Chung, Yu-Chia. , He, Zhihai, Han, Tony X., and Keller, James M. (2008), Activity analysis, summarization, and visualization for indoor human activity monitoring. *IEEE Transactions on Circuits and Systems for Video Technology*, 18(11), pp. 1489-1498.

44. Jalal, Ahmad, Kamal, Shaharyar, and Kim, Daijin (2014), A depth video sensor-based life-logging human activity recognition system for elderly care in smart indoor environments. *Sensors*, 14(7), 11735-11759.

45. P. Natarajan and R. Nevatia, "View and scale invariant action recognition using multiview shape-flow models," in 2008 IEEE Conference on Computer Vision and Pattern Recognition, pp. 1– 8, Anchorage, AK, USA, 2008.
46. M. Marszalek, I. Laptev, and C. Schmid, "Actions in context," in 2009 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2009, pp. 2929–2936, Miami, FL, USA, 2009.
47. I. Laptev, M. Marszalek, C. Schmid, and B. Rozenfeld, "Learning realistic human actions from movies," in 2008 IEEE Conference on Computer Vision and Pattern Recognition, pp. 1–8, Anchorage, AK, USA, 2008.
48. Demiris, George, Oliver, Debra Parker, Giger, Jarod, Skubic, Marjorie, and Rantz, Marilyn (2009), Older adults' privacy considerations for vision based recognition methods of Elder Care applications. *Technology and Health Care*, vol. 17, no. 1, pp. 41-48.
49. J. Wang, Z. Liu, Y. Wu, and J. Yuan, "Mining actionlet ensemble for action recognition with depth cameras," in 2012 IEEE Conference on Computer Vision and Pattern Recognition, pp. 1290– 1297, Providence, RI, USA, 2012.
50. F. Adib, Z. Kabelac, D. Katabi, R. C. Miller, "3d tracking via body radio reflections", Proc. 11th USENIX Conf. Netw. Syst. Des. Implementation, vol. 14, pp. 317-329.
51. F. Adib, Z. Kabelac, D. Katabi, "Multi-person localization via RF body reflections", Proc. 12th USENIX Conf. Netw. Syst. Des. Implementation, pp. 279-292, 2015.
52. H. Gines, C. Zhe, S. Tomas, W. Shih-En, J. Hanbyul and S. Yaser, "Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields", 2017. __
53. Ghorbani, S., Mahdavian, K., Thaler, A., Kording, K., Cook, D. J., Blohm, G., & Troje, N. F. (2020). MoVi: A Large Multipurpose Motion and Video Dataset. arXiv preprint arXiv:2003.01888.
54. Chung, Jane, Mustafa Ozkaynak, and George Demiris. "Examining daily activity routines of older adults using workflow." *Journal of biomedical informatics* 71 (2017): 82-90.
55. Pumpinyo, Sumalee, and Saowaluck Koocharoenprasit. "A Survey of Leisure Activities that the Elderly Desire." *Journal of Advanced Research in Social Sciences* 3.3 (2020): 14-19.

56. Yen, Hsin-Yen, and Li-Jung Lin. "Quality of life in older adults: Benefits from the productive engagement in physical activity." *Journal of Exercise Science & Fitness* 16.2 (2018): 49-54.

โครงการดูแลผู้สูงอายุ

ภาคผนวก ก
รายงานการจัดซื้อครุภัณฑ์ในโครงการ

โครงการดูแลผู้สูงอายุ

1. รายงานการจัดซื้อครุภัณฑ์ในโครงการ

1.1 ครุภัณฑ์สำหรับการวิจัยและพัฒนาฯ

ลำดับ	รายการจัดซื้อครุภัณฑ์ (สำหรับการวิจัยและพัฒนาฯ)	วัน/เดือน/ปี	มูลค่า	เอกสารอ้างอิง
1	คอมพิวเตอร์ประมวลผล 2 เครื่อง	8/11/2562	114,843.10	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
2	1. กล้องโทรทัศน์วงจรปิด Dome IP Camera 12 ตัว 2. กล้องโทรทัศน์วงจรปิด Bullet IP Camera 12 ตัว	3/7/2563	236,256.00	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
3	Surveillance HDD 8TB 256mb 4 ตัว	29/04/2563	40,000.00	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
4	กล้อง Day and Night IR Vandal Resistant Dome IP Camera 1 ตัว	12/6/2563	7,918.00	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
5	1. กล้องโทรทัศน์วงจรปิด Dome IP Camera 1 ตัว 2. กล้องโทรทัศน์วงจรปิด Bullet IP Camera 1 ตัว	21/5/2563	17,535.16	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
6	คอมพิวเตอร์ประมวลผล 2 เครื่อง	12/6/2563	169,680.00	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบนำฝาก
7	Nvidia Jetson TX2 dev kit 4 เครื่อง	18/02/2563	36,561.72	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
8	Nvidia Jetson TX2 dev kit 6 เครื่อง	17/03/2563	58,861.14	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
9	เครื่องเซิร์ฟเวอร์ Superserver 2029P-C1RT	6/8/2563	14,4450.00	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี
10	Embedded system boards (Raspberry Pi class) 20 ตัว	4/6/2564	19,260	ใบเสนอราคา/ ใบสั่งซื้อ/ ใบแจ้งหนี้/ ใบกำกับภาษี

