



การรู้จำกิจกรรมที่ปรับได้ โดยใช้ข้อมูลตัวรับรู้ของอุปกรณ์สวมใส่
Adaptive Activity Recognition Using The Sensory Data of Wearable Device



กตติกา กองศิล

มหาวิทยาลัยบูรพา

2565

การรู้จำกิจกรรมที่ปรับได้ โดยใช้ข้อมูลตัวรับรู้ของอุปกรณ์สวมใส่



กตিকা กองศิลป์

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาการสารสนเทศ

คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา

2565

ลิขสิทธิ์เป็นของมหาวิทยาลัยบูรพา

Adaptive Activity Recognition Using The Sensory Data of Wearable Device



KATIKA KONGSIL

A THESIS SUBMITTED IN PARTIAL FULFILLMENT OF
THE REQUIREMENTS FOR THE MASTER DEGREE OF SCIENCE

IN INFORMATICS

FACULTY OF INFORMATICS

BURAPHA UNIVERSITY

2022

COPYRIGHT OF BURAPHA UNIVERSITY

คณะกรรมการควบคุมวิทยานิพนธ์และคณะกรรมการสอบวิทยานิพนธ์ได้พิจารณา
วิทยานิพนธ์ของ กติกา กองศิลป์ ฉบับนี้แล้ว เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการสารสนเทศ ของมหาวิทยาลัยบูรพาได้

คณะกรรมการควบคุมวิทยานิพนธ์

..... อาจารย์ที่ปรึกษาหลัก

(ผู้ช่วยศาสตราจารย์ ดร. จักริน สุขสวัสดิ์ชน)

..... อาจารย์ที่ปรึกษาร่วม

(ผู้ช่วยศาสตราจารย์ ดร. อรุณัฐ สุขสวัสดิ์ชน)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธาน

(รองศาสตราจารย์ ดร. ศุภกานต์ พิมลธเรศ)

..... กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร. โกเมศ อัมพวัน)

..... กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร. อรุณัฐ สุขสวัสดิ์ชน)

..... กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร. จักริน สุขสวัสดิ์ชน)

คณะวิทยาการสารสนเทศอนุมัติให้รับวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรวิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการสารสนเทศ ของมหาวิทยาลัยบูรพา

..... คณบดีคณะวิทยาการสารสนเทศ

(ผู้ช่วยศาสตราจารย์ ดร. กฤษณะ ชินสาร)

วันที่.....เดือน.....พ.ศ.....

60910061: สาขาวิชา: วิทยาการสารสนเทศ; วท.ม. (วิทยาการสารสนเทศ)

คำสำคัญ: การรู้จำกิจกรรม, ตัวรับรู้, อุปกรณ์สวมใส่ข้อมือ

กติกากองศิลป์ : การรู้จำกิจกรรมที่ปรับได้ โดยใช้ข้อมูลตัวรับรู้ของอุปกรณ์สวมใส่.

(Adaptive Activity Recognition Using The Sensory Data of Wearable Device)

คณะกรรมการควบคุมวิทยานิพนธ์: จักริน สุขสวัสดิ์ชน, อูรีรัฐ สุขสวัสดิ์ชน ปี พ.ศ. 2565.

ในปัจจุบันที่เทคโนโลยีได้ถูกพัฒนาอย่างก้าวกระโดดและได้เข้ามาเป็นส่วนหนึ่งในอยู่
ชีวิตประจำวันมากขึ้นทำให้คุณภาพชีวิตดีขึ้น แต่ในทางตรงข้ามกันก็ทำให้ผู้คนขาดการออกกำลังกาย
หรือสร้างนิสัยที่ไม่ดีเพิ่มมากขึ้น เช่น การนอนมากเกินไป โรคกล้ามเนื้ออ่อนแอ การทำงานใน
สำนักงานที่มีการเคลื่อนไหวน้อย เป็นต้น ซึ่งพฤติกรรมเหล่านี้ทำให้เกิดโรคไม่ติดต่อ (NCDs) เช่น
โรคหัวใจและหลอดเลือด โรคมะเร็ง โรคความดันโลหิตสูง และโรคอ้วน เป็นต้น ซึ่งมีอัตราการ
เสียชีวิตที่สูง ในการส่งเสริมสุขภาพควรมีกิจกรรมที่มีประสิทธิภาพในการติดตามการทำกิจกรรมการออก
กำลังกายในเชิงปริมาณ ซึ่งการตรวจจับการออกกำลังกายโดยอัตโนมัติในระหว่างวันทำได้โดยใช้
วิธีการรู้จำกิจกรรม โดยมีการนำกระแสข้อมูลเชิงเวลาจากตัวรับรู้บนอุปกรณ์ติดตัวผู้ใช้งานมาสร้าง
เป็นตัวแบบรู้จำกิจกรรมที่สามารถระบุกิจกรรมได้ถูกต้องแม่นยำ จึงมีงานวิจัยที่ได้ศึกษาอุปกรณ์
หลายตัวนำไปติดตามตำแหน่งต่าง ๆ บนร่างกายมาสร้างตัวแบบรู้จำกิจกรรมร่วมกันที่มีความแม่นยำ
สูงแต่มีข้อจำกัดที่การยุ่งยากต่อการติดตั้งและใช้งานในชีวิตประจำวันได้ยาก จากการศึกษาพบว่า
ตำแหน่งและการวางแนวของอุปกรณ์มีผลต่อประสิทธิภาพในการรู้จำกิจกรรม ดังนั้นวิทยานิพนธ์นี้ได้
นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมทางกายภาพจากกระแสข้อมูลเชิงเวลาจากตัวรับรู้
Accelerometer และ Gyroscope บนอุปกรณ์ที่สวมใส่ข้อมือ Smartwatch-based Physical
Activity Recognition หรือ S-PAR ซึ่งวิธีการ S-PAR1 เป็นต้นแบบโดยแบ่งการสร้างตัวแบบรู้จำ
กิจกรรมตามลักษณะของข้อมูลกิจกรรมได้แก่ กลุ่มกิจกรรมอยู่กับที่และกลุ่มกิจกรรมเคลื่อนไหว,
วิธีการ S-PAR2 ได้นำการเลือกคุณลักษณะมาประยุกต์ใช้และปรับพารามิเตอร์วิธีการรู้จำให้ได้
ประสิทธิภาพในการรู้จำกิจกรรมเพิ่มขึ้นและวิธีการ S-PAR3 สามารถปรับปรุงตัวแบบรู้จำที่เหมาะสม
กับข้อมูลของผู้ใช้แต่ละคน โดยทดลองกับฐานข้อมูลกิจกรรมจำนวน 4 ฐาน ผลจากการทดลองแสดงให้เห็นว่าวิธีการ S-PAR มีประสิทธิภาพที่ดีกว่างานวิจัยที่เปรียบเทียบตามลำดับ

60910061: MAJOR: INFORMATICS; M.Sc. (INFORMATICS)

KEYWORDS: Activity Recognition, Sensors, Wrist-worn device, Streaming data

KATIKA KONGSIL : ADAPTIVE ACTIVITY RECOGNITION USING THE SENSORY DATA OF WEARABLE DEVICE. ADVISORY COMMITTEE: JAKKARIN SUKSAWATCHON, Ph.D., UREERAT SUKSAWATCHON, Ph.D. 2022.

Nowadays, the continuous growth of technology caused convenience in daily life for a better quality of life. In contrast, physical inactivity or unhealthy habits has increased such as hypersomnia, nomophobia, inactive office working, etc. These behaviors caused to Non-Communicable Diseases (NCDs) such as cardiovascular diseases, cancers, hypertension, and obesity, which have high mortality. For health promotion, it should be some efficient mechanisms to track or monitor for the quantifying physical activities. The automation detection of physical activity during the day should be analyzed first by an activity recognition (AR) method. At the present, many researches focused on the activity recognition framework from multiple sensors attached on the body. The results were showed the high accuracy in recognition rate, but the setting of multiple devices on the body was inconvenience and discomfort in daily life. From our studies, it found that the position and orientation affected to the performance of activity recognition as well. Therefore, the thesis proposes a new physical activity recognition framework based on the combination of accelerometer and gyroscope sensors attached to wrist-worn devices. “Smartwatch-based Physical Activity Recognition” or “S-PAR”. The S-PAR1 proposes the structure to distinguish the activities based on their characteristics (dormant and energetic activities). S-PAR2 applies the feature selection and parameter tuning to improve the overall recognition performance, and S-PAR3 can adapt the model to personal data. From the experiment results on 4 public datasets, the proposed models provided the overall performance in detection and recognition in physical activities with a high recognition rate.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้เสร็จสมบูรณ์ได้ด้วยดีการสนับสนุนจากคณาจารย์ คณะวิทยาการสารสนเทศที่ช่วยแนะนำและให้ความรู้แก่ผู้วิจัย โดยเฉพาะอย่างยิ่งผู้ช่วยศาสตราจารย์ ดร. จักริน สุขสวัสดิ์ชน อาจารย์ที่ปรึกษาหลัก และผู้ช่วยศาสตราจารย์ ดร. อรุณัฐ สุขสวัสดิ์ชน อาจารย์ที่ปรึกษาร่วมที่ช่วยให้คำปรึกษาและแนะทางในการดำเนินงานวิทยานิพนธ์เล่มนี้อีกทั้งยังช่วยแก้ไขข้อบกพร่องและแนะนำในงานเขียนวิทยานิพนธ์ด้วยดีเสมอมา ผู้วิจัยรู้สึกซาบซึ้งเป็นอย่างยิ่ง จึงขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้

ขอขอบคุณ คุณพ่อพิณิจ คุณแม่พรนภา กองศิล รวมทั้งพี่ ๆ น้อง ๆ และเพื่อน ๆ ที่ช่วยเหลือในการให้คำแนะนำและให้กำลังใจในการเรียนและการดำเนินงานวิทยานิพนธ์ตลอดสี่ปีที่ผ่านมาทำให้ผู้วิจัยประสบความสำเร็จในการศึกษาด้วยดี

วิทยานิพนธ์นี้ได้รับทุนสนับสนุนจากงบประมาณเงินรายได้จากเงินอุดหนุนรัฐบาล (งบประมาณแผ่นดิน) ประจำปีงบประมาณ พ.ศ. 2560 มหาวิทยาลัยบูรพา ผ่านสำนักงานคณะกรรมการการวิจัยแห่งชาติ เลขที่สัญญา 141/2560 และ 141/2561 และจากบัณฑิตวิทยาลัย มหาวิทยาลัยบูรพา ประจำปีงบประมาณ พ.ศ. 2563


กตिका กองศิล

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฒ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 แนวทางการแก้ปัญหา.....	8
1.3 วัตถุประสงค์ของวิทยานิพนธ์.....	9
1.4 ขอบเขตวิทยานิพนธ์.....	9
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	10
1.6 แผนดำเนินโครงการ.....	11
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	13
2.1 ทฤษฎีที่เกี่ยวข้อง.....	13
2.1.1 ตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ข้อมือ.....	13
2.1.2 การประมวลผลทางสัญญาณวงจรกรองความถี่และการปรับข้อมูลให้เรียบ.....	14
2.1.3 การคำนวณทางสถิติและความถี่สำหรับการวิเคราะห์และจำแนกกลุ่มข้อมูล.....	15
2.1.4 วิธีการเลือกคุณลักษณะและวิธีการลดมิติของข้อมูล.....	18
2.1.5 เครื่องมือในการสร้างตัวแบบรู้จำกิจกรรม.....	22
2.1.6 ทฤษฎีการรู้จำรูปแบบ.....	23

2.1.6 การรู้จำกิจกรรม	28
2.2 งานวิจัยที่เกี่ยวข้อง.....	29
บทที่ 3 วิธีการที่นำเสนอ	39
3.1 การศึกษาและวิเคราะห์กระแสข้อมูลเชิงเวลาจากตัวรับรู้สำหรับสร้างตัวแบบรู้จำกิจกรรม... 40	
3.1.1 ฐานข้อมูลกิจกรรม.....	40
3.1.2 วิเคราะห์ข้อมูลการทำกิจกรรม	42
3.2 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition (S-PAR)..... 69	
3.2.1 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition 1 (S-PAR1).....	69
3.2.2 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition 2 (S-PAR2).....	84
3.2.3 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition 3 (S-PAR3).....	91
บทที่ 4 ผลการดำเนินงาน	96
4.1 ข้อมูลกิจกรรมที่ใช้ในการทดลอง.....	96
4.2 วิธีการที่ใช้วัดประสิทธิภาพความถูกต้องตัวแบบรู้จำกิจกรรม	97
4.3 การวัดประสิทธิภาพความถูกต้องและความแม่นยำการรู้จำกิจกรรม	98
4.3.1 การวัดประสิทธิภาพของวิธีการรู้จำกิจกรรม S-PAR1	98
4.3.2 การวัดประสิทธิภาพของวิธีการรู้จำกิจกรรม S-PAR2	112
4.4.3 การวัดประสิทธิภาพของวิธีการรู้จำกิจกรรม S-PAR3	132
บทที่ 5 สรุปผลการดำเนินงานและข้อเสนอแนะ.....	145
5.1 สรุปผลการดำเนินงาน.....	145
5.2 วิจาร์ณผลการดำเนินงาน	149
5.2.1 ข้อดีของงานวิทยานิพนธ์	149
5.2.2 ข้อจำกัดของงานวิทยานิพนธ์	149

5.3 ข้อเสนอแนะของงานวิทยานิพนธ์.....	149
ภาคผนวก.....	150
ภาคผนวก ก เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์.....	151
ภาคผนวก ข เอกสารเผยแพร่ผลงานวิจัย.....	153
บรรณานุกรม.....	170
ประวัติย่อของผู้วิจัย.....	175



สารบัญตาราง

	หน้า
ตารางที่ 1 ชุดข้อมูลที่ใช้ในการทดลองที่เก็บการทำกิจกรรมทางกายภาพจากอุปกรณ์ที่สวมใส่ข้อมือ	10
ตารางที่ 2 แผนดำเนินงานโครงงาน	11
ตารางที่ 3 ตารางสมการคำนวณทางคณิตศาสตร์สถิติ	16
ตารางที่ 4 ตารางสมการคำนวณทางความถี่	17
ตารางที่ 5 พารามิเตอร์ของคลาสเมธอด LinearDiscriminantAnalysis จากไลบรารี Scikit-learn	26
ตารางที่ 6 พารามิเตอร์ของคลาสเมธอด svm.SVC จากไลบรารี Scikit-learn	26
ตารางที่ 7 พารามิเตอร์ของคลาสเมธอด SGDClassifier จากไลบรารี Scikit-learn	28
ตารางที่ 8 คุณลักษณะที่นำเสนอในงานวิจัย Chowdhury และคณะ (2017)	33
ตารางที่ 9 ประเภทคุณลักษณะที่นำเสนอในงานวิจัย Chowdhury และคณะ (2017)	33
ตารางที่ 10 คุณลักษณะที่นำเสนอในงานวิจัย Chowdhury และคณะ (2018)	35
ตารางที่ 11 รายละเอียดฐานข้อมูลออนไลน์ที่มีการเก็บข้อมูลกิจกรรมจากอุปกรณ์ที่สวมใส่ข้อมือ ..	40
ตารางที่ 12 ค่าที่เกิดขึ้นของแกนข้อมูลตัวรับรู้ Accelerometer ในแต่ละฐานข้อมูลกิจกรรม	46
ตารางที่ 13 ฐานข้อมูลและกิจกรรมแต่ละกลุ่มกิจกรรมทางกายภาพ	75
ตารางที่ 14 การคำนวณทางคณิตศาสตร์สถิติของคุณลักษณะในวิธีการ S-PAR1	81
ตารางที่ 15 ตารางคุณลักษณะที่ใช้สร้างตัวแบบรู้จำกิจกรรมเคลื่อนไหวของวิธีการรู้จำกิจกรรม S-PAR2	88
ตารางที่ 16 ตารางวิธีการเลือกคุณลักษณะและจำนวนคุณลักษณะในแต่ละฐานข้อมูลของวิธีการ S-PAR3	92
ตารางที่ 17 ตารางจำนวนรอบ Epoch และขนาดของ Minibatch ในแต่ละฐานข้อมูลกิจกรรม	95
ตารางที่ 18 จำนวนแถวข้อมูลกิจกรรมในแต่ละฐานข้อมูลกิจกรรม	96
ตารางที่ 19 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูล RealWorld..	99

ตารางที่ 20 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล RealWorld	99
ตารางที่ 21 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 (2013) จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล RealWorld.....	100
ตารางที่ 22 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) กับฐานข้อมูล RealWorld.....	100
ตารางที่ 23 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูล PARDUSS..	103
ตารางที่ 24 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล PARDUSS	103
ตารางที่ 25 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล PARDUSS	103
ตารางที่ 26 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) กับฐานข้อมูล PARDUSS.....	104
ตารางที่ 27 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูลกิจกรรม MHEALTH.....	106
ตารางที่ 28 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล MHEALTH	106
ตารางที่ 29 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล MHEALTH	107
ตารางที่ 30 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) กับฐานข้อมูล MHEALTH.....	107
ตารางที่ 31 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูลกิจกรรม WISDM	109
ตารางที่ 32 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล WISDM.....	110
ตารางที่ 33 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล WISDM.....	110

ตารางที่ 34 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) กับ ฐานข้อมูล WISDM.....	110
ตารางที่ 35 Confusion Matrix การรู้จำกิจกรรมของวิธีการ S-PAR2 กับฐานข้อมูล RealWorld	113
ตารางที่ 36 Confusion Matrix การรู้จำกิจกรรมของวิธีการ SVM จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล RealWorld.....	113
ตารางที่ 37 Confusion Matrix การรู้จำกิจกรรมของวิธีการ RF จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล RealWorld.....	114
ตารางที่ 38 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล RealWorld.....	114
ตารางที่ 39 Confusion Matrix การรู้จำกิจกรรมของวิธีการ S-PAR2 กับฐานข้อมูล PARDUSS..	116
ตารางที่ 40 Confusion Matrix การรู้จำกิจกรรมของวิธีการ SVM จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล PARDUSS.....	117
ตารางที่ 41 Confusion Matrix การรู้จำกิจกรรมของวิธีการ RF จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล PARDUSS.....	117
ตารางที่ 42 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล PARDUSS.....	118
ตารางที่ 43 Confusion Matrix การรู้จำกิจกรรมของวิธีการ S-PAR2 กับฐานข้อมูล MHEALTH.	120
ตารางที่ 44 Confusion Matrix การรู้จำกิจกรรมของวิธีการ SVM จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล MHEALTH.....	121
ตารางที่ 45 Confusion Matrix การรู้จำกิจกรรมของวิธีการ RF จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล MHEALTH.....	121
ตารางที่ 46 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล MHEALTH.....	122
ตารางที่ 47 Confusion Matrix การรู้จำกิจกรรมของวิธีการ S-PAR2 กับฐานข้อมูล WISDM.....	124
ตารางที่ 48 Confusion Matrix การรู้จำกิจกรรมของวิธีการ SVM จากงานวิจัย Chowdhury และ คณะ (2017) กับฐานข้อมูล WISDM.....	124

ตารางที่ 49 Confusion Matrix การรู้จำกิจกรรมของวิธีการ RF จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล MHEALTH	125
ตารางที่ 50 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล MHEALTH	125
ตารางที่ 51 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของวิธีการ S-PAR3 กับฐานข้อมูล RealWorld.....	133
ตารางที่ 52 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล RealWorld.....	133
ตารางที่ 53 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับฐานข้อมูล RealWorld.....	134
ตารางที่ 54 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของวิธีการ S-PAR3 กับฐานข้อมูล PARDUSS.....	136
ตารางที่ 55 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล PARDUSS	136
ตารางที่ 56 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับฐานข้อมูล PARDUSS.....	137
ตารางที่ 57 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของวิธีการ SPAR-3 กับฐานข้อมูล MHEALTH.....	139
ตารางที่ 58 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล MHEALTH	139
ตารางที่ 59 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับฐานข้อมูล MHEALTH.....	140
ตารางที่ 60 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของวิธีการ S-PAR3 กับฐานข้อมูล WISDM.....	142
ตารางที่ 61 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล WISDM	142

ตารางที่ 62 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับ ฐานข้อมูล MHEALTH.....	142
---	-----



สารบัญภาพ

หน้า

ภาพที่ 1 การติดอุปกรณ์บนร่างกายของงานวิจัย Sztylek, Stuckenschmidt, และ Petrich (2017) และการติดอุปกรณ์บนร่างกายของงานวิจัย Nguyen และคณะ (2018).....	3
ภาพที่ 2 แผนภาพเชิงเส้นของกระแสข้อมูลเชิงเวลาของกิจกรรมนอนที่แตกต่างกันของผู้ใช้ที่ 3, 11 และ 13 จากฐานข้อมูล RealWorld	7
ภาพที่ 3 แผนภาพการกระจายข้อมูลกิจกรรมที่มีการเคลื่อนไหวของร่างกายจากฐานข้อมูลกิจกรรม RealWorld.....	7
ภาพที่ 4 กรอบแนวคิดวิธีการรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition (SPAR)	9
ภาพที่ 5 แสดงลักษณะแกนของตัวรับรู้ Accelerometer และ Gyroscope (Shahmohammadi และคณะ, 2017).....	14
ภาพที่ 6 แผนภาพการเปลี่ยนแปลงข้อมูลกระแสเชิงเวลาจากตัวรับรู้ Accelerometer จากรูปแบบเชิงเวลาเป็นรูปแบบความถี่	17
ภาพที่ 7 แผนภาพการทำงานวิธีการเลือกคุณลักษณะของแต่ละประเภท	19
ภาพที่ 8 ขั้นตอนการทำงานของวิธีการเลือกคุณลักษณะ Relief-F.....	20
ภาพที่ 9 ขั้นตอนการทำงานของวิธีการเลือกคุณลักษณะ Sequential Floating Forward Selection.....	21
ภาพที่ 10 ขั้นตอนการทำงานของวิธีการเลือกคุณลักษณะ Recursive Feature Elimination	22
ภาพที่ 11 ขั้นตอนการรู้จำกิจกรรม	29
ภาพที่ 12 ภาพการเก็บข้อมูลขณะทำกิจกรรม (a) และแผนภาพขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (b) (Chernbumroong, Atkins, และYu, 2011).....	30
ภาพที่ 13 กรอบแนวคิดงานวิจัยและอุปกรณ์ในการเก็บข้อมูลของ Da Silva และ Galeazzo (2013)	31
ภาพที่ 14 กรอบแนวคิดงานวิจัย Shoaib และคณะ (2015).....	32

ภาพที่ 15 กรอบแนวคิดของงานวิจัย Chowdhury และคณะ (2017)	33
ภาพที่ 16 ภาพขั้นตอนในการคำนวณค่าน้ำหนักของงานวิจัย Chowdhury และคณะ (2018)	35
ภาพที่ 17 ภาพขั้นตอนในการคำนวณค่าน้ำหนักของงานวิจัย Chowdhury และคณะ (2018)	36
ภาพที่ 18 ภาพขั้นตอนในการรู้จำกิจกรรมของวิจัย Chowdhury และคณะ (2018).....	36
ภาพที่ 19 ขั้นตอนการปรับค่าน้ำหนักของวิจัย Chowdhury และคณะ (2018).....	37
ภาพที่ 20 ขั้นตอนการรวมค่าน้ำหนักเพื่อระบุกิจกรรมของงานวิจัย Chowdhury และคณะ (2018)	38
ภาพที่ 21 ภาพรวมของวิธีการ Smartwatch-based Physical Activity Recognition (S-PAR) ..	39
ภาพที่ 22 การติดตั้งอุปกรณ์บนตำแหน่งต่างๆ ของร่างกาย และแอปพลิเคชันในการเก็บข้อมูลของ ฐานข้อมูลกิจกรรม RealWorld	41
ภาพที่ 23 ภาพประกอบการเก็บข้อมูลขณะทำกิจกรรมจากฐานข้อมูลกิจกรรม MHEALTH.....	42
ภาพที่ 24 แผนภาพการกระจายข้อมูลดิบทุกกิจกรรมของฐานข้อมูลกิจกรรม RealWorld.....	43
ภาพที่ 25 แผนภาพการตัวอย่างการแบ่งเป็นชุดข้อมูลย่อยด้วยเทคนิค Sliding window ด้วยขนาด เท่ากับ 1 วินาที (ไฮไลท์สีเหลือง).....	43
ภาพที่ 26 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล RealWorld	44
ภาพที่ 27 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล PARDUSS.....	44
ภาพที่ 28 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล MHEALTH.....	44
ภาพที่ 29 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล WISDM (ผู้ใช้ 10 คน)	45
ภาพที่ 30 แผนภาพการกระจายข้อมูลของตัวรับรู้ Accelerometer ของกลุ่มกิจกรรมอยู่กับที่แต่ละ ฐานข้อมูลกิจกรรม	47
ภาพที่ 31 แผนภาพเชิงเส้นกระแสน้ำข้อมูลเชิงเวลาการยืนจากฐานข้อมูลกิจกรรม PARDUSS ของ อาสาสมัคร 4 คน	48

ภาพที่ 32 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาการนั่งจากฐานข้อมูลกิจกรรม PARDUSS ของอาสาสมัคร 4 คน	48
ภาพที่ 33 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของการยืนของอาสาสมัครที่ 1, 2, 3 และ 8 ในฐานข้อมูลกิจกรรม RealWorld	49
ภาพที่ 34 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของการนั่งของอาสาสมัครที่ 1, 2, 7 และ 8 ในฐานข้อมูลกิจกรรม RealWorld	50
ภาพที่ 35 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของการนอนของอาสาสมัครที่ 1, 2, 3 และ 7 ในฐานข้อมูล RealWorld.....	50
ภาพที่ 36 แผนภาพกระแสข้อมูลเชิงเวลาการยืนของฐานข้อมูลกิจกรรม MHEALTH ของอาสาสมัคร 4 คน	51
ภาพที่ 37 แผนภาพกระแสข้อมูลเชิงเวลาการนั่งของฐานข้อมูลกิจกรรม MHEALTH ของอาสาสมัคร 4 คน	51
ภาพที่ 38 แผนภาพกระแสข้อมูลเชิงเวลาตัวอย่างการนอนของฐานข้อมูลกิจกรรม MHEALTH ของอาสาสมัคร 4 คน	52
ภาพที่ 39 แผนภาพกระแสข้อมูลเชิงเวลาการยืนของฐานข้อมูลกิจกรรม WISDM ของอาสาสมัคร 4 คน.....	52
ภาพที่ 40 แผนภาพกระแสข้อมูลเชิงเวลาตัวอย่างการนั่งของอาสาสมัคร 4 คนจากฐานข้อมูลกิจกรรม WISDM	53
ภาพที่ 41 แผนภาพการกระจายข้อมูลของกลุ่มกิจกรรมเคลื่อนไหวของฐานข้อมูลกิจกรรม RealWorld.....	53
ภาพที่ 42 แผนภาพการกระจายข้อมูลของกลุ่มกิจกรรมเคลื่อนไหวของฐานข้อมูลกิจกรรม PARDUSS.....	54
ภาพที่ 43 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครคนที่ 1 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Accelerometer (20 วินาที)	55
ภาพที่ 44 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครที่ 2 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Accelerometer (20 วินาที)	55

ภาพที่ 58 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Accelerometer ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม MHEALTH (20 วินาที).....	63
ภาพที่ 59 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Accelerometer ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 2 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)	63
ภาพที่ 60 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Accelerometer ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 3 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)	64
ภาพที่ 61 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Gyroscope ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 1 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)	64
ภาพที่ 62 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Gyroscope ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 2 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)	65
ภาพที่ 63 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Gyroscope ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 3 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)	65
ภาพที่ 64 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Accelerometer	66
ภาพที่ 65 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Accelerometer	66
ภาพที่ 66 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 3 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Accelerometer	67
ภาพที่ 67 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Gyroscope	67
ภาพที่ 68 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Gyroscope	68
ภาพที่ 69 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Gyroscope	68
ภาพที่ 70 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition 1 (S-PAR1) ขั้นตอนสร้างตัวแบบรู้จำกิจกรรม	70
ภาพที่ 71 แผนภาพตัวอย่างการตัดส่วนหัวและส่วนท้ายของข้อมูลกิจกรรม	71

ภาพที่ 72 แผนภาพขั้นตอนการรองความถี่ต่ำและผลลัพธ์ที่ได้ในแต่ละขั้นตอน..... 72

ภาพที่ 73 แผนภาพกระแสข้อมูลเชิงเวลาความเร่งที่วัดได้จากตัวรับรู้ Accelerometer 72

ภาพที่ 74 แสดงตัวอย่างข้อมูลดิบ (Raw data) และข้อมูลที่ถูกรอง (Filtered data)..... 73

ภาพที่ 75 แผนภาพตัวอย่างการแบ่งชุดข้อมูลกิจกรรมสำหรับการสร้างและทดสอบตัวแบบรู้จำกิจกรรมด้วยวิธีการ Leave-one-subject-out cross validation 74

ภาพที่ 76 ภาพตัวอย่างการแบ่งข้อมูลเป็นหน้าต่าง (Windows) จากฐานข้อมูล RealWorld ไฮไลท์สีแดงแสดงขนาด 2 วินาที (100 จุด) 75

ภาพที่ 77 ตารางแสดงค่า Accelerometer และค่าขนาดความเร่งในการแบ่ง Windows..... 76

ภาพที่ 78 แผนภาพตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมเคลื่อนไหวกับกิจกรรมอยู่กับที่ของฐานข้อมูลกิจกรรม RealWorld และ PARDUSS..... 78

ภาพที่ 79 แผนภาพเส้นแสดงลักษณะกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแกน X, Y และ Z ของกิจกรรมยืนของอาสาสมัครที่ 1 และ 3 จากฐานข้อมูลกิจกรรม RealWorld 79

ภาพที่ 80 แผนภาพเส้นแสดงลักษณะกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแกน X, Y และ Z ของกิจกรรมนั่งของอาสาสมัครที่ 1 และ 3 จากฐานข้อมูลกิจกรรม RealWorld 79

ภาพที่ 81 แผนภาพเส้นแสดงลักษณะกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแกน X, Y และ Z ของกิจกรรมนอนของอาสาสมัครที่ 1 และ 3 จากฐานข้อมูลกิจกรรม RealWorld 79

ภาพที่ 82 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition (S-PAR1) ขั้นตอนรู้จำกิจกรรม 83

ภาพที่ 83 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition 2 (S-PAR2) ขั้นตอนสร้างตัวแบบรู้จำกิจกรรม 85

ภาพที่ 84 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition 2 (S-PAR2) ขั้นตอนรู้จำกิจกรรม 85

ภาพที่ 85 แผนภาพแสดงเส้นแบ่งกิจกรรมข้อมูลจากตัวแบบรู้จำ Linear SVM 88

ภาพที่ 86 แผนภาพขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมของวิธีการ Smartwatch-based Physical Activity Recognition 3 (S-PAR3) 92

ภาพที่ 87 แผนภาพการแบ่งชุดข้อมูลสำหรับเรียนรู้เพิ่มเติม (Extra training data) และการปรับตัว แบบรู้จำกิจกรรม.....	94
ภาพที่ 88 หลักการ Minibatch Gradient Descent ในขั้นตอน Extra training ของ S-PAR3.....	95
ภาพที่ 89 แผนภาพแห่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล RealWorld	101
ภาพที่ 90 แผนภาพแห่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับวิธีการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล RealWorld	101
ภาพที่ 91 แผนภาพแห่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับวิธีการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล RealWorld	102
ภาพที่ 92 แผนภาพแห่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล PARDUSS	104
ภาพที่ 93 แผนภาพแห่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล PARDUSS	105
ภาพที่ 94 แผนภาพแห่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล PARDUSS.	105
ภาพที่ 95 แผนภาพแห่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล MHEALTH	108
ภาพที่ 96 แผนภาพแห่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล MHEALTH	108
ภาพที่ 97 แผนภาพแห่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล MHEALTH	109
ภาพที่ 98 แผนภาพแห่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล WISDM	111
ภาพที่ 99 แผนภาพแห่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล WISDM	111

ภาพที่ 100 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล WISDM	112
ภาพที่ 101 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล RealWorld	115
ภาพที่ 102 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล RealWorld	115
ภาพที่ 103 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล RealWorld	116
ภาพที่ 104 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล PARDUSS	118
ภาพที่ 105 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล PARDUSS	119
ภาพที่ 106 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล PARDUSS	119
ภาพที่ 107 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล MHEALTH	122
ภาพที่ 108 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล MHEALTH	123
ภาพที่ 109 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล MHEALTH	123
ภาพที่ 110 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล WISDM	125
ภาพที่ 111 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล WISDM	126
ภาพที่ 112 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล WISDM	126

ภาพที่ 113 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล RealWorld ในแต่ละขนาดของ Window 127

ภาพที่ 114 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล PARDUSS ในแต่ละขนาดของ Window 128

ภาพที่ 115 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล MHEALTH ในแต่ละขนาดของ Window 128

ภาพที่ 116 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล WISDM ในแต่ละขนาดของ Window 129

ภาพที่ 117 แผนภาพแสดงค่าเฉลี่ย F-measure ของวิธีการเลือกคุณลักษณะที่ทดลองกับกลุ่มกิจกรรมในฐานข้อมูล RealWorld 130

ภาพที่ 118 แผนภาพแสดงค่าเฉลี่ย F-Measure ของวิธีการเลือกคุณลักษณะทดลองกับกลุ่มกิจกรรมในฐานข้อมูลกิจกรรม PARDUSS 130

ภาพที่ 119 แผนภาพแสดงค่าเฉลี่ย F-measure ของวิธีการเลือกคุณลักษณะที่ทดลองกับกลุ่มกิจกรรมในฐานข้อมูลในฐานข้อมูลกิจกรรม MHEALTH 131

ภาพที่ 120 แผนภาพแสดงค่าเฉลี่ย F-measure ของวิธีการเลือกคุณลักษณะที่ทดลองกับกลุ่มกิจกรรมในฐานข้อมูลในฐานข้อมูลกิจกรรม WISDM 131

ภาพที่ 121 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม RealWorld 134

ภาพที่ 122 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม RealWorld 135

ภาพที่ 123 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม RealWorld 135

ภาพที่ 124 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม PARDUSS 137

ภาพที่ 125 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม PARDUSS 138

ภาพที่ 126 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม PARDUSS	138
ภาพที่ 127 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม MHEALTH	140
ภาพที่ 128 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม MHEALTH	141
ภาพที่ 129 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม MHEALTH	141
ภาพที่ 130 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม WISDM	143
ภาพที่ 131 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม WISDM	143
ภาพที่ 132 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม WISDM	144
ภาพที่ 133 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของการรู้จำกิจกรรมระหว่างงานวิจัยที่เปรียบเทียบกับวิธีการ S-PAR1	146
ภาพที่ 134 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของการรู้จำกิจกรรมระหว่างงานวิจัยที่เปรียบเทียบกับวิธีการ S-PAR2	147
ภาพที่ 135 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของการรู้จำกิจกรรมระหว่างงานวิจัยที่เปรียบเทียบกับวิธีการ S-PAR3	148
ภาพที่ 136 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของวิธีการรู้จำกิจกรรม S-PAR ทั้งสามเวอร์ชันในแต่ฐานข้อมูล	148

บทที่ 1

บทนำ

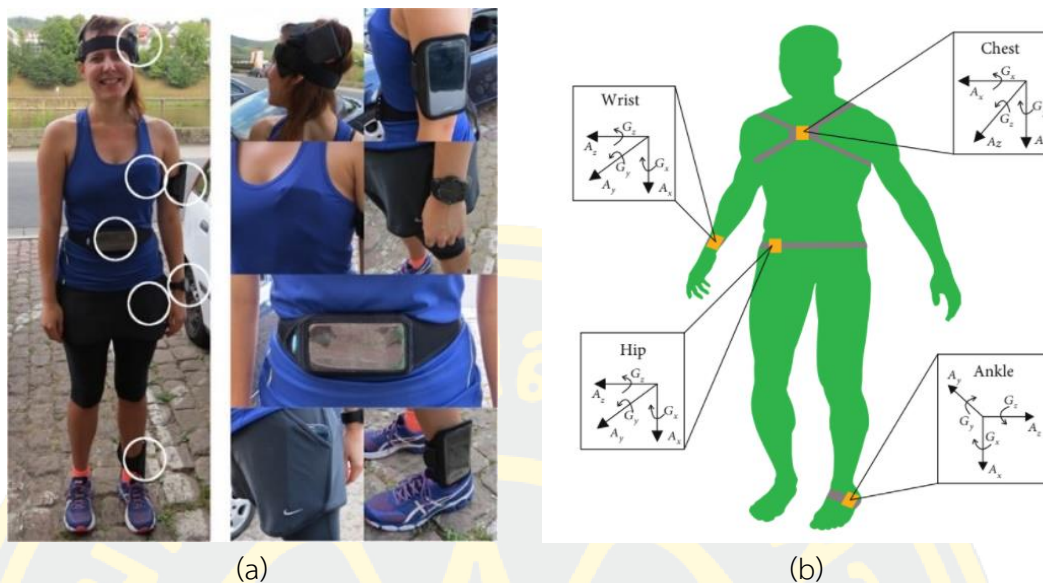
1.1 ที่มาและความสำคัญของปัญหา

ในปัจจุบันที่เทคโนโลยีและนวัตกรรมได้พัฒนาอย่างรวดเร็ว มีผลทำให้วิถีการใช้ชีวิตหรือพฤติกรรมเปลี่ยนแปลงไปจากเดิม จึงมีโอกาที่จะเกิดพฤติกรรมเสี่ยงในการใช้ชีวิตประจำวันเพิ่มมากขึ้นตามไปด้วยตัวอย่างเช่น การใช้งานอุปกรณ์สื่อสารหรือสื่อต่าง ๆ มากจนเกินไปทำให้ขาดการออกกำลังกายอย่างสม่ำเสมอ การพักผ่อนไม่เพียงพอ ความเครียดสะสม เป็นต้น ซึ่งการทำพฤติกรรมเหล่านี้ติดต่อกันเป็นระยะเวลาานานทำให้มีโอกาสสูงที่จะเป็นโรคในกลุ่ม NCDs (Non-Communicable diseases) เป็นกลุ่มโรคที่ไม่ได้เกิดจากเชื้อโรคหรือการติดต่อแพร่กระจายมาสู่คน แต่เกิดจากนิสัยหรือการทำพฤติกรรมเสี่ยงในชีวิตประจำวัน ที่ค่อย ๆ สะสมจนเป็นอาการเรื้อรังยากต่อการรักษาตัวอย่างโรคในกลุ่มโรค NCDs ได้แก่ โรคหัวใจ โรคเบาหวาน โรคมะเร็ง เป็นต้น ซึ่งเป็นกลุ่มโรคที่มีการเสียชีวิตมากที่สุดอันดับต้น ๆ ดังนั้นการลดพฤติกรรมเสี่ยงที่เป็นสาเหตุที่ทำให้เกิดโรคคือการติดตามเฝ้าระวังและแจ้งเตือนให้เกิดนิสัยหรือพฤติกรรมที่ถูกต้อง ทั้งนี้ต้องรู้ก่อนว่าในแต่ละวันมีการทำกิจกรรมอะไรบ้าง จึงมีการนำเทคโนโลยีและความรู้ต่าง ๆ ในปัจจุบันมาประยุกต์ใช้เพื่อช่วยในการจดจำกิจกรรมของมนุษย์ หนึ่งในนั้นมีหลักความรู้ทางด้านวิทยาการคอมพิวเตอร์ที่เรียกว่า “การรู้จำกิจกรรม” (Activity recognition) เป็นวิธีการนำข้อมูลการทำกิจกรรมต่าง ๆ มาเรียนรู้และสร้างตัวแบบรู้จำกิจกรรม (Learning model) ที่มีความสามารถในระบุกิจกรรมได้อย่างถูกต้อง จึงมีหลายวิธีในการเก็บข้อมูลกิจกรรมที่มีลักษณะเป็นการเคลื่อนไหวของร่างกายที่เรียกว่า กิจกรรมทางกายภาพ (Physical activity) ตัวอย่างเช่น การเดิน การวิ่ง การยืน เป็นต้น ซึ่งมีวิธีการหนึ่งที่น่าสนใจคือการรู้จำกิจกรรมจากตัวรับรู้บนอุปกรณ์พกพาหรือสวมใส่ (Wearable sensors) ความสามารถของตัวรับรู้คือการสร้างกระแสข้อมูลเชิงเวลา (Temporal streaming data) ที่สัมพันธ์กับการเคลื่อนไหว ในขณะที่ทำกิจกรรม นำมาผ่านวิธีการเรียนรู้ (Learning algorithms) จนกระทั่งได้ตัวแบบรู้จำกิจกรรมที่สามารถนำมาใช้ระบุกิจกรรมที่ทำในแต่ละวันได้อย่างแม่นยำ

จึงมีหลายงานวิจัยที่ศึกษาและพัฒนาวิธีการรู้จำกิจกรรมทางกายภาพโดยใช้กระแสข้อมูลเชิงเวลาจากตัวรับรู้ ซึ่งลักษณะของข้อมูลกิจกรรมขึ้นอยู่กับชนิดตัวรับรู้บนอุปกรณ์, จำนวนของอุปกรณ์และตัวรับรู้, ตำแหน่งที่ติดตั้งอุปกรณ์บนร่างกาย, ลักษณะท่าทางและสภาพแวดล้อมขณะเก็บข้อมูลโดยมีรายละเอียดดังต่อไปนี้

1. งานวิจัยที่ใช้อุปกรณ์ที่ติดตามตำแหน่งต่าง ๆ ของร่างกาย (Multiple position)

งานวิจัยในกลุ่มนี้จะนำกระแสข้อมูลเชิงเวลาที่ได้รับจากตัวรับรู้บนอุปกรณ์ในแต่ละตำแหน่งที่ติดตามส่วนต่างๆ ของร่างกาย มาช่วยในการวิเคราะห์หาคุณลักษณะเด่นของแต่ละกิจกรรมที่จะนำมาสร้างเป็นตัวแบบรู้จำกิจกรรม ตัวอย่างงานวิจัยที่เกี่ยวข้องได้แก่ งานวิจัยของ Sztylek, Stuckenschmidt, และ Petrich (2017) ได้ทดลองเก็บข้อมูลการทำกิจกรรมจากตัวรับรู้ Accelerometer บนอุปกรณ์สมาร์ทโฟนและนาฬิกาอัจฉริยะที่นำมาติดตามร่างกายทั้งหมด 7 ตำแหน่งได้แก่ ศีรษะ, หน้าอก, ข้อมือ, ต้นแขน, ต้นขา, เหวและข้อเท้า แสดงดังภาพที่ 1(a) โดยเน้นการเก็บข้อมูลกิจกรรมทางกายภาพทั้งหมด 8 กิจกรรมได้แก่ การยืน การนั่ง การนอน การเดิน การเดินขึ้นบันได การเดินลงบันได การวิ่ง และการกระโดด จากนั้นนำกระแสข้อมูลเชิงเวลาที่ได้จากตัวรับรู้และตำแหน่งที่ติดตั้งอุปกรณ์มาสร้างตัวแบบรู้จำกิจกรรม จากงานวิจัยนี้พบว่า การติดอุปกรณ์ที่ตำแหน่งเอวจะให้ประสิทธิภาพมากที่สุดในการระบุกิจกรรมทางกายภาพและเมื่อรู้จำร่วมกับอุปกรณ์ที่ตำแหน่งต้นขาจะทำให้ตัวแบบรู้จำมีความแม่นยำในการระบุการเดินขึ้นลงบันไดได้เพิ่มมากขึ้น อีกหนึ่งตัวอย่างงานวิจัยคืองานวิจัยของ Nguyen และคณะ (2018) นำเสนอวิธีการเรียนรู้จำกิจกรรมในชีวิตประจำวัน (Daily Living Activity Recognition) โดยใช้กระแสข้อมูลเชิงเวลาที่ได้จาก Accelerometer เก็บข้อมูลการทำกิจกรรมจำนวน 13 กิจกรรมโดยติดอุปกรณ์บนร่างกายทั้งหมด 4 ตำแหน่งได้แก่ หน้าอก, เหว, ข้อมือและข้อเท้าดังภาพที่ 1(b) ซึ่งงานวิจัยนี้เน้นการนำกระแสข้อมูลเชิงเวลาที่ได้จากทุกตำแหน่งบนร่างกายมาหาคุณลักษณะที่ดีที่สุดสำหรับใช้สร้างตัวแบบรู้จำกิจกรรม และทำให้ได้ตัวแบบรู้จำกิจกรรมที่มีความแม่นยำในการรู้จำทุกกิจกรรมมากกว่า 90%



ภาพที่ 1 การติดอุปกรณ์บนร่างกายของงานวิจัย Sztzyler, Stuckenschmidt, และ Petrich (2017) และการติดอุปกรณ์บนร่างกายของงานวิจัย Nguyen และคณะ (2018)

จากตัวอย่างสองงานวิจัยที่กล่าวมาข้างต้น แสดงให้เห็นว่าการนำกระแสข้อมูลเชิงเวลาของตัวรับรู้ Accelerometer ที่ได้จากการติดตามตำแหน่งต่างๆ บนร่างกายมาใช้สร้างตัวแบบรู้จำกิจกรรมจะสามารถรู้จำได้หลากหลายกิจกรรมและแยกความแตกต่างของกิจกรรมที่มีลักษณะคล้ายคลึงกันได้ดี ทำให้ตัวแบบรู้จำกิจกรรมมีประสิทธิภาพสูง แต่ยังมีข้อจำกัดที่สำคัญคือความยุ่งยากในการติดหรือสวมใส่อุปกรณ์ในการเก็บข้อมูลที่จะนำมาใช้และเมื่อนำมาใช้ในงานในสภาพแวดล้อมจริงอาจจะทำให้เกิดความไม่สะดวกสบายต่อผู้ใช้งานได้

- งานวิจัยที่ใช้อุปกรณ์สมาร์ทโฟน (Smartphone) ซึ่งได้รับความสนใจเป็นอย่างมากในการนำมาใช้เป็นอุปกรณ์ในการรู้จำกิจกรรม เนื่องจากเป็นอุปกรณ์ที่สามารถพกพาได้สะดวกและภายในอุปกรณ์มีการฝังตัวรับรู้หลายชนิดตัวอย่างเช่น Accelerometer, Gyroscope, Magnetometer และ GPS เป็นต้น จึงมีงานวิจัยจำนวนมากที่นำกระแสข้อมูลเชิงเวลาจากสมาร์ทโฟนนี้ไปใช้สร้างตัวแบบรู้จำกิจกรรม ตัวอย่างงานวิจัยได้แก่ งานวิจัยของ Bayat, Pomplun, และ Tran (2014) เก็บกระแสข้อมูลเชิงเวลาที่ได้จากตัวรับรู้ Accelerometer ของอุปกรณ์สมาร์ทโฟนบนระบบปฏิบัติการ Android โดยให้ผู้ใช้เลือกใส่สมาร์ทโฟนไว้ในกระเป๋ากางเกงหรือถือไว้ในมือ จากนั้นนำข้อมูลที่เก็บจากผู้ไปใช้สร้างตัวแบบรู้จำกิจกรรมที่มีการเคลื่อนไหวของร่างกายทั้งหมด 6 กิจกรรมได้แก่ การเดินช้า การเดินเร็ว การวิ่ง การเดิน

ขึ้นบันได การเดินลงบันไดและการเดินแอโรบิค ซึ่งผลการทดลองของงานวิจัยนี้ พบว่า ตำแหน่งของสมาร์ทโฟนใส่ในกระเป๋าทางเกงมีประสิทธิภาพในการรู้จำกิจกรรมมากที่สุด และอีก หนึ่งตัวอย่างงานวิจัยคืองานวิจัยของ Therdsak, Jakkarin, และ Ureerat (2017) ได้นำเสนอวิธีการรู้จำกิจกรรมจากตัวรับรู้ Accelerometer ที่สามารถทำงานบนอุปกรณ์ สมาร์ทโฟนได้ที่มีชื่อว่า “Impersonal Smartphone-based Activity Recognition” (ISAR) ที่รู้จำกิจกรรมทางกายภาพทั้งหมด 5 กิจกรรมได้แก่ การยืน, การนั่ง, การเดิน, การเดินขึ้นลงบันไดและการวิ่งจ็อกกิ้ง จากฐานข้อมูลสาธารณะที่มีชื่อว่า WISDM โดยกำหนด ตำแหน่งของสมาร์ทโฟนต้องใส่ในกระเป๋าทางเกงด้านหน้าเท่านั้น ซึ่งผลการทดลองแสดงให้เห็นว่าตัวแบบรู้จำกิจกรรมมีประสิทธิภาพในการรู้จำกิจกรรมที่มีลักษณะอยู่กับที่และการเดิน ได้ดีแต่ประสิทธิภาพในการรู้จำกิจกรรมการเดินขึ้นลงบันไดค่อนข้างต่ำ

