

ระบบรู้จำกิจกรรมที่ปรับได้ โดยใช้ข้อมูลตัวรับรู้แอกเซลโรมิเตอร์
ของสมาร์ทโฟน

เทิดศักดิ์ ดุงแก้ว

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาการสารสนเทศ
คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา
สิงหาคม 2561
ลิขสิทธิ์ของมหาวิทยาลัยบูรพา

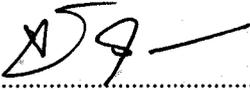
ADAPTIVE ACTIVITY RECOGNITION SYSTEM USING THE ACCELEROMETER
SENSORY DATA OF SMARTPHONE

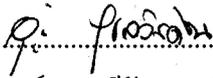
THERDSAK DUNGKAEW

A THESIS SUBMITTED IN PARTIAL FULFILLMENT OF THE REQUIREMENT FOR
THE MASTER DEGREE OF SCIENCE
IN INFORMATICS
FACULTY OF INFORMATICS
BURAPHA UNIVERSITY
AUGUST 2018
COPYRIGHT OF BURAPHA UNIVERSITY

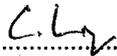
คณะกรรมการควบคุมวิทยานิพนธ์และคณะกรรมการสอบวิทยานิพนธ์ได้พิจารณา
วิทยานิพนธ์ของ เทิดศักดิ์ ดุงแก้ว ฉบับนี้แล้ว เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการสารสนเทศ ของมหาวิทยาลัยบูรพาได้

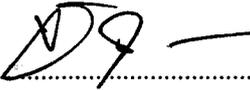
คณะกรรมการควบคุมวิทยานิพนธ์

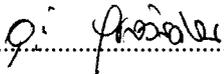

.....อาจารย์ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.จักริน สุขสวัสดิ์ชน)


.....อาจารย์ที่ปรึกษาร่วม
(ผู้ช่วยศาสตราจารย์ ดร.อุรีรัฐ สุขสวัสดิ์ชน)

คณะกรรมการสอบวิทยานิพนธ์


.....ประธานกรรมการ
(ศาสตราจารย์ ดร.ชิตชนก เหลือสินทรัพย์)


.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.จักริน สุขสวัสดิ์ชน)


.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.อุรีรัฐ สุขสวัสดิ์ชน)


.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.โกเมศ อัมพวัน)

คณะวิทยาการสารสนเทศ อนุมัติให้รับวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตาม
หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการสารสนเทศ ของมหาวิทยาลัยบูรพา


.....คณบดีคณะวิทยาการสารสนเทศ
(ผู้ช่วยศาสตราจารย์ ดร.กฤษณะ ชินสาร)

วันที่...15...เดือน สิงหาคม พ.ศ. 2561

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้เสร็จสมบูรณ์ได้ด้วยดีด้วยการสนับสนุนจากคณาจารย์ คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพาทุกท่านที่ช่วยแนะนำและให้ความรู้แก่ผู้วิจัย โดยเฉพาะอย่างยิ่ง ผู้ช่วยศาสตราจารย์ ดร.จักริน สุขสวัสดิ์ชน อาจารย์ที่ปรึกษาหลัก และผู้ช่วยศาสตราจารย์ ดร.อุรีรัฐ สุขสวัสดิ์ชน อาจารย์ที่ปรึกษาร่วมที่ช่วยให้คำปรึกษาและแนวทางในการดำเนินงานวิทยานิพนธ์เล่มนี้ อีกทั้งยังช่วยแก้ไขข้อบกพร่องและแนะนำในงานเขียนวิทยานิพนธ์ด้วยดีเสมอมา ผู้วิจัยรู้สึกซาบซึ้งเป็นอย่างยิ่ง จึงขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้

ขอขอบคุณ คุณพ่อไพศาล คุณแม่ผอง ดุงแก้ว รวมทั้งพี่ ๆ น้อง ๆ และเพื่อน ๆ ที่ช่วยเหลือในการให้คำแนะนำและให้กำลังใจในการเรียนและการดำเนินงานวิทยานิพนธ์ตลอดสามปีที่ผ่านมา ทำให้ผู้วิจัยประสบความสำเร็จในการศึกษาด้วยดี

วิทยานิพนธ์นี้ได้รับทุนสนับสนุนจากงบประมาณเงินรายได้จากเงินอุดหนุนรัฐบาล (งบประมาณแผ่นดิน) ประจำปีงบประมาณ พ.ศ. 2560 มหาวิทยาลัยบูรพา ผ่านสำนักงานคณะกรรมการการวิจัยแห่งชาติ เลขที่สัญญา 141/2560

เทิดศักดิ์ ดุงแก้ว

58910104: สาขาวิชา: วิทยาการสารสนเทศ; วท.ม. (วิทยาการสารสนเทศ)

คำสำคัญ: การรู้จำกิจกรรม/ตัวรับรู้/อุปกรณ์สมาร์ทโฟน

เทิดศักดิ์ ดุงแก้ว: ระบบรู้จำกิจกรรมที่ปรับได้ โดยใช้ข้อมูลตัวรับรู้แอคเซเลอโรมิเตอร์ของสมาร์ทโฟน คณะกรรมการควบคุมวิทยานิพนธ์: จักริน สุขสวัสดิ์ชน, Ph.D., อรุณีรัฐ สุขสวัสดิ์ชน, Ph.D., 127 หน้า. ปี พ.ศ. 2561.

วัตถุประสงค์ของการรู้จำกิจกรรมจากสมาร์ทโฟน คือการวิเคราะห์ข้อมูลกระแสเชิงเวลาจากตัวรับรู้และระบุกิจกรรมที่เกิดขึ้น ณ ขณะนั้นอย่างถูกต้องแม่นยำ ดังนั้นการรู้จำกิจกรรมทางกายภาพของมนุษย์โดยใช้การวิเคราะห์ข้อมูลตัวรับรู้แอคเซเลอโรมิเตอร์จากโทรศัพท์มือถือของผู้ใช้จึงเป็นประเด็นที่น่าสนใจสำหรับนักวิจัยและนักพัฒนา งานวิจัยส่วนใหญ่ที่เกี่ยวกับการรู้จำกิจกรรมเป็นงานวิจัยที่สร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคล ตัวแบบรู้จำกิจกรรมเหล่านี้ใช้ข้อมูลของผู้ใช้คนเดียวสำหรับสอนและทดสอบ โดยให้ระบุกิจกรรมตามระยะเวลาที่กำหนด อย่างไรก็ตามการสร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคลอาจเป็นการรบกวนผู้ใช่มากเกินไป เนื่องจากต้องเสียเวลาสำหรับเก็บรวบรวมข้อมูลกิจกรรม หากผู้ใช้ไม่สามารถทำกิจกรรมทั้งหมดหรือทำไม่ครบตามระยะเวลาที่กำหนด การรู้จำกิจกรรมอาจมีความผิดพลาดเกิดขึ้นได้

ดังนั้นวิทยานิพนธ์นี้จึงได้นำเสนอกรอบแนวคิดการรู้จำกิจกรรมแบบใหม่ 2 วิธี สำหรับการรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลา กรอบแนวคิดแรกคือ “การรู้จำกิจกรรมไม่เฉพาะบุคคลบนอุปกรณ์สมาร์ทโฟน” หรือ “ไอซาร์” วิธีการไอซาร์ประกอบด้วยขั้นตอนออฟไลน์และออนไลน์ ขั้นตอนออฟไลน์เป็นขั้นตอนสร้างตัวแบบรู้จำกิจกรรมจากข้อมูลที่ทราบการทำกิจกรรม ร่วมกับการใช้เทคนิควิธีการจัดกลุ่มข้อมูล ส่วนขั้นตอนออนไลน์เป็นการรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาแบบเรียลไทม์ที่สามารถประมวลผลบนอุปกรณ์ กรอบแนวคิดที่สองคือ “การปรับปรุงการรู้จำกิจกรรมไม่เฉพาะบุคคลบนอุปกรณ์สมาร์ทโฟน” หรือ “ไอซาร์พลัส” ผลงานหลักในวิทยานิพนธ์นี้ คือ (1) นำเสนอวิธีการใหม่สำหรับจำแนกกิจกรรมตามคุณลักษณะของแต่ละกิจกรรม โดยจำแนกข้อมูลออกเป็น 2 กลุ่มกิจกรรม ได้แก่ กลุ่มกิจกรรมแบบนิ่งและกลุ่มกิจกรรมแบบเคลื่อนไหว จากข้อมูลกระแสเชิงเวลาที่กำลังเข้ามาและไม่ทราบว่าเป็นกิจกรรมอะไร (2) ตัวแบบรู้จำกิจกรรมแบบใหม่ นำเสนอวิธีการจัดการกับข้อมูลที่ทับซ้อนกัน และสามารถปรับปรุงตัวแบบรู้จำกิจกรรมได้โดยอัตโนมัติ กรอบแนวคิดที่นำเสนอนี้ได้ทดลองกับผู้ใช้หลายคนในสภาพการณ์จริง โดยใช้ข้อมูลสำหรับสอนและทดสอบจากข้อมูลกิจกรรม WISDM และ UniMiB-SHAR ผลจากการทดลองพบว่าวิธีการ ISAR และ ISAR+ สามารถให้ประสิทธิภาพที่ดีกว่าวิธีการ STAR ในสถานการณ์จริง โดยเฉพาะอย่างยิ่งกับข้อมูลสอนและทดสอบจากผู้ใช้ที่ต่างกันและไม่จำเป็นต้องสอบถามกิจกรรมที่แท้จริงจากผู้ใช้

58910104: MAJOR: INFORMATICS; M.Sc. (INFORMATICS)

KEYWORD: ACTIVITY RECOGNITION/SENSORS/SMARTPHONE/STREAMING DATA/
UNSUPERVISED

THERDSAK DUNGKAEW: ADAPTIVE ACTIVITY RECOGNITION SYSTEM USING THE ACCELEROMETER SENSORY DATA OF SMARTPHONE. THESIS ADVISSOR: JAKKARIN SUKSAWATCHON, Ph.D., UREERAT SUKSAWATCHON, Ph.D., 127 P. 2018.

The objective of the smartphone-based activity recognition is to analyze the continuous sensory data and identify the occurrence of the current activities with high accuracy. Therefore, how to be able recognize the human physical activities by analyzing acceleration data generated by a user's cell phone, is interesting issue for many researchers and developers. Most of the research papers in activities recognition with sensory data are personal classifier models. These models are trained and tested using the collected and annotated data of the same users. However, creating the personalized classifier models may interfere with the users because of spending times to collect activities data. Moreover, if the users cannot complete all activities or cannot complete over a specified period of time so the model can be incorrect recognition.

In order to overcome this problem, this thesis proposes the two new activities recognition frameworks for evolving sensory data. The first one is "impersonal smartphone-based activity recognition using the accelerometer sensory data" or "ISAR". The ISAR is an offline and online phase. In offline phase, we build classifier model from a set of annotated sensory data based on characteristics of activities and clustering approach. The online phase is recognition component which can proceed on-board the mobile phone for real-time data. The second proposed framework is "an improvement impersonal smartphone-based activity recognition using the accelerometer sensory data" or "ISAR+". Our main contributions in this work are: (1) we propose the new method for distinguishing the activities based on their characteristics. Our new method can be used for identifying the sensory data into two types of activities that are dormant and energetic activities from incoming unlabeled data. (2) The new classifier modeling and recognition component are introduced to deal with the overlapping data and to cut off any inquiry the users about true activities.

The proposed frameworks were trained and tested in an experiment with multiple human subjects in real-world conditions by using WISDM and UniMiB-SHAR datasets. From experimental results, ISAR and ISAR+ can perform dramatically better than STAR model in real situation, especially across different users and without inquiry users.

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
สารบัญ.....	ช
สารบัญตาราง.....	ฉ
สารบัญภาพ.....	ญ
บทที่	
1 บทนำ.....	1
1.1 ที่มาและความสำคัญปัญหาวิทยานิพนธ์.....	1
1.2 แนวทางแก้ไขปัญหา.....	5
1.3 วัตถุประสงค์ของวิทยานิพนธ์.....	9
1.4 ขอบเขตวิทยานิพนธ์.....	9
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	10
1.6 แผนดำเนินโครงการ.....	11
2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	12
2.1 ทฤษฎีที่เกี่ยวข้อง.....	12
2.2 งานวิจัยที่เกี่ยวข้อง.....	23
3 วิธีการที่นำเสนอ.....	35
3.1 การศึกษาและวิเคราะห์ข้อมูลสำหรับสร้างตัวแบบรู้จำกิจกรรม.....	35
3.2 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (ISAR).....	45
3.3 ขั้นตอนการพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรม (ISAR+).....	61
4 ผลการดำเนินงาน.....	76
4.1 ข้อมูลกิจกรรมที่ใช้ในการทดลอง.....	76
4.2 การออกแบบการทดลองและวิธีการที่ใช้วัดประสิทธิภาพตัวแบบรู้จำกิจกรรม.....	78
4.3 การวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรม.....	81
4.4 การวัดประสิทธิภาพด้านเวลาของการรู้จำกิจกรรม.....	86
5 สรุปผลการดำเนินงานและข้อเสนอแนะ.....	91
5.1 สรุปผลการดำเนินงาน.....	91
5.2 วิเคราะห์ผลการดำเนินงาน.....	93
บรรณานุกรม.....	95

สารบัญ (ต่อ)

	หน้า
ภาคผนวก.....	100
ภาคผนวก ก เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์	101
ภาคผนวก ข เอกสารเผยแพร่ผลงานวิจัย	103
ประวัติย่อของผู้วิจัย.....	113

สารบัญตาราง

ตารางที่	หน้า
1-1	แผนดำเนินโครงการ..... 11
2-1	ชนิดตัวรับรู้ของอุปกรณ์เคลื่อนที่แบบพกพา และรายละเอียดการใช้งาน..... 13
2-2	งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบสำหรับการรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จาก อุปกรณ์สมาร์ทโฟน..... 23
2-3	การประเมินระดับความเชื่อมั่นที่ได้จากมาตรวัดของวิธีการ STAR..... 34
3-1	เปรียบเทียบข้อมูลกิจกรรมการยืนตามลักษณะการสวมใส่อุปกรณ์ โดยใช้แผนภูมิเส้นข้อมูล Accelerometer..... 42
3-2	เปรียบเทียบข้อมูลกิจกรรมการนั่งตามลักษณะการสวมใส่อุปกรณ์ โดยใช้แผนภูมิเส้นข้อมูล Accelerometer..... 43
3-3	การจับคู่วิธีการ SD และวิธีการทางสถิติอื่น ๆ ในการรู้จำกิจกรรม โดยใช้ข้อมูล WISDM..... 70
4-1	จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ WISDM 77
4-2	จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ UniMiB-SHAR 78
4-3	Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ STAR กับข้อมูล WISDM..... 81
4-4	Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR กับข้อมูล WISDM..... 82
4-5	Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR+ กับข้อมูล WISDM 82
4-6	Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ STAR กับข้อมูล UniMiB-SHAR..... 84
4-7	Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR กับข้อมูล UniMiB-SHAR..... 84
4-8	Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR+ กับข้อมูล UniMiB-SHAR..... 84
4-9	ความซับซ้อนเชิงเวลาของวิธีการ ISAR, ISAR+ และ STAR 87

สารบัญภาพ

ภาพที่	หน้า
1-1	แผนภูมิกระจายของข้อมูลกิจกรรมการเดินและการขึ้นลงบันได 4
1-2	แผนภูมิกระจายของข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 27 และหมายเลข 36 ที่มีการวางอุปกรณ์ต่างกัน..... 5
1-3	กรอบแนวคิดวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)..... 7
1-4	กรอบแนวคิดวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)..... 8
2-1	ตัวรับรู้ชนิด Accelerometer sensor 13
2-2	วิธีการแบ่งกลุ่มข้อมูลแบบ K-mean, Spectral Clustering, DBSCAN และ Gaussian Mixture..... 16
2-3	ขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบรู้จำ 19
2-4	ขั้นตอนการทดสอบตัวแบบ 19
2-5	ขั้นตอนการนำตัวแบบไปใช้งานจริง..... 19
2-6	ขั้นตอนการรู้จำกิจกรรม..... 22
2-7	กรอบแนวคิดวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR)..... 28
2-8	ขั้นตอนการแบ่งกลุ่มข้อมูลแต่ละกิจกรรมออกเป็นกลุ่มย่อยตามจำนวนกลุ่มที่กำหนด..... 29
2-9	ขั้นตอนการรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาของวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR)..... 33
3-1	ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 27 จากข้อมูล WISDM..... 36
3-2	ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 13 จากข้อมูล UniMiB-SHAR..... 36
3-3	แผนภูมิกระจายของข้อมูลกิจกรรมการยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได 37
3-4	แผนภูมิกระจายของข้อมูลกิจกรรมการยืน ผู้ใช้หมายเลข 27 และ ผู้ใช้หมายเลข 36 จากข้อมูล WISDM..... 38
3-5	แผนภูมิกระจายของข้อมูลกิจกรรมการยืนที่ต่างสถานที่ของผู้ใช้ทั้งสองคน 41
3-6	แผนภูมิกระจายของข้อมูลการยืนที่มีลักษณะการสวมใส่อุปกรณ์ต่างกัน..... 41
3-7	แผนภูมิกระจายของข้อมูลการนั่งที่มีลักษณะการสวมใส่อุปกรณ์ต่างกัน 43
3-8	แผนภูมิกระจายของข้อมูลการเดินที่มีลักษณะการสวมใส่อุปกรณ์ต่างกัน 44

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
3-9 ภาพรวมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR).....	46
3-10 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบนั่ง.....	47
3-11 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบเคลื่อนไหว.....	47
3-12 ตัวอย่างค่า Magnitude (M_j) ของข้อมูลกิจกรรม.....	48
3-13 ตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมแบบเคลื่อนไหว (Energetic activities) และกิจกรรมแบบนั่ง (Dormant activities) ออกจากกันได้.....	50
3-14 แผนภูมิกระจายของข้อมูลกิจกรรม (ข้อมูลดิบ).....	52
3-15 แผนภูมิกระจายของข้อมูลกิจกรรม (ข้อมูลที่แปลงด้วยส่วนเบี่ยงเบนมาตรฐาน).....	52
3-16 ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR).....	53
3-17 ขั้นตอนออนไลน์ของวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR).....	55
3-18 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการนั่ง.....	56
3-19 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการยืน.....	56
3-20 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว.....	58
3-21 การระบุกิจกรรมโดยเปรียบเทียบระยะทางของ $SD_{j(ax)}$, $SD_{j(ay)}$, $SD_{j(az)}$ และ C_k^{act} ของแต่ละกลุ่มย่อยภายใน Classifier model (CM).....	58
3-22 ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR).....	59
3-23 กรอบแนวคิดวิธีการ An improvement of impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+).....	62
3-24 ตัวอย่างวิธีการ ISAR+ ที่มีการแบ่งกลุ่มข้อมูลแล้วไม่มีการแบ่งกลุ่มข้อมูล.....	63
3-25 ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+).....	68

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
3-26	ขั้นตอนการตรวจสอบการปรับปรุงตัวแบบรู้จำกิจกรรม 71
3-27	ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) 73
3-28	ขั้นตอนออนไลน์ การปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)..... 74
4-1	ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 27 จากข้อมูล WISDM..... 77
4-2	ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 13 จากข้อมูล UniMiB-SHAR 78
4-3	ตัวอย่างการแบ่งข้อมูลกิจกรรมสำหรับสร้างและทดสอบตัวแบบรู้จำกิจกรรมด้วยวิธี K-Fold Cross Validation 79
4-4	แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM.....82
4-5	แผนภูมิแท่งเปรียบเทียบ Recall ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM.....83
4-6	แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM.....83
4-7	แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR.....85
4-8	แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR.....85
4-9	แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR.....86
4-10	แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนสร้างตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล WISDM 88
4-11	แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนสร้างตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR 88
4-12	แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล WISDM..... 89

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4-13	แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR..... 90
5-1	แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล WISDM พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure..... 92
5-2	แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล UniMiB-SHAR พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure.....93

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญปัญหาวิทยานิพนธ์

ปัจจุบันมีเทคโนโลยีที่ทันสมัยเข้ามาอำนวยความสะดวก ให้กับการใช้ชีวิตของเรามากมาย และหนึ่งในเทคโนโลยีที่คนรักสุขภาพและการออกกำลังกายนิยมใช้ก็คือ แอปพลิเคชันแนะนำการออกกำลังกาย ซึ่งแอปพลิเคชันเหล่านี้ถูกพัฒนาขึ้นบนอุปกรณ์สื่อสารเคลื่อนที่ ได้แก่ สมาร์ทโฟน นาฬิกาอัจฉริยะ เป็นต้น ฟังก์ชันการทำงานของแต่ละแอปพลิเคชัน มีหลากหลายแล้วแต่จะเลือกใช้งาน ไม่ว่าจะเป็นการคำนวณแคลอรีการทำกิจกรรม การคำนวณระยะทางการทำกิจกรรม การจับเวลาการทำกิจกรรม เป็นต้น ถือเป็นเรื่องน่าประหลาดใจอย่างมาก ว่าทำไมแอปพลิเคชันเหล่านี้ถึงได้รู้ว่าคุณ ขณะนั้น ผู้ใช้กำลังทำกิจกรรมอะไรอยู่ ซึ่งสิ่งที่ทำให้แอปพลิเคชันรู้ว่าผู้ใช้กำลังทำกิจกรรมอะไรอยู่ ก็คือการวิเคราะห์ข้อมูลจากตัวรับรู้ (Sensors) ของอุปกรณ์สื่อสารเคลื่อนที่ เช่น Accelerometer sensor, Gyroscope sensor เป็นต้น โดยอาศัยศาสตร์ “การรู้จำกิจกรรม” (Activity recognition) การรู้จำกิจกรรม เป็นศาสตร์ทางวิทยาการคอมพิวเตอร์แขนงหนึ่ง ที่มีวัตถุประสงค์เพื่อสร้างตัวแบบสำหรับการจำแนก (Classifier model) หรือระบุประเภทการทำกิจกรรมของคนเรา ไม่ว่าจะเป็น การยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได เป็นต้น โดยใช้ข้อมูลที่ได้จากตัวรับรู้ของอุปกรณ์สื่อสารเคลื่อนที่ ซึ่งตัวรับรู้เหล่านี้จะผลิตกระแสข้อมูลเชิงเวลา (Temporal streaming data) อย่างต่อเนื่องด้วยอัตราการสุ่มตัวอย่างที่กำหนดไว้ และกระแสข้อมูลที่ได้จากตัวรับรู้จะถูกนำมาใช้ในการสร้างตัวแบบผ่านขั้นตอนการเรียนรู้ (Learning algorithm) จนกระทั่งได้ตัวแบบรู้จำกิจกรรมที่สามารถนำมาใช้วิเคราะห์ได้ว่า ผู้ใช้ทำกิจกรรมอะไรบ้างในแต่ละวัน

ในปัจจุบันมีหลายงานวิจัยที่เกี่ยวกับการพัฒนาขั้นตอนวิธีการรู้จำกิจกรรม ให้สามารถระบุประเภทของการทำกิจกรรมต่าง ๆ ได้แม่นยำมากยิ่งขึ้น ซึ่งการสร้างตัวแบบรู้จำกิจกรรม สามารถสร้างตัวแบบได้เป็นสองลักษณะ ขึ้นอยู่กับลักษณะข้อมูลที่ใช้สร้างตัวแบบ (Lockhart และ Weiss, 2014) ได้แก่

- 1) ตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model) เป็นตัวแบบเฉพาะบุคคลที่ถูกพัฒนาเพื่อแยกแยะ หรือระบุกิจกรรมที่ทำในแต่ละวันของคนคนนั้น การสร้างตัวแบบเฉพาะบุคคลนี้จะต้องให้ผู้ที่ใช้งานตัวแบบเป็นคนเตรียมข้อมูลของการทำกิจกรรมต่าง ๆ ผ่านทางแอปพลิเคชัน เช่น ให้ผู้ใช้ทำกิจกรรมการเดิน การยืน การนั่ง การวิ่ง และการขึ้นลงบันได โดยทำกิจกรรมละ 5 นาที เป็นต้น เพื่อให้ได้ข้อมูลการทำกิจกรรม และใช้เป็นข้อมูลสำหรับสร้างตัวแบบในขั้นตอนการเรียนรู้ และทดสอบตัวแบบของผู้ใช้เฉพาะบุคคล ตัวอย่างงานวิจัยที่เน้นสร้างตัวแบบรู้จำกิจกรรมเฉพาะ

บุคคล ได้แก่ งานวิจัยของ Gomes และคณะ (2012) ได้พัฒนาวิธีการที่ชื่อว่า “MARS” ย่อมาจาก “Mobile Activity Recognition System” โดยวิธีการ MARS สามารถรู้จำกิจกรรมจากข้อมูลกระแสที่ได้จาก Accelerometer sensor ของสมาร์ทโฟน ซึ่งวิธีการ MARS มีขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบ (Training phase) โดยให้ผู้ใช้แสดงท่าทางกิจกรรมต่าง ๆ กิจกรรมละ 30 วินาที เพื่อเก็บข้อมูลการทำกิจกรรมของผู้ใช้ จากนั้นจะใช้วิธี Naive Bayes ในการสร้างตัวแบบรู้จำกิจกรรม ต่อมางานวิจัยของ Lockhart และ Weiss (2014) ได้นำเสนอวิธีการที่ชื่อว่า “Actitracker” โดยวิธีการนี้จะมีขั้นตอนที่เรียกว่า Training mode เช่นเดียวกับกับ MARS เพื่อเก็บรวบรวมข้อมูลการทำกิจกรรมของผู้ใช้ที่ได้จาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน โดยให้ผู้ใช้ทำท่าทางกิจกรรมต่าง ๆ กิจกรรมละประมาณ 2-3 นาที จากนั้นข้อมูลการทำกิจกรรมของผู้ใช้จะถูกส่งไปที่เครื่องแม่ข่าย แล้วจึงใช้วิธี Random Forest ในการสร้างตัวแบบรู้จำกิจกรรม งานวิจัยของ Uddin และคณะ (2016) นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมโดยมีการพิจารณารูปแบบการเปลี่ยนกิจกรรม เช่น จากยืนไปนั่ง จากนั่งไปนอน จากนอนไปยืน เป็นต้น ซึ่งจะเก็บข้อมูล Accelerometer และ Gyroscope ที่ได้จากอุปกรณ์สมาร์ทโฟนของผู้ใช้ขณะทำกิจกรรม รวมถึงการเปลี่ยนกิจกรรมในรูปแบบต่าง ๆ จากนั้นจะนำข้อมูลไปสร้างตัวแบบด้วยวิธีการ Random Forest งานวิจัยของ Lee และคณะ (2017) นำเสนอวิธีการที่ชื่อว่า “One Dimensional Convolutional Neural Network” เรียกโดยย่อว่า “1D-CNN” มุ่งเน้นการรู้จำกิจกรรม 3 กิจกรรมได้แก่ การเดิน การวิ่ง และการหยุดนิ่ง (Staying still) โดยวิธีการ 1D-CNN จะเก็บข้อมูลการทำกิจกรรมของผู้ใช้ ซึ่งได้ทำการติดตั้งอุปกรณ์ไว้หลายตำแหน่ง ได้แก่ กระเป๋ากางเกง กระเป๋าสะพาย และการใช้มือถืออุปกรณ์ เป็นต้น ระยะเวลาการทำกิจกรรมแต่ละกิจกรรมประมาณ 10 นาที จากนั้นจะแปลงข้อมูล Accelerometer ให้เป็นข้อมูล Magnitude แล้วนำไปสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการ Convolutional Neural Network (CNN)

จากงานวิจัยที่กล่าวมาข้างต้น ถึงแม้จะได้ตัวแบบรู้จำกิจกรรมเฉพาะของคนคนนั้นก็ตาม แต่การสร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคลยังมีข้อจำกัดที่สำคัญ คือ แต่ละวิธีการจำเป็นต้องให้ผู้ใช้ทำกิจกรรมเพื่อเก็บข้อมูลเฉพาะบุคคลสำหรับสร้างตัวแบบรู้จำกิจกรรม ซึ่งถ้าผู้ใช้ทำกิจกรรมไม่ครบหรือไม่ตรงตามเวลาที่กำหนด ก็จะไม่สามารสร้างตัวแบบรู้จำกิจกรรมได้ หรือได้ตัวแบบรู้จำกิจกรรมที่ไม่สมบูรณ์ นอกจากนั้นถ้าผู้ใช้ทำท่าทางกิจกรรมต่าง ๆ ตั้งใจมากเกินไปจนเกร็งหรือไม่เป็นธรรมชาติตามลักษณะการทำกิจกรรมของผู้ใช้เอง ก็จะได้ข้อมูลที่ใช้สร้างตัวแบบรู้จำกิจกรรมที่อาจไม่เหมือนกับข้อมูลการทำกิจกรรมเมื่อใช้งานจริง ทำให้ตัวแบบรู้จำกิจกรรมที่ได้มีความผิดพลาดในการรู้จำกิจกรรม

2) ตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model) เป็นตัวแบบรู้จำกิจกรรมที่สร้างมาจากข้อมูลการทำกิจกรรมของผู้ใช้คนใดก็ได้ไม่เฉพาะเจาะจง ดังนั้นผู้ที่ใช้งานตัวแบบจึงไม่

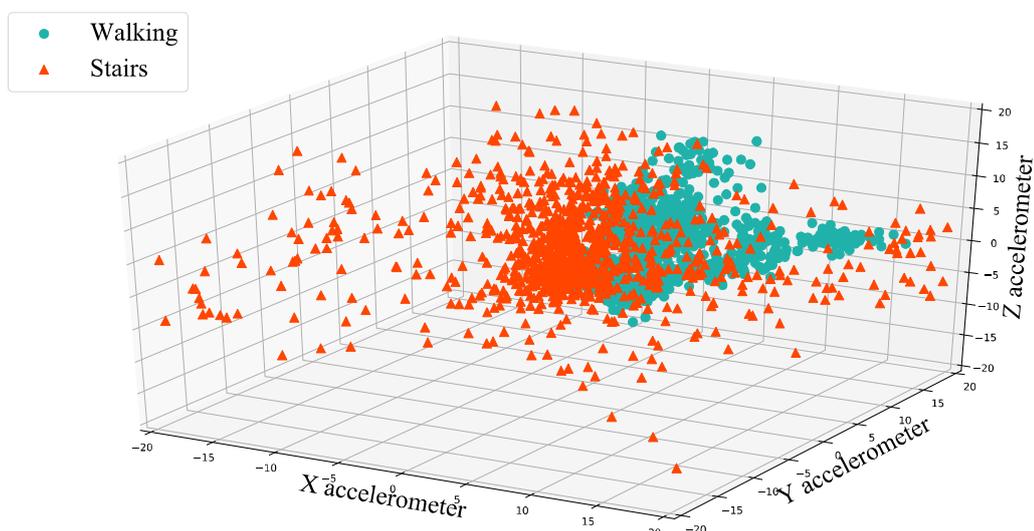
จำเป็นต้องเก็บข้อมูลการทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนดด้วยตัวเอง เหมือนอย่างตัวแบบรู้จำกิจกรรมเฉพาะบุคคล ซึ่งสอดคล้องกับงานวิจัยของ Abdallah และคณะ (2015) ได้นำเสนอวิธีการที่ชื่อว่า “STAR” ย่อมาจาก “Stream learning for mobile Activity Recognition” ที่สามารถรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาที่ได้จากข้อมูลจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน วิธีการ STAR มีกระบวนการทำงานสองส่วน ได้แก่ 1) ขั้นตอนเตรียมตัวแบบรู้จำกิจกรรม (Offline modeling phase) สำหรับสร้างตัวแบบรู้จำกิจกรรม โดยนำข้อมูลการทำกิจกรรมในแต่ละกิจกรรม แบ่งเป็นกลุ่มย่อย (Clustering) ตามจำนวนกลุ่มที่กำหนด แล้วเก็บข้อมูลสรุป (Statistics summary) ของแต่ละกลุ่ม ได้แก่ จำนวนของข้อมูลในแต่ละกลุ่ม ค่าศูนย์กลางของข้อมูล ส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่นของข้อมูล และค่ารัศมีของข้อมูล เป็นต้น ซึ่งในแต่ละกลุ่มย่อย จะเก็บข้อมูลสรุปทั้งสิ้น 6 ค่า 2) ขั้นตอนการรู้จำกิจกรรมและปรับปรุงตัวแบบรู้จำกิจกรรม (Online recognition และ adaption phase) เป็นขั้นตอนที่นำตัวแบบจากขั้นตอนสร้างตัวแบบรู้จำกิจกรรมมาใช้งานจริง โดยข้อมูลที่ส่งมาอย่างต่อเนื่องจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน จะถูกแบ่งออกเป็นหน้าต่าง (window) ซึ่งข้อมูลในแต่ละหน้าต่างจะถูกแบ่งเป็นสองกลุ่ม แต่ละกลุ่มจะถูกวัดด้วย 4 มาตรฐาน ได้แก่ Distance, Gravity, Density และ Deviation ซึ่งถ้ามาตรฐานทั้ง 4 มาตรฐานวัดหรือ 3 ใน 4 มาตรฐานระบุเป็นกิจกรรมเดียวกัน ตัวแบบรู้จำกิจกรรมก็จะทำนายว่าผู้ใช้กำลังทำกิจกรรมนั้น ถ้ามาตรฐาน 2 ใน 4 ระบุเป็นกิจกรรมเดียวกันโดยที่อีก 2 มาตรฐานระบุกิจกรรมต่างกัน ตัวแบบรู้จำกิจกรรมจะทำนายว่าเป็นกิจกรรมที่มาตรฐาน 2 ตัวระบุตรงกันและปรับปรุงตัวแบบรู้จำกิจกรรมด้วยวิธี Incremental learning แต่ถ้ามาตรฐาน 2 ใน 4 ระบุเป็นกิจกรรมเดียวกันและมาตรฐานวัดอีก 2 ตัวที่เหลือก็ระบุว่าเป็นกิจกรรมเดียวกันแต่คนละกิจกรรมกับมาตรฐาน 2 ตัวแรก หรือทั้ง 4 มาตรฐานระบุกิจกรรมไม่เหมือนกันเลย จะใช้วิธี Active learning เพื่อให้ผู้ใช้ระบุกิจกรรมที่กำลังทำ จากนั้นจึงปรับค่าข้อมูลสรุปของกลุ่มย่อยกิจกรรมที่ผู้ใช้ระบุกับข้อมูลใหม่ที่เข้ามา

อย่างไรก็ตาม แม้ว่าวิธีการ STAR จะเป็นตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล ที่สามารถรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลา และสามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับกับผู้ใช้แต่ละคนได้ แต่วิธีการ STAR ยังมีข้อจำกัดดังนี้

- เนื่องจากการขึ้นลงบันได จัดว่าเป็นการเดินในอีกรูปแบบหนึ่ง จึงมีผลทำให้วิธีการ STAR ยังให้ค่าความถูกต้องที่ค่อนข้างต่ำในการรู้จำกิจกรรมที่มีความคล้ายกัน โดยมีความถูกต้องของการรู้จำกิจกรรมการขึ้นลงบันไดเพียง 49.2%² เท่านั้น และเมื่อนำข้อมูลของกิจกรรมการขึ้นลงบันได

² อ้างอิงจากผลการทดลองของงานวิจัย Adaptive mobile activity recognition system with evolving data streams โดยใช้ข้อมูลกิจกรรมจากฐานข้อมูล WISDM

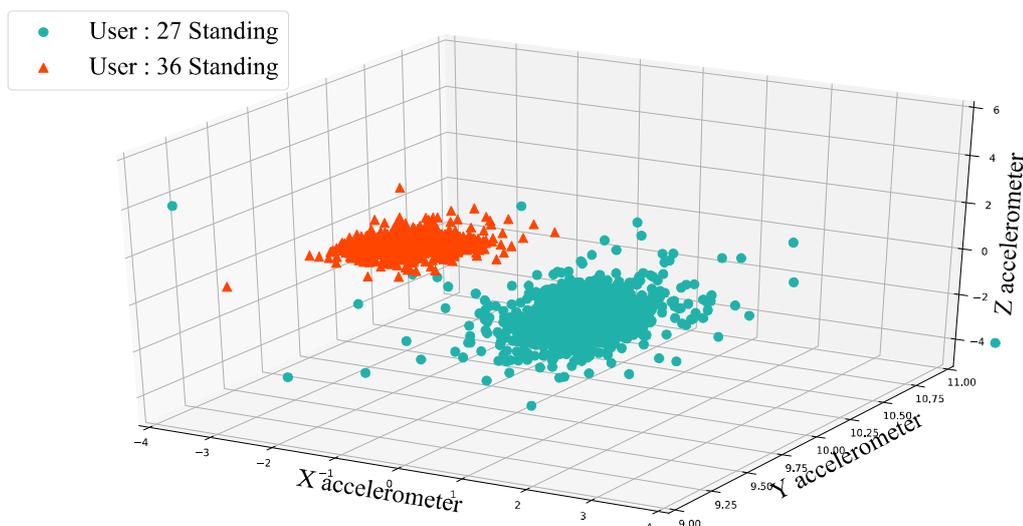
และการเดินมาสร้างเป็นแผนภูมิกระจาย ดังภาพที่ 1-1 จะเห็นว่าข้อมูลทั้ง 2 กิจกรรมมีความซ้อนทับกัน (Overlapping data) ทำให้การรู้จำ 2 กิจกรรมนี้ มีความผิดพลาดเกิดขึ้นได้



ภาพที่ 1-1 แผนภูมิกระจายของข้อมูลกิจกรรมการเดินและการขึ้นลงบันได

- เนื่องจากวิธีการ STAR เป็นการรู้จำกิจกรรมไม่เฉพาะบุคคล จึงอาจมีกรณีที่มีข้อมูลการทำกิจกรรมของผู้ใช้ตัวแบบรู้จำกิจกรรม แตกต่างจากข้อมูลการทำกิจกรรมที่ใช้สร้างตัวแบบรู้จำกิจกรรม ดังภาพที่ 1-2 แสดงแผนภูมิกระจายของข้อมูลการเดินของผู้ใช้หมายเลข 27 และ 36 จะเห็นได้ว่ามีลักษณะที่แตกต่างกัน ทั้งนี้อาจเนื่องจากลักษณะการวางอุปกรณ์ที่ต่างกัน ดังนั้นถ้านำข้อมูลกิจกรรมของผู้ใช้หมายเลข 27 มาสร้างตัวแบบรู้จำกิจกรรมและให้ผู้ใช้หมายเลข 36 เป็นคนใช้ตัวแบบรู้จำกิจกรรม วิธีการ STAR จะไม่สามารถระบุกิจกรรมของผู้ใช้ได้ถูกต้อง จึงเป็นเหตุให้เกิดการทำ Active learning ที่ต้องให้ผู้ใช้ระบุกิจกรรมที่กำลังทำ ณ ขณะนั้น แล้วจึงปรับปรุงตัวแบบรู้จำกิจกรรม แต่ถ้าผู้ใช้ไม่ได้ระบุกิจกรรมที่ทำทันที วิธีการ STAR ก็จะไม่สามารถปรับปรุงตัวแบบรู้จำกิจกรรม ทำให้เกิดความผิดพลาดในการรู้จำกิจกรรมได้

- การใช้วิธีจำแนกกิจกรรมโดยใช้มาตรวัดหลายตัว ได้แก่ Distance, Gravity, Density และ Deviation ซึ่งมาตรวัดบางตัวอาจทำให้ความถูกต้องของการรู้จำกิจกรรมคลาดเคลื่อนได้ ตัวอย่างเช่น มาตรวัด Gravity โดยมีหลักการคือ ระบุกิจกรรมด้วยการใช้แรงดึงดูด ซึ่งแรงดึงดูดขึ้นอยู่กับจำนวนข้อมูลในกลุ่มย่อยของกิจกรรม ยิ่งข้อมูลในกลุ่มมีมากก็จะมีแรงดึงดูดกลุ่มข้อมูลที่เล็กกว่ามากขึ้นเท่านั้น ดังนั้นถ้ากลุ่มย่อยของกิจกรรมใดมีขนาดใหญ่ที่สุด มาตรวัด Gravity ก็จะระบุเป็นกิจกรรมนั้น แต่กิจกรรมที่ถูกต้องอาจมีกลุ่มย่อยขนาดเล็ก จึงเกิดความผิดพลาดในการรู้จำกิจกรรมขึ้นได้



ภาพที่ 1-2 แผนภูมิกระจายข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 27 และหมายเลข 36 ที่มีการวางอุปกรณ์ต่างกัน

1.2 แนวทางแก้ไขปัญหา

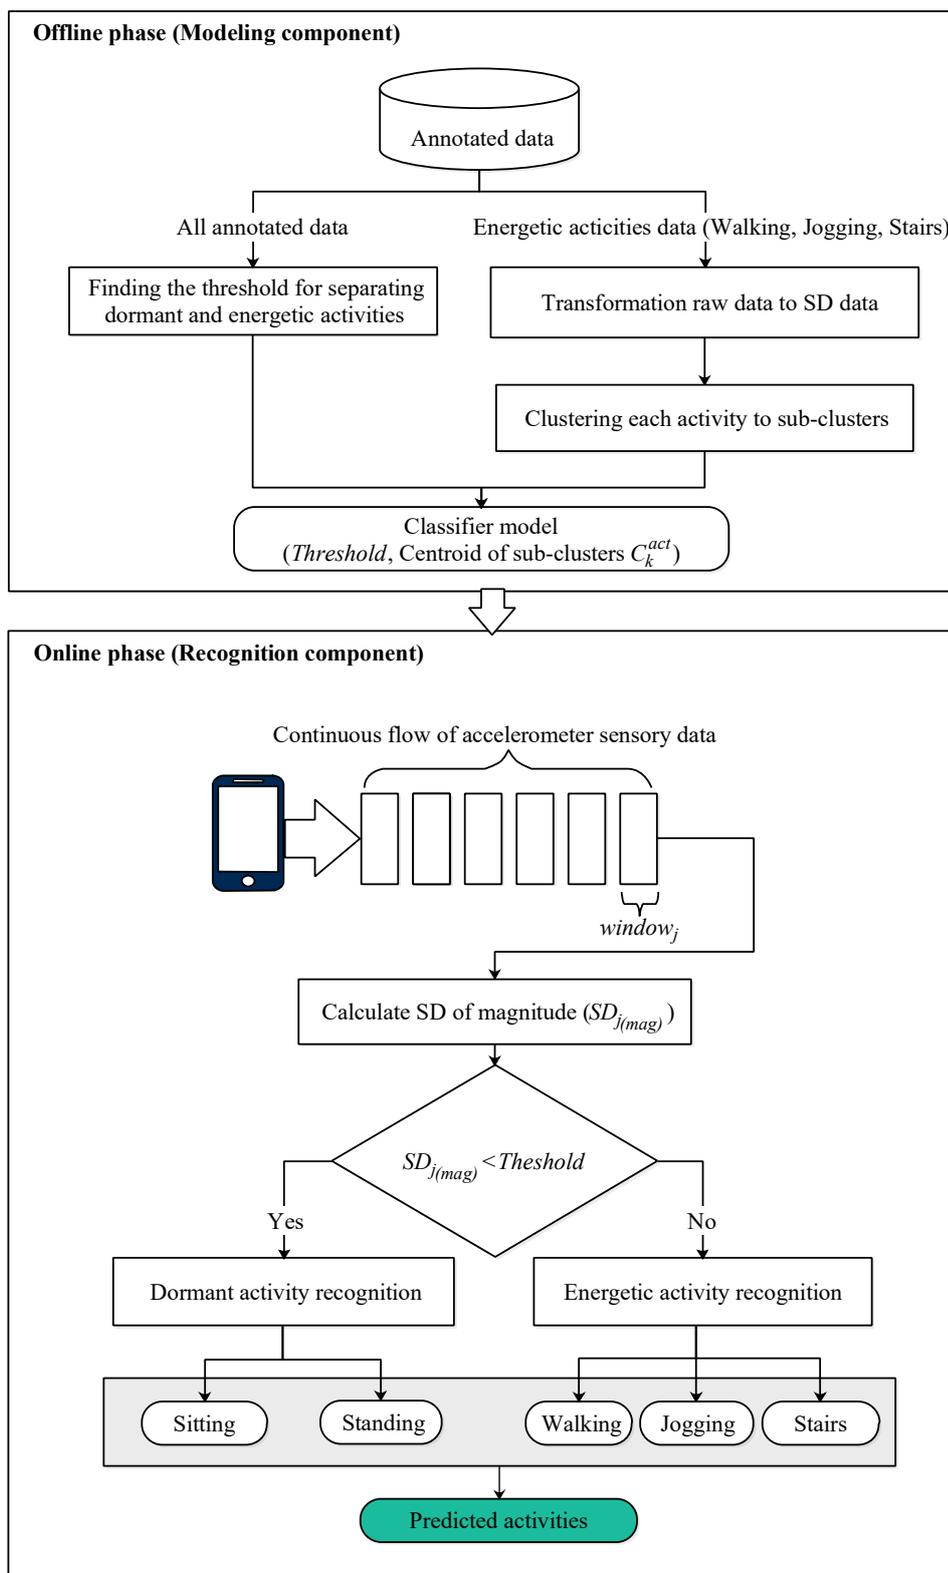
จากข้อจำกัดของวิธีการ STAR ที่กล่าวมาข้างต้น วิทยานิพนธ์นี้จึงได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรม 2 วิธี เพื่อเพิ่มประสิทธิภาพทั้งความถูกต้องและเวลา และสามารถปรับตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลโดยอัตโนมัติ โดยนำเสนอวิธีการที่เรียกว่า “Impersonal smartphone-based activity recognition using the accelerometer sensory data” หรือเรียกว่า “ISAR” และวิธีการ “An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data” หรือเรียกว่า “ISAR+” โดยวิธีการ ISAR มีกรอบแนวคิดด้วยกันสองส่วน ได้แก่ ขั้นตอนออฟไลน์ (Offline phase) สำหรับสร้างตัวแบบรู้จำกิจกรรม และขั้นตอนออนไลน์ (Online phase) สำหรับรู้จำกิจกรรมและปรับปรุงตัวแบบรู้จำกิจกรรม ดังภาพที่ 1-3 ซึ่งมีรายละเอียดดังนี้

