



รายงานวิจัยฉบับสมบูรณ์
การรู้จำกิจกรรมที่ปรับได้สำหรับการวิเคราะห์พฤติกรรมเสี่ยงจากกระแสข้อมูลเชิงเวลา
บนอุปกรณ์เคลื่อนที่แบบพกพา

ผู้ช่วยศาสตราจารย์จักริน สุขสวัสดิ์ชื่น	หัวหน้าโครงการวิจัย
ศาสตราจารย์ชิตชนก เหลือสินทรัพย์	ผู้ร่วมวิจัย
ผู้ช่วยศาสตราจารย์อุรวิรัฐ สุขสวัสดิ์ชื่น	ผู้ร่วมวิจัย
ผู้ช่วยศาสตราจารย์ชนัญชิตาคุษฎี ทูลศิริ	ผู้ร่วมวิจัย
นายเหมรัมย์มี วชิรหัตถพงษ์	ผู้ร่วมวิจัย

โครงการวิจัยประเภทงบประมาณเงินรายได้
(เงินอุดหนุนจากรัฐบาล) ประจำปีงบประมาณ พ.ศ. 2561
มหาวิทยาลัยบูรพา

รหัสโครงการ 667961
สัญญาเลขที่ 113/2561

รายงานวิจัยฉบับสมบูรณ์
การรู้จำกิจกรรมที่ปรับได้สำหรับการวิเคราะห์พฤติกรรมเสี่ยงจากกระแสข้อมูลเชิงเวลา
บนอุปกรณ์เคลื่อนที่แบบพกพา

ผู้ช่วยศาสตราจารย์จักริน สุขสวัสดิ์ชน	หัวหน้าโครงการวิจัย
ศาสตราจารย์ชิตชนก เหลือสินทรัพย์	ผู้ร่วมวิจัย
ผู้ช่วยศาสตราจารย์อุรวิรัฐ สุขสวัสดิ์ชน	ผู้ร่วมวิจัย
ผู้ช่วยศาสตราจารย์ชญชิตาคุษฎี ทูลศิริ	ผู้ร่วมวิจัย
นายเหมรัมย์ วีชรหัสถพงษ์	ผู้ร่วมวิจัย

คณะวิทยาการสารสนเทศ

กิตติกรรมประกาศ

รายงานฉบับสมบูรณ์ฉบับนี้เสร็จสมบูรณ์ได้ด้วยดีด้วยการสนับสนุนจากทีมคณะผู้วิจัยทุกท่านที่ช่วยแนะนำให้คำปรึกษา และแนะแนวทางในการดำเนินงานวิจัยให้สำเร็จลุล่วง

ขอขอบคุณนายเทิดศักดิ์ ดุงแก้ว และนายกตিকা กองศีล นิสิตระดับปริญญาโท และนิสิตระดับปริญญาตรีทุกคน ที่มาช่วยในงานวิจัย และเป็นกำลังสำคัญในการร่วมทำงานวิจัยชิ้นนี้ให้สำเร็จลุล่วง

ขอขอบคุณพื้นที่ทำงานและพื้นที่ทดลองเก็บข้อมูลจาก อาคารสิรินธร คณะวิทยาศาสตร์ และห้องปฏิบัติการวิจัย Mobile Application Developers Incubation คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา อาคารใหม่

งานวิจัยนี้ได้รับทุนสนับสนุนจากงบประมาณเงินรายได้จากเงินอุดหนุนรัฐบาล (งบประมาณแผ่นดิน) ประจำปีงบประมาณ พ.ศ. 2560 และ พ.ศ. 2561 มหาวิทยาลัยบูรพา ผ่านสำนักงานคณะกรรมการการวิจัยแห่งชาติ เลขที่สัญญา 113/2561

ผู้ช่วยศาสตราจารย์ ดร.จักริน สุขสวัสดิ์ชน
หัวหน้าโครงการวิจัย

บทคัดย่อ

งานวิจัยส่วนใหญ่ที่เกี่ยวข้องกับการสร้างตัวแบบรู้จำกิจกรรม ด้วยข้อมูลกระแสเชิงเวลา จากตัวรับรู้แอกเซเลอโรมิเตอร์ของสมาร์ทโฟน และอุปกรณ์สวมใส่ข้อมือ จะใช้วิธีสร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคล โดยจำเป็นต้องเก็บข้อมูลการทำกิจกรรมต่าง ๆ ของผู้ใช้ตามระยะเวลาที่กำหนด จากนั้นจึงนำข้อมูลที่ได้ออกไปสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการจำแนกข้อมูลวิธีการต่าง ๆ ซึ่งจะได้ตัวแบบรู้จำกิจกรรมที่เหมาะสมกับผู้ใช้คนนั้น แต่อย่างไรก็ตามการสร้างตัวแบบรู้จำกิจกรรมลักษณะนี้อาจเป็นการรบกวนผู้ใช้มากเกินไป เนื่องจากผู้ใช้จะต้องเสียเวลาเก็บข้อมูลการทำกิจกรรมด้วยตัวเอง ยิ่งไปกว่านั้นถ้าหากผู้ใช้ทำกิจกรรมไม่ครบทุกกิจกรรมหรือไม่ตรงตามเวลาที่กำหนด การรู้จำกิจกรรมก็อาจเกิดความผิดพลาดขึ้นได้

จากโครงการวิจัยที่ได้รับทุนสนับสนุนจากงบประมาณเงินรายได้จากเงินอุดหนุนรัฐบาล (งบประมาณแผ่นดิน) ประจำปีงบประมาณ พ.ศ. 2560 มหาวิทยาลัยบูรพา ผ่านสำนักงานคณะกรรมการการวิจัยแห่งชาติ ที่ผ่านมา ผู้วิจัยได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล 2 วิธี ได้แก่ 1) วิธี “การรู้จำกิจกรรมแบบไม่เฉพาะบุคคลบนอุปกรณ์สมาร์ทโฟน” หรือ “ไอชาร์” และ 2) วิธี “ปรับปรุงการรู้จำกิจกรรมแบบไม่เฉพาะบุคคลบนอุปกรณ์สมาร์ทโฟน” หรือ “ไอชาร์พลัส” ซึ่งมีประสิทธิภาพด้านเวลา และความถูกต้อง ในการรู้จำกิจกรรมจากกระแสตัวรับรู้แอกเซเลอโรมิเตอร์ของสมาร์ทโฟน

ในโครงการวิจัยนี้เป็นโครงการที่ได้รับทุนสนับสนุนต่อเนื่องเป็นปีที่ 2 ซึ่งจะทำการทดลองวิจัยโดยใช้อุปกรณ์ที่เป็นอุปกรณ์สวมใส่ที่ข้อมือ หรือนาฬิกาอัจฉริยะ ซึ่งกระแสของข้อมูลที่จะใช้ในการรู้จำกิจกรรมจะมีความซับซ้อนมากกว่าข้อมูลที่มาจกสมาร์ทโฟน รวมถึงการใช้ข้อมูลจากตัวรับรู้มากกว่า 1 ตัวเพื่อเพิ่มความถูกต้องในการทำนายกิจกรรมให้มากขึ้น ซึ่งจากการออกแบบวิธีการดำเนินงาน ผู้วิจัยได้นำเสนอวิธีการใหม่นี้ว่า “Smartwatch based Physical Activity Recognition” หรือเรียกว่า “S-PAR” และผลการทดลองเมื่อทำการเปรียบเทียบกับงานวิจัยอื่นโดยใช้อุปกรณ์จริงจากฐานข้อมูลสาธารณะ พบว่าวิธีการ S-PAR มีผลความถูกต้องดีกว่าวิธีการที่นำมาเปรียบเทียบ ซึ่งสามารถนำไปประยุกต์และพัฒนาต่อยอดเป็นแอปพลิเคชันต่อไปได้

Abstract

Most of the research papers in activity recognition model with sensory data acquired from an accelerometer of smartphones and wearable devices, focused on building personal model. It is necessary to collect activities data of the user who utilizes the model for a definite time. Then, these labeled activities data are used to create the classifier model by classification methods. So, the classifier model is suitable for individual user. However, creating the personal model may be too interfere for the user, because the target user must gather and annotate the types of activities by performing all activities for a definite time and enough training data. Moreover, if the user does not complete all activities or do not complete the time. The activity recognition model can predict the wrong type of activities.

From the previous project supported by Research Grant of Burapha University through National Research Council of Thailand in Grant no. 141/2560, we proposed an algorithm for creating a classifier model by using 2 algorithms including 1) "Impersonal smartphone-based activity recognition using the accelerometer sensory data" or "ISAR", and 2) "An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data" or "ISAR+". These two proposed models can achieve in both the time performance and accuracies of activities recognition with sensory data acquired from an accelerometer of smartphones.

This project has been supported for the second consecutive year which focused on building the activities recognition model from sensory data gathered from wrist-worn devices or smartwatches. The sensory data produced from smartwatches are more complex than the data from smartphones and have to use more than 1 sensors to improve the prediction accuracy. Therefore, this research proposed the new method named "Smartwatch based Physical Activity Recognition" or "S-PAR". From the results, S-PAR model provides the overall performance in detection and prediction activities type. Therefore, our proposed model can be used to utilize in application

สารบัญ

	หน้า
กิตติกรรมประกาศ.....	ก
บทคัดย่อ	ข
Abstract.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญภาพ	ฑ
บทที่ 1	1
บทนำ.....	1
1.1 ที่มาและความสำคัญปัญหา.....	1
1.2 แนวทางแก้ไขปัญหา	6
1.3 วัตถุประสงค์ของโครงการวิจัย.....	13
1.4 ขอบเขตของโครงการวิจัย	14
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	15
1.6 แผนดำเนินโครงการวิจัย	15
บทที่ 2	17
ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	17
2.1 ทฤษฎีที่เกี่ยวข้อง	17
2.1.1 ตัวรับรู้ของอุปกรณ์สื่อสารเคลื่อนที่สมาร์ทโฟน.....	17
2.1.2 ตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ข้อมือ	20
2.1.3 ทฤษฎีการรู้จำ.....	21
2.1.4 การคำนวณทางสถิติสำหรับวิเคราะห์ข้อมูล	24
2.1.5 การรู้จำกิจกรรม (Activity Recognition)	26
2.2 งานวิจัยที่เกี่ยวข้อง	27
งานวิจัยที่เกี่ยวข้องเกี่ยวกับงานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ	30
2.2.2 ตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model)	34
2.2.2 ตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model).....	36
บทที่ 3	42
วิธีการที่นำเสนอ.....	42
3.1 การศึกษาและวิเคราะห์ข้อมูลสำหรับสร้างตัวแบบรู้จำกิจกรรม.....	42
3.1.1 ข้อมูลกิจกรรม	42
3.2 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (ISAR)	45
3.2.1 ISAR ขั้นตอนออฟไลน์ (Modeling).....	47

3.2.2 ISAR ขั้นตอนออนไลน์ (Recognition)	53
3.2.3 ข้อจำกัดของวิธีการ ISAR.....	58
3.3 ขั้นตอนการพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรม (ISAR+)	59
3.3.1 การพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ ขั้นตอนออฟไลน์ (Offline phase : Modelling component).....	61
3.3.2 การพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ ISAR+ ขั้นตอนออนไลน์ (Recognition)	67
3.4 ขั้นตอนการพัฒนาวิธีการ “Smartwatch-base Physical Activity Recognition” (S-PAR)	71
3.4.1 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (Modeling phase).....	73
3.4.2 ขั้นตอนที่รู้จำกิจกรรม (Recognition phase).....	82
บทที่ 4	85
ผลการดำเนินงานวิจัย	85
4.1 ข้อมูลกิจกรรมที่ใช้ในการทดลอง.....	85
4.1.1 ข้อมูล WISDM.....	85
4.1.2 ข้อมูล UniMiB-SHAR.....	86
4.1.3 ข้อมูลกิจกรรม Complex human activities dataset.....	87
4.1.1 ข้อมูลกิจกรรม RealworldHAR	88
4.2 การออกแบบการทดลองและวิธีการที่ใช้วัดประสิทธิภาพตัวแบบรู้จำกิจกรรม.....	89
4.2.1 ขั้นตอนการแบ่งข้อมูลสำหรับสร้างตัวแบบรู้จำกิจกรรมและข้อมูลทดสอบตัวแบบ รู้จำกิจกรรม.....	89
4.2.2 วิธีการที่ใช้วัดประสิทธิภาพของตัวแบบรู้จำกิจกรรม	91
4.3 การวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมของวิธีการ ISAR และ ISAR+	92
4.3.1 ผลการทดลองกับข้อมูลกิจกรรม WISDM	92
4.3.2 ผลการทดลองกับข้อมูลกิจกรรม UniMiB-SHAR.....	94
4.4 การวัดประสิทธิภาพด้านเวลาของการรู้จำกิจกรรมของวิธีการ ISAR และ ISAR+ ...	97
4.5 การวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมของวิธีการ S- PAR.....	101
4.5.1 ผลการทดลองกับข้อมูลกิจกรรม Complex human activities dataset.....	101
4.5.2 ผลการทดลองกับข้อมูลกิจกรรม RealworldHAR	105
บทที่ 5	109
สรุปผลการดำเนินงานและข้อเสนอแนะ	109
5.1 สรุปผลการดำเนินงาน.....	109
5.1.1 ผลการดำเนินงานสำหรับวิธีการ ISAR และ ISAR+ ที่ทดลองกับข้อมูลจากอุปกรณ์ สมาร์ทโฟน.....	109

5.1.2 ผลการดำเนินงานสำหรับวิธีการ S-PAR ที่ทดลองกับข้อมูลจากอุปกรณ์สวมใส่ที่ ข้อมือ (Wrist-worn)	111
5.2 วิจัยผลการดำเนินงาน	113
5.2.1 ข้อดีของงานวิจัย.....	113
5.2.2 ข้อจำกัดของงานวิจัย	114
5.2.3 ข้อเสนอแนะของงานวิจัย.....	114
บรรณานุกรม.....	115
ประวัติย่อของผู้วิจัย.....	121

สารบัญตาราง

หน้า

ตารางที่ 2-1 ชนิดตัวรับรู้ของอุปกรณ์เคลื่อนที่แบบพกพา และรายละเอียดการใช้งาน.....	18
ตารางที่ 2-2 ชนิดตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือและรายละเอียดการใช้งาน.....	20
ตารางที่ 2-3 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบสำหรับการรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์สมาร์ตโฟน	28
ตารางที่ 2-4 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ	32
ตารางที่ 2-5 การประเมินระดับความเชื่อมั่นที่ได้จากมาตรวัดของวิธีการ STAR.....	41
ตารางที่ 3-1 การจับคู่วิธีการ SD และวิธีการทางสถิติอื่น ๆ ในการรู้จำกิจกรรม โดยใช้ข้อมูล WISDM	67
ตารางที่ 4-1 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ WISDM	85
ตารางที่ 4-2 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ UniMiB-SHAR	86
ตารางที่ 4-3 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ Complex human activities dataset.....	87
ตารางที่ 4-4 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ RealworldHAR.....	88
ตารางที่ 4-5 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ STAR กับข้อมูล WISDM.....	92
ตารางที่ 4-6 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR กับข้อมูล WISDM.....	93
ตารางที่ 4-7 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR+ กับข้อมูล WISDM.....	93
ตารางที่ 4-8 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ STAR กับข้อมูล UniMiB-SHAR.....	95
ตารางที่ 4-9 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR กับข้อมูล UniMiB-SHAR.....	95
ตารางที่ 4-10 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ ISAR+ กับข้อมูล UniMiB-SHAR ..	95
ตารางที่ 4-11 ความซับซ้อนเชิงเวลาของวิธีการ ISAR, ISAR+ และ STAR.....	98
ตารางที่ 4-12 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 1 กับข้อมูลกิจกรรม Complex human activities dataset.....	102

สารบัญตาราง (ต่อ)

หน้า

ตารางที่ 4-13 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 1 กับข้อมูลกิจกรรม Complex human activities dataset..... 102

ตารางที่ 4-14 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของ Shoaib และคณะ (2015) กับ ข้อมูลกิจกรรม Complex human activities dataset..... 103

ตารางที่ 4-15 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของ S-PAR กับข้อมูลกิจกรรม Complex human activities dataset 103

ตารางที่ 4-16 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 1 กับข้อมูลกิจกรรม RealworldHAR 105

ตารางที่ 4-17 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 2 กับข้อมูลกิจกรรม RealworldHAR 106

ตารางที่ 4-18 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของ S-PAR กับข้อมูลกิจกรรม RealworldHAR..... 106

สารบัญภาพ

หน้า

ภาพที่ 1-1 แผนภูมิกระจายของข้อมูลกิจกรรมการเดินและการขึ้นลงบันได	5
ภาพที่ 1-2 แผนภูมิกระจายข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 27 และหมายเลข 36 ที่มีการวางอุปกรณ์ต่างกัน	6
ภาพที่ 1-3 กรอบแนวคิดวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR).....	8
ภาพที่ 1-4 กรอบแนวคิดวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)	9
ภาพที่ 1-5 แผนภูมิกระจายของข้อมูลกิจกรรมการเดิน การเดินขึ้นบันได และการลงบันได	11
ภาพที่ 1-6 แผนภูมิกระจายตัวอย่างข้อมูลกิจกรรมนอนที่แตกต่างกันของผู้ใช้หมายเลข 3, 11 และ 13	12
ภาพที่ 1-7 กรอบแนวคิดวิธีการ “Smartwatch-based Physical Activity Recognition” หรือเรียกว่า “S-PAR”	13
ภาพที่ 2-1 ตัวรับรู้ชนิด Accelerometer sensor	18
ภาพที่ 2-2 ลักษณะแกนของตัวรับรู้ชนิด Accelerometer และ Gyroscope	20
ภาพที่ 2-3 วิธีการแบ่งกลุ่มข้อมูลแบบ K-mean, Spectral Clustering, DBSCAN และ Gaussian Mixture	21
ภาพที่ 2-4 ขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบรู้จำ	23
ภาพที่ 2-5 ขั้นตอนการทดสอบตัวแบบ	24
ภาพที่ 2-6 ขั้นตอนการนำตัวแบบไปใช้งานจริง	24
ภาพที่ 2-7 ขั้นตอนการรู้จำกิจกรรม	27
ภาพที่ 2-8 กรอบแนวคิดงานวิจัยของ Silva และ Galeazzo (2013)	31
ภาพที่ 2-9 กรอบแนวคิดวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR)	36
ภาพที่ 2-10 ขั้นตอนการแบ่งกลุ่มข้อมูลแต่ละกิจกรรมออกเป็นกลุ่มย่อยตามจำนวนกลุ่มที่กำหนด.	37
ภาพที่ 2-11 ขั้นตอนการรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาของวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR)	40

สารบัญภาพ (ต่อ)

หน้า

ภาพที่ 3-1 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 27 จากข้อมูล WISDM.....	43
ภาพที่ 3-2 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 13 จากข้อมูล UniMiB-SHA	43
ภาพที่ 3-3 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 1 จากข้อมูลกิจกรรม Complex human activities dataset.....	44
ภาพที่ 3-4 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 9 จากข้อมูลกิจกรรม RealworldHAR45	
ภาพที่ 3-5 ภาพรวมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR).....	46
ภาพที่ 3-6 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบนิ่ง	47
ภาพที่ 3-7 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบเคลื่อนไหว	47
ภาพที่ 3-8 ตัวอย่างค่า Magnitude (M_i) ของข้อมูลกิจกรรม	48
ภาพที่ 3-9 ตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมแบบเคลื่อนไหว (Energetic activities) และกิจกรรมแบบนิ่ง (Dormant activities) ออกจากกันได้.....	50
ภาพที่ 3-10 แผนภูมิกระจายของข้อมูลกิจกรรม (ข้อมูลดิบ)	52
ภาพที่ 3-11 แผนภูมิกระจายของข้อมูลกิจกรรม (ข้อมูลที่แปลงด้วยส่วนเบี่ยงเบนมาตรฐาน).....	52
ภาพที่ 3-12 ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR).....	53
ภาพที่ 3-13 ขั้นตอนออนไลน์ของวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)	54
ภาพที่ 3-14 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการนั่ง	55
ภาพที่ 3-15 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการยืน.....	55
ภาพที่ 3-16 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว	57
ภาพที่ 3-17 การระบุกิจกรรมโดยเปรียบเทียบระยะทางของ $SDj(ax)$, $SDj(ay)$, $SDj(az)$ และ $Ckact$ ของแต่ละกลุ่มย่อยภายใน Classifier model (CM).....	57

สารบัญภาพ (ต่อ)

หน้า

ภาพที่ 3-18 ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)..... 58

ภาพที่ 3-19 กรอบแนวคิดวิธีการ An improvement of impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) 60

ภาพที่ 3-20 ตัวอย่างวิธีการ ISAR+ ที่มีการแบ่งกลุ่มข้อมูลแล้วไม่มีการแบ่งกลุ่มข้อมูล..... 61

ภาพที่ 3-21 ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) 66

ภาพที่ 3-22 ขั้นตอนการตรวจสอบการปรับปรุงตัวแบบรู้จำกิจกรรม 68

ภาพที่ 3-23 ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+) 70

ภาพที่ 3-24 ขั้นตอนออนไลน์ การปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)..... 71

ภาพที่ 3-25 กรอบแนวคิดวิธีการ Smartwatch-base Physical Activity Recognition (S-PAR). 72

ภาพที่ 3-26 ขั้นตอนการแยกความแรงที่เกิดจากแรงโน้มถ่วงและความเร่งเชิงเส้นจากความเร่งจากตัวรับรู้ Accelerometer..... 73

ภาพที่ 3-27 กระแสข้อมูลเชิงเวลาความเร่งที่วัดได้จากตัวรับรู้ Accelerometer เป็นการรวมกันระหว่างความเร่งที่เกิดแรงโน้มถ่วงและความเร่งเชิงเส้นที่เกิดจากผู้ใช้งานของกิจกรรมเดินจากข้อมูลกิจกรรม RealworldHAR 74

ภาพที่ 3-28 แผนภูมิเส้นลักษณะกระแสข้อมูลเชิงเวลาความเร่ง Acclerometer ของกลุ่มกิจกรรมนี้่จจากข้อมูลกิจกรรม RealworldHAR..... 75

ภาพที่ 3-29 แผนภูมิเส้นลักษณะกระแสข้อมูลเชิงเวลาความเร่ง Acclerometer ของกลุ่มกิจกรรมเคลื่อนไหวจากข้อมูลกิจกรรม RealworldHAR..... 75

ภาพที่ 3-30 ตัวอย่างค่า Magnitude (*Mi*) ของข้อมูลกิจกรรม..... 76

สารบัญภาพ (ต่อ)

หน้า

ภาพที่ 3-31 ตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมเคลื่อนไหวกับกิจกรรมแบบนั่ง	77
ภาพที่ 3-32 แผนภูมิเส้นแสดงลักษณะกระแสดังข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตาม แนวแกน X, Y และ Z ของกิจกรรมยืนของผู้ใช้ที่ 1 และ 3 จากข้อมูลกิจกรรม RealworldHAR....	78
ภาพที่ 3-33 แผนภูมิเส้นแสดงลักษณะกระแสดังข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตาม แนวแกน X, Y และ Z ของกิจกรรมนอนของผู้ใช้ที่ 1 และ 3 จากข้อมูลกิจกรรม RealworldHAR .	78
ภาพที่ 3-34 แผนภูมิเส้นแสดงลักษณะกระแสดังข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตาม แนวแกน X, Y และ Z ของกิจกรรมนอนของผู้ใช้ที่ 1 และ 3 จากข้อมูลกิจกรรม RealworldHAR .	78
ภาพที่ 3-35 แผนภูมิเส้นลักษณะการเปลี่ยนค่าความเร่งเชิงเส้นของกลุ่มกิจกรรมเคลื่อนไหวจาก ข้อมูลกิจกรรม RealworldHAR.....	80
ภาพที่ 3-36 แผนภูมิเส้นลักษณะการเปลี่ยนค่าความเร็วเชิงมุมของกลุ่มกิจกรรมเคลื่อนไหวจากข้อมูล กิจกรรม RealworldHAR	80
ภาพที่ 3-37 ขั้นตอนรู้จำกิจกรรมของวิธีการ S-PAR	83
ภาพที่ 3-38 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบนั่ง.....	84
ภาพที่ 3-39 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว	84
ภาพที่ 4-1 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 27 จากข้อมูล WISDM.....	86
ภาพที่ 4-2 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 13 จากข้อมูล UniMiB-SHAR	87
ภาพที่ 4-3 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 1 จากข้อมูลกิจกรรม Complex human activities dataset	88
ภาพที่ 4-4 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 9 จากข้อมูลกิจกรรม RealworldHAR89	
ภาพที่ 4-5 ตัวอย่างการแบ่งข้อมูลกิจกรรมสำหรับสร้างและทดสอบตัวแบบรู้จำกิจกรรมด้วยวิธี K- Fold Cross Validation	90
ภาพที่ 4-6 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล กิจกรรม WISDM.....	93
ภาพที่ 4-7 แผนภูมิแท่งเปรียบเทียบ Recall ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล กิจกรรม WISDM.....	94

สารบัญภาพ (ต่อ)

หน้า

ภาพที่ 4-8 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM	94
ภาพที่ 4-9 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR	96
ภาพที่ 4-10 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR.....	96
ภาพที่ 4-11 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR.....	97
ภาพที่ 4-12 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนสร้างตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล WISDM	99
ภาพที่ 4-13 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนสร้างตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR	99
ภาพที่ 4-14 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล WISDM.....	100
ภาพที่ 4-15 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR.....	101
ภาพที่ 4-16 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการของ Da Silva และ Galeazzo (2013) กับวิธีที่นำเสนอด้วยข้อมูลกิจกรรม Complex Human Activities Dataset	104
ภาพที่ 4-17 แผนภูมิแท่งเปรียบเทียบ Recall ระหว่างวิธีการของ Da Silva และ Galeazzo (2013) กับวิธีที่นำเสนอด้วยข้อมูลกิจกรรม Complex Human Activities Dataset.....	104
ภาพที่ 4-18 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการของ Da Silva และ Galeazzo (2013) กับวิธีการที่นำเสนอด้วยข้อมูลกิจกรรม Complex Human Activities Dataset.....	105
ภาพที่ 4-19 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการของ Da Silva และ Galeazzo (2013), งานวิจัย Shaiob และคณะ (2015) และ S-PAR ด้วยข้อมูลกิจกรรม RealworldHAR	107
ภาพที่ 4-20 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการของ Da Silva และ Galeazzo (2013), งานวิจัย Shaiob และคณะ (2015) และ S-PAR ด้วยข้อมูลกิจกรรม RealworldHAR	107

สารบัญภาพ (ต่อ)

หน้า

ภาพที่ 4-21 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการของ Da Silva และ Galeazzo (2013), งานวิจัย Shaiob และคณะ (2015) และ S-PAR ด้วยข้อมูลกิจกรรม RealworldHAR....	108
ภาพที่ 5-1 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล WISDM พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure	110
ภาพที่ 5-2 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ ISAR, ISAR+ และ STAR กับข้อมูล UniMiB-SHAR พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure	111
ภาพที่ 5-3 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ S-PAR, งานวิจัย Da Silva และ Galeazzo (2013) และงานวิจัย Shoaib และคณะ (2015) กับข้อมูล Complex human activities dataset พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure	112
ภาพที่ 5-4 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ S-PAR, งานวิจัย Da Silva และ Galeazzo (2013) และงานวิจัย Shoaib และคณะ (2015) กับข้อมูล RealworldHAR พิจารณาทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure	113

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญปัญหา

จากสถานการณ์ในปัจจุบันของโลกที่เปลี่ยนแปลงไปอย่างรวดเร็ว ทั้งทางด้านการเมือง เศรษฐกิจ สังคม สิ่งแวดล้อม รวมทั้งความก้าวหน้าทางเทคโนโลยี ซึ่งมีผลทำให้มนุษย์มีพฤติกรรมการใช้ชีวิตที่ไม่สมดุลเกิดขึ้น และมีแนวโน้มที่จะก่อให้เกิดปัญหาด้านสุขภาพเพิ่มมากขึ้น โดยเฉพาะโรค ร้ายจากการใช้ชีวิตของคนในปัจจุบันที่เราสร้างขึ้นมาเอง ที่เรียกว่าโรค NCDs (Non-Communicable Diseases) ซึ่งเกิดจากนิสัยหรือพฤติกรรมการใช้ชีวิตที่ไม่ถูกต้อง เช่น การไม่ออกกำลังกาย การนอนดึก การทำงานต่างที่ไม่ถูกสุขลักษณะ ความเครียด การรับประทานอาหารที่รสจัดเกินไป เป็นต้น จากข้อมูลจากสำนักงานสถิติแห่งชาติพบว่า มีผู้เสียชีวิตด้วยโรค NCDs หรือโรคไม่ติดต่อเรื้อรัง สูงขึ้นมาก โดย 4 โรคที่พบอันดับต้น ๆ ได้แก่ โรคมะเร็ง เบาหวาน ความดันโลหิตสูง โรคหัวใจ ในปี 2555 มีสถิติผู้เสียชีวิตรวมกันจำนวน 89,775 คน โดยร้อยละ 37 หรือ 33,545 คน เสียชีวิตขณะอายุยังไม่ถึง 60 ปี ซึ่งเป็นสาเหตุหลักที่ทำให้คนวัยแรงงานอายุสั้นลง คิดเป็นมูลค่าความเสียหายทางเศรษฐกิจถึง 2 แสนล้านบาท/ปี และสถิติโรค NCDs ล่าสุดในปี 2558 ข้อมูลจาก สสส. พบว่าคนไทยกว่า 300,000 คน เสียชีวิตจากกลุ่มโรค NCDs และมีโอกาสเพิ่มขึ้นต่อเนื่องทุก ๆ ปี และข้อมูลจากองค์การอนามัยโลก ระบุว่าประชากรทั่วโลกเสียชีวิตด้วยกลุ่มโรค NCDs 63% ซึ่งสูงถึง ร้อยละ 80 ในประเทศกำลังพัฒนา รวมถึงประเทศไทย ก็มีผู้เสียชีวิตด้วยกลุ่มโรคนี้สูงกว่าอัตราการเสียชีวิตเฉลี่ยของประชากรทั้งโลกถึง 10% และสูงกว่าทุกประเทศในโลก อย่างไรก็ตามโรค NCDs เป็นโรคที่เกิดจากปัจจัยที่หลีกเลี่ยงและป้องกันได้ การเกิดโรคและเสียชีวิตจากโรคนี้ได้ และข้อมูลที่ สำคัญจากสำนักงานสถิติแห่งชาติพบว่าปัจจุบันนี้ประชากรในประเทศไทยกำลังเข้าสู่สังคมผู้สูงอายุ กล่าวคือมีจำนวนผู้สูงอายุเพิ่มขึ้นเรื่อยๆ แต่ทารกที่เกิดน้อยลง ทำให้ประชากรในวัยแรงงานมีจำนวน ลดลง และหากประชากรวัยแรงงานนี้มีอายุที่สั้นลงจากโรคในกลุ่ม NCDs ซึ่งเกิดจากการใช้ชีวิตกับ พฤติกรรมที่เสี่ยงต่อการเกิดโรค ปัญหาเศรษฐกิจ สังคม จะเกิดขึ้นอย่างแน่นอน

โรค NCDs จึงกลายเป็นปัญหาเร่งด่วนที่ภาครัฐควรตระหนัก เนื่องจากโรค NCDs ไม่เพียงแต่มีผลกระทบต่อเศรษฐกิจของครัวเรือน ที่ทำให้ขาดแรงงานหลักที่สร้างรายได้ให้ครอบครัวแล้ว ผู้สูงอายุอาจขาดผู้ดูแล โดยเฉพาะครอบครัวขนาดเล็ก และโรคนี้ยังส่งผลกระทบต่อการพัฒนา เศรษฐกิจและสังคมของประเทศโดยเฉพาะด้านคุณภาพของทรัพยากรมนุษย์ ซึ่งในปัจจุบันประเทศไทยได้กำหนดโรค NCDs เป็นเป้าหมายหลักการพัฒนาในแผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ ฉบับที่ 10 และจะต้องสานต่อเจตนารมณ์ในช่วงแผนพัฒนาเศรษฐกิจและสังคมแห่งชาติฉบับที่ 11 และแผนพัฒนาระยะยาวอย่างจริงจังและต่อเนื่อง สำนักคณะกรรมการพัฒนาเศรษฐกิจและสังคม แห่งชาติกระทรวง สาธารณสุขและสถาบันโภชนาการ มหาวิทยาลัยมหิดลได้เล็งเห็นตระหนักถึง ความสำคัญดังกล่าวผ่านกระบวนการจัดทำแผนยุทธศาสตร์สุขภาพวิถีชีวิตไทย พ.ศ. 2554-2563

