

# การรู้จำกิจกรรมประจำวันของมนุษย์แบบปรับตัวได้โดยใช้ข้อมูลจากตัวรับรู้ แอคเซเลอโรมิเตอร์ของสมาร์ทโฟน

## Adaptive Human Daily Activity Recognition Using Accelerometer Sensory Data from Smartphones

อุรีรัฐ สุขสวัสดิ์ชัน<sup>1</sup>, จักริน สุขสวัสดิ์ชัน<sup>1</sup>, วรวิทย์ วีระพันธ์<sup>2</sup>, เมฆรัศมี วชิรหัตถพงศ์<sup>2</sup>, วิทวัส พันธุ์มุจินดา<sup>2</sup>  
Ureerat Suksawatchon<sup>1</sup>, Jakkarin Suksawatchon<sup>1</sup>, Worawit Werapan<sup>1</sup>,  
Hemmarat Wachirahatthapong<sup>2</sup>, Wittawas Puntumchinda<sup>2</sup>

Received: 12 June 2019 ; Revised: 23 August 2019 ; Accepted: 17 September 2019

### บทคัดย่อ

การรู้จำกิจกรรมของมนุษย์โดยใช้ข้อมูลกระแสจากตัวรับรู้แอคเซเลอโรมิเตอร์ของสมาร์ทโฟนยังคงเป็นประเด็นที่น่าสนใจสำหรับนักวิจัย งานวิจัยส่วนใหญ่พัฒนาด้วยแบบรู้จำกิจกรรมเป็นแบบเฉพาะบุคคล ซึ่งต้องใช้ข้อมูลสำหรับสร้างตัวแบบมาจากผู้ใช้ที่ต้องการจะใช้ตัวแบบรู้จำเท่านั้น โดยให้ผู้ใช้ทำกิจกรรมต่าง ๆ ภายในระยะเวลาที่กำหนด ซึ่งอาจก่อความไม่สะดวกให้แก่ผู้ใช้มากเกินไป ดังนั้นงานวิจัยนี้จึงได้นำเสนอกรอบแนวคิดใหม่ของการรู้จำกิจกรรมที่หยุดหย่อนได้ด้วยสมาร์ทโฟน ที่ชื่อเรียกว่า “ไอชาร์พลัส” ซึ่งเป็นตัวแบบไม่เฉพาะบุคคล (สากล) ที่สามารถใช้กับผู้ใช้ใหม่ได้ โดยที่ผู้ใช้ใหม่ที่ต้องการใช้งานสามารถนำตัวแบบไปใช้งานได้ทันทีโดยที่ไม่ต้องเตรียมข้อมูลสำหรับสร้างตัวแบบเอง ทั้งนี้ เพราะตัวแบบที่นำเสนอมีความสามารถปรับตัวแบบได้ตามข้อมูลกระแสของผู้ใช้แต่ละคนโดยใช้การเรียนรู้แบบเพิ่มขึ้นสำหรับการรู้จำในเวลาจริง งานวิจัยนี้ได้วัดประสิทธิภาพของตัวแบบที่นำเสนอทั้งในด้านความถูกต้องของการทำงานและด้านเวลาที่ใช้โดยใช้ข้อมูลสาธารณะที่เป็นการเก็บข้อมูลจริงของ การรู้จำกิจกรรมจำนวน 2 ชุดข้อมูล ผลการทดลองแสดงให้เห็นว่า วิธีการไอชาร์พลัสมีประสิทธิภาพที่ดีกว่าวิธีการอื่นที่นำมาเปรียบเทียบ โดยเฉพาะอย่างยิ่งกับข้อมูลสอนและข้อมูลทดสอบจากผู้ใช้ที่ต่างกันและไม่จำเป็นต้องสอบถามกิจกรรมที่แท้จริงจากผู้ใช้ ซึ่งวิธีการไอชาร์พลัสได้แสดงให้เห็นว่ามีความถูกต้องเฉลี่ยในการทำงานหรืออนุมานการทำงานมากกว่า 85%

**คำสำคัญ:** การรู้จำกิจกรรม ตัวรับรู้แอคเซเลอโรมิเตอร์ สมาร์ทโฟน การทำเหมือนข้อมูล สุขภาพ

### Abstract

Human activity recognition using streaming data from the accelerometer sensor of smartphone is still an interesting issue for researchers. Most researches develop the recognition model based on personal model type which require the training data obtained from only user who will utilize the model. To prepare the training data, the user must perform various activities and annotate them within the specified time. This is a major inconvenience for the users. In this paper, we propose a new smartphone-based dynamic framework for physical activity recognition named “ISAR+”. The new framework is an impersonal (universal) model which can be built once and used on new users without requiring labeled training data from those users. Because the proposed model is adaptability with evolving data streams of each new user by using the incremental learning for real-time recognition. This work was validated the proposed model in terms of prediction accuracy and usage times on two public activity recognition datasets. The experimental results

<sup>1</sup> ผู้ช่วยศาสตราจารย์, <sup>2</sup> อาจารย์, คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา อำเภอเมือง จังหวัดชลบุรี 20131

<sup>1</sup> Assist. Prof., <sup>2</sup> Lecturer, Faculty of Informatics, Burapha University, Mueang District, Chonburi, 20131

\* Corresponding author: Ureerat Suksawatchon, Faculty of Informatics, Burapha University, Mueang District, Chonburi, 20131

Email: ureerat@go.buu.ac.th

show that ISAR+ can achieve the best performance compared with the state-of-the-art models for streaming activity recognition, especially across different users and without inquiry from users. The ISAR+ has demonstrated the average accuracy more than 85% in both datasets.

**Keyword:** Activity recognition, Accelerometer sensor, Smartphones, Data mining, Health

## บทนำ

ปัจจุบันอุปกรณ์เคลื่อนที่ขนาดพกพา (Mobile device) ได้รับความนิยมในการใช้งานเป็นอย่างมาก ไม่ว่าจะเป็นสมาร์ทโฟน (Smartphone) หรืออุปกรณ์สวมใส่ (Wearable devices) อย่างนาฬิกาอัจฉริยะ ซึ่งคนส่วนใหญ่ใช้อุปกรณ์เหล่านี้ เมื่อเป็นปัจจัยที่ 5 แห่งอนุวัติอุปกรณ์เหล่านี้มีการติดตั้ง ตัวรับรู้ (Sensor) อัจฉริยะที่หลากหลายแบบ ด้วยอย่างเช่น Accelerometer Sensor ที่มีไว้สำหรับตรวจจับการเคลื่อนไหว ของอุปกรณ์ โดยเป็นการตรวจจับแบบ 3 แกน Gyroscope sensor เป็นตัวรับรู้ที่มีไว้สำหรับตรวจจับลักษณะของการหมุน ของอุปกรณ์ เป็นต้น ซึ่งข้อมูลจากตัวรับรู้เหล่านี้เป็นข้อมูล กระแสเชิงเวลา (Temporal streaming data) อย่างต่อเนื่อง ด้วยอัตราการสุ่มตัวอย่างตามที่กำหนดไว้ และกระแสข้อมูลเหล่านี้สามารถนำมาใช้สร้างตัวแบบรู้จำกิจกรรม (Activity recognition model) ผ่านขั้นตอนการเรียนรู้ (Learning algorithm) ด้วยวิธีการทำงานการทำเหมืองข้อมูล (Data mining) หรือการเรียนรู้ของเครื่องจักร (Machine learning) จนกระทั่ง ได้ตัวแบบรู้จำกิจกรรมที่สามารถตรวจจับและอนุมาน (Inferring) ว่าผู้ใช้กำลังทำการใดในขณะนั้นจากข้อมูลที่ ตัวรับรู้ส่งมา ตัวอย่างเช่นผู้ใช้กำลังยืน นั่ง เดิน หรือวิ่ง เป็นต้น ยิ่งไปกว่านั้นตัวแบบการรู้จำกิจกรรมของมนุษย์ถูกนำมาสร้าง เป็นแอปพลิเคชันที่สำคัญมาก many โดยเฉพาะแอปพลิเคชัน การดูแลสุขภาพ

การสร้างตัวแบบรู้จำกิจกรรมจำเป็นอย่างยิ่งที่ต้องเตรียม ข้อมูลการทำกิจกรรม (Annotated activities data) ดังนั้น ตัวแบบรู้จำกิจกรรมจึงสามารถสร้างได้ 3 ลักษณะ ขึ้นอยู่กับ ลักษณะข้อมูลที่ใช้สร้างตัวแบบ<sup>1</sup> ดังนี้

(1) ตัวแบบเฉพาะบุคคล (Personal model) เป็นตัวแบบ เฉพาะบุคคลที่สร้างขึ้นเพื่อจำแนกและระบุการทำกิจกรรมที่ทำ ของคนหนึ่งคนเดียว ดังนั้นการสร้างตัวแบบเฉพาะบุคคลนี้ ต้องให้ผู้ที่จะใช้งานตัวแบบเป็นผู้เตรียมข้อมูลของการทำ กิจกรรม ด้วยการทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนด ผ่านทางแอปพลิเคชันของผู้สร้างตัวแบบ จากนั้นข้อมูลการทำ กิจกรรมจากตัวรับรู้ของคนนั้นจะถูกนำไปสร้างตัวแบบและ ทดสอบตัวแบบตามขั้นตอนวิธีการเรียนรู้

(2) ตัวแบบไม่เฉพาะบุคคล (Impersonal model) หรือ ตัวแบบสากล (Universal model) ตัวแบบนี้ใช้ข้อมูลการทำ กิจกรรมของผู้ใช้คนใดก็ได้ไม่เฉพาะเจาะจง มาใช้สร้างตัวแบบ กล่าวคือผู้ที่ใช้งานตัวแบบไม่ต้องเก็บข้อมูลการทำกิจกรรม ของตนเอง ก็สามารถเริ่มใช้ตัวแบบรู้จำกิจกรรมผ่านแอปพลิ เคชันนั้น ๆ ได้ทันที ทั้งนี้เพื่อความสะดวกของผู้ใช้งาน

(3) ตัวแบบลูกผสม (Hybrid model) เป็นตัวแบบที่ใช้ การรวมกันของตัวแบบเฉพาะบุคคลและตัวแบบไม่เฉพาะ บุคคล ดังนั้นการสร้างตัวแบบใช้ทั้งข้อมูลการทำกิจกรรมของ ผู้ใช้คนใดก็ได้ไม่เฉพาะเจาะจง ร่วมกับข้อมูลการทำกิจกรรม ของผู้ที่ต้องการใช้ตัวแบบ จึงเป็นต้องให้ผู้ใช้งานตัวแบบทำ กิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนด

ดังนั้นในบทความวิจัยนี้ คงจะผู้วิจัยต้องการนำเสนอ ตัวแบบรู้จำกิจกรรมแบบใหม่โดยใช้เพียงกระแสข้อมูลจาก Accelerometer sensor ของสมาร์ทโฟนเท่านั้น และตัวแบบ ที่นำเสนอเป็นตัวแบบไม่เฉพาะบุคคลหรือตัวแบบสากล เพื่อเป็นตัวแบบกลางที่สามารถใช้กับบุคคลใดก็ได้ เมื่อผู้ใช้ ใหม่นำไปใช้งานจริง ตัวแบบรู้จำที่นำเสนอเป็นสามารถปรับ ตัวแบบ (Adaptive model) ได้อย่างอัตโนมัติ เพื่อให้เป็น ตัวแบบรู้จำที่เข้ากับลักษณะการทำกิจกรรมของผู้ใช้คนนั้น โดยที่ผู้ใช้ใหม่ไม่ต้องเตรียมข้อมูลการทำกิจกรรมใด ๆ และ ไม่ต้องมีขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบใหม่ ซึ่งจะยกล่าว ในรายละเอียดต่อไป

## งานวิจัยการรู้จำกิจกรรม

งานวิจัยที่เกี่ยวกับการรู้จำกิจกรรมด้วยข้อมูลจากตัวรับรู้ของ สมาร์ทโฟนยังคงเป็นหัวข้อที่ได้รับความสนใจและพัฒนา ผลงานวิจัยอย่างต่อเนื่อง โดยเริ่มจากงานวิจัยที่เน้นการสร้าง ตัวแบบรู้จำเฉพาะบุคคล ได้แก่ งานวิจัยของ Gomes et al.<sup>2</sup> ที่พิมพ์ในปี ค.ศ. 2012 ที่พัฒนาวิธีการที่ชื่อว่า “MARS” โดยวิธีการนี้ สามารถรู้จำกิจกรรมจากข้อมูลกระแสที่ได้จาก Accelerometer sensor ของสมาร์ทโฟน ซึ่งวิธีการ MARS มีขั้นตอนการเรียนรู้ (Training phase) เพื่อสร้างตัวแบบรู้จำ กิจกรรม ดังนั้นผู้ใช้ต้องเก็บสมาร์ทโฟนไว้ที่กระเบื้องเงา กิจกรรม ที่ตั้งขนาดหน้า และทำกิจกรรมทั้งหมด 5 กิจกรรม ได้แก่

เดิน (Walking), วิ่งเบา ๆ (Jogging), ปีนบันได (Climbing stairs), นั่ง (Sitting), และยืน (Standing) กิจกรรมละ 30 วินาที เพื่อใช้เป็นข้อมูลการทำกิจกรรมของผู้ใช้สำหรับเรียนรู้ตัวแบบ จากนั้นใช้วิธี Naïve Bayes ในการสร้างตัวแบบบูรณาการกิจกรรม โดยวิธีการ MARS เน้นที่การสร้างตัวแบบบูรณาการกิจกรรมและเก็บข้อมูลไว้ในอุปกรณ์สมาร์ทโฟน (On-board device)

ในปี ค.ศ. 2014 งานวิจัยของ Lockhart และ Weiss<sup>3</sup> ได้นำเสนอวิธีการที่ชื่อว่า "Actitracker" โดยวิธีการนี้มีขั้นตอนการเรียนรู้เช่นเดียวกันกับวิธีการ MARS เพื่อเก็บรวบรวมข้อมูลการทำกิจกรรมของผู้ใช้ที่ได้จาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน โดยให้ผู้ใช้เก็บสมาร์ทโฟนไว้ที่กระเพาะ การเงงที่ด้านข้างหน้า และทำกิจกรรมทั้งหมด 7 กิจกรรมคล้ายกับวิธีการ MARS โดยการแยกการปีนบันได เป็นการขึ้นบันไดและลงบันได และเพิ่มกิจกรรมนอนนิ่ง (Lying down) ซึ่งผู้ใช้ต้องทำกิจกรรมละประมาณ 2-3 นาที จากนั้นข้อมูลการทำกิจกรรมของผู้ใช้จะถูกส่งไปที่เครื่องแม่ข่ายเพื่อสร้างตัวแบบบูรณาการกิจกรรมด้วยวิธีจำแนกประเภทหลายวิธี แต่ Random Forest เป็นวิธีการที่ให้ผลการอนุมานการทำกิจกรรมดีที่สุด

ส่วนงานวิจัยของ Uddin *et al.*<sup>4</sup> ในปี ค.ศ. 2016 ได้นำเสนอวิธีการสร้างตัวแบบบูรณาการกิจกรรมโดยใช้การพิจารณารูปแบบการเปลี่ยนกิจกรรม เช่น จากยืนไปนั่ง จากนั่งไปนอน จากนอนไปยืน เป็นต้น เช่นเดียวกันกับวิธีการอื่น กล่าวคือต้องให้ผู้ใช้ทำกิจกรรมในรูปแบบต่าง ๆ รวมไปถึงการเปลี่ยนกิจกรรม จากกิจกรรมหนึ่งเป็นอีกกิจกรรมหนึ่งในรูปแบบต่าง ๆ โดยข้อมูลการทำกิจกรรมได้จาก Accelerometer sensor และ Gyroscope sensor ของอุปกรณ์สมาร์ทโฟน จากนั้นจะนำข้อมูลไปสร้างตัวแบบด้วยวิธีการ Random Forest

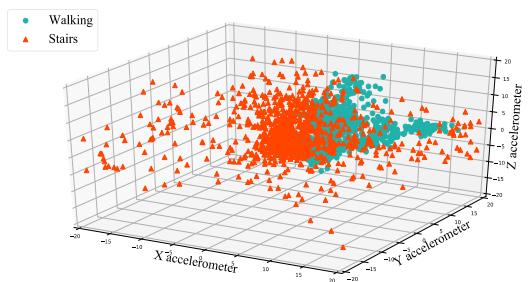
ในส่วนของงานวิจัยที่เน้นการสร้างตัวแบบไม่เฉพาะบุคคล เช่น งานวิจัยของ Abdallah *et al.*<sup>5</sup> เมย์แพร์ในปี ค.ศ. 2015 ได้นำเสนอวิธีการ "STAR" ที่สามารถถูกรักษาการกับข้อมูลกระแสเชิงเวลาที่ได้จาก Accelerometer sensor เพียงตัวรับรู้ด้วยของอุปกรณ์สมาร์ทโฟน วิธีการ STAR ไม่จำเป็นต้องให้ผู้ใช้ทำกิจกรรมต่าง ๆ เนื่องจากวิธีการ STAR ใช้ข้อมูลการทำกิจกรรมจากงานวิจัยของ Lockhart และ Weiss<sup>3</sup> ในการสร้างตัวแบบบูรณาการ โดยเน้นที่ 5 กิจกรรมหลัก ได้แก่ เดิน วิ่งเบา ๆ ปีนบันได (รวมขึ้นและลงบันได) นั่ง และ ยืน ยกเว้นกิจกรรมการนอนนิ่ง ๆ นอกจากนี้วิธีการ STAR ใช้แนวคิด Active learning ในกรณีที่ตัวแบบบูรณาการให้ผลการทำนายหรืออนุมานว่าผู้ใช้กำลังทำกิจกรรมอย่างน้อย 2 กิจกรรมในเวลาเดียวกัน จะต้องให้ผู้ใช้ยืนยันการทำกิจกรรมจริงในขณะนั้นผ่านแอปพลิเคชันของ STAR วิธีการ STAR

มีขั้นตอนการทำงานเป็นสองส่วน ส่วนที่หนึ่งเป็นขั้นตอนการสร้างตัวแบบบูรณาการ (Modelling component) ที่เรียกว่า LM (Learning model) โดยนำข้อมูลการทำกิจกรรม (Annotated data) ของแต่ละกิจกรรม แบ่งเป็นกลุ่มย่อย (Clustering) ตามจำนวนกลุ่มที่กำหนด แล้วเก็บข้อมูลสรุป (Statistics summary) ของแต่ละกลุ่มย่อย ขั้นตอนในส่วนที่สอง คือการรู้จำกิจกรรมและปรับปรุงตัวแบบบูรณาการ (Online recognition and adaption phase) เป็นขั้นตอนที่นำตัวแบบ LM มาใช้งานจริงบนอุปกรณ์สมาร์ทโฟน โดยข้อมูลกระแสที่ส่งมาอย่างต่อเนื่องจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน จะถูกแบ่งออกเป็นหน้าต่าง (Window) ซึ่งข้อมูลกระแสในแต่ละหน้าต่างถูกแบ่งเป็นสองกลุ่มโดยใช้วิธีการแบ่งกลุ่ม Expectation Maximization (EM) กลุ่มที่มีข้อมูลมากที่สุดจะถูกนำไปจำแนกประเภทกิจกรรมด้วยมาตรฐาน 4 ตัว ได้แก่ Distance, Gravity, Density และ Deviation ซึ่งถ้ามาตรฐาน 3 ใน 4 มาตรฐานระบุเป็นกิจกรรมเดียวกัน จะปรับปรุงตัวแบบบูรณาการ LM ด้วยวิธี Incremental learning แต่ถ้ามาตรฐานทั้ง 4 มาตรฐานต่างกันจะถูกตัดออก จึงปรับค่าข้อมูลสรุปของกลุ่มย่อยของกิจกรรมที่ผู้ใช้ระบุกับข้อมูลกระแสที่เข้ามา

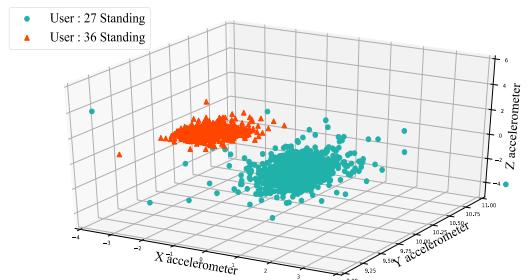
ในปี ค.ศ. 2018 งานวิจัยของ Jalal *et al.*<sup>6</sup> ได้นำเสนอตัวแบบไม่เฉพาะบุคคลเช่นเดียวกัน ที่สามารถถูกรักษาการกิจกรรมจากข้อมูลกระแสเชิงเวลาที่ได้จาก Accelerometer sensor การทำนายหรืออนุมานว่าปัจจุบันผู้ใช้กำลังทำกิจกรรมใดในงานวิจัยนี้ได้นำเสนอตัวแบบที่มีการทำงาน 3 ขั้นตอนตามลำดับ คือ ขั้นตอนการทำจัดสัญญาณรบกวนโดยใช้ตัวกรองมัธยฐาน (Median filter) อันดับ 3 จากนั้นสัญญาณที่ผ่านการทำจัดมาแล้วจะเข้าสู่ขั้นตอนการสกัดคุณลักษณะแบบลำดับชั้น (Hierarchical features) ได้แก่ ขนาดของสัญญาณค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐาน เป็นต้น และสุดท้ายเป็นขั้นตอนการทำคุณลักษณะที่สกัดได้จากสัญญาณมาสร้างเป็นตัวแบบสำหรับการจำแนกกิจกรรมด้วย Linear Support Vector Machine

