

เทคนิคการลดมิติแบบใหม่สำหรับการรู้จำกิจกรรมทางกายภาพ  
จากสัญญาณเซนเซอร์วัดความเร่งที่ถูกติดที่เอว

A NOVEL DIMENSION REDUCTION TECHNIQUE FOR PHYSICAL ACTIVITY  
RECOGNITION FROM A WAIST-MOUNTED ACCELEROMETER



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมชีวการแพทย์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2559

KMITL-2016-EN-M-045-119

เทคนิคการลดมิติแบบใหม่สำหรับการรู้จำกิจกรรมทางกายภาพ  
จากสัญญาณเซนเซอร์วัดความเร่งที่ถูกติดที่เอว

## A NOVEL DIMENSION REDUCTION TECHNIQUE FOR PHYSICAL ACTIVITY RECOGNITION FROM A WAIST-MOUNTED ACCELEROMETER



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมชีวการแพทย์  
คณะวิศวกรรมศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
พ.ศ.2559  
KMITL-2016-EN-M-045-119

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# **A NOVEL DIMENSION REDUCTION TECHNIQUE FOR PHYSICAL ACTIVITY RECOGNITION FROM A WAIST-MOUNTED ACCELEROMETER**

**BENJAWAN PRAPOCHANUNG**



**A THESIS SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF  
MASTER OF ENGINEERING IN BIOMEDICAL ENGINEERING  
FACULTY OF ENGINEERING  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG  
2016**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้





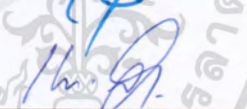


**COPYRIGHT 2016**  
**FACULTY OF ENGINEERING**  
**KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คณะวิศวกรรมศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
ใบรับรองวิทยานิพนธ์

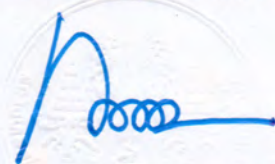
หัวข้อวิทยานิพนธ์ เทคนิคการลดมิติแบบใหม่สำหรับการรู้จำกิจกรรมทางกายภาพจากสัญญาณเซนเซอร์  
วัดความเร่งที่ถูกติดที่เอว  
Thesis Title A Novel Dimension Reduction Technique for Physical Activity Recognition  
from a Waist-Mounted Accelerometer  
นักศึกษา นางสาวเบญจวรรณ ประไพ์ชนิง  
รหัสประจำตัว 55612705  
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชา วิศวกรรมชีวการแพทย์  
อาจารย์ที่ปรึกษาวิทยานิพนธ์ ดร.เทอดศักดิ์ ลีหาทอง  
หมายเลขวิทยานิพนธ์ KMITL-2016-EN-M-045-119

คณะกรรมการสอบวิทยานิพนธ์	ลายมือชื่อ
ผศ.ดร.กิตติพล ชิตสกุล	
รศ.ดร.สุรพันธุ์ เอื้อไพบูลย์	
รศ.ดร.มนัส สัจจวิมล	
ผศ.ดร.สุพันธุ์ ตั้งจิตกุศลมั่น	
ดร.เทอดศักดิ์ ลีหาทอง	

วัน / เดือน / ปี ที่สอบ วันพุธที่ 13 กรกฎาคม พ.ศ. 2559 เวลา 09.30-11.30 น.  
สถานที่สอบ ณ อาคารเฉลิมพระเกียรติ ห้อง HM-304

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

คณะวิศวกรรมศาสตร์ รับรองแล้ว



(รองศาสตราจารย์ ดร. คมสัน มาลีสี)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษา **ฉบับนี้ คณะวิศวกรรมศาสตร์** ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และวันที่ 13 กรกฎาคม พ.ศ. 2559 นี้ที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์

เทคนิคการลดมิติแบบใหม่สำหรับการรู้จำกิจกรรมทางกายภาพจากสัญญาณเซนเซอร์วัดความเร่งที่ถูกติดที่เอว

นักศึกษา

นางสาวเบญจวรรณ ประไพ์ชนิ่ง

รหัสประจำตัว

55612705

ปริญญา

วิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชา

วิศวกรรมชีวการแพทย์

พ.ศ.

2559

อาจารย์ที่ปรึกษาวิทยานิพนธ์

ดร.เทอดศักดิ์ ลีวหาทอง

### บทคัดย่อ

วิทยานิพนธ์ฉบับนี้นำเสนอเทคนิคการลดมิติแบบใหม่สำหรับการรู้จำกิจกรรมทางกายภาพจากเซนเซอร์วัดความเร่งที่ถูกติดที่เอว อันดับแรกการแปลงเวฟเลตถูกใช้เพื่อที่จะดึงคุณลักษณะจากสัญญาณความเร่ง ต่อมาเทคนิคที่นำเสนอถูกใช้เพื่อที่จะลดมิติของคุณลักษณะเวฟเลต สุดท้ายโครงข่ายประสาทเทียมแบบหลายชั้นถูกใช้เพื่อรู้จำกิจกรรมทางกายภาพจากคุณลักษณะที่ถูกลดมิติ ในการทดลองของเราอาสาสมัคร 5 คน ที่มีสุขภาพแข็งแรง มีอายุระหว่าง 21 ถึง 25 ปี ถูกขอร้องให้ติดเซนเซอร์วัดความเร่งสามแกนไว้ที่เอวด้านขวา ต่อมาอาสาสมัครถูกขอร้องให้ทำกิจกรรมทางกายภาพในชีวิตประจำวัน 5 กิจกรรม คือ 1.) ลุกขึ้นจากที่นอน 2.) ล้มตัวลงบนที่นอน 3.) ลุกขึ้นจากเก้าอี้ 4.) นั่งลงบนเก้าอี้ 5.) การเดิน และเหตุการณ์การล้ม 5 กิจกรรม 1.) หกล้มไปด้านหน้า 2.) หกล้มไปด้านหลัง 3.) หกล้มไปด้านซ้าย 4.) หกล้มไปด้านขวา 5.) หกล้มในขณะที่กำลังลุกขึ้น เพื่อที่จะประเมินประสิทธิภาพของอัลกอริทึมที่นำเสนอ ความถูกต้องของการรู้จำและจำนวนตัวดำเนินการที่ใช้ทั้งหมดถูกนำมาใช้ ประสิทธิภาพของการรู้จำสำหรับการตั้งค่าที่แตกต่างกันของ mother wavelets, vanishing moments, ระดับการแยกองค์ประกอบเวฟเลต, อัตราการลดมิติ และจำนวนโหนดในชั้นซ่อนของโครงข่ายประสาทเทียมถูกใช้เพื่อประเมินผล จากการทดลองการลดมิติที่นำเสนอไม่เพียงแต่ลดจำนวนตัวดำเนินการที่ใช้แต่ยังเพิ่มความแม่นยำในการรู้จำอีกด้วย

<b>Thesis Title</b>	A Novel Dimension Reduction Technique for Physical Activity Recognition from a Waist-Mounted Accelerometer
<b>Student</b>	Miss Benjawan Prapochanung
<b>Student ID.</b>	55612705
<b>Degree</b>	Master of Engineering
<b>Program</b>	Biomedical Engineering
<b>Year</b>	2016
<b>Thesis Advisor</b>	Dr. Thursdak Leauhatong

## ABSTRACT

This thesis proposes a novel dimension reduction technique for physical activity recognition from a waist-mounted accelerometer. Firstly, the wavelet transform is used to extract features from the acceleration signals. Then the proposed technique is used to reduce the dimension of the wavelet features. Finally, the Multi-Layer Perceptron Neural Network (MLPNN) is used to recognize the physical activities from the reduced features. In our experiments, 5 volunteers who were healthy with the ages between 21 to 25 year old were asked to mount a tri-axial accelerometer at the right side of their waists. Next, the volunteers were asked to perform 5 daily-life physical activities: 1) getting up from a bed 2) lying down on a bed 3) standing up from a chair 4) sitting down on a chair and 5) walking; and 5 falling events: 1) forward fall 2) backward fall 3) falling to the left side 4) falling to the right side and 5) falling when standing up. In order to evaluate the performance of the proposed algorithm, the average precision of the recognition and the total number of the used operators were calculated. The performance of the recognition with different setting of mother wavelets, vanishing moments, decomposition level, the rate of the dimension reduction, and the number of nodes of the hidden layer were evaluated. From the experiments, the proposed dimension reduction not only reduce the total number of the used operators but also increase the precision of the recognition.

## กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จได้ด้วยความกรุณาจากอาจารย์ที่ปรึกษา ดร.เทอดศักดิ์ ลีมหาทอง ที่ให้ความช่วยเหลือ ให้คำชี้แนะช่วยแก้ปัญหาตลอดจนให้ความรู้และประสบการณ์ที่ดีแก่ข้าพเจ้า

ขอขอบพระคุณกรรมการสอบหัวข้อและโครงร่างวิทยานิพนธ์และคณาจารย์ภาควิชาวิศวกรรมอิเล็กทรอนิกส์ คณะวิศวกรรมศาสตร์ที่ได้กรุณาให้คำแนะนำตลอดจนข้อชี้แนะ จนในที่สุดทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลงได้

ขอขอบคุณ คุณอดุลย์เดช นิมนวล คุณธีรวัฒน์ นารณอดุม คุณนิติพัฒน์ ญัฐไธธนกุล และคุณพรชรัส นากอร่าม ที่คอยให้คำปรึกษาชี้แนะแนวทางการออกแบบอุปกรณ์และโปรแกรมสำหรับการทดลอง

ขอขอบคุณน้อง ๆ นักศึกษา ในห้องปฏิบัติการ และน้อง ๆ นักศึกษาสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังที่มีส่วนร่วมในการทดลอง

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับบิดามารดา ซึ่งเป็นที่รักและเคารพยิ่ง ตลอดจนครูอาจารย์ที่เคารพทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้และถ่ายทอดประสบการณ์ที่ดีให้แก่ข้าพเจ้า

เบญจวรรณ ประไพ์ชนัง

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VIII
สารบัญรูป.....	X
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมา.....	1
1.2 วัตถุประสงค์ของการศึกษา.....	3
1.3 ทฤษฎีหรือแนวความคิดที่ใช้ในการวิจัย.....	3
1.4 ขอบเขตและขั้นตอนการวิจัย.....	4
1.5 คำโครงวิทยานิพนธ์.....	4
บทที่ 2 งานวิจัยที่เกี่ยวข้อง.....	5
2.1 ระบาดวิทยาของการหกล้มในผู้สูงอายุ.....	5
2.1.1 สาเหตุของการหกล้มของผู้สูงอายุ.....	5
2.1.1.1 ปัจจัยภายในร่างกาย.....	6
2.1.1.2 ปัจจัยภายนอกในร่างกาย.....	7
2.1.2 การบาดเจ็บจากการหกล้มของผู้สูงอายุ.....	8
2.1.2.1 ผลกระทบต่อสุขภาพกาย.....	8
2.1.2.2 ผลกระทบต่อจิตใจ.....	8
2.2 การศึกษาชีวกลศาสตร์ของการเคลื่อนไหวของร่างกายและการล้ม.....	9
2.2.1 ระบบพิกัดของร่างกาย.....	9
2.2.1.1 ระนาบ (Plane).....	9
2.2.1.2 แกน (axis).....	9
2.2.1.3 จุดศูนย์ถ่วง (Center of Gravity).....	10
2.2.1.4 เสถียรภาพ (Stability).....	10
2.2.2 หลักพลวัตของการเคลื่อนไหวของมนุษย์.....	11
2.2.2.1 ความเร่งของร่างกาย (Body Acceleration).....	11
2.2.2.2 ความเร็วเชิงมุมของร่างกาย (Body Angular velocity).....	12
2.2.2.3 ความแตกต่างระหว่างวัยรุ่นกับผู้สูงอายุ.....	12
2.2.2.4 คุณสมบัติการหกล้มของมนุษย์.....	12

# สารบัญ(ต่อ)

	หน้า
2.3 งานวิจัยที่เกี่ยวข้อง.....	13
2.3.1 กลุ่มงานวิจัยงานวิจัยที่มุ่งเน้นหาตำแหน่งที่เหมาะสมสำหรับตรวจจับการทกล้ม และจดจำกิจกรรมทางกายภาพของมนุษย์.....	13
2.3.2 กลุ่มงานวิจัยงานวิจัยที่มุ่งเน้นพัฒนาอัลกอริทึมสำหรับตรวจจับการทกล้มและ จดจำกิจกรรมทางกายภาพของมนุษย์.....	15
บทที่ 3 ทฤษฎีที่เกี่ยวข้อง.....	17
3.1 การแปลงเวฟเลต (Wavelet Transform).....	17
3.1.1 ทฤษฎีการประมาณค่า (Approximation) .....	17
3.1.2 ตัวอย่างการประมาณสัญญาณดิสครีตทางเวลาโดยฟังก์ชันเดลต้า.....	18
3.1.3 การสร้าง Basis โดยการสเกล .....	19
3.1.4 การวิเคราะห์แบบ Multi-resolution .....	21
3.1.5 การแปลงดิสครีตเวฟเลต ( Discrete Wavelet Transform ) .....	23
3.1.6 การแปลงเวฟเลตแบบเร็ว ( Fast Wavelet Transform ).....	24
3.1.7 Mother Wavelet.....	26
3.1.7.1 Haar Mother Wavelet.....	26
3.1.7.2 Daubechies Mother Wavelet.....	27
3.1.7.3 Coiflet Mother Wavelet.....	28
3.1.7.4 Symlet Mother Wavelet.....	29
3.1.7.5 Biorthogonal Mother Wavelet.....	30
3.2 ทฤษฎีการลดมิติ (Dimension Reduction).....	31
3.2.1 การวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis).....	32
3.2.2 การวิเคราะห์การจำแนกเชิงเส้น (Linear Discriminant Analysis).....	34
3.3 ทฤษฎีโครงข่ายประสาทเทียม (Artificial Neural Network).....	36
3.3.1 การโครงข่ายประสาทเชิงชีววิทยา (Biological Neural Network).....	36
3.3.2 โครงข่ายประสาทเทียม (Artificial Neural Network).....	39
3.3.3 โครงข่ายประสาทเทียมอย่างง่าย (Single layer perceptron).....	40
3.3.4 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron) .....	42
3.3.5 ฟังก์ชันถ่ายโอน (Activation Function or Transfer Function).....	47
3.3.6 กฎการเรียนรู้ (Learning Rule).....	48
3.3.6.1 เรียนรู้แบบไม่มีผู้สอน (unsupervised learning).....	49
3.3.6.2 การเรียนรู้แบบมีผู้สอน (supervised).....	51
3.3.6.3 Back Propagation Neural Network, BPNN.....	52

# สารบัญ(ต่อ)

	หน้า
บทที่ 4 ขั้นตอนการวิจัย.....	55
4.1. ระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหว (Signal Acquisition System).....	55
4.1.1. อุปกรณ์ตรวจวัดและส่งสัญญาณ (Signal Acquisition Device).....	56
4.1.1.1. เซนเซอร์วัดความเร่งสามแกน (Tri-axial Accelerometer).....	56
4.1.1.2. ไมโครคอนโทรลเลอร์.....	58
4.1.1.3. บลูทูธ (Bluetooth).....	58
4.1.2. การรับและเก็บสัญญาณ.....	59
4.2. อัลกอริทึมที่นำเสนอสำหรับตรวจจับสัญญาณการเคลื่อนไหว.....	63
4.2.1 การดึงคุณลักษณะของสัญญาณความเร่งโดยใช้การแปลงเวฟเลต.....	63
4.2.2 วิธีที่นำเสนอสำหรับการลดมิติของคุณลักษณะเวฟเลต.....	66
4.2.2.1. จัดการข้อมูลคุณลักษณะเวฟเลต.....	67
4.2.2.2. หาเมตริกซ์ความแปรปรวน.....	69
4.2.2.3. การโปรเจกชันข้อมูลไปยังปริภูมิที่ถูกลดมิติ.....	70
4.2.3 การคัดแยกสัญญาณการเคลื่อนไหวและการหกล้มของมนุษย์โดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ.....	71
บทที่ 5 การทดลองและผลการทดลอง.....	74
5.1 การประเมินประสิทธิภาพ.....	74
5.2 การวัดและจัดเก็บข้อมูลสัญญาณการเคลื่อนไหว.....	77
5.3 การทดลองและผลการทดลอง.....	78
5.3.1 การทดลองการจดจำกิจกรรมทางกายภาพของมนุษย์.....	78
5.3.1.1. ผลการทดลองการจดจำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต.....	81
5.3.1.2. ผลการทดลองการจดจำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต.....	83
5.3.1.3. ผลการทดลองการจดจำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุต.....	85
5.3.1.4. ผลการทดลองการจดจำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุต.....	87

# สารบัญ(ต่อ)

หน้า

5.3.1.5. สรุปผลการทดลองการจดจำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลต วิธีการลดมิติที่นำเสนอและโครงข่ายประสาทเทียม.....	89
5.3.2 การจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวัน.....	90
5.3.2.1. ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวันด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต.....	93
5.3.2.2. ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวันด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต.....	95
5.3.2.3. ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวันด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุต.....	97
5.3.2.4. ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวันด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุต.....	99
5.3.2.5. สรุปผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลต วิธีการลดมิติที่นำเสนอและโครงข่ายประสาทเทียม.....	101
บทที่ 6 สรุปผลการวิจัย.....	103
เอกสารอ้างอิง.....	105
ภาคผนวก ก.....	110
ภาคผนวก ข ผลงานที่ได้รับการตีพิมพ์.....	117
ประวัติผู้เขียน.....	125