ขึ้น และคณะรัฐมนตรีได้มีมติอนุมัติในหลักการ แผนยุทธศาสตร์และกลไกการขับเคลื่อนยุทธศาสตร์ระดับชาติดังกล่าว เพื่อใช้เป็นกรอบชี้ทิศทางการขับเคลื่อนสู่ภาคปฏิบัติการอย่างบูรณาการและเป็นเอกภาพทุกระดับ ในการปรับเปลี่ยนชีวิตใหม่และวิถีชีวิตที่ลดเสี่ยง ลดโรค ลดภาวะแทรกซ้อน ลดการพิการ ลดการตาย และลดภาระค่าใช้จ่ายทั้งในระดับบุคคล ครอบครัว ชุมชน สังคม และ ประเทศ ให้ก้าวสู่วิถีชีวิตพอเพียง ระบบสุขภาพพอเพียง และสังคมสุขภาวะ

ดังนั้นแนวทางการป้องกัน และลดปริมาณผู้ป่วยในกลุ่มโรค NCDs นี้ จะต้องปรับเปลี่ยนพฤติกรรมและการใช้ชีวิตให้ถูกต้อง แต่ในปัจจุบันการที่คนเราไม่สามารถปรับเปลี่ยนพฤติกรรมได้นั้น อาจเป็นเพราะขาดการกระตุ้นที่ตัวบุคคลโดยตรง ตัวอย่างเช่น ส่วนใหญ่เมื่อเรานั่งทำงานแล้วมักจะไม่นั่งทำงานไปก็ชั่วโมงแล้ว ควรจะเคลื่อนไหวร่างกายหรือเปลี่ยนอิริยาบถแล้วหรือยัง ซึ่งการนั่งทำงานเป็นเวลานานของคนเราไม่มีใครมาคอยบอกหรือกระตุ้นว่าควรลุกจากที่นั่งเพื่อให้ร่างกายได้เคลื่อนไหวหรือทำกิจกรรมอย่างอื่น ปัญหาเหล่านี้เกิดเพราะพฤติกรรมและความเคยชินของคนเราก่อให้เกิดโรค NCDs ดังนั้นการที่จะแก้ปัญหาเหล่านี้ สิ่งหนึ่งที่สำคัญคือเราต้องรู้ก่อนว่าคนเราทำอะไรบ้างในหนึ่งวัน โดยเน้นที่กิจกรรมทางกายภาพหลัก ๆ ได้แก่ เดิน วิ่ง นั่ง ขึ้นบันได เป็นต้น และใช้ข้อมูลกิจกรรมเหล่านี้มาวิเคราะห์และวางแผน กระตุ้น และเฝ้าระวังพฤติกรรมเสี่ยงที่ก่อให้เกิดโรค NCDs ที่ตัวบุคคลได้โดยตรง รวมถึงสามารถเห็นแนวโน้มของการปรับเปลี่ยนพฤติกรรมที่ชัดเจนและเป็นรูปธรรมมากยิ่งขึ้น

ปัจจุบันมีเทคโนโลยีที่ทันสมัยเข้ามาอำนวยความสะดวก ให้กับการใช้ชีวิตของเรามากมาย และหนึ่งในเทคโนโลยีที่คนรักสุขภาพและการออกกำลังกายนิยมใช้ก็คือ แอปพลิเคชันแนะนำการออกกำลังกาย ซึ่งแอปพลิเคชันเหล่านี้ถูกพัฒนาขึ้นบนอุปกรณ์สื่อสารเคลื่อนที่ ได้แก่ สมาร์ทโฟน นาฬิกาอัจฉริยะ เป็นต้น ฟังก์ชันการทำงานของแต่ละแอปพลิเคชัน มีหลากหลายแล้วแต่จะเลือกใช้งาน ไม่ว่าจะเป็นการคำนวณแคลอรีการทำกิจกรรม การคำนวณระยะทางการทำกิจกรรม การจับเวลาการทำกิจกรรม เป็นต้น ถือเป็นเรื่องน่าประหลาดใจอย่างมาก ว่าทำไมแอปพลิเคชันเหล่านี้ถึงได้รู้ว่าคุณขณะนั้น ผู้ใช้กำลังทำกิจกรรมอะไรอยู่ ซึ่งสิ่งที่ทำให้แอปพลิเคชันรู้ว่าผู้ใช้กำลังทำกิจกรรมของอะไรอยู่ 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 สามารถ

สร้างตัวแบบได้เป็นสองลักษณะ ขึ้นอยู่กับลักษณะข้อมูลที่ใช้สร้างตัวแบบ (Lockhart และ Weiss, 2014) ได้แก่

1) ตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model) เป็นตัวแบบเฉพาะบุคคลที่ถูกพัฒนาเพื่อแยกแยะ หรือระบุกิจกรรมที่ทำในแต่ละวันของคนคนนั้น การสร้างตัวแบบเฉพาะบุคคลนี้ จะต้องให้ผู้ใช้ที่จะใช้งานตัวแบบเป็นคนเตรียมข้อมูลของการทำกิจกรรมต่าง ๆ ผ่านทางแอปพลิเคชัน เช่น ให้ผู้ใช้ทำกิจกรรมการเดิน การยืน การนั่ง การวิ่ง และการขึ้นลงบันได โดยทำกิจกรรมละ 5 นาที เป็นต้น เพื่อให้ได้ข้อมูลการทำกิจกรรม และใช้เป็นข้อมูลสำหรับสร้างตัวแบบในขั้นตอนการเรียนรู้ และทดสอบตัวแบบของผู้ใช้เฉพาะบุคคล ตัวอย่างงานวิจัยที่เน้นสร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคล 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 Naïve Bayes ในการสร้างตัวแบบรู้จำกิจกรรม ต่อมา งานวิจัยของ 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 ซึ่งถ้าผู้ใช้ทำกิจกรรมไม่ครบ หรือทำไม่ตรงตามเวลาที่กำหนด ก็จะไม่สามารถสร้างตัวแบบรู้จำกิจกรรมได้ หรือได้ตัวแบบรู้จำกิจกรรมที่ไม่สมบูรณ์ นอกจากนี้ถ้าผู้ใช้ทำท่าทางกิจกรรมต่าง ๆ ตั้งใจมากเกินไปจนเกร็งหรือไม่เป็นธรรมชาติตามลักษณะการทำกิจกรรมของผู้ใช้เอง ก็จะได้ข้อมูลที่ใช้สร้างตัวแบบรู้จำกิจกรรมที่อาจไม่


เหมือนกับข้อมูลการทำกิจกรรมเมื่อใช้งานจริง ทำให้ตัวแบบรู้จำกิจกรรมที่ได้มีความผิดพลาดในการรู้จำกิจกรรม

2) ตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model) เป็นตัวแบบรู้จำกิจกรรมที่สร้างมาจากข้อมูลการทำกิจกรรมของผู้ใช้คนใดก็ได้ไม่เฉพาะเจาะจง ดังนั้นผู้ที่ใช้งานตัวแบบจึงไม่จำเป็นต้องเก็บข้อมูลการทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนดด้วยตัวเอง เหมือนอย่างตัวแบบรู้จำกิจกรรมเฉพาะบุคคล ซึ่งสอดคล้องกับงานวิจัยของ Abdallah และคณะ (2015) ได้นำเสนอวิธีการที่ชื่อว่า “STAR” ย่อมาจากจาก “Stream learning for mobile Activity Recognition” ที่สามารถรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาที่ได้จากข้อมูลจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน วิธีการ STAR มีกรอบการทำงานสองส่วน ได้แก่ 1) ขั้นตอนเตรียมตัวแบบรู้จำกิจกรรม (Offline modeling phase) สำหรับสร้างตัวแบบรู้จำกิจกรรม โดยนำข้อมูลการทำกิจกรรมในแต่ละกิจกรรม แบ่งเป็นกลุ่มย่อย (Clustering) ตามจำนวนกลุ่มที่กำหนด แล้วเก็บข้อมูลสรุป (Statistics summary) ของแต่ละกลุ่ม ได้แก่ จำนวนของข้อมูลในแต่ละกลุ่ม ค่าศูนย์กลางของข้อมูล ส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่นของข้อมูล และค่ารัศมีของข้อมูล เป็นต้น ซึ่งในแต่ละกลุ่มย่อยจะเก็บข้อมูลสรุปทั้งสิ้น 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 และเมื่อนำข้อมูลของกิจกรรมการขึ้นลงบันไดและการเดินมาสร้างเป็นแผนภูมิกระจาย ดังภาพที่ 1-1 จะเห็นว่าข้อมูลทั้ง 2 กิจกรรมมีความซ้อนทับกัน (Overlapping data) ทำให้การรู้จำ 2 กิจกรรมนี้ มีความผิดพลาดเกิดขึ้นได้


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



ภาพที่ 1-1 แผนภูมิกระจายของข้อมูลกิจกรรมการเดินและการขึ้นลงบันได

- เนื่องจากวิธีการ STAR เป็นการรู้จำกิจกรรมไม่เฉพาะบุคคล จึงอาจมีกรณีที่มีข้อมูลการทำกิจกรรมของผู้ใช้ตัวแบบรู้จำกิจกรรม แตกต่างจากข้อมูลการทำกิจกรรมที่ใช้สร้างตัวแบบรู้จำกิจกรรม ดังภาพที่ 1-2 แสดงแผนภูมิกระจายของข้อมูลการเดินของผู้ใช้หมายเลข 27 และ 36 จะเห็นได้ว่ามีลักษณะที่แตกต่างกัน ทั้งนี้อาจเนื่องมาจากลักษณะการวางอุปกรณ์ที่ต่างกัน 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 ที่มีกรวางอุปกรณ์ต่างกัน

1.2 แนวทางแก้ไขปัญหา

แนวทางที่ 1

จากข้อจำกัดของวิธีการ STAR ที่กล่าวมาข้างต้น งานวิจัยนี้จึงได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรม 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

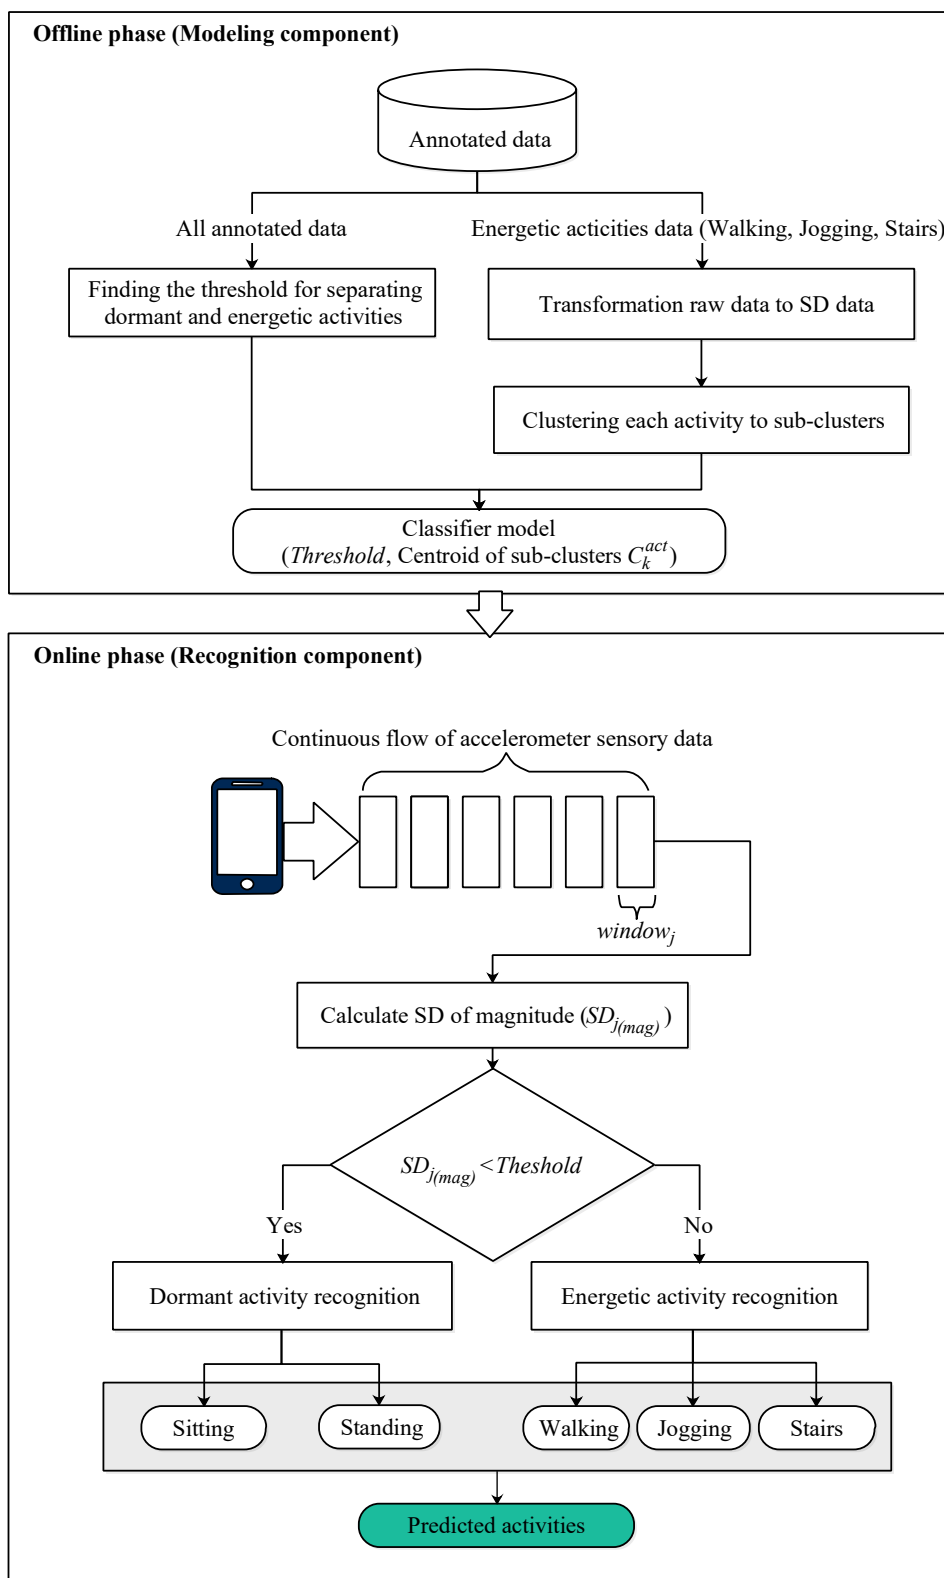
- ขั้นตอนออฟไลน์ เป็นขั้นตอนสำหรับสร้างตัวแบบรู้จำกิจกรรม โดยใช้ข้อมูลการทำกิจกรรมของผู้ใช้คนใดก็ได้ ในส่วนนี้จะประกอบไปด้วย ขั้นตอนการหาค่าขีดแบ่ง (Threshold) สำหรับแบ่งประเภทของกิจกรรมเป็นสองประเภท ได้แก่ กิจกรรมแบบนิ่งและกิจกรรมแบบเคลื่อนไหว ขั้นตอนต่อมาคือการแปลงข้อมูลกิจกรรม ให้เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน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

- ขั้นตอนออนไลน์ เป็นขั้นตอนสำหรับรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลา และปรับปรุงตัวแบบรู้จำกิจกรรม โดยข้อมูลต่อเนื่องจาก Accelerometer sensor ของสมาร์ทโฟนจะถูกแบ่งออกเป็นหน้าต่าง (window) และนำข้อมูลแต่ละหน้าต่างมาคำนวณค่าส่วนเบี่ยงเบนมาตรฐาน

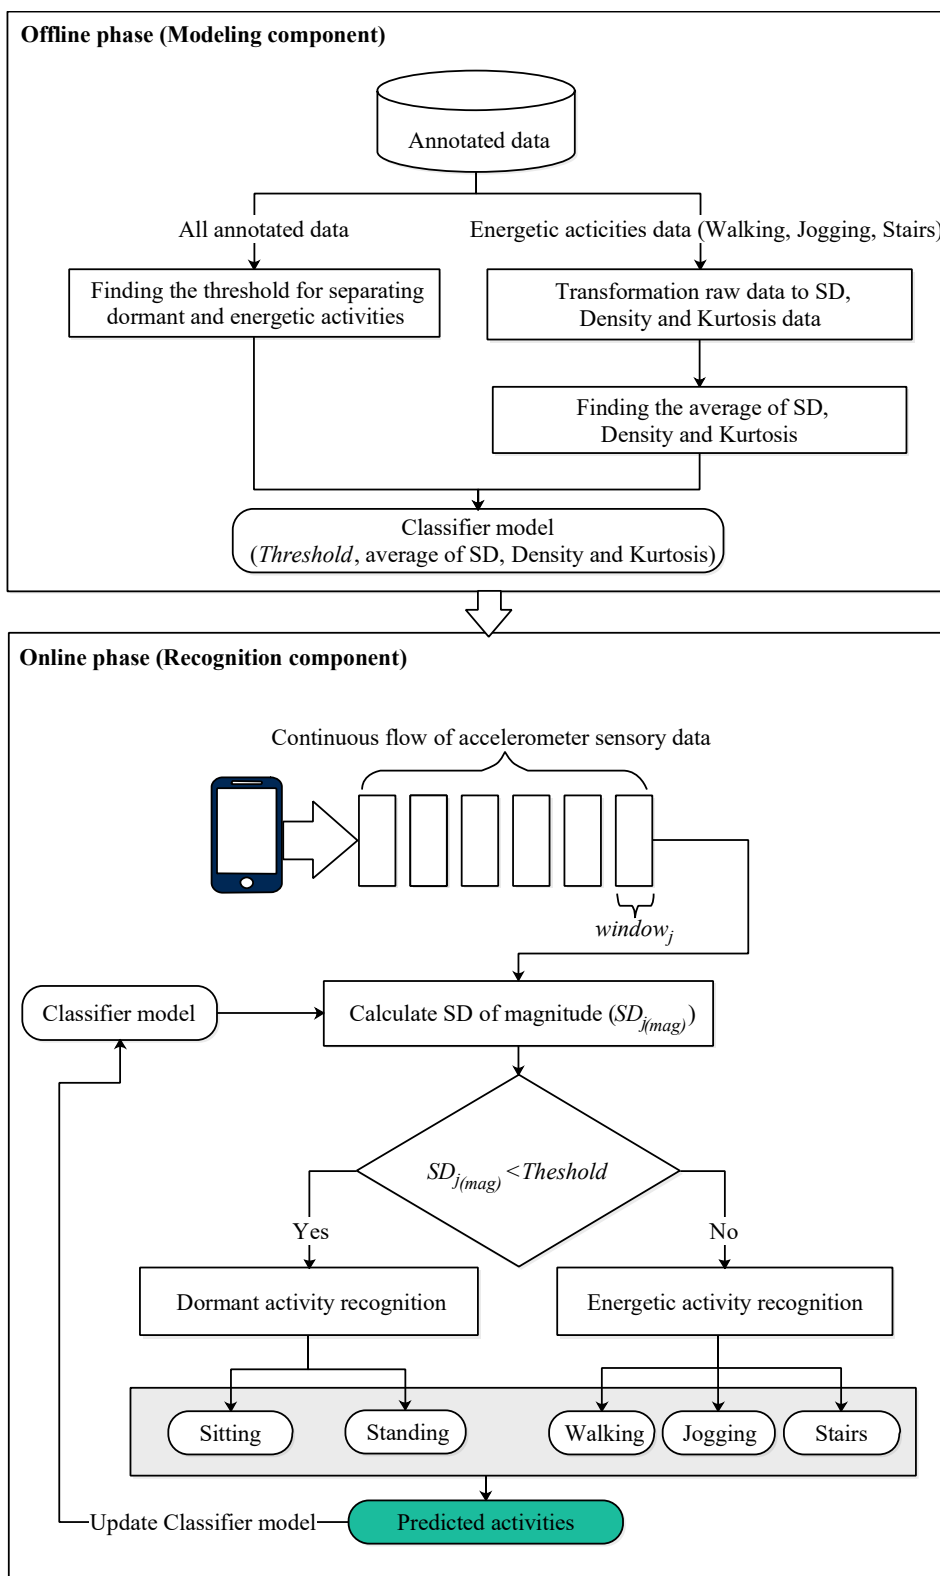
ของ Magnitude ข้อมูล เพื่อใช้เปรียบเทียบกับค่าขีดแบ่ง สำหรับจำแนกประเภทของกิจกรรม ถ้าเป็นกิจกรรมแบบนิ่งจะใช้วิธีการเปรียบเทียบระยะห่างระหว่างเส้นข้อมูล Accelerometer ตามแนวแกน X, Y และ Z ในการระบุว่าเป็นกิจกรรม การยืนหรือการนั่ง แต่ถ้าเป็นกิจกรรมแบบเคลื่อนไหว จะใช้วิธีการคำนวณค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล 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 และยังเหมาะสมสำหรับการรู้จำกิจกรรมที่ประมวลผลบนอุปกรณ์



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+)


จากงานวิจัยที่กล่าวมาข้างต้น ได้พัฒนาวิธีการรู้จำกิจกรรมจากอุปกรณ์สมาร์ตโฟนได้ถูกต้องแม่นยำเทียบเท่าอุปกรณ์ที่ติดตามตำแหน่งต่าง ๆ ของร่างกาย แต่เมื่อนำอุปกรณ์สมาร์ตโฟนนำมาใช้งานจริงต้องกำหนดตำแหน่งของอุปกรณ์บนร่างกายให้ชัดเจนตัวอย่างเช่น การใส่อุปกรณ์ในกระเป๋า กางเกง การแนบอุปกรณ์ไว้ที่เอว เป็นต้นหรือมีโอกาสนี้ผู้ใช้งานไม่ได้พกอุปกรณ์ไว้กับตัวหรือใส่กระเป๋าสาขายาวไว้ ทำให้ประสิทธิภาพในการรู้จำกิจกรรมที่ลักษณะการวางแนวของอุปกรณ์ที่เหมือนกันหรือกิจกรรมที่กำลังเคลื่อนไหวลดลง

แนวทางที่ 2

นาฬิกาอัจฉริยะ (Smartwatch) หรืออุปกรณ์ที่สวมใส่ข้อมือ (Wrist-worn) เป็นอุปกรณ์ที่กำลังได้รับความนิยมในปัจจุบัน เนื่องจากมีขนาดเล็กและสามารถสวมใส่ได้ตลอดเวลา รวมทั้งบนอุปกรณ์มีการฝังตัวรับรู้ ตัวอย่างงานวิจัยที่เน้นทดลองกับอุปกรณ์ชนิดนี้ได้แก่ Mortazavi และคณะ (2015) นำเสนอวิธีการรู้จำกิจกรรมที่เก็บข้อมูลกระแสเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope จากนาฬิกาอัจฉริยะโดยสวมใส่ไว้ที่ข้อมือด้านซ้าย โดยเน้นการทำกิจกรรมหนึ่งในอริยาบทต่าง ๆ เช่นการยืนใช้งานสมาร์ตโฟน การนั่งทำงานบนคอมพิวเตอร์ การนอนอ่านหนังสือ เป็นต้น Kwon และ Choi (2018) นำเสนอวิธีการรู้จำกิจกรรมที่เก็บกระแสข้อมูลเชิงเวลาของการทำกิจกรรมในสำนักงาน กิจกรรมในครัวและกิจกรรมนอกบ้านโดยให้ผู้ใช้สวมใส่นาฬิกาอัจฉริยะในข้อมือด้านที่ถนัด ซึ่งนำข้อมูลกระแสเชิงเวลาจาก Accelerometer และการระบุถึงตำแหน่งในการทำกิจกรรมของผู้ใช้งานช่วยเพิ่มความแม่นยำในการรู้จำกิจกรรม จากนั้นส่งกระแสข้อมูลเชิงเวลาไปยังเครื่องแม่ข่ายเพื่อสร้างตัวแบบรู้จำกิจกรรม

จากงานวิจัยที่กล่าวมาข้างต้น ในการเก็บกระแสข้อมูลเชิงเวลาในการทำกิจกรรมต่าง ๆ จากอุปกรณ์ลดความยุ่งยากและภาระต่อผู้ใช้ แต่งานวิจัยส่วนใหญ่เน้นการเก็บข้อมูลการทำกิจกรรมภายในห้องและใช้ภายในงานวิจัยเอง อีกทั้งยังข้อจำกัดดังต่อไปนี้


- มีลักษณะของกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer ของกิจกรรมขึ้นและลงบันได คล้ายกับกิจกรรมเดิน ซึ่งมีผลต่อความถูกต้องที่ลดลงในการจำแนกกิจกรรมของตัวแบบรู้จำกิจกรรม เมื่อนำข้อมูลของกิจกรรมเดิน ขึ้นบันไดและลงบันไดมาเป็นแผนภูมิกระจายดังภาพที่ 1-5 จะเห็นว่าข้อมูลทั้งสามกิจกรรมมีลักษณะข้อมูลที่ทับซ้อนกัน (Overlapping data)



ภาพที่ 1-5 แผนภูมิกระจายของข้อมูลกิจกรรมการเดิน การเดินขึ้นบันได และการลงบันได

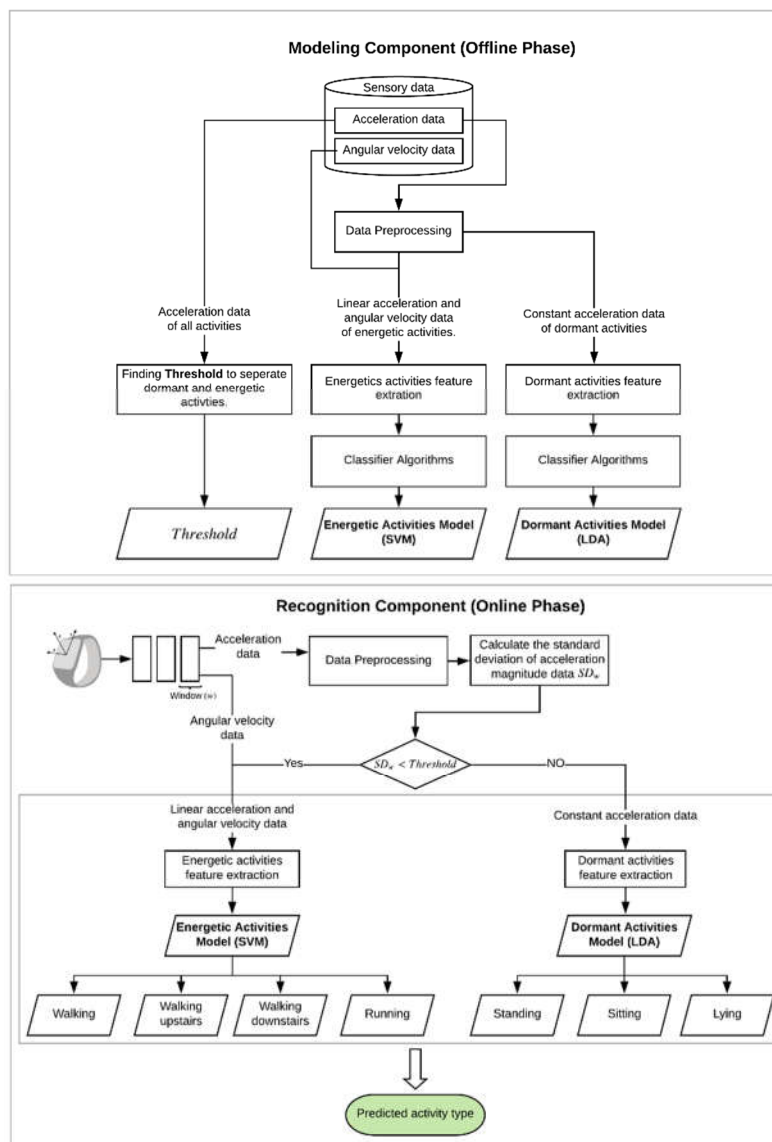
ทั้งนี้งานวิจัยที่ทำการทดลองกับอุปกรณ์ชนิดนี้ส่วนใหญ่เน้นกระแสรวมข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer เพียงหนึ่งตัวจึงทำให้ยังไม่สามารถแก้ปัญหาที่เกิดขึ้นได้ ดังนั้นในงานวิจัยนี้จึงมีแนวคิดจะนำกระแสรวมข้อมูลเชิงเวลาจากตัวรับรู้ Gyroscope อาจมีส่วนช่วยให้การจำแนกกิจกรรมเคลื่อนไหวได้แก่ การเดิน, การเดินขึ้นบันได, การเดินลงบันไดและการวิ่งให้มีความถูกต้องเพิ่มมากขึ้น

- กระแสรวมข้อมูลเชิงเวลาจากการทำกิจกรรมแบบอยู่กับที่หรือหยุดนิ่งเช่น การยืน, การนั่งและการนอนของผู้ใช้บางคนมีความแตกต่างจากผู้ใช้อื่นที่ถูกนำมาใช้สร้างตัวแบบรู้จำกิจกรรมดังภาพที่ 1-3 เป็นตัวอย่างของข้อมูลกิจกรรมนอนของผู้ใช้หมายเลข 3, 11 และ 13 จากภาพที่ 1-6 จะเห็นได้ว่าการกระจายตัวของข้อมูลในกิจกรรมเดียวกันของผู้ใช้ทั้งสามคนกระจายตัวแตกต่างกันเนื่องจากการวางแผนของอุปกรณ์นำพิกัดอัจฉริยะหรืออุปกรณ์สวมใส่ ซึ่งมีผลให้การรู้จำกิจกรรมมีความถูกต้องแม่นยำลดลง



ภาพที่ 1-6 แผนภูมิกระจายตัวอย่างข้อมูลกิจกรรมนอนที่แตกต่างกันของผู้ใช้หมายเลข 3, 11 และ 13

จากประเด็นปัญหาที่กล่าวมาข้างต้น งานวิจัยนี้จะนำเสนอวิธีการขั้นตอนวิธีการรู้จำกิจกรรมจากนาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ โดยนำเสนอวิธีการที่เรียกว่า “Smartwatch-based Physical Activity Recognition” หรือเรียกว่า “S-PAR” โดยวิธีการ S-PAR มีกรอบแนวคิดเป็นงานดังภาพที่ 1-7



ภาพที่ 1-7 กรอบแนวคิดวิธีการ “Smartwatch-based Physical Activity Recognition” หรือเรียกว่า “S-PAR”

1.3 วัตถุประสงค์ของโครงการวิจัย

1.3.1 เพื่อพัฒนาขั้นตอนวิธีใหม่ที่มีประสิทธิภาพและมีความถูกต้องโดยใช้กระแสข้อมูลจากตัวรับรู้บนอุปกรณ์เคลื่อนที่แบบพกพา (Smartphone) แบบ 1 ตัวรับรู้

1.3.2 เพื่อพัฒนาตัวแบบรับรู้กิจกรรม (Activity Recognition Model) โดยการใช้การเรียนรู้ที่ปรับตัวได้สำหรับกระแสข้อมูลเชิงเวลาที่สามารถประมวลผลบนอุปกรณ์เคลื่อนที่แบบพกพา

1.3.3 เพื่อพัฒนาขั้นตอนวิธีใหม่ที่มีประสิทธิภาพและมีความถูกต้องโดยใช้กระแสข้อมูลจากตัวรับรู้บนอุปกรณ์สวมใส่ (Wrist-worn) แบบ 1 ตัวรับรู้หรือมากกว่า