จากตัวอย่างงานวิจัยที่กล่าวมาข้างต้น ได้พยายามพัฒนาวิธีการรู้จำกิจกรรมโดยใช้กระแสข้อมูล เวลาจากตัวรับรู้ Accelerometer บนอุปกรณ์สมาร์ทโฟนให้มีประสิทธิภาพเทียบเท่ากับการใช้ หลายตัวรับรู้ที่ติดตามตำแหน่งต่างๆ บนร่างกาย ซึ่งผลการทดลองแสดงให้เห็นว่าสามารถรู้จำได้ดีใน บางกิจกรรม แต่ในจะมีประสิทธิภาพในการรู้จำกิจกรรมที่มีลักษณะคล้ายคลึงกันมากได้แม่นยำต่ำ ดังนั้นงานวิจัยส่วนใหญ่จะเน้นไปทางการรู้จำกิจกรรมเฉพาะกลุ่มหรือลดจำนวนกิจกรรมที่มีลักษณะ คล้ายคลึงกัน และยังมีข้อจำกัดที่สำคัญคือ ต้องกำหนดตำแหน่งและทิศทางของอุปกรณ์บนร่างกายให้ ชัดเจนก่อนจะนำไปผ่านกระบวนการสร้างตัวแบบรู้จำกิจกรรม ดังนั้นเมื่อนำไปใช้ในสภาพแวดล้อม จริงมีโอกาสที่ผู้ใช้งานจะนำอุปกรณ์สมาร์ทโฟนไปยังที่อยู่อื่นๆ บนร่างกายหรือภายนอกร่างกาย ตัวอย่างเช่นนำอุปกรณ์สมาร์ทโฟนใส่ในกระเป๋าถือหรือวางไว้บนโต๊ะขณะทำกิจกรรมไม่สามารถรู้จำ กิจกรรมได้

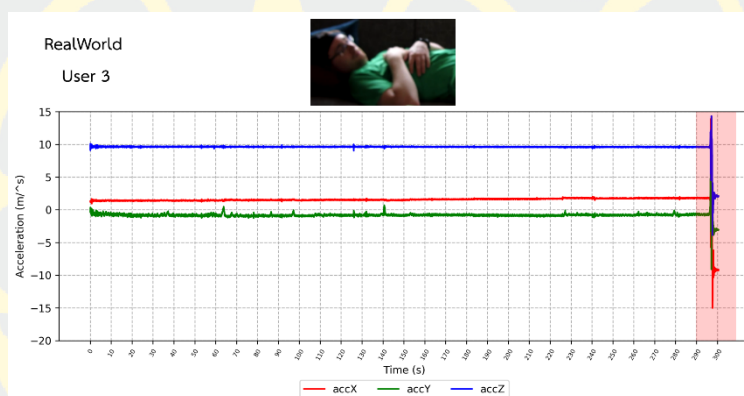
1. งานวิจัยที่ใช้อุปกรณ์ที่สวมใส่ข้อมือ (Wrist-worn device) หรือนาฬิกาอัจฉริยะ (Smartwatch) ซึ่งลักษณะของอุปกรณ์ที่มีขนาดเล็กและสามารถสวมใส่ข้อมือได้ตลอดเวลา ทำให้ได้รับความนิยมเพิ่มมากขึ้นในปัจจุบัน นอกจากนี้อุปกรณ์ชนิดนี้ยังมีการฝังตัวรับรู้ เช่นเดียวกับอุปกรณ์สมาร์ทโฟน ซึ่งงานวิจัยจำนวนหนึ่งที่สนใจนำกระแสข้อมูลเชิงเวลาจาก อุปกรณ์นี้มาสร้างเป็นตัวแบบรู้จำกิจกรรม แต่ยังมีจำนวนงานวิจัยน้อยกว่ามากเมื่อเทียบกับ งานวิจัยที่รู้จำกิจกรรมด้วยสมาร์ทโฟน (Demrozi และคณะ, 2020) ซึ่งตัวอย่างงานวิจัย ได้แก่ งานวิจัยของ Weiss และคณะ (2016) ที่นำเสนอการเปรียบเทียบการสร้างตัวแบบรู้จำ กิจกรรมด้วยสมาร์ทโฟนกับนาฬิกาอัจฉริยะ โดยเก็บข้อมูลการทำกิจกรรมจากตัวรับรู้

Accelerometer และ Gyroscope ทั้งหมด 18 กิจกรรมซึ่งมีการแบ่งกิจกรรมออกเป็น 3 กลุ่มได้แก่ กลุ่มกิจกรรมทางกายภาพ กลุ่มกิจกรรมที่ใช้มือเป็นหลัก และกลุ่มกิจกรรมการรับประทานอาหารเช้า ผลการทดลองเบื้องต้นของงานวิจัยนี้พบว่ากระแสข้อมูลเชิงเวลาที่ได้รับเฉพาะตัวรู้ Accelerometer บนนาฬิกาอัจฉริยะสามารถรู้จำกิจกรรมที่ใช้มือและการรับประทานอาหารเช้าได้ดีที่สุดและรู้จำกิจกรรมทางกายภาพได้ดีกว่าในบางกิจกรรม อีกหนึ่งตัวอย่างคืองานวิจัย M.-C. Kwon และ Choi (2018) นำเสนอวิธีการรู้จำกิจกรรมที่เก็บกระแสข้อมูลเชิงเวลา 11 กิจกรรม ซึ่งแยกออกเป็น 3 กลุ่มได้แก่ กลุ่มกิจกรรมในสำนักงาน, กลุ่มกิจกรรมในครัวและกลุ่มกิจกรรมนอกบ้าน โดยให้อาสาสมัครสวมใส่นาฬิกาอัจฉริยะในข้อมือด้านที่ถนัด ซึ่งนำข้อมูลกระแสเชิงเวลาจากตัวรับรู้ Accelerometer ที่เป็นตัวรับรู้หลัก และข้อมูลตำแหน่ง GPS ขณะทำกิจกรรมของผู้ใช้ (ห้องทำงาน, ห้องครัวและภายนอกบ้าน) ที่จะช่วยเพิ่มความแม่นยำในการรู้จำกิจกรรม จากนั้นส่งข้อมูลผ่านสมาร์ตโฟนไปยังเครื่องแม่ข่าย (Server) เพื่อสร้างตัวแบบรู้จำกิจกรรม

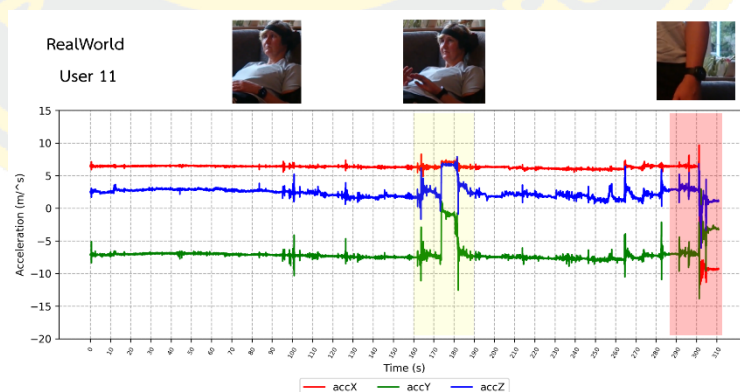
จากงานวิจัยที่กล่าวมาข้างต้น การเก็บกระแสข้อมูลเชิงเวลาจากตัวรับรู้บนอุปกรณ์ชนิดนี้จะช่วยลดความยุ่งยากและไม่เป็นภาระต่อผู้ใช้งาน แต่งานวิจัยส่วนใหญ่จะเน้นรู้จำกิจกรรมที่มีลักษณะของข้อมูลที่มีความแตกต่างกันอย่างชัดเจนหรือกลุ่มกิจกรรมใดกลุ่มหนึ่ง ซึ่งเมื่อนำมาประยุกต์ใช้กับกระแสข้อมูลเชิงเวลาของกลุ่มกิจกรรมทางกายภาพที่มีการเคลื่อนไหวของร่างกายในสภาพแวดล้อมจริงที่รูปแบบของข้อมูลมีหลากหลายหรือมีลักษณะของข้อมูลที่คล้ายคลึงกันอาจจะส่งผลกับประสิทธิภาพของตัวแบบรู้จำในกลุ่มกิจกรรมนี้ลดลง ซึ่งในงานวิทยานิพนธ์นี้จะเน้นไปที่การศึกษาและพัฒนาวิธีการรู้จำกิจกรรมทางกายภาพที่เป็นเคลื่อนไหวของร่างกายตัวอย่างเช่น การยืน การนั่ง การเดิน เป็นต้น โดยใช้กระแสข้อมูลเชิงเวลาจากนาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ข้อมือให้มีประสิทธิภาพในการรู้จำมากที่สุด เพื่อที่จะนำไปประยุกต์ใช้ในงานติดตามเฝ้าระวังสุขภาพต่อไป ซึ่งจากงานวิจัยที่กล่าวมาข้างต้นยังพบข้อจำกัดและประเด็นปัญหาต่างๆ ที่เกี่ยวข้องกับการเก็บข้อมูลกิจกรรมทางกายภาพของตัวรับรู้ Accelerometer จากอุปกรณ์ชนิดนี้โดยจะกล่าวถึงประเด็นปัญหาอย่างละเอียดดังต่อไปนี้

- **ประเด็นปัญหาที่ 1** ลักษณะของกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer ณ ตำแหน่งอุปกรณ์ข้อมือในการทำกิจกรรมทางกายภาพที่ร่างกายอยู่กับที่ตัวอย่างเช่น การยืน การนั่งและการนอนของบางคนมีความแตกต่างจากคนอื่น ทำให้เกิด**ปัญหาการทำกิจกรรมเดียวกันแต่มีลักษณะข้อมูลกิจกรรมที่แตกต่างกันอย่างชัดเจน** ซึ่งปัญหาเกิดจากการเก็บ

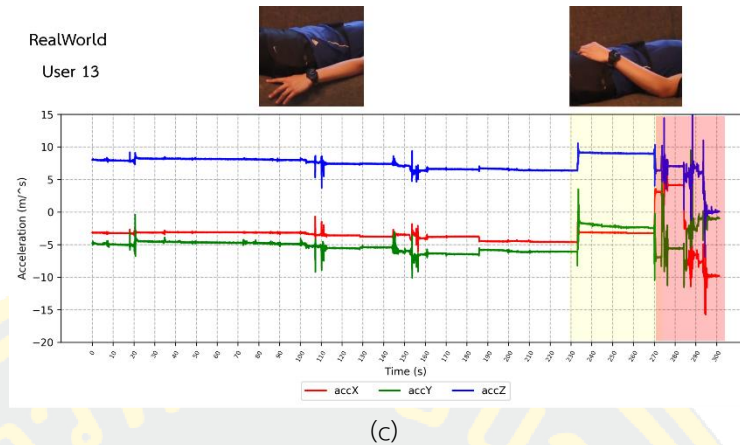
ข้อมูลกิจกรรมจากนาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ที่ตำแหน่งข้อมือมีโอกาสเปลี่ยนแปลงแกนข้อมูลของตัวรับรู้ Accelerometer ได้ง่ายกว่าอุปกรณ์ที่ตำแหน่งอื่นๆ ดังภาพที่ 2 แสดงแกนข้อมูลจากตัวรับรู้ Accelerometer ของผู้ใช้งานจำนวน 3 คนขณะเก็บข้อมูลการนอน จะสังเกตเห็นลักษณะข้อมูลที่เกิดขึ้นระหว่างการเก็บข้อมูลได้แก่ 1) การเปลี่ยนลักษณะการวางมือของผู้ใช้คนที่ 11 (2b) และ 13 (2c) ทำให้ข้อมูลของการนอนนั้นเปลี่ยนไปช่วงระยะหนึ่งและแกนข้อมูลทั้งสามค่า (X, Y และ Z) ของการนอนของผู้ใช้คนที่ 11 (2b) จะไม่เหมือนกับผู้ใช้คนอื่น 2) ข้อมูลส่วนท้ายของทั้งสามคนเกิดการเปลี่ยนแปลงท่าทางเพื่อกดยกการเก็บข้อมูลทำให้เกิดข้อมูลที่ไม่ได้เกี่ยวข้อง (Noise)



(a)

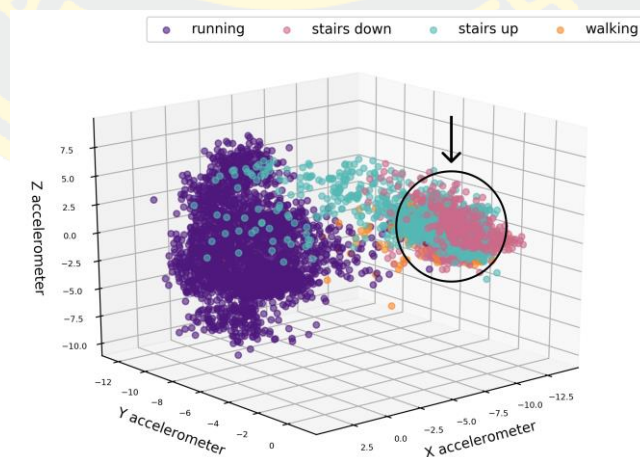


(b)



ภาพที่ 2 แผนภาพเชิงเส้นของกระแสข้อมูลเชิงเวลาของกิจกรรมนอนที่แตกต่างกันของผู้ใช้ที่ 3, 11 และ 13 จากฐานข้อมูล RealWorld

- ประเด็นปัญหาที่ 2 เป็นปัญหาที่เกิดจากลักษณะของกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer ที่ได้จากอุปกรณ์สวมใส่ข้อมือหรือนาฬิกาที่มีความคล้ายคลึงกัน หากนำกระแสข้อมูลเชิงเวลามาสร้างเป็นแผนภาพการกระจายข้อมูล (Scatter plot) ดังตัวอย่างภาพที่ 3 จะเห็นได้ว่าการเดิน การเดินขึ้นบันได การเดินลงบันได มีลักษณะของกลุ่มข้อมูลที่ซับซ้อนกัน (Overlapping data) ไม่สามารถแยกเป็นกลุ่มอย่างชัดเจน ซึ่งลักษณะการทับซ้อนกันของข้อมูลทำให้มีผลต่อประสิทธิภาพในการระบุกิจกรรม



ภาพที่ 3 แผนภาพการกระจายข้อมูลกิจกรรมที่มีการเคลื่อนไหวของร่างกายจากฐานข้อมูลกิจกรรม RealWorld

1.2 แนวทางการแก้ปัญหา

จากประเด็นปัญหาที่กล่าวมาข้างต้น ในงานวิทยานิพนธ์นี้จะขอเสนอแนวทางการแก้ปัญหาในแต่ละประเด็นดังนี้

- แนวทางการแก้ปัญหาที่ 1 การทำกิจกรรมเดียวกันแต่มีลักษณะข้อมูลกิจกรรมที่แตกต่างกัน จะพิจารณากระแสข้อมูลเชิงเวลาที่ได้รับจากตัวรับรู้ Accelerometer เป็นหลัก เนื่องจากเป็นตัวรับรู้ที่สามารถแยกความแตกต่างของกิจกรรมทางกายภาพที่ร่างกายอยู่กับที่ได้ ซึ่งในการสร้างตัวแบบรู้จำกิจกรรมอยู่กับที่ (Dormant Activities) ซึ่งในการสร้างตัวแบบกิจกรรมอยู่กับที่ ได้เลือกคุณลักษณะและวิธีการเรียนรู้ที่ครอบคลุมข้อมูลที่เป็นกิจกรรมเดียวกันแต่มีลักษณะแตกต่างกันให้ได้มากที่สุด และการปรับปรุงตัวแบบรู้จำให้เข้ากับกระแสข้อมูลเชิงเวลาของแต่ละคนส่งผลให้ประสิทธิภาพในตัวแบบรู้จำกิจกรรมเพิ่มขึ้น
- แนวทางการแก้ปัญหาที่ 2 การทับซ้อนของข้อมูลกิจกรรมที่ได้จากตัวรับรู้ Accelerometer ทำให้ตัวแบบรู้จำยากต่อระบุกิจกรรม ซึ่งในการสร้างตัวแบบรู้จำกิจกรรมเคลื่อนไหว (Energetic Activities) โดยที่การเลือกคุณลักษณะและการเรียนรู้จำที่เหมาะสมที่สามารถลดการ Underfitting ที่เกิดจากข้อมูลทับซ้อนกันและได้นำกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Gyroscope นำมาพิจารณาร่วมกัน จะช่วยเพิ่มประสิทธิภาพในการรู้จำที่มีลักษณะคล้ายคลึงกันอย่างมีนัยสำคัญ

จากทั้งสองแนวทางการแก้ปัญหาวิทยานิพนธ์นี้ขอเสนอวิธีการรู้จำกิจกรรมที่มีชื่อว่า “Smartwatch-based Physical Activity Recognition” โดยสามารถเรียกโดยย่อว่า “SPAR” ซึ่งกรอบแนวคิดของวิธีการนี้แสดงดังภาพที่ 4 โดยเริ่มจากกระบวนการเตรียมกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope จากนั้นสร้างเป็นตัวแบบรู้จำทั้งหมดสามตัวแบบ ได้แก่ **ตัวแบบรู้จำกลุ่มกิจกรรม** ที่ทำหน้าที่ระบุว่ากระแสข้อมูลเชิงเวลาที่เข้ามานั้นเป็น “กลุ่มกิจกรรมเคลื่อนไหว (Energetic Activities)” หรือ “กลุ่มกิจกรรมอยู่กับที่ (Dormant Activities)” ที่กล่าวมาข้างต้น ซึ่งในแต่ละกลุ่มกิจกรรมมีตัวแบบรู้จำกิจกรรมที่มีวิธีการเรียนรู้และพารามิเตอร์ที่แตกต่างกันเพื่อให้รู้จำกิจกรรมในกลุ่มนั้น ๆ ตามลักษณะกระแสข้อมูลเชิงเวลาให้มีประสิทธิภาพในการรู้จำให้ได้มากที่สุด รายละเอียดในการพัฒนาวิธีการรู้จำกิจกรรม SPAR มีทั้งหมดสามเวอร์ชันโดยวิธีการรู้จำกิจกรรม S-PAR1 เป็นวิธีการต้นแบบของการสร้างแบบรู้จำกิจกรรม วิธีการรู้จำกิจกรรม S-PAR2 ได้ปรับปรุงวิธีการเลือกคุณลักษณะและวิธีการสร้างตัวแบบรู้จำกิจกรรมให้เหมาะสมในแต่ละ

ฐานข้อมูลกิจกรรม และวิธีการรู้จำกิจกรรม SPAR-3 ได้เพิ่มขั้นตอนปรับปรุงตัวแบบรู้จำกิจกรรมจากข้อมูลผู้ใช้แต่ละคน ที่ทำให้ตัวแบบรู้จำกิจกรรมสามารถรู้จำกิจกรรมเฉพาะของแต่ละคนและนำไปใช้งานในสภาพแวดล้อมจริงให้มีประสิทธิภาพมากที่สุด



ภาพที่ 4 กรอบแนวคิดวิธีการรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition (SPAR)

1.3 วัตถุประสงค์ของวิทยานิพนธ์

1. เพื่อศึกษาและวิเคราะห์ปัญหาที่เกิดขึ้นในการรู้จำกิจกรรมโดยใช้ข้อมูลจากตัวรับรู้ของนาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ
2. เพื่อพัฒนาวิธีการสร้างตัวแบบรู้จำกิจกรรมที่สามารถปรับตัวแบบให้เหมาะสมกับผู้ใช้แต่ละบุคคล
3. เพื่อพัฒนาตัวแบบรู้จำกิจกรรมจากกระแสข้อมูลเชิงเวลาจากอุปกรณ์ที่สวมใส่ข้อมือให้มีประสิทธิภาพในด้านความถูกต้องในการรู้จำกิจกรรม

1.4 ขอบเขตวิทยานิพนธ์

1. วิทยานิพนธ์นี้สร้างตัวแบบรู้จำกิจกรรม โดยใช้ข้อมูลกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope บนอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ
2. วิทยานิพนธ์นี้สร้างตัวแบบรู้จำกิจกรรมในกลุ่มกิจกรรมทางกายภาพที่เป็นการเคลื่อนไหวท่าทางของร่างกาย

3. วิทยานิพนธ์นี้ใช้ชุดข้อมูลกิจกรรมที่สามารถเข้าถึงแบบสาธารณะ (Public Dataset) จำนวน 4 ฐานข้อมูลโดยมีรายละเอียดดังตารางที่ 1

ตารางที่ 1 ชุดข้อมูลที่ใช้ในการทดลองที่เก็บการทำกิจกรรมทางกายภาพจากอุปกรณ์ที่สวมใส่ข้อมือ

ชุดข้อมูลกิจกรรม	อุปกรณ์	กิจกรรมทางกายภาพ	จำนวนข้อมูล
Physical Activity Recognition Dataset Using Smartphone Sensors (PARDUSS)	Samsung Galaxy s2 จำลองเป็นอุปกรณ์ที่ตำแหน่งข้อมือข้างขวา	7 กิจกรรมได้แก่ การยืน การนั่ง การเดิน การเดินขึ้นบันได การเดินลงบันได การวิ่งและการปั่นจักรยาน	อาสาสมัคร 10 คน มีจำนวนตัวอย่างรวมกันทั้งหมด 540,000 ตัวอย่าง
Human Activity Recognition RealWorld (RealWorld)	นาฬิกาอัจฉริยะ LG G Watch R ที่ตำแหน่งข้อมือข้างขวา	7 กิจกรรมได้แก่ การยืน, การนั่ง การนอน การเดิน,การเดินขึ้นบันได การเดินลงบันไดและการวิ่ง	อาสาสมัคร 10 คน จำนวน 1,000,174 ตัวอย่าง
Mobile HEALTH (MHEALTH)	Shimmer Wearable sensor ณ ตำแหน่งข้อมือด้านที่ขวา	8 กิจกรรมได้แก่ การยืน การนั่ง การนอน การเดิน, การเดินขึ้นบันได การเดินลงบันได การวิ่ง การวิ่งจ็อกกิ้งและการปั่นจักรยาน	อาสาสมัคร 10 คน มีจำนวนตัวอย่างรวมกันทั้งหมด 245,760 ตัวอย่าง
Wireless Sensor Data Mining (WISDM)	นาฬิกาอัจฉริยะ LG G Watch ที่ตำแหน่งข้อมือข้างขวา	5 กิจกรรมได้แก่การยืน, การนั่ง การเดิน การเดินขึ้นลงบันได และการวิ่ง	อาสาสมัคร 45 คน มีจำนวนตัวอย่างรวมกันทั้งหมด 881,287 ตัวอย่าง

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. เข้าใจปัญหาของการรู้จำกิจกรรมโดยใช้กระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope ของอุปกรณ์ที่สวมใส่ข้อมือหรือนาฬิกาอัจฉริยะ
2. ได้ขั้นตอนวิธีการสร้างตัวแบบรู้จำกิจกรรมที่สามารถปรับให้เหมาะสมกับผู้ใช้แต่ละบุคคล
3. ได้ตัวแบบรู้จำกิจกรรมที่มีประสิทธิภาพด้านความถูกต้องของการรู้จำกิจกรรม

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้องที่นำมาใช้ในการพัฒนาขั้นตอนวิธีการรู้จำกิจกรรมที่นำเสนอในวิทยานิพนธ์นี้ แบ่งเป็นหัวข้อดังต่อไปนี้

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 ตัวรับรู้ของอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์สวมใส่ข้อมือ

ตัวรับรู้ (Sensor) เป็นวัตถุชนิดหนึ่งที่เป็นลักษณะของวงจรทางไฟฟ้าที่ประกอบขึ้นเพื่อทำหน้าที่ตรวจจับสัญญาณหรือปริมาณทางฟิสิกส์และแปลงให้เป็นสัญญาณทางไฟฟ้า ซึ่งในปัจจุบันที่ตัวรับรู้ที่มีขนาดเล็กลงทำให้สามารถฝังลงบนอุปกรณ์อิเล็กทรอนิกส์ต่างๆ ตัวอย่างเช่นตัวรับรู้ที่ฝังลงบนอุปกรณ์สมาร์ตโฟนหรือนาฬิกาอัจฉริยะได้แก่ Accelerometer, Gyroscope, Magnetometer, Barometric pressure, Heart rate sensor เป็นต้น ซึ่งจะนำกระแสข้อมูลเชิงเวลาที่ได้วัดค่าได้ไปประยุกต์ใช้กับการใช้งานของแต่ละแอปพลิเคชัน ซึ่งในวิทยานิพนธ์นี้ใช้กระแสข้อมูลเชิงเวลาจากตัวรับรู้จากอุปกรณ์ที่สวมใส่ที่ข้อมือคือ Accelerometer และ Gyroscope sensor ในการรู้จำกิจกรรม โดยมีรายละเอียดดังต่อไปนี้

- Accelerometer sensor เป็นตัวรับรู้ที่สามารถตรวจจับความเร่งในการเคลื่อนที่และความเอียงของอุปกรณ์ได้ หลักการทำงานคือวัดความเร่งที่เกิดขึ้นตามแนวแกนประกอบไปด้วยแกน X, แกน Y และแกน Z ดังภาพที่ 5 ซึ่งความเร่งที่เกิดขึ้นประกอบไปด้วยแรงสองส่วนคือความเร่งที่เกิดจากการกระทำของผู้ใช้ต่ออุปกรณ์ที่เรียกว่า ความเร่งเชิงเส้น (Linear acceleration) และความเร่งที่เกิดจากแรงโน้มถ่วงของโลก (Gravity component) ที่กระทำต่อตัวรับรู้โดยจะมีค่าเท่ากับ 9.8 m/s^2 ซึ่งในการตรวจจับความเร่งของตัวรับรู้จะต้องกำหนดจำนวนจุดข้อมูล (Data point) ที่ความเร่งที่เกิดขึ้นในแต่ละวินาทีที่เรียกว่าอัตราการสุ่ม (Sampling rate) ถ้ากำหนดอัตราการสุ่มข้อมูลจำนวนมากจะจะสามารถวัดกระแสข้อมูลเชิงเวลาความเร่งได้ละเอียดขึ้น แต่จะใช้พลังงานสูงและเกิดความร้อนเพิ่มมากขึ้นตามไปด้วย
- Gyroscope sensor เป็นตัวรับรู้ที่สามารถตรวจจับอัตราเร่งเชิงมุมของการหมุนรอบแกนของอุปกรณ์ มีลักษณะการตรวจจับตามแนวแกนเช่นเดียวกับตัวรับรู้ Accelerometer



ภาพที่ 5 แสดงลักษณะแกนของตัวรับรู้ Accelerometer และ Gyroscope (Shahmohammadi และคณะ, 2017)

2.1.2 การประมวลผลทางสัญญาณวงจรกรองความถี่และการปรับข้อมูลให้เรียบ

- การประมวลผลทางสัญญาณวงจรกรองความถี่ (Filter Circuit) เป็นหนึ่งในเทคนิคการประมวลผลทางสัญญาณ (Signal Processing) ซึ่งเป็นการยอมให้ความถี่ของสัญญาณไฟฟ้าผ่านได้บางช่วงเท่านั้นความถี่อื่น ๆ จะถูกลดทอนหรือตัดออกไป โดยลักษณะการกรองถี่ถูกแบ่งออกเป็น 3 ประเภท ได้แก่ กรองความถี่ต่ำ (Low pass filter) เป็นให้ความถี่ที่ต่ำกว่าที่กำหนดผ่านไปได้, กรองความถี่สูง (High pass filter) เป็นการให้ความถี่ที่สูงกว่าที่กำหนดผ่านไปได้และกรองสัญญาณช่วงความถี่ (Band pass filter) ที่ให้ความถี่ที่อยู่ระหว่างค่าความถี่ตัดผ่านสามารถผ่านไปได้ ซึ่งจะต้องกำหนดความถี่ที่ต้องการและค่าความถี่ตัดผ่าน (Cutoff frequency) ซึ่งมีการนำเทคนิคนี้มาประยุกต์ใช้กับตัวรับรู้เนื่องจากกระแสข้อมูลเชิงเวลาจะมีลักษณะเป็นความถี่ของสัญญาณไฟฟ้าเมื่อเกิดการเปลี่ยนแปลงโดยนำมาใช้ในการแยกสัญญาณออกกันและการคืนค่าสัญญาณที่เพี้ยนไป ดังนั้นในวิทยานิพนธ์นี้ได้นำหลักการประมวลผลทางสัญญาณวงจรกรองความถี่ Butterworth Low pass Filter (Bayat, Pomplun, และ Tran, 2014) ประยุกต์ใช้ในการแยกสัญญาณความเร่งเชิงเส้นและความเร่งที่เกิดจากแรงโน้มถ่วงของโลกที่ได้จากตัวรับรู้ Accelerometer โดยหลักการทำงานจะกำหนดค่าความถี่ตอบสนอง (Frequency response) ที่เรียกว่า Order filter ค่าเริ่มต้นอยู่ที่ 1 นั้นหมายความว่ามีการทำกรองความถี่หนึ่งครั้ง เมื่อมีกำหนดค่ามากขึ้นจะทำให้สัญญาณ Transition band ค่อย ๆ ลดลงและถ้ามีค่ามากจะทำให้ Transition band ลดลงอย่างรวดเร็วเข้าใกล้ Ideal Response มากที่สุด
- การปรับข้อมูลให้เรียบโดยค่าเฉลี่ยเคลื่อนที่ (Moving Average) การปรับข้อมูลให้เรียบเป็นหนึ่งในวิธีการในการประมวลผลทางสัญญาณ เพื่อลดค่าของข้อมูลที่มีความผิดปกติที่

เกิดขึ้นจากการสุ่มข้อมูล (Sampling data) (Garcia-Ceja และ Brena, 2013) ซึ่งสามารถนำมาประยุกต์ใช้กับกระแสข้อมูลเชิงเวลาที่วัดค่าได้จากตัวรับรู้โดยกำหนดจำนวนจุดข้อมูลที่อยู่ ณ ตำแหน่งก่อนหน้าและจุดข้อมูลที่ต้องการปรับให้เรียบ (k) จากนั้นนำมาหาค่าเฉลี่ยและกำหนดค่าใหม่ให้กับจุดข้อมูลที่ต้องการปรับให้เรียบโดยมีดังสมการที่ 2.1

$$sx_i = \frac{1}{k} \sum_{j=i-k}^{i-1} x_j \quad (2.1)$$

โดยที่	i	คือจุดข้อมูลที่นำมาคำนวณปรับให้เรียบมีค่าเริ่มต้นตั้งแต่ 1 ถึงจำนวนชุดข้อมูล
	j	คือตำแหน่ง (index) ของข้อมูลที่นำมาพิจารณา
	sx_i	คือจุดข้อมูลที่ i ที่ถูกปรับให้เรียบ
	x_j	คือค่าข้อมูลตำแหน่ง j ที่นำมาพิจารณา
	k	คือจำนวนค่าที่นำมาพิจารณาในการปรับให้เรียบ

2.1.3 การคำนวณทางสถิติและความถี่สำหรับการวิเคราะห์และจำแนกกลุ่มข้อมูล


วิทยานิพนธ์นี้ใช้หลักการคำนวณทางสถิติและความถี่ในการวิเคราะห์กระแสข้อมูลเชิงเวลาที่เป็นข้อมูลดิบจากตัวรับรู้ ซึ่งนำมาแบ่งเป็นชุดข้อมูลขนาดเล็กและคำนวณเป็นคุณลักษณะ (Features) สำหรับสร้างตัวแบบรู้จำกิจกรรม (Figo และคณะ, 2010) โดยมีรายละเอียดของหลักการคำนวณทางสถิติและความถี่ดังต่อไปนี้

- **การคำนวณทางสถิติ (Mathematical and statistical techniques)** เป็นการนำหลักการคณิตศาสตร์สถิติมาคำนวณร่วมกับกระแสข้อมูลเชิงเวลาที่ได้รับจากตัวรับรู้ Accelerometer และ Gyroscope ซึ่งค่าสถิติที่ได้เกิดจากกระแสข้อมูลเชิงเวลาที่เกิดขึ้น ณ ช่วงหนึ่ง (Time domain) ซึ่งถูกนำมาประยุกต์ใช้ในขั้นตอนการเตรียมข้อมูลและการสร้างกลุ่มคุณลักษณะ ซึ่งในตารางที่ 5 แสดงสมการทางสถิติทั้งหมดที่ใช้ในการคำนวณ

ตารางที่ 3 ตารางสมการคำนวณทางคณิตศาสตร์สถิติ

ลำดับ	คุณลักษณะ	สมการคำนวณ
1	Average	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
2	Median	$m = \begin{cases} \frac{(n+1)}{2}; & \text{where } n \text{ is odd} \\ \frac{\frac{n}{2} + (\frac{n}{2} + 1)}{2}; & \text{where } n \text{ is even} \end{cases}$
3	Variance	$var = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
4	Standard deviation	$STD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$
5	Minimum	$\max(x)$
6	Maximum	$\min(x)$
7	Skewness	$Skew = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^{\frac{3}{2}}}$
8	Kurtosis	$Kurt = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^2}$
9	25th percentile	$p25 = \frac{25}{100} (n+1)$
10	75th percentile	$p75 = \frac{75}{100} (n+1)$
11	Interquartile range	$IQR = Q3_{x_i} - Q1_{x_i}$
12	Root Mean Squared	$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$
13	Mean Crossing	$MC_{x_i} = \sum_{i=1}^n \text{sign}\{(x(i) - \bar{x}) \times (x(i-1) - \bar{x}) < 0\}$
14	Cross-correlation coefficient	$r(x, y) = \frac{\sum_{n=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{n=1}^n x_i - \bar{x}} \sqrt{\sum_{n=1}^n y_i - \bar{y}}}$

- **การคำนวณทางความถี่ (Frequency domain)** เป็นวิธีการประมาณค่าสัญญาณใดๆ ให้อยู่ในรูปสมการคณิตศาสตร์โดยแยกองค์ประกอบความถี่คลื่นไซน์ (Sine wave) และแทนค่าที่ใกล้เคียงกับข้อมูลสัญญาณที่ต่อเนื่องกัน (Continuous signal) มากที่สุด ซึ่งเป็นการเปลี่ยนแปลงจากข้อมูลรูปแบบเชิงเวลา (Time domain) ให้เป็นอยู่ในรูปแบบเชิงความถี่ (Frequency domain) โดยใช้เทคนิค Fast Fourier Transformation (FFT) (Sztyley, Stuckenschmidt, และ Petrich, 2017) โดยสามารถประยุกต์ใช้กับกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope จากข้อมูลรูปแบบเชิงเวลาในหนึ่งครั้งการสุมให้อยู่ในรูปความถี่ซึ่งมีความสัมพันธ์ระหว่างค่าความถี่ (Freq) หน่วยเฮิร์ตและขนาดของความถี่ (Amp) ดังภาพที่ 5 ดังนั้นจึงมีหลายงานวิจัยที่พัฒนาตัวรับรู้จำกิจกรรมนำเทคนิคนี้มาใช้ในการคำนวณคุณลักษณะเพิ่มเติมดังตารางที่ 4



ภาพที่ 6 แผนภาพการเปลี่ยนแปลงข้อมูลกระแสเชิงเวลาจากตัวรับรู้ Accelerometer จากรูปแบบเชิงเวลาเป็นรูปแบบความถี่

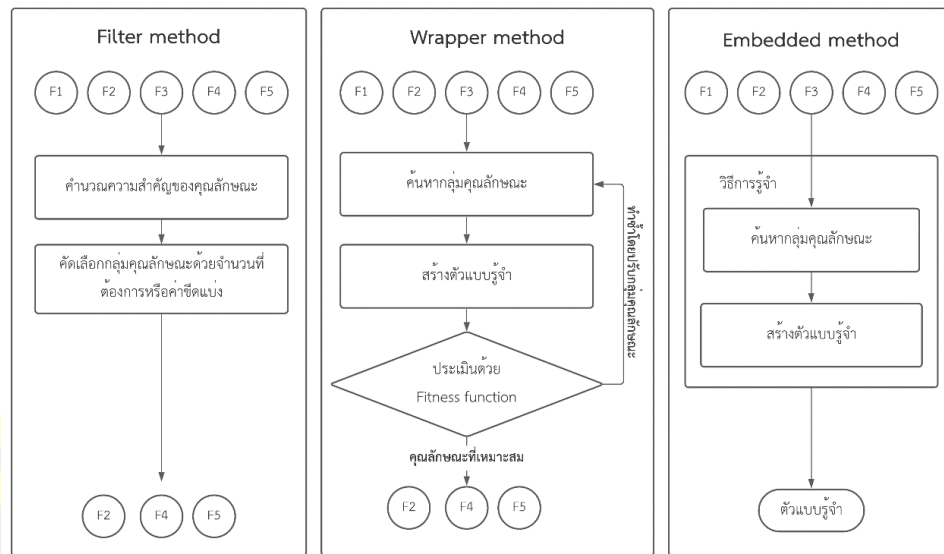
ตารางที่ 4 ตารางสมการคำนวณทางความถี่

ลำดับ	คุณลักษณะ	สมการคำนวณ
1	Magnitude (Amplitude) of dominant frequency	$M = \operatorname{argmax}_i(Amp_i)$
2	Dominant frequency	$f_{max} = \operatorname{Freq}(\operatorname{argmax}_i(Amp_i))$
3	Magnitude Energy	$e = \frac{1}{N} \sum_{i=1}^N Amp_i ^2$

2.1.4 วิธีการเลือกคุณลักษณะและวิธีการลดมิติของข้อมูล

ในขั้นตอนสร้างตัวแบบรู้จำจะต้องใช้กลุ่มคุณลักษณะที่บ่งบอกถึงลักษณะของข้อมูล ซึ่งถ้ามีกลุ่มคุณลักษณะที่ไม่มีคุณภาพหรือมากเกินไปที่เกิดปัญหาทำให้มีผลต่อประสิทธิภาพของตัวแบบรู้จำและใช้ทรัพยากรในการคำนวณมากเกินไปโดยไม่จำเป็น ดังนั้นจึงมีขั้นตอนการเลือกกลุ่มของคุณลักษณะที่สำคัญจากคุณลักษณะทั้งหมด (Feature selection) ที่จะนำมาสร้างตัวแบบรู้จำกิจกรรมได้ ประสิทธิภาพดียิ่งขึ้น ประเภทของวิธีการเลือกคุณลักษณะถูกแบ่งออกเป็นสามประเภทดังภาพที่ 7 โดยมีรายละเอียดดังต่อไปนี้

- 1) ประเภท Filter-based ใช้หลักการทางสถิติในการหาค่าน้ำหนักของคุณลักษณะหรือความสัมพันธ์ของคุณลักษณะ ตัวอย่างวิธีการประเภทนี้ได้แก่ Fisher score และ Correlation coefficient (Hadjerci และคณะ, 2016)
- 2) ประเภท Wrapper-based ใช้หลักการวิธีการค้นหาแบบละโมภ (Greedy algorithms) ที่จะค้นหากลุ่มของคุณลักษณะเท่าที่เป็นไปได้โดยประเมินกลุ่มของคุณลักษณะโดยให้ตัวแบบรู้จำกิจกรรมที่ให้ประสิทธิภาพที่ได้ผลประสิทธิภาพดีที่สุดก่อนนำไปสร้างเป็นตัวแบบรู้จำ ตัวอย่างวิธีการเลือกคุณลักษณะในประเภทนี้ได้แก่ Sequential forward selection (SFS), Sequential backward feature (SBF) และ Recursive Feature Elimination (RFE)
- 3) ประเภท Embedded-based ใช้หลักการเรียนรู้สร้างตัวแบบรู้จำกิจกรรมบางวิธีการจะมีการออกแบบขั้นตอนให้สร้างตัวแบบรู้จำโดยเลือกกลุ่มคุณลักษณะโดยดูจากค่าน้ำหนักหรือค่าสถิติบางอย่างที่เหมาะสมกับขั้นตอนคำนวณการแบ่งกลุ่มข้อมูล ตัวอย่างวิธีการเลือกคุณลักษณะในประเภทนี้ได้แก่ Tree-based Algorithms เช่น Random forest, Extra tree



ภาพที่ 7 แผนภาพการทำงานวิธีการเลือกคุณลักษณะของแต่ละประเภท

ซึ่งในวิทยานิพนธ์นี้ทดลองขั้นตอนการวิธีการเลือกคุณลักษณะจำนวน 4 วิธีการได้แก่ Fisher Score , Relief-F, Sequntial Floating Forward Selection (SFFs), Recursive Feature Elimination (RFE) โดยมีรายละเอียดดังนี้

- **วิธีการการเลือกคุณลักษณะ Fisher Score** เป็นวิธีเลือกคุณลักษณะประเภท Filter-based ที่ค้นหากลุ่มของคุณลักษณะ (Gu, Li, และ Han, 2012) โดยพิจารณาเลือกคุณลักษณะจากการค่าการกระจายตัวของคุณลักษณะ โดยมีสมมุติฐานที่ว่า ระยะห่างของข้อมูลแต่ละกลุ่มข้อมูลในคุณลักษณะควรจะห่างกันมากที่สุดและข้อมูลที่เป็นกลุ่มข้อมูลเดียวกันในคุณลักษณะควรจะเกาะกลุ่มหรือใกล้กัน ดังสมการที่ 2.2 โดยจะเลือกคุณลักษณะที่มีค่ามากที่สุดตามลำดับถึงที่จำนวนคุณลักษณะที่ต้องการ (Fan, Jia, และ Jia, 2019)

$$Fisher_score(f_i) = \frac{\sum_{j=1}^c n_j (\bar{x}_{ij} - \bar{x}_i)^2}{\sum_{j=1}^c \sum_{y_i=j} (x - \bar{x}_{ij})^2} \quad (2.2)$$

โดย	f_i	คือ ค่าคุณลักษณะที่ i ในชุดข้อมูล
	c	คือ จำนวนกลุ่มของข้อมูลของชุดข้อมูล
	n_j	คือ ค่าจำนวนชุดข้อมูลที่เป็นคลาสที่ j
	\bar{x}_i	คือ ค่าเฉลี่ยของคุณลักษณะที่ i
	\bar{x}_{ij}	คือ ค่าเฉลี่ยของคุณลักษณะที่ i ที่เป็นคลาสที่ j
	x	คือ จุดข้อมูลที่อยู่ในคลาสที่ j

- วิธีการการเลือกคุณลักษณะ Relief-F** เป็นวิธีเลือกคุณลักษณะประเภท Filter-based โดยวิธีการการจะเรียงลำดับคุณลักษณะตามน้ำหนักที่ได้จากระยะห่างของข้อมูลในคุณลักษณะ (Capela, Lemaire, และ Baddour, 2015) โดยมีสมมุติฐานของวิธีการนี้คือคุณลักษณะที่ดีควรมีกลุ่มข้อมูลเดียวกันอยู่ระยะที่ใกล้ และกลุ่มข้อมูลที่ต่างกันควรมีระยะที่ห่างกัน (Tian และคณะ, 2020) โดยในแต่ละรอบกำหนดสุ่มข้อมูลหนึ่งแถว ซึ่งกำหนดจำนวนจุดข้อมูลที่ใกล้เคียงกัน (Nearest neighbours) โดยจะแยกออกจุดใกล้เคียงออกเป็นสองแบบได้แก่ จุดข้อมูลที่เป็นกลุ่มเดียวกัน (H_j) (Nearest hit) และจุดข้อมูลที่ต่างกลุ่ม (M_j) (Nearest misses) นำมาคำนวณระยะห่างจากของชนิดข้อมูลที่เป็นตัวเลขดังสมการที่ 2.3 และคำนวณค่าความสำคัญแต่ละในคุณลักษณะดังภาพที่ 8

Algorithm 1: Relief-F

Input : for each training instance a vector of attribute values (A) and the class value
Output: the vector W of estimations of the qualities of attributes
1 set all weights $W[A] := 0.0$;
2 **for** $i := 1$ to m **do do**
3 randomly select an instance R_i ;
4 find k nearest hits H_j ;
5 **for each class** $C \neq \text{class}(R_i)$ **do do**
6 from class C find k nearest misses $M_j(C)$;
7 **end**
8 **for** $A := 1$ to a **do do**
9 $W[A] := W[A] - \sum_{j=1}^k \frac{\text{diff}(A, R_i, H_j)}{m \cdot k} + \sum_{C \neq \text{class}(R_i)} \frac{P(C)}{1 - P(\text{Class}(R_i))} \frac{\sum_{j=1}^k \text{diff}(A, R_i, M_j(C))}{m \cdot k}$
10 **end**
11 **end**


ภาพที่ 8 ขั้นตอนการทำงานของวิธีการเลือกคุณลักษณะ Relief-F

$$\text{diff}(A, I_1, I_2) = \frac{|\text{value}(A, I_1) - \text{value}(A, I_2)|}{\max(A) - \min(A)} \quad (2.3)$$

โดย A คือ คุณลักษณะที่กำลังพิจารณา
 I_1 คือ ค่าชุดข้อมูลที่ 1 ที่กำลังพิจารณา
 I_2 คือ ค่าชุดข้อมูลที่ 2 ที่กำลังพิจารณา
 diff คือ ค่าระยะทางระหว่างค่าที่ 1 และค่าที่ 2 ในคุณลักษณะ A


- วิธีการเลือกคุณลักษณะ Sequential Floating Forward Selection (SFFS)** เป็นวิธีเลือกคุณลักษณะประเภท Wrapper-based เป็นวิธีที่ต่อยอดมาจากวิธีการเลือกคุณลักษณะ Sequential Forward Selection (SFS) โดยเริ่มพิจารณาคุณลักษณะตั้งแต่หนึ่งคุณลักษณะ

จนถึงจำนวนคุณลักษณะที่ได้กำหนดไว้ แต่ได้เพิ่มความสามารถในการลดจำนวนคุณลักษณะที่ส่งผลให้ตัวแบบรู้จำกิจกรรมมีประสิทธิภาพลดลงในแต่ละรอบ ซึ่งวิธีการเลือกคุณลักษณะนี้ต้องสร้างตัวแบบรู้จำเพื่อใช้ในการวัดผลประสิทธิภาพของคุณลักษณะที่ถูกเลือกในแต่ละรอบ (Ahmed, Rafiq, และIslam, 2020) ดังภาพที่ 9



ภาพที่ 9 ขั้นตอนการทำงานของวิธีการเลือกคุณลักษณะ Sequential Floating Forward Selection

- วิธีการเลือกคุณลักษณะ Recursive Feature Elimination (RFE) เป็นวิธีการเลือกคุณลักษณะประเภท Wrapper-based (Ahmed, Rafiq, และIslam, 2020) ใช้หลักการลดจำนวนคุณลักษณะลงโดยพิจารณาจากความสำคัญของคุณลักษณะจากวิธีการรู้จำที่สามารถให้ค่าน้ำหนักในแต่ละคุณลักษณะได้ เช่นค่าน้ำหนัก (Weight coefficients) จากวิธีการรู้จำเชิงเส้น (Linear model), ซัพพอร์ตเวกเตอร์แมชชีนเชิงเส้น (Linear SVM) หรือการหาความสำคัญของคุณลักษณะจากวิธีการ Tree-based algorithms ซึ่งแต่ละรอบในการสร้างตัวแบบรู้จำจะลบคุณลักษณะที่มีความสำคัญน้อยที่สุดจนกว่าจะได้จำนวนคุณลักษณะที่กำหนด (Guyon และคณ, 2002) ขั้นตอนแสดงได้ดังภาพที่ 10



ภาพที่ 10 ขั้นตอนการทำงานของวิธีการเลือกคุณลักษณะ Recursive Feature Elimination

- การลดมิติของข้อมูล Principal Component Analysis (PCA) เป็นหนึ่งในวิธีการลดมิติ (Dimensionality reduction) คุณลักษณะใช้หลักการทางสถิติและเมทริกซ์แทนตัวข้อมูล โดยหาแกนที่เข้ากับข้อมูลในแต่ละคุณลักษณะให้ได้มากที่สุด ซึ่งจะได้ลำดับของแกนข้อมูลเรียงตามลำดับความสำคัญ ซึ่งจะนำตัดแกนที่เป็นตัวแทนของข้อมูลที่สำคัญน้อยทิ้งลงไป ซึ่งจะได้ลักษณะที่สำคัญในการโปรเจกชันลงบนแกนใหม่ ซึ่งการลดมิติของข้อมูลจะได้แกนข้อมูลใหม่ที่เป็นตัวแทนของข้อมูลชุดนั้น ต่างจากวิธีการเลือกคุณลักษณะที่ค่าภายในคุณลักษณะยังเป็นค่าเดิม

2.1.5 เครื่องมือในการสร้างตัวแบบรู้จำกิจกรรม

ในวิทยานิพนธ์นี้ได้พัฒนาสร้างตัวแบบรู้จำด้วยภาษาโปรแกรม Python (เวอร์ชัน 3.7) เป็นภาษาคอมพิวเตอร์ที่สามารถนำมาใช้พัฒนาโปรแกรมได้หลากหลายวัตถุประสงค์ ซึ่งจุดเด่นคือ Library สำหรับจัดการกับข้อมูล (Data management), การเรียนรู้ของเครื่องจักร (Machine Learning) และการสร้างแผนภาพจากข้อมูล (Data visualization) โดยมีรายละเอียดของไลบรารีที่ใช้ในการพัฒนาตัวแบบรู้จำกิจกรรมดังต่อไปนี้