- **ขั้นตอนออฟไลน์** เป็นขั้นตอนสำหรับสร้างตัวแบบรู้จำกิจกรรม โดยใช้ข้อมูลการทำกิจกรรมของผู้ใช้คนใดก็ได้ ในส่วนนี้จะประกอบไปด้วย ขั้นตอนการหาค่าขีดแบ่ง (Threshold) สำหรับแบ่งประเภทของกิจกรรมเป็นสองประเภท ได้แก่ กิจกรรมแบบนิ่งและกิจกรรมแบบเคลื่อนไหว ขั้นตอนต่อมาคือการแปลงข้อมูลกิจกรรม ให้เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) โดยใช้เฉพาะข้อมูลกิจกรรมแบบเคลื่อนไหว จากนั้นจะแบ่งกลุ่มข้อมูลส่วนเบี่ยงเบนมาตรฐานแต่ละกิจกรรมออกเป็นกลุ่มย่อย แล้วเก็บข้อมูลสรุป ได้แก่ ค่าขีดแบ่ง และค่าศูนย์กลางของแต่ละกลุ่มย่อย

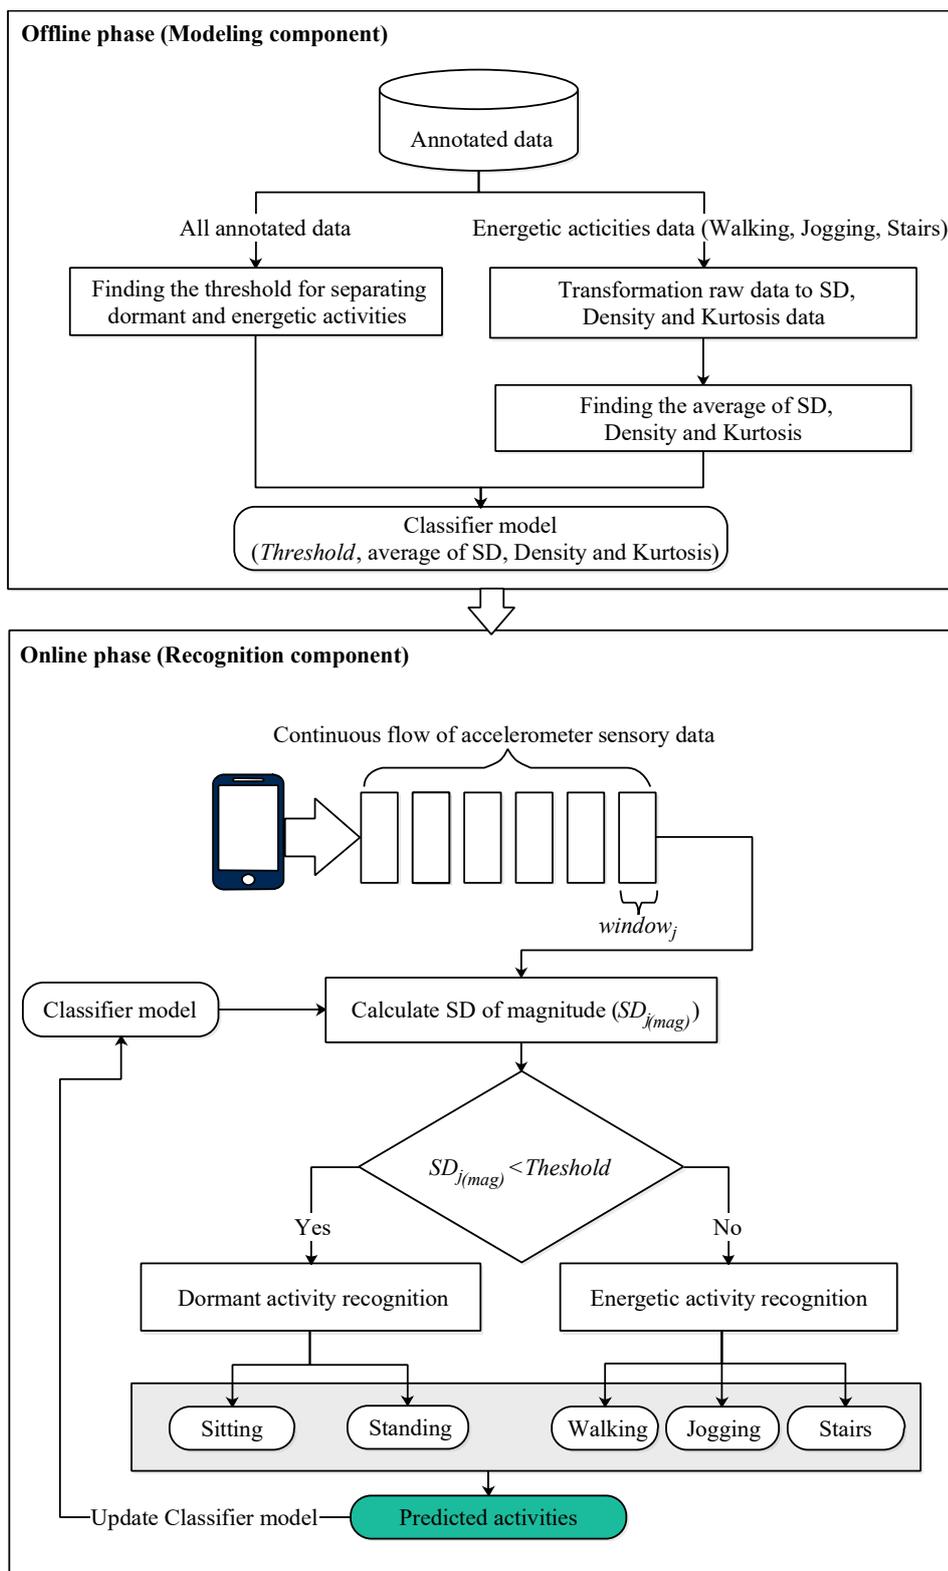
- **ขั้นตอนออนไลน์** เป็นขั้นตอนสำหรับรู้จำกิจกรรมกับข้อมูลกระแสวิ่งเวลา และปรับปรุงตัวแบบรู้จำกิจกรรม โดยข้อมูลต่อเนื่องจาก Accelerometer sensor ของสมาร์ทโฟนจะถูกแบ่งออกเป็นหน้าต่าง (window) และนำข้อมูลแต่ละหน้าต่างมาคำนวณค่าส่วนเบี่ยงเบนมาตรฐานของ Magnitude ข้อมูล เพื่อใช้เปรียบเทียบกับค่าขีดแบ่ง สำหรับจำแนกประเภทของกิจกรรม ถ้าเป็นกิจกรรมแบบนิ่งจะใช้วิธีการเปรียบเทียบระยะห่างระหว่างเส้นข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ในการระบุว่าเป็นกิจกรรม การยืนหรือการนั่ง แต่ถ้าเป็นกิจกรรมแบบเคลื่อนไหว จะใช้วิธีการคำนวณค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer จากนั้นจะนำไปเปรียบเทียบกับค่าศูนย์กลางแต่ละกลุ่มย่อยที่ได้จากขั้นตอนออฟไลน์ เพื่อระบุว่าเป็นกิจกรรม การเดิน การวิ่ง หรือการขึ้นลงบันได

สำหรับวิธีการ ISAR+ เป็นวิธีการที่พัฒนาต่อยอดมาจากวิธีการ ISAR เพื่อให้สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้ มีกรอบแนวคิดดังภาพที่ 1-4 โดยวิธีการ ISAR ได้เพิ่มมาตรวัดสำหรับการปรับปรุงตัวแบบรู้จำกิจกรรม ได้แก่ มาตรวัดส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความหนาแน่น (Density) และความโด่ง (Kurtosis) โดยขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมจะเก็บข้อมูลสรุป ได้แก่ ขีดแบ่งกับค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่นและความโด่งของแต่ละกิจกรรม ซึ่งไม่จำเป็นต้องแบ่งกลุ่มข้อมูลก่อน ทำให้สามารถลดเวลาและขั้นตอนการคำนวณลงได้

จากขั้นตอนที่ได้กล่าวมาทำให้วิธีการ ISAR และ ISAR+ มีประสิทธิภาพการรู้จำกิจกรรมที่เหนือกว่า STAR ทั้งด้านเวลาและความถูกต้อง เนื่องจากวิธีการ ISAR และ ISAR+ มีการแบ่งกลุ่มลักษณะกิจกรรมเป็นสองประเภท จึงช่วยลดเวลาในการคำนวณลงได้ครึ่งหนึ่ง และยังใช้วิธีแปลงข้อมูลกิจกรรมด้วยส่วนเบี่ยงเบนมาตรฐาน จึงช่วยลดการซ้อนทับของข้อมูลกิจกรรม ทำให้สามารถจำแนกข้อมูลได้ง่ายขึ้น ส่งผลให้ความถูกต้องของการรู้จำกิจกรรมสูงขึ้น ยิ่งไปกว่านั้นวิธีการ ISAR+ ยังมีเกณฑ์สำหรับการปรับปรุงตัวแบบรู้จำกิจกรรม ทำให้สามารถปรับปรุงตัวแบบรู้จำกิจกรรมได้โดยอัตโนมัติ ไม่จำเป็นต้องให้ผู้ใช้คอยระบุกิจกรรมอยู่ตลอดเวลาเหมือนวิธีการ STAR และยิ่งเหมาะสมสำหรับการรู้จำกิจกรรมที่ประมวลผลบนอุปกรณ์



ภาพที่ 1-3 กรอบแนวคิดวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)



ภาพที่ 1-4 กรอบแนวคิดวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)

1.3 วัตถุประสงค์ของวิทยานิพนธ์

1.3.1 เพื่อศึกษาและวิเคราะห์ปัญหาที่เกิดขึ้นในการรู้จำกิจกรรมโดยใช้ข้อมูลจากตัวรับรู้ของสมาร์ตโฟน

1.3.2 เพื่อพัฒนาวิธีการสร้างตัวแบบรู้จำกิจกรรมที่สามารถปรับตัวแบบให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้

1.3.3 เพื่อพัฒนาตัวแบบรู้จำกิจกรรมให้มีประสิทธิภาพทั้งด้านเวลาและความถูกต้องในการรู้จำกิจกรรม

1.4 ขอบเขตวิทยานิพนธ์

1.4.1 วิทยานิพนธ์นี้มุ่งเน้นที่จะศึกษาและพัฒนาขั้นตอนวิธีการเพื่อสร้างตัวแบบการรู้จำกิจกรรมของผู้ใช้อุปกรณ์เคลื่อนที่แบบพกพา โดยใช้กระแสข้อมูลจาก Accelerometer sensor ของอุปกรณ์สมาร์ตโฟน

1.4.2 วิทยานิพนธ์นี้มุ่งเน้นการรู้จำกิจกรรมในกลุ่มกิจกรรมทางกายภาพ ซึ่งเป็นกิจกรรมพื้นฐานของมนุษย์ ดังต่อไปนี้

- การเดิน (Walking)
- การยืน (Standing)
- การนั่ง (Sitting)
- การวิ่ง (Jogging)
- การขึ้นลงบันได (Stairs)

1.4.3 ข้อมูลที่ใช้ในการทดลองจะใช้ข้อมูลการทำกิจกรรมจากฐานข้อมูล WISDM และฐานข้อมูล UniMiB-SHAR ซึ่งเป็นฐานข้อมูลสาธารณะ โดยมีรายละเอียดดังนี้

- ข้อมูล WISDM³ ประกอบด้วย รหัสผู้ใช้ กิจกรรมที่ทดสอบ เวลาในการบันทึกกิจกรรม ค่า Accelerometer แนวแกน X แนวแกน Y และแนวแกน Z ตามลำดับ ซึ่งเก็บข้อมูลการทำกิจกรรมของผู้ใช้ทั้งหมด 5 กิจกรรม ได้แก่ การยืน การเดิน การวิ่ง การนั่งและการขึ้นลงบันได โดยเลือกข้อมูลของผู้ใช้ 19 คนจาก 36 คน ซึ่งเป็นผู้ใช้ที่มีการทำกิจกรรมครบทุกกิจกรรม มีจำนวนตัวอย่างรวมกันทั้งหมด 618,820 ตัวอย่าง

³ <http://www.cis.fordham.edu/wisdm>

- ข้อมูล UniMiB-SHAR⁴ ประกอบด้วย รหัสผู้ใช้ กิจกรรมที่ผู้ใช้ทดสอบ ค่า Accelerometer แนวแกน X แนวแกน Y และแนวแกน Z ตามลำดับ ซึ่งเก็บข้อมูลการทำกิจกรรมของผู้ใช้ทั้งหมด 5 กิจกรรม ได้แก่ การยืน การเดิน การวิ่ง การนั่งและการขึ้นลงบันได โดยเลือกข้อมูลของผู้ใช้จำนวน 23 คนจาก 30 คน ซึ่งเป็นผู้ใช้ที่มีการทำกิจกรรมครบทุกกิจกรรม มีจำนวนตัวอย่างรวมกันทั้งหมด 1,848,500 ตัวอย่าง

1.4.4 การทดลองและการประเมินผลในวิทยานิพนธ์ได้เปรียบเทียบวิธีการที่นำเสนอ ISAR+, ISAR และ STAR โดยการเลือกข้อมูลสำหรับสอนและทดสอบด้วยวิธี K-Fold Cross-validation คือการใช้ข้อมูลของผู้ใช้หนึ่งคนสำหรับทดสอบตัวแบบรู้จำกิจกรรม และข้อมูลของผู้ใช้คนที่เหลือสำหรับสอนตัวแบบรู้จำกิจกรรม จากนั้นเปลี่ยนข้อมูลสำหรับทดสอบเป็นของผู้ใช้คนถัดไป และข้อมูลของผู้ใช้คนที่เหลือเป็นข้อมูลสำหรับสอน ทำซ้ำจนกว่าจะครบทุกคนแล้วนำผลลัพธ์มาเฉลี่ยกัน โดยวิทยานิพนธ์นี้ใช้วิธีวัดประสิทธิภาพความถูกต้องคือ Precision, Recall และ F-measure รวมทั้งทดสอบประสิทธิภาพเชิงเวลาในขั้นตอนสร้างตัวแบบรู้จำกิจกรรม ขั้นตอนรู้จำกิจกรรม และขั้นตอนปรับปรุงตัวแบบรู้จำกิจกรรม

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 เข้าใจปัญหาของการรู้จำกิจกรรมโดยใช้ข้อมูลจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน

1.5.2 ได้วิธีการสร้างตัวแบบรู้จำกิจกรรมที่สามารถปรับตัวให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้

1.5.3 ได้ตัวแบบรู้จำกิจกรรมที่มีประสิทธิภาพทั้งในด้านเวลาและความถูกต้องของการรู้จำกิจกรรม

⁴ <http://www.sal.disco.unimib.it/technologies/unimib-shar>

1.6 แผนดำเนินงาน

ตารางที่ 1-1 แผนดำเนินงาน

กิจกรรม	ปี พ.ศ.	เดือน													
		ม.ค.-มี.ค.			เม.ย.-มิ.ย.			ก.ค.-ก.ย.			ต.ค.-ธ.ค.				
1. ศึกษาปัญหาทางวิจัย - ศึกษาทฤษฎีที่เกี่ยวข้อง - ศึกษางานวิจัยที่เกี่ยวข้อง - เขียนโปรแกรมจากงานวิจัยที่เกี่ยวข้อง	2558												x	x	x
	2559	x	x	x	x	x	x	x	x	x	x	x	x	x	x
	2560	x	x	x	x	x									
2. รวบรวมข้อมูลจากฐานข้อมูล เก็บข้อมูลการทำกิจกรรมและวิเคราะห์ข้อมูลข้อมูลกิจกรรม	2559	x	x	x	x	x									
3. ออกแบบและเขียนโปรแกรมวิธีการที่นำเสนอในงานวิทยานิพนธ์ (ISAR)	2559	x	x	x	x	x	x	x	x	x	x	x	x	x	x
	2560	x	x	x	x	x	x	x							
4. สอบเค้าโครงวิทยานิพนธ์	2560	x													
5. เขียนบทความวิจัยเพื่อเสนอในงานประชุมวิชาการ	2560											x	x	x	
6. ปรับปรุงวิธีการที่นำเสนอให้สมบูรณ์และมีประสิทธิภาพ (ISAR+)	2560														x
7. ทดสอบและประเมินความถูกต้องของวิธีการที่นำเสนอ	2560														x
	2561	x													
8. เขียนวิทยานิพนธ์ฉบับสมบูรณ์	2561	x	x	x	x	x	x	x	x						
9. สอบปกป้องวิทยานิพนธ์	2561									x					

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้องที่นำมาใช้ในการพัฒนาขั้นตอนวิธีที่นำเสนอในวิทยานิพนธ์นี้ โดยจะแบ่งเป็นส่วนต่าง ๆ ดังนี้

2.1 ทฤษฎีที่เกี่ยวข้อง ประกอบด้วย

2.1.1 ตัวรับรู้ของอุปกรณ์สื่อสารเคลื่อนที่สมาร์ทโฟน

2.1.2 ทฤษฎีการรู้จำ

2.1.3 การคำนวณทางสถิติสำหรับวิเคราะห์ข้อมูล

2.1.4 การรู้จำกิจกรรม

2.2 งานวิจัยที่เกี่ยวข้อง ประกอบด้วย

2.2.1 ตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model)

2.2.2 ตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model)

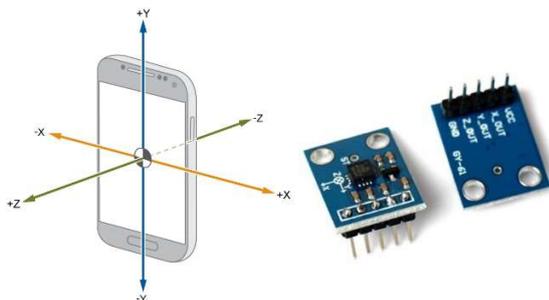
2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 ตัวรับรู้ของอุปกรณ์สื่อสารเคลื่อนที่สมาร์ทโฟน

งานวิทยานิพนธ์นี้มุ่งเน้นจะใช้กระแสข้อมูลจากตัวรับรู้ของอุปกรณ์สมาร์ทโฟน ซึ่งในการนำไปประยุกต์ใช้งานจะได้สะดวก เนื่องจากสมาร์ทโฟนเป็นที่นิยมอย่างแพร่หลายในปัจจุบัน โดยตัวรับรู้ที่เลือกใช้ในวิทยานิพนธ์นี้ คือ Accelerometer sensor ซึ่งมีรายละเอียดดังต่อไปนี้

- **Accelerometer sensor** เป็นตัวรับรู้ที่สามารถตรวจจับการเคลื่อนไหวของอุปกรณ์สมาร์ทโฟนได้ โดย Accelerometer sensor จะวัดความเร่งที่เกิดขึ้นของอุปกรณ์สมาร์ทโฟนตามแนวแกน X, Y และ Z มีลักษณะดังภาพที่ 2-1 ซึ่งเมื่ออุปกรณ์เคลื่อนที่ไปในทิศทางใด ก็จะได้แสดงค่าความเร่งที่เกิดขึ้นในทิศทางนั้น ๆ รวมกับค่าแรงดึงดูดของโลกที่กระทำต่ออุปกรณ์ด้วย

นอกจากนี้ยังมีรับรู้อื่น ๆ ของอุปกรณ์สมาร์ทโฟนที่น่าสนใจและหลายตัวก็นำมาใช้ร่วมกับ Accelerometer sensor ในการรู้จำกิจกรรม ซึ่งมีรายละเอียดและการใช้งานดังตารางที่ 2-1



ภาพที่ 2-1 ตัวรับรู้ชนิด Accelerometer sensor⁴

ตารางที่ 2-1 ชนิดตัวรับรู้ของอุปกรณ์เคลื่อนที่แบบพกพา และรายละเอียดการใช้งาน⁵

ตัวรับรู้	รายละเอียด
Gyroscope sensor	ตัวรับรู้ที่สามารถตรวจจับการหมุนของอุปกรณ์สมาร์ทโฟน โดยเป็นการตรวจจับ 3 แกน (3-Axes) เช่นเดียวกับกับ Accelerometer sensor แต่จะมีความถูกต้องและแม่นยำมากกว่า เช่นการควบคุมการเล่นเกมต่างๆ โดยเฉพาะเกมที่ต้องอาศัยการเคลื่อนไหวในหลาย ๆ ทิศทาง ที่เห็นได้ชัดก็เช่นบรรดาเกมแข่งรถทั้งหลาย หากอาศัย Accelerometer sensor เพียงอย่างเดียว ในบางครั้งการควบคุมก็อาจจะไม่เป็นไปตามที่ใจต้องการ แต่การที่มี Gyroscope sensor มาเสริม ก็จะทำให้การควบคุมมีความถูกต้องแม่นยำมากขึ้น ไม่ว่าจะจับถือเครื่องอุปกรณ์ในอิริยาบถแบบใดก็ตาม
Heart Rate sensor	เป็นตัวรับรู้ที่มีไว้สำหรับการตรวจวัดอัตราการเต้นของหัวใจ โดยในทางฮาร์ดแวร์ Heart Rate sensor จะประกอบไปด้วยอุปกรณ์ 2 ชิ้นส่วนด้วยกัน ชิ้นส่วนแรกคือไฟ Red LED สำหรับการยิงลำแสงไปที่ผิวหนังของผู้ใช้งานและชิ้นส่วนที่สองคือ Pulse sensor สำหรับการตรวจวัดการเคลื่อนไหวของเม็ดเลือดแดงในเส้นเลือด เช่น เส้นเลือดฝอยซึ่งอยู่ที่ปลายนิ้วมือ ดังนั้นก็จะมีประโยชน์มากสำหรับผู้ที่ชอบการออกกำลังกาย หรือผู้ที่รักในการดูแลสุขภาพของตนเอง เช่น สำหรับการวิ่งออกกำลังกาย ก็จะสามารถตรวจสอบได้ว่าก่อนและหลังการวิ่งเรามีอัตราการเต้นของหัวใจเป็นอย่างไร ได้ประโยชน์จากการวิ่งมากน้อยแค่ไหน

⁴ <http://curiously.com>

⁵ <https://www.thaimobilecenter.com>

ตารางที่ 2-1 ชนิดตัวรับรู้ของอุปกรณ์เคลื่อนที่แบบพกพา และรายละเอียดการใช้งาน (ต่อ)

ตัวรับรู้	รายละเอียด
Proximity sensor	ตัวรับรู้สำหรับการตรวจจပ်ระยะห่างระหว่างผู้ใช้กับตัวเครื่องสมาร์ทโฟน เพื่อการตอบสนองที่ถูกต้องเหมาะสม เช่น ในขณะที่ผู้ใช้งานกำลังสนทนา จะช่วยให้สามารถตรวจสอบได้ว่าขณะนั้นผู้ใช้งานมีการแนบหูไว้ติดกับตัวเครื่อง หรือเอาใบหน้ามาแนบกับตัวเครื่องหรือไม่ ซึ่งหากตรวจพบระบบก็จะทำการปิดหน้าจอแสดงผลโดยอัตโนมัติ เพื่อไม่ให้ใบหน้าหรือใบหูของผู้ใช้งานไปสัมผัสโดนฟังก์ชันบางอย่างที่อยู่บนหน้าจอแบบไม่ตั้งใจ
Gesture sensor	ตัวรับรู้สำหรับการตรวจจပ်ลักษณะการเคลื่อนไหวของฝ่ามือ หรือลักษณะท่าทางของผู้ใช้งาน โดยเป็นการตรวจจပ်ด้วยลำแสงอินฟราเรด (Infrared rays) ดังนั้นก็จะทำให้เครื่องสามารถทำงานตามการแสดงท่าทางของผู้ใช้งานได้ เช่น ในสมาร์ทโฟนบางรุ่นที่มี Gesture sensor หากผู้ใช้งานโบกฝ่ามือไปทางซ้าย ก็อาจจะเป็นการสั่งให้เลื่อนไปดูรูปภาพถัดไปในแกลเลอรี โดยที่ผู้ใช้งานไม่ต้องสัมผัสที่หน้าจอเลยแม้แต่น้อย
Geomagnetic sensor (Digital Compass)	ตัวรับรู้ที่ใช้สำหรับตรวจจပ်คลื่นแม่เหล็กไฟฟ้า หรือที่เรียกว่าเข็มทิศดิจิทัล (Digital compass) โดยจะเป็นการตรวจจပ်แบบ 3 แกน (3-Axes) ซึ่งจะมีประโยชน์มากสำหรับการใช้งานแอปพลิเคชันแผนที่ หรือระบบนำทางต่าง ๆ รวมถึงแอปพลิเคชันประเภท AR Applications (Augmented Reality) ซึ่งต้องอาศัยข้อมูลทิศทางที่ถูกต้องแม่นยำ
Barometer sensor	ตัวรับรู้ที่ใช้สำหรับการตรวจวัดความกดอากาศ สามารถให้ข้อมูลความสูงจากระดับน้ำทะเลได้ ซึ่งนับว่าเป็นข้อมูลที่มีประโยชน์มากสำหรับบางแอปพลิเคชัน โดยเฉพาะแอปพลิเคชันสำหรับการออกกำลังกายต่าง ๆ เช่น ในการออกกำลังกายด้วยการวิ่ง การเดิน หรือการปั่นจักรยาน หากทำในระดับความสูงที่ต่างกัน ก็จะมีอัตราการเผาผลาญแคลอรีที่ต่างกันไปด้วยนั่นเอง
Finger Scanner sensor	มีเฉพาะสมาร์ทโฟนบางรุ่น บางรุ่นเรียก Touch sensor เป็นตัวรับรู้ที่ใช้สำหรับตรวจจပ်ความถูกต้องของลายนิ้วมือผู้ใช้งาน ใช้ร่วมกับระบบรักษาความปลอดภัยของตัวเครื่อง หรือแอปพลิเคชันที่ต้องการความปลอดภัยสูง เช่น การทำธุรกรรมทางการเงินต่าง ๆ

ตารางที่ 2-1 ชนิดตัวรับรู้ของอุปกรณ์เคลื่อนที่แบบพกพา และรายละเอียดการใช้งาน (ต่อ)

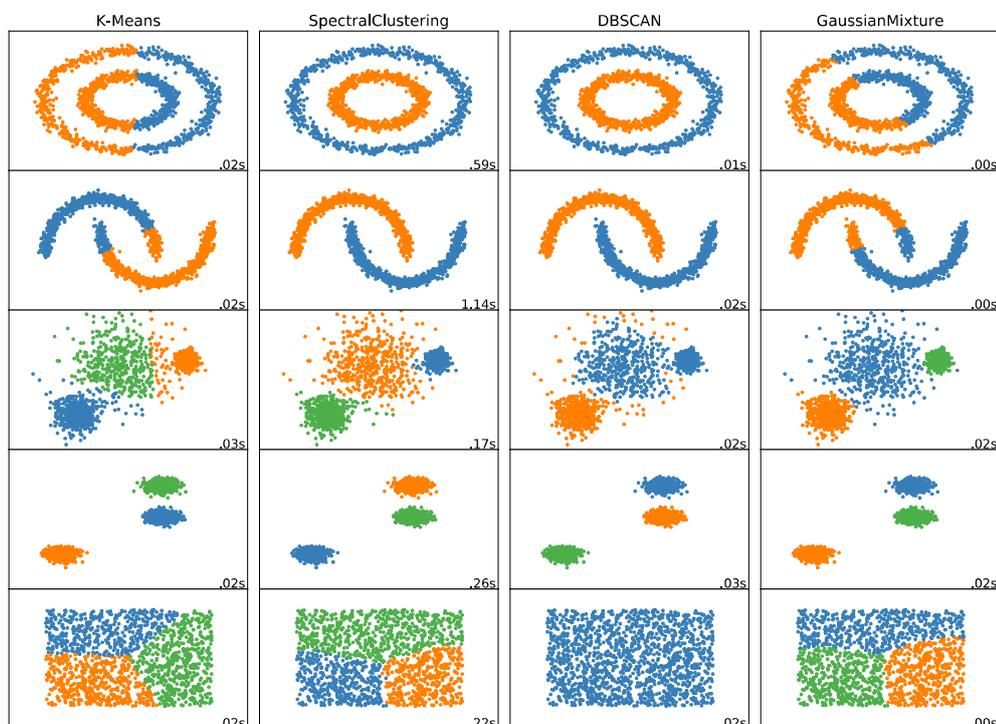
ตัวรับรู้	รายละเอียด
Temperature sensor	ตัวรับรู้สำหรับการตรวจวัดอุณหภูมิ ซึ่งสามารถนำไปใช้ประโยชน์กับแอปพลิเคชันได้หลายประเภท เช่น หากเราไปเดินอยู่ท่ามกลางทะเลทรายอันร้อนระอุแต่ไม่มีสัญญาณอินเทอร์เน็ต ก็ยังสามารถรู้ได้ว่าบริเวณนั้นมีอุณหภูมิที่สูงมากขนาดไหน
Humidity sensor	ตัวรับรู้ที่ใช้สำหรับการตรวจวัดค่าความชื้นสัมพัทธ์ หรืออัตราส่วนระหว่างปริมาณความชื้น (ไอน้ำ) ที่มีอยู่จริงในอากาศ กับปริมาณความชื้นที่อากาศขณะนั้นจะรองรับได้เต็มที่ในอุณหภูมิเดียวกัน ซึ่งเป็นข้อมูลที่มีประโยชน์ โดยเฉพาะผู้ที่ออกกำลังกายเป็นประจำ เช่น หากต้องออกกำลังกายในสภาพอากาศที่มีความชื้นสูง การระเหยของเหงื่อก็จะทำได้ไม่ทันนัก อีกทั้งร่างกายก็ต้องมีการขับเหงื่อออกมามากขึ้นด้วย ส่งผลให้ร่างกายหรือหัวใจต้องทำงานหนักกว่าปกติ

2.1.2 ทฤษฎีการเรียนรู้จำ

การเรียนรู้รูปแบบ (Pattern recognition) เป็นศาสตร์ทางวิทยาการคอมพิวเตอร์แขนงหนึ่งที่มีจุดประสงค์เพื่อจำแนกหรือระบุประเภทข้อมูล โดยกระบวนการจะมีการสร้างตัวแบบรู้จำสำหรับจัดการข้อมูลให้อยู่ในกลุ่มที่กำหนดมาให้ การสร้างตัวแบบรู้จำสามารถทำได้โดยใช้ 2 วิธีการที่สำคัญ ได้แก่ ขั้นตอนวิธีการแบ่งกลุ่ม (Clustering algorithms) และขั้นตอนการจำแนกประเภท (Classification algorithms)

- **ขั้นตอนวิธีการแบ่งกลุ่ม** เป็นเทคนิคการวิเคราะห์ข้อมูล ซึ่งแบ่งกลุ่มข้อมูลออกเป็นกลุ่มย่อยหลายกลุ่ม โดยใช้ลักษณะของข้อมูลเป็นเกณฑ์ในการแบ่งกลุ่ม นั้นหมายความว่าข้อมูลที่อยู่ในกลุ่มย่อยเดียวกันจะมีลักษณะหรือคุณสมบัติที่คล้ายคลึงกัน ในขั้นตอนการแบ่งกลุ่มจะอาศัยความเหมือนหรือความใกล้ชิดของข้อมูล โดยคำนวณจากการวัดระยะห่างเวกเตอร์ของข้อมูลด้วยมาตรวัดระยะแบบต่าง ๆ ได้แก่ การวัดระยะแบบยูคลิด (Euclidean distance) การวัดระยะแบบแมนฮัตตัน (Manhattan distance) การวัดระยะแบบแจ็กการ์ด (Jaccard distance) เป็นต้น การแบ่งกลุ่มข้อมูลเป็นกระบวนการเรียนรู้ข้อมูลที่ไม่ได้กำหนดประเภทของข้อมูลเอาไว้ก่อน จึงถือว่าขั้นตอนวิธีการแบ่งกลุ่มข้อมูลเป็นการเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) ส่วนวิธีการแบ่งกลุ่มข้อมูลที่นิยมใช้มีอยู่ด้วยกันหลายวิธี ตัวอย่างดังภาพที่ 2-2 การแบ่งกลุ่มแบบเคมีนส์ (K-mean clustering) การแบ่งกลุ่มแบบสเปคทรัล (Spectral clustering) การแบ่งกลุ่มแบบดีปัสแกน

(DBSCAN clustering) การแบ่งกลุ่มแจกแจงผสมแบบเกาส์ (Gaussian Mixture Model clustering) เป็นต้น ซึ่งการแบ่งกลุ่มแต่ละวิธีจะเหมาะสมกับข้อมูลแต่ละแบบแตกต่างกันไป



ภาพที่ 2-2 วิธีการแบ่งกลุ่มข้อมูลแบบ K-mean, Spectral Clustering, DBSCAN และ Gaussian Mixture⁶

ในวิทยานิพนธ์นี้จะขออธิบายวิธีการแบ่งกลุ่มข้อมูลแบบ Gaussian Mixture Model (Moon, 1996) (Tomasi, 2004) เนื่องจากเป็นวิธีการแบ่งกลุ่มข้อมูลใช้ในวิธีการที่นำเสนอ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR) และวิธีการที่นำมาเปรียบเทียบ Adaptive mobile activity recognition system with evolving data streams (Abdallah และคณะ, 2015) โดยจะใช้วิธีการประมาณการค่ามากที่สุดด้วยเทคนิควิธีทางคณิตศาสตร์ที่เรียกว่า Expectation Maximization (EM) วิธีดังกล่าวเป็นกระบวนการทำซ้ำ (Recursive) แบ่งเป็นสองขั้นตอน 1) ขั้นตอนการประมาณการ (คาดคะเน) ซึ่งเป็นขั้นตอนของการคาดคะเนค่าขั้นต้นก่อน 2) ขั้นตอนการปรับปรุงค่า แล้วส่งกลับไปให้ขั้นตอนที่หนึ่ง

⁶ <http://scikit-learn.org/stable/modules/clustering.html>

ทำงาน กระบวนการทั้งหมดจะหยุดก็ต่อเมื่อค่าความน่าจะเป็นของขั้นตอนในรอบที่ผ่านมากับรอบปัจจุบันมีค่าใกล้เคียงกันมาก ๆ โดยการประมาณค่าในวิทยานิพนธ์นี้ก็คือความน่าจะเป็นของข้อมูลกิจกรรม ซึ่งใช้ฟังก์ชันเกาส์ในการประมาณค่าความน่าจะเป็น เนื่องจากต้องการแบ่งกลุ่ม (Clustering) ของแต่ละกลุ่มตามความน่าจะเป็นว่าข้อมูลที่กำลังพิจารณาควรอยู่กลุ่มใด ซึ่งขั้นตอนทั้งหมดสามารถอธิบายได้ตามสมการที่ (2.1) ถึง (2.5)

ฟังก์ชันความน่าจะเป็นของเกาส์

$$g(x; \mu_k, \sigma_k) = \frac{1}{(\sqrt{2\pi\sigma_k})^D} e^{-\frac{1}{2}\left(\frac{\|x-\mu_k\|}{\sigma_k}\right)^2} \quad (2.1)$$

วิธีการประมาณการค่ามากที่สุด (Expectation Maximization)

กำหนดค่าเริ่มต้นให้กับตัวแปร $p_k^{(0)}, \mu_k^{(0)}, \sigma_k^{(0)}$

ขั้นที่ 1 ประมาณการ (E Step)

$$p^{(i)}(k|n) = \frac{p_k^{(i)} g(x_n; \mu_k^{(i)}, \sigma_k^{(i)})}{\sum_{k=1}^K p_k^{(i)} g(x_n; \mu_k^{(i)}, \sigma_k^{(i)})} \quad (2.2)$$

ขั้นที่ 2 ปรับปรุงค่า (M Step)

$$\mu_k^{(i+1)} = \frac{\sum_{n=1}^N p^{(i)}(k|n) x_n}{\sum_{n=1}^K p^{(i)}(k|n)} \quad (2.3)$$

$$\sigma_k^{(i+1)} = \sqrt{\frac{1}{D} \frac{\sum_{n=1}^N p^{(i)}(k|n) \|x_n - \mu_k^{(i+1)}\|^2}{\sum_{n=1}^K p^{(i)}(k|n)}} \quad (2.4)$$

$$p_k^{(i+1)} = \frac{1}{N} \sum_{n=1}^N p^{(i)}(k|n) \quad (2.5)$$

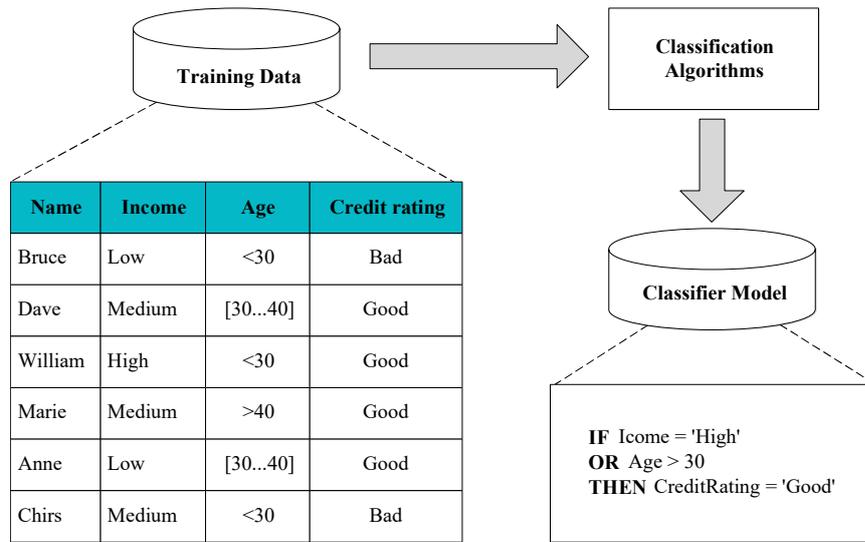
โดยที่	x_n	คือ ค่าข้อมูล ($n = 1, 2, 3, \dots, N$)
	μ_k	คือ ค่าเฉลี่ยของข้อมูล ($k = 1, 2, 3, \dots, K$)
	σ_k	คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล ($k = 1, 2, 3, \dots, K$)
	p_k	คือ ค่าถ่วงน้ำหนัก ($k = 1, 2, 3, \dots, K$)

$p(k n)$	คือ ความน่าจะเป็นที่ข้อมูลตัวที่ n จะเป็นสมาชิกของกลุ่มที่ k
N	คือ จำนวนข้อมูลทั้งหมด
D	คือ มิติของข้อมูล
K	คือ จำนวนกลุ่มทั้งหมด
i	คือ รอบที่ใช้ในการคำนวณ

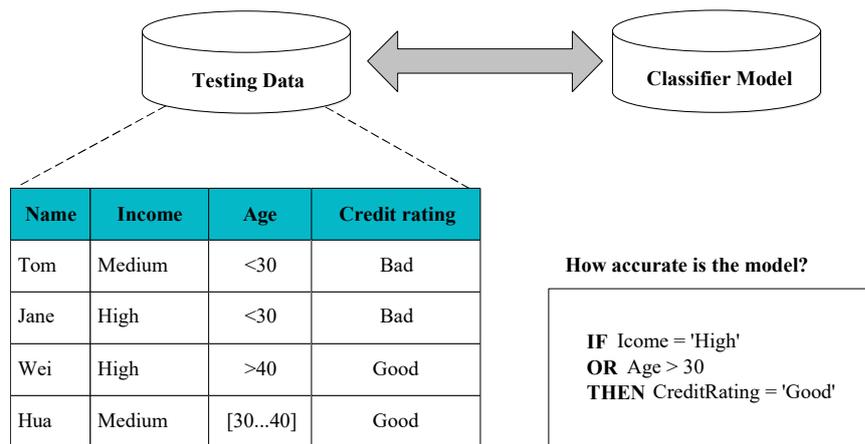
กระบวนการทั้งหมดจะหยุดทำเมื่อค่าความน่าจะเป็นของรอบปัจจุบันมีค่าใกล้เคียงกับค่าความน่าจะเป็นในรอบที่ผ่านมามาก ๆ

- **ขั้นตอนวิธีการจำแนกประเภท** ใช้สำหรับจำแนกหรือระบุประเภทของข้อมูล โดยนำข้อมูลส่วนหนึ่งที่ทราบประเภทมาสอนระบบเพื่อให้เรียนรู้รูปแบบที่เกิดขึ้นในข้อมูล เรียกข้อมูลส่วนนี้ว่าข้อมูลสอน (Training data) แล้วจึงสร้างเป็นตัวแบบการรู้จำ (Classifier model) ดังภาพที่ 2-3 ส่วนข้อมูลที่เหลือจากข้อมูลสอนระบบจะนำมาเป็นข้อมูลที่ใช้ทดสอบ (Testing data) ซึ่งกลุ่มที่แท้จริงของข้อมูลที่ใช้ทดสอบนี้จะถูกนำมาเปรียบเทียบกับกลุ่มที่หาได้จากตัวแบบเพื่อทดสอบความถูกต้อง และปรับปรุงตัวแบบจนกว่าจะได้ค่าความถูกต้องเป็นที่น่าพอใจ ดังภาพที่ 2-4 ในส่วนการใช้งานจริงนั้น เมื่อมีข้อมูลเข้ามาก็จะนำข้อมูลนี้ไปผ่านตัวแบบ โดยตัวแบบจะทำนายหรือบอกประเภทของข้อมูลได้ว่าเป็นประเภทใด ดังภาพที่ 2-5 ซึ่งขั้นตอนวิธีการจำแนกประเภทเป็นกระบวนการเรียนรู้ข้อมูลที่กำหนดประเภทของข้อมูลเอาไว้ก่อน จึงถือว่าขั้นตอนวิธีการจำแนกประเภทข้อมูลเป็นการเรียนรู้แบบมีผู้สอน (Supervised learning)

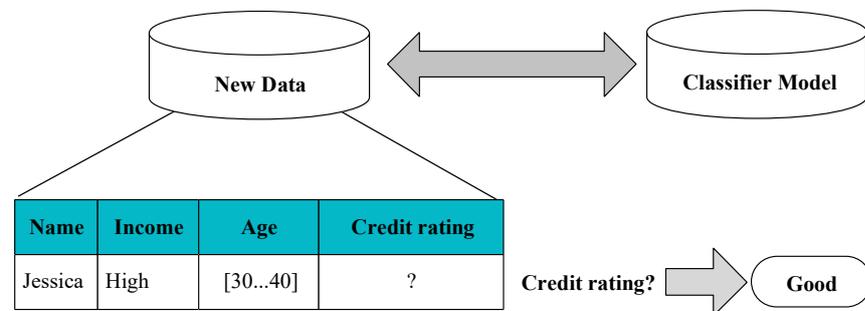
วิธีการสร้างตัวแบบสำหรับจำแนกประเภทข้อมูลที่นิยม ได้แก่ ต้นไม้ตัดสินใจ (Decision tree) โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ (Back propagation neural networks) และซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) เป็นต้น



ภาพที่ 2-3 ขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบรู้จำ



ภาพที่ 2-4 ขั้นตอนการทดสอบตัวแบบ



ภาพที่ 2-5 ขั้นตอนการนำตัวแบบไปใช้งานจริง

2.1.3 การคำนวณทางสถิติสำหรับวิเคราะห์ข้อมูล

วิทยานิพนธ์นี้ได้ใช้การคำนวณทางสถิติหลายวิธีในการวิเคราะห์ข้อมูลสำหรับการสร้างตัวแบบรู้จำกิจกรรม ได้แก่ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ความหนาแน่น (Density) และความโด่ง (Kurtosis) เป็นต้น ซึ่งมีรายละเอียดดังต่อไปนี้

- **ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation)⁷** คือการคำนวณค่าทางสถิติที่ใช้ในการวัดการกระจายของข้อมูล สามารถหาได้จากสมการที่ (2.6)

$$SD = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N - 1}} \quad (2.6)$$

โดยที่	SD	คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล
	x_i	คือ ค่าของข้อมูล ($i = 1, 2, 3, \dots, N$)
	\bar{x}	คือ ค่าเฉลี่ยของข้อมูล
	N	คือ จำนวนของข้อมูล

- **ความหนาแน่น (Density)⁸** คือ ปริมาณของมวลสารที่มีอยู่ในวัตถุใดวัตถุหนึ่ง หาได้จากอัตราส่วนของมวลต่อปริมาตรของวัตถุนั้น ๆ นอกจากนี้ในทางสถิติสามารถหาความหนาแน่นของประชากร โดยคำนวณจากอัตราส่วนของจำนวนประชากรต่อพื้นที่ ซึ่งในวิทยานิพนธ์นี้ได้นำวิธีการหาความหนาแน่นมาใช้พิจารณาข้อมูล โดยกำหนดการอ้างอิงตัวแปรให้เหมาะสมกับข้อมูลที่พิจารณาดังสมการที่ (2.7)

$$Density = \frac{Mass}{Volume} \quad (2.7)$$

โดยที่	$Density$	คือ ค่าความหนาแน่นของข้อมูล
	$Mass$	คือ จำนวนของข้อมูล
	$Volume$	คือ ค่าพิสัยของข้อมูล

⁷ https://en.wikipedia.org/wiki/Standard_deviation

⁸ <https://en.wikipedia.org/wiki/Density>

• **ความโด่ง (Kurtosis)⁹** คือ ระดับความสูงโด่งของการแจกแจงของข้อมูล โดยพิจารณาจากโค้งความถี่ ว่ามีความโด่งมากน้อยเพียงใด ความโด่งของโค้งความถี่แบ่งได้เป็น 3 ระดับ ได้แก่ โค้งความถี่ที่มีการแจกแจงที่โด่งปกติ โด่งมากและโด่งน้อย โดยจะเป็นการคำนวณหาค่าสัมประสิทธิ์ความโด่ง ซึ่งมีวิธีการคำนวณดังสมการที่ (2.8)

$$Kurtosis = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{(\sum_{i=1}^N (x_i - \bar{x})^2)^2} \quad (2.8)$$

โดยที่ **Kurtosis** คือ ค่าสัมประสิทธิ์ความโด่งของข้อมูล

x_i คือ ค่าของข้อมูล ($i = 1, 2, 3, \dots, N$)

\bar{x} คือ ค่าเฉลี่ยของข้อมูล

N คือ จำนวนของข้อมูล

เมื่อคำนวณได้ค่าสัมประสิทธิ์ความโด่งแล้ว ก็พิจารณาความโด่งของโค้งความถี่ ดังนี้

ถ้า สัมประสิทธิ์ความโด่ง = 0.263 โค้งความถี่มีการแจกแจงที่โด่งปกติ

สัมประสิทธิ์ความโด่ง > 0.263 โค้งความถี่มีการแจกแจงที่โด่งมาก

สัมประสิทธิ์ความโด่ง < 0.263 โค้งความถี่มีการแจกแจงที่โด่งน้อย

2.1.4 การรู้จำกิจกรรม (Activity Recognition)