จากการวิจัยที่กล่าวมาข้างต้น ถึงแม้การสร้างตัวแบบเฉพาะบุคคลจะได้ตัวแบบบูรณาการที่เหมาะสมกับคนคนนั้น แต่ด้วยข้อจำกัดที่สำคัญ คือ จำเป็นต้องให้ผู้ใช้ทำกิจกรรมเพื่อเก็บข้อมูลสำหรับสร้างตัวแบบ ซึ่งถ้าผู้ใช้ทำกิจกรรมไม่ครบถ้วนกิจกรรมหรือทำไม่ครบตามเวลาที่กำหนด ก็จะไม่สามารถสร้างตัวแบบบูรณาการกิจกรรมได้ หรือได้ตัวแบบบูรณาการที่ไม่สมบูรณ์ ดังจากการสร้างตัวแบบบูรณาการไม่เฉพาะบุคคลที่ผู้ใช้สามารถนำตัวแบบไปใช้งานได้ทันที จากนั้นตัวแบบบูรณาการถูกรับปรับปรุงตัวแบบอย่างอัตโนมัติเพื่อให้เป็น

ตัวแบบบัญชีสำหรับผู้ใช้แต่ละคนโดยเฉพาะ แต่อย่างไรก็ตาม เนื่องจากตัวแบบไม่เฉพาะบุคคล ยังมีข้อจำกัดที่สำคัญที่อาจทำให้การท่านายหรืออ่อนมานกิจกรรมผิดพลาด อันเนื่องมาจากการใช้ข้อมูลการทำกิจกรรมของผู้ใช้คนอื่นมาสร้างตัวแบบ ตัวอย่างเช่นกิจกรรมบางกิจกรรมมีความคล้ายคลึงกัน เช่น การขึ้นลงบันไดมีความคล้ายกับการเดิน เนื่องจากการขึ้นลงบันไดเป็นการเดินรูปแบบหนึ่ง สังเกตได้จาก Figure 1 เป็นการแสดงแผนภาพการกระจายของข้อมูลกิจกรรมการเดินและการขึ้นลงบันได จะเห็นว่าข้อมูลของกิจกรรมทั้งสองมีความทับซ้อนกัน (Overlapping data) การจำแนกกิจกรรมทั้งสองจึงง่ายหากความผิดพลาดขึ้นได้ นอกจากนี้ตัวแบบบัญชีไม่เฉพาะบุคคลนั้นสร้างจากข้อมูลกิจกรรมของผู้ใช้คนใดก็ได้ ซึ่งถ้าข้อมูลการทำกิจกรรมที่ใช้สร้างตัวแบบแตกต่างกับข้อมูลของผู้ใช้งานตัวแบบมากเกินไป อาจทำให้ตัวแบบบัญชีที่สร้างขึ้นทำนายกิจกรรมผิดพลาดได้ จะเห็นได้จาก Figure 2 ที่เป็นแผนภาพการกระจายของข้อมูลกิจกรรมการยืน ถ้าการสร้างตัวแบบบัญชีกิจกรรมใช้ข้อมูลผู้ใช้หมายเลข 27 ก็อาจไม่สามารถรู้จักกิจกรรมการยืนของผู้ใช้หมายเลข 36 ได้ เนื่องจากลักษณะข้อมูลกิจกรรมการยืนของผู้ใช้ทั้งสองคนแตกต่างกัน ทั้งนี้อาจเกิดจากการจัดวางอุปกรณ์สมาร์ทโฟนในระเบียบที่แตกต่างกัน



**Figure 1** Accelerometer data of walking and stairs activities.



**Figure 2** Standing activity data of two users.

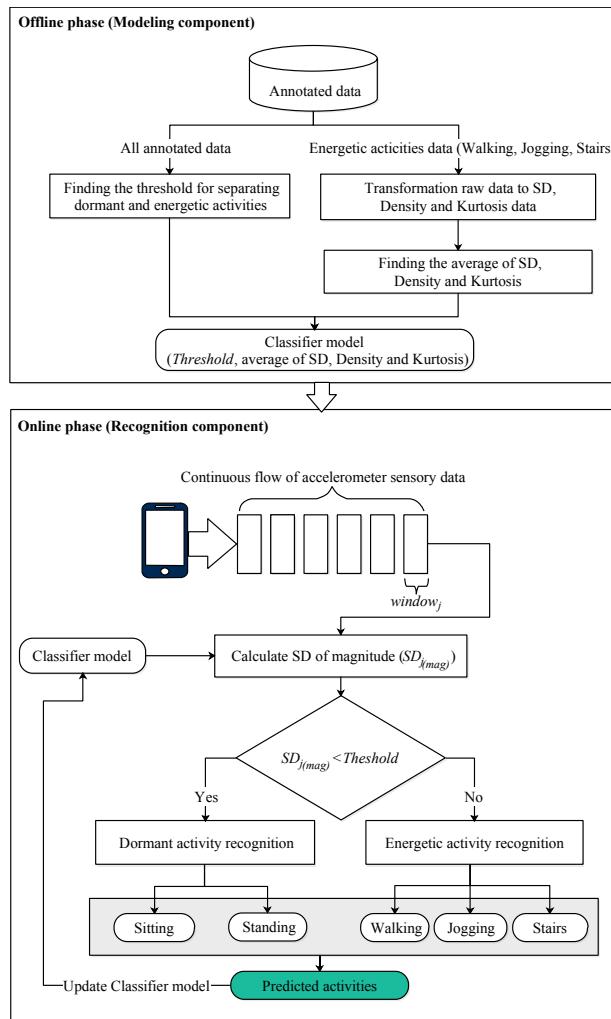
## กรอบแนวคิดที่นำเสนอ

เพื่อการแก้ปัญหาของงานวิจัยที่กล่าวมาข้างต้น งานวิจัยนี้จึงนำเสนอตัวแบบบัญชีกิจกรรมแบบใหม่ชื่อว่า “ISAR+” (An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data) ซึ่งเป็นตัวแบบบัญชีกิจกรรมไม่เฉพาะบุคคลที่พัฒนาต่อยอดมาจากวิธีการเดิมของผู้วิจัยเองที่ชื่อ ISAR<sup>7</sup> โดยวิธีการ ISAR+ มีจุดเด่นดังนี้

(1) เป็นตัวแบบบัญชีไม่เฉพาะบุคคลหรือตัวแบบกลางโดยผู้ใช้ใหม่ที่ต้องการใช้งานสามารถนำตัวแบบไปใช้งานได้โดยที่ไม่ต้องเตรียมข้อมูลสำหรับสร้างตัวแบบเอง และไม่ต้องมีขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบใหม่ ทั้งนี้ เพราะวิธีการ ISAR+ เป็นตัวแบบบัญชีที่สามารถปรับตัวแบบให้เหมาะสมกับลักษณะการทำกิจกรรมของผู้ใช้ใหม่แต่ละบุคคลได้ด้วยวิธีการเรียนรู้แบบเพิ่มขึ้น (Incremental learning) และวิธีการ ISAR+ ไม่มีส่วนของการทำ Active learning

(2) เป็นตัวแบบบัญชีที่มีน้ำหนักเบา (Light-weight recognition model) เนื่องจากใช้ข้อมูลที่ได้จาก Accelerometer sensor เพียงตัวรับรู้เดียวเท่านั้นในการสร้างตัวแบบ ดังนั้นตัวแบบที่นำเสนอจึงที่สามารถติดตั้งภายใต้อุปกรณ์สมาร์ทโฟน และสามารถรู้จักกิจกรรมแบบเวลาจริงได้

วิธีการ ISAR+ มีกรอบแนวคิดแสดงดัง Figure 3 ประกอบด้วย 2 ขั้นตอน ได้แก่ ขั้นตอนออนไลน์สำหรับสร้างตัวแบบบัญชีกิจกรรม (Modeling component) และ ขั้นตอนออนไลน์สำหรับบัญชีกิจกรรมและปรับปรุงตัวแบบบัญชีกิจกรรม (Recognition component)



**Figure 3** An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+).

### วิธีการวิจัย

#### ข้อมูลที่ใช้สร้างตัวแบบ

วิธีการ ISAR+ ใช้ข้อมูลการทำกิจกรรมที่เป็นข้อมูลสาธารณะ (Public data) ได้แก่ 1) ข้อมูล WISDM<sup>3,8</sup> ที่เก็บการทำกิจกรรมของอาสาสมัครจำนวน 36 คน ด้วยการใช้อุปกรณ์สมาร์ทโฟน โดยให้อาสาสมัครทั้ง 36 คน ใส่อุปกรณ์สมาร์ทโฟนไว้ในกระเป๋าเป้ากางเกงด้านหน้า ซึ่งตั้งค่าอัตราการสัมผัสด้วยข้อมูลเท่ากับ 20 Hz และทำกิจกรรมต่าง ๆ ด้วยข้อมูลแสดงดัง Figure 4 และ 2) ข้อมูล UniMiB-SHAR<sup>9</sup> ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 30 คน ด้วยการใช้อุปกรณ์สมาร์ทโฟนโดยให้อาสาสมัครทั้ง 30 คน ใส่อุปกรณ์สมาร์ทโฟนไว้ในกระเป๋าเป้ากางเกง

ด้านหน้า ซึ่งตั้งค่าอัตราการสัมผัสด้วยข้อมูลเท่ากับ 50 Hz และทำกิจกรรมทางกายภาพต่าง ๆ ด้วยข้อมูลแสดงดัง Figure 5

เนื่องจากข้อมูลสาธารณะที่นำมาใช้สร้างตัวแบบรู้จำกิจกรรม มีกิจกรรมอนิ่งเพียงกิจกรรมเดียวที่อาสาสมัครไม่ได้ทำทุกคน จึงทำให้กิจกรรมนี้มีจำนวนด้วยกันที่จำนวนน้อยกว่ากิจกรรมอื่น ๆ หากนำข้อมูลกิจกรรมอนิ่งมาใช้สร้างตัวแบบอาจทำให้ได้ตัวแบบที่รู้จำกิจกรรมผิดพลาดได้ดังนั้นในงานวิจัยนี้จึงเน้นการสร้างตัวแบบรู้จำกิจกรรมเพียง 5 กิจกรรม ได้แก่ นั่ง ยืน วิ่ง และขึ้นลงบันได เช่นเดียวกันกับวิธีการ STAR และงานวิจัย<sup>6</sup> ดังนั้นจำนวนด้วยกันของแต่ละกิจกรรมที่ใช้ในการสร้างตัวแบบแสดงใน Table 1

Sample	User	Lable	Timestamp	ax	ay	az
s <sub>1</sub>	27	Walking	10401072248	4.21	7.97	-2.07
s <sub>2</sub>	27	Walking	10401172376	0.95	8.47	0.65
s <sub>3</sub>	27	Walking	10401322278	4.21	15.79	0.99
s <sub>4</sub>	27	Walking	10401372327	1.65	13.53	-0.69
s <sub>5</sub>	27	Walking	10401422315	-2.34	13.48	1.45
s <sub>6</sub>	27	Walking	10401472303	-0.76	10.27	-0.84
:	:		:	:	:	:
s <sub>i</sub>	27	Walking	:	ax <sub>i</sub>	ay <sub>i</sub>	az <sub>i</sub>
:	:		:	:	:	:
s <sub>N</sub>	27	Walking	:	ax <sub>N</sub>	ay <sub>N</sub>	az <sub>N</sub>