- **Pandas (เวอร์ชัน 0.24.2)** เป็นไลบรารีที่ทำหน้าที่อ่านข้อมูลจากไฟล์, การเตรียมข้อมูล และการบันทึกข้อมูลลงบนไฟล์ ซึ่งไลบรารีมีชนิดข้อมูลที่เรียกว่า Data frame เป็นแทนในการจัดเก็บข้อมูลแบบตาราง (Tabular data)
- **Numpy (เวอร์ชัน 1.16.3)** เป็นไลบรารีที่มีกลุ่มคำสั่งในการคำนวณทางวิทยาศาสตร์ ตัวอย่างเช่น การคำนวณคณิตศาสตร์พื้นฐาน, พื้นฐานพีชคณิตเชิงเส้น (Linear Algebra), การคำนวณทางด้านสถิติ ซึ่งสามารถนำข้อมูลจากไลบรารี Pandas มาคำนวณเป็นข้อมูลนำเข้า (input) ให้กับไลบรารีที่ทำหน้าที่สร้างตัวแบบรู้จำกิจกรรมต่อไป
- **Scikit-learn (เวอร์ชัน 0.20.3)** เป็นไลบรารีในการสร้างแบบรู้จำ โดยสร้างตัวแทน (Object) ของวิธีการเรียนรู้ชนิดต่างๆ (Learning method) ตามการตั้งค่าพารามิเตอร์ (Parameters) ซึ่งไลบรารีมีวิธีการเรียนรู้ในการสร้างตัวแบบรู้จำตามวัตถุประสงค์ของงาน ได้แก่ การเรียนรู้แบบมีผู้สอน (Supervised Learning) และการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ซึ่งในหัวข้อ 2.1.6 ทฤษฎีการรู้จำรูปแบบจะมีส่วนในวิธีการเรียนรู้และพารามิเตอร์จากไลบรารีนี้มาใช้ในการสร้างตัวแบบรู้จำกิจกรรม
- **Matplotlib (เวอร์ชัน 3.0.3)** เป็นไลบรารีในการสร้างแผนภาพจากข้อมูล ซึ่งในงานวิทยานิพนธ์ได้นำมาสร้างรูปภาพที่ใช้อธิบายข้อมูลและผลการทดลอง

2.1.6 ทฤษฎีการรู้จำรูปแบบ

การรู้จำรูปแบบ (Pattern recognition) เป็นศาสตร์ทางวิทยาการคอมพิวเตอร์แขนงหนึ่งมีจุดประสงค์ให้คอมพิวเตอร์มีความสามารถจำแนกหรือแบ่งกลุ่มข้อมูลได้เมื่อมีข้อมูลผ่านเข้ามา โดยค้นหารูปแบบลักษณะของข้อมูลผ่านวิธีการเรียนรู้ (Learning algorithm) มาสร้างเป็นตัวแบบรู้จำ ซึ่งวิธีการเรียนรู้แบ่งออกเป็น 2 วิธีการได้แก่ วิธีการจำแนกข้อมูล (Classification algorithms) และวิธีการแบ่งข้อมูล (Clustering algorithms) ซึ่งในวิทยานิพนธ์นี้ได้้นำวิธีการขั้นตอนการจำแนกข้อมูลมาใช้ในการสร้างตัวแบบรู้จำกิจกรรม โดยชุดข้อมูลกิจกรรมจะมีแถวข้อมูลที่บ่งบอกว่าแถวข้อมูลนี้เป็นกิจกรรมอะไรและเรียนรู้ตามลักษณะข้อมูลของกลุ่มข้อมูลนั้น จึงเรียกขั้นตอนวิธีการจำแนกข้อมูลนี้ว่าขั้นตอนเรียนรู้แบบมีผู้สอน (Supervised learning) ในการประเมินประสิทธิภาพตัวแบบรู้จำจะแบ่งชุดข้อมูลออกเป็นสองชุดได้แก่ ข้อมูลฝึกสอน (Training data) นำมาใช้สร้างตัวแบบรู้จำและข้อมูลทดสอบ (Testing data) ที่นำมาใช้วัดประสิทธิภาพ โดยขั้นตอนวิธีการจำแนกข้อมูลที่นำมาใช้ในวิทยานิพนธ์มีรายละเอียดดังนี้

- การวิเคราะห์การจำแนกประเภทเชิงเส้น (Linear Discriminant Analysis) เป็นขั้นตอนการจำแนกกลุ่มข้อมูลแบบมีผู้สอนโดยที่จะลดจำนวนของมิติที่ไม่มีสำคัญในการจำแนกกลุ่มข้อมูลเพื่อที่จะลดภาระในการคำนวณหรือการเรียนรู้ของตัวแบบรู้จำมากเกินไป (Overfitting) ซึ่งคือหลักการทำงานคือทำการหาเส้นตรง (w) ที่นำมาเมื่อข้อมูลลงเส้นโปรเจกชันลงเส้นตรงที่หาค่าน้ำหนักได้แล้ว ($y = xw^T$) แล้วจะสามารถจำแนกกลุ่มข้อมูลได้มากที่สุด ซึ่งหาค่าความแปรปรวนภายในกลุ่ม (S_w) (Covariance within group) กับค่าความแปรปรวนระหว่างกลุ่ม (S_b) (Covariance between group) ดังสมการที่ 2.5 และ 2.6 ซึ่งวิธีการตั้งสมมติฐานว่าค่าเฉลี่ยของทั้งสองกลุ่มข้อมูลจะได้ค่าเฉลี่ยของเส้นตรงที่จะนำมาโปรเจกชันข้อมูล จึงนำทั้งสองค่าแปลงให้อยู่ในรูปสมการของ Fisher criterion เพื่อนำทั้งสองค่ามาหาอัตราส่วนสูงสุดที่อาจจะเป็นทิศทางเส้นตรงที่สามารถแบ่งกลุ่มข้อมูลให้ได้มากที่สุด ดังสมการที่ 2.6 จากนั้นจัดสมการให้อยู่ในรูปแบบโอเกนเวกเตอร์ (Eigenvectors) เพื่อแก้สมการดังสมการที่ 2.7 ซึ่งค่าโอเกนที่มีค่ามากที่สุดจะสัมพันธ์กับโอเกนเวกเตอร์ที่สามารถโปรเจกชันของข้อมูลที่สามารถจำแนกกลุ่มข้อมูลได้มากที่สุด ดังนั้นสามารถตัดโอเกนที่มีค่าน้อยที่จะลดมิติของข้อมูลได้

$$S_W = \sum_{i=1}^c \sum_{x \in C_i}^n (x - \bar{x}_i)(x - \bar{x}_i)^T \quad (2.4)$$

$$S_B = \sum_{x \in C_i}^c (\bar{x}_i - m)(\bar{x}_i - m)^T \quad (2.5)$$

$$J(w) = \frac{S_B}{S_W} \quad (2.6)$$

$$S_W^{-1} S_B w = \lambda w \quad (2.7)$$

โดย	x	คือ ค่าข้อมูลที่เป็นสมาชิกของกลุ่ม c
	\bar{x}_i	คือ ค่าเฉลี่ยของกลุ่มของข้อมูลที่ i
	m	คือ ค่าเฉลี่ยของข้อมูลทั้งหมด
	c	คือ ค่าจำนวนกลุ่มข้อมูล
	λ	คือ ค่าโอเกนที่นำมาพิจารณา
	w	คือ ค่าโอเกนเวกเตอร์ที่นำมาโปรเจกชัน

จากการขั้นตอนการลดมิติของข้อมูลขั้นตอนต่อไปเป็นการจำแนกกลุ่มข้อมูล ซึ่งการวิเคราะห์การจำแนกประเภทเชิงเส้นได้นำหลักการทฤษฎีของเบย์ (Naive Bayes) มาใช้ในการจำแนกกลุ่มของข้อมูลทดสอบแบบรู้จำ โดยหลักการจะตั้งสมมติฐานที่ความน่าจะเป็นกลุ่มข้อมูลนี้ในชุดข้อมูลนี้ ถ้าข้อมูลชุดนี้มีกลุ่มข้อมูลนี้มาก่อน ซึ่งลักษณะความน่าจะเป็นอย่างมีเงื่อนไข (Conditional Probability) ดังนั้นในสมการที่ 2.8 เป็นการประมาณค่าความน่าจะเป็น (Likelihood) ของแต่ละกลุ่มข้อมูล $P(x_i|y)$ ซึ่งกระแสข้อมูลเชิงเวลาเป็นค่าตัวเลขจึงใช้การแจกแจงปกติของตัวแปรหลายตัว (Multivariate gaussian distribution) ดังสมการที่ 2.9 ในการประมาณค่าที่จะเกิดขึ้นของกลุ่มข้อมูลเมื่อข้อมูลนำเข้าเป็นคุณลักษณะนั้นๆ จากนั้นนำแต่ละค่าความน่าจะเป็นได้ในแต่ละคุณลักษณะมาคูณรวมกับความน่าจะเป็นของกลุ่มนั้นจากข้อมูลสำหรับสร้างตัวแบบรู้จำและกลุ่มกิจกรรมที่ค่ามากที่สุด

$$\hat{y} = \operatorname{argmax} P(y) \prod_{i=1}^n P(x_i|y) \quad (2.8)$$

$$P(x_i|y) = \frac{1}{\sigma_y \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x_i - \mu_y}{\sigma_y} \right)^2} \quad (2.9)$$

โดย	n	คือจำนวนคุณลักษณะ
	\hat{y}	คือกลุ่มของข้อมูล
	$P(x_i y)$	คือค่าความน่าจะเป็นที่กลุ่มข้อมูล y เป็นเมื่อเป็นข้อมูลนำเข้าคุณลักษณะ x
	$P(y)$	คือ ค่าความน่าจะเป็นก่อนหน้าของกลุ่มข้อมูลนั้นๆ (Class Prior Probability)
	x_i	คือ ค่าความข้อมูลของคุณลักษณะที่ i จากข้อมูลทดสอบแบบรู้จำ
	μ_y	คือ ค่าเฉลี่ยของกลุ่ม y ที่มาของคุณลักษณะที่ i จากข้อมูลสำหรับสร้างตัวแบบรู้จำ
	σ_y	คือค่าความแปรปรวนของกลุ่ม y ที่มาของคุณลักษณะที่ i จากข้อมูลสำหรับสร้างตัวแบบรู้จำ

ซึ่งในไลบรารี Scikit-Learn มีคลาสเมธอด LinearDiscriminantAnalysis ในสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการวิเคราะห์การจำแนกประเภทเชิงเส้นโดยมีพารามิเตอร์ที่ในวิทยานิพนธ์ดังตารางที่ 5

ตารางที่ 5 พารามิเตอร์ของคลาสเมธอด `LinearDiscriminantAnalysis` จากไลบรารี `Scikit-learn`

ชื่อพารามิเตอร์	คำอธิบายและค่าเริ่มต้น
<code>n_components</code>	จำนวนมิติที่ต้องการลด (โปรเจกชัน) ซึ่งค่าเริ่มต้นจะเลือกจากจำนวนที่น้อยที่สุดระหว่างจำนวนที่กลุ่มข้อมูลลบด้วย 1 (<code>n_classes - 1</code>) หรือจำนวนคุณลักษณะ (<code>n_features</code>)

- วิธีการสร้างตัวแบบรู้จำซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine)** เป็นขั้นตอนวิธีการจำแนกกลุ่มข้อมูล ซึ่งหลักการการทำงานคือมีเส้นขอบที่จะมาช่วยกำหนดเส้นที่แบ่งกลุ่มข้อมูลซึ่งเรียกเส้นที่มาช่วยให้การกำหนดเรียกว่า ซัพพอร์ตเวกเตอร์ (Support vector) โดยจะพิจารณาจากจุดที่ใกล้ที่สุดโดยมีเส้นขอบ (Margin) และพยายามให้ระยะห่างระหว่างเส้นแบ่งกลุ่มข้อมูลและเส้นขอบให้ได้มากที่สุดและค่าผิดพลาดที่อยู่ระหว่างเส้นแบ่งและเส้นขอบให้น้อยที่สุดซึ่งจะทำให้เส้นแบ่งอยู่ระหว่างทั้งสองกลุ่มอย่างเหมาะสม นอกจากนี้สามารถใช้งานร่วมกับข้อมูลที่มีลักษณะไม่เป็นเชิงเส้น (Non-linear) โดยการเปลี่ยนแปลงมิติของข้อมูลโดยใช้ฟังก์ชันอื่นๆ ทางคณิตศาสตร์แล้วแบ่งกลุ่มของข้อมูลด้วยเส้นตรง ซึ่งเรียกฟังก์ชันทางคณิตศาสตร์ว่า Kernel ยกตัวอย่างเช่น ฟังก์ชันเส้นตรง (Linear kernel) ดังสมการที่ 2.10, ฟังก์ชันเส้นโค้ง (Polynomial kernel) ดังสมการที่ 2.11 และ ฟังก์ชันรัศมี (Radial basis function kernel) ที่เหมาะกับข้อมูลที่กระจุกอยู่ระหว่างกลางของกลุ่มข้อมูลอื่นดังสมการที่ 2.12

$$K(x_i, x_j) = x_i^t x_j \quad (2.10)$$

$$K(x_i, x_j) = (1 + (x_i x_j))^d \quad (2.11)$$

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2.12)$$

ซึ่งในไลบรารี `Scikit-learn` มีคลาสเมธอด `svm.SVC` ในสร้างตัวแบบรู้จำกิจกรรมโดยมีพารามิเตอร์ที่ในวิทยานิพนธ์ดังตารางที่ 6

ตารางที่ 6 พารามิเตอร์ของคลาสเมธอด `svm.SVC` จากไลบรารี `Scikit-learn`

ชื่อพารามิเตอร์	คำอธิบายและค่าเริ่มต้น
<code>kernel</code>	เป็นพารามิเตอร์ที่กำหนดการตัดสินใจ (Decision Boundary) ค่าเริ่มต้นเท่ากับ RBF
<code>C</code>	เป็นพารามิเตอร์ที่ควบคุมระยะเส้นขอบของ Support vector โดยมีค่ามากจะทำให้ขอบเขตในการพิจารณาข้อมูลแคบลง ค่าเริ่มต้นเท่ากับ 1

gamma	เป็นพารามิเตอร์ที่ใช้เฉพาะ Kernel RBF เพื่อควบคุมระยะของข้อมูลที่กำลังพิจารณาเป็นกลุ่มเดียวกัน ค่าเริ่มต้นเท่ากับ
decision_function_shape	เป็นพารามิเตอร์ในการกำหนดรูปแบบการสร้างตัวแบบสำหรับรู้จำข้อมูลที่มีมากกว่าสองกลุ่ม ค่าเริ่มต้นเท่ากับ OVR (One-vs-rest)

- วิธีการสร้างตัวแบบรู้จำรูปแบบเชิงเส้นด้วยการปรับพารามิเตอร์ด้วย Stochastic gradient descent** โดยเป็นวิธีการสร้างตัวแบบรู้จำเชิงเส้น (Linear model) โดยมีพื้นฐานมาจากฟังก์ชันความผิดพลาด (Convex loss function) ที่จะปรับพารามิเตอร์ที่เหมาะสมให้ตัวแบบรู้จำรูปแบบข้อมูลโดยใช้หลักการ Gradient descent ไปยังค่าน้ำหนัก (Weight) และค่าไบแอส (Bias) เพื่อให้ได้ค่าความผิดพลาดจากตัวแบบรู้จำให้ต่ำที่สุด (Saez, Baldominos, และ Isasi, 2017) ประเภทฟังก์ชันความผิดพลาดได้แก่ Hinge, Perceptron, Logistic regression, Linear regression (Ridge, Lasso) เป็นต้น ซึ่งในวิทยานิพนธ์นี้ใช้ฟังก์ชันการวัดค่าความผิดพลาด hinge (soft-margin) ที่มีลักษณะคล้ายกับ Linear Kernel ของทฤษฎีรู้จำ SVM ดังสมการที่ 2.13 และ 2.14 โดยฟังก์ชัน Regularization จะลดช่วยความสำคัญของค่าน้ำหนักเพื่อป้องกันการเกิด Overfitting ในตัวแบบรู้จำดังสมการที่ 2.15 นำมารวมกันในการประเมินค่าความผิดพลาดโดยเฉลี่ยของพารามิเตอร์ค่าน้ำหนักและไบแอสในแต่รอบในการสร้างตัวแบบรู้จำดังสมการที่ 2.16

$$f(x) = w^T x + b \quad (2.13)$$

$$L(y_i, f(x_i)) = \max(0, 1 - y_i f(x_i)) \quad (2.14)$$

$$R(w) = \frac{1}{2} \sum_{j=1}^m w_j^2 = \|w\|_2^2 \quad (2.15)$$

$$E(w, b) = \frac{1}{n} \sum_{i=1}^n L(y_i, f(x_i)) + \alpha R(w) \quad (2.16)$$

โดย	L	คือ ฟังก์ชันวัดความผิดพลาดของตัวแบบรู้จำกิจกรรม
	R	คือ ฟังก์ชัน Ridge Regression สำหรับการทำให้ Regularization
	α	คือ ค่าพารามิเตอร์ที่ช่วยปรับค่า Regularization ให้มีความสำคัญมากหรือน้อย
	$f(x_i)$	คือ ตัวแบบรู้จำเชิงเส้นที่ค่าสร้างจากชุดข้อมูล x_i
	n	คือ จำนวนแถวข้อมูล

$E(w, b)$ คือ ค่าประสิทธิภาพโดยเฉลี่ยที่ได้จากตัวแบบรู้จำเชิงเส้นที่ค่าน้ำหนักและไบแอส (w, b)

ซึ่งในไลบรารี Scikit-learn มีคลาสเมธอด `SGDClassifier` ในสร้างตัวแบบรู้จำกิจกรรม โดยมีพารามิเตอร์ที่ใช้ในวิทยานิพนธ์ดังตารางที่ 8

ตารางที่ 7 พารามิเตอร์ของคลาสเมธอด `SGDClassifier` จากไลบรารี `Scikit-learn`

ชื่อพารามิเตอร์	คำอธิบายและค่าเริ่มต้น
loss	เป็นพารามิเตอร์ในการกำหนดฟังก์ชันความผิดพลาด ค่าเริ่มต้นคือฟังก์ชัน hinge
penalty	เป็นพารามิเตอร์ที่กำหนดฟังก์ชันในควบคุมเพื่อไม่ให้ตัวแบบรู้จำเรียนรู้น้อยหรือมากเกินไป (Regularization) ค่าเริ่มต้นคือฟังก์ชัน L2 (Ridge)
alpha	เป็นพารามิเตอร์ที่ควบคุมความสำคัญของพารามิเตอร์พารามิเตอร์ penalty ค่าเริ่มต้นเท่ากับ 0.0001

2.1.6 การรู้จำกิจกรรม

ในวิทยานิพนธ์นี้มุ่งเน้นการรู้จำกิจกรรมทางการภาพโดยใช้กระแสข้อมูลเชิงเวลาจากตัวรับรู้จากอุปกรณ์นาฬิกาอัจฉริยะหรืออุปกรณ์ที่สวมใส่ข้อมือ ซึ่งการได้ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมจากข้อมูลประกอบไปด้วย 5 ขั้นตอนหลัก (Demrozi และคณะ, 2020) ดังภาพที่ 11 โดยมีรายละเอียดดังต่อไปนี้

1) ขั้นตอนการเก็บกระแสข้อมูลเชิงเวลาจากตัวรู้ เป็นขั้นตอนการเก็บกระแสข้อมูลเชิงเวลาจากตัวรับรู้ด้วยอัตราสุ่มตัวอย่างที่กำหนดมาบนอุปกรณ์ ซึ่งลักษณะกระแสข้อมูลเชิงเวลาขึ้นอยู่กับลักษณะกิจกรรมของอาสาสมัครขณะกระทำ, สภาพแวดล้อมขณะทำกิจกรรม, การตั้งค่าและตำแหน่งอุปกรณ์หรือตัวรับรู้และเงื่อนไขบางอย่างในการทำกิจกรรม ชนิดของข้อมูลส่วนใหญ่ที่ได้รับจากตัวรับรู้เป็นชนิดตัวเลขที่ต่อเนื่องกัน (Continuous data)


2) ขั้นตอนการเตรียมข้อมูล เป็นขั้นตอนตรวจสอบว่ากระแสข้อมูลเชิงเวลาที่ได้รับมีสภาพสมบูรณ์หรือไม่ ในขั้นตอนนี้มีหลากหลายวิธีการที่จัดการกับชุดฐานข้อมูลกิจกรรมออนไลน์ ตัวอย่างเช่น การค้นหาว่าข้อมูลเกิดการหายข้อมูลไป (Missing data), การแยกข้อมูลอะไรบางอย่างออกจากกระแสข้อมูลในบางตัวรับรู้ที่มีมาให้, การปรับข้อมูลให้เรียบ (Smoothing data) เป็นต้น และ

ในขั้นตอนนี้สามารถกำหนดรูปแบบการแบ่งชุดข้อมูลออกเป็นสองส่วนได้แก่ ข้อมูลสำหรับเรียนรู้ (Training set) และข้อมูลสำหรับทดสอบ (Testing set) ซึ่งให้พร้อมนำไปใช้ในขั้นตอนถัดไป

3) ขั้นตอนการสกัดคุณลักษณะ เป็นขั้นตอนในการคำนวณคุณลักษณะที่สำคัญจากข้อมูล สำหรับการเรียนรู้โดยวิธีการการคำนวณทางสถิติและการคำนวณทางความถี่ที่จะนำไปใช้ในขั้นตอนสร้างตัวแบบรู้จำกิจกรรม

4) ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม เป็นขั้นตอนในการสร้างตัวแบบรู้จำกิจกรรมจากคุณลักษณะร่วมกับทฤษฎีการรู้จำรูปแบบ ซึ่งจะต้องกำหนดพารามิเตอร์ต่าง ๆ ของวิธีการที่เลือกผลลัพธ์ที่ได้ตัวแบบรู้จำกิจกรรม (Activity Recognition Model)

5) ขั้นตอนการวัดประสิทธิภาพตัวแบบรู้จำกิจกรรม เป็นขั้นตอนการนำตัวแบบรู้จำกิจกรรมมารู้จำกิจกรรมจากชุดข้อมูลสำหรับทดสอบ ที่จะนำข้อมูลที่ละหนึ่งตัวอย่างและระบุให้ได้ว่าข้อมูลชุดนั้นเป็นกิจกรรมอะไร ซึ่งวิธีการวัดประสิทธิภาพต่าง ๆ เป็นสิ่งสำคัญที่จะบอกได้ว่าตัวแบบรู้จำกิจกรรมที่สร้างขึ้นสามารถระบุได้อย่างมีถูกต้องมากน้อยเท่าไร




ภาพที่ 11 ขั้นตอนการรู้จำกิจกรรม

2.2 งานวิจัยที่เกี่ยวข้อง

Chernbumroong, Atkins, และ Yu (2011) ได้นำเสนอวิธีการรู้จำกิจกรรมในชีวิตประจำวันโดยที่ให้ความสำคัญต่อตำแหน่งของอุปกรณ์ในการเก็บข้อมูล ซึ่งงานวิจัยได้ศึกษาพบว่าการติดตั้งอุปกรณ์ส่วนใหญ่ไว้ตำแหน่งเอว, หลังหรือแขนเป็นหลักที่อาจจะไม่เหมาะสมสำหรับการใช้งานประจำวัน จึงได้ทำการทดลองสร้างตัวแบบรู้จำกิจกรรม (automatic activity classification) โดยใช้อุปกรณ์หนึ่งตัวที่สวมใส่ที่ข้อมือที่เป็นตำแหน่งที่เหมาะสมมากกว่าในการรู้จำกิจกรรม ซึ่งได้ทำการทดลองเก็บข้อมูลการทำกิจกรรมทั้งหมด 5 กิจกรรมได้แก่ การนั่ง การยืน การนอน การเดิน การวิ่ง จากตัวรับรู้ Accelerometer ของนาฬิกาอัจฉริยะดังภาพที่ 11a ซึ่งนำกระแสข้อมูลเชิงเวลามาแบ่งและสกัดคุณลักษณะทางคณิตศาสตร์สถิติ (Time domain) และทางความถี่ (Frequency Domain) โดยได้ทดลองกับวิธีการเลือกคุณลักษณะต่างๆ และนำสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการเรียนรู้


Decision Tree (C4.5) และ Artificial Neural Network (ANN) ดังภาพที่ 12(b) ผลการทดลองแสดงให้เห็นว่าการเลือกคุณลักษณะที่ถูกคัดเลือกและวิธีการขั้นตอนเรียนรู้ Decision Tree (C4.5) มีประสิทธิภาพในการระบุกิจกรรมได้ถูกต้องสูงถึง 94.13% ซึ่งเป็นตัวเลขที่สูง แต่ยังคงขาดปัจจัยอื่นที่มีผลต่อประสิทธิภาพในการรู้จำมารวมพิจารณาด้วยเช่น การใช้ฐานข้อมูลที่มาจากแหล่งเดียวอาจจะไม่มีลักษณะข้อมูลในรูปแบบอื่นและการวิธีการวัดประสิทธิภาพที่อาจจะให้ผลไบแอส (Bias) เนื่องจากมีข้อมูลของผู้ใช้ของผู้ทดสอบเข้ามาเกี่ยวข้องขณะสร้างตัวแบบรู้จำ



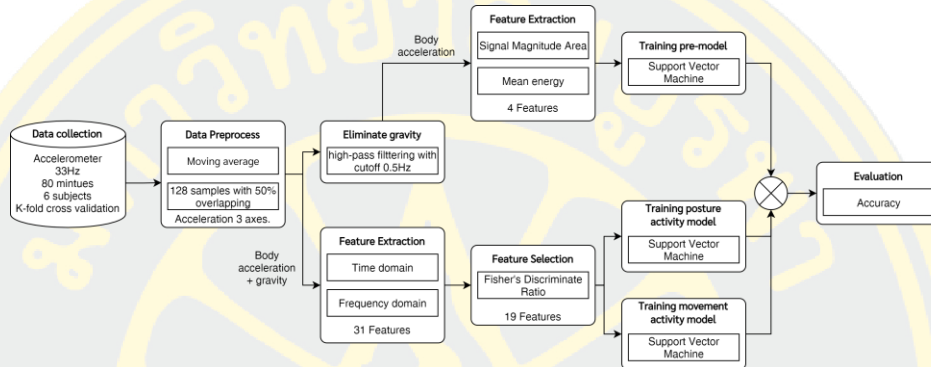
ภาพที่ 12 ภาพการเก็บข้อมูลขณะทำกิจกรรม (a) และแผนภาพขั้นตอนการสร้างตัวแบบรู้จำกิจกรรม (b) (Chembumroong, Atkins, และ Yu, 2011)

Da Silva และ Galeazzo (2013) ได้นำเสนอระบบการรู้จำกิจกรรมสองรูปแบบได้แก่ รูปแบบที่หนึ่งที่มีตัวแบบรู้จำกิจกรรมเพียงตัวแบบเดียวภาพที่ 13a และรูปแบบที่สองที่มีตัวแบบรู้จำแยกตามประเภทกิจกรรมได้แก่ ตัวแบบรู้จำกิจกรรมอยู่กับที่ (Posture) และตัวแบบรู้จำกิจกรรมเคลื่อนไหว (Movement) ซึ่งจะมีตัวแบบรู้จำประเภทกิจกรรมรวมกันทั้งหมด 3 ตัวแบบรู้จำกิจกรรมดังภาพที่ 12b โดยเก็บข้อมูลการทำกิจกรรมจำนวน 8 กิจกรรมได้แก่ การนอน, การนั่ง, การยืน, การทำงานบนคอมพิวเตอร์, การเดิน, การเดินขึ้นบันได, การเดินลงบันได, การวิ่ง จากตัวรับรู้ Accelerometer ของนาฬิกาอัจฉริยะดังภาพที่ 13c ซึ่งนำมาผ่านขั้นตอนการสกัดและเลือกคุณลักษณะและสร้างตัวแบบรู้จำกิจกรรมโดยวิธีการเรียนรู้ SVM ซึ่งผลการทดลองแสดงให้เห็นถึงประสิทธิภาพในการระบุกิจกรรมได้ถูกต้องของรูปแบบที่หนึ่งและรูปแบบที่สอง 93.47% และ 90.63% ตามลำดับ แสดงว่าถึง

จะมีการแยกตัวแบบรู้จำตามประเภทของกิจกรรมที่ได้ประสิทธิภาพน้อยกว่า โดยให้เหตุผลว่ามีปัญหา
กับตัวแบบรู้จำประเภทกิจกรรมที่ทำงานผิดพลาดค่อนข้างมากกว่า



(a)



(b)




(c)

ภาพที่ 13 กรอบแนวคิดงานวิจัยและอุปกรณ์ในการเก็บข้อมูลของ Da Silva และ Galeazzo (2013)

Mortazavi และคณะ (2015) ได้ตั้งคำถามการทดลองที่ว่านาฬิกาอัจฉริยะจะสามารถในการ
รู้จำกิจกรรมนั้นได้อย่างถูกต้องเทียบเท่ากับอุปกรณ์สมาร์ทโฟนได้หรือไม่ ซึ่งทดลองเก็บข้อมูลจากตัว
รับรู้ Accelerometer และ Gyroscope ที่เน้นเก็บการเปลี่ยนกิจกรรมและการทำกิจกรรมที่นิ่งที่ใน
อริยาบถต่าง ๆ เช่นการยืนใช้งานสมาร์ทโฟน การนั่งทำงานบนคอมพิวเตอร์ การนอนอ่านหนังสือ
 เป็นต้น และสร้างเป็นแบบรู้จำกิจกรรมโดยวิธี Support Vector Machine (SVM-PUK) บน
ซอฟต์แวร์ Weka ซึ่งผู้วิจัยได้สรุปผลการทดลองได้ว่านาฬิกาอัจฉริยะสามารถรู้จำกิจกรรมอยู่กับที่ได้
เทียบเท่าสมาร์ทโฟน

Shoaib และคณะ (2015) ศึกษาการรู้จำกิจกรรมบนหนึ่งอุปกรณ์หรือร่วมกันระหว่างสมาร์ทโฟนและอุปกรณ์ที่สวมใส่ข้อมือที่มีตัวรับรู้ Accelerometer และ Gyroscope โดยกำหนดพารามิเตอร์ในการทดลองได้แก่ ขนาดของ Windows เท่ากับ 2 วินาทีที่ Overlapping เท่ากับ 50 เปอร์เซ็นต์ ซึ่งพิจารณาค่าสถิติสองค่าได้แก่ ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานบนแกนของตัวรับรู้ทั้งสามแกน (X, Y และ Z) และ Magnitude ของแต่ละตัวรับรู้ทั้งหมด 16 คุณลักษณะจากนั้นสร้างเป็นแบบจำลองกิจกรรมบนซอฟต์แวร์ Weka โดยวิธีการ Decision tree (J48), K-nearest neighbor (IB1) และ SVM (LibSVM) และประเมินตัวแบบรู้จำกิจกรรมด้วยวิธีการ 10-fold cross validation ดังภาพที่ 14 ซึ่งผลการทดลองเบื้องต้นการนำกระแสข้อมูลเชิงเวลาจากทั้งสองตัวรับรู้ร่วมกันบนอุปกรณ์นาฬิกาอัจฉริยะมีประสิทธิภาพใกล้เคียงกับการใช้กระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer ของสมาร์ทโฟนและอุปกรณ์ที่สวมใส่ข้อมือ จะช่วยเพิ่มประสิทธิภาพในการรู้จำกิจกรรมทางกายภาพที่ซับซ้อนกันสูงเช่นกิจกรรมเดินและเดินขึ้นลงบันได แต่อย่างไรก็ตามผลการทดลองที่ตีพิมพ์เป็นผลการทดลองเบื้องต้นที่ทดลองกับวิธีการสร้างตัวแบบรู้จำที่ยังไม่ถูกปรับและทดลองกับฐานข้อมูลเพียงหนึ่งฐานข้อมูลเท่านั้น อีกทั้งวิธีการประเมินผลตัวแบบรู้จำกิจกรรมที่ให้ไปแอสกับข้อมูลทดสอบ



ภาพที่ 14 กรอบแนวคิดงานของวิจัย Shoaib และคณะ (2015)

Shahmohammadi และคณะ (2017) ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมเฉพาะบุคคล (Personal model) โดยใช้วิธีการ Active Learning เพื่อให้ผู้ใช้บอกกิจกรรมในขณะที่กำลังสร้างตัวแบบรู้จำกิจกรรมก่อนที่จะรู้จำกิจกรรม ซึ่งเก็บข้อมูลกิจกรรมได้แก่ การนั่ง การยืน การนอน การเดินและการวิ่งจากตัวรับรู้ Accelerometer และ Gyroscope จากนาฬิกาอัจฉริยะเทียบกับประสิทธิภาพกับขั้นตอนวิธีการเรียนรู้แบบมีผู้สอนต่าง ๆ

Chowdhury และคณะ (2017) ได้นำเสนอระบบการรู้จำกิจกรรมทางกายภาพจากกระแสข้อมูลเชิงเวลาการทำกิจกรรมจากตัวรับรู้ Accelerometer บนอุปกรณ์ ณ ตำแหน่งข้อมือโดยเน้นประเมินวิธีการเรียนรู้การสร้างตัวแบบรู้จำในประเภทต่างๆ ซึ่งได้นำฐานข้อมูลที่เป็นฐานข้อมูลสาธารณะที่มีชื่อว่า PAMAP2 และฐานข้อมูลที่เกิดขึ้นเองในห้องปฏิบัติการมาใช้ในการทดลองโดยคำนวณในแต่ละแกนข้อมูลตัวรับรู้จำนวนคุณลักษณะที่จำนวน 16 คุณลักษณะ ดังตารางที่ 8 จากนั้นนำวิธีการ


Data normalization ในปรับค่าแต่ละคุณลักษณะและเลือกคุณเลือกด้วยวิธีการ Correlation-based ดังภาพที่ 15 จากนั้นนำมาสร้างเป็นตัวแบบรู้จำกิจกรรมด้วยวิธีการต่างๆ ดังตารางที่ 9 ซึ่งผลการทดลองวัดประสิทธิภาพที่ได้ดีที่สุดในแต่ละประเภทได้แก่ SVM, Random Forest และ Weighted Majority Voting มีประสิทธิภาพในการรู้จำกิจกรรมได้ถูกต้อง 81.4%, 83.22% และ 85.64% ตามลำดับ จะเห็นได้ว่าวิธีการสร้างตัวแบบรู้จำกิจกรรมที่มีหลายตัวแบบรู้จำมาช่วยในการระบุกิจกรรมทำให้มีประสิทธิภาพในการรู้จำกิจกรรมสูงขึ้น ซึ่งข้อจำกัดคือการนำมาใช้กับการรู้จำข้อมูลที่ไม่เคยเรียนรู้ข้อมูลชุดนั้นมาก่อน (Streaming data) หากนำวิธีการ Data normalization อาจจะทำให้ได้ขอบเขต (Scale) ของข้อมูลเพี้ยนได้

ตารางที่ 8 คุณลักษณะที่นำเสนอในงานวิจัย Chowdhury และคณะ (2017)

ประเภทคุณลักษณะ	คุณลักษณะในประเภท
การคำนวณทางคณิตศาสตร์สถิติ	Mean, Standard deviation, Minimum, Maximum, Variance, Median, Skewness, 25th percentile, 75th percentile, Kurtosis, Zero crossings, และ cross-axis correlations
การคำนวณทางความถี่	Spectral energy, Dominant frequency, Dominant frequency magnitude

ตารางที่ 9 ประเภทคุณลักษณะที่นำเสนอในงานวิจัย Chowdhury และคณะ (2017)

ประเภทการเรียนรู้	วิธีการเรียนรู้
Single model	K-nearest neighbors (KNN), Binary Decision Tree (BDT), Support Vector Machines (SVM) และ Artificial Neural Networks (ANNs)
Conventional Ensemble	Bagging, Boosting และ Random Forest
Custom Ensemble	Weighted Majority Voting (WMV) Naive Bayes Combiner (NB) และ Behaviour Knowledge Space (BKS)



ภาพที่ 15 กรอบแนวคิดของงานวิจัย Chowdhury และคณะ (2017)


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

Chowdhury และคณะ (2018) ได้นำเสนอระบบรู้จำกิจกรรมทางกายภาพจากตัวรับรู้ Accelerometer ณ ตำแหน่งต่าง ๆ ของร่างกาย (เข่า, หน้าอก, ข้อมือ) ในงานวิจัยนี้จะแสดงผลทดลองวัดประสิทธิภาพของหนึ่งหรือหลายตัวรับรู้รับในการระบุกิจกรรม ในขั้นตอนการสร้างแบบรู้จำและพิจารณาค่าน้ำหนักโดยนำเสนอวิธีการ Posterior-adapted class-based weighted ที่มีต่อยอดมากกับวิธีการ Class-based weighted decision fusion ที่จะนำค่าน้ำหนักที่ได้รับมาจากการวัดประสิทธิภาพของตัวแบบรู้จำในการรู้จำแต่ละกิจกรรมได้มากน้อยเท่าไร ซึ่งจะมีขั้นตอนการปรับค่าผลความน่าจะเป็นในแต่ละกลุ่มกิจกรรม (Posterior probability) ที่ได้จากชุดข้อมูลสำหรับทดสอบร่วมกับค่าน้ำหนัก โดยงานวิจัยจะเปรียบเทียบกับวิธีการ Model-based weighted voting ซึ่งการกำหนดค่าน้ำหนักขึ้นอยู่กับประสิทธิภาพทั้งหมดของแต่ละตัวแบบรู้จำ ไม่มีการคำนึงถึงกลุ่มข้อมูล ดังนั้นค่าน้ำหนักที่ได้จะไม่เกี่ยวข้องกับกลุ่มกิจกรรมและในการรวมค่าน้ำหนักจะใช้หลักการ Weighted majority vote โดยระบบรู้จำกิจกรรมมีรายละเอียดขั้นตอนต่อไปนี้

ขั้นตอนที่ 1 สร้างตัวแบบรู้จำกิจกรรม (Training phase) โดยนำกระแสข้อมูลเชิงเวลา Accelerometer มาตัดแบ่งข้อมูลใช้หลักการ Sliding window โดยไม่มีการคิดข้อมูลเก่าจาก Window ก่อนหน้านี้ (non-overlapping) ซึ่งกำหนดขนาดของ Window เท่ากับ 2 วินาที ซึ่งจะสกัดคุณลักษณะในแต่ละ Window จำนวน 45 คุณลักษณะดังตารางที่ 10 จากนั้นนำหลักการ Normalization ในปรับค่าแต่ละคุณลักษณะและการเลือกคุณเลือกด้วยวิธีการ Correlation-based และวิธีการสร้างตัวแบบรู้จำกิจกรรม SVM ในการสร้างตัวแบบรู้จำกิจกรรมดังภาพที่ 16

ตารางที่ 10 คุณลักษณะที่นำเสนอในงานวิจัย Chowdhury และคณะ (2018)

ประเภทคุณลักษณะ	คุณลักษณะในประเภท
การคำนวณทางสถิติ	Mean, Standard deviation, Minimum, Maximum, Variance, Median, Skewness, 25th percentile, 75th percentil Kurtosis, Median crossings, Energy และ cross-axis correlations
การคำนวณทางความถี่	Dominant frequency, Dominant frequency magnitude




ภาพที่ 16 ภาพขั้นตอนในการคำนวณค่าน้ำหนักของงานวิจัย Chowdhury และคณะ (2018)

ขั้นตอนที่ 2 ขั้นตอนการคำนวณน้ำหนัก (Weight calculation phase) จะแบ่งข้อมูลสำหรับการสร้างตัวแบบรู้จำกิจกรรมโดยใช้หลักการ 10-fold cross validation จากนั้นรวมผลการระบุกิจกรรมในแต่ละรอบ (Fold) และวัดผลประสิทธิภาพด้วย F-measure ให้กับของทุกกลุ่มข้อมูลกิจกรรมดังภาพที่ 17 ดังนั้นผลลัพธ์ที่ได้คือ F-measure ที่เป็นค่าน้ำหนักทุกกลุ่มกิจกรรมในแต่ละตัวแบบรู้จำแทนด้วย $W_1 = \{W_{11}, W_{12} \dots W_{1n}\}$ โดยที่ใน W_{1i} กลุ่มค่าน้ำหนักของกลุ่มกิจกรรมของตัวแบบรู้จำที่ i เช่น $\{w_{1i1}, w_{1i2} \dots w_{1im}\}$ และสามารถหาค่าเฉลี่ยประสิทธิภาพของแต่ละตัวแบบรู้จำกิจกรรมดังสมการที่ 2.17


$$W_{avgi} = \overline{w_{1i}} , 1 \leq i \leq n \quad (2.17)$$

โดย W_{avgi} คือ ค่าน้ำหนักโดยเฉลี่ยของตัวแบบรู้จำที่ i
 w_{1i} คือ ค่าน้ำหนักของทุกกิจกรรมของตัวแบบรู้จำที่ i
 n คือ จำนวนตัวแบบรู้จำกิจกรรม



ภาพที่ 17 ภาพขั้นตอนในการคำนวณค่าน้ำหนักของงานวิจัย Chowdhury และคณะ (2018)

ขั้นตอนที่ 3 การรู้จำกิจกรรมและปรับค่าน้ำหนัก (Individual model decision phase) ชุดข้อมูลทดสอบจะถูกแบ่งตามขนาดผ่าน Window ที่กำหนดไว้และผ่านกระบวนการในการระบุกิจกรรม ซึ่งผลลัพธ์ที่ได้จะได้กลุ่มข้อมูลกิจกรรมแทนด้วย $V_i(x)$ และความน่าจะเป็น (posterior probabilities) ของข้อมูลกิจกรรมที่ถูกระบุจากตัวแบบรู้จำกิจกรรมแทนด้วย W_{2i} ดังภาพที่ 18



ภาพที่ 18 ภาพขั้นตอนในการรู้จำกิจกรรมของงานวิจัย Chowdhury และคณะ (2018)

จากนั้นเริ่มขั้นตอนปรับค่าน้ำหนักดังภาพที่ 19 โดยเริ่มกำหนดค่าเริ่มต้นค่าน้ำหนัก W ของตัวแบบรู้จำที่ i ของชุดข้อมูลทดสอบ x เริ่มต้นเท่ากับ W_1 ดังสมการที่ 2.18 และปรับค่าน้ำหนักของแต่ละตัวแบบรู้จำกิจกรรมและแต่ละกลุ่มกิจกรรมดังสมการที่ 2.19


$$W_i(x) = W_{1i}, 1 \leq i \leq n \quad (2.18)$$

$$w_{ik} = (\alpha * w_{ik} + (1 - \alpha) * W_{2i}); 1 \leq k \leq m, 1 \leq i \leq n, V_i = C_k \quad (2.19)$$

โดย W_i คือ ค่าน้ำหนักของแต่ละตัวแบบรู้จำกิจกรรมที่ i หลังจากการปรับของแต่ละข้อมูลทดสอบ

W_{1i} คือ ค่าน้ำหนักจากขั้นตอนคำนวณค่าน้ำหนักจากข้อมูลสำหรับสร้างตัวแบบรู้จำที่ i

- α คือ ค่าปรับ Weight โดยกำหนดเป็นค่า 0 ถึง 1
- w_{ik} คือ ค่าน้ำหนักของกลุ่มกิจกรรมที่ k ของตัวแบบรู้จำที่ i
- W_{2i} คือ ค่าความน่าจะเป็นกลุ่มกิจกรรมที่ i
- m คือ จำนวนกลุ่มกิจกรรม
- n คือ จำนวนตัวแบบรู้จำกิจกรรม
- V_i คือ กลุ่มกิจกรรมที่ถูกระบุจากตัวแบบรู้จำกิจกรรมที่ i
- C_k คือ กลุ่มกิจกรรมที่ k



ภาพที่ 19 ขั้นตอนการปรับค่าน้ำหนักของวิจัย Chowdhury และคณะ (2018)

ขั้นตอนที่ 4 การรวมค่าน้ำหนักเพื่อระบุกิจกรรม (Decision Fusion Phase) ขั้นตอนนี้เป็นการรวมค่าน้ำหนักที่ได้จากขั้นตอนปรับค่าน้ำหนักเพื่อระบุกิจกรรมสุดท้ายดังภาพที่ 20 ซึ่งวิธีการระบุกิจกรรมแบบ Model-based weighted voting จะพิจารณาค่าเฉลี่ยของค่าน้ำหนักของกลุ่มกิจกรรมที่ตัวแบบรู้จำกิจกรรมที่ระบุได้ดังสมการที่ 2.20 และระบุกิจกรรมที่มีค่าคะแนนสูงที่สุด จะแตกต่างกับวิธีการระบุกิจกรรมแบบ Class-based weighted decision fusion จะพิจารณา w_1 เป็นค่าน้ำหนักที่ยังไม่ถูกปรับของแต่ละกลุ่มกิจกรรมของตัวแบบรู้จำกิจกรรม ดังสมการที่ 2.21 และวิธีการระบุกิจกรรมแบบ Posterior-adapted class-based จะพิจารณาจากค่าน้ำหนักที่ถูกปรับแล้ว w ของแต่ละกลุ่มกิจกรรมของตัวแบบรู้จำกิจกรรม ดังสมการที่ 2.22 และรวมค่าคะแนนของแต่ละกลุ่มกิจกรรมและเลือกกลุ่มกิจกรรมที่มีค่าคะแนนมากที่สุดดังสมการที่ 2.23

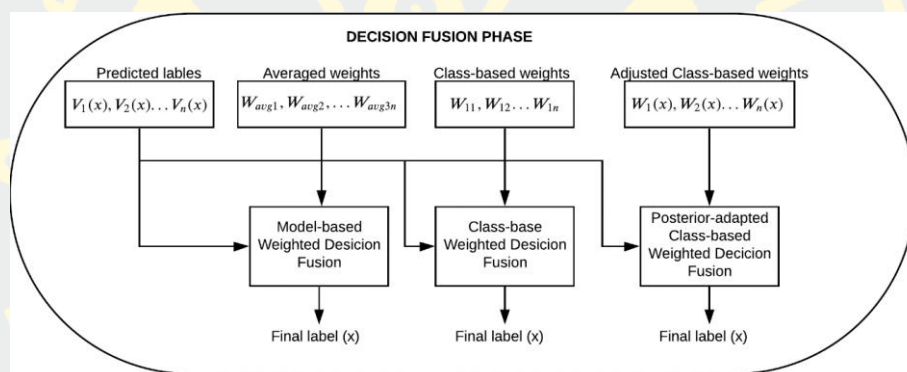
$$Score_{V_i(x)} = \sum w_{avgi} , 1 \leq i \leq n \quad (2.20)$$

$$Score_k = \sum_{V_i(x)=C_k} w_{1ik} \quad 1 \leq k \leq m, 1 \leq i \leq n \quad (2.21)$$

$$Score_k = \sum_{V_i(x)=C_k} w_{ik} \quad 1 \leq k \leq m, 1 \leq i \leq n \quad (2.22)$$

$$final_{label} = C \operatorname{argmax}_{k=1}^m Score_k \quad (2.23)$$

โดย	$V_i(x)$	คือ ผลการระบุกิจกรรมของตัวแบบรู้จำกิจกรรมที่ i ของชุดข้อมูลที่ x
	w_{avg_i}	คือ ค่าเฉลี่ยของค่าน้ำหนักจากตัวแบบรู้จำกิจกรรมที่ i
	w_{1ik}	คือ ค่าน้ำหนักที่ยังไม่ได้ปรับของกิจกรรมที่ k ของตัวแบบรู้จำที่ i
	w_{ik}	คือ ค่าน้ำหนักที่ถูกปรับของกิจกรรมที่ k ของตัวแบบรู้จำที่ i
	$Score_{V_i(x)}$	คือ ค่าคะแนนของผลการระบุกิจกรรมของตัวแบบรู้จำกิจกรรมที่ i ของชุดข้อมูลที่ x
	$Score_k$	คือ ค่าคะแนนของการระบุกิจกรรม k
	m	คือ จำนวนกลุ่มกิจกรรม
	n	คือ จำนวนตัวแบบรู้จำกิจกรรม



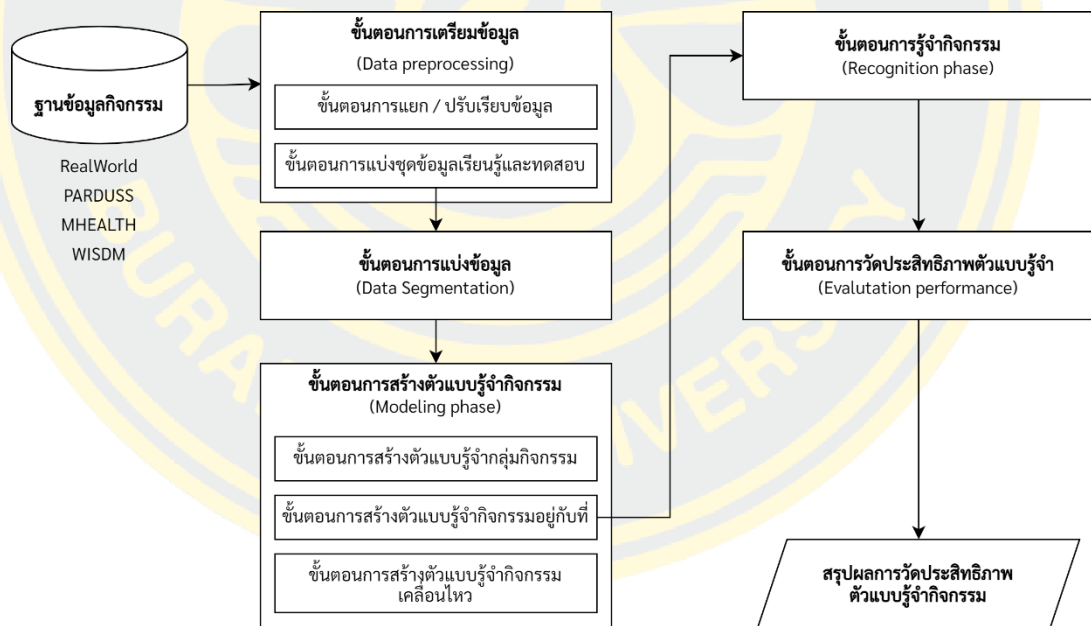
ภาพที่ 20 ขั้นตอนการรวมค่าน้ำหนักเพื่อระบุกิจกรรมของงานวิจัย Chowdhury และคณะ (2018)