การรู้จำกิจกรรมในวิทยานิพนธ์นี้มุ่งเน้นการรู้จำกิจกรรมโดยใช้ข้อมูลจากตัวรับรู้ของอุปกรณ์สื่อสารเคลื่อนที่สมาร์ทโฟน จึงได้ศึกษางานวิจัยของ Shoab และคณะ (2015) ที่ทำการสำรวจงานวิจัยที่เกี่ยวข้องกับการกับสร้างตัวแบบรู้จำกิจกรรม ได้อธิบายถึงกระบวนการรู้จำกิจกรรมซึ่งประกอบไปด้วย 4 ขั้นตอนดังภาพที่ 2-6

1) ขั้นตอน Sensing เป็นขั้นตอนการเก็บข้อมูลจากตัวรับรู้ด้วยอัตราสุ่มตัวอย่างที่กำหนดไว้

2) ขั้นตอน Feature extraction เป็นขั้นตอนการสกัดคุณลักษณะที่สำคัญของข้อมูลที่จะนำไปใช้ในการสร้างตัวแบบรู้จำกิจกรรม

3) ขั้นตอน Training เป็นขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (Classifier model) สำหรับใช้ในการจำแนกประเภทกิจกรรม ซึ่งต้องนำข้อมูลส่วนหนึ่งมาสอนให้ตัวแบบเกิดการเรียนรู้ที่

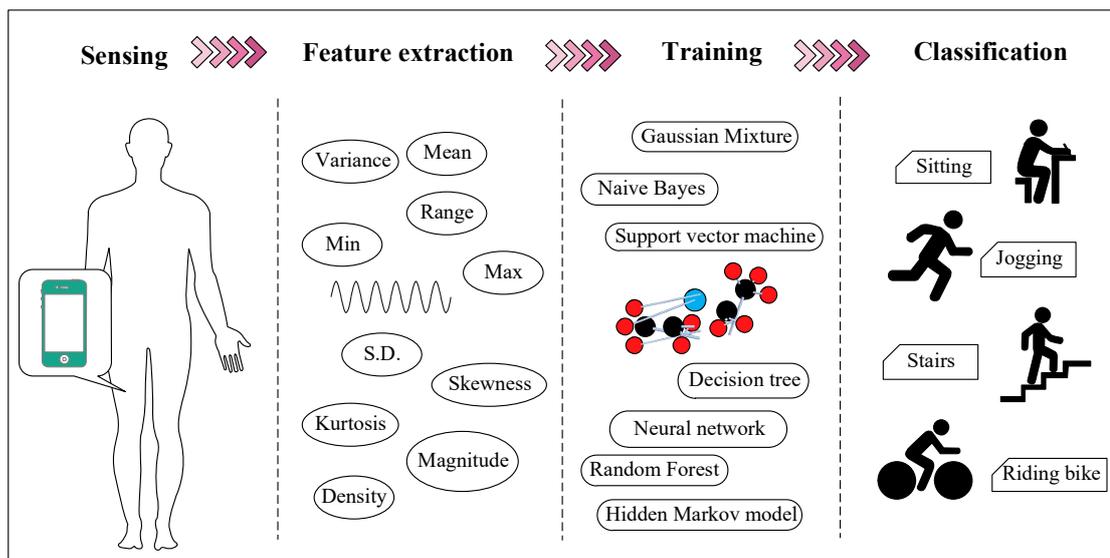
⁹ <https://en.wikipedia.org/wiki/Kurtosis>

สามารถจำแนกประเภทของกิจกรรมได้ การเรียนรู้สามารถแยกได้เป็น 2 วิธีการ คือ การเรียนรู้แบบออนไลน์ (Online learning) และการเรียนรู้แบบออฟไลน์ (Offline learning)

การเรียนรู้ออนไลน์จะนำข้อมูลเข้ามาทีละ 1 ตัวอย่าง เพื่อสอนให้ตัวแบบเกิดการเรียนรู้ หากตัวแบบเกิดการเรียนรู้ผิดพลาด ตัวแบบก็จะถูกปรับปรุงทันที แล้วจึงนำข้อมูลตัวอย่างถัดไปมาสอนตัวแบบ ทำเช่นนี้จนกระทั่งได้ค่าความถูกต้องเป็นที่น่าพอใจ

การเรียนรู้แบบออฟไลน์จะตรงกันข้ามกับการเรียนรู้แบบออนไลน์ กล่าวคือข้อมูลสอนจะถูกนำเข้ามาสอนตัวแบบทีละตัวอย่าง หากตัวแบบเกิดการเรียนรู้ผิดพลาด ก็จะเก็บข้อผิดพลาดนี้ไว้ก่อน จนกระทั่งข้อมูลทั้งหมดถูกนำเข้ามาสอนตัวแบบครบทุกตัวอย่างแล้วจึงปรับปรุงตัวแบบ ทำเช่นนี้จนกว่าจะได้ค่าความถูกต้องเป็นที่น่าพอใจ

4) ขั้นตอน Classification เป็นขั้นตอนการนำไปใช้งาน โดยใช้ตัวแบบที่สร้างขึ้นจากขั้นตอน Training เพื่อรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาที่มาจากอุปกรณ์สมาร์ทโฟน ซึ่งขั้นตอนนี้สามารถประมวลผลได้ทั้งบนอุปกรณ์และบนเครื่องแม่ข่าย (Server) แล้วแต่ลักษณะของการออกแบบและการนำไปใช้งาน เมื่อประมวลผลเสร็จแล้วจะระบุกิจกรรมที่กำลังทำอยู่ ณ ขณะนั้น



ภาพที่ 2-6 ขั้นตอนการรู้จำกิจกรรม¹⁰

¹⁰ <https://becominghuman.ai>

2.2 งานวิจัยที่เกี่ยวข้อง

งานวิจัยทางด้านการรู้จำกิจกรรม (Activity recognition) เป็นเรื่องที่น่าสนใจและมีความสำคัญเป็นอย่างมาก งานวิจัยทางด้านนี้เป็นงานวิจัยที่เกี่ยวกับการสร้างตัวแบบสำหรับการรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้ ซึ่งวิธีที่ใช้ในการสร้างตัวแบบสำหรับการรู้จำกิจกรรมส่วนใหญ่ที่หลายงานวิจัยนำมาประยุกต์ใช้คือวิธีการจำแนกประเภทข้อมูล (Classification approaches) ได้แก่ ต้นไม้ตัดสินใจ (Decision tree) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) หรือเทคนิค Naive Bayes เป็นต้น (Preece และคณะ, 2009) (Peterek และคณะ, 2014) (Vo และคณะ, 2013)

ตารางที่ 2-2 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบสำหรับการรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์สมาร์ทโฟน

งานวิจัย	ตัวรับรู้	อัตราสุ่มตัวอย่าง (Hz)	กิจกรรมที่สามารถรู้จำได้	วิธีการที่ใช้สร้างตัวแบบรู้จำกิจกรรม	วิธีการเรียนรู้
Lane และคณะ (2011)	Accelerometer	ไม่ได้ระบุ	Walking, Running, Still, Driving a car	Naïve Bayes	Offline
Reddy และคณะ (2010)	Accelerometer, GPS	32	Walking, Running, Still, Biking, In vehicle	Decision tree, DHMM	Offline
Anjum และ Ilyas (2013)	Accelerometer	8	Walking, Running, Upstairs, Downstairs, Still, Biking, Driving a car	Decision tree	Offline
Lara และ Labrador (2012)	Accelerometer	50	Walking, Sitting, Running	Decision tree	Offline
Liang และคณะ (2012)	Accelerometer	2, 10, 20	Walking, Standing, Sitting, Running, Upstairs, Downstairs, Biking, Driving, Jumping, Using elevator down	Hierarchical decision tree	Online

ตารางที่ 2-2 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบสำหรับการรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์สมาร์ทโฟน (ต่อ)

งานวิจัย	ตัวรับรู้	อัตราสุ่มตัวอย่าง (Hz)	กิจกรรมที่สามารถรู้จำได้	วิธีการที่ใช้สร้างตัวแบบรู้จำกิจกรรม	วิธีการเรียนรู้
Wang และคณะ (2009)	Accelerometer	ไม่ได้ระบุ	Walking, Standing, Sitting, Upstairs, Biking, Laying, Phone on table/detached	Decision tree	Offline
Yan และคณะ (2012)	Accelerometer	5, 16, 50, 100	Walking, Standing, Sitting, Downstairs, Using elevator up, Using elevator down	Decision tree	Online
Anguita และคณะ (2013)	Accelerometer	50	Walking, Standing, Sitting, Upstairs, Downstairs, Phone on table/detached	SVM	Online
Frank และคณะ (2011)	Accelerometer	ไม่ได้ระบุ	Walking, Jogging, Running, Jumping	SVM	Online
Khan และคณะ (2013)	Accelerometer	20	Walking, Standing, Running, Upstairs, Downstairs, Jumping	PNN	Offline
Kim และคณะ (2013)	Accelerometer, Magnetometer, Gyroscope	50	Walking, Running, Upstairs, Downstairs, Still	Hierarchical SVM	Offline
Ouchi และ Doi (2012)	Accelerometer (A), Audio (mic)	20 (A), 16000 (mic)	Walking, Running, Vacuuming, Laying, Washing dishes, Ironing, Brushing teeth, Hair drying, Flushing the toilet, Boarding	SMV	Offline

ตารางที่ 2-2 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบสำหรับการรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์สมาร์ทโฟน (ต่อ)

งานวิจัย	ตัวรับรู้	อัตราสุ่มตัวอย่าง (Hz)	กิจกรรมที่สามารถรู้จำได้	วิธีการที่ใช้สร้างตัวแบบรู้จำกิจกรรม	วิธีการเรียนรู้
Stewart และคณะ (2012)	Accelerometer	50	Walking, Jogging, Still	SMV	Offline
Kose และคณะ (2012)	Accelerometer	10, 20, 100	Walking, Standing, Sitting, Running	Naive Bayes + KNN clustered	Offline
Das และคณะ (2010)	Accelerometer	125	Walking, Running, Upstairs, Downstairs, Jumping, Phone on table/detached	KNN classifier	Offline
Siirtola (2012)	Accelerometer	40	Walking, Standing, Sitting, Running, Biking, Driving a car	NKK, QDA	Offline
Thiemjarus (2013)	Accelerometer	50	Walking, Standing, Sitting, Running, Jumping, Laying	KNN	Offline
Das และคณะ (2012)	Accelerometer	20	Walking, Standing, Sitting, Running, Upstairs	Naive Bayes	Offline
Gomes และคณะ (2012)	Accelerometer	ไม่ได้ระบุ	Walking, Standing, Sitting, Running	Naive Bayes	Online
Vo และคณะ (2013)	Accelerometer	32	Walking, Jogging, Upstairs, Downstairs, Biking	SVM + K-medoids clustering	Offline
Zhao และคณะ (2013)	Accelerometer, Magnetometer	50	Walking, Jogging, Upstairs, Downstairs, Still, Biking, Using elevator up, Using elevator down	Decision tree + PNN	Offline

จากตารางที่ 2-2 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบสำหรับการรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้ของอุปกรณ์สมาร์ตโฟน จะเห็นว่างานวิจัยส่วนใหญ่เน้นสร้างตัวแบบรู้จำกิจกรรมโดยใช้วิธีการเรียนรู้แบบออฟไลน์ สอดคล้องกับงานวิจัยของ Shoab และคณะ (2015) ที่ได้สำรวจได้สำรวจงานวิจัยที่เกี่ยวกับการสร้างตัวแบบรู้จำกิจกรรม พบว่า 80 เปอร์เซ็นต์ของงานวิจัยที่ศึกษาเป็นการสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการเรียนรู้แบบออฟไลน์ ซึ่งตัวแบบที่ได้จากวิธีดังกล่าวจะเป็นตัวแบบที่คงตัว (Static model) ที่ไม่สามารถปรับปรุงตัวแบบให้เข้ากับลักษณะข้อมูลใหม่ที่เข้ามาได้ทันที หากต้องการปรับปรุงตัวแบบรู้จำกิจกรรมจะต้องนำข้อมูลที่ทราบประเภทอยู่แล้ว (Annotated data) ทั้งหมด (ทั้งข้อมูลที่เคยใช้สอนและข้อมูลใหม่) มาผ่านขั้นตอนการเรียนรู้เดิมอีกครั้งเพื่อสร้างตัวแบบรู้จำกิจกรรมใหม่ แต่เนื่องจากข้อมูลที่ได้จากตัวรับรู้ของอุปกรณ์สมาร์ตโฟนมีลักษณะเป็นกระแสข้อมูลเชิงเวลา (Temporal streaming data) ที่เกิดขึ้นอย่างต่อเนื่องตลอดเวลาและมีปริมาณมาก ดังนั้นวิธีการสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการเรียนรู้แบบออฟไลน์จึงไม่เหมาะในการนำไปใช้สำหรับสร้างตัวแบบรู้จำกิจกรรมที่รองรับกับการใช้งานได้จริง

วิธีการสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการเรียนรู้แบบออนไลน์สามารถปรับปรุงตัวแบบรู้จำกิจกรรมได้ทันทีจากข้อมูลที่เข้ามาใหม่ จึงเหมาะสมในการนำไปใช้งานจริงกับข้อมูลที่ได้จากตัวรับรู้ของอุปกรณ์สมาร์ตโฟนที่มีลักษณะเป็นกระแสข้อมูลเชิงเวลา ซึ่งในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมจะต้องนำข้อมูลการทำกิจกรรมของผู้ใช้มาสอนตัวแบบรู้จำกิจกรรม สามารถทำได้สองวิธีขึ้นอยู่กับข้อมูลที่นำมาสร้างตัวแบบรู้จำกิจกรรม ได้แก่ การสร้างตัวแบบรู้จำกิจกรรมจากข้อมูลการทำกิจกรรมของผู้ใช้คนเดียวกับผู้ที่จะใช้ตัวแบบรู้จำกิจกรรม เรียกว่าตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model) และการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลการทำกิจกรรมจากบุคคลใดก็ได้ เรียกว่าตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model)

ตัวแบบรู้จำกิจกรรมเฉพาะบุคคลจะใช้ข้อมูลการทำกิจกรรมของผู้ใช้ตัวแบบในการสร้างตัวแบบรู้จำกิจกรรม โดยจะให้ผู้ใช้งานแสดงท่าทางกิจกรรมทุกกิจกรรมตามระยะเวลาที่กำหนด ตัวอย่างเช่น ให้ผู้ใช้ การนั่ง การยืน การเดิน และการวิ่ง โดยทำกิจกรรมละ 20 นาที จากนั้นจะนำข้อมูลกิจกรรมที่ได้นี้ไปสร้างเป็นตัวแบบรู้จำกิจกรรม ส่วนตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคลนั้นจะใช้ข้อมูลการทำกิจกรรมของผู้ใช้คนใดก็ได้ในการสร้างตัวแบบรู้จำกิจกรรม เช่น ข้อมูลการทำกิจกรรมจากฐานข้อมูลสาธารณะ

2.2.1 ตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model)

งานวิจัยที่สร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคลจะเน้นสร้างตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้เป็นรายบุคคล โดยการใช้ข้อมูลการทำกิจกรรมของคนคนนั้นสำหรับเป็นข้อมูลในการสอนตัวแบบรู้จำกิจกรรม มีตัวอย่างงานวิจัยดังนี้

งานวิจัยของ Gomes และคณะ (2012) ได้พัฒนาขั้นตอนวิธีชื่อ “Mobile Activity Recognition System” หรือเรียกว่า “MARS” สำหรับรู้จำกิจกรรมกับข้อมูลกระแสวิ่งเวลา กระบวนการสร้างตัวแบบรู้จำกิจกรรมประกอบไปด้วย ขั้นตอนสำหรับการเตรียมข้อมูลที่ใช้สร้างตัวแบบรู้จำกิจกรรม (Training Phase) ซึ่งจะเก็บข้อมูลการทำกิจกรรมของผู้ใช้โดยให้ผู้ใช้แสดงท่าทางการทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนด แล้วจึงนำข้อมูลกิจกรรมที่ได้ไปสร้างตัวแบบรู้จำกิจกรรม ซึ่งวิธีการ MARS ใช้เทคนิควิธี Naïve Bayes ในการจำแนกประเภทของกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรม โดยวิธีการ MARS สามารถประมวลผลบนอุปกรณ์ (On board)

งานวิจัยของ Lockhart และ Weiss (2014) นำเสนอระบบที่ชื่อ “Actitracker” สำหรับรู้จำกิจกรรมต่าง ๆ ที่ผู้ใช้กระทำ โดยเน้นกิจกรรมแบบกายภาพพื้นฐาน ได้แก่ การเดิน การวิ่ง การขึ้นลงบันได การยืน การนั่ง และการนอน เริ่มต้นระบบ Actitracker จะสร้างตัวแบบรู้จำกิจกรรมด้วยข้อมูลการทำกิจกรรมจากอาสาสมัครจำนวน 59 คน โดยให้ผู้ใช้ใส่อุปกรณ์สมาร์ทโฟนไว้ที่กระเป๋ากางเกงด้านหน้า ตัวอุปกรณ์สมาร์ทโฟนจะส่งสัญญาณข้อมูล Accelerometer ไปยังเครื่องแม่ข่ายเพื่อประมวลผลในขั้นตอนต่าง ๆ ส่วนการสร้างตัวแบบรู้จำกิจกรรมจะใช้ขั้นตอนวิธี Random Forest ซึ่งเป็นเทคนิคหนึ่งในการจำแนกประเภทข้อมูล ในส่วนการรู้จำเฉพาะบุคคล (Personal model) ระบบนี้มีขั้นตอนที่เรียกว่า Training mode สำหรับการเก็บข้อมูลการทำกิจกรรมต่าง ๆ เฉพาะบุคคลเพื่อเป็นข้อมูลสอน โดยที่ผู้ใช้ต้องทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนดผ่านแอปพลิเคชันที่ติดตั้งไว้ในอุปกรณ์สมาร์ทโฟน จากนั้นข้อมูลจะถูกส่งไปประมวลผลที่เครื่องแม่ข่ายเพื่อปรับปรุงตัวแบบรู้จำกิจกรรมที่สร้างไว้

งานวิจัยของ Uddin และคณะ (2016) นำเสนอขั้นตอนวิธีที่ชื่อว่า “Human Activity and Postural Transitions” เรียกโดยย่อว่า “HAPT” สำหรับการรู้จำกิจกรรมกับข้อมูลจากตัวรับรู้ของอุปกรณ์สมาร์ทโฟน ซึ่งวิธีการ HAPT ใช้ข้อมูลจากตัวรับ Accelerometer และ Gyroscope สำหรับรู้จำกิจกรรม ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมจะใช้เทคนิควิธี Random Forest ซึ่งวิธีการ HAPT ทำการรู้จำกิจกรรมโดยมีการพิจารณารูปแบบการเปลี่ยนกิจกรรม เช่น จากนั่งไปยืน จากนั่งไปนอน จากยืนไปนอน จากนอนไปนั่ง เป็นต้น ซึ่งในขั้นตอนสำหรับเตรียมข้อมูลเพื่อสอนตัวแบบจะให้ผู้ใช้ใส่อุปกรณ์สมาร์ทโฟนไว้ที่เอว จากนั้นให้ทำกิจกรรมต่าง ๆ ได้แก่ การยืน การเดิน การนั่ง การขึ้นลงบันได และท่าทางการเปลี่ยนกิจกรรมได้แก่ ยืนแล้วนั่ง นั่งแล้วยืน ยืนแล้วนอน นอนแล้วนั่ง นั่งแล้วนอน และนอนแล้วยืน เป็นต้น

งานวิจัยของ Lee และคณะ (2017) นำเสนอวิธีการที่ชื่อว่า “One Dimensional Convolutional Neural Network” เรียกโดยย่อว่า “1D-CNN” สำหรับการรู้จำกิจกรรมจากข้อมูล Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน มีแนวคิดในการใช้ข้อมูลเพียง 1 มิติในการรู้จำกิจกรรม 3 แบบ ได้แก่ การเดิน การวิ่ง และการหยุดนิ่ง (Staying still) ในขั้นตอนเตรียมข้อมูล

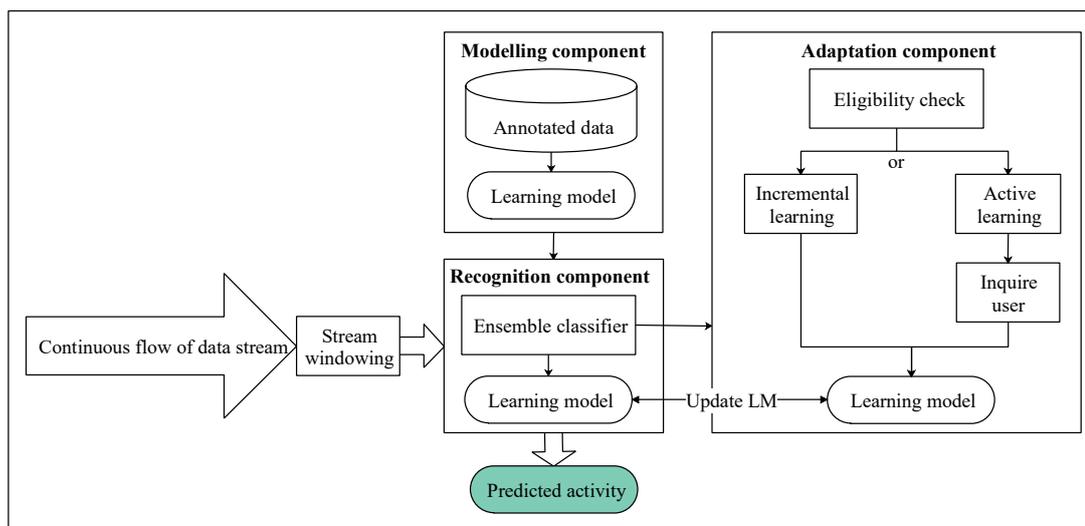
สำหรับสอนตัวแบบรู้จำกิจกรรม จะให้ผู้ใช้ใส่อุปกรณ์สมาร์ตโฟนโดยติดตั้งไว้หลายตำแหน่ง ได้แก่ ถือไว้บนมือ ใส่ไว้ในกระเป๋ากางเกง ใส่ไว้ในกระเป๋าสะพาย เป็นต้น จากนั้นให้ทำกิจกรรมทั้ง 3 แบบ กิจกรรมละประมาณ 10 นาที เมื่อได้ข้อมูลของการทำกิจกรรมทั้งหมดแล้ว จะทำการแปลงข้อมูล Accelerometer ให้เป็นข้อมูล Magnitude แล้วจึงนำไปสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการ Convolutional Neural Network

2.2.2 ตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model)

งานวิจัยที่สร้างตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคลจะเน้นสร้างตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้ทุกคน โดยการใช้ข้อมูลการทำกิจกรรมของใครก็ได้สำหรับเป็นข้อมูลในการสอนตัวแบบรู้จำกิจกรรม มีตัวอย่างงานวิจัยดังนี้

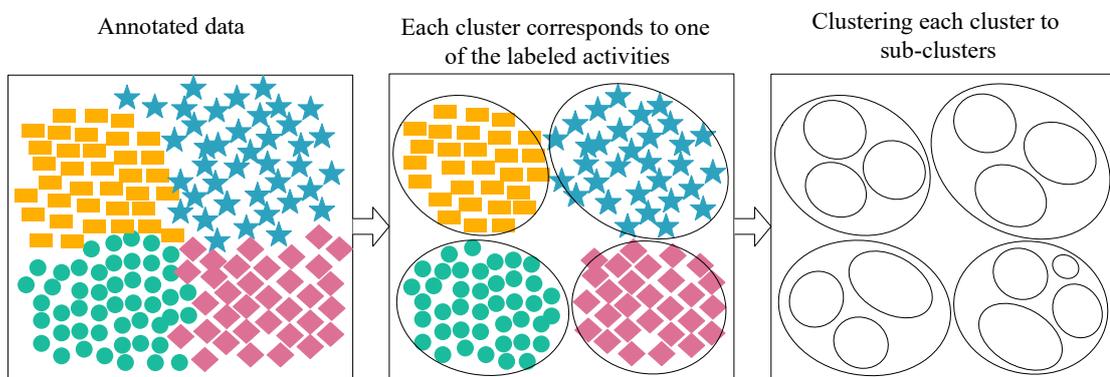
งานวิจัยของ Lgnatov (2017) เสนอขั้นตอนวิธีการสร้างตัวแบบรู้จำกิจกรรมกับข้อมูลตัวรับรู้ของสมาร์ตโฟน โดยเน้นการรู้จำกิจกรรมทางกายภาพ ได้แก่ การเดิน การวิ่ง การขึ้นลงบันได การยืน การนั่งและการนอน โดยใช้เทคนิค Convolutional Neural Network สำหรับสร้างตัวแบบรู้จำกิจกรรม ซึ่งข้อมูลสำหรับสอนตัวแบบรู้จำกิจกรรมจะเป็นข้อมูลการทำกิจกรรมจากฐานข้อมูลออนไลน์สาธารณะ ได้แก่ WISDM และ UCI เป็นต้น

งานวิจัยของ Abdallah และคณะ (2015) เสนอขั้นตอนวิธีที่ชื่อว่า “Adaptive mobile activity recognition system with evolving data streams” หรือเรียกโดยย่อว่า “STAR” สามารถรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาจากตัวรับรู้ของอุปกรณ์สมาร์ตโฟนได้ โดยมีกรอบแนวคิดดังภาพที่ 2-7



ภาพที่ 2-7 กรอบแนวคิดวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR)

ในขั้นตอนแรกเป็นการเตรียมตัวแบบจะใช้ข้อมูลที่ทราบว่าเป็นกิจกรรมชนิดใด (Annotated data) โดยแบ่งข้อมูลของแต่ละกิจกรรมเป็นกลุ่มย่อย (Sub-clusters) ด้วยวิธีการแบ่งกลุ่มข้อมูล เช่น การแบ่งกลุ่มแบบเคมีนส์ (K-mean clustering) หรือการแบ่งกลุ่มแจกแจงผสมแบบเกาส์ (Gaussian Mixture Model) เป็นต้น โดยผู้ใช้ต้องกำหนดจำนวนกลุ่มย่อยที่ต้องการ ดังภาพที่ 2-8 จากนั้นเก็บเฉพาะข้อมูลสรุป (Statistics summary) ของแต่ละกลุ่มย่อย (Sub-clusters) และกลุ่มใหญ่ (Clusters) ได้แก่ จำนวนของข้อมูลภายในกลุ่ม จุดศูนย์กลางของกลุ่ม ส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่น เป็นต้น สามารถคำนวณได้จากสมการที่ (2.9) ถึง (2.16)



ภาพที่ 2-8 ขั้นตอนการแบ่งกลุ่มข้อมูลแต่ละกิจกรรมออกเป็นกลุ่มย่อยตามจำนวนกลุ่มที่กำหนด

การหาค่าศูนย์กลางมวลของกลุ่มย่อย (Sub-clusters)

$$Centroid_k = \frac{\sum_{i=1}^m P_i}{Weight_k} \quad (2.9)$$

โดยที่ $Centroid_k$ คือ จุดศูนย์กลางของข้อมูลกลุ่มย่อยที่ k

$Weight_k$ คือ จำนวนข้อมูลทั้งหมดภายในกลุ่มย่อยที่ k

P_i คือ ข้อมูลตัวอย่างที่ i ($i = 1, 2, 3, \dots, m$) ซึ่งข้อมูล 1 ตัวอย่างประกอบด้วยคู่อันดับ 3 ค่า คือ ค่า Accelerometer แกน X, Y และ Z

m คือ จำนวนข้อมูลทั้งหมดภายในกลุ่มย่อย

k คือ ลำดับกลุ่มย่อย โดยที่ $k = 1, 2, 3, \dots, K$ ซึ่ง K คือจำนวนของกลุ่มย่อย

การหาค่าส่วนเบี่ยงเบนมาตรฐานภายในกลุ่มย่อย

$$WISCSD_k = \sqrt{\frac{\sum_{i=1}^m (EDistance(P_i, Centroid_k))^2}{Weight_k}} \quad (2.10)$$

โดยที่ $WISCSD_k$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานภายในกลุ่มย่อยที่ k

$Centroid_k$ คือ จุดศูนย์กลางข้อมูลของกลุ่มย่อยที่ k

$Weight_k$ คือ จำนวนข้อมูลทั้งหมดภายในกลุ่มย่อยที่ k

P_i คือ ข้อมูลตัวอย่างลำดับที่ i ($i = 1, 2, 3, \dots, m$) ซึ่งข้อมูล 1 ตัวอย่างประกอบด้วยคู่อันดับ 3 ค่า คือ ค่า Accelerometer แกน X, Y และ Z

m คือ จำนวนข้อมูลทั้งหมดภายในกลุ่มย่อย

k คือ ลำดับกลุ่มย่อย โดยที่ $k = 1, 2, 3, \dots, K$ ซึ่ง K คือจำนวนของกลุ่มย่อย

$EDistance(P_i, Centroid_k)$ คือ ฟังก์ชันหาระยะห่างระหว่างข้อมูล P_i และ $Centroid_k$ โดยใช้วิธีการ Euclidean distance

การหาค่าเฉลี่ยของระยะห่างระหว่างจุดศูนย์กลางข้อมูลและข้อมูลแต่ละตัวภายในกลุ่มย่อย

$$AvDist_k = \frac{\sum_{i=1}^m EDistance(P_i, Centroid_k)}{Weight_k} \quad (2.11)$$

โดยที่ $AvDist_k$ คือ ค่าเฉลี่ยของระยะห่างระหว่างจุดศูนย์กลางข้อมูลและข้อมูลแต่ละตัวภายในกลุ่มย่อยที่ k

$Centroid_k$ คือ จุดศูนย์กลางข้อมูลของกลุ่มย่อยที่ k

$Weight_k$ คือ จำนวนข้อมูลทั้งหมดภายในกลุ่มย่อยที่ k

P_i คือ ข้อมูลตัวอย่างลำดับที่ i ($i = 1, 2, 3, \dots, m$) ซึ่งข้อมูล 1 ตัวอย่างประกอบด้วยคู่อันดับ 3 ค่า คือ ค่า Accelerometer แกน X, Y และ Z

m คือ จำนวนข้อมูลทั้งหมดภายในกลุ่มย่อย

k คือ ลำดับกลุ่มย่อย โดยที่ $k = 1, 2, 3, \dots, K$ ซึ่ง K คือจำนวนของกลุ่มย่อย

$EDistance(P_i, Centroid_k)$ คือ ฟังก์ชันหาระยะห่างระหว่างข้อมูล P_i และ $Centroid_k$ โดยใช้วิธีการ Euclidean distance

การหาความหนาแน่นของข้อมูลภายในกลุ่มย่อย

$$Density_k = \frac{Weight_k}{Volume_k} \quad (2.12)$$

$$Volume_k = \frac{4}{3}\pi Radii_k^3 \quad (2.13)$$

- โดยที่ $Density_k$ คือ ค่าความหนาแน่นของข้อมูลภายในกลุ่มย่อยที่ k
 $Volume_k$ คือ พื้นที่ของข้อมูลกลุ่มย่อยที่ k
 $Weight_k$ คือ จำนวนข้อมูลทั้งหมดภายในกลุ่มย่อยที่ k
 $Radii_k$ คือ รัศมีของข้อมูลกลุ่มย่อยที่ k
 k คือ ลำดับกลุ่มย่อย โดยที่ $k = 1, 2, 3, \dots, K$ ซึ่ง K คือจำนวนของกลุ่มย่อย

การหาจุดศูนย์กลางข้อมูลของกลุ่มใหญ่ (Clusters)

$$Centroid_{act} = \frac{\sum_{i=1}^{Nsub_{act}} Centroid_k}{Nsub_{act}} \quad (2.14)$$

- โดยที่ $Centroid_{act}$ คือ จุดศูนย์กลางข้อมูลของกิจกรรม act
 $Centroid_k$ คือ จุดศูนย์กลางข้อมูลของกลุ่มย่อยที่ k ($k = 1, 2, 3, \dots, K$ ซึ่ง K คือจำนวนของกลุ่มย่อย)
 $Nsub_{act}$ คือ จำนวนกลุ่มย่อยภายในกิจกรรม act
 act คือ กิจกรรมที่พิจารณาได้แก่ *sitting, standing, walking, jogging* และ *stairs*

การหาค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูลกลุ่มใหญ่

$$WISCSD_{act} = \sqrt{\frac{\sum_{i=1}^m (EDistance(P_i, Centroid_{act}))^2}{Weight_{act}}} \quad (2.15)$$

- โดยที่ $WISCSD_{act}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูลกิจกรรม act
 $Centroid_{act}$ คือ จุดศูนย์กลางข้อมูลของกิจกรรม act

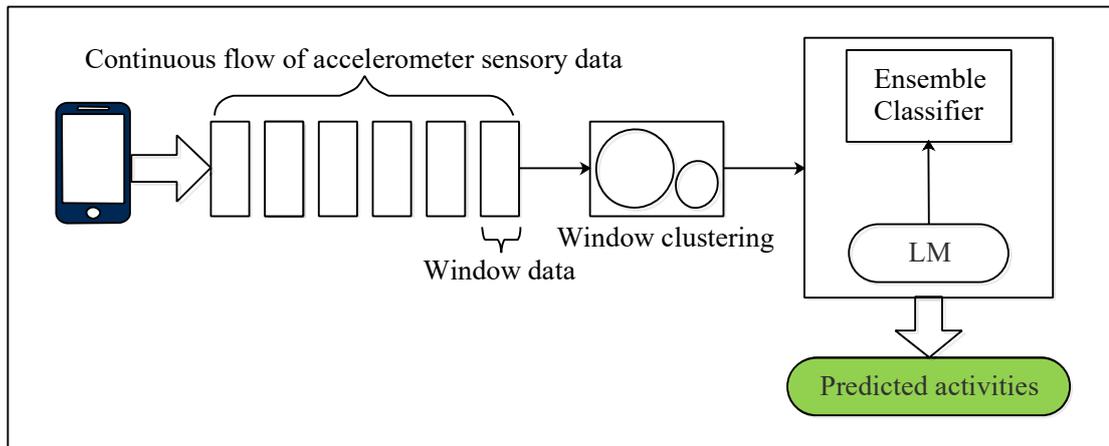
$Weight_{act}$	คือ จำนวนข้อมูลทั้งหมดภายในกิจกรรม act
P_i	คือ ข้อมูลตัวอย่างลำดับที่ i ($i = 1, 2, 3, \dots, m$) ซึ่งข้อมูล 1 ตัวอย่างประกอบด้วยคู่อันดับ 3 ค่า คือ ค่า Accelerometer แกน X, Y และ Z
m	คือ จำนวนข้อมูลทั้งหมดภายในกิจกรรม act
act	คือ กิจกรรมที่พิจารณาได้แก่ <i>sitting, standing, walking, jogging</i> และ <i>stairs</i>
$EDistance(P_i, Centroid_{act})$	คือ ฟังก์ชันหาระยะห่างระหว่างข้อมูล P_i และ $Centroid_{act}$ โดยใช้วิธีการ Euclidean distance

การหาค่าแรงดึงดูดที่กระทำต่อกันระหว่างกลุ่มย่อยแต่ละกลุ่มภายในกลุ่มใหญ่

$$GF_{ij} = G \frac{Weight_{k_i} Weight_{k_j}}{r^2} \quad (2.16)$$

โดยที่ GF_{ij}	คือ ค่าแรงดึงดูดที่กระทำต่อกันระหว่างกลุ่มย่อยแต่ละกลุ่มในหนึ่งกิจกรรม
$Weight_{k_i}$	คือ จำนวนข้อมูลภายในกลุ่มย่อยที่ k_i
$Weight_{k_j}$	คือ จำนวนข้อมูลภายในกลุ่มย่อยที่ k_j
r	คือ ระยะห่างระหว่างจุดศูนย์กลางกลุ่มย่อยที่พิจารณา

ส่วนที่สองเป็นส่วนของการรู้จำกิจกรรมและการปรับตัวแบบ ซึ่งวิธีการ STAR สามารถประมวลผลบนสมาร์ตโฟนโดยข้อมูลกระแสจากตัวรับรู้จะถูกนำเข้ามาประมวลผลทีละ 1 window แสดงดังภาพที่ 2-9 ขนาดของ window จะถูกกำหนดด้วยอัตราการสุ่มตัวอย่างของข้อมูลกิจกรรมนั้น ๆ จากนั้นจะทำการแบ่งกลุ่มข้อมูลภายใน window ออกเป็น 2 กลุ่มด้วยเทคนิควิธีการแบ่งกลุ่มข้อมูลแบบ K-mean หรือ Gaussian Mixture Model ก็ได้ แล้วนำข้อมูลของกลุ่มที่มีขนาดใหญ่ที่สุดไปจำแนกประเภทกิจกรรมด้วยมาตรวัด (Ensemble classification) ซึ่งประกอบด้วยมาตรวัด Distance, Gravity, Density และ Deviation แต่ละมาตรวัดรายละเอียดการจำแนกกิจกรรมดังนี้



ภาพที่ 2-9 ขั้นตอนการรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาของวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR)

- **มาตรวัด Distance** จะจำแนกกิจกรรมโดยใช้ระยะห่างของจุดศูนย์กลางข้อมูลที่เข้ามาใหม่ ($Centroid_{c_{new}}$) กับจุดศูนย์กลางข้อมูลกลุ่มย่อย ($Centroid_{sc}$) ที่ได้จากขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม โดยมาตรวัด Distance จะระบุเป็นกิจกรรมของกลุ่มย่อยที่มีระยะห่างน้อยที่สุด

- **มาตรวัด Gravity** จะจำแนกกิจกรรมโดยใช้แรงดึงดูดที่กระทำระหว่างกลุ่มข้อมูลที่เข้ามาใหม่กับข้อมูลของกลุ่มย่อยแต่ละกลุ่มที่ได้จากขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม สามารถคำนวณได้จากสมการที่ (2.12) โดยมาตรวัด Gravity จะระบุเป็นกิจกรรมของกลุ่มย่อยที่มีแรงดึงดูดมากที่สุด

- **มาตรวัด Density** จะจำแนกกิจกรรมโดยการนำข้อมูลที่เข้ามาใหม่ไปคำนวณค่าความหนาแน่น ซึ่งคำนวณโดยนำไปรวมกับค่าความหนาแน่นของกลุ่มย่อยแต่ละกลุ่มที่ได้ในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม มาตรวัด Density จะระบุเป็นกิจกรรมของกลุ่มย่อยที่เมื่อคำนวณความหนาแน่นรวมกับข้อมูลใหม่แล้วมีค่าเปลี่ยนไปน้อยที่สุด

- **มาตรวัด Deviation** จะจำแนกกิจกรรมโดยการนำข้อมูลที่เข้ามาใหม่ไปคำนวณค่าส่วนเบี่ยงเบนมาตรฐาน ซึ่งคำนวณโดยนำไปรวมกับค่าส่วนเบี่ยงเบนมาตรฐานของกลุ่มย่อยแต่ละกลุ่มที่ได้ในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม มาตรวัด Deviation จะระบุเป็นกิจกรรมของกลุ่มย่อยที่เมื่อคำนวณส่วนเบี่ยงเบนมาตรฐานรวมกับข้อมูลใหม่แล้วมีค่าเปลี่ยนไปน้อยที่สุด

เมื่อมาตรวัดทุกตัวระบุกิจกรรมเสร็จแล้วจะนำผลที่ได้มาประเมินหาค่าความเชื่อมั่นเพื่อทำนายกิจกรรม มีรายละเอียดดังตารางที่ 2-3 ถ้ามีระดับความเชื่อมั่นเท่ากับ 75% หรือ 100% จะทำนายกิจกรรมตามที่มาตรวัดส่วนใหญ่ระบุ ถ้าระดับความเชื่อมั่นเท่ากับ 50% โดยที่มาตรวัด 2 ใน 4 ระบุเป็นกิจกรรมเดียวกัน ส่วนมาตรวัดอีก 2 ตัวที่เหลือก็ระบุเป็นกิจกรรมที่แตกต่างกัน จะทำนาย

เป็นกิจกรรมที่มาตรวัด 2 ตัวระบุตรงกัน และจะทำการปรับปรุงตัวแบบรู้จำกิจกรรมโดยใช้วิธีการ Incremental learning โดยทำการปรับค่าสรุปของกลุ่มย่อยกิจกรรมที่ทำนายได้กับข้อมูลที่เข้ามาใหม่ แต่ถ้าระดับความเชื่อมั่นเท่ากับ 25% หรือ 50% โดยที่มาตรวัด 2 ใน 4 ระบุเป็นกิจกรรมเดียวกัน ส่วนมาตรวัดอีก 2 ตัวที่เหลือก็ระบุเป็นกิจกรรมเดียวกันแต่คนละกิจกรรมกับ 2 มาตรวัดก่อนหน้า ทำให้วิธีการ ISAT ไม่สามารถทำนายกิจกรรมได้ในทันทีจำเป็นต้องทำ Active learning โดยจะให้ผู้ใช้เป็นคนระบุกิจกรรมที่กำลังทำ ณ ขณะนั้น จากนั้นจะทำการปรับค่าสรุปของกลุ่มย่อยกับข้อมูลที่เข้ามาใหม่

ตารางที่ 2-3 การประเมินระดับความเชื่อมั่นที่ได้จากมาตรวัดของวิธีการ STAR

ระดับความ เชื่อมั่น (%)	รายละเอียด	การตัดสินใจของตัว แบบรู้จำกิจกรรม	การปรับปรุงตัว แบบรู้จำกิจกรรม
25	มาตรวัดแต่ละตัวจะระบุกิจกรรมที่ แตกต่างกัน	ไม่สามารถทำนาย กิจกรรมได้ ต้องให้ผู้ ใช้ระบุกิจกรรม	Active
50	มาตรวัด 2 ใน 4 ระบุเป็นกิจกรรม เดียวกัน ส่วนมาตรวัด 2 ตัวที่ เหลือก็ระบุเป็นกิจกรรมเดียวกัน	ส่งทั้ง 2 กิจกรรมไปให้ ผู้ใช้ระบุกิจกรรม	Active
50	มาตรวัด 2 ใน 4 ระบุเป็นกิจกรรม เดียวกัน ส่วนมาตรวัด 2 ตัวที่ เหลือก็ระบุเป็นกิจกรรมที่แตกต่าง กัน	ทำนายเป็นกิจกรรมที่ มาตรวัด 2 ใน 4 ระบุ เป็นกิจกรรมเดียวกัน	Incremental
75	มาตรวัด 3 ใน 4 ระบุกิจกรรม เดียวกัน	ทำนายเป็นกิจกรรม ที่มาตรวัด 3 ใน 4 ระบุ	ไม่ต้องปรับปรุงตัว แบบรู้จำกิจกรรม
100	มาตรวัดทั้ง 4 ระบุกิจกรรม เดียวกัน	ทำนายเป็นกิจกรรม ที่มาตรวัดทั้ง 4 ระบุ	ไม่ต้องปรับปรุงตัว แบบรู้จำกิจกรรม

บทที่ 3

วิธีการที่นำเสนอ

วิทยานิพนธ์นี้ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมที่มีชื่อว่า “Impersonal smartphone-based activity recognition using the accelerometer sensory data” เรียกโดยย่อว่า “ISAR” ซึ่งเป็นตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model) ที่สามารถรู้จำกิจกรรมกับข้อมูลกระแสวิงเวลาจาก Accelerometer sensor ของอุปกรณ์สมาร์ตโฟน โดยมุ่งเน้นการรู้จำกิจกรรมทางกายภาพ ได้แก่ การยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได เป็นต้น และวิธีการ “An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data” เรียกโดยย่อว่า “ISAR+” ซึ่งเป็นวิธีการรู้จำกิจกรรมที่พัฒนาต่อยอดมาจากวิธีการ ISAR โดยวิธีการ ISAR+ สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้

3.1 การศึกษาและวิเคราะห์ข้อมูลสำหรับสร้างตัวแบบรู้จำกิจกรรม

3.1.1 ข้อมูลกิจกรรม

- ข้อมูล WISDM¹¹ ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 36 คน ด้วยการใช้แอปพลิเคชันที่สามารถตรวจจับค่า Accelerometer ของอุปกรณ์สมาร์ตโฟน โดยให้อาสาสมัครทั้ง 36 คน ใส่อุปกรณ์สมาร์ตโฟนไว้ในกระเป๋ากางเกงด้านหน้า ซึ่งตั้งค่าอัตราสุ่มตัวอย่างของข้อมูลเท่ากับ 20 Hz และทำกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรม ได้แก่ การนั่ง การยืน การเดิน การวิ่ง และการขึ้นลงบันได ตัวข้อมูลประกอบด้วย รหัสผู้ใช้ กิจกรรมที่ผู้ใช้ทำ เวลาที่ผู้ใช้ทำกิจกรรม และค่า Accelerometer ตามแนวแกน X, Y และ Z โดยเรียก ax , ay และ az ตามลำดับ ตัวอย่างข้อมูลดังภาพที่ 3-1

¹¹ <http://www.cis.fordham.edu/wisdm>

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
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	27	Walking	\vdots	ax_i	ay_i	az_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	27	Walking	\vdots	ax_N	ay_N	az_N

ภาพที่ 3-1 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 27 จากข้อมูล WISDM

• ข้อมูล UniMiB-SHAR¹² ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 30 คน ด้วยการใช้แอปพลิเคชันที่สามารถตรวจจับค่า Accelerometer ของอุปกรณ์สมาร์ทโฟน โดยให้อาสาสมัครทั้ง 30 คน ใส่อุปกรณ์สมาร์ทโฟนไว้ในกระเป๋ากางเกงด้านหน้า ซึ่งตั้งค่าอัตราสุ่มตัวอย่างของข้อมูลเท่ากับ 50 Hz และทำกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรม ได้แก่ การนั่ง การยืน การเดิน การวิ่ง และการขึ้นลงบันได ตัวข้อมูลประกอบด้วย รหัสผู้ใช้ กิจกรรมที่ผู้ใช้ทำ และค่า Accelerometer ตามแนวแกน X, Y และ Z โดยเรียก ax , ay และ az ตามลำดับ ตัวอย่างข้อมูลดังภาพที่ 3-2