# สารบัญตาราง

ตารางที่	หน้า
2.1 ประเภทกิจกรรมสำหรับการทดลองของ H Gjoreski และคณะ.....	14
3.1 ฟังก์ชันถ่ายโอนแบบต่างๆ.....	48
4.1 สถานะของเซนเซอร์วัดความเร่ง.....	57
4.2 รายละเอียดขาของเซนเซอร์วัดความเร่ง.....	58
4.3 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของ การคัดแยกสัญญาณการเคลื่อนไหวของมนุษย์.....	72
4.4 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของ การคัดแยกสัญญาณการหกล้มของมนุษย์.....	73
5.1 แสดงพารามิเตอร์ที่ใช้ในการทดลอง.....	75
5.2 แสดงจำนวนสัญญาณการเคลื่อนไหวของแต่ละกิจกรรมจากอาสาสมัครทั้งหมด 5 คน.....	77
5.3 แสดงรายละเอียดการใช้สัญญาณการเคลื่อนไหวของการทดลองการรู้จำกิจกรรมทาง กายภาพของมนุษย์.....	79
5.4 แสดงความสัมพันธ์ระหว่างอัตราการลดมิติ จำนวนสัมพันธ์ของคุณลักษณะเวฟเล็ต และจำนวนโหนดชั้นอินพุทของโครงข่ายประสาทเทียม.....	80
5.5 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเล็ตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท.....	82
5.6 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเล็ตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท.....	84
5.7 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเล็ตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท.....	86
5.8 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเล็ตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท.....	88
5.9 สรุปผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ที่มีประสิทธิภาพดีที่สุด.....	89
5.10 สรุปผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ที่มีความแม่นยำสูงที่สุด.....	89
5.11 แสดงรายละเอียดการใช้สัญญาณการเคลื่อนไหวสำหรับการทดลองการจำแนกการ หกล้มออกจากกิจกรรมในชีวิตประจำวัน.....	91
5.12 ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย สัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเล็ตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท.....	94

## สารบัญตาราง(ต่อ)

ตารางที่	หน้า
5.13 ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย สัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต.....	96
5.14 ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย สัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุต.....	98
5.15 ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย สัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุต.....	100
5.16 สรุปผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ที่มี ประสิทธิภาพดีที่สุด.....	101
5.17 สรุปผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ที่มี ความแม่นยำสูงที่สุด.....	101

# สารบัญรูป

รูปที่	หน้า
1.1 จำนวนและร้อยละของประชากรสูงอายุ พ.ศ. 2537 2545 2550 2554 และ 2557 .....	1
1.2 สาเหตุที่ทำให้ผู้สูงอายุได้รับบาดเจ็บจากสาเหตุภายนอกในปีงบประมาณ 2551 .....	2
1.3 ตัวอย่างปัจจัยเสี่ยงในการหกล้มของผู้สูงอายุ.....	2
1.4 ขั้นตอนสำหรับรู้จำกิจกรรมทางกายภาพของมนุษย์ .....	4
2.1 ตัวอย่างการหกล้มของผู้สูงอายุ.....	5
2.2 ระบบพิกัดของร่างกาย .....	9
2.3 จุดศูนย์กลางของร่างกายตัวอย่างความเสี่ยงในการหกล้ม .....	10
2.4 Base of support (BOS) และ Line of gravity (LOG) ของมนุษย์.....	10
2.5 แนวแกนการเคลื่อนไหวร่างกายของมนุษย์.....	11
2.6 เฟสการล้มจากสัญญาณเวกเตอร์ผลรวมความเร่ง 3 แกน.....	12
2.7 ระบบรู้จำกิจกรรมและตรวจจับการหกล้มของ H Gjoreski และคณะ .....	14
2.8 ขั้นตอนตรวจจับการหกล้มโดยทั่วไป .....	15
2.9 ตำแหน่งที่ใช้สำหรับติดตั้งเซ็นเซอร์วัดความเร่ง.....	15
2.10 อัลกอริทึมสำหรับตรวจจับการหกล้มของ Nattaitanakul.....	16
3.1 ผลลัพธ์ค่าประมาณของฟังก์ชันเดลต้า.....	19
3.2 รูปสเกลของ Basis ต่างๆ.....	20
3.3 ความสัมพันธ์ระหว่างพื้นที่ของสเกลฟังก์ชันและเวฟเลตฟังก์ชัน.....	22
3.4 ความสัมพันธ์ระหว่างสเกลฟังก์ชันและเวฟเลตฟังก์ชัน.....	23
3.5 บล็อกไดอะแกรมของการแปลงเวฟเลตแบบดิสครีต .....	25
3.6 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Harr Wavelet.....	26
3.7 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet .....	27
3.8 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Coiflet Wavelet .....	28
3.9 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet.....	29
3.10 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Biorthogonal Wavelet .....	31
3.11 การอธิบายการแปลงการวิเคราะห์หอนงค์ประกอบหลักด้วยกราฟฟิก 2 มิติ.....	33
3.12 โปรเจกชันของเมตริกซ์ $x$ ไปยังปริภูมิใหม่ $W'$ .....	34
3.13 โปรเจกชันของเมตริกซ์ $x$ ไปยังปริภูมิใหม่.....	35
3.14 รายละเอียดของเซลล์ประสาทชีวภาพ .....	37

## สารบัญรูป(ต่อ)

รูปที่	หน้า
3.15 สัญญาณทางไฟฟ้าของระบบประสาท .....	38
3.16 แบบจำลองของ Sensory neurons, Motor neurons และ Interneurons .....	39
3.17 แผงผังโครงข่ายประสาท .....	39
3.18 แผงผังของเซลล์ประสาทชีวภาพและเซลล์ประสาทเทียม .....	40
3.19 ฟังก์ชันถ่ายโอน.....	42
3.20 ความสัมพันธ์ระหว่างเวกเตอร์น้ำหนัก และเวกเตอร์ขาเข้าของนิวรอน.....	43
3.21 การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว .....	44
3.22 รูปแบบเวกเตอร์อินพุตและเอาต์พุตของฟังก์ชัน XOR.....	44
3.23 แสดงเส้นแบ่งพื้นที่ที่เกิดจากนิวรอน .....	45
3.24 ตัวอย่างเครือข่ายไปข้างหน้าขนาด 2 ชั้น (ชั้นละ 2 นิวรอนและ 1 นิวรอน).....	45
3.25 โครงข่ายประสาทเทียมแบบหลายชั้น.....	47
3.26 การสกัดคุณลักษณะเด่นขององค์ประกอบหลักของการกระจายรูปแบบของชั้นขาเข้า ด้วยสองชั้นขาออก.....	50
3.27 ขั้นตอนการเรียนรู้แบบมีผู้สอน.....	52
3.28 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN).....	52
4.1 ลำดับขั้นตอนสำหรับรู้จำกิจกรรมทางกายภาพของมนุษย์.....	55
4.2 การใช้งานอุปกรณ์ตรวจวัดสัญญาณ.....	55
4.3 อุปกรณ์ตรวจวัดสัญญาณความเร่ง .....	56
4.4 โครงสร้างของเซนเซอร์วัดความเร่งสามแกน (ET-MMA7331L).....	56
4.5 ระบบแกนที่ใช้กับงานวิจัยนี้ .....	57
4.6 ไมโครคอนโทรลเลอร์เบอร์ PIC32MX460F512L ของบริษัทไมโครชิพ .....	58
4.7 บลทูล HC05.....	59
4.8 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มไปด้านหน้า .....	60
4.9 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการลุกจากที่นอน .....	60
4.10 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการล้มตัวลงนอน.....	61

## สารบัญรูป(ต่อ)

รูปที่	หน้า
4.11 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการลุกจากเก้าอี้ .....	61
4.12 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการนั่งเก้าอี้ .....	61
4.13 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการเดิน .....	61
4.14 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการล้มหน้า .....	62
4.15 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการล้มหลัง .....	62
4.16 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการล้มซ้าย .....	62
4.17 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการล้มขวา .....	62
4.18 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการล้มในขณะที่กำลังลุกขึ้นยืน .....	63
4.19 การแยกองค์ประกอบสัญญาณความเร่งโดยใช้หลักการของฟิวเตอร์แบงค์ .....	63
4.20 การแปลงแบบเวฟเลทแบบไม่ต่อเนื่องโดยพื้นฐานการวิเคราะห์แบบ multi-resolution .....	64
4.21 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลท Daucechies2 ระดับที่ 1 .....	64
4.22 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลท Daucechies2 ระดับที่ 2 .....	64
4.23 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลท Coiflet1 ระดับที่ 1 .....	65
4.24 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลท Coiflet1 ระดับที่ 2 .....	65
4.25 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลท Symlet2 ระดับที่ 1 .....	65

## สารบัญรูป(ต่อ)

รูปที่	หน้า
4.26 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Symlet2 ระดับที่ 2.....	65
4.27 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Biorthogonal11 ระดับที่ 1.....	65
4.28 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Biorthogonal11 ระดับที่ 2.....	66
4.29 ตัวอย่างจำนวนคุณลักษณะของเวฟเลตจากการแปลงเวฟเลตระดับที่ 1.....	66
4.30 ตัวอย่างคุณลักษณะของเวฟเลตจากการแปลงเวฟเลตระดับที่ 1 ของแกน vertical.....	67
4.31 ตัวอย่างคุณลักษณะของเวฟเลตจากการแปลงเวฟเลตระดับที่ 2 ของแกน vertical.....	68
4.32 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการรู้จำรูปแบบของสัญญาณการเคลื่อนไหวของมนุษย์.....	72
4.33 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการรู้จำรูปแบบของการคัดแยกสัญญาณการหกล้มของมนุษย์.....	73
5.1 ขั้นตอนการวิจัยสำหรับวิทยานิพนธ์ฉบับนี้.....	74
5.2 กราฟแสดงการประเมินประสิทธิภาพของระบบที่นำเสนอ.....	75
5.3 การรู้จำกิจกรรมในชีวิตประจำวันและเหตุการณ์การล้มของมนุษย์.....	78
5.4 ตัวอย่างสัญญาณคุณลักษณะเวฟเลตของสัญญาณการหกล้มไปด้านหน้า 1248 สัมประสิทธิ์ของการแปลงเวฟเลตระดับที่ 1 จากเซนเซอร์วัดความเร่ง 3 แกน.....	78
5.5 ตัวอย่างสัญญาณคุณลักษณะเวฟเลตของสัญญาณการหกล้มไปด้านหน้า 1248 สัมประสิทธิ์จากการแปลงเวฟเลตระดับที่ 2 จากเซนเซอร์วัดความเร่ง 3 แกน.....	79
5.6 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองรู้จำกิจกรรมทางกายภาพของมนุษย์ โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติและใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต.....	80
5.7 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองรู้จำกิจกรรมทางกายภาพของมนุษย์ โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติและใช้ฟังก์ชัน linear ในชั้นเอาต์พุต.....	80
5.8 กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต.....	81

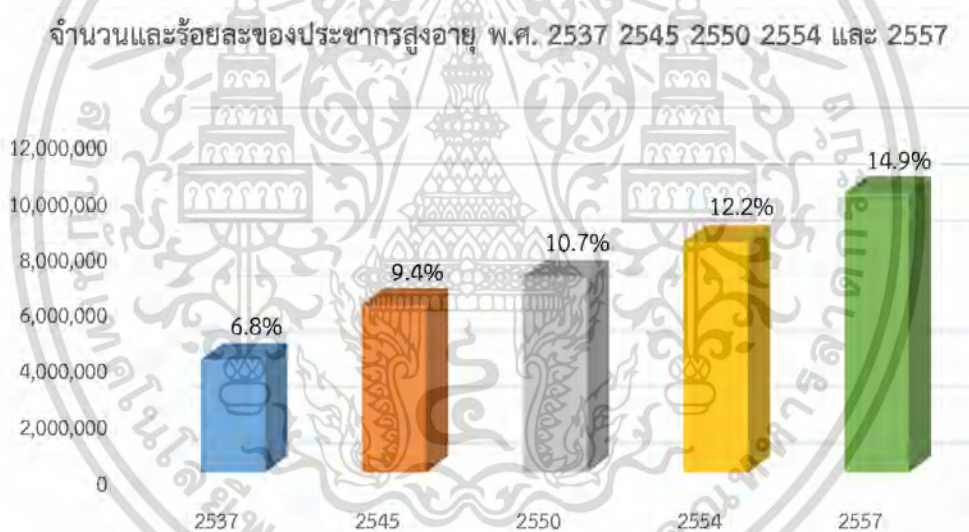
## สารบัญรูป(ต่อ)

รูปที่	หน้า
5.9 กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของ มนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และ ใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท.....	83
5.10 กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของ มนุษย์ด้วย สัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และ ใช้ฟังก์ชัน linear ในชั้นเอาต์พุท.....	85
5.11 กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของ มนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และ ใช้ฟังก์ชัน linear ในชั้นเอาต์พุท.....	87
5.12 การทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวัน .....	90
5.13 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองการจำแนกการหกล้ม ออกจากกิจกรรมในชีวิตประจำวัน โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติ และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท.....	92
5.14 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองการจำแนกการหกล้ม ออกจากกิจกรรมในชีวิตประจำวัน โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติ และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท.....	92
5.15 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการหกล้มออกจากกิจกรรม ทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลต ระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท.....	93
5.16 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการหกล้มออกจากกิจกรรม ทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลต ระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท.....	95
5.17 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการหกล้มออกจากกิจกรรม ทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลต ระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท.....	97
5.18 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการหกล้มออกจากกิจกรรม ทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลต ระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท.....	99

# บทที่ 1 บทนำ

## 1.1 ความเป็นมา

ปัจจุบันจำนวนประชากรผู้สูงอายุในไทยมีแนวโน้มเพิ่มมากขึ้นอย่างต่อเนื่อง ทำให้ประเทศไทยเป็นประเทศหนึ่งในอาเซียนที่เข้าสู่การเป็นสังคมสูงวัย (Aging Society) การเป็นสังคมสูงวัย คือ การที่มีจำนวนผู้สูงอายุหรือประชากรอายุ 60 ปีขึ้นไป เพิ่มสูงขึ้นจนมากกว่าร้อยละ 10 ของประชากรทั้งหมด จากรายงานผลเบื้องต้นการสำรวจประชากรผู้สูงอายุในประเทศไทย พ.ศ.2557 [1] พบว่าประเทศไทยมีจำนวนและสัดส่วนของผู้สูงอายุเพิ่มขึ้นอย่างรวดเร็วและต่อเนื่อง โดยในปี 2537 มีจำนวนผู้สูงอายุคิดเป็นร้อยละ 6.8 ของประชากรทั้งประเทศ และเพิ่มขึ้นเป็นร้อยละ 9.4 ร้อยละ 10.7 ร้อยละ 12.2 ในปี 2545 2550 2554 ตามลำดับ และผลการสำรวจปี 2557 พบว่ามีจำนวนผู้สูงอายุคิดเป็นร้อยละ 14.9 ของประชากรทั้งหมด ดังแสดงในรูปที่ 1.1

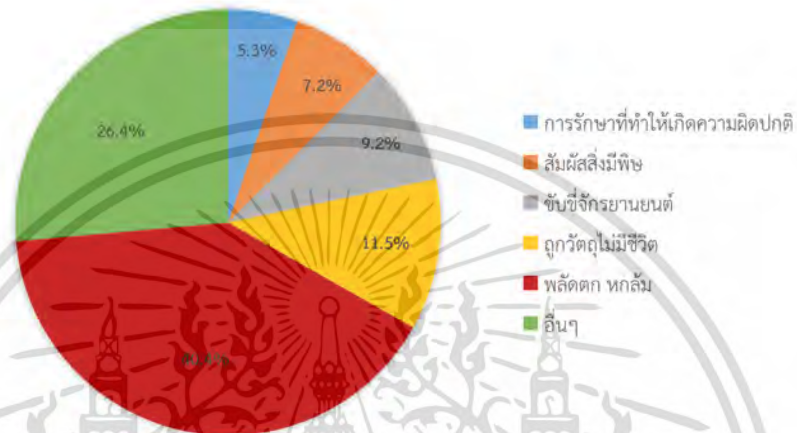


รูปที่ 1.1 จำนวนและร้อยละของประชากรสูงอายุ พ.ศ. 2537 2545 2550 2554 และ 2557 [1]

ในขณะที่วัยเด็กและแรงงานลดน้อยลงเรื่อยๆ จึงส่งผลกระทบต่อสภาวะทางสังคมและเศรษฐกิจโดยรวมของประเทศ ทำให้ต้องมีการจัดระบบการดูแลผู้สูงอายุในระยะยาวให้มีคุณภาพชีวิตที่ดี ทั้งเรื่องการจัดสรรทรัพยากรต่างๆ ที่มีอยู่อย่างจำกัด การจัดสรรสวัสดิการที่จำเป็นสำหรับผู้สูงอายุ รวมทั้งการบริการทางการแพทย์ที่จำเป็นในระยะยาว

ผู้สูงอายุมีโอกาสเกิดอุบัติเหตุได้ง่ายและเมื่อเกิดอุบัติเหตุขึ้นแล้วก็มีโอกาสเกิดปัญหาแทรกซ้อนตามมาได้มาก จากฐานข้อมูลผู้ป่วยในรายบุคคลหลักประกันสุขภาพถ้วนหน้าและสวัสดิการการรักษาพยาบาลข้าราชการและครอบครัว ที่รวบรวมโดยสำนักนโยบายและยุทธศาสตร์ กระทรวงสาธารณสุข [2] พบว่า สาเหตุที่ทำให้ผู้สูงอายุได้รับบาดเจ็บจากสาเหตุภายนอกในปีงบประมาณ 2551 ใน

5 ลำดับแรก ได้แก่ 1) พลัดตกหกล้ม 2) อุบัติเหตุจากวัตถุกลไกไม่มีชีวิต 3) อุบัติเหตุจากการขับขี่จักรยานยนต์ 4) สัมผัสกับสัตว์หรือพืชมีพิษ และ 5) การรักษาทางศัลยกรรมและอายุรกรรมที่ทำให้เกิดความผิดปกติ ดังแสดงในรูปที่ 1.2 ในผู้สูงอายุพบว่าการหกล้มที่พบ 50-67 % เป็นการหกล้มที่เกิดขึ้นในบ้าน และผู้สูงอายุเพศหญิงจะมีอัตราการหกล้มสูงกว่าผู้สูงอายุเพศชาย [3]