จากงานวิจัยที่กล่าวมาข้างต้นแสดงให้เห็นว่างานวิจัยทั้งหมดได้นำกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer บนอุปกรณ์สวมใส่ข้อมือมาใช้ในการสร้างตัวแบบรู้จำกิจกรรมทางกายภาพเป็นหลัก ซึ่งให้ความสำคัญกับการพัฒนาตัวแบบรู้จำกิจกรรมได้ให้ประสิทธิภาพในการระบุได้แม่นยำถูกต้อง (Accuracy) ให้ได้มากที่สุด แต่ผลการทดลองที่น่าเสถียรส่วนใหญ่ที่มีความแม่นยำสูงอาจจะเป็นเพราะว่าใช้ข้อมูลเก็บเองหรือเลือกบางส่วนของข้อมูลที่มีปัญหาน้อยหรือการแบ่งข้อมูลที่เบแอสกับการสร้างตัวแบบรู้จำเช่นการมีข้อมูลบางส่วนข้อมูลทดสอบมาใช้ในการเรียนรู้มาก ซึ่งงานวิจัยที่กล่าวมาข้างต้นไม่ได้พูดถึงและวิเคราะห์ปัญหาของข้อมูลที่เกิดขึ้น ซึ่งเป็นปัจจัยสำคัญที่ส่งผลต่อประสิทธิภาพในการระบุกิจกรรม ทำให้ขั้นตอนการเตรียมข้อมูล, การเลือกคุณลักษณะและวิธีการสร้างตัวแบบรู้จำกิจกรรมที่เหมาะสมเฉพาะฐานข้อมูลใดฐานข้อมูลหนึ่งเท่านั้นหรือในบางขั้นตอนที่ไม่สามารถทำได้ในขณะที่สร้างตัวแบบรู้จำกิจกรรมและรู้จำกิจกรรมแบบที่ข้อมูลเข้ามาต่อเนื่องกัน

บทที่ 3

วิธีการที่นำเสนอ

วิทยานิพนธ์นี้ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรมกับข้อมูลกระแสวิ่งเวลาจากตัวรับรู้ Accelerometer และ Gyroscope ของอุปกรณ์สวมใส่ข้อมือ ที่มีชื่อว่า Smartwatch-based Physical Activity Recognition เรียกโดยย่อว่า “SPAR” โดยเน้นการรู้จำกิจกรรมทางกายภาพ (Physical Activities) เนื้อหาในบทนี้จะประกอบไปด้วย 1) รายละเอียดของฐานข้อมูลกิจกรรมสาธารณะ (Public dataset) 2) กระบวนการวิเคราะห์ข้อมูลกิจกรรมจากตัวรับรู้และ 3) ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมจำนวน 3 วิธีการที่พัฒนาต่อยอดกันมา ซึ่งแต่ละวิธีการได้มีการเพิ่มประสิทธิภาพในการระบุกิจกรรมทางกายภาพให้แม่นยำถูกต้องเพิ่มมากขึ้น และปรับปรุงตัวแบบรู้จำให้เหมาะสมกับผู้ใช้แต่ละบุคคล โดยขั้นตอนการรู้จำกิจกรรมของตัวแบบรู้จำกิจกรรม S-PAR มีขั้นตอนหลักดังภาพที่ 21



ภาพที่ 21 ภาพรวมของวิธีการ Smartwatch-based Physical Activity Recognition (S-PAR)

3.1 การศึกษาและวิเคราะห์กระแสข้อมูลเชิงเวลาจากตัวรับรู้สำหรับสร้างตัวแบบรู้จำกิจกรรม

3.1.1 ฐานข้อมูลกิจกรรม

ในวิทยานิพนธ์นี้ได้นำฐานข้อมูลกิจกรรมที่มีการเก็บข้อมูลจากอุปกรณ์สวมใส่ข้อมือจำนวน 4 ฐานข้อมูลกิจกรรม โดยแต่ละฐานข้อมูลผู้วิจัยได้เลือกเฉพาะข้อมูลที่ทำกิจกรรมทางกายภาพมาใช้ในการสร้างและทดสอบตัวแบบรู้จำกิจกรรม รายละเอียดในแต่ละฐานข้อมูลกิจกรรมแสดงดังตารางที่ 11

ตารางที่ 11 รายละเอียดฐานข้อมูลออนไลน์ที่มีการเก็บข้อมูลกิจกรรมจากอุปกรณ์ที่สวมใส่ข้อมือ

ฐานข้อมูลกิจกรรม	จำนวนอาสาสมัครที่ทำครบทุกกิจกรรม	สภาพแวดล้อมในการเก็บข้อมูล	อุปกรณ์ที่สวมใส่ข้อมือและระยะเวลา	อัตราการสุ่มข้อมูลต่อ 1 วินาที	กิจกรรมทางกายภาพ
RealWorld (Szytler และ Stuckenschmidt, 2016)	10 จาก 15 คน	ภายนอกห้องปฏิบัติการ	LG G Watch R smartwatch ที่ตำแหน่งข้อมือขวาเป็นระยะเวลา 10 นาที	50Hz	การยืน การนั่ง การนอน การเดิน การเดินลงบันได การเดินขึ้นบันไดและการวิ่ง
PARDUSS (Shoaib, Scholten, และ Havinga, 2013)	10 คน	ภายในห้องปฏิบัติการ	Samsung Galaxy s2 ที่ตำแหน่งข้อมือขวาเป็นระยะเวลา 3-4 นาที	50 Hz	การยืน การนั่ง การเดิน การเดินลงบันได การเดินขึ้นบันได การวิ่งและการปั่นจักรยาน

MHEALTH (Banos และ คณะ, 2014)	10 คน	ภายในพื้นที่ห้อง ปฏิบัติการ ยกเว้นกิจกรรม ปั่นจักรยาน	Shimmer Wearable sensor ณ ตำแหน่งข้อมือ ขวาเป็น ระยะเวลา 1 นาที	50Hz	การยืน การ นั่ง การนอน การเดิน การ เดินขึ้นลง บันได การวิ่ง การวิ่งจ็อกกิ้ง และการปั่น จักรยาน
WISDM (Weiss, Yoneda, และ Hayajneh, 2019)	45 จาก 51 คน	ภายในห้อง ปฏิบัติการ	LG G Watch ณ ตำแหน่ง ข้อมือที่ถนัด เป็นระยะเวลา 3-4 นาที	20Hz	การยืน การ นั่ง การเดิน การเดินขึ้นลง บันได การวิ่ง และการปั่น จักรยาน

จากตารางที่ 11 ฐานข้อมูลกิจกรรม RealWorld และฐานข้อมูลกิจกรรม MHEALTH ที่มีการถ่ายภาพประกอบเพื่อให้รู้ว่าใช้อุปกรณ์อะไร มีการวางหรือติดอุปกรณ์ที่ตำแหน่งใดของร่างกาย รวมถึงใช้แอปพลิเคชันใดในการทดลองเก็บข้อมูลการทำกิจกรรม ดังภาพที่ 22 และภาพที่ 23




ภาพที่ 22 การติดตั้งอุปกรณ์บนตำแหน่งต่างๆ ของร่างกาย และแอปพลิเคชันในการเก็บข้อมูลของฐานข้อมูลกิจกรรม RealWorld



การยืน



การนอน




การเดิน



การวิ่ง



การเดินขึ้นบันได



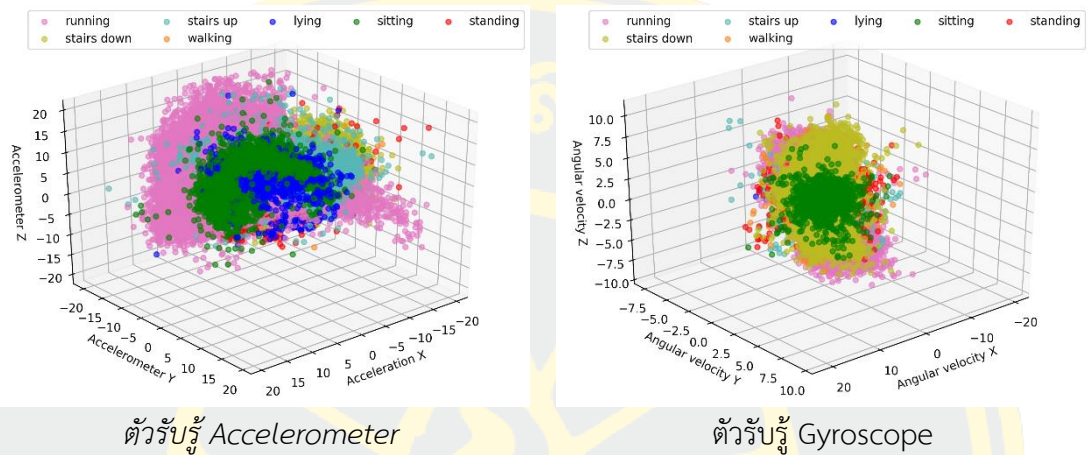
การเดินลงบันได

ภาพที่ 23 ภาพประกอบการเก็บข้อมูลขณะทำกิจกรรมจากฐานข้อมูลกิจกรรม MHEALTH

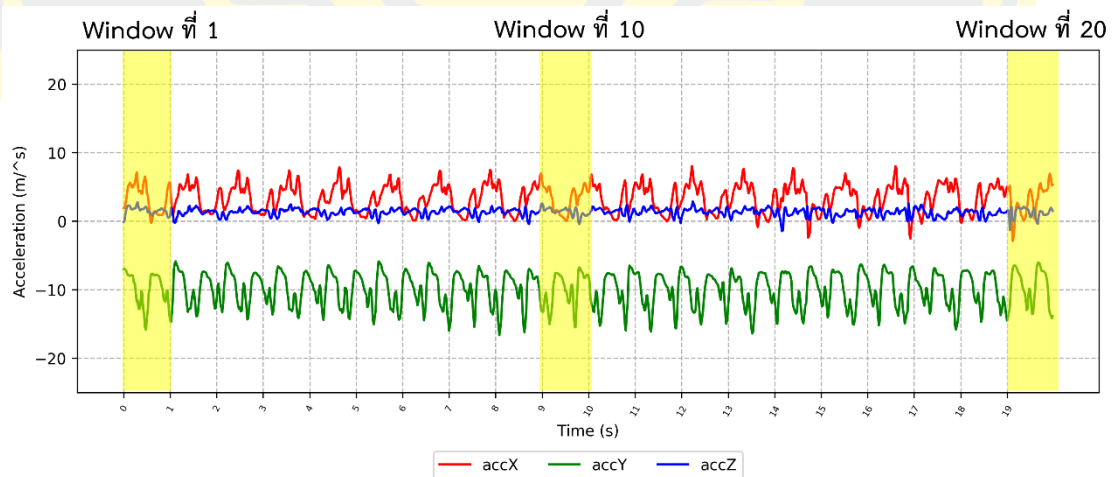
3.1.2 วิเคราะห์ข้อมูลการทำกิจกรรม

ก่อนที่จะสร้างตัวแบบรู้จำกิจกรรม SPAR วิทยาลัยพนธ์นี้ได้ศึกษาและวิเคราะห์ข้อมูลการทำกิจกรรมในแต่ฐานข้อมูลกิจกรรมที่กล่าวไปข้างต้น เพื่อที่นักวิจัยจะได้เข้าใจลักษณะของข้อมูลการทำกิจกรรม โดยนำข้อมูลดิบจากการทำกิจกรรมในฐานข้อมูล RealWorld ทุกกิจกรรมที่วัดค่าได้จากตัวรับรู้ Accelerometer ที่เป็นตัวรับรู้หลักและตัวรับรู้ Gyroscope ในแต่ละแกนมาแสดงเป็นแผนภาพการกระจายตัวของข้อมูลดังภาพที่ 24 จะเห็นได้ว่าข้อมูลมีการกระจายและทับซ้อนเป็นจำนวนมาก ทำให้มองเห็นกลุ่มกิจกรรมไม่ชัดเจน หากนำข้อมูลดิบที่ได้จาก Accelerometer หรือ Gyroscope มาสร้างตัวแบบรู้จำโดยตรงนั้นอาจจะทำให้ได้ตัวแบบรู้จำกิจกรรมที่ไม่มีความแม่นยำมากนัก ดังนั้นในงานวิทยาลัยพนธ์นี้จึงมีการวิเคราะห์เบื้องต้น โดยนำกระแสข้อมูลเชิงเวลาของแต่ละกิจกรรม มา

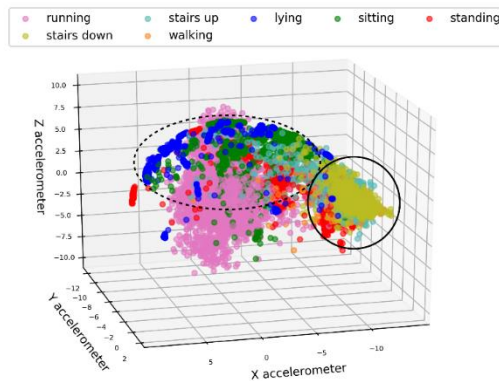
แบ่งเป็นชุดข้อมูลย่อยด้วยเทคนิค Sliding window ดังตัวอย่างในภาพที่ 24 โดยขนาดของของ Window มีค่าเท่ากับอัตราการสุ่มข้อมูล (Sampling rate) ของตัวรับรู้ที่กำหนดในแต่ละฐานข้อมูลกิจกรรม จากนั้นนำข้อมูลกระแสข้อมูลเชิงเวลาในแต่ละ Window มาหาค่าเฉลี่ยและแสดงแผนภาพการกระจายตัวแบบจุดดังภาพที่ 26 ถึงภาพที่ 29



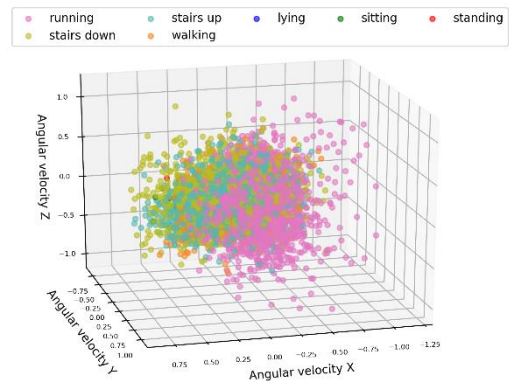
ภาพที่ 24 แผนภาพการกระจายข้อมูลดิบทุกกิจกรรมของฐานข้อมูลกิจกรรม RealWorld



ภาพที่ 25 แผนภาพการตัวอย่างการแบ่งเป็นชุดข้อมูลย่อยด้วยเทคนิค Sliding window ด้วยขนาดเท่ากับ 1 วินาที (ไฮไลท์สีเหลือง)

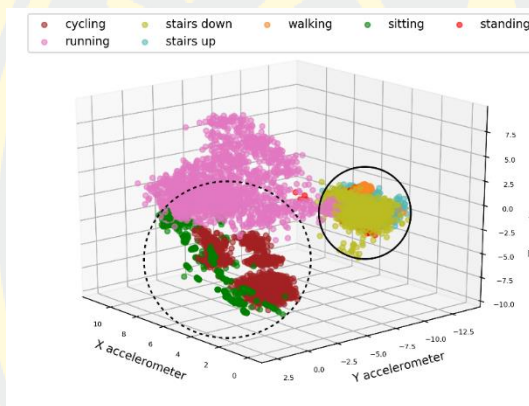


ตัวรับรู้ Accelerometer

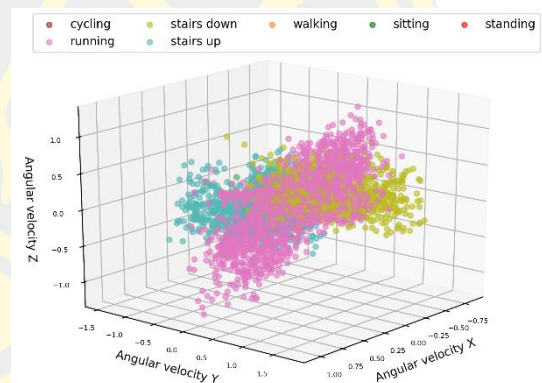


ตัวรับรู้ Gyroscope

ภาพที่ 26 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล RealWorld

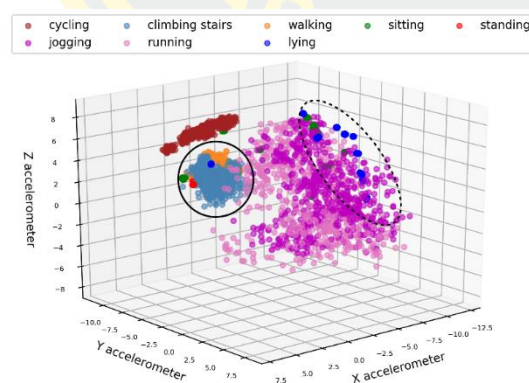


ตัวรับรู้ Accelerometer

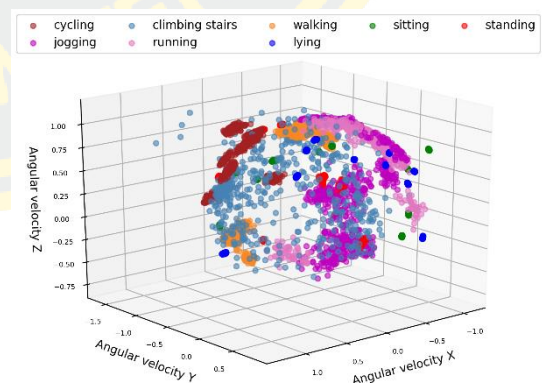


ตัวรับรู้ Gyroscope

ภาพที่ 27 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล PARDUSS




ตัวรับรู้ Accelerometer



ตัวรับรู้ Gyroscope

ภาพที่ 28 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล MHEALTH



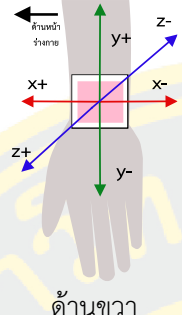

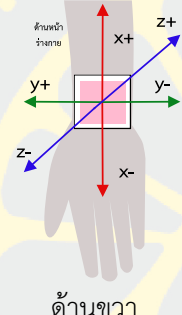
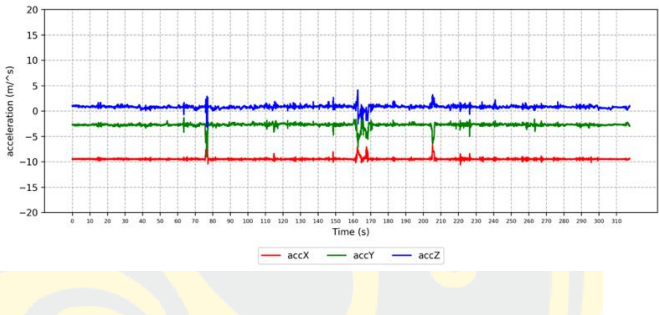
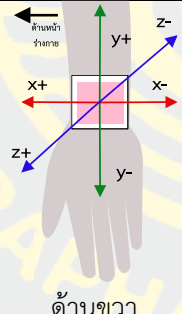
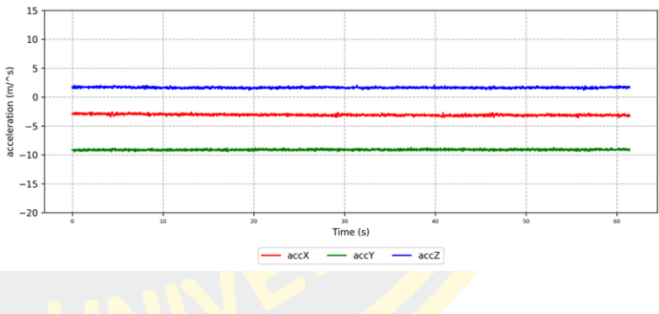
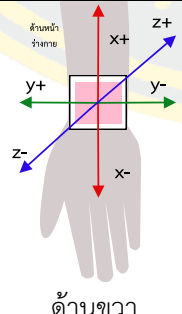
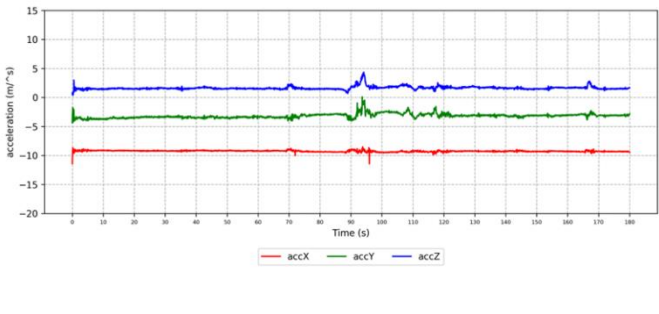
ภาพที่ 29 แผนภาพการกระจายข้อมูลของค่าเฉลี่ยแต่ละ Window ทุกกิจกรรมจากฐานข้อมูล WISDM (ผู้ใช้ 10 คน)


จากภาพที่ 26 ถึงภาพที่ 29 แสดงการกระจายตัวของค่าเฉลี่ยที่คำนวณแต่ละ Windows พบว่าเห็นกลุ่มข้อมูลกิจกรรมได้ชัดเจนมากขึ้น นอกจากนี้จะเห็นได้ว่าทุกฐานข้อมูลเกิดการทำกิจกรรมเดียวกันแต่มีลักษณะการกระจายข้อมูลแตกต่างกัน สังเกตได้จากข้อมูลกิจกรรมภายในวงกลมเส้นปะ ที่ไม่เป็นกลุ่มที่กระจุกตัวอย่างชัดเจนและภายในวงกลมเส้นเกิดการทับซ้อนของข้อมูลกิจกรรม ซึ่งเกิดจากค่าเฉลี่ยของกิจกรรมการเดิน (การเดิน, การเดินขึ้นบันไดและการเดินลงบันได) ที่ใกล้เคียงกันมากโดยอธิบายประเด็นปัญหาอย่างละเอียดดังต่อไปนี้

- ประเด็นปัญหาที่ 1 ข้อมูลกิจกรรมเดียวกันแต่มีลักษณะการกระจายข้อมูลแตกต่างกัน


ปัญหานี้ส่วนใหญ่จะเกิดขึ้นกับทำกิจกรรมที่ร่างกายอยู่กับที่ (การยืน, การนั่ง และการนอน) โดยข้อมูลกิจกรรมในกลุ่มนี้จะอาศัยการวัดแรงที่เกิดขึ้นจากแรงโน้มถ่วงจากตัวรับรู้ Accelerometer ซึ่งแกนข้อมูลที่ได้รับผลจากแรงโน้มถ่วงจะมีค่าประมาณ 9.8 หรือ -9.8 m/s^2 เพื่อให้เห็นภาพชัดเจนยิ่งขึ้นจะแสดงตัวอย่างของกระแสข้อมูลเชิงเวลาของการยืนของผู้ใช้ 1 คน โดยขณะที่ยืนข้อมือจะแนบไปกับลำตัวดังตารางที่ 12 จึงจะสังเกตเห็นว่ามีข้อมูลแกนใดแกนหนึ่งที่ได้รับผลจากแรงโน้มถ่วง (แกน X หรือแกน Y)

ตารางที่ 12 ค่าที่เกิดขึ้นของแกนข้อมูลตัวรับรู้ Accelerometer ในแต่ละฐานข้อมูลกิจกรรม


ฐานข้อมูลกิจกรรม	ตำแหน่งของอุปกรณ์	กระแสข้อมูลเชิงเวลาของกิจกรรมอื่น
PARDUSS	 <p>ด้านขวา</p>	
RealWorld	 <p>ด้านขวา</p>	
MHEALTH	 <p>ด้านขวา</p>	
WISDM	 <p>ด้านขวา</p>	




เมื่อนำกระแสข้อมูลเชิงเวลาของกิจกรรมที่ทำอยู่กับที่ของอาสาสมัครทุกคนในแต่ละฐานข้อมูลมาแสดงเป็นแผนภาพการกระจายตัวดังภาพที่ 30 จะเห็นได้ว่าการกระจายตัวของข้อมูลกิจกรรมเดียวกันกระจุกเป็นกลุ่มหรือข้อมูลมีการกระจายสะเปะสะปะออกไป เนื่องจากท่าทางและสภาพแวดล้อมขณะเก็บข้อมูลของแต่ละอาสาสมัครที่แตกต่างกันส่งผลให้ข้อมูลเปลี่ยนแปลงได้ง่ายกว่าตำแหน่งอื่นบนร่างกาย ซึ่งมีผลต่อประสิทธิภาพในการรู้จำกิจกรรม โดยจะอธิบายปัญหานี้ในแต่ละฐานข้อมูลกิจกรรมดังต่อไปนี้




ฐานข้อมูลกิจกรรม PARDUSS



ฐานข้อมูลกิจกรรม RealWorld



ฐานข้อมูลกิจกรรม MHEALTH




ฐานข้อมูลกิจกรรม WISDM


ภาพที่ 30 แผนภาพการกระจายข้อมูลของตัวรับรู้ Accelerometer ของกลุ่มกิจกรรมอยู่กับที่แต่ละฐานข้อมูลกิจกรรม

○ กลุ่มกิจกรรมอยู่กับที่ในฐานะข้อมูลกิจกรรม PARDUSS

จากภาพที่ 30 การกระจายข้อมูลกิจกรรมของฐานข้อมูล PARDUSS จะเห็นได้ว่าลักษณะกลุ่มข้อมูลของการนั่งและการยืนแยกออกจากกันได้ชัดเจนกว่าฐานข้อมูลอื่น เมื่อพิจารณาแผนภาพเชิงเส้นของกระแสข้อมูลเชิงเวลาทั้งสองกิจกรรมจากอาสาสมัคร 4 คน ดังแผนภาพที่ 31 และภาพที่ 32 จะเห็นว่าลักษณะข้อมูลการนั่งของอาสาสมัครคนที่ 1, 5 และ 9 มีเปลี่ยนแปลงขณะทำกิจกรรม อาจเกิดจากการเปลี่ยนท่าทางขณะเก็บข้อมูลกิจกรรม




ภาพที่ 31 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาการยืนจากฐานข้อมูลกิจกรรม PARDUSS ของอาสาสมัคร 4 คน




ภาพที่ 32 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาการนั่งจากฐานข้อมูลกิจกรรม PARDUSS ของอาสาสมัคร 4 คน

○ กลุ่มกิจกรรมอยู่กับที่ในฐานะข้อมูลกิจกรรม RealWorld


ในภาพที่ 33 ถึงภาพที่ 35 เป็นตัวอย่างกระแสข้อมูลเชิงเวลาของอาสาสมัครในขณะที่เก็บข้อมูลการทำกิจกรรม ทำให้เห็นลักษณะและการวางอุปกรณ์สวมใส่ข้อมือขณะทำกิจกรรม จะเห็นได้ว่าไม่มีลักษณะของกระแสข้อมูลเชิงเวลาแต่ละคนมีความแตกต่างกัน ซึ่งเกิดจากเปลี่ยนท่าทางในขณะที่เก็บข้อมูล ทำให้ค่าที่ได้ในแต่ละแกนข้อมูลจากตัวรับรู้ Accelerometer กิจกรรมเดียวกันของอาสาสมัครจึงมีความแตกต่างจากอาสาสมัครคนอื่นหรืออาจจะคล้ายกับข้อมูลกิจกรรมอื่นและมีข้อมูลรบกวนที่เกิดจากการเปลี่ยนท่าทางค่อนข้างมากเมื่อเทียบฐานข้อมูลกิจกรรม PARDUSS



ภาพที่ 33 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของการยืนของอาสาสมัครที่ 1, 2, 3 และ 8 ในฐานะข้อมูลกิจกรรม RealWorld




ภาพที่ 34 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของการนั่งของอาสาสมัครที่ 1, 2, 7 และ 8 ในฐานข้อมูลกิจกรรม RealWorld




ภาพที่ 35 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของการนอนของอาสาสมัครที่ 1, 2, 3 และ 7 ในฐานข้อมูล RealWorld

○ กลุ่มกิจกรรมอยู่กับที่ในฐานะข้อมูลกิจกรรม MHEALTH


จากภาพที่ 30 เป็นกระแสข้อมูลเชิงเวลาในฐานะข้อมูล MHEALTH จะเห็นลักษณะของข้อมูลกิจกรรมเป็นกลุ่มข้อมูลที่ชัดเจนและลักษณะการกระจายตัวของข้อมูลกิจกรรมเดียวกันกระจุกตัวเป็นจุด ๆ เมื่อวิเคราะห์แล้วพบว่าเกิดจากลักษณะแนววางอุปกรณ์ตัวรับรู้ของอาสาสมัครแต่ละคนขณะทำกิจกรรมนั้นมีความแตกต่างกัน ส่วนภาพที่ 36 ถึงภาพที่ 38 จะเห็นว่าแกนข้อมูลกระแสข้อมูลเชิงเวลาของแต่ละอาสาสมัครโดยเฉพาะการนั่งและนอนมีลักษณะข้อมูลแตกต่างกัน ทำให้ได้ตัวแบบที่รู้จักกิจกรรมที่ผิดพลาดได้




การยืนของอาสาสมัครที่ 1



การยืนของอาสาสมัครที่ 2




การยืนของอาสาสมัครที่ 3




การยืนของอาสาสมัครที่ 4


ภาพที่ 36 แผนภาพกระแสข้อมูลเชิงเวลาการยืนของฐานข้อมูลกิจกรรม MHEALTH ของอาสาสมัคร 4 คน




การนั่งของอาสาสมัครที่ 1



การนั่งของอาสาสมัครที่ 1




การนั่งของอาสาสมัครที่ 3




การนั่งของอาสาสมัครที่ 4


ภาพที่ 37 แผนภาพกระแสข้อมูลเชิงเวลาการนั่งของฐานข้อมูลกิจกรรม MHEALTH ของอาสาสมัคร 4 คน




การนอนของอาสาสมัครที่ 1



การนอนของอาสาสมัครที่ 2



การนอนของอาสาสมัครที่ 3




การนอนของอาสาสมัครที่ 4


ภาพที่ 38 แผนภาพกระแสข้อมูลเชิงเวลาตัวอย่างการนอนของฐานข้อมูลกิจกรรม MHEALTH ของอาสาสมัคร 4 คน

○ กลุ่มกิจกรรมหยุดนิ่งของฐานข้อมูลกิจกรรม WISDM


ในภาพที่ 39 ถึงภาพที่ 40 จะเห็นได้ว่าลักษณะข้อมูลที่ได้จากการยืนมีความแตกต่างกัน เนื่องจากอาสาสมัครจะสวมอุปกรณ์ข้อมือด้านที่ข้อมือซ้ายหรือขวา โดยสังเกตการยืนของอาสาสมัคร คนที่ 2 มีแกนข้อมูลแกน X ที่สลับกันที่แตกต่างจากอาสาสมัครคนอื่น ในส่วนอาสาสมัครคนที่ 3 มีข้อมูลรบกวนเกิดขึ้นชัดเจน ทำให้ตัวแบบรู้จำระบุกิจกรรมในกลุ่มนี้ได้ผิดพลาดเพิ่มมากขึ้น




การยืนของอาสาสมัครที่ 1



การยืนของอาสาสมัครที่ 2




การยืนของอาสาสมัครที่ 3




การยืนของอาสาสมัครที่ 4


ภาพที่ 39 แผนภาพกระแสข้อมูลเชิงเวลาการยืนของฐานข้อมูลกิจกรรม WISDM ของอาสาสมัคร 4 คน




การนั่งของอาสาสมัครที่ 1



การนั่งของอาสาสมัครที่ 2



การนั่งของอาสาสมัครที่ 3




การนั่งของอาสาสมัครที่ 4


ภาพที่ 40 แผนภาพกระจายข้อมูลเชิงเวลาตัวอย่างการนั่งของอาสาสมัคร 4 คนจากฐานข้อมูลกิจกรรม WISDM

● ประเด็นปัญหาที่ 2 การซ้อนทับของข้อมูลกิจกรรม

เพื่อให้เห็นปัญหาประเด็นนี้ให้ชัดเจนขึ้นมากยิ่งขึ้น ผู้วิจัยขอยกตัวอย่างกิจกรรมที่มีการเคลื่อนไหวของร่างกายจากตัวรับรู้ Accelerometer และ Gyroscope ในฐานข้อมูลกิจกรรม RealWorld และ PARDUSS ซึ่งประกอบด้วยกิจกรรมได้แก่การเดิน, การเดินขึ้นบันได, การเดินลงบันได, การวิ่ง และเพิ่มเติมการปั่นจักรยานในฐานข้อมูลกิจกรรม PARDUSS มาแสดงภาพการกระจายข้อมูลดังภาพที่ 41 และภาพที่ 42




Accelerometer



Gyroscope

ภาพที่ 41 แผนภาพการกระจายข้อมูลของกลุ่มกิจกรรมเคลื่อนไหวของฐานข้อมูลกิจกรรม RealWorld




ภาพที่ 42 แผนภาพภาพการกระจายข้อมูลของกลุ่มกิจกรรมเคลื่อนไหวของฐานข้อมูลกิจกรรม PARDUSS

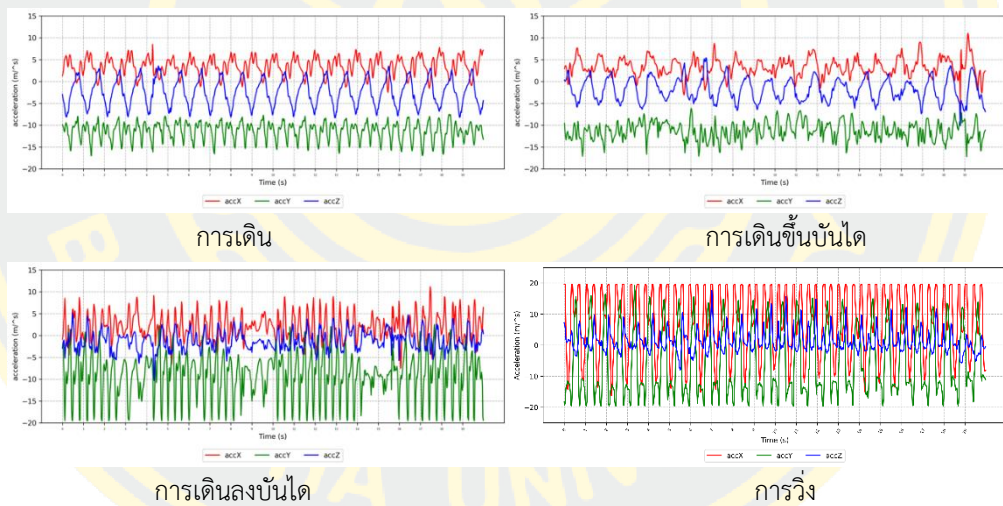
ในภาพที่ 41 และภาพที่ 42 จะสังเกตเห็นว่าตำแหน่งที่ถูกรวบรวมข้อมูลจากการกระจายตัวข้อมูลจากตัวรับรู้ Accelerometer ของการเดิน, การเดินขึ้นบันได และการเดินลงบันไดของทั้งสองฐานข้อมูลมีลักษณะปัญหาเดียวกันคือ กลุ่มข้อมูลของแต่ละกิจกรรมมีลักษณะทับซ้อนกัน ทำให้ยากต่อการแยกได้ว่าผู้ใช้กำลังทำกิจกรรมอะไร เช่นเดียวกันกับการกระจายตัวข้อมูลจากตัวรับรู้ Gyroscope ที่มีลักษณะปัญหาเช่นเดียวกัน ส่งผลให้ตัวรับรู้จำกิจกรรมระบุในกลุ่มกิจกรรมนี้ได้ยาก ซึ่งปัญหาที่เกิดขึ้นอาจจะเกิดจากคุณภาพของข้อมูลขึ้นอยู่กับหลายปัจจัยได้แก่ สภาพแวดล้อมในการทดลอง, อุปกรณ์และตัวรับรู้ที่สวมใส่ในขณะเก็บข้อมูลของแต่ละฐานข้อมูลนั้นแตกต่างกัน โดยมีรายละเอียดของกลุ่มกิจกรรมเคลื่อนไหวของแต่ละฐานข้อมูลกิจกรรมดังต่อไปนี้

○ กลุ่มกิจกรรมเคลื่อนไหวในฐานข้อมูลกิจกรรม PARDUSS


จากภาพที่ 42 แสดงการกระจายตัวของกิจกรรมเคลื่อนไหว ได้แก่การเดิน, การเดินขึ้นบันไดและการเดินลงบันได มีลักษณะการทับซ้อนกันของกลุ่ม เมื่อพิจารณาแผนภาพกระจายข้อมูลเชิงเวลาของตัวรับรู้ Accelerometer และ Gyroscope จากอาสาสมัคร 3 คน ดังภาพที่ 43 ถึงภาพที่ 48 จะเห็นว่าช่วงของข้อมูล (Range) ที่เกิดขึ้นในแต่ละแกนข้อมูลของการเดินและการเดินขึ้นลงบันไดของแต่ละอาสาสมัครมีค่าใกล้เคียงกันมากเมื่อเทียบกับแกนข้อมูลกิจกรรมวิ่งที่ร่างกายของอาสาสมัครมีการเคลื่อนไหวมากกว่าทำให้ค่าที่ได้รับมีความเร่งจากผู้ใช้แวก่มาก ส่งผลให้การรู้จำกิจกรรมที่เป็นการเดินมีโอกาที่จะผิดพลาดได้ง่ายกว่า




ภาพที่ 43 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครคนที่ 1 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Accelerometer (20 วินาที)




ภาพที่ 44 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครคนที่ 2 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Accelerometer (20 วินาที)




ภาพที่ 45 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครคนที่ 3 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Accelerometer (20 วินาที)



ภาพที่ 46 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครคนที่ 1 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Gyroscope (20 วินาที)



ภาพที่ 47 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครคนที่ 1 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Gyroscope (20 วินาที)


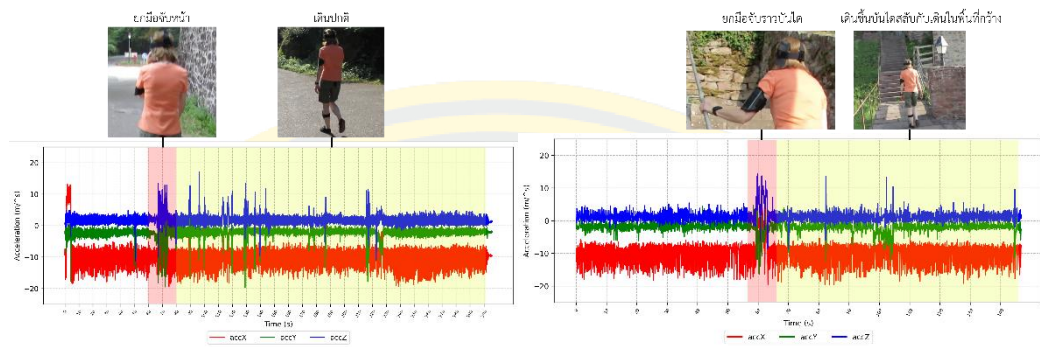


ภาพที่ 48 แผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่เป็นลักษณะการเดินของอาสาสมัครคนที่ 3 ของฐานข้อมูลกิจกรรม PARDUSS จากตัวรับรู้ Gyroscope (20 วินาที)


○ กลุ่มกิจกรรมเคลื่อนไหวในฐานข้อมูลกิจกรรม RealWorld


การเก็บข้อมูลในกลุ่มกิจกรรมเคลื่อนไหวของฐานข้อมูล RealWorld จะเก็บการทำกิจกรรมภายนอกห้องทดลอง เมื่อนำมาแสดงเป็นแผนภาพเชิงเส้นกระแสข้อมูลเชิงเวลาที่สอดคล้องกับภาพขณะเก็บข้อมูลกิจกรรมของอาสาสมัคร 3 คนดังภาพที่ 49 ถึงภาพที่ 51 จะเห็นได้ว่าการเดินขึ้นบันไดและการเดินลงบันไดจะมีเป็นการเดินในพื้นที่โล่งระหว่างการขึ้นลงบันไดสลับกับการเดินลงขึ้นบันไดที่ไม่ชันมากหรือทางลาดทำให้มีการเดินแทรกอยู่ระหว่างเก็บข้อมูล และการเดินขึ้นลงบันไดในที่แคบทำ

ให้อาสาสมัครบางคนอาจจะเกร็งแขนและข้อมือหรือการจับราวบันไดของอาสาสมัครทำให้ได้แกนข้อมูลของกระแสข้อมูลเชิงเวลาที่ได้รับแตกต่างกันออกไป




ภาพที่ 49 แผนภาพกระแสข้อมูลเชิงเวลาของกิจกรรมการเดินของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม RealWorld






กิจกรรมเดินลงบันได

ภาพที่ 50 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม RealWorld



การเดิน

การเดินขึ้นบันได

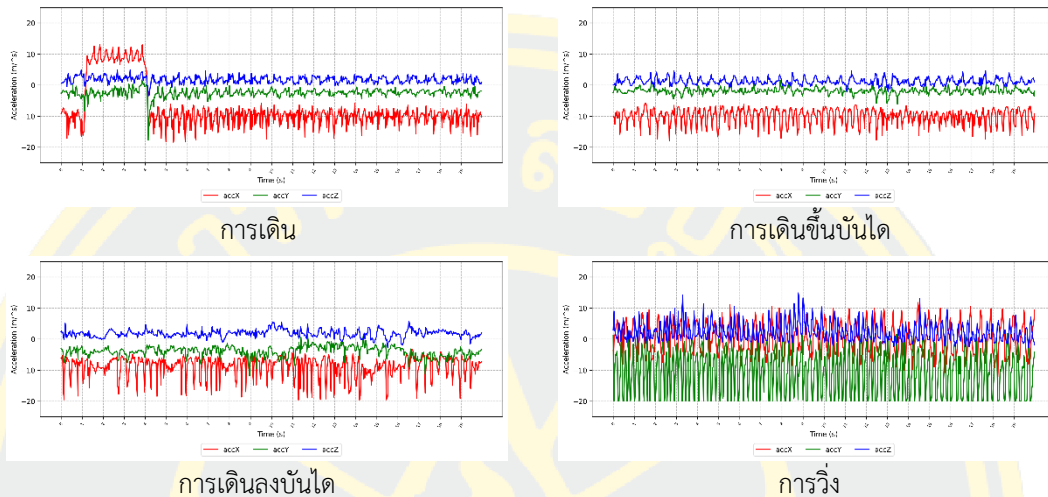


การเดินลงบันได

ภาพที่ 51 แผนภาพกระแสข้อมูลเชิงเวลาทั้งหมดของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 3 ในฐานข้อมูลกิจกรรม RealWorld

เพื่อให้ลักษณะของกระแสข้อมูลเชิงเวลาได้ชัดเจนมากยิ่งขึ้น จะตัดเมื่อข้อมูลบางส่วนจาก มาแสดงเป็นแผนภาพที่ 52 ถึงภาพที่ 57 จะเห็นได้ว่ากระแสข้อมูลเชิงเวลาจากทั้งสองตัวรับรู้ของการ เดิน, การเดินขึ้นบันได และการเดินลงบันไดมีลักษณะของข้อมูลและระยะที่ใกล้เคียงกัน ทำให้มองเห็น


สามกิจกรรมนี้เป็นกิจกรรมเดียวกัน และมีข้อมูลรบกวนจากการเปลี่ยนแปลงท่าทางขณะเก็บกิจกรรมของอาสาสมัครแต่ละคน จึงทำให้การรู้จักกิจกรรมเคลื่อนไหวของฐานข้อมูล Realworld ยากกว่าฐานกิจกรรมอื่น




ภาพที่ 52 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 1 ของฐานข้อมูลกิจกรรม RealWorld (20 วินาที) จากตัวรับรู้ Accelerometer




ภาพที่ 53 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ของฐานข้อมูลกิจกรรม RealWorld (20 วินาที) จากตัวรับรู้ Accelerometer




ภาพที่ 54 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 3 ในฐานข้อมูลกิจกรรม RealWorld (20 วินาที) จากตัวรับรู้ Accelerometer



ภาพที่ 55 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม RealWorld (20 วินาที) จากตัวรับรู้ Gyroscope



ภาพที่ 56 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม RealWorld (20 วินาที) จากตัวรับรู้ Gyroscope




ภาพที่ 57 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 3 ในฐานข้อมูลกิจกรรม RealWorld (20 วินาที) จากตัวรับรู้ Gyroscope


○ กลุ่มกิจกรรมเคลื่อนไหวในฐานข้อมูลกิจกรรม MHEALTH

ในการวิเคราะห์ลักษณะข้อมูลจากฐานข้อมูล MHEALTH โดยพิจารณาจากข้อมูลกิจกรรมเคลื่อนไหวจากตัวรับรู้ Accelerometer และ Gyroscope ของอาสาสมัคร 3 คน แสดงดังภาพที่ 58 ถึงภาพที่ 60 จะสังเกตเห็นว่าค่าในแต่แกนข้อมูลของตัวรับรู้ Accelerometer ของการเดินและการเดินขึ้นลงบันไดมีค่าใกล้เคียงกัน ซึ่งเป็นปัญหาเดียวกันกับฐานข้อมูลกิจกรรมอื่นและในฐานข้อมูลนี้มีการเก็บข้อมูลการวิ่งและการวิ่งจ็อกกิ้งซึ่งทั้ง 2 กิจกรรมนี้มีลักษณะมีค่าใกล้เคียงกัน ทำให้ตัวแบบรู้จำ


กิจกรรมมองเป็นกิจกรรมเดียวกัน ในขณะที่กระแสข้อมูลเชิงเวลาจาก Gyroscope ดังภาพที่ 61 ถึง 64 แสดงให้เห็นถึงรูปแบบของข้อมูลการเดินและการเดินขึ้นลงบันไดของแต่ละคนได้ชัดเจน แต่การวิ่งและการวิ่งจ็อกกิ้งจะมีรูปแบบของข้อมูลเฉพาะของแต่ละคนในขณะที่ทำกิจกรรม




ภาพที่ 58 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับสัญญาณ Accelerometer ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)




ภาพที่ 59 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับสัญญาณ Accelerometer ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 2 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)




การเดิน



การเดินลงขั้นบันได




การวิ่ง




การวิ่งจ็อกกิ้ง


ภาพที่ 60 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Accelerometer ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 3 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)




การเดิน



การเดินขึ้นลงบันได




การวิ่ง




การวิ่งจ็อกกิ้ง

ภาพที่ 61 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Gyroscope ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 1 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)



ภาพที่ 62 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Gyroscope ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 2 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)




ภาพที่ 63 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนจากตัวรับรู้ Gyroscope ของกลุ่มกิจกรรมเคลื่อนไหวของอาสาสมัครที่ 3 ของฐานข้อมูลกิจกรรม MHEALTH (20 วินาที)

○ กลุ่มกิจกรรมเคลื่อนไหวของฐานข้อมูลกิจกรรม WISDM

จากภาพที่ 64 ถึงภาพที่ 66 จะเห็นว่าค่าในแต่ละแกนของข้อมูลการเดินและการเดินขึ้นลงบันไดใกล้เคียงกันมากเช่นเดียวกับฐานข้อมูลกิจกรรมอื่น แต่กระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer ในฐานข้อมูลนี้ในแกนข้อมูล X มีการสลับกันเพราะสวมใส่อุปกรณ์ด้านซ้ายหรือขวา ซึ่งทำให้ข้อมูลจากสองตัวรับรู้ที่ได้รับขึ้นอยู่กับอาสาสมัครแต่ละคน อีกทั้งกระแสข้อมูลเชิงเวลาของตัว


รับรู้ Gyroscope ของอาสาสมัครแต่ละคนมีลักษณะแตกต่างกันอย่างชัดเจนและสังเกตได้ยากดังภาพที่ 67 ถึงภาพที่ 69




ภาพที่ 64 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Accelerometer




ภาพที่ 65 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Accelerometer



การเดิน




การเดินขึ้นลงบันได




การวิ่ง


ภาพที่ 66 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 3 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Accelerometer



การเดิน




การเดินขึ้นลงบันได




การวิ่ง

ภาพที่ 67 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 1 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Gyroscope