**Figure 4** The example of annotated data of walking activity data provided by WISDM.

Sample	User	Lable	ax	ay	az
s <sub>1</sub>	13	Standing	-1.88	9.85	-0.23
s <sub>2</sub>	13	Standing	-0.19	9.92	-0.57
s <sub>3</sub>	13	Standing	-0.61	10.27	-0.88
s <sub>4</sub>	13	Standing	-0.11	9.58	2.49
s <sub>5</sub>	13	Standing	-0.72	9.89	2.41
s <sub>6</sub>	13	Standing	-0.53	9.34	2.49
:	:		:	:	:
s <sub>i</sub>	13	Standing	ax <sub>i</sub>	ay <sub>i</sub>	az <sub>i</sub>
:	:		:	:	:
s <sub>N</sub>	13	Standing	ax <sub>N</sub>	ay <sub>N</sub>	az <sub>N</sub>

**Figure 5** The example of annotated data of standing activity data provided by UniMiB-SHAR.

#### ขั้นตอนการดำเนินการวิจัย

วิธีการ ISAR+ ประกอบไปด้วย ขั้นตอนออนไลน์สำหรับสร้างตัวแบบรู้จำกิจกรรม และขั้นตอนออนไลน์สำหรับรู้จำกิจกรรมและปรับปรุงตัวแบบ โดยงานวิจัยนี้ได้นำการสร้างตัวแบบรู้จำกิจกรรมทางกายภาพ ได้แก่ เดิน นั่ง ยืน วิ่ง เป้า และขึ้นลงบันได

**Table 1** The number of samples for each activity provided by WISDM and UniMiB-SHAR

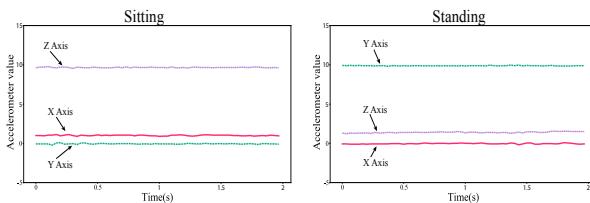
Activity	The number of samples	
	WISDM	UniMiB-SHAR
Standing	38,520	319,550
Sitting	50,000	405,350
Walking	223,300	482,900
Jogging	129,900	395,200
Up-Down Stairs	177,100	245,500

เนื่องจากเป็นกิจกรรมพื้นฐานของมนุษย์ วิธีการ ISAR+ แบ่งประเภทของกิจกรรมออกเป็น 2 กลุ่มใหญ่ กลุ่มแรกเป็น กิจกรรมที่มีการเคลื่อนไหวร่างกายเล็กน้อย ได้แก่ ยืน และนั่ง เรียกว่า “กิจกรรมแบบอยู่นิ่ง (Dormant activities)” กลุ่มที่สองเป็นกิจกรรมที่เคลื่อนไหวร่างกายค่อนข้างมากหรือการยับร่างกายอย่างรวดเร็ว ได้แก่ เดิน วิ่ง และขึ้นลงบันได เรียกว่า “กิจกรรมแบบเคลื่อนไหว (Energetic activities)” รายละเอียดของแต่ละขั้นตอนตามกรอบแนวคิดดังนี้

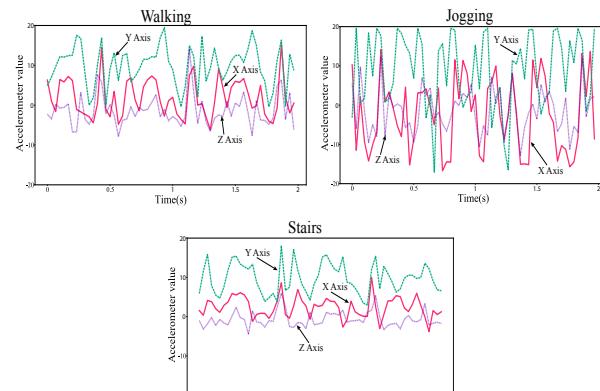
1. ขั้นตอนอุปไฟล์ เป็นขั้นตอนสำหรับสร้างตัวแบบรู้จำกิจกรรม หรือ Classifier Model (CM) ดังแสดงใน **Algorithm 1**

กำหนดให้  $act$  เป็นเซตของกิจกรรมต่างๆ แต่ละ  $act$  ประกอบด้วยเซตของตัวอย่าง (Sample)  $S = \{s_1, s_2, s_3, \dots, s_i, \dots, s_N\}$  โดยที่  $N$  หมายถึงจำนวนตัวอย่างของแต่ละ  $act$  และ  $s_i$  นิยามเป็น 4-tuple คือ  $(ax_i, ay_i, az_i, t_i)$  ซึ่ง  $ax_i, ay_i, az_i$  คือค่า Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับ หมายถึง  $t_i$  ชนิดของกิจกรรม (Activity Label)

จาก **Algorithm 1** เริ่มต้นจากการหาค่าขีดแบ่ง  $Threshold$  เพื่อใช้สำหรับแยกประเภทของข้อมูลกิจกรรม ดังที่ได้กล่าวไว้ข้างต้นจาก Figure 6 และ Figure 7 จะสังเกตได้ว่าเส้นข้อมูลของค่า Accelerometer ทั้ง 3 แกนของกิจกรรม ทั้ง 2 กลุ่ม มีความแตกต่างกันอย่างชัดเจน กิจกรรมแบบนิ่ง ลักษณะเส้นข้อมูลของค่า Accelerometer มีการแก่ง่อนอยมาก หรือเกือบคงที่ และมีการกระจายตัวของข้อมูลน้อย เนื่องจาก กิจกรรมกลุ่มนี้มีการเคลื่อนไหวน้อย ทำให้มีผลต่อค่า Accelerometer ตรงกันข้ามกับกิจกรรมแบบเคลื่อนไหว ที่เส้นข้อมูลมีลักษณะแก่ง่อนอย่างมาก และมีการกระจายตัวของข้อมูลที่สูง เนื่องจากกิจกรรมกลุ่มนี้เกิดการเปลี่ยนแปลงของค่า Accelerometer ตลอดเวลา



**Figure 6** Accelerometer lines of dormant activities.



**Figure 7** Accelerometer lines of energetic activities.

ดังนั้นการหาค่าขีดแบ่ง  $Threshold$  เริ่มจากพิจารณาแต่ละ  $act$  โดยคำนวณค่า Magnitude ( $M_i$ ) ของแต่ละตัวอย่าง  $s_i$  ด้วย Equation 1 จากนั้นคำนวณค่าเฉลี่ยของค่า Magnitude ( $M_i$ ) ของแต่ละ window  $j$  ( $M_j$ ) โดย 1 window มีจำนวนตัวอย่างเท่ากับอัตราการสูบของข้อมูลที่ใช้ แล้วนำไปคำนวณหาค่าส่วนเบี่ยงเบนมาตรฐาน (SD) ของแต่ละ window  $j$  โดยใช้ Equation 2 ซึ่งจะทำให้ได้ค่า  $SD_{j(mag)}^{act}$

$$M_i = \sqrt{ax_i^2 + ay_i^2 + az_i^2} \quad (1)$$

โดยที่  $i = 1, 2, 3, \dots, n$  ซึ่ง  $n$  คือ จำนวนข้อมูลตัวอย่างทั้งหมดภายใน window ที่  $j$

$$SD_{j(mag)}^{act} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (M_i - \bar{M}_j)^2} \quad (2)$$

**Algorithm 1:** ISAR+ model : Offline phase (Modeling component)

```

/*  $N_{\zeta}$  = the set of annotated data of
all activities. */  

/*  $CM = \{Std_{CM}^{act}, Dens_{CM}^{act}, Kurt_{CM}^{act}\}$  when act
are walking, jogging and stairs. */  

/* Threshold = the separating dormant
and energetic activites. */  

/*  $J$  = the number of window. */  

/*  $n$  = the number of data in window. */  

Input :  $N_{\zeta}$ .  

Output:  $CM, Threshold$ .  

1 for each act in annotated data do  

    /* act = (sitting, standing, walking,
    jogging, staris) */  

    2 for each window  $j$  do  

        /*  $j = 1, 2, 3, \dots, J$  */  

        3 Compute  $M_i$  for each sample using eq. (1)  

        /*  $i = 1, 2, 3, \dots, n$  */  

        4 Compute average magnitude  $\bar{M}_j$  of window  $j$ .  

        5 Compute standard deviation  $SD_{j(mag)}^{act}$  using eq.  

            (2).  

    6 end  

7 end  

8 Find the maximum of standard deviation of dormant
activities  $SD_{max}$  using eq. (3).  

9 Find the minimum of standard deviation of energetic
activities  $SD_{min}$  using eq. (4).  

10 Compute  $Threshold = \frac{SD_{max} + SD_{min}}{2}$ .  

11 for each energetic activity act do  

    /* act = (walking, jogging, staris) */  

    12 for each window  $j$  do  

        /*  $j = 1, 2, 3, \dots, J$  */  

        13 Compute the standard deviation of each
        acceleration values using eq. (6)-(8).  

        14 Compute the density of each acceleration values
        using eq. (9)-(11).  

        15 Compute the kurtosis of each acceleration values
        using eq. (12)-(14).  

    16 end  

    17 Compute average of standard deviation using eq.
        (15)-(17) then set  $SD_{CM}^{act}$  using eq. (24)  

    18 Compute average of density using eq. (18)-(20) then
        set  $Dens_{CM}^{act}$  using eq. (25)  

    19 Compute average of kurtosis using eq. (21)-(23) then
        set  $Kurt_{CM}^{act}$  using eq. (26)  

    20 Add  $SD_{CM}^{act}$ ,  $Dens_{CM}^{act}$  and  $Kurt_{CM}^{act}$  to the  $CM$ .  

21 end

```

หาค่า SD ที่มากที่สุดของกิจกรรมแบบนิ่ง ( $SD_{max}$ )

$$SD_{max} = \max \{SD_{j(mag)}^{act} \mid act \in \{\text{sitting, standing}\}\} \quad (3)$$

หาค่า SD ที่น้อยที่สุดของกิจกรรมเคลื่อนไหว ( $SD_{min}$ )

$$SD_{min} = \min \{SD_{j(mag)}^{act} \mid act \in \{\text{walking, jogging, stairs}\}\} \quad (4)$$

คำนวณค่าขีดแบ่ง  $Threshold$  ดังนี้

$$Threshold = \frac{SD_{max} + SD_{min}}{2} \quad (5)$$

จาก Figure 8 แสดงให้เห็นว่าค่าขีดแบ่ง  $Threshold$  ที่คำนวณได้สามารถแยกประเภทกิจกรรมทั้งสองกลุ่มได้ ซึ่งค่า  $Threshold$  นี้จะนำไปใช้ในขั้นตอนออนไลน์

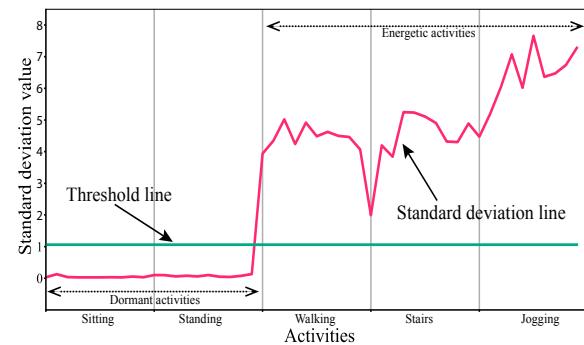


Figure 8 The threshold line.

จากนั้นเมื่อนำข้อมูลค่า Accelerometer ทั้ง 3 แกน ของกิจกรรมแบบเคลื่อนไหว โดยให้แสดงเป็นแผนภาพ การกระจายตัวดัง Figure 9 คณะผู้วิจัยพบว่า ข้อมูลแต่ละ กิจกรรมซ้อนทับกันมาก ทั้งนี้เนื่องจากทั้ง 3 กิจกรรม มีลักษณะคล้ายกัน เช่นการเดินขึ้นลงบันไดก็ถือว่าเป็นการเดิน ในรูปแบบหนึ่ง ดังนั้นถ้านำข้อมูลชุดนี้ไปสร้างตัวแบบรูปจำ กิจกรรม จะทำให้ได้ตัวแบบที่ทำงานหรืออนุมานการทำงาน ของกิจกรรมปัจจุบันผิดพลาดได้ แต่เมื่อพิจารณาในรายละเอียด อื่น กลับพบว่าแม้ข้อมูลจะทับซ้อนกัน แต่มีการกระจายตัว ที่แตกต่างกัน ดังนั้นคณะผู้วิจัยจึงตั้งสมมติฐานขึ้นว่า การ แปลงข้อมูลของค่า Accelerometer ทั้ง 3 แกน ของแต่ละ  $act$  ไปเป็นค่าของส่วนเบี่ยงเบนมาตรฐาน (SD) ของแต่ละแกน ในแต่ละ window สามารถแยกข้อมูลของแต่ละกิจกรรม ได้ดีขึ้น ซึ่งการแปลงข้อมูลกิจกรรมทำได้โดยใช้ Equations 6, 7 และ 8

$$SD_{j(ax)}^{act} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax_i - \bar{ax})^2} \quad (6)$$

$$SD_{j(ay)}^{act} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay_i - \bar{ay})^2} \quad (7)$$

$$SD_{j_{(az)}}^{act} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (az_i - \bar{az}_j)^2} \quad (8)$$

โดยที่  $\bar{ax}_j, \bar{ay}_j, \bar{az}_j$  คือค่าเฉลี่ยของค่า Accelerometer ของตัวอย่าง  $S_j$  ตามแนวแกน X, Y และ Z ตามลำดับ  $i = 1, 2, 3, \dots, n$  ซึ่ง  $n$  คือจำนวนข้อมูลตัวอย่างทั้งหมดภายใน window ที่  $j$

จาก Figure 10 เป็นผลลัพธ์จากการแปลงข้อมูลค่า Accelerometer ของทั้ง 3 กิจกรรม ไปเป็นค่าของ  $SD$  ในแต่ละ window จะเห็นได้ว่ากลุ่มข้อมูลแต่ละกิจกรรมที่เคยทับช้อนกันสามารถแยกเป็นกลุ่มออกจากกันได้ซึ่งจะส่งผลให้การจำแนกข้อมูลกิจกรรมสามารถทำได้่ายยิ่งขึ้น

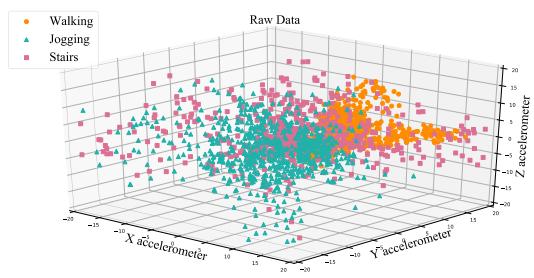


Figure 9 Accelerometer data of energetic activities.

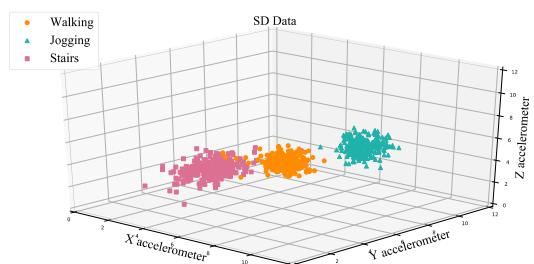


Figure 10 SD data of energetic activities.

นอกจากนี้ในวิธีการ ISAR+ มีการแปลงข้อมูลค่า Accelerometer ตามแกน X, Y และ Z ของแต่ละ  $act$  ในแต่ละ window  $j$  เป็นข้อมูลความหนาแน่น ( $Dens_{j_{(ax)}}^{act}, Dens_{j_{(ay)}}^{act}, Dens_{j_{(az)}}^{act}$ ) และความถ่อง ( $Kurt_{j_{(ax)}}^{act}, Kurt_{j_{(ay)}}^{act}, Kurt_{j_{(az)}}^{act}$ ) อีกด้วย เพื่อใช้เป็นคุณลักษณะที่สำคัญในการนำายหรืออนุมานการทำกิจกรรมของขั้นตอนการปรับปรุงตัวแบบรู้จำกิจกรรมในขั้นตอนออนไลน์ ซึ่งมีวิธีการคำนวณดัง Equation 9 ถึง Equation 14

$$Dens_{j_{(ax)}}^{act} = \frac{n}{ax_{max} - ax_{min}} \quad (9)$$

$$Dens_{j_{(ay)}}^{act} = \frac{n}{ay_{max} - ay_{min}} \quad (10)$$

$$Dens_{j_{(az)}}^{act} = \frac{n}{az_{max} - az_{min}} \quad (11)$$

$$Kurt_{j_{(ax)}}^{act} = \frac{\sum_{i=1}^n (ax_i - \bar{ax}_j)^4}{(\sum_{i=1}^n (ax_i - \bar{ax}_j)^2)^2} \quad (12)$$

$$Kurt_{j_{(ay)}}^{act} = \frac{\sum_{i=1}^n (ay_i - \bar{ay}_j)^4}{(\sum_{i=1}^n (ay_i - \bar{ay}_j)^2)^2} \quad (13)$$

$$Kurt_{j_{(az)}}^{act} = \frac{\sum_{i=1}^n (az_i - \bar{az}_j)^4}{(\sum_{i=1}^n (az_i - \bar{az}_j)^2)^2} \quad (14)$$

สุดท้ายคำนวณหาค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐานความหนาแน่น และความถ่องของแต่ละกิจกรรมแบบเคลื่อนไหว สามารถคำนวณได้จาก Equation 15 ถึง Equation 23 จากนั้นจะได้ Classifier model (CM) เพื่อเก็บข้อมูลสรุปได้แก่ ค่าขีดบ่ำ (Threshold) ค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐาน ( $SD_{CM}^{act}$ ) ค่าเฉลี่ยของความหนาแน่น ( $Dens_{CM}^{act}$ ) และค่าเฉลี่ยของความถ่อง ( $Kurt_{CM}^{act}$ ) ดัง Equation 24 ถึง Equation 26

ค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานตามแกน X, Y และ Z

$$SD_{avg_{(ax)}}^{act} = \frac{\sum_{j=1}^J SD_{j_{(ax)}}^{act}}{J} \quad (15)$$

$$SD_{avg_{(ay)}}^{act} = \frac{\sum_{j=1}^J SD_{j_{(ay)}}^{act}}{J} \quad (16)$$

$$SD_{avg_{(az)}}^{act} = \frac{\sum_{j=1}^J SD_{j_{(az)}}^{act}}{J} \quad (17)$$

ค่าเฉลี่ยความหนาแน่นตามแกน X, Y และ Z

$$Dens_{avg_{(ax)}}^{act} = \frac{\sum_{j=1}^J Dens_{j_{(ax)}}^{act}}{J} \quad (18)$$

$$Dens_{avg_{(ay)}}^{act} = \frac{\sum_{j=1}^J Dens_{j_{(ay)}}^{act}}{J} \quad (19)$$

$$Dens_{avg_{(az)}}^{act} = \frac{\sum_{j=1}^J Dens_{j_{(az)}}^{act}}{J} \quad (20)$$

ค่าเฉลี่ยความถ่องตามแกน X, Y และ Z

$$Kurt_{avg(ax)}^{act} = \frac{\sum_{j=1}^J Kurt_{j(ax)}^{act}}{J} \quad (21)$$

$$Kurt_{avg(ay)}^{act} = \frac{\sum_{j=1}^J Kurt_j^{act}}{J} \quad (22)$$

$$Kurt_{avg(az)}^{act} = \frac{\sum_{j=1}^J Kurt_{j(az)}^{act}}{J} \quad (23)$$

โดยที่  $j = 1, 2, 3, \dots, J$  และ  $J$  คือจำนวน window ทั้งหมดของหนึ่งกิจกรรม ( $act$ )

$$SD_{CM}^{act} = (SD_{avg(ax)}^{act}, SD_{avg/ay)}^{act}, SD_{avg(ay)}^{act}) \quad (24)$$

$$Dens_{CM}^{act} = (Dens_{avg(ax)}^{act}, Dens_{avg/ay)}^{act}, Dens_{avg(ay)}^{act}) \quad (25)$$

$$Kurt_{CM}^{act} = (Kurt_{avg_{(ax)}}^{act}, Kurt_{avg_{(ay)}}^{act}, Kurt_{avg_{(ay)}}^{act}) \quad (26)$$

ขั้นตอนออนไลน์

ภาพรวมการทำงานของขั้นตอนออนไลน์แสดงได้ดัง Figure 3 ซึ่งประกอบด้วยขั้นตอนการรู้จำจีกรรมและปรับตัวแบบกับข้อมูลกระเสเชิงเวลาที่ผลิตอย่างต่อเนื่องจากตัวรับรู้ Accelerometer ของสมาร์ทโฟน โดยการจัดการกับข้อมูลกระเสจะนำเข้าข้อมูลกระเสที่ลະ window ซึ่งจำนวนตัวอย่างภายใน window จะขึ้นอยู่กับการตั้งค่าอัตราสุ่มตัวอย่างของอุปกรณ์สมาร์ทโฟน การทำงานของขั้นตอนนี้แสดงใน **Algorithm 2** รวมถึงการปรับปรุงตัวแบบรู้จำจีกรรมใน **Algorithm 3**

ใน **Algorithm 2** เริ่มต้นจากการแปลงข้อมูลค่า Accelerometer ของตัวอย่างภายใน window เป็นส่วนเบี่ยงเบนมาตรฐานของ Magnitude ( $SD_{j_{(mag)}}$ ) เพื่อใช้ในการจำแนกว่าข้อมูลกระแทกที่เข้ามาเป็นกิจกรรมแบบผิ้งหรือแบบเคลื่อนไหว โดยเปรียบเทียบกับค่าขีดแบ่ง *Threshold* ที่คำนวณไว้แล้วในขั้นตอนออฟไลน์ ในการจำแนกประเภทกิจกรรมว่าเป็นกิจกรรมแบบผิ้งหรือเป็นกิจกรรมแบบเคลื่อนไหว มีเกณฑ์ดังนี้

ถ้า  $SD_{j_{(mag)}} < Threshold$  และดูว่าข้อมูลกระแสที่นำเข้ามาเป็นกิจกรรมแบบไหน

แต่ถ้า  $SD_{j(mag)} > Threshold$  แสดงว่าข้อมูลภาระเสื่อม  
นำเข้ามามากจนเกินกิจกรรมแบบเดลล์คุณให้

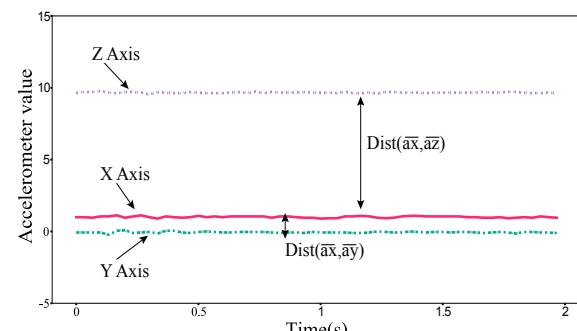
**Algorithm 2:** ISAR+ model : Online phase (Recognition component)

```

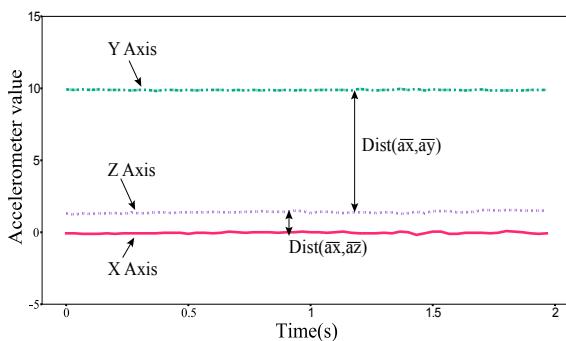
/* $S_\zeta$ = the set of non-stationary streaming data
*/
/* $CM = \{SD_{CM}^{act}, Dens_{CM}^{act}, Kurt_{CM}^{act}\}$ when act are
walking, jogging and stairs.
/* $Threshold$ = the separating dormant and
energetic activites.
/* $J$ = the number of window.
/* $n$ = the number of data in window.
Input : $S_\zeta$, $CM$, $Threshold$.
Output: $P_{act}$.
1 while $S_\zeta$ is not empty do
2   for each fixed size window $j$ do
3     /* $j = 1, 2, \dots, J$ */
4     Compute $M_i$ using eq. (1) of each sample in window $j$.
5     /* $i = 1, 2, 3, \dots, n$ */
6     Compute average $\bar{M}_j$ of window $j$.
7     Compute standard deviation
8     $SD_{j(mag)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (M_i - \bar{M}_j)^2}$
9     if $SD_{j(mag)} < Threshold$ then
10       | Compute the average values $(\bar{ax}_j, \bar{ay}_j, \bar{az}_j)$ of each
11       | acceleration values x, y, and z.
12       | Compute $Dist(\bar{ax}, \bar{ay})$ and $Dist(\bar{ax}, \bar{az})$ using eq. (27)
13       | and (28)
14       if $Dist(\bar{ax}, \bar{ay}) > Dist(\bar{ax}, \bar{az})$ then
15         | $P_{act}$ = standing
16       else
17         | $P_{act}$ = sitting
18       end
19     else
20       | Compute the average values $(\bar{ax}_j, \bar{ay}_j, \bar{az}_j)$ of each
21       | acceleration values x, y, and z.
22       | Compute the standard deviation of each acceleration
23       | values $SD_{j(ax)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax_i - \bar{ax})^2}$,
24       | $SD_{j(ay)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay_i - \bar{ay})^2}$, $SD_{j(az)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (az_i - \bar{az})^2}$ then set to $SD_j$ then set to $SD_j = (SD_{j(ax)}, SD_{j(ay)}, SD_{j(az)})$.
25       | Find the nearest activity $act$ such that
26       | $Predicted = argmin_{act} (||SD_j - SD_{CM}^{act}||)$
27       | /* $act \in [walking, jogging, stairs]$ */
28       | Set the activity of $Predicted$ to $P_{act}$.
29   end
30 end

```

ในการรู้จำกิจกรรมแบบนิ่ง (Dormant activities recognition) เนื่องจากกิจกรรมแบบนิ่ง หมายถึงกิจกรรมที่มีการขยับร่างกายน้อย ได้แก่ การยืนและการนั่ง ดังนั้น การจำแนกกิจกรรมว่าจะเป็นการยืนหรือการนั่ง จะจำแนกจากลักษณะสัมผัสมูลของค่า Accelerometer ดังแสดงใน Figure 11 และ Figure 12



**Figure 11** The accelerometer lines of sitting activity.



**Figure 12** The accelerometer lines of standing activity.

จาก Figure 11 และ Figure 12 เป็นการแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของการยืนและ การนั่ง ซึ่งจะสังเกตว่าในกิจกรรมการยืนค่า Accelerometer ตามแนวแกน Y จะมีค่าที่ห่างจาก Accelerometer ตามแนวแกน X และ Z อย่างเห็นได้ชัด ส่วนกิจกรรมการนั่งจะมีค่า Accelerometer ตามแนวแกน Z ห่างจากค่า Accelerometer ตามแนวแกน X และ Y อย่างชัดเจน สาเหตุที่เป็นเช่นนี้ เนื่องจากในขณะที่เรานั่งหรือยืน จะมีความเร่งที่เกิดขึ้น จากแรงโน้มถ่วงของโลกที่แตกต่างกันในแต่ละแกน จากข้อ สังเกตนี้จึงได้ใช้ระยะห่างของค่า Accelerometer ตามแนว แกน Y และ Z ที่มีต่อกันค่า Accelerometer ตามแนวแกน X มาใช้ในการจำแนกว่าข้อมูลนั้นเป็นการยืนหรือการนั่ง ซึ่งเหตุผลที่ให้ค่า Accelerometer ตามแนวแกน X เป็นข้อมูล หลักในการวัดระยะห่าง เพราะไม่ว่าจะเป็นการยืนหรือการนั่ง ค่า Accelerometer ตามแนวแกน X จะมีลักษณะเหมือนกัน คือเข้าใกล้ 0 ต่างจากค่า Accelerometer ตามแนวแกน Y และ Z ที่เปลี่ยนไปตามแต่กิจกรรม ดังนั้นในงานวิจัยนี้จึงใช้การ จำแนกกิจกรรมแบบนี้ดัง Equation 29 และ Equation 30

$$Dist(\bar{ax}, \bar{ay}) = \sqrt{(\bar{ax} - \bar{ay})^2} \quad (27)$$

$$Dist(\bar{ax}, \bar{az}) = \sqrt{(\bar{ax} - \bar{az})^2} \quad (28)$$

เงื่อนไขสำหรับตรวจสอบข้อมูลที่เข้ามาเป็นการยืน

$$\text{if } Dist(\bar{ax}, \bar{ay}) > Dist(\bar{ax}, \bar{az}) \text{ then} \\ P_{act} = \text{Standing} \quad (29)$$

เงื่อนไขสำหรับตรวจสอบข้อมูลที่เข้ามาเป็นการนั่ง

$$\text{if } Dist(\bar{ax}, \bar{ay}) < Dist(\bar{ax}, \bar{az}) \text{ then} \\ P_{act} = \text{Standing} \quad (30)$$

สำหรับการรู้จำกิจกรรมแบบเคลื่อนไหว (Energetic activities recognition) จำแนกด้วยการคำนวณ SD ของ ข้อมูลที่เข้ามาใหม่ในแต่ละ window โดยใช้ Equation 6 ถึง Equation 8 เปรียบเทียบกับค่าเฉลี่ย SD แต่ละกิจกรรมที่อยู่ ใน CM ซึ่งสามารถคำนวณได้ดัง Equation 31

$$\text{Predicted} = \arg \min_{act} (\|SD_j - SD_{CM}^{act}\|) \\ : act \in [\text{walking, jogging, stairs}] \quad (31)$$

เมื่อสามารถทำนายหรืออนุมานได้แล้วว่า ข้อมูลกระแสใน window  $j$  เป็นการทำกิจกรรมอะไร ขั้นตอนต่อมาจะตรวจสอบ ว่าต้องปรับปรุงตัวแบบรู้จำกิจกรรม CM หรือไม่ เพื่อที่จะทำให้ ได้ตัวแบบที่เหมาะสมกับลักษณะการทำกิจกรรมของผู้ใช้ ตาม การทำงานของ **Algorithm 3** โดยการคำนวณความหนาแน่น ( $Dens_j$ ) และความโถง ( $Kurt_j$ ) ในแต่ละแกนของข้อมูลกระแส ใน window  $j$  จากนั้นนำไปเปรียบเทียบกับค่าที่เก็บไว้ใน CM ซึ่งใช้หลักการเดียวกันกับตอนที่ทำการรู้จำกิจกรรมด้วย ส่วนเบี่ยงเบนมาตรฐาน ( $SD_{vote}$ ) ความหนาแน่น ( $Dens_{vote}$ ) และความโถง ( $Kurt_{vote}$ ) ถ้าหากทั้ง 3 วิธีระบุเป็นกิจกรรมเดียวกันก็จะทำการปรับปรุงตัวแบบรู้จำกิจกรรมด้วย Equation 32 ถึง Equation 34

#### การปรับปรุงส่วนเบี่ยงเบนมาตรฐานภายใน CM

$$\text{new}SD_{CM}^{act} = \frac{SD_{CM}^{act} + SD_j}{2} \quad (32)$$

#### การปรับปรุงความหนาแน่นภายใน CM

$$\text{new}Dens_{CM}^{act} = \frac{Dens_{CM}^{act} + Dens_j}{2} \quad (33)$$

#### การปรับปรุงความโถงภายใน CM

$$\text{new}Kurt_{CM}^{act} = \frac{Kurt_{CM}^{act} + Kurt_j}{2} \quad (34)$$

**Algorithm 3:** ISAR+ model : Online phase (Adaptation component)

```

/* windowj = the set of accelerometer sensor data
when j = 1,2,3,...,J. */
/* CM = {SDCMact, DensCMact, KurtCMact} when act are
walking, jogging and stairs. */
/* Pact = The predicted activities. */
/* J = the number of window. */
/* n = the number of data in window. */
Input : windowj, CM, SDj, Pact.
Output: The new CM.
1 Set SDvote = Pact.
2 Compute the density of each acceleration values in windowj such that
  Densj(ax) =  $\sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax - \bar{ax})^2}$ , Densj(ay) =
     $\sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay - \bar{ay})^2}$ , Densj(az) =  $\sqrt{\frac{1}{n-1} \sum_{i=1}^n (az - \bar{az})^2}$ 
  then set to Densj
  Densj = (Densj(ax), Densj(ay), Densj(az))
3 Compute the kurtosis of each acceleration values in windowj such that
  Kurtj(ax) =  $\sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax - \bar{ax})^2}$ , Kurtj(ay) =
     $\sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay - \bar{ay})^2}$ , Kurtj(az) =  $\sqrt{\frac{1}{n-1} \sum_{i=1}^n (az - \bar{az})^2}$ 
  then set to Kurtj
  Kurtj = (Kurtj(ax), Kurtj(ay), Kurtj(az))
4 Find the nearest activity act with density and kurtosis such that
  Densvote = argminact(||Densj - DensCMact||)
  Kurtvote = argminact(||Kurtj - KurtCMact||)
  /* act ∈ [walking, jogging, stairs] */
5 if SDvote, Densvote and Kurtvote are same activity then
  | Update CM with calculate
  |   newSDCMact, newDensCMact, newKurtCMact using eq.(32)-(34).
  |   Set CM = {newSDCMact, newDensCMact, newKurtCMact}.
6 else
  | Not update CM
7 end

```

**ผลการศึกษา**

ในงานวิจัยนี้จะวัดประสิทธิผลในด้านความถูกต้องในการทำนายหรืออนุมานกิจกรรมของตัวแบบและประสิทธิภาพด้านเวลาของตัวแบบรู้จำกิจกรรม โดยขั้นตอนการรู้จำกิจกรรมของวิธีการที่นำเสนอ ISAR+ เปรียบเทียบประสิทธิภาพกับวิธีการ STAR<sup>5</sup> วิธีการจากงานวิจัย<sup>6</sup> และวิธีการ ISAR<sup>7</sup> โดยใช้อ้อมูล WISDM และข้อมูล UniMiB-SHAR เนื่องจากงานวิจัยนี้มีการทดสอบประสิทธิภาพของตัวแบบรู้จำกิจกรรมที่สร้างขึ้นกับวิธีการ STAR ซึ่งวิธีการ STAR มีทั้ง STAR (without Active learning) และ STAR (with Active learning) ดังนั้นการจำลองวิธีการ STAR ที่มี Active learning ทำได้โดยใช้คำตอบที่ได้จากชุดข้อมูลทดสอบแทนคำตอบที่ได้จากผู้ใช้ ส่วนวิธีการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมงานวิจัยนี้ใช้มารวัดหลาຍวิธี ได้แก่ Precision, Recall, F-measure และ Accuracy

Precision เป็นการวัดความแม่นยำของตัวแบบรู้จำกิจกรรม โดยวัดจากจำนวนที่ตัวแบบรู้จำกิจกรรมทำนายถูกต้องและเป็นกิจกรรมที่กำลังพิจารณา ว่ามีอัตราส่วนเท่าไรกับจำนวนกิจกรรมที่ถูกทำนายเป็นกิจกรรมที่กำลังพิจารณา ทั้งหมดสามารถคำนวณจาก Equation 35

$$\text{Precision} = \frac{TP}{TP + FP} \quad (35)$$

ส่วนการวัด Recall เป็นการวัดความถูกต้องของตัวแบบรู้จำกิจกรรม โดยวัดจากจำนวนที่ตัวแบบรู้จำกิจกรรมทำนายถูกต้องและเป็นกิจกรรมที่กำลังพิจารณา ว่ามีอัตราส่วนเท่าไรกับจำนวนกิจกรรมที่กำลังพิจารณาทั้งหมด คำนวณโดยใช้ Equation 36

$$\text{Recall} = \frac{TP}{TP + FN} \quad (36)$$

มาตรวัด F-measure เป็นการวัดความถูกต้องและแม่นยำของตัวแบบรู้จำกิจกรรม โดยใช้ค่าเฉลี่ยของ Precision และ Recall คำนวณโดยใช้ Equation 37

$$F\text{-measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (37)$$

ส่วนมาตรวัด Accuracy เป็นการวัดความถูกต้องของตัวแบบในการทำนายหรืออนุมานกิจกรรมที่กำลังทำ โดยจะพิจารณาจากจำนวนครั้งที่ตัวแบบทำนายถูกต้องเทียบกับจำนวนตัวอย่างทั้งหมดที่ใช้ในการทดสอบตัวแบบ

$$\text{Accuracy} = \frac{TP}{\text{Total Samples}} \quad (38)$$

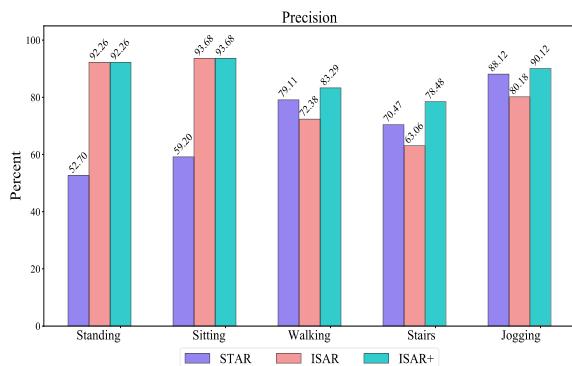
โดยที่ TP (True Positive) คือจำนวนครั้งที่ตัวแบบทำนายถูกต้องและตรงกันกับกิจกรรมที่กำลังทำ FP (False Positive) และ FN (False Negative) คือ จำนวนครั้งที่ตัวแบบทำนายไม่ถูกต้อง และไม่ตรงกันกับกิจกรรมที่กำลังทำ

การวัดประสิทธิภาพของตัวแบบรู้จำแต่ละวิธี ใช้วิธีการวัดที่เรียกว่า Leave-one-subject-out (LOSO) cross validation กล่าวคือใช้อ้อมูลการทำกิจกรรมทุกกิจกรรมของผู้ใช้ 1 คน เป็นข้อมูลชุดทดสอบ ส่วนข้อมูลการทำกิจกรรมของผู้ใช้คนอื่นใช้สำหรับสร้างตัวแบบรู้จำ จากนั้นลับข้อมูลการทำกิจกรรมของผู้ใช้แล้วทดสอบ แล้วลับข้อมูลชุดทดสอบและลับข้อมูลสำหรับสร้างตัวแบบ ทำลักษณะเช่นนี้จนกว่าจะครบทุกคน

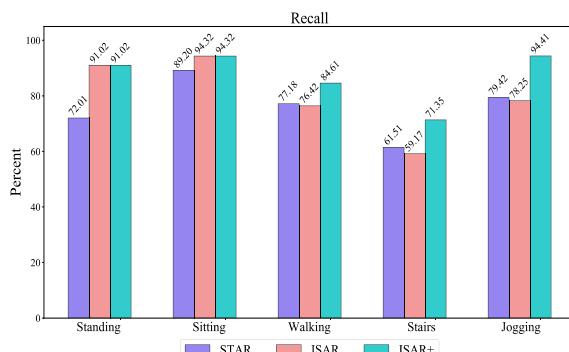
**ผลการรู้จำกิจกรรมกับข้อมูล WISDM**

ผลการวัดประสิทธิภาพของตัวแบบรู้จำกิจกรรมด้วยมาตรวัด Precision, Recall และ F-measure แสดงดังกราฟใน Figure 14 ถึง Figure 16 จากกราฟแสดงให้เห็นว่า วิธีการ ISAR+ มีประสิทธิภาพของการรู้จำกิจกรรมที่ดีที่สุดในทุก

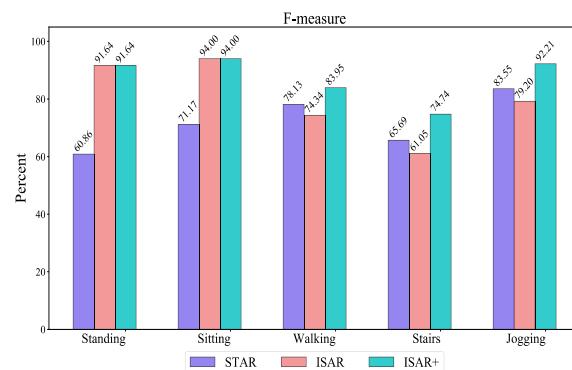
กิจกรรมทั้ง 3 มาตรวัด โดยเฉพาะอย่างยิ่งกิจกรรมนั่ง ยืน และวิ่งเบา ๆ ที่มีค่าความแม่นยำมากกว่า 90% ส่วนกิจกรรมที่เป็นการเดินมีความแม่นยำเกิน 80% ทั้ง 3 มาตรวัด และการขึ้นลงบันไดให้ผลการทำนายหรือการอนุมานการทำกิจกรรมที่น้อยกว่า 80% แต่ยังมีประสิทธิภาพที่ดีกว่าวิธีการ STAR ทั้งนี้อาจเนื่องจากข้อมูลกิจกรรมการขึ้นลงบันไดมีจำนวนตัวอย่างที่น้อยเมื่อเทียบกับข้อมูลการทำกิจกรรมอย่างอื่น จึงทำให้เกิดปัญหาที่เรียกว่าข้อมูลที่ไม่สมดุล (Imbalance data) ซึ่งมีผลต่อความแม่นยำของตัวแบบ เมื่อพิจารณาในภาพรวมวิธีการ ISAR+ ยังมีความถูกต้อง (Accuracy) เฉลี่ยเท่ากับ 85.77% ซึ่งยังคงให้ผลความถูกต้องดีกว่าวิธีการอื่น แสดงได้ดัง Table 2



**Figure 14** Precision of activity recognition using WISDM dataset. Each model is represented in different colors.



**Figure 15** Recall of activity using WISDM dataset. Each model is represented in different colors.



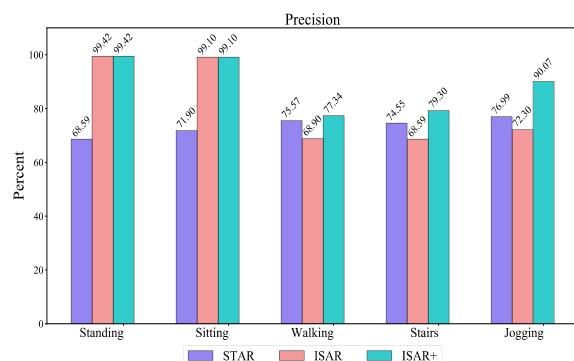
**Figure 16** F-measure of activity recognition using WISDM dataset. Each model is represented in different colors.

**Table 2** Results of applying ISAR+ versus state-of-the-art methods on WISDM dataset

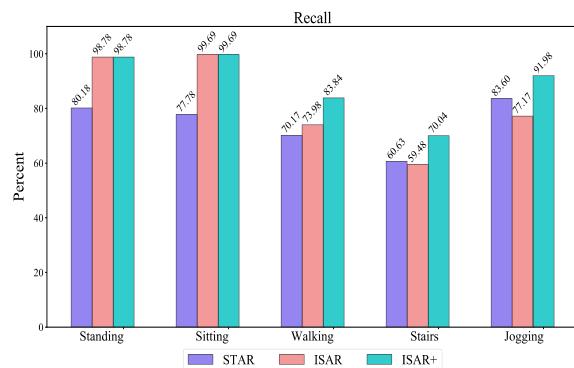
Model	Accuracy
STAR without active learning <sup>5</sup>	23.40%
STAR with active learning <sup>5</sup>	77.29%
Research <sup>6</sup>	82.77%
ISAR <sup>7</sup>	75.67%
<b>ISAR+</b>	<b>85.81%</b>

#### ผลการรู้จำกิจกรรมกับข้อมูล UniMiB-SHAR

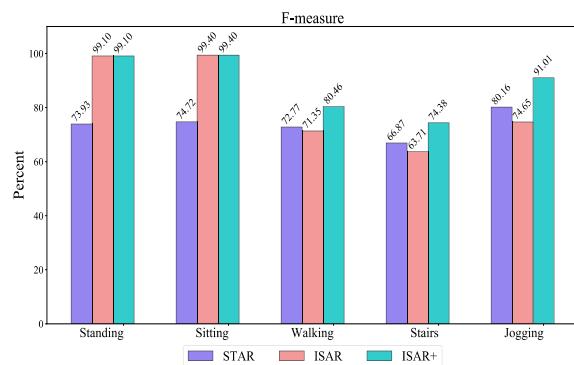
ผลการวัดประสิทธิภาพความแม่นยำของตัวแบบบูรณาการกิจกรรมด้วยมาตรวัด Precision, Recall และ F-measure แสดงดัง Figure 17 ถึง Figure 19 จะเห็นว่าวิธีการ ISAR+ มีประสิทธิภาพความแม่นยำที่ดีที่สุดของการทำนายหรือการอนุมานการทำกิจกรรมในทุกกิจกรรม โดยเฉพาะกิจกรรมที่เป็นการนั่ง ยืน และวิ่งเบา ๆ ที่วิธีการ ISAR+ ให้ผลการทำนายหรืออนุมานกิจกรรมมีความแม่นยำที่สูงเกิน 90% เมื่อพิจารณาประสิเดนความถูกต้องในการทำนายหรืออนุมานวิธีการ ISAR+ มีความถูกต้องเฉลี่ยเท่ากับ 88.03% และให้ผลความถูกต้องดีที่สุดและดีกว่าวิธีการอื่นแสดงได้ดัง Table 3



**Figure 17** Precision of activity recognition on UniMiB-SHAR. Each model is represented in different colors.



**Figure 18** Recall of activity recognition on UniMiB-SHAR. Each model is represented in different colors.



**Figure 19** F-measure of activity recognition on UniMiB-SHAR. Each model is represented in different colors.

**Table 3** Results of applying ISAR+ versus state-of-the-art methods on UniMiB-SHAR dataset

Model	Accuracy
STAR without active learning <sup>5</sup>	22.29 %
STAR with active learning <sup>5</sup>	73.31 %
ISAR <sup>7</sup>	81.23 %
<b>ISAR+</b>	<b>88.03 %</b>

### การวัดประสิทธิภาพด้านเวลาของตัวแบบ

การวัดประสิทธิภาพด้านเวลาของวิธีการที่นำเสนอ ISAR+ จะเปรียบเทียบกับวิธีการเดิมของผู้วิจัยคือ วิธีการ ISAR และวิธีการ STAR ส่วนวิธีการจากงานวิจัยหมายเลขอ 6 ไม่ได้เปรียบเทียบ เนื่องจากลักษณะขั้นตอนวิธีไม่ได้เป็น 2 ขั้นตอน (อฟไลน์และออนไลน์) เมื่อเทียบกับวิธีการ STAR

วิธีการ STAR ในขั้นตอนการสร้างตัวแบบรู้จำจิกรรม (Modeling) ได้ใช้วิธีการแบ่งกลุ่มข้อมูล จึงทำให้มีความซับซ้อนเชิงเวลาคือ  $O(KNI)$  โดยที่  $K$  คือจำนวนกลุ่มในการแบ่งกลุ่มข้อมูล  $N$  คือ จำนวนตัวอย่างข้อมูลทั้งหมดของแต่ละกิจกรรม และ  $I$  คือ จำนวนการวนลูปในการแบ่งกลุ่มข้อมูล กิจกรรม ส่วนขั้นตอนการรู้จำจิกรรม (Recognition) วิธีการ STAR ได้ใช้การแบ่งกลุ่มข้อมูลออกเป็น 2 กลุ่มแล้วใช้มาตราวัดหลายตัวในการระบุกิจกรรม ซึ่งมีความซับซ้อนเชิงเวลาคือ  $O(2nl) + O(Kn)$  โดยที่  $n$  คือ จำนวนตัวอย่างข้อมูล กิจกรรมภายใน 1 window (ขั้นอยู่กับอัตราการสัมผัตัวอย่างของข้อมูลนั้น) และในขั้นตอนปรับปรุง ตัวแบบรู้จำจิกรรม (Update) วิธีการ STAR มีความซับซ้อนเชิงเวลา คือ  $O(Kn)$

ส่วนวิธีการ ISAR ในขั้นตอนการสร้างตัวแบบรู้จำจิกรรม (Modeling) ได้แปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบน มาตรฐานก่อนนำไปแบ่งกลุ่มข้อมูล ซึ่งมีความซับซ้อนเชิงเวลา คือ  $O(N) + O(KJl)$  โดยที่  $J$  คือจำนวนของ window ขั้นตอนการรู้จำจิกรรม (Recognition) วิธีการ ISAR ไม่ได้มีการแบ่งกลุ่มข้อมูล แต่ใช้เพียงหนึ่งมาตราวัดในการระบุกิจกรรมที่กำลังทำ จึงมีความซับซ้อนเชิงเวลาคือ  $O(n)$

สุดท้ายวิธี ISAR+ ที่นำเสนอในงานวิจัยนี้ ในขั้นตอนสร้างตัวแบบรู้จำจิกรรม (Modeling) ไม่มีการแบ่งกลุ่มข้อมูลเช่นเดียวกัน แต่มีการแปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบน มาตรฐาน ความโดย衷 ความหนาแน่น ซึ่งมีความซับซ้อนเชิงเวลาคือ  $O(N)$  ในขั้นตอนการรู้จำจิกรรม (Recognition) วิธีการ ISAR+ ใช้เพียงหนึ่งมาตราวัดในการระบุกิจกรรม เช่นเดียวกับวิธีการ ISAR ดังนั้นจึงมีความซับซ้อนเชิงเวลาคือ  $O(n)$  และขั้นตอนการปรับปรุงตัวแบบรู้จำจิกรรม (Update)

วิธีการ ISAR+ ได้พิจารณาค่าส่วนเบี่ยงเบนมาตรฐาน ค่าความดense และค่าความหนาแน่นของข้อมูลภายใน window จึงมีความซับซ้อนเชิงเวลา  $O(n)$  คือ แสดงตั้ง Table 4

**Table 4** Time complexity of ISAR, ISAR+ and STAR models

Model	Modeling	Recognition	Update
STAR	$O(Knl)$	$O(2nl) + O(Kn)$	$O(Kn)$
ISAR	$O(N) + O(Kjl)$	$O(n)$	-
ISAR+	$O(N)$	$O(n)$	$O(n)$

### สรุปผลการทดลอง

จากการทดลองเปรียบเทียบการวัดประสิทธิภาพความถูกต้องและแม่นยำของการรู้จำกิจกรรมด้วยวิธี Precision, Recall, F-measure และ Accuracy แสดงให้เห็นว่าวิธีการที่นำเสนอ ISAR+ มีประสิทธิภาพผลด้านความถูกต้องและความแม่นยำได้ดีที่สุดของการทำนายหรือการอนุมานการทำกิจกรรมปัจจุบัน โดยที่วิธีการ ISAR+ สามารถแก้ปัญหาการรู้จำกิจกรรม เมื่อข้อมูลกิจกรรมที่ใช้สร้างตัวแบบมีความทับซ้อนกัน และสามารถใช้ข้อมูลการทำกิจกรรมของผู้ใช้ทั่วไปที่มีลักษณะการทำกิจกรรมที่ต่างกันในการสร้างตัวแบบที่ไม่เฉพาะบุคคล ดังนั้นวิธีการ ISAR+ จึงถือได้ว่าเป็นตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคลที่สามารถปรับปรุงตัวแบบให้เข้ากับลักษณะการทำกิจกรรมของผู้ใช้ใหม่แต่ละบุคคลได้โดยอัตโนมัติ นอกจากนี้ในการวัดประสิทธิภาพเชิงเวลา วิธีการ ISAR+ มีประสิทธิภาพดีที่สุดทั้งขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม และขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำ ซึ่งน่าจะเหมาะสมสำหรับการนำไปประยุกต์ใช้ในงานจริงกับรู้จำกิจกรรมที่ประมวลผลภายในอุปกรณ์ได้

### กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการสนับสนุนการวิจัยจากงบประมาณเงินรายได้ (เงินอุดหนุนจากรัฐบาล) ประจำปีงบประมาณ พ.ศ. 2561 มหาวิทยาลัยมหิดล ผ่านสำนักงานคณะกรรมการวิจัยแห่งชาติ สัญญาเลขที่ 113/2561 และจากสำนักงานกองทุนสนับสนุนการวิจัย (RTA6080013) สุดท้ายของขอบคุณศาสตราจารย์ ดร.ชิดชนก เหลือสินทรัพย์ ที่ช่วยแนะนำทางในการทำวิจัยนี้ รวมถึงนายทิดศักดิ์ ดุงแก้ว ที่ช่วยให้งานวิจัยนี้สำเร็จลุล่วงด้วยดี

### เอกสารอ้างอิง

- Lockhart, JW, Weiss, GM. Limitations with Activity Recognition Methodology & Data Sets. Proceedings of the 2014 ACM Conference on Ubiquitous Computing (UBICOMP) Adjunct Publication (2nd International Workshop on Human Activity Sensing Corpus and its Application); Seattle, WA: 2014.
- Gomes, J, Krishnaswamy, S, Gaber, M, Sousa, P, Menasalvas, E. MARS: A Personalised Mobile Activity Recognition System. Proceedings of the 2012 IEEE 13th International Conference on Mobile Data Management (MDM); Bengaluru, Karnataka; 2012. P. 316–319.
- Lockhart, JW, Weiss, GM. The Benefits of Personalized Smartphone-based Activity Recognition Models. Proceedings of the 2014 SIAM International Conference on Data Mining; 2014. P. 614–622.
- Uddin, MT, Billah, M, Hossain, MF. Random Forests based Recognition of Human Activities and Postural Transitions on Smartphone. Proceedings of the 5<sup>th</sup> International Conference on Informatics, Electronics and Vision (ICIEV); 2016. P. 250-255.
- Abdallah, ZS, Gaber, MM, Srinivasan, B. Adaptive mobile activity recognition system with evolving data streams. Neurocomputing; 2015. P. 304-317.
- Jalal, A, Quaid, MAK, Hasan, AS. Wearable Sensor-based Human Behavior Understanding and Recognition in Daily Life for Smart Environments. 2018 International Conference on Frontiers of Information Technology (FIT); 2018. P. 105-110.
- Dungkaew, T, Suksawatchon J, Suksawatchon U. Impersonal smartphone-based activity recognition using the accelerometer sensory data. Proceeding of the 2017 2nd International Conference on Information Technology (INCIT). Nakhonpathom, Bangkok; 2017. P. 1-6.
- Jennifer, R, Kwapisz, GM, Weiss and Samuel A. Moore. Activity Recognition using Cell Phone Accelerometers, Proceedings of the Fourth International Workshop on Knowledge Discovery from Sensor Data (at KDD-10) 2010.
- Micucci, D, Mobilio, M, Napoletano, P. UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones. Preprints 2017, 2017060033 (doi: 10.20944/preprints201706.0033.v1).