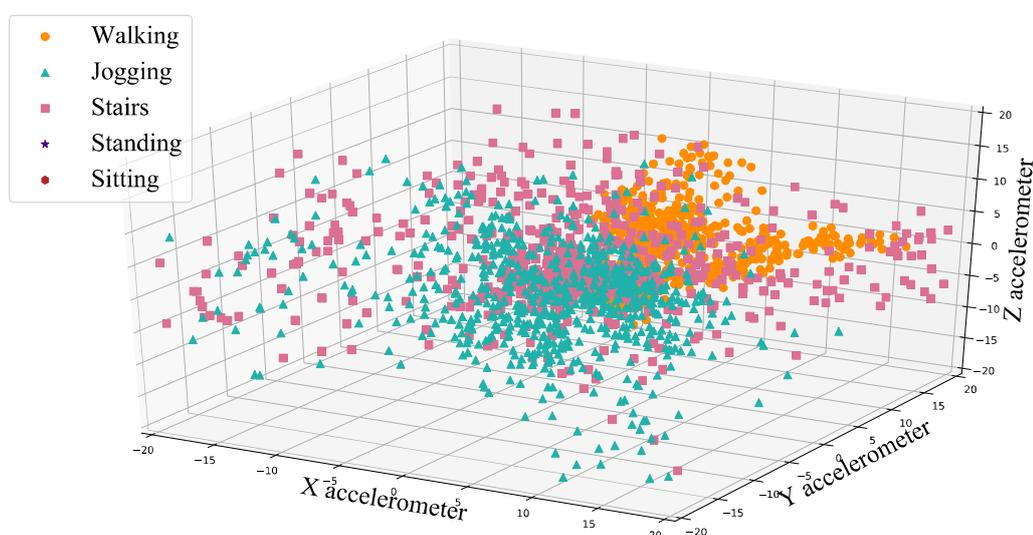
Sample	User	Lable	ax	ay	az
s_1	13	Standing	-1.88	9.85	-0.23
s_2	13	Standing	-0.19	9.92	-0.57
s_3	13	Standing	-0.61	10.27	-0.88
s_4	13	Standing	-0.11	9.58	2.49
s_5	13	Standing	-0.72	9.89	2.41
s_6	13	Standing	-0.53	9.34	2.49
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	13	Standing	ax_i	ay_i	az_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	13	Standing	ax_N	ay_N	az_N

ภาพที่ 3-2 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 13 จากข้อมูล UniMiB-SHAR

¹² <http://www.sal.disco.unimib.it/technologies/unimib-shar>

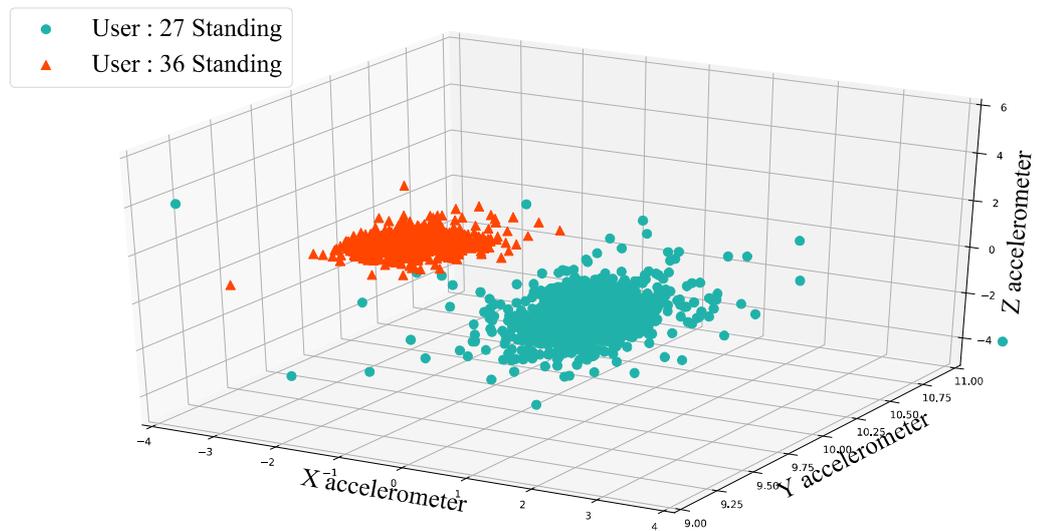
3.1.2 วิเคราะห์ข้อมูลกิจกรรม

วิทยานิพนธ์นี้ได้ศึกษาและวิเคราะห์ข้อมูลกิจกรรมที่ได้รวบรวมมา เพื่อให้เข้าใจลักษณะของข้อมูลกิจกรรมมากยิ่งขึ้น โดยได้นำข้อมูลกิจกรรมแต่ละกิจกรรมมาแสดงด้วยแผนภูมิกระจาย ดังภาพที่ 3-3 จะเห็นว่าข้อมูลกิจกรรมแต่ละกิจกรรมมีการกระจายตัวและทับซ้อนกัน ข้อมูลกิจกรรมการยืนและการนั่งไม่สามารถมองเห็นได้ เนื่องจากโดนข้อมูลของกิจกรรมการเดิน การวิ่ง และการขึ้นลงบันไดซ้อนทับอยู่ ซึ่งทำให้การจำแนกกิจกรรมจากข้อมูลลักษณะนี้เป็นเรื่องยากและอาจเกิดความผิดพลาดได้ง่าย



ภาพที่ 3-3 แผนภูมิกระจายของข้อมูลกิจกรรมการยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได

นอกจากนี้ยังได้ทดลองเปรียบเทียบข้อมูลกิจกรรมของผู้ใช้หมายเลข 27 และ 36 จากข้อมูล WISDM ซึ่งเป็นข้อมูลที่ใช้ในงานวิจัย Adaptive mobile activity recognition system with evolving data streams (Abdallah และคณะ, 2015) ดังภาพที่ 3-4 ซึ่งเมื่อพิจารณาข้อมูลกิจกรรมที่แสดงจะเห็นว่าค่า Accelerometer กิจกรรมการยืนของผู้ใช้ทั้งสองคนอยู่แยกกลุ่มกันอย่างชัดเจน ทำให้เกิดประเด็นสงสัยว่าทำไมข้อมูลกิจกรรมประเภทเดียวกัน ถึงได้มีลักษณะที่แตกต่างกันเช่นนี้ ดังนั้นเพื่อหาสาเหตุหรือปัจจัยที่ทำให้ข้อมูลการทำกิจกรรมของผู้ใช้แต่ละคนแตกต่างกัน จึงได้ออกแบบการทดลองโดยจะทำการเก็บข้อมูลกิจกรรมด้วยตัวเอง ซึ่งมีรายละเอียดการทดลองดังต่อไปนี้



ภาพที่ 3-4 แผนภูมิกระจายของข้อมูลกิจกรรมการยืน ผู้ใช้หมายเลข 27 และ ผู้ใช้หมายเลข 36 จากข้อมูล WISDM

- **ขอบเขตสำหรับการทดลอง**

- 1) **กิจกรรม**

- 1.1) การเดิน (Walking)
- 1.2) การยืน (Standing)
- 1.3) การนั่ง (Sitting)
- 1.4) การวิ่ง (Jogging)
- 1.5) การขึ้นลงบันได (Walking)

- 2) **สถานที่**

- 2.1) บริเวณทางเดินชั้น 5 อาคารสิรินธร มหาวิทยาลัยบูรพา
- 2.2) บริเวณทางเดินหลังอาคาร Central Laboratory มหาวิทยาลัยบูรพา

- 3) **อุปกรณ์**

- 3.1) iPhone 5s

- 4) **ตัวรับรู้**

- 4.1) Accelerometer sensor

5) ตำแหน่งและลักษณะการสวมใส่อุปกรณ์ โดยใส่ในกระเป๋ากางเกงด้านหน้า ซึ่งมีลักษณะการสวมใส่อุปกรณ์ ดังนี้

- 5.1) หน้าหน้า – หัวตั้ง
- 5.3) หน้าหน้า – หัวกลับ
- 5.4) หน้าหลัง – หัวตั้ง
- 5.5) หน้าหลัง – หัวกลับ

6) รายละเอียดผู้เข้าร่วมการทดลอง การเก็บข้อมูลกิจกรรมมีผู้เข้าร่วม 10 คน โดยมีช่วงอายุ 20 – 27 ปี แบ่งเป็นชาย 6 คน และหญิง 4 คน

7) ขั้นตอนการทดลอง

7.1) ประเด็นสงสัย

7.1.1) ทำไมผู้ใช้แต่ละคนทำกิจกรรมประเภทเดียวกัน แต่กลับมีลักษณะข้อมูลที่แตกต่างกันได้ (ดังตัวอย่างภาพที่ 3-4)

7.2) สมมติฐาน

7.2.1) สถานที่การทำกิจกรรมที่แตกต่างกันอาจส่งผลให้ข้อมูลกิจกรรมแตกต่างกัน

7.2.2) ลักษณะการสวมใส่อุปกรณ์ที่แตกต่างกันอาจส่งผลให้ข้อมูลกิจกรรมแตกต่างกัน

7.3) ตรวจสอบสมมติฐาน

สมมติฐานที่ 1 สถานที่การทำกิจกรรมที่แตกต่างกันอาจส่งผลให้ข้อมูลกิจกรรมแตกต่างกัน

(1) ตัวแปรต้น คือ สถานที่สำหรับเก็บข้อมูลกิจกรรม

(2) ตัวแปรตาม คือ ข้อมูลกิจกรรม

(3) ตัวแปรควบคุม คือ รูปแบบการทำกิจกรรม เวลาที่ใช้ในการทำกิจกรรม อุปกรณ์ที่ใช้เก็บข้อมูลกิจกรรม ตำแหน่งการสวมใส่อุปกรณ์

ปฏิบัติการทดลองที่ 1 สถานที่สำหรับใช้ในการเก็บข้อมูลกิจกรรมมี 2 ที่ได้แก่ บริเวณทางเดินชั้น 5 อาคารสิรินธร และบริเวณทางเดินหลังอาคาร Central Laboratory มหาวิทยาลัยบูรพา ทั้ง 2 สถานที่จะมีขั้นตอนการเก็บข้อมูลเหมือนกัน นั่นคือ ผู้เข้าร่วมการทดลองจะต้องสวมใส่อุปกรณ์สมาร์ตโฟนสำหรับเก็บข้อมูลกิจกรรมไว้ที่กระเป๋ากางเกงด้านหน้าข้างขวา ให้ผู้เข้าร่วมการทดลองทำกิจกรรมทั้งหมด 5 กิจกรรม ได้แก่ การยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได แต่ละกิจกรรมใช้เวลา 10 นาที

สมมติฐานที่ 2 ลักษณะของการสวมใส่อุปกรณ์ที่ต่างกันอาจส่งผลให้ข้อมูลกิจกรรมแตกต่างกัน

- (1) ตัวแปรต้น คือ ลักษณะการสวมใส่อุปกรณ์
- (2) ตัวแปรตาม คือ ข้อมูลกิจกรรม
- (3) ตัวแปรควบคุม คือ รูปแบบการทำกิจกรรม เวลาที่ใช้ในการทำกิจกรรม อุปกรณ์ที่ใช้เก็บข้อมูลกิจกรรม ตำแหน่งการสวมใส่อุปกรณ์

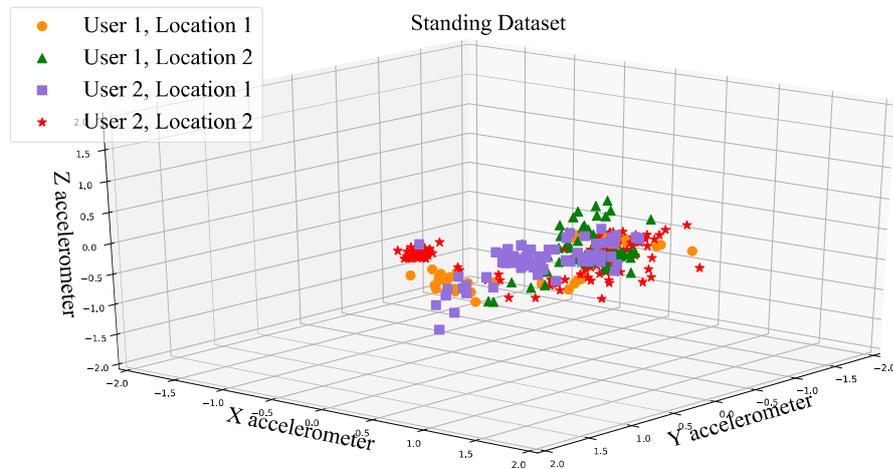
ปฏิบัติการทดลองที่ 2 ลักษณะการสวมใส่อุปกรณ์มี 4 แบบ ได้แก่

- (1) หน้าหน้า – หัวตั้ง
- (2) หน้าหน้า – หัวกลับ
- (3) หน้าหลัง – หัวตั้ง
- (4) หน้าหลัง – หัวกลับ

ผู้เข้าร่วมการทดลองจะต้องสวมใส่อุปกรณ์สมาร์ตโฟนสำหรับเก็บข้อมูลกิจกรรมไว้ที่กระเป๋ากางเกงด้านหน้าข้างขวา ให้ผู้เข้าร่วมการทดลองทำกิจกรรมทั้งหมด 5 กิจกรรม ได้แก่ การยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได แต่ละกิจกรรมใช้เวลา 10 นาที โดยแต่ละกิจกรรมจะมีการเก็บข้อมูลทั้งหมด 4 แบบ ตามลักษณะของการสวมใส่อุปกรณ์

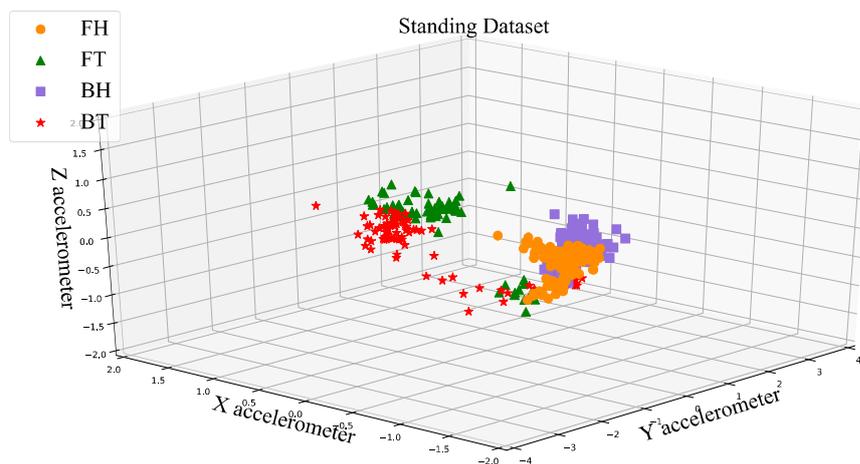
8) ผลการทดลอง

จากปฏิบัติการทดลองที่ 1 การทำกิจกรรมต่างสถานที่ นำข้อมูลของการทำกิจกรรมที่ต่างสถานที่มาแสดงด้วยแผนภูมิกระจายดังภาพที่ 3-5 โดยตัวอย่างเป็นการนำข้อมูลกิจกรรมการยืนของผู้ใช้สองคน ซึ่งผู้ใช้แต่ละคนได้เก็บข้อมูลการทำกิจกรรมในสองสถานที่ ได้แก่ บริเวณทางเดินชั้น 5 ของอาคารสิรินธร มหาวิทยาลัยบูรพา และบริเวณทางเดินหลังอาคาร Central Laboratory มหาวิทยาลัยบูรพา จะสังเกตเห็นว่าถึงแม้การทำกิจกรรมที่ต่างสถานที่ที่กันและมีระดับความสูงจากพื้นดินที่แตกต่างกันแต่ข้อมูลการทำกิจกรรมการยืนของผู้ใช้ทั้ง 2 คน กระจุกเป็นกลุ่มเดียวกัน (ได้ผลลัพธ์เช่นนี้ทุกกิจกรรม) สรุปก็คือการทำกิจกรรมแบบเดียวกัน ถึงจะทำในสถานที่ที่แตกต่างกันก็ไม่ทำให้ลักษณะของข้อมูลกิจกรรมแตกต่างกัน



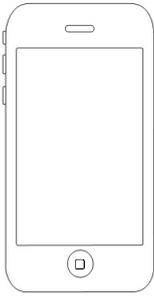
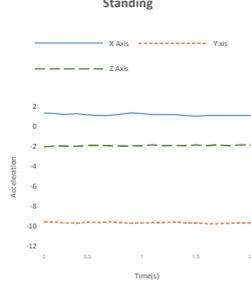
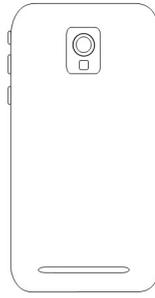
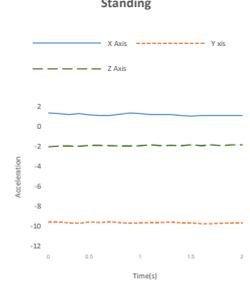
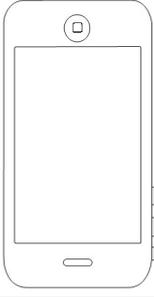
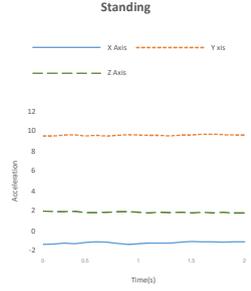
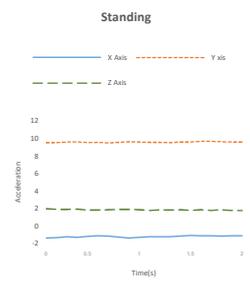
ภาพที่ 3-5 แผนภูมิกระจายของข้อมูลกิจกรรมการยืนที่ต่างสถานที่ของผู้ใช้ทั้งสองคน

จากปฏิบัติการทดลองที่ 2 ลักษณะการสวมใส่อุปกรณ์ที่ต่างกัน ข้อสงสัยที่ว่าลักษณะการสวมใส่อุปกรณ์ทำให้ได้ข้อมูลที่ต่างกันหรือไม่ จึงได้นำข้อมูลของกิจกรรมที่มีลักษณะการสวมใส่อุปกรณ์ที่ต่างกันมาแสดงด้วยแผนภูมิกระจายโดยมีข้อมูลตามลักษณะการสวมใส่อุปกรณ์ดังนี้ หันหน้า-หัวตั้ง (FH) หันหน้า-หัวกลับ (FT) หันหลัง-หัวตั้ง (BH) หันหลัง-หัวกลับ (BT) ตัวอย่างดังภาพที่ 3-6

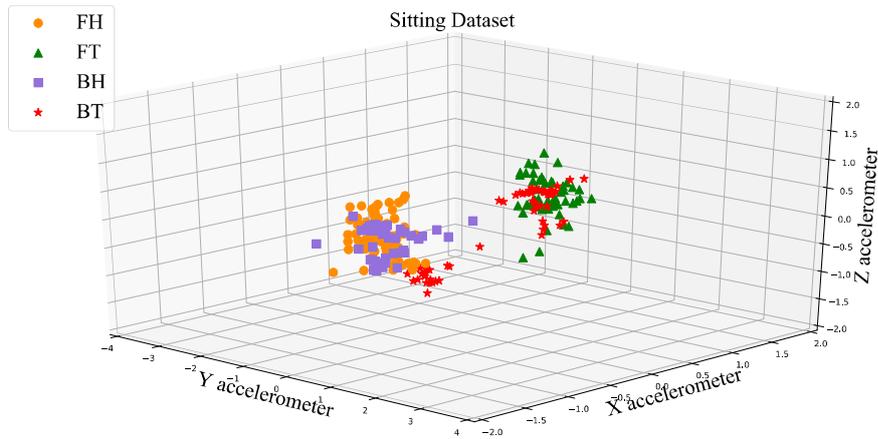


ภาพที่ 3-6 แผนภูมิกระจายของข้อมูลการยืนที่มีลักษณะการสวมใส่อุปกรณ์ต่างกัน

ตารางที่ 3-1 เปรียบเทียบข้อมูลกิจกรรมการยืนตามลักษณะการสวมใส่อุปกรณ์ โดยใช้แผนภูมิเส้น ข้อมูล Accelerometer

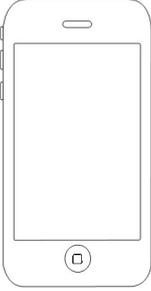
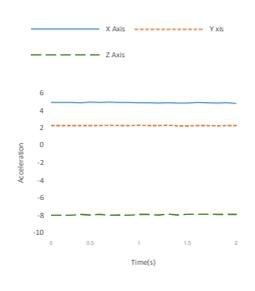
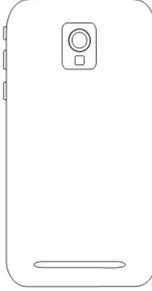
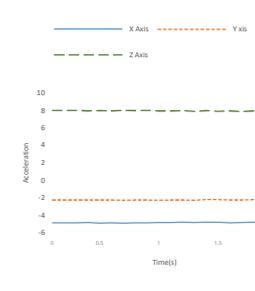
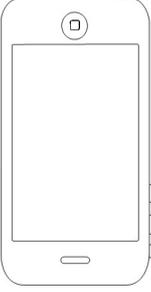
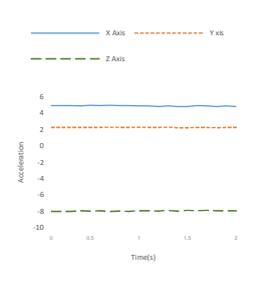
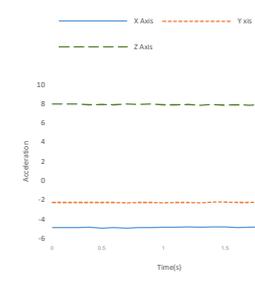
ลักษณะการสวมใส่อุปกรณ์	ลักษณะสัญญาณ	ลักษณะการสวมใส่อุปกรณ์	ลักษณะสัญญาณ
<p>หันหน้า-หัวตั้ง</p> 	<p>Standing</p> 	<p>หันหลัง-หัวตั้ง</p> 	<p>Standing</p> 
<p>หันหน้า-หัวกลับ</p> 	<p>Standing</p> 	<p>หันหลัง-หัวกลับ</p> 	<p>Standing</p> 

จากภาพที่ 3-6 และตาราง 3-1 จะสังเกตเห็นว่าข้อมูลการยืนแบ่งออกเป็น 2 กลุ่มอย่างชัดเจน กลุ่มแรกคือ **หันหน้า-หัวตั้ง (FH)** และ **หันหลัง-หัวตั้ง (BH)** ส่วนกลุ่มที่สอง คือ **หันหน้า-หัวกลับ (FT)** และ **หันหลัง-หัวกลับ (BT)** สรุปคือการสวมใส่อุปกรณ์ที่ต่างกันส่งผลให้ข้อมูลการยืนมีความแตกต่างกัน โดยความแตกต่างนี้เกิดจากค่า Accelerometer แกน Y เมื่อสวมใส่อุปกรณ์แบบหัวตั้ง ค่า Y จะมีค่าที่ต่ำ แต่ถ้าสวมใส่อุปกรณ์แบบหัวกลับ ค่า Y จะมีค่าสูง ทำให้ข้อมูลมีความแตกต่างกัน

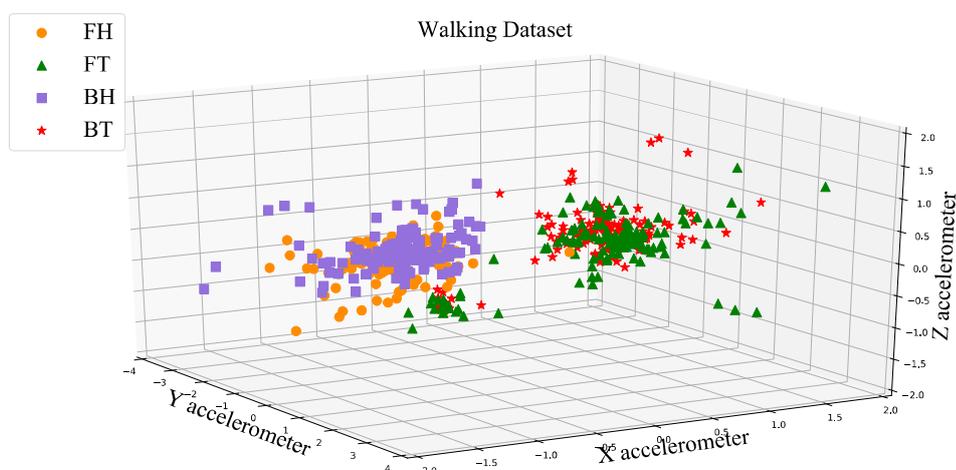


ภาพที่ 3-7 แผนภูมิกระจายของข้อมูลการนั่งที่มีลักษณะการสวมใส่อุปกรณ์ต่างกัน

ตารางที่ 3-2 เปรียบเทียบข้อมูลกิจกรรมการนั่งตามลักษณะการสวมใส่อุปกรณ์ โดยใช้แผนภูมิเส้น ข้อมูล Accelerometer

ลักษณะการสวมใส่อุปกรณ์	ลักษณะสัญญาณ	ลักษณะการสวมใส่อุปกรณ์	ลักษณะสัญญาณ
<p>หันหน้า-หัวตั้ง</p> 	<p>Sitting</p> 	<p>หันหลัง-หัวตั้ง</p> 	<p>Sitting</p> 
<p>หันหน้า-หัวกลับ</p> 	<p>Sitting</p> 	<p>หันหลัง-หัวกลับ</p> 	<p>Sitting</p> 

จากภาพที่ 3-7 และตาราง 3-2 จะสังเกตเห็นว่าข้อมูลการนั่งแบ่งออกเป็น 2 กลุ่มอย่างชัดเจน กลุ่มแรกคือ **หันหน้า-หัวตั้ง (FH)** และ **หันหน้า-หัวกลับ (FT)** ส่วนกลุ่มที่สองคือ **หันหลัง-หัวตั้ง (BH)** และ **หันหลัง-หัวกลับ (BT)** สรุปคือการสวมใส่อุปกรณ์ที่ต่างกันส่งผลให้ข้อมูลการนั่งมีความแตกต่างกัน โดยความแตกต่างนี้เกิดจากค่า Accelerometer แกน Z เมื่อสวมใส่อุปกรณ์แบบหันหน้า ค่า Z จะมีค่าที่ต่ำ แต่ถ้าสวมใส่อุปกรณ์แบบหันหลัง ค่า Z จะมีค่าสูง ทำให้ข้อมูลมีความแตกต่างกัน



ภาพที่ 3-8 แผนภูมิกระจายของข้อมูลการเดินที่มีลักษณะการสวมใส่อุปกรณ์ต่างกัน

จากภาพที่ 3-8 จะสังเกตเห็นว่าข้อมูลการเดินแบ่งออกเป็น 2 กลุ่มอย่างชัดเจน กลุ่มแรกคือ **หันหน้า-หัวตั้ง (FH)** และ **หันหลัง-หัวตั้ง (BH)** ส่วนกลุ่มที่สองคือ **หันหน้า-หัวกลับ (FT)** และ **หันหลัง-หัวกลับ (BT)** สรุปคือการสวมใส่อุปกรณ์ที่ต่างกันส่งผลให้ข้อมูลการเดินมีความแตกต่างกัน โดยความแตกต่างนี้เกิดจากค่า Accelerometer แกน Y เมื่อสวมใส่อุปกรณ์แบบหัวตั้ง ค่า Y จะมีค่าที่ต่ำ แต่ถ้าสวมใส่อุปกรณ์แบบหัวกลับ ค่า Y จะมีค่าสูง ทำให้ข้อมูลมีความแตกต่างกัน **ซึ่งข้อสรุปนี้ยังรวมถึงกิจกรรมการเดินขึ้นลงบันไดและการวิ่งอีกด้วย**

9) สรุปผลการทดลอง

จากการตั้งประเด็นสงสัยที่ว่า ทำไมการทำกิจกรรมเดียวกันถึงมีข้อมูลที่แตกต่างกัน จึงได้ตั้งสมมติฐาน 2 ข้อ คือ 1. สถานที่ในการทำกิจกรรมที่ต่างกันอาจส่งผลให้ข้อมูลกิจกรรมแตกต่างกัน 2. ลักษณะการสวมใส่อุปกรณ์ที่ต่างกันอาจส่งผลให้ข้อมูลกิจกรรมแตกต่างกัน จากนั้นได้ทำการทดลองเพื่อพิสูจน์สมมติฐาน และทำการวิเคราะห์ข้อมูลจากการทดลองจึงได้ข้อสรุปดังนี้

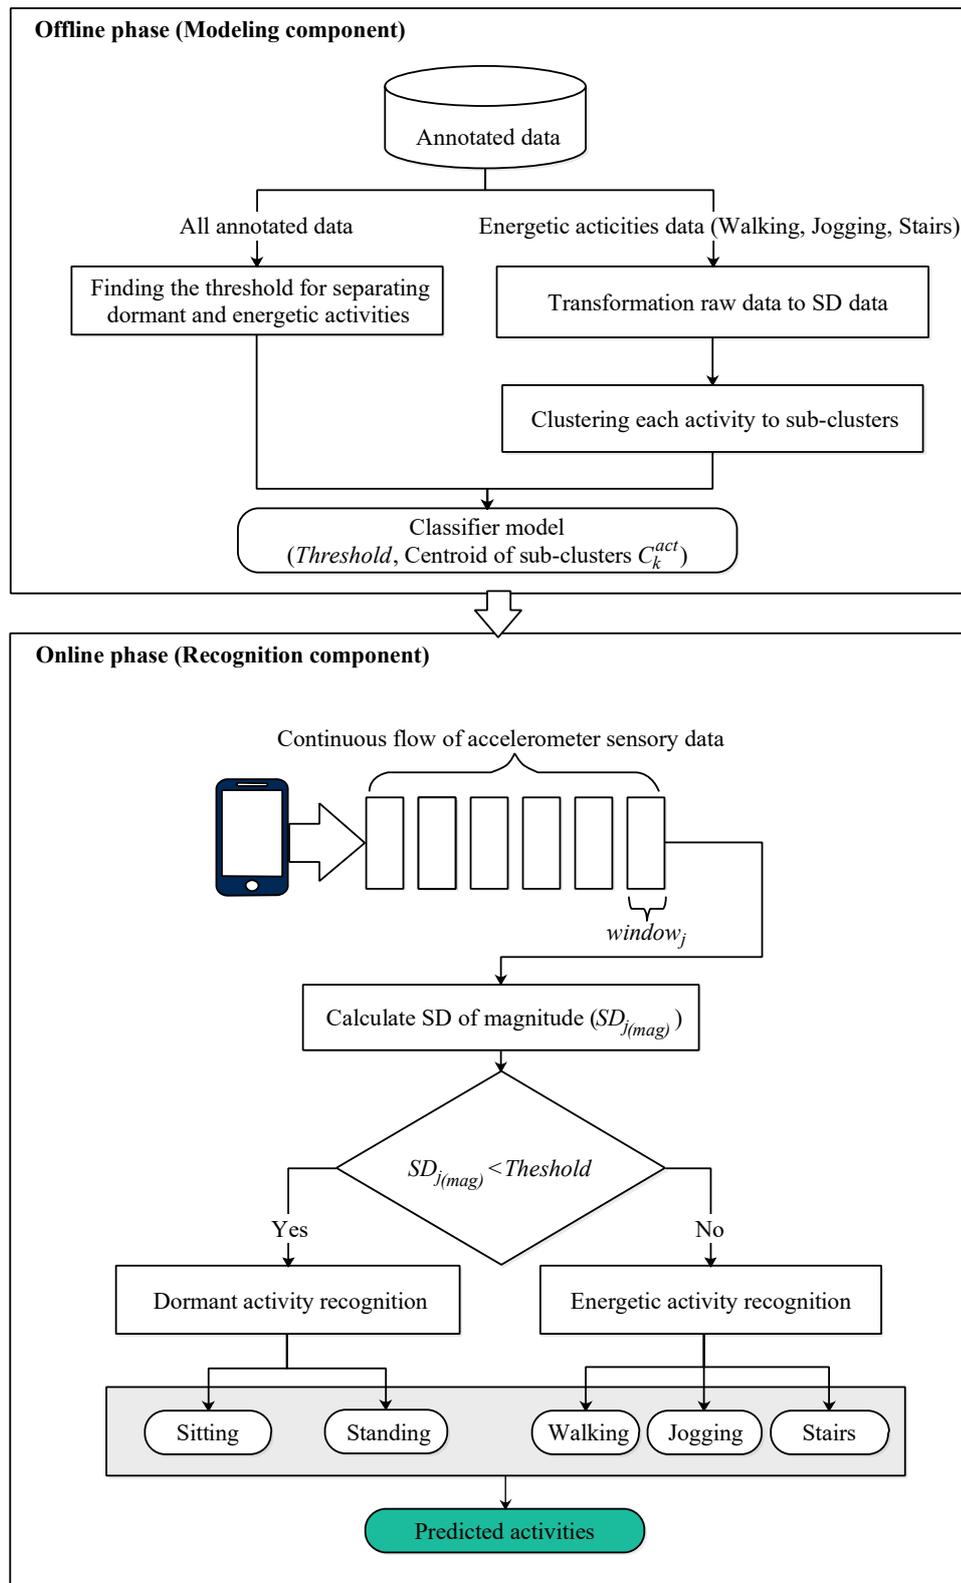
(1) การทำกิจกรรมแบบเดียวกันแต่มีข้อมูลกิจกรรมที่แตกต่างกัน นั้นเพราะว่ามีลักษณะการสวมใส่อุปกรณ์ที่แตกต่างกัน

(2) สถานที่ในการทำกิจกรรมไม่ส่งผลให้ข้อมูลกิจกรรมเปลี่ยนไป

จากขั้นตอนการวิเคราะห์ข้อมูลกิจกรรมจะเห็นว่า มีประเด็นที่น่าสนใจอยู่สองประเด็น ที่ส่งผลต่อความถูกต้องในการรู้จำกิจกรรม นั่นก็คือ การทับซ้อนของข้อมูลกิจกรรมและลักษณะการสวมใส่อุปกรณ์ ดังนั้นวิทยานิพนธ์นี้จึงได้พัฒนาตัวแบบรู้จำกิจกรรม โดยเน้นวิธีการที่จะช่วยลดความทับซ้อนของข้อมูลกิจกรรม และสร้างตัวแบบรู้จำกิจกรรมที่มีความยืดหยุ่นกับลักษณะการสวมใส่อุปกรณ์ทุกแบบ เพื่อให้ตัวแบบรู้จำกิจกรรมสามารถจำแนกกิจกรรมได้ถูกต้องมากขึ้น โดยตัวแบบนี้มีชื่อว่า “Impersonal smartphone-based activity recognition using the accelerometer sensory data” เรียกโดยย่อว่า “ISAR” โดยมีรายละเอียดดังในขั้นตอนถัดไป

3.2 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (ISAR)

สำหรับขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมประกอบไปด้วย ขั้นตอนออฟไลน์สำหรับสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนออนไลน์สำหรับรู้จำกิจกรรม โดยวิทยานิพนธ์นี้ได้สนใจการรู้จำกิจกรรมทางกายภาพ ได้แก่ การเดิน การนั่ง การยืน การวิ่ง และการขึ้นลงบันได เนื่องจากเป็นกิจกรรมพื้นฐานของมนุษย์ และแบ่งประเภทของกิจกรรมออกเป็น 2 กลุ่ม กลุ่มแรกเป็นกิจกรรมที่มีการเคลื่อนไหวร่างกายเล็กน้อยหรือแทบไม่เคลื่อนไหวเลย ได้แก่ การยืนและการนั่ง เรียกกิจกรรมกลุ่มนี้ว่า “กิจกรรมแบบนิ่ง (Dormant activities)” กลุ่มที่สองเป็นกิจกรรมที่เคลื่อนไหวร่างกายค่อนข้างมากหรือการขยับร่างกายอย่างรวดเร็ว ได้แก่ การเดิน การวิ่ง และการขึ้นลงบันได เรียกกิจกรรมนี้ว่า “กิจกรรมแบบเคลื่อนไหว (Energetic activities)” ซึ่งมีกรอบแนวคิดดังภาพที่ 3-9

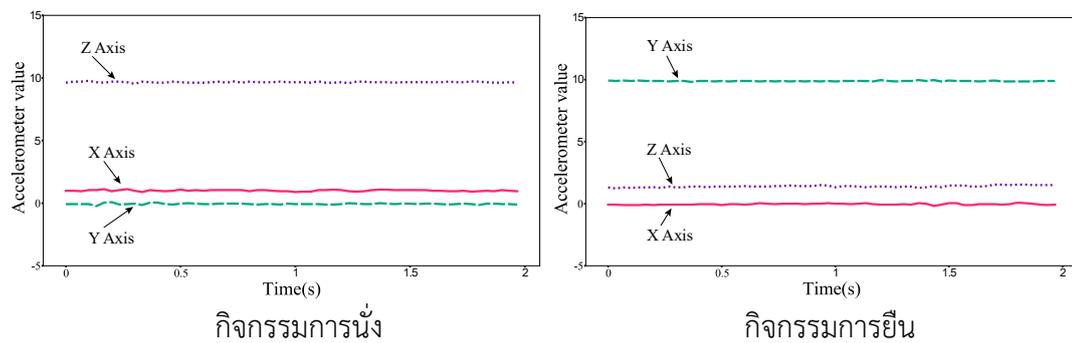


ภาพที่ 3-9 ภาพรวมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

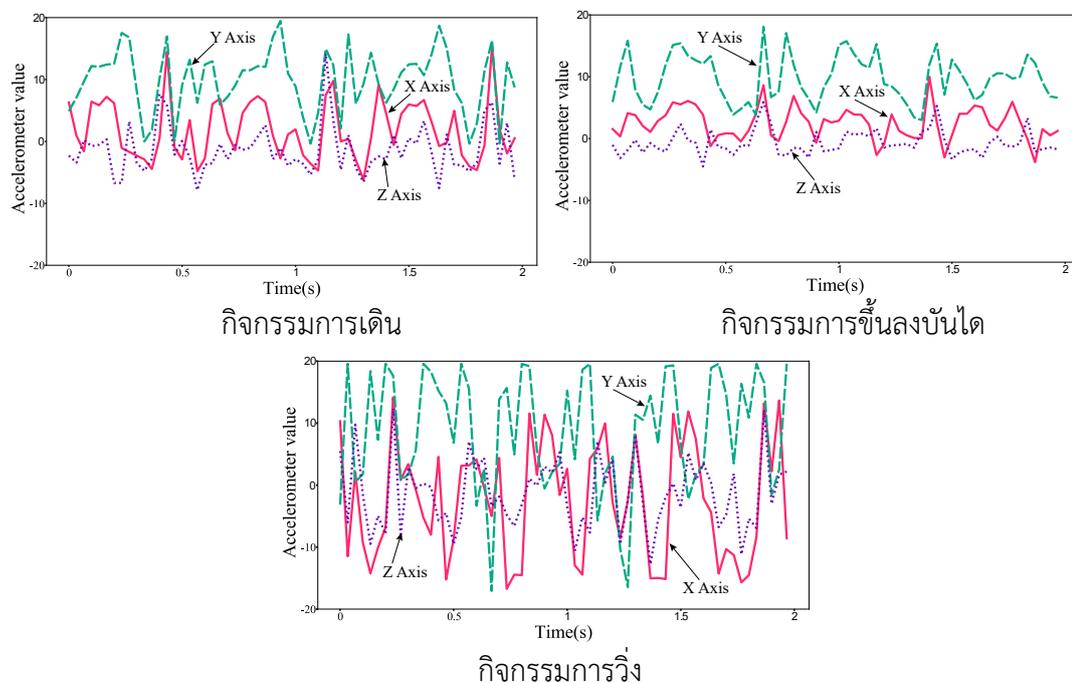
3.2.1 ISAR ชั้นตอนออฟไลน์ (Modeling)

ในขั้นตอนออฟไลน์จะเป็นการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ทราบว่าเป็นกิจกรรมประเภทใด (Annotated data) มีขั้นตอนดังนี้

- ขั้นตอนการหาค่า Threshold สำหรับแยกประเภทกิจกรรม (Finding the threshold for separating dormant and energetic activities) โดยได้แบ่งกลุ่มกิจกรรมเป็นสองกลุ่ม ได้แก่ กลุ่มกิจกรรมแบบนิ่งและกลุ่มกิจกรรมแบบเคลื่อนไหว ดังภาพที่ 3-10 และ 3-11



ภาพที่ 3-10 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบนิ่ง



ภาพที่ 3-11 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบเคลื่อนไหว

จากภาพที่ 3-10 และ 3-11 จะเห็นว่าลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมทั้งสองกลุ่มมีความแตกต่างกันอย่างชัดเจนดังนี้ **กิจกรรมแบบเคลื่อนไหว** ได้แก่ การเดิน การวิ่ง และการขึ้นลงบันได เส้นข้อมูลจะแกว่งไปมาเนื่องจากข้อมูลของกิจกรรมกลุ่มนี้มีค่าแตกต่างกันมาก ข้อมูลจึงมีการกระจายตัวที่สูง แต่**กิจกรรมแบบนั่ง** ได้แก่ การนั่งและการยืน เส้นข้อมูลจะแกว่งน้อยมากหรือเกือบคงที่ เนื่องจากข้อมูลกิจกรรมกลุ่มนี้มีค่าใกล้เคียงกัน ข้อมูลจึงมีการกระจายตัวต่ำ ดังนั้นการหาค่าขีดแบ่ง (Threshold) สำหรับแบ่งกิจกรรมแบบเคลื่อนไหวและแบบนั่ง จึงได้นำส่วนเบี่ยงเบนมาตรฐานเข้ามาช่วยในการแบ่งข้อมูลกิจกรรมทั้งสองกลุ่ม เนื่องจากส่วนเบี่ยงเบนมาตรฐานสามารถวิเคราะห์การกระจายตัวของข้อมูลได้อย่างดี โดยมีวิธีการหาค่าขีดแบ่งดังสมการที่ (3.1) ถึง (3.4)

$$M_i = \sqrt{ax_i^2 + ay_i^2 + az_i^2} \quad (3.1)$$

โดยที่ M_i คือ ค่า Magnitude ที่ i ($i = 1, 2, 3, \dots, N$ เมื่อ N คือ จำนวนตัวอย่างของหนึ่งกิจกรรม) ตัวอย่างดังภาพที่ 3-12

ax_i คือ ค่า Accelerometer ตามแนวแกน X ที่ i

ay_i คือ ค่า Accelerometer ตามแนวแกน Y ที่ i

az_i คือ ค่า Accelerometer ตามแนวแกน Z ที่ i

Sample	Lable	Timestamp	ax	ay	az	Magnitude
s_1	Sitting	14824292218000	-4.99	-2.26	7.88	15.13
s_2	Sitting	14824342298000	-4.99	-2.30	7.96	15.25
s_3	Sitting	14824392255000	-5.01	-2.30	8.01	15.32
s_4	Sitting	14824442273000	-5.01	-2.34	7.88	15.24
s_5	Sitting	14824492170000	-5.01	-2.30	7.89	15.20
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Sitting	\vdots	ax_i	ay_i	az_i	M_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_{20}	Sitting	\vdots	ax_{20}	ay_{20}	az_{20}	M_{20}
s_{21}	Sitting	\vdots	ax_{21}	ay_{21}	az_{21}	M_{21}
s_{22}	Sitting	\vdots	ax_{22}	ay_{22}	az_{22}	M_{22}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	Sitting	\vdots	ax_N	ay_N	az_N	M_N

} $window_{j=1}$

ภาพที่ 3-12 ตัวอย่างค่า Magnitude (M_i) ของข้อมูลกิจกรรม

$$SD_{j(mag)}^{act} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (M_i - \bar{M}_j)^2} \quad (3.2)$$

- โดยที่ $SD_{j(mag)}^{act}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของ Magnitude ภายใน window ที่ j
- M_i คือ ค่า Magnitude ที่ i ($i = 1, 2, 3, \dots, N$ เมื่อ N คือ จำนวนตัวอย่างของหนึ่งกิจกรรม)
- \bar{M}_j คือ ค่าเฉลี่ยของ Magnitude ของ window ที่ j
- N คือ ค่าจำนวนข้อมูลทั้งหมดของกิจกรรมที่กำลังพิจารณา
- j คือ ค่าที่ใช้สำหรับระบุลำดับของ window (ขนาด window จะเท่ากับขนาดอัตราสุ่มตั้งอย่างของข้อมูลนั้น)
- act คือ กิจกรรมที่กำลังพิจารณา

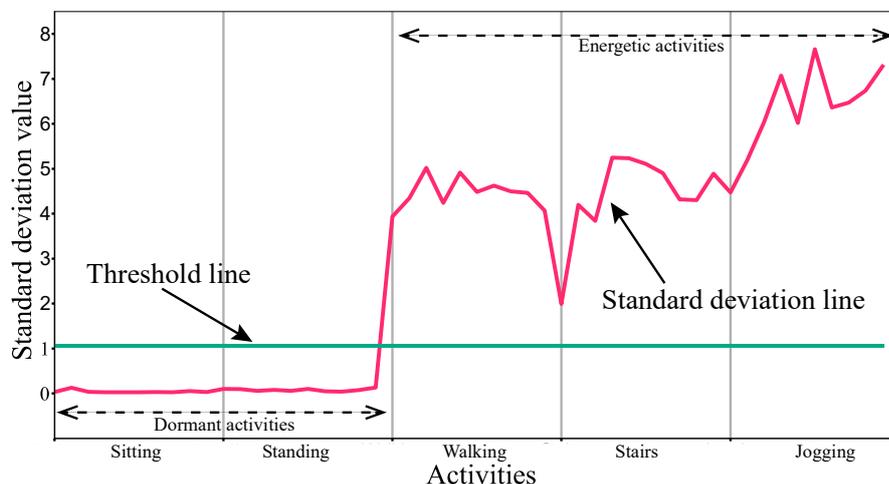
เมื่อคำนวณส่วนเบี่ยงเบนมาตรฐานครบทุกกิจกรรมแล้ว ให้นำค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มาหาค่าเฉลี่ยแต่ละกิจกรรม เพื่อคำนวณค่าขีดแบ่ง ดังสมการที่ (3.3) และ (3.4)

$$SD_{avg(mag)}^{act} = \frac{\sum_{j=1}^J SD_{j(mag)}^{act}}{J} \quad (3.3)$$

$$Threshold = \frac{SD_{max(mag)}^{dor} + SD_{min(mag)}^{ene}}{2} \quad (3.4)$$

- โดยที่ $SD_{avg(mag)}^{act}$ คือ ค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานของ Magnitude ในแต่ละ กิจกรรม ($act = sitting, standing, jogging, walking, stairs$)
- $Threshold$ คือ ค่าขีดแบ่ง สำหรับแบ่งประเภทกิจกรรม
- $SD_{max(mag)}^{dor}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานที่มากที่สุดของกิจกรรมแบบนั่ง พิจารณาจาก $SD_{avg(mag)}^{act}$ โดยที่ ($act = sitting, standing$)
- $SD_{min(mag)}^{ene}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานที่น้อยที่สุดของกิจกรรมแบบเคลื่อนไหว พิจารณาจาก $SD_{avg(mag)}^{act}$ โดยที่ ($act = walking, jogging, stairs$)
- J คือ จำนวน window ของข้อมูลหนึ่งกิจกรรม

เมื่อคำนวณตามสมการที่ (3.3) จะเห็นว่าค่าขีดแบ่งคือค่ากึ่งกลางที่สามารถแบ่งข้อมูลกิจกรรมทั้งสองกลุ่มได้ ดังภาพที่ 3-13



ภาพที่ 3-13 ตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมแบบเคลื่อนไหว (Energetic activities) และกิจกรรมแบบนิ่ง (Dormant activities) ออกจากกันได้

- ขั้นตอนการแปลงข้อมูลกิจกรรมด้วย SD (Transformation raw data to SD data) ข้อมูลกิจกรรมเมื่อนำมาแสดงเป็นแผนภูมิกระจาย ดังภาพที่ 3-13 จะเห็นว่าข้อมูลแต่ละกิจกรรมมีความทับซ้อนกันมาก ทำให้ยากในการจำแนกกิจกรรมจากข้อมูลลักษณะนี้ แต่เมื่อพิจารณากลับพบว่าถึงแม้ข้อมูลจะทับซ้อนกัน แต่มีการกระจายตัวที่แตกต่างกัน ดังนั้นจึงได้ตั้งสมมติฐานขึ้นว่า ข้อมูลที่มีการกระจายตัวแตกต่างกัน การใช้ส่วนเบี่ยงเบนมาตรฐานจะสามารถแยกข้อมูลได้ดีขึ้น จากนั้นจึงได้พิสูจน์สมมติฐานโดยการแปลงข้อมูลกิจกรรมด้วยส่วนเบี่ยงเบนมาตรฐาน ดังสมการที่ (3.5) ถึง (3.7)

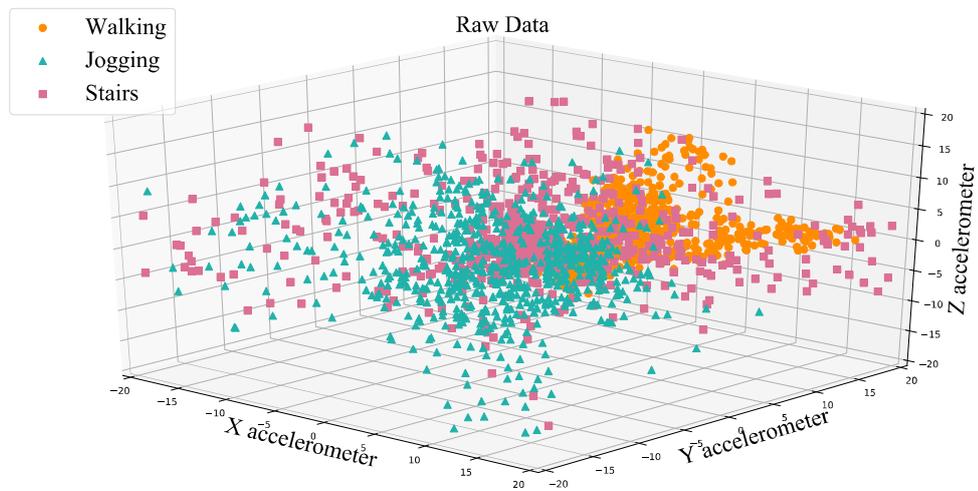
$$SD_{j(ax)}^{act} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax_i - \bar{ax}_j)^2} \quad (3.5)$$

$$SD_{j(ay)}^{act} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay_i - \bar{ay}_j)^2} \quad (3.6)$$

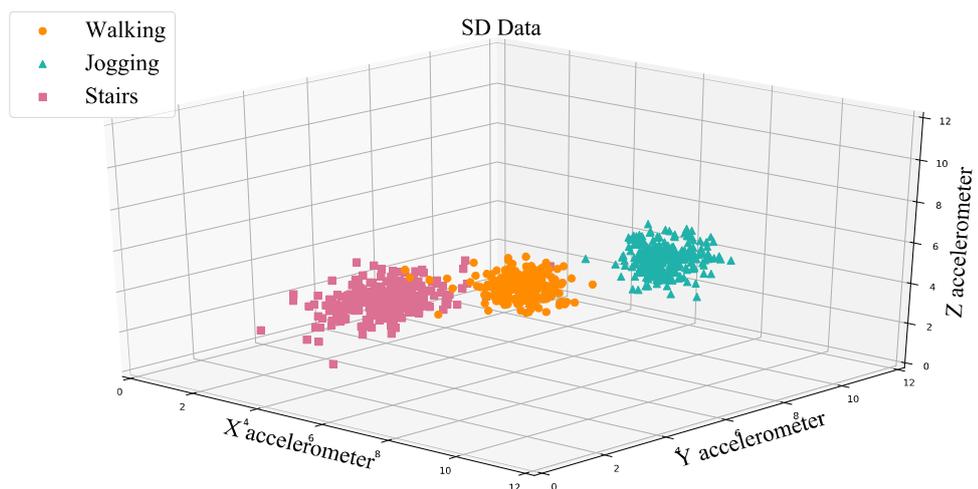
$$SD_{j(az)}^{act} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (az_i - \bar{az}_j)^2} \quad (3.7)$$

- โดยที่ $SD_{j(ax)}^{act}$, $SD_{j(ay)}^{act}$, $SD_{j(az)}^{act}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer แกน X, Y และ Z ตามลำดับ ของ window ที่ j
- ax_i คือ ค่า Accelerometer แนวแกน X ที่ i
- \bar{ax}_j คือ ค่าเฉลี่ยของ Accelerometer แนวแกน X ของ window ที่ j
- ay_i คือ ค่า Accelerometer แนวแกน Y ที่ i
- \bar{ay}_j คือ ค่าเฉลี่ยของ Accelerometer แนวแกน Y ของ window ที่ j
- az_i คือ ค่า Accelerometer แนวแกน Z ที่ i
- \bar{az}_j คือ ค่าเฉลี่ยของ Accelerometer แนวแกน Z ของ window ที่ j
- n คือ จำนวนข้อมูลทั้งหมดภายใน 1 window
- i คือ ค่าที่ใช้สำหรับระบุลำดับของข้อมูล โดยที่ $i = 1, 2, 3, \dots, n$
- j คือ ค่าที่ใช้สำหรับระบุลำดับของ window (ขนาด window จะเท่ากับขนาด อัตราสุ่มตัวอย่างของข้อมูลนั้น)

ผลลัพธ์ที่ได้คือข้อมูลแต่ละกิจกรรมที่ทับซ้อนกัน สามารถแยกออกจากกัน ตัวอย่างดังภาพที่ 3-14 ข้อมูลดิบของการทำกิจกรรม ซึ่งเห็นได้ชัดเจนว่ามีความทับซ้อนกันอย่างมาก แต่เมื่อนำมาแปลงให้กลายเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานแล้วข้อมูลการทำกิจกรรมนั้นสามารถแยกออกจากกันได้ ตัวอย่างดังภาพที่ 3-15 ดังนั้นถ้าหากแปลงข้อมูลกิจกรรมให้เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานก่อนนำไปจำแนกกิจกรรม ก็จะส่งผลให้การจำแนกข้อมูลกิจกรรมสามารถทำได้ง่ายขึ้น



ภาพที่ 3-14 แผนภูมิกระจายของข้อมูลกิจกรรม (ข้อมูลดิบ)



ภาพที่ 3-15 แผนภูมิกระจายของข้อมูลกิจกรรม (ข้อมูลที่แปลงด้วยส่วนเบี่ยงเบนมาตรฐาน)

- **ขั้นตอนการแบ่งกลุ่มข้อมูล SD** จากขั้นตอนที่แล้ว เมื่อแปลงข้อมูลกิจกรรมแล้วจะเห็นว่าข้อมูลแต่ละกิจกรรมที่เคยทับซ้อนกัน สามารถที่จะแยกออกจากกันได้ แต่ก็ยังมีข้อมูลบางกิจกรรมที่ยังทับซ้อนกันและมีค่าอยู่ใกล้กันมาก ดังนั้นจึงได้มีการแบ่งข้อมูลกิจกรรมแต่ละกิจกรรมออกเป็นกลุ่มย่อย (Sub-cluster) โดยใช้วิธีแบ่งกลุ่มแบบ Gaussian Mixture Model (GMM) เนื่องจากข้อมูลกิจกรรมมีการแจกแจงปกติ จากนั้นจะทำการเก็บค่าขีดแบ่ง และค่าศูนย์กลาง (Centroid) ของแต่ละกลุ่มย่อยไว้ใน Classifier model เพื่อใช้ในขั้นตอนออนไลน์ของการรู้จำกิจกรรม

การสร้างตัวแบบรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR) ที่ได้กล่าวมาข้างต้น สามารถอธิบายเป็นขั้นตอนได้ดังภาพที่ 3-16

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

```

/*  $N_\zeta$  = the set of annotated data of all activities. */
/*  $CM = \{C_1^{act}, C_2^{act}, C_3^{act}, \dots, C_k^{act}\}$  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. */
/*  $K$  = the number of sub-clusters. */
Input :  $N_\zeta$ .
Output:  $CM, Threshold$ .
1 for each  $act$  in annotated data do
2   for each window  $j$  do
3     /*  $j = 1, 2, 3, \dots, J$  */
4     Compute  $M_i$  for each sample using eq. (3.1)
5     /*  $i = 1, 2, 3, \dots, n$  */
6     Compute average magnitude  $\bar{M}_j$  of window  $j$ .
7     Compute standard deviation  $SD_{j(mag)}^{act}$  using eq. (3.2).
8   end
9   Compute average of standard deviation  $SD_{avg(mag)}^{act}$  using eq. (3.3)
10  Find the maximum of standard deviation of dormant activities  $SD_{max(mag)}^{dor}$  from  $SD_{avg(mag)}^{act}$ 
    when  $act$  are sitting and standing.
11  Find the minimum of standard deviation of energetic activities  $SD_{min(mag)}^{ene}$  from  $SD_{avg(mag)}^{act}$ 
    when  $act$  are walking, jogging and stairs.
12  Compute  $Threshold = \frac{SD_{max(mag)}^{dor} + SD_{min(mag)}^{ene}}{2}$ .
13 for each energetic activity  $act$  do
14   /*  $act = (\text{walking, jogging, stairs})$  */
15   Let  $D$  be the empty set.
16   for each window  $j$  do
17     /*  $j = 1, 2, 3, \dots, J$  */
18     Compute the average values  $(\bar{a}x_j, \bar{a}y_j, \bar{a}z_j)$  of each acceleration values  $x, y,$  and  $z$ .
19     Compute the standard deviation of each acceleration values  $SD_{j(ax)}^{act}, SD_{j(ay)}^{act}, SD_{j(az)}^{act}$ 
    using eq. (3.5)-(3.7).
20      $Std = (SD_{j(ax)}^{act}, SD_{j(ay)}^{act}, SD_{j(az)}^{act})$ .
21      $D = D \cup Std$ .
22   end
23   Cluster  $D$  into  $k$  sub-clusters using GMM algorithm.
24   /*  $k = 1, 2, 3, \dots, K$  */
25   Compute centroid  $C_k^{act}$  of all sub-clusters and add to  $CM$ .
26 end

```

ภาพที่ 3-16 ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ ISAR แสดงดังภาพที่ 3-16 เริ่มต้นจากการแปลงข้อมูล Accelerometer เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน โดยคำนวณค่า Magnitude M_i และค่าเฉลี่ย Magnitude \bar{M}_j สำหรับหาค่าส่วนเบี่ยงเบนมาตรฐาน $SD_{j(mag)}^{act}$ ซึ่งพิจารณาข้อมูลที่ละ window โดยใช้สมการที่ (3.1) และ (3.2) (บรรทัดที่ 1-5) เมื่อแปลงข้อมูลครบทุก window แล้ว จากนั้นคำนวณค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานแต่ละกิจกรรม $SD_{avg(mag)}^{act}$ โดยใช้สมการที่ (3.3) (บรรทัดที่ 7) เมื่อแปลงข้อมูลและคำนวณค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานแต่ละกิจกรรมเสร็จแล้ว จะหาค่าส่วนเบี่ยงเบนมาตรฐานที่มากที่สุดของกลุ่มกิจกรรมแบบนิ่ง $SD_{max(mag)}^{dor}$ โดยพิจารณาจาก $SD_{avg(mag)}^{act}$ โดยที่ *act* คือ กิจกรรมการนั่ง (*sitting*) และกิจกรรมการยืน (*standing*) (บรรทัดที่ 9) จากนั้นหาค่าส่วนเบี่ยงเบนมาตรฐานที่น้อยที่สุดของกลุ่มกิจกรรมแบบเคลื่อนไหว $SD_{min(mag)}^{ene}$ พิจารณาจาก $SD_{avg(mag)}^{act}$ โดยที่ *act* คือ กิจกรรมการเดิน (*walking*) กิจกรรมการวิ่ง (*jogging*) และกิจกรรมการขึ้นลงบันได (*stairs*) (บรรทัดที่ 10) แล้วจึงคำนวณหาค่าขีดแบ่ง *Threshold* โดยใช้สมการที่ (3.4) (บรรทัดที่ 9-11) ขั้นตอนต่อมาพิจารณาเฉพาะข้อมูลกิจกรรมแบบเคลื่อนไหว กำหนดให้ *D* เป็นเซตว่าง (บรรทัดที่ 13) แปลงข้อมูล Accelerometer เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานโดยพิจารณาที่ละ window เริ่มจากคำนวณค่าเฉลี่ยข้อมูล Accelerometer ตามแนวแกน x, y และ z ($\bar{ax}_j, \bar{ay}_j, \bar{az}_j$) (บรรทัดที่ 15) จากนั้นคำนวณส่วนเบี่ยงเบนมาตรฐานของข้อมูลแต่ละแกน $SD_{j(ax)}^{act}, SD_{j(ay)}^{act}$ และ $SD_{j(az)}^{act}$ โดยใช้สมการที่ (3.5) ถึง (3.7) (บรรทัดที่ 16) กำหนดให้ตัวแปร $Std = (SD_{j(ax)}^{act}, SD_{j(ay)}^{act}, SD_{j(az)}^{act})$ (บรรทัดที่ 17) แล้วเพิ่ม *Std* เข้าไปในเซต *D* (บรรทัดที่ 18) เมื่อทำการแปลงข้อมูลเสร็จแล้วจะนำเซต *D* ไปแบ่งกลุ่มข้อมูลด้วยเทคนิควิธี Gaussian Mixture Model (GMM) (บรรทัดที่ 20) จากนั้นเก็บเฉพาะค่าศูนย์กลางของแต่ละกลุ่มย่อย C_k^{act} ไว้ใน Classifier model (*CM*) (บรรทัดที่ 21)

3.2.2 ISAR ขั้นตอนออนไลน์ (Recognition)

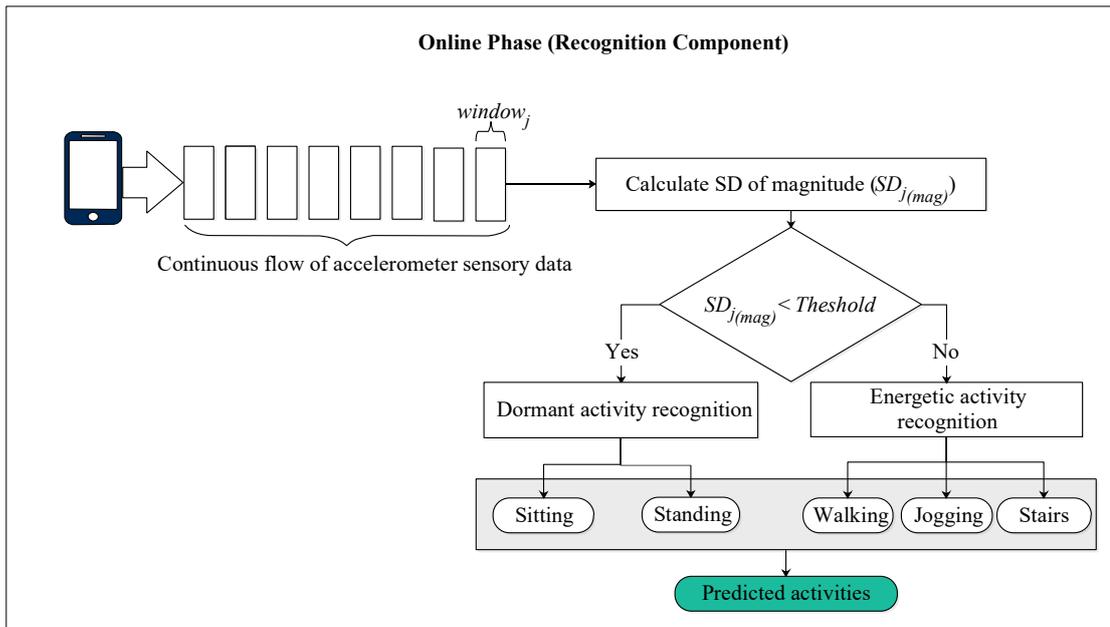
ในขั้นตอนนี้จะทำการรู้จำกิจกรรมกับข้อมูลจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน ซึ่งเป็นข้อมูลกระแสเชิงเวลาที่ไหลเข้ามา โดยข้อมูลจะถูกแบ่งออกเป็น window ซึ่งขนาดของข้อมูลภายใน window จะขึ้นอยู่กับค่าอัตราสุ่มตัวอย่างของอุปกรณ์สมาร์ทโฟน โดยมีการทำงานตามภาพที่ 3-17 ข้อมูล Accelerometer จะถูกคำนวณด้วยส่วนเบี่ยงเบนมาตรฐาน จากนั้นจะทำการเปรียบเทียบกับค่าขีดแบ่งที่เก็บไว้ใน Classifier model ถ้าหากส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer มีค่ามากกว่าค่าขีดแบ่งแสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมแบบเคลื่อนไหว แต่ถ้าน้อยกว่าค่าขีดแบ่งแสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมแบบนิ่ง

- **ขั้นตอนการแบ่งประเภทกิจกรรมด้วยค่าขีดแบ่ง (Threshold)** ในขั้นตอนนี้จะทำการแบ่งประเภทของกิจกรรมว่าเป็นกิจกรรมแบบนิ่งหรือเป็นกิจกรรมแบบเคลื่อนไหว จากข้อมูล

ภายใน window โดยการคำนวณค่าส่วนเบี่ยงเบนมาตรฐานของ Magnitude ข้อมูล จากนั้นจะนำไปเปรียบเทียบกับค่าขีดแบ่งที่เก็บไว้ใน Classifier model โดยมีเกณฑ์ดังนี้

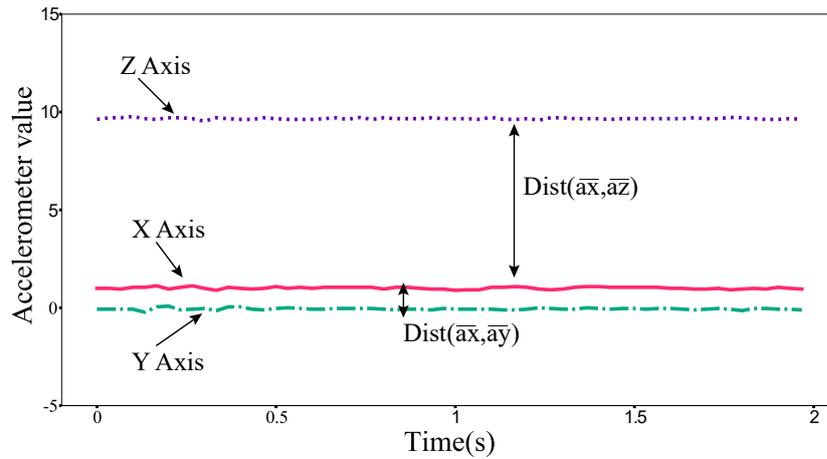
ถ้า $SD_{j(mag)} < Threshold$ แสดงว่าข้อมูลเป็นกิจกรรมแบบนิ่ง

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

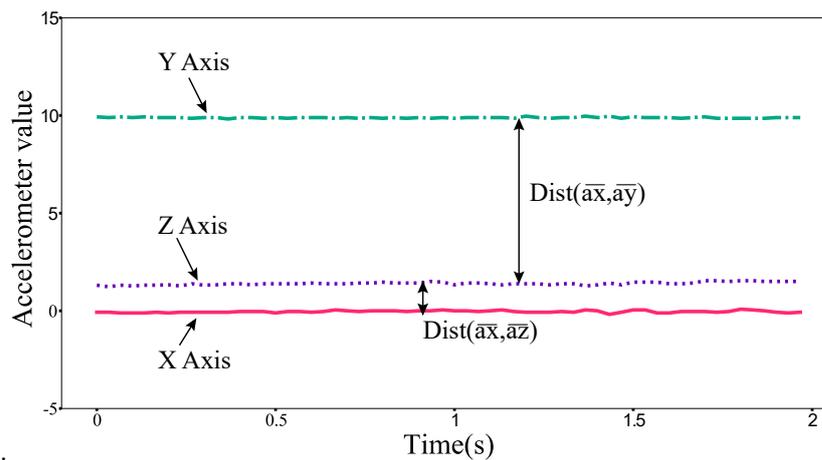


ภาพที่ 3-17 ขั้นตอนออนไลน์ของวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

- ขั้นตอนการจำกิจกรรมแบบนิ่ง (Dormant activity recognition) กิจกรรมแบบนี้ หมายถึงกิจกรรมที่มีการขยับร่างกายน้อย ได้แก่ การยืนและการนั่ง โดยการจำแนกประเภทของกิจกรรมทั้งสองจะจำแนกจากลักษณะเส้นข้อมูล Accelerometer ซึ่งทั้ง 2 กิจกรรมมีลักษณะข้อมูลดังภาพที่ 3-18 และ 3-19



ภาพที่ 3-18 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการนั่ง



ภาพที่ 3-19 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการยืน

จากภาพที่ 3-17 และ 3-18 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการยืนและกิจกรรมการนั่ง เมื่อพิจารณาจะพบว่าในกิจกรรมการยืนค่า Accelerometer ตามแนวแกน Y จะมีค่าที่ห่างจาก Accelerometer ตามแนวแกน X และ Z อย่างเห็นได้ชัด ส่วนกิจกรรมการนั่งจะมีค่า Accelerometer ตามแนวแกน Z ห่างจากค่า Accelerometer ตามแนวแกน X และ Y อย่างเห็นได้ชัด สาเหตุที่เป็นเช่นนี้เนื่องจาก ในขณะที่ทำกิจกรรมการนั่งและการยืน มีความแรงที่เกิดขึ้นจากแรงโน้มถ่วงของโลกที่แตกต่างกันในแต่ละแกน จากข้อสังเกตนี้จึงได้ใช้

ระยะห่างของค่า Accelerometer ตามแนวแกน Y และ Z ที่มีต่อค่า Accelerometer ตามแนวแกน X มาใช้ในการจำแนกว่าข้อมูลนั้นเป็นกิจกรรมการยืนหรือกิจกรรมการนั่ง ซึ่งเหตุผลที่ให้ค่า Accelerometer ตามแนวแกน X เป็นข้อมูลหลักในการวัดระยะห่างเพราะไม่ว่าจะเป็นการยืนหรือการนั่ง ค่า Accelerometer ตามแนวแกน X จะมีลักษณะเหมือนกันคือเข้าใกล้ 0 ต่างจากค่า Accelerometer ตามแนวแกน Y และ Z ที่เปลี่ยนไปตามแต่กิจกรรม ในงานวิทยานิพนธ์นี้จึงใช้การจำแนกกิจกรรมแบบนิ่ง (Dormant activities) ดังสมการที่ (3.8) และ (3.11)

$$Dist(\bar{ax}, \bar{ay}) = \sqrt{(\bar{ax} - \bar{ay})^2} \quad (3.8)$$

$$Dist(\bar{ax}, \bar{az}) = \sqrt{(\bar{ax} - \bar{az})^2} \quad (3.9)$$

วิธีหาว่าข้อมูลเป็นกิจกรรมการยืน

$$Standing = Dist(\bar{ax}, \bar{ay}) > Dist(\bar{ax}, \bar{az}) \quad (3.10)$$

วิธีหาว่าข้อมูลเป็นกิจกรรมการนั่ง

$$Sitting = Dist(\bar{ax}, \bar{ay}) < Dist(\bar{ax}, \bar{az}) \quad (3.11)$$

โดยที่ $Dist(\bar{ax}, \bar{ay})$ คือ ระยะห่างระหว่างข้อมูล Accelerometer ตามแนวแกน X และแนวแกน Y

$Dist(\bar{ax}, \bar{az})$ คือ ระยะห่างระหว่างข้อมูล Accelerometer ตามแนวแกน X และแนวแกน Z

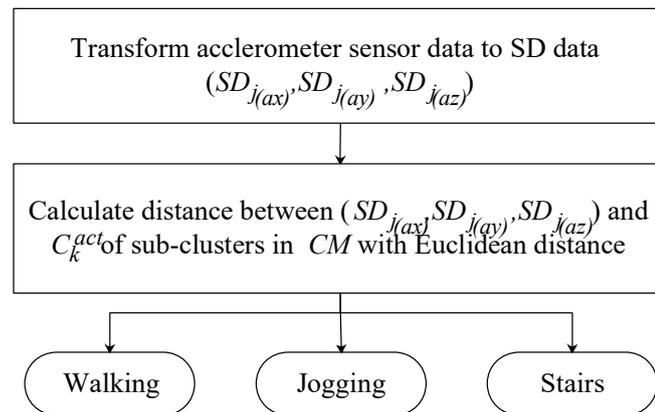
\bar{ax} คือ ค่าเฉลี่ยของค่า Accelerometer ตามแนวแกน X

\bar{ay} คือ ค่าเฉลี่ยของค่า Accelerometer ตามแนวแกน Y

\bar{az} คือ ค่าเฉลี่ยของค่า Accelerometer ตามแนวแกน Z

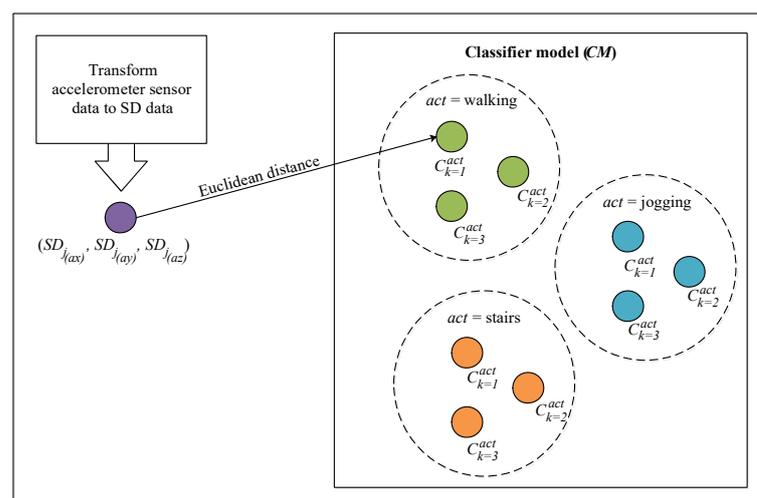
- **ขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว (Energetic activity recognition)**

โดยกิจกรรมแบบเคลื่อนไหว ได้แก่ การเดิน การวิ่ง และการขึ้นลงบันได ทั้ง 3 กิจกรรมจะทำการจำแนกกิจกรรมด้วยการคำนวณส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer แต่ละแกน โดยมีขั้นตอนดังภาพที่ 3-20



ภาพที่ 3-20 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว

จากภาพที่ 3-20 ขั้นตอนแรกคือแปลงข้อมูล Accelerometer ด้วยส่วนเบี่ยงเบนมาตรฐาน โดยจะได้ $SD_{j(ax)}$, $SD_{j(ay)}$ และ $SD_{j(az)}$ ซึ่งเป็นค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z จากนั้นจะนำไปเปรียบเทียบกับ C_k^{act} ของแต่ละกลุ่มย่อยที่เก็บไว้ใน Classifier model (CM) โดยการใช้การเปรียบเทียบระยะทางแบบยูคลิด (Euclidean distance) ตัวอย่างดังภาพที่ 3-21 ถ้าหาก C_k^{act} กลุ่มย่อยของกิจกรรมไหนมีระยะทางเมื่อเปรียบเทียบน้อยที่สุด แสดงว่าข้อมูลมีความคล้ายกันที่สุด จะระบุข้อมูลที่เข้ามาใหม่ว่าเป็นกิจกรรมนั้น



ภาพที่ 3-21 การระบุกิจกรรมโดยเปรียบเทียบระยะทางของ $SD_{j(ax)}$, $SD_{j(ay)}$, $SD_{j(az)}$ และ C_k^{act} ของแต่ละกลุ่มย่อยภายใน Classifier model (CM)

รู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR) ที่ได้กล่าวมาข้างต้น สามารถอธิบายเป็นขั้นตอนได้ดังภาพที่ 3-22

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

```

/*  $S_{\zeta}$  = the set of non-stationary streaming data. */
/*  $CM = \{C_1^{act}, C_2^{act}, C_3^{act}, \dots, C_k^{act}\}$  when  $act$  are walking, jogging and stairs. */
/*
/*  $Threshold$  = the separating dormant and energetic activities. */
/*  $P_{act}$  = the predicted activities. */
/*  $J$  = the number of window. */
/*  $n$  = the number of data in window. */
/*  $K$  = the number of sub-clusters. */
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. (3.1) 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  $SD_{j(mag)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (M_i - \bar{M}_j)^2}$ 
8     if  $SD_{j(mag)} < Threshold$  then
9       Compute the average values  $(\bar{a}x_j, \bar{a}y_j, \bar{a}z_j)$  of each acceleration values  $x, y,$  and  $z$ .
10      Compute  $Dist(\bar{a}x, \bar{a}y)$  and  $Dist(\bar{a}x, \bar{a}z)$  using eq. (3.8) and (3.9).
11      if  $Dist(\bar{a}x, \bar{a}y) > Dist(\bar{a}x, \bar{a}z)$  then
12        |  $P_{act} = \text{standing}$ 
13      else
14        |  $P_{act} = \text{sitting}$ 
15      end
16    else
17      Compute the average values  $(\bar{a}x_j, \bar{a}y_j, \bar{a}z_j)$  of each acceleration values  $x, y,$  and  $z$ .
18      Compute the standard deviation of each acceleration values
19       $SD_{j(ax)}, SD_{j(ay)}, SD_{j(az)}$  using eq. (3.5)-(3.7). then set  $SD_j$ 
20       $SD_j = (SD_{j(ax)}, SD_{j(ay)}, SD_{j(az)})$ 
21      Find the nearest sub-cluster  $w$  such that
22       $w = \operatorname{argmin}_{k=1, \dots, K} (||SD_j - C_k^{act}||)$ 
23      /*  $k = 1, 2, 3, \dots, K$  */
24      Set the activity of sub-cluster  $sc_w$  to  $P_{act}$ .
25    end
26  end
27 end

```

ภาพที่ 3-22 ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ ISAR แสดงดังภาพที่ 3-22 ข้อมูลที่เข้ามาเป็นข้อมูลกระแสเชิงเวลา Accelerometer sensor ซึ่งนำมาคำนวณที่ละ window เริ่มจากการคำนวณค่า Magnitude M_i และค่าเฉลี่ย Magnitude \bar{M}_j สำหรับหาค่าส่วนเบี่ยงเบนมาตรฐาน $SD_{j(mag)}$ โดยใช้สมการที่ (3.1) และ (3.2) (บรรทัดที่ 1-5) จากนั้นตรวจสอบว่าข้อมูลที่เข้ามาอยู่ในกลุ่มกิจกรรมแบบนิ่งหรือกลุ่มกิจกรรมแบบเคลื่อนไหว โดยเปรียบเทียบค่า $SD_{j(mag)}$ และค่า *Threshold* ถ้าค่า $SD_{j(mag)}$ น้อยกว่าค่า *Threshold* แสดงว่าข้อมูลอยู่ในกลุ่มกิจกรรมแบบนิ่ง (บรรทัดที่ 6) การรู้จำกิจกรรมแบบนิ่งเริ่มจากการคำนวณค่าเฉลี่ยของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ที่เข้ามาใหม่ $\bar{ax}_j, \bar{ay}_j, \bar{az}_j$ จากนั้นคำนวณหาระยะห่างระหว่างข้อมูล Accelerometer ตามแนวแกน X และ Y $Dist(\bar{ax}_j, \bar{ay}_j)$ และคำนวณหาระยะห่างระหว่างข้อมูล Accelerometer ตามแนวแกน X และ Z $Dist(\bar{ax}_j, \bar{az}_j)$ โดยใช้สมการที่ (3.8) และ (3.9) (บรรทัดที่ 7-8) จากนั้นจำแนกข้อมูลว่าเป็นกิจกรรมการยืนหรือกิจกรรมการนั่ง ด้วยการเปรียบเทียบระหว่างค่าของ $Dist(\bar{ax}_j, \bar{ay}_j)$ และ $Dist(\bar{ax}_j, \bar{az}_j)$ ถ้า $Dist(\bar{ax}_j, \bar{ay}_j)$ มากกว่า $Dist(\bar{ax}_j, \bar{az}_j)$ แสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมการยืน กำหนดให้ $P_{act} = standing$ แต่ถ้า $Dist(\bar{ax}_j, \bar{ay}_j)$ น้อยกว่า $Dist(\bar{ax}_j, \bar{az}_j)$ แสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมการนั่ง กำหนดให้ $P_{act} = sitting$ (บรรทัดที่ 9-13) แต่ถ้าข้อมูลที่เข้ามาอยู่ในกลุ่มกิจกรรมแบบเคลื่อนไหว นั่นคือ $SD_{j(mag)}$ มากกว่าค่า *Threshold* (บรรทัดที่ 14) จะคำนวณค่าเฉลี่ยข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ที่เข้ามาใหม่ $\bar{ax}_j, \bar{ay}_j, \bar{az}_j$ (บรรทัดที่ 15) จากนั้นคำนวณส่วนเบี่ยงเบนมาตรฐานของข้อมูลแต่ละแกน $SD_{j(ax)}, SD_{j(ay)}$ และ $SD_{j(az)}$ แล้วกำหนดให้ $SD_j = (SD_{j(ax)}, SD_{j(ay)}, SD_{j(az)})$ (บรรทัดที่ 16) จากนั้นนำ SD_j ไปคำนวณกับค่า C_k^{act} ที่อยู่ใน *CM* ถ้า C_k^{act} กลุ่มย่อยกิจกรรมไหนมีค่าใกล้เคียงกับ SD_j มากที่สุดก็จะระบุว่าข้อมูลที่เข้ามาใหม่เป็นกิจกรรมนั้น $P_{act} = act$ (บรรทัดที่ 17-18)

3.2.3 ข้อจำกัดของวิธีการ ISAR

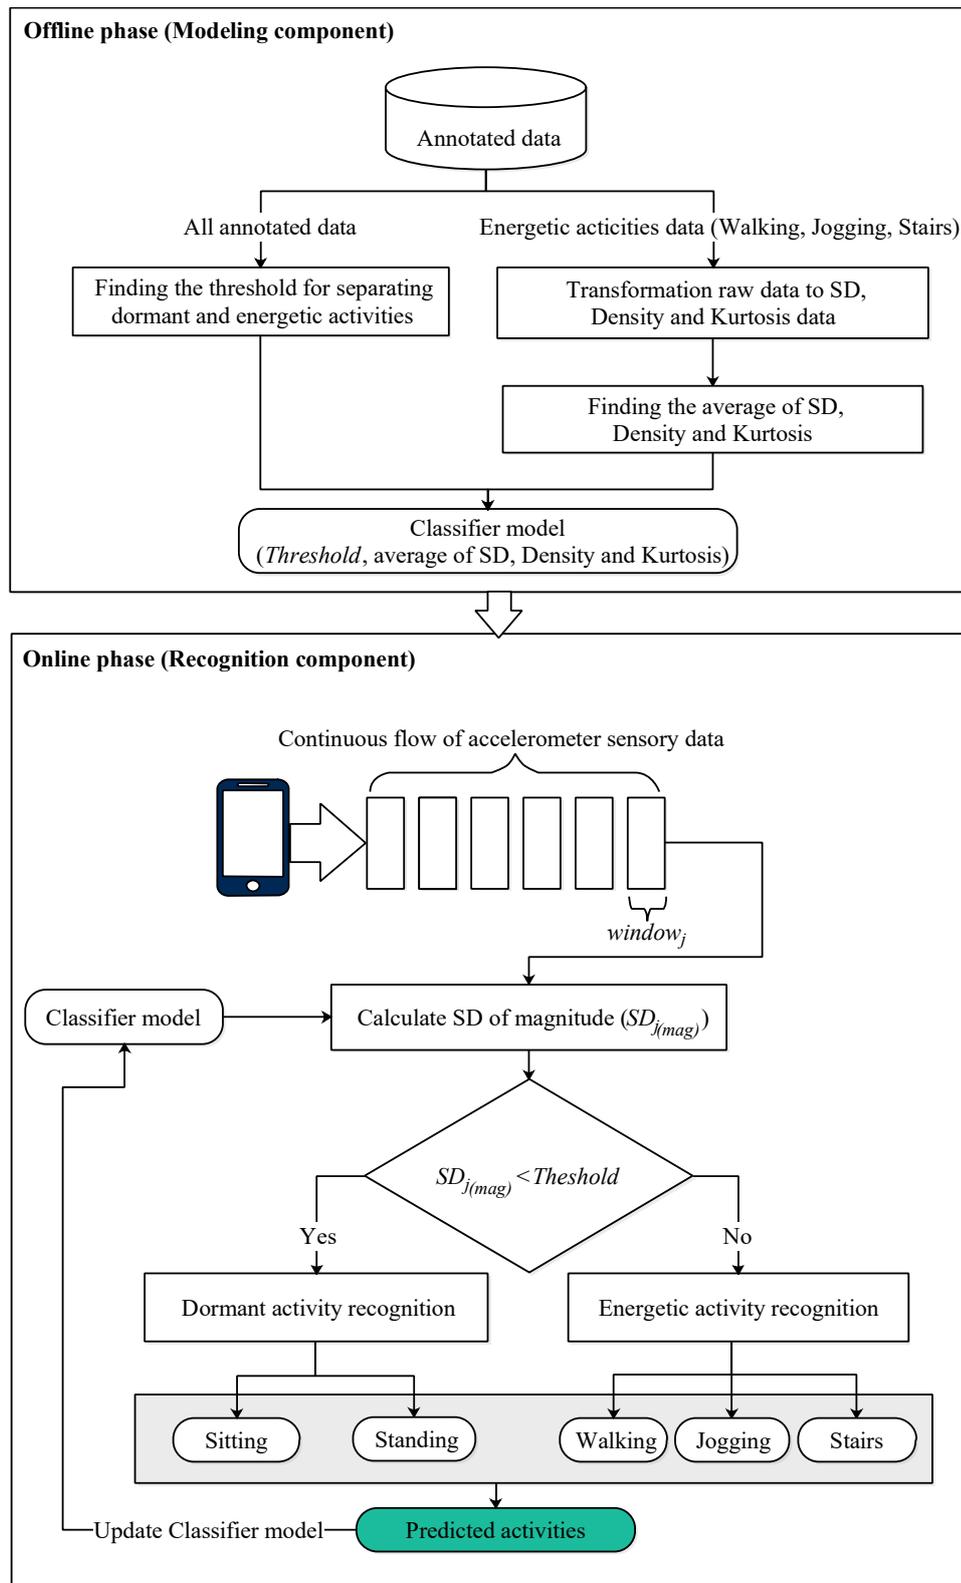
หลังจากสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการ ISAR และได้นำไปทดลองกับข้อมูล WISDM และ UniMiB-SHAR พบว่าเมื่อทดสอบกับข้อมูลการทำกิจกรรมของผู้ใช้ทุกคนแล้ว วิธีการ ISAR มีความถูกต้องในการรู้จำกิจกรรมที่สูงเฉพาะผู้ใช้บางรายเท่านั้น เนื่องมาจากวิธีการ ISAR ไม่สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้งานแต่ละบุคคลได้ ถ้าข้อมูลการทำกิจกรรมของผู้ใช้คนใดมีลักษณะคล้ายกับข้อมูลกิจกรรมที่ใช้สร้างตัวแบบ การรู้จำกิจกรรมของผู้ใช้คนนั้นจะมีความถูกต้องสูง กลับกันถ้าข้อมูลการทำกิจกรรมของผู้ใช้คนใดแตกต่างจากข้อมูลกิจกรรมที่ใช้สร้างตัว

แบบ การรู้จำกิจกรรมของผู้ใช้คนนั้นก็มีความถูกต้องต่ำ อีกทั้งยังพบว่าขั้นตอนการแบ่งกลุ่มข้อมูลกิจกรรม ไม่ได้ช่วยทำให้การรู้จำกิจกรรมดีขึ้น ซึ่งทำให้เสียเวลาในการคำนวณโดยเปล่าประโยชน์

จากข้อจำกัดของวิธีการ ISAR ที่ได้กล่าวมาข้างต้น วิทยานิพนธ์นี้จึงได้เสนอวิธีการสำหรับพัฒนาการรู้จำกิจกรรมวิธีการ ISAR ให้สามารถปรับปรุงตัวแบบรู้จำกิจกรรมได้ โดยใช้ชื่อใหม่ว่า “An improvement of impersonal smartphone-based activity recognition using the accelerometer sensory data” หรือเรียกว่า “ISAR+” ซึ่งเป็นวิธีการรู้จำกิจกรรมที่สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคล และทำให้ความถูกต้องของการรู้จำกิจกรรมเพิ่มมากขึ้น

3.3 ขั้นตอนการพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรม (ISAR+)

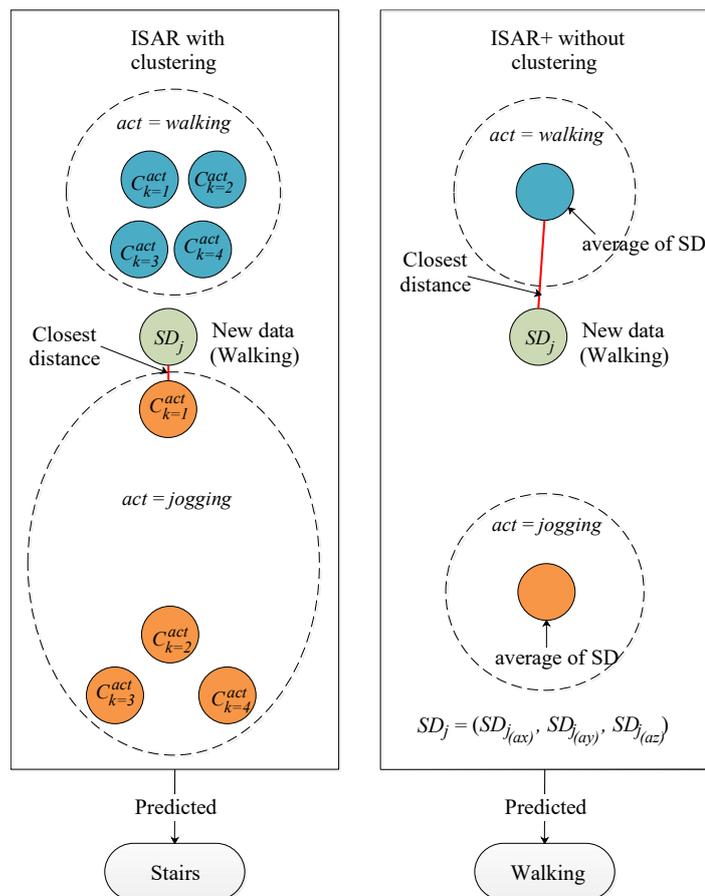
วิธีการ ISAR+ เป็นตัวแบบการรู้จำกิจกรรมที่พัฒนามาจากวิธีการ ISAR โดยได้ปรับปรุงตัวแบบการรู้จำกิจกรรมให้สามารถปรับตัวแบบรู้จำกิจกรรมให้เข้ากับผู้ใช้แต่ละบุคคลได้ ซึ่งวิธีการ ISAR+ มีกรอบแนวคิดดังภาพที่ 3-23 ซึ่งมีการปรับปรุงตัวแบบรู้จำกิจกรรมดังต่อไปนี้ ขั้นตอนออนไลน์ 1) ใช้ค่าเฉลี่ยแทนการแบ่งกลุ่มของข้อมูลส่วนเบี่ยงเบนมาตรฐาน 2) เพิ่มการแปลงข้อมูลความหนาแน่น (Density) และความโด่ง (Kurtosis) ของข้อมูล ขั้นตอนออนไลน์ 1) เพิ่มการปรับปรุงตัวแบบรู้จำกิจกรรมโดยใช้มาตรวัด 3 ตัว ได้แก่ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ความหนาแน่น (Density) และความโด่ง (Kurtosis) ของข้อมูล



ภาพที่ 3-23 กรอบแนวคิดวิธีการ An improvement of impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)

3.3.1 การพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ ขั้นตอนออฟไลน์ (Offline phase : Modelling component)

● ใช้ค่าเฉลี่ยแทนการแบ่งกลุ่มของข้อมูลส่วนเบี่ยงเบนมาตรฐาน วิธีการ ISAR+ ได้ตัดขั้นตอนของการแบ่งกลุ่มข้อมูล โดยมีสมมติฐานว่า เมื่อทำการแบ่งกลุ่มข้อมูลจะทำให้ได้ขอบเขตของข้อมูลกิจกรรมนั้น ๆ มากยิ่งขึ้น จนทำให้ขอบเขตของข้อมูลแต่ละกิจกรรมใกล้ชิดกันมากเกินไป หรืออาจทับซ้อนกัน เช่น ขอบเขตของข้อมูลกิจกรรมการเดินและการขึ้นลงบันได จึงอาจทำให้การรู้จำกิจกรรมทั้งสองกิจกรรมผิดพลาดขึ้นได้ ตัวอย่างดังภาพที่ 3-24 ข้อมูลกิจกรรมการขึ้นลงบันไดที่ใช้สร้างตัวแบบรู้จำกิจกรรมอาจมีความโดดเด่นผิดปกติ เมื่อแบ่งกลุ่มข้อมูลจึงมีขอบเขตข้อมูลที่มากขึ้น เมื่อใช้ตัวแบบรู้จำกิจกรรมนี้กับข้อมูลที่เข้ามาซึ่งเป็นกิจกรรมการเดิน แต่อยู่ใกล้กับขอบเขตกิจกรรมการขึ้นลงบันไดมากกว่าขอบเขตกิจกรรมการเดิน จึงทำให้ ISAR ระบุกิจกรรมผิดพลาด แต่ถ้าหากใช้แค่จุดศูนย์กลางของข้อมูลโดยไม่จำเป็นต้องแบ่งกลุ่ม น่าจะทำให้การรู้จำกิจกรรมมีความถูกต้องมากขึ้น วิทยานิพนธ์นี้จึงได้ตัดขั้นตอนการแบ่งกลุ่มข้อมูลออก โดยเปลี่ยนเป็นการเก็บค่าเฉลี่ยของข้อมูลแทน



ภาพที่ 3-24 ตัวอย่างวิธีการ ISAR+ ที่มีการแบ่งกลุ่มข้อมูลแล้วไม่มีการแบ่งกลุ่มข้อมูล

• เพิ่มการแปลงข้อมูลความหนาแน่น (Density) และความโค้ง (Kurtosis) ของข้อมูลวิธีการ ISAR+ ได้เพิ่มการแปลงข้อมูล Accelerometer sensor ด้วยความหนาแน่น (Density) และความโค้ง (Kurtosis) เพื่อจะใช้เป็นเกณฑ์สำหรับปรับปรุงตัวแบบรู้จำกิจกรรมร่วมกับส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) โดยมีขั้นตอนวิธีดังสมการที่ (3.12) ถึง (3.17)

$$Dens_{j(ax)}^{act} = \frac{n}{ax_{max} - ax_{min}} \quad (3.12)$$

$$Dens_{j(ay)}^{act} = \frac{n}{ay_{max} - ay_{min}} \quad (3.13)$$

$$Dens_{j(az)}^{act} = \frac{n}{az_{max} - az_{min}} \quad (3.14)$$

โดยที่ $Dens_{j(ax)}^{act}, Dens_{j(ay)}^{act}, Dens_{j(az)}^{act}$ คือ ค่าความหนาแน่นของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับ ของ window ที่ j

ax_{Max} คือ ค่า Accelerometer ตามแนวแกน X ที่มากที่สุด

ax_{Min} คือ ค่า Accelerometer ตามแนวแกน X ที่น้อยที่สุด

ay_{Max} คือ ค่า Accelerometer ตามแนวแกน Y ที่มากที่สุด

ay_{Min} คือ ค่า Accelerometer ตามแนวแกน Y ที่น้อยที่สุด

az_{Max} คือ ค่า Accelerometer ตามแนวแกน Z ที่มากที่สุด

az_{Min} คือ ค่า Accelerometer ตามแนวแกน Z ที่น้อยที่สุด

n คือ จำนวนข้อมูลทั้งหมดภายใน 1 window

j คือ ค่าที่ใช้สำหรับระบุลำดับของ window (ขนาด window จะเท่ากับขนาดอัตราสุ่มตั้งอย่างของข้อมูลนั้น)

$$Kurt_{j(ax)}^{act} = \frac{\sum_{i=1}^n (ax_i - \bar{ax}_j)^4}{(\sum_{i=1}^n (ax_i - \bar{ax}_j)^2)^2} \quad (3.15)$$

$$Kurt_{j(ay)}^{act} = \frac{\sum_{i=1}^n (ay_i - \bar{ay}_j)^4}{(\sum_{i=1}^n (ay_i - \bar{ay}_j)^2)^2} \quad (3.16)$$

$$Kurt_{j(az)}^{act} = \frac{\sum_{i=1}^n (az_i - \bar{az}_j)^4}{(\sum_{i=1}^n (az_i - \bar{az}_j)^2)^2} \quad (3.17)$$

โดยที่ $Kurt_{j(ax)}^{act}, Kurt_{j(ay)}^{act}, Kurt_{j(az)}^{act}$ คือ ค่าความหนาแน่นของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับ ของ window ที่ j

ax_i คือ ค่า Accelerometer ตามแนวแกน X ตัวที่ i

\bar{ax}_j คือ ค่าเฉลี่ยของข้อมูล Accelerometer ตามแนวแกน X ของ window ที่ j

ay_i คือ ค่า Accelerometer ตามแนวแกน Y ตัวที่ i

\bar{ay}_j คือ ค่าเฉลี่ยของข้อมูล Accelerometer ตามแนวแกน Y ของ window ที่ j

az_i คือ ค่า Accelerometer ตามแนวแกน Z ตัวที่ i

\bar{az}_j คือ ค่าเฉลี่ยของข้อมูล Accelerometer ตามแนวแกน Z ของ window ที่ j

n คือ จำนวนข้อมูลทั้งหมดภายใน 1 window

i คือ ค่าที่ใช้สำหรับระบุลำดับของข้อมูล โดยที่ $i = 1, 2, 3, \dots, n$

j คือ ค่าที่ใช้สำหรับระบุลำดับของ window (ขนาด window จะเท่ากับขนาด อัตราสุ่มตั้งอย่างของข้อมูลนั้น)

- เก็บข้อมูลสรุปสำหรับตัวแบบการรู้จำกิจกรรม (Classifier model) ในขั้นตอนนี้ จะเก็บข้อมูลสรุปไว้ใน Classifier model (CM) ได้แก่ ค่าขีดแบ่ง (Threshold) ค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐาน ค่าเฉลี่ยความหนาแน่น และค่าเฉลี่ยความโด่ง สำหรับใช้ในการรู้จำกิจกรรมในขั้นตอนออนไลน์ ซึ่งการเก็บค่าขีดแบ่งมีกระบวนการเหมือนกับวิธีการ ISAR ส่วนค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐาน ค่าเฉลี่ยความหนาแน่น และค่าเฉลี่ยความโด่ง สามารถคำนวณได้จากสมการที่ (3.18) ถึง (3.26)

กำหนดให้ SD_{CM}^{act} คือค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูลแต่ละกิจกรรมที่จะเก็บไว้ใน Classifier model ซึ่ง $SD_{CM}^{act} = (SD_{avg(ax)}^{act}, SD_{avg(ay)}^{act}, SD_{avg(az)}^{act})$ คำนวณได้จากสมการที่ (3.18) ถึง (3.20)

$$SD_{avg(ax)}^{act} = \frac{\sum_{j=1}^J SD_{j(ax)}^{act}}{J} \quad (3.18)$$

$$SD_{avg(ay)}^{act} = \frac{\sum_{j=1}^J SD_{j(ay)}^{act}}{J} \quad (3.19)$$

$$SD_{avg(az)}^{act} = \frac{\sum_{j=1}^J SD_{j(az)}^{act}}{J} \quad (3.20)$$

โดยที่ $SD_{avg(ax)}^{act}, SD_{avg(ay)}^{act}, SD_{avg(az)}^{act}$ คือ ค่าเฉลี่ยเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับ

$SD_{j(ax)}^{act}, SD_{j(ay)}^{act}, SD_{j(az)}^{act}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับของ window ที่ j ($j = 1, 2, 3, \dots, J$)

J คือ จำนวน window ของข้อมูลหนึ่งกิจกรรม

กำหนดให้ $Dens_{CM}^{act}$ คือค่าความหนาแน่นของข้อมูลแต่ละกิจกรรมที่จะเก็บไว้ใน Classifier model ซึ่ง $Dens_{CM}^{act} = (Dens_{avg(ax)}^{act}, Dens_{avg(ay)}^{act}, Dens_{avg(az)}^{act})$ คำนวณได้จากสมการที่ (3.21) ถึง (3.23)

$$Dens_{avg(ax)}^{act} = \frac{\sum_{j=1}^J Dens_{j(ax)}^{act}}{J} \quad (3.21)$$

$$Dens_{avg(ay)}^{act} = \frac{\sum_{j=1}^J Dens_{j(ay)}^{act}}{J} \quad (3.22)$$

$$Dens_{avg(az)}^{act} = \frac{\sum_{j=1}^J Dens_{j(az)}^{act}}{J} \quad (3.23)$$

โดยที่ $Dens_{avg(ax)}^{act}, Dens_{avg(ay)}^{act}, Dens_{avg(az)}^{act}$ คือ ค่าเฉลี่ยความหนาแน่นของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับ

$Dens_{j(ax)}^{act}, Dens_{j(ay)}^{act}, Dens_{j(az)}^{act}$ คือ ค่าความหนาแน่นของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับของ window ที่ j ($j = 1, 2, 3, \dots, J$)

J คือ จำนวน window ของข้อมูลหนึ่งกิจกรรม

กำหนดให้ $Kurt_{CM}^{act}$ คือค่าความโด่งของข้อมูลแต่ละกิจกรรมที่จะเก็บไว้ใน Classifier model ซึ่ง $Kurt_{CM}^{act} = (Kurt_{avg(ax)}^{act}, Kurt_{avg(ay)}^{act}, Kurt_{avg(az)}^{act})$ คำนวณได้จากสมการที่ (3.24) ถึง (3.26)

$$Kurt_{avg(ax)}^{act} = \frac{\sum_{j=1}^J Kurt_{j(ax)}^{act}}{J} \quad (3.24)$$

$$Kurt_{avg(ay)}^{act} = \frac{\sum_{j=1}^J Kurt_{j(ay)}^{act}}{J} \quad (3.25)$$

$$Kurt_{avg(az)}^{act} = \frac{\sum_{j=1}^J Kurt_{j(az)}^{act}}{J} \quad (3.26)$$

โดยที่ $Kurt_{avg(ax)}^{act}, Kurt_{avg(ay)}^{act}, Kurt_{avg(az)}^{act}$ คือ ค่าเฉลี่ยความโด่งของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับ
 $Kurt_{j(ax)}^{act}, Kurt_{j(ay)}^{act}, Kurt_{j(az)}^{act}$ คือ ค่าความโด่งของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ตามลำดับของ window ที่ j ($j = 1, 2, 3, \dots, J$)
 J คือ จำนวน window ของข้อมูลหนึ่งกิจกรรม

การสร้างตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) ที่ได้กล่าวมาข้างต้น สามารถอธิบายเป็นขั้นตอนได้ดังภาพที่ 3-25

Algorithm 3: 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 activities. */
/*  $J$  = 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
  /*  $act = (\text{sitting, standing, walking, jogging, stairs})$  */
2 for each window  $j$  do
  /*  $j = 1, 2, 3, \dots, J$  */
3   Compute  $M_i$  for each sample using eq. (3.1)
  /*  $i = 1, 2, 3, \dots, n$  */
4   Compute average magnitude  $\bar{M}_j$  of window  $j$ .
5   Compute standard deviation  $SD_{j(mag)}^{act}$  using eq. (3.2).
6 end
7   Compute average of standard deviation  $SD_{avg(mag)}^{act}$  using eq. (3.3)
8 end
9 Find the maximum of standard deviation of dormant activities  $SD_{max(mag)}^{dor}$  from  $SD_{avg(mag)}^{act}$ 
  when  $act$  are sitting and standing.
10 Find the minimum of standard deviation of energetic activities  $SD_{min(mag)}^{ene}$  from  $SD_{avg(mag)}^{act}$ 
  when  $act$  are walking, jogging and stairs.
11 Compute  $Threshold = \frac{SD_{max(mag)}^{dor} + SD_{min(mag)}^{ene}}{2}$ .
12 for each energetic activity  $act$  do
  /*  $act = (\text{walking, jogging, stairs})$  */
13 for each window  $j$  do
  /*  $j = 1, 2, 3, \dots, J$  */
14   Compute the standard deviation of each acceleration values  $SD_{j(ax)}^{act}, SD_{j(ay)}^{act}, SD_{j(az)}^{act}$ 
    using eq. (3.5)-(3.7).
15   Compute the density of each acceleration values  $Dens_{j(ax)}^{act}, Dens_{j(ay)}^{act}, Dens_{j(az)}^{act}$  using
    eq. (3.12)-(3.14).
16   Compute the kurtosis of each acceleration values  $Kurt_{j(ax)}^{act}, Kurt_{j(ay)}^{act}, Kurt_{j(az)}^{act}$  using
    eq. (3.15)-(3.17).
17 end
18 Compute average of standard deviation  $SD_{avg(ax)}^{act}, SD_{avg(ay)}^{act}, SD_{avg(az)}^{act}$  using eq.
  (3.18)-(3.20) then set  $SD_{CM}^{act} = (SD_{avg(ax)}^{act}, SD_{avg(ay)}^{act}, SD_{avg(az)}^{act})$ .
19 Compute average of density  $Dens_{avg(ax)}^{act}, Dens_{avg(ay)}^{act}, Dens_{avg(az)}^{act}$  using eq. (3.21)-(3.23)
  then set  $Dens_{CM}^{act} = (Dens_{avg(ax)}^{act}, Dens_{avg(ay)}^{act}, Dens_{avg(az)}^{act})$ .
20 Compute average of kurtosis  $Kurt_{avg(ax)}^{act}, Kurt_{avg(ay)}^{act}, Kurt_{avg(az)}^{act}$  using eq. (3.24)-(3.26)
  then set  $Kurt_{CM}^{act} = (Kurt_{avg(ax)}^{act}, Kurt_{avg(ay)}^{act}, Kurt_{avg(az)}^{act})$ .
21 Add  $SD_{CM}^{act}, Dens_{CM}^{act}$  and  $Kurt_{CM}^{act}$  to the  $CM$ .
22 end

```

ภาพที่ 3-25 ชั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone- based activity recognition using the accelerometer sensory data (ISAR+)

ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ แสดงดังภาพที่ 3-25 เริ่มต้นจากการแปลงข้อมูล Accelerometer เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน โดยคำนวณค่า Magnitude M_i และค่าเฉลี่ย Magnitude \bar{M}_j สำหรับหาค่าส่วนเบี่ยงเบนมาตรฐาน $SD_{j(mag)}^{act}$ ซึ่งพิจารณาข้อมูลที่ละ window โดยใช้สมการที่ (3.1) และ (3.2) (บรรทัดที่ 1-5) เมื่อแปลงข้อมูลครบทุก window แล้ว จากนั้นคำนวณค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานแต่ละกิจกรรม $SD_{avg(mag)}^{act}$ โดยใช้สมการที่ (3.3) (บรรทัดที่ 7) เมื่อแปลงข้อมูลและคำนวณค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานแต่ละกิจกรรมเสร็จแล้ว จะหาค่าส่วนเบี่ยงเบนมาตรฐานที่มากที่สุดของกลุ่มกิจกรรมแบบนิ่ง $SD_{max(mag)}^{dor}$ โดยพิจารณาจาก $SD_{avg(mag)}^{act}$ โดยที่ *act* คือ กิจกรรมการนั่ง (*sitting*) และกิจกรรมการยืน (*standing*) (บรรทัดที่ 9) จากนั้นหาค่าส่วนเบี่ยงเบนมาตรฐานที่น้อยที่สุดของกลุ่มกิจกรรมแบบเคลื่อนไหว $SD_{min(mag)}^{ene}$ พิจารณาจาก $SD_{avg(mag)}^{act}$ โดยที่ *act* คือ กิจกรรมการเดิน (*walking*) กิจกรรมการวิ่ง (*jogging*) และกิจกรรมการขึ้นลงบันได (*stairs*) (บรรทัดที่ 10) แล้วจึงคำนวณหาค่าขีดแบ่ง *Threshold* โดยใช้สมการที่ (3.4) (บรรทัดที่ 11) ขั้นตอนต่อมาพิจารณาเฉพาะข้อมูลกิจกรรมแบบเคลื่อนไหว แปลงข้อมูล Accelerometer ที่ละ window ให้เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่นและความโด่ง คำนวณส่วนเบี่ยงเบนมาตรฐาน $SD_{j(ax)}^{act}$, $SD_{j(ay)}^{act}$ และ $SD_{j(az)}^{act}$ โดยใช้สมการที่ (3.5) ถึง (3.7) (บรรทัดที่ 14) คำนวณความหนาแน่น $Dens_{j(ax)}^{act}$, $Dens_{j(ay)}^{act}$ และ $Dens_{j(az)}^{act}$ โดยใช้สมการที่ (3.12) ถึง (3.14) (บรรทัดที่ 15) และคำนวณความโด่ง $Kurt_{j(ax)}^{act}$, $Kurt_{j(ay)}^{act}$ และ $Kurt_{j(az)}^{act}$ โดยใช้สมการที่ (3.15) ถึง (3.17) (บรรทัดที่ 16) จากนั้นจะคำนวณค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐาน $SD_{avg(ax)}^{act}$, $SD_{avg(ay)}^{act}$ และ $SD_{avg(az)}^{act}$ โดยใช้สมการที่ (3.18) ถึง (3.20) แล้วกำหนดให้ตัวแปร $SD_{CM}^{act} = (SD_{avg(ax)}^{act}, SD_{avg(ay)}^{act}, SD_{avg(az)}^{act})$ (บรรทัดที่ 18) จากนั้นคำนวณค่าเฉลี่ยของความหนาแน่น $Dens_{avg(ax)}^{act}$, $Dens_{avg(ay)}^{act}$ และ $Dens_{avg(az)}^{act}$ โดยใช้สมการที่ (3.21) ถึง (3.23) แล้วกำหนดให้ตัวแปร $Dens_{CM}^{act} = (Dens_{avg(ax)}^{act}, Dens_{avg(ay)}^{act}, Dens_{avg(az)}^{act})$ (บรรทัดที่ 19) จากนั้นคำนวณค่าเฉลี่ยของความโด่ง $Kurt_{avg(ax)}^{act}$, $Kurt_{avg(ay)}^{act}$ และ $Kurt_{avg(az)}^{act}$ โดยใช้สมการที่ (3.24) ถึง (3.26) แล้วกำหนดให้ตัวแปร $Kurt_{CM}^{act} = (Kurt_{avg(ax)}^{act}, Kurt_{avg(ay)}^{act}, Kurt_{avg(az)}^{act})$ (บรรทัดที่ 20) แล้วจึงจัดเก็บค่า SD_{CM}^{act} , $Dens_{CM}^{act}$ และ $Kurt_{CM}^{act}$ ไว้ใน *CM* (บรรทัดที่ 21)

3.3.2 การพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ ขั้นตอนออนไลน์ (Recognition)

- ปรับปรุงตัวแบบรู้จำกิจกรรมโดยใช้มาตรวัด 3 ตัว ได้แก่ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ความหนาแน่น (Density) และความโด่ง (Kurtosis) วิธีการทางสถิติที่ใช้ในการวิเคราะห์ข้อมูลมีอยู่ด้วยกันหลายวิธี ได้แก่ ส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่น ความโด่ง ความเบ้ ความสัมพันธ์ และช่วงข้อมูล เป็นต้น ในส่วนของวิธีการ ISAR ที่ได้ใช้ส่วนเบี่ยงเบนมาตรฐาน

ในการรู้จำกิจกรรมนั้น วิทยานิพนธ์นี้จึงได้พิจารณาวิธีการทางสถิติอื่น ๆ ที่เมื่อใช้ร่วมกันกับส่วนเบี่ยงเบนมาตรฐานแล้วสามารถรู้จำกิจกรรมได้ดี เพื่อที่จะนำมาใช้เป็นเกณฑ์สำหรับการปรับตัวแบบรู้จำกิจกรรมได้ จึงได้ทดลองจับคู่การใช้ส่วนเบี่ยงเบนมาตรฐานกับวิธีการอื่น ๆ ในการรู้จำกิจกรรม ซึ่งมีผลลัพธ์การรู้จำกิจกรรม ดังตารางที่ 3-3

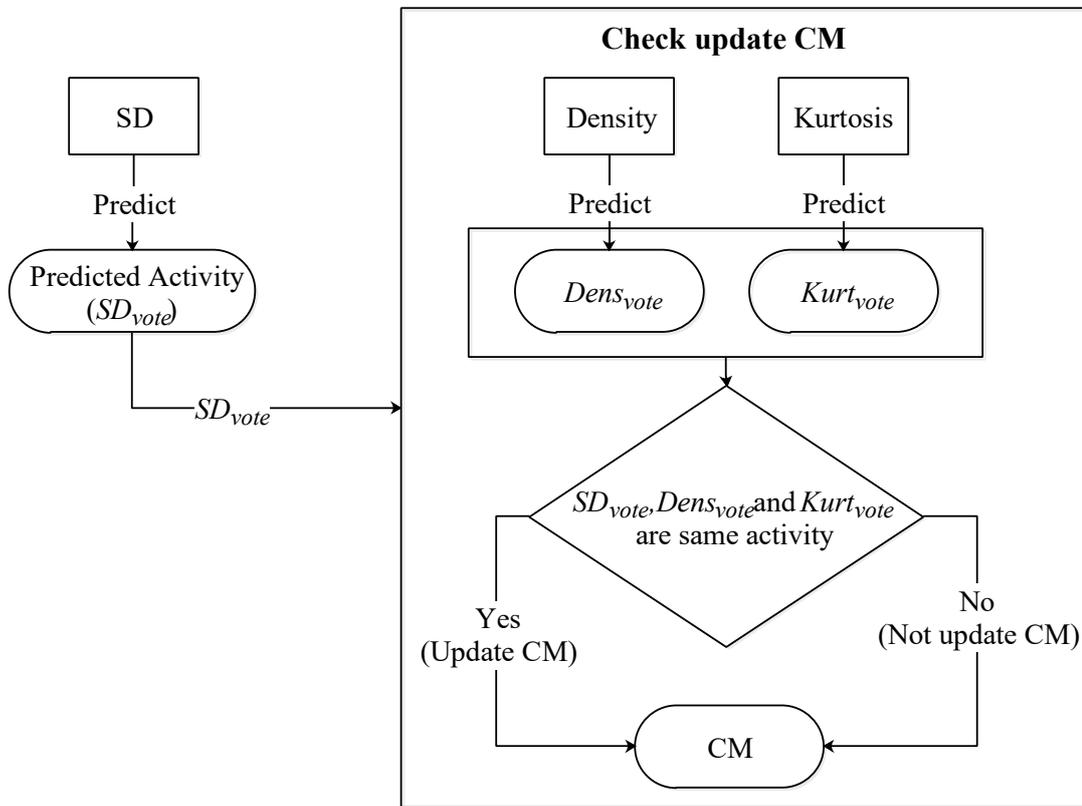
ตารางที่ 3-3 การจับคู่วิธีการ SD และวิธีการทางสถิติอื่น ๆ ในการรู้จำกิจกรรม โดยใช้ข้อมูล WISDM

วิธีการ	การระบุกิจกรรมตรงกัน (%)	ความถูกต้องของการระบุกิจกรรม (%)
SD และ Density	77.81	80.22
SD และ Correlation	38.42	78.56
SD และ Kurtosis	53.04	89.97
SD และ Range	89.59	67.51
SD, Density และ Range	74.77	80.9
SD, Density และ Kurtosis	44.68	91.64
SD, Density, Kurtosis และ Range	43.60	92.09
SD, Density, Correlation และ Kurtosis	14.77	93.33
SD, Density, Correlation, Kurtosis และ Range	14.50	93.43

จากตารางที่ 3-3 จะเห็นว่ายิ่งใช้วิธีการทางสถิติมากขึ้น ก็มีแนวโน้มที่จะรู้จำกิจกรรมได้ถูกต้องสูงขึ้นด้วย แต่อย่างไรก็ตามการใช้วิธีการทางสถิติหลายตัวจะทำให้เพิ่มการคำนวณมากขึ้นเหมือนกัน เมื่อพิจารณาหาเกณฑ์สำหรับปรับปรุงตัวแบบรู้จำกิจกรรม จึงได้เลือกส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่นและความโค้ง เนื่องจากเมื่อใช้ทั้ง 3 ตัวนี้รวมกัน สามารถระบุกิจกรรมได้ถูกต้องถึง 91.64% อีกทั้งยังมีโอกาสที่จะทำการปรับปรุงตัวแบบรู้จำกิจกรรมถึง 44.68% ซึ่งขั้นตอนในการปรับปรุงตัวแบบรู้จำกิจกรรมมีรายละเอียดดังภาพที่ 3-26

จากภาพที่ 3-26 หลังจากรู้จำกิจกรรมด้วยการใช้ส่วนเบี่ยงเบนมาตรฐาน จะทำการตรวจสอบว่าต้องปรับปรุงตัวแบบรู้จำกิจกรรมหรือไม่ โดยการคำนวณความหนาแน่นและความโค้งของข้อมูล แล้วนำไปเปรียบเทียบกับค่าที่เก็บไว้ใน Classifier model ซึ่งใช้หลักการเดียวกันกับตอนที่ทำการรู้จำกิจกรรมด้วยส่วนเบี่ยงเบนมาตรฐาน จากนั้นจะพิจารณากิจกรรมที่ระบุด้วยส่วนเบี่ยงเบน

มาตรฐาน ความหนาแน่นและความโด่ง ถ้าหากทั้ง 3 วิธีระบุเป็นกิจกรรมเดียวกันก็จะทำการปรับปรุงตัวแบบรู้จำกิจกรรม โดยมีขั้นตอนวิธีดังสมการที่ (3.24) ถึง (3.26)



ภาพที่ 3-26 ขั้นตอนการตรวจสอบการปรับปรุงตัวแบบรู้จำกิจกรรม

ปรับปรุงตัวแบบรู้จำกิจกรรม โดยกำหนดให้ $CM = (newSD_{CM}^{act}, newDens_{CM}^{act}, newKurt_{CM}^{act})$ คำนวณได้จากสมการที่ (3.24) ถึง (3.26)

ปรับปรุงส่วนเบี่ยงเบนมาตรฐานภายใน Classifier model

$$newSD_{CM}^{act} = \frac{SD_{CM}^{act} + SD_j}{2} \tag{3.24}$$

ปรับปรุงความหนาแน่นภายใน Classifier model

$$newDens_{CM}^{act} = \frac{Dens_{CM}^{act} + Dens_j}{2} \tag{3.25}$$

ปรับปรุงความโค้งภายใน Classifier model

$$newKurt_{CM}^{act} = \frac{Kurt_{CM}^{act} + Kurt_j}{2} \quad (3.26)$$

โดยที่	SD_{CM}^{act}	คือ ค่าส่วนเบี่ยงเบนมาตรฐานเดิมที่อยู่ใน CM
	SD_j	คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูลที่เข้ามาใหม่
	$Dens_{CM}^{act}$	คือ ค่าความหนาแน่นเดิมที่อยู่ใน CM
	$Dens_j$	คือ ค่าความหนาแน่นของข้อมูลที่เข้ามาใหม่
	$Kurt_{CM}^{act}$	คือ ค่าความโค้งเดิมที่อยู่ใน CM
	$Kurt_j$	คือ ค่าความโค้งของข้อมูลที่เข้ามาใหม่

การรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) ที่ได้กล่าวมาข้างต้น สามารถอธิบายเป็นขั้นตอนได้ดังภาพที่ 3-27 และ 3-28

ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ ISAR+ แสดงดังภาพที่ 3-27 ข้อมูลที่เข้ามาเป็นข้อมูลกระแสเชิงเวลา Accelerometer sensor ซึ่งนำมาคำนวณที่ละ window เริ่มจากการคำนวณค่า Magnitude M_i และค่าเฉลี่ย Magnitude \bar{M}_j สำหรับหาค่าส่วนเบี่ยงเบนมาตรฐาน $SD_{j(mag)}$ โดยใช้สมการที่ (3.1) และ (3.2) (บรรทัดที่ 1-5) จากนั้นตรวจสอบว่าข้อมูลที่อยู่ในกลุ่มกิจกรรมแบบนิ่งหรือกลุ่มกิจกรรมแบบเคลื่อนไหว โดยเปรียบเทียบค่า $SD_{j(mag)}$ และค่า *Threshold* ถ้าค่า $SD_{j(mag)}$ น้อยกว่าค่า *Threshold* แสดงว่าข้อมูลอยู่ในกลุ่มกิจกรรมแบบนิ่ง (บรรทัดที่ 6) การรู้จำกิจกรรมแบบนิ่งเริ่มจากการคำนวณค่าเฉลี่ยของข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ที่เข้ามาใหม่ $\bar{ax}_j, \bar{ay}_j, \bar{az}_j$ จากนั้นคำนวณหาระยะห่างระหว่างข้อมูล Accelerometer ตามแนวแกน X และ Y $Dist(\bar{ax}_j, \bar{ay}_j)$ และคำนวณหาระยะห่างระหว่างข้อมูล Accelerometer ตามแนวแกน X และ Z $Distance(\bar{ax}_j, \bar{az}_j)$ โดยใช้สมการที่ (3.8) และ (3.9) (บรรทัดที่ 7-8) จากนั้นจำแนกข้อมูลว่าเป็นกิจกรรมยืนหรือกิจกรรมนั่ง ด้วยการเปรียบเทียบระหว่างค่าของ $Dist(\bar{ax}_j, \bar{ay}_j)$ และ $Dist(\bar{ax}_j, \bar{az}_j)$ ถ้า $Dist(\bar{ax}_j, \bar{ay}_j)$ มากกว่า $Dist(\bar{ax}_j, \bar{az}_j)$ แสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมการยืน กำหนดให้ $P_{act} = standing$ แต่ถ้า $Dist(\bar{ax}_j, \bar{ay}_j)$ น้อยกว่า $Dist(\bar{ax}_j, \bar{az}_j)$ แสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมการนั่ง กำหนดให้ $P_{act} = sitting$ (บรรทัดที่ 9-13) แต่ถ้าข้อมูลที่เข้ามาอยู่ในกลุ่มกิจกรรมแบบเคลื่อนไหว คือค่า $SD_{j(mag)}$ มากกว่าค่า *Threshold* (บรรทัดที่ 14) จะคำนวณค่าเฉลี่ยข้อมูล Accelerometer ตามแนวแกน X, Y และ Z

ที่เข้ามาใหม่ $\bar{ax}_j, \bar{ay}_j, \bar{az}_j$ (บรรทัดที่ 15) จากนั้นคำนวณส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer แต่ละแกน $SD_{j(ax)}, SD_{j(ay)}$ และ $SD_{j(az)}$ แล้วกำหนดให้ตัวแปร $SD_j = (SD_{j(ax)}, SD_{j(ay)}, SD_{j(az)})$ (บรรทัดที่ 16) จากนั้นนำ SD_j ไปคำนวณกับค่า SD_{CM}^{act} ที่อยู่ใน CM ถ้า SD_{CM}^{act} ของกิจกรรมไหนมีค่าใกล้เคียงกับ SD_j มากที่สุดก็จะระบุว่าข้อมูลที่เข้ามาใหม่เป็นกิจกรรมนั้น $P_{act} = act$ (บรรทัดที่ 17-18)

Algorithm 4: 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 activities. */
/*  $J$  = 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. (3.1) 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  $SD_{j(mag)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (M_i - \bar{M}_j)^2}$ 
8     if  $SD_{j(mag)} < Threshold$  then
9       Compute the average values  $(\bar{ax}_j, \bar{ay}_j, \bar{az}_j)$  of each acceleration values  $x, y,$  and  $z$ .
10      Compute  $Dist(\bar{ax}, \bar{ay})$  and  $Dist(\bar{ax}, \bar{az})$  using eq. (3.8) and (3.9)
11      if  $Dist(\bar{ax}, \bar{ay}) > Dist(\bar{ax}, \bar{az})$  then
12        |  $P_{act} = standing$ 
13      else
14        |  $P_{act} = sitting$ 
15      end
16    else
17      Compute the average values  $(\bar{ax}_j, \bar{ay}_j, \bar{az}_j)$  of each acceleration values  $x, y,$  and  $z$ .
18      Compute the standard deviation of each acceleration values  $SD_{j(ax)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax - \bar{ax})^2}$ ,
19       $SD_{j(ay)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay - \bar{ay})^2}, SD_{j(az)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (az - \bar{az})^2}$  then set to  $SD_j$ 
20       $SD_j = (SD_{j(ax)}, SD_{j(ay)}, SD_{j(az)})$ 
21      Find the nearest activity  $act$  such that
22       $act = argmin_{act=walking, jogging, stairs} (\|SD_j - SD_{CM}^{act}\|)$ 
23      Set the activity of  $act$  to  $P_{act}$ .
24    end
25  end
26 end

```

ภาพที่ 3-27 ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)

Algorithm 5: 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), SKurtj(az))
4 Find the nearest activity act with density and kurtosis such that
   Densvote = argminact=walking,jogging,stairs(||Densj - DensCMact||)
   Kurtvote = argminact=walking,jogging,stairs(||Kurtj - KurtCMact||)
5 if SDvote, Densvote and Kurtvote are same activity then
6 | Update CM such that
   | newSDCMact =  $\frac{SD_{CM}^{act} + SD_j}{2}$ , newDensCMact =  $\frac{Dens_{CM}^{act} + Dens_j}{2}$ , newKurtCMact =  $\frac{Kurt_{CM}^{act} + Kurt_j}{2}$ 
7 | Set CM = {newSDCMact, newDensCMact, newKurtCMact}.
8 else
9 | Not update CM
10 end

```

ภาพที่ 3-28 ขั้นตอนออนไลน์ การปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)

ขั้นตอนออนไลน์ การปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ แสดงดังภาพที่ 3-28 เมื่อจำแนกกิจกรรมในขั้นตอนการรู้จำกิจกรรมเสร็จแล้ว จะตรวจสอบว่าสามารถปรับปรุงตัวแบบรู้จำกิจกรรมได้หรือไม่ โดยใช้มาตรวัด 3 ตัว ได้แก่ ส่วนเบี่ยงเบนมาตรฐาน (SD_{vote}) ความหนาแน่น ($Dens_{vote}$) และความโด่ง ($Kurt_{vote}$) เริ่มแรกกำหนดให้ $SD_{vote} = P_{act}$ ซึ่งใช้ส่วนเบี่ยงเบนมาตรฐานระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรม (บรรทัดที่ 1) จากนั้นคำนวณค่าความหนาแน่นและความโด่งของข้อมูล Accelerometer ที่เข้ามาใหม่ในแต่ละแกน กำหนดให้ $Dens_j = (Dens_{j(ax)}, Dens_{j(ay)}, Dens_{j(az)})$ (บรรทัดที่ 2) และกำหนดให้ $Kurt_j = (Kurt_{j(ax)}, Kurt_{j(ay)}, Kurt_{j(az)})$ (บรรทัดที่ 3) จากนั้นจะนำค่า $Dens_j$ และ $Kurt_j$ ไปคำนวณกับ $Dens_{CM}^{act}$ และ $Kurt_{CM}^{act}$ ที่อยู่ใน CM โดย $Dens_{vote}$ จะระบุเป็นกิจกรรมที่มีค่า $Dens_{CM}^{act}$ ใกล้เคียงกับ $Dens_j$ มากที่สุด และ $Kurt_{vote}$ จะระบุเป็นกิจกรรมที่มีค่า $Kurt_{CM}^{act}$ ใกล้เคียงกับ $Kurt_j$ มากที่สุด

(บรรทัดที่ 4) จากนั้นจะเปรียบเทียบการระบุกิจกรรมของมาตรวัด SD_{vote} , $Dens_{vote}$ และ $Kurt_{vote}$ ถ้าทั้ง 3 มาตรวัดระบุเป็นกิจกรรมเดียวกันจะทำการปรับปรุงตัวแบบรู้จำกิจกรรม (บรรทัดที่ 5) โดย 1) ปรับปรุงค่าส่วนเบี่ยงเบนมาตรฐานของ CM ใหม่ ($newSD_{CM}^{act}$) คำนวณจากค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐานที่อยู่ใน CM (SD_{CM}^{act}) และส่วนเบี่ยงเบนมาตรฐานของข้อมูลที่เข้ามาใหม่ (SD_j) 2) ปรับปรุงค่าความหนาแน่นของ CM ใหม่ ($newDens_{CM}^{act}$) คำนวณจากค่าเฉลี่ยของความหนาแน่นที่อยู่ใน CM ($Dens_{CM}^{act}$) และความหนาแน่นของข้อมูลที่เข้ามาใหม่ ($Dens_j$) และ 3) ปรับปรุงค่าความโด่งของ CM ใหม่ ($newKurt_{CM}^{act}$) คำนวณจากค่าเฉลี่ยของความโด่งที่อยู่ใน CM ($Kurt_{CM}^{act}$) และความโด่งของข้อมูลที่เข้ามาใหม่ ($Kurt_j$) (บรรทัดที่ 6-7) แต่ถ้ามาตรวัดทั้ง 3 ไม่ได้ระบุเป็นกิจกรรมเดียวกันก็จะไม่ปรับปรุงตัวแบบรู้จำกิจกรรม (บรรทัดที่ 8-9)

บทที่ 4

ผลการดำเนินงาน

ในบทนี้จะกล่าวถึงผลการดำเนินงานโดยการวัดประสิทธิภาพความถูกต้องและเวลาที่ใช้ในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนการรู้จำกิจกรรมของวิธีการที่นำเสนอ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR) และวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory (ISAR+) เปรียบเทียบกับวิธีการ Adaptive mobile activity recognition system with evolving data streams (Abdallah และคณะ, 2015) ใน 2 ข้อมูลกิจกรรม คือ ข้อมูลกิจกรรม WISDM และข้อมูลกิจกรรม UniMiB-SHAR โดยใช้วิธีการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธี Precision, Recall และ F-measure โดยรายละเอียดของผลดำเนินงานแสดงดังต่อไปนี้

- 4.1) ข้อมูลกิจกรรมที่ใช้ในการทดลอง
- 4.2) การออกแบบการทดลองและวิธีการที่ใช้วัดประสิทธิภาพตัวแบบรู้จำกิจกรรม
- 4.3) การวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรม
- 4.5) การวัดประสิทธิภาพด้านเวลาของตัวแบบรู้จำกิจกรรม

4.1 ข้อมูลกิจกรรมที่ใช้ในการทดลอง

4.1.1 ข้อมูล WISDM¹³

ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 36 คน ด้วยการใช้อุปกรณ์ที่สามารถตรวจจับค่า Accelerometer ของอุปกรณ์สมาร์ทโฟน โดยให้อาสาสมัครทั้ง 36 คน สวมใส่อุปกรณ์สมาร์ทโฟนไว้ในกระเป๋าทางเกงด้านหน้า ซึ่งตั้งค่าอัตราสุ่มตัวอย่างของข้อมูลเท่ากับ 20 Hz และทำกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรม ได้แก่ การนั่ง การยืน การเดิน การวิ่ง และการขึ้นลงบันได โดยในการทดลองนี้ได้เลือกใช้ข้อมูลการทำกิจกรรมของผู้ใช้ 19 คนที่ทำกิจกรรมครบทั้ง 5 กิจกรรม ซึ่งมีจำนวนตัวอย่างข้อมูลในแต่ละกิจกรรม ดังตารางที่ 4-1 และตัวอย่างข้อมูลกิจกรรมดังภาพที่ 4-1

¹³ <http://www.cis.fordham.edu/wisdm>

ตารางที่ 4-1 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ WISDM

กิจกรรม	จำนวนตัวอย่าง (Record)
การยืน	38,520
นั่ง	50,000
การเดิน	223,300
การวิ่ง	129,900
การขึ้นลงบันได	177,100

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
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	27	Walking	\vdots	ax_i	ay_i	az_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	27	Walking	\vdots	ax_N	ay_N	az_N

ภาพที่ 4-1 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 27 จากข้อมูล WISDM

4.1.2 ข้อมูล UniMiB-SHAR¹⁴

ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 30 คน ด้วยการใช้อุปกรณ์ที่สามารถตรวจจับค่า Accelerometer ของอุปกรณ์สมาร์ทโฟน โดยให้อาสาสมัครทั้ง 30 คน สวมใส่อุปกรณ์สมาร์ทโฟนไว้ในกระเป๋าทางเกงด้านหน้า ซึ่งตั้งค่าอัตราสุ่มตัวอย่างของข้อมูลเท่ากับ 50 Hz และทำกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรม โดยในการทดลองนี้ได้เลือกใช้ข้อมูลการทำกิจกรรมของผู้ใช้จำนวน 23 คนที่ทำกิจกรรมครบทั้ง 5 กิจกรรม ซึ่งมีจำนวนตัวอย่างข้อมูลในแต่ละกิจกรรมดังตารางที่ 4-2 และมีตัวอย่างข้อมูลกิจกรรมดังภาพที่ 4-2

¹⁴ <http://www.sal.disco.unimib.it/technologies/unimib-shar>

ตารางที่ 4-2 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ UniMiB-SHAR

กิจกรรม	จำนวนตัวอย่าง
การยืน	319,550
นั่ง	405,350
การเดิน	482,900
การวิ่ง	395,200
การขึ้นลงบันได	245,500

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
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	13	Standing	ax_i	ay_i	az_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	13	Standing	ax_N	ay_N	az_N

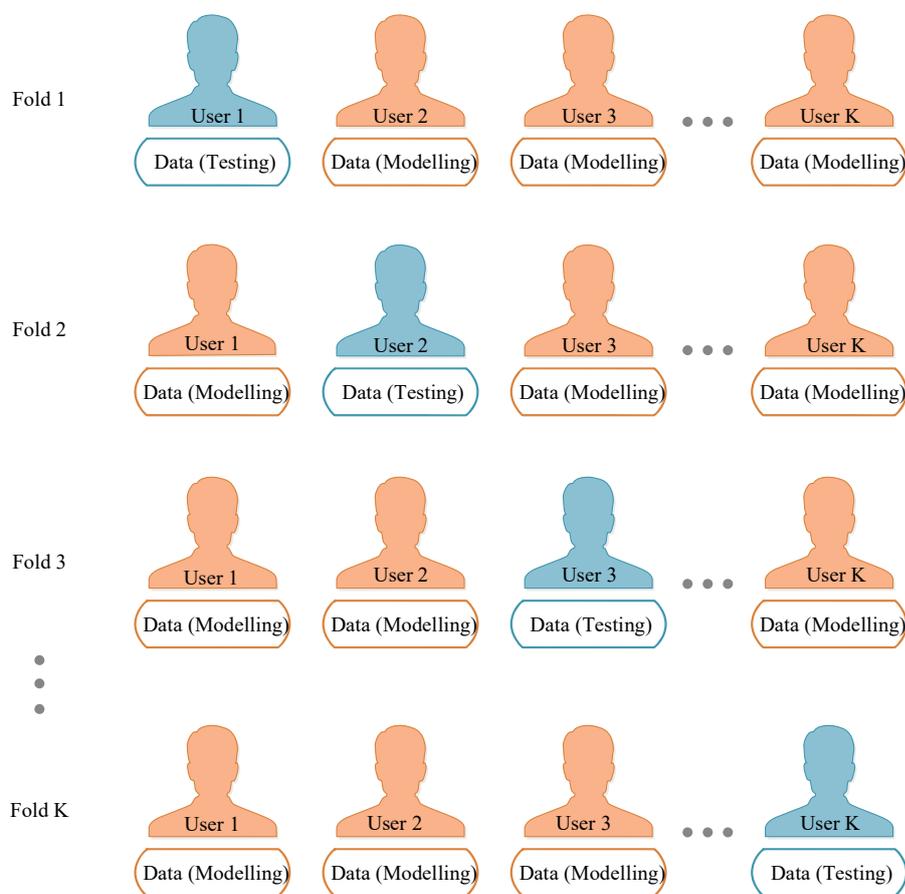
ภาพที่ 4-2 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 13 จากข้อมูล UniMiB-SHAR

4.2 การออกแบบการทดลองและวิธีการที่ใช้วัดประสิทธิภาพตัวแบบรู้จำกิจกรรม

สำหรับการออกแบบการทดลองในวิทยานิพนธ์นี้ได้ใช้วิธีการแบ่งข้อมูล และวิธีการวัดประสิทธิภาพของตัวแบบรู้จำกิจกรรม ดังนี้

4.2.1 ขั้นตอนการแบ่งข้อมูลสำหรับสร้างตัวแบบรู้จำกิจกรรมและข้อมูลทดสอบตัวแบบรู้จำกิจกรรม

วิทยานิพนธ์นี้ได้ใช้วิธี K-Fold Cross Validation สำหรับแบ่งข้อมูลกิจกรรมเพื่อใช้สร้างตัวแบบรู้จำกิจกรรมและใช้ทดสอบตัวแบบรู้จำกิจกรรม โดยจะแบ่งข้อมูลกิจกรรมออกเป็น K ชุด ซึ่งกำหนดให้ K แทนจำนวนของผู้ใช้ ข้อมูล 1 ชุดคือข้อมูลกิจกรรมของผู้ใช้ 1 คน การเลือกข้อมูลกิจกรรมชุดใดสร้างตัวแบบรู้จำกิจกรรมและชุดใดใช้ทดสอบตัวแบบรู้จำกิจกรรม มีรายละเอียดดังภาพที่ 4-3



ภาพที่ 4-3 ตัวอย่างการแบ่งข้อมูลกิจกรรมสำหรับสร้างและทดสอบตัวแบบรู้จำกิจกรรมด้วยวิธี K-Fold Cross Validation

จากภาพที่ 4-3 แบ่งข้อมูลกิจกรรมออกเป็น K ชุด เพื่อใช้สำหรับสร้างตัวแบบรู้จำกิจกรรม หลังจากนั้นทำการทดสอบประสิทธิภาพของตัวแบบรู้จำกิจกรรม K ครั้ง ดังนี้

- รอบที่ 1 ใช้ข้อมูลชุดที่ 2 ถึงชุดที่ K สร้างตัวแบบรู้จำกิจกรรมและใช้ข้อมูลชุดที่ 1 เพื่อทำการทดสอบตัวแบบรู้จำกิจกรรม
- รอบที่ 2 ใช้ข้อมูลชุดที่ 1 และชุดที่ 3 ถึงชุดที่ K สร้างตัวแบบรู้จำกิจกรรมและใช้ข้อมูลชุดที่ 2 เพื่อทำการทดสอบตัวแบบรู้จำกิจกรรม
- รอบที่ 3 ใช้ข้อมูลชุดที่ 1, 2 และชุดที่ 4 ถึงชุดที่ K สร้างตัวแบบรู้จำกิจกรรมและใช้ข้อมูลชุดที่ 3 เพื่อทำการทดสอบตัวแบบรู้จำกิจกรรม
- รอบที่ K ใช้ข้อมูลชุดที่ 1 ถึงชุดที่ K-1 สร้างตัวแบบรู้จำกิจกรรมและใช้ข้อมูลชุดที่ K เพื่อทำการทดสอบตัวแบบรู้จำกิจกรรม

ข้อดีของวิธีการ K-Fold Cross Validation คือสามารถป้องกันการเกิด Overfitting ของโมเดลได้ เพราะจะมีการสลับกันของข้อมูลในการทำหน้าที่ทั้งตัวสร้างโมเดลและเป็นตัวทดสอบโมเดล ดังนั้นจึงสามารถช่วยลดระดับความ Bias ลงได้

4.2.2 วิธีการที่ใช้วัดประสิทธิภาพของตัวแบบรู้จำกิจกรรม

สำหรับขั้นตอนการวัดประสิทธิภาพความถูกต้องได้เลือกใช้วิธีการวัดประสิทธิภาพคือ Precision, Recall และ F-measure โดยมีวิธีการคำนวณดังต่อไปนี้

- **Precision** เป็นการวัดความแม่นยำของตัวแบบรู้จำกิจกรรม โดยวัดจากจำนวนที่ตัวแบบรู้จำกิจกรรมทำนายถูกต้องและเป็นกิจกรรมที่กำลังพิจารณา ว่ามีอัตราส่วนเท่าไรกับจำนวนกิจกรรมที่ถูกทำนายเป็นกิจกรรมที่กำลังพิจารณาทั้งหมด สามารถคำนวณตามสมการที่ (4.1)

$$Precision = \frac{TP}{TP + FP} \quad (4.1)$$

- **Recall** เป็นการวัดความถูกต้องของตัวแบบรู้จำกิจกรรม โดยวัดจากจำนวนที่ตัวแบบรู้จำกิจกรรมทำนายถูกต้องและเป็นกิจกรรมที่กำลังพิจารณา ว่ามีอัตราส่วนเท่าไรกับจำนวนกิจกรรมที่กำลังพิจารณาทั้งหมด สามารถคำนวณตามสมการที่ (4.2)

$$Recall = \frac{TP}{TP + FN} \quad (4.2)$$

- **F-measure** เป็นการวัดความถูกต้องและแม่นยำของตัวแบบรู้จำกิจกรรม โดยใช้ค่าเฉลี่ยของ Precision และ Recall สามารถคำนวณตามสมการที่ (4.3)

$$F - measure = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4.3)$$

โดยที่ TP (True Positive) คือ จำนวนครั้งที่ตัวแบบรู้จำกิจกรรมทำนายถูกต้อง และเป็นกิจกรรมที่กำลังพิจารณา

FP (False Positive) คือ จำนวนครั้งที่ตัวแบบรู้จำกิจกรรมทำนายไม่ถูกต้อง แต่เป็นกิจกรรมที่กำลังพิจารณา

FN (False Negative) คือ จำนวนครั้งที่ตัวแบบรู้จำกิจกรรมทำนายไม่ถูกต้อง และไม่ เป็นกิจกรรมที่กำลังพิจารณา

4.3 การวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรม

การทดลองในวิทยานิพนธ์นี้ได้เปรียบเทียบวิธีการที่นำเสนอ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR) วิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory (ISAR+) และวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR) กับข้อมูลกิจกรรม WISDM และข้อมูลกิจกรรม UniMiB-SHAR โดยจะเปรียบเทียบประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรม ซึ่งมีรายละเอียดผลการทดลองดังต่อไปนี้

4.3.1 ผลการทดลองกับข้อมูลกิจกรรม WISDM

การรู้จำกิจกรรมด้วยวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล WISDM แสดงผลลัพธ์ดังตารางที่ 4-3 ถึง 4-5 สามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Precision, Recall และ F-measure แสดงดังภาพที่ 4-4 ถึง 4-6 จะเห็นว่าวิธีการ ISAR+ มีประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมที่ดีที่สุดในทุก ๆ กิจกรรม โดยเฉพาะอย่างยิ่งกิจกรรมการนั่ง การยืน และการวิ่ง ที่มีค่าความถูกต้องและความแม่นยำมากกว่า 90 เปอร์เซ็นต์ และเหตุผลที่วิธีการ ISAR ที่มีค่าความถูกต้องและความแม่นยำของการรู้จำกิจกรรมการนั่งและการยืนเท่ากับวิธีการ ISAR+ เนื่องจากทั้ง 2 วิธีมีขั้นตอนการรู้จำกิจกรรมแบบนิ่ง (Dormant activities) ที่เหมือนกัน

ตารางที่ 4-3 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ STAR กับข้อมูล WISDM

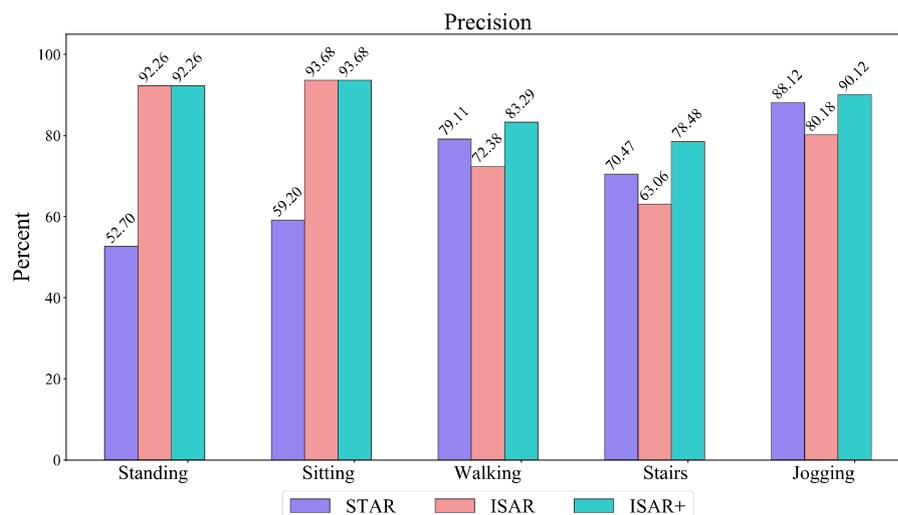
		Prediction activities				
		Standing	Sitting	Walking	Stairs	Jogging
Actual activities	Standing	27,740	2,240	1,320	6,620	600
	Sitting	220	44,600	1,780	80	3,320
	Walking	13,300	14,980	172,340	15,140	7,540
	Stairs	10,760	9,540	22,200	79,900	7,500
	Jogging	620	3,980	20,200	11,640	140,660

ตารางที่ 4-4 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR กับข้อมูล WISDM

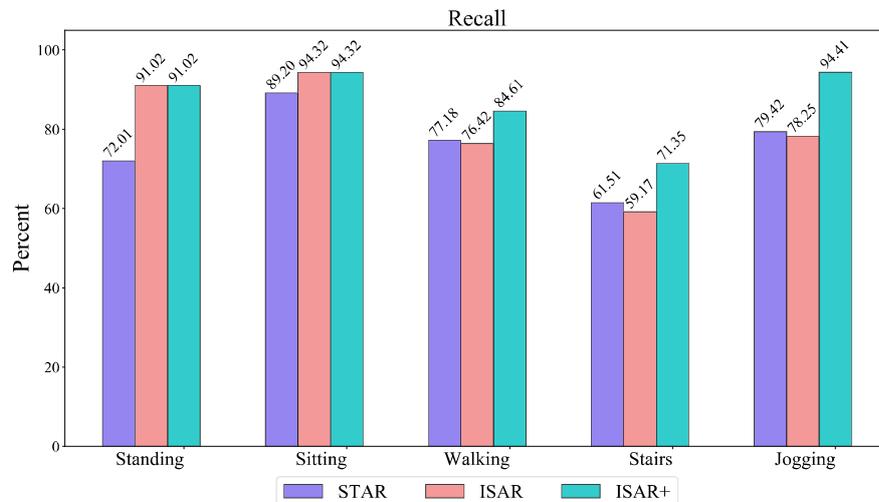
		Prediction activities				
		Standing	Sitting	Walking	Stairs	Jogging
Actual activities	Standing	35,060	3,020	60	380	0
	Sitting	2,420	47,160	20	400	0
	Walking	20	20	170,640	28,560	24,060
	Stairs	500	140	42,200	76,860	10,200
	Jogging	0	0	22,840	15,680	138,580

ตารางที่ 4-5 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR+ กับข้อมูล WISDM

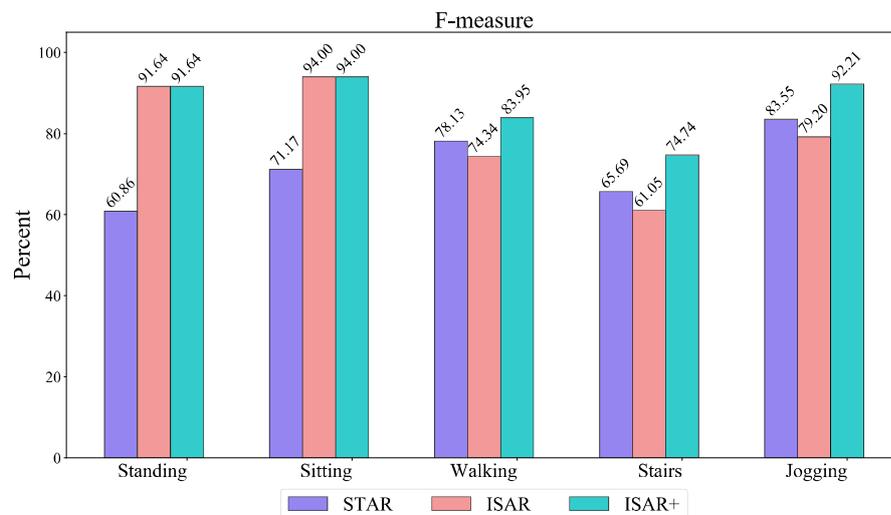
		Prediction activities				
		Standing	Sitting	Walking	Stairs	Jogging
Actual activities	Standing	35,060	3,020	20	400	20
	Sitting	2,420	47,160	40	380	0
	Walking	20	20	188,940	21,560	12,760
	Stairs	500	140	31,020	92,680	5,560
	Jogging	0	0	6,820	3,080	167,200



ภาพที่ 4-4 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM



ภาพที่ 4-5 แผนภูมิแท่งเปรียบเทียบ Recall ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM



ภาพที่ 4-6 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM

4.3.2 ผลการทดลองกับข้อมูลกิจกรรม UniMiB-SHAR

การรู้จำกิจกรรมด้วยวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล UniMiB-SHAR แสดงผลลัพธ์ดังตารางที่ 4-6 ถึง 4-8 สามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Precision, Recall และ F-measure แสดงดังภาพที่ 4-7 ถึง 4-9 จะเห็นว่าวิธีการ ISAR+ มีประสิทธิภาพทั้งความถูกต้องและความแม่นยำของการรู้จำกิจกรรมที่ดีที่สุด

ทุก ๆ กิจกรรม โดยเฉพาะอย่างยิ่งกิจกรรมการนั่ง การยืน และการวิ่ง ที่มีค่าความถูกต้องและความแม่นยำมากกว่า 90 เปอร์เซ็นต์

ตารางที่ 4-6 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ STAR กับข้อมูล UniMiB-SHAR

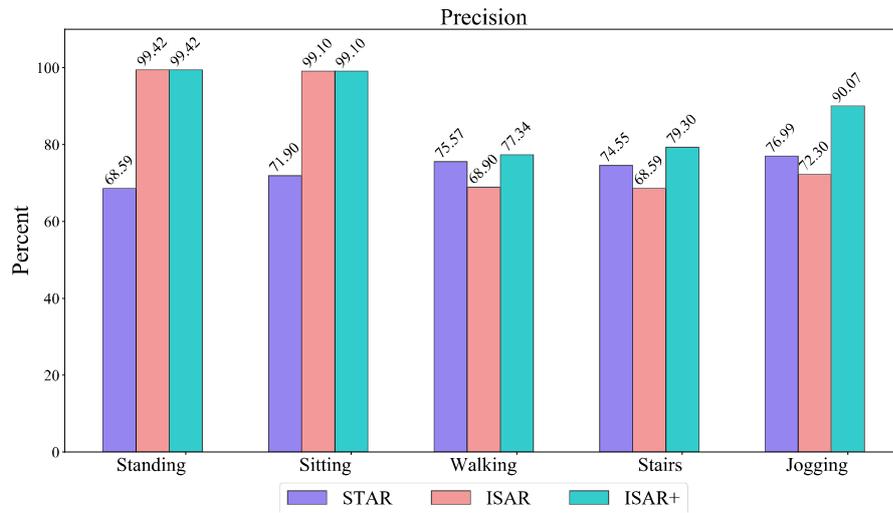
		Prediction activities				
		Standing	Sitting	Walking	Stairs	Jogging
Actual activities	Standing	256,200	48,500	4,100	8,650	2,100
	Sitting	74,050	315,300	8,400	6,500	1,100
	Walking	25,200	34,350	338,850	52,450	32,050
	Stairs	12,500	35,000	82,000	239,600	26,100
	Jogging	5,600	5,400	15,050	14,200	205,250

ตารางที่ 4-7 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR กับข้อมูล UniMiB-SHAR

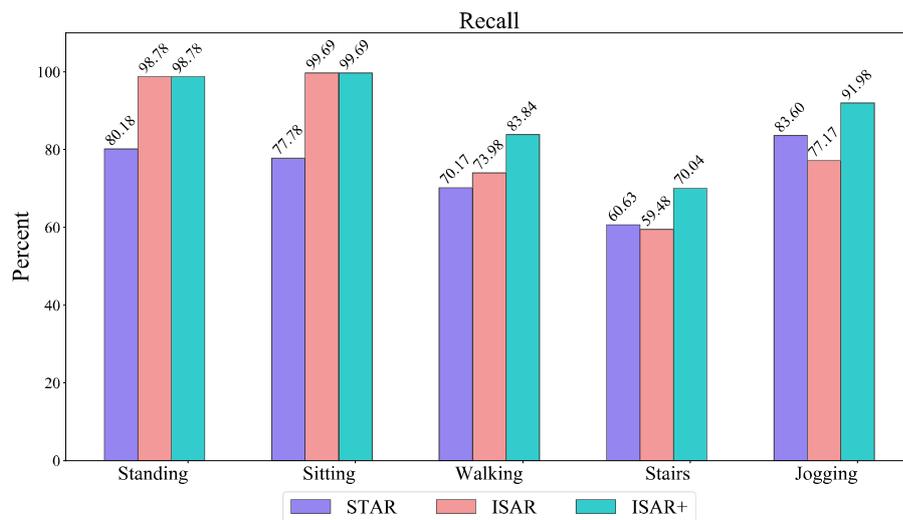
		Prediction activities				
		Standing	Sitting	Walking	Stairs	Jogging
Actual activities	Standing	315,650	3,400	450	50	0
	Sitting	1,000	404,100	200	50	0
	Walking	500	150	357,250	82,350	42,650
	Stairs	350	100	129,750	235,050	29,950
	Jogging	0	0	30,850	25,200	189,450

ตารางที่ 4-8 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR+ กับข้อมูล UniMiB-SHAR

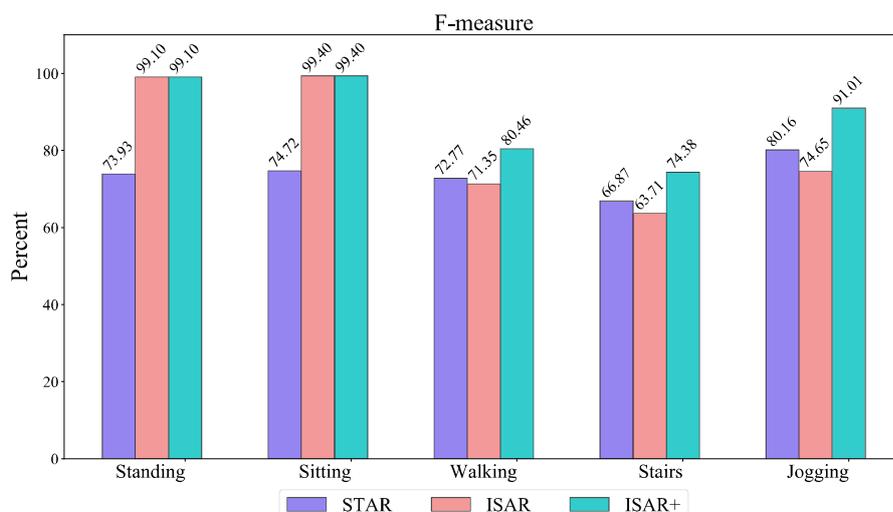
		Prediction activities				
		Standing	Sitting	Walking	Stairs	Jogging
Actual activities	Standing	315,650	3,400	450	50	0
	Sitting	1,000	404,100	200	50	0
	Walking	500	150	404,850	62,650	14,750
	Stairs	350	100	107,800	276,800	10,150
	Jogging	0	0	10,200	9,500	225,800



ภาพที่ 4-7 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR



ภาพที่ 4-8 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR



ภาพที่ 4-9 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR

4.4 การวัดประสิทธิภาพด้านเวลาของการรู้จำกิจกรรม

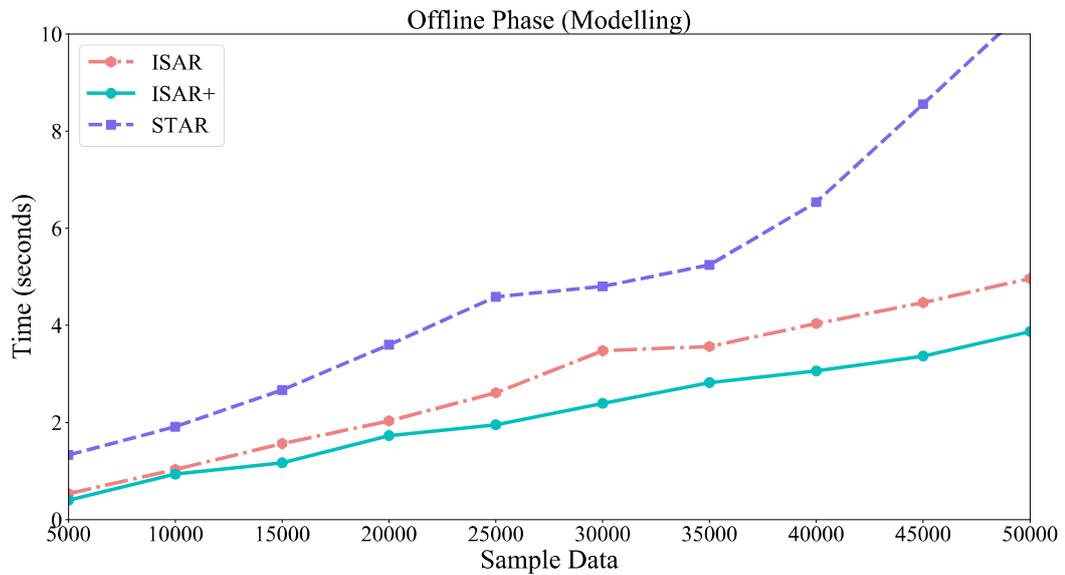
สำหรับการวัดประสิทธิภาพด้านเวลาของวิธีการที่นำเสนอ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR) และวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) เปรียบเทียบกับวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR) ซึ่งสามารถรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลา Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน โดยวิธีการ STAR ได้ใช้วิธีการแบ่งกลุ่มข้อมูลในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม จึงมีความซับซ้อนเชิงเวลาคือ $O(KNl)$ โดยที่ K คือ จำนวนกลุ่มในการแบ่งกลุ่มข้อมูล N คือ จำนวนตัวอย่างข้อมูลทั้งหมดของแต่ละกิจกรรม และ l คือ จำนวนการวนลูบในการแบ่งกลุ่มข้อมูลกิจกรรม ส่วนขั้นตอนการรู้จำกิจกรรมวิธีการ STAR ได้ใช้การแบ่งกลุ่มข้อมูลออกเป็น 2 กลุ่มแล้วใช้มาตรวัดหลายตัวในการระบุกิจกรรม ซึ่งมีความซับซ้อนเชิงเวลาคือ $O(2nl) + O(Kn)$ โดยที่ n คือ จำนวนตัวอย่างข้อมูลกิจกรรมภายใน 1 window (ขึ้นอยู่กับอัตราสุ่มตัวอย่างของข้อมูลนั้น) และในขั้นตอนปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ STAR มีความซับซ้อนเชิงเวลา คือ $O(Kn)$ ส่วนวิธีการ ISAR ในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมได้ทำการแปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานก่อนนำไปแบ่งกลุ่มข้อมูล ซึ่งมีความซับซ้อนเชิงเวลาคือ $O(N) + O(KJl)$ โดยที่ J คือ จำนวนของ window ขั้นตอนการรู้จำกิจกรรมวิธีการ ISAR ไม่ได้ทำการแบ่งกลุ่มข้อมูลและใช้เพียง 1 มาตรวัดในการระบุกิจกรรม จึงมีความซับซ้อนเชิงเวลาคือ $O(n)$ ส่วนวิธี ISAR+ ในขั้นตอนสร้างตัวแบบรู้จำกิจกรรมไม่มีการแบ่งกลุ่มข้อมูลแต่มีการแปลงข้อมูล

กิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน ความโด่ง ความหนาแน่น ซึ่งมีความซับซ้อนเชิงเวลาคือ $O(N)$ ในขั้นตอนการรู้จำกิจกรรมวิธีการ ISAR+ ใช้เพียง 1 มาตรการในการระบุกิจกรรมเช่นเดียวกับวิธีการ ISAR ดังนั้นจึงมีความซับซ้อนเชิงเวลาคือ $O(n)$ และขั้นตอนการปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ ได้พิจารณาค่าส่วนเบี่ยงเบนมาตรฐาน ค่าความโด่งและค่าความหนาแน่นของข้อมูลภายใน window จึงมีความซับซ้อนเชิงเวลา คือ $O(n)$ แสดงดังตารางที่ 4-9

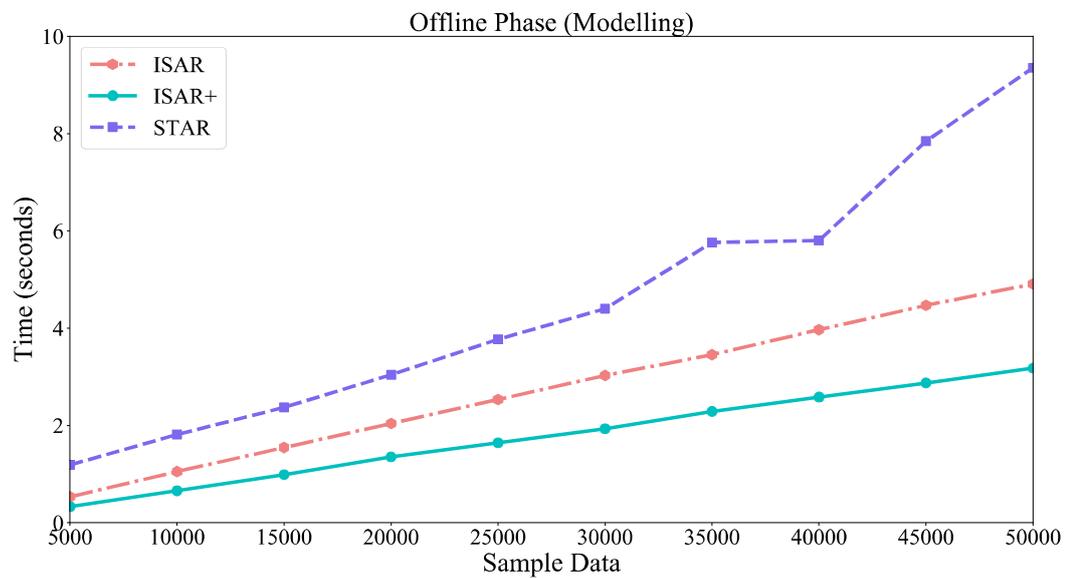
ตารางที่ 4-9 ความซับซ้อนเชิงเวลาของวิธีการ ISAR, ISAR+ และ STAR

วิธีการ	ขั้นตอนสร้างตัวแบบรู้จำกิจกรรม	ขั้นตอนรู้จำกิจกรรม	ขั้นตอนปรับปรุงตัวแบบรู้จำกิจกรรม
STAR	$O(KNl)$	$O(2nl) + O(Kn)$	$O(Kn)$
ISAR	$O(N) + O(KJl)$	$O(n)$	ไม่มีขั้นตอนนี้
ISAR+	$O(N)$	$O(n)$	$O(n)$

จากตารางที่ 4-9 ได้เปรียบเทียบความซับซ้อนเชิงเวลาที่ใช้ในการคำนวณของขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม การรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมของวิธีการ ISAR, ISAR+ และวิธีการ STAR ซึ่งขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมนั้นวิธีการ ISAR+ มีประสิทธิภาพด้านเวลาที่ดีที่สุด เนื่องจากเป็นวิธีการเดียวที่ไม่ได้ทำการแบ่งกลุ่มข้อมูล จึงทำให้ขั้นตอนการคำนวณลดลงมาก และเพื่อให้เห็นภาพชัดเจนยิ่งขึ้นจึงได้ลองทำการทดสอบจับเวลาที่ใช้ในการสร้างตัวแบบรู้จำกิจกรรมของวิธีการ ISAR, ISAR+ และวิธีการ STAR โดยใช้ข้อมูลกิจกรรม WISDM และ UniMiB-SHAR ซึ่งข้อมูลทั้ง 2 มีอัตราการสุ่มตัวอย่างที่ต่างกัน นั่นคือ 20 Hz และ 50 Hz ตามลำดับ โดยพิจารณาข้อมูลกิจกรรม 5000 ตัวอย่าง ถึง 50000 ตัวอย่าง ซึ่งเป็นกิจกรรมการยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันไดกิจกรรมละเท่า ๆ กันใช้เป็นข้อมูลสำหรับทดสอบ ประมวลผลวิธีการทดลองบนเครื่อง CPU core i5-7500 3.40 GHz และหน่วยความจำ (RAM) 8 GB ซึ่งเขียนโปรแกรมโดยใช้ภาษาไพทอน (Python) ผลลัพธ์การทดลองแสดงดังภาพที่ 4-10 และ 4-11



ภาพที่ 4-10 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนสร้างตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล WISDM

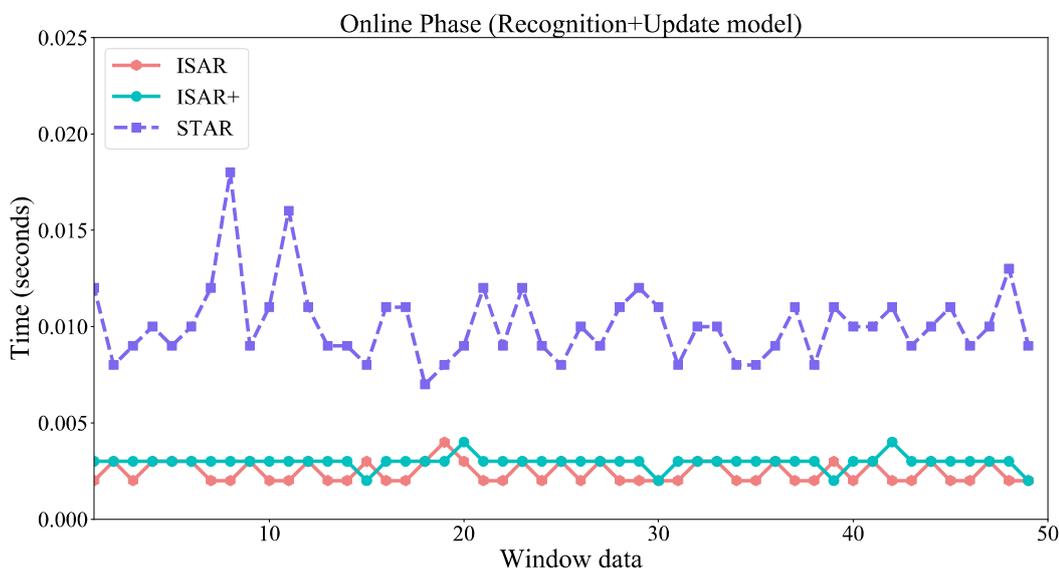


ภาพที่ 4-11 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนสร้างตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR

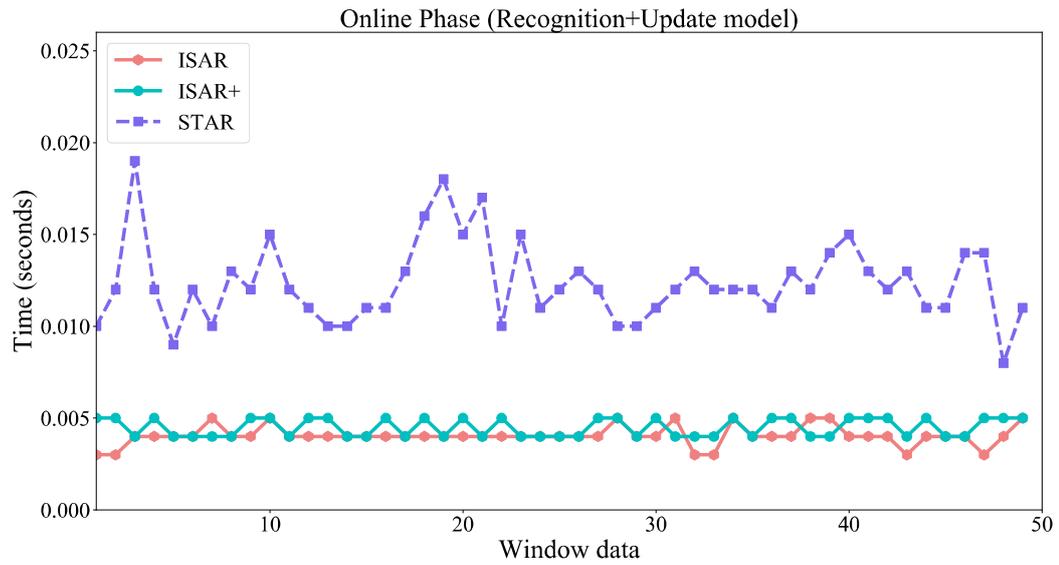
จากภาพที่ 4-10 และ 4-11 จะเห็นว่าเวลาที่ใช้ในการสร้างตัวแบบรู้จำกิจกรรมกับข้อมูลกิจกรรม WISDM และ UniMiB-SHAR มีแนวโน้มไปในทิศทางเดียวกันนั่นคือ วิธีการ STAR จะใช้เวลาค่อนข้างมากเนื่องจากจำเป็นต้องนำข้อมูลกิจกรรมทั้งหมดไปแบ่งกลุ่ม ยังมีจำนวนตัวอย่างข้อมูล

กิจกรรมมากก็ยิ่งใช้เวลามากขึ้นอย่างเห็นได้ชัดเจน ต่อมาวิธีการ ISAR ซึ่งมีขั้นตอนการแบ่งกลุ่มข้อมูลเหมือนกัน แต่ใช้เวลาน้อยกว่าวิธีการ STAR เนื่องจากได้แปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานแล้วจึงนำไปแบ่งกลุ่มที่หลัง (ข้อมูลกิจกรรม 1 window แปลงเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานได้ 1 ตัวอย่าง) ข้อมูลส่วนเบี่ยงเบนมาตรฐานมีจำนวนน้อยกว่าข้อมูลกิจกรรมมาก จึงคำนวณได้เร็วกว่าวิธีการ STAR ส่วนวิธีการ ISAR+ ไม่มีการแบ่งกลุ่มข้อมูล จึงทำให้ใช้เวลาในการคำนวณน้อยที่สุด

สำหรับเวลาที่ใช้ในการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมของวิธีการ ISAR, ISAR+ และ STAR จะทำการทดสอบร่วมกัน เนื่องจากขั้นตอนทั้งสองทำงานต่อเนื่องกัน โดยพิจารณาเวลาที่ใช้ในการรู้จำกิจกรรมในแต่ละ window แสดงดังภาพที่ 4-12 และ 4-13 ซึ่งจะเห็นว่าวิธีการ STAR ใช้เวลาในการคำนวณมากกว่าวิธีการ ISAR และ ISAR+ อย่างเห็นได้ชัดเจน เนื่องวิธีการ STAR จะต้องแบ่งข้อมูลภายใน window เป็น 2 กลุ่ม ก่อนที่จะนำข้อมูลแต่ละกลุ่มเข้าไประบุกิจกรรมในแต่ละมาตรวัด ส่วนวิธีการ ISAR และ ISAR+ ใช้เวลาในการคำนวณใกล้เคียงกันเนื่องจากใช้มาตรวัดในการระบุกิจกรรมที่เหมือนกัน โดยวิธีการ ISAR จะใช้เวลาในการคำนวณน้อยกว่าวิธีการ ISAR+ เล็กน้อย เนื่องจากวิธีการ ISAR ไม่มีขั้นตอนการปรับปรุงตัวแบบรู้จำกิจกรรม



ภาพที่ 4-12 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล WISDM



ภาพที่ 4-13 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR

บทที่ 5

สรุปผลการดำเนินงานและข้อเสนอแนะ

สำหรับวิทยานิพนธ์นี้ ผู้จัดทำวิทยานิพนธ์จะกล่าวถึงการสรุปและวิจารณ์ผลการดำเนินงานโครงการ ได้แก่ การสรุปผลการทดลอง และการวิจารณ์เกี่ยวกับข้อดี ข้อบกพร่องและรวมถึงข้อเสนอแนะของวิทยานิพนธ์

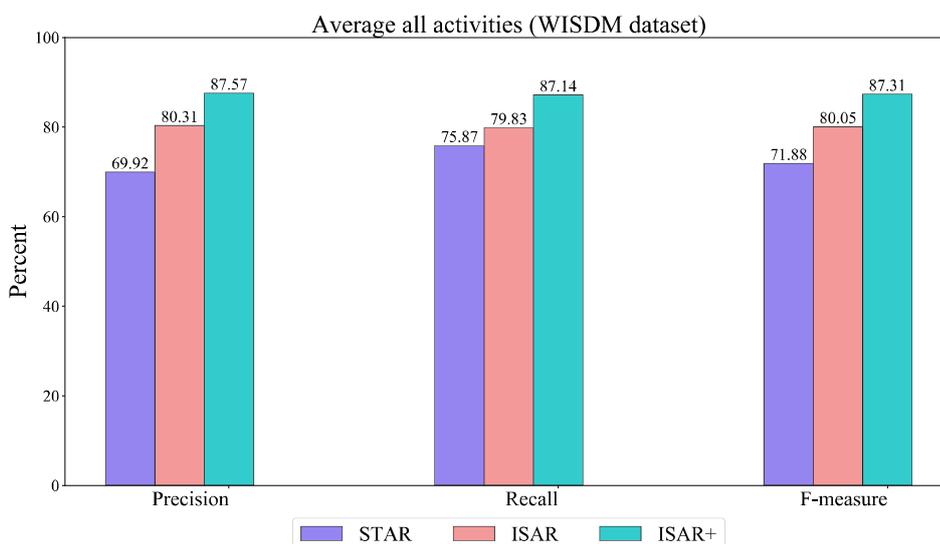
5.1 สรุปผลการดำเนินงาน

วิทยานิพนธ์นี้ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมโดยใช้วิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR) ซึ่งเป็นการสร้างตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model) ที่สามารถรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลา Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน กิจกรรมที่สามารถรู้จำได้เป็นกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรม ได้แก่ การยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได เป็นต้น และวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) ซึ่งได้ปรับปรุงการรู้จำกิจกรรมจากวิธีการ ISAR ให้มีประสิทธิภาพมากยิ่งขึ้น วิธีการ ISAR+ มีกรอบแนวคิดด้วยกันสองขั้นตอน ได้แก่ ขั้นตอนออฟไลน์สำหรับสร้างตัวแบบรู้จำกิจกรรม และขั้นตอนออนไลน์สำหรับรู้จำกิจกรรมและปรับปรุงตัวแบบรู้จำกิจกรรม

ขั้นตอนออฟไลน์ จะพิจารณาข้อมูลที่รู้ว่าเป็นกิจกรรมอะไร (Annotated data) นำมาหาค่าขีดแบ่ง (Threshold) สำหรับแบ่งประเภทของกิจกรรมเป็นสองประเภท ได้แก่ กิจกรรมแบบนิ่งและกิจกรรมแบบเคลื่อนไหว แปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ข้อมูลความหนาแน่น (Density) และข้อมูลความโด่ง (Kurtosis) โดยเลือกเฉพาะข้อมูลกิจกรรมแบบเคลื่อนไหว จากนั้นจะเก็บข้อมูลสรุป ได้แก่ ค่าขีดแบ่ง (Threshold) ค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐาน ค่าเฉลี่ยของความหนาแน่น และค่าเฉลี่ยของความโด่ง

ขั้นตอนออนไลน์ รู้จำกิจกรรมโดยพิจารณาข้อมูลกระแสเชิงเวลาจาก Accelerometer sensor ของสมาร์ทโฟน จำแนกข้อมูลที่เข้ามาว่าเป็นกิจกรรมประเภทอะไรด้วยค่าขีดแบ่งที่หาได้ในขั้นตอนออฟไลน์ ถ้าหากเป็นกิจกรรมแบบนิ่งจะระบุกิจกรรมด้วยมาตรวัด Accelerometer line แต่ถ้าเป็นกิจกรรมแบบเคลื่อนไหวจะระบุกิจกรรมด้วยมาตรวัด SD Distance หลังจากนั้นจะใช้ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความหนาแน่น (Density) และ ความโด่ง (Kurtosis) เป็นเกณฑ์สำหรับการปรับปรุงตัวแบบรู้จำกิจกรรม เพื่อให้เหมาะสมกับผู้ใช้แต่ละบุคคล

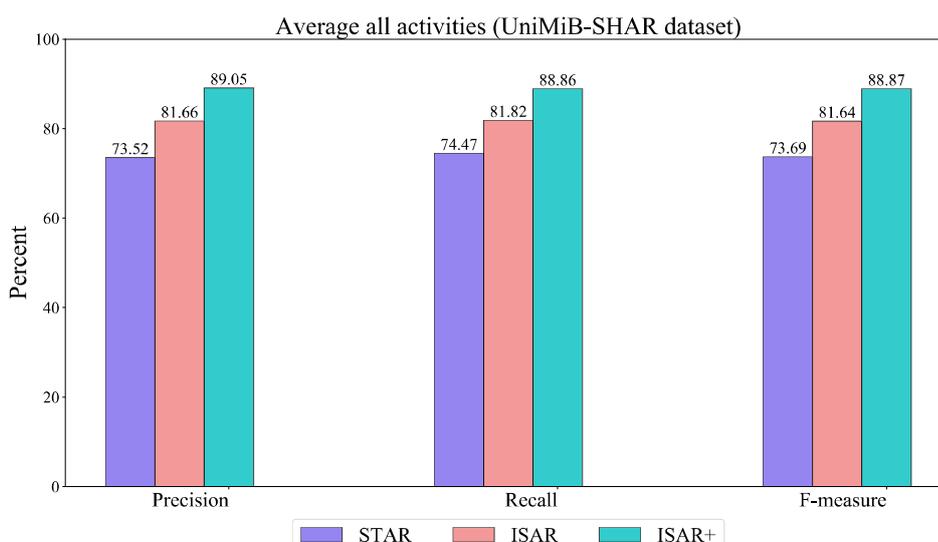
จากผลการทดลองที่นำเสนอในวิทยานิพนธ์นี้กับข้อมูล WISDM โดยใช้วิธีการวัดประสิทธิภาพตัวแบบรู้จำกิจกรรมด้วยวิธี Precision สำหรับวัดความแม่นยำของตัวแบบรู้จำกิจกรรม Recall สำหรับวัดความถูกต้องของตัวแบบรู้จำกิจกรรมและ F-measure ซึ่งเป็นค่าเฉลี่ยระหว่างความแม่นยำและความถูกต้องของตัวแบบรู้จำกิจกรรม แสดงดังภาพที่ 5-1 โดยเมื่อพิจารณาทุกกิจกรรมรวมกันวิธีการ ISAR+ มีค่าความแม่นยำเท่ากับ 87.57% ค่าความถูกต้องเท่ากับ 87.14% และค่าเฉลี่ยความถูกต้องและแม่นยำเท่ากับ 87.31% เช่นเดียวกับผลการทดลองด้วยข้อมูลกิจกรรม UniMIB-SHAR แสดงดังภาพที่ 5-2 วิธีการ ISAR+ มีค่าความแม่นยำเท่ากับ 89.05% ค่าความถูกต้องเท่ากับ 88.86% และค่าเฉลี่ยความถูกต้องและแม่นยำเท่ากับ 88.89% แสดงให้เห็นว่าวิธีการสร้างตัวแบบรู้จำกิจกรรมที่นำเสนอในวิทยานิพนธ์นี้มีประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมที่ดีที่สุด



ภาพที่ 5-1 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล WISDM พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure

สำหรับประสิทธิภาพด้านเวลาของตัวแบบรู้จำกิจกรรมขั้นตอนวิธี ISAR+ มีประสิทธิภาพที่ดีกว่าวิธีการ ISAR และ STAR เนื่องจากวิธีการ ISAR+ สามารถสร้างตัวแบบรู้จำกิจกรรมโดยไม่ต้องแบ่งกลุ่มข้อมูล จึงทำให้ช่วยลดขั้นตอนการคำนวณลงได้ และในขั้นตอนการรู้จำกิจกรรมวิธีการ ISAR+ ได้พิจารณาลักษณะข้อมูลกิจกรรมโดยแบ่งกิจกรรมออกเป็น 2 ประเภท ได้แก่ กิจกรรมแบบนิ่งและแบบเคลื่อนไหว การรู้จำกิจกรรมแต่ละประเภทใช้มาตรวัดเพียงแค่ 1 ตัวเท่านั้น ทำให้

รู้จำกิจกรรมได้รวดเร็ว ต่างจากวิธีการ STAR ที่มีการใช้มาตรวัดหลายตัวในการรู้จำกิจกรรม และมีขั้นตอนการแบ่งกลุ่มข้อมูลทั้งตอนสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนการรู้จำกิจกรรม ซึ่งเวลาที่ใช้ในการแบ่งกลุ่มข้อมูลแต่ละครั้งไม่แน่นอนขึ้นอยู่กับจำนวนรอบของการแบ่งกลุ่ม ทำให้วิธีการ ISAR+ มีประสิทธิภาพด้านเวลาที่เหนือกว่าวิธีการ STAR ดังนั้นจึงสามารถอนุมานได้ว่าวิธีการ ISAR+ สามารถประมวลผลบนอุปกรณ์ได้เช่นเดียวกับวิธีการ STAR



ภาพที่ 5-2 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล UniMiB-SHAR พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure

5.2 วิจัยรณัผลการดำเนินงาน

5.2.1 ข้อดีของวิทยานิพนธ์

1. วิธีการ ISAR+ สามารถลดความทับซ้อนของข้อมูลกิจกรรม โดยการแปลงข้อมูลกิจกรรมด้วยส่วนเบี่ยงเบนมาตรฐาน
2. สามารถรู้จำกิจกรรมโดยใช้เพียงข้อมูล Accelerometer sensor ของสมาร์ตโฟน
3. สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้โดยอัตโนมัติ
4. ตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ สามารถประมวลผลบนอุปกรณ์ได้

5.2.2 ข้อจำกัดของวิทยานิพนธ์

1. วิทยานิพนธ์นี้ทำการรู้จำกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรม ได้แก่ การยืน การนั่ง การเดิน การวิ่ง และการขึ้นลงบันได

2. จำเป็นต้องสวมใส่อุปกรณ์ไว้ที่กระเป๋ากางเกงสำหรับการรู้จำกิจกรรม
3. รู้จำกิจกรรมบนอุปกรณ์สมาร์ตโฟน
4. การพิจารณา window ที่มีขนาดคงที่ อาจทำให้อุปกรณ์ต้องสูญเสียพลังงานมาก เนื่องจากจะต้องรู้จำกิจกรรมทุก ๆ วินาที

5.2.3 ข้อเสนอแนะของวิทยานิพนธ์

1. การพิจารณาขนาดของ window ที่มีความยืดหยุ่น อาจทำให้ไม่จำเป็นต้องรู้จำกิจกรรมในทุก ๆ วินาที จะช่วยประหยัดพลังงานของอุปกรณ์ได้
2. การเลือกข้อมูลการทำกิจกรรมของผู้ใช้ที่เหมาะสมสำหรับสร้างตัวแบบรู้จำกิจกรรม น่าจะช่วยให้ประสิทธิภาพของการรู้จำกิจกรรมดีขึ้น
3. การเพิ่มการรู้จำกิจกรรมที่มีความซับซ้อน เช่น เล่นกีฬา ดูทีวี และทำอาหาร เป็นต้น อาจจำเป็นต้องเพิ่มข้อมูลจากตัวรับรู้ เช่น Gyroscope, Heart Rate และ Barometer เป็นต้น เข้ามาช่วยในการคำนวณ เพื่อให้การรู้จำกิจกรรมมีความถูกต้องแม่นยำมากยิ่งขึ้น

บรรณานุกรม

- Abdallah, Z.S., Gaber, M.M., Srinivasan, B. (2015). Adaptive mobile activity recognition system with evolving data streams. *Neurocomputing*, 150, 304-317.
- Anguita, D., Ghio, A., Oneto, L., Parra, X., Reyes-Ortiz, J.L. (2013). Energy efficient smartphone-based activity recognition using fixed-point arithmetic. *The Journal of Universal Computer Science*, 19, 1295-1314.
- Anjum, A., Ilyas, M. (2013). Activity recognition using smartphone sensors. *In Proceedings of the 2013 IEEE Consumer Communications and Networking Conference*, 914-919.
- Das, S., Green, L., Perez, B., Murphy, M., Perring, A. (2010). Detecting user activities using the accelerometer on android smartphones. *Technical Report, Carnegie Mellon University, Pittsburgh, PA, USA, 2010*.
- Das, B., Seelye, A., Thomas, B., Cook, D., Holder, L., Schmitter-Edgecombe, M. (2012). Using smartphones for context-aware prompting in smart environments. *In Proceedings of the 2012 IEEE Consumer Communications and Networking Conference (CCNC)*, 399-403.
- Gomes, J., Krishnaswamy, S., Gaber, M., Sousa, P., Menasalvas, E. (2012). MARS: A personalised mobile activity recognition system. *In Proceedings of the 2012 IEEE 13th International Conference on Mobile Data Management (MDM)*, 316-319.
- Frank, J., Mannor, S., Precup, D. (2011). Activity Recognition with Mobile Phones. *Lecture Notes in Computer Science*, 6913, 630-633.
- Khan, A.M., Tufail, A., Khattak, A.M., Laine, T.H. (2014) Activity recognition on smartphones via sensor-fusion and KDA-based SVMs. *International Journal of Distributed Sensor Networks*, 1-14.
- Khan, A.M., Siddiqi, M.H., Lee, S.W. (2013). Exploratory data analysis of acceleration signals to select light-weight and accurate features for real-time activity recognition on smartphones. *Sensors*, 13, 13099-13122.

- Kim, T.S., Cho, J.H., Kim, J.T. (2013). Mobile motion sensor-based human activity recognition and energy expenditure estimation in building environments. *Smart Innovation, Systems and Technologies*, 22, 987–993.
- Kose, Mustafa., Incel, O.D., Ersoy, C. (2012). Online human activity recognition on smart phones. *In Proceedings of the Workshop on Mobile Sensing: From Smartphones and Wearables to Big Data, Beijing, China*, 11–15.
- Lane, N.D., Mohammod, M., Lin, M., Yang, X., Lu, H., Ali, S., Doryab, A., Berke, E., Choudhury, T., Campbell, A. (2011). Bewell: A smartphone application to monitor, model and promote wellbeing. *In Proceedings of the 5th International ICST Conference on Pervasive Computing Technologies for Healthcare*, 23–26.
- Lara, O., Labrador, M. (2012). A mobile platform for real-time human activity recognition. *In Proceedings of the 2012 IEEE Consumer Communications and Networking Conference*, 667–671.
- Lee, S.M., Yoon, S.M., Cho, H. (2017). Human activity recognition from accelerometer data using convolutional neural network. *In Proceedings of the 2017 IEEE International Conference on Big Data and Smart Computing (BigComp)*, 131–134.
- Lgnatov, A. (2018). Real-time human activity recognition from accelerometer data using convolutional neural networks. *Applied Soft Computing Journal*, 62, 915–922.
- Liang, Y., Zhou, X., Yu, Z., Guo, B., Yang, Y. (2012). Energy efficient activity recognition based on low resolution accelerometer in smartphones. *Lecture Notes in Computer Science*, 7296, 122–136.
- Lockhart, J.W., Weiss, G.M. (2014). The benefits of personalized smartphone-based activity recognition models, *In Proceedings of the 2014 SIAM International Conference on Data Mining*, 614–622
- Lu, H., Yang, J., Liu, Z., Lane, N.D., Choudhury, T., Campbell, A.T. (2010). The jigsaw continuous sensing engine for mobile phone applications. *In Proceedings of the 8th ACM Conference on Embedded Networked Sensor Systems*, 71–84.

- Martin, H., Bernardos, A.M., Iglesias, J., Casar, J.R. (2013). Activity logging using lightweight classification techniques in mobile devices. *Personal and Ubiquitous Computing*, 17, 675–695.
- Miluzzo, E., Lane, N.D., Fodor, K., Peterson, R., Lu, H., Musolesi, M., Eisenman, S.B., Zheng, X., Campbell, A.T. (2008). Sensing meets mobile social networks: the design, implementation and evaluation of the cenceme application. *In Proceedings of the 6th ACM Conference on Embedded Network Sensor Systems*, 337–350.
- Moon, T.K. (1996). The expectation-maximization algorithm. *In Proceedings of IEEE Signal Processing Magazine*, 14, 47-60.
- Ouchi, K., Doi, M. (2012). Indoor-outdoor activity recognition by a smartphone. *In Proceedings of the 2012 ACM Conference on Ubiquitous Computing*, 600–601.
- Peterek, T., Penhaker, M., Gajdos, P., Dohnalek, P. (2014). Comparison of classification algorithms for physical activity recognition. *Innovations in Bio-Inspired Computing and Applications*, 123-131.
- Preece, S.J., Goulerman, J.Y., Kenney, L.P., Howard, D., Meijer, K., Crompton, R. (2009). Activity identification using body-mounted sensors a review of classification techniques. *Physiological Measurement*, 30(4), 1-33.
- Reddy, S., Mun, M., Burke, J., Estrin, D., Hansen, M., Srivastava, M. (2010). Using mobile phones to determine transportation modes. *ACM Transactions on Sensor Networks (TOSN)*, 6, 1–27.
- Ryder, J., Longstaff, B., Reddy, S., Estrin, D. (2009). Ambulation a tool for monitoring mobility patterns over time using mobile phones. *In Proceedings of the International Conference on Computational Science and Engineering*, 4, 927–931.
- Schindhelm, C. (2012). Activity recognition and step detection with smartphones: Towards terminal based indoor positioning system. *In Proceedings of the 2012 IEEE 23rd International Symposium on Personal Indoor and Mobile Radio Communications (PIMRC)*, 2454–2459.

- Shoab, M., Bosch, S., Incel, O.D., Scholten, H., Havinga, P.J. (2015). A survey of online activity recognition using mobile phones. *Sensors*, 15, 2059-2085.
- Siirtola, P. (2012). Recognizing human activities user-independently on smartphones based on accelerometer data. *International Journal of Interactive Multimedia and Artificial Intelligence*, 1, 38-45.
- Siirtola, P., Roning, J. (2013). Ready-to-use activity recognition for smartphones. In *Proceedings of the 2013 IEEE Symposium on Computational Intelligence and Data Mining (CIDM)*, 59-64.
- Stewart, V., Ferguson, S., Peng, J.X., Rafferty, K. (2012). Practical automated activity recognition using standard smartphones. In *Proceedings of the IEEE International Conference on Pervasive Computing and Communications Workshops*, 229-234.
- Thiemjarus, S., Henpraserttae, A., Marukatat, S. (2013). A study on instance-based learning with reduced training prototypes for device-context-independent activity recognition on a mobile phone. In *Proceedings of the 2013 IEEE International Conference on Body Sensor Networks (BSN)*, 1-6.
- Tomasi, C. (2004). Estimating Gaussian Mixture Densities with EM - A Tutorial. Duke University
- Uddin, M.T., Billah, M., Hossain, M.F. (2016). Random forests based recognition of human activities and postural transitions on smartphone. In *Proceedings of the 2016 5th International Conference on Informatics, Electronics and Vision (ICIEV)*, 250-255.
- Vo, Q.V., Hoang, M.T., Choi, D. (2013). Personalization in Mobile Activity Recognition System Using K-Medoids Clustering Algorithm. *International Journal of Distributed Sensor Networks*, 1-12.
- Wang, Y., Lin, J., Annavaram, M., Jacobson, Q.A., Hong, J., Krishnamachari, B., Sadeh, N. (2009). A framework of energy efficient mobile sensing for automatic user state recognition. In *Proceedings of the 7th International Conference on Mobile Systems, Applications, and Services*, 179-192.
- Yan, Z., Subbaraju, V., Chakraborty, D., Misra, A., Aberer, K. (2012). Energy-efficient continuous activity recognition on mobile phones: An activity-adaptive

approach. *In Proceedings of the 2012 16th International Symposium on Wearable Computers (ISWC)*, 17–24.

Zhao, K., Du, J., Li, C., Zhang, C., Liu, H., Xu, C. (2013). Healthy: A diary system based on activity recognition using smartphone. *In Proceedings of the 2013 IEEE 10th International Conference on Mobile Ad-Hoc and Sensor Systems (MASS)*, 290–294.

ภาคผนวก

ภาคผนวก ก

เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์



บันทึกข้อความ

สำนักงานจัดการศึกษา คณะวิทยาการสารสนเทศ ม.บูรพา
เลขที่ 1146
วันที่ ๐๑ ก.ย. ๒๕๖๐
11:00 น.

ส่วนงาน สำนักงานอธิการบดี กองบริการการศึกษา งานส่งเสริมการวิจัย โทร. ๒๕๖๑-๒๕๖๒
ที่ ศธ ๖๒๐๐/๐๗๕๘๓ วันที่ ๓๑ สิงหาคม พ.ศ. ๒๕๖๐
เรื่อง ขอแจ้งรับรองโครงการวิจัยที่ส่งมาขอรับการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา

เรียน นายเทิดศักดิ์ ดุงแก้ว (นิสิตระดับบัณฑิตศึกษา คณะวิทยาการสารสนเทศ)

ตามที่ท่านได้ส่งเอกสารโครงการวิจัยเพื่อขอรับการพิจารณาจริยธรรมการวิจัยในมนุษย์
ในหัวข้อโครงการวิจัยเรื่อง การรู้จักกิจกรรมที่ปรับได้ โดยใช้ข้อมูลตัวรับรู้แอกเซเลอโรมิเตอร์ของสมาร์ตโฟน
นั้น

บัดนี้ คณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา ได้พิจารณา
ตามวิธีดำเนินการมาตรฐาน (Standard Operating Procedures, SOP) ฉบับที่ ๑ พ.ศ. ๒๕๖๐
ที่ได้ประกาศใช้เมื่อวันที่ ๙ มกราคม พ.ศ. ๒๕๖๐ แล้วว่า โครงการวิจัยดังกล่าวไม่ได้ทำการศึกษาวิจัย
ในมนุษย์ จึงเห็นสมควรให้ดำเนินการวิจัยได้

จึงเรียนมาเพื่อโปรดทราบ

(ผู้ช่วยศาสตราจารย์ ดร.วิวิทส์ แจ้งเอี่ยม)

ประธานคณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์
มหาวิทยาลัยบูรพา

ภาคผนวก ข
เอกสารเผยแพร่ผลงานวิจัย



The 2nd International Conference on Information Technology



Theme : IT for Value-Based Economy

Dates: November 2-3, 2017

Venue: Faculty of ICT, Mahidol University, Nakhon Pathom, Thailand

Organized by:
Faculty of ICT,
Mahidol University, Thailand

Committee

General Chair

Jaremsri L. Mitranont, (MU, Thailand)

Advisory Board

- Werasak Kuntach (MUT, Thailand)
- Woraphon Lilakiataskun (MUT, Thailand)
- Nipon Charoenkitkam (KMUTT, Thailand)
- Narangdech Keeratipranon (DPU, Thailand)
- Phayung Meesad (KMUTNB, Thailand)
- Noppom Chatikakumtorn (KMITL, Thailand)
- Teeravisit Laohapensaeng (MFU, Thailand)
- Pun Thongchunum (PSU, Thailand)
- Thiraporn Wongsasardsakul (BU, Thailand)
- Thana Sukvaree (SPU, Thailand)
- Chetneti Srisaan (RSU, Thailand)
- Sujin Butdisuwan (MSU, Thailand)
- Poonpong Boonbrahm (WU, Thailand)
- Dechanuchit Katanyutaveetip (SiamU, Thailand)
- Suda Suwannapirom (NPU, Thailand)
- Somsak Chartnamphet (SU, Thailand)
- Ruttikorn Varakulsiripunth (TNI, Thailand)
- Pisit Chamkietkong (PIM, Thailand)
- Krisana Chinnasarn (BU, Thailand)
- Thitirath Cheosuwan (UP, Thailand)

Organizing Committee

- Rattana Wetprasit (PSU, Thailand)
- Sasitorn Kaewman (MSU, Thailand)
- Thitiporn Lertrudachakul (TNI, Thailand)
- Suppat Rungraungsrip (WU, Thailand)
- Pruegsa Duangphasuk (MUT, Thailand)
- Panwit Tuwanuti (KMITL, Thailand)
- Datchakorn Tancharoen (PIM, Thailand)
- Pawitra Chiravirakul (MU, Thailand)
- Songsri Tangsripairoj (MU, Thailand)
- Boonsit Yimwadsana (MU, Thailand)
- Pagaporn Pengsart (MU, Thailand)
- Suppawong Tuarob (MU, Thailand)
- Wudhichart Sawangphol (MU, Thailand)

Contact

Email: incit2017@mahidol.ac.th
Website: <http://incit2017.ict.mahidol.ac.th>

The 2nd International Conference on Information Technology (InCIT 2017) aims to strengthen the collaboration and provide a forum for academicians, professionals and researchers to discuss and exchange their research results, innovative ideas and experiences in all aspects of intelligent, as well as to identify emerging research topics and define the future direction. The conference will feature paper presentations as well as keynote speech by keynote speakers. The InCIT 2017 will be held on November 2-3, 2017 in Nakhon Pathom, often referred to as Thailand's oldest city.

Topics

- Artificial Intelligence
- Big Data
- Data Analytic
- Data Mining
- Database Technology
- Pattern Recognition
- Information Extraction / Information Retrieval
- Cloud Computing
- Communications and Networking
- IT Security and Privacy
- Internet of Things
- Platform Technologies
- Computer Game
- Multimedia and Virtual Reality
- Computer Vision / Image Processing
- Human Computer Interaction
- Digital Media Technology
- E-Commerce, E-Education, E-Government, E-Industry, E-Society
- IT in Education
- IT Management
- Digital Information Management
- Social and Professional Issues
- Social Network Analysis
- Information Systems Technology
- Software Engineering
- Web and Internet Technologies
- Smart Technology
- IT Application
- Other Related Topics

Important Dates

- | | |
|----------------------------|-------------------------------------|
| Submission Deadline | 1 July–31 August– 15 September 2017 |
| Notification of Acceptance | 6 October 2017 |
| Camera Ready Submission | 15 October 2017 |
| Author Registration | 6–15 October 2017 |
| Early-bird Registration | 6–22 October 2017 |
| Regular Registration | 22–31 Oct 2017 |
| Conference Dates | 2–3 November 2017 |

All accepted and presented papers will be published in the InCIT 2017 Conference Proceedings and submitted to IEEE Xplore. Selected high quality papers will be proposed for further extension before publishing in ECTI-Transaction on Computer and Information Technology (ECTI-CIT), indexed by the Thai-Journal Citation Index (TCI).

The 2nd International Conference on Information Technology 2017



Schedule

Thursday 2 November 2017

Time	Paper ID	Title	Topic
15:10	1	Banana Cultivar Classification using Scale Invariant Shape Analysis	Computer Vision / Image Processing
15:30	2	Durian Cultivar recognition using discriminant function	Pattern Recognition
15:50	3	Impersonal Smartphone-based Activity Recognition Using the Accelerometer Sensory Data	Pattern Recognition
16:10	4	Relationship Extraction from Thai Children's Tales for Generating Illustration	Artificial Intelligence
16:30	5	Factors Influencing Teenagers Behavior on Posting and Sharing Messages via Facebook	Social Network Analysis
16:50	6		

Session 1-B (Data Analytic) (Room IT332)			
Chair: Dr. Aptrak Hoonlor			
Paper ID	Title	Topic	
1	24	Regression Model for Predicting the Maximum Load of the Movement	Data Analytic
2	53	Sound Events Separation and Recognition using L1-Sparse Complex Nonnegative Matrix Factorization and Multi-Class Mean Suprvector Support Vector Machine	Data Analytic
3	57	Blind 3D Sound Source Direction using Stereo Microphones based on Time-Delay Estimation and Polar-Pattern Histogram	Data Analytic
4	54	Enhancing Comment Feedback Classification using Text Classifiers with Word Centrality Measures	Data Analytic
5	9	A Comparative Study of Ensemble Back-propagation Neural Network for the Regression Problems	Data Analytic
6			

Session 1-C (Health IT) (Room IT334)			
Chair: Asst. Prof. Dr. Sudsaenguan Ngamsuriyaroj			
Paper ID	Title	Topic	
1	47	Transfer Learning Based Quantitative Assessment Model of Upper Limb Movement Ability for Stroke Survivors	HIT
2	64	A Method of Rehabilitation Training for Finger Pair Movement Based on Multi-Leap Motions	HIT
3	67	Wearable Rehabilitation Assessment System Based on Complex Network	HIT
4	63	Pinch Simulation With Haptic Feedback for Stroke Rehabilitation: A Pilot Study	HIT
5	41	Health Risk Analysis System for Family Caregiver of Disabled Person	HIT
6	61	Virtual Reality Escape Room: The Last Breakout	HIT

Impersonal Smartphone-based Activity Recognition Using the Accelerometer Sensory Data

Therdsak Dungkaew*, Jakkarin Suksawatchon†, Ureerat Suksawatchon‡
Mobile Application Developers Incubation Research Laboratory, Faculty of Informatics,
Burapha University, Chonburi, 20131, Thailand
Email: *dungkaew.th@gmail.com, †jakkarin@go.buu.ac.th, ‡ureerat.w@gmail.com

Abstract—Smartphone-based activity recognition focuses on identifying the current activities of a mobile user by employing the sensory data which are available on smartphones. A light-weight model and less inquiry users for true activities, are necessary for deploying the activity recognition on a mobile platform for identifying activities based on new sensory data in real time. In this paper, we propose a new smartphone-based activity recognition framework for evolving sensory data stream called *ISAR*. It stands for Impersonal Smartphone-based Activity Recognition. *ISAR* model is built using annotated sensory data from a panel of user as training data and are applied to the new users. Our new model is an offline and online phase. In offline phase, we propose a new method for finding the threshold value which used to distinguish between dormant activities and energetic activities. Only a set of the energetic activities are used to build a light-weight classifier model. In online phase, we introduce the recognition technique of unannotated streaming sensory data with different activities. The experimental results using real human activity recognition data have conducted and compared with STAR model in terms of the accuracy and time complexity. Our results indicates that *ISAR* model can perform dramatically better than STAR model. Moreover, *ISAR* can utilize better than STAR model in real situation, especially across different users and without inquiry users.

Keywords—Activity recognition, Streaming data, Unsupervised learning

I. INTRODUCTION

In recent years, smartphone-based activity recognition has been extensively explored in the research of mobile computing due to its importance for context-aware application [1]. These applications can be used for healthcare and fitness monitoring. In addition, smartphones not only serve us a communication medium, but also are equipped by powerful CPU and GPU [2]. Modern smartphones have incorporated diverse and powerful sensors including accelerometers. They can be useful for many purposes. One of these purposes can be monitoring the physical activity from sensory data [2].

The objective of the smartphone-based activity recognition is to analyze the continuous sensory data and identify the occurrence of the current activities with high accuracy [3]. Therefore, how to be able recognize the human activities such as sitting, standing, walking, running, upstairs and downstairs by analyzing those sensors data, is interesting issue for many researchers and developers. There exists many researches that widely studied with different approaches. Most of researches

focus on traditional classification techniques such as support vector machine (SVM), decision trees, k-nearest neighbor algorithm (k-NN), artificial neural network, etc. The classifier model is trained and tested using the collected and annotated data by domain expert. When the model is ready to use, the classifier model is used to predict activities from the continuous sensory data. Since all the traditional classification learning techniques use prior knowledge of collected data to build the classifier models in external environment, and the obtained models are static and general model. So they are not suitable for classifying when the users' activities profiles or personalization of users' activities change. The recognition model will be retrained to update the model.

Many researches try to improve the classification learning techniques without retraining the whole data set. MARS [3] algorithm is dynamic classifier model and is built to facilitate the adaptation of the classifier while the user's activities patterns change without retraining the model. During the training phase, user performs the activities and annotates interactively the data gathered from the sensors using a user interface. These annotated data are saved to built the recognition model in offline learning algorithm. The MARS model is anytime updated on-board the mobile devices in incremental manner when new labeled data are incorporated by user. Therefore, MARS is a personal model which users must provide labeled training data.

The recent and interesting model is STAR model introduced by Abdallah and the team [4]. The STAR model is an impersonal and adaptive activity recognition that incrementally learns from evolving sensory data stream. The recognition and adaptive process can perform on a mobile phone device with limited resources. The STAR model build a learning model from a set of labeled data obtained from one user, and then adjust the model to fit the new particular users in incremental learning manner without requiring labeled training data from those users. It seems like the STAR model can be generalization model, however, it has some limitations. If the model fail to detect the occurrence of activities to new users. It dues to the pattern of doing activities of new users are different to the pattern of the user used to create the model or the orientation difference of mobile device. Then the active learning is performed to inquire the users about

true activities. For example, Fig. 1(a) depicts the snapshot of the “Standing” activity of different users in WISDM dataset which used to build STAR model. This figure illustrates that “Standing” are totally misclassified for new users if such users activities are different to the user used to create the model. In addition, Fig. 1(b) shows the overlapping among three activities including “Walking”, “Jogging”, and “Stair”, that will lead to getting in poor recognition accuracy and then the active learning will be performed. Moreover, there are some researches [5], [6] attempt to solve the limitations of STAR model by adding other sensors such as gyroscope, GPS, and other body-worn sensors. Although it makes increase accuracy of activity prediction, it takes more time to calculate and cannot proceed on mobile device.

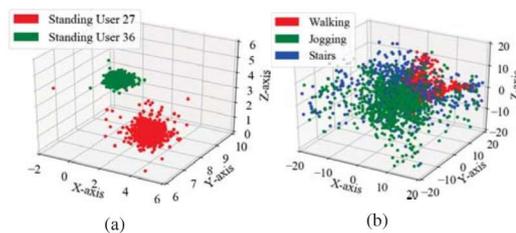


Fig. 1. (a) 3D scatter plot of the WISDM dataset. (b) 3D scatter plot of three activities of one user. Each activity is represented by different color.

In this paper, we propose new activity recognition for evolving sensory data stream called *ISAR*, which stands for Impersonal Smartphone-based Activity Recognition. The proposed framework is an accelerometer based and light-weight framework for identifying the occurrence activities from the continuous sensory data. *ISAR* is an offline and online phase. In offline phase, we build classifier model from a set of annotated sensory data based on characteristics of activities and clustering approach. The online phase is recognition component which can proceed on-board the mobile phone for real-time data. Our main contributions in this work are: (1) we propose the new method for distinguishing the activities based on their characteristics. Our new method can be used for identifying the sensory data into two types of activities that are dormant and energetic activities from incoming unlabeled data. (2) The new classifier modeling and recognition component are introduced to deal with the overlapping data and to cut off any inquiry the users about true activities

II. RELATED WORKS

The immense research in smartphone-based activity recognition has widely used the learning methods. Most of learning methods are the supervised learning algorithms. In existing supervised learning, the annotated data is gathered to train a classifier model offline in the external environment. Then the constructed model is deployed for recognition the occurrence activities. Nevertheless, the obtained model is static model

which cannot deploy in a realistic situation. Because phone-based sensors typically produce streaming data which are various kinds of change. This is the one of the main causes should be concerned if we create the personal model with the annotated of data from a panel of users [7]. For example, Lockhart and the team [8] developed a smartphone-based activity recognition named Actitracker. It uses Random Forest to generate the activity recognition model with the annotated of data from a panel of users, but it will generate much more accurate personal model when retaining the model for a specific user is perform [8].

A few researches have considered the streaming data for human activity recognition. MARS [3] stands for Mobile Activity Recognition System which can identify the occurrence of activity in streaming data from mobile device. Since, the model type of MARS is personal model which use training data only from the user who utilizes the model. So in the training phase, the user makes a gesture activity and labels interactively the data gathered from the sensors via a graphical user interface. the annotated data will be processed on-board by the incremental Naïve Bayes compared with C4.5 decision tree. In the recognition phase, the new incoming unlabeled data is classified using the built model. From the experiments, MARS shows the feasibility to execute and update the model from a stream of sensory data based on individual users labeled data.

Another approach is proposed by Abdallah and the team called STAR model [4]. STAR stands for SStream learning for mobile Activity Recognition which is smartphone-based dynamic recognition for evolving sensory data streams. In offline phase, this phase aims to build learning model for activity recognition. A learning model represents a set of annotated data for each activity in term of sub-clusters. Each sub-cluster is extracted the summary information used to describe and distinguish it from other sub-clusters. The online phase is executed on board the smartphone for real time recognition. It composes of recognition and adaptation components. The recognition component uses to predict activities in each sliding window using cluster-based approach and then an ensemble technique is applied on clusters of each window [4]. STAR model uses four measurements including Distance, Gravity, Density and Deviation. These four measures are used to assess the similarity of each new cluster with sub-clusters in learning model. If all measures or three measures vote for the same sub-cluster, the learning model is unnecessary to update the summary information of such sub-clusters. Otherwise, if it gives equal votes or each measure chooses different sub-cluster, the active learning occurs that means the true label is provided by user. In this case, incremental learning is performed to refine the characteristics of such sub-clusters. Although, STAR is an efficient model which can deal with the continuous data stream and avoid retaining the model when a new user utilizes the system. However, STAR model can be misclassified for the new users if their activities are different to the users used to create the model. Since, STAR model uses data from WISDM, there exists the overlapping among

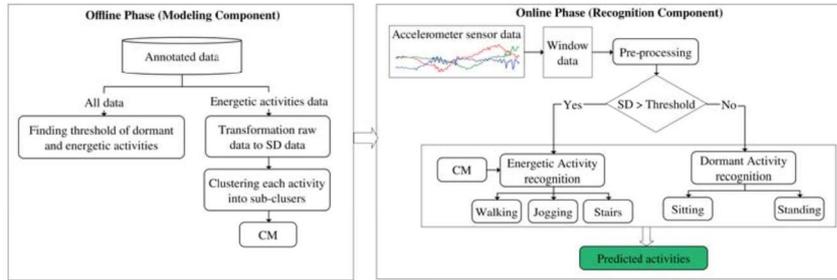


Fig. 2. The Impersonal Smartphone-based Activity Recognition framework (ISAR).

three activities including “Walking”, “Jogging”, and “Stair”. This leads to getting in poor recognition accuracy, and then the active learning will be performed.

III. ISAR FRAMEWORK

In this section, we introduce our new mobile activity recognition framework for streaming sensory data, named *ISAR*. The *ISAR* framework is divided into offline phase for modeling component and online phase for recognition component as shown in Fig. 2.

A. Data understanding

In this work, we exploit the real activity recognition dataset for creating our proposed impersonal model. Thus, all experiments are conducted on WISDM dataset [9]. This annotated dataset contains data collected from user’s mobile phone accelerometer sensor in laboratory conditions. A large number of users carry a smart phone in their front pants leg pocket and perform to walk, jog, sit, stand, upstairs and downstairs for a specific periods of time. In all activities, the accelerometer data were collected every 50 ms, so we got 20 samples per second [9]. This dataset contains more than one million labeled accelerometer sensory data called *annotated data*. The example of WISDM dataset is shown in Fig. 3.

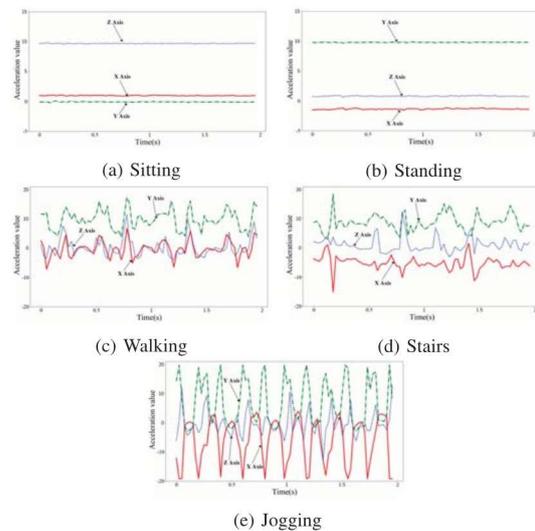
Sample	Label	Timestamp	ax	ay	az
s_1	Sitting	14824292218000	-4.99	-2.26	7.88
s_2	Sitting	14824342298000	-4.99	-2.30	7.96
s_3	Sitting	14824392255000	-5.01	-2.30	8.01
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Sitting	\vdots	ax_i	ay_i	az_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	Sitting	\vdots	ax_N	ay_N	az_N

Fig. 3. The example of annotated data of sitting activity data provided by WISDM.

B. Offline phase

In *ISAR* framework, we begin with building the modeling component in offline processing. The modeling component aims to build a classifier model (*CM*) used for activity recognition component in online phase. To deal with the overlapping problems, the pattern of acceleration is considered. For further using, the acceleration values of x , y , and z axes are called

x , y , and z values respectively. Figs. 4(a) and 4(b) plot the acceleration values of three axes of sitting and standing. As seen in these figures, the x , y , and z values are almost steady state [10], so sitting and standing are *dormant activities*. The acceleration lines of both activity have different remarkable features as well. For sitting, the x values are close to y values, but the z values are deviate from the other acceleration values. For standing, on the other hand, the y values have the greatest values and deviate from x and z values, but the x values are close to z values [10]. Figs. 4(c), 4(d), and 4(e) show the acceleration of three axes of walking, stairs, and jogging respectively. All these acceleration graphs illustrate that the x , y , and z acceleration values are very significantly, so these three activities are called *energetic activities* [10].

Fig. 4. The deviation of the acceleration values of x , y , and z axes of the five activities.

Let act be the set of activities in *annotated data*, act is composed of the set of samples S , which $S =$

$\{s_1, s_2, \dots, s_i, \dots, s_N\}$ where N is the number of samples in each activity. Each s_i is defined as a 4-tuple, (ax_i, ay_i, az_i, t_i) where t_i is the activity label of the sample s_i . The modeling component is consisted of three steps as the following.

Step 1: Converting the acceleration values to the standard deviation values. First, for each acceleration value s_i , the magnitude datum M_i is computed using equation (1) [11]. Then, for each activity we employ a fixed window of size n samples used for calculating the standard deviation SD_j using equation (2). In this work, n is determined as 20 samples.

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

where M_i , is the magnitude of acceleration value i , $i = 1, 2, 3, \dots, N$.

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

where SD_j is the standard deviation of samples within window j of each *act*, and \bar{M}_j is the average of samples within window j .

Step 2: Finding the threshold value used for classifying between dormant and energetic activities in online phase. First, the minimum of the standard deviation of energetic activities and the maximum of the standard deviation of dormant activities are computed. Then the *Threshold* (see **Algorithm** Offline Phase) is obtained by averaging these two values.

Step 3: Building the classifier model (*CM*). Only energetic activities including walking, running, and stairs, are used to build *CM*. Since the overlapping problem emerges from these three activities as illustrated in Fig. 5(a), so the original data of these three activities are transformed to *SD* space as illustrated in Fig. 5(b). This figure shows transformation to *SD* space which can overcome the overlapping problem. Thus, for each activity, a fixed window of size 20 (n) samples are used for calculating the standard deviation of each acceleration axis.

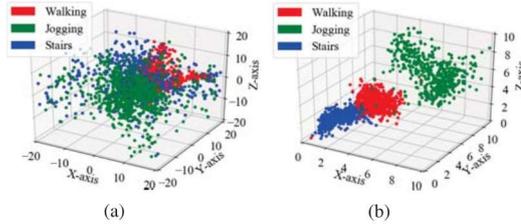


Fig. 5. (a) Scatter plot of energetic activities data. (b) Scatter plot of energetic activities data in *SD* space.

After that, we apply the clustering-based approach to split each energetic activity into K sub-clusters (*sc*). For preliminary study, K is set to 3 for each energetic activity. In this work, we use the Gaussian mixture model (GMM) for

clustering data. Finally, we extract only the statistics summary of each sub-cluster and discard the data from the system to save the memory. Because the *CM* must be processed on board of mobile device. The statistics summaries of sub-clusters include the following.

- $Weight_{sc_k}$ is the total number of data samples that belong to the sub-cluster k .
- $Centroid_{sc_k}$ is the center of sub-cluster k . For d dimensional data sample, K is the number of sub-clusters. $Centroid_{sc_k}$ is also a d dimensional vector of the average value of the samples inside the k^{th} sub-cluster as equation (3). So, we defined $Centroid_{sc_k} = (c_1, c_2, \dots, c_l, \dots, c_d)$, as follow,

$$c_l = \frac{\sum_{i=1}^m P_{il}}{Weight_{sc_k}}, \quad (3)$$

where c_l is the centroid of the l^{th} feature, and P_{il} is the l^{th} feature of the i^{th} sample inside the sub-cluster sc_k .

All details are described in **Algorithm** Offline Phase

Algorithm 1: Offline Phase (Modeling Component)

Input : N_C = set of annotated data of all activities.
Output: (1) $CM = \{Centroid_{sc_1}, Centroid_{sc_2}, \dots, Centroid_{sc_k}\}$,
(2) *Threshold*.

```

1 for each act in annotated data do
2   for each window j do
3     Compute  $M_i$  for each sample using eq. (1)
4     Compute average magnitude  $\bar{M}_j$  of window j.
5     Compute standard deviation  $SD_j$  using eq. (2).
6   end
7 end
8 Find the maximum of standard deviation of dormant activities  $SD_{max}$ .
9 Find the minimum of standard deviation of energetic activities  $SD_{min}$ .
10 Compute  $Threshold = \frac{SD_{max} + SD_{min}}{2}$ .
11 for each energetic activity act do
12   Let  $D$  be the empty set.
13   for each window j do
14     Compute the average values  $(\bar{ax}_j, \bar{ay}_j, \bar{az}_j)$  of each
15     acceleration values x, y, and z.
16     Compute the standard deviation of each acceleration values
17      $Std = (SD_{ax_j}, SD_{ay_j}, SD_{az_j})$ .
18      $D = D \cup Std$ .
19   end
20 Cluster  $D$  into  $k$  sub-clusters using GMM algorithm.
21 Compute  $Centroid_{sc_k}$  of all sub-clusters and add to  $CM$ .
22 end
```

C. Online phase

This section describes how to utilize *ISAR* for identifying the occurrence activities when dealing with the continuous sensory data stream. Thus, the recognition component is used to predict the activities in the data stream with a single pass and throw away of data, and can perform on the smartphone with limited resources. Fig. 2 also shows the process of recognition component in the streaming environment. Firstly, a continuous fixed size of sliding window is applied to segment the stream of data, and each small data chunk is performed the following steps.

Step 1: In *pre-processing* step, we compute the magnitude of acceleration value for each datum in the chunk by using

equation (1), and compute the standard deviation of all samples in that data chunk by using the same formula of equation (2), denoted as SD .

Step 2: If SD is less than the *Threshold* value obtained from offline phase, then all data in such data chunk will be the dormant activities. Otherwise, all data in such data chunk will be the energetic activities.

Step 3: For dormant activity, we found that the distances among acceleration value x , y , and z are significantly different and can be used for separating the sort of activity. The average of acceleration values x , y , and z is calculated denoted as $\bar{a}x$, $\bar{a}y$, and $\bar{a}z$ respectively. Then, the distance between the average value is computed by using equations (4) and (5). Therefore, sitting and standing activities can be distinguished using the proposed rule-based as follows:

If $Dist(\bar{a}x, \bar{a}z) > Dist(\bar{a}x, \bar{a}y)$ then activity is sitting.

If $Dist(\bar{a}x, \bar{a}y) > Dist(\bar{a}x, \bar{a}z)$ then activity is standing.

$$Dist(\bar{a}x, \bar{a}y) = \sqrt{\bar{a}x^2 - \bar{a}y^2} \quad (4)$$

$$Dist(\bar{a}x, \bar{a}z) = \sqrt{\bar{a}x^2 - \bar{a}z^2} \quad (5)$$

For energetic activity, the incoming data chunk is considered as the new sub-cluster. Thus, we compute the standard deviation of all acceleration values in such data chunk. After that, the classifier model (CM) deploys the Euclidean distance to assess the similarity of the new sub-cluster with CM sub-clusters. Then, the classifier model decides on the predicted label as the sub-cluster with the nearest distance.

All of the details are described in **Algorithm** Online Phase.

IV. THE EXPERIMENTS

In this section, we describe the evaluation of our proposed framework and report the experimental studies on the public database WISDM [9].

A. Experiments setup

To evaluate the recognition quality of *ISAR* framework, this work uses WISDM dataset for testing the model. This dataset consists of 18 users that each user performed the five activities. There are 1,078,140 samples for sitting data, 1,001,980 samples for standing data, 5,594,020 samples for walking data, 3,062,720 samples for stairs data and 4,445,160 samples for jogging data. Since, *ISAR* is the impersonal model, so we use the notion of k -cross-validation to evaluate the model. In this work, k is set to 18 which is the same as the number of users. Thus, one user is used for the training data, and the remaining $k - 1$ users are a validation data for testing model. The cross validation process is repeated k folds. The results of k folds can be averaged to produce the overall results. Since *ISAR* framework is a smartphone-based and uses only accelerometer sensor like STAR framework, so we will compare the performance between *ISAR* and STAR in terms of accuracy and time complexity.

Algorithm 2: Online Phase (Recognition Component)

Input : (1) Set of non-stationary streaming data,
(2) $CM = \{Centroid_{sc_1}, Centroid_{sc_2}, \dots, Centroid_{sc_k}\}$,
(3) *Threshold*.

Output: The predicted activities (P_{act}).

```

1 while stream is not empty do
2   for each fixed size window  $j$  do
3     Compute  $M_j$  using eq. (1) of each sample in window  $j$ .
4     Compute average  $\bar{M}_j$  of window  $j$ .
5     Compute standard deviation  $SD_j$  using eq. (2).
6     if  $SD_j < Threshold$  then
7       Compute the average values ( $\bar{a}x_j, \bar{a}y_j, \bar{a}z_j$ ) of each
8         acceleration values  $x$ ,  $y$ , and  $z$ .
9         Compute  $Dist(\bar{a}x, \bar{a}y)$  and  $Dist(\bar{a}x, \bar{a}z)$  using eq. 4 and
10        5.
11        if  $Dist(\bar{a}x, \bar{a}y) > Dist(\bar{a}x, \bar{a}z)$  then
12           $P_{act} = standing$ 
13        else
14           $P_{act} = sitting$ 
15        end
16      else
17        Compute the average values ( $\bar{a}x_j, \bar{a}y_j, \bar{a}z_j$ ) of each
18          acceleration values  $x$ ,  $y$ , and  $z$ .
19        Compute the standard deviation of each acceleration
20          values  $Std = (SD_{ax_j}, SD_{ay_j}, SD_{az_j})$ .
21        Find the nearest sub-cluster  $w$  such that
22           $w = argmin_{k=1, \dots, K} (||Std - Centroid_{sc_k}||)$ .
23        Set the activity of sub-cluster  $sc_w$  to  $P_{act}$ .
24      end
25    end
26  end

```

B. Experimental results and discussions

In this section, we report the experimental results of *ISAR* and STAR models for activity recognition on WISDM dataset. Since STAR model incorporates active learning for evolving data stream when the model cannot identify the occurrence activities by inquiry user for true label. Therefore, we implemented STAR model into two types which are STAR with active learning and STAR without active learning. For STAR with active learning, when the model cannot recognize the incoming activities of the testing data and active learning will be required, we use the actual labeled data of testing data as the answers obtained from the users. The summary results obtained from the experiments that presented in Table I. This table indicates the predictive accuracy accordance with each activities. The percentage numbers in parentheses show the number of inquires users for true label of STAR model with active learning.

In Table I, it demonstrates that STAR model achieves high level of accuracy every activity. When comparing between *ISAR* and STAR with active learning, Table I shows that *ISAR* model can achieve the good performance. For dormant activities, standing and sitting, *ISAR* can accomplish accuracies above 90%. For energetic activities, jogging is easier to recognize than stairs and walking because jogging extremely changes in acceleration value and rather separated cluster as illustrated in Fig. 5(b). For walking and stairs, they are much more difficult to identify because their characteristics are quite close and their clusters are still overlapping. Although

there exist some overlapping problem. *ISAR* can still recognize walking and stairs activities quite well than *STAR* with and without active learning, because *ISAR* model does not need users to assign the true activities for the unidentified activities.

In addition, both of *ISAR* and *STAR* are light-weight model and can utilize the models for real time activity recognition. So we performed the analysis of processing time by comparison with these two models as shown in Table II. First, we begin with analysis *ISAR* processing time. The main computational complexity in offline phase arises from two main processes that are finding the threshold value and clustering algorithm. In finding the threshold value, we consider all the stored annotated data, so the computational complexity is $O(Nm)$ where N is the number of annotated data and m is the number of windows. For clustering approach, we apply GMM clustering for energetic activities to build classifier model (*CM*) with a complexity of $O(kmi)$ where k is the number of sub-clusters and i is the number of iterations to perform the clustering. In online phase, *ISAR* performs only recognition processing by considering each window, so the processing time is $O(mn)$ where n is the number of instances within a single window. For *STAR* model, it also applied the GMM clustering approach to create the learning model, thus the computational complexity of creating the learning model is $O(kNi)$. The online phase of *STAR* model consists of recognition and adaptation components. The recognition component identifies incoming activities in each window with a clustering-based technique by partitioning into two sub-clusters. Thus, the complexity for clustering data in each window is $O(2ni)$ and the recognition technique in *STAR* complexity is $O(k)$ where k is the number of sub-clusters in the learning model. While the processing time of the incremental adaptation technique is $O(nk)$. If we consider the utilization in real environment, *ISAR* is more applicable than *STAR* model, because clustering technique does not require in *ISAR* model.

TABLE I. THE PREDICTION ACCURACY OF THREE MODELS.

Techniques	Standing	Sitting	Walking	Jogging	Stairs
<i>ISAR</i> (%)	90.26	96.43	60.77	79.41	49.22
<i>STAR</i> without active learning (%)	24.08	18.93	27.00	25.96	21.03
<i>STAR</i> with active learning (%)	77.24 (52.6%)	95.64 (79.0%)	73.05 (45.5%)	81.43 (55.0%)	59.10 (39.3%)

TABLE II. THE COMPUTATIONAL COMPLEXITY OF *ISAR* AND *STAR* MODELS.

Techniques	Offline Phase	Recognition	Adaptation
<i>ISAR</i>	$O(Nm) + O(kmi)$	$O(mn)$	-
<i>STAR</i>	$O(kNi)$	$O(2ni) + O(k)$	$O(nk)$

V. CONCLUSIONS

Smartphone-based activity recognition is an important viewpoint in developing pervasive applications such as healthcare, elderly care and fitness monitoring when dealing with evolving streaming data. In this paper, we research on the physical activity recognition based on accelerometer embedded in mobile devices. We have developed *ISAR*, an impersonal and light-weight model for identifying activities in a non-stationary

sensory streaming data. The *ISAR* model is developed by using annotated sensory data from a panel of user as training data and are applied to the new users. The offline-online framework is used in *ISAR* model. In offline phase, we build classifier model from a set of annotated data based on characteristics of activities and clustering-based approach. In online phase, the recognition component is utilized on-board the mobile phone for non-stationary data.

ISAR's ability to distinguish the activities based on their characteristics – dormant and energetic activities is one of our contributions which *ISAR* can recognize the activities quite well. In addition, *ISAR* model does not inquire users to assign the true activities when the unidentified activities occur. The developed framework is evaluated with the real datasets. The experiments showed that *ISAR* model could successfully identify activities from the evolving data stream and could apply across different users. As a future work, we plan to improve the recognition component in online phase that may further enhance the accuracy of *ISAR* model.

VI. ACKNOWLEDGEMENT

This work was financially supported by the Research Grant of Burapha University through National Research Council of Thailand. We would like to thank Professor Dr.Chidchanok Lursinsap who has always guided our to work the research for the right path.

REFERENCES

- [1] S. A. Hoseini-Tabatabaei, A. Gluhak, and R. Tafazolli, "A survey on smartphone-based systems for opportunistic user context recognition," *ACM Comput. Surv.*, vol. 45, no. 3, pp. 27:1–27:51, Jul. 2013.
- [2] T. Peterek, M. Penhaker, P. Gajdoš, and P. Dohnálek, *Comparison of Classification Algorithms for Physical Activity Recognition*, 2014, pp. 123–131.
- [3] J. B. Gomes, S. Krishnaswamy, M. M. Gaber, P. A. C. Sousa, and E. Menasalvas, "Mars: A personalised mobile activity recognition system," pp. 316–319, July 2012.
- [4] Z. S. Abdallah, M. M. Gaber, B. Srinivasan, and S. Krishnaswamy, "Adaptive mobile activity recognition system with evolving data streams," *Neurocomputing*, vol. 150, Part A, pp. 304 – 317, 2015.
- [5] C. Deng, W. Yuan, Z. Tao, and J. Cao, "Detecting novel class for sensor-based activity recognition using reject rule," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9864 LNCS, pp. 34–44, 2016.
- [6] Z. Abdallah, M. Gaber, B. Srinivasan, and S. Krishnaswamy, "Anynovel: detection of novel concepts in evolving data streams: An application for activity recognition," *Evolving Systems*, vol. 7, no. 2, pp. 73–93, 2016.
- [7] J. W. Lockhart and G. M. Weiss, "Limitations with activity recognition methodology data sets," in *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct Publication*, ser. UbiComp '14 Adjunct, 2014, pp. 747–756.
- [8] G. M. Weiss, J. W. Lockhart, T. T. Pulickal, P. T. McHugh, I. H. Ronan, and J. L. Timko, "Actitracker: A smartphone-based activity recognition system for improving health and well-being," in *2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, 2016, pp. 682–688.
- [9] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, "Activity recognition using cell phone accelerometers," *SIGKDD Explor. Newsl.*, vol. 12, no. 2, pp. 74–82, Mar. 2011.
- [10] Y. Kwon, K. Kang, and C. Bae, "Unsupervised learning for human activity recognition using smartphone sensors," *Expert Systems with Applications*, vol. 41, no. 14, pp. 6067 – 6074, 2014.
- [11] T. Nguyen, S. Gupta, S. Venkatesh, and D. Phung, "Nonparametric discovery of movement patterns from accelerometer signals," *Pattern Recognition Letters*, vol. 70, pp. 52 – 58, 2016.



The Council of IT Deans of Thailand

presents the

Oral Presentation Certificate

to

**Therdsak Dungkaew,
Jakkarin Suksawatchon and Ureerat Suksawatchon**

for the paper entitled

**“Impersonal Smartphone-based
Activity Recognition Using the Accelerometer Sensory Data”**

in The 2nd International Conference on Information Technology (InCIT2017)
2-3 November 2017 at Faculty of ICT, Mahidol University, Thailand

Jaremsri J. Mitranont

(Assoc. Prof. Jaremsri Mitranont)

President of Council of IT Deans of Thailand

InCIT 2017 General Chair

Dean of Faculty of ICT, Mahidol University