การเดิน

การเดินขึ้นลงบันได




การวิ่ง

ภาพที่ 68 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Gyroscope



การเดิน

การเดินขึ้นลงบันได



การวิ่ง

ภาพที่ 69 แผนภาพกระแสข้อมูลเชิงเวลาบางส่วนของกิจกรรมที่เป็นลักษณะเดินของอาสาสมัครที่ 2 ในฐานข้อมูลกิจกรรม WISDM (20 วินาที) จากตัวรับรู้ Gyroscope

จากการวิเคราะห์ข้อมูลกิจกรรมจากตัวรับรู้บนอุปกรณ์ที่สวมใส่ข้อมือหนึ่งอุปกรณ์จะเห็นได้ว่ากิจกรรมที่ร่างกายหยุดอยู่กับที่ตัวอย่างเช่น การยืน การนั่งและการนอนจะเกิดปัญหาข้อมูลกิจกรรมเดียวกันแต่มีลักษณะข้อมูลแตกต่างกัน ซึ่งเกิดขึ้นจากลักษณะท่าทางขณะเก็บข้อมูลที่แตกต่างกันขึ้นอยู่กับแต่ละคนและสามารถเปลี่ยนแปลงได้ง่าย ดังนั้นตัวแบบรู้จำจะต้องเรียนรู้รูปแบบหลัก ๆ ที่เกิดขึ้นกับอาสาสมัครทุกคนและสามารถปรับตามลักษณะของข้อมูลของแต่ละคน และกิจกรรมที่มีการขยับร่างกายไปจุดอื่น โดยตัวรับรู้ Accelerometer สามารถวัดความเร่งที่เกิดขึ้นจาก

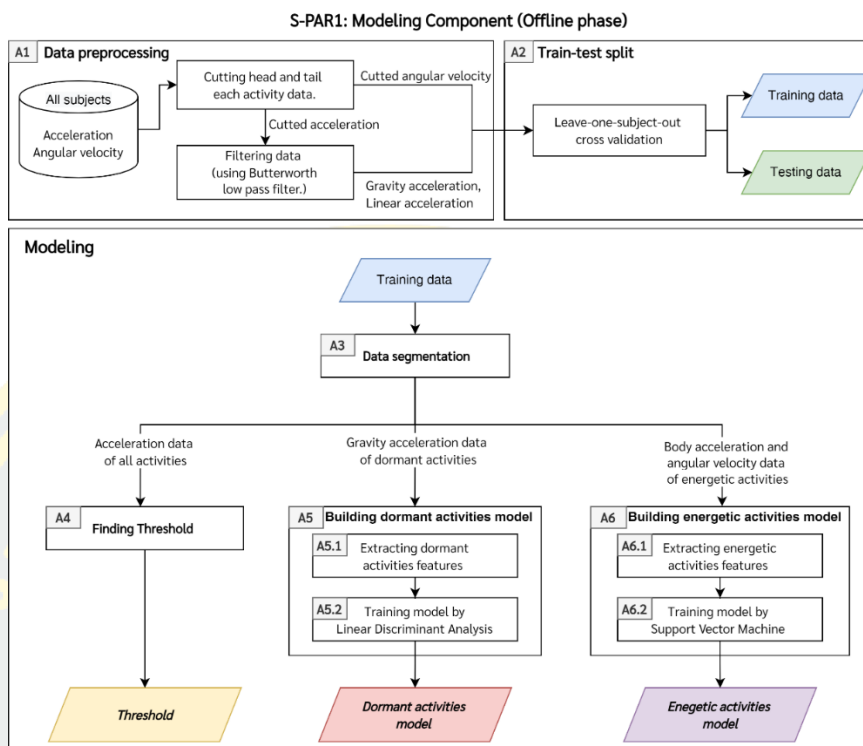
ผู้ใช้ที่เป็นตัวรับรู้หลักเพียงหนึ่งตัว ซึ่งในบางกิจกรรมมีลักษณะข้อมูลคล้ายกันมากเช่น การเดิน การเดินขึ้นบันไดและการเดินลงบันได ทำให้เกิดปัญหาการทับซ้อนของกลุ่มข้อมูลที่ต่างกิจกรรม จึงทำให้ตัวแบบรู้จำกิจกรรมระบุทั้งสามกิจกรรมมีความผิดพลาดสูงได้ ดังนั้นการเลือกวิธีการสร้างตัวแบบรู้จำที่ปรับจูนพารามิเตอร์ที่เหมาะสมและนำข้อมูลจากตัวรับรู้ Gyroscope มาเพิ่มจำนวนคุณลักษณะในการพิจารณาอาจจะช่วยให้ตัวแบบรู้จำกิจกรรมลดการระบุผิดพลาดได้น้อยลงทำให้ประสิทธิภาพในการรู้จำกิจกรรมได้ดีขึ้น

3.2 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition (S-PAR)

ในวิทยานิพนธ์ได้นำเสนอตัวแบบรู้จำทั้งหมด 3 เวอร์ชัน ดังจะกล่าวรายละเอียดในหัวข้อต่อไป

3.2.1 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition 1 (S-PAR1)

กรอบแนวคิดของวิธีการนี้ประกอบไปด้วย 2 องค์ประกอบได้แก่ กรอบแนวคิดสำหรับสร้างตัวแบบรู้จำกิจกรรม (Modeling component) เป็นขั้นตอนในสร้างแบบรู้จำกิจกรรมจากกระแสข้อมูลเชิงเวลาจากตัวรับรู้และกรอบแนวคิดรู้จำกิจกรรม (Recognition component) ที่เป็นขั้นตอนทดสอบตัวแบบรู้จำกิจกรรมที่สร้างขึ้น ซึ่งในกรอบแนวคิดสร้างตัวแบบรู้จำกิจกรรมจะประกอบไปด้วย 3 ขั้นตอนได้แก่การเตรียมข้อมูล, ขั้นตอนแบ่งข้อมูลสำหรับสร้างและทดสอบตัวแบบรู้จำและขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมดังภาพที่ 70 โดยมีรายละเอียดดังต่อไปนี้



ภาพที่ 70 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition 1 (S-PAR1) ขั้นตอนสร้างตัวแบบรู้จำกิจกรรม

ขั้นตอนสร้างตัวแบบรู้จำกิจกรรม S-PAR1 (Modeling component)


- A1 ขั้นตอนการเตรียมข้อมูล (Data Preprocessing)

ในขั้นตอนนี้จะประกอบไปด้วยการตัดข้อมูลส่วนเริ่มต้นและส่วนท้าย (Cutting head and tail of each activity data) และการกรองความถี่ของกระแสข้อมูลเชิงเวลา (Filtering data)


- A1.1 การตัดข้อมูลส่วนเริ่มต้นและส่วนท้าย (Cutting head and tail of each activity data)

ขั้นตอนนี้เป็นการนำกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope มาตัดข้อมูลส่วนเริ่มต้นและส่วนท้ายของแต่ละกิจกรรมที่เกิดจากการกดเริ่มและหยุดบันทึกข้อมูลการทำกิจกรรม โดยจะตัดข้อมูลเฉพาะฐานข้อมูลกิจกรรม RealWorld และ WISDM โดยกำหนดจำนวนข้อมูลที่ตัดตามขนาดของอัตราการสุ่มข้อมูลเป็นเวลาเท่ากับ 10 วินาที (Chowdhury และคณะ, 2017) แสดงดังภาพที่ 71 ไฮไลต์สีแดงเป็นกระแสข้อมูลเชิงเวลาที่ถูกตัดออกไป ซึ่งฐานข้อมูลกิจกรรม

PARDUSS ที่ตัดข้อมูลเริ่มต้นและสิ้นสุดการเก็บข้อมูล (Shoaib, Scholten, และ Havinga, 2013) และฐานข้อมูลกิจกรรม MHEALTH ได้ตัดส่วนนี้ให้แล้ว



การเดินของผู้ใช้คนที่ 1 จากฐานข้อมูล RealWorld



การเดินของผู้ใช้คนที่ 1 จากฐานข้อมูล WISDM

ภาพที่ 71 แผนภาพตัวอย่างการตัดส่วนหัวและส่วนท้ายของข้อมูลกิจกรรม


○ A1.2 การกรองความถี่ของกระแสข้อมูลเชิงเวลา (Filtering data)

ในขั้นตอนนี้ นำกระแสข้อมูลเชิงเวลาที่ได้จากตัวรับรู้ Accelerometer ซึ่งเป็นการวัดความเร่ง (Acceleration) เกิดขึ้นจะประกอบอยู่สองส่วน ได้แก่ ความเร่งที่เกิดจากแรงโน้มถ่วง (Gravity acceleration) และความเร่งเชิงเส้นที่เกิดจากการทำกิจกรรมของผู้ใช้ (Linear acceleration) วัดความเร่ง (Acceleration) ที่เกิดขึ้นบนระนาบสามมิติได้แก่แกน X, Y และ Z ซึ่งการแยกความเร่งทั้งสองค่าจะช่วยลดสัญญาณรบกวน (Noise) ของกระแสข้อมูลเชิงเวลาของกลุ่มกิจกรรมอยู่กับที่และนำความเร่งที่ถูกแยกเป็นคุณลักษณะเพิ่มเติมที่อาจจะช่วยให้ตัวรับรู้จำกิจกรรมได้แม่นยำเพิ่มขึ้น ดังนั้นมีหลายงานวิจัยที่นำตัวกรองความถี่ (Filter) มาประยุกต์ใช้ในการแยกความเร่งจากตัวรับรู้ Accelerometer ยกตัวอย่างเช่นงานวิจัยที่ใช้เป็นงานวิจัยของ Bayat, Pomplun, และ Tran (2014) ได้ทดลองนำตัวกรองความถี่ที่ต่ำ (Low pass filter) ที่กำหนดความถี่ตัดผ่านอยู่ระหว่าง 0.1 ถึง 0.5 โดยแนะนำที่ความถี่ตัดผ่านเท่ากับ 0.25 Hz ในการแยกความเร่งที่เกิดจากแรงโน้มถ่วงได้และนำไปลบกับกระแสข้อมูลเชิงเวลาให้ได้ความเร่งที่เกิดจากผู้ใช้งานดังภาพที่ 72 ส่วน

งานวิจัยของ Anguita และคณะ (2013) ได้ตั้งสมมุติฐานว่าความเร่งที่เกิดจากแรงโน้มถ่วงจากตัวรับ Accelerometer บนอุปกรณ์สมาร์ทโฟนจะอยู่ในความถี่ที่ต่ำ จึงได้นำตัวกรองความถี่ต่ำ Butterworth low-pass โดยกำหนดความถี่ตัดผ่าน (Cutoff frequency) เท่ากับ 0.3 Hz กรองความถี่สูงออกจากสัญญาณ ผลการทดลองแสดงให้เห็นว่าสามารถแยกความเร่งที่เกิดจากแรงโน้มถ่วงได้ ซึ่งสอดคล้องกับของงานวิจัย Uddin, Billah, และ Hossain (2016) ที่แนะนำให้ใช้วิธีการและพารามิเตอร์เดียวกัน ส่วนในงานวิทยานิพนธ์นี้ประยุกต์ใช้วิธีการ Butterworth low-pass filter ซึ่งกำหนดค่าความถี่ตัดเท่ากับ 0.3 Hz ซึ่งผลลัพธ์แสดงดังภาพที่ 73 และภาพแสดงผลในรูปแบบตารางดังภาพที่ 74 ประกอบด้วย จำนวนข้อมูล, กิจกรรมที่เก็บข้อมูล, เวลาที่เก็บข้อมูลและค่าที่เกิดขึ้นกับแกนข้อมูลทั้ง 3 แกนได้แก่ ค่าความเร่งจากตัวรับ Accelerometer (*Acc*), ค่าความเร่งเชิงมุมจากตัวรับ Gyroscope (*Gyro*) และค่าความเร่งที่แยกจาก Accelerometer คือความเร่งที่เกิดจากแรงโน้มถ่วง (*Gra*) และความเร่งที่เกิดจากผู้ใช้งาน (*Li*)




ภาพที่ 72 แผนภาพขั้นตอนกรองความถี่ต่ำและผลลัพธ์ที่ได้ในแต่ละขั้นตอน



ความเร่งที่วัดได้จากตัวรับ Accelerometer



ความเร่งเชิงเส้นที่เกิดจากผู้ใช้งาน



ความเร่งที่เกิดจากแรงโน้มถ่วง


ภาพที่ 73 แผนภาพกระแสข้อมูลเชิงเวลาความเร่งที่วัดได้จากตัวรับ Accelerometer

Raw data									Filtered data					
Sample	Label	Timestamp	AccX	AccY	AccZ	GyroX	GyroY	GyroZ	GraX	GraY	GraZ	LiX	LiY	LiZ
s_1	Walking	90434711346831	15.54	1.44	-2.26	-2.34	-1.42	-5.83	14.89	1.78	-2.23	0.65	-0.35	-0.03
s_2	Walking	90434761148901	14.48	-0.61	-3.25	-4.55	0.90	-4.96	14.78	1.40	-2.11	-0.29	-2.02	-1.14
s_2	Walking	90434810950971	15.59	-5.92	2.88	-3.91	0.44	-4.94	14.66	1.045	-1.99	0.90	-6.96	4.88
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
s_i	Walking	Timestamp _i	AccX _i	AccY _i	AccZ _i	GyroX _i	GyroY _i	GyroZ _i	GraX _i	GraY _i	GraZ _i	LiX _i	LiY _i	LiZ _i
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
s_n	Walking	Timestamp _n	AccX _n	AccY _n	AccZ _n	GyroX _n	GyroY _n	GyroZ _n	GraX _n	GraY _n	GraZ _n	LiX _n	LiY _n	LiZ _n

ภาพที่ 74 แสดงตัวอย่างข้อมูลดิบ (Raw data) และข้อมูลที่ถูกรอง (Filtered data)

- A2 ขั้นตอนการแบ่งชุดข้อมูลสำหรับเรียนรู้และทดสอบตัวแบบรู้จำ (Train-test split)


ในวิทยานิพนธ์นี้ได้ใช้วิธี Leave-one-subject-out cross validation สำหรับแบ่งชุดข้อมูลเพื่อใช้สร้างตัวแบบรู้จำกิจกรรม (Training data) และใช้ทดสอบตัวแบบรู้จำกิจกรรม (Testing data) โดยกำหนดจำนวนรอบ K ตามจำนวนของผู้ใช้ ซึ่งข้อมูลหนึ่งชุดคือข้อมูลของผู้ใช้หนึ่งคน ซึ่งในแต่ละรอบจะเปลี่ยนข้อมูลในการสร้างตัวแบบรู้จำกิจกรรมเป็นจำนวน K-1 ชุดและข้อมูลหนึ่งชุดที่ใช้ทดสอบเป็นข้อมูลผู้ใช้ที่ไม่ได้เป็นส่วนในการสร้างตัวแบบรู้จำกิจกรรมดังภาพที่ 75 ซึ่งข้อดีของวิธีการของ Leave-one-subject-out cross validation คือข้อมูลของผู้ที่ใช้เป็นข้อมูล ทดสอบไม่ได้เป็นส่วนหนึ่งในการสร้างตัวแบบรู้จำกิจกรรมที่สามารถลดการเกิดปัญหา Overfitting ของตัวแบบรู้จำกิจกรรมที่มีผลทำให้ลดความเอนเอียง (Bias) ของการวัดประสิทธิภาพความถูกต้องและความแม่นยำได้ (Dehghani, Glatard, และ Shihab, 2019)



ภาพที่ 75 แผนภาพตัวอย่างการแบ่งชุดข้อมูลกิจกรรมสำหรับการสร้างและทดสอบตัวแบบรู้จำกิจกรรม ด้วยวิธีการ Leave-one-subject-out cross validation

- **A3 ขั้นตอนการแบ่งชุดข้อมูลในการสร้างตัวแบบรู้จำกิจกรรมและรู้จำกิจกรรม (Data Segmentation)**

ขั้นตอนนี้เป็นขั้นตอนที่สำคัญในการรู้จำกิจกรรม เนื่องจากการเก็บกระแสข้อมูลเชิงเวลาที่มีลักษณะเป็นชุดตัวเลขที่มีขนาดเท่ากับอัตราการสุ่มของตัวรับรู้คุณกับระยะเวลาในการเก็บข้อมูลจึงทำให้ข้อมูลมีขนาดใหญ่และมีความแปรปรวนของค่าที่เกิดขึ้นสูง เมื่อนำมาสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการเรียนรู้ที่ต้องพิจารณาข้อมูลทุกแถวจะทำให้ใช้เวลาในการประมวลผลเพิ่มขึ้นและขนาดของข้อมูลที่ไม่เท่ากันในการรู้จำกิจกรรมแบบชุดข้อมูลเข้ามาต่อเนื่องกัน (Streaming data) จะมีผลต่อวิธีการคำนวณคุณลักษณะและการรู้จำกิจกรรมได้ ดังนั้นงานวิจัยที่ศึกษาการสร้างตัวแบบรู้จำกิจกรรมได้นำกระแสข้อมูลเชิงเวลาต่อเนื่องกันของกิจกรรมมาแบ่งชุดข้อมูลที่มีขนาดเล็กที่เรียกว่า Windows ที่สามารถพิจารณาค่าที่เกิดขึ้นในแต่ละ Windows และสามารถนำมาสร้างเป็นคุณลักษณะเพิ่มเติมที่เป็นตัวแทนของกิจกรรมใน Windows ซึ่งจะช่วยลดจำนวนของข้อมูลและลดซับซ้อนและเวลาในการประมวลผลของตัวแบบรู้จำกิจกรรม โดยที่ขนาดของ Windows จะเท่ากับจำนวนอัตราการสุ่มคูณกับจำนวนระยะเวลาวินาทีที่กำหนด ซึ่งการกำหนดวินาทีที่เหมาะสมจะทำให้ตัวแบบรู้จำกิจกรรมมีความแม่นยำเพิ่มมากขึ้น ซึ่งมีงานวิจัย Ferrari (2020) แนะนำให้ขนาดของ Window เท่ากับ 2 วินาทีเพียงพอต่อรู้จำกิจกรรมทางกายภาพ ดังนั้นในงานวิทยานิพนธ์นี้กำหนดขนาดเท่ากับ 2 วินาทีดังภาพที่ 76 กับทุกฐานข้อมูลกิจกรรม



ภาพที่ 76 ภาพตัวอย่างการแบ่งข้อมูลเป็นหน้าต่าง (Windows) จากฐานข้อมูล RealWorld ไฮไลต์สีแดงแสดงขนาด 2 วินาที (100 จุด)

ขั้นตอนถัดไปวิทยานิพนธ์นี้ได้แบ่งกิจกรรมออกเป็นสองกลุ่มได้แก่ กลุ่มกิจกรรมอยู่กับที่และกลุ่มกิจกรรมเคลื่อนไหว โดยสังเกตลักษณะจากการขยับตัวเคลื่อนไหวของร่างกายที่ค่าความเร่งจากตัวรับรู้ Accelerometer และ Gyroscope ตามแนวแกน X, Y และ Z การกระจายของข้อมูลกิจกรรมแบบเคลื่อนไหวมากกว่ากิจกรรมอยู่กับที่ (Y. Kwon, Kang, และ Bae, 2014) จัดกลุ่มกิจกรรมได้ตามตารางที่ 13

ตารางที่ 13 ฐานข้อมูลและกิจกรรมแต่ละกลุ่มกิจกรรมทางกายภาพ

ฐานข้อมูล	กลุ่มกิจกรรมอยู่กับที่ (Dormant activity)	กลุ่มกิจกรรมเคลื่อนไหว (Energetic activity)
RealWorld	การยืน การนั่ง การนอน	การเดิน การเดินขึ้นบันได การเดินลงบันได การวิ่ง
PARDUSS	การยืน การนั่ง	การเดิน การเดินขึ้นบันได การเดินลงบันได การวิ่ง
MHEALTH	การยืน การนั่ง การนอน	การเดิน การเดินขึ้นลงบันได การวิ่ง, การวิ่งจ็อกกิ้ง
WISDM	การยืน การนั่ง	การเดิน การเดินขึ้นลงบันได การวิ่ง

- A4 ขั้นตอนการหาค่าขีดแบ่ง (Threshold) สำหรับแบ่งกลุ่มกิจกรรม

ในขั้นตอนนี้เป็นการหาค่าขีดแบ่งสำหรับกำหนดกลุ่มกิจกรรมให้กับแต่ละ Windows โดยพิจารณาจากความเร่ง (Acceleration) จากตัวรับรู้ Accelerometer ซึ่งสามารถคำนวณขนาดของ

ค่าความเร่ง (Acceleration Magnitude) ดังสมการที่ 3.1 และคำนวณคุณลักษณะส่วนเบี่ยงเบนมาตรฐานของขนาดความเร่งดังสมการที่ 3.2

Sample	AccX	AccY	AccZ	AccM
$s_1^{walking}$	15.54	1.44	-2.26	15.77
\vdots	\vdots	\vdots	\vdots	\vdots
$s_{100}^{walking}$	AccX ₁₀₀	AccY ₁₀₀	AccZ ₁₀₀	M ₁₀₀
\vdots	\vdots	\vdots	\vdots	\vdots
$s_i^{walking}$	AccX _i	AccY _i	AccZ _i	M _i
\vdots	\vdots	\vdots	\vdots	\vdots
$s_n^{walking}$	AccX _n	AccY _n	AccZ _n	M _n

ภาพที่ 77 ตารางแสดงค่า Accelerometer และค่าขนาดความเร่งในการแบ่ง Windows

$$AccM_i = \sqrt{AccX_i^2 + AccY_i^2 + AccZ_i^2} \quad (3.1)$$

โดยที่ i คือค่าลำดับของแถวในชุดข้อมูลตั้งแต่ i
 $AccM_i$ คือค่า Magnitude จากตัวรับรู้ Accelerometer ที่ i
 $AccX_i$ คือค่า Accelerometer ตามแนวแกน X ที่ i
 $AccY_i$ คือค่า Accelerometer ตามแนวแกน Y ที่ i
 $AccZ_i$ คือค่า Accelerometer ตามแนวแกน Z ที่ i

$$SD_{AccM_j}^{act} = \sqrt{\frac{1}{n_j - 1} \sum_{i=1}^{n_j} (AccM_{ji} - \overline{AccM}_j)^2} \quad (3.2)$$

โดยที่ $SD_{AccM_j}^{act}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของขนาดความเร่ง ($AccM$) ที่ Windows j ของแต่ละกิจกรรม (act)
 $AccM_{ji}$ คือ ค่าขนาดความเร่งของแถว i ใน Windows j
 \overline{AccM}_j คือ ค่าเฉลี่ยของขนาดความเร่งของ Windows j
 n_j คือ ค่าจำนวนข้อมูลทั้งหมดของกิจกรรมที่กำลังพิจารณา
 j คือ ค่าที่ใช้สำหรับระบุลำดับของ Windows
 act คือ กิจกรรมที่กำลังพิจารณา

เมื่อคำนวณส่วนเบี่ยงเบนมาตรฐานของแต่ละ Windows ครบทุกกิจกรรมแล้ว ให้คำนวณค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐานทุก Windows ของแต่ละกิจกรรมดังสมการที่ 3.3 และคำนวณค่าขีดแบ่งของกลุ่มกิจกรรมดังสมการที่ 3.4

$$AVG_{SD_{AccM}}^{act} = \frac{\sum_{j=1}^{j^{act}} SD_{AccM_j}^{act}}{j^{act}} \quad (3.3)$$

โดยที่ $AVG_{SD_{AccM}}^{act}$ คือ ค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐานขนาดความเร่งในแต่ละกิจกรรม

j^{act} คือ จำนวน Window ของข้อมูลของกิจกรรม

$SD_{AccM_j}^{act}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของขนาดความเร่งในแต่ละ Window ของกิจกรรม


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

โดยที่ $Threshold$ คือ ค่าขีดแบ่งกลุ่มกิจกรรม

SD_{max}^{dor} คือ ค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐานขนาดความเร่งที่มากที่สุดของกิจกรรมอยู่กับที่

SD_{min}^{ene} คือ ค่าเฉลี่ยของส่วนเบี่ยงเบนมาตรฐานขนาดความเร่งที่น้อยที่สุดของกลุ่มกิจกรรมเคลื่อนไหว

เมื่อคำนวณตามสมการที่ 3.4 จะได้ค่าขีดแบ่งกลุ่มกิจกรรม (Threshold) เป็นค่าเฉลี่ยกลางที่สามารถแบ่งข้อมูลกิจกรรมทั้งสองกลุ่มได้ดังภาพที่ 78



ภาพที่ 78 แผนภาพตัวอย่างค่าขีดแบ่งที่สามารถแบ่งข้อมูลกิจกรรมเคลื่อนไหวกับกิจกรรมอยู่กับที่ของฐานข้อมูลกิจกรรม RealWorld และ PARDUSS


- A5 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมอยู่กับที่ (Building dormant activities model)

ขั้นตอนนี้ประกอบไปด้วยสองขั้นตอนได้แก่ ขั้นตอนการคำนวณคุณลักษณะของกลุ่มกิจกรรมอยู่กับที่และการสร้างตัวแบบรู้จำกิจกรรมกลุ่มอยู่กับที่โดยมีรายละเอียดดังต่อไปนี้


- A5.1 ขั้นตอนการคำนวณคุณลักษณะของกลุ่มกิจกรรมอยู่กับที่

ในขั้นตอนสร้างคุณลักษณะจะพิจารณาจากกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงของกลุ่มกิจกรรมอยู่กับที่ ซึ่งมีลักษณะเส้นตรงและไม่มีข้อมูลความเร่งที่เกิดจากผู้ใช้งานเข้ามาเกี่ยวข้อง ดังนั้นลักษณะข้อมูลการทำกิจกรรมในกลุ่มนี้จะขึ้นอยู่กับทิศทางและตำแหน่งของข้อมือที่


สวมใสอุปกรณ์ดังภาพที่ 79 ถึง 81 และคำนวณคุณลักษณะทางสถิติค่าเฉลี่ยของกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงในแต่ละ Windows ทั้ง 3 แกนดังสมการที่ 3.5 ถึง 3.7



ภาพที่ 79 แผนภาพเส้นแสดงลักษณะกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแกน X, Y และ Z ของกิจกรรมยืนของอาสาสมัครที่ 1 และ 3 จากฐานข้อมูลกิจกรรม RealWorld



ภาพที่ 80 แผนภาพเส้นแสดงลักษณะกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแกน X, Y และ Z ของกิจกรรมนั่งของอาสาสมัครที่ 1 และ 3 จากฐานข้อมูลกิจกรรม RealWorld



ภาพที่ 81 แผนภาพเส้นแสดงลักษณะกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วงตามแกน X, Y และ Z ของกิจกรรมนอนของอาสาสมัครที่ 1 และ 3 จากฐานข้อมูลกิจกรรม RealWorld

$$AVG_{GraX_j}^{act} = \frac{\sum_{i=1}^{n_j} GraX_i}{n_j} \quad (3.5)$$

$$AVG_{GraY_j}^{act} = \frac{\sum_{i=1}^{n_j} GraY_i}{n_j} \quad (3.6)$$

$$AVG_{GraZ_j}^{act} = \frac{\sum_{i=1}^{n_j} GraZ_i}{n_j} \quad (3.7)$$

โดยที่	$AVG_{GraX_j}^{act}$	คือ ค่าเฉลี่ยของข้อมูลค่าความเร่งที่เกิดจากแรงโน้มถ่วงแกน X ของ Windows ที่ j
	$AVG_{GraY_j}^{act}$	คือ ค่าเฉลี่ยของข้อมูลค่าความเร่งที่เกิดจากแรงโน้มถ่วงแกน Y ของ Windows ที่ j
	$AVG_{GraZ_j}^{act}$	คือ ค่าเฉลี่ยของข้อมูลค่าความเร่งที่เกิดจากแรงโน้มถ่วงแกน Z ของ Windows ที่ j
	$GraX_i$	คือ ความเร่งที่เกิดจากแรงโน้มถ่วงแนวแกน X ที่ i
	$GraY_j$	คือ ความเร่งที่เกิดจากแรงโน้มถ่วงแนวแกน Y ที่ i
	$GraZ_i$	คือ ความเร่งที่เกิดจากแรงโน้มถ่วงแนวแกน Z ที่ i
	n_j	คือ จำนวนข้อมูลทั้งหมดภายใน Window
	i	คือ ค่าที่ใช้สำหรับระบุลำดับของข้อมูล โดยที่ $i = 1, 2, 3, \dots, n$
	j	คือ ค่าที่ใช้สำหรับระบุลำดับของ Window

○ A5.2 การสร้างตัวแบบรู้จำกลุ่มกิจกรรมอยู่กับที่

ขั้นตอนนี้จะนำคุณลักษณะค่าเฉลี่ยของทั้งสามแกนนำมาสร้างเป็นตัวแบบรู้จำโดยใช้วิธีเรียนรู้การจำแนกกลุ่มการวิเคราะห์การจำแนกประเภทเชิงเส้น (Linear Discriminant Analysis) เป็นวิธีการสร้างเส้นตรงที่สามารถแบ่งกลุ่มกิจกรรมให้ได้มากที่สุดและทำการมิติที่โพรเจคชัน (Projection) ลงบนเส้นตรงจากจำนวนคุณลักษณะ 3 เป็น 2 คุณลักษณะเพื่อลดการกระจายกลุ่มย่อยของกลุ่มกิจกรรมอยู่กับที่และรู้จำกิจกรรมด้วยวิธีการ Naïve Bayes โดยใช้การพิจารณาการกระจายข้อมูลแบบ Gaussian distribution จากผลการทดลองที่สร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการนี้สามารถให้ประสิทธิภาพในการรู้จำที่ดีที่สุด

- A6: ขั้นตอนการสร้างตัวแบบรู้จำกลุ่มกิจกรรมเคลื่อนไหว (Building energetic activities model)

ประกอบด้วยขั้นตอนการคำนวณคุณลักษณะของกิจกรรมเคลื่อนไหวและสร้างตัวแบบรู้จำด้วยวิธีการเรียนรู้ Support Vector Machine (SVM) โดยมีรายละเอียดดังต่อไปนี้

○ A6.1 ขั้นตอนการคำนวณคุณลักษณะของกลุ่มกิจกรรมเคลื่อนไหว

โดยขั้นตอนนี้ นำกระแสข้อมูลเชิงเวลาที่เกิดจากผู้ใช้งานตัวรับรู้ Accelerometer และกระแสข้อมูลเชิงเวลาอัตราเร่งเชิงมุมจากตัวรับรู้ Gyroscope ในแต่ละ Windows j ทั้งหมด 6 แกนข้อมูล มาคำนวณทางสถิติจำนวน 12 คุณลักษณะดังตารางที่ 14 จะได้จำนวนคุณลักษณะทั้งหมดเท่ากับ 72 คุณลักษณะ ซึ่งเป็นจำนวนคุณลักษณะจำนวนมากเมื่อเทียบกับงานวิจัยอื่น ดังนั้นจึงนำวิธีการจัดหมู่กลุ่มคุณลักษณะ (Combination) โดยเริ่มทดลองสร้างตัวแบบรับรู้กิจกรรมตั้งแต่ 1 การคำนวณค่าสถิติ 1 ลำดับถึง 12 ลำดับ จะได้จำนวนกลุ่มคุณลักษณะจำนวน 4095 กลุ่มที่ใช้ในการทดลองสร้างตัวแบบรับรู้กิจกรรม ซึ่งจากการทดลองได้วิธีการคำนวณทางสถิติจำนวน 3 วิธีการได้แก่ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความเบ้ (Skewness) และเปอร์เซ็นต์ไทล์ที่ 75 (75th Percentile) คิดเป็นจำนวน 18 คุณลักษณะที่ประสิทธิภาพดีที่สุด

ตารางที่ 14 การคำนวณทางคณิตศาสตร์สถิติของคุณลักษณะในวิธีการ S-PAR1

ลำดับ	คุณลักษณะ	สมการคำนวณ
1	Average	$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x(i)$
2	Median	$m_j = \begin{cases} \frac{(n+1)}{2}; & \text{where } n \text{ is odd} \\ \frac{n}{2} + \left(\frac{n}{2} + 1\right); & \text{where } n \text{ is even} \end{cases}$
3	Variance	$var_j = \frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})^2$
4	Standard deviation	$s_j = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})^2}$
5	Minimum	$\max(x)$
6	Maximum	$\min(x)$
7	Skewness	$Skew_j = \frac{\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^3}{\left(\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^2\right)^{\frac{3}{2}}}$
8	Kurtosis	$Kurt_j = \frac{\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^4}{\left(\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^2\right)^2}$
9	25th percentile	$p25_j = \frac{25}{100} (n + 1)$
10	75th percentile	$p75_j = \frac{75}{100} (n + 1)$

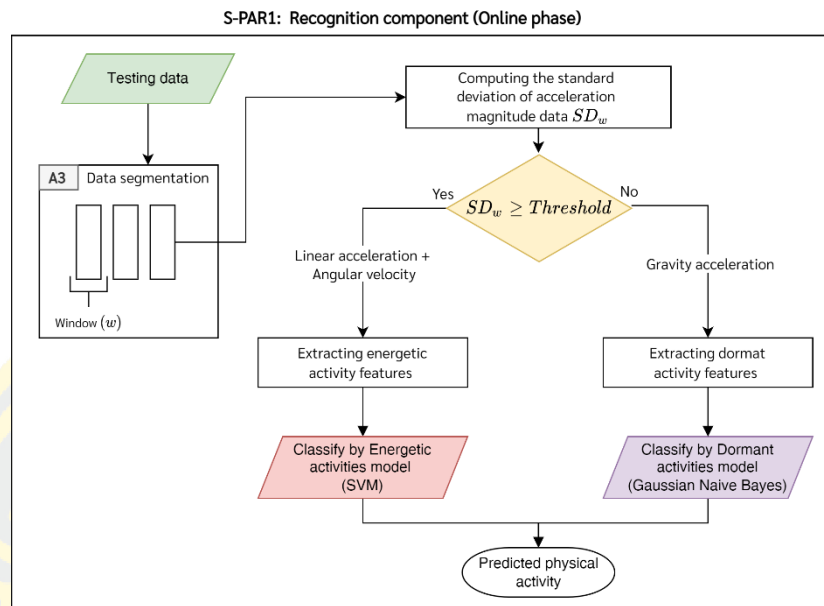
11	Interquartile range	$IQR_j = Q3_{x_i} - Q1_{x_i}$
12	Root Mean Squared	$RMS_j = \sqrt{\frac{1}{n} \sum_{i=1}^n x(i)^2}$

○ A6.2 ขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมของกลุ่มกิจกรรมเคลื่อนไหว

เมื่อคำนวณคุณลักษณะในแต่ละ Window ของแต่ละกิจกรรม จะนำมาสร้างเป็นตัวแบบรู้จำกิจกรรมเคลื่อนไหวโดยวิธีการเรียนรู้ Support Vector Machine (svm.SVC) โดยกำหนดพารามิเตอร์เป็นค่าเริ่มต้นที่ไลบรารี Scikit-learn ตามตารางค่าเริ่มต้นในบทที่ 2 เนื่องจากได้ทดลองเปรียบเทียบกับวิธีการเรียนรู้อื่นๆ ได้แก่ Decision Tree, Naïve Bayes, K-Nearest Neighbors และ Artificial Neural Network ที่ไม่มีการปรับพารามิเตอร์ในการสร้างตัวแบบรู้จำกิจกรรม ซึ่งวิธีการเรียนรู้ SVM ให้ประสิทธิภาพในการรู้จำกิจกรรมมากที่สุด

ขั้นตอนรู้จำกิจกรรมของวิธีการรู้จำกิจกรรม S-PAR1 (Recognition component)

ในขั้นตอนนี้เป็นการจำลองกระแสข้อมูลเชิงเวลาของตัวรับรู้ Accelerometer และ Gyroscope จากข้อมูลทดสอบ (Testing data) ของผู้ใช้หนึ่งคนให้แต่ละรอบแสดงดังภาพที่ 82 ซึ่งแบ่งกระแสข้อมูลเชิงเวลาออกเป็น Windows ที่มีขนาดเท่ากับ 2 วินาทีและโดยนำผ่านกระบวนการดังต่อไปนี้



ภาพที่ 82 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition (S-PAR1) ขั้นตอนรู้จำกิจกรรม

- ขั้นตอนการแบ่งประเภทกิจกรรมด้วยค่าขีดแบ่ง ในขั้นตอนนี้จะทำการกำหนดกลุ่มข้อมูลใน Window ว่าเป็นกลุ่มกิจกรรมอยู่กับที่หรือกลุ่มกิจกรรมเคลื่อนไหว ซึ่งนำกระแสข้อมูลเชิงเวลาค่าความเร่ง (Acceleration) จากตัวรับรู้ Accelerometer ในแต่ละ Window มาคำนวณหาค่าส่วนเบี่ยงเบนมาตรฐานของค่าขนาดของความเร่ง (Standard deviation of acceleration magnitude data) ซึ่งเปรียบเทียบกับค่าขีดแบ่งที่สร้างไว้โดยมีเกณฑ์ดังนี้
 - ถ้า $SD_{M_j} \geq Threshold$ แสดงว่าข้อมูลจะเป็นกิจกรรมเคลื่อนไหว
 - แต่ถ้า $SD_{M_j} < Threshold$ แสดงว่าข้อมูลเป็นกิจกรรมอยู่กับที่
- ขั้นตอนการรู้จำกลุ่มกิจกรรมหยุดกับที่ ขั้นตอนนี้เป็นการรู้จำกิจกรรมของ Windows ที่ถูกกำหนดให้เป็นกลุ่มกิจกรรมอยู่กับที่ โดยคำนวณคุณลักษณะค่าเฉลี่ยในแต่ละแกนจากกระแสข้อมูลเชิงเวลาความเร่งที่เกิดจากแรงโน้มถ่วง (Gravity acceleration) นำมาผ่านตัวแบบรู้จำกิจกรรมอยู่กับที่ด้วยวิธีการจำแนกกลุ่มการวิเคราะห์การจำแนกประเภทเชิงเส้น (LDA) และระบุกิจกรรมหยุดกับที่โดยผ่านหลักการของ Gaussian Native Bayes
- ขั้นตอนการรู้จำกิจกรรมเคลื่อนไหว ขั้นตอนนี้เป็นการรู้จำกิจกรรมที่มีการเคลื่อนไหว โดยคำนวณคุณลักษณะค่าส่วนเบี่ยงเบนมาตรฐาน, ค่าความเบ้และเปอร์เซ็นต์ไทล์ที่ 75 จาก


กระแสข้อมูลเชิงเวลาความเร่งเชิงเส้น (Linear acceleration) จากตัวรับรู้ Accelerometer และกระแสข้อมูลเชิงเวลาอัตราเร่งเชิงมุม (Angular velocity) จากตัวรับรู้ Gyroscope นำมาผ่านตัวแบบรู้จำกิจกรรม SVM ในการระบุกิจกรรมเคลื่อนไหว

ข้อจำกัดของวิธีการ S-PAR1

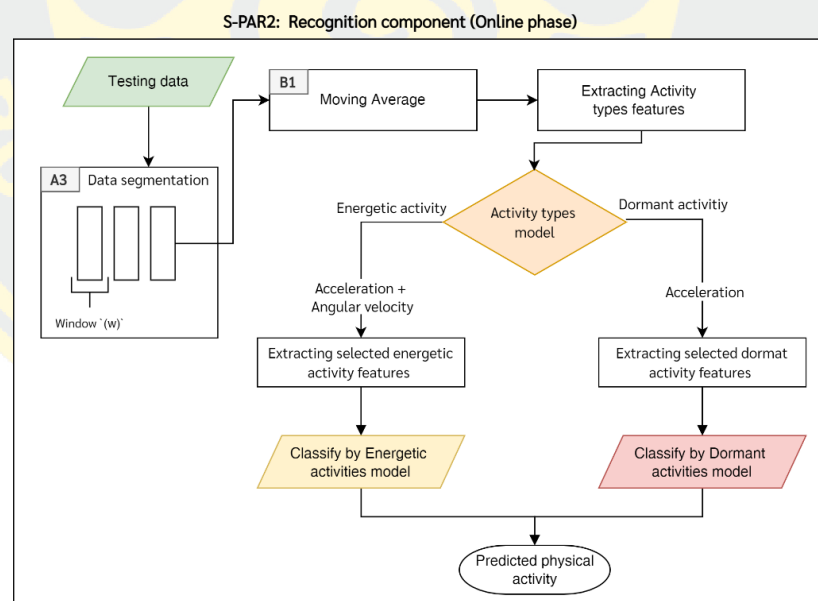
จากการสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการ S-PAR1 นำมาวัดประสิทธิภาพในการรู้จำกิจกรรมกับสี่ฐานข้อมูลเปรียบเทียบผลการทดลองกับงานวิจัยที่เกี่ยวข้อง ผลการทดลองแสดงให้เห็นว่าวิธีการ S-PAR1 สามารถรู้จำกิจกรรมทั้งสองกลุ่มกิจกรรมในฐานข้อมูล RealWorld และ PARDUSS ได้ดีแต่จะสังเกตเห็นว่าค่าความถูกต้องและแม่นยำของการเดินขึ้นบันไดและการเดินลงบันไดมีค่าค่อนข้างต่ำและจะแปรผกผันกับกิจกรรมการเดินและฐานข้อมูล MHEALTH และ WISDM มีประสิทธิภาพในการรู้จำกิจกรรมต่ำกว่างานวิจัยที่เปรียบเทียบ โดยที่ข้อมูลกลุ่มกิจกรรมอยู่กับที่ กิจกรรมเดียวกันมีการกระจายออกเป็นกลุ่มย่อยออกไปมากกว่าฐานข้อมูลอื่น ซึ่งการโปรเจกชันลดมิติข้อมูลลงอาจจะทำให้วิธีการเรียนรู้จำไม่สามารถแยกความแตกต่างของกิจกรรมที่ข้อมูลทีโปรเจกชันลงมาทับซ้อนกันและในขั้นตอนการองความถี่สำหรับฐานข้อมูล MHEALTH ที่พารามิเตอร์ไม่ได้เหมาะสมกับข้อมูลกิจกรรมจากการตั้งค่าของตัวรับรู้ทำให้ข้อมูลที่สำคัญหายไปซึ่งส่งผลต่อรู้จำกิจกรรมเคลื่อนไหวซึ่งจะต้องพัฒนาในเวอร์ชันถัดไป

3.2.2 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition 2 (S-PAR2)

เป็นการพัฒนาต่อยอดมาจากวิธีการรู้จำกิจกรรม S-PAR1 โดยได้พัฒนาตัวแบบรู้จำกิจกรรมให้มีประสิทธิภาพในการระบุกิจกรรมที่ทำได้ถูกต้องเพิ่มมากขึ้น โดยปรับปรุงและเพิ่มขั้นตอนบางส่วนในการตัวแบบรู้จำกิจกรรมที่แสดงในภาพที่ 83 และภาพที่ 84 ซึ่งในกรอบที่นำหน้าด้วยตัวอักษร B แทนเป็นการปรับปรุงขั้นตอนในวิธีการ S-PAR2 โดยรายละเอียดดังต่อไปนี้



ภาพที่ 83 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition 2 (S-PAR2) ขั้นตอนสร้างตัวแบบรู้จำกิจกรรม



ภาพที่ 84 แผนภาพวิธีการ Smartwatch-based Physical Activity Recognition 2 (S-PAR2) ขั้นตอนรู้จำกิจกรรม

- **B1 เพิ่มการปรับเรียบข้อมูล (Moving Average)**

ในการสร้างตัวแบบรู้จำกิจกรรม (Modeling Component) ในกรอบการเตรียมข้อมูล (Data preprocessing) ได้เปลี่ยนจากวิธีการกรองความถี่ต่ำด้วยวิธีการ Butterworth filter low pass เป็นการเพิ่มขั้นตอนการปรับเรียบข้อมูล (Moving Average) ในกรอบการสร้างตัวแบบรู้จำกิจกรรม (Modeling) เนื่องจากค่าที่ตัดผ่านเหมาะสมสำหรับตัวรับรู้ Accelerometer บนอุปกรณ์สมาร์ทโฟนและนาฬิกาอัจฉริยะเท่านั้น ทำให้กระแสข้อมูลเชิงเวลาที่เก็บจากตัวรับรู้บนอุปกรณ์อื่นสูญเสียข้อมูลที่สำคัญไปและไม่สามารถใช้งานร่วมกับตัวรับรู้ชนิดอื่นและกระแสข้อมูลเชิงเวลาที่แบ่งเป็นแต่ละ Window ได้ จึงนำมาวิธีการปรับเรียบข้อมูลที่สามารถลดสัญญาณรบกวนที่เกิดจากข้อผิดพลาดจากการสุ่มจากตัวรับรู้ที่ทำงานผิดพลาดหรืออาสาสมัครและสามารถใช้งานร่วมกับกระแสข้อมูลเชิงเวลาจากตัวรับรู้ทุกฐานข้อมูลกิจกรรมและช่วยคุณภาพของคุณลักษณะดีขึ้น ในการทดลองกำหนดจำนวนค่าที่นำมาพิจารณาในการปรับเรียบข้อมูลตั้งแต่ 1 ถึง 10 จุดซึ่งข้อควรระวังคือการนำจำนวนค่าที่นำมาพิจารณามากเกินไปอาจจะทำให้ข้อมูลที่สำคัญหายไปได้ ซึ่งนำหลักการนี้ใช้กับกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope และกำหนดให้จำนวนค่าที่นำมาพิจารณาเท่ากับ 5 จุด

- **B2 ปรับวิธีการรู้จำกลุ่มกิจกรรม (Building activity types model)**

ในขั้นตอนนี้เปลี่ยนวิธีการในการแบ่งกลุ่มกิจกรรมจากวิธีการหาค่าขีดแบ่ง (Threshold) เป็นการสร้างตัวแบบรู้จำกิจกรรมด้วยวิธีการเรียนรู้ SVM ซึ่งเพิ่มคุณลักษณะค่าส่วนเบี่ยงเบนมาตรฐานของขนาดของอัตราเร่งเชิงมุม (Angular velocity magnitude) จากตัวรับรู้ Gyroscope ของแต่ละกิจกรรมดังสมการที่ 3.8 และ 3.9


$$GyroM_i = \sqrt{GyroX_i^2 + GyroY_i^2 + GyroZ_i^2} \quad (3.8)$$

โดย	$GyroM_i$	คือค่าขนาดอัตราเร่งเชิงมุม (Magnitude) ที่ i
	$GyroX_i$	คือค่าอัตราเร่งเชิงมุมตามแนวแกน X ที่ i
	$GyroY_i$	คือค่าอัตราเร่งเชิงมุมตามแนวแกน Y ที่ i
	$GyroZ_i$	คือค่าอัตราเร่งเชิงมุมตามแนวแกน Z ที่ i


$$SD_{GyroM_j} = \sqrt{\frac{1}{n_j - 1} \sum_{i=1}^{n_j} (GyroM_{ji} - Gyro\bar{M}_j)^2} \quad (3.9)$$

โดย SD_{GyroM_j} คือ ค่าส่วนเบี่ยงเบนมาตรฐานของขนาดอัตราเร่งเชิงมุมของตัวรับรู้
จากตัวรับรู้ Gyroscope ภายใน Windows ที่ j ของแต่ละกลุ่มกิจกรรม
 $GyroM_{ji}$ คือ ค่าขนาดอัตราเร่งเชิงมุมของตัวรับรู้ Gyroscope ที่ i ใน
Windows ที่ j
 $Gyro\bar{M}_j$ คือ ค่าเฉลี่ยขนาดอัตราเร่งเชิงมุมของตัวรับรู้ Gyroscope ของ
Windows ที่ j
 n_j คือ ค่าจำนวนข้อมูลใน Windows ของกิจกรรมที่กำลังพิจารณา
 j คือ ค่าที่ใช้สำหรับระบุลำดับของ Windows


จะได้ค่าส่วนเบี่ยงเบนมาตรฐานที่คำนวณได้จากตัวรับรู้จากตัวรับรู้ Gyroscope ของแต่ละ
กิจกรรมรวมกับค่าส่วนเบี่ยงเบนมาตรฐานจากตัวรับรู้ Accelerometer รวมเป็นสองคุณลักษณะ
จากนั้นนำมาสร้างเป็นตัวแบบรู้จำกลุ่มกิจกรรม (Activity type model) โดยใช้วิธีการสร้างตัวแบบ
รู้จำกิจกรรม SVM โดยกำหนดใช้ฟังก์ชัน Kernel เท่ากับ Linear เมื่อคำนวณตามสมการและนำเสนอ
คุณลักษณะผ่านขั้นตอนการเรียนรู้ จะเห็นว่าเส้นแบ่งข้อมูลกิจกรรมทั้งสองกลุ่มดังภาพที่ 84




ฐานข้อมูลกิจกรรม RealWorld



ฐานข้อมูลกิจกรรม PARDUSS



ฐานข้อมูลกิจกรรม MHEALTH



ฐานข้อมูลกิจกรรม WISDM

ภาพที่ 85 แผนภาพแสดงเส้นแบ่งกิจกรรมข้อมูลจากตัวแบบรู้จำ Linear SVM

- B3 ปรับวิธีการสร้างตัวแบบรู้จำกลุ่มกิจกรรมอยู่กับที่ (Building dormant activities model)

ในวิธีการสร้างตัวแบบรู้จำกิจกรรมกลุ่มกิจกรรมอยู่กับที่ของวิธีการ S-PAR2 ที่ได้รับการปรับปรุงโดยรายละเอียดดังต่อไปนี้