1.2 ครุภัณฑ์สำหรับการดำเนินโครงการ

ลำดับ	รายการจัดซื้อครุภัณฑ์ (สำหรับการดำเนินโครงการทั่วไป)	วัน/เดือน/ปี	มูลค่า	เอกสารอ้างอิง
1	ค่าภาษีขนส่ง Nvidia Jetson TX2 dev kit 4 เครื่อง	18/02/2563	4,553.50	ใบแจ้งหนี้/ ใบกำกับภาษี
2	ค่าภาษีขนส่ง Nvidia Jetson TX2 dev kit 6 เครื่อง	17/03/2563	6,300.50	ใบแจ้งหนี้/ ใบกำกับภาษี

ประวัติคณະนักวิจัย



Prof. Matthew N. Dailey received the B.S. and M.S. in Computer Science from North Carolina State University and the Ph.D. in Computer Science and Cognitive Science from the University of California, San Diego. He spent two years as a Research Scientist with Vision Robotics Corporation of San Diego, CA USA and two years as a Lecturer in the Computer Science and Information Technology programs at Sirindhorn International Institute of Technology, Thammasat University, Thailand. In 2006, he joined the Information and Communication Technologies (ICT) department at the Asian Institute of Technology (AIT), Thailand, where he is now a Professor. He is also the Director of the AIT Artificial Intelligence Center. His research interests lie in machine learning, deep learning, computer vision, and AI applications in a variety of sectors including health care.



Assoc. Prof. Mongkol Ekpanyapong received the B.Eng. degree in computer engineering from Chulalongkorn University, Bangkok, Thailand, in 1997, the M.Eng. degree in computer science from the Asian Institute of Technology, Thailand, in 2000, and the [M.Sc.](#) and Ph.D. degrees in electrical and computer engineering from the Georgia Institute of Technology, Atlanta, GA, USA, in 2003 and 2006, respectively. From 1997 to 1998, he was a System Engineer with United Communication Network, Thailand. From 2006 to 2009, he was a Senior Computer Architect with Core 2 Architecture Design Team, Intel Corporation, USA. He joined the School of Engineering and Technology, Asian Institute of Technology, in 2009, where he is currently an Associate Professor. His research

interests include VLSI design, physical design automation, microarchitecture, compiler, and embedded systems.



Miss. Aniqua Zereen is a PhD candidate at Asian Institute of Technology (AIT), Thailand and a Lecturer of Computer Science and Engineering Department of BRAC University, Bangladesh. Currently she is a research assistant at Artificial Intelligent Center, AIT. She has earned B.S. and M.S. degrees from BRAC University. She achieved Recognition in the Dean's list of meritorious students for outstanding performance. She received "Best Paper Award" at TCCE-2020 and ICERIE-2017. She worked as a summer-student at CERN, the European Organization for Nuclear Research. She is a recipient of Bangabandhu Science and Technology Fellowship Trust. Her research interests include computer vision, artificial intelligence and machine learning.



Mr. Anubinda Gurung is a software engineer at Rimes where he works on data visualization and web application development. He received his B.Tech and M.Eng degree in Computer Science and Engineering from Sharda University, India and Asian Institute of Technology, Thailand, in 2016 and 2020 respectively. From 2019 to 2020, he worked as a research assistant at AICenter.



Mr. Amir Rajak is a Research Associate at the Artificial Intelligence Center, Asian Institute of Technology (AIT). His research primarily focuses on deep learning and machine learning applications especially in the field of computer vision. His research includes computer vision for human-centered real world applications. He received his M.Sc. degree in Information Management from AIT in 2019. He was a recipient of His Majesty the King's Scholarship for the year 2017-2019. He also holds professional experience working as a senior software engineer in data analytics, data warehousing, and business intelligence applications for five years in his home country, Nepal. His research interests include machine learning for human analytics, biomedical applications, and NLP/NLU.



Mr. Jednipat Moonrinta is a senior research associate at Artificial Intelligence Center, Asian Institute of Technology where he performs research and development on several video analytics applications, especially human analytics applications. He received his B.Eng degree in Computer Engineering from Chiang Mai University in 2008. He received his M.Eng degree in Computer Engineering from Asian Institute of Technology in 2010. He has started working on computer vision, image processing, and machine learning since 2010. He is currently studying in a doctoral program in Computer Science and Information Management, AIT.



กองทุนวิจัยและพัฒนากิจการกระจายเสียง กิจการโทรทัศน์ และกิจการโทรคมนาคม เพื่อประโยชน์สาธารณะ
(สำนักงาน กสทช.)