1.4 ขอบเขตของโครงการวิจัย

1.4.1 งานวิจัยนี้มุ่งเน้นที่จะศึกษาและพัฒนาขั้นตอนวิธีการเพื่อสร้างตัวแบบการรู้จำกิจกรรมของผู้ใช้อุปกรณ์เคลื่อนที่แบบพกพา โดยใช้กระแสข้อมูลจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน และจากตัวรับรู้ Accelerometer และ Gyroscope บนอุปกรณ์นาฬิกาอัจฉริยะ หรือลักษณะเป็นอุปกรณ์ที่สวมใส่ข้อมือ

1.4.2 งานวิจัยนี้มุ่งเน้นการรู้จำกิจกรรมในกลุ่มกิจกรรมทางกายภาพ ซึ่งเป็นกิจกรรมพื้นฐานของมนุษย์ ดังต่อไปนี้

- การเดิน (Walking)
- การยืน (Standing)
- การนั่ง (Sitting)
- การวิ่ง (Jogging)
- การขึ้น/ลงบันได (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

- 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

- ข้อมูล Pervasive System research datasets⁵ ที่มีชื่อว่า Complex human activities dataset จากงานวิจัย Shoab และคณะ (2016) เก็บข้อมูลโดยติดอุปกรณ์สมาร์ทโฟนที่ตำแหน่งข้อมือข้างขวา ประกอบไปด้วย เวลาที่บันทึกการทำกิจกรรม กิจกรรมที่ทดสอบ ค่า Accelerometer Sensor แนวแกน X, Y และ Z ค่า Linear Acceleration Sensor แนวแกน X, Y และ Z ค่า Gyroscope Sensor แนวแกน X, Y และ Z ค่า Magnetometer แนวแกน X, Y และ Z

³ <http://www.cis.fordham.edu/wisdm>

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

⁵ <https://www.utwente.nl/en/eemcs/ps/research/dataset/>

ทำการเก็บข้อมูลทำกิจกรรมของผู้ใช้ทั้งหมด 13 กิจกรรมซึ่งในงานวิจัยนี้เลือกกิจกรรมที่เป็นกิจกรรมทางกายทั้งหมด 6 กิจกรรมได้แก่ การยืน การนั่ง การเดิน การเดินขึ้นบันได การเดินลงบันได การวิ่งที่มีการเก็บข้อมูลจากผู้ใช้งานจำนวน 10 คน มีจำนวนตัวอย่างรวมกันทั้งหมด 540,000 ตัวอย่าง

- ข้อมูล RealworldHAR⁶ เก็บข้อมูลโดยใช้นาฬิกาอัจฉริยะที่ตำแหน่งข้อมือข้างขวา ประกอบไปด้วย เวลาที่บันทึกการทำกิจกรรม กิจกรรมที่ทดสอบ ค่า Accelerometer Sensor แนวแกน X, Y และ Z ค่า Gyroscope Sensor แนวแกน X, Y และ Z ค่า Magnetometer แนวแกน X, Y, และ Z ทำการเก็บข้อมูลทำกิจกรรมของผู้ใช้ทั้งหมด 7 กิจกรรมได้แก่ การยืน การนั่ง การนอน การเดิน การเดินขึ้นบันได การเดินลงบันได การวิ่ง โดยเลือกข้อมูลของผู้ใช้ 10 คนจาก 15 ที่ข้อมูลและครบทุกกิจกรรม มีจำนวนตัวอย่างรวมกันทั้งหมด 1,000,174 ตัวอย่าง

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 ได้ขั้นตอนวิธีใหม่ที่มีประสิทธิภาพมากกว่าวิธีการรู้จำกิจกรรมในงานวิจัยที่มีอยู่เดิมทั้งในด้านความถูกต้องและเวลาในการประมวลผล สำหรับข้อมูลนำเข้าจากอุปกรณ์สมาร์ทโฟน และอุปกรณ์สวมใส่ที่ข้อมือ แบบ 1 ตัวรับรู้ หรือมากกว่า 1 ตัว

1.5.2 ได้วิธีการสร้างตัวแบบรู้จำกิจกรรมที่สามารถปรับตัวให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้

1.5.3 ได้ตัวแบบรู้จำกิจกรรมที่มีประสิทธิภาพทั้งในด้านเวลาและความถูกต้องของการรู้จำกิจกรรม

1.6 แผนดำเนินโครงการวิจัย

ปี	กิจกรรม	ด.ค.	พ.ย.	ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.
2561	1. ศึกษาการทำงานของอุปกรณ์สวมใส่ที่ข้อมือ และศึกษาวิธีการรับส่งสัญญาณ วิธีการจัดเก็บและดึงข้อมูลตัวรับรู้ (Sensors) จากอุปกรณ์	X											
2561	2. ศึกษาทฤษฎีและงานวิจัยอื่น ๆ ที่เกี่ยวข้องเพิ่มเติมจากที่ศึกษามา	X											
2561	3. ทดสอบวิธีการการรับส่งสัญญาณ และการจัดเก็บข้อมูลจากอุปกรณ์จริง		X										
2561	4. เก็บรวบรวมข้อมูลเพื่อใช้สำหรับการทดลองในเบื้องต้น โดยรวบรวมข้อมูลที่มีอยู่แล้วจากฐานข้อมูลงานวิจัยที่เผยแพร่ให้ศึกษา		X										

⁶ <https://sensor.informatik.uni-mannheim.de/>

2561	5. ออกแบบขั้นตอนวิธี และสร้างตัวแบบสำหรับรู้จักกิจกรรม (activities) จากตัวข้อมูลกระแสตัวรับรู้ แบบ 1 ตัวรับรู้และมากกว่า และทดสอบเทียบผลความถูกต้องกับข้อมูลที่ได้จากฐานข้อมูลจากงานวิจัยที่เกี่ยวข้อง			X	X	X	X	X	X				
2561	6. ทำการทดลอง และเปรียบเทียบประสิทธิภาพด้านความถูกต้องในการรู้จักกิจกรรมกับวิธีการที่มีอยู่เดิม (STAR) สำหรับ 1 ตัวรับรู้				X	X	X	X	X				
2561	7. พัฒนาโปรแกรมสำหรับขั้นตอนวิธีที่ออกแบบในข้อ 6						X	X	X	X	X	X	
2561	8. ปรับปรุงวิธีการในข้อ 5 ให้มีประสิทธิภาพมากขึ้น												X
2562	8. ปรับปรุงวิธีการในข้อ 5 ให้มีประสิทธิภาพมากขึ้น	X	X	X									
2562	9. ทดสอบกับข้อมูลจริงที่ได้มาจากฐานข้อมูลสาธารณะ และปรับปรุงวิธีการ				X	X							
2562	10. สรุปผลงานวิจัยที่ดำเนินงานในช่วงปีที่ 2 และจัดทำบทความวิจัยเพื่อส่งตีพิมพ์ในงานประชุมวิชาการระดับนานาชาติ						X	X	X				
2562	11. จัดทำรายงานฉบับสมบูรณ์									X	X	X	

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้องที่นำมาใช้ในการพัฒนาขั้นตอนวิธีที่นำเสนอในงานวิจัยนี้ โดยจะแบ่งเป็นส่วนต่าง ๆ ดังนี้

2.1 ทฤษฎีที่เกี่ยวข้อง ประกอบด้วย

- 2.1.1 ตัวรับรู้ของอุปกรณ์สื่อสารเคลื่อนที่สมาร์ทโฟน
- 2.1.2 ตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ข้อมือ
- 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

งานงานวิจัยนี้มุ่งเน้นจะใช้กระแสข้อมูลจากตัวรับรู้ของอุปกรณ์สมาร์ทโฟน ซึ่งในการนำไปประยุกต์ใช้งานจะทำได้สะดวก เนื่องจากสมาร์ทโฟนเป็นที่นิยมอย่างแพร่หลายในปัจจุบัน โดยตัวรับรู้ที่เลือกใช้ในงานวิจัยนี้ คือ Accelerometer sensor ซึ่งมีรายละเอียดดังต่อไปนี้

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

นอกจากนี้ยังมีรับรู้อื่น ๆ ของอุปกรณ์สมาร์ทโฟนที่น่าสนใจและหลายตัวก็นำมาใช้ร่วมกับ Accelerometer sensor ในการรู้จำกิจกรรม ซึ่งมีรายละเอียดและการใช้งานดังตารางที่ 2-1



ภาพที่ 2-1 ตัวรับรู้ชนิด Accelerometer sensor⁶

ตารางที่ 2-1 ชนิดตัวรับรู้ของอุปกรณ์เคลื่อนที่แบบพกพา และรายละเอียดการใช้งาน⁷

ตัวรับรู้	รายละเอียด
Gyroscope sensor	ตัวรับรู้ที่สามารถตรวจจับการหมุนของอุปกรณ์สมาร์ทโฟน โดยเป็นการตรวจจับ 3 แกน (3-Axes) เช่นเดียวกับกับ Accelerometer sensor แต่จะมีความถูกต้องและแม่นยำมากกว่า เช่นการควบคุมการเล่นเกมนต่างๆ 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
Gesture sensor	ตัวรับรู้สำหรับการตรวจจับลักษณะการเคลื่อนไหวของฝ่ามือ หรือลักษณะท่าทางของผู้ใช้งาน โดยเป็นการตรวจจับด้วยลำแสงอินฟราเรด (Infrared rays) ดังนั้นก็จะทำให้เครื่องสามารถทำงานตามการแสดงท่าทางของผู้ใช้งานได้ เช่น ในสมาร์ทโฟนบางรุ่นที่มี Gesture sensor หากผู้ใช้งาน

⁶ <http://curiously.com>

⁷ <https://www.thaimobilecenter.com>

ตารางที่ 2-1 ชนิดตัวรับรู้ของอุปกรณ์เคลื่อนที่แบบพกพา และรายละเอียดการใช้งาน (ต่อ)


ตัวรับรู้	รายละเอียด
	โบกฝ่ามือไปทางซ้าย ก็อาจจะเป็นการสั่งให้เลื่อนไปดูรูปภาพถัดไปใน แกลเลอรี โดยที่ผู้ใช้งานไม่ต้องสัมผัสที่หน้าจอเลยแม้แต่น้อย
Proximity sensor	ตัวรับรู้สำหรับการตรวจจับระยะห่างระหว่างผู้ใช้กับตัวเครื่องสมาร์ทโฟน เพื่อการตอบสนองที่ถูกต้องเหมาะสม เช่น ในขณะที่ผู้ใช้งานกำลังสนทนา จะช่วยให้สามารถตรวจสอบได้ว่าขณะนั้นผู้ใช้งานมีการแนบหูไว้ติดกับ ตัวเครื่อง หรือเอาใบหน้ามาแนบกับตัวเครื่องหรือไม่ ซึ่งหากตรวจพบ ระบบก็จะทำการปิดหน้าจอแสดงผลโดยอัตโนมัติ เพื่อไม่ให้ใบหน้าหรือ ใบหูของผู้ใช้งานไปสัมผัสโดนฟังกซ์ชันบางอย่างที่อยู่บนหน้าจอแบบไม่ตั้งใจ
Geomagnetic sensor (Digital Compass)	ตัวรับรู้ที่ใช้สำหรับตรวจจับคลื่นแม่เหล็กไฟฟ้า หรือที่เรียกว่าเข็มทิศดิจิทัล (Digital compass) โดยจะเป็นการตรวจจับแบบ 3 แกน (3-Axes) ซึ่งจะมี ประโยชน์มากสำหรับการใช้งานแอปพลิเคชันแผนที่ หรือระบบนำทางต่าง ๆ รวมถึงแอปพลิเคชันประเภท AR Applications (Augmented Reality) ซึ่งต้องอาศัยข้อมูลทิศทางที่ถูกต้องแม่นยำ
Barometer sensor	ตัวรับรู้ที่ใช้สำหรับการตรวจวัดความกดอากาศ สามารถให้ข้อมูลความสูง จากระดับน้ำทะเลได้ ซึ่งนับว่าเป็นข้อมูลที่มีประโยชน์มากสำหรับบาง แอปพลิเคชัน โดยเฉพาะแอปพลิเคชันสำหรับการออกกำลังกายต่าง ๆ เช่น ในการออกกำลังกายด้วยการวิ่ง การเดิน หรือการปั่นจักรยาน หากทำใน ระดับความสูงที่ต่างกัน ก็จะมีอัตราการเผาผลาญแคลอรีที่ต่างกันไปด้วย นั้นเอง
Finger Scanner sensor	มีเฉพาะสมาร์ทโฟนบางรุ่น บางรุ่นเรียก Touch sensor เป็นตัวรับรู้ที่ใช้ สำหรับตรวจจับความถูกต้องของลายนิ้วมือผู้ใช้งาน ใช้ร่วมกับระบบรักษา ความปลอดภัยของตัวเครื่อง หรือแอปพลิเคชันที่ต้องการความปลอดภัยสูง เช่น การทำธุรกรรมทางการเงินต่าง ๆ
Temperature sensor	ตัวรับรู้สำหรับการตรวจวัดอุณหภูมิ ซึ่งสามารถนำไปใช้ประโยชน์กับ แอปพลิเคชันได้หลายประเภท เช่น หากเราไปเดินอยู่ท่ามกลางทะเลทราย อันร้อนระอุแต่ไม่มีสัญญาณอินเทอร์เน็ต ก็ยังสามารถรู้ได้ว่าบริเวณนั้นมี อุณหภูมิที่สูงมากขนาดไหน
Humidity sensor	ตัวรับรู้ที่ใช้สำหรับการตรวจวัดค่าความชื้นสัมพัทธ์ หรืออัตราส่วนระหว่าง ปริมาณความชื้น (ไอน้ำ) ที่มีอยู่จริงในอากาศ กับปริมาณความชื้นที่อากาศ ขณะนั้นจะรองรับได้เต็มที่ในอุณหภูมิเดียวกัน ซึ่งเป็นข้อมูลที่มีประโยชน์ โดยเฉพาะผู้ที่ออกกำลังกายอยู่เป็นประจำ เช่น หากต้องออกกำลังกายใน สภาพอากาศที่มีความชื้นสูง การระเหยของเหงื่อก็จะทำได้ไม่เต็มที่ อีกทั้ง ร่างกายก็ต้องมีการขับเหงื่อออกมามากขึ้นด้วย ส่งผลให้ร่างกายหรือหัวใจ ต้องทำงานหนักกว่าปกติ

2.1.2 ตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ข้อมือ

กระแสข้อมูลจากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ที่ข้อมือที่ใช้ในงานวิจัยนี้ คือ Accelerometer และ Gyroscope ซึ่งมีรายละเอียดดังต่อไปนี้

- Accelerometer sensor เป็นตัวรับรู้ที่สามารถตรวจจับความเร่งในการเคลื่อนที่และความเอียงของอุปกรณ์ได้ หลักการทำงานคือวัดความเร่งที่เกิดขึ้นตามแนวแกนประกอบไปด้วยแกน X, แกน Y และแกน Z มีลักษณะดังภาพที่ 2-2 ซึ่งความเร่งที่เกิดขึ้นประกอบไปด้วยแรงสองส่วน คือ ความเร่งที่เกิดจากการกระทำของผู้ใช้ต่ออุปกรณ์ที่เรียกว่า ความเร่งเชิงเส้น (Linear acceleration) และความเร่งที่เกิดจากแรงโน้มถ่วงของโลก (Gravity component) ที่กระทำต่อตัวรับรู้โดยจะมีค่าเท่ากับ 9.8 m/s^2 ซึ่งต้องกำหนดจำนวนจุดข้อมูลที่จะบอกตำแหน่งความเร่งที่เกิดขึ้นในแต่ละวินาทีที่เรียกว่าอัตราการสุ่ม (Sampling rate)

- Gyroscope sensor เป็นตัวรับรู้ที่สามารถตรวจจับความเร็วเชิงมุมของการหมุนรอบแกนของอุปกรณ์ มีลักษณะการตรวจจับตามแนวแกนเช่นเดียวกับ Accelerometer



ภาพที่ 2-2 ลักษณะแกนของตัวรับรู้ชนิด Accelerometer และ Gyroscope


ตารางที่ 2-2 ชนิดตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือและรายละเอียดการใช้งาน

ตัวรับรู้	รายละเอียด
Magnetometer	ตัวรับรู้ที่ตรวจจับคลื่นแม่เหล็กไฟฟ้า ที่เรียกว่าเข็มทิศดิจิทัล (Digital compass) โดยจะเป็นการตรวจจับแบบ 3 แกน (3-Axes) ใช้บอกตำแหน่งของขั้วแม่เหล็กโลก สามารถนำตัวรับรู้ชนิดนี้มาใช้งานร่วมกับตัวรับรู้อื่น ๆ เพื่อเพิ่มความแม่นยำในการติดตามเคลื่อนไหว
Barometric pressure sensor	ตัวรับรู้ที่ตรวจจับความกดอากาศและให้ข้อมูลความสูงจากระดับน้ำทะเล ซึ่งพบตัวรับรู้จะพบตัวรับรู้ในนาฬิกาอัจฉริยะบางรุ่นหรือบางยี่ห้อเท่านั้น
Heart rate sensor	ตัวรับรู้ที่ตรวจจับวัดอัตราการเต้นของหัวใจ โดยหลักการทำงานนั้น ที่ด้านหลังของนาฬิกาอัจฉริยะจะมีหลอดไฟ LED สีเขียวที่ยิงลำแสงไปที่ผิวหนังของผู้ใช้งาน เพื่อตรวจจับจังหวะการเปลี่ยนแปลงสีของกระแสเลือด ในจังหวะที่มีความเข้ม-จางหรือสีแดงมาก-น้อยสลับกัน ตามจังหวะการเต้นของหัวใจ ช่วยให้ทราบถึงการทำงานของหัวใจก่อนและหลังการออกกำลังกาย

2.1.3 ทฤษฎีการรู้จำ

การรู้จำรูปแบบ (Pattern recognition) เป็นศาสตร์ทางวิทยาการคอมพิวเตอร์แขนงหนึ่งที่มีจุดประสงค์เพื่อจำแนกหรือระบุประเภทข้อมูล โดยกระบวนการจะมีการสร้างตัวแบบรู้จำสำหรับจัดการข้อมูลให้อยู่ในกลุ่มที่กำหนดมาให้ การสร้างตัวแบบรู้จำสามารถทำได้โดยใช้ 2 วิธีการที่สำคัญ ได้แก่ ขั้นตอนวิธีการแบ่งกลุ่ม และขั้นตอนการจำแนกประเภท

- 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 2-3 การแบ่งกลุ่มแบบเคมีนส์ (K-mean clustering) การแบ่งกลุ่มแบบสเปคทริล (Spectral clustering) การแบ่งกลุ่มแบบ DBSCAN การแบ่งกลุ่ม Gaussian Mixture Model เป็นต้น ซึ่งการแบ่งกลุ่มแต่ละวิธีจะเหมาะสมกับข้อมูลแต่ละแบบแตกต่างกันไป



ภาพที่ 2-3 วิธีการแบ่งกลุ่มข้อมูลแบบ K-mean, Spectral Clustering, DBSCAN และ Gaussian Mixture⁸

ในงานวิจัยนี้จะขออธิบายวิธีการแบ่งกลุ่มข้อมูลแบบ 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

⁸ <http://scikit-learn.org/stable/modules/clustering.html>

streams (Abdallah และคณะ, 2015) โดยจะใช้วิธีการประมาณการค่ามากที่สุดด้วยเทคนิควิธีทางคณิตศาสตร์ที่เรียกว่า Expectation Maximization (EM) วิธีดังกล่าวเป็นกระบวนการทำซ้ำ (Recursive) แบ่งเป็นสองขั้นตอน 1) ขั้นตอนการประมาณการ (คาดคะเน) ซึ่งเป็นขั้นตอนของการคาดคะเนค่าขั้นต้นก่อน 2) ขั้นตอนการปรับปรุงค่า แล้วส่งกลับไปให้ขั้นตอนที่หนึ่งทำงาน กระบวนการทั้งหมดจะหยุดก็ต่อเมื่อค่าความน่าจะเป็นของขั้นตอนในรอบที่ผ่านมาในรอบปัจจุบันมีค่าใกล้เคียงกันมาก ๆ โดยการประมาณค่าในงานวิจัยนี้ก็คือความน่าจะเป็นของข้อมูลกิจกรรม 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)

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

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

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

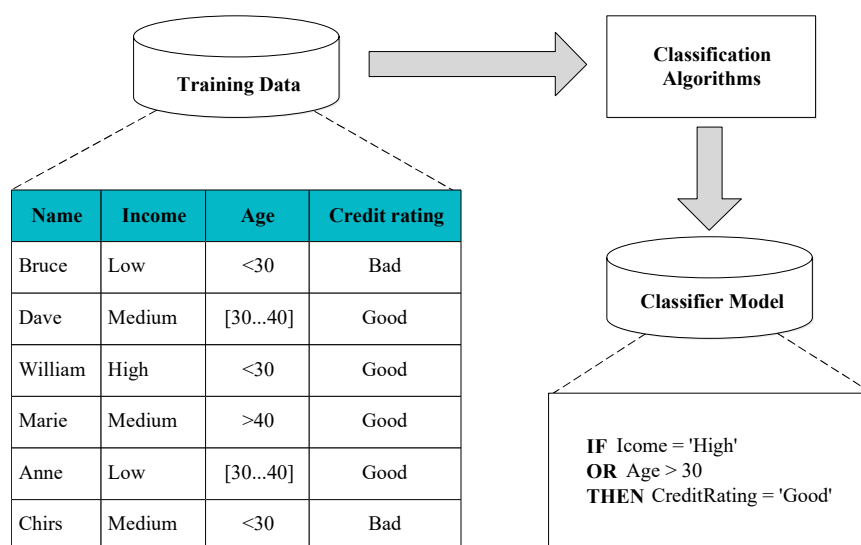
โดยที่	x_n	คือ ค่าข้อมูล ($n = 1, 2, 3, \dots, N$)
	μ_k	คือ ค่าเฉลี่ยของข้อมูล ($k = 1, 2, 3, \dots, K$)
	σ_k	คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูล ($k = 1, 2, 3, \dots, K$)
	p_k	คือ ค่าถ่วงน้ำหนัก ($k = 1, 2, 3, \dots, K$)

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

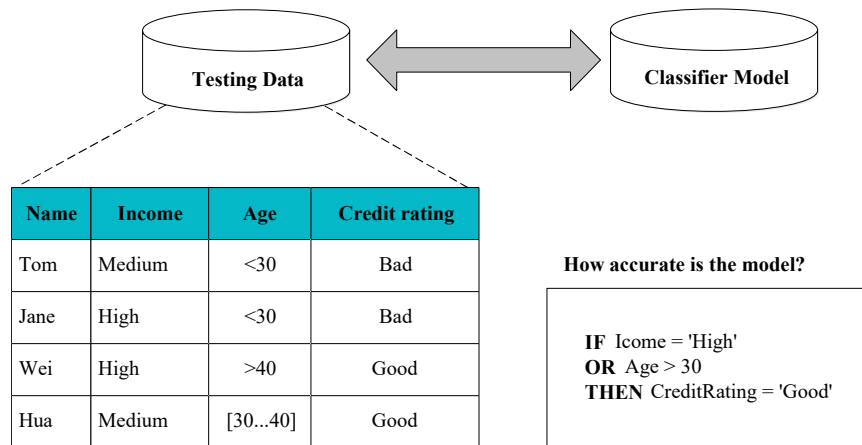
กระบวนการทั้งหมดจะหยุดทำเมื่อค่าความน่าจะเป็นของรอบปัจจุบันมีค่าใกล้เคียงกับค่าความน่าจะเป็นในรอบที่ผ่านมา มาก ๆ

- ขั้นตอนวิธีการจำแนกประเภท ใช้สำหรับจำแนกหรือระบุประเภทของข้อมูล โดยนำข้อมูลส่วนหนึ่งที่ทราบประเภทมาสอนระบบเพื่อให้เรียนรู้รูปแบบที่เกิดขึ้นในข้อมูล เรียกข้อมูลส่วนนี้ว่าข้อมูลสอน (Training data) แล้วจึงสร้างเป็นตัวแบบการรู้จำ (Classifier model) ดังภาพที่ 2-4 ส่วนข้อมูลที่เหลือจากข้อมูลสอนระบบจะนำมาเป็นข้อมูลที่ใช้ทดสอบ (Testing data) ซึ่งกลุ่มที่แท้จริงของข้อมูลที่ใช้ทดสอบนี้จะถูกนำมาเปรียบเทียบกับกลุ่มที่หาได้จากตัวแบบเพื่อทดสอบความถูกต้อง และปรับปรุงตัวแบบจนกว่าจะได้ค่าความถูกต้องเป็นที่น่าพอใจ ดังภาพที่ 2-5 ในส่วนการใช้งานจริงนั้น เมื่อมีข้อมูลเข้ามาก็จะนำข้อมูลนี้ไปผ่านตัวแบบ โดยตัวแบบจะทำนายหรือบอกประเภทของข้อมูลได้ว่าเป็นประเภทใด ดังภาพที่ 2-6 ซึ่งขั้นตอนวิธีการจำแนกประเภทเป็นกระบวนการเรียนรู้ข้อมูลที่กำหนดประเภทของข้อมูลเอาไว้ก่อน จึงถือว่าขั้นตอนวิธีการจำแนกประเภทข้อมูลเป็นการเรียนรู้แบบมีผู้สอน (Supervised learning)

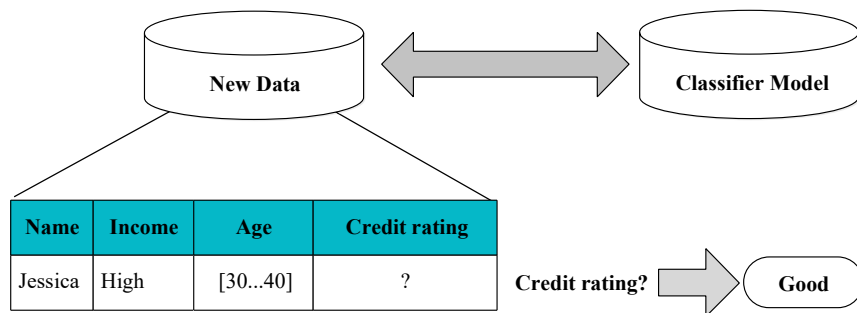
วิธีการสร้างตัวแบบสำหรับจำแนกประเภทข้อมูลที่นิยม ได้แก่ ต้นไม้ตัดสินใจ (Decision tree) โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ (Back propagation neural networks) และซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) เป็นต้น



ภาพที่ 2-4 ขั้นตอนการเรียนรู้เพื่อสร้างตัวแบบรู้จำ



ภาพที่ 2-5 ขั้นตอนการทดสอบตัวแบบ



ภาพที่ 2-6 ขั้นตอนการนำตัวแบบไปใช้งานจริง

2.1.4 การคำนวณทางสถิติสำหรับวิเคราะห์ข้อมูล

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

- ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation)⁹ คือการคำนวณค่าทางสถิติที่ใช้ในการวัดการกระจายของข้อมูล สามารถหาได้จากสมการที่ (2.6)

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

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

⁹ https://en.wikipedia.org/wiki/Standard_deviation

N คือ จำนวนของข้อมูล

• ความหนาแน่น (Density)¹⁰ คือ ปริมาณของมวลสารที่มีอยู่ในวัตถุใดวัตถุหนึ่ง หาได้จากอัตราส่วนของมวลต่อปริมาตรของวัตถุนั้น ๆ นอกจากนี้ในทางสถิติสามารถหาความหนาแน่นของประชากร โดยคำนวณจากอัตราส่วนของจำนวนประชากรต่อพื้นที่ ซึ่งในงานวิจัยนี้ได้นำวิธีการหาความหนาแน่นมาใช้พิจารณาข้อมูล โดยกำหนดการอ้างอิงตัวแปรให้เหมาะกับข้อมูลที่พิจารณาดังสมการที่ (2.7)

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

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

• ความโด่ง (Kurtosis)¹¹ คือ ระดับความสูงโด่งของการแจกแจงของข้อมูล โดยพิจารณาจากโค้งความถี่ ว่ามีความโด่งมากน้อยเพียงใด ความโด่งของโค้งความถี่แบ่งได้เป็น 3 ระดับ ได้แก่ โค้งความถี่ที่มีการแจกแจงที่โด่งปกติ โด่งมากและโด่งน้อย โดยจะเป็นการคำนวณหาค่าสัมประสิทธิ์ความโด่ง ซึ่งมีวิธีการคำนวณดังสมการที่ (2.8)

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

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

เมื่อคำนวณได้ค่าสัมประสิทธิ์ความโด่งแล้ว ก็พิจารณาความโด่งของโค้งความถี่ ดังนี้
 ถ้าสัมประสิทธิ์ความโด่ง = 0.263 โค้งความถี่ที่มีการแจกแจงที่โด่งปกติ
 สัมประสิทธิ์ความโด่ง > 0.263 โค้งความถี่ที่มีการแจกแจงที่โด่งมาก
 สัมประสิทธิ์ความโด่ง < 0.263 โค้งความถี่ที่มีการแจกแจงที่โด่งน้อย

¹⁰ <https://en.wikipedia.org/wiki/Density>

¹¹ <https://en.wikipedia.org/wiki/Kurtosis>

2.1.5 การรู้จำกิจกรรม (Activity Recognition)

การรู้จำกิจกรรมในงานวิจัยนี้มุ่งเน้นการรู้จำกิจกรรมโดยใช้ข้อมูลจากตัวรับรู้ของอุปกรณ์สื่อสารเคลื่อนที่สมาร์ทโฟน จึงได้ศึกษางานวิจัยของ Shoaib และคณะ (2015) ที่ทำการสำรวจงานวิจัยที่เกี่ยวข้องกับการกับสร้างตัวแบบรู้จำกิจกรรม ได้อธิบายถึงกระบวนการรู้จำกิจกรรมซึ่งประกอบไปด้วย 4 ขั้นตอนดังภาพที่ 2-6

1) ขั้นตอน Sensing เป็นขั้นตอนการเก็บข้อมูลจากตัวรับรู้ด้วยอัตราสุ่มตัวอย่างที่กำหนดไว้

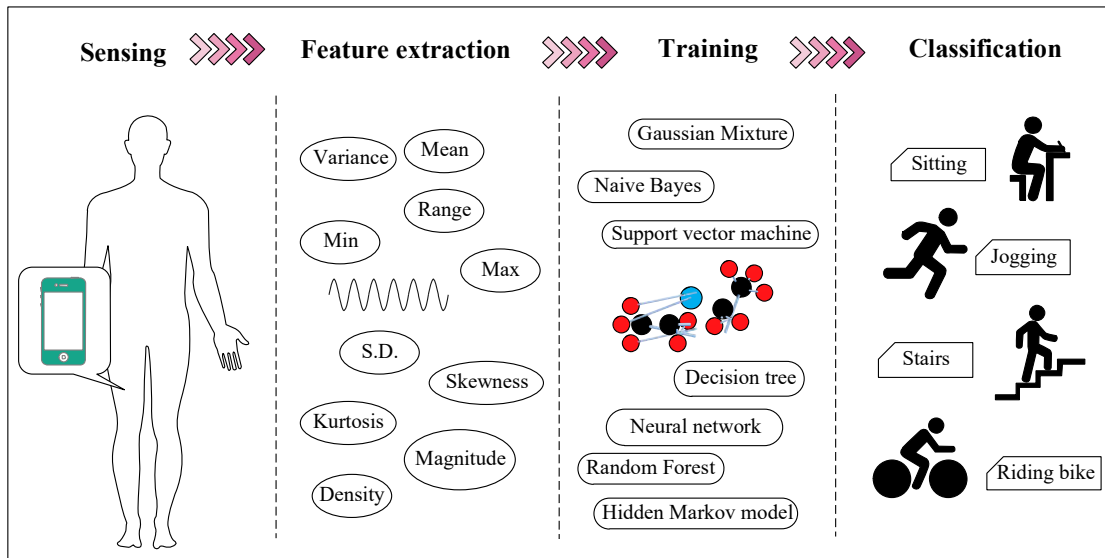
2) ขั้นตอน Feature extraction เป็นขั้นตอนการสกัดคุณลักษณะที่สำคัญของข้อมูลที่จะนำไปใช้ในการสร้างตัวแบบรู้จำกิจกรรม

3) ขั้นตอน Training เป็นขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (Classifier model) สำหรับใช้ในการจำแนกประเภทกิจกรรม ซึ่งต้องนำข้อมูลส่วนหนึ่งมาสอนให้ตัวแบบเกิดการเรียนรู้ที่สามารถจำแนกประเภทของกิจกรรมได้ การเรียนรู้สามารถแยกได้เป็น 2 วิธีการ คือ การเรียนรู้แบบออนไลน์ (Online learning) และการเรียนรู้แบบออฟไลน์ (Offline learning)

การเรียนรู้ออนไลน์จะนำข้อมูลเข้ามาทีละ 1 ตัวอย่าง เพื่อสอนให้ตัวแบบเกิดการเรียนรู้ หากตัวแบบเกิดการเรียนรู้ผิดพลาด ตัวแบบก็就会被ปรับปรุงทันที แล้วจึงนำข้อมูลตัวอย่างถัดไปมาสอนตัวแบบ ทำเช่นนี้จนกระทั่งได้ค่าความถูกต้องเป็นที่น่าพอใจ

การเรียนรู้แบบออฟไลน์จะตรงกันข้ามกับการเรียนรู้แบบออฟไลน์ กล่าวคือข้อมูลสอนจะถูกนำเข้ามาสอนตัวแบบทีละตัวอย่าง หากตัวแบบเกิดการเรียนรู้ผิดพลาด ก็จะเก็บข้อผิดพลาดนี้ไว้ก่อน จนกระทั่งข้อมูลทั้งหมดถูกนำเข้ามาสอนตัวแบบครบทุกตัวอย่างแล้วจึงปรับปรุงตัวแบบ ทำเช่นนี้จนกว่าจะได้ค่าความถูกต้องเป็นที่น่าพอใจ

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



ภาพที่ 2-7 ขั้นตอนการรู้จำกิจกรรม¹²

2.2 งานวิจัยที่เกี่ยวข้อง

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

¹² <https://becominghuman.ai>

ตารางที่ 2-3 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
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
Stewart และคณะ (2012)	Accelerometer	50	Walking, Jogging, Still	SMV	Offline
Kose และคณะ (2012)	Accelerometer	10, 20, 100	Walking, Standing, Sitting, Running	Naïve Bayes + KNN clustered	Offline
Das และคณะ (2010)	Accelerometer	125	Walking, Running, Upstairs, Downstairs Jumping, Phone on table/detached	KNN classifier	Offline
Thiemjarus (2013)	Accelerometer	50	Walking, Standing, Sitting, Running, Jumping, Laying	KNN	Offline
Siirtola (2012)	Accelerometer	40	Walking, Standing, Sitting, Running, Biking, Driving a car	NKK, QDA	Offline
Gomes และคณะ (2012)	Accelerometer	ไม่ได้ระบุ	Walking, Standing, Sitting, Running	Naïve Bayes	Online
Das และคณะ (2012)	Accelerometer	20	Walking, Standing, Sitting, Running, Upstairs	Naïve Bayes	Offline
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 2-3 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

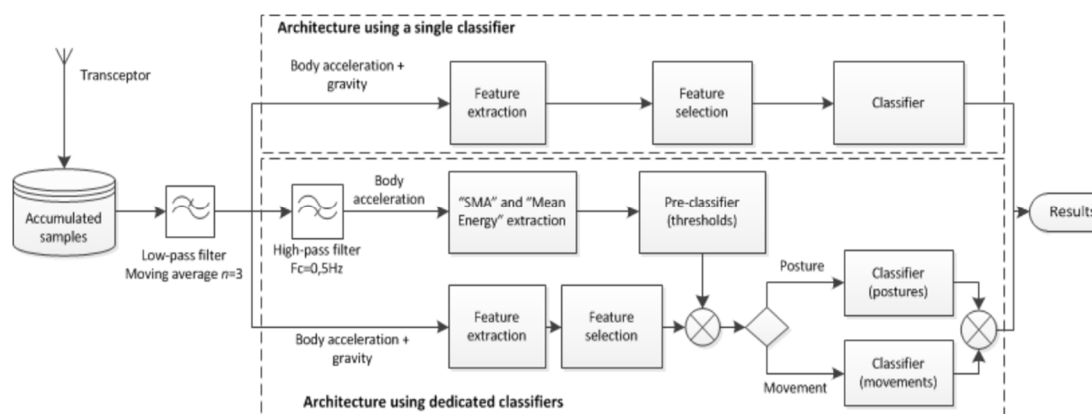
วิธีการสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการเรียนรู้แบบออนไลน์สามารถปรับปรุงตัวแบบรู้จำกิจกรรมได้ทันทีจากข้อมูลที่เข้ามาใหม่ จึงเหมาะสมในการนำไปใช้งานจริงกับข้อมูลที่ได้จากตัวรับรู้ของอุปกรณ์สมาร์ตโฟนที่มีลักษณะเป็นกระแสข้อมูลเชิงเวลา ซึ่งในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมจะต้องนำข้อมูลการทำกิจกรรมของผู้ใช้มาสอนตัวแบบรู้จำกิจกรรม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

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

งานวิจัยที่เกี่ยวข้องเกี่ยวกับงานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ

Saisukul, Atkins และ Yu (2011) ได้ทำการทดลองเก็บข้อมูลการทำกิจกรรม 5 กิจกรรม ได้แก่ การนั่ง การยืน การนอน การเดิน การวิ่ง จากตัวรับรู้ Accelerometer ของนาฬิกาอัจฉริยะ นำข้อมูลมาสกัดคุณลักษณะที่สำคัญของแต่ละกิจกรรมโดยใช้วิธีการคำนวณทางสถิติทางเวลา (Time Domain) และการคำนวณทางความถี่ (Frequency Domain) และสร้างตัวแบบรู้จำกิจกรรมโดยขั้นตอนรู้จำกิจกรรมได้แก่ Decision Tree และ Artificial Neural Network (ANN)

Da Silva และ Galeazzo (2013) ได้นำเสนอระบบการรู้กิจกรรมโดยสร้างตัวแบบรู้จำกิจกรรมในการแยกประเภทของกิจกรรมและตามประเภทกิจกรรมทั้งหมดสามตัวแบบรู้จำกิจกรรมซึ่งได้แบ่งประเภทของกิจกรรมเป็น 2 ประเภทได้แก่ กิจกรรมนิ่ง (Posture) และกิจกรรมเคลื่อนไหว (Movement) ซึ่งเก็บข้อมูลการทำกิจกรรมจำนวน 8 กิจกรรมได้แก่ การนอน, การนั่ง, การยืน, การทำงานบนคอมพิวเตอร์, การเดิน, การเดินขึ้นบันได, การเดินลงบันได, การวิ่ง จากตัวรับรู้ Accelerometer ของนาฬิกาอัจฉริยะและสร้างตัวแบบรู้จำกิจกรรมโดยวิธีการเรียนรู้แบบมีผู้สอน ได้แก่ Support Vector machine (SVM), Artificial Neural Networks (ANN) และ The Multilayer Perceptron (MLP) ที่นำมาเปรียบเทียบในการรู้จำกิจกรรมที่ใช้ตัวแบบรู้จำกิจกรรมหนึ่งตัวดังภาพที่ 2-8



ภาพที่ 2-8 กรอบแนวคิดงานวิจัยของ Silva และ Galeazzo (2013)

Mortazavi และคณะ (2015) ได้ตั้งคำถามการทดลองที่ว่านาฬิกาอัจฉริยะมีความสามารถในการรู้จำกิจกรรมนิ่งได้อย่างถูกต้องเทียบเท่ากับอุปกรณ์สมาร์ตโฟนได้หรือไม่ ซึ่งทดลองเก็บข้อมูลจากตัวรับรู้ Accelerometer และ Gyroscope ที่เน้นเก็บการเปลี่ยนกิจกรรมและการทำกิจกรรมที่นิ่งๆ ในอริยาบถต่าง ๆ เช่นการยืนใช้งานสมาร์ตโฟน การนั่งทำงานบนคอมพิวเตอร์ การนอนอ่านหนังสือ เป็นต้น และสร้างเป็นแบบรู้จำกิจกรรมโดยวิธี Support Vector Machine (SVM-PUK) บนซอฟต์แวร์ Weka ซึ่งผู้วิจัยได้สรุปผลการทดลองได้ว่านาฬิกาอัจฉริยะสามารถรู้จำกิจกรรมนิ่งได้เทียบเท่าสมาร์ตโฟน

Sun และคณะ (2017) ได้นำเสนอระบบที่มีชื่อว่า “ActDetector” ที่ถูกแบ่งออกเป็นสองส่วนได้แก่ ส่วนที่ทำหน้าที่ระบุว่าตำแหน่งนาฬิกาอัจฉริยะอยู่ที่ข้อมือข้างซ้ายหรือขวาและส่วนรู้จำกิจกรรม ซึ่งเก็บข้อมูลกิจกรรมได้แก่ การนั่ง, การเดิน, การเดินขึ้นบันได, การเดินลงบันได, การกิน, การขับยานพาหนะ และการนั่งบนยานพาหนะจากตัวรับรู้ Accelerometer และ Gyroscope จากนาฬิกาอัจฉริยะ ซึ่งการทำงานในส่วนของระบุตำแหน่งของนาฬิกาจะดูจากค่าในแกน X ของ

Accelerometer เป็นหลักและส่วนรู้จำกิจกรรมจะแบ่งประเภทของกิจกรรมโดยกำหนดค่าคงที่ (Threshold) และสร้างตัวแบบรู้จำกิจกรรมด้วยโดยวิธี Support Vector Machine (SVM)

Shahmohammadi, Hosseini, King และ Sarrafzadeh (2017) ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model) โดยใช้วิธีการ Active Learning เพื่อให้ผู้ใช้บอกกิจกรรมในขณะที่กำลังสร้างตัวแบบรู้จำกิจกรรมก่อนที่จะรู้จำกิจกรรม ซึ่งเก็บข้อมูลกิจกรรมได้แก่ การเดิน การนั่ง การยืน การวิ่งและการนอนจากตัวรับรู้ Accelerometer และ Gyroscope จากนาฬิกาอัจฉริยะเทียบกับประสิทธิภาพกับตัวขั้นตอนวิธีการเรียนรู้แบบมีผู้สอนต่าง ๆ

Kwon และ Choi (2018) ได้นำเสนอระบบรู้จำกิจกรรมที่ส่งกระแสข้อมูลเชิงเวลาจากนาฬิกาอัจฉริยะผ่านสมาร์ทโฟนไปยังเครื่องแม่ข่าย (Server) เพื่อสร้างตัวแบบรู้จำกิจกรรม ซึ่งเก็บข้อมูลกิจกรรมโดยแยกเป็นแต่ละประเภทได้แก่ กิจกรรมในสำนักงาน, กิจกรรมในห้องครัวและกิจกรรมนอกบ้าน จากตัวรับรู้ Accelerometer และให้ผู้ใช้บอกถึงตำแหน่งการทำกิจกรรมที่เวลาใช้งานจริงสามารถตรวจจับได้จากตัวรับรู้ GPS โดยสร้างเป็นแบบรู้จำกิจกรรมโดยผ่านวิธีการเรียนรู้ Artificial Neural Network (ANN)

ตารางที่ 2-4 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ

งานวิจัย	ตัวรับรู้	อัตราสุ่มตัวอย่าง (Hz)	กิจกรรมที่สามารถรู้จำได้	วิธีการที่ใช้สร้างตัวแบบรู้จำกิจกรรม
Saisakul, Atkins และ Yu (2011)	Accelerometer	33	Sitting, Standing, Lying, Walking, Running	Decision Tree, Artificial Neural Network (ANN)
Silva และ Galeazzo (2013)	Accelerometer	33	Lying, Sitting, Standing, Walking, Running, Walking upstairs, Walking downstairs, Working on computer	SVM

ตารางที่ 2-4 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ (ต่อ)

งานวิจัย	ตัวรับรู้	อัตราสุ่มตัวอย่าง (Hz)	กิจกรรมที่สามารถรู้จำได้	วิธีการที่ใช้สร้างตัวแบบรู้จำกิจกรรม
Mortazavi และคณะ (2015)	Accelerometer Gyroscope Magnetometer	10, 50, 100	Transitions, Standing, Sitting, Lying, Walking	SVM
Nguyen, Fan และ Shahabi (2015)	Accelerometer	30	Standing, Walking, Sitting, Lying	Naive Bayes, SVM, Decision tree, Multilayer Perceptron K-nearest neighbor, Random Forest
Shoaib และคณะ (2016)	Accelerometer Gyroscope	50	Walking, Running, Sitting, Standing, Jogging, Biking, Walking upstairs, Walking downstairs	Bayesian networks, Naive Bayes, SVM, Logistic regression, K- nearest neighbor, Rule-based Classifier, Decision tree
Konak, Turan, Shoaib, และ Incel (2016)	Accelerometer Gyroscope	50	Walking, Standing, Jogging, Sitting, Biking, Walking upstairs, Walking downstairs, Typing, Writing, Drinking Coffee, Talking, Smoking, Eating	Naive Bayes, Decision tree, Random Forest
Weiss และคณะ (2016)	Accelerometer Gyroscope	20	General activities (not hand-oriented), General activities (hand-oriented),	Random Forest, Decision tree, Naive Bayes, K-nearest

ตารางที่ 2-4 งานวิจัยที่เกี่ยวข้องกับการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ได้จากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ (ต่อ)

งานวิจัย	ตัวรับรู้	อัตราสุ่มตัวอย่าง (Hz)	กิจกรรมที่สามารถรู้จำได้	วิธีการที่ใช้สร้างตัวแบบรู้จำกิจกรรม
			Eating activities (hand-oriented)	neighbor, Multi-layer perceptron
Korpela และคณะ (2016)	Accelerometer	100	Activity, Gesture Activity	Decision tree
Shahmohammadi, Hosseini, King และ Sarrafzadeh (2017)	Accelerometer Gyroscope	10	Standing, Sitting, Laying Down, Walking	Active Learning
Sun และคณะ (2017)	Accelerometer	60, 100	Walking, Running, Walking Upstairs, Walking downstairs, eating, driving,vechicie	SVM
Ahmad และ Khan (2017)	Accelerometer	ไม่ระบุ	Walking upstairs, Walking downstairs, Running, Walking, Jogging	SVM, K-nearest neighbor, Ensemble model (BAG), Decision Tree
Kwon และ Choi (2018)	Accelerometer	10	Office work, Reading, Writing, Taking a rest, Playing a game, Eating, Cooking, Washing dishes, Walking, Running, Taking a transport	Artificial neural network

2.2.2 ตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model)

งานวิจัยที่สร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคลจะเน้นสร้างตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้เป็นรายบุคคล โดยการใช้ข้อมูลการทำกิจกรรมของคนคนนั้นสำหรับเป็นข้อมูลในการสอนตัวแบบรู้จำกิจกรรม มีตัวอย่างงานวิจัยดังนี้

งานวิจัยของ Gomes และคณะ (2012) ได้พัฒนาขั้นตอนวิธีชื่อ “Mobile Activity Recognition System” หรือเรียกว่า “MARS” สำหรับรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลา กระบวนการสร้างตัวแบบรู้จำกิจกรรมประกอบไปด้วย ขั้นตอนสำหรับการเตรียมข้อมูลที่ใช้สร้างตัว

แบบรู้จำกิจกรรม (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 โดยให้ผู้ใช้ใส่อุปกรณ์สมาร์ตโฟนไว้ที่กระเป๋าทางเกงด้านหน้า ตัวอุปกรณ์สมาร์ตโฟนจะส่งสัญญาณข้อมูล Accelerometer ไปยังเครื่องแม่ข่ายเพื่อประมวลผลในขั้นตอนต่าง ๆ ส่วนการสร้างตัวแบบรู้จำกิจกรรมจะใช้ขั้นตอนวิธี Random Forest ซึ่งเป็นเทคนิคหนึ่งในการจำแนกประเภทข้อมูล ในส่วนการรู้จำเฉพาะบุคคล (Personal model) ระบบนี้มีขั้นตอนที่เรียกว่า Training mode สำหรับการเก็บข้อมูลการทำกิจกรรมต่าง ๆ เฉพาะบุคคลเพื่อเป็นข้อมูลสอน โดยที่ผู้ใช้ต้องทำกิจกรรมต่าง ๆ ตามระยะเวลาที่กำหนดผ่านแอปพลิเคชันที่ติดตั้งไว้ในอุปกรณ์สมาร์ตโฟน จากนั้นข้อมูลจะถูกส่งไปประมวลผลที่เครื่องแม่ข่ายเพื่อปรับปรุงตัวแบบรู้จำกิจกรรมที่สร้างไว้

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

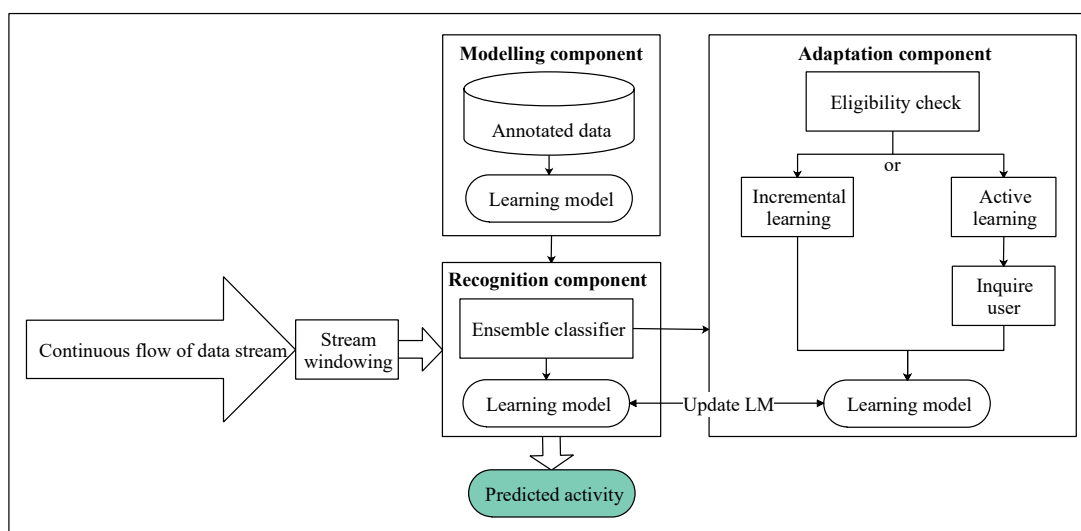
งานวิจัยของ Lee และคณะ (2017) นำเสนอวิธีการที่ชื่อว่า “One Dimensional Convolutional Neural Network” เรียกโดยย่อว่า “1D-CNN” สำหรับการรู้จำกิจกรรมจากข้อมูล Accelerometer sensor ของอุปกรณ์สมาร์ตโฟน มีแนวคิดในการใช้ข้อมูลเพียง 1 มิติในการรู้จำกิจกรรม 3 แบบ ได้แก่ การเดิน การวิ่ง และการหยุดนิ่ง (Staying still) ในขั้นตอนเตรียมข้อมูลสำหรับสอนตัวแบบรู้จำกิจกรรม จะให้ผู้ใช้ใส่อุปกรณ์สมาร์ตโฟนโดยติดตั้งไว้หลายตำแหน่ง ได้แก่ ถือไว้บนมือ ใส่ไว้ในกระเป๋าทางเกง 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 2-9



ภาพที่ 2-9 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 2-10 จากนั้นเก็บเฉพาะข้อมูลสรุป (Statistics summary) ของแต่ละกลุ่มย่อย (Sub-clusters) และกลุ่มใหญ่ (Clusters) ได้แก่ จำนวนของข้อมูลภายในกลุ่ม จุดศูนย์กลางของกลุ่ม ส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่น เป็นต้น สามารถคำนวณได้จากสมการที่ (2.9) ถึง (2.16)



ภาพที่ 2-10 ขั้นตอนการแบ่งกลุ่มข้อมูลแต่ละกิจกรรมออกเป็นกลุ่มย่อยตามจำนวนกลุ่มที่กำหนด

การหาค่าศูนย์กลางของข้อมูลของกลุ่มย่อย (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 <i>sitting, standing, walking, jogging</i> และ <i>stairs</i>

การหาค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูลกลุ่มใหญ่

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

โดยที่ $WISCS_{act}$	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

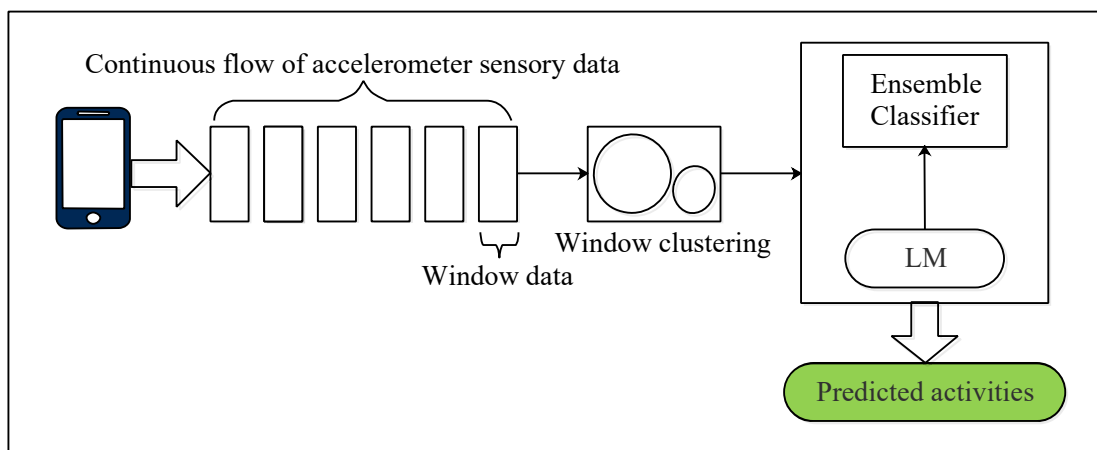
การหาค่าแรงดึงดูดที่กระทำต่อกันระหว่างกลุ่มย่อยแต่ละกลุ่มภายในกลุ่มใหญ่

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

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 2-11 ขนาดของ window จะถูกกำหนดด้วยอัตราการสุ่มตัวอย่างของข้อมูลกิจกรรมนั้น ๆ จากนั้นจะทำการแบ่งกลุ่มข้อมูลภายใน window ออกเป็น 2 กลุ่มด้วยเทคนิควิธีการแบ่งกลุ่ม

ข้อมูลแบบ K-mean หรือ Gaussian Mixture Model ก็ได้ แล้วนำข้อมูลของกลุ่มที่มีขนาดใหญ่ที่สุดไปจำแนกประเภทกิจกรรมด้วยมาตรวัด (Ensemble classification) ซึ่งประกอบด้วยมาตรวัด Distance, Gravity, Density และ Deviation แต่ละมาตรวัดรายละเอียดการจำแนกกิจกรรมดังนี้



ภาพที่ 2-11 ขั้นตอนการรู้จำกิจกรรมกับข้อมูลกระแสเชิงเวลาของวิธีการ Adaptive mobile activity recognition system with evolving data streams (STAR)

- มาตรวัด Distance จะจำแนกกิจกรรมโดยใช้ระยะห่างของจุดศูนย์กลางข้อมูลที่เข้ามาใหม่ ($Centroid_{new}$) 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

เมื่อมาตรวัดทุกตัวระบุกิจกรรมเสร็จแล้วจะนำผลที่ได้มาประเมินหาความเชื่อมั่นเพื่อทำนายกิจกรรม มีรายละเอียดดังตารางที่ 2-5 ถ้ามีระดับความเชื่อมั่นเท่ากับ 75% หรือ 100% จะทำนายกิจกรรมตามที่มาตรวัดส่วนใหญ่ระบุ ถ้าระดับความเชื่อมั่นเท่ากับ 50% โดยที่มาตรวัด 2 ใน 4

ระบุเป็นกิจกรรมเดียวกัน ส่วนมาตรวัดอีก 2 ตัวที่เหลือก็ระบุเป็นกิจกรรมที่แตกต่างกัน จะทำนายเป็นกิจกรรมที่มาตรวัด 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 โดยจะให้ผู้ใช่เป็นคนระบุกิจกรรมที่กำลังทำ ณ ขณะนั้น จากนั้นจะทำการปรับค่าสรุปของกลุ่มย่อยกับข้อมูลที่เข้ามาใหม่

ตารางที่ 2-5 การประเมินระดับความเชื่อมั่นที่ได้จากมาตรวัดของวิธีการ STAR

ระดับความเชื่อมั่น (%)	รายละเอียด	การตัดสินใจของตัวแบบรู้จำกิจกรรม	การปรับปรุงตัวแบบรู้จำกิจกรรม
25	มาตรวัดแต่ละตัวจะระบุกิจกรรมที่แตกต่างกัน	ไม่สามารถทำนายกิจกรรมได้ ต้องให้ผู้ใช่ระบุกิจกรรม	Active
50	มาตรวัด 2 ใน 4 ระบุเป็นกิจกรรมเดียวกัน ส่วนมาตรวัด 2 ตัวที่เหลือก็ระบุเป็นกิจกรรมเดียวกัน	ส่งทั้ง 2 กิจกรรมไปให้ผู้ใช่ระบุกิจกรรม	Active
50	มาตรวัด 2 ใน 4 ระบุเป็นกิจกรรมเดียวกัน ส่วนมาตรวัด 2 ตัวที่เหลือก็ระบุเป็นกิจกรรมที่แตกต่างกัน	ทำนายเป็นกิจกรรมที่มาตรวัด 2 ใน 4 ระบุเป็นกิจกรรมเดียวกัน	Incremental
75	มาตรวัด 3 ใน 4 ระบุกิจกรรมเดียวกัน	ทำนายเป็นกิจกรรมที่มาตรวัด 3 ใน 4 ระบุ	ไม่ต้องปรับปรุงตัวแบบรู้จำกิจกรรม
100	มาตรวัดทั้ง 4 ระบุกิจกรรมเดียวกัน	ทำนายเป็นกิจกรรมที่มาตรวัดทั้ง 4 ระบุ	ไม่ต้องปรับปรุงตัวแบบรู้จำกิจกรรม

บทที่ 3

วิธีการที่นำเสนอ

งานวิจัยนี้ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมที่สามารถรู้จำกิจกรรมกับข้อมูลกระแสวิ่งเวลาจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน และอุปกรณ์สวมใส่ที่ข้อมือ โดยมุ่งเน้นการรู้จำกิจกรรมทางกายภาพ ได้แก่ การยืน การนั่ง การเดิน การวิ่ง และการขึ้น/ลงบันได เป็นต้น ดังต่อไปนี้

1. วิธีการ “Impersonal smartphone based activity recognition using the accelerometer sensory data” เรียกโดยย่อว่า “ISAR” ซึ่งเป็นตัวแบบรู้จำกิจกรรมไม่เฉพาะบุคคล (Impersonal model) กับข้อมูลกระแสวิ่งเวลาจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน

2. วิธีการ “An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data” เรียกโดยย่อว่า “ISAR+” ซึ่งเป็นวิธีการรู้จำกิจกรรมที่พัฒนาต่อยอดมาจากวิธีการ ISAR โดยวิธีการ ISAR+ สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้

3. วิธีการ “Smartwatch-base Physical Activity Recognition” เรียกโดยย่อว่า “S-PAR” ซึ่งเป็นวิธีการรู้จำกิจกรรมที่พัฒนาต่อยอด และนำแนวคิดบางส่วนมาจากวิธีการ ISAR+ สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้ โดยใช้ข้อมูลกระแสวิ่งเวลาจาก Accelerometer sensor และ Gyroscope ของอุปกรณ์สวมใส่ที่ข้อมือหรือนาฬิกาอัจฉริยะ

3.1 การศึกษาและวิเคราะห์ข้อมูลสำหรับสร้างตัวแบบรู้จำกิจกรรม

3.1.1 ข้อมูลกิจกรรม

● ข้อมูล WISDM¹³ ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 36 คน ด้วยการใช้อุปกรณ์ที่สามารถตรวจจับค่า Accelerometer ของอุปกรณ์สมาร์ทโฟน โดยให้อาสาสมัครทั้ง 36 คน ใส่อุปกรณ์สมาร์ทโฟนไว้ในกระเป๋ากางเกงด้านหน้า 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

¹³ <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-SHAR¹⁴ ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ ที่บันทึกการทำกิจกรรมของอาสาสมัครจำนวน 30 คน ด้วยการใช้อุปกรณ์ที่สามารถตรวจจับค่า Accelerometer ของอุปกรณ์สมาร์ทโฟน โดยให้อาสาสมัครทั้ง 30 คน ใส่อุปกรณ์สมาร์ทโฟนไว้ในกระเป๋าทางเกงด้านหน้า 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-SHA

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

• ข้อมูล Pervasive System research datasets¹⁵ ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ ที่มีชื่อว่า Complex human activities dataset จากงานวิจัย Shoab และคณะ (2016) เก็บข้อมูลโดยอาสาสมัครทั้ง 10 คนติดอุปกรณ์สมาร์ทโฟนที่ตำแหน่งข้อมือข้างขวา ซึ่งตั้งค่าอัตราสุ่มตัวอย่างของข้อมูลเท่ากับ 50 Hz และทำการเก็บข้อมูลทำกิจกรรมของผู้ใช้ทั้งหมด 13 กิจกรรมซึ่งในงานวิทยานิพนธ์นี้เลือกกิจกรรมที่เป็นกิจกรรมทางกายทั้งหมด 6 กิจกรรมได้แก่ การยืน การนั่ง การเดิน การเดินขึ้นบันได การเดินลงบันได และการวิ่ง ตัวข้อมูลประกอบไปด้วย เวลาที่บันทึกการทำกิจกรรม กิจกรรมที่ผู้ใช้ทำค่า Accelerometer ตามแนวแกน X, Y, Z และค่า Gyroscope แนวแกน X, Y และ Z ที่นำมาใช้ในงานวิทยานิพนธ์นี้โดยเรียก Ax , Ay , Az และ Gx , Gy , Gz ตามลำดับ ตัวอย่างข้อมูลดังภาพที่ 3-3

Sample	Class	User	Timestamp	Ax	Ay	Az	Gx	Gy	Gz
s_1	Walking	1	1.39E+12	3.21	-12.69	1.51	-1.79	2.62	-1.37
s_1	Walking	1	1.39E+12	3.92	-10.48	0.87	-1.78	3.54	-1.33
s_1	Walking	1	1.39E+12	2.59	-10.37	2.72	-3.26	5.07	-1.12
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Walking	1	\vdots	Ax_i	Ay_i	Az_i	Gx_i	Gy_i	Gz_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	Walking	1	\vdots	Ax_N	Ay_N	Az_N	Gx_N	Gy_N	Gz_N

ภาพที่ 3-3 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 1 จากข้อมูลกิจกรรม Complex human activities dataset

• ข้อมูลกิจกรรม RealworldHAR¹⁶ ข้อมูลนี้เป็นข้อมูลออนไลน์สาธารณะ เก็บข้อมูลโดยอาสาสมัครทั้ง 15 คนติดอุปกรณ์สมาร์ทโฟนที่ตำแหน่งข้อมือข้างขวา ทำการเก็บข้อมูลทำกิจกรรมของผู้ใช้ทั้งหมด 7 กิจกรรมได้แก่ การยืน การนั่ง การนอน การเดิน การเดินขึ้นบันได การเดินลงบันได และการวิ่ง โดยเลือกข้อมูลของผู้ใช้ 10 คนที่ข้อมูลและครบทุกกิจกรรม ตัวข้อมูลประกอบไปด้วย เวลาที่บันทึกการทำกิจกรรม กิจกรรมที่ผู้ใช้ทำค่า Accelerometer ตามแนวแกน X, Y, Z และค่า Gyroscope แนวแกน X, Y และ Z ที่นำมาใช้ในงานวิทยานิพนธ์นี้โดยเรียก Ax , Ay , Az และ Gx , Gy , Gz ตามลำดับ ตัวอย่างข้อมูลดังภาพที่ 3-4

¹⁵ <https://www.utwente.nl/en/eemcs/ps/research/dataset/>

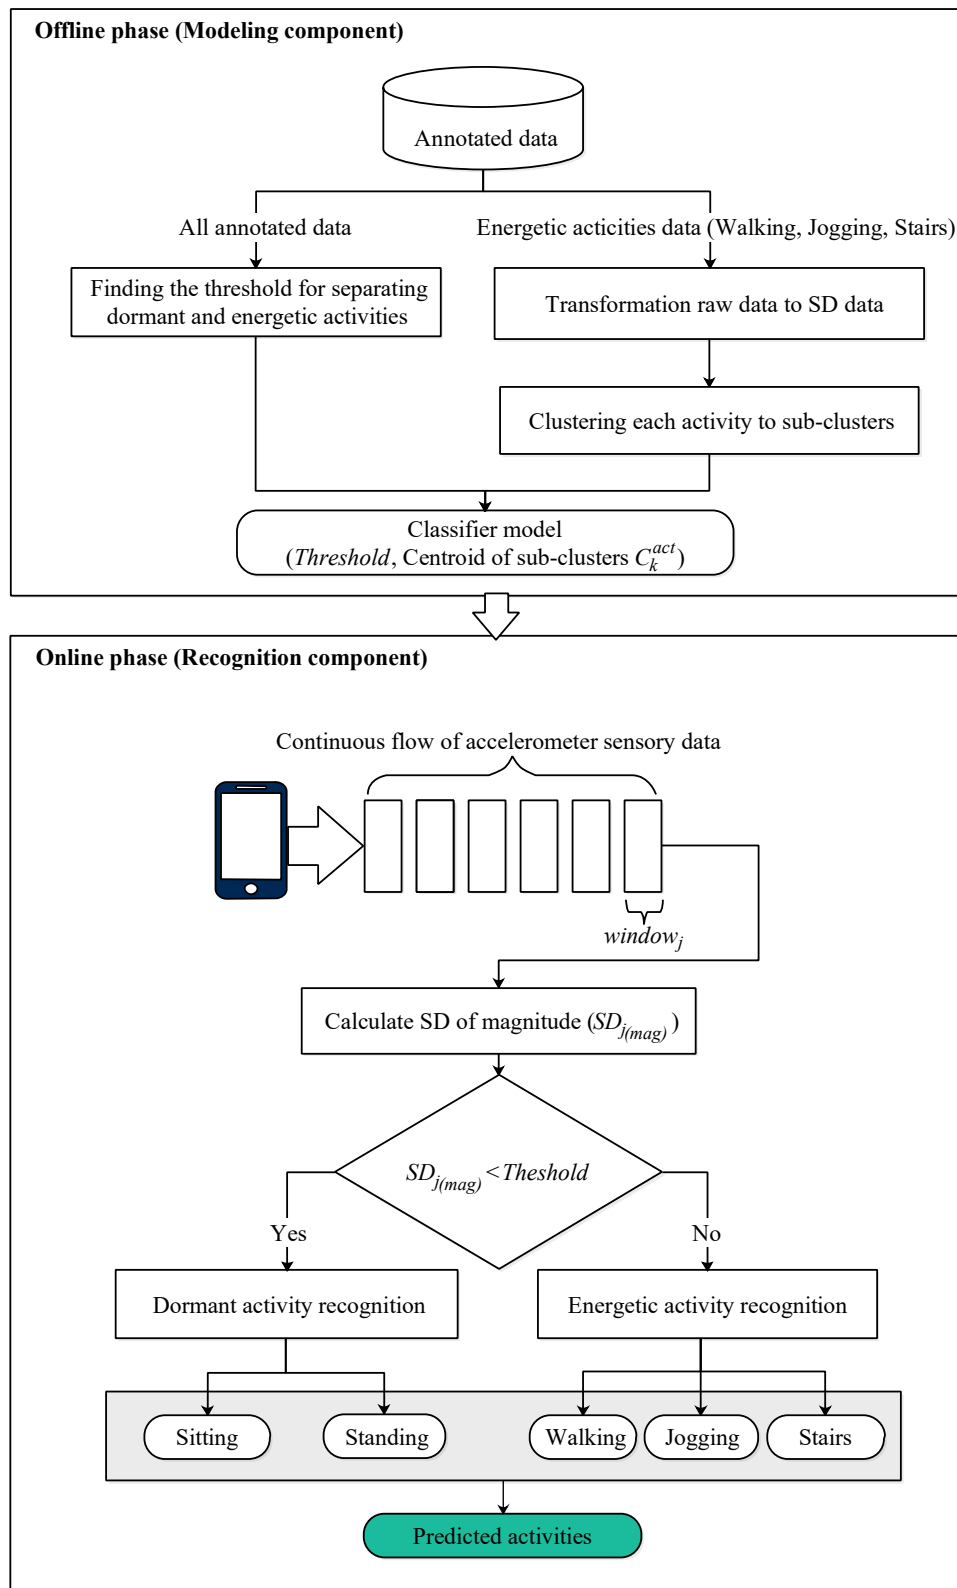
¹⁶<https://sensor.informatik.uni-mannheim.de/>

Sample	Class	User	Timestamp	A_x	A_y	A_z	G_x	G_y	G_z
s_1	Standing	9	1435991672020	-9.48	-2.26	1.53	-0.02	0.00	0.01
s_2	Standing	9	1435991672042	-9.49	-2.27	1.54	-0.03	0.00	0.01
s_3	Standing	9	1435991672061	-9.50	-2.33	1.53	-0.02	0.00	0.01
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Standing	9	\vdots	A_{x_i}	A_{y_i}	A_{z_i}	G_{x_i}	G_{y_i}	G_{z_i}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	Standing	9	\vdots	A_{x_N}	A_{y_N}	A_{z_N}	G_{x_N}	G_{y_N}	G_{z_N}

ภาพที่ 3-4 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 9 จากข้อมูลกิจกรรม RealworldHAR

3.2 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (ISAR)

สำหรับขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมประกอบไปด้วย ขั้นตอนออฟไลน์สำหรับสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนออนไลน์สำหรับรู้จำกิจกรรม โดยงานวิจัยนี้ได้สนใจการรู้จำกิจกรรมทางกายภาพ ได้แก่ การเดิน การนั่ง การยืน การวิ่ง และการขึ้นลงบันได เนื่องจากเป็นกิจกรรมพื้นฐานของมนุษย์ และแบ่งประเภทของกิจกรรมออกเป็น 2 กลุ่ม กลุ่มแรกเป็นกิจกรรมที่มีการเคลื่อนไหวร่างกายเล็กน้อยหรือแทบไม่เคลื่อนไหวเลย ได้แก่ การยืนและการนั่ง เรียกกิจกรรมกลุ่มนี้ว่า “กิจกรรมแบบนิ่ง (Dormant activities)” กลุ่มที่สองเป็นกิจกรรมที่เคลื่อนไหวร่างกายค่อนข้างมากหรือการขยับร่างกายอย่างรวดเร็ว ได้แก่ การเดิน การวิ่ง และการขึ้นลงบันได เรียกกลุ่มกิจกรรมนี้ว่า “กิจกรรมแบบเคลื่อนไหว (Energetic activities)” ซึ่งมีกรอบแนวคิดดังภาพที่ 3-5




ภาพที่ 3-5 ภาพรวมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

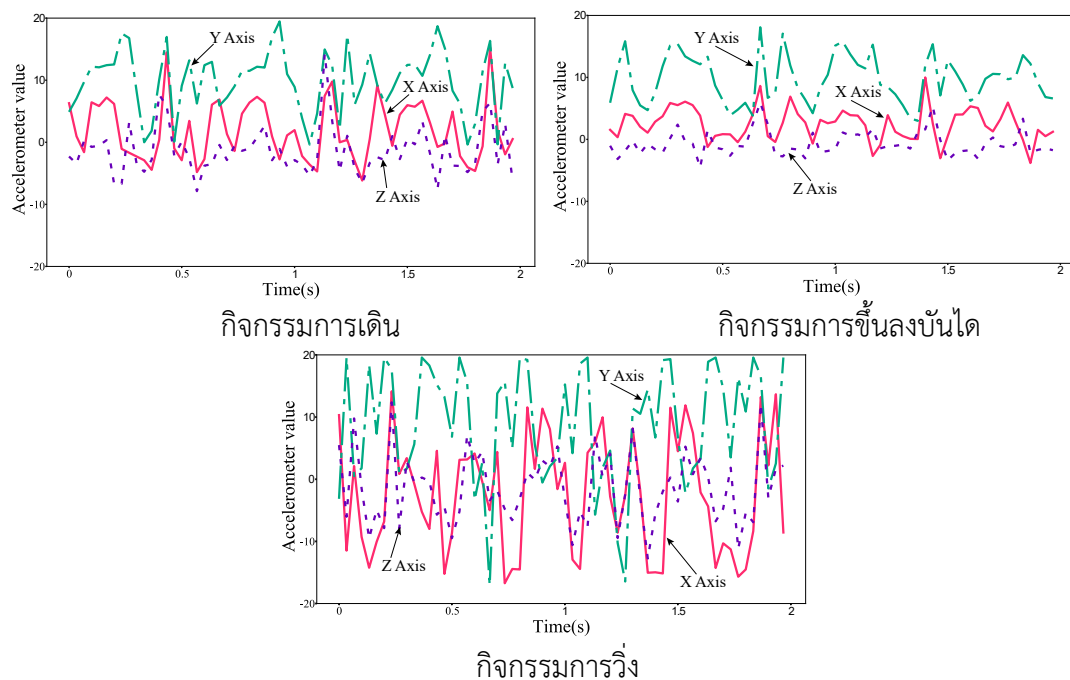
3.2.1 ISAR ชั้นตอนออฟไลน์ (Modeling)

ในขั้นตอนออฟไลน์จะเป็นการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ทราบว่าเป็นกิจกรรมประเภทใด (Annotated data) มีขั้นตอนดังนี้

- ขั้นตอนการหาค่า Threshold สำหรับแยกประเภทกิจกรรม (Finding the threshold for separating dormant and energetic activities) โดยได้แบ่งกลุ่มกิจกรรมเป็นสองกลุ่ม ได้แก่ กลุ่มกิจกรรมแบบนิ่งและกลุ่มกิจกรรมแบบเคลื่อนไหว ดังภาพที่ 3-6 และ 3-7



ภาพที่ 3-6 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบนิ่ง



ภาพที่ 3-7 แผนภูมิเส้นลักษณะการเปลี่ยนค่า Accelerometer ของกลุ่มกิจกรรมแบบเคลื่อนไหว

จากภาพที่ 3-6 และ 3-7 จะเห็นว่าลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมทั้งสองกลุ่มมีความแตกต่างกันอย่างชัดเจนดังนี้ กิจกรรมแบบเคลื่อนไหว ได้แก่ การเดิน การวิ่ง และการขึ้นลงบันได เส้นข้อมูลจะแกว่งไปมาเนื่องจากข้อมูลของกิจกรรมกลุ่มนี้มีค่า

แตกต่างกันมาก ข้อมูลจึงมีการกระจายตัวที่สูง แต่กิจกรรมแบบนิ่ง ได้แก่ การนั่งและการยืน เส้นข้อมูลจะแกว่งน้อยมากหรือเกือบคงที่ เนื่องจากข้อมูลกิจกรรมกลุ่มนี้มีค่าใกล้เคียงกัน ข้อมูลจึงมีการกระจายตัวต่ำ ดังนั้นการหาค่าขีดแบ่ง (Threshold) สำหรับแบ่งกิจกรรมแบบเคลื่อนไหวและแบบนิ่ง จึงได้นำส่วนเบี่ยงเบนมาตรฐานเข้ามาช่วยในการแบ่งข้อมูลกิจกรรมทั้งสองกลุ่ม เนื่องจากส่วนเบี่ยงเบนมาตรฐานสามารถวิเคราะห์การกระจายตัวของข้อมูลได้ดี 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 3-8

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 3-8 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 จะเท่ากับขนาดอัตราสุ่มตัวอย่างของข้อมูลนั้น)
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 ค่าส่วนเบี่ยงเบนมาตรฐานที่มากที่สุดของกิจกรรมแบบหนึ่ง 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 3-9



ภาพที่ 3-9 ตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมแบบเคลื่อนไหว (Energetic activities) และกิจกรรมแบบนิ่ง (Dormant activities) ออกจากกันได้

- ขั้นตอนการแปลงข้อมูลกิจกรรมด้วย SD (Transformation raw data to SD data) ข้อมูลกิจกรรมเมื่อนำมาแสดงเป็นแผนภูมิกระจาย ดังภาพที่ 3-9 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
\overline{ax}_j	คือ ค่าเฉลี่ยของ Accelerometer แนวแกน X ของ window ที่ j
ay_i	คือ ค่า Accelerometer แนวแกน Y ที่ i
\overline{ay}_j	คือ ค่าเฉลี่ยของ Accelerometer แนวแกน Y ของ window ที่ j
az_i	คือ ค่า Accelerometer แนวแกน Z ที่ i
\overline{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 3-10 ข้อมูลดิบของการทำกิจกรรม ซึ่งเห็นได้ชัดเจนว่ามีความทับซ้อนกันอย่างมาก แต่เมื่อนำมาแปลงให้กลายเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานแล้วข้อมูลการทำกิจกรรมนั้นสามารถแยกออกจากกันได้ ตัวอย่างดังภาพที่ 3-11 ดังนั้นถ้าหากแปลงข้อมูลกิจกรรมให้เป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานก่อนนำไปจำแนกกิจกรรม ก็จะส่งผลให้การจำแนกข้อมูลกิจกรรมสามารถทำได้ง่ายยิ่งขึ้น



ภาพที่ 3-10 แผนภูมิกระจายของข้อมูลกิจกรรม (ข้อมูลดิบ)



ภาพที่ 3-11 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 3-12

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 end
11 Find the maximum of standard deviation of dormant activities  $SD_{max(mag)}^{dor}$  from  $SD_{avg(mag)}^{act}$ 
    when  $act$  are sitting and standing.
12 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.
13 Compute  $Threshold = \frac{SD_{max(mag)}^{dor} + SD_{min(mag)}^{ene}}{2}$ .
14 for each energetic activity  $act$  do
15   /*  $act = (\text{walking, jogging, stairs})$  */
16   Let  $D$  be the empty set.
17   for each window  $j$  do
18     /*  $j = 1, 2, 3, \dots, J$  */
19     Compute the average values  $(\bar{a}x_j, \bar{a}y_j, \bar{a}z_j)$  of each acceleration values  $x, y,$  and  $z$ .
20     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).
21      $Std = (SD_{j(ax)}^{act}, SD_{j(ay)}^{act}, SD_{j(az)}^{act})$ .
22      $D = D \cup Std$ .
23   end
24   Cluster  $D$  into  $k$  sub-clusters using GMM algorithm.
25   /*  $k = 1, 2, 3, \dots, K$  */
26   Compute centroid  $C_k^{act}$  of all sub-clusters and add to  $CM$ .
27 end

```

ภาพที่ 3-12 ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

3.2.2 ISAR ขั้นตอนออนไลน์ (Recognition)

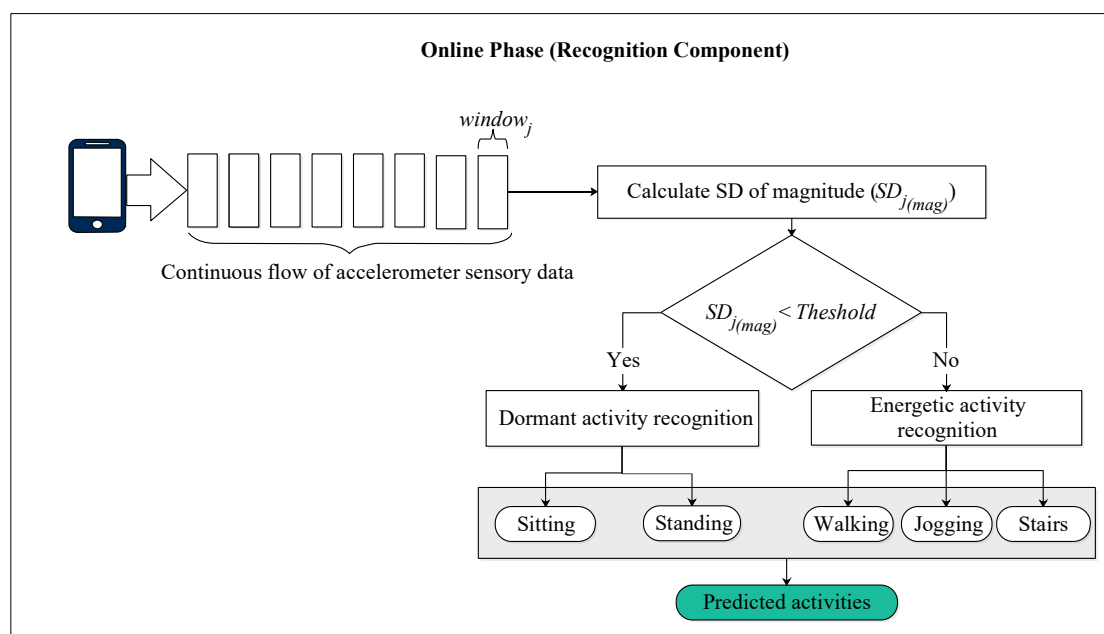
ในขั้นตอนนี้จะทำการรู้จำกิจกรรมกับข้อมูลจาก Accelerometer sensor ของอุปกรณ์สมาร์ทโฟน ซึ่งเป็นข้อมูลกระแสเชิงเวลาที่ไหลเข้ามา โดยข้อมูลจะถูกแบ่งออกเป็น window ซึ่งขนาดของข้อมูลภายใน window จะขึ้นอยู่กับค่าอัตราสุ่มตัวอย่างของอุปกรณ์สมาร์ทโฟน โดยมีการทำงานตามภาพที่ 3-13 ข้อมูล Accelerometer จะถูกคำนวณด้วยส่วนเบี่ยงเบนมาตรฐาน

จากนั้นจะทำการเปรียบเทียบกับค่าขีดแบ่งที่เก็บไว้ใน Classifier model ถ้าหากส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer มีค่ามากกว่าค่าขีดแบ่งแสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมแบบเคลื่อนไหว แต่ถ้าน้อยกว่าค่าขีดแบ่งแสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมแบบนิ่ง

- ขั้นตอนการแบ่งประเภทกิจกรรมด้วยค่าขีดแบ่ง (Threshold) ในขั้นตอนนี้จะทำการแบ่งประเภทของกิจกรรมว่าเป็นกิจกรรมแบบนิ่งหรือเป็นกิจกรรมแบบเคลื่อนไหว จากข้อมูลภายใน window โดยการคำนวณค่าส่วนเบี่ยงเบนมาตรฐานของ Magnitude ข้อมูล จากนั้นจะนำไปเปรียบเทียบกับค่าขีดแบ่งที่เก็บไว้ใน Classifier model โดยมีเกณฑ์ดังนี้


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

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

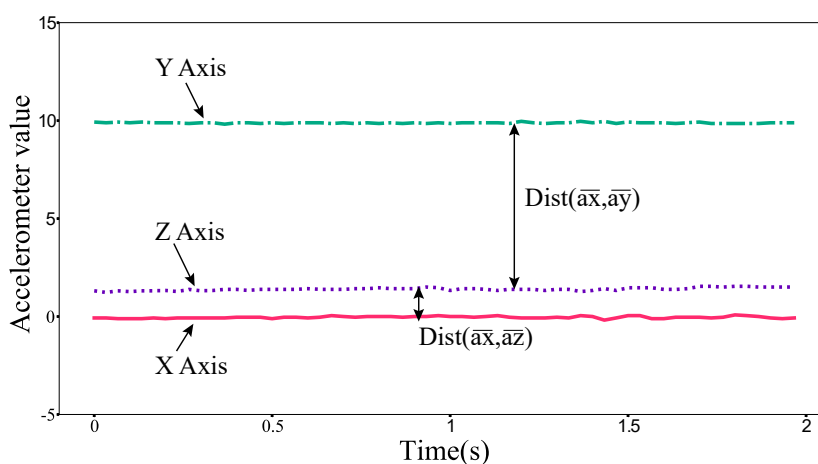


ภาพที่ 3-13 ขั้นตอนออนไลน์ของวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

- ขั้นตอนการจำกิจกรรมแบบนิ่ง (Dormant activity recognition) กิจกรรมแบบนี้ หมายถึงกิจกรรมที่มีการขยับร่างกายน้อย ได้แก่ การยืนและการนั่ง โดยการจำแนกประเภทของกิจกรรมทั้งสองจะจำแนกจากลักษณะเส้นข้อมูล Accelerometer ซึ่งทั้ง 2 กิจกรรมมีลักษณะข้อมูลดังภาพที่ 3-14 และ 3-15



ภาพที่ 3-14 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการนั่ง



ภาพที่ 3-15 แผนภูมิเส้นแสดงลักษณะค่า Accelerometer ตามแนวแกน X, Y และ Z ของกิจกรรมการยืน

จากภาพที่ 3-14 และ 3-15 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 จากข้อสังเกตนี้จึงได้ใช้ระยะห่างของค่า 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 ในงานงานวิจัยนี้จึงใช้การจำแนกกิจกรรมแบบนิ่ง (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

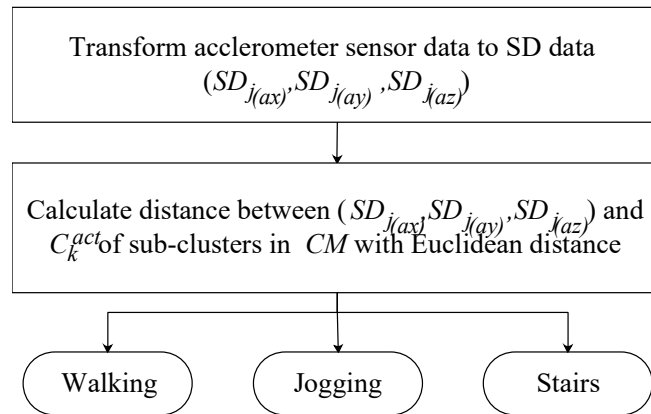
$Dist(\bar{ax}, \bar{az})$ คือ ระยะห่างระหว่างข้อมูล Accelerometer ตามแนวแกน X และแนวแกน Z

\bar{ax} คือ ค่าเฉลี่ยของค่า Accelerometer ตามแนวแกน X

\bar{ay} คือ ค่าเฉลี่ยของค่า Accelerometer ตามแนวแกน Y

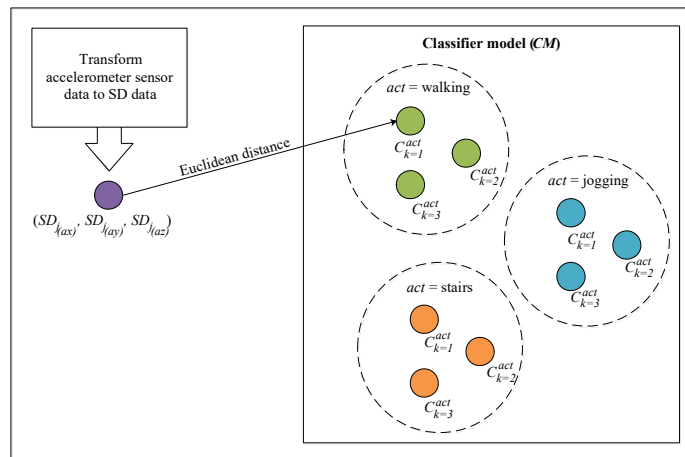
\bar{az} คือ ค่าเฉลี่ยของค่า Accelerometer ตามแนวแกน Z

- ขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว (Energetic activity recognition) โดยกิจกรรมแบบเคลื่อนไหว ได้แก่ การเดิน การวิ่ง และการขึ้นลงบันได ทั้ง 3 กิจกรรมจะทำการจำแนกกิจกรรมด้วยการคำนวณส่วนเบี่ยงเบนมาตรฐานของข้อมูล Accelerometer แต่ละแกน โดยมีขั้นตอนดังภาพที่ 3-16



ภาพที่ 3-16 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว

จากภาพที่ 3-16 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 3-17 ถ้าหาก C_k^{act} กลุ่มย่อยของกิจกรรมไหนมีระยะทางเมื่อเปรียบเทียบกับน้อยที่สุด แสดงว่าข้อมูลมีความคล้ายกันที่สุด จะระบุข้อมูลที่เข้ามาใหม่ว่าเป็นกิจกรรมนั้น



ภาพที่ 3-17 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 3-18

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      
$$w = \underset{k=1, \dots, K}{\operatorname{argmin}} (||SD_j - C_k^{act}||)$$

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 3-18 ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิธีการ Impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR)

3.2.3 ข้อจำกัดของวิธีการ ISAR

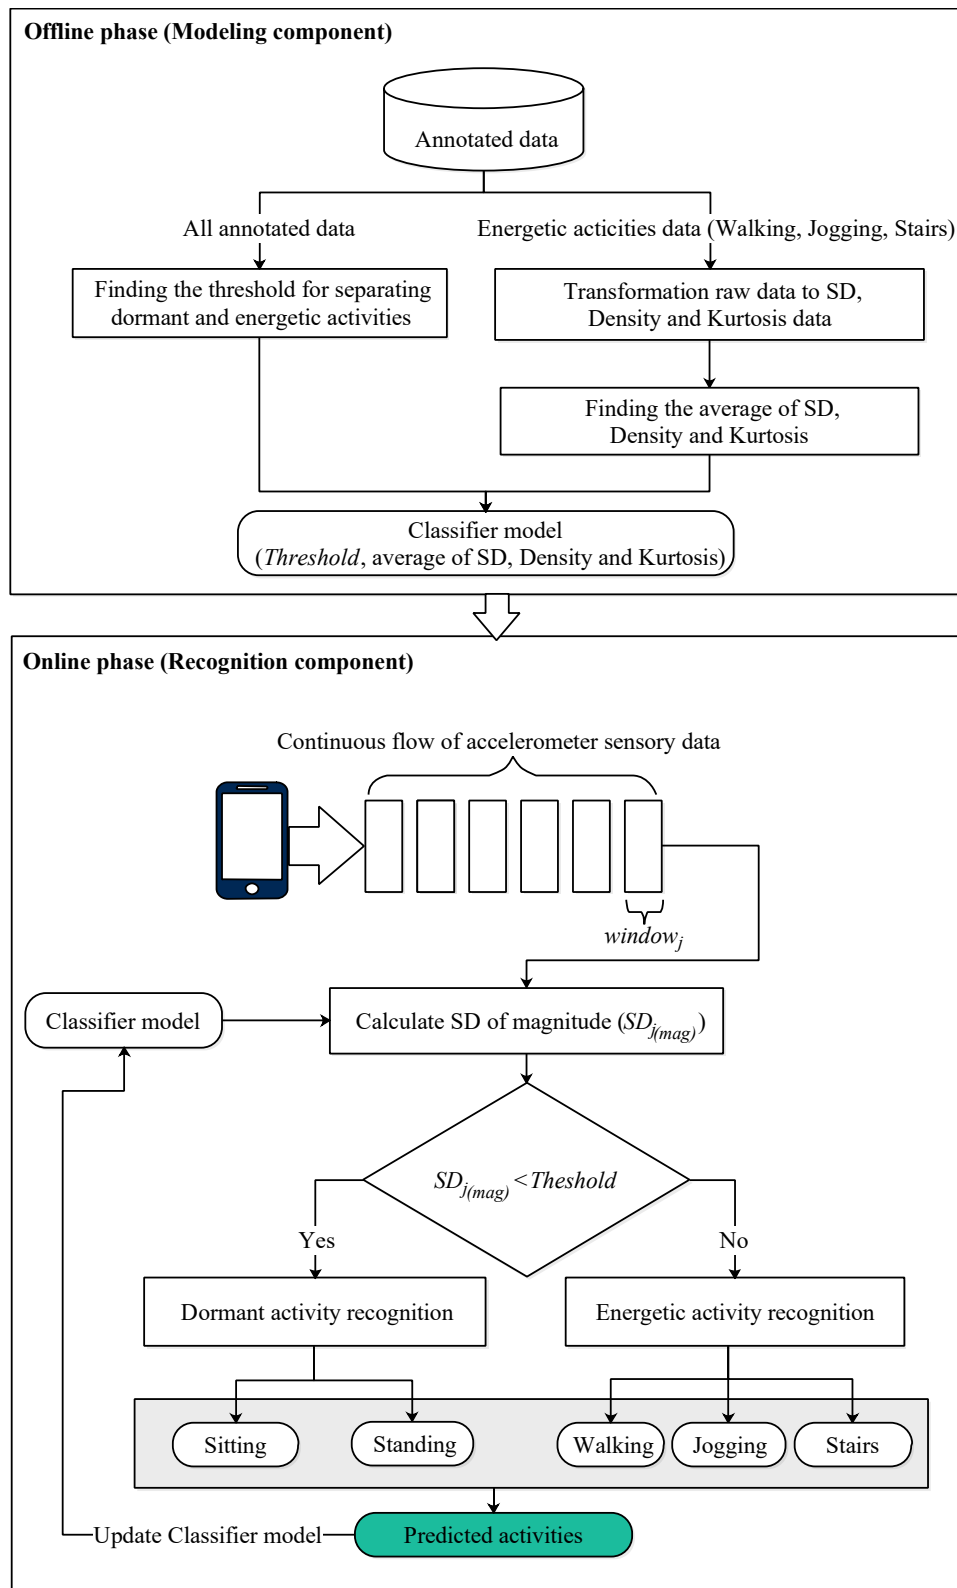
หลังจากสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการ ISAR และได้นำไปทดลองกับข้อมูล WISDM และ UniMiB-SHAR พบว่าเมื่อทดสอบกับข้อมูลการทำกิจกรรมของผู้ใช้ทุกคนแล้ว วิธีการ ISAR มีความถูกต้องในการรู้จำกิจกรรมที่สูงเฉพาะผู้ใช้บางรายเท่านั้น เนื่องมาจากวิธีการ ISAR ไม่

สามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้ ถ้าข้อมูลการทำกิจกรรมของผู้ใช้คนใดมีลักษณะคล้ายกับข้อมูลกิจกรรมที่ใช้สร้างตัวแบบ การรู้จำกิจกรรมของผู้ใช้คนนั้นจะมีความถูกต้องสูง กลับกันถ้าข้อมูลการทำกิจกรรมของผู้ใช้คนใดแตกต่างจากข้อมูลกิจกรรมที่ใช้สร้างตัวแบบ การรู้จำกิจกรรมของผู้ใช้คนนั้นก็จะมีค่าความถูกต้องต่ำ อีกทั้งยังพบว่าขั้นตอนการแบ่งกลุ่มข้อมูลกิจกรรม ไม่ได้ช่วยทำให้การรู้จำกิจกรรมดีขึ้น ซึ่งทำให้เสียเวลาในการคำนวณโดยเปล่าประโยชน์

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

3.3 ขั้นตอนการพัฒนาและปรับปรุงตัวแบบรู้จำกิจกรรม (ISAR+)

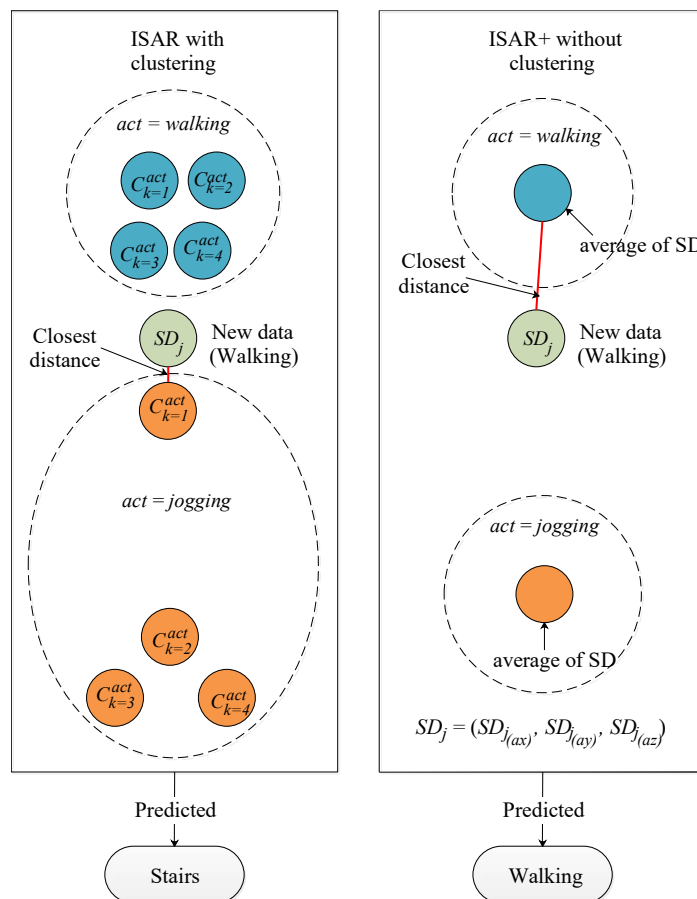
วิธีการ ISAR+ เป็นตัวแบบการรู้จำกิจกรรมที่พัฒนาจากวิธีการ ISAR โดยได้ปรับปรุงตัวแบบการรู้จำกิจกรรมให้สามารถปรับตัวแบบรู้จำกิจกรรมให้เข้ากับผู้ใช้แต่ละบุคคลได้ ซึ่งวิธีการ ISAR+ มีกรอบแนวคิดดังภาพที่ 3-19 ซึ่งมีการปรับปรุงตัวแบบรู้จำกิจกรรมดังต่อไปนี้ ขั้นตอนออนไลน์ 1) ใช้ค่าเฉลี่ยแทนการแบ่งกลุ่มของข้อมูลส่วนเบี่ยงเบนมาตรฐาน 2) เพิ่มการแปลงข้อมูลความหนาแน่น (Density) และความโด่ง (Kurtosis) ของข้อมูล ขั้นตอนออนไลน์ 1) เพิ่มการปรับปรุงตัวแบบรู้จำกิจกรรมโดยใช้มาตรวัด 3 ตัว ได้แก่ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ความหนาแน่น (Density) และความโด่ง (Kurtosis) ของข้อมูล



ภาพที่ 3-19 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 3-20 ข้อมูลกิจกรรมการขึ้นลงบันไดที่ใช้สร้างตัวแบบรู้จำกิจกรรมอาจมีความโดดเด่นผิดปกติ เมื่อแบ่งกลุ่มข้อมูลจึงมีขอบเขตข้อมูลที่มากขึ้น เมื่อใช้ตัวแบบรู้จำกิจกรรมนี้กับข้อมูลที่เข้ามาซึ่งเป็นกิจกรรมการเดิน แต่อยู่ใกล้กับขอบเขตกิจกรรมการขึ้นลงบันไดมากกว่าขอบเขตกิจกรรมการเดิน จึงทำให้ ISAR ระบุกิจกรรมผิดพลาด แต่ถ้าหากใช้แค่จุดศูนย์กลางของข้อมูลโดยไม่จำเป็นต้องแบ่งกลุ่ม น่าจะทำให้การรู้จำกิจกรรมมีความถูกต้องมากขึ้น งานวิจัยนี้จึงได้ตัดขั้นตอนการแบ่งกลุ่มข้อมูลออก โดยเปลี่ยนเป็นการเก็บค่าเฉลี่ยของข้อมูลแทน



ภาพที่ 3-20 ตัวอย่างวิธีการ ISAR+ ที่มีการแบ่งกลุ่มข้อมูลแล้วไม่มีการแบ่งกลุ่มข้อมูล

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

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

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

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

โดยที่ $Den_{j(ax)}^{act}, Den_{j(ay)}^{act}, Den_{j(az)}^{act}$ 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

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

ay_i คือ ค่า Accelerometer ตามแนวแกน Y ตัวที่ i

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

az_i คือ ค่า Accelerometer ตามแนวแกน Z ตัวที่ i

\overline{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) ในขั้นตอนนี้จะเก็บข้อมูลสรุปไว้ใน 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 ค่าเฉลี่ยเบี่ยงเบนมาตรฐานมาตรฐานของข้อมูล 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 ตาม
 แนวแกน 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+) ที่ได้กล่าวมา
 ข้างต้น สามารถอธิบายเป็นขั้นตอนได้ดังภาพที่ 3-21

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 3-21 ขั้นตอนออฟไลน์ การสร้างตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)

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 ที่ได้ใช้ส่วนเบี่ยงเบนมาตรฐานในการรู้จำกิจกรรมนั้น งานวิจัยนี้จึงได้พิจารณาวิธีการทางสถิติอื่น ๆ ที่เมื่อใช้ร่วมกันกับส่วนเบี่ยงเบนมาตรฐานแล้วสามารถรู้จำกิจกรรมได้ดี เพื่อที่จะนำมาใช้เป็นเกณฑ์สำหรับการปรับตัวแบบรู้จำกิจกรรมได้ จึงได้ทดลองจับคู่การใช้ส่วนเบี่ยงเบนมาตรฐานกับวิธีการอื่น ๆ ในการรู้จำกิจกรรม ซึ่งมีผลลัพธ์การรู้จำกิจกรรม ดังตารางที่ 3-1

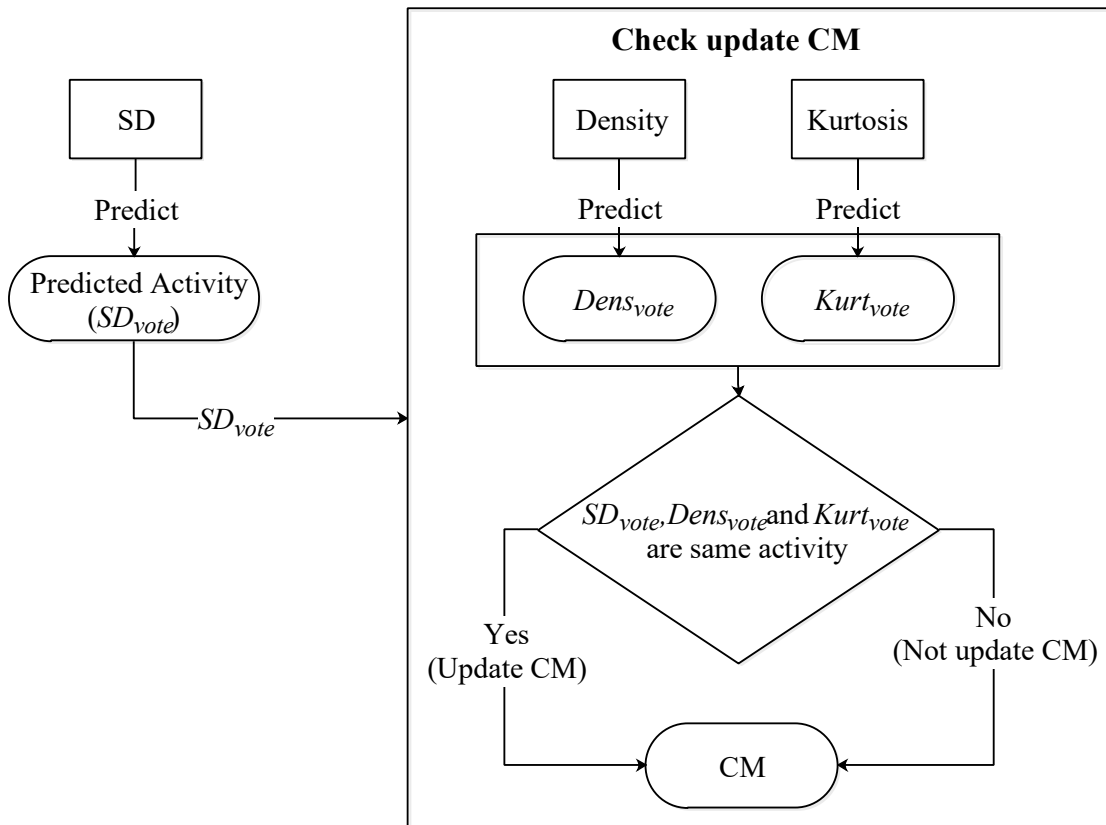
ตารางที่ 3-1 การจับคู่วิธีการ SD และวิธีการทางสถิติอื่น ๆ ในการรู้จำกิจกรรม โดยใช้ข้อมูล WISDM

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 3-1 จะเห็นว่ายิ่งใช้วิธีการทางสถิติมากขึ้น ก็มีแนวโน้มที่จะรู้จำกิจกรรมได้ถูกต้องสูงขึ้นด้วย แต่อย่างไรก็ตามการใช้วิธีการทางสถิติหลายตัวจะทำให้เพิ่มการคำนวณมากขึ้นเหมือนกัน เมื่อพิจารณาหาเกณฑ์สำหรับปรับปรุงตัวแบบรู้จำกิจกรรม จึงได้เลือกส่วนเบี่ยงเบนมาตรฐาน ความหนาแน่นและความโด่ง เนื่องจากเมื่อใช้ทั้ง 3 ตัวนี้รวมกัน สามารถระบุกิจกรรมได้ถูกต้องถึง 91.64% อีกทั้งยังมีโอกาสที่จะทำการปรับปรุงตัวแบบรู้จำกิจกรรมถึง 44.68% ซึ่งขั้นตอนในการปรับปรุงตัวแบบรู้จำกิจกรรมมีรายละเอียดดังภาพที่ 3-22

จากภาพที่ 3-22 หลังจากรู้จำกิจกรรมด้วยการใช้ส่วนเบี่ยงเบนมาตรฐาน จะทำการตรวจสอบว่าต้องปรับปรุงตัวแบบรู้จำกิจกรรมหรือไม่ โดยการคำนวณความหนาแน่นและความโด่งของข้อมูล แล้วนำไปเปรียบเทียบกับค่าที่เก็บไว้ใน Classifier model ซึ่งใช้หลักการเดียวกันกับตอนที่ทำการรู้จำกิจกรรมด้วยส่วนเบี่ยงเบนมาตรฐาน จากนั้นจะพิจารณากิจกรรมที่ระบุด้วยส่วนเบี่ยงเบน

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



ภาพที่ 3-22 ขั้นตอนการตรวจสอบการปรับปรุงตัวแบบรู้จำกิจกรรม

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

ปรับปรุงส่วนเบี่ยงเบนมาตรฐานภายใน Classifier model

$$newSD_{CM}^{act} = \frac{SD_{CM}^{act} + SD_j}{2} \quad (3.24)$$

ปรับปรุงความหนาแน่นภายใน Classifier model

$$newDens_{CM}^{act} = \frac{Dens_{CM}^{act} + Dens_j}{2} \quad (3.25)$$

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 3-23 และ 3-24

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  $(\bar{a}x_j, \bar{a}y_j, \bar{a}z_j)$  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         $P_{act} = standing$ 
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 acceleration values x, y, and z.
18      Compute the standard deviation of each acceleration values  $SD_{j(ax)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ax - \bar{a}x)^2}$ ,
19       $SD_{j(ay)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (ay - \bar{a}y)^2}$ ,  $SD_{j(az)} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (az - \bar{a}z)^2}$  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 3-23 ขั้นตอนออนไลน์ การรู้จำกิจกรรมวิถีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)

Algorithm 5: ISAR+ model : Online phase (Adaptation component)

```

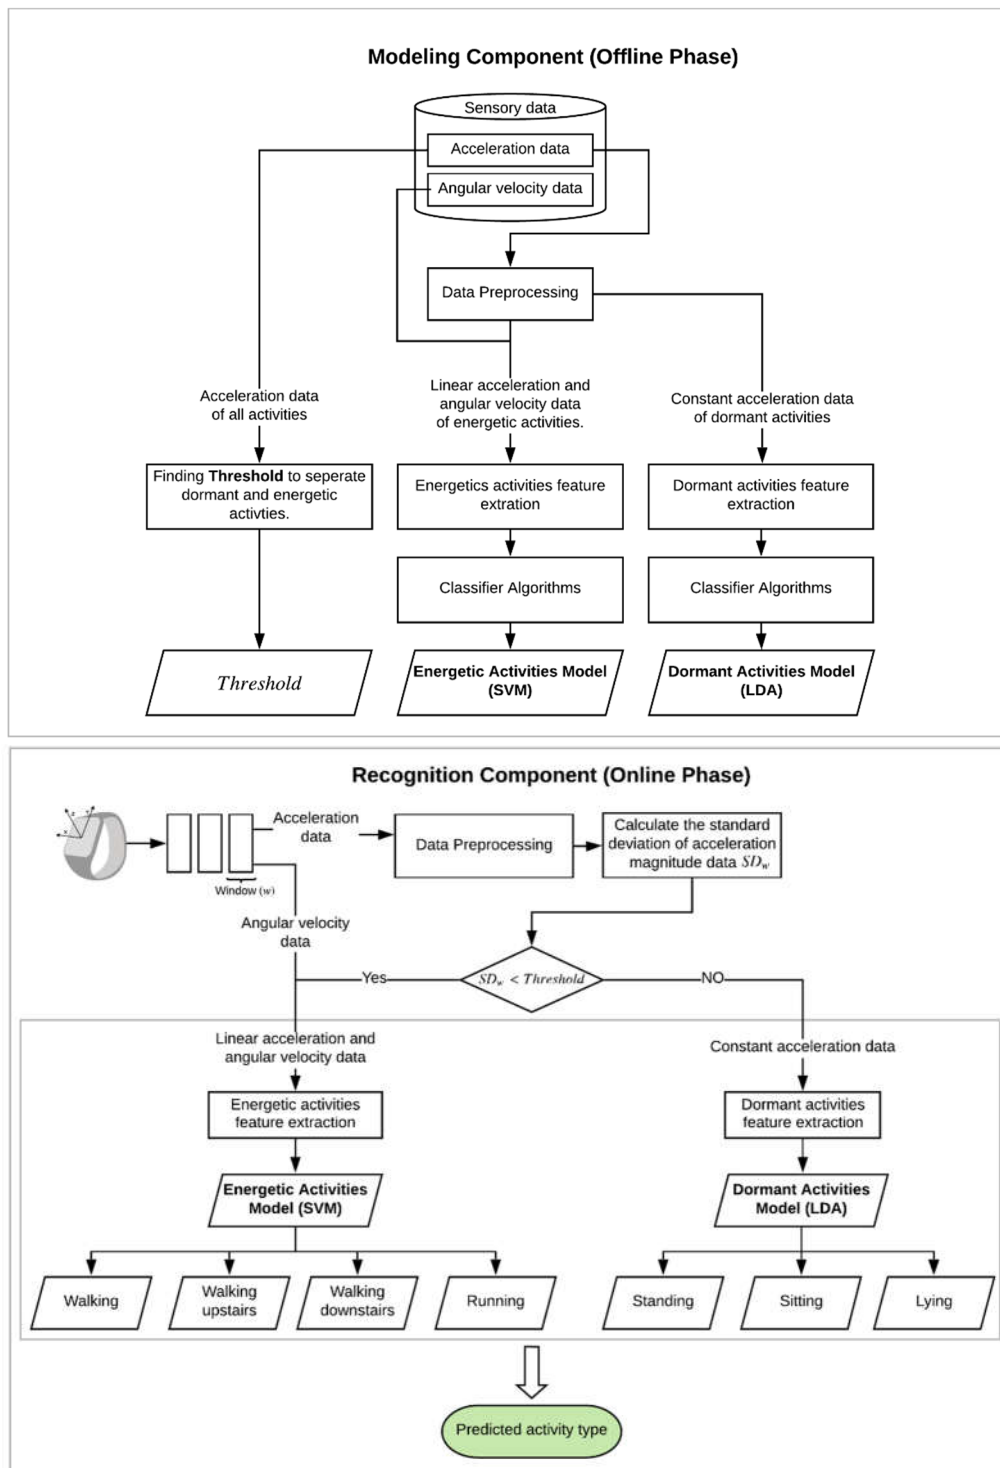
/* windowj = the set of accelerometer sensor data when j = 1, 2, 3, ..., J. */
/* CM = {SDCMact, DensCMact, KurtCMact} when act are walking, jogging and stairs. */
/* Pact = The predicted activities. */
/* J = the number of window. */
/* n = the number of data in window. */
Input : windowj, CM, SDj, 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 3-24 ขั้นตอนออนไลน์ การปรับปรุงตัวแบบรู้จำกิจกรรมวิธีการ An improvement impersonal smartphone-based activity recognition using the accelerometer sensory data (ISAR+)

3.4 ขั้นตอนการพัฒนาวิธีการ “Smartwatch-base Physical Activity Recognition” (S-PAR)

สำหรับขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมประกอบไปด้วย ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนรู้จำกิจกรรม โดยงานวิจัยนี้ได้สนใจและศึกษาการรู้จำกิจกรรมทางกายภาพได้แก่ การยืน การนั่ง การนอน การเดิน การเดินขึ้นบันได การเดินลงบันได และการวิ่ง ซึ่งจะแบ่งประเภทกิจกรรมออกเป็นสองกลุ่ม กลุ่มที่หนึ่งเป็นกิจกรรมที่มีร่างกายที่หยุดนิ่งหรือมีการเคลื่อนไหวน้อยได้แก่ การยืน การนั่งและการนอน เรียกกิจกรรมกลุ่มนี้ว่า กิจกรรมแบบนิ่ง (Dormant activities) กลุ่มที่สองเป็นกิจกรรมที่เคลื่อนไหวของร่างกายได้แก่ การเดิน การเดินขึ้นบันไดและการลงบันได เรียกกลุ่มกิจกรรมนี้ว่า “กิจกรรมแบบเคลื่อนไหว (Energetic activities)” ซึ่งมีกรอบแนวคิดดังภาพที่ 3-25




ภาพที่ 3-25 กรอบแนวคิดวิธีการ Smartwatch-base Physical Activity Recognition (S-PAR)

3.4.1 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (Modeling phase)

ในขั้นตอนนี้จะเป็นการสร้างตัวแบบรู้จำกิจกรรมโดยใช้ข้อมูลที่ทราบว่าเป็นกิจกรรมกรรมประเภทใด โดยมีขั้นตอนดังนี้

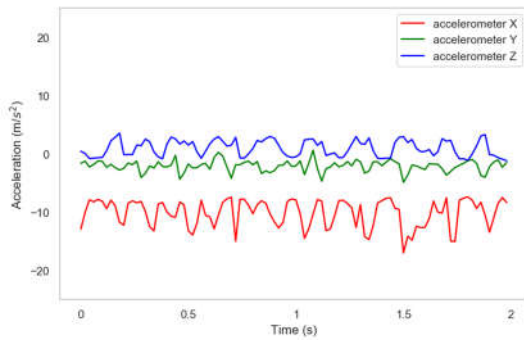
3.4.1.1 ขั้นตอนการเตรียมข้อมูล (Data Preprocess) ขั้นตอนนี้มีหน้าที่จัดการกระแสข้อมูลเชิงเวลาที่ได้รับจากตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ ซึ่งค่าความเร่งจากตัวรับรู้ Accelerometer เกิดจากการรวมกันระหว่างความเร่งที่เกิดจากแรงโน้มถ่วงและความเร่งเชิงเส้นจากการกระทำกิจกรรมของผู้ใช้ จึงมีหลายงานวิจัยที่นำการประมวลผลทางสัญญาณที่มีชื่อว่า วงจรกรองความถี่ (Filter) มาประยุกต์ใช้กับการรู้จำกิจกรรมจากกระแสข้อมูลเชิงเวลาจากตัวรับรู้ ตัวอย่างเช่น งานวิจัยของ Anguita, Ghio และ Oneta (2013) ได้นำวิธีการ Median filter และ 3rd Low-pass Butterworth filter ที่กำหนดค่าความถี่ตัดเท่ากับ 20 Hz เพื่อลดสัญญาณรบกวน (Noise) ของกระแสข้อมูลเชิงเวลา Accelerometer ของอุปกรณ์สมาร์ตโฟนและได้ตั้งสมมุติฐานว่า ความเร่งที่เกิดจากแรงโน้มถ่วงจะมีความถี่ที่ต่ำ ซึ่งได้ทำการทดลองโดยใช้ Low-pass filter และได้รับผลการทดลองว่าค่าความถี่ตัดเท่ากับ 0.3 Hz สามารถแยกความเร่งที่เกิดจากแรงโน้มถ่วงออกจากความเร่งได้ งานวิจัยของ Bayat, Pomplun และ Tran (2014) ได้นำวิธีการ Low-pass filter ที่กำหนดความถี่ตัดเท่ากับ 0.25Hz เพื่อที่จะแยกความเร่งที่เกิดจากแรงโน้มถ่วง Khan, Tufail, Khattak และ Laine (2014) ได้ระบุว่าความเร่งที่เกิดจากแรงโน้มถ่วงเป็นสัญญาณรบกวนของกระแสข้อมูลเชิงเวลาจาก Accelerometer ที่มีผลต่อประสิทธิภาพของการรู้จำกิจกรรม จึงนำวิธีการ Low-pass filter มาประยุกต์ใช้ตามขั้นตอนดังภาพที่ 3-26 เพื่อที่จะได้ความเร่งเชิงเส้นที่เกิดจากผู้ใช้และงานวิจัย Uddin, Billah และ Hossain (2016) ได้นำวิธีการ Butterworth low-pass filter ที่กำหนดความถี่ตัดเท่ากับ 0.3 Hz ในการแยกความเร่งที่เกิดจากแรงโน้มถ่วงและความเร่งเชิงเส้น

ในงานวิจัยนี้ได้ประยุกต์ใช้วิธีการ Butterworth low-pass filter ซึ่งกำหนดค่าความถี่ตัดเท่ากับ 0.3 Hz กับกระแสข้อมูลเชิงเวลาของตัวรับรู้ Accelerometer จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์สวมตามขั้นตอนดังภาพที่ 3-26 ซึ่งผลลัพธ์ของการแยกกระแสข้อมูลเชิงเวลาความเร่งที่




ภาพที่ 3-26 ขั้นตอนการแยกความเร่งที่เกิดจากแรงโน้มถ่วงและความเร่งเชิงเส้นจากความเร่งจากตัวรับรู้ Accelerometer

เกิดจากแรงโน้มถ่วงและกระแสข้อมูลเชิงเวลาความเร่งเชิงเส้นที่เกิดจากการกิจกรรมหรือเคลื่อนไหวของผู้ใช้งานจากกระแสข้อมูลเชิงเวลาความเร่งจาก Accelerometer ดังภาพที่ 3-27




กระแสข้อมูลเชิงเวลาความเร่งที่วัดได้จากตัวรับรู้

Accelerometer




กระแสข้อมูลเชิงเวลาความเร่งเชิงเส้น




กระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วง

ภาพที่ 3-27 กระแสข้อมูลเชิงเวลาความเร่งที่วัดได้จากตัวรับรู้ Accelerometer เป็นการรวมกันระหว่างความเร่งที่เกิดแรงโน้มถ่วงและความเร่งเชิงเส้นที่เกิดจากผู้ใช้ของกิจกรรมเดินจากข้อมูลกิจกรรม RealworldHAR


3.4.1.2 การหาค่าเส้นขีดแบ่งสำหรับแยกประเภทกิจกรรม ซึ่งการจัดกลุ่มกิจกรรมตามการขยับตัวหรือเคลื่อนไหวของร่างกายซึ่งแบ่งออกเป็นสองกลุ่มได้แก่ กลุ่มกิจกรรมนิ่งและกลุ่มกิจกรรมเคลื่อนไหวดังภาพที่ 3-28 และ 3-29



กิจกรรมการยืน




กิจกรรมนั่ง




กิจกรรมนอน


ภาพที่ 3-28 แผนภูมิเส้นลักษณะกระแสดังกล่าวแสดงข้อมูลเชิงเวลาความเร่ง Accelerometer ของกลุ่มกิจกรรม
นี้จากข้อมูลกิจกรรม RealworldHAR




กิจกรรมเดิน



กิจกรรมเดินขึ้นบันได



กิจกรรมเดินลงบันได



กิจกรรมวิ่ง

ภาพที่ 3-29 แผนภูมิเส้นลักษณะกระแสดังกล่าวแสดงข้อมูลเชิงเวลาความเร่ง Accelerometer ของกลุ่มกิจกรรม
เคลื่อนไหวจากข้อมูลกิจกรรม RealworldHAR

จากภาพที่ 3-29 เห็นได้ว่าค่าความเร่งจาก Accelerometer ตามแนวแกน X, แกน Y และ แกน Z มีแกว่งของข้อมูลกิจกรรมเคลื่อนไหวมากกว่ากิจกรรมแบบนิ่ง ดังนั้นในการคำนวณหาค่าขีด
แบ่ง (Threshold) สำหรับแบ่งประเภทของกิจกรรม จึงได้นำค่าส่วนเบี่ยงเบนมาตรฐานของขนาดของ
ความเร่ง (Magnitude) ของความเร่งจาก Accelerometer ในแต่ละ window ที่สามารถแบ่งข้อมูล
กิจกรรมทั้งสองกลุ่มได้อย่างดี โดยมีวิธีการหาค่าขีดแบ่งดังสมการที่ 3.1 ถึง 3.4

$$M_i = \sqrt{Ax_i^2 + Ay_i^2 + Az_i^2} \quad (3.1)$$

โดยที่ M_i คือค่า Magnitude ที่ i ($i = 1, 2, 3, \dots, N$ เมื่อ N คือ จำนวนตัวอย่างของหนึ่งกิจกรรม) ตัวอย่างดังภาพที่ 3-30

Ax_i คือค่า Accelerometer ตามแนวแกน X ที่ i

Ay_i คือค่า Accelerometer ตามแนวแกน Y ที่ i

Az_i คือค่า Accelerometer ตามแนวแกน Z ที่ i

Sample	Class	Timestamp	Ax	Ay	Az	Magnitude
s_1	Standing	1436624160041	-9.43	-2.65	1.04	9.85
s_2	Standing	1436624160042	-9.39	-2.63	1.09	9.81
s_3	Standing	1436624160050	-9.38	-2.63	1.01	9.79
s_4	Standing	1436624160089	-9.39	-2.62	1.00	9.80
s_5	Standing	1436624160109	-9.40	-2.68	0.94	9.82
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Standing	\vdots	Ax_i	Ay_i	Az_i	M_i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_{100}	Standing	\vdots	Ax_{100}	Ay_{100}	Az_{100}	M_{100}
s_{101}	Standing	\vdots	Ax_{101}	Ay_{101}	Az_{101}	M_{101}
s_{102}	Standing	\vdots	Ax_{102}	Ay_{102}	Az_{101}	M_{102}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	Standing	\vdots	Ax_N	Ay_N	Az_N	M_N

} $Window_{j=1}$

ภาพที่ 3-30 ตัวอย่างค่า Magnitude (M_i) ของข้อมูลกิจกรรม

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

โดยที่ $SD_{j(M)}^{act}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของ Magnitude ภายใน window ที่ j

M_i คือ ค่า Magnitude ที่ i

\bar{M}_j คือ ค่าเฉลี่ยของ Magnitude ของ window ที่ j

N คือ ค่าจำนวนข้อมูลทั้งหมดของกิจกรรมที่กำลังพิจารณา

j คือ ค่าที่ใช้สำหรับระบุลำดับของ Window

act คือ กิจกรรมที่กำลังพิจารณา

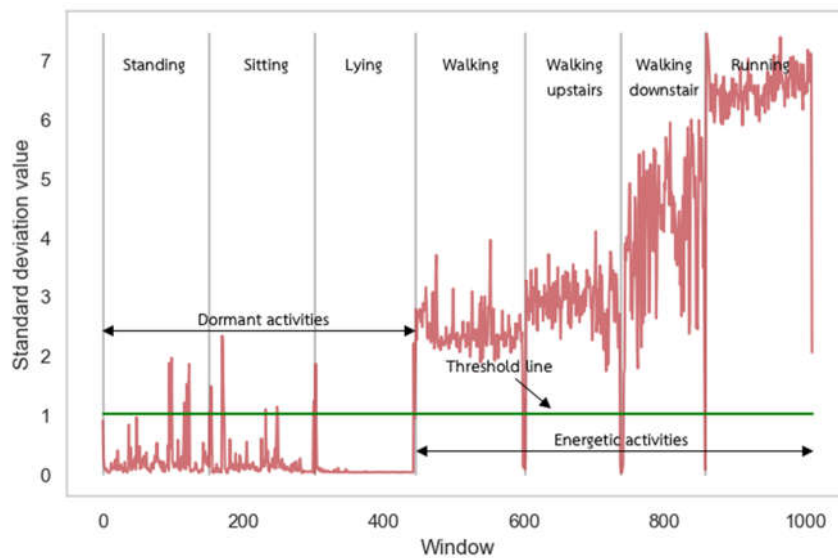
เมื่อคำนวณส่วนเบี่ยงเบนมาตรฐานครบทุกกิจกรรมแล้ว ให้นำค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มาหาค่าเฉลี่ยแต่ละกิจกรรมเพื่อคำนวณค่าขีดแบ่งดังสมการที่ 3.3 และ 3.4

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

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

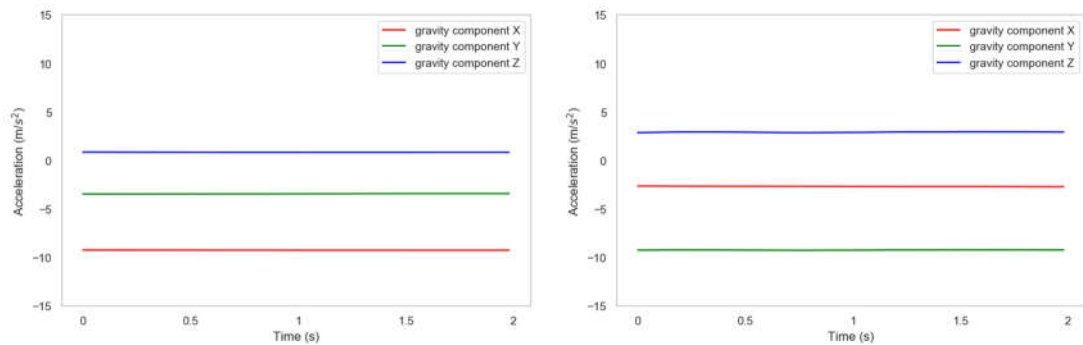
โดยที่	$SD_{avg(M)}^{act}$	คือ ค่าส่วนเบี่ยงเบนมาตรฐานของ Magnitude ในแต่ละกิจกรรม
	$Threshold$	คือ ค่า Magnitude ที่ i
	$SD_{max(M)}^{dor}$	คือ ค่าส่วนเบี่ยงเบนมาตรฐานที่มากที่สุดของกิจกรรมแบบนั่งได้แก่ กิจกรรมนั่ง กิจกรรมยืนและกิจกรรมนอน
	$SD_{min(M)}^{ene}$	คือ ค่าส่วนเบี่ยงเบนมาตรฐานที่มากที่สุดของกิจกรรมแบบนั่งได้แก่ กิจกรรมเดิน กิจกรรมเดินขึ้นบันได, กิจกรรมเดินลงบันไดและกิจกรรมวิ่ง
	j	คือ จำนวน window ของข้อมูลหนึ่งกิจกรรม

เมื่อกำหนดตามสมการที่ 3.4 จะเห็นว่าค่าขีดแบ่งคือค่ากึ่งกลางที่สามารถแบ่งข้อมูลกิจกรรมทั้งสองกลุ่มได้ ดังภาพที่ 3-31

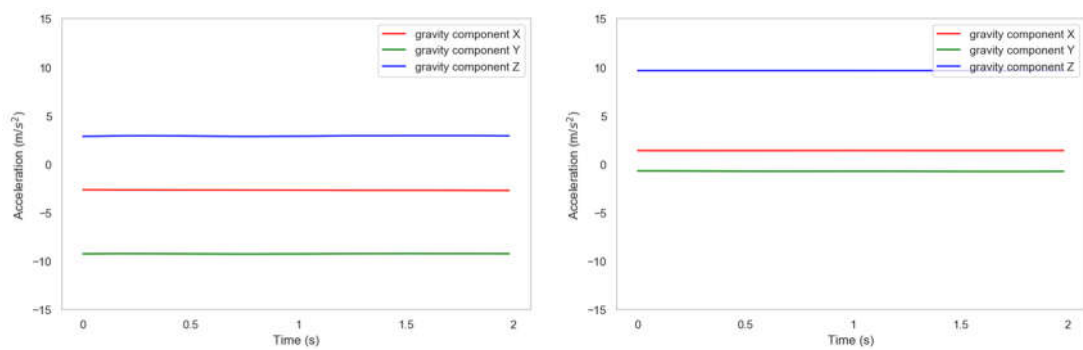


ภาพที่ 3-31 ตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมเคลื่อนไหวกับกิจกรรมแบบนั่ง

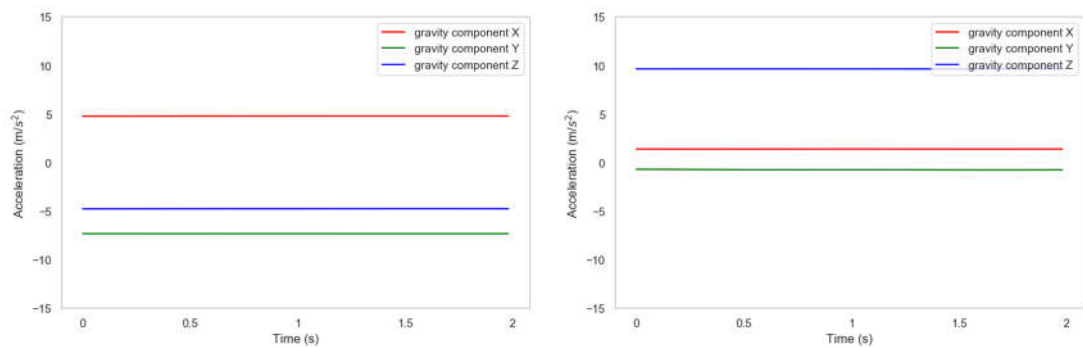
3.4.1.3 ขั้นตอนการสกัดคุณลักษณะของกิจกรรมหนึ่งและสร้างตัวแบบรู้จำด้วยขั้นตอนการจำแนกกลุ่มการวิเคราะห์การจำแนกประเภทเชิงเส้น ในการจำแนกกิจกรรมหนึ่งได้แก่การยืน, การนั่งและการนอน โดยนำกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงมาพิจารณาซึ่งมีลักษณะดังภาพที่ 3-32, 3-33 และ 3-34



ภาพที่ 3-32 แผนภูมิเส้นแสดงลักษณะกระแสดข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแนวแกน X, Y และ Z ของกิจกรรมยืนของผู้ใช้ที่ 1 และ 3 จากข้อมูลกิจกรรม RealworldHAR



ภาพที่ 3-33 แผนภูมิเส้นแสดงลักษณะกระแสดข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแนวแกน X, Y และ Z ของกิจกรรมนอนของผู้ใช้ที่ 1 และ 3 จากข้อมูลกิจกรรม RealworldHAR



ภาพที่ 3-34 แผนภูมิเส้นแสดงลักษณะกระแสดข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแนวแกน X, Y และ Z ของกิจกรรมนอนของผู้ใช้ที่ 1 และ 3 จากข้อมูลกิจกรรม RealworldHAR

จากภาพที่ 3-32, 3-33 และ 3-34 เห็นได้ว่ากระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงมีลักษณะเส้นตรงที่ไม่มี ความเร่งที่เกิดจากผู้ใช้งานเข้ามาเกี่ยวข้อง แต่จะค่าที่เกิดขึ้นในแต่ ขึ้นอยู่กับทิศทางและตำแหน่งของข้อมือที่ติดอุปกรณ์ ในเบื้องต้นสามารถสกัดคุณลักษณะค่าเฉลี่ย กระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงในแต่ละแกนดังสมการที่ 3.6 ถึง 3.7

$$Mean_{j(graX)}^{act} = \frac{\sum_{i=1}^N graX_i}{n} \quad (3.5)$$


$$Mean_{j(graY)}^{act} = \frac{\sum_{i=1}^N graY_i}{n} \quad (3.6)$$

$$Mean_{j(graZ)}^{act} = \frac{\sum_{i=1}^N graZ_i}{n} \quad (3.7)$$


โดยที่	$Mean_{j(graX)}^{act}, Mean_{j(graY)}^{act}, Mean_{j(graZ)}^{act}$	คือ ค่าเฉลี่ยของข้อมูลค่า ความเร่งที่เกิดจากแรงโน้มถ่วงแกน X, Y และ Z ของ Window ที่ j
$graX_i$		คือ ความเร่งที่เกิดจากแรงโน้มถ่วงแนวแกน X ที่ i
$graY_j$		คือ ความเร่งที่เกิดจากแรงโน้มถ่วงแนวแกน Y ที่ i
$graZ_i$		คือ ความเร่งที่เกิดจากแรงโน้มถ่วงแนวแกน Z ที่ i
n		คือ จำนวนข้อมูลทั้งหมดภายใน 1 window
i		คือ ค่าที่ใช้สำหรับระบุลำดับของข้อมูล โดยที่ $i = 1, 2, 3, \dots, n$
j		คือ ค่าที่ใช้สำหรับระบุลำดับของ window

เมื่อคำนวณการสกัดคุณลักษณะค่าเฉลี่ยในแต่ละ window ของแต่ละกิจกรรมหนึ่ง นำมาสร้างเป็นตัวแบบรู้จำกิจกรรมหนึ่งโดยขั้นตอนการจำแนกกลุ่มการวิเคราะห์การจำแนกประเภทเชิงเส้น (Linear Discriminant Analysis) โดยกำหนดให้ทำการโปรเจกชันจากสามมิติลงบนหนึ่งมิติที่ลดการกระจายกลุ่มย่อยของทั้งสามกิจกรรม


3.4.1.4 ขั้นตอนการสกัดคุณลักษณะของกิจกรรมเคลื่อนไหวและสร้างตัวแบบรู้จำด้วย ขั้นตอนการจำแนกกลุ่มซัพพอร์ตเวกเตอร์แมชชีน ในการจำแนกกิจกรรมหนึ่งได้แก่การเดิน, การเดิน ขึ้นบันไดและการเดินลงบันไดและการวิ่ง โดยในการจำแนกจากลักษณะกระแสข้อมูลเชิงเวลา ความเร่งเชิงเส้นแนวแกน X, แกน Y และแกน Z จาก Accelerometer และกระแสข้อมูลเชิงเวลา ความเร็วเชิงมุมแนวแกน X, แกน Y และแกน Z จาก Gyroscope ดังภาพที่ 3-35 และ 3-36




กิจกรรมการเดิน



กิจกรรมเดินขึ้นบันได




กิจกรรมเดินลงบันได




กิจกรรมวิ่ง


ภาพที่ 3-35 แผนภูมิเส้นลักษณะการเปลี่ยนค่าความเร่งเชิงเส้นของกลุ่มกิจกรรมเคลื่อนไหวจากข้อมูลกิจกรรม RealworldHAR




กิจกรรมการเดิน



กิจกรรมเดินขึ้นบันได



กิจกรรมเดินลงบันได



กิจกรรมวิ่ง

ภาพที่ 3-36 แผนภูมิเส้นลักษณะการเปลี่ยนค่าความเร็วเชิงมุมของกลุ่มกิจกรรมเคลื่อนไหวจากข้อมูลกิจกรรม RealworldHAR

จากภาพที่ 3-35 และ 3-36 จะนำข้อมูลกระแสข้อมูลเชิงเวลาทั้งสองแรงในแต่ละแกนสกัดคุณลักษณะได้แก่ ค่าเฉลี่ยกำลังสอง (Root Mean Square) ค่าความเบ้ (Skewness) และพิสัยระหว่างควอร์ไทล์ (Interquartile range) โดยมีขั้นตอนวิธีดังสมการที่ 3.8 ถึง 3.10

$$RMS_{j(x)}^{act} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (3.8)$$

$$RMS_{j(y)}^{act} = \sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2} \quad (3.9)$$

$$RMS_{j(z)}^{act} = \sqrt{\frac{1}{n} \sum_{i=1}^n z_i^2} \quad (3.10)$$

โดยที่ $RMS_{j(x)}^{act}, RMS_{j(y)}^{act}, RMS_{j(z)}^{act}$ คือ ค่าเฉลี่ยกำลังสองแนวแกน X, Y และ Z ของ window ที่ j

x_i คือ ค่าแนวแกน X ที่ i

y_j คือ ค่าแนวแกน Y ที่ i

z_i คือ ค่าแนวแกน Z ที่ i

n คือ จำนวนข้อมูลทั้งหมดภายใน 1 window

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

j คือ ค่าที่ใช้สำหรับระบุลำดับของ Window

$$Skew_{j(x)}^{act} = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_j)^3}{\left(\frac{1}{N} \sum_{i=1}^n (X_i - \bar{X}_j)^2\right)^3} \quad (3.11)$$

$$Skew_{j(y)}^{act} = \frac{\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_j)^3}{\left(\frac{1}{N} \sum_{i=1}^n (Y_i - \bar{Y}_j)^2\right)^3} \quad (3.12)$$

$$Skew_{j(z)}^{act} = \frac{\frac{1}{n} \sum_{i=1}^n (Z_i - \bar{Z}_j)^3}{\left(\frac{1}{N} \sum_{i=1}^n (Z_i - \bar{Z}_j)^2\right)^3} \quad (3.13)$$

โดยที่ $Skew_{j(x)}^{act}, Skew_{j(y)}^{act}, Skew_{j(z)}^{act}$ คือ ค่าความเบ้แนวแกน X, Y และ Z ของ window ที่ j

X_i คือ ค่าแนวแกน X ที่ i

Y_i คือ ค่าแนวแกน Y ที่ i

Z_i คือ ค่าแนวแกน Z ที่ i

\bar{X}_j	คือ ค่าเฉลี่ยแนวแกน X ของ window ที่ j
\bar{Y}_j	คือ ค่าเฉลี่ยแนวแกน Y ของ window ที่ j
\bar{Z}_j	คือ ค่าเฉลี่ยแนวแกน Z ของ window ที่ j
n	คือ จำนวนข้อมูลทั้งหมดภายใน 1 window
i	คือ ค่าที่ใช้สำหรับระบุลำดับของข้อมูล โดยที่ $i = 1, 2, 3, \dots, n$
j	คือ ค่าที่ใช้สำหรับระบุลำดับของ Window

$$IQR_{j(X)}^{act} = Q3_{j(X)}^{act} - Q1_{j(X)}^{act} \quad (3.14)$$

$$IQR_{j(Y)}^{act} = Q3_{j(Y)}^{act} - Q1_{j(Y)}^{act} \quad (3.15)$$

$$IQR_{j(Z)}^{act} = Q3_{j(Z)}^{act} - Q1_{j(Z)}^{act} \quad (3.16)$$

โดยที่ $IQR_{j(X)}^{act}, IQR_{j(Y)}^{act}, IQR_{j(Z)}^{act}$ คือ ค่าพิสัยระหว่างควอร์ไทล์แนวแกน X, Y และ Z ของ window ที่ j

$Q3_{j(X)}^{act}$	คือ ค่า ณ ตำแหน่งควอไทล์ขอบเขตบนแนวแกน X ที่ j
$Q3_{j(Y)}^{act}$	คือ ค่า ณ ตำแหน่งควอไทล์ขอบเขตบนแนวแกน Y ที่ j
$Q3_{j(Z)}^{act}$	คือ ค่า ณ ตำแหน่งควอไทล์ขอบเขตบนแนวแกน Z ที่ j
$Q1_{j(X)}^{act}$	คือ ค่า ณ ตำแหน่งควอไทล์ขอบเขตล่างแนวแกน X ที่ j
$Q1_{j(Y)}^{act}$	คือ ค่า ณ ตำแหน่งควอไทล์ขอบเขตล่างแนวแกน Y ที่ j
$Q1_{j(Z)}^{act}$	คือ ค่า ณ ตำแหน่งควอไทล์ขอบเขตล่างแนวแกน Z ที่ j
j	คือ ค่าที่ใช้สำหรับระบุลำดับของ Window

เมื่อกำหนดการสกัดคุณลักษณะสามคุณลักษณะในแต่ละ Window ของแต่ละกิจกรรมเคลื่อนไหว นำมาสร้างเป็นตัวแบบรู้จำกิจกรรมเคลื่อนไหว โดยขั้นตอนการจำแนกกลุ่มซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) โดยกำหนดใช้ฟังก์ชัน Kernel เท่ากับ Radial Basis Function (RBF)

3.4.2 ขั้นตอนรู้จำกิจกรรม (Recognition phase)

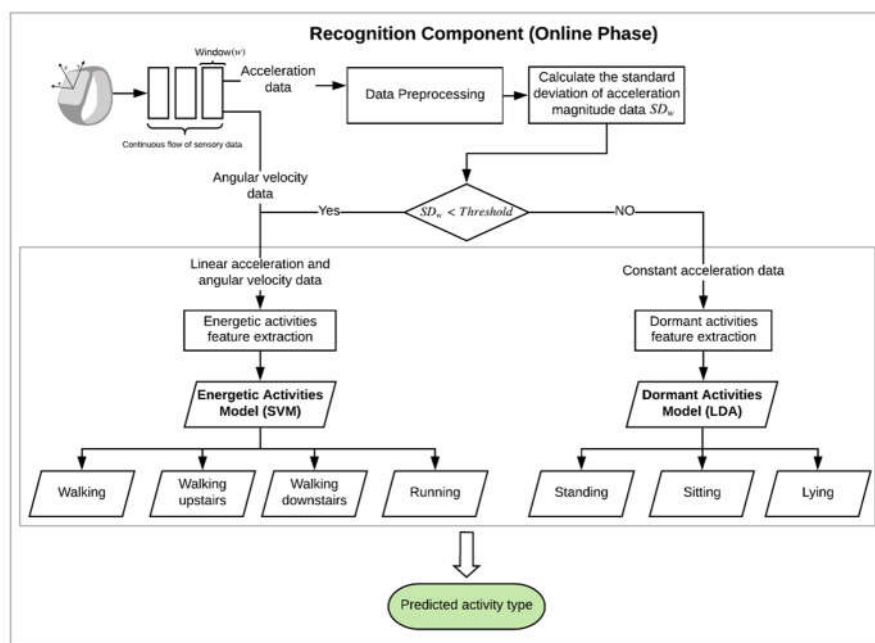
ในขั้นตอนนี้เป็นขั้นตอนรู้จำกิจกรรมจากกระแสข้อมูลเชิงเวลาของตัวรับรู้ Accelerometer และ Gyroscope ซึ่งกระแสข้อมูลเชิงเวลาที่ได้รับจากตัวรับรู้ถูกสร้างขึ้นตามอัตราการสุ่มตัวอย่างในแต่ละวินาทีต่อเนื่องกัน ดังนั้นงานวิจัยนี้จึงมีการแบ่งการคำนวณกระแสข้อมูลเชิงเวลาออกเป็น Window ที่กำหนดขนาดเท่ากับอัตราการสุ่มตัวอย่างของอุปกรณ์เป็นเวลา 2 วินาที ซึ่งมีขั้นตอนการทำงานดังภาพที่ 3-37 ซึ่งกระแสข้อมูลเชิงเวลาจาก Accelerometer ในแต่ละ Window จะนำมาแยกเป็นค่าความเร่งเส้นตรงที่เกิดจากผู้ใช้งานและค่าความเร่งเส้นตรงที่เกิดจาก

แรงโน้มถ่วงเช่นเดียวกันกับขั้นตอนการเตรียมข้อมูลในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมจากนั้นคำนวณส่วนเบี่ยงเบนมาตรฐานจากค่าขนาดของความเร่งที่นำการเปรียบเทียบกับค่าขีดแบ่ง ถ้าหากส่วนเบี่ยงเบนมาตรฐานของค่าความเร่งจาก Accelerometer มีค่ามากกว่าค่าขีดแบ่งแสดงว่าข้อมูลที่เข้ามาเป็นกิจกรรมเคลื่อนไหวแต่ถ้าน้อยกว่าค่าขีดแบ่งแสดงว่าข้อมูลเป็นกิจกรรมนิ่ง

3.4.2.1 ขั้นตอนการแบ่งประเภทกิจกรรมด้วยค่าขีดแบ่ง ในขั้นตอนนี้จะทำการแบ่งประเภทของกิจกรรมว่าเป็นกิจกรรมนิ่งหรือเคลื่อนไหว ซึ่งนำค่าความเร่งจาก Accelerometer ภายใน Window คำนวณหาค่าส่วนเบี่ยงเบนมาตรฐานของขนาดของความเร่ง (Magnitude) ที่นำไปเปรียบเทียบกับค่าขีดแบ่งที่สร้างไว้โดยมีเกณฑ์ดังนี้

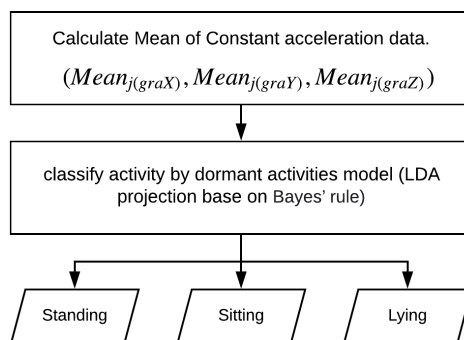
ถ้า $SD_{j(mag)} > Threshold$ แสดงว่าข้อมูลจะเป็นกิจกรรมแบบเคลื่อนไหว

แต่ถ้า $SD_{j(mag)} < Threshold$ แสดงว่าข้อมูลเป็นกิจกรรมนิ่ง



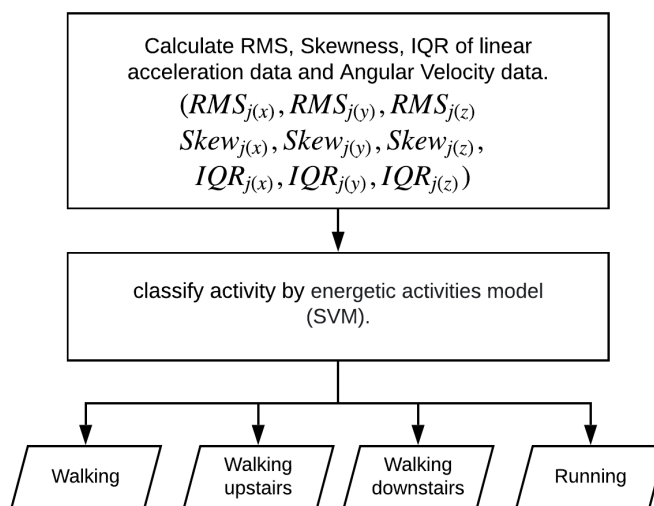
ภาพที่ 3-37 ขั้นตอนรู้จำกิจกรรมของวิธีการ S-PAR

3.4.2.2 ขั้นตอนการรู้จำกิจกรรมนิ่ง ขั้นตอนนี้เป็นการรู้จำกิจกรรมที่มีการขยับร่างกายน้อยได้แก่ การยืน, การนั่งและการนอน โดยทำการสกัดคุณลักษณะค่าเฉลี่ยในแต่ละแกนจากกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วง นำมาผ่านขั้นตอนการจำแนกกลุ่มการวิเคราะห์การจำแนกประเภทเชิงเส้นในการรู้จำกิจกรรมนิ่งที่สร้างในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม ดังภาพที่ 3-38



ภาพที่ 3-38 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบนิ่ง

3.4.2.3 ขั้นตอนการรู้จำกิจกรรมเคลื่อนไหว ขั้นตอนนี้เป็นการรู้จำกิจกรรมหมายถึงที่มีการเคลื่อนไหวของร่างกายได้แก่ การเดิน, การเดินขึ้นบันได, การเดินลงบันไดและการวิ่ง โดยทำการสกัดคุณลักษณะค่าเฉลี่ยกำลังสอง, ความเบ้และพิสัยระหว่างควอร์ไทล์จากกระแสข้อมูลเชิงเวลา ความเร่งเชิงเส้นจาก Accelerometer และกระแสข้อมูลเชิงเวลาอัตราเร่งเชิงมุมจาก Gyroscope นำมาผ่านขั้นตอนซัพพอร์ตเวกเตอร์แมชชีนในการรู้จำกิจกรรมเคลื่อนไหวที่สร้างในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม ดังภาพที่ 3-39



ภาพที่ 3-39 การระบุกิจกรรมในขั้นตอนการรู้จำกิจกรรมแบบเคลื่อนไหว

บทที่ 4 ผลการดำเนินงานวิจัย

ในบทนี้จะกล่าวถึงผลการดำเนินงานโดยการวัดประสิทธิภาพความถูกต้องและเวลาที่ใช้ในขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนการรู้จำกิจกรรมของวิธีการที่นำเสนอทั้ง 3 วิธีการ คือ ISAR, ISAR+ และ SPAR 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 WISDM¹⁷

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

ตารางที่ 4-1 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ WISDM

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

¹⁷ <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 4-1 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 27 จากข้อมูล WISDM

4.1.2 ข้อมูล UniMiB-SHAR¹⁸

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

ตารางที่ 4-2 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ UniMiB-SHAR

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

¹⁸ <http://www.sal.disco.unimib.it/technologies/unimib-shar>

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

4.1.3 ข้อมูลกิจกรรม Complex human activities dataset

ข้อมูลกิจกรรมนี้เป็นข้อมูลออนไลน์สาธารณะ ซึ่งเก็บกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope จากอุปกรณ์สมาร์ทโฟน Samsung Galaxy S2 ที่ติดบนข้อมือ ด้านขวาที่กำหนดอัตราสุ่มตัวอย่างของข้อมูลเท่ากับ 50 Hz โดยบันทึกการทำกิจกรรมทางกายภาพของอาสาสมัครจำนวน 10 คนทั้งหมด 6 กิจกรรมได้แก่ การยืน การนั่ง การเดิน การเดินขึ้นบันได การเดินลงบันไดและการวิ่ง ซึ่งมีจำนวนตัวอย่างข้อมูลในแต่ละกิจกรรมดังตารางที่ 4-3 และมีตัวอย่างข้อมูลกิจกรรมดังภาพที่ 4-3

ตารางที่ 4-3 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ Complex human activities dataset

กิจกรรม	จำนวนตัวอย่าง (Record)
การยืน	90,000
การนั่ง	90,000
การเดิน	90,000
การเดินขึ้นบันได	90,000
การเดินลงบันได	90,000
การวิ่ง	90,000

Sample	Class	User	Timestamp	A_x	A_y	A_z	G_x	G_y	G_z
s_1	Walking	1	1.39E+12	3.21	-12.69	1.51	-1.79	2.62	-1.37
s_1	Walking	1	1.39E+12	3.92	-10.48	0.87	-1.78	3.54	-1.33
s_1	Walking	1	1.39E+12	2.59	-10.37	2.72	-3.26	5.07	-1.12
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Walking	1	\vdots	A_{x_i}	A_{y_i}	A_{z_i}	G_{x_i}	G_{y_i}	G_{z_i}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	Walking	1	\vdots	A_{x_N}	A_{y_N}	A_{z_N}	G_{x_N}	G_{y_N}	G_{z_N}

ภาพที่ 4-3 ตัวอย่างข้อมูลกิจกรรมการเดินของผู้ใช้หมายเลข 1 จากข้อมูลกิจกรรม Complex human activities dataset

4.1.1 ข้อมูลกิจกรรม RealworldHAR

ข้อมูลกิจกรรมนี้เป็นข้อมูลออนไลน์สาธารณะ ซึ่งเก็บกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope จากอุปกรณ์นาฬิกาอัจฉริยะ LG G Watch R ที่กำหนดอัตราสุ่มตัวอย่างของข้อมูลเท่ากับ 50 Hz โดยบันทึกการทำกิจกรรมทางกายภาพของอาสาสมัครจำนวน 15 คนโดยในการทดลองนี้ได้เลือกใช้ข้อมูลการทำกิจกรรมของผู้ใช้จำนวน 10 คนที่ทำกิจกรรมครบทั้งหมด 7 กิจกรรมได้แก่ การยืน, การนั่ง, การนอน, การเดิน, การเดินขึ้นบันได, การเดินลงบันไดและการวิ่ง ซึ่งมีจำนวนตัวอย่างข้อมูลในแต่ละกิจกรรมดังตารางที่ 4-4 และมีตัวอย่างข้อมูลกิจกรรมดังภาพที่ 4-4

ตารางที่ 4-4 จำนวนข้อมูลกิจกรรมแต่ละกิจกรรมของ RealworldHAR

กิจกรรม	จำนวนตัวอย่าง (Record)
การยืน	155,788
การนั่ง	138,063
การนอน	142,316
การเดินขึ้นบันได	138,409
การเดินลงบันได	116,806
การวิ่ง	153,089

Sample	Class	User	Timestamp	A_x	A_y	A_z	G_x	G_y	G_z
s_1	Standing	9	1435991672020	-9.48	-2.26	1.53	-0.02	0.00	0.01
s_2	Standing	9	1435991672042	-9.49	-2.27	1.54	-0.03	0.00	0.01
s_3	Standing	9	1435991672061	-9.50	-2.33	1.53	-0.02	0.00	0.01
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Standing	9	\vdots	A_{x_i}	A_{y_i}	A_{z_i}	G_{x_i}	G_{y_i}	G_{z_i}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_N	Standing	9	\vdots	A_{x_N}	A_{y_N}	A_{z_N}	G_{x_N}	G_{y_N}	G_{z_N}

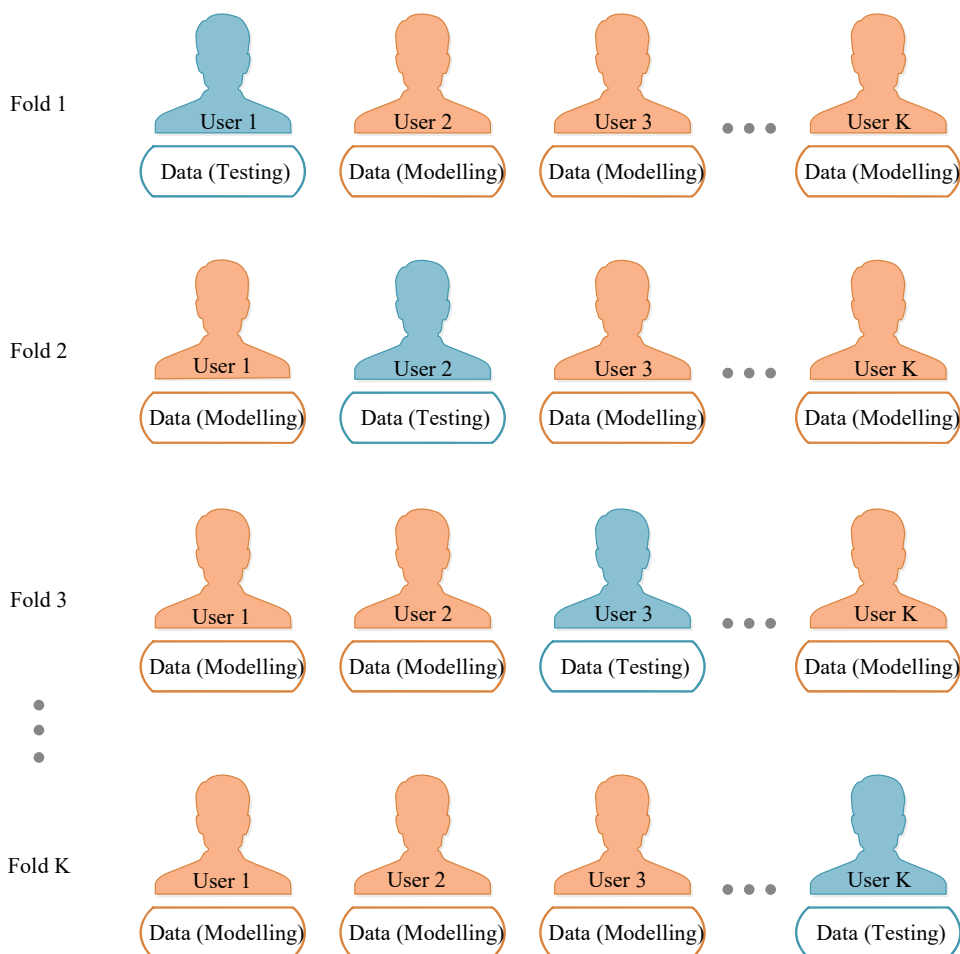
ภาพที่ 4-4 ตัวอย่างข้อมูลกิจกรรมการยืนของผู้ใช้หมายเลข 9 จากข้อมูลกิจกรรม RealworldHAR

4.2 การออกแบบการทดลองและวิธีการที่ใช้วัดประสิทธิภาพตัวแบบรู้จำกิจกรรม

สำหรับการออกแบบการทดลองในงานวิจัยนี้ได้ใช้วิธีการแบ่งข้อมูล และวิธีการวัดประสิทธิภาพของตัวแบบรู้จำกิจกรรม ดังนี้

4.2.1 ขั้นตอนการแบ่งข้อมูลสำหรับสร้างตัวแบบรู้จำกิจกรรมและข้อมูลทดสอบตัวแบบรู้จำกิจกรรม

งานวิจัยนี้ได้ใช้วิธี K-Fold Cross Validation สำหรับแบ่งข้อมูลกิจกรรมเพื่อใช้สร้างตัวแบบรู้จำกิจกรรมและใช้ทดสอบตัวแบบรู้จำกิจกรรม โดยจะแบ่งข้อมูลกิจกรรมออกเป็น K ชุด ซึ่งกำหนดให้ K แทนจำนวนของผู้ใช้ ข้อมูล 1 ชุดคือข้อมูลกิจกรรมของผู้ใช้ 1 คน การเลือกข้อมูลกิจกรรมชุดใดสร้างตัวแบบรู้จำกิจกรรมและชุดใดใช้ทดสอบตัวแบบรู้จำกิจกรรม มีรายละเอียดดังภาพที่ 4-5



ภาพที่ 4-5 ตัวอย่างการแบ่งข้อมูลกิจกรรมสำหรับสร้างและทดสอบตัวแบบรู้จำกิจกรรมด้วยวิธี K-Fold Cross Validation

จากภาพที่ 4-5 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 และไม่เป็นกิจกรรมที่กำลังพิจารณา

4.3 การวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมของวิธีการ ISAR และ ISAR+

การทดลองในงานวิจัยนี้ได้เปรียบเทียบวิธีการที่นำเสนอ 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 4-5 ถึง 4-7 สามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Precision, Recall และ F-measure แสดงดังภาพที่ 4-6 ถึง 4-8 จะเห็นว่าวิธีการ ISAR+ มีประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมที่ดีที่สุดในทุก ๆ กิจกรรม โดยเฉพาะอย่างยิ่งกิจกรรมการนั่ง การยืน และการวิ่ง ที่มีค่าความถูกต้องและความแม่นยำมากกว่า 90 เปอร์เซ็นต์ และเหตุผลที่วิธีการ ISAR ที่มีค่าความถูกต้องและแม่นยำของการรู้จำกิจกรรมการนั่งและการยืนเท่ากับวิธีการ ISAR+ เนื่องจากทั้ง 2 วิธีมีขั้นตอนการรู้จำกิจกรรมแบบนิ่ง (Dormant activities) ที่เหมือนกัน

ตารางที่ 4-5 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 4-6 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 4-7 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 4-6 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM



ภาพที่ 4-7 แผนภูมิแท่งเปรียบเทียบ Recall ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูลกิจกรรม WISDM



ภาพที่ 4-8 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 4-8 ถึง 4-10 สามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Precision, Recall และ F-measure แสดงดังภาพที่ 4-9 ถึง 4-11 จะเห็นว่าวิธีการ ISAR+ มีประสิทธิภาพทั้งความถูกต้องและความแม่นยำของการรู้จำกิจกรรมที่ดีที่สุดในทุก ๆ กิจกรรม โดยเฉพาะอย่างยิ่งกิจกรรมการนั่ง การยืน และการวิ่ง ที่มีค่าความถูกต้องและความแม่นยำมากกว่า 90 เปอร์เซ็นต์

ตารางที่ 4-8 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 4-9 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 4-10 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 4-9 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR



ภาพที่ 4-10 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR



ภาพที่ 4-11 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR

4.4 การวัดประสิทธิภาพด้านเวลาของการรู้จำกิจกรรมของวิธีการ ISAR และ ISAR+


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 $O(KNI)$ โดยที่ K คือ จำนวนกลุ่มในการแบ่งกลุ่มข้อมูล N คือ จำนวนตัวอย่างข้อมูลทั้งหมดของแต่ละกิจกรรม และ I 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+ ในขั้นตอนสร้างตัวแบบรู้จำกิจกรรมไม่มีการแบ่งกลุ่มข้อมูลแต่มีการแปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐาน ความโด่ง ความหนาแน่น ซึ่งมีความซับซ้อนเชิงเวลาคือ $O(N)$ ในขั้นตอนการรู้จำกิจกรรมวิธีการ ISAR+ ใช้เพียง 1 มาตรวัดในการระบุกิจกรรมเช่นเดียวกับวิธีการ ISAR ดังนั้นจึงมีความซับซ้อนเชิงเวลาคือ $O(n)$ และขั้นตอนการปรับปรุงตัวแบบรู้จำกิจกรรม

วิธีการ ISAR+ ได้พิจารณาค่าส่วนเบี่ยงเบนมาตรฐาน ค่าความโด่งและค่าความหนาแน่นของข้อมูลภายใน window จึงมีความซับซ้อนเชิงเวลา คือ $O(n)$ แสดงดังตารางที่ 4-11


ตารางที่ 4-11 ความซับซ้อนเชิงเวลาของวิธีการ ISAR, ISAR+ และ STAR

วิธีการ	ขั้นตอนสร้างตัวแบบ รู้จำกิจกรรม	ขั้นตอนรู้จำกิจกรรม	ขั้นตอนปรับปรุงตัว แบบรู้จำกิจกรรม
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 4-11 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 4-12 และ 4-13



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




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


จากภาพที่ 4-12 และ 4-13 จะเห็นว่าเวลาที่ใช้ในการสร้างตัวแบบรู้จำกิจกรรมกับข้อมูลกิจกรรม WISDM และ UniMiB-SHAR มีแนวโน้มไปในทิศทางเดียวกันนั่นคือ วิธีการ STAR จะใช้เวลาค่อนข้างมากเนื่องจากจำเป็นต้องนำข้อมูลกิจกรรมทั้งหมดไปแบ่งกลุ่ม ยังมีจำนวนตัวอย่างข้อมูลกิจกรรมมากก็ยิ่งใช้เวลามากขึ้นอย่างเห็นได้ชัดเจน ต่อมาวิธีการ ISAR ซึ่งมีขั้นตอนการแบ่งกลุ่มข้อมูลเหมือนกัน แต่ใช้เวลาน้อยกว่าวิธีการ STAR เนื่องจากได้แปลงข้อมูลกิจกรรมเป็นข้อมูลส่วนเบี่ยงเบนมาตรฐานแล้วจึงนำไปแบ่งกลุ่มที่หลัง (ข้อมูลกิจกรรม 1 window แปลงเป็นข้อมูลส่วนเบี่ยงเบน

มาตรฐานได้ 1 ตัวอย่าง) ข้อมูลส่วนเบี่ยงเบนมาตรฐานมีจำนวนน้อยกว่าข้อมูลกิจกรรมมาก จึงคำนวณได้เร็วกว่าวิธีการ STAR ส่วนวิธีการ ISAR+ ไม่มีการแบ่งกลุ่มข้อมูล จึงทำให้ใช้เวลาในการคำนวณน้อยที่สุด

สำหรับเวลาที่ใช้ในการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมของวิธีการ ISAR, ISAR+ และ STAR จะทำการทดสอบร่วมกัน เนื่องจากขั้นตอนทั้งสองทำงานต่อเนื่องกัน โดยพิจารณาเวลาที่ใช้ในการรู้จำกิจกรรมในแต่ละ window แสดงดังภาพที่ 4-14 และ 4-15 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 4-14 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล WISDM



ภาพที่ 4-15 แผนภูมิเส้นเปรียบเทียบเวลาในการคำนวณขั้นตอนการรู้จำกิจกรรมและการปรับปรุงตัวแบบรู้จำกิจกรรมระหว่างวิธีการ ISAR, ISAR+ และ STAR ด้วยข้อมูล UniMiB-SHAR

4.5 การวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมของวิธีการ S-PAR

การทดลองในงานวิจัยนี้ได้เปรียบเทียบวิธีการที่นำเสนอ Smartwatch-based Physical Activity Recognition (S-PAR) และวิธีการขั้นตอนรู้จำกิจกรรมจากงานวิจัย Da Silva และ Galeazzo (2013) ได้นำเสนอขั้นตอนสร้างและเรียนรู้จำกิจกรรมจากกระแสข้อมูลเชิงเวลาจาก Accelerometer ที่แบ่งออกเป็นสองโครงสร้างได้แก่ โครงสร้างที่ 1 (Architecture 1) เป็นการใชตัวแบบรู้จำกิจกรรมหนึ่งตัวและโครงสร้างที่ 2 (Architecture 2) มีการแบ่งตัวแบบรู้จำกิจกรรมออกเป็นสองประเภทได้กิจกรรมเคลื่อนไหว (Dynamic) และกิจกรรมนิ่ง (Postural) และงานวิจัย Shoib และคณะ (2015) ได้นำเสนอขั้นตอนการรู้จำกิจกรรมจากกระแสข้อมูลเชิงเวลาจาก Accelerometer และ Gyroscope จากนาฬิกาอัจฉริยะ กับข้อมูลกิจกรรม Complex human activities dataset และข้อมูล RealWorldHAR โดยจะเปรียบเทียบประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรม ซึ่งมีรายละเอียดผลการทดลองดังต่อไปนี้

4.5.1 ผลการทดลองกับข้อมูลกิจกรรม Complex human activities dataset

การรู้จำกิจกรรมด้วยวิธีการ S-PAR, งานวิจัย Da Silva และ Galeazzo (2013) และงานวิจัย Shoib และคณะ (2015) กับข้อมูลกิจกรรม Complex human activities dataset แสดงผลลัพธ์ดังตารางที่ 4-12 ถึง 4-15 และสามารถผลการทดลองเปรียบเทียบแสดงอยู่ในรูปแผนภูมิเปรียบเทียบ Precision, Recall และ F-measure ดังภาพที่ 4-16 ถึง 4-17 จะเห็นได้ว่าวิธีการ S-PAR มีประสิทธิภาพในรู้จำกิจกรรมกิจกรรมนิ่งมีความถูกต้องและแม่นยำใกล้เคียงกับงานวิจัยที่นำมาเปรียบเทียบและสามารถรู้จำกิจกรรมเคลื่อนไหวโดยภาพรวมประสิทธิภาพในการรู้จำกิจกรรมมีค่า

ความถูกต้องและแม่นยำสูงกว่างานวิจัยที่นำมาเปรียบเทียบในกิจกรรมการเดินและการเดินขึ้นบันได และการรู้จำกิจกรรมวิ่งมีค่าความถูกต้องและความแม่นยำที่ใกล้เคียงกัน

ตารางที่ 4-12 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 1 กับข้อมูลกิจกรรม Complex human activities dataset.

		Prediction activities					
		Standing	Sitting	Walking	Walking Upstairs	Walking Downstairs	Running
Actual activities	Standing	1370	4	1	2	10	3
	Sitting	2	1384	0	0	1	3
	Walking	92	0	850	87	361	0
	Walking Upstairs	8	0	334	418	630	0
	Walking Downstairs	11	1	32	5	1339	2
	Running	9	0	0	0	2	1379

ตารางที่ 4-13 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 1 กับข้อมูลกิจกรรม Complex human activities dataset

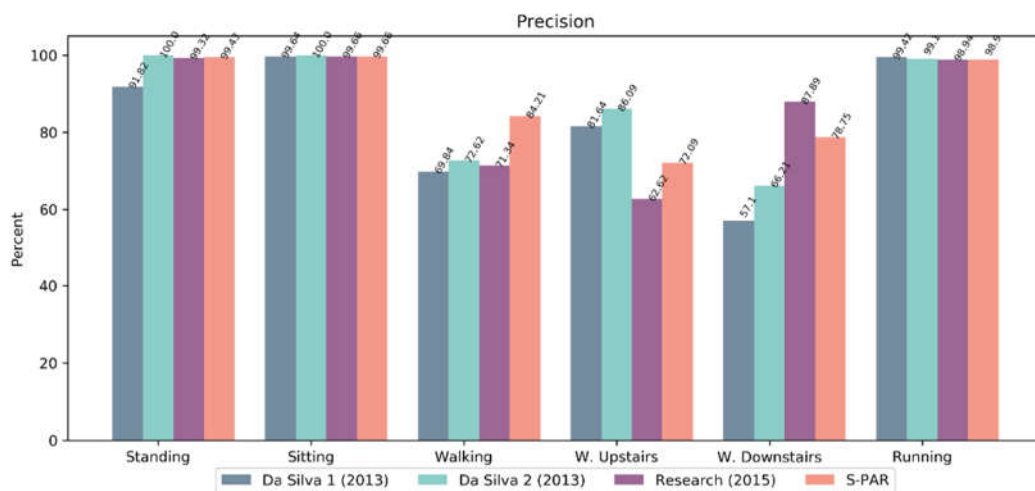
		Prediction activities					
		Standing	Sitting	Walking	Walking Upstairs	Walking Downstairs	Running
Actual activities	Standing	1356	0	6	5	18	5
	Sitting	0	1357	1	3	25	4
	Walking	0	0	1072	71	247	0
	Walking Upstairs	0	0	346	687	357	0
	Walking Downstairs	0	0	50	32	1305	3
	Running	0	0	0	0	19	1371

ตารางที่ 4-14 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของ Shoaib และคณะ (2015) กับ ข้อมูลกิจกรรม Complex human activities dataset

		Prediction activities					
		Standing	Sitting	Walking	Walking Upstairs	Walking Downstairs	Running
Actual activities	Standing	1775	2	1	1	10	1
	Sitting	2	1784	0	0	0	0
	Walking	0	0	1011	714	64	1
	Walking Upstairs	1	0	312	1336	136	5
	Walking Downstairs	9	0	93	81	1597	10
	Running	0	1	0	0	4	1785

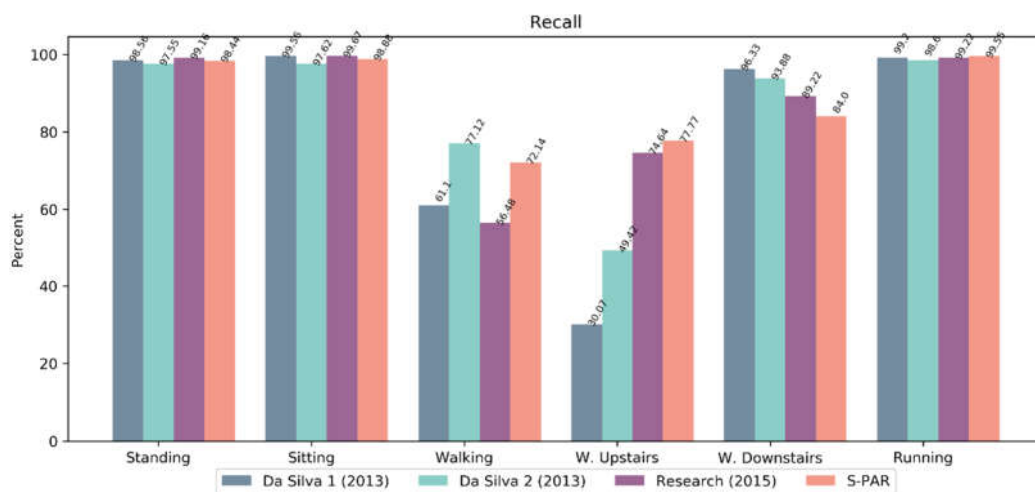
ตารางที่ 4-15 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของ S-PAR กับ ข้อมูลกิจกรรม Complex human activities dataset

		Prediction activities					
		Standing	Sitting	Walking	Walking Upstairs	Walking Downstairs	Running
Actual activities	Standing	886	3	2	1	7	1
	Sitting	0	890	1	1	8	0
	Walking	1	0	656	174	69	0
	Walking Upstairs	1	0	82	700	117	0
	Walking Downstairs	3	0	37	95	756	9
	Running	0	0	1	0	3	896




ภาพที่ 4-16 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการของ Da Silva และ Galeazzo (2013) กับวิธีที่นำเสนอด้วยข้อมูลกิจกรรม Complex Human Activities Dataset

\



ภาพที่ 4-17 แผนภูมิแท่งเปรียบเทียบ Recall ระหว่างวิธีการของ Da Silva และ Galeazzo (2013) กับวิธีที่นำเสนอด้วยข้อมูลกิจกรรม Complex Human Activities Dataset



ภาพที่ 4-18 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการของ Da Silva และ Galeazzo (2013) กับวิธีการที่นำเสนอด้วยข้อมูลกิจกรรม Complex Human Activities Dataset

4.5.2 ผลการทดลองกับข้อมูลกิจกรรม RealworldHAR

การรู้จำกิจกรรมด้วยวิธีการ S-PAR, งานวิจัย Da Silva และ Galeazzo (2013) และงานวิจัย Shoaib และคณะ (2015) กับข้อมูลกิจกรรม RealworldHAR แสดงผลลัพธ์ดังตารางที่ 4-16 ถึง 4-18 และผลการทดลองเปรียบเทียบแสดงอยู่ในรูปแผนภูมิเปรียบเทียบ Precision, Recall และ F-measure ดังภาพที่ 4-19 ถึง 4-21 จะเห็นได้ว่าวิธีการ S-PAR มีประสิทธิภาพในรู้จำกิจกรรมกิจกรรมหนึ่งที่มีความถูกต้องและความแม่นยำของกิจกรรมสูงกว่างานที่นำมาเปรียบเทียบโดยเฉพาะกิจกรรมนอน และกิจกรรมเคลื่อนไหวสามารถรู้จำกิจกรรมที่เป็นลักษณะการเดินได้แก่ การเดิน, การเดินขึ้นบันไดและการเดินลงบันไดได้ดีกว่าตีกว่างานที่นำมาเปรียบเทียบ

ตารางที่ 4-16 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 1 กับข้อมูลกิจกรรม RealworldHAR


		Prediction activities						
		Standing	Sitting	Lying	Walking	Walking Upstairs	Walking Downstairs	Running
Actual activities	Standing	1943	288	63	31	66	38	4
	Sitting	112	1529	523	12	76	4	3
	Walking	192	591	1506	5	23	14	4
	Lying	64	62	1	1498	323	269	5
	Walking Upstairs	57	93	11	529	811	422	5
	Walking Downstairs	35	16	4	1222	247	1459	7
	Running	285	67	15	12	28	16	2033

ตารางที่ 4-17 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของงานวิจัย Da Silva และ Galeazzo (2013) ที่ 2 กับข้อมูลกิจกรรม RealworldHAR


		Prediction activities						
		Standing	Sitting	Lying	Walking	Walking Upstairs	Walking Downstairs	Running
Actual activities	Standing	1873	266	48	19	93	22	112
	Sitting	69	1469	455	20	111	1	134
	Walking	226	533	1465	11	44	8	48
	Lying	43	1	0	1700	252	114	112
	Walking Upstairs	33	52	6	683	842	217	95
	Walking Downstairs	27	10	0	345	408	1086	134
	Running	234	43	11	8	50	9	2101

ตารางที่ 4-18 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของ S-PAR กับข้อมูลกิจกรรม RealworldHAR


		Prediction activities						
		Standing	Sitting	Lying	Walking	Walking Upstairs	Walking Downstairs	Running
Actual activities	Standing	1246	155	53	6	35	14	52
	Sitting	107	1021	199	3	59	11	51
	Walking	108	271	1083	6	20	5	7
	Lying	22	0	0	965	309	117	13
	Walking Upstairs	27	40	13	348	633	166	12
	Walking Downstairs	222	4	0	91	187	898	11
	Running	156	26	12	2	30	11	1339



ภาพที่ 4-19 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการของ Da Silva และ Galeazzo (2013), งานวิจัย Shaiob และคณะ (2015) และ S-PAR ด้วยข้อมูลกิจกรรม RealworldHAR



ภาพที่ 4-20 แผนภูมิแท่งเปรียบเทียบ Precision ระหว่างวิธีการของ Da Silva และ Galeazzo (2013), งานวิจัย Shaiob และคณะ (2015) และ S-PAR ด้วยข้อมูลกิจกรรม RealworldHAR



ภาพที่ 4-21 แผนภูมิแท่งเปรียบเทียบ F-measure ระหว่างวิธีการของ Da Silva และ Galeazzo (2013), งานวิจัย Shaiob และคณะ (2015) และ S-PAR ด้วยข้อมูลกิจกรรม RealworldHAR

บทที่ 5

สรุปผลการดำเนินงานและข้อเสนอแนะ

สำหรับงานวิจัยนี้ ผู้จัดทำงานวิจัยจะกล่าวถึงการสรุปและวิจารณ์ผลการดำเนินโครงการ ได้แก่ การสรุปผลการทดลอง และการวิจารณ์เกี่ยวกับข้อดี ข้อบกพร่องและรวมถึงข้อเสนอแนะของงานวิจัย

5.1 สรุปผลการดำเนินงาน

5.1.1 ผลการดำเนินงานสำหรับวิธีการ ISAR และ ISAR+ ที่ทดลองกับข้อมูลจากอุปกรณ์สมาร์ตโฟน


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

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

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


จากผลการทดลองที่นำเสนอในงานวิจัยนี้กับข้อมูล WISDM โดยใช้วิธีการวัดประสิทธิภาพตัวแบบรู้จำกิจกรรมด้วยวิธี Precision สำหรับวัดความแม่นยำของตัวแบบรู้จำกิจกรรม Recall สำหรับวัดความถูกต้องของตัวแบบรู้จำกิจกรรมและ F-measure ซึ่งเป็นค่าเฉลี่ยระหว่างความแม่นยำและความถูกต้องของตัวแบบรู้จำกิจกรรม แสดงดังภาพที่ 5-1 โดยเมื่อพิจารณาทุกกิจกรรมรวมกัน วิธีการ ISAR+ มีค่าความแม่นยำเท่ากับ 87.57% ค่าความถูกต้องเท่ากับ 87.14% และค่าเฉลี่ยความ

ถูกต้องและแม่นยำเท่ากับ 87.31% เช่นเดียวกับผลการทดลองด้วยข้อมูลกิจกรรม UniMiB-SHAR แสดงดังภาพที่ 5-2 วิธีการ ISAR+ มีค่าความแม่นยำเท่ากับ 89.05% ค่าความถูกต้องเท่ากับ 88.86% และค่าเฉลี่ยความถูกต้องและแม่นยำเท่ากับ 88.89% แสดงให้เห็นว่าวิธีการสร้างตัวแบบรู้จำกิจกรรมที่นำเสนอในงานวิจัยนี้มีประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมที่ดีที่สุด



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 กิจกรรมแบบนั่งและแบบเคลื่อนไหว การรู้จำกิจกรรมแต่ละประเภทใช้มาตรวัดเพียงแค่ 1 ตัวเท่านั้น ทำให้รู้จำกิจกรรมได้รวดเร็ว 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


5.1.2 ผลการดำเนินงานสำหรับวิธีการ S-PAR ที่ทดลองกับข้อมูลจากอุปกรณ์สวมใส่ที่ข้อมือ (Wrist-worn)

งานวิจัยนี้ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition (S-PAR) เป็นการสร้างตัวแบบรู้จำกิจกรรมจากกระแสข้อมูลเชิงเวลาจาก Accelerometer และ Gyroscope ของอุปกรณ์สวมใส่ข้อมือหรือนาฬิกาอัจฉริยะ กิจกรรมที่สามารถเรียนรู้ได้เป็นกิจกรรมทั้งหมด 7 กิจกรรมได้แก่ การยืน, การนั่ง, การนอน, การเดิน, การเดินขึ้นบันได, การเดินลงบันไดและการวิ่ง มีกรอบแนวคิดสองขั้นตอนได้แก่ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนรู้จำกิจกรรม


ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม ซึ่งการเตรียมข้อมูลได้นำวิธีการตรวจสอบความถี่ต่ำในมาแยกความแรงจากแรงโน้มถ่วงและความแรงเชิงเส้นที่เกิดจากผู้ใช้ของกระแสข้อมูลเชิงเวลาจาก Accelerometer พิจารณาลักษณะการแกว่งของค่าความแรงทุกกิจกรรมที่นำมาหาค่าขีดแบ่ง (Threshold) สำหรับแยกประเภทของกิจกรรมเป็นสองประเภทได้แก่ กิจกรรมนิ่งและกิจกรรมเคลื่อนไหว ในกิจกรรมนิ่งนำข้อมูลความแรงที่เกิดจากแรงโน้มถ่วงของกิจกรรมนิ่งทุกกิจกรรมนำมาหาค่าเฉลี่ย (Mean) ในแต่ละแกนและใช้วิธีการ Linear Discriminant Analysis (LDA) ในการสร้างแบบรู้จำกิจกรรมและกิจกรรมเคลื่อนไหวนำข้อมูลความแรงเชิงเส้นและความเร็วเชิงมุมของกิจกรรมของกิจกรรมเคลื่อนไหวทุกกิจกรรมนำมาหาค่าเฉลี่ยกำลังสอง (Root Mean Square) ค่าความเบ้ (Skewness) และพิสัยระหว่างควอร์ไทล์ (Interquartile range) ในแต่ละแกนและสร้างแบบรู้จำกิจกรรมด้วยวิธีการ Support vector machine (SVM)

ขั้นตอนรู้จำกิจกรรม ขั้นตอนนี้พิจารณากระแสข้อมูลเชิงเวลาจาก Accelerometer และ Gyroscope ของอุปกรณ์สวมใส่ข้อมือหรือนาฬิกาอัจฉริยะ ซึ่งค่าขีดแบ่งที่ทำได้ในขั้นตอนสร้างตัวแบบรู้จำกิจกรรมที่สามารถระบุกระแสข้อมูลเชิงเวลาความเร่งว่าเป็นกิจกรรมประเภทอะไร ถ้าเป็นกิจกรรมเคลื่อนไหวจะนำกระแสข้อมูลเชิงเวลาหาค่าเฉลี่ยกำลังสอง (Root Mean Square) ค่าความเบ้ (Skewness) และพิสัยระหว่างควอร์ไทล์ (Interquartile range) ในแต่ละแกนและจำแนกกิจกรรมด้วยแบบรู้จำกิจกรรม SVM แต่ถ้าหากเป็นกิจกรรมนิ่งจะนำหาค่าเฉลี่ย (Mean) ในแต่ละแกนและจำแนกกิจกรรมด้วยแบบรู้จำกิจกรรม LDA

จากผลการทดลองที่นำเสนอในงานวิจัยนี้กับข้อมูล ซึ่งใช้วิธีการวัดประสิทธิภาพตัวแบบรู้จำกิจกรรมด้วยวิธีการ Precision สำหรับวัดความแม่นยำของตัวแบบรู้จำกิจกรรม Recall และ F-measure ซึ่งเป็นค่าเฉลี่ยระหว่างค่าความแม่นยำและความถูกต้อง แสดงดังภาพที่ 5-3 พิจารณาประสิทธิภาพของทุกกิจกรรมเทียบ S-PAR กับวิธีการจากงานวิจัยที่นำมาเปรียบเทียบ ในข้อมูลกิจกรรม Complex human activities dataset มีค่าความแม่นยำเท่ากับ 88.84% ค่าความถูกต้องเท่ากับ 88.46% และค่าเฉลี่ยความถูกต้องและความแม่นยำเท่ากับ 88.61% ซึ่งการผลการทดลองกับข้อมูลกิจกรรม RealworldHAR มีทิศทางที่ไปในทางเดียวกันที่มีค่าความแม่นยำเท่ากับ 71.86% ค่าความถูกต้องเท่ากับ 72.96% และค่าเฉลี่ยความถูกต้องและความแม่นยำเท่ากับ 71.52% แสดงให้เห็นว่าวิธีการรู้จำกิจกรรมที่ได้นำเสนอในงานวิจัยนี้มีประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมที่ดีที่สุด



ภาพที่ 5-3 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิธีการ S-PAR, งานวิจัย Da Silva และ Galeazzo (2013) และงานวิจัย Shoab และคณะ (2015) กับข้อมูล Complex human activities dataset พิจารณารวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure



ภาพที่ 5-4 แผนภูมิแท่งประสิทธิภาพการรู้จำกิจกรรมวิถีการ S-PAR, งานวิจัย Da Silva และ Galeazzo (2013) และงานวิจัย Shoab และคณะ (2015) กับข้อมูล RealworldHAR พิจารณา รวมทุกกิจกรรม โดยใช้ตัววัดประสิทธิภาพ Precision, Recall และ F-measure

5.2 วิจัยรณผลการดำเนินงาน

5.2.1 ข้อดีของงานวิจัย

สำหรับวิถีการ ISAR และ ISAR+ เป็นวิถีการที่สามารถรู้จำกิจกรรมโดยใช้ข้อมูลเพียงตัวเดียว จาก Accelerometer sensor ของสมารต์โฟน จึงมีความสะดวกในการนำไปประยุกต์ใช้งาน และทำให้อุปกรณ์ที่ประมวลผลประหยัดพลังงาน นอกจากนี้วิธีการดังกล่าวยังสามารถปรับปรุงตัวแบบรู้จำกิจกรรมให้เหมาะสมกับผู้ใช้แต่ละบุคคลได้โดยอัตโนมัติ ไม่ต้องให้ผู้ใช้เป็นผู้กำหนดเหมือนวิธีการ STAR

สำหรับวิถีการ S-PAR เป็นวิถีการที่นำแนวคิดบางส่วนมาจาก ISAR+ เป็นนำมาประยุกต์ใช้งานในการรู้จำกิจกรรมทางกายภาพโดยใช้ Accelerometer และ Gyroscope เป็นตัวรับรู้พื้นฐานที่สำคัญบนอุปกรณ์สวมใส่ข้อมือหรือนาฬิกาอัจฉริยะ เพราะไม่สามารถนำวิธีการ ISAR+ มาใช้ประมวลผลได้กับข้อมูลที่มาจากการสวมใส่ข้อมือเนื่องจากข้อมูลมีความซับซ้อนมากกว่าอุปกรณ์สมารต์โฟน จึงต้องมีการปรับปรุงขั้นตอนวิธีการดำเนินงานใหม่ให้เหมาะสมกับอุปกรณ์ รวมถึงการที่ต้องเพิ่มการเก็บข้อมูลจากเซ็นเซอร์ Gyroscope เพิ่มอีก 1 ตัว เพื่อเพิ่มประสิทธิภาพความถูกต้องให้มากขึ้น ซึ่งจากผลการดำเนินงานจะเห็นได้ว่าวิธีการ S-PAR มีประสิทธิภาพในการรู้จำกิจกรรมด้านความถูกต้องมากกว่าวิธีการอื่น

สำหรับการนำไปประยุกต์ใช้งาน และพัฒนาเป็นแอปพลิเคชันต่อไป ทั้งวิธีการ ISAR+ และ S-PAR เป็นวิถีการที่สามารถนำไปใช้ได้ และรองรับการจัดการกับข้อมูลขนาดใหญ่ รวมถึงสามารถประมวลผลได้อย่างรวดเร็วในอุปกรณ์สวมใส่ไม่ว่าจะเป็นสมารต์โฟน อุปกรณ์สวมใส่ข้อมือหรือนาฬิกาอัจฉริยะ

5.2.2 ข้อจำกัดของงานวิจัย

1. งานวิจัยนี้ทำการรู้จำกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรม ได้แก่ การยืน การนั่ง การเดิน การวิ่ง และการขึ้น/ลงบันได
2. การพิจารณา window ที่มีขนาดคงที่ อาจทำให้อุปกรณ์ต้องสูญเสียพลังงานมาก เนื่องจากจะต้องรู้จำกิจกรรมทุก ๆ วินาที
3. ผลการทดสอบทำการทดลองกับข้อมูลจริงที่นำมาจากฐานข้อมูลสาธารณะที่ให้ดาว์นโหลดมาใช้งานได้ แต่ยังไม่ได้นำไปทดสอบกับข้อมูลผู้ใช้ ในสถานที่จริง

5.2.3 ข้อเสนอแนะของงานวิจัย

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). *A public domain dataset for human activity recognition using smartphones*. Paper presented at the Esann.
- 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.
- Bayat, A., Pomplun, M., & Tran, D. A. (2014). A study on human activity recognition using accelerometer data from smartphones. *Procedia Computer Science*, 34, 450-457.
- Chernbumroong, S., Atkins, A. S., & Yu, H. (2011). *Activity classification using a single wrist-worn accelerometer*. Paper presented at the 2011 5th International Conference on Software, Knowledge Information, Industrial Management and Applications (SKIMA) Proceedings.
- 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.
- Da Silva, F. G., & Galeazzo, E. (2013). *Accelerometer based intelligent system for human movement recognition*. Paper presented at the 5th IEEE International Workshop on Advances in Sensors and Interfaces IWASI.
- Dungkaew, T., Suksawatchon, J., & Suksawatchon, U. (2017). *Impersonal smartphone-based activity recognition using the accelerometer sensory data*. Paper

presented at the 2017 2nd International Conference on Information Technology (INCIT).

- 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.
- Konak, S., Turan, F., Shoaib, M., & Incel, Ö. D. (2016). *Feature Engineering for Activity Recognition from Wrist-worn Motion Sensors*. Paper presented at the PECCS.
- Korpela, J., Maekawa, T., Eberle, J., Chakraborty, D., & Aberer, K. (2016). *Tree-structured classifier for acceleration-based activity and gesture recognition on smartwatches*. Paper presented at the 2016 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops).
- 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.
- Kwon, M.-C., & Choi, S. (2018). Recognition of Daily Human Activity Using an Artificial Neural Network and Smartwatch. *Wireless Communications and Mobile Computing, 2018*.
- Lane, N.D., Mohammad, 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.
- Mannini, A., & Intille, S. (2018). Classifier Personalization for Activity Recognition using Wrist Accelerometers. *IEEE journal of biomedical and health informatics*.
- 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.
- Mortazavi, B., Nemati, E., VanderWall, K., Flores-Rodriguez, H. G., Cai, J. Y. J., Lucier, J., . . . Sarrafzadeh, M. (2015). Can smartwatches replace smartphones for posture tracking? *Sensors*, 15(10), 26783-26800.

- Nguyen, M., Fan, L., & Shahabi, C. (2015). *Activity recognition using wrist-worn sensors for human performance evaluation*. Paper presented at the 2015 IEEE International Conference on Data Mining Workshop (ICDMW).
- Nguyen, N. D., Bui, D. T., Truong, P. H., & Jeong, G.-M. (2018). Position-Based Feature Selection for Body Sensors regarding Daily Living Activity Recognition. *Journal of Sensors, 2018*.
- 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.
- Shahmohammadi, F., Hosseini, A., King, C. E., & Sarrafzadeh, M. (2017). *Smartwatch based activity recognition using active learning*. Paper presented at the Proceedings of the Second IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies.
- Shoaib, 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.
- Shoaib, M., Bosch, S., Scholten, H., Havinga, P. J., & Incel, O. D. (2015). Towards detection of bad habits by fusing smartphone and smartwatch sensors. Paper

- presented at the 2015 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops).
- Shoaib, M., Bosch, S., Incel, O., Scholten, H., & Havinga, P. (2016). Complex human activity recognition using smartphone and wrist-worn motion sensors. *Sensors*, 16(4), 426.
- 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.
- Sun, X., Qiu, L., Wu, Y., & Cao, G. (2017). *ActDetector: Detecting Daily Activities Using Smartwatches*. Paper presented at the Mobile Ad Hoc and Sensor Systems (MASS), 2017 IEEE 14th International Conference on.
- Sztyler, T., Stuckenschmidt, H., & Petrich, W. (2017). Position-aware activity recognition with wearable devices. *Pervasive and Mobile Computing*, 38, 281-295.
- 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.
- Weiss, G. M., Timko, J. L., Gallagher, C. M., Yoneda, K., & Schreiber, A. J. (2016). Smartwatch-based activity recognition: A machine learning approach. Paper presented at the 2016 IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI).
- 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.