- B3.1 ขั้นตอนการสกัดคุณลักษณะของกลุ่มกิจกรรมอยู่กับที่ (Extracting dormant activities features)

ในขั้นตอนนี้เป็นการเพิ่มจำนวนคุณลักษณะของการรู้จำกิจกรรมอยู่กับที่เนื่องจากเฉพาะค่าเฉลี่ยของแต่ละแกนในวิธีการ S-PAR1 อาจจะไม่เพียงพอในการสร้างตัวแบบรู้จำกิจกรรมซึ่งมีผลต่อประสิทธิภาพในรู้จำกิจกรรมโดยตรง ดังนั้นวิธีการ S-PAR2 นี้จึงเพิ่มจำนวนคุณลักษณะโดยคำนวณค่าคณิตศาสตร์สถิติจำนวน 5 ลำดับในตารางที่ 15 ได้แก่ Average(1), Median (2), Standard deviation (4), Minimum (5) และ Maximum (6) ทำให้จำนวนคุณลักษณะจาก 3 คุณลักษณะเป็น 15 คุณลักษณะ

ตารางที่ 15 ตารางคุณลักษณะที่ใช้สร้างตัวแบบรู้จำกิจกรรมเคลื่อนไหวของวิธีการรู้จำกิจกรรม S-PAR2

ลำดับ	คุณลักษณะ	สมการคำนวณ	จำนวน
1	Average	$\bar{x}_i = \frac{1}{n} \sum_{i=1}^n x(i)$	6
2	Median	$m_i = \begin{cases} \frac{(n+1)}{2}; & \text{where } n \text{ is odd} \\ \frac{n}{2} + \frac{(n+1)}{2}; & \text{where } n \text{ is even} \end{cases}$	6

3	Variance	$var_i = \frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})^2$	6
4	Standard deviation	$s_i = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})^2}$	6
5	Minimum	$\max(x)$	6
6	Maximum	$\min(x)$	6
7	Skewness	$Skew_{x_i} = \frac{\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^3}{\left(\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^2\right)^{\frac{3}{2}}}$	6
8	Kurtosis	$Kurt_{x_i} = \frac{\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^4}{\left(\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}_i)^2\right)^2}$	6
9	25th percentile	$p25_{x_i} = \frac{25}{100} (n+1)$	6
10	75th percentile	$p75_{x_i} = \frac{75}{100} (n+1)$	6
11	Interquartile range	$IQR_{x_i} = Q3_{x_i} - Q1_{x_i}$	6
12	Root Mean Squared	$RMS_{x_i} = \sqrt{\frac{1}{n} \sum_{i=1}^n x(i)^2}$	6
13	Mean Crossing	$MC_{x_i} = \sum_{i=1}^n \text{sign}\{(x(i) - \bar{x}) \times (x(i-1) - \bar{x}) < 0\}$	6
14	Cross-correlation coefficient	$r(x, y) = \frac{\sum_{n=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{n=1}^n x_i - \bar{x}} \sqrt{\sum_{n=1}^n y_i - \bar{y}}}$	15
15	Dominant frequency	$f_{max} = f_m ; m = \underset{k}{\text{argmax}} FFT_k$	6
16	Magnitude of dominant frequency	$mf = \underset{k}{\text{argmax}} FFT_k$	6
17	Magnitude Energy	$e = \frac{1}{kn} \sum_{i=1}^{kn} FFT_i ^2$	6
	จำนวนคุณลักษณะทั้งหมด		111

○ B3.2 ขั้นตอนการเลือกคุณลักษณะของกลุ่มกิจกรรมอยู่กับที่ (Selecting feature by Fisher score)

จากการเพิ่มจำนวนคุณลักษณะทำให้ในการสร้างตัวแบบรู้จำกิจกรรมต้องเพิ่มการคำนวณมากขึ้นอาจจะทำให้วิธีการรู้จำกิจกรรมเรียนรู้คุณลักษณะมากเกินไปอาจจะทำให้เกิดปัญหา Underfitting หรือ Overfitting ได้ ดังนั้นจำเป็นต้องมีขั้นตอนการเลือกคุณลักษณะที่เหมาะสมกับลักษณะของข้อมูลกิจกรรมและลดการคำนวณคุณลักษณะที่พิจารณา จึงเพิ่มขั้นตอนการเลือก

คุณลักษณะ (Feature selection) โดยกำหนดวิธีการเลือกคุณลักษณะ Fisher Score และกำหนดจำนวนคุณลักษณะที่เลือกเท่ากับ 6 คุณลักษณะจาก 12 คุณลักษณะ

○ B3.3 สร้างตัวแบบรู้จำกิจกรรมอยู่กับที่ (Training model by Naïve Bayes)

ในขั้นตอนนี้ได้ทำการเปลี่ยนวิธีการเรียนรู้ในการสร้างตัวแบบรู้จำกิจกรรมอยู่กับที่จากเดิมใช้วิธีการจำแนกกลุ่มวิเคราะห์การจำแนกประเภทเชิงเส้น Linear Discriminate Analysis (LDA) เป็นวิธีการ Naïve Bayes โดยคำนวณความน่าจะเป็นแบบ Gaussian distribution ซึ่งนำมาใช้ร่วมกับวิธีการเลือกคุณลักษณะ Fisher Score จากผลการทดลองที่ให้ประสิทธิภาพในการรู้จำแม่นยำมากที่สุด

● B4 ปรับวิธีการสร้างตัวแบบรู้จำกลุ่มกิจกรรมเคลื่อนไหว (Building energetic activities model)

ในวิธีการสร้างตัวแบบรู้จำกิจกรรมกลุ่มกิจกรรมเคลื่อนไหวของวิธีการ S-PAR2 ได้รับการปรับปรุงโดยรายละเอียดดังต่อไปนี้

○ B4.1 ขั้นตอนการสกัดคุณลักษณะของกลุ่มกิจกรรมเคลื่อนไหว (Extracting energetic activities features)

ในขั้นตอนนี้จะพิจารณากระแสข้อมูลเชิงเวลาในแต่ละแกนจากตัวรับรู้ Accelerometer และ Gyroscope ตามตารางที่ 15 คุณลักษณะลำดับที่ถึง 1 ถึง 14 เป็นการคำนวณโดยใช้หลักการทางสถิติและคุณลักษณะลำดับที่ 15 ถึง 17 เป็นการคำนวณทางความถี่ (Frequency domain) ผ่านหลักการ Fast fourier transform ทำให้จำนวนคุณลักษณะทั้งหมดเท่ากับ 111 คุณลักษณะ

○ B4.2 ขั้นตอนการเลือกคุณลักษณะของกลุ่มกิจกรรมเคลื่อนไหว (Selecting feature by Recursive Feature Elimination)

จากขั้นตอนสกัดคุณลักษณะของกลุ่มกิจกรรมเคลื่อนไหวจะได้คุณลักษณะมีจำนวนมากว่างานวิจัยที่เปรียบเทียบและอาจเกิดปัญหา Underfitting หรือ Overfitting เช่นเดียวกัน จึงได้นำวิธีการเลือกคุณลักษณะ Recursive Feature Elimination (RFE) มาช่วยในการเลือกคุณลักษณะที่เหมาะสมกับข้อมูลกิจกรรมเคลื่อนไหวเพื่อให้ได้จำนวนลักษณะที่น้อยที่สุดแต่ได้ประสิทธิภาพในการระบุกิจกรรมได้ดีที่สุด ซึ่งขั้นตอนรู้จำกิจกรรมของวิธีการ REF จะต้องกำหนดพารามิเตอร์นี้ได้แก่วิธีการที่ใช้ในประเมินเลือกคุณลักษณะคือขั้นตอนการเรียนรู้ SVM โดยกำหนดฟังก์ชันเปลี่ยนแปลง

มิติของข้อมูล (Kernel) เท่ากับ Linear function, กำหนดพารามิเตอร์ C เป็น 0.01 และจำนวนคุณลักษณะเท่ากับ 30 คุณลักษณะ

○ B4.3 ขั้นตอนสร้างตัวแบบรู้จำกิจกรรมเคลื่อนไหว (Training model by Support Vector machine)

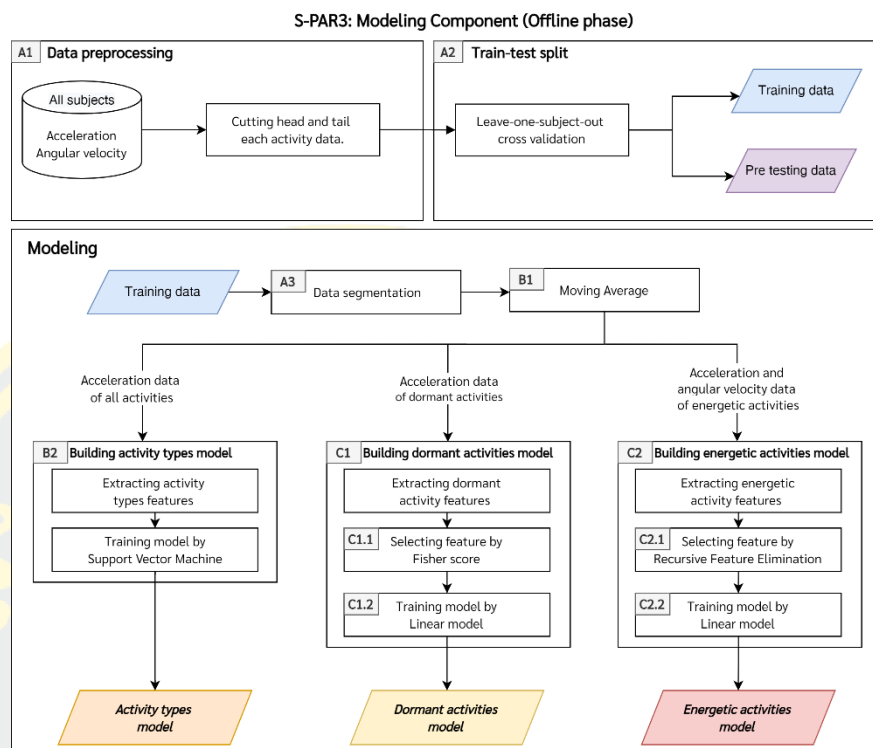
ขั้นตอนนี้เป็นการนำกลุ่มคุณลักษณะของกิจกรรมเคลื่อนไหวที่ถูกเลือกไปสร้างเป็นตัวแบบรู้จำด้วยวิธีการเรียนรู้ SVM โดยที่เปลี่ยนฟังก์ชันแปลงมิติของข้อมูล (Kernel) จาก Radial Basis function (RBF) เป็น Linear function เหมือนกันกับตัวแบบรู้จำจากวิธีการเลือกคุณลักษณะ และกำหนดค่า Regularization ค่าพารามิเตอร์ C เท่ากับ 0.01 จากเดิมมีค่าเท่ากับ 1 เพื่อให้วิธีการรู้จำยอมให้ขอบเขต (Margin) ของเส้น Support Vector ที่เรียกว่า Soft margin เพื่อให้มีข้อมูลที่เป็นคนละกลุ่มกิจกรรมสามารถเกิดขึ้นได้ทำให้วิธีการเรียนรู้ได้ข้อมูลที่เป็น Noise ในแต่ละกลุ่มกิจกรรมเนื่องจากข้อมูลมีการ Overlapping อยู่แล้วซึ่งทำให้ลดปัญหา Underfitting ของตัวแบบรู้จำกิจกรรมจากการทดลองด้วยพารามิเตอร์นี้ ทำให้การรู้จำกิจกรรมเคลื่อนไหวของวิธีการ SPAR-2 มีความแม่นยำเพิ่มขึ้นจาก S-PAR1 และเปรียบเทียบกับวิจัยที่เกี่ยวข้องมีประสิทธิภาพมากที่สุด

ข้อจำกัดของวิธีการรู้จำกิจกรรม S-PAR2

จากการพัฒนาตัวแบบรู้จำกิจกรรม S-PAR2 และนำไปทดลองกับทุกฐานข้อมูล ผลการทดลองแสดงให้เห็นว่าประสิทธิภาพในรู้จำกิจกรรมโดยรวมทุกกิจกรรมเพิ่มขึ้นโดยเฉพาะกลุ่มกิจกรรมเคลื่อนไหวที่มีการทับซ้อนข้อมูลกันสูงได้ถูกต้องเพิ่มมากขึ้น แต่ยังมีข้อจำกัดในการรู้จำกิจกรรมอยู่กับที่ตัวแบบรู้จำกิจกรรมรู้จำข้อมูลของอาสาสมัครบางคนที่มีความแตกต่างของค่าข้อมูลกันมากในกิจกรรมเดียวกันหรือมีความใกล้เคียงกับกิจกรรมอื่นในกลุ่มเดียวกัน โดยเฉพาะการทำกิจกรรมของอาสาสมัครในฐานข้อมูลกิจกรรม RealWorld ที่เก็บจากการทำกิจกรรมจากภายนอกห้องทดลองทำให้ประสิทธิภาพรู้จำกิจกรรมในกลุ่มนี้เพิ่มขึ้นจากวิธีการเดิมไม่มากนัก

3.2.3 ตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition 3 (S-PAR3)

เป็นการพัฒนาจากตัวแบบรู้จำกิจกรรม S-PAR2 ที่สามารถปรับปรุงตัวแบบการรู้จำกิจกรรมให้เข้ากับผู้ใช้แต่ละบุคคลให้มากที่สุด ซึ่งตำแหน่งตัวอักษร C ภายในภาพที่ 86 เป็นตำแหน่งที่ได้รับการปรับปรุงมีรายละเอียดดังต่อไปนี้



ภาพที่ 86 แผนภาพขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมของวิธีการ Smartwatch-based Physical Activity Recognition 3 (S-PAR3)

- **C1.1 และ C2.1 การปรับจำนวนคุณลักษณะของวิธีการเลือกคุณลักษณะ**

จากวิธีการ S-PAR2 ที่จำนวนคุณลักษณะของแต่ละกลุ่มกิจกรรมมีจำนวนเท่ากันในทุกฐานข้อมูล ดังนั้นในภาพที่ 85 ณ ตำแหน่ง C1.1 และ C2.1 จึงพยายามค้นหาจำนวนคุณลักษณะที่น้อยที่สุดที่ประสิทธิภาพในแต่ละฐานข้อมูลกิจกรรม โดยทำการทดลองกับวิธีการเลือกคุณลักษณะเดิมที่จะลดหนึ่งคุณลักษณะในทุกๆ รอบจากจำนวนครึ่งหนึ่งของจำนวนคุณลักษณะทั้งหมดและเลือกจำนวนคุณลักษณะที่มีประสิทธิภาพในระบูกิจกรรมมากที่สุด ซึ่งจำนวนคุณลักษณะของกลุ่มกิจกรรมในแต่ละฐานข้อมูลแสดงดังตารางที่ 16

ตารางที่ 16 ตารางวิธีการเลือกคุณลักษณะและจำนวนคุณลักษณะในแต่ละฐานข้อมูลของวิธีการ S-PAR3

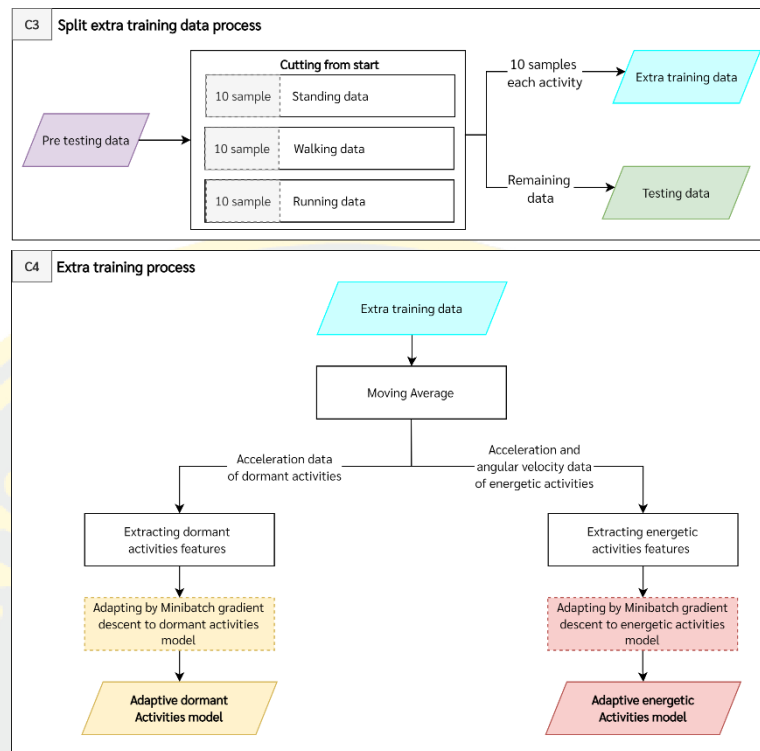
ฐานข้อมูล	วิธีการเลือกคุณลักษณะ	คุณลักษณะกิจกรรมอยู่กับที่	วิธีการเลือกคุณลักษณะ	คุณลักษณะกิจกรรมเคลื่อนไหว
RealWorld	Fisher Score	10	RFE	24
PURDUSS	Fisher Score	2	RFE	19
MHEALTH	Fisher Score	10	RFE	19
WISDM	Fisher Score	10	RFE	15

- C1.2 และ C2.3 การเปลี่ยนวิธีการรู้จำกิจกรรม

ในการสร้างตัวแบบรู้จำกิจกรรมทั้งสองกลุ่มกิจกรรมวิธีการเรียนรู้จะต้องสามารถเรียนรู้จากข้อมูลสำหรับสร้างตัวแบบรู้จำและปรับค่าพารามิเตอร์ตามจากข้อมูลบางส่วนของข้อมูลทดสอบได้ จึงได้เปลี่ยนจากวิธีการเรียนรู้เดิมที่เป็นวิธีการเรียนรู้ SVM เป็นวิธีการเรียนรู้สมการเชิงเส้น (Linear model) ที่สามารถประมาณค่าความผิดพลาดจากการระบุกิจกรรมโดยคำนวณจาก Loss function ซึ่งกำหนดเป็นฟังก์ชัน Hinge และใช้หลักการ Stochastic Gradient Descent ที่สามารถปรับค่าน้ำหนัก (Weight) และค่าไบแอส (Bias)

- C3 และ C4 ขั้นตอนการแบ่งข้อมูลบางส่วนและปรับตัวแบบรู้จำกิจกรรม (Split extra training data process and Extra training process)

เมื่อสร้างตัวแบบรู้จำกิจกรรมเรียบร้อยแล้วขั้นตอนถัดไปเป็นแบ่งข้อมูลของอาสาสมัครที่ใช้เป็นข้อมูลทดสอบ (Pre testing data) บางส่วนมาใช้ในการปรับตัวแบบรู้จำกิจกรรมนำแบบรู้จำกิจกรรมที่แสดงดังภาพที่ 87 ซึ่งในขั้นตอน ณ ตำแหน่งที่ C3 เป็นการแบ่งข้อมูลโดยพิจารณาการตัดข้อมูลไม่เกิน 20% ของข้อมูลทดสอบ ซึ่งขนาดข้อมูลที่เหมาะสมเท่ากับ 10 Windows ต่อหนึ่งกิจกรรม (Reiss และ Stricker, 2013) และข้อมูลที่เหลือจะนำไปใช้วัดประสิทธิภาพตัวแบบรู้จำกิจกรรม



ภาพที่ 87 แผนภาพการแบ่งชุดข้อมูลสำหรับเรียนรู้เพิ่มเติม (Extra training data) และการปรับตัวแบบรู้จำกิจกรรม

เมื่อหลังจากตัดแบ่งข้อมูลบางส่วนจากข้อมูลทดสอบเรียบร้อยแล้ว นำมาปรับเรียบข้อมูล และคำนวณกลุ่มคุณลักษณะที่เลือกในแต่ละกลุ่มกิจกรรมจากนั้นนำมาปรับปรุงค่าพารามิเตอร์ในตัวแบบรู้จำกิจกรรมใช้หลักการ Minibatch Gradient Descent ดังภาพที่ 88 ซึ่งกำหนดพารามิเตอร์จำนวนรอบ Epoch (e) และขนาดของกลุ่มข้อมูลที่จะใช้ในการปรับตัวแบบรู้จำในแต่ละรอบ Minibatch (b) โดยวิธีการจะวนซ้ำเพื่อปรับตัวแบบรู้จำกิจกรรมตามจำนวนพารามิเตอร์ e ในแต่ละรอบจะสลับแถวในชุดข้อมูล D_i (บรรทัดที่ 2) จากนั้นทำการสุ่มโดยไม่ซ้ำจากชุดข้อมูล D_i ตามจำนวนพารามิเตอร์ b (บรรทัดที่ 4) เพื่อไม่ให้ในแต่ละรอบในการปรับตัวแบบรู้จำกิจกรรมมากเกินไป จะได้ชุดข้อมูล $\langle x_i, y_i \rangle$ ที่มีคุณลักษณะและกิจกรรม ที่ทำการสุ่มเรียบร้อยแล้วผ่านวิธีการในการปรับตัวแบบต่อไป (บรรทัดที่ 6) ซึ่งพารามิเตอร์จำนวนรอบ (Epoch) และขนาดข้อมูลที่ใช้ในการปรับ (Minibatch) ของแต่ละกลุ่มกิจกรรมและฐานข้อมูลไม่เท่ากันดังตารางที่ 17 โดยทำการทดลองโดยกำหนดขนาดของ Epoch เท่ากับ 10 ถึง 700 รอบ และจำนวน Minibatch เท่ากับ 8 และ 16 ข้อมูล จับคู่ทั้งสองค่าที่ให้ประสิทธิภาพในการรู้จำกิจกรรมที่แม่นยำถูกต้องมากที่สุดในแต่ละกลุ่มกิจกรรมและฐานข้อมูล

Algorithm 2: S-PAR3 : Minibatch stochastic process to update activity model in extra training phases

```

/* M = The learning model (dormant or energetic activities) */
/* D = The feature set of activity types (dormant or energetic activities) */
/* b = The number data in Minibatch */
/* e = The number of epoch */
Input : M, D
Output: AM
1 for i = 1, 2, ... , e do
2   randomly shuffle  $D_i$  in the extra training set D
3   for j = 1, 2 ... , b do
4     draw random sample without replacement  $(x_i^{[j]}, y_i^{[j]}) \in D_i$ 
5   end
6   Update M from previous epoch by  $(x_i, y_i)$  to calculate loss function and update weight and bias of the linear model (AM) (partial_fit( $x_i, y_i$ ) Scikit-learn SGD method).
7 end

```

ภาพที่ 88 หลักการ Minibatch Gradient Descent ในขั้นตอน Extra training ของ S-PAR3

ตารางที่ 17 ตารางจำนวนรอบ Epoch และขนาดของ Minibatch ในแต่ละฐานข้อมูลกิจกรรม

ฐานข้อมูล	กิจกรรมอยู่กับที่	กิจกรรมเคลื่อนไหว
RealWorld	300 epoch / 16 minibatch	300 epoch / 16 minibatch
PARDUSS	50 epoch / 8 minibatch	350epoch / 16 minibatch
MHEALTH	100 epoch / 16 minibatch	250 epoch / 16 minibatch
WISDM	450 epoch / 16 minibatch	350 epoch / 16 minibatch

บทที่ 4

ผลการดำเนินงาน

ในบทนี้จะกล่าวถึงผลการดำเนินงานโดยการวัดประสิทธิภาพความถูกต้องในการระบุกิจกรรมจากขั้นตอนการสร้างตัวแบบรู้จำกิจกรรมและขั้นตอนการรู้จำกิจกรรมของวิธีการที่นำเสนอ **Smartwatch-based Physical Activity Recognition (SPAR)** กับงานวิจัยที่มีการนำเสนอวิธีการพัฒนาตัวแบบรู้จำกิจกรรมด้วยมาตรวัดประสิทธิภาพทั้งหมด 3 ตัวมาตรวัดได้แก่ Recall, Precision และ F-measure โดยมีรายละเอียดของผลดำเนินงานแสดงดังต่อไปนี้

- 4.1) ข้อมูลกิจกรรมที่ใช้ในการทดลอง
- 4.2) การวัดประสิทธิภาพความถูกต้องและความแม่นยำการรู้จำกิจกรรม
- 4.3) ผลการทดลองการวัดประสิทธิภาพตัวแบบรู้จำกิจกรรม

4.1 ข้อมูลกิจกรรมที่ใช้ในการทดลอง

วิทยานิพนธ์นี้ได้นำฐานข้อมูลกิจกรรมที่มีการเก็บข้อมูลการทำกิจกรรมทางกายภาพจากอุปกรณ์ที่มีตัวรับรู้ Accelerometer และ Gyroscope ที่สวมใส่ข้อมือจำนวน 4 ฐานข้อมูลที่สามารถเข้าถึงได้อย่างสาธารณะ โดยมีจำนวนแถวข้อมูลในแต่ละฐานข้อมูลกิจกรรมแสดงดังตารางที่ 18

ตารางที่ 18 จำนวนแถวข้อมูลกิจกรรมในแต่ละฐานข้อมูลกิจกรรม

ฐานข้อมูล	RealWorld	PARDUSS	MHEALTH	WISDM
Standing	155,788	90,000	30,720	180,718
Sitting	138,063	90,000	30,720	177,213
Lying	142,316	-	30,720	-
Walking	138,409	90,000	30,720	174,682
Stairs up	114,703	90,000	30,720	175,096
Stairs down	116,806	90,000		
Running	153,089	90,000	30,720	173,578
Jogging	-	-	30,720	-
Cycling	-	90,000	30,720	-

4.2 วิธีการที่ใช้วัดประสิทธิภาพความถูกต้องตัวแบบรู้จำกิจกรรม

การขั้นตอนการวัดประสิทธิภาพความถูกต้องได้เลือกมาตรวัดประสิทธิภาพของตัวแบบรู้จำคือ Recall, Precision และ F-measure โดยมีวิธีการคำนวณดังต่อไปนี้

Recall เป็นการวัดความถูกต้องในการรู้จำกิจกรรม โดยวัดจากจำนวนของกิจกรรมที่กำลังพิจารณาและทำนายถูกต้องต่ออัตราส่วนจำนวนกิจกรรมที่พิจารณาทั้งหมด สามารถคำนวณตามสมการที่ 4.1

$$Recall = \frac{TP}{TP + FN} \quad (4.1)$$

Precision เป็นการวัดความแม่นยำในการระบุกิจกรรม โดยวัดจากจำนวนของกิจกรรมที่ระบุกิจกรรมที่พิจารณาได้ถูกต้องต่ออัตราส่วนจำนวนการระบุกิจกรรมที่พิจารณาจากตัวแบบรู้จำกิจกรรมทั้งหมด ค่าเท่ากับ 1 แสดงว่าตัวแบบรู้จำกิจกรรมระบุกิจกรรมอื่นที่ไม่เป็นกิจกรรมที่พิจารณา สามารถคำนวณตามสมการที่ 4.2

$$Precision = \frac{TP}{TP + FP} \quad (4.2)$$

F-measure เป็นการวัดประสิทธิผลและความถูกต้องของตัวแบบรู้จำกิจกรรม โดยใช้หาค่าเฉลี่ยของประสิทธิภาพของตัวแบบรู้จำกิจกรรมจาก Precision และ Recall สามารถคำนวณตามสมการที่ 4.3

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

โดยที่	TP	คือจำนวนครั้งที่ตัวแบบรู้จำกิจกรรมที่ระบุกิจกรรมจากข้อมูลทดสอบตรงกับกิจกรรมที่เป็นคำตอบจริง (True Positive)
	FN	คือจำนวนครั้งที่ตัวแบบรู้จำกิจกรรมที่ระบุกิจกรรมจากข้อมูลทดสอบไม่ตรงกับกิจกรรมที่เป็นคำตอบจริง (False Negative)
	FP	คือจำนวนครั้งที่ตัวแบบรู้จำกิจกรรมที่ระบุกิจกรรมอื่นจากข้อมูลทดสอบอื่นไม่ตรงกับกิจกรรมที่เป็นคำตอบจริง (False Positive)

4.3 การวัดประสิทธิภาพความถูกต้องและความแม่นยำการรู้จำกิจกรรม

ในงานวิทยานิพนธ์นี้มีการเปรียบเทียบผลการทดลองที่วัดจากวิธีการที่นำเสนอทั้ง 3 วิธีกับงานวิจัยอื่นที่นำเสนอการตรวจจับรู้จำกิจกรรมโดยมีรายละเอียดดังต่อไปนี้

4.3.1 การวัดประสิทธิภาพของวิธีการรู้จำกิจกรรม S-PAR1

การเปรียบเทียบประสิทธิภาพในการรู้จำกิจกรรม S-PAR1 กับงานวิจัยที่นำเสนอการตรวจจับรู้จำกิจกรรมกิจกรรมทางกายภาพจากกระแสข้อมูลเชิงเวลาอุปกรณ์สวมใส่ข้อมือได้แก่งานวิจัย “Accelerometer based intelligent system for human movement recognition” (Da Silva และ Galeazzo, 2013) และงานวิจัย “Towards detection of bad habits by fusing smartphone and smartwatch” (Shoaib และคณะ, 2015) กับ 4 ฐานข้อมูลกิจกรรม ซึ่งในฐานข้อมูลกิจกรรม PARDUSS และ MHEALTH จะไม่ได้พิจารณาการปั่นจักรยานร่วมด้วย

- ผลการทดลองของวิธีการรู้จำกิจกรรม S-PAR1 กับฐานข้อมูลกิจกรรม RealWorld

การรู้จำกิจกรรมด้วยวิธีการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูลกิจกรรม RealWorld แสดงในรูปแบบของ Confusion Matrix ดังตารางที่ 19 และงานวิจัยที่เปรียบเทียบดังตารางที่ 20 ถึง 23 ที่สามารถคำนวณด้วยการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Recall, Precision และ F-measure แสดงดังภาพที่ 89 ถึง 91 จะเห็นได้ว่าวิธีการรู้จำกิจกรรม S-PAR1 สามารถรู้จำกิจกรรมอยู่กับที่ได้ถูกต้องและแม่นยำกว่างานวิจัยที่เปรียบเทียบ โดยเฉพาะการนั่งและการนอน ในส่วนการรู้จำกิจกรรมเคลื่อนไหวมีประสิทธิภาพโดยเฉลี่ยแล้วใกล้เคียงกัน เมื่อหักลบกันแล้วทำให้ F-measure โดยเฉลี่ยทุกกิจกรรมในฐานข้อมูลกิจกรรม RealWorld นั้นสูงกว่าเล็กน้อย

ตารางที่ 19 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูล RealWorld

		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1173	151	53	7	41	13	43
	Sitting	71	998	199	4	56	8	35
	Lying	75	266	1067	2	3	2	5
	Walking	0	0	0	983	270	91	2
	Stairs up	3	39	13	358	596	142	8
	Stairs down	0	0	0	86	164	881	2
	Running	138	24	12	3	22	7	1290

ตารางที่ 20 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1195	170	34	7	51	19	5
	Sitting	69	1011	243	6	38	3	1
	Lying	82	419	915	1	2	1	0
	Walking	12	31	3	889	311	97	2
	Stairs up	26	60	6	270	631	165	1
	Stairs down	4	5	0	96	213	814	0
	Running	151	43	7	7	19	6	1263

ตารางที่ 21 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 (2013) จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1134	168	33	15	67	11	53
	Sitting	34	974	224	12	67	4	56
	Lying	93	368	928	4	13	2	12
	Walking	41	0	0	898	246	114	46
	Stairs up	4	36	1	274	610	195	39
	Stairs down	0	0	0	121	252	754	5
	Running	136	24	7	5	51	4	1269

ตารางที่ 22 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1236	132	64	7	22	12	8
	Sitting	141	823	357	1	33	5	11
	Lying	58	421	618	0	144	1	178
	Walking	19	31	0	920	278	89	9
	Stairs up	23	52	11	410	517	143	3
	Stairs down	4	3	0	105	152	869	0
	Running	157	19	17	7	8	5	1283



ภาพที่ 89 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล RealWorld



ภาพที่ 90 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล RealWorld



ภาพที่ 91 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับวิธีการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล RealWorld

- ผลการทดลองของวิธีการรู้จำกิจกรรม S-PAR1 กับฐานข้อมูลกิจกรรม PARDUSS

การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 ด้วยฐานข้อมูลกิจกรรม PARDUSS แสดงผลลัพธ์ดังตารางที่ 23 และงานวิจัยที่เปรียบเทียบดังตารางที่ 24 ถึง 26 สามารถคำนวณด้วยการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Recall, Precision และ F-measure แสดงดังภาพที่ 92 ถึง 94 จะเห็นได้ว่าผลการทดลองวัดประสิทธิภาพ F-measure ทั้งสี่วิธีการสามารถรู้จำกิจกรรมอยู่กับที่ใกล้เคียงกันและในการรู้จำกิจกรรมเคลื่อนไหวโดยเฉพาะอย่างยิ่ง การเดิน, การเดินขึ้นบันไดและการเดินลงบันไดที่มีความใกล้เคียงของข้อมูลกันมากจึงทำให้การระบุกิจกรรมผิดพลาดได้ง่าย ซึ่งผลการทดลองแสดงให้เห็นว่าค่า Recall และ Precision ของทั้งสี่วิธีที่ระบุผิดพลาดสลับกัน แต่โดยรวมแล้ววิธีการ S-PAR1 ระบุได้แม่นยำถูกต้องมากกว่าส่งผลให้ F-measure โดยเฉลี่ยของทุกกิจกรรมของวิธีการที่นำเสนอเทียบกันซึ่งวิธีการ S-PAR1 มีประสิทธิภาพมากกว่า

ตารางที่ 23 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูล PARDUSS

		Prediction activities					
		Standing	Sitting	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	886	3	1	2	6	2
	Sitting	0	890	0	3	7	0
	Walking	1	0	704	181	14	0
	Stairs up	1	0	103	744	52	0
	Stairs down	3	0	44	42	803	8
	Running	0	0	2	0	2	896

ตารางที่ 24 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล PARDUSS


		Prediction activities					
		Standing	Sitting	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	880	1	05	5	7	7
	Sitting	0	896	0	0	0	4
	Walking	3	0	540	253	104	0
	Stairs up	2	0	141	670	86	1
	Stairs down	4	0	38	86	769	3
	Running	2	0	0	0	4	894

ตารางที่ 25 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล PARDUSS


		Prediction activities					
		Standing	Sitting	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	879	0	0	7	11	3
	Sitting	0	877	0	1	18	4
	Walking	0	0	568	266	66	0
	Stairs up	0	0	91	733	75	1
	Stairs down	0	0	29	100	769	2
	Running	0	0	0	0	2	898

ตารางที่ 26 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) กับฐานข้อมูล PARDUSS


		Prediction activities					
		Standing	Sitting	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	889	0	2	0	6	3
	Sitting	1	898	0	0	0	1
	Walking	0	0	541	340	19	0
	Stairs up	1	0	214	614	41	3
	Stairs down	4	0	45	24	826	1
	Running	0	0	0	1	0	899



ภาพที่ 92 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล PARDUSS



ภาพที่ 93 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล PARDUSS



ภาพที่ 94 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoaib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล PARDUSS

- ผลการทดลองของวิธีการรู้จำกิจกรรม S-PAR1 กับฐานข้อมูลกิจกรรม MHEALTH

การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 ด้วยฐานข้อมูลกิจกรรม MHEALTH แสดงผลลัพธ์ดังแสดงผลลัพธ์ดังตารางที่ 27 และงานวิจัยที่เปรียบเทียบดังตารางที่ 28 ถึง 30 สามารถคำนวณด้วยการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยมาตรวัด Recall,

Precision และ F-measure แสดงดังภาพที่ 95 ถึง 97 จะเห็นได้ว่าในกลุ่มกิจกรรมอยู่กับการ วิถีการรู้จำกิจกรรม S-PAR1 ระบุการนั่งและการนอนได้ผิดพลาดส่งผลให้ค่า Precision ของทั้งสาม กิจกรรมอยู่กับการที่ต่ำกว่าวิธีการที่เปรียบเทียบและวิธีการ S-PAR1 สามารถรู้จำกิจกรรมการวิ่งและวิ่ง จ็อกกิ้งได้ดีแต่การรู้จำกิจกรรมการเดินและการเดินขึ้นลงบันไดมีประสิทธิภาพน้อยกว่างานวิจัยที่ เปรียบเทียบ

ตารางที่ 27 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูลกิจกรรม MHEALTH

		Prediction activities						
		Standing	Sitting	Lying	Walking	Running	Stairs	Jogging
Actual activities	Standing	300	0	0	0	0	0	0
	Sitting	60	240	0	0	0	0	0
	Lying	0	120	180	0	0	0	0
	Walking	0	0	0	215	0	85	0
	Running	0	0	0	0	271	0	29
	Stairs	0	0	0	31	0	269	0
	Jogging	0	0	0	0	62	0	238

ตารางที่ 28 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล MHEALTH


		Prediction activities						
		Standing	Sitting	Lying	Walking	Running	Stairs	Jogging
Actual activities	Standing	290	7	0	0	0	3	0
	Sitting	43	238	18	0	0	1	0
	Lying	0	17	253	0	30	0	0
	Walking	0	0	0	230	0	70	0
	Running	0	0	0	0	246	1	53
	Stairs	1	0	0	34	2	263	0
	Jogging	0	0	0	0	73	0	227

ตารางที่ 29 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 จากงานวิจัย Da Silva และ Galeazzo (2013) กับฐานข้อมูล MHEALTH


		Prediction activities						
		Standing	Sitting	Lying	Walking	Running	Stairs	Jogging
Actual activities	Standing	278	19	0	0	0	3	0
	Sitting	73	226	1	0	0	0	0
	Lying	0	31	269	0	0	0	0
	Walking	0	0	0	258	0	42	0
	Running	0	0	0	0	248	0	52
	Stairs	0	0	0	28	0	272	0
	Jogging	0	0	0	0	72	0	228

ตารางที่ 30 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) กับฐานข้อมูล MHEALTH


		Prediction activities						
		Standing	Sitting	Lying	Walking	Running	Stairs	Jogging
Actual activities	Standing	299	1	0	0	0	0	0
	Sitting	30	210	30	0	0	30	0
	Lying	0	30	240	0	30	0	0
	Walking	0	0	0	178	0	122	0
	Running	0	0	0	0	248	0	52
	Stairs	0	0	0	63	4	233	0
	Jogging	0	0	0	0	69	0	231



ภาพที่ 95 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoib และคณะ (2014) กับการรู้จักกิจกรรม S-PAR1 ด้วยฐานข้อมูล MHEALTH



ภาพที่ 96 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoib และคณะ (2014) กับการรู้จักกิจกรรม S-PAR1 ด้วยฐานข้อมูล MHEALTH



ภาพที่ 97 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoab และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล MHEALTH

- ผลการทดลองของวิธีการรู้จำกิจกรรม S-PAR1 กับฐานข้อมูลกิจกรรม WISDM

การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 ด้วยฐานข้อมูลกิจกรรม WISDM แสดงผลลัพธ์ตั้งตารางที่ 31 และงานวิจัยที่เปรียบเทียบตั้งตารางที่ 32 ถึง 34 สามารถคำนวณด้วยการวัดประสิทธิภาพ ความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Recall, Precision และ F-measure แสดงดังภาพที่ 97 ถึง 98 จะเห็นได้ว่าผลการทดลองวัดประสิทธิภาพ F-measure ทั้งสี่วิธีการมี ประสิทธิภาพใกล้เคียงกัน

ตารางที่ 31 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการ S-PAR1 กับฐานข้อมูลกิจกรรม WISDM

		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3080	919	24	3	122
	Sitting	514	3328	38	7	172
	Walking	6	2	2988	12	991
	Running	2	0	17	3895	56
	Stairs	48	6	821	64	3070

ตารางที่ 32 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 1 จากงานวิจัย Da Silva และ Galeazzo (2013) ที่ฐานข้อมูล WISDM


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3285	681	65	5	112
	Sitting	848	3009	67	14	121
	Walking	48	31	2754	41	1125
	Running	0	5	11	3864	90
	Stairs	65	63	607	107	3167

ตารางที่ 33 Confusion Matrix การรู้จำกิจกรรมของวิธีการ Architecture 2 จากงานวิจัย Da Silva และ Galeazzo (2013) ที่ฐานข้อมูล WISDM


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3110	849	60	4	125
	Sitting	674	3133	85	15	152
	Walking	45	12	2834	27	1081
	Running	2	0	18	3870	80
	Stairs	74	15	732	72	3116

ตารางที่ 34 Confusion Matrix การรู้จำกิจกรรมด้วยจากงานวิจัย Shoaib และคณะ (2015) ที่ฐานข้อมูล WISDM


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3235	708	13	51	141
	Sitting	524	3370	28	16	121
	Walking	7	26	2918	22	1026
	Running	0	3	16	3902	49
	Stairs	38	52	830	59	3030



ภาพที่ 98 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล WISDM



ภาพที่ 99 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล WISDM



ภาพที่ 100 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Da Silva และ Galeazzo (2013) และ Shoib และคณะ (2014) กับการรู้จำกิจกรรม S-PAR1 ด้วยฐานข้อมูล WISDM

4.3.2 การวัดประสิทธิภาพของวิธีการรู้จำกิจกรรม S-PAR2

การเปรียบเทียบประสิทธิภาพในการรู้จำกิจกรรม S-PAR2 กับงานวิจัยที่นำเสนอการตรวจจับรู้จำกิจกรรมทางกายภาพจากกระแสข้อมูลเชิงเวลาอุปกรณ์สวมใส่ข้อมือคืองานวิจัย “Ensemble methods for classification of physical activities from wrist accelerometry” (Chowdhury และคณะ, 2017) โดยเลือกวิธีการที่ขั้นตอนวิธีการที่มีประสิทธิภาพในการรู้จำกิจกรรมในแต่ละประเภทการเรียนรู้มากที่สุดได้แก่วิธีการเรียนรู้ Support Vector Machine (SVM), Random Forest (RF) และ Weighted Majority Vote (WMV) เปรียบเทียบในฐานข้อมูลกิจกรรมทั้งหมด 4 ฐานข้อมูลโดยมีรายละเอียดดังต่อไปนี้

- ผลการทดลองวิธีการ S-PAR2 กับข้อมูลกิจกรรม RealWorld

การรู้จำกิจกรรมด้วยวิธีการ S-PAR2 กับฐานข้อมูลกิจกรรม RealWorld แสดงผลลัพธ์ดังตารางที่ 35 และงานวิจัยที่เปรียบเทียบดังตารางที่ 36 ถึง 38 สามารถคำนวณด้วยการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Recall, Precision และ F-measure แสดงดังภาพที่ 101 ถึง 103 จะเห็นได้ว่าวิธีการรู้จำกิจกรรม S-PAR2 สามารถรู้จำการเดินและการเดินขึ้นบันไดได้ดีกว่าวิธีการที่เปรียบเทียบมากโดยเฉพาะกิจกรรมเดินที่มีค่า Recall และ Precision มากกว่าชัดเจน

ตารางที่ 35 Confusion Matrix การรู้จำกิจกรรมของวิธีการ S-PAR2 กับฐานข้อมูล RealWorld

		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1299	72	67	4	11	5	3
	Sitting	168	960	205	8	8	0	2
	Lying	28	240	1131	0	0	1	0
	Walking	0	0	0	1025	224	55	22
	Stairs up	22	36	15	289	627	132	18
	Stairs down	0	0	0	88	148	873	4
	Running	149	6	31	13	81	13	1183

ตารางที่ 36 Confusion Matrix การรู้จำกิจกรรมของวิธีการ SVM จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1204	156	30	6	52	6	7
	Sitting	135	911	267	10	26	0	2
	Lying	68	276	1053	0	2	1	0
	Walking	11	19	1	839	343	110	3
	Stairs up	30	51	10	389	526	131	2
	Stairs down	6	1	1	96	147	861	1
	Running	143	45	28	26	15	6	1213

ตารางที่ 37 Confusion Matrix การรู้จำกิจกรรมของวิธีการ RF จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1139	99	58	13	44	13	95
	Sitting	106	931	248	5	53	3	5
	Lying	15	350	889	1	6	1	138
	Walking	10	22	1	819	361	103	10
	Stairs up	38	49	10	339	575	125	3
	Stairs down	4	6	0	81	166	855	1
	Running	156	25	5	3	13	6	1268

ตารางที่ 38 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1200	133	52	16	44	9	7
	Sitting	63	1013	230	7	33	2	3
	Lying	27	333	1037	0	2	1	0
	Walking	13	13	2	819	351	119	9
	Stairs up	26	46	12	382	551	118	4
	Stairs down	2	3	0	117	131	860	0
	Running	147	26	7	14	9	7	1266



ภาพที่ 101 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล RealWorld



ภาพที่ 102 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล RealWorld



ภาพที่ 103 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล RealWorld

- ผลการทดลองวิธีการ S-PAR2 กับข้อมูลกิจกรรม PARDUSS

การรู้จำกิจกรรมด้วยวิธีการ S-PAR2 กับฐานข้อมูลกิจกรรม PARDUSS แสดงผลลัพธ์ดังตารางที่ 39 และงานวิจัยที่เปรียบเทียบดังตารางที่ 40 ถึง 42 สามารถคำนวณด้วยการวัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Recall, Precision และ F-measure แสดงดังภาพที่ 104 ถึง 106 จะเห็นได้ว่าวิธีการ S-PAR2 สามารถรู้จำกิจกรรมการเดิน, การเดินขึ้นบันได และการเดินลงบันไดได้ดีกว่า สืบเนื่องจากการค่า Recall และ Precision ของทั้งสามกิจกรรมเทียบกับวิธีการอื่นที่เปรียบเทียบ

ตารางที่ 39 Confusion Matrix การรู้จำกิจกรรมของวิธีการ S-PAR2 กับฐานข้อมูล PARDUSS

		Prediction activities						
		Standing	Sitting	Walking	Stairs up	Stairs down	Running	Cycling
Actual activities	Standing	866	3	20	0	5	0	6
	Sitting	0	875	0	0	0	0	25
	Walking	0	0	713	168	19	0	0
	Stairs up	4	0	115	768	13	0	0
	Stairs down	2	0	23	10	860	1	4
	Running	0	0	0	1	1	897	1
	Cycling	0	20	0	0	1	2	877

ตารางที่ 40 Confusion Matrix การรู้จำกิจกรรมของวิธีการ SVM จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล PARDUSS


		Prediction activities						
		Standing	Sitting	Walking	Stairs up	Stairs down	Running	Cycling
Actual activities	Standing	882	3	0	9	6	0	0
	Sitting	7	877	0	0	1	0	15
	Walking	0	0	590	251	59	0	0
	Stairs up	1	0	108	710	81	0	0
	Stairs down	1	0	22	96	778	2	1
	Running	3	0	68	2	3	822	2
	Cycling	0	10	0	0	2	9	879

ตารางที่ 41 Confusion Matrix การรู้จำกิจกรรมของวิธีการ RF จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล PARDUSS


		Prediction activities						
		Standing	Sitting	Walking	Stairs up	Stairs down	Running	Cycling
Actual activities	Standing	884	3	5	3	2	0	3
	Sitting	0	885	0	0	0	0	15
	Walking	0	0	407	438	55	0	0
	Stairs up	1	0	70	734	95	0	0
	Stairs down	2	0	13	150	733	0	2
	Running	0	0	2	0	1	895	2
	Cycling	0	36	0	1	3	0	860

ตารางที่ 42 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล PARDUSS


		Prediction activities						
		Standing	Sitting	Walking	Stairs up	Stairs down	Running	Cycling
Actual activities	Standing	888	3	0	6	3	0	0
	Sitting	1	884	0	0	1	0	14
	Walking	0	0	580	281	39	0	0
	Stairs up	1	0	103	710	85	1	0
	Stairs down	2	0	34	97	763	1	3
	Running	0	0	0	1	2	895	2
	Cycling	0	8	0	0	1	2	889



ภาพที่ 104 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล PARDUSS




ภาพที่ 105 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล PARDUSS




ภาพที่ 106 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล PARDUSS

ตารางที่ 46 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล MHEALTH


		Prediction activities							
		Standing	Sitting	Lying	Walking	Running	Stairs	Jogging	Cycling
Actual activities	Standing	300	0	0	0	0	0	0	0
	Sitting	31	264	4	1	0	0	0	0
	Lying	0	59	241	0	0	0	0	0
	Walking	0	0	0	221	0	79	0	0
	Running	0	0	0	0	237	0	63	0
	Stairs	0	1	0	40	0	258	0	1
	Jogging	0	0	0	0	60	0	240	0
	Cycling	0	0	0	0	0	0	0	300



ภาพที่ 107 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล MHEALTH



ภาพที่ 108 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล MHEALTH



ภาพที่ 109 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล MHEALTH

- ผลการทดลองวิธีการ S-PAR2 กับข้อมูลกิจกรรม WISDM

การรู้จำกิจกรรมด้วยวิธีการ S-PAR2 กับฐานข้อมูลกิจกรรม WISDM แสดงผลลัพธ์ดังตารางที่ 47 และงานวิจัยที่เปรียบเทียบดังตารางที่ 48 ถึง 50 สามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Recall, Precision และ F-measure แสดงดังภาพที่ 109 ถึงภาพที่ 111 ในการระบุกิจกรรมอยู่กับที่ของทั้งสี่วิธีการมีประสิทธิภาพใกล้เคียงกันมาก ส่วนในการรู้จำกิจกรรมเคลื่อนไหว S-PAR2 สามารถรู้จำการเดินและการเดินขึ้นลงบันไดได้ดีกว่า

ตารางที่ 47 Confusion Matrix การรู้จำกิจกรรมของวิธีการ S-PAR2 กับฐานข้อมูล WISDM

		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3473	498	20	3	64
	Sitting	773	3068	19	12	97
	Walking	74	0	3101	41	693
	Running	6	0	20	3801	53
	Stairs	77	11	664	89	3078

ตารางที่ 48 Confusion Matrix การรู้จำกิจกรรมของวิธีการ SVM จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล WISDM


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3122	782	61	0	93
	Sitting	676	3145	48	13	87
	Walking	28	78	2768	18	1017
	Running	1	7	29	3804	39
	Stairs	59	58	883	59	2860

ตารางที่ 49 Confusion Matrix การรู้จำกิจกรรมของวิธีการ RF จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล MHEALTH


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3380	532	24	1	121
	Sitting	609	3217	29	10	104
	Walking	15	27	2619	14	1234
	Running	0	2	12	3790	76
	Stairs	39	58	662	64	3096

ตารางที่ 50 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล MHEALTH


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3298	621	35	1	103
	Sitting	462	3368	34	13	92
	Walking	20	69	2882	25	913
	Running	1	4	10	3825	40
	Stairs	67	82	753	73	2944



ภาพที่ 110 แผนภาพแท่งเปรียบเทียบ Recall ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล WISDM



ภาพที่ 111 แผนภาพแท่งเปรียบเทียบ Precision ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล WISDM




ภาพที่ 112 แผนภาพแท่งเปรียบเทียบ F-measure ระหว่างงานวิจัย Chowdhury และคณะ (2017) กับการรู้จำกิจกรรม S-PAR2 ด้วยฐานข้อมูล WISDM


- ผลการทดลองเปรียบเทียบประสิทธิภาพกับวิธีการ S-PAR2 โดยกำหนดขนาด Window ที่แตกต่างกัน

ในการรู้จำกิจกรรมจำนวนข้อมูลในแต่ละ Windows มีผลต่อขั้นตอนการสกัดคุณลักษณะในการขั้นตอนการสร้างตัวรู้จำกิจกรรม ดังนั้นได้ทำการทดลองประสิทธิภาพกับวิธีการ S-PAR2 โดยกำหนดจำนวนข้อมูลในแต่ละ Window Windows 2 วินาทีเป็นขนาดของ Windows ที่ใช้ในการทดลองและ 10 วินาที (Chowdhury และคณะ, 2017) และการลักษณะการข้อมูลในแต่ละ Windows แบบทับ


ซ้อน (Overlapping) และไม่ทับซ้อน (Non-overlapping) ซึ่งความแตกต่างของทั้งสองแบบ คือ รูปแบบไม่ทับซ้อนจะข้อมูลการทำกิจกรรมใน Windows เป็นกระแสข้อมูลเชิงเวลาที่เข้าใหม่ทั้งหมด โดยแบบทับซ้อนจะมีข้อมูลครึ่งหนึ่ง (50 เปอร์เซ็นต์) ของ Windows ก่อนหน้านี้และกระแสข้อมูลใหม่ครึ่งหนึ่งรวมกัน ดังนั้นกระแสข้อมูลเชิงเวลาที่เข้ามาใหม่ในแต่ละ Windows แบบไม่ทับซ้อนจะเท่ากับ 2 และ 10 วินาทีและแบบทับซ้อนจะเท่ากับ 1 และ 5 วินาที โดยผลลัพธ์การทดลอง ประสิทธิภาพค่าเฉลี่ย F-measure ของทุกกิจกรรมกับ 4 ฐานข้อมูลกิจกรรมแสดงดังภาพที่ 113 ถึง 116 จะเห็นว่าวิธีการ S-PAR2 มีประสิทธิภาพในการรู้จำกิจกรรมได้ดีกว่ากับงานวิจัยที่เปรียบเทียบกับทุกขนาด Windows กับทุกฐานข้อมูลมีค่า F-measure ต่างกันเพียงเล็กน้อยเท่านั้น




ภาพที่ 113 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล RealWorld ในแต่ละขนาดของ Window



ภาพที่ 114 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล PARDUSS ในแต่ละขนาดของ Window



ภาพที่ 115 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล MHEALTH ในแต่ละขนาดของ Window




ภาพที่ 116 แผนภูมิแท่งเปรียบเทียบค่าเฉลี่ย F-measure ของฐานข้อมูล WISDM ในแต่ละขนาดของ Window


- ผลการทดลองเปรียบเทียบประสิทธิภาพวิธีการเลือกคุณลักษณะในขั้นตอนการสร้างตัวรู้จำกิจกรรม S-PAR2

กลุ่มของคุณลักษณะเป็นองค์ประกอบสำคัญที่นำมาใช้ในการการสร้างตัวรู้จำกิจกรรม S-PAR2 ซึ่งในขั้นตอนสกัดคุณลักษณะทำให้มีจำนวนคุณลักษณะค่อนข้างมาก ดังนั้นค้นหาคุณลักษณะที่สำคัญและลดการคำนวณคุณลักษณะในขณะรู้จำกิจกรรมที่อาจช่วยเพิ่มประสิทธิภาพในรู้จำกิจกรรม จึงได้ทดลองวัดประสิทธิภาพวิธีการเลือกคุณลักษณะจำนวน 5 วิธีการได้แก่ Fisher Score, Relief-F, SFFS, RFE, PCA และ ซึ่งแบ่งการทดลองและวัดประสิทธิภาพ F-measure ตามกลุ่มกิจกรรมอยู่กับที่และกลุ่มกิจกรรมเคลื่อนไหวกับทุกฐานข้อมูลดังภาพที่ 117 ถึงภาพที่ 120 ผลการทดลองจะเห็นว่าได้ว่าวิธีการเลือกคุณลักษณะ Recursive Feature Eliminate (RFE) สามารถในการรู้จำกลุ่มกิจกรรมเคลื่อนไหวได้ดีที่สุด เนื่องจากการเลือกคุณลักษณะใช้ตัวรู้จำที่คำนวณและเลือกคุณลักษณะที่มีค่าน้ำหนักที่มีผลต่อการระบุกลุ่มข้อมูลมากที่สุดและเมื่อนำมาสร้างตัวรู้จำกิจกรรมที่มีวิธีการเรียนรู้เดียวกันที่มีคุณลักษณะที่มีความสำคัญและจำนวนเหมาะสม จึงทำให้วิธีการรู้จำได้พัฒนาให้ได้ถึงจุดค่าเหมาะสมที่สุด (optimize) ลดการ Overfitting ที่ทำให้การระบุกิจกรรมมีประสิทธิภาพดีขึ้น และวิธีการเลือกคุณลักษณะ Fisher Score โดยค้นหาคุณลักษณะที่มีอัตราส่วนระหว่างระยะห่างระหว่างกลุ่มข้อมูลกิจกรรมและการกระจายของกลุ่มกิจกรรมเดียวกันน้อย ซึ่งการเลือกที่มีค่าอัตราส่วนของทั้งสองค่าที่มีค่ามากที่สุดตามลำดับจะได้คุณลักษณะที่มีจุดของค่าที่สามารถ


แบ่งกลุ่มข้อมูลกิจกรรมได้ดี ซึ่งในรู้จักกลุ่มกิจกรรมอยู่กับที่มีประสิทธิภาพในทุกฐานข้อมูลกิจกรรม
 ดังนั้นจึงเลือกทั้งสองวิธีการนี้ไปใช้สร้างตัวแบบรู้จักกิจกรรม




ภาพที่ 117 แผนภาพแสดงค่าเฉลี่ย F-measure ของวิธีการเลือกคุณลักษณะที่ทดลองกับกลุ่มกิจกรรมในฐานข้อมูล RealWorld



ภาพที่ 118 แผนภาพแสดงค่าเฉลี่ย F-Measure ของวิธีการเลือกคุณลักษณะทดลองกับกลุ่มกิจกรรมในฐานข้อมูล กิจกรรม PARDUSS



ภาพที่ 119 แผนภาพแสดงค่าเฉลี่ย F-measure ของวิธีการเลือกคุณลักษณะที่ทดลองกับกลุ่มกิจกรรมในฐานข้อมูล
ในฐานข้อมูลกิจกรรม MHEALTH



ภาพที่ 120 แผนภาพแสดงค่าเฉลี่ย F-measure ของวิธีการเลือกคุณลักษณะที่ทดลองกับกลุ่มกิจกรรมในฐานข้อมูล
ในฐานข้อมูลกิจกรรม WISDM

4.4.3 การวัดประสิทธิภาพของวิธีการรู้จำกิจกรรม S-PAR3

การเปรียบเทียบประสิทธิภาพในการรู้จำกิจกรรม S-PAR3 กับงานวิจัยที่นำเสนอการตัวแบบรู้จำกิจกรรมกิจกรรมทางกายภาพจากกระแสข้อมูลเชิงเวลาอุปกรณ์สวมใส่ข้อมือได้แก่ งานวิจัย “Ensemble methods for classification of physical activities from wrist accelerometry” (Chowdhury และคณะ, 2017) ซึ่งได้นำวิธีการการสร้างตัวแบบรู้จำแบบ Custom ensemble method โดยใช้หลักการ Weighted Majority Vote ในการระบุกิจกรรมที่เป็นวิธีการที่มีประสิทธิภาพดีที่สุดมาใช้วัดผลและวิธีการจากงานวิจัย “Physical Activity Recognition Using Posterior-Adapted Class-Based Fusion of Multiaccelerometer Data” (Chowdhury และคณะ, 2018) เปรียบเทียบกับฐานข้อมูลกิจกรรมทั้งหมด 4 ฐานข้อมูลโดยรายละเอียดดังต่อไปนี้

- **ผลการทดลองวิธีการ S-PAR3 กับข้อมูลกิจกรรม RealWorld**

ผลการทดลองวิธีการรู้จำกิจกรรมด้วยวิธีการ S-PAR3 กับฐานข้อมูลกิจกรรม RealWorld แสดงผลลัพธ์ดังตารางที่ 51 และงานวิจัยที่เปรียบเทียบดังตารางที่ 52 ถึง 53 ซึ่งสามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ Recall, Precision และ F-measure แสดงดังภาพที่ 121 ถึง 123 จะเห็นได้ว่าวิธีการรู้จำกิจกรรม S-PAR3 มีประสิทธิภาพในการรู้จำกิจกรรมอยู่กับที่ทุกกิจกรรมมากกว่า 80 เปอร์เซ็นต์และการรู้จำกิจกรรมกลุ่มกิจกรรมเคลื่อนไหวในตาราง Confusion Matrix แสดงให้เห็นว่าได้วางงานวิจัยนำมาเปรียบเทียบระบุได้ผิดพลาดมากกว่าระหว่างกิจกรรมเดินและกิจกรรมเดินขึ้นบันได ซึ่งวิธีการ S-PAR3 มีประสิทธิภาพในการรู้จำกิจกรรมเดินได้เพิ่มขึ้นจาก S-PAR2 ประมาณ 5 เปอร์เซ็นต์ และกิจกรรมเดินขึ้นบันไดเพิ่มขึ้นประมาณ 11 เปอร์เซ็นต์แต่การรู้จำกิจกรรมเดินลงบันไดลดลงจากเดิมประมาณ 3 เปอร์เซ็นต์ เนื่องจากทั้งสองกิจกรรมมีค่าซ้อนทับกันมากอีกทั้งคุณภาพของข้อมูลที่ใกล้เคียงกัน ทำให้ตัวแบบรู้จำกิจกรรมมีโอกาสที่ระบุกิจกรรมเดินขึ้นบันไดเป็นกิจกรรมเดินลงบันไดได้มากกว่า (ในกรณีที่เป็นการระบุกิจกรรมชนิดเดียวกัน)

ตารางที่ 51 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของวิธีการ S-PAR3 กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1130	172	36	3	10	5	5
	Sitting	38	988	207	7	9	0	2
	Lying	49	115	1135	0	1	0	0
	Walking	0	0	0	843	303	69	11
	Stairs up	16	32	25	83	773	99	11
	Stairs down	0	0	0	98	174	738	3
	Running	152	15	19	29	7	12	1142

ตารางที่ 52 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1092	159	39	10	50	8	3
	Sitting	76	901	235	4	26	0	9
	Lying	30	254	1008	1	3	1	3
	Walking	18	17	0	773	307	109	2
	Stairs up	29	51	6	363	468	119	3
	Stairs down	0	2	0	75	123	812	1
	Running	146	30	7	5	12	8	1168

ตารางที่ 53 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับฐานข้อมูล RealWorld


		Prediction activities						
		Standing	Sitting	Lying	Walking	Stairs up	Stairs down	Running
Actual activities	Standing	1102	155	36	9	47	7	5
	Sitting	183	802	225	8	30	0	3
	Lying	75	179	1043	0	2	1	0
	Walking	11	17	0	775	301	115	7
	Stairs up	24	60	3	372	433	144	3
	Stairs down	5	0	0	84	101	821	2
	Running	145	45	14	15	29	9	1119



ภาพที่ 121 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม RealWorld



ภาพที่ 122 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม RealWorld



ภาพที่ 123 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม RealWorld

- ผลการทดลองวิธีการ S-PAR3 กับข้อมูลกิจกรรม PARDUSS

ผลการทดลองวิธีการรู้จำกิจกรรมด้วยวิธีการรู้จำกิจกรรม S-PAR3 กับฐานข้อมูลกิจกรรม PARDUSS แสดงผลลัพธ์ดังตารางที่ 54 และงานวิจัยที่เปรียบเทียบดังตารางที่ 55 ถึง 56 สามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ

Recall, Precision และ F-measure แสดงดังภาพที่ 123 ถึงภาพที่ 126 จะเห็นได้ว่าการปรับตัวแบบรู้จำกิจกรรม SPAR-3 มีประสิทธิภาพในการรู้จำทุกกิจกรรมได้มากกว่า 90 เปอร์เซ็นต์

ตารางที่ 54 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของวิธีการ S-PAR3 กับฐานข้อมูล PARDUSS


		Prediction activities						
		Standing	Sitting	Walking	Stairs up	Stairs down	Running	Cycling
Actual activities	Standing	771	1	15	2	0	0	11
	Sitting	0	779	0	0	0	0	21
	Walking	0	0	744	41	13	2	0
	Stairs up	4	0	55	733	7	0	1
	Stairs down	2	0	11	10	738	24	15
	Running	0	0	0	0	0	796	4
	Cycling	0	20	0	0	0	1	779

ตารางที่ 55 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล PARDUSS


		Prediction activities						
		Standing	Sitting	Walking	Stairs up	Stairs down	Running	Cycling
Actual activities	Standing	788	3	0	6	3	0	0
	Sitting	0	785	0	0	1	0	14
	Walking	0	0	514	245	41	0	0
	Stairs up	1	0	96	629	73	1	0
	Stairs down	2	0	28	90	676	1	3
	Running	0	0	0	0	1	797	2
	Cycling	0	8	0	0	0	2	790

ตารางที่ 56 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับฐานข้อมูล PARDUSS


		Prediction activities						
		Standing	Sitting	Walking	Stairs up	Stairs down	Running	Cycling
Actual activities	Standing	791	3	0	4	2	0	0
	Sitting	6	786	0	0	0	0	8
	Walking	0	0	495	252	53	0	0
	Stairs up	2	0	96	628	74	0	0
	Stairs down	6	0	25	81	687	1	0
	Running	76	0	0	2	0	721	1
	Cycling	0	8	0	0	1	2	789



ภาพที่ 124 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม PARDUSS



ภาพที่ 125 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม PARDUSS




ภาพที่ 126 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม PARDUSS

- ผลการทดลองวิธีการ S-PAR3 กับข้อมูลกิจกรรม MHEALTH


ผลการทดลองวิธีการรู้จำกิจกรรมด้วยวิธีการรู้จำกิจกรรม S-PAR3 กับฐานข้อมูลกิจกรรม MHEALTH แสดงผลลัพธ์ดังตารางที่ 57 และงานวิจัยที่เปรียบเทียบดังตารางที่ 58 ถึง 59 สามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ

ตารางที่ 59 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับฐานข้อมูล MHEALTH


		Prediction activities							
		Standing	Sitting	Lying	Walking	Runinng	Stairs	Jogging	Cycling
Actual activities	Standing	181	19	0	0	0	0	0	0
	Sitting	40	160	0	0	0	0	0	0
	Lying	0	27	153	0	0	0	0	20
	Walking	0	0	0	160	0	40	0	0
	Runinng	0	0	0	0	156	0	44	0
	Stairs	0	0	0	27	0	173	0	0
	Jogging	0	0	0	0	45	7	148	0
	Cycling	0	11	0	1	0	0	0	188



ภาพที่ 127 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม MHEALTH



ภาพที่ 128 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณະ (2017), Chowdhury และคณະ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม MHEALTH



ภาพที่ 129 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณະ (2017), Chowdhury และคณະ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม MHEALTH

● ผลการทดลองวิธีการ S-PAR3 กับข้อมูลกิจกรรม WISDM

ผลการทดลองวิธีการรู้จำกิจกรรมด้วยวิธีการรู้จำกิจกรรม S-PAR3 กับฐานข้อมูลกิจกรรม WISDM แสดงผลลัพธ์ดังตารางที่ 57 และงานวิจัยที่เปรียบเทียบดังตารางที่ 58 ถึง 59 ซึ่งสามารถคำนวณด้วยตัววัดประสิทธิภาพความถูกต้องและความแม่นยำของการรู้จำกิจกรรมด้วยวิธีการ

Recall, Precision และ F-measure แสดงดังภาพที่ 131 ถึงภาพที่ 132 จะเห็นได้ว่าตัวแบบรู้จำสามารถระบุกิจกรรมในกลุ่มกิจกรรมอยู่กับที่และกิจกรรมเดินและกิจกรรมเดินขึ้นลงบันไดเพิ่มขึ้นอย่างมีนัยสำคัญ

ตารางที่ 60 Confusion Matrix การรู้จำกิจกรรมด้วยวิธีการของวิธีการ S-PAR3 กับฐานข้อมูล WISDM


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3288	246	31	1	42
	Sitting	330	3072	35	8	74
	Walking	17	50	2833	71	488
	Running	1	5	51	3316	57
	Stairs	60	17	543	64	2785

ตารางที่ 61 Confusion Matrix การรู้จำกิจกรรมของวิธีการ WMV จากงานวิจัย Chowdhury และคณะ (2017) กับฐานข้อมูล WISDM


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	3001	500	26	0	81
	Sitting	567	2810	22	10	110
	Walking	10	27	2592	17	813
	Running	1	5	10	3369	45
	Stairs	44	62	657	64	2642

ตารางที่ 62 Confusion Matrix การรู้จำกิจกรรมจากงานวิจัย Chowdhury และคณะ (2018) กับฐานข้อมูล MHEALTH


		Prediction activities				
		Standing	Sitting	Walking	Running	Stairs
Actual activities	Standing	2776	718	47	0	67
	Sitting	689	2706	37	12	75
	Walking	21	49	2540	16	833
	Running	1	3	21	3356	49
	Stairs	65	56	752	76	2520



ภาพที่ 130 แผนภูมิแท่ง Recall เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม WISDM



ภาพที่ 131 แผนภูมิแท่ง Precision เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม WISDM



ภาพที่ 132 แผนภูมิแท่ง F-measure เปรียบเทียบระหว่างวิธีการ Chowdhury และคณะ (2017), Chowdhury และคณะ (2018) และวิธีการ S-PAR3 ด้วยฐานข้อมูลกิจกรรม WISDM

บทที่ 5


สรุปผลการดำเนินงานและข้อเสนอแนะ

ในบทนี้จะกล่าวถึงการสรุปและวิจารณ์ผลการดำเนินงานของวิทยานิพนธ์นี้ซึ่งประกอบด้วย การสรุปผลการดำเนินงานและการวิจารณ์ข้อดีวิธีการที่นำเสนอและข้อบกพร่องและรวมถึง ข้อเสนอแนะของวิทยานิพนธ์

5.1 สรุปผลการดำเนินงาน


วิทยานิพนธ์นี้ได้นำเสนอวิธีการสร้างตัวแบบรู้จำกิจกรรม Smartwatch-based Physical Activity Recognition (SPAR) ที่นำกระแสข้อมูลเชิงเวลาจากตัวรับรู้ Accelerometer และ Gyroscope ของอุปกรณ์ที่สวมใส่ข้อมือ ซึ่งมีการพัฒนาวิธีการรู้จำกิจกรรม SPAR ทั้งสามเวอร์ชันโดย มีรายละเอียดดังต่อไปนี้

- **วิธีการรู้จำกิจกรรม S-PAR1** เป็นการสร้างตัวแบบรู้จำกิจกรรมตามคุณลักษณะของข้อมูล กิจกรรม ซึ่งแบ่งกลุ่มกิจกรรมออกเป็นสองกลุ่มได้แก่ กลุ่มกิจกรรมอยู่กับที่และกิจกรรม เคลื่อนไหวโดยใช้ค่าขีดแบ่งกิจกรรม จากผลการทดลองที่นำเสนอในวิทยานิพนธ์เทียบกับ งานวิจัยที่นำเสนอวิธีการรู้จำกิจกรรมจากอุปกรณ์ ณ ตำแหน่งเดียวกันกับ 4 ฐานข้อมูล กิจกรรมแสดงดังภาพที่ 133 จะเห็นได้ว่าประสิทธิภาพ F-measure ของฐานข้อมูล RealWorld และ PARDUSS มีค่าเฉลี่ย F-measure สูงกว่าประมาณ 3-4 เปอร์เซ็นต์และใน ฐานข้อมูล WISDM มีค่าเฉลี่ยที่ใกล้เคียงกัน แต่ในฐานข้อมูล MHEALTH ที่ S-PAR1 มี ค่าเฉลี่ยน้อยกว่าวิธีการจากงานวิจัยแรกประมาณ 2-3 เปอร์เซ็นต์




ภาพที่ 133 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของการรู้จำกิจกรรมระหว่างงานวิจัยที่เปรียบเทียบกับวิธีการ S-PAR1

- วิธีการรู้จำกิจกรรม S-PAR2** เป็นการปรับปรุงตัวแบบรู้จำกิจกรรมที่เพิ่มประสิทธิภาพในการรู้จำกิจกรรมให้แม่นยำถูกต้องมากขึ้น การเปลี่ยนแปลงที่สำคัญได้แก่วิธีการการแบ่งกลุ่มกิจกรรมจากค่าขีดแบ่งกิจกรรมเป็นตัวแบบรู้จำกลุ่มกิจกรรม, เพิ่มวิธีการเลือกคุณลักษณะที่เหมาะสมกับฐานข้อมูลและลดจำนวนคุณลักษณะให้น้อยที่สุดและวิธีการเรียนรู้ในการสร้างตัวแบบรู้จำกิจกรรมในแต่ละกลุ่มกิจกรรมที่ได้ประสิทธิภาพมากที่สุด จากผลการทดลองที่นำเสนอในวิทยานิพนธ์กับ 4 ฐานข้อมูลกิจกรรม แสดงดังภาพที่ 134 จะเห็นได้ว่าประสิทธิภาพค่าเฉลี่ยของ F-measure สูงกว่าในทุกฐานข้อมูลประมาณ 2-4 เปอร์เซ็นต์เมื่อเทียบกับทั้งสามวิธีการของงานวิจัยที่เปรียบเทียบ




ภาพที่ 134 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของการรู้จำกิจกรรมระหว่างงานวิจัยที่เปรียบเทียบกับวิธีการ S-PAR2

- วิธีการรู้จำกิจกรรม S-PAR3** เป็นการพัฒนาตัวแบบรู้จำกิจกรรมให้สามารถปรับปรุงได้ โดยเพิ่มขึ้นตอนที่มีชื่อว่า Extra Training ซึ่งจะเป็นการตัดข้อมูลอาสาสมัครทดสอบบางส่วนในแต่ละกิจกรรม นำมาปรับปรุงพารามิเตอร์ ซึ่งได้นำวิธีการรู้เรียนเชิงเส้น (Linear Model) ที่สามารถปรับค่าน้ำหนัก (Weight) โดยผ่านใช้หลักการ Minibatch Gradient Descent อีกทั้งพยายามใช้จำนวนคุณลักษณะที่เหมาะสมที่จะทำให้ตัวแบบรู้จำกิจกรรม S-PAR3 สามารถรู้จำกิจกรรมได้แม่นยำถูกต้องมากที่สุด จากการทดลองที่นำเสนอในวิทยานิพนธ์กับ 4 ฐานข้อมูลกิจกรรมเช่นเดียวกับ S-PAR3 แสดงดังภาพที่ 135 จะเห็นได้ว่าค่าเฉลี่ย F-measure สูงกว่าในทุกฐานข้อมูลอย่างน้อย 4 เปอร์เซ็นต์



ภาพที่ 135 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของการรู้จำกิจกรรมระหว่างงานวิจัยที่เปรียบเทียบกับวิธีการ S-PAR3

เมื่อเปรียบเทียบประสิทธิภาพด้วยมาตรวัด F-measure ของวิธีการสร้างตัวแบบรู้จำกิจกรรม S-PAR ทั้งสามเวอร์ชันที่นำเสนอตั้งภาพที่ 136 จะเห็นได้ว่าวิธีการ S-PAR มีการพัฒนาประสิทธิภาพในการรู้จำกิจกรรมใน 4 ฐานข้อมูลเพิ่มขึ้นตามลำดับและในเวอร์ชัน 3 สามารถมีประสิทธิภาพในการรู้จำกิจกรรมมากกว่า 90 เปอร์เซ็นต์ในฐานข้อมูล PARDUSS และ MHEALTH



ภาพที่ 136 แผนภาพแท่งแสดงค่า F-measure โดยเฉลี่ยของวิธีการรู้จำกิจกรรม S-PAR ทั้งสามเวอร์ชันในแต่ฐานข้อมูล

5.2 วิจารณ์ผลการดำเนินงาน

5.2.1 ข้อดีของงานวิทยานิพนธ์

1. วิธีการรู้จำกิจกรรม S-PAR1 นำเสนอวิธีการสร้างตัวแบบรู้จำกลุ่มกิจกรรม (อยู่กับที่หรือเคลื่อนไหว) และสร้างตัวแบบรู้จำตามลักษณะกระแสดข้อมูลเชิงเวลาจากตัวรับรู้ทั้งสองตัว
2. วิธีการรู้จำกิจกรรม S-PAR2 นำเสนอวิธีการเลือกคุณลักษณะและปรับพารามิเตอร์ในการสร้างตัวแบบรู้จำกิจกรรมที่ได้ประสิทธิภาพในการรู้จำกิจกรรมในทุกฐานข้อมูล
3. วิธีการรู้จำกิจกรรม S-PAR3 สามารถปรับตัวแบบรู้จำกิจกรรมตามกระแสดข้อมูลเชิงเวลาของผู้ใช้แต่ละคนที่ทำให้ประสิทธิภาพในการรู้จำเพิ่มขึ้น

5.2.2 ข้อจำกัดของงานวิทยานิพนธ์

จากการวิเคราะห์และทดลองสร้างตัวแบบรู้จำกิจกรรมทำให้รู้ว่าวิธีการทั่วไปในการรู้จำกิจกรรมจากกระแสดข้อมูลเชิงเวลาเฉพาะอุปกรณ์สวมใส่ข้อมือไม่สามารถทะลุพีดานประสิทธิภาพสูงขึ้นในการรู้จำกิจกรรม โดยเฉพาะฐานข้อมูลที่เก็บในสภาพแวดล้อมจริง ที่ทำให้คุณภาพของข้อมูลที่ได้เป็นข้อจำกัดในการปรับปรุงตัวแบบรู้จำกิจกรรมที่มีผลต่อประสิทธิภาพของตัวแบบรู้จำกิจกรรมซึ่งอาจจะทำให้ต้องเพิ่มขึ้นตอนเตรียมข้อมูล, จำนวนคุณลักษณะหรือวิธีการสร้างตัวแบบรู้จำกิจกรรมที่มีซับซ้อนทำให้ขนาดของวิธีการรู้จำมีขนาดใหญ่และเวลาในการประมวลผลเพิ่มมากขึ้นตามไปด้วย

5.3 ข้อเสนอแนะของงานวิทยานิพนธ์

1. ใช้กระแสดข้อมูลเชิงเวลาตัวรับรู้เฉพาะทางในบางกิจกรรมที่อาจจะช่วยเพิ่มประสิทธิภาพรู้จำกิจกรรมที่มีความซับซ้อน
2. การนำสร้างตัวแบบรู้จำกิจกรรมที่เป็น Deep Learning ที่อาจจะช่วยเพื่อการรู้จำกิจกรรมมีความถูกต้องแม่นยำมากยิ่งขึ้น



ภาคผนวก



ภาคผนวก ก

เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์



ที่ ๑๔๐/๒๕๖๒

เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์
มหาวิทยาลัยบูรพา

คณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา ได้พิจารณาโครงการวิจัย

รหัสโครงการวิจัย Sci 070/2562
โครงการวิจัยเรื่อง การรู้จักกิจกรรมที่ปรับได้โดยใช้ข้อมูลตัวรับรู้ของอุปกรณ์สวมใส่
หัวหน้าโครงการวิจัย นายกตिका กองคิล
หน่วยงานที่สังกัด นิสิตรระดับบัณฑิตศึกษา คณะวิทยาการสารสนเทศ

คณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา ได้พิจารณาแล้วเห็นว่าโครงการวิจัยดังกล่าวเป็นไปตามหลักการของจริยธรรมการวิจัยในมนุษย์ โดยที่ผู้วิจัยเคารพสิทธิและศักดิ์ศรีในความเป็นมนุษย์ ไม่มีการล่วงละเมิดสิทธิ สวัสดิภาพ และไม่ก่อให้เกิดอันตรายแก่ตัวผู้วิจัยและผู้เข้าร่วมโครงการวิจัย

จึงเห็นสมควรให้ดำเนินการวิจัยในขอบข่ายของโครงการวิจัยที่เสนอได้ (ดูตามเอกสารตรวจสอบ)

๑. เอกสารโครงการวิจัยฉบับภาษาไทย ฉบับที่ ๑ วันที่ ๑ เดือน สิงหาคม พ.ศ. ๒๕๖๒
 ๒. เอกสารชี้แจงผู้เข้าร่วมโครงการวิจัย ฉบับที่ - วันที่ - เดือน - พ.ศ. -
 ๓. เอกสารแบบแสดงความยินยอมของผู้เข้าร่วมโครงการวิจัย ฉบับที่ - วันที่ - เดือน - พ.ศ. -
 ๔. เอกสารแสดงรายละเอียดเครื่องมือที่ใช้ในการวิจัยซึ่งผ่านการพิจารณาจากผู้ทรงคุณวุฒิแล้ว หรือชุดที่ใช้เก็บข้อมูลจริงจากผู้เข้าร่วมโครงการวิจัย ฉบับที่ - วันที่ - เดือน - พ.ศ. -
- การรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์ฉบับนี้ มีผลถึงวันที่ ๓๑ เดือน กรกฎาคม พ.ศ. ๒๕๖๓

ออกให้ ณ วันที่ ๑ เดือน สิงหาคม พ.ศ. ๒๕๖๒

ลงนาม

(รองศาสตราจารย์ ดร.วิวิท แจงเอียด)

ประธานคณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์
มหาวิทยาลัยบูรพา



ภาคผนวก ข
เอกสารเผยแพร่ผลงานวิจัย



The 4th International Conference on Information Technology

24-25 October 2019, Bangkok, Thailand.

Organized by: Faculty of Information Technology, Thai-Nichi Institute of Technology and Council of IT Deans of Thailand (CITT)

Theme : Encompassing Intelligent Technology and Innovation Towards the New Era of Human Life.

The 4th International Conference on Information Technology (InCIT2019) has goal and objective to be the forum of sharing the research in the related areas of information and communication technology. We believe that the research encompasses intelligent technology and innovation for the next society of human being will be very important. Authors who involves those research areas are cordially invited to submit papers and present in InCIT2019. In addition, the conference will strengthen the collaboration and provide opportunities for delegates to exchange and discuss new innovative ideas and research results, as well as the future directions for cooperative research.

The topics include, but are not limited to

- Artificial Intelligence
- Data Science and Analytics
- Cloud Service and Computing
- Communications and Networking
- Computer Animation and Game
- Digital Multimedia Technology
- Database Technology
- E-Commerce, E-Education, E-Government, E-Industry, E-Society
- Geo-informatics
- Human Computer Interaction
- IT in Education
- IT and Project Management
- IT Security and Privacy
- IT and Mobile Application
- Image Processing
- Intelligence Communications
- Internet of Things
- Network Security and Privacy
- Augmented and Virtual Reality
- Pattern Recognition
- Platform Technologies
- Quantum Computing
- Signal Processing
- Natural Language Processing
- Bio-medical Informatics
- Smart and Expert Systems
- Web and Internet Technologies
- Wireless and Mobile Networks
- Other Related Topics

Important Dates

Paper Submission Deadline: Extended to 20 June 2019
Notification of Acceptance: 15 July 2019
Camera-Ready: 31 August 2019
Early Bird Registration: 10 September 2019
Regular Registration: 11-25 September 2019
Conference Date: 24-25 October 2019

Registration fee

Categories	Authors		Participants
	Early Bird	Regular	
Non IEEE/ECTI Member	USD 350 or THB 10,500	USD 400 or THB 12,000	USD 200 or THB 6,000
IEEE/ECTI Member	USD 315 or THB 9,450	USD 360 or THB 10,800	USD 180 or THB 5,400



Contact InCIT Secretariat : incit@tni.ac.th, Tel :+66 (0) 2763 2752

Honorary Chair	
Bandhiti Rojaryanont	TNI, Thailand
President of Thai-Nichi Institute of Technology	
General Chair	
Rutikorn Varakulsiripunth	TNI, Thailand
Chairman of Council of IT Deans of Thailand (CITT)	
General Co-chair	
Krisana Chinnasarn	BUU, Thailand
Phayung Meesad	KMUTNB, Thailand
Advisory Board	
Woraphon Liakiataskun	MUT, Thailand
Kriengkrai Porkaew	KMUTT, Thailand
Narongdech Keeratipranon	DPU, Thailand
Nopporn Chotikakumtorn	KMITL, Thailand
Pattanasak Mongkolkeat	MU, Thailand
Teeravisit Laohapensaeng	MFU, Thailand
Sinchai Kamolpithwong	PSU, Thailand
Thirapon Wongsardisakul	BU, Thailand
Thana Suwarea	SPU, Thailand
Chetnati Srisaan	RSU, Thailand
Sasitorn Keawman	MSU, Thailand
Poepong Boonbrahm	WU, Thailand
Dechanuchit Katarayutawetip	StamU, Thailand
Anong Rungsak	NPU, Thailand
Somsak Charinamphet	SU, Thailand
Pisit Charnkeikong	PIM, Thailand
Thirath Cheesuan	UP, Thailand
Norio Shiratori	CHUGU-U / TOHOKU, Japan
Kenzo Takahashi	UEC, Japan
Susumu Yoshida	KYOTO-U, Japan
Yoshikazu Miyanaga	HOKUDAI, Japan
Branka Vucotic	SYDNEY, Australia
Ying-Dar Lin	NCTU, Taiwan
Yasushi Kato	SFAIS, Japan
Technical Program Supporting Committee	
Kosin Chamnongthai	KMUTT, Thailand
Kunpong Woraratpanya	KMITL, Thailand
Chotipat Pornsavalit	KMITL, Thailand
Noppadol Maneerat	KMITL, Thailand
Sakchai Tipchaksurat	KMITL, Thailand
Wimol San-Uth	TNI, Thailand
Waree Kongprawechnon	SIIT, Thailand
Virach Somlertlamvanich	SIIT, Thailand
Saiyan Saiyod	KKU, Thailand
Putchong Uthayopas	KU, Thailand
Chaodit Asawakul	CU, Thailand
Kazuhiko Hamamoto	TOKAI-U, Japan
Samuel S. Chua	LPU, Philippines
I Wayan Mustika	UGM, Indonesia
Hitoshi Isahara	TUT, Japan
Kaoru Takahashi	ARIAKE-NCT, Japan
Salahuddin Muhammad Salim Zabir	TSURUOKA-NCT, Japan
Takashi Mitsushashi	TOHOKU, Japan
Hiroshi Tsunoda	TOHTECH, Japan



Physical Activity Recognition Using Streaming Data from Wrist-worn Sensors

Katika Kongsil
Mobile Application Developers
Incubation Laboratory
Faculty of Informatics
Burapha University
 Chonburi, Thailand
 60910061@go.buu.ac.th

Jakkarin Suksawatchon
Mobile Application Developers
Incubation Laboratory
Faculty of Informatics
Burapha University
 Chonburi, Thailand
 jakkarin@go.buu.ac.th

Ureerat Suksawatchon
Mobile Application Developers
Incubation Laboratory
Faculty of Informatics
Burapha University
 Chonburi, Thailand
 ureerat@go.buu.ac.th

Abstract—Most of the existing researches in smartwatches based activity recognition focused on developing the subject (user) specific approach or personal model which the subject must collect the labeled data for training the model. It is inconvenient for the users are unable to perform all activities during the specified times. In this paper, we introduce a cross subjects approach or impersonal activity recognition model based on the fusion of two sensors embedded on smartwatches called S-PAR. It stands for Smartwatches based Physical Activity Recognition. Therefore, the users who utilize the model, are not necessary to gather initial the labeled data. The experiments were carried out to examine the performance of S-PAR model against with state-of-the-art methods by using two public databases collected under realistic conditions. From the results, S-PAR model provides the overall performance in detection and prediction activities type. Therefore, our proposed model can be used in the real life environment.

Index Terms—Activity recognition, Smartwatches, Machine learning, Impersonal model, Wrist-worn sensors

I. INTRODUCTION

In the current situation, non-communicable diseases (NCDs) are the world's number one health problem which is increasing in low and mid-income countries. The greatest disease burden of NCDs is from diabetes, cardiovascular diseases, cancers, hypertension, and obesity. It dues to five main NCDs risk factors, including unhealthy diet, tobacco use, air pollution, and physical inactivity or unhealthy habits [1]. Especially, physical inactivity is considered as one of the biggest public healthy problems because of sedentary lifestyle such as hypersomnia, office working, sitting in front of a computer all the day, or playing games for long hours. Strategies for health promotion should be some efficient applications or mechanisms to track or monitor for quantifying physical activities. To measure the quantifying physical activities, the automated detection of physical activity types (for example, walking, running, sitting) doing during the day should be analyzed first by an *activity recognition* method [2].

As a continuous growth of technology, most smartphones and smartwatches are being integrated with multiple sensors, i.e., accelerometers, magnetometers, gyrometers etc., and wireless communication [3]. These advancements can be utilized to identify the physical activity type by analyzing the sensors data. Most researches focused on smartphone-based physical activity recognition, for example, those proposed in [4]–[6]. Although many researches in smartphone-based

activity recognition which used triaxial accelerometer sensors or multiple sensors, achieved more than 90% accuracy, but those sensors were attached to different positions on the subjects' body like arms, chest and waist etc. for gathering the sensor data. It makes these approaches may not be practical usage in the real living situations because the sensors over body may obstruct for performing the activities. Despite, there exist some researches have studied the use of a single triaxial accelerometer attached to only waist, chest or kept smartphone in the pocket for smartphone-based activity recognition [7], however, placing the sensors on those locations cause obstruct and discomfort in doing the daily activity especially in elderly persons or limit for women who usually kept the smartphone in their handbag not the pocket.

As wrist-worn devices such as smartwatches, fitness wristbands etc., become widespread usage, it has integrated the multiple sensors which are easier to detect the physical activities. There exists many approaches that aim to detect and identify human activity types. Most of existing works built the activity recognition model depended on a subject specific approach or personal model. That is the target users must gather and annotate the types of activities by performed all activities for a definite time and enough training data. In addition, the subject has to perform the activities with no movement constraint or less movement, i.e., standing still, sitting on a chair, walking without swinging arms etc. This is often not practicable and discomfort, especially, elderly or patients who cannot perform all activities.

Therefore, in this study we introduce the new model called Smartwatch-based Physical Activity Recognition or S-PAR using data collected from a triaxial accelerometer and a triaxial gyrometer which built on smartwatches. We focus on common physical activities usually performing in daily life such as standing, sitting, lying, walking, stairs up, stairs down, and running. The S-PAR is composed of two components: modeling component and recognition component. The modeling component is an offline processing which aims to building two activities recognition models. One model is used to detect and predict the dormant activities types and the another is used for the energetic activities types. The recognition component is a online processing which uses those two models to detect and predict the current activities type from streaming sensor data in real time manner.

The main contributions of our research are as follows:

- We present the new model which is a cross subjects activity recognition model or impersonal model. Therefore, the target users who utilize the model, have not prepare the training data because our proposed model can be built once and used training data from the other users.
- We used the training data obtained the public databases. These datasets were collected under realistic constrains, i.e., walking in the city with swinging arms, running in a forest, or climbed us the stairs of old castle [8]. Therefore, our proposed model can use in the real life environment.

II. RELATED WORK

There have been several studies which have focused on wrist-worn devices like smartwatches or fitness wristbands for activity recognition.

For example, Da-Silva, et al. [9] proposed two activity recognition systems with a wrist-worn accelerometer sensor to recognize eight physical activities such as standing, sitting, lying, running, walking, stairs up, stairs down, working on a computer. The first system has a single classifier to identify all activities and the second system added a pre-classifier to separate type of activities: movement of postures. The two architectures were evaluated with MLP neural networks, k-NN, support vector machine (SVM) algorithms. The result shows the best performance with accuracy of 93.47% by using SVM. From studied those two pieces of research, it was found that the best accuracy of more than 90% was achieved by using only personal data or a subject-specific approach that is the target user has to collect and label data. Moreover, the subject has to perform activities with no movement constraint and discomfort, i.e., walking with normal speed or standing still. This situation is not feasible for elders or patients who are unable to perform all activities with the constraints.

Shoaib et al. [7] focused on the fusion of wrist-worn (smartwatches) devices and smartphones for physical activity recognition. Seven subjects had to carry smartphones in the right jeans pocket and smartwatches on their right wrist position to collect the training data. They performed 7 basic activities like walking, jogging, biking, etc., and 6 complex activities such as typing, drinking coffee, giving a talk, smoking. The average and standard deviation were extracted from accelerometer and gyroscope sensor to recognize 13 activities. For efficiency analysis, three classification algorithms including decision tree, SVM, and k-NN, were selected. The result shows the fusion of two devices could achieve with high accuracy. However, in case of the subjects did not carry both devices or the position of two devices on subjects' body can impact the recognition accuracy. Besides, Shahmohammadi et al. [10] proposed smartwatch-based activity recognition with active learning to provide personalize model. Each subject who utilize the model had to prepare the training data by performing 5 commonly daily activities including standing, sitting, laying down, walking, and running in a certain of time. In addition, Shahmohammadi and the team introduced retraining the model by inquiry true activity types from the subjects when the unknown activities occurred.

The authors claimed that their model can reduce the amount of training data about 46% with an average accuracy 92%. However, there some limitations of this model. For example, if the active learning provided queries for confirmation the current activity or unknown activity, but the users cannot respond the system immediately. So, the retraining cannot performed and the performance will be decreased.

III. THE PROPOSED ACTIVITY RECOGNITION

In this section, we described our proposed the Smartwatch-based Physical Activity Recognition which called S-PAR for shortly as shown in Fig. 1. Our proposed framework is composed of two components which are the modeling component and the recognition component. The modeling component is to build dormant activity model and energetic activity model. For the recognition component is used to identify physical activity type from the streaming sensory data produced from sensors in real time.

A. Sensory data understanding

This study used streaming sensory data obtained from two sensors of wrist-worn device like smartwatch, which widely used in physical activity recognition. For the first sensor, the single accelerometer sensor is used to measure the acceleration signals along the X-axis, Y-axis and Z-axis named A_x , A_y and A_z values respectively. In generally, each acceleration signal is combined between body acceleration due to the movement of the users' body and constant (gravitational) acceleration due to gravity force [4]. The second sensor is the single gyroscope sensor used to measure the angular velocity along three axes named G_x , G_y and G_z values. Typically, the gyroscope sensor mostly uses together with accelerometer sensor to detect the movement activities like walking, running, etc. [11]. The samples of streaming dataset are depicted in Fig. 2.

For further using, some notations are defined here. Let ACT be the set of activities in labeled training data. Each Act is consisted of the set of samples S , where $S = \{s_1, s_2, \dots, s_i, \dots, s_N\}$, and N is the number of samples in each activity. Each s_i is defined as a 7-tuple $(A_{x_i}, A_{y_i}, A_{z_i}, G_{x_i}, G_{y_i}, G_{z_i}, t_i)$ where t_i is the activity type of the sample s_i . In this research, the basic movements were selected which are standing, sitting, lying, walking, stairs up, stairs down, and running.

B. Data Preprocessing

The streaming data collected from smartwatches were pre-processed for noise reduction. In this work the acceleration values due to gravity (constant acceleration) were considered as noise. We segment the signal data based on the 2-second non-overlapping sliding window. In each window j , we applied the low-pass filter for each axis of the acceleration in order to separate the body acceleration and the constant acceleration due to gravity force. The 3rd order Butterworth low-pass filter with a cut off of 0.3 Hz was used [12] to obtain the constant acceleration, and then these raw signals in window j were subtracted with the constant acceleration to extract the body acceleration [13]. After performing this step, the gravitation acceleration data must be filter out, so we obtained the body accelerations of the signals for using

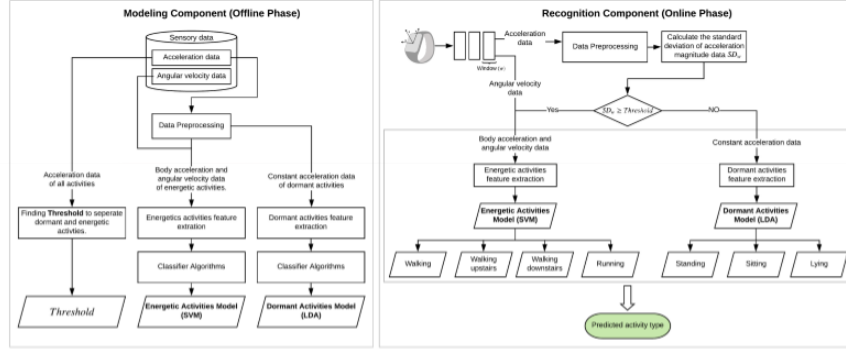


Fig. 1: The proposed physical activity recognition system (S-PAR).

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

Fig. 2: The samples of streaming dataset.




Fig. 3: The result of extraction the acceleration signals with the low-pass filter.

in the next step. The results after applied data preprocessing step are shown in Fig. 3.

C. Modeling Component

The modeling component is an offline processing which aims (i) to find the *Threshold* value for separation the category of activities, and (ii) to build a classifier model for each category of activities. One model is for dormant activities and the another is for energetic activities.

1) *Finding Threshold*: We began with consider the pattern of acceleration signal. It was found that the acceleration

of three axes of walking, and running are high vibrant. These signals are the *energetic activities*. On the other hand, the acceleration of standing, sitting and lying activities are influenced from the gravity force, and all the acceleration values are almost still [5]. These signals are called the *dormant activities*. This work applied the *Threshold* finding from [5] for separating the incoming signal to dormant or energetic activities. This *Threshold* value is used in recognition component. The steps of finding this *Threshold* as the follows:

Step 1: For each activity in Act and for each window j , the magnitude of a sample s_i (M_i) is computed using Eq. 1. Then we calculate the standard deviation of window j (SD_j) by using Eq. 2.

$$M_i = \sqrt{Ax_i^2 + Ay_i^2 + Az_i^2} \quad (1)$$

where $i=1, 2, 3, \dots, n$; and n is the number of samples within window j . In this paper, n is predefined as the sampling rate.

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

where \bar{M}_j is the average of magnitude in window j .

Step 2: The average of the standard deviation for each activity in (SD_{Avg}^{Act}) is computed by using Eq. 3.

$$SD_{Avg}^{Act} = \frac{\sum_{j=1}^J SD_j^{Act}}{J} \quad (3)$$

where J is number of windows for each activity.

Step 3: We compute the minimum of the average of standard deviation considered only energetic activities (SD_{min}^{ener}), and the maximum of the average of standard deviation in dormant activities (SD_{max}^{dor}). Then, the *Threshold* is computed from the average of these value by using Eq. 4.

$$Threshold = \frac{SD_{max}^{dor} + SD_{min}^{ener}}{2} \quad (4)$$




Fig. 4: The *Threshold* value represented by green line.

Finally, this *Threshold* can be used to separate the categories of activity into dormant activities and energetic activities as shown in Fig. 4.