รูปที่ 1.2 สาเหตุที่ทำให้ผู้สูงอายุได้รับบาดเจ็บจากสาเหตุภายนอกในปีงบประมาณ 2551 [3]

การหกล้มเป็นปัญหาที่อันตรายที่สุดสำหรับผู้สูงอายุ ซึ่งการหกล้มแต่ละครั้งก่อให้เกิดการบาดเจ็บรุนแรงเช่น สะโพกหัก อัมพฤกษ์ อัมพาต หรือเสียชีวิต โดยปัจจัยเสี่ยงในการหกล้มของผู้สูงอายุแบ่งเป็น 2 ปัจจัยหลักคือ ปัญหาทางกายภาพของผู้สูงอายุ เช่น เคยได้รับการผ่าตัดหัวเข่า ไขข้อเสื่อม ความดันหรือโรคหัวใจ เป็นต้น อีกปัจจัยคือสภาพแวดล้อมเช่น พื้นลื่น หรือ พื้นขรุขระ ทางต่างระดับ หรือ ทางลาดชัน เป็นต้น ดังแสดงในรูปที่ 1.3 สิ่งเหล่านี้เป็นปัจจัยเสี่ยงที่อาจทำให้เกิดการหกล้มเพิ่มขึ้น



รูปที่ 1.3 ตัวอย่างปัจจัยเสี่ยงในการหกล้มของผู้สูงอายุ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เพื่อที่จะลดอัตราการบาดเจ็บหรือการเสียชีวิต ระบบที่สามารถตรวจจับการหกล้มได้อย่างมีประสิทธิภาพและถูกต้องต้องถูกพัฒนา นอกจากนี้การหกล้มมักเกิดขึ้นระหว่างกิจกรรมในชีวิตประจำวันต่าง ๆ เช่น ขณะที่กำลังเดิน กำลังนั่ง กำลังลุก หรือกำลังนอน ดังนั้นอัลกอริทึมจึงจำเป็นต้องจำแนกการหกล้มออกจากกิจกรรมต่างๆในชีวิตประจำวันได้

## 1.2 วัตถุประสงค์ของการศึกษา

วิทยานิพนธ์ฉบับนี้มุ่งเน้นศึกษาประสิทธิภาพของเครื่องตรวจจับสัญญาณความเร่งและพัฒนาอัลกอริทึมสำหรับการรู้จำกิจกรรมการเคลื่อนไหวแบบต่าง ๆ ของมนุษย์และจำแนกการหกล้มออกจากกิจกรรมการเคลื่อนไหวแบบต่างๆ ในชีวิตประจำวัน ให้มีความถูกต้องแม่นยำ และใช้เวลาประมวลผลที่รวดเร็ว โดยนำการแปลงเวฟเลต (Wavelet Transform) วิธีการลดมิติที่นำเสนอ (Proposed Dimension Reduction Method) และทฤษฎีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back Propagation Neural Network) มาเป็นเครื่องมือสำหรับรู้จำกิจกรรมทางกายภาพของมนุษย์จากสัญญาณความเร่งสามแกน

## 1.3 ทฤษฎีหรือแนวความคิดที่ใช้ในการวิจัย

จากความก้าวหน้าทางเทคโนโลยีในปัจจุบัน ทำให้เซนเซอร์วัดความเร่งและเซนเซอร์วัดความเร่งเชิงมุมเป็นอุปกรณ์ที่มีขนาดเล็ก น้ำหนักเบา ราคาถูก ใช้พลังงานต่ำ และสามารถสวมใส่ได้ [4] ซึ่งมีข้อดีที่สำคัญคือ สามารถติดกับตัวของผู้สูงอายุได้ตลอดเวลา โดยไม่ละเมิดความเป็นส่วนตัว ในขณะที่การใช้กล้อง หรือไมโครโฟน อาจละเมิดความเป็นส่วนตัวของผู้ใช้งานได้ ดังนั้นเซนเซอร์วัดความเร่งและเซนเซอร์วัดความเร่งเชิงมุมจึงถูกใช้อย่างกว้างขวางเพื่อที่จะสังเกตการเคลื่อนไหวของมนุษย์ในชีวิตประจำวัน [5],[6],[7]

จากบทความของ M. Kangas และคณะ [8] เปรียบเทียบตำแหน่งสำหรับติดเซนเซอร์วัดความเร่งสามแกนบนร่างกายที่เหมาะสมที่สุด สำหรับการรู้จำกิจกรรมของมนุษย์และการตรวจจับการหกล้ม เนื่องจากสัญญาณเอาท์พุทจากเซนเซอร์วัดความเร่งสามแกนจะแตกต่างกันถ้าติดที่ตำแหน่งต่างกัน จากผลลัพธ์พบว่าบริเวณที่เหมาะสมที่สุดสำหรับวิเคราะห์กิจกรรมคือบริเวณเอว ซึ่งสอดคล้องกับบทความของ M.J. Mathie และคณะ [9] ที่กล่าวว่า บริเวณเอวเป็นตำแหน่งที่ใกล้กับจุดศูนย์กลางแรงโน้มถ่วงของร่างกายซึ่งให้ข้อมูลที่เชื่อถือได้สำหรับการเคลื่อนไหวของมนุษย์

จากบทความของ Sengto และ Leauhatong [10] ได้นำเสนออัลกอริทึมสำหรับตรวจจับการหกล้มที่อยู่บนพื้นฐานของการกำหนดค่าขีดเริ่มของขนาดของความเร่งและใช้โครงข่ายประสาทเทียม และเร็วๆ นี้ Nuttaitanakul และ Leauhatong [11] ได้ปรับปรุงอัลกอริทึมของ Sengto และ Leauhatong โดยเพิ่มการดึงคุณลักษณะของสัญญาณความเร่งซึ่งใช้การแปลงเวฟเลต (Wavelet Transform) และโครงข่ายประสาทเทียมทำให้มีประสิทธิภาพเพิ่มขึ้น

จากบทความที่ได้ศึกษามาวิทยานิพนธ์ฉบับนี้มุ่งเน้นที่จะเพิ่มประสิทธิภาพของอัลกอริทึมสำหรับตรวจจับการหกล้มและรู้จำกิจกรรมในชีวิตประจำวันจากเซนเซอร์วัดความเร่งสามแกนที่ถูกติดที่เอว โดยปรับปรุงอัลกอริทึมของ Nuttaitanakul และ Leauhatong โดยใช้การแปลงเวฟเลต (Wavelet

Transform) วิธีการลดมิติที่นำเสนอ (Proposed Dimension Reduction Method) และทฤษฎีโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer Perceptron Neural Network)

## 1.4 ขอบเขตและขั้นตอนการวิจัย

วิทยานิพนธ์ฉบับนี้พัฒนาอัลกอริทึมสำหรับรู้จำกิจกรรมทางกายภาพของมนุษย์ โดยมีองค์ประกอบ 2 ส่วนหลัก ส่วนแรกคือ ส่วนของการเก็บสัญญาณการเคลื่อนไหวโดยใช้ “เครื่องตรวจวัดสัญญาณการเคลื่อนไหว” ซึ่งประกอบด้วย เซนเซอร์วัดความเร่งแบบสามแกน และไมโครคอนโทรลเลอร์ ซึ่งจะส่งข้อมูลไปจัดเก็บและประมวลผลต่อยังคอมพิวเตอร์ อีกส่วนคือ ส่วนของอัลกอริทึมสำหรับรู้จำกิจกรรม สามารถแบ่งเป็น 4 ขั้นตอน คือ การเก็บข้อมูล (Signal Acquisition), การดึงคุณลักษณะ (Feature Extraction), วิธีการลดมิติที่นำเสนอ (Proposed Dimension Reduction Method) และการรู้จำกิจกรรมทางกายภาพของมนุษย์ (Human Physical Activity Recognition) ดังแสดงในรูปที่ 1.4



รูปที่ 1.4 ขั้นตอนสำหรับรู้จำกิจกรรมทางกายภาพของมนุษย์

สำหรับงานวิจัยในวิทยานิพนธ์ฉบับนี้จะรู้จำกิจกรรมทั้งหมด 10 กิจกรรม จากอาสาสมัครสุขภาพดีอายุระหว่าง 21-25 ปี จำนวน 5 คน (ผู้ชาย 4 คน ผู้หญิง 1 คน) โดยที่กิจกรรมแบ่งเป็น 2 กลุ่มคือ กิจกรรมในชีวิตประจำวัน 5 กิจกรรมได้แก่ ลูกจากที่นอน ล้มตัวลงนอนบนที่นอน ลูกจากเก้าอี้ นั่งลงบนเก้าอี้ และเดิน อีกกลุ่มคือเหตุการณ์การหกล้ม 5 เหตุการณ์ ได้แก่ หกล้มไปด้านหน้า หกล้มไปด้านหลัง หกล้มไปด้านซ้าย หกล้มไปด้านขวา และหกล้มไปด้านซ้ายขณะที่กำลังลุกขึ้นยืน

## 1.5 เค้าโครงวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้ได้แบ่งเนื้อหาออกเป็น 6 บท ด้วยกันคือ

บทที่ 1 กล่าวถึงบทนำ ความเป็นมาของเนื้อหา วัตถุประสงค์ของการศึกษา ทฤษฎีหรือแนวความคิดที่ใช้ในการวิจัย ขอบเขตการวิจัย และเค้าโครงวิทยานิพนธ์

บทที่ 2 กล่าวถึงงานวิจัยที่เกี่ยวข้องกับงานในวิทยานิพนธ์ฉบับนี้

บทที่ 3 กล่าวถึงทฤษฎีที่เกี่ยวข้องกับงานในวิทยานิพนธ์ฉบับนี้

บทที่ 4 กล่าวถึงขั้นตอนการวิจัย ในวิทยานิพนธ์ฉบับนี้ประกอบด้วย 4 ขั้นตอน ได้แก่ การวัดสัญญาณความเร่งของแต่ละกิจกรรม การดึงคุณลักษณะของสัญญาณ วิธีการลดมิติของสัญญาณ และ การรู้จำกิจกรรม

บทที่ 5 กล่าวถึงการวิจัยและผลการวิจัย

บทที่ 6 กล่าวถึงสรุปผลการวิจัย

## บทที่ 2 งานวิจัยที่เกี่ยวข้อง

### 2.1 ระบาดวิทยาของการหกล้มในผู้สูงอายุ

การหกล้มและเสถียรภาพของการก้าวเดิน คือ ปัญหาร้ายแรงที่สุดที่ผู้สูงอายุต้องเผชิญ และเป็นสาเหตุสำคัญของการบาดเจ็บรุนแรง อัมพฤกษ์อัมพาต หรือถึงขั้นเสียชีวิต ในปี 2555 “Shell Point Retirement Community” องค์กรไม่แสวงหากำไรแห่งหนึ่งของสหรัฐอเมริกาที่ทำงานเกี่ยวกับเรื่องการดูแลผู้สูงอายุ [12] ได้รายงานข้อมูลที่น่าเป็นห่วงเกี่ยวกับปัญหาการหกล้มของผู้สูงอายุ กล่าวว่าการหกล้มเป็นสาเหตุที่ทำให้ผู้สูงอายุต้องนอนโรงพยาบาลนานขึ้นเป็น 2 เท่าของการเข้าโรงพยาบาลด้วยเหตุผลอื่นๆ และ 2 ใน 3 ของผู้สูงอายุที่เคยหกล้มแล้ว มีโอกาสที่จะเกิดการหกล้มครั้งใหม่ได้อีกภายในเวลา 6 เดือน นอกจากนี้ 1 ใน 4 ของผู้สูงอายุที่เกิดปัญหากระดูกสะโพกหักจากการหกล้มจะเสียชีวิตภายใน 6 เดือน หลังจากการหกล้ม ถึงแม้ว่าจะไม่เสียชีวิตแต่ปัญหาใหญ่ที่ผู้สูงอายุต้องเผชิญคือ ผลกระทบต่อจิตใจ ทำให้ผู้สูงอายุสูญเสียความมั่นใจในการเคลื่อนไหว กลัวการหกล้ม ทำให้ต้องเป็นภาระของผู้ดูแลและครอบครัว อีกทั้งยังมีการสูญเสียค่าใช้จ่ายในการดูแลรักษา รวมทั้งเป็นภาระของสถานพยาบาลที่ต้องดูแลรักษาผู้สูงอายุที่เกิดการหกล้มเพิ่มขึ้น

#### 2.1.1 สาเหตุของการหกล้มของผู้สูงอายุ

จากบทความทางระบาดวิทยาของการหกล้มในผู้สูงอายุพบว่าการหกล้มไม่ได้มีชนิดเดียวและยากที่จะระบุสาเหตุของการหกล้ม [13] เช่นเกิดจากการสะดุดหรือการลื่นดังแสดงในรูปที่ 2.1 โดยทั่วไปการหกล้มถูกจำแนกโดยความสัมพันธ์ของปัจจัยทางด้านสุขภาพ สังคม และสิ่งแวดล้อม ทั้งประชากรในชุมชนและสถาบัน [3]



รูปที่ 2.1 ตัวอย่างการหกล้มของผู้สูงอายุ [13]

(ก) การหกล้มแบบพลากหรือสะดุด

(ข) การหกล้มแบบลื่นไถล

ปัจจัยของการหกล้มสามารถจำแนกได้ดังต่อไปนี้

### 2.1.1.1 ปัจจัยภายในร่างกาย

สภาวะร่างกายหรือการเปลี่ยนแปลงภายในร่างกายที่ทำให้เกิดความเสี่ยงต่อการหกล้ม การเปลี่ยนแปลงตามวัย เมื่อผ่านวัยผู้ใหญ่แล้วจะมีการสลายของเซลล์มากกว่าการสร้าง ทำให้การทำงานของอวัยวะต่าง ๆ ภายในร่างกายของผู้สูงอายุเสื่อมลง เกิดพยาธิสภาพตามมา ผู้สูงอายุจึงมีการเปลี่ยนแปลงแบบเสื่อมลงทั้งด้านร่างกายและจิตใจทำให้เกิดการหกล้มได้ง่ายซึ่งการเปลี่ยนแปลงของผู้สูงอายุที่ทำให้เกิดการหกล้มสูงขึ้น

การเปลี่ยนแปลงในระบบประสาท เมื่ออายุเพิ่มขึ้นความไวในการรับรู้ความรู้สึก การรับรู้ตำแหน่ง การรับรู้เหตุการณ์ที่เกิดขึ้น และการตอบสนองต่อการเปลี่ยนแปลงต่าง ๆ ลดต่ำลง นอกจากนี้ผู้สูงอายุยังมีการเสื่อมลงของระบบประสาทอัตโนมัติ ซึ่งทำหน้าที่ควบคุมร่างกายให้อยู่ในภาวะสมดุล (Homeostasis) โดยพบว่าจำนวนประสาทซิมพาเทติก และอัตราการนำพลังของเส้นประสาทลดลง เป็นผลให้ผู้สูงอายุมีปฏิกิริยาตอบสนองต่อสิ่งเร้าเชิงซ้ำ มีภาวะความดันโลหิตต่ำเมื่อเปลี่ยนท่า (Postural Hypotension) ทำให้ผู้สูงอายุมีอาการหน้ามืด วิงเวียนศีรษะ และเกิดการหกล้มตามมาได้ นอกจากนี้ผู้สูงอายุมักมีการรับรู้ความรู้สึกของระบบประสาทและสมองผิดปกติ ทั้งนี้เนื่องมาจากภาวะสมองเสื่อม เนื้อสมองตาย โรคหลอดเลือดสมอง หรือโรคพาร์กินสัน ซึ่งเป็นโรคและความผิดปกติที่เกิดจากการเปลี่ยนแปลงในระบบหัวใจและหลอดเลือดของผู้สูงอายุ ทำให้ระบบการควบคุมสมองส่วนกลางผิดปกติ อวัยวะต่าง ๆ ทำงานไม่ประสานกัน สูญเสียความสามารถในการรักษาสมดุลของร่างกาย ผู้สูงอายุจึงเกิดการหกล้มได้ง่าย นอกจากนี้อาการวิงเวียนศีรษะ (Vertigo) ซึ่งพบบ่อยในวัยสูงอายุก็มักเป็นสาเหตุที่ทำให้ผู้สูงอายุเกิดการหกล้ม

ความเสื่อมของการมองเห็น ผู้สูงอายุมีการเปลี่ยนแปลงในทางเสื่อมลงของดวงตาและสายตา คือ เลนส์ตาหนาตัว ขุ่นมัวและแข็ง ลานสายตาแคบลง ทำให้ความชัดเจนและการรับรู้ความตื้นลึกของภาพลดต่ำลง ส่งผลให้ผู้สูงอายุสะดุดและหกล้มได้ง่ายโดยเฉพาะขณะขึ้นลงบันได นอกจากนี้ความสามารถในการแยกสีของผู้สูงอายุก็ลดต่ำลง ทำให้เกิดการรับรู้ภาพพื้นหรือห้องที่มีสีสั่นและลวดลายไม่เหมาะสมกับผู้สูงอายุผิดพลาด จนทำให้เกิดปัญหาการหกล้มตามมา

การเปลี่ยนแปลงของระบบโครงสร้างและกล้ามเนื้อ มวลกล้ามเนื้อของผู้สูงอายุมีการลดลง การหดตัวและความยืดหยุ่นของกล้ามเนื้อก็ ความแข็งแรงของกระดูกจึงลดต่ำลงตามวัยที่เพิ่มมากขึ้น และยังพบว่าการที่กระดูกต้องรับน้ำหนักตัวเป็นเวลานานทำให้ความยืดหยุ่นของข้อลดต่ำลง และหากน้ำหนักตัวมากก็ยิ่งส่งผลให้เกิดความเสื่อมได้มากยิ่งขึ้น ดังนั้นการเปลี่ยนแปลงของกล้ามเนื้อ กระดูกและข้อของผู้สูงอายุ จึงส่งผลให้ความสามารถในการทรงตัวของผู้สูงอายุลดต่ำลง และเกิดการหกล้มได้ ซึ่งปัญหาและความผิดปกติของระบบกล้ามเนื้อและกระดูกที่พบบ่อยในวัยสูงอายุ คือ ข้ออักเสบ ข้อเสื่อม ภาวะกระดูกพรุน กระดูกหัก การตัดขา (Amputation) และภาวะกล้ามเนื้ออ่อนแรง ซึ่งความผิดปกติเหล่านี้ทำให้

ความสามารถในการทรงตัวของผู้สูงอายุลดต่ำลง นอกจากนี้ การเจ็บป่วยเฉียบพลันในระบบกล้ามเนื้อและกระดูก เช่น การปวดตึงกล้ามเนื้อก็อาจเป็นสาเหตุของการหกล้มได้

นอกจากนี้ผู้สูงอายุส่วนใหญ่มีปัญหาเกี่ยวกับการกลั้นปัสสาวะ ทั้งนี้เนื่องจากความเสื่อมในการยืดหยุ่นของกล้ามเนื้อของอวัยวะในระบบทางเดินปัสสาวะ ปัญหาเหล่านี้ส่งผลให้ ผู้สูงอายุต้องเข้าห้องน้ำบ่อยครั้งและต้องเร่งรีบเพื่อเข้าห้องน้ำให้ทัน ทำให้ผู้สูงอายุเสี่ยงต่อการหกล้มได้ง่าย

ความผิดปกติของระบบหัวใจและหลอดเลือด ระบบไหลเวียนโลหิตมีความสำคัญอย่างมากต่อกลไกการทรงตัว ความผิดปกติของหัวใจและหลอดเลือด เช่น การตีบแคบของหลอดเลือด การเกิดกล้ามเนื้อหัวใจตาย และการเต้นผิดปกติของหัวใจ ล้วนมีผลให้ปริมาณเลือดที่ออกจากหัวใจน้อยลง ทำให้ความดันโลหิตลดต่ำลงประกอบกับความสามารถในการชดเชยการลดระดับของความดันโลหิต ด้วยการเพิ่มอัตราการเต้นของหัวใจ และการหดตัวของหลอดเลือดในวัยผู้สูงอายุทำได้ไม่ดีเช่นเดิม ปริมาณเลือดที่ไปเลี้ยงสมองจึงลดลง และเมื่อถึงขีดจำกัดสูงสุดของภาวะขาดเลือดในสมอง จะส่งผลให้ผู้สูงอายุเกิดอาการหน้ามืด เป็นลม และเกิดการหกล้มตามมา

### 2.1.1.2 ปัจจัยภายนอกร่างกาย

ปัจจัยทางด้านสิ่งแวดล้อมสถานการณ์ภายนอกร่างกาย แสงสว่างที่ไม่เพียงพอ พื้นลื่น ขรุขระ มีสิ่งกีดขวาง ที่ไม่เหมาะสมกับผู้สูงอายุ ห้องสุขาที่ไม่ปลอดภัยขาดที่ยึดเกาะ บันไดที่มีวัสดุสิ่งของวางเกะกะ หรือขาดราวยึดจับ รวมถึงสัตว์เลี้ยงภายในบ้าน ล้วนเป็นสาเหตุที่ทำให้ผู้สูงอายุเกิดการหกล้ม รายงานภาวะสุขภาพประชาชนไทย พ.ศ. 2551-2 ของสำนักงานสำรวจสุขภาพประชาชนไทย [14] พบว่า สาเหตุการหกล้มของผู้สูงอายุ 2 อันดับแรกเกิดจากสาเหตุภายนอก คือ พื้นลื่น และการสะดุดสิ่งกีดขวาง นอกจากนี้ยังมีสาเหตุอื่น ๆ อีก ได้แก่ การถูกกระแทกกระแทก และการตกบันได และการได้รับยา เนื่องจากผู้สูงอายุเป็นกลุ่มที่พบอุบัติการณ์ของอาการไม่พึงประสงค์จากการใช้ยามากที่สุด โดยมีสาเหตุมาจากการใช้ยาหลายชนิดร่วมกัน และการเปลี่ยนแปลงทางสรีรวิทยาจากความชรา ที่มีต่อเภสัชจลนศาสตร์ และเภสัชพลศาสตร์ รวมถึงผลจากความผิดพลาดในการใช้ยาของตัวผู้สูงอายุหรือการขาดความรอบคอบของแพทย์ที่สั่งยา การศึกษาแบบ Meta-analysis พบว่า ยาที่มักเป็นปัจจัยเสี่ยงของการหกล้ม ได้แก่ ยาที่ออกฤทธิ์ต่อจิตประสาท ยารักษาภาวะหัวใจเต้นผิดจังหวะ ยาขับปัสสาวะ ยานอนหลับ และยาด้านภาวะซึมเศร้า ส่วนยาที่เพิ่มความเสี่ยงต่อการเกิดกระดูกหักจากการหกล้ม ได้แก่ ยานอนหลับ และยาคลายกล้ามเนื้อ อย่างไรก็ตามยาทุกชนิดที่ผู้สูงอายุกำลังรับประทานอยู่อาจเป็นสาเหตุของการหกล้มได้เสมอ

สภาวะจิตใจ (Mental State) และการรู้คิด (Cognitive) เป็นตัวประสานระหว่างสิ่งแวดล้อมกับกระบวนการเดินและการทรงตัว หากมีความบกพร่องทางด้านจิตใจและการรู้คิด เช่น กลัวการหกล้ม วิตกกังวล ซึมเศร้า หรือมีภาวะสมองเสื่อม จะทำให้ผู้สูงอายุเสี่ยงต่อการหกล้มเพิ่มมากขึ้น มีการศึกษาเป็นจำนวนมากที่ระบุไว้อย่างชัดเจนว่า ความกลัวการหกล้มของผู้สูงอายุเป็นภาวะด้านจิตใจที่สัมพันธ์กับการหกล้ม การศึกษาที่ติดตามกลุ่มผู้สูงอายุที่กลัวการหกล้มไปเป็นระยะเวลา 20 เดือน พบว่าความกลัวการหกล้มนี้สามารถทำนายการเกิดการหกล้มของผู้สูงอายุได้อย่างมีนัยสำคัญทางสถิติ ความกลัวทำให้เกิด

ความล้มเหลวไม่มั่นใจในก้าวเดิน ประสิทธิภาพการก้าวเท้าลดลง ก้าวเท้าได้ช้าและสั้นลง ซึ่งรูปแบบการก้าวเดินลักษณะนี้ทำให้เกิดความไม่มั่นคงของศีรษะลำตัวโอนเอนล้มง่ายขึ้น และนอกจากนี้ยังพบว่าการตอบสนองของกล้ามเนื้อขา การควบคุมการทรงตัว ความแข็งแรงของข้อสะโพกและข้อเข่าของผู้สูงอายุที่กลัวการหกล้มมีความแข็งแรงต่ำกว่าผู้สูงอายุที่ไม่กลัวการหกล้ม ดังนั้น ผู้สูงอายุที่กลัวการหกล้มจึงมีโอกาสเสี่ยงต่อการหกล้มมากกว่าผู้สูงอายุที่ไม่กลัวการหกล้มถึง 3.73 เท่า [15]

## 2.1.2 การบาดเจ็บจากการหกล้มของผู้สูงอายุ

### 2.1.2.1. ผลกระทบต่อสุขภาพกาย

การหกล้มก่อให้เกิดการบาดเจ็บตั้งแต่ระดับเล็กน้อยจนถึงขั้นรุนแรง เช่น ฟกช้ำ ถลอกตามร่างกาย ซึ่งการบาดเจ็บเล็กน้อยนี้ สามารถพบได้ประมาณครึ่งหนึ่งของการบาดเจ็บจากการหกล้มทั้งหมด การบาดเจ็บเหล่านี้อาจไม่ก่อให้เกิดผลกระทบมากนัก แต่หากเป็นการบาดเจ็บที่สร้างความเจ็บปวดเรื้อรังหรือการบาดเจ็บรุนแรง จะก่อให้เกิดผลกระทบอย่างมากทั้งต่อตัวผู้สูงอายุและครอบครัว ผู้สูงอายุที่หกล้มประมาณร้อยละ 50% [16] มีการบาดเจ็บที่รุนแรง เช่น กระดูกหัก การบาดเจ็บที่สมองและผิวหนังอย่างรุนแรง โดยร้อยละ 3.5-6 ของการหกล้มจะทำให้เกิดกระดูกหัก บริเวณกระดูกที่พบบ่อย คือ กระดูกข้อสะโพก เมื่อติดตามกลุ่มผู้สูงอายุที่หกล้มและมีกระดูกข้อสะโพกหักไปเป็นระยะเวลา 1 ปี พบว่า มีอัตราการเสียชีวิตสูงถึง ร้อยละ 20-30 และร้อยละ 25-75 ของผู้สูงอายุกลุ่มนี้ มีการสูญเสียความสามารถในการดำเนินกิจวัตรประจำวัน เป็นเหตุให้ผู้สูงอายุเข้าสู่ภาวะพึ่งพาเร็วขึ้น

### 2.1.2.2. ผลกระทบต่อจิตใจ

ผู้สูงอายุที่หกล้มมักมีปัญหาในการลุกเดิน ต้องมีคนคอยช่วยเหลืออยู่ตลอดเวลาทั้งที่ไม่มีความผิดปกติของระบบประสาทหรือข้อกระดูกใด ๆ กลุ่มอาการนี้ เรียกว่า “กลุ่มอาการภายหลังการหกล้ม” (Post-falls Syndrome) อาการนี้จะพบมากในผู้ที่มีอายุค่อนข้างมาก ซึ่งสามารถรักษาให้ดีขึ้นได้ด้วยการฟื้นฟูสมรรถภาพร่วมกับการส่งเสริมสถานะด้านจิตใจให้มีความเชื่อมั่นในตนเองประมาณร้อยละ 50-60 ของผู้สูงอายุที่เคยหกล้มจะเกิดความกลัวการหกล้มและไม่มั่นใจในการปฏิบัติกิจกรรม ผู้สูงอายุที่เกิดการบาดเจ็บที่รุนแรงจะต้องพักรักษาตัวในโรงพยาบาลนานกว่าวัยอื่น ๆ และหลังจากรับการรักษาพยาบาลแล้ว มักไม่สามารถกลับไปทำงานหรือดำเนินชีวิตได้ตามปกติ ทำให้ผู้สูงอายุเกิดความเครียด วิตกกังวล ขาดความมั่นใจในตนเอง และความรู้สึกมีคุณค่าในตนเองต่ำ เนื่องจากต้องพึ่งพาคูคณอื่นในการปฏิบัติกิจกรรมต่าง ๆ และกลัวการหกล้มซ้ำอีก การหกล้มและภาวะทุพพลภาพจากการหกล้มยังส่งผลให้เกิดความเสื่อมถอยของสมรรถภาพร่างกาย วิธีการดำเนินการในชีวิตประจำวันและกิจกรรมทางสังคมถูกจำกัด ทำให้ผู้สูงอายุต้องถูกแยกออกจากสังคมเกิดปัญหาทางด้านจิตใจและจิตสังคมตามมา ซึ่งทั้งหมดมีผลสืบเนื่องต่อระดับคุณภาพชีวิตของผู้สูงอายุ

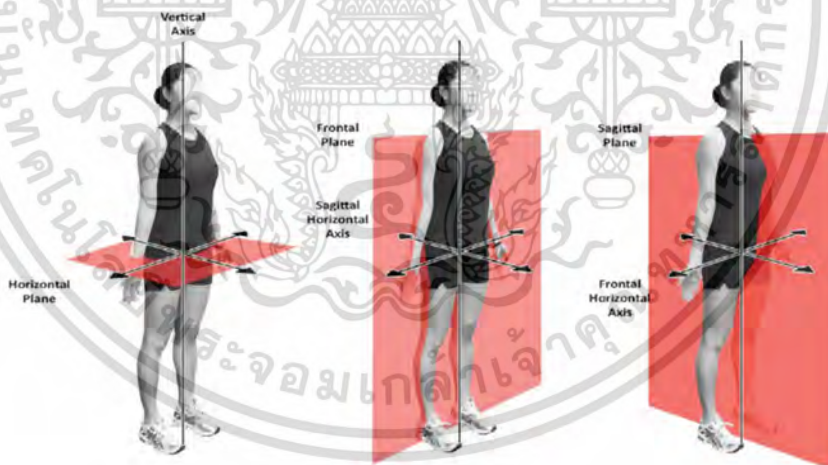
## 2.2 การศึกษาชีวกลศาสตร์ของการเคลื่อนไหวของร่างกายและการหกล้ม

ชีวกลศาสตร์เข้าถึงเหตุการณ์การลื่นและการหกล้มอธิบายพารามิเตอร์ของการเดิน เช่น การก้าวยาว ระยะการลื่น ความเร็วของส้นเท้า มุมของเท้า แรงกระทำจากพื้น เช่น แรงตามแนวนอนและแนวตั้ง แรงเสียดทาน เกี่ยวข้องในการเดินของมนุษย์ภายใต้เงื่อนไขปกติและไม่ปกติ เพื่อที่จะวิเคราะห์หลักการของเสถียรภาพของร่างกายและกลศาสตร์ของการลื่นและการหกล้ม มันจำเป็นที่จะต้องเข้าใจหลักพลวัตแต่ละส่วนของร่างกายในการเคลื่อนไหว [17]

### 2.2.1 ระบบพิกัดของร่างกาย

#### 2.2.1.1 ระนาบ (Plane)

ระนาบของการกระทำถูกกำหนดด้วยแนวของการอ้างอิงของร่างกาย ซึ่งแบ่งเป็น 3 ระนาบและแต่ละระนาบจะตั้งฉากซึ่งกันและกัน จากรูปที่ 2.2 Sagittal plane คือระนาบที่ตัดผ่านร่างกายจากหน้าไปหลังโดยแบ่งร่างกายออกเป็นส่วนซ้ายและส่วนขวา การเคลื่อนไหวที่เกิดขึ้นในระนาบนี้จะเป็นการยืดหดตัว Frontal plane คือระนาบที่ตัดผ่านร่างกายจากด้านหนึ่งไปยังอีกด้านหนึ่ง ซึ่งแบ่งร่างกายออกเป็นส่วนหน้ากับส่วนหลัง การเคลื่อนไหวที่เกิดขึ้นในระนาบนี้จะเป็นการกางออกและหุบ Transverse plane คือระนาบที่ตัดผ่านร่างกายในแนวขวาง และแบ่งร่างกายออกเป็นส่วนบนและส่วนล่าง การหมุนจะเกิดขึ้นที่ระนาบนี้




รูปที่ 2.2 ระบบพิกัดของร่างกาย [17]

#### 2.2.1.2 แกน (Axis)

แกน คือจุดที่วิ่งผ่านศูนย์กลางรอบ ๆ ข้อต่อซึ่งคือจุดหมุนของส่วนต่างๆ จากรูปที่ 2.2 sagittal axis คือจุดที่วิ่งผ่านข้อต่อจากหน้าไปหลัง front axis คือจุดที่วิ่งผ่านข้อต่อจากด้านหนึ่งไปยังอีกด้านหนึ่ง vertical axis คือจุดที่วิ่งผ่านข้อต่อจากบนไปล่าง

### 2.2.1.3 จุดศูนย์ถ่วง (Center of Gravity)


เมื่อไหร่ก็ตามที่ระนาบแต่ละระนาบตัดผ่านกึ่งกลางของกันและกัน เรียกว่า cardinal plane ระนาบนี้จะแบ่งร่างกายทุกส่วนเท่าๆกัน จุดที่ทั้งสามระนาบตัดกันคือจุดศูนย์ถ่วง (Center of Gravity) ในท่ายืนปกติจะอยู่ที่ประมาณระดับของกระดูกสันหลังส่วนกระเบนเหน็บชั้นที่สอง ดังแสดงในรูปที่ 2.3 จุดศูนย์ถ่วงจะแตกต่างกันไปตามลักษณะท่าทาง และรูปร่างของร่างกายที่เปลี่ยนแปลง



รูปที่ 2.3 จุดศูนย์ถ่วงของร่างกาย [17]

### 2.2.1.4 เสถียรภาพ (Stability)

ในทางวิทยาศาสตร์ วัตถุจะเกิดความสมดุล เมื่อทอร์ก (Torque) ทั้งหมดกระทำต่อวัตถุจากทุกด้านมีค่าเท่ากัน และทำให้อยู่ในสภาวะสมดุล จุดสมดุลของร่างกายมนุษย์คือจุดศูนย์ถ่วงของร่างกาย ความปลอดภัยและความเสี่ยงของการเคลื่อนไหวขึ้นอยู่กับสถานะของสมดุลซึ่งขึ้นอยู่กับหลักการของความสัมพันธ์จุดศูนย์กลางของแรงโน้มถ่วงของร่างกายและพื้นผิวที่รองรับ ซึ่ง Base of support (BOS) คือ ส่วนของร่างกายที่ติดกับพื้นผิวที่รองรับหรือติดกับพื้นและ Line of gravity (LOG) คือ เส้นสมมติในแนวตั้งที่ลากผ่าน COG ไปยังจุดศูนย์กลางของโลก ดังแสดงในรูปที่ 2.4



รูปที่ 2.4 Base of support (BOS) และ Line of gravity (LOG) ของมนุษย์ [17]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.2.2 หลักพลวัตของการเคลื่อนไหวของมนุษย์

### 2.2.2.1 ความเร่งของร่างกาย (Body Acceleration)

ความเร่งของร่างกายขึ้นอยู่กับรูปแบบของการเคลื่อนไหวของร่างกายตามแนวแกนร่างกายในลักษณะต่าง ๆ [18] ซึ่งความเร่งที่เกิดจากการเคลื่อนไหวในแนวแกนตั้ง (vertical) จะมีความถี่สูงกว่าความเร่งที่เกิดจากแนวแกนแบ่งหน้าหลัง (antero-posterior) และแนวแกนแบ่งซ้ายขวา (medio-lateral) ดังรูปที่ 2.5



รูปที่ 2.5 แนวแกนการเคลื่อนไหวร่างกายของมนุษย์ [18]

ความถี่ของการเคลื่อนไหวที่เกิดขึ้นจะมีความแตกต่างกันในแต่ละส่วน ยกตัวอย่าง ขณะเดินถ้าวัดที่ร่างกายส่วนบน ช่วงความถี่ของความเร่งจะมีค่าระหว่าง 0.8Hz ถึง 15Hz และถ้าวัดแนวแกนตั้งขณะที่สั่นเท้ากระทบกับพื้นความถี่ของความเร่งจะมีค่าประมาณ 60Hz และสำหรับกิจกรรมต่างๆในชีวิตประจำวันช่วงความถี่ของความเร่งส่วนใหญ่จะมีค่า 0.3Hz ถึง 3.5Hz

ขนาดของความเร่งในการเคลื่อนไหวจะแตกต่างกันในแต่ละส่วน ยกตัวอย่าง ขณะเดิน ถ้าวัดที่ร่างกายส่วนบน ขนาดของความเร่งจะเปลี่ยนแปลงในทิศทางแนวตั้งระหว่าง  $-0.3g$  ถึง  $0.8g$  และจะเปลี่ยนแปลงในแนวแกนหน้าหลังระหว่าง  $-0.3g$  ถึง  $0.4g$  สำหรับการวิ่งจะสร้างแอมพลิจูดความเร่งที่มีขนาดกว้างมากซึ่งจะเปลี่ยนแปลงในแนวแกนนอนระหว่าง  $0.9g$  ถึง  $5.0g$  และจะเปลี่ยนแปลงที่ข้อเท้าในแนวแกนตั้งระหว่าง  $3.0g$  ถึง  $12.0g$

เพื่อที่จะตรวจจับกิจกรรมในชีวิตประจำวันโดยใช้เซนเซอร์วัดความเร่ง ในการวัดความเร่งของการเดินอาจสุ่มความถี่ที่อย่างน้อย 20Hz และใช้ช่วงวัดความเร่งอยู่ในช่วง  $\pm 6g$  [19] และ เพื่อที่จะได้ความถี่สูงของการเคลื่อนไหวน้อย ๆ ของผู้สูงอายุ [20] เพิ่มความถี่ในการสุ่มเป็น 150Hz ซึ่งจะสามารถนำไปใช้อธิบายการเคลื่อนไหวเฉพาะในผู้สูงอายุ และสำหรับการสังเกตการเคลื่อนไหวของมนุษย์และตรวจจับการหกล้มจะใช้ความถี่การสุ่มในช่วง 50Hz ถึง 1kHz

### 2.2.2.2 ความเร็วเชิงมุมของร่างกาย (Body Angular Velocity)

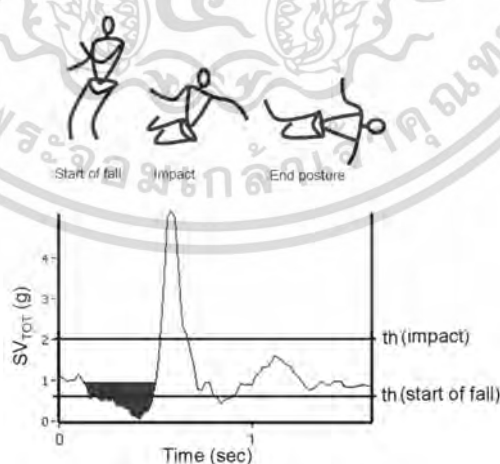
Lui และคณะ [21] เสนอวิธีการตรวจจับการหกล้มและกิจกรรมในชีวิตประจำวัน โดยใช้ระบบ กล้อง และ เซนเซอร์วัดความเร็วเชิงมุม (gyroscope) ติดที่หน้าอกเพื่อที่จะตรวจจับความเร่งเชิงมุม ส่วนบน ซึ่งมีอาสาสมัครผู้สูงอายุ 10 คน และได้ผลลัพธ์ของความเร็วเชิงมุมสูงสุดเฉลี่ยแตกต่างกันในแต่ละกิจกรรม คือ ขณะเดิน  $7-9.5^{\circ}/s$  ขณะกำลังนั่ง  $112.1^{\circ}/s$  และการโน้มตัวจะสูงกว่า  $118.7^{\circ}/s$  สำหรับการล้มไปด้านหลัง ความเร็วเชิงมุมสูงสุดที่มากที่สุดของกิจกรรมในชีวิตประจำวันจะไม่เกิน  $220^{\circ}/s$  [22] นอกจากนี้จากบทความของ Rodríguez และคณะ [23] ที่เสนอระบบตรวจจับการเคลื่อนไหวโดยใช้ การวัดความเร็วเชิงมุม ซึ่งสุ่มความถี่ในช่วง  $50-350\text{Hz}$

### 2.2.2.3 ความแตกต่างระหว่างวัยรุ่นกับผู้สูงอายุ

คุณสมบัติทางไดนามิกของการเคลื่อนที่ระหว่างผู้สูงอายุกับวัยรุ่น [24] สามารถสังเกตได้จากค่า ความเร่งที่ส่วนต่างๆ ซึ่งสามารถแสดงได้ดังนี้ ค่าความเร่งสูงสุดเฉลี่ยฝั่งบวจากส่วนanterior-posterior ของผู้ทดลองผู้สูงอายุจะมีค่าต่ำกว่าผู้ทดลองวัยรุ่น ซึ่งผู้สูงอายุ เท่ากับ  $0.26g$  แต่วัยรุ่นเท่ากับ  $0.40g$  ค่า ความเร่งสูงสุดเฉลี่ยฝั่งลบของการสัมผัสของสันเท้าของผู้ทดลองผู้สูงอายุจะมีค่าต่ำกว่าผู้ทดลองวัยรุ่น ซึ่ง ผู้สูงอายุ เท่ากับ  $-0.20g$  แต่วัยรุ่นเท่ากับ  $-0.09g$  และ Time-Delay ระหว่างความเร่งที่ส่วนหัวและ ลำตัวของผู้ทดลองผู้สูงอายุจะมีค่าสูงกว่าผู้ทดลองวัยรุ่น ซึ่งผู้สูงอายุ เท่ากับ  $-31.3\text{ms}$  แต่วัยรุ่นเท่ากับ  $-96.7\text{ms}$

### 2.2.2.4 คุณสมบัติการหกล้มของมนุษย์

Kangas M. และคณะ [25] แบ่งการหกล้มออกเป็น 3 เฟสดังแสดงในรูปที่ 2.5



รูปที่ 2.6 เฟสการหกล้มจากสัญญาณเวกเตอร์ผลรวมความเร่ง 3 แกน [25]

- เฟสก่อนการหกล้ม (start of fall) คือ ช่วงของกิจกรรมบางกิจกรรมที่ซึ่งเป็นเหตุการณ์นำไปสู่การหกล้ม ยกตัวเช่น การลื่น การไถล หรือการสะดุด เป็นต้น
- เฟสการกระทบพื้น (impact) คือช่วงของการที่บางส่วนของร่างกาย เช่น ศรีษะ มือ สะโพก หรือหัวเข่า เป็นต้น กระทบกับพื้น
- เฟสหลังจากการหกล้ม (end posture) คือช่วงของกิจกรรมบางกิจกรรมที่เกิดหลังจากการที่บางส่วนของร่างกายกระทบพื้น

## 2.3 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับระบบตรวจจับการหกล้มและรู้จำกิจกรรมทางกายภาพของมนุษย์โดยใช้เซนเซอร์วัดความเร่งมีการพัฒนาอย่างต่อเนื่อง แบ่งเป็น 2 กลุ่มหลัก คือ กลุ่มงานวิจัยที่มุ่งเน้นหาตำแหน่งที่เหมาะสมสำหรับตรวจจับการหกล้มและรู้จำกิจกรรมทางกายภาพของมนุษย์ และ กลุ่มงานวิจัยที่มุ่งเน้นพัฒนาอัลกอริทึมสำหรับตรวจจับการหกล้มและรู้จำกิจกรรมทางกายภาพของมนุษย์

### 2.3.1 กลุ่มงานวิจัยงานวิจัยที่มุ่งเน้นหาตำแหน่งที่เหมาะสมสำหรับตรวจจับการหกล้มและรู้จำกิจกรรมทางกายภาพของมนุษย์

Kangas M. และคณะ [25] เสนออัลกอริทึมสำหรับตรวจจับการหกล้มโดยวิธีตัดสินใจโดยใช้ค่าเทรชโฮลด์ (Threshold) จากค่าพารามิเตอร์ของเซนเซอร์วัดความเร่ง งานวิจัยนี้มุ่งเน้นที่จะค้นหาค่าเทรชโฮลด์ที่ใช้สำหรับตัดสินใจ และตำแหน่งที่ติดเซนเซอร์วัดความเร่งบนร่างกายที่เหมาะสมที่สุดสำหรับตรวจจับการหกล้ม ดังแสดงในรูปที่ 2.5 ในการทดลองใช้เซนเซอร์วัดความเร่งสามแกนติดที่เอว ข้อมือ และหัว จำลองกิจกรรมสองกลุ่มคือ การหกล้ม และกิจกรรมในชีวิตประจำวัน


จากผลการทดลองพบว่า การติดเซนเซอร์วัดความเร่งที่หัวและที่เอว สามารถตรวจจับการหกล้มได้อย่างมีประสิทธิภาพพอๆกัน สรุปว่าสำหรับการใช้งานจริงการติดเซนเซอร์ที่เอวเหมาะสมมากกว่า

H. Gjoreski และคณะ [26] เสนอการเปรียบเทียบตำแหน่งของการติดเซนเซอร์วัดความเร่งสำหรับการรู้จำท่าทางและตรวจจับการหกล้ม สำหรับการทดลองแบ่งออกเป็น 2 แบบคือ การรู้จำท่าทางและตรวจจับการหกล้ม โดยมีกิจกรรมดังแสดงในตารางที่ 2.1

**ตารางที่ 2.1** ประเภทกิจกรรมสำหรับการทดลองของ H. Gjoreski และคณะ

การทดลองที่ 1: การรู้จักกิจกรรม	การทดลองที่ 2: การตรวจจับการหกล้ม	
การนอน การนั่ง การยืน นอนคว่ำ นั่งบนพื้น นั่งลง ลุกขึ้นยืน	หกล้ม	สะดุด หกล้มช้า หกล้มจากเก้าอี้อย่างช้า หกล้มจากเก้าอี้อย่างรวดเร็ว
	ไม่หกล้ม	นั่งอย่างรวดเร็ว นอนคว่ำ

ในการทดลองใช้เซนเซอร์วัดความเร่ง 4 เซนเซอร์ติดที่เอว หน้าอก ต้นขา และข้อเท้าของอาสาสมัคร และนำสัญญาณของเซนเซอร์วัดความเร่งจาก 9 กรณีได้แก่ ออก เอว หน้าอกกับข้อเท้า เอวกับข้อเท้า หน้าอกกับต้นขา หน้าอกกับต้นขา เอวกับต้นขา หน้าอก ข้อเท้ากับต้นขา เอว ข้อเท้ากับต้นขา และหน้าอก เอว ข้อเท้า และต้นขา มาวิเคราะห์ตามระบบรู้จักกิจกรรมและตรวจจับการหกล้มดังแสดงในรูปที่ 2.6




**รูปที่ 2.7** ระบบรู้จักกิจกรรมและตรวจจับการหกล้มของ H. Gjoreski และคณะ [26]

จากผลการทดลองพบว่า การติดเซนเซอร์วัดความเร่งที่อกและที่เอว สามารถตรวจจับการหกล้มได้อย่างมีประสิทธิภาพพอๆกัน สรุปว่าสำหรับการใช้งานจริงการติดเซนเซอร์ที่เอวเหมาะสมมากกว่าเพราะมีความสะดวกสบายมากกว่า

### 2.3.2 กลุ่มงานวิจัยงานวิจัยที่มุ่งเน้นพัฒนาอัลกอริทึมสำหรับตรวจจับการหกล้มและรู้จำกิจกรรมทางกายภาพของมนุษย์

โดยทั่วไประบบตรวจจับการหกล้มจะประกอบไปด้วย 3 ขั้นตอน คือ การเก็บข้อมูล (Signal Acquisition) การดึงคุณลักษณะ (Feature Extraction) และ การตัดแยกประเภท (Classification) ดังแสดงในรูปที่ 2.7



รูปที่ 2.8 ขั้นตอนตรวจจับการหกล้มโดยทั่วไป

Omar Aziz และ Stephen N. Robinovitch [27] นำเสนออัลกอริทึมสำหรับตัดแยกสาเหตุการหกล้มของมนุษย์จากเซนเซอร์ที่สามารถสวมใส่ได้ ซึ่งอัลกอริทึมประกอบด้วย 3 ขั้นตอน คือขั้นตอนแรกทำการเก็บสัญญาณจากเซนเซอร์วัดความเร่งจาก 5 ตำแหน่ง ได้แก่ หัว กระดูกสันอก เวด้านขวา ข้อเท้าขวา ข้อเท้าซ้าย ดังแสดงในรูปที่ 2.8




รูปที่ 2.9 ตำแหน่งที่ใช้สำหรับติดเซนเซอร์วัดความเร่ง [20]

ต่อมาดึงคุณลักษณะจากสัญญาณโดยใช้ค่าเฉลี่ยและค่าความแปรปรวนจากเซนเซอร์วัดความเร่งแกน X, Y และ Z สุดท้ายตัดแยกกิจกรรมโดยใช้การวิเคราะห์การจำแนกเชิงเส้น (Linear Discriminant Analysis)

N. Nattaitanakul และคณะ [11] นำเสนออัลกอริทึมสำหรับตัดแยกประเภทกิจกรรมของมนุษย์จากเซนเซอร์วัดความเร่ง 3 แกน ซึ่งอัลกอริทึมประกอบด้วย 3 ขั้นตอน ดังแสดงในรูปที่ 2.8 คือขั้นตอนแรกทำการเก็บสัญญาณจากเซนเซอร์วัดความเร่งที่ติดที่เอว ต่อมาดึงคุณลักษณะจากสัญญาณโดยการแปลงเวฟเลต สุดท้ายตัดแยกประเภทของกิจกรรมโดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ซึ่งการตัดแยกกิจกรรมจะประกอบไปด้วย 2 กลุ่ม คือ 1) กลุ่มหกล้ม ประกอบด้วย ล้มไปด้านหน้า ล้มไป

ด้านหลัง ล้มไปด้านซ้าย ล้มไปด้านขวา และล้มขณะที่ลุกขึ้นยืน 2) กลุ่มไม่ล้ม ประกอบด้วย ล้มตัวลงนอนบนที่นอน ลุกจากที่นอน นั่งเก้าอี้ ลุกจากเก้าอี้ และเดิน ซึ่งการทดลองใช้จำนวนข้อมูลทั้งหมด 1500 ข้อมูล ที่ได้จากอาสาสมัครทั้งหมด 5 คน อัลกอริทึมของ N. Nattaitanakul และคณะ สามารถตรวจจับสัญญาณประเภทการหกล้ม และไม่หกล้มได้อย่างแม่นยำ



รูปที่ 2.10 อัลกอริทึมสำหรับตรวจจับการหกล้มของ Nattaitanakul [11]

## บทที่ 4

# ขั้นตอนการวิจัยระบบรู้จำกิจกรรมทางกายภาพ

วิทยานิพนธ์ฉบับนี้นำเสนอวิธีการลดมิติแบบใหม่สำหรับระบบรู้จำกิจกรรมทางกายภาพของมนุษย์ ซึ่งสามารถแบ่งเป็น 2 ส่วนสำคัญ คือ ส่วนระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหว (Signal Acquisition) โดยตัวอุปกรณ์จะติดกับตัวผู้ใช้งานและส่งข้อมูลการเคลื่อนไหวตลอดเวลาที่ทำการทดลอง และส่วนของอัลกอริทึมสำหรับตรวจจับการทักล้ม แบ่งเป็น 3 ขั้นตอน ได้แก่ การดึงคุณลักษณะของสัญญาณ (Feature Extraction) โดยการใช้การแปลงเวฟเลต จากนั้นทำการลดมิติของคุณลักษณะเวฟเลต โดยใช้วิธีการลดมิติที่นำเสนอ (Proposed Dimension Reduction Method) สุดท้ายโครงข่ายประสาทเทียมถูกนำมาใช้ในการรู้จำกิจกรรมทางกายภาพของมนุษย์ (Human Physical Activity Recognition) ดังแสดงในรูปที่ 4.1 นอกจากนี้วิทยานิพนธ์ฉบับนี้หาการรวมกันของพารามิเตอร์จากแต่ละขั้นตอนข้างต้นที่เหมาะสมที่สุดสำหรับการใช้งานจริง



รูปที่ 4.1 ลำดับขั้นตอนสำหรับรู้จำกิจกรรมทางกายภาพของมนุษย์

### 4.1 ระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหว (Signal Acquisition System)


ระบบตรวจวัดสัญญาณความเร่งประกอบด้วย 2 ส่วนหลัก คือ ส่วนอุปกรณ์ตรวจวัดและส่งสัญญาณ และส่วนรับและจัดเก็บสัญญาณ ซึ่งตัวอุปกรณ์จะถูกติดไว้ที่เอวฝั่งขวาของผู้ทดลองและส่งสัญญาณไปเก็บและประมวลผลยังคอมพิวเตอร์โดยผ่านการสื่อสารแบบบลูทูธ ดังแสดงในรูปที่ 4.2



รูปที่ 4.2 การใช้งานอุปกรณ์ตรวจวัดสัญญาณ

### 4.1.1 อุปกรณ์ตรวจวัดและส่งสัญญาณ (Signal Acquisition Device)


อุปกรณ์ตรวจวัดสัญญาณความเร่งประกอบไปด้วย 3 ส่วน ดังแสดงในรูปที่ 4.3 ส่วนแรกคือ เซนเซอร์วัดความเร่งสามแกน (ET-MMA7331L) ใช้สำหรับวัดสัญญาณความเร่งของการเคลื่อนไหวของอาสาสมัคร ต่อมาไมโครคอนโทรลเลอร์ใช้สำหรับรับสัญญาณความเร่งจากเซนเซอร์และส่งข้อมูลผ่านบลูทูธไปยังคอมพิวเตอร์เพื่อเก็บสัญญาณและนำไปวิเคราะห์



รูปที่ 4.3 อุปกรณ์ตรวจวัดสัญญาณความเร่ง

#### 4.1.1.1 เซนเซอร์วัดความเร่งสามแกน (Tri-axial Accelerometer)


เซนเซอร์วัดความเร่งสามแกน (ET-MMA7331L) [41] เป็นตัววัดความเร่งเมื่อวัตถุมีการสั่นสะเทือน หรือการเคลื่อนที่ ซึ่งสัญญาณเอาต์พุตออกมาในรูปสัญญาณอนาล็อก ซึ่งโมดูลนี้สามารถวัดค่าได้สามแกน คือ แกน X แกน Y และแกน Z ดังแสดงรูปที่ 4.4 (ก) และสามารถเลือกย่านการวัดได้ 2 ย่านคือ  $\pm 4g$  และ  $\pm 12g$  โครงสร้างของเซนเซอร์ดังแสดงรูปที่ 4.4 (ข)



รูปที่ 4.4 โครงสร้างของเซนเซอร์วัดความเร่งสามแกน (ET-MMA7331L)

- (ก) ตำแหน่งทิศทางของเซนเซอร์วัดความเร่งทั้ง 3 แกน
- (ข) โครงสร้างของเซนเซอร์และตำแหน่งขาต่อใช้งาน

สำหรับงานวิจัยฉบับนี้ จะเทียบแกนของเซนเซอร์กับระบบแกนของร่างกาย ซึ่งแกน X จะเทียบกับแกน vertical แกน Y จะเทียบกับแกน sagittal horizontal และแกน Z จะเทียบกับแกน frontal horizontal ดังแสดงในรูปที่ 4.5



รูปที่ 4.5 ระบบแกนที่ใช้กับงานวิจัย

ค่าแรงดันเอาต์พุตที่อ่านได้จากเซนเซอร์ประกอบไปด้วย 2 ส่วนคือ แรงดัน Offset และ Sensitivity ในส่วนของแรงดัน Offset นั้นจะมีการแปรตามแรงดันไฟเลี้ยง หาได้จากสมการที่ 4.1

$$V_{\text{offset}(0-g)} = V_{DD}/2 \quad (4.1)$$

ส่วนค่า Sensitivity หรือค่าความไวในการวัดจะถูกกำหนดจากโรงงาน ซึ่งค่าความไวนี้จะขึ้นอยู่กับย่านการวัดที่เลือกใช้งาน ซึ่งสามารถกำหนดสถานะการใช้งานได้ดังตารางที่ 4.1 การคำนวณขนาดแรงดันของขาสัญญาณในแนวแกน X, Y, และ Z ได้ดังสมการที่ (4.2)

$$V_{\text{out}(analog)} = V_{\text{offset}} + (\text{Sensitivity} \times g) \quad (4.2)$$

กำหนดให้  $V_{\text{out}(analog)}$  คือขนาดแรงดันที่วัดได้จากขาของเซนเซอร์วัดความเร่งแกน X, Y, และ Z ส่วน  $V_{\text{offset}}$  คือค่าครึ่งหนึ่งของแรงดันไฟเลี้ยงที่จ่ายให้กับตัวเซนเซอร์วัดความเร่ง และค่าความไวคือค่าจากตารางที่ 4.1

ตารางที่ 4.1 สถานะของเซนเซอร์วัดความเร่ง

g-Select	g-Rang	Sensitivity
0	4g	308mV/g
1	12g	83.6 mV/

การใช้งานเซนเซอร์วัดความเร่งแบบสามแกนสามารถเลือกโหมดการทำงานได้ 3 โหมดดังนี้ โหมดพัก (Sleep) โหมดทดสอบ (Self-Test) และโหมดวัดสัญญาณความเร่ง (Measurement) สำหรับวิทยานิพนธ์ฉบับนี้เลือกใช้โหมดวัดสัญญาณความเร่ง มีลักษณะการทำงานคือ เซนเซอร์จะวัดสัญญาณค่าแรงโน้มถ่วง (g) แกน X, Y, และ Z โดยต้องกำหนดขาสัญญาณของ Self-Test และ Sleep เป็น 0 และ 1 ตามลำดับ และขาสัญญาณ g-Select เป็น 0 g เลือกวัดความเร่งที่ย่าน 4g ซึ่งมีรายละเอียดของขาเซนเซอร์ดังแสดงในตารางที่ 4.2

**ตารางที่ 4.2** รายละเอียดขาของเซนเซอร์วัดความเร่ง

ลำดับขา	ชื่อขา	รายละเอียด
1	VDD	ขาจ่ายไฟเลี้ยง 2.2 V - 3.6V
2	XOUT	ขาสัญญาณแรงดัน Output ในแนวแกน X (Analog)
3	YOUT	ขาสัญญาณแรงดัน Output ในแนวแกน Y (Analog)
4	ZOUT	ขาสัญญาณแรงดัน Output ในแนวแกน Z (Analog)
5	VSS	ขาสัญญาณ Ground
6	SLEE	ขาสัญญาณ เลือก Sleep Mode ทำงานที่ Logic 0
7	g-Select	ขาสัญญาณ สำหรับเลือกย่านการวัด '0'=Rang 4-g ; '1'=Rang 12-g
8	Self	ขาสัญญาณสำหรับเลือก Self-Test Mode ทำงานที่ Logic '1'

#### 4.1.1.2 ไมโครคอนโทรลเลอร์

ไมโครคอนโทรลเลอร์ (PIC32MX460F512L) ใช้สำหรับประมวลผลสัญญาณความเร่งจากเซนเซอร์วัดความเร่ง ทำหน้าแปลงสัญญาณอนาล็อกเป็นสัญญาณดิจิทัล 10 บิตข้อมูล



**รูปที่ 4.6** ไมโครคอนโทรลเลอร์เบอร์ PIC32MX460F512L ของบริษัทไมโครชิพ

#### 4.1.1.3 บลูทูธ (Bluetooth)

บลูทูธ คือ เทคโนโลยีการสื่อสารแบบไร้สายระยะใกล้แบบเครือข่ายไร้สายส่วนบุคคลเป็นมาตรฐานที่ถูกรอกออกมาเพื่อใช้ในการเชื่อมต่ออุปกรณ์ไร้สายขนาดเล็ก



รูปที่ 4.7 บลูทูธ HC05

ซึ่งในวิทยานิพนธ์เล่มนี้ทางผู้วิจัยได้ใช้ บลูทูธ (HC05) ดังแสดงในรูปที่ 4.4 เป็นตัวสื่อสาร ระหว่าง ไมโครคอนโทรลเลอร์กับคอมพิวเตอร์

#### 4.1.2 การรับและเก็บสัญญาณ


ในการเตรียมข้อมูลของสัญญาณการเคลื่อนไหวต่างๆ เริ่มต้นด้วยการกำหนดให้เครื่องตรวจวัดสัญญาณการเคลื่อนไหวมีความถี่ในการวัดสัญญาณที่ 200 เฮิรต (Hz) ซึ่งสัญญาณที่วัดด้วยเซนเซอร์วัดความเร่งจะอยู่ในรูปแบบของอนาล็อกและจะแปลงเป็นสัญญาณดิจิตอลดังสมการ (4.3) และ (4.4) จากนั้นสัญญาณจะถูกส่งผ่านทางบลูทูธเพื่อไปบันทึกด้วยคอมพิวเตอร์

$$g = \frac{(V_{ADC} \times R_{ADC}) - V_{DD}/2}{Sensitivity}, \quad (4.3)$$

$$R_{ADC} = \frac{V_{DD}}{2^n - 1} \quad (4.4)$$

โดยกำหนดให้ค่า  $g$  คือสัญญาณความเร่งในหน่วย  $m/s^2$ ,  $V_{ADC}$  คือค่าสัญญาณที่บันทึกไว้,  $V_{DD}$  คือค่าแรงดันที่จ่ายให้กับตัวตรวจจับความเร่งแบบสามแกน,  $n$  คือจำนวนบิต (BIT) ของการแปลงสัญญาณอนาล็อกเป็นสัญญาณดิจิตอล ( $n=10$ ),  $Sensitivity$  คือค่าความละเอียดที่กำหนดให้กับเซนเซอร์วัดความเร่งแบบสามแกนในการตรวจวัดสัญญาณการเคลื่อนไหวซึ่งในงานวิจัยนี้กำหนดไว้ที่ 308mV/g

จากการสังเกตของผู้วิจัย พบว่าสัญญาณความเร่งจากการหกล้ม สามารถแบ่งได้ 3 ส่วนดังแสดงในรูปที่ 4.7 ส่วนแรกคือสัญญาณความเร่งที่ได้มาจากการหกล้มเช่น ลื่น, สะดุด และอื่นๆ ซึ่งในส่วนนี้จะใช้เวลาประมาณ 1 วินาที ส่วนที่สองคือสัญญาณความเร่งที่เกิดขึ้นเมื่อบางส่วนของร่างกายกระทบกับพื้น เช่น สะโพก มือ ขา หรือ หัว เนื่องจากการกระทบทำให้เกิดการเปลี่ยนแปลงของร่างกายอย่างรวดเร็วทำให้เกิดสัญญาณความเร่งที่มีค่าสูงสุด ซึ่งระยะเวลาที่เกิดขึ้นประมาณ 100-200 มิลลิวินาที และส่วนสุดท้าย คือ สัญญาณความเร่งของกิจกรรมบางอย่างที่เกิดขึ้นหลังจากที่กระทบพื้น เช่น การม้วนตัว หรือ การไถลของร่างกาย ซึ่งในส่วนนี้จะใช้น้อยกว่า 1 วินาที ดังนั้นผู้วิจัยจึงประมาณสัญญาณความเร่งของการหกล้มไว้ที่ประมาณ 2 วินาที จึงทำให้ผู้วิจัยเก็บบันทึกสัญญาณความเร่งการเคลื่อนไหวประเภทต่างๆ ใช้น้อยกว่า 2 วินาทีด้วย



**รูปที่ 4.8** ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มไปด้านหน้า

จากที่กล่าวมาข้างต้น สัญญาณการเคลื่อนไหวที่ได้จากแกน vertical (X), sagittal horizontal (Y) และ frontal horizontal (Z) แต่ละแกนจะมีความยาวเท่ากับ 416 samples ดังนั้นจำนวนของ samples ทั้งหมดที่ใช้ในอัลกอริทึมที่นำเสนอจะยาวเท่ากับ 1248 samples


ตัวอย่างสัญญาณการเคลื่อนไหว 10 รูปแบบ ประกอบด้วยกิจกรรมทางกายภาพในชีวิตประจำวัน 5 กิจกรรมได้แก่ 1.) ลุกขึ้นจากที่นอน 2.) ล้มตัวลงนอนบนที่นอน 3.) ลุกขึ้นจากเก้าอี้ 4.) นั่งลงบนเก้าอี้ 5.) การเดิน และเหตุการณ์การหกล้ม 5 เหตุการณ์ ได้แก่ 1.) ล้มไปด้านหน้า 2.) ล้มไปด้านหลัง 3.) ล้มไปด้านซ้าย 4.) ล้มไปด้านขวา และ 5.) ล้มในขณะที่กำลังลุกขึ้นยืน ดังแสดงในรูปที่ 4.9 – 4.18




**รูปที่ 4.9** ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการลุกจากที่นอน



รูปที่ 4.10 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มตัวลงนอน



รูปที่ 4.11 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการลุกจากเก้าอี้



รูปที่ 4.12 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการนั่งเก้าอี้



รูปที่ 4.13 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการเดิน



รูปที่ 4.14 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มหน้า



รูปที่ 4.15 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มหลัง



รูปที่ 4.16 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มซ้าย



รูปที่ 4.17 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มขวา



รูปที่ 4.18 ตัวอย่างสัญญาณการเคลื่อนไหวของแกน vertical -, sagittal horizontal -, และ frontal horizontal - ของการหกล้มในขณะที่กำลังลุกขึ้นยืน


## 4.2 อัลกอริทึมที่นำเสนอสำหรับตรวจจับสัญญาณการเคลื่อนไหว

วิทยานิพนธ์ฉบับนี้นำเสนออัลกอริทึมสำหรับตรวจจับสัญญาณการเคลื่อนไหวซึ่งมี 3 ขั้นตอน ดังต่อไปนี้

1. การดึงคุณลักษณะของสัญญาณความเร่งโดยใช้การแปลงเวฟเลต (Wavelet Transform)
2. การลดมิติของคุณลักษณะเวฟเลตโดยใช้วิธีการลดมิติที่นำเสนอ
3. การรู้จำกิจกรรมการเคลื่อนไหวในชีวิตประจำวันและเหตุการณ์การหกล้มจากสัญญาณความเร่ง โดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น

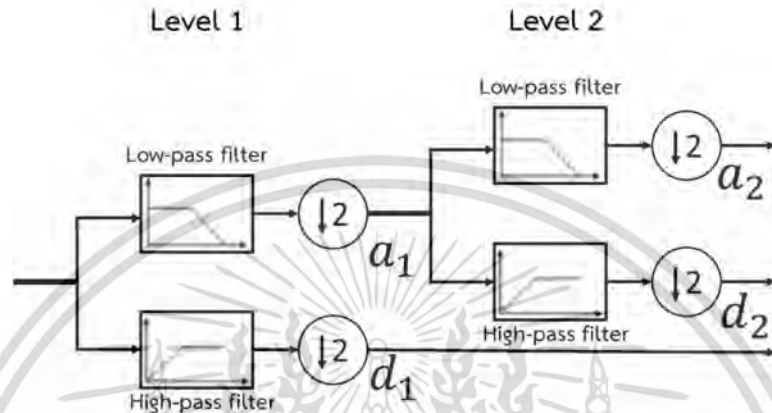
### 4.2.1 การดึงคุณลักษณะของสัญญาณความเร่งโดยใช้การแปลงเวฟเลต (Wavelet Transform)

ในวิทยานิพนธ์ฉบับนี้ได้นำเวฟเลตมาประยุกต์ใช้กับสัญญาณความเร่ง ซึ่งสามารถทำการแปลงได้ดังรูป 4.19 จากรูปนั้นสามารถอธิบายได้ว่าการแปลงเวฟเลตของสัญญาณความเร่งจะแปลงเป็นแนวแกนนอน ตามจำนวนตัวอย่าง (Sample) ของสัญญาณความเร่ง ซึ่งทำให้สัญญาณความเร่งแบ่งออกเป็น 2 สับแบนด์ ซึ่งเป็นการแปลงเวฟเลตระดับเดียว (Single level) โดยที่สับแบนด์แรก ( $S_{b1}$ ) เป็นส่วนของสัญญาณความเร่งที่ผ่านตัวกรองความถี่ต่ำผ่าน ซึ่งแทนด้วย  $a$  และสับแบนด์ที่สอง ( $S_{b2}$ ) จะเป็นส่วนของสัญญาณความเร่งที่ผ่านตัวกรองความถี่สูงผ่าน ซึ่งแทนด้วย  $d$



รูปที่ 4.19 การแยกองค์ประกอบสัญญาณความเร่งโดยใช้หลักการของพีวเตอร์แบงค์

ผลจากการแปลงเวฟเลต ข้อมูลในสับแบนด์ที่ 1 จะเป็นข้อมูลที่เป็นสัมประสิทธิ์ความถี่ต่ำ และแสดงรายละเอียดของสัญญาณความถี่ในสับแบนด์ที่ 2 ถ้านำเอาสับแบนด์ที่ 1 ไปผ่านการแปลงเวฟเลตต่อไปอีกจะทำให้สามารถแยกสัญญาณความถี่ออกได้เป็นหลายสับแบนด์ เรียกว่าการแปลงเวฟเลตหลายระดับ (Multilevel Wavelet Transform) ดังรูปที่ 4.20



รูปที่ 4.20 การแปลงแบบเวฟเลตแบบไม่ต่อเนื่องโดยพื้นฐานการวิเคราะห์แบบ multi-resolution


โดยในงานวิจัยนี้ได้เลือกใช้ Mother Wavelet ทั้งหมด 4 ชนิดคือ Daubechies Wavelet (DB), Symlet Wavelet (Sym), Coiflet Wavelet (Coif) และ Biorthogonal Wavelet (Bior) และเลือกใช้การแปลงเวฟเลตแบบไม่ต่อเนื่อง 1 – 2 ระดับ เพื่อที่จะนำไปวิเคราะห์เปรียบเทียบว่าสัญญาณความถี่จากการแปลงเวฟเลตว่าเวฟเลตแบบไหนเหมาะสมที่สุดโดยการเปรียบเทียบทั้ง 2 ระดับ ตัวอย่างการแปลงเวฟเลตของสัญญาณความถี่ของการหกล้มไปข้างหน้าแสดงดังรูป 4.21 - 4.28



รูปที่ 4.21 ลักษณะสัญญาณความถี่แกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Daubechies2 ระดับที่ 1



รูปที่ 4.22 ลักษณะสัญญาณความถี่แกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Daubechies2 ระดับที่ 2



รูปที่ 4.23 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Coiflet1 ระดับที่ 1




รูปที่ 4.24 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Coiflet1 ระดับที่ 2




รูปที่ 4.25 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Symlet2 ระดับที่ 1



รูปที่ 4.26 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Symlet2 ระดับที่ 2




รูปที่ 4.27 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 1



รูปที่ 4.28 ลักษณะสัญญาณความแรงแกน X จากการทกล้มไปด้านหน้าใช้การแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 2

## 4.2.2 วิธีที่นำเสนอสำหรับการลดมิติของคุณลักษณะเวฟเลต

ในทางปฏิบัติจำนวนของคุณลักษณะเวฟเลตมีขนาดใหญ่ (1248 สัมประสิทธิ์) ดังแสดงในรูปที่ 4.29 แต่จำนวนของสัญญาณความแรงสำหรับการสอนมีขนาดเล็ก (750 สัญญาณ) ผลลัพธ์นี้นำไปสู่ปัญหาที่รู้จักกันดีคือ คำสาปของมิติ (Curse of Dimensionality) และปัญหาของตัวอย่างที่น้อยเกินไป (Small Sample Size) เพื่อที่จะปรับปรุงทั้งความแม่นยำและเวลาในการดำเนินการของอัลกอริทึมจึงจำเป็นต้องมีการลดจำนวนของมิติของข้อมูล

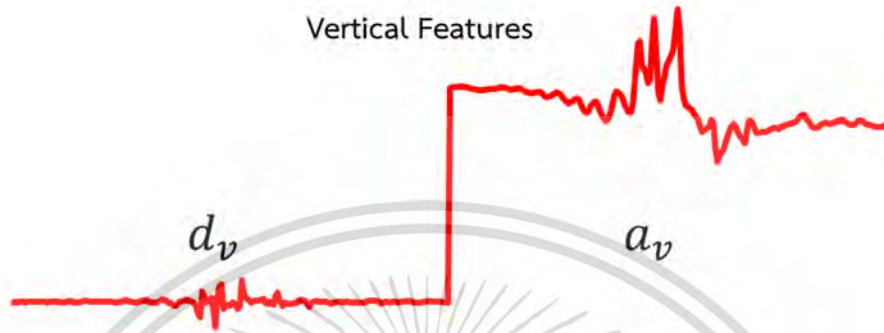


รูปที่ 4.29 ตัวอย่างจำนวนคุณลักษณะของเวฟเลตจากการแปลงเวฟเลตระดับที่ 1

วิธีการลดมิติเช่น การวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis) และการวิเคราะห์การจำแนกเชิงเส้น (Linear Discriminant Analysis) ยังไม่สามารถแก้ทั้งสองปัญหาได้ ดังนั้น ในวิทยานิพนธ์ฉบับนี้จึงเสนอวิธีการลดมิติแบบใหม่ ซึ่งประกอบด้วย 3 ขั้นตอน คือ เริ่มจากการจัดการข้อมูลคุณลักษณะของเวฟเลต (Rearranged Matrix) ต่อมาหาเมตริกซ์ความแปรปรวนของสัญญาณ (Variance Scatter Matrix) และสุดท้ายทำการโปรเจกชันข้อมูลไปยังปริภูมิที่ถูกลดมิติ (Dimension Reduction Mapping Matrix) สามารถอธิบายได้ดังนี้

### 4.2.2.1 จัดการข้อมูลคุณลักษณะเวฟเลต

จากการแปลงเวฟเลตระดับที่ 1 จะได้คุณลักษณะการแปลงเวฟเลตจากสัญญาณความถี่ทั้งสามแกน ซึ่งคือ vertical, sagittal horizontal, และ frontal horizontal ดังแสดงรูปที่ 4.30



รูปที่ 4.30 ตัวอย่างคุณลักษณะของเวฟเลตจากการแปลงเวฟเลตระดับที่ 1 ของแกน vertical

ให้  $a_v$ ,  $a_s$ , และ  $a_f$  เป็นคอลัมน์เมตริกซ์ของสัมประสิทธิ์การประมาณของการแยกองค์ประกอบเวฟเลตระดับที่ 1 ของแกน vertical, sagittal horizontal, และ frontal horizontal ของสัญญาณความถี่ตามลำดับ ให้  $d_v$ ,  $d_s$ , และ  $d_f$  เป็นคอลัมน์เมตริกซ์ของสัมประสิทธิ์รายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่ 1 ของแกน vertical, sagittal horizontal, และ frontal horizontal ของสัญญาณความถี่ตามลำดับ เนื่องจากจำนวนของตัวอย่างของแต่ละแกนของสัญญาณความถี่คือ 416 ดังนั้นจำนวนของสัมประสิทธิ์ของ  $a_v, a_s, a_f, d_v, d_s$ , และ  $d_f$  คือ 208

ให้  $r$  เป็นอัตราการ down sampling คอลัมน์เมตริกซ์การประมาณและรายละเอียดของ  $r$  down sampling ที่ตำแหน่ง  $i$  สามารถคำนวณได้ดังสมการต่อไปนี้

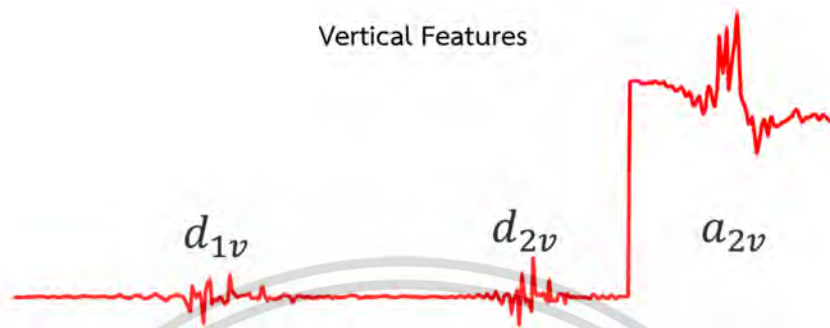
$$\mathbf{a}_{Ax,r,i} = [a_{Ax}(i), a_{Ax}(r+i), a_{Ax}(2r+i), \dots]^T, \quad (4.5)$$

$$\mathbf{d}_{Ax,r,i} = [d_{Ax}(i), d_{Ax}(r+i), d_{Ax}(2r+i), \dots]^T \quad (4.6)$$

โดยที่  $Ax \in \{a, s, f\}$ , และ  $i \in \{0, 1, \dots, r-1\}$

จำนวนของเมตริกซ์การประมาณและรายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่ 1 ที่ถูก down sampling คือ  $2 \times 3 \times r$  และจะได้มิติเท่ากับ  $208/r$

จากการแปลงเวฟเลตระดับที่ 2 จะได้คุณลักษณะการแปลงเวฟเลตจากสัญญาณความถี่ทั้งสามแกน ซึ่งคือ vertical, sagittal horizontal, และ frontal horizontal ดังแสดงรูปที่ 4.31



รูปที่ 4.31 ตัวอย่างคุณลักษณะของเวฟเลตจากการแปลงเวฟเลตระดับที่ 2 ของแกน vertical

ให้  $a_{2v}$ ,  $a_{2s}$ , และ  $a_{2f}$  เป็นคอลัมน์เมตริกซ์ของสัมประสิทธิ์การประมาณของการแยกองค์ประกอบเวฟเลตระดับที่ 2 ของแกน vertical, sagittal horizontal, และ frontal horizontal ของสัญญาณความถี่ตามลำดับ ให้  $d_{2v}$ ,  $d_{2s}$ , และ  $d_{2f}$  เป็นคอลัมน์เมตริกซ์ของสัมประสิทธิ์รายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่ 2 ของแกน vertical, sagittal horizontal, และ frontal horizontal ของสัญญาณความถี่ตามลำดับ และให้  $d_{1v}$ ,  $d_{1s}$ , และ  $d_{1f}$  เป็นคอลัมน์เมตริกซ์ของสัมประสิทธิ์รายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่ 1 ของแกน vertical, sagittal horizontal, และ frontal horizontal ของสัญญาณความถี่ตามลำดับ เนื่องจากจำนวนของตัวอย่างของแต่ละแกนของสัญญาณความถี่คือ 416 ดังนั้นจำนวนของสัมประสิทธิ์ของ  $d_{1v}$ ,  $d_{1s}$ , และ  $d_{1f}$  คือ 208 และ  $a_{2v}$ ,  $a_{2s}$ ,  $a_{2f}$ ,  $d_{2v}$ ,  $d_{2s}$ , และ  $d_{2f}$  คือ 104

คอลัมน์เมตริกซ์การประมาณและรายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่ 1 และ 2 ของ อัตราการ down sampling เท่ากับ  $r$  ที่ตำแหน่ง  $i$  สามารถคำนวณได้ดังสมการต่อไปนี้

$$\mathbf{d}_{1,Ax,r,i} = [d_{1,Ax}(i), d_{1,Ax}(r+i), d_{1,Ax}(2r+i), \dots]^T \quad (4.7)$$

$$\mathbf{d}_{2,Ax,r,i} = \left[ d_{2,Ax}(i), d_{2,Ax}\left(\frac{r}{2}+i\right), d_{2,Ax}\left(2\frac{r}{2}+i\right), \dots \right]^T \quad (4.8)$$

$$\mathbf{a}_{2,Ax,r,i} = \left[ a_{2,Ax}(i), a_{2,Ax}\left(\frac{r}{2}+i\right), a_{2,Ax}\left(2\frac{r}{2}+i\right), \dots \right]^T \quad (4.9)$$

โดยที่  $Ax \in \{a, s, f\}$ , และ  $i \in \{0, 1, \dots, r-1\}$

จำนวนคอลัมน์ของเมตริกซ์การประมาณและรายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่ 1 ที่ถูก down sampling คือ  $2 \times 3 \times r$  และจะได้มิติเท่ากับ  $208/r$  จำนวนของเมตริกซ์การประมาณและรายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่ 2 ที่ถูก down sampling คือ  $2 \times 3 \times \frac{r}{2}$  และจะได้มิติเท่ากับ  $104/r$

#### 4.2.2.2 หาเมตริกซ์ความแปรปรวน

ให้  $A_{l,Ax,r,i,c}$  เป็นเซตของเมตริกซ์การประมาณของการแยกองค์ประกอบเวฟเลตระดับที่  $l$  ที่ถูก down sampling และ  $D_{l,Ax,r,i,c}$  เป็นเซตของเมตริกซ์รายละเอียดของการแยกองค์ประกอบเวฟเลตระดับที่  $l$  ที่ถูก down sampling ของจำนวนกิจกรรมทั้งหมด  $C$  กิจกรรม

เริ่มจากหาเมตริกซ์ค่าเฉลี่ยของของเมตริกซ์การประมาณ ( $A_{l,Ax,r,i,c}$ ) และเมตริกซ์รายละเอียด ( $D_{l,Ax,r,i,c}$ ) ที่ถูก down sampling สามารถคำนวณได้ดังสมการต่อไปนี้

$$\bar{\mathbf{a}}_{l,Ax,r,i,c} = \frac{1}{n_c} \sum_{\mathbf{a}_{l,Ax,r,i} \in A_{l,Ax,r,i,c}} \mathbf{a}_{l,Ax,r,i}, \quad (4.10)$$

$$\bar{\mathbf{d}}_{l,Ax,r,i,c} = \frac{1}{n_c} \sum_{\mathbf{d}_{l,Ax,r,i} \in D_{l,Ax,r,i,c}} \mathbf{d}_{l,Ax,r,i} \quad (4.11)$$

โดยที่  $n_c$  คือจำนวนของสัญญาณความถี่สำหรับการสอนของกิจกรรมลำดับที่  $c$  ( $c^{th}$ )

จาก  $r$  และ  $C$  เมตริกซ์ความผิดพลาดของเมตริกซ์การประมาณและรายละเอียดที่ถูก down sampling สามารถเขียนอยู่ในรูปสมการได้ดังนี้

$$\mathbf{E}_{r,c} = [\hat{\mathbf{a}}_{l,v,r,0,c}, \dots, \hat{\mathbf{a}}_{l,f,r,r-1,c}, \hat{\mathbf{d}}_{l,v,r,0,c}, \dots, \hat{\mathbf{d}}_{l,f,r,r-1,c}] \quad (4.12)$$

โดยที่

$$\hat{\mathbf{a}}_{l,Ax,r,i,c} = (\mathbf{a}_{l,Ax,r,i} - \bar{\mathbf{a}}_{l,Ax,r,i,c}) \quad (4.13)$$

$$\hat{\mathbf{d}}_{l,Ax,r,i,c} = (\mathbf{d}_{l,Ax,r,i} - \bar{\mathbf{d}}_{l,Ax,r,i,c}) \quad (4.14)$$

โดยที่  $\mathbf{a}_{l,Ax,r,i} \in A_{l,Ax,r,i,c}$  และ  $\mathbf{d}_{l,Ax,r,i} \in D_{l,Ax,r,i,c}$

เมตริกซ์ความแปรปรวนภายในคลาสสามารถคำนวณได้ดังสมการต่อไปนี้

$$\mathbf{V}_r^W = \sum_c n_c \mathbf{E}_{r,c}^T \mathbf{E}_{r,c} \quad (4.15)$$

ให้  $N$  เป็นจำนวนของสัญญาณที่ใช้สำหรับการสอนทั้งหมด เมตริกซ์ความผิดพลาดเฉลี่ยของเมตริกซ์การประมาณและรายละเอียดที่ถูก down sampling สามารถเขียนอยู่ในรูปสมการได้ดังนี้

$$\bar{\mathbf{E}}_{r,c} = [\tilde{\mathbf{a}}_{l,v,r,0,c}, \dots, \tilde{\mathbf{a}}_{l,f,r,r-1,c}, \tilde{\mathbf{d}}_{l,v,r,0,c}, \dots, \tilde{\mathbf{d}}_{l,f,r,r-1,c}] \quad (4.16)$$

โดยที่

$$\tilde{\mathbf{a}}_{l, Ax, r, i, c} = \bar{\mathbf{a}}_{l, Ax, r, i, c} - \frac{1}{N} \sum_{\mathbf{a}_{l, Ax, r, i}} \mathbf{a}_{l, Ax, r, i} \quad (4.17)$$

$$\tilde{\mathbf{d}}_{l, Ax, r, i, c} = \bar{\mathbf{d}}_{l, Ax, r, i, c} - \frac{1}{N} \sum_{\mathbf{d}_{l, Ax, r, i}} \mathbf{d}_{l, Ax, r, i} \quad (4.18)$$

เมตริกซ์ความแปรปรวนระหว่างคลาสสามารถคำนวณได้ดังสมการต่อไปนี้

$$\mathbf{V}_r^B = \sum_c n_c \bar{\mathbf{E}}_{r,c}^T \bar{\mathbf{E}}_{r,c} \quad (4.19)$$

#### 4.2.2.3 การโปรเจกชันข้อมูลไปยังปริภูมิที่ถูกลดมิติ

เพื่อที่จะหาโปรเจกชันในปริภูมิใหม่  $\mathbf{W}$  ที่ให้ค่าของ criteria  $J(\mathbf{w})$  [35] มีค่ามากที่สุดสามารถหาได้จากสมการต่อไปนี้

$$J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{V}_r^B \mathbf{w}}{\mathbf{w}^T \mathbf{V}_r^W \mathbf{w}} \quad (4.20)$$

จากสมการที่ (4.20)  $\mathbf{W}$  สามารถหาค่าได้จากการแยกองค์ประกอบไอเกนดังแสดงในสมการที่ 4.21

$$\det\left((\mathbf{V}_r^W)^{-1} \mathbf{V}_r^B - \lambda I\right) = 0 \quad (4.21)$$

ซึ่งเอาท์พุทของวิธีการลดมิติที่นำเสนอสามารถคำนวณได้ดังสมการต่อไปนี้

$$\mathbf{F}_r = \mathbf{A}_r \mathbf{W}_r \quad (4.22)$$

โดยที่  $\mathbf{A}_r = [\mathbf{a}_{l,v,r,0}, \dots, \mathbf{a}_{l,f,r,r-1}, \mathbf{d}_{l,v,r,0}, \dots, \mathbf{d}_{l,f,r,r-1}]$  เป็นเมตริกซ์อินพุทของเมตริกซ์การประมาณและรายละเอียดที่ถูก down sampling ของสัญญาณที่ใช้สำหรับทดสอบ และ  $\mathbf{W}_r = [\mathbf{w}_1, \mathbf{w}_2, \mathbf{w}_3]$  คือ เมตริกซ์ของไอเกนเวกเตอร์สามอันดับแรก  $\mathbf{F}_r = [\mathbf{f}_1, \mathbf{f}_2, \mathbf{f}_3]$  คือเมตริกซ์เอาท์พุทของการลดมิติที่นำเสนอ เนื่องจากจำนวนของคอลัมน์ของ  $\mathbf{A}_r$  คือ  $2 \times 3 \times r$  และ  $\mathbf{F}_r$  คือ 3 ดังนั้นอัตราการลดมิติเท่ากับ  $2r$

### 4.2.3 การรู้จำสัญญาณการเคลื่อนไหวและการหกล้มของมนุษย์โดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Neural Network)

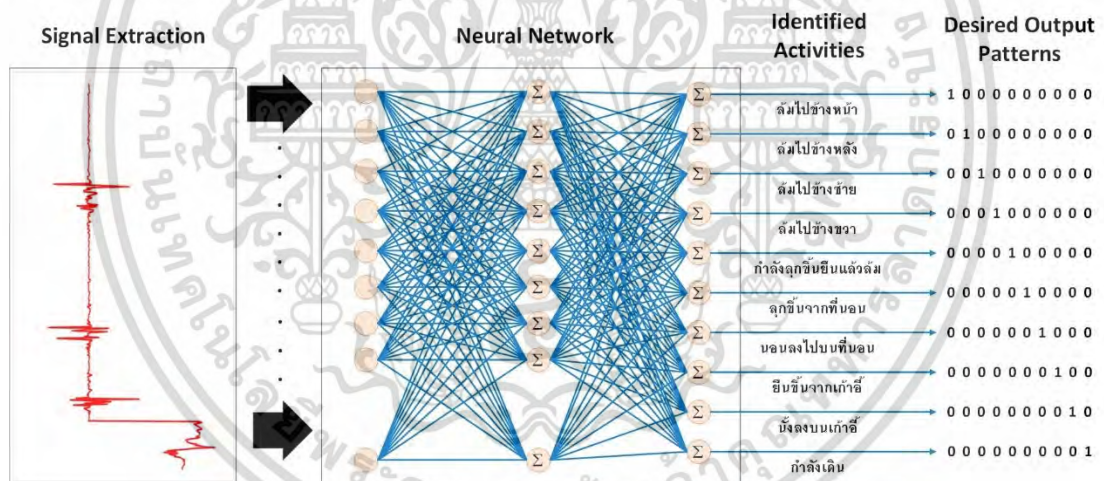
ในทางปฏิบัติการเคลื่อนไหวหลายชนิดเช่น หกล้มไปด้านหน้า หกล้มไปด้านหลัง หกล้มไปด้านขวา หกล้มไปด้านซ้าย หกล้มในขณะที่กำลังยืน จะมีรูปแบบสัญญาณที่มีความซับซ้อนและมีความคล้ายคลึงกันมาก ผลที่ตามมาคือเกิดความยากในการใช้สมการคำนวณหรือเขียนโปรแกรมเพื่อรู้จำสัญญาณ แต่อย่างไรก็ตามด้วยความก้าวหน้าของเทคโนโลยี จึงมีความเป็นไปได้ที่จะออกแบบอัลกอริทึมสำหรับการรู้จำรูปแบบสัญญาณ ซึ่งงานวิจัยในครั้งนี้ได้ใช้วิธีที่เรียกว่า “โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ” เพื่อจำจรูปแบบสัญญาณแล้วรู้จำสัญญาณ ซึ่งโครงข่ายประสาทเทียมจะประกอบไปด้วย 3 ชั้นคือ ชั้นขาเข้า (Input neuron) ชั้นซ่อน (Hidden layer) ชั้นขาออก (Output layer) ซึ่งใช้ Activation function ในชั้นซ่อน เป็น ฟังก์ชัน log sigmoidal ดังสมการ 4.23 และใช้ Activation function ในชั้นขาออกเป็นฟังก์ชัน log sigmoidal หรือ Linear ดังสมการ 4.24 จำนวนเซลล์ประสาทในชั้นขาเข้าจะเท่ากับขนาดของสัญญาณความเร่งที่ถูกดึงคุณลักษณะด้วยการแปลงเวฟเลตและผ่านการลดมิติจากวิธีที่นำเสนอ และในชั้นขาออกจะมีเซลล์ประสาทตามจำนวนการรู้จำสัญญาณ โดยค่าตัวเลขของสัญญาณขาออกเป้าหมาย (Desired Output) จะมีค่าเป็น 1 ยกตัวอย่างเช่น การรู้จำสัญญาณการเคลื่อนไหวของมนุษย์ดังแสดงในตารางที่ 4.3 และ การรู้จำการหกล้มดังแสดงในตารางที่ 4.4 ตามลำดับ

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (4.23)$$

$$f(x) = x \quad (4.24)$$

ตารางที่ 4.3 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของการรู้จำสัญญาณการเคลื่อนไหวของมนุษย์


รูปแบบสัญญาณขาเข้า	ค่าตัวเลขของสัญญาณขาออกเป้าหมาย (Desired Output) สำหรับโครงข่ายประสาทเทียม
หกล้มไปด้านหน้า	1 0 0 0 0 0 0 0 0 0
หกล้มไปด้านหลัง	0 1 0 0 0 0 0 0 0 0
หกล้มไปด้านซ้าย	0 0 1 0 0 0 0 0 0 0
หกล้มไปด้านขวา	0 0 0 1 0 0 0 0 0 0
หกล้มในขณะที่กำลังยืน	0 0 0 0 1 0 0 0 0 0
ลุกขึ้นจากที่นอน	0 0 0 0 0 1 0 0 0 0
ล้มตัวลงนอนบนที่นอน	0 0 0 0 0 0 1 0 0 0
ลุกขึ้นจากเก้าอี้	0 0 0 0 0 0 0 1 0 0
นั่งลงไปบนเก้าอี้	0 0 0 0 0 0 0 0 1 0
เดิน	0 0 0 0 0 0 0 0 0 1



รูปที่ 4.32 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการรู้จำรูปแบบของสัญญาณการเคลื่อนไหวของมนุษย์

ตารางที่ 4.4 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของการรู้จำสัญญาณการหกล้มของมนุษย์

รูปแบบสัญญาณขาเข้า	ค่าตัวเลขของสัญญาณขาออกเป้าหมาย (Desired Output) สำหรับโครงข่ายประสาทเทียม
ประเภทการหกล้ม	1 0
ประเภทการเคลื่อนไหวปกติ	0 1



รูปที่ 4.33 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการรู้จำรูปแบบของการคัดแยกสัญญาณการหกล้มของมนุษย์

# บทที่ 3

## ทฤษฎีที่เกี่ยวข้อง

วิทยานิพนธ์ฉบับนี้เป็นงานวิจัยเกี่ยวกับระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหวและการหกล้ม ทฤษฎีที่เกี่ยวข้องกับระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหวและการหกล้มที่พัฒนาในวิทยานิพนธ์ฉบับนี้ประกอบไปด้วย 3 ทฤษฎี คือ

1. ทฤษฎีการแปลงเวฟเลต ซึ่งอธิบายไว้ในหัวข้อที่ 3.1
2. ทฤษฎีการลดมิติ ซึ่งอธิบายไว้ในหัวข้อที่ 3.2
3. ทฤษฎีโครงข่ายประสาทเทียม ซึ่งอธิบายไว้ในหัวข้อที่ 3.3

### 3.1 ทฤษฎีการแปลงเวฟเลต (Wavelet Transform)

#### 3.1.1 ทฤษฎีการประมาณค่า (Approximation)

จากทฤษฎีพีชคณิตเชิงเส้น ถ้าสัญญาณที่กำลังพิจารณา  $f(t)$  เป็นฟังก์ชันในปริภูมิที่ถูก Span โดยฟังก์ชัน Basis [28 และ 29] ดังนั้นเราสามารถที่จะเขียนสัญญาณนั้นให้อยู่ในรูปของผลรวมเชิงเส้นของฟังก์ชัน Basis ได้ดังนี้

$$f(t) = \sum_k a_k \phi_k(t) \quad (3.1)$$

โดยที่  $k$  คือ ดัชนีจำนวนเต็มจำนวนจำกัดหรือไม่จำกัดก็ได้

$a_k$  คือ ค่าสัมประสิทธิ์การขยาย

$\phi_k(t)$  คือ ฟังก์ชันการขยายหรือฟังก์ชัน Basis

ถ้าแทน  $\phi_k(t)$  ด้วย  $\exp(j2\pi kt/T)$  เราจะได้สมการการกระจายอนุกรมฟูเรียร์ ดังนั้นสมการการกระจายอนุกรมฟูเรียร์จึงเป็นกรณีพิเศษของสมการที่ 3.1 ในกรณีทั่วไป ถ้าเราเลือกฟังก์ชัน Basis ที่เหมาะสม เราสามารถหาเซตของ  $\{\phi_k(t)\}$  และ  $\{\tilde{\phi}_k(t)\}$  ที่ตั้งฉากซึ่งกันและกัน (Orthonormal) โดยที่สมการ Inner Product ของเซตทั้งสองจะเป็น

$$\langle \phi_i(t), \tilde{\phi}_j(t) \rangle = \int \phi_i(t) \tilde{\phi}_j^*(t) dt = \delta_{ij} \quad (3.2)$$

โดยที่  $\{\tilde{\phi}_k(t)\}$  เรียกว่าเซตของคู่ฟังก์ชันของ  $\{\phi_k(t)\}$  จากคุณสมบัติ Orthonormal เราสามารถหาค่าสัมประสิทธิ์  $a_k$  ได้จาก

$$\begin{aligned}
\langle f(t), \tilde{\phi}_k(t) \rangle &= \int f(t) \tilde{\phi}_k^*(t) \\
&= \int \left( \sum_{k'} a_{k'} \phi_{k'} \right) \tilde{\phi}_k^*(t) dt \\
&= \sum_{k'} a_{k'} \left( \int \phi_{k'}(t) \tilde{\phi}_k^*(t) dt \right) \\
&= \sum_{k'} a_{k'} \delta_{k'k} \\
&= a_k
\end{aligned} \tag{3.3}$$

เราสามารถเขียนสมการที่ 3.3 ใหม่ได้ดังนี้

$$a_k = \langle f(t), \tilde{\phi}_k(t) \rangle = \int f(t) \tilde{\phi}_k^*(t) dt \tag{3.4}$$

**3.1.2** ตัวอย่างการประมาณสัญญาณดิสครีตทางเวลาโดยฟังก์ชันเดลต้า  
พิจารณาสัญญาณดิสครีตทางเวลา  $x[n]$  ที่มีสมการดังนี้

$$x[n] = \left( \frac{1}{2} \right)^{|n|} \tag{3.5}$$

จากนั้นเลือกใช้เซตของฟังก์ชัน Basis เป็น  $\{\phi_k[n]\} = \{\delta[n-k]\}$  และ เซตของคู่ฟังก์ชัน เป็น  $\{\tilde{\phi}_k[n]\} = \{\phi_k[n]\} = \{\delta[n-k]\}$  เพื่อหาสัมประสิทธิ์การขยายของ  $x[n]$  ในขั้นแรกต้องตรวจสอบว่าฟังก์ชัน Basis ที่ถูกเลือกมีคุณสมบัติ Orthonormal หรือไม่ ดังต่อไปนี้


$$\langle \phi_i[n], \tilde{\phi}_j[n] \rangle = \langle \delta[n-i], \delta[n-j] \rangle = \sum_{m=-\infty}^{\infty} \delta[n-i] \delta[n-j] = \delta_{ij} \tag{3.6}$$

จากสมการที่ 3.4 เราสามารถหาค่าสัมประสิทธิ์การขยายได้ดังนี้

$$a_k = \langle x[n], \delta[n-k] \rangle = \sum_{n=-\infty}^{\infty} \left( \frac{1}{2} \right)^{|n|} \delta[n-k] = \left( \frac{1}{2} \right)^{|k|} \tag{3.7}$$

รูปที่ 3.1 แสดงค่าสัมประสิทธิ์  $a_k$  เมื่อ  $k \in [K_1, K_2]$

ตัวอย่างนี้เลือกใช้เซตของฟังก์ชัน  $\{\delta[n-k]\}$  เป็นฟังก์ชัน Basis ในการหาค่าสัมประสิทธิ์เซตของฟังก์ชัน  $\{\delta[n-k]\}$  สามารถแปลได้อีกความหมายหนึ่งคือ เซตของการเลื่อนเดลต้าฟังก์ชัน  $\delta[n]$  ไปยังตำแหน่ง  $n = k$



รูปที่ 3.1 ผลลัพธ์ค่าประมาณของฟังก์ชันเดลต้า

ในตัวอย่างนี้เราเลือกบางส่วนของฟังก์ชัน Basis  $\{\delta[n-k]\}$  เพื่อนำมาหาค่าสัมประสิทธิ์ของตัวเอง ฟังก์ชัน Basis นี้ อาจถูกตีความได้หลายลักษณะซึ่งฟังก์ชัน Basis อาจแทนเป็นการเลื่อนของฟังก์ชันเดี่ยวเดลต้า  $\delta[n] - \delta[n-k]$  จะหมายถึงตำแหน่งของอิมพัลส์ที่  $n=k$  ค่าสัมประสิทธิ์บางส่วนที่ใช้ในสัญญาณคืนกลับคือตำแหน่งที่เราพิจารณา ยกตัวอย่าง ถ้าเราต้องการวิเคราะห์สัญญาณเมื่อ  $n \in [-2, 0]$  เราสามารถใช้  $a_2, a_1$  และ  $a_0$  เพื่อใช้หารูปแบบการสร้างสัญญาณคืนกลับได้

### 3.1.3 การสร้าง Basis โดยการสเกล

ในหัวข้อก่อนหน้านี้เราสามารถสร้างเซตของฟังก์ชัน Basis ได้โดยการเลื่อนฟังก์ชัน Basis ต้นแบบ ในหัวข้อนี้เราจะยกตัวอย่างการสร้างเซตของฟังก์ชัน Basis โดยการสเกลหรือการขยายขนาด ฟังก์ชัน Basis ต้นแบบ

กำหนดให้ ฟังก์ชันต่อเนื่อง  $\phi(t)$  เป็นฟังก์ชันสี่เหลี่ยม (Rectangular) ที่มีจุดศูนย์กลางอยู่ ณ ตำแหน่ง  $x = 1/2$  และมีความกว้างเท่ากับ 1 ซึ่งสามารถเขียนเป็นสมการได้ดังนี้

$$\phi(t) = \begin{cases} 1, & 0 \leq t < 1 \\ 0, & \text{Otherwise} \end{cases} \quad (3.8)$$

เราสามารถสเกลขนาดของฟังก์ชัน  $\phi(t)$  ได้ดังนี้


$$\phi_s(t) = \phi(st) \quad (3.9)$$

โดยที่  $s$  คือ แฟกเตอร์แบบต่อเนื่องของการสเกล

ถ้า  $s$  มีค่าสูงขึ้น ซัพพอร์ตของ Basis จะแคบลง ในกรณีที่ใช้ Basis แบบดิสครีต เราใช้  $s = 2^n$  เพื่อความง่าย โดยที่  $n$  เป็นเลขจำนวนเต็ม ดังนั้นเราสามารถเขียนสมการที่ 3.9 ใหม่ได้ดังนี้

$$\phi_n(t) = \phi(2^n t) \quad (3.10)$$

โดยที่  $n$  เป็นดัชนีบ่งชี้การสเกล



รูปที่ 3.2 รูปสเกลของ Basis ต่างๆ

(ก)  $\phi_n(t) = \phi_0(t)$ , (ข)  $\phi_n(t) = \phi_1(t)$ ,

(ค)  $\phi_n(t) = \phi_{-1}(t)$ , (ง)  $\phi_n(t) = \phi_2(t)$

รูปที่ 3.2 (ก)-(ง) แสดง  $\phi_n(t)$  ที่  $n=0,1,-1$  และ 2 ตามลำดับ การสเกลฟังก์ชัน  $\phi(t)$  ให้มีซัพพอร์ตแคบลง จะทำให้  $\phi(t)$  มีองค์ประกอบความถี่สูงขึ้น ดังนั้นเราสามารถที่จะประมาณค่าขององค์ประกอบความถี่สูงได้อย่างแม่นยำโดยกำหนดค่าการสเกลให้สูงขึ้น

คำถามต่อไป คือ แฟมิลีของ  $\{\phi_n(t)\}$  เป็นเซตของฟังก์ชันที่ Orthogonal ซึ่งกันและกันหรือไม่ เราลองตรวจสอบสองฟังก์ชันสองอันดับแรก คือ  $\phi_0(t)$  และ  $\phi_1(t)$  ดังต่อไปนี้

$$\langle \phi_0(t), \phi_1(t) \rangle = \int_{-\infty}^{\infty} \phi_0(t) \phi_1(t) dt = \int_0^{1/2} dt = 1/2$$

จะเห็นได้ว่าฟังก์ชันทั้งสองไม่เป็น Orthogonal ซึ่งกันและกัน ดังนั้นฟังก์ชันอื่นๆก็เช่นเดียวกัน แต่เราสามารถที่จะใช้กระบวนการของ Gram-Schmidt เพื่อสร้างเซตของ Orthonormal Basis จาก  $\{\phi_n(t)\}$  ที่มีอยู่ ดังต่อไปนี้

$$\begin{aligned}
\phi'_0(t) &= \phi_0(t) = \phi(t) \\
\phi'_1(t) &= \phi_1(t) - \frac{\langle \phi_1(t), \phi_0(t) \rangle}{\langle \phi_0(t), \phi_0(t) \rangle} \phi_0(t) \\
&= \begin{cases} 1/2, 0 \leq t < 1/2 \\ -1/2, 1/2 \leq t < 1 \\ 0, \text{Otherwise} \end{cases} & (3.11) \\
&= \psi(t)/2
\end{aligned}$$

เราสามารถใช้กระบวนการของ Gram-Schmidt กับฟังก์ชัน Basis อื่นๆ แต่ถ้าเราพิจารณาฟังก์ชัน Basis สองตัวแรก และการแปลงฟูเรียร์ของฟังก์ชัน Basis สองตัวแรก จากการตรวจสอบ  $\phi(t)$  จะมีค่าเฉลี่ยไม่เท่ากับศูนย์ ในขณะที่  $\psi(t)$  มีค่าเฉลี่ยเท่ากับศูนย์ ค่าของ  $\phi(t)$  มีการกระโดดสองครั้งที่ตำแหน่ง 0 และ 1 ในขณะที่  $\psi(t)$  กระโดดที่ 0, 1/2, 1 ดังนั้นพลังงานของ  $\phi(t)$  จะสะสมมากที่ความถี่ต่ำ ในขณะที่พลังงานของ  $\psi(t)$  อยู่ที่ความถี่สูง เราจะเรียก  $\phi(t)$  ว่า ฟังก์ชันการสเกล เพื่อคำนวณฟังก์ชันการประมาณค่า (Approximated Function) ที่ระดับต่ำกว่า และ  $\psi(t)$  ว่าฟังก์ชันเวฟเลตเพื่อคำนวณฟังก์ชันรายละเอียด (Detail Function) ที่ระดับต่ำกว่า

### 3.1.4 การวิเคราะห์แบบ Multi-resolution

เราสามารถสร้างเซตของฟังก์ชัน Basis ที่มีคุณสมบัติ Orthonormal จากฟังก์ชันสเกลและฟังก์ชันเวฟเลตโดยใช้พารามิเตอร์ 2 ตัว คือ พารามิเตอร์การขยาย (Scaling) และ พารามิเตอร์การเลื่อน (Translating) ได้ดังนี้

$$\begin{aligned}
\phi_{j,k}(t) &= 2^{j/2} \phi(2^j t - k) \\
\psi_{j,k}(t) &= 2^{j/2} \psi(2^j t - k)
\end{aligned} \quad (3.