

การรู้จำกิจกรรมประจำวันของมนุษย์แบบปรับตัวได้ โดยใช้ข้อมูลจากตัวรับรู้ แอสเซนเซอร์โรมิเตอร์ของสมาร์ทโฟน

Adaptive Human Daily Activity Recognition Using Accelerometer Sensory Data from Smartphones

อุรีรัฐ สุขสวัสดิ์ชน¹, จักกริน สุขสวัสดิ์ชน¹, วรวิทย์ วีระพันธุ์², เหมรัตน์ วชิรหัตถพงษ์², วิทวัส พันธุมจินดา²
Ureerat Suksawatchon¹, Jakkarin Suksawatchon¹, Worawit Werapan¹,
Hemmarat Wachirahatthapong², Wittawas Puntumchinda²

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

บทคัดย่อ

การรู้จำกิจกรรมของมนุษย์โดยใช้ข้อมูลกระแสจากตัวรับรู้แอสเซนเซอร์โรมิเตอร์ของสมาร์ทโฟนยังคงเป็นประเด็นที่น่าสนใจสำหรับนักวิจัย งานวิจัยส่วนใหญ่พัฒนาตัวแบบรู้จำกิจกรรมเป็นแบบเฉพาะบุคคล ซึ่งต้องใช้ข้อมูลสำหรับสร้างตัวแบบมาจากผู้ใช้ที่ต้องการจะใช้ตัวแบบรู้จำเท่านั้น โดยให้ผู้ใช้ทำกิจกรรมต่าง ๆ ภายในระยะเวลาที่กำหนด ซึ่งอาจก่อความไม่สะดวกให้แก่ผู้ใช้งานมากเกินไป ดังนั้นงานวิจัยนี้จึงได้นำเสนอกรอบแนวคิดใหม่ของการรู้จำกิจกรรมที่หยึดหยุ่นได้ด้วยสมาร์ทโฟน ที่ชื่อเรียกว่า “ไอซาร์พลัส” ซึ่งเป็นตัวแบบไม่เฉพาะบุคคล (สากล) ที่สามารถใช้กับผู้ใช้ใหม่ได้ โดยที่ผู้ใช้ใหม่ที่ต้องการใช้งานสามารถนำตัวแบบไปใช้งานได้ทันทีโดยไม่ต้องเตรียมข้อมูลสำหรับสร้างตัวแบบเอง ทั้งนี้เพราะตัวแบบที่นำเสนอสามารถปรับตัวแบบได้ตามข้อมูลกระแสของผู้ใช้แต่ละคนโดยใช้การเรียนรู้แบบเพิ่มขึ้นสำหรับการรู้จำในเวลาจริง งานวิจัยนี้ได้วัดประสิทธิภาพของตัวแบบที่นำเสนอทั้งในด้านความถูกต้องของการทำนายและด้านเวลาที่ใช้โดยใช้ข้อมูลสาธารณะที่เป็นการเก็บข้อมูลจริงของการรู้จำกิจกรรมจำนวน 2 ชุดข้อมูล ผลการทดลองแสดงให้เห็นว่า วิธีการไอซาร์พลัสมีประสิทธิภาพที่ดีกว่าวิธีการอื่นที่นำมาเปรียบเทียบ โดยเฉพาะอย่างยิ่งกับข้อมูลสอนและข้อมูลทดสอบจากผู้ใช้ที่ต่างกันและไม่จำเป็นต้องสอบถามกิจกรรมที่แท้จริงจากผู้ใช้ ซึ่งวิธีการไอซาร์พลัสได้แสดงให้เห็นว่ามีความถูกต้องเฉลี่ยในการทำนายหรืออนุมานการทำกิจกรรมมากกว่า 85%

คำสำคัญ: การรู้จำกิจกรรม ตัวรับรู้แอสเซนเซอร์โรมิเตอร์ สมาร์ทโฟน การทำเหมืองข้อมูล 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

¹ ผู้ช่วยศาสตราจารย์, ² อาจารย์, คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา อำเภอเมือง จังหวัดชลบุรี 20131

¹ Assist. Prof., ² 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 ซึ่งคนส่วนใหญ่ใช้อุปกรณ์เหล่านี้เหมือนเป็นปัจจัยที่ 5 แน่หนอนว่าอุปกรณ์เหล่านี้มีการติดตั้งตัวรับรู้ (Sensor) อัจฉริยะที่หลากหลายแบบ ตัวอย่างเช่น Accelerometer Sensor ที่มีไว้สำหรับตรวจจับการเคลื่อนไหวของอุปกรณ์ โดยเป็นการตรวจจับแบบ 3 แกน Gyroscope sensor เป็นตัวรับรู้ที่มีไว้สำหรับตรวจจับลักษณะของการหมุนของอุปกรณ์ เป็นต้น ซึ่งข้อมูลจากตัวรับรู้เหล่านี้เป็นข้อมูลกระแสดึงเวลา (Temporal streaming data) อย่างต่อเนื่องด้วยอัตราการสุ่มตัวอย่างตามที่กำหนดไว้ และกระแสข้อมูลเหล่านี้สามารถนำมาใช้สร้างตัวแบบรู้จำกิจกรรม (Activity recognition model) ผ่านขั้นตอนการเรียนรู้ (Learning algorithm) ด้วยวิธีการทางทำเหมืองข้อมูล (Data mining) หรือการเรียนรู้ของเครื่องจักร (Machine learning) จนกระทั่งได้ตัวแบบรู้จำกิจกรรมที่สามารถตรวจจับและอนุมาน (Inferring) ว่าผู้ใช้งานกำลังทำกิจกรรมใดในขณะนั้นจากข้อมูลที่ตัวรับรู้ส่งมา ตัวอย่างเช่นผู้ใช้งานกำลังยืน นั่ง เดิน หรือวิ่ง เป็นต้น ยิ่งไปกว่านั้นตัวแบบการรู้จำกิจกรรมของมนุษย์ถูกนำมาสร้างเป็นแอปพลิเคชันที่สำคัญมากมาย โดยเฉพาะแอปพลิเคชันการดูแลสุขภาพ

การสร้างตัวแบบรู้จำกิจกรรมจำเป็นต้องเตรียมข้อมูลการทำกิจกรรม (Annotated activities data) ดังนั้นตัวแบบรู้จำกิจกรรมจึงสามารถสร้างได้ 3 ลักษณะ ขึ้นอยู่กับลักษณะข้อมูลที่ใช้สร้างตัวแบบ¹ ดังนี้

(1) ตัวแบบเฉพาะบุคคล (Personal model) เป็นตัวแบบเฉพาะบุคคลที่สร้างขึ้นเพื่อจำแนกและระบุการกิจกรรมที่ทำของคนหนึ่งคนเท่านั้น ดังนั้นการสร้างตัวแบบเฉพาะบุคคลนี้ต้องให้ผู้ที่จะใช้งานตัวแบบเป็นผู้เตรียมข้อมูลของการทำกิจกรรม ด้วยการทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนดผ่านทางแอปพลิเคชันของผู้สร้างตัวแบบ จากนั้นข้อมูลการทำกิจกรรมจากตัวรับรู้ของคนนั้นจะถูกนำไปสร้างตัวแบบและทดสอบตัวแบบตามขั้นตอนวิธีการเรียนรู้

(2) ตัวแบบไม่เฉพาะบุคคล (Impersonal model) หรือตัวแบบสากล (Universal model) ตัวแบบนี้ใช้ข้อมูลการทำกิจกรรมของผู้ใช้คนใดก็ได้ไม่เฉพาะเจาะจง มาใช้สร้างตัวแบบ กล่าวคือผู้ใช้งานตัวแบบไม่ต้องเก็บข้อมูลการทำกิจกรรมของตนเอง ก็สามารถเริ่มใช้ตัวแบบรู้จำกิจกรรมผ่านแอปพลิเคชันนั้น ๆ ได้ทันที ทั้งนี้เพื่อความสะดวกของผู้ใช้งาน

(3) ตัวแบบลูกผสม (Hybrid model) เป็นตัวแบบที่ใช้การรวมกันของตัวแบบเฉพาะบุคคลและตัวแบบไม่เฉพาะบุคคล ดังนั้นการสร้างตัวแบบใช้ทั้งข้อมูลการทำกิจกรรมของผู้ใช้คนใดก็ได้ไม่เฉพาะเจาะจง ร่วมกับข้อมูลการทำกิจกรรมของผู้ที่ต้องการใช้ตัวแบบ จึงจำเป็นต้องให้ผู้ใช้งานตัวแบบทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนด

ดังนั้นบทความวิจัยนี้ คณะผู้วิจัยต้องการนำเสนอตัวแบบรู้จำกิจกรรมแบบใหม่โดยใช้เพียงกระแสข้อมูลจาก Accelerometer sensor ของสมาร์ทโฟนเท่านั้น และตัวแบบที่นำเสนอนี้เป็นตัวแบบไม่เฉพาะบุคคลหรือตัวแบบสากล เพื่อเป็นตัวแบบกลางที่สามารถใช้กับบุคคลใดก็ได้ เมื่อผู้ใช้ใหม่นำไปใช้งานจริง ตัวแบบรู้จำที่นำเสนอสามารถปรับตัวแบบ (Adaptive model) ได้อย่างอัตโนมัติ เพื่อให้เป็นตัวแบบรู้จำที่เข้ากับลักษณะการทำกิจกรรมของผู้ใช้คนนั้น โดยที่ผู้ใช้ใหม่ไม่ต้องเตรียมข้อมูลการทำกิจกรรมใด ๆ และไม่ต้องมีขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบใหม่ ซึ่งจะขอล่าวในรายละเอียดต่อไป

งานวิจัยการรู้จำกิจกรรม

งานวิจัยที่เกี่ยวกับการรู้จำกิจกรรมด้วยข้อมูลจากตัวรับรู้ของสมาร์ทโฟนยังคงเป็นหัวข้อที่ได้รับความสนใจและพัฒนาผลงานวิจัยอย่างต่อเนื่อง โดยเริ่มจากงานวิจัยที่เน้นการสร้างตัวแบบรู้จำเฉพาะบุคคล ได้แก่ งานวิจัยของ Gomes et al.² ตีพิมพ์ในปี ค.ศ. 2012 ที่พัฒนาวิธีการที่ชื่อว่า "MARS" โดยวิธีการนี้ สามารถรู้จำกิจกรรมจากข้อมูลกระแสที่ได้จาก Accelerometer sensor ของสมาร์ทโฟน ซึ่งวิธีการ MARS มีขั้นตอนการเรียนรู้ (Training phase) เพื่อสร้างตัวแบบรู้จำกิจกรรม ดังนั้นผู้ใช้งานต้องเก็บสมาร์ทโฟนไว้ที่กระเป๋ากางเกงที่ต้นขาด้านหน้า และทำกิจกรรมทั้งหมด 5 กิจกรรม ได้แก่

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

ในปี ค.ศ. 2014 งานวิจัยของ Lockhart และ Weiss³ ได้นำเสนอวิธีการที่ชื่อว่า "Actitracker" โดยวิธีการนี้มีขั้นตอนการเรียนรู้เช่นเดียวกับกับวิธีการ MARS เพื่อเก็บรวบรวมข้อมูลการทำกิจกรรมของผู้ใช้ที่ได้จาก Accelerometer sensor ของอุปกรณ์สมาร์ตโฟน โดยให้ผู้ใช้เก็บสมาร์ตโฟนไว้ที่กระเป๋ากางเกงที่ต้นขาด้านหน้า และทำกิจกรรมทั้งหมด 7 กิจกรรม คล้ายกับวิธีการ MARS โดยการแยกการปีนบันได เป็นการขึ้นบันไดและลงบันได และเพิ่มกิจกรรมนอนนิ่ง (Lying down) ซึ่งผู้ใช้ต้องทำกิจกรรมละประมาณ 2-3 นาที จากนั้นข้อมูลการทำกิจกรรมของผู้ใช้จะถูกส่งไปที่เครื่องแม่ข่ายเพื่อสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีจำแนกประเภทหลายวิธี แต่ Random Forest เป็นวิธีการที่ให้ผลการอนุมานการทำกิจกรรมที่ดีที่สุด

ส่วนงานวิจัยของ Uddin *et al.*⁴ ในปี ค.ศ.2016 ได้แนะนำวิธีการสร้างตัวแบบรู้จำกิจกรรมโดยใช้การพิจารณารูปแบบการเปลี่ยนกิจกรรม เช่น จากยืนไปนั่ง จากนั่งไปนอน จากนอนไปยืน เป็นต้น เช่นเดียวกับวิธีการอื่น กล่าวคือต้องให้ผู้ใช้ทำกิจกรรมในรูปแบบต่าง ๆ รวมไปถึงการเปลี่ยนกิจกรรม จากกิจกรรมหนึ่งเป็นอีกกิจกรรมหนึ่งในรูปแบบต่าง ๆ โดยข้อมูลการทำกิจกรรมได้จาก Accelerometer sensor และ Gyroscope sensor ของอุปกรณ์สมาร์ตโฟน จากนั้นจะนำข้อมูลไปสร้างตัวแบบด้วยวิธีการ Random Forest

ในส่วนของงานวิจัยที่เน้นการสร้างตัวแบบไม่เฉพาะบุคคล เช่น งานวิจัยของ Abdallah *et al.*⁵ เผยแพร่ในปี ค.ศ. 2015 ได้แนะนำวิธีการ "STAR" ที่สามารถรู้จำกิจกรรมกับข้อมูลกระแสวิ่งเวลาที่ได้จาก Accelerometer sensor เพียงตัวรับรู้เดียวของอุปกรณ์สมาร์ตโฟน วิธีการ STAR ไม่จำเป็นต้องให้ผู้ใช้ทำกิจกรรมต่าง ๆ เนื่องจากวิธีการ STAR ใช้ข้อมูลการทำกิจกรรมจากงานวิจัยของ Lockhart และ Weiss³ ในการสร้างตัวแบบรู้จำกิจกรรม โดยเน้นที่ 5 กิจกรรมหลัก ได้แก่ เดิน วิ่งเบา ๆ ปีนบันได (รวมขึ้นและลงบันได) นั่ง และ ยืน ยกเว้นกิจกรรมการนอนนิ่ง ๆ นอกจากนี้วิธีการ STAR ใช้แนวคิด Active learning ในกรณีที่ตัวแบบรู้จำให้ผลการทำนายหรืออนุมานว่าผู้ใช้กำลังทำกิจกรรมอย่างน้อย 2 กิจกรรมในเวลาเดียวกัน จะต้องให้ผู้ใช้ยืนยันการทำกิจกรรมจริงในขณะนั้นผ่านแอปพลิเคชันของ STAR วิธีการ STAR

มีขั้นตอนการทำงานเป็นสองส่วน ส่วนที่หนึ่งเป็นขั้นตอนการสร้างตัวแบบรู้จำ (Modelling component) ที่เรียกว่า LM (Learning model) โดยนำข้อมูลการทำกิจกรรม (Annotated data) ของแต่ละกิจกรรม แบ่งเป็นกลุ่มย่อย (Clustering) ตามจำนวนกลุ่มที่กำหนด แล้วเก็บข้อมูลสรุป (Statistics summary) ของแต่ละกลุ่มย่อย ขั้นตอนในส่วนที่สอง คือการเรียนรู้จำกิจกรรมและปรับปรุงตัวแบบรู้จำ (Online recognition and adaption phase) เป็นขั้นตอนที่นำตัวแบบ LM มาใช้งานจริงบนอุปกรณ์สมาร์ตโฟน โดยข้อมูลกระแสที่ส่งมาอย่างต่อเนื่องจาก Accelerometer sensor ของอุปกรณ์สมาร์ตโฟน จะถูกแบ่งออกเป็นหน้าต่าง (Window) ซึ่งข้อมูลกระแสในแต่ละหน้าต่างถูกแบ่งเป็นสองกลุ่มโดยใช้วิธีการแบ่งกลุ่ม Expectation Maximization (EM) กลุ่มที่มีข้อมูลมากที่สุดจะถูกนำไปจำแนกประเภทกิจกรรมด้วยมาตรวัด 4 ตัว ได้แก่ Distance, Gravity, Density และ Deviation ซึ่งถ้ามาตรวัด 3 ใน 4 มาตรวัดระบุเป็นกิจกรรมเดียวกัน จะปรับปรุงตัวแบบรู้จำ LM ด้วยวิธี Incremental learning แต่ถ้ามาตรวัดทั้ง 4 มาตรวัดระบุกิจกรรมแตกต่างกันจะใช้วิธี Active learning เพื่อให้ผู้ใช้ระบุกิจกรรมที่กำลังทำ จากนั้นจึงปรับค่าข้อมูลสรุปของกลุ่มย่อยของกิจกรรมที่ผู้ใช้ระบุกับข้อมูลกระแสที่เข้ามา

ในปี ค.ศ. 2018 งานวิจัยของ Jalal *et al.*⁶ ได้แนะนำเสนอตัวแบบไม่เฉพาะบุคคลเช่นเดียวกัน ที่สามารถรู้จำกิจกรรมจากข้อมูลกระแสวิ่งเวลาที่ได้จาก Accelerometer sensor การทำนายหรืออนุมานว่าปัจจุบันผู้ใช้กำลังทำกิจกรรมใดในงานวิจัยนี้ได้แนะนำเสนอตัวแบบที่มีการทำงาน 3 ขั้นตอนตามลำดับ คือ ขั้นตอนการกำจัดสัญญาณรบกวนโดยใช้ตัวกรองมัธยฐาน (Median filter) อันดับ 3 จากนั้นสัญญาณที่ผ่านการกำจัดมาแล้วจะเข้าสู่ขั้นตอนการสกัดคุณลักษณะแบบลำดับชั้น (Hierarchical features) ได้แก่ ขนาดของสัญญาณค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐาน เป็นต้น และสุดท้ายเป็นขั้นตอนการนำคุณลักษณะที่สกัดได้จากสัญญาณมาสร้างเป็นตัวแบบสำหรับการจำแนกกิจกรรมด้วย Linear Support Vector Machine

จากงานวิจัยที่กล่าวมาข้างต้น ถึงแม้การสร้างตัวแบบเฉพาะบุคคลจะได้ตัวแบบรู้จำกิจกรรมที่เหมาะสมกับคนคนนั้น แต่ด้วยข้อจำกัดที่สำคัญ คือ จำเป็นต้องให้ผู้ใช้ทำกิจกรรมเพื่อเก็บข้อมูลสำหรับสร้างตัวแบบ ซึ่งถ้าผู้ใช้ทำกิจกรรมไม่ครบทุกกิจกรรมหรือไม่ครบตามเวลาที่กำหนด ก็จะไม่สามารถสร้างตัวแบบรู้จำกิจกรรมได้ หรือได้ตัวแบบรู้จำกิจกรรมที่ไม่สมบูรณ์ ต่างจากการสร้างตัวแบบรู้จำไม่เฉพาะบุคคลที่ผู้ใช้สามารถนำตัวแบบไปใช้งานได้ทันที จากนั้นตัวแบบรู้จำสามารถปรับปรุงตัวแบบอย่างอัตโนมัติเพื่อให้เป็น

ตัวแบบรู้จำสำหรับผู้ใช้แต่ละคนโดยเฉพาะ แต่อย่างไรก็ตาม เนื่องจากตัวแบบไม่เฉพาะบุคคล ยังมีข้อจำกัดที่สำคัญที่อาจทำให้การทำนายหรืออนุมานกิจกรรมผิดพลาด อันเนื่องมาจากการใช้ข้อมูลการทำกิจกรรมของผู้ใช้คนอื่นมาสร้างตัวแบบ ตัวอย่างเช่นกิจกรรมบางกิจกรรมมีความคล้ายคลึงกัน เช่น การขึ้นลงบันไดมีความคล้ายกับการเดิน เนื่องจากการขึ้นลงบันไดเป็นการเดินรูปแบบหนึ่ง สังเกตได้จาก Figure 1 เป็นการแสดงแผนภาพการกระจายของข้อมูลกิจกรรมการเดินและการขึ้นลงบันได จะเห็นว่าข้อมูลของกิจกรรมทั้งสองมีความทับซ้อนกัน (Overlapping data) การจำแนกกิจกรรมทั้งสองจึงเกิดความผิดพลาดขึ้นได้ นอกจากนี้ตัวแบบรู้จำไม่เฉพาะบุคคลนั้นสร้างจากข้อมูลกิจกรรมของผู้ใช้คนใดก็ได้ ซึ่งถ้าข้อมูลการทำกิจกรรมที่ใช้สร้างตัวแบบแตกต่างกับข้อมูลของผู้ใช้งานตัวแบบมากเกินไป อาจทำให้ตัวแบบรู้จำที่สร้างขึ้นทำนายกิจกรรมผิดพลาดได้ จะเห็นได้จาก Figure 2 ที่เป็นแผนภาพการกระจายของข้อมูลกิจกรรมการยืน ถ้าการสร้างตัวแบบรู้จำกิจกรรมใช้ข้อมูลผู้ใช้หมายเลข 27 ก็อาจไม่สามารถรู้จำกิจกรรมการยืนของผู้ใช้หมายเลข 36 ได้ เนื่องจากลักษณะข้อมูลกิจกรรมการยืนของผู้ใช้ทั้งสองคนแตกต่างกัน ทั้งนี้อาจเกิดจากการจัดวางอุปกรณ์สมาร์ทโฟนในกระเป๋าที่แตกต่างกัน

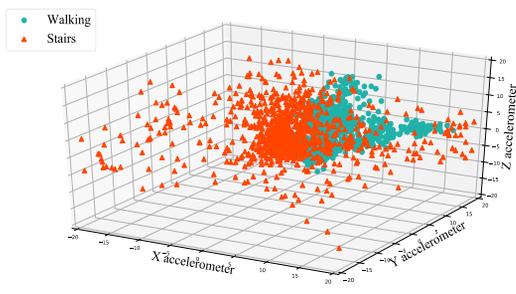


Figure 1 Accelerometer data of walking and stairs activities.

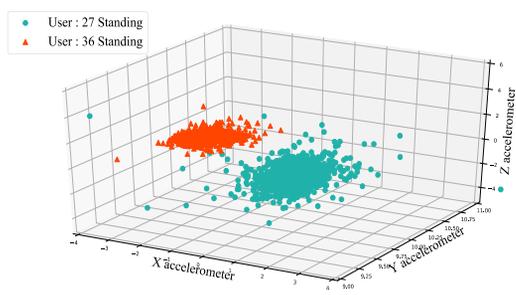


Figure 2 Standing activity data of two users.

กรอบแนวคิดที่นำเสนอ

เพื่อการแก้ปัญหาของงานวิจัยที่กล่าวมาข้างต้น งานวิจัยนี้จึงนำเสนอตัวแบบรู้จำกิจกรรมแบบใหม่ชื่อว่า “ISAR+” (An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data) ซึ่งเป็นตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคลที่พัฒนาต่อยอดมาจากการเดิมของผู้วิจัยเองที่ชื่อ ISAR⁷ โดยวิธีการ ISAR+ มีจุดเด่นดังนี้

- (1) เป็นตัวแบบรู้จำไม่เฉพาะบุคคลหรือตัวแบบกลาง โดยผู้ใช้ใหม่ที่ต้องการใช้งานสามารถนำตัวแบบไปใช้งานได้ โดยไม่ต้องเตรียมข้อมูลสำหรับสร้างตัวแบบเอง และไม่ต้องมีขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบใหม่ ทั้งนี้เพราะวิธีการ ISAR+ เป็นตัวแบบรู้จำที่สามารถปรับตัวแบบให้เหมาะสมกับลักษณะการทำกิจกรรมของผู้ใช้ใหม่แต่ละบุคคลได้ด้วยวิธีการเรียนรู้แบบเพิ่มขึ้น (Incremental learning) และวิธีการ ISAR+ ไม่มีส่วนของการทำ Active learning
- (2) เป็นตัวแบบรู้จำที่มีน้ำหนักเบา (Light-weight recognition model) เนื่องจากใช้ข้อมูลที่ได้จาก Accelerometer sensor เพียงตัวรับรู้เดียวเท่านั้นในการสร้างตัวแบบ ดังนั้นตัวแบบที่นำเสนอจึงที่สามารถติดตั้งภายในอุปกรณ์สมาร์ทโฟน และสามารถรู้จำกิจกรรมแบบเวลาจริงได้

วิธีการ ISAR+ มีกรอบแนวคิดแสดงดัง Figure 3 ประกอบด้วย 2 ขั้นตอน ได้แก่ ขั้นตอนออฟไลน์สำหรับสร้างตัวแบบรู้จำกิจกรรม (Modeling component) และขั้นตอนออนไลน์สำหรับรู้จำกิจกรรมและปรับปรุงตัวแบบรู้จำกิจกรรม (Recognition component)

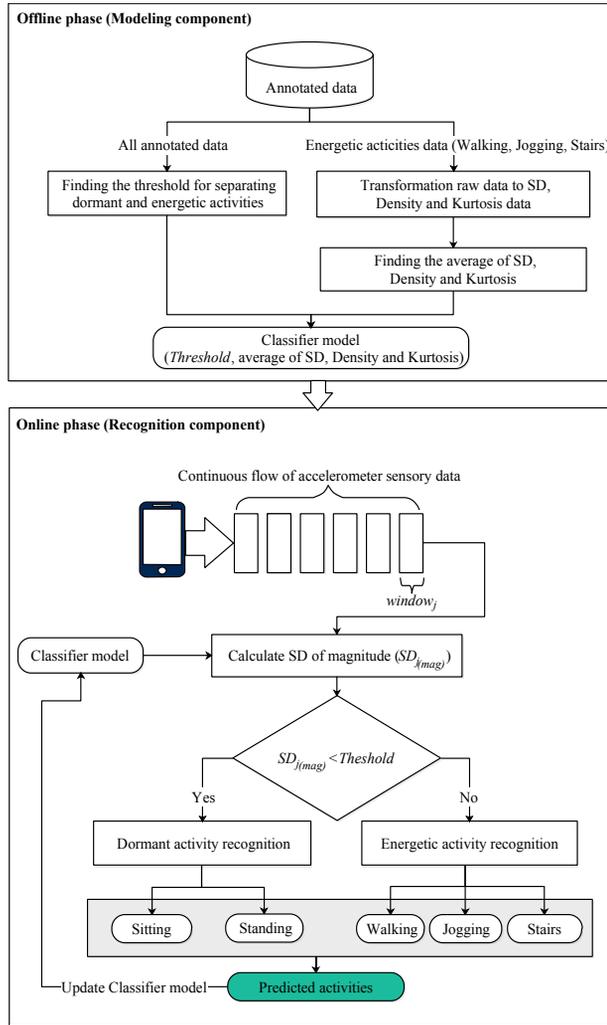


Figure 3 An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+).

วิธีการวิจัย

ข้อมูลที่ใช้สร้างตัวแบบ

วิธีการ ISAR+ ใช้ข้อมูลการทำกิจกรรมที่เป็นข้อมูลสาธารณะ (Public data) ได้แก่ 1) ข้อมูล WISDM^{3,8} ที่เก็บการทำกิจกรรมของอาสาสมัครจำนวน 36 คน ด้วยการใช้แอปพลิเคชันที่สามารถตรวจจับสัญญาณ Accelerometer sensor ของอุปกรณ์สมาร์ตโฟน โดยให้อาสาสมัครทั้ง 36 คน ใส่อุปกรณ์สมาร์ตโฟนไว้ในกระเป๋าทางเกงด้านหน้า ซึ่งตั้งค่าอัตราการสุ่มตัวอย่างของข้อมูลเท่ากับ 20 Hz และทำกิจกรรมต่าง ๆ ตัวอย่างข้อมูลแสดงดัง Figure 4 และ 2) ข้อมูล UniMiB-SHAR⁹ ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 30 คน ด้วยการใช้แอปพลิเคชันที่สามารถตรวจจับค่า Accelerometer sensor ของอุปกรณ์สมาร์ตโฟน โดยให้อาสาสมัครทั้ง 30 คน ใส่อุปกรณ์สมาร์ตโฟนไว้ในกระเป๋าทาง

ด้านหน้า ซึ่งตั้งค่าอัตราการสุ่มตัวอย่างของข้อมูลเท่ากับ 50 Hz และทำกิจกรรมทางกายภาพต่าง ๆ ตัวอย่างข้อมูลดัง Figure 5

เนื่องจากข้อมูลสาธารณะที่นำมาใช้สร้างตัวแบบรู้จักกิจกรรม มีกิจกรรมนอนนิ่งเพียงกิจกรรมเดียวที่อาสาสมัครไม่ได้ทำทุกคน จึงทำให้กิจกรรมนี้มีจำนวนตัวอย่างที่จำนวนน้อยกว่ากิจกรรมอื่น ๆ หากนำข้อมูลกิจกรรมนอนนิ่งมาใช้สร้างตัวแบบอาจทำให้ได้ตัวแบบที่รู้จักกิจกรรมผิดพลาดได้ ดังนั้นในงานวิจัยนี้จึงเน้นการสร้างตัวแบบรู้จักกิจกรรมเพียง 5 กิจกรรม ได้แก่ นิ่ง ยืน เดิน วิ่ง และขึ้นลงบันได เช่นเดียวกับกับวิธีการ STAR และงานวิจัย⁶ ดังนั้นจำนวนตัวอย่างของแต่ละกิจกรรมที่ใช้ในการสร้างตัวแบบแสดงใน Table 1

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

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

Sample	User	Lable	ax	ay	az
s ₁	13	Standing	-1.88	9.85	-0.23
s ₂	13	Standing	-0.19	9.92	-0.57
s ₃	13	Standing	-0.61	10.27	-0.88
s ₄	13	Standing	-0.11	9.58	2.49
s ₅	13	Standing	-0.72	9.89	2.41
s ₆	13	Standing	-0.53	9.34	2.49
⋮	⋮	⋮	⋮	⋮	⋮
s _i	13	Standing	ax _i	ay _i	az _i
⋮	⋮	⋮	⋮	⋮	⋮
s _N	13	Standing	ax _N	ay _N	az _N

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

ขั้นตอนการดำเนินการวิจัย

วิธีการ ISAR+ ประกอบไปด้วย ขั้นตอนออฟไลน์สำหรับสร้างตัวแบบรู้จักกิจกรรม และขั้นตอนออนไลน์สำหรับรู้จักกิจกรรมและปรับปรุงตัวแบบ โดยงานวิจัยนี้ได้เน้นการสร้างตัวแบบรู้จักกิจกรรมทางกายภาพ ได้แก่ เดิน นิ่ง ยืน วิ่งเบา ๆ 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 กลุ่มแรกเป็นกิจกรรมที่มีการเคลื่อนไหวร่างกายเล็กน้อย ได้แก่ ยืน และนั่ง เรียกกิจกรรมกลุ่มนี้ว่า “กิจกรรมแบบอยู่นิ่ง (Dormant activities)” กลุ่มที่สองเป็นกิจกรรมที่เคลื่อนไหวร่างกายค่อนข้างมากหรือการขยับร่างกายอย่างรวดเร็ว ได้แก่ เดิน วิ่ง และขึ้นลงบันได เรียกกลุ่มกิจกรรมนี้ว่า “กิจกรรมแบบเคลื่อนไหว (Energetic activities)” รายละเอียดของแต่ละขั้นตอนตามกรอบแนวคิดดังนี้

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

กำหนดให้ *act* เป็นเซตของกิจกรรมต่าง ๆ 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* เพื่อใช้สำหรับแยกประเภทของข้อมูลกิจกรรมดังที่ได้กล่าวไปข้างต้นจาก Figure 6 และ Figure 7 จะสังเกตเห็นได้ว่าเส้นข้อมูลของค่า Accelerometer ทั้ง 3 แกนของกิจกรรมทั้ง 2 กลุ่ม มีความแตกต่างกันอย่างชัดเจน กิจกรรมแบบนิ่ง ลักษณะเส้นข้อมูลของค่า Accelerometer มีการแกว่งน้อยมากหรือเกือบคงที่ และมีการกระจายตัวของข้อมูลน้อย เนื่องจากกิจกรรมกลุ่มนี้มีการเคลื่อนไหวน้อย ทำให้ไม่มีผลต่อค่า Accelerometer ตรงกันข้ามกับกิจกรรมแบบเคลื่อนไหว ที่เส้นข้อมูลมีลักษณะแกว่งขึ้นลงมาก และมีการกระจายตัวของข้อมูลที่สูง เนื่องจากกิจกรรมกลุ่มนี้เกิดการเปลี่ยนแปลงของค่า Accelerometer ตลอดเวลา

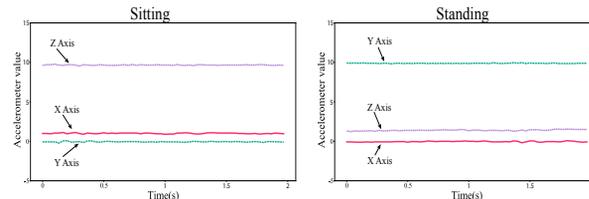


Figure 6 Accelerometer lines of dormant activities.

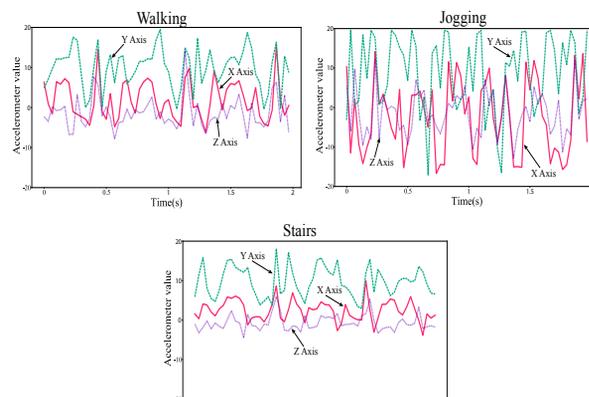


Figure 7 Accelerometer lines of energetic activities.

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 มีจำนวนตัวอย่างเท่ากับอัตราการสุ่มของข้อมูลที่ใช้ แล้วนำไปคำนวณหาค่าส่วนเบี่ยงเบนมาตรฐาน (SD) ของแต่ละ window j โดยใช้ Equation 2 ซึ่งจะทำได้ค่า $SD_{j(mag)}^{act}$

$$M_i = \sqrt{ax_i^2 + ay_i^2 + az_i^2} \tag{1}$$

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

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

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

```

/*  $N_C$  = 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 activities. */
/*  $J$  = the number of window. */
/*  $n$  = the number of data in window. */
Input :  $N_C$ .
Output:  $CM, Threshold$ .
1 for each  $act$  in annotated data do
  /*  $act = (sitting, standing, walking,$ 
  jogging, stairs) */
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
  /*  $act = (walking, jogging, stairs)$ 
  */
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 ที่มากที่สุดของกิจกรรมแบบหนึ่ง (SD_{max})

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

หาค่า SD ที่น้อยที่สุดของกิจกรรมเคลื่อนไหว (SD_{min})

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

คำนวณค่าขีดแบ่ง $Threshold$ ดังนี้

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

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

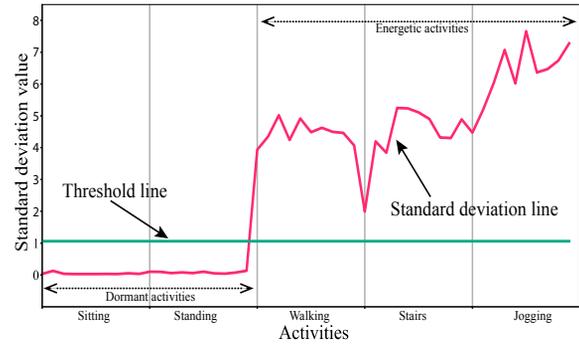


Figure 8 The threshold line.

จากนั้นเมื่อนำข้อมูลค่า Accelerometer ทั้ง 3 แกน ของกิจกรรมแบบเคลื่อนไหว โดยให้แสดงเป็นแผนภาพ การกระจายตัวดัง Figure 9 คณะผู้วิจัยพบว่า ข้อมูลแต่ละ กิจกรรมซ้อนทับกันมาก ทั้งนี้เนื่องจากทั้ง 3 กิจกรรม มีลักษณะคล้ายกัน เช่นการเดินขึ้นลงบันไดก็ถือว่าการเดิน ในรูปแบบหนึ่ง ดังนั้นถ้านำข้อมูลชุดนี้ไปสร้างตัวแบบรู้จำ กิจกรรม จะทำให้ได้ตัวแบบที่ทำนายหรืออนุมานการทำ กิจกรรมปัจจุบันผิดพลาดได้ 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

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

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

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

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

จาก Figure 10 เป็นผลลัพธ์จากการแปลงข้อมูลค่า Accelerometer ของทั้ง 3 กิจกรรม ไปเป็นค่าของ SD ในแต่ละ window จะเห็นได้ว่ากลุ่มข้อมูลแต่ละกิจกรรมที่เคยทับซ้อนกัน สามารถแยกเป็นกลุ่มออกจากกันได้ ซึ่งจะส่งผลให้การจำแนกข้อมูลกิจกรรมสามารถทำได้ง่ายยิ่งขึ้น

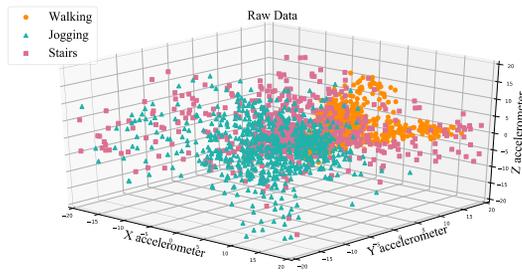


Figure 9 Accelerometer data of energetic activities.

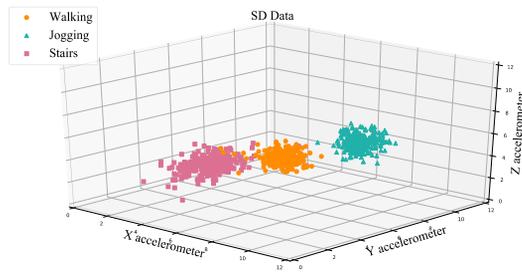


Figure 10 SD data of energetic activities.

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

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

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

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

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

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

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

สุดท้ายคำนวณหาค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่น และความโค้งของแต่ละกิจกรรมแบบเคลื่อนไหว สามารถคำนวณได้จาก Equation 15 ถึง Equation 23 จากนั้นจะได้ Classifier model (CM) เพื่อเก็บข้อมูลสรุปได้แก่ ค่าขีดแบ่ง (Threshold) ค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐาน (SD_{CM}^{act}) ค่าเฉลี่ยของความหนาแน่น ($Dens_{CM}^{act}$) และค่าเฉลี่ยของความโค้ง ($Kurt_{CM}^{act}$) 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

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

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

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

ค่าเฉลี่ยความโค้งตามแกน X, Y และ Z

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

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

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

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

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

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

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

ขั้นตอนออนไลน์

ภาพรวมการทำงานของขั้นตอนออนไลน์แสดงได้ดัง Figure 3 ซึ่งประกอบด้วยขั้นตอนการรู้จักกิจกรรมและปรับตัวแบบกับข้อมูลกระแสวิ่งเวลาที่ผลิตอย่างต่อเนื่องจากตัวรับรู้ Accelerometer ของสมาร์ตโฟน โดยการจัดการกับข้อมูลกระแสจะนำเข้ามาข้อมูลกระแสทีละ window ซึ่งจำนวนตัวอย่างภายใน window จะขึ้นอยู่กับค่าอัตราสุ่มตัวอย่างของอุปกรณ์สมาร์ตโฟน การทำงานของขั้นตอนนี้แสดงใน Algorithm 2 รวมถึงการปรับปรุงตัวแบบรู้จักกิจกรรมใน Algorithm 3

ใน Algorithm 2 เริ่มต้นจากการแปลงข้อมูลค่า Accelerometer ของตัวอย่างภายใน window เป็นส่วนเบี่ยงเบนมาตรฐานของ Magnitude ($SD_{j(mag)}$) เพื่อใช้ในการจำแนกว่าข้อมูลกระแสที่เข้ามาเป็นกิจกรรมแบบนิ่งหรือแบบเคลื่อนไหว โดยเปรียบเทียบกับค่าขีดแบ่ง *Threshold* ที่คำนวณไว้แล้วในขั้นตอนออฟไลน์ ในการจำแนกประเภทกิจกรรมว่าเป็นกิจกรรมแบบนิ่งหรือเป็นกิจกรรมแบบเคลื่อนไหว มีเกณฑ์ดังนี้

ถ้า $SD_{j(mag)} < Threshold$ แสดงว่าข้อมูลกระแสที่นำเข้ามาเป็นกิจกรรมแบบนิ่ง

แต่ถ้า $SD_{j(mag)} > Threshold$ แสดงว่าข้อมูลกระแสที่นำเข้ามาจะเป็นกิจกรรมแบบเคลื่อนไหว

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

```

/* Sζ = the set of non-stationary streaming data.
*/
/* CM = {SDCMact, DensCMact, KurtCMact} when act are walking, jogging and stairs.
*/
/* Threshold = the separating dormant and energetic activities.
*/
/* J = the number of window.
*/
/* n = the number of data in window.
*/
Input : Sζ, CM, Threshold.
Output: Pact.
1 while Sζ is not empty do
2   for each fixed size window j do
3     /* j = 1, 2, ..., J
4     Compute Mi using eq. (1) of each sample in window j.
5     /* i = 1, 2, 3, ..., 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 acceleration values x, y, and z.
11      Compute  $Dist(\bar{ax}, \bar{ay})$  and  $Dist(\bar{ax}, \bar{az})$  using eq. (27) and (28)
12      if  $Dist(\bar{ax}, \bar{ay}) > Dist(\bar{ax}, \bar{az})$  then
13        Pact = standing
14      else
15        Pact = sitting
16      end
17    else
18      Compute the average values ( $\bar{ax}_j, \bar{ay}_j, \bar{az}_j$ ) of each acceleration values x, y, and z.
19      Compute the standard deviation of each acceleration values  $SD_{j(ax)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax - \bar{ax})^2}$ ,  $SD_{j(ay)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay - \bar{ay})^2}$ ,  $SD_{j(az)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (az - \bar{az})^2}$  then set to SDj
20       $SD_j = (SD_{j(ax)}, SD_{j(ay)}, SD_{j(az)})$ 
21      Find the nearest activity act such that
22       $Predicted = argmin_{act} (\|SD_j - SD_{CM}^{act}\|)$ 
23      /* act ∈ [walking, jogging, stairs]
24      Set the activity of Predicted to Pact.
25    end
26  end
27 end
    
```

ในการรู้จักกิจกรรมแบบนิ่ง (Dormant activities recognition) เนื่องจากกิจกรรมแบบนิ่ง หมายถึงกิจกรรมที่มีการขยับร่างกายน้อย ได้แก่ การยืนและการนั่ง ดังนั้นการจำแนกกิจกรรมว่าจะเป็นการยืนหรือการนั่ง จะจำแนกจากลักษณะเส้นข้อมูลของค่า Accelerometer ดังแสดงใน Figure 11 และ Figure 12

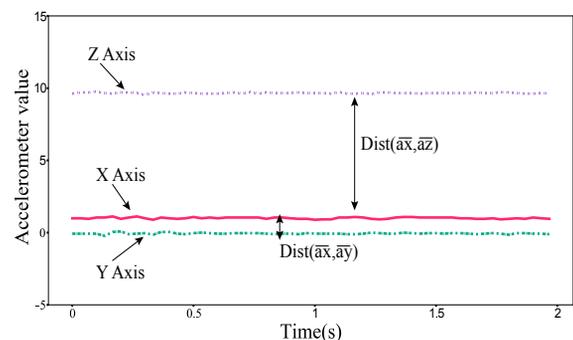


Figure 11 The accelerometer lines of sitting activity.

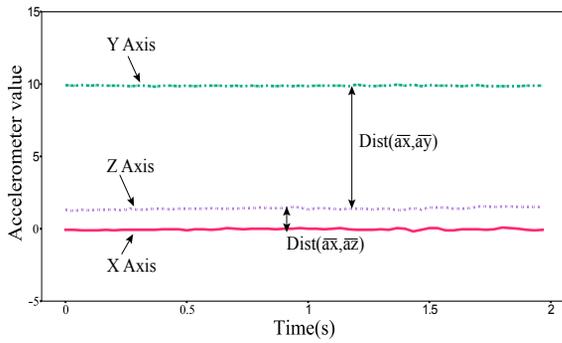


Figure 12 The accelerometer lines of standing activity.

จาก Figure 11 และ Figure 12 เป็นการแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของการยืนและการนั่ง ซึ่งจะสังเกตว่าในกิจกรรมการยืนค่า Accelerometer ตามแนวแกน Y จะมีค่าที่ห่างจาก Accelerometer ตามแนวแกน X และ Z อย่างเห็นได้ชัด ส่วนกิจกรรมการนั่งจะมีค่า Accelerometer ตามแนวแกน Z ห่างจากค่า Accelerometer ตามแนวแกน X และ Y อย่างชัดเจน สาเหตุที่เป็นเช่นนี้เนื่องจากในขณะที่เรานั่งหรือยืน จะมีความแรงที่เกิดขึ้นจากแรงโน้มถ่วงของโลกที่แตกต่างกันในแต่ละแกน จากข้อสังเกตนี้จึงได้ใช้ระยะห่างของค่า Accelerometer ตามแนวแกน Y และ Z ที่มีต่อค่า Accelerometer ตามแนวแกน X มาใช้ในการจำแนกว่าข้อมูลนั้นเป็นการยืนหรือการนั่ง ซึ่งเหตุผลที่ให้ค่า Accelerometer ตามแนวแกน X เป็นข้อมูลหลักในการวัดระยะห่าง เพราะไม่ว่าจะเป็นการยืนหรือการนั่ง ค่า Accelerometer ตามแนวแกน X จะมีลักษณะเหมือนกันคือเข้าใกล้ 0 ต่างจากค่า Accelerometer ตามแนวแกน Y และ Z ที่เปลี่ยนไปตามแต่กิจกรรม ดังนั้นในงานวิจัยนี้จึงใช้การจำแนกกิจกรรมแบบหนึ่งดัง 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 ของข้อมูลที่เข้ามาใหม่ในแต่ละ window โดยใช้ Equation 6 ถึง Equation 8 เปรียบเทียบกับค่าเฉลี่ย SD แต่ละกิจกรรมที่อยู่ใน 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 ขั้นตอนต่อมาจะตรวจสอบว่าต้องปรับปรุงตัวแบบรู้จำกิจกรรม CM หรือไม่ เพื่อให้ได้ตัวแบบที่เหมาะสมกับลักษณะการทำกิจกรรมของผู้ใช้ ตามการทำงานของ **Algorithm 3** โดยการคำนวณความหนาแน่น ($Dens_j$) และความโด่ง ($Kurt_j$) ในแต่ละแกนของข้อมูลกระแสใน window j จากนั้นนำไปเปรียบเทียบกับค่าที่เก็บไว้ใน CM ซึ่งใช้หลักการเดียวกันกับตอนที่ทำการรู้จำกิจกรรมด้วยส่วนเบี่ยงเบนมาตรฐาน จากนั้นจะพิจารณากิจกรรมที่ระบุด้วยส่วนเบี่ยงเบนมาตรฐาน (SD_{vote}) ความหนาแน่น ($Dens_{vote}$) และความโด่ง ($Kurt_{vote}$) 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

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

การปรับปรุงความโด่งภายใน 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
6   Update CM with calculate
   newSDCMact, newDensCMact, newKurtCMact using eq.(32)-(34).
   Set CM = {newSDCMact, newDensCMact, newKurtCMact}.
7 else
8   Not update CM
9 end

```

ผลการศึกษา

ในงานวิจัยนี้จะวัดประสิทธิผลในด้านความถูกต้องในการทำนายหรืออนุมานกิจกรรมของตัวแบบและประสิทธิภาพด้านเวลาของตัวแบบรู้จำกิจกรรม โดยขั้นตอนการรู้จำกิจกรรมของวิธีการที่นำเสนอ ISAR+ เปรียบเทียบประสิทธิภาพกับ วิธีการ STAR⁵ วิธีการจากงานวิจัย⁶ และวิธีการ ISAR⁷ โดยใช้ข้อมูล WISDM และข้อมูล UniMiB-SHAR เนื่องจากงานวิจัยนี้มี การทดสอบประสิทธิภาพของตัวแบบรู้จำกิจกรรมที่สร้างขึ้นกับวิธีการ STAR ซึ่งวิธีการ STAR มีทั้ง STAR (without Active learning) และ STAR (with Active learning) ดังนั้นการจำลองวิธีการ STAR ที่มี Active learning ทำได้โดยใช้คำตอบที่ได้จากชุดข้อมูลทดสอบแทนคำตอบที่ได้จากผู้ใช้ ส่วนวิธีการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมงานวิจัยนี้ใช้มาตรวัดหลายวิธี ได้แก่ Precision, Recall, F-measure และ Accuracy

Precision เป็นการวัดความแม่นยำของตัวแบบรู้จำกิจกรรม โดยวัดจากจำนวนที่ตัวแบบรู้จำกิจกรรมทำนายถูกต้องและเป็นกิจกรรมที่กำลังพิจารณาว่ามีอัตราส่วนเท่าไรกับจำนวนกิจกรรมที่ถูกทำนายเป็นกิจกรรมที่กำลังพิจารณาทั้งหมดสามารถคำนวณจาก Equation 35

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

ส่วนการวัด Recall เป็นการวัดความถูกต้องของตัวแบบรู้จำกิจกรรม โดยวัดจากจำนวนที่ตัวแบบรู้จำกิจกรรมทำนายถูกต้องและเป็นกิจกรรมที่กำลังพิจารณาว่ามีอัตราส่วนเท่าไรกับจำนวนกิจกรรมที่กำลังพิจารณาทั้งหมด คำนวณโดยใช้ Equation 36

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

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

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

ส่วนมาตรวัด Accuracy เป็นการวัดความถูกต้องของตัวแบบในการทำนายหรืออนุมานกิจกรรมที่กำลังทำ โดยจะพิจารณาจากจำนวนครั้งที่ตัวแบบทำนายถูกต้องเทียบกับจำนวนตัวอย่างทั้งหมดที่ใช้ในการทดสอบตัวแบบ

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

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

การวัดประสิทธิภาพของตัวแบบรู้จำแต่ละวิธี ใช้วิธีการวัดที่เรียกว่า Leave-one-subject-out (LOSO) cross validation กล่าวคือใช้ข้อมูลการทำกิจกรรมทุกกิจกรรมของผู้ใช้ 1 คน เป็นข้อมูลชุดทดสอบ ส่วนข้อมูลการทำกิจกรรมของผู้ใช้คนอื่นใช้สำหรับสร้างตัวแบบรู้จำ จากนั้นสลับข้อมูลการทำกิจกรรมของผู้ใช้แต่ละคนเป็นข้อมูลชุดทดสอบและข้อมูลสำหรับสร้างตัวแบบ ทำลักษณะเช่นนี้จนกว่าจะครบทุกคน

ผลการรู้จำกิจกรรมกับข้อมูล WISDM

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

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

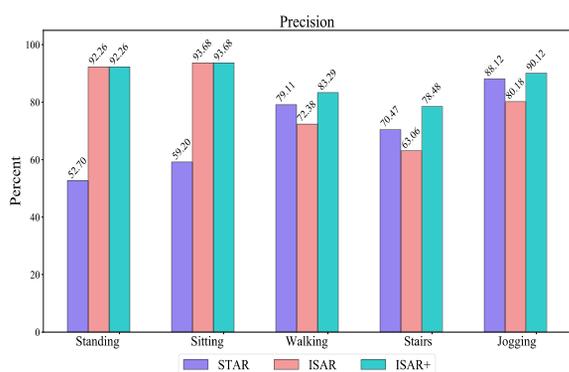


Figure 14 Precision of activity recognition using WISDM dataset. Each model is represented in different colors.

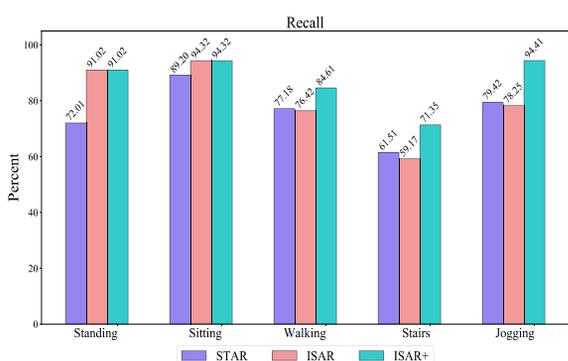


Figure 15 Recall of activity using WISDM dataset. Each model is represented in different colors.

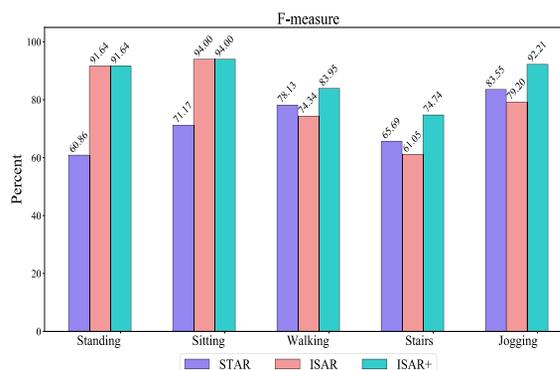


Figure 16 F-measure of activity recognition using WISDM dataset. Each model is represented in different colors.

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

Model	Accuracy
STAR without active learning ⁵	23.40%
STAR with active learning ⁵	77.29%
Research ⁶	82.77%
ISAR ⁷	75.67%
ISAR+	85.81%

ผลการรู้จำกิจกรรมกับข้อมูล UniMiB-SHAR

ผลการวัดประสิทธิภาพความแม่นยำของตัวแบบรู้จำกิจกรรมด้วยมาตรฐาน Precision, Recall และ F-measure แสดงดัง Figure 17 ถึง Figure 19 จะเห็นว่าวิธีการ ISAR+ มีประสิทธิภาพความแม่นยำที่ดีที่สุดของการทำนายหรือการอนุมานการทำกิจกรรมในทุกกิจกรรม โดยเฉพาะกิจกรรมที่เป็นการเดินทาง ยืน และวิ่งเบา ๆ ที่วิธีการ ISAR+ ให้ผลการทำนายหรืออนุมานกิจกรรมมีความแม่นยำที่สูงเกิน 90% เมื่อพิจารณาประเด็นความถูกต้องในการทำนายหรืออนุมานวิธีการ ISAR+ มีความถูกต้องเฉลี่ยเท่ากับ 88.03% และให้ผลความถูกต้องที่ดีที่สุดและดีกว่าวิธีการอื่นแสดงได้ดัง Table 3

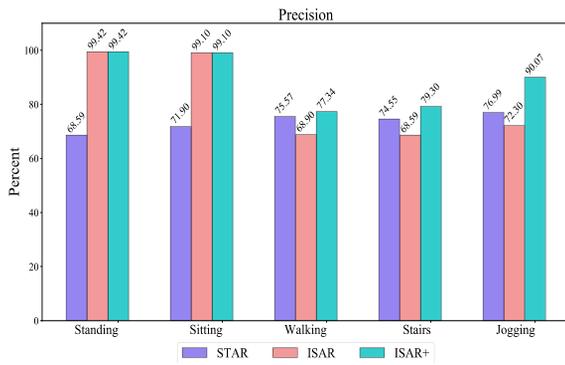


Figure 17 Precision of activity recognition on UniMiB-SHAR. Each model is represented in different colors.

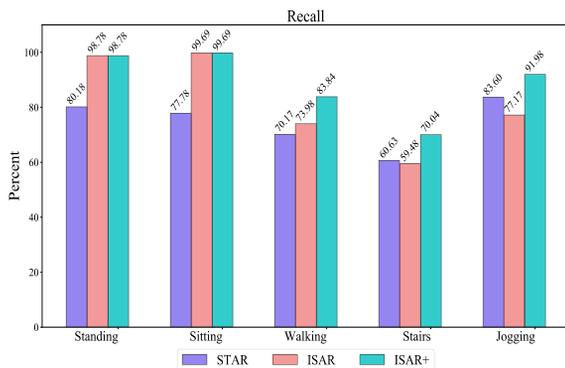


Figure 18 Recall of activity recognition on UniMiB-SHAR. Each model is represented in different colors.

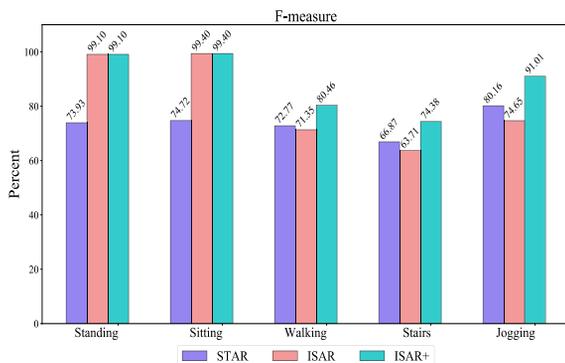


Figure 19 F-measure of activity recognition on UniMiB-SHAR. Each model is represented in different colors.

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

Model	Accuracy
STAR without active learning ⁵	22.29 %
STAR with active learning ⁵	73.31 %
ISAR ⁷	81.23 %
ISAR+	88.03 %

การวัดประสิทธิภาพด้านเวลาของตัวแบบ

การวัดประสิทธิภาพด้านเวลาของวิธีการที่นำเสนอ ISAR+ จะเปรียบเทียบกับวิธีการเดิมของผู้วิจัยคือ วิธีการ ISAR และวิธีการ STAR ส่วนวิธีการจากงานวิจัยหมายเลข 6 ไม่ได้เปรียบเทียบ เนื่องจากลักษณะขั้นตอนวิธีไม่ได้เป็น 2 ขั้นตอน (ออฟไลน์และออนไลน์) เหมือนกับวิธีการ STAR

วิธีการ STAR ในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (Modeling) ได้ใช้วิธีการแบ่งกลุ่มข้อมูล จึงทำให้มีความซับซ้อนเชิงเวลาคือ $O(KNl)$ โดยที่ K คือจำนวนกลุ่มในการแบ่งกลุ่มข้อมูล N คือ จำนวนตัวอย่างข้อมูลทั้งหมดของแต่ละกิจกรรม และ l คือ จำนวนการวนลูปในการแบ่งกลุ่มข้อมูลกิจกรรม ส่วนขั้นตอนการรู้จำกิจกรรม (Recognition) วิธีการ STAR ได้ใช้การแบ่งกลุ่มข้อมูลออกเป็น 2 กลุ่มแล้วใช้มาตรวัดหลายตัวในการระบุกิจกรรม ซึ่งมีความซับซ้อนเชิงเวลาคือ $O(2nl) + O(Kn)$ โดยที่ n คือ จำนวนตัวอย่างข้อมูลกิจกรรมภายใน 1 window (ขึ้นอยู่กับอัตราการสุ่มตัวอย่างของข้อมูลนั้น) และในขั้นตอนปรับปรุง ตัวแบบรู้จำกิจกรรม (Update) วิธีการ STAR มีความซับซ้อนเชิงเวลา คือ $O(Kn)$

ส่วนวิธีการ ISAR ในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (Modeling) ได้แปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานก่อนนำไปแบ่งกลุ่มข้อมูล ซึ่งมีความซับซ้อนเชิงเวลา คือ $O(N) + O(KJl)$ โดยที่ J คือจำนวนของ window ขั้นตอนการรู้จำกิจกรรม (Recognition) วิธีการ ISAR ไม่ได้มีการแบ่งกลุ่มข้อมูล แต่ใช้เพียงหนึ่งมาตรวัดในการระบุกิจกรรมที่กำลังทำ จึงมีความซับซ้อนเชิงเวลา คือ $O(n)$

สุดท้ายวิธี ISAR+ ที่นำเสนอในงานวิจัยนี้ ในขั้นตอนสร้างตัวแบบรู้จำกิจกรรม (Modeling) ไม่มีการแบ่งกลุ่มข้อมูลเช่นเดียวกัน แต่มีการแปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน ความโด่ง ความหนาแน่น ซึ่งมีความซับซ้อนเชิงเวลา คือ $O(N)$ ในขั้นตอนการรู้จำกิจกรรม (Recognition) วิธีการ ISAR+ ใช้เพียงหนึ่งมาตรวัดในการระบุกิจกรรมเช่นเดียวกับวิธีการ ISAR ดังนั้นจึงมีความซับซ้อนเชิงเวลา คือ $O(n)$ และขั้นตอนการปรับปรุงตัวแบบรู้จำกิจกรรม (Update)

วิธีการ ISAR+ ได้พิจารณาค่าส่วนเบี่ยงเบนมาตรฐาน ค่าความโด่งและค่าความหนาแน่นของข้อมูลภายใน window จึงมีความซับซ้อนเชิงเวลา $O(n)$ คือ แสดงดัง 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

จากผลการทดลองเปรียบเทียบการวัดประสิทธิภาพความถูกต้องและแม่นยำของการรู้จำกิจกรรมด้วยวิธี Precision, Recall, F-measure และ Accuracy แสดงให้เห็นว่าวิธีการที่นำเสนอ ISAR+ มีประสิทธิภาพผลด้านความถูกต้องและความแม่นยำได้ดีที่สุดของการทำนายหรือการอนุมานการทำกิจกรรมปัจจุบัน โดยที่วิธีการ ISAR+ สามารถแก้ปัญหาการรู้จำกิจกรรม เมื่อข้อมูลกิจกรรมที่ใช้สร้างตัวแบบมีความทับซ้อนกัน และสามารถใช้อัตราการเรียนรู้ของผู้ใช้ทั่วไปที่มีลักษณะการทำกิจกรรมที่ต่างกันในการสร้างตัวแบบที่ไม่เฉพาะบุคคล ดังนั้นวิธีการ ISAR+ จึงถือได้ว่าเป็นตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคลที่สามารถปรับปรุงตัวแบบให้เข้ากับลักษณะการทำกิจกรรมของผู้ใช้ใหม่แต่ละบุคคลได้โดยอัตโนมัติ นอกจากนี้ในการวัดประสิทธิภาพเชิงเวลาวิธีการ ISAR+ มีประสิทธิภาพดีที่สุดในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม และขั้นตอนการเรียนรู้กิจกรรมและการปรับปรุงตัวแบบรู้จำ ซึ่งน่าจะเหมาะสมสำหรับการนำไปประยุกต์ใช้ในงานจริงกับรู้จำกิจกรรมที่ประมวลผลภายในอุปกรณ์ได้

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการสนับสนุนการวิจัยจากงบประมาณเงินรายได้ (เงินอุดหนุนจากรัฐบาล) ประจำปีงบประมาณ พ.ศ. 2561 มหาวิทยาลัยบูรพา ผ่านสำนักงานคณะกรรมการวิจัยแห่งชาติ สัญญาเลขที่ 113/2561 และจากสำนักงานกองทุนสนับสนุนการวิจัย (RTA6080013) สุดทำยขอขอบคุณศาสตราจารย์ ดร.ชิตชนก เหลือสินทรัพย์ ที่ช่วยแนะนำทางในการทำวิจัยนี้ รวมถึงนายเทิดศักดิ์ 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 5th 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).