2) *Building The Dormant Activities Recognition Model:* The only constant acceleration signals along X-axis, Y-axis and Z-axis were used, and the process of building the proposed model was described as follows:

Step 1: For each activity in $Act \in \{\textit{sitting, standing, lying}\}$, the constant acceleration along three axes defined as $(\textit{gra}X_i, \textit{gra}Y_i, \textit{gra}Z_i)$ are transformed to the average of constant acceleration related to each axis in each window j denoted as $(\textit{Mean}_{j(\textit{gra}X)}^{\textit{Act}}, \textit{Mean}_{j(\textit{gra}Y)}^{\textit{Act}}, \textit{Mean}_{j(\textit{gra}Z)}^{\textit{Act}})$ by using Eq. 5.

$$\begin{aligned} \textit{Mean}_{j(\textit{gra}X)}^{\textit{Act}} &= \frac{\sum_{i=1}^n \textit{gra}X_i}{n} \\ \textit{Mean}_{j(\textit{gra}Y)}^{\textit{Act}} &= \frac{\sum_{i=1}^n \textit{gra}Y_i}{n} \\ \textit{Mean}_{j(\textit{gra}Z)}^{\textit{Act}} &= \frac{\sum_{i=1}^n \textit{gra}Z_i}{n} \end{aligned} \quad (5)$$

Step 2: In order to search the best classifier model, five different techniques were evaluated. The decision tree, k-Nearest Neighbors (kNN), random forest, Support Vector Machine (SVM) with RBF kernel, and Linear Discriminant Analysis (LDA) techniques were selected for this purpose. The experimental results are shown in Section IV. After evaluation with the average of constant acceleration for all dormant activities, the LDA presented the best performance. Therefore, LDA was used for the dormant activities recognition model.

3) *Building The Energetic Activities Recognition Model:* The body acceleration signals and angular velocity signals related three axes were used. Now, we defined new notations for easier to understanding. So, these two signals along X-axis, Y-axis and Z-axis were denoted as x_i , y_i , and z_i respectively. The process of proposed model was described as follows:

Step 1: For each activity in $Act \in \{\textit>walking, stairsup, stairsdown, running}\}$, each signal along three axes is transformed to the root mean squared (*RMS*), skewness (*Skew*), and interquatile range (*IQR*) in each window j by using Eqs. 6, 7, and 8. After performing this step, there are 18 features used in the next step.

$$\begin{aligned} \textit{RMS}_{j(X)}^{\textit{Act}} &= \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \\ \textit{RMS}_{j(Y)}^{\textit{Act}} &= \sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2} \\ \textit{RMS}_{j(Z)}^{\textit{Act}} &= \sqrt{\frac{1}{n} \sum_{i=1}^n z_i^2} \end{aligned} \quad (6)$$

$$\begin{aligned} \textit{Skew}_{j(X)}^{\textit{Act}} &= \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_j)^3}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_j)^2\right)^{3/2}} \\ \textit{Skew}_{j(Y)}^{\textit{Act}} &= \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_j)^3}{\left(\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_j)^2\right)^{3/2}} \\ \textit{Skew}_{j(Z)}^{\textit{Act}} &= \frac{\frac{1}{n} \sum_{i=1}^n (z_i - \bar{z}_j)^3}{\left(\frac{1}{n} \sum_{i=1}^n (z_i - \bar{z}_j)^2\right)^{3/2}} \end{aligned} \quad (7)$$

$$\begin{aligned} \textit{IQR}_{j(X)}^{\textit{Act}} &= Q3_{j(X)}^{\textit{Act}} - Q1_{j(X)}^{\textit{Act}} \\ \textit{IQR}_{j(Y)}^{\textit{Act}} &= Q3_{j(Y)}^{\textit{Act}} - Q1_{j(Y)}^{\textit{Act}} \\ \textit{IQR}_{j(Z)}^{\textit{Act}} &= Q3_{j(Z)}^{\textit{Act}} - Q1_{j(Z)}^{\textit{Act}} \end{aligned} \quad (8)$$

Step 2: In this study, we compared the performance of five classifiers including the decision tree, k-Nearest Neighbors (kNN), random forest, Support Vector Machine (SVM) with RBF kernel, and Naïve Bayes. The experimental results are shown in Section IV, and SVM with RBF kernel gave the best performance. Therefore, SVM was used for the energetic activities recognition model.

D. Recognition component

This section explained how to apply the S-PAR model to detect and predict the current activity type from streaming sensory data. Fig. 1 shows the recognition component processing. We simulated the real-time environment for usage S-PAR model by feeding the continuous streaming data from the testing data. A 2-second non-overlapping sliding window, was applied to deal with the stream of data into a small data chunk. So, each small data chunk was performed in the following steps.

Step 1: In *Data Preprocessing* step, the only acceleration signals along three axes were separated to the body acceleration and the constant acceleration due to gravity by using the 3rd order Butterworth low-pass filter. After that we calculated the magnitude (M_i) of each raw acceleration signal and then compute the standard deviation (SD_w) of all the magnitude (M_i) in such data chunk.

Step 2: If SD_w is more than or equal *Threshold*, then the incoming signals will be the dormant activities. Otherwise, the incoming signals will be the energetic activities.

Step 3: If the incoming signals were dormant activities, then the only constant acceleration signal along three axes was computed the average of each axis by using Eq. 5. Then we applied these average values to *Dormant Activities Model* (LDA) to obtained the predicted activity type. Otherwise if

the incoming signals were energetic activities, then both the body acceleration signals and angular velocity signals along three axes were computed root mean square (*RMS*), skewness (*Skew*) and interquartile (*IQR*) of each axis. After that, we applied the transformed signals to *Energetic Activities Model* (SVM) to obtain the predicted activity type.

IV. RESULTS AND DISCUSSION

In this section, we presented how to evaluate S-PAR model and display the experimental results on two public datasets.

A. Experiments Setup

The dataset for this research were collected from the public databases. The first dataset (*DS1*) is the Complex Human Activities Dataset from pervasive system research datasets [14]. This dataset contains a linear acceleration and a angular velocity values of 10 participants. The participants performed 6 activities listed in Table I. The *DS1* dataset were collected from Samsung Galaxy S2 Smartphone attached on the right wrist with the sampling frequency is 50Hz. The second dataset (*DS2*) is acquired from [8]. This data set contains a linear acceleration data and a triaxial angular velocity values collected from 15 subjects. Each subject wore LG G Watch R and performed 7 physical activities under realistic conditions such as the subjects walked through the city or jogged in a forest etc. [8]. The details of *DS2* dataset are listed in Table I. The sensors on device were sent with a sampling rate of 50Hz.

TABLE I: The number of samples for each activity in two datasets.

Activity Types	<i>DS1</i>	<i>DS2</i>
Standing	90,000	155,788
Sitting	90,000	138,063
Lying	-	142,316
Walking	90,000	138,409
Stairs Up	90,000	114,703
Stairs Down	90,000	116,806
Running	90,000	153,089

To evaluate the performance of the proposed model, we used a leave-one-subject-out (LOSO) cross validation [10]. Therefore, the data of one subject were used as the test dataset and the data of the other subjects were used as the training dataset. This process was repeated for every subject as the test dataset. In addition, the proposed model (S-PAR) used F-score [15] to measure the efficiency compared with state-of-the-art models which are two architectures proposed in [9] and the research [7].

$$F - score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (9)$$

B. Evaluation the Activity Recognition

In order to show the performance of S-PAR, we compared it to state-of-the-art methods. Table II shows the average of F-score matrices of all activities on two public datasets. From these results, S-PAR obtains the best performance which is able to achieve at rate 88.62% on *DS1* dataset with the lowest standard deviation. In the same way, S-PAR presents the best results for *DS2* at accuracy rate 71.52% with the lowest

standard deviation. Why did all of algorithms obtained the results lower 80% on *DS2*? Because *DS2* dataset was carried out under realistic constraints in real life environment as mentioned before. Therefore, we can conclude that the S-PAR model can achieve the best performance with the lowest dispersion in all datasets compared with 3 models.

TABLE II: The average of F-score measurement on public datasets.

Algorithms	<i>DS1</i>	<i>DS2</i>
Architecture 1 (2013) [9]	79.14±22.65 %	68.67±13.26 %
Architecture 2 (2013) [9]	85.70±19.53 %	66.84±11.72 %
Research (2015) [7]	86.28±16.65 %	62.75±15.35 %
S-PAR	88.62±11.71 %	71.52±11.34 %

C. Evaluation the Classifier Models

As mentioned before in subsection III-C, the S-PAR model uses LDA and SVM as the classifiers for detection and prediction the current activity type. We compared their performance to the other common classification techniques and evaluated with LOSO cross validation. Each classification algorithm was implemented with Scikit-learn which is a free software machine learning library for the Python programming language, and the parameters of each algorithm were set by using the default. Tables III and IV demonstrate the efficiency of the different classification techniques performed in two datasets using the F-score measurement. Table III shows that LDA can achieve the high performance for dormant activities in both datasets. For energetic activities, LDA cannot deal with the non-linear data and overlapping data, so we decided to use Naïve Bayes in stead of LDA. Table IV demonstrates that SVM can obtain the best efficiency in overall.

V. CONCLUSIONS

In this research, we present the new activity recognition model using the streaming sensor data produced from the accelerometer and gyroscope embedded on smartwatches. The proposed model is a cross subjects approach or an impersonal activity recognition model. That means the model was built at once, and the new users can be utilized without requiring the training data from those users. For building the activity recognition, we examined varieties of machine learning algorithms. LDA and SVM presented the best results and were applied for dormant activities model and energetic activities model, respectively. In addition, the proposed model was carried out to examine the performance compared with the other models. From the results, the proposed model provides the overall performance in detection and prediction activities types. For a future research, we have planned to enhance S-PAR model to detect and predict the activities types more efficiency.

ACKNOWLEDGMENT

This work was financially supported by Research Grant of Burapha University through National Research Council of Thailand in Grant no. 141/2560 and no. 113/2561.

TABLE III: F-score measure metric for each classifier in dormant activities.

Activity Types	Classification techniques				
	Decision Tree	k-NN	Random forest	SVM	LDA
DS1					
Standing	98.35±2.55%	98.92±2.00%	98.50±2.25%	98.92±1.95%	98.92±2.00%
Sitting	98.61±2.06%	99.26±1.00%	98.79±1.70%	99.27±0.93%	99.27±1.00%
DS2					
Standing	71.30±12.90%	74.57±12.86%	74.60±13.02%	74.68±13.51%	75.43±15.18%
Sitting	55.63±22.28%	58.80±25.40%	52.48±23.00%	53.19±23.66%	69.51±27.57%
Lying	37.01±37.05%	43.01±62.13%	43.09±41.18%	46.26±37.71%	70.56±35.78%

TABLE IV: F-score measure metric for each classifier in energetic activities.

Activity Types	Classification techniques				
	Decision Tree	k-NN	Random forest	SVM	Naive Bayes
DS1					
Walking	52.79±22.6%	66.74±20.44%	66.48±27.21%	75.12±22.128%	66.40±33.54%
Stairs Up	55.41±9.89%	63.61±13.70%	68.26±11.05%	75.31±9.44%	61.15±22.92%
Stairs Down	71.66±11.56%	76.96±14.00%	81.71±9.11%	81.37±11.07%	68.81±20.38%
Running	98.62±1.51%	99.17±1.17%	99.17±0.94%	99.24±1.57%	97.71±4.05%
DS2					
Walking	54.20±10.61%	62.13±7.75%	64.00±9.22%	68.37±10.21%	63.22±12.59%
Stairs Up	40.75±12.16%	41.78±12.43%	43.96±13.82%	50.02±14.88%	29.30±17.15%
Stairs Down	62.74±9.82%	66.52±7.74%	68.68±10.41%	74.21±8.18%	54.58±16.95%
Running	89.04±9.86%	90.00±10.45%	89.91±10.00%	87.99±9.58%	87.65±11.03%

REFERENCES

- [1] I. Vuori, "World health organization and physical activity," *Progress in Preventive Medicine*, 2018.
- [2] A. Bonomi and K. Westertep, "Advances in physical activity monitoring and lifestyle interventions in obesity: A review," *International Journal of Obesity*, pp. 167–177, 2005.
- [3] M. Kheirkhahan, S. Nair, A. Davoudi, P. Rashidi, A. A. Wani-gatunga, D. B. Corbett, T. Mendoza, T. M. Manini, and S. Ranka, "A smartwatch-based framework for real-time and online assessment and mobility monitoring," *Journal of Biomedical Informatics*, pp. 29–40, 2019.
- [4] A. Bayat, M. Pomplun, and D. A. Tran, "A study on human activity recognition using accelerometer data from smartphones," *Procedia Computer Science*, pp. 450–457, 2014.
- [5] T. Dungkaew, J. Suksawatchon, and U. Suksawatchon, "Impersonal smartphone-based activity recognition using the accelerometer sensory data," in *2017 2nd International Conference on Information Technology (InCIT)*, 2017, pp. 1–6.
- [6] Y. Lu, Y. Wei, L. Liu, J. Zhong, L. Sun, and Y. Liu, "Towards unsupervised physical activity recognition using smartphone accelerometers," *Multimedia Tools and Applications*, pp. 10701–10719, 2017.
- [7] M. Shoaib, S. Bosch, H. Scholten, P. J. M. Havinga, and O. D. Incel, "Towards detection of bad habits by fusing smartphone and smartwatch sensors," in *2015 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops)*, 2015, pp. 591–596.
- [8] T. Szyler, H. Stuckenschmidt, and W. Petrich, "Position-aware activity recognition with wearable devices," *Pervasive and mobile computing*, pp. 281–295, 2017.
- [9] F. G. da Silva and E. Galeazzo, "Accelerometer based intelligent system for human movement recognition," in *5th IEEE International Workshop on Advances in Sensors and Interfaces IWASI*, 2013, pp. 20–24.
- [10] F. Shahmohammadi, A. Hosseini, C. E. King, and M. Sarrafzadeh, "Smartwatch based activity recognition using active learning," in *Proceedings of the Second IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies*. IEEE Press, 2017, pp. 321–329.
- [11] Y. Kwon, K. Kang, and C. Bac, "Unsupervised learning for human activity recognition using smartphone sensors," *Expert Systems with Applications*, pp. 6067–6074, 2014.
- [12] M. T. Uddin, M. M. Billah, and M. F. Hossain, "Random forests based recognition of human activities and postural transitions on smartphone," in *2016 5th International Conference on Informatics*, 2016, pp. 250–255.
- [13] A. M. Khan, A. Tufail, A. M. Khattak, and T. H. Laine, "Activity recognition on smartphones via sensor-fusion and kda-based svms," *International Journal of Distributed Sensor Networks*, 2014.
- [14] M. Shoaib, S. Bosch, O. Incel, H. Scholten, and P. Havinga, "Complex human activity recognition using smartphone and wrist-worn motion sensors," *Sensors*, p. 426, 2016.
- [15] M.-C. Kwon and S. Choi, "Recognition of daily human activity using an artificial neural network and smartwatch," *Wireless Communications and Mobile Computing*, 2018.

INCIT 2019

4th International Conference on Information Technology

Certificate of Presentation

This is to certify that

Katika Kongsil

had presented paper entitled

Physical Activity Recognition Using Streaming Data from Wrist-worn Sensors

in

2019 4th International Conference on Information Technology

Organized by Faculty of Information Technology, Thai-Nichi Institute of Technology

and Council of IT Deans of Thailand, 24th-25th October 2019.



Assoc. Prof. Dr. Ruttikom Varakulsiripunth
Dean of Faculty of Information Technology
President of Council of IT Deans of Thailand





InCIT 2020

October 21 -22

@Bangsaen, Chonburi, Thailand

IEEE THAILAND SECTION ECTI Association สคทส. CITT

- Artificial Intelligence
- Data Science and Analytics
- Cloud Service and Computing
- Communications and Networking
- Computer Animation and Game
- Digital Multimedia Technology
- Database Technology
- E-Commerce, E-Education,
E-Government, E-Industry,
E-Society
- Geo-informatics
- Human Computer Interaction
- IT in Education
- IT and Project Management
- IT Security and Privacy
- IT and Mobile Application
- Image Processing
- Intelligence Communications
- Internet of Things
- Network Security and Privacy
- Augmented and Virtual Reality
- Pattern Recognition
- Platform Technologies
- Quantum Computing
- Signal Processing
- Natural Language Processing
- Bio-medical Informatics
- Smart and Expert Systems
- Web and Internet Technologies
- Wireless and Mobile Networks
- Other Related Topics

Call For Papers

Important Date



Please: note: Due to the Coronavirus (COVID19) situation in Thailand and around the world, the organizers of the conference understand there are safety concerns for both authors and participants. In response to this, we have two presentation channels: one for online presentations, and another for onsite presentations. Even if you cannot be present, do not let that dissuade you from submitting a paper, since you can still present it in the online channel. Presentation slots will be allocated and authors will be informed after final judgment of the submitted papers.

Line Official

The Association of Council of IT Deans

Submission Website

<http://edas.info/N27427>



Wrist-worn Physical Activity Recognition: A Fusion Learning Approach

Katika Kongsil
Mobile Application Developers
Incubation Laboratory
Faculty of Informatics
Burapha University
 Chonburi, Thailand
 60910061@go.buu.ac.th

Jakkarin Suksawatchon
Mobile Application Developers
Incubation Laboratory
Faculty of Informatics
Burapha University
 Chonburi, Thailand
 jakkarin@go.buu.ac.th

Ureerat Suksawatchon
Mobile Application Developers
Incubation Laboratory
Faculty of Informatics
Burapha University
 Chonburi, Thailand
 ureerat@go.buu.ac.th

Abstract—With the advantages of technology in sensors on wrist-worn devices, many researchers have investigated and utilized the signals to recognize the physical activity in a living context. However, these studies are still faced with challenging problems, especially improving the recognition rate. Without using the recorded sensor data of target subjects, we aim to create a cross-subject activity recognition framework composed of three important models by using the fusion approach of machine learning. Performance was tested on four public datasets with different window sizes. Our experimental results demonstrate that our proposed framework achieves the highest recognition rate when compared with state-of-the-art models. In some datasets, our framework achieves more than 80% success in the recognition rate. In the other datasets, our proposed model can achieve up to 90%. In summary, our proposed framework is capable of being an activity recognition tool for classifying and identifying the physical activities in real world scenarios.

Index Terms—Activity recognition, Wearable sensors, Cross-subjects approach, Machine learning, Pattern recognition

I. INTRODUCTION

Nowadays, wearable devices with embedded sensors play an important role in various applications like sports tracking, health monitoring, etc. The embedded sensors such as accelerometers, magnetometers, gyroscope, etc. produce real-time streaming signals data, and many studies have used these signals to classify or identify human activity in daily life.

Recently, there has been much research focusing on Human Activity Recognition (HAR) based on real-time streaming signals produced from wearable devices. Most of the existing activity recognition models were built depending on the subject. This is called a subject-specific approach. The subject who uses the model must collect data and label them using a mobile application by performing the activities in a period of time within a controlled environment. The subject-specific model is not suitable in practice, especially for elders who may be unable to perform all of the required activities. In addition, some research [1], introduces the HAR method using multiple sensors placed at different body positions, such as on the head, upper arm, forearm, waist, thigh, and shin. The research [2] concluded that an accelerometer sensor attached to the waist

is the most suitable location in real-world scenarios. The study of [3] reported that the multiple accelerometers placed on the ankle and wrist show superior classification performance. However, these proposed models cannot be utilized in real-world scenarios because of the inconvenience and discomfort of wearing the sensors in daily life.

To achieve high performance, the ideas of segmentation of the sampling data into sliding windows and extraction of the feature vector for each sliding window are utilized. Most of the existing research applies the sliding window with 50% overlapping and consider window sizes of between one and three seconds [2]. For generating features in each sliding window, time and frequency domain features are commonly used, and then feature selection is applied to select the relevant features for activity classification. For example, the study of [4] applies a Correlation-Based Feature selection (CBF) technique to extract and select the 45 features from each accelerometer. The research of [5] uses the Sequential Floating Forward Selection (SFFS) to select 216 features from the three axes of three sensors, then the studies apply the extracted and selected features to classify all kinds of activities. Actually, each activity has different characteristic data, therefore it should be applied with different features related to the type of activities.

In this paper, we introduce a new physical activity recognition framework based on the combination of accelerometer and gyroscope sensors attached to wrist-worn devices. Our framework is composed of three models including (i) the *activity types model* used to categorize the activities into energetic and dormant activities, (ii) the *energetic activities model* used to recognize the movement activities, and (iii) the *dormant activities model* used to identify stationary activity.

The main contributions of our framework are the following.

- Our proposed framework is a cross-subject approach which depends only on the annotated data of a certain person, except for the target user. Our three proposed models were trained using several public datasets in laboratory and various other settings.
- We investigated and conducted the experiment to show the effect of the different sliding window sizes with

overlapping by half and without overlapping.

- We show that the suitable features used to classify the activities based on the type of activities are able to recognize with higher performance using our framework than other comparing models.

II. RELATED WORK

Several state-of-the-art studies focused on physical activity recognition from wrist-worn sensors, aiming to find the important factors to achieve high performance such as data segmentation, feature extraction, feature selection, new strategy of machine learning, and different evaluation metrics. Konak et al. [6] analyzed the activity recognition performance obtained from a smartphone emulating a wrist-worn device with embedded sensors, particularly focusing on the accelerometer and gyroscope sensors. This work also investigated the use of different features including motion, orientation, and rotation features in activity recognition both singly and in combination. Different classification techniques were utilized, such as Naive Bayes (NB), Decision Tree (DT), and Random Forest (RF). The recognition results show that the orientation features with the random forest can achieve the highest average accuracy. However, the classification results in walking activity patterns (walking, walking upstairs, and walking downstairs) yield poor performance.

Chowdhury et al. [4] investigated and compared several single classifier and ensemble methods which were based on data from a wrist-worn accelerometer sensor. The datasets were obtained from both public dataset and their own datasets collected in a laboratory environment. Three machine learning algorithms were compared to evaluate the performance of both the single classifier algorithms and conventional ensemble methods. The single classifier algorithms studied were K-nearest neighbors (KNN), binary decision tree (BDT), support vector machines (SVM), and artificial neural networks (ANN). Three conventional ensemble methods used were bagging, boosting, and random forests. The final prediction result was made with a combination of three methods: weighted majority vote (WMV), naive Bayes combiner, and behavior knowledge space (BKS). The whole process starts with the preprocessing, feature extraction, normalization and feature selection, and modeling, respectively. The evaluation results demonstrated that the conventional ensemble methods outperform the other methods. However, there are some limitations for utilization in real-time activity recognition, such as an excessive window size and using the dataset in a predetermined sequence of activities.

The other activity recognition framework [3] emphasized the use of weighted decision fusion to effectively combine multiple accelerometer data, named the posterior-adapted class-based weighted decision fusion, to improve the final activity class prediction. Two public datasets were used in this study and obtained from accelerometer sensors on three body positions: ankle, chest, and wrist. This framework was extended from the study of Chowdhury et al. [4] by adding the SVM approach as a baseline classification algorithm and

proposed a process of calculating decision fusion class-based weights, which the confidence score for each model based on training and test data. The experiments were conducted on both single and all combinations of accelerometer positions. The classification performance was compared with the baseline algorithm and other decisions using fusion techniques. The classification results show the combination of accelerometers located on the ankle and wrist achieve the highest average performance. The performance of using only a single wrist-worn accelerometer position was significantly less accurate than the other positions, especially for the accuracy of movement activities such as walking and stairs activities.

Ayman et al. [5] proposed an activity recognition framework using three wrist-worn sensors including an accelerometer, gyroscope, and magnetometer. The eighteen time-domain features were extracted from the three axes and the magnitude of each sensor (216 features). Then they applied SFFS to determine the optimal feature sets. 10-fold cross-validation was used to evaluate three machine learning algorithms (SVM, DT, RF). The results show that the RF classifier achieves a high recognition rate. The lack of evaluation metrics and validation like cross-validation leads to overestimating the performance which is not appropriate for unseen data in a real-time system. Lu et al. [7] proposed the multiscale features approach for human activity recognition called MFE-HAR, which exploits the global and local scales from the combination of data from accelerometer and gyroscope sensors on a single wrist-worn device. Two public datasets from different wrist-worn devices were analyzed. Five machine learning algorithms were compared: the gradient boosting decision tree (GBDT), random forest, logistics regression, support vector machine, and K-nearest neighbors. The results show the GBDT learning model performed the best. However, the feature extraction process is too complicated and may not be suitable to apply in a real-time system.

III. PROPOSED FRAMEWORK

In this section, we describe our proposed activity recognition framework which consists of the modeling and recognition components. The modeling component is built based on three models: *activity types*, *energetic activities*, and *dormant activities models*. Each of them uses different features and machine learning strategies as shown in Fig 1. The recognition component aims to identify the physical activity type of incoming data streams produced from sensors, and then classifies the data into a predicted activity as illustrated in Fig 3. Our proposed framework was implemented by using Scikit-learn which is an open-source machine learning system written in the Python programming language.

A. Sensory data

The authors of this study selected four public datasets for human activity recognition. A description of each dataset is provided in Table I. Those datasets were collected from embedded sensors on wearable devices like smartphones, smartwatches, and inertial measurement units (IMU). The

TABLE I: A description of each of the wrist-worn datasets

Dataset	Number of Subjects	Environment	Wrist worn device	Sampling rate	Dormant physical activity selected	Energetic physical activities selected
REALWORLD [8]	10	Out-of-lab	LG G Watch R smartwatch at forearm	50Hz	Standing, sitting, lying down	Walking, ascending stairs, descending stairs, running
Research Work [9]	10	Laboratory	Samsung Galaxy s2 Smartphones at right wrist	50Hz	Standing, sitting	Walking, ascending stairs, descending stairs, running, cycling
MHEALTH [10]	10	Out-of-lab	Shimmer Wearable sensor at right forearm	50Hz	Standing, sitting, lying down	Walking, stairs, running, jogging, cycling
WISDM [11]	48	Laboratory	LG G Watch smartwatch at dominant wrist	20Hz	Standing, sitting	Walking, stairs, jogging




Fig. 1: Modeling Component

subjects performed various activity types such as physical activity, transition activity, gesture activity, etc. in a specific time period. The data acquisition was set up with a variety of different conditions, such as the number of wearable devices or sensors, the positions of those sensors, sensor specifications, the environment (in laboratory or out-of-lab in a real situation), and biological characteristics of the subjects. For the purposes of this study, we used sensory data acquired from tri-axial accelerometer and tri-axial gyroscope sensors embedded on a wrist-worn device. Samples of sensory data are illustrated in Table II, and Fig. 2 shows the characteristics acceleration values of energetic and dormant activities.

B. Data Preprocessing

To handle non-steady-state data, we cut off about 10 seconds from the beginning and end of the sensory data. Linear interpolation is used to fill in missing data for some datasets which had missing sensor data. To reduce the noise and minimize the effect of random errors, we then applied the moving average method with a window length of 4 data points

TABLE II: Samples of sensory data in the WISDM dataset

Sample	Label	A_x	A_y	A_z	G_x	G_y	G_z
s_1	Walking	12.28	-1.86	0.48	-1.89	-3.01	-5.83
s_2	Walking	15.64	-1.69	0.77	-0.67	-2.57	-6.30
s_3	Walking	15.86	-2.35	0.15	0.73	-1.60	-5.91
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Walking	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
s_N	Walking	A_{x_N}	A_{y_N}	A_{z_N}	G_{x_N}	G_{y_N}	G_{z_N}

of raw data for each sensor axis and each activity. That is, the smoothed data at time t is obtained by averaging values of the streaming data within a specified window length as shown in Eq. 1.

$$x_s(t) = \frac{1}{n} \sum_{i=t-n}^{t-1} x(i) \quad (1)$$

Where x is the raw vector, x_s is the smoothed vector, and n is the window length.

C. Modeling Component

In this component, we categorize the physical activity into two types including *dormant* and *energetic* activities by considering the pattern of sensor data. The characteristics of the signal data of dormant activities (standing, sitting, and lying) is rather stationary. On the other hand, the signal data of energetic activities (walking and running) are highly vibrant. The Modeling Component aims to build classifier models for classifying the physical activity categories (dormant or energetic activities), and also the models for identifying the individual physical activities. After performing the smoothing of the data in the Data Preprocessing stage, the following steps proceeded over a sliding window with 50% overlapping and without overlapping:

1) *Building the Physical Activity Types Model*: We built the model to classify the binary activity classes between dormant or energetic activities. First, we calculated the magnitude of the signal for each axis of the accelerometer and gyroscope signals over a sliding window as shown in Eq. 2 and extracted the standard deviation of magnitude using Eq. 3 [12]. These

TABLE I: A description of each of the wrist-worn datasets

Dataset	Number of Subjects	Environment	Wrist worn device	Sampling rate	Dormant physical activity selected	Energetic physical activities selected
REALWORLD [8]	10	Out-of-lab	LG G Watch R smartwatch at forearm	50Hz	Standing, sitting, lying down	Walking, ascending stairs, descending stairs, running
Research Work [9]	10	Laboratory	Samsung Galaxy s2 Smartphones at right wrist	50Hz	Standing, sitting	Walking, ascending stairs, descending stairs, running, cycling
MHEALTH [10]	10	Out-of-lab	Shimmer Wearable sensor at right forearm	50Hz	Standing, sitting, lying down	Walking, stairs, running, jogging, cycling
WISDM [11]	48	Laboratory	LG G Watch smartwatch at dominant wrist	20Hz	Standing, sitting	Walking, stairs, jogging

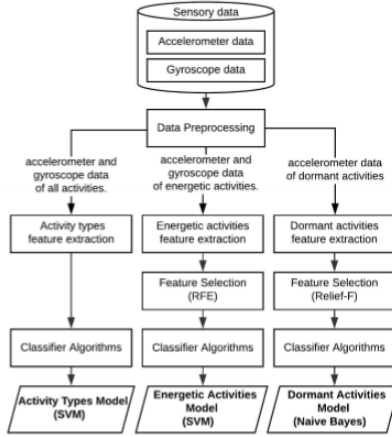


Fig. 1: Modeling Component

subjects performed various activity types such as physical activity, transition activity, gesture activity, etc. in a specific time period. The data acquisition was set up with a variety of different conditions, such as the number of wearable devices or sensors, the positions of those sensors, sensor specifications, the environment (in laboratory or out-of-lab in a real situation), and biological characteristics of the subjects. For the purposes of this study, we used sensory data acquired from tri-axial accelerometer and tri-axial gyroscope sensors embedded on a wrist-worn device. Samples of sensory data are illustrated in Table II, and Fig. 2 shows the characteristics acceleration values of energetic and dormant activities.

B. Data Preprocessing

To handle non-steady-state data, we cut off about 10 seconds from the beginning and end of the sensory data. Linear interpolation is used to fill in missing data for some datasets which had missing sensor data. To reduce the noise and minimize the effect of random errors, we then applied the moving average method with a window length of 4 data points

TABLE II: Samples of sensory data in the WISDM dataset

Sample	Label	A_x	A_y	A_z	G_x	G_y	G_z
s_1	Walking	12.28	-1.86	0.48	-1.89	-3.01	-5.83
s_2	Walking	15.64	-1.69	0.77	-0.67	-2.57	-6.30
s_3	Walking	15.86	-2.35	0.15	0.73	-1.60	-5.91
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
s_i	Walking	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
s_N	Walking	A_{x_N}	A_{y_N}	A_{z_N}	G_{x_N}	G_{y_N}	G_{z_N}

of raw data for each sensor axis and each activity. That is, the smoothed data at time t is obtained by averaging values of the streaming data within a specified window length as shown in Eq. 1.

$$x_s(t) = \frac{1}{n} \sum_{i=t-n}^{t-1} x(i) \quad (1)$$

Where x is the raw vector, x_s is the smoothed vector, and n is the window length.

C. Modeling Component

In this component, we categorize the physical activity into two types including *dormant* and *energetic* activities by considering the pattern of sensor data. The characteristics of the signal data of dormant activities (standing, sitting, and lying) is rather stationary. On the other hand, the signal data of energetic activities (walking and running) are highly vibrant. The Modeling Component aims to build classifier models for classifying the physical activity categories (dormant or energetic activities), and also the models for identifying the individual physical activities. After performing the smoothing of the data in the Data Preprocessing stage, the following steps proceeded over a sliding window with 50% overlapping and without overlapping:

1) *Building the Physical Activity Types Model*: We built the model to classify the binary activity classes between dormant or energetic activities. First, we calculated the magnitude of the signal for each axis of the accelerometer and gyroscope signals over a sliding window as shown in Eq. 2 and extracted the standard deviation of magnitude using Eq. 3 [12]. These

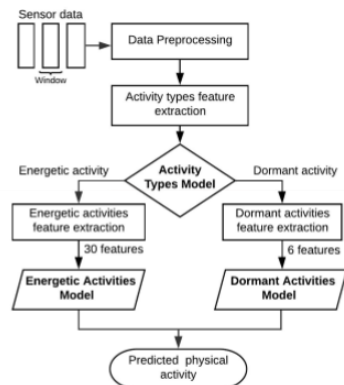


Fig. 3: Recognition Component

used for building the dormant activities model. In this study, we tested the performance with five classifier models: KNN, DT, SVM, RF, and Naïve Bayes. Naïve Bayes with Gaussian distribution yielded the best performance and was selected as the dormant activities model.

D. Recognition Component

In this component, we describe how to utilize the models built from the Modeling Component to classify the activity of the incoming data. All of the recognition component processes are illustrated in Fig.3. To simulate a real-time environment, the testing data was used as streaming data. The testing data was streamed and segmented over a sliding window as a small data fragment j . Then, each fragment was executed in the following steps.

Step 1: Each axis of the accelerometer and gyroscope data was smoothed by using a moving average in the data preprocessing stage. Then, the smoothed signals were extracted as two features, the magnitude (M_i) and the standard deviation SD_j , by using Eq. 2 and Eq. 3.

Step 2: The data fragment was assigned as one of the activity categories which was the dormant activity or energetic activity by using the activity types model.

Step 3: Then, the data fragment was extracted the features based on the assigned activity category.

Step 4: Finally, the features of such data fragment were identified as the physical activity label by using the energetic activities model or dormant activities model.

IV. EXPERIMENTAL RESULTS AND DISCUSSION

In this section, we present the evaluation of our proposed framework by comparing it with state-of-the-art activity recognition models and also reporting the experimental activity recognition results for four datasets.

A. Experiment setup

Since our proposed framework was developed based on a cross-subject approach, we evaluated the performance of our framework with leave-one-subject-out cross-validation. In each round, only the data of one subject (a target user) was used for testing. The remaining subjects' data were used for training models. This guaranteed that the sensor data of each subject was used once for testing. The F1-score was used to measure the recognition rate of our proposed framework. The F1-score was computed as follows:

$$F1 - score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \times 100 \quad (4)$$

In this study, we compared our proposed system with state-of-the-art study [4] with four public datasets. From the research [4], we selected the three classification algorithms which achieved the best performance on each learning method strategy including the single support vector machines (SVM), the random forest (RF), and the weighted majority vote (WMV). They conducted the experiments by extracting 45 features from the accelerometer data over a 10-seconds sliding window with 50% overlapping, and then applied the feature normalization and used the CBF feature selection before classification process. So we designed our experiments by using sliding window sizes of 2s and 10s over 50% overlapping and without overlapping windows to investigate the effects of the different window sizes.

B. Performance Evaluation

Table IV shows the average and standard deviation of the F1-score metrics for all physical activities of each public dataset. From this table, we can conclude that our proposed framework gives the best performance among all models evaluated. Our framework achieved good results of up to an 80% recognition rate in three datasets, while the Real-World dataset [8] achieves the lowest (>75%) recognition rate. However, this performance is reasonable, because the RealWorld dataset was collected under free-context living. When considering the effect of each window size, for the RealWorld dataset [8] the window size of 10-second had the highest recognition rate for both the overlapping and without overlapping cases. Considering the dataset in Research Work [9] and the WISDM [11] dataset, the results indicate that the window size of 10-second gives the highest performance in both overlapping and without overlapping cases as well. In contrast, in the MHEALTH [10] dataset the 2-second window size without overlapping achieved an average recognition rate of 90%, which was the highest performance for this dataset. We can summarize our results by stating that large, overlapping windows achieved the highest performance. However, this is a trade-off with higher computation time. Furthermore, the window size also depends on the kind of datasets used to build the activity recognition models.

TABLE IV: The performance of our proposed framework compared with competing models on four public datasets

Datasets	Sliding window	Average F1-score metric of each model			
		SVMs	RF	WMV	Our framework
RealWorld	2-second without overlapping	70.68±14.34%	69.25±11.40%	72.98±13.39%	74.65±10.93%
	2-second overlapping	71.16±13.95%	68.53±11.93%	72.42±13.50%	75.26±10.16%
	10-second without overlapping	71.97±14.11%	72.64±14.00%	73.06±12.61%	77.03±10.63%
	10-second overlapping	71.71±14.90%	72.08±14.62%	74.82±14.15%	77.19±10.38%
Research Work [9]	2-second without overlapping	88.51±13.81%	84.46±17.94%	88.90±13.19%	92.08±7.64%
	2-second overlapping	87.99±14.45%	85.23±16.23%	88.73±13.56%	92.50±6.95%
	10-second without overlapping	91.36±9.46%	87.87±13.56%	90.72±10.47%	92.35±6.31%
	10-second overlapping	91.26±9.49%	89.83±11.03%	91.75±8.16%	93.34±5.77%
MHEALTH	2-second without overlapping	81.83±6.33%	79.89±13.26%	84.07±8.09%	90.62±8.91%
	2-second overlapping	82.14±6.02%	80.67±12.92%	84.66±8.09%	89.75±8.82%
	10-second without overlapping	84.29±7.79%	81.66±9.66%	86.68±7.53%	89.74±8.50%
	10-second overlapping	84.12±6.87%	82.55±11.52%	86.04±8.07%	89.43±9.99%
WISDM	2-second without overlapping	81.66±9.84%	83.24±9.49%	79.57±8.06%	83.47±8.06%
	2-second overlapping	79.48±10.75%	81.63±10.37%	79.46±9.70%	84.38±8.04%
	10-second without overlapping	84.25±8.24%	82.80±9.91%	85.17±7.72%	87.41±6.79%
	10-second overlapping	83.74±8.60%	82.63±9.84%	85.43±7.73%	87.20±6.70%

V. CONCLUSION

This study introduces a new activity recognition framework to improve the performance of daily physical activity recognition from accelerometer and gyroscope sensors on a wrist-worn device. The proposed system has three models: the activity types, dormant activities, and the energetic activities models with a fusion approach of machine learning techniques. To evaluate the performance, we tested against the other models using different window sizes. The experiments performed depended on large public datasets that consist of events collected by people performing different physical activities and were evaluated with leave-one-subject-out cross validation. In summary, the experimental results prove that our framework outperforms the other models considered. Using the cross-subjects approach, our models identified the activities of the target user with higher accuracy. In addition, the features obtained from RFE and ReliefF selection methods were able to classify the different activities with a high recognition rate. Our proposed framework is a feasible and reliable tool for classifying and identifying physical activities in real-world situations. In future work, we plan to improve the performance by incorporating personalized data.

ACKNOWLEDGMENT

This work was financially supported by the Research Grant of Burapha University through the National Research Council of Thailand in Grant no. 141/2560 and no. 113/2561.

REFERENCES

- [1] A. Vahdatpour, N. Amini, and M. Sarrafzadeh, "On-body device localization for health and medical monitoring applications," in *2011 IEEE International Conference on Pervasive Computing and Communications (PerCom)*. IEEE, 2011, pp. 37–44.
- [2] T. Szttyler, H. Stuckenschmidt, and W. Petrich, "Position-aware activity recognition with wearable devices," *Pervasive and mobile computing*, vol. 38, pp. 281–295, 2017.
- [3] A. K. Chowdhury, D. Tjondronegoro, V. Chandran, and S. G. Trost, "Physical activity recognition using posterior-adapted class-based fusion of multiaccelerometer data," *IEEE journal of biomedical and health informatics*, vol. 22, no. 3, pp. 678–685, 2017.
- [4] —, "Ensemble methods for classification of physical activities from wrist accelerometry," *Medicine & Science in Sports & Exercise*, vol. 49, no. 9, pp. 1965–1973, 2017.
- [5] A. Ayman, O. Attalah, and H. Shaban, "An efficient human activity recognition framework based on wearable imu wrist sensors," in *2019 IEEE International Conference on Imaging Systems and Techniques (IST)*. IEEE, 2019, pp. 1–5.
- [6] S. Konak, F. Turan, M. Shoab, and Ö. D. Incel, "Feature engineering for activity recognition from wrist-worn motion sensors," in *PECCS*, 2016, pp. 76–84.
- [7] J. Lu, X. Zheng, Q. Z. Sheng, Z. Hussain, J. Wang, and W. Zhou, "Mfe-har: multiscale feature engineering for human activity recognition using wearable sensors," in *Proceedings of the 16th EA International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, 2019, pp. 180–189.
- [8] T. Szttyler and H. Stuckenschmidt, "On-body localization of wearable devices: An investigation of position-aware activity recognition," in *2016 IEEE International Conference on Pervasive Computing and Communications (PerCom)*. IEEE, 2016, pp. 1–9.
- [9] M. Shoab, H. Scholten, and P. J. Havinga, "Towards physical activity recognition using smartphone sensors," in *2013 IEEE 10th international conference on ubiquitous intelligence and computing and 2013 IEEE 10th international conference on autonomic and trusted computing*. IEEE, 2013, pp. 80–87.
- [10] O. Banos, R. Garcia, J. A. Holgado-Terriza, M. Damas, H. Pomares, I. Rojas, A. Saez, and C. Villalonga, "inhealthroid: a novel framework for agile development of mobile health applications," in *International workshop on ambient assisted living*. Springer, 2014, pp. 91–98.
- [11] G. M. Weiss, K. Yoneda, and T. Hayajneh, "Smartphone and smartwatch-based biometrics using activities of daily living," *IEEE Access*, vol. 7, pp. 133 190–133 202, 2019.
- [12] K. Kongsil, J. Suksawatchon, and U. Suksawatchon, "Physical activity recognition using streaming data from wrist-worn sensors," in *2019 4th International Conference on Information Technology (InCIT)*. IEEE, 2019, pp. 274–279.
- [13] Q. Chen, Z. Meng, X. Liu, Q. Jin, and R. Su, "Decision variants for the automatic determination of optimal feature subset in rf-rfe," *Genes*, vol. 9, no. 6, p. 301, 2018.
- [14] S. Fan, Y. Jia, and C. Jia, "A feature selection and classification method for activity recognition based on an inertial sensing unit," *Information*, vol. 10, no. 10, p. 290, 2019.



CERTIFICATE OF CONTRIBUTIONS

KATIKA KONGSIL, UREERAT SUKSAWATCHON AND JAKKARIN SUKSAWATCHON
ENTITLED

WRIST-WORN PHYSICAL ACTIVITY RECOGNITION: A FUSION LEARNING APPROACH

HAS CONTRIBUTED TO

THE 5TH INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY: INCIT2020
OCTOBER 21 – 22, 2020
THE TIDE RESORT, BANGSAEN BEACH, CHONBURI, THAILAND

V. Rattana

RUTTIKORN VARAKULSIRIPUNTH, PH.D.
PRESIDENT OF THE ASSOCIATION OF COUNCIL OF IT DEANS



บรรณานุกรม

- Ahmed, N., Rafiq, J. I., & Islam, M. R. (2020). Enhanced human activity recognition based on smartphone sensor data using hybrid feature selection model. *Sensors*, 20(1), 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.
- Banos, O., Garcia, R., Holgado-Terriza, J. A., Damas, M., Pomares, H., Rojas, I., . . . Villalonga, C. (2014). *mHealthDroid: a novel framework for agile development of mobile health applications*. Paper presented at the International workshop on ambient assisted living.
- 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.
- Capela, N. A., Lemaire, E. D., & Baddour, N. (2015). Feature selection for wearable smartphone-based human activity recognition with able bodied, elderly, and stroke patients. *PloS one*, 10(4), e0124414.
- 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.
- Chowdhury, A. K., Tjondronegoro, D., Chandran, V., & Trost, S. G. (2017). Ensemble methods for classification of physical activities from wrist accelerometry. *Medicine & Science in Sports & Exercise*.
- Chowdhury, A. K., Tjondronegoro, D., Chandran, V., & Trost, S. G. (2018). Physical activity recognition using posterior-adapted class-based fusion of multiaccelerometer data. *IEEE journal of biomedical and health informatics*, 22(3), 678-685.
- 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.

Dehghani, A., Glatard, T., & Shihab, E. (2019). Subject Cross Validation in Human Activity Recognition. *arXiv preprint arXiv:1904.02666*.

Demrozi, F., Pravadelli, G., Bihorac, A., & Rashidi, P. (2020). Human activity recognition using inertial, physiological and environmental sensors: a comprehensive survey. *IEEE Access*.

Fan, S., Jia, Y., & Jia, C. (2019). A feature selection and classification method for activity recognition based on an inertial sensing unit. *Information*, 10(10), 290.

Ferrari, A. (2020). Personalization of Human Activity Recognition Methods using Inertial Data.

Figo, D., Diniz, P. C., Ferreira, D. R., & Cardoso, J. M. (2010). Preprocessing techniques for context recognition from accelerometer data. *Personal and Ubiquitous Computing*, 14(7), 645-662.

Garcia-Ceja, E., & Brena, R. (2013). Long-term activity recognition from accelerometer data. *Procedia Technology*, 7, 248-256.

Gu, Q., Li, Z., & Han, J. (2012). Generalized fisher score for feature selection. *arXiv preprint arXiv:1202.3725*.

Guyon, I., Weston, J., Barnhill, S., & Vapnik, V. (2002). Gene selection for cancer classification using support vector machines. *Machine learning*, 46(1), 389-422.

Hadjerci, O., Hafiane, A., Conte, D., Makris, P., Veyres, P., & Delbos, A. (2016). Computer-aided detection system for nerve identification using ultrasound images: a comparative study. *Informatics in Medicine Unlocked*, 3, 29-43.

Kwon, M.-C., & Choi, S. (2018). Recognition of Daily Human Activity Using an Artificial Neural Network and Smartwatch. *Wireless Communications and Mobile Computing*, 2018.

Kwon, Y., Kang, K., & Bae, C. (2014). Unsupervised learning for human activity recognition using smartphone sensors. *Expert Systems with Applications*, 41(14), 6067-6074.

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. Retrieved from

<https://www.mdpi.com/1424-8220/15/10/26783/pdf>

- 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.
- Reiss, A., & Stricker, D. (2013). *Personalized mobile physical activity recognition*. Paper presented at the Proceedings of the 2013 international symposium on wearable computers.
- Saez, Y., Baldominos, A., & Isasi, P. (2017). A comparison study of classifier algorithms for cross-person physical activity recognition. *Sensors*, 17(1), 66.
- 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., Scholten, H., & Havinga, P. (2014). Fusion of smartphone motion sensors for physical activity recognition. *Sensors*, 14(6), 10146-10176.
- 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., Scholten, H., & Havinga, P. J. (2013). *Towards physical activity recognition using smartphone sensors*. Paper presented at the 2013 IEEE 10th international conference on ubiquitous intelligence and computing and 2013 IEEE 10th international conference on autonomic and trusted computing.
- Sztyler, T., & Stuckenschmidt, H. (2016). *On-body localization of wearable devices: An investigation of position-aware activity recognition*. Paper presented at the 2016 IEEE International Conference on Pervasive Computing and Communications (PerCom).
- Sztyler, T., Stuckenschmidt, H., & Petrich, W. (2017). *Position-aware activity recognition with wearable devices*. (38).
- Therdsak, D., Jakkarin, S., & Ureerat, S. (2017). *Impersonal smartphone-based activity recognition using the accelerometer sensory data*. Paper presented at the 2017

2nd International Conference on Information Technology (INCIT).

Tian, Y., Zhang, J., Wang, J., Geng, Y., & Wang, X. (2020). Robust human activity recognition using single accelerometer via wavelet energy spectrum features and ensemble feature selection. *Systems Science & Control Engineering*, 8(1), 83-96.

Uddin, M. T., Billah, M. M., & Hossain, M. F. (2016). *Random forests based recognition of human activities and postural transitions on smartphone*. Paper presented at the 2016 5th International Conference on Informatics, Electronics and Vision (Iciev).

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).

Weiss, G. M., Yoneda, K., & Hayajneh, T. (2019). Smartphone and smartwatch-based biometrics using activities of daily living. *IEEE Access*, 7, 133190-133202.

ประวัติย่อของผู้วิจัย

ชื่อ-สกุล	กตติกา กองศีล
วัน เดือน ปี เกิด	28 พฤษภาคม 2538
สถานที่เกิด	จังหวัดแพร่
สถานที่อยู่ปัจจุบัน	บ้านเลขที่ 209 หมู่ที่ 2 ตำบลไทรย้อย อำเภอดงช้าง จังหวัดแพร่ 54110
ตำแหน่งและประวัติการ ทำงาน	วิทยาศาสตร์บัณฑิต สาขาวิทยาการคอมพิวเตอร์ คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา
ประวัติการศึกษา	ประถมศึกษา โรงเรียนเทพนารีจังหวัดแพร่ มัธยมศึกษาตอนต้น โรงเรียนพิริยาลัยจังหวัดแพร่ มัธยมศึกษาปลาย โรงเรียนพิริยาลัยจังหวัดแพร่ ปริญญาตรี วิทยาศาสตร์บัณฑิต สาขาวิทยาการ คอมพิวเตอร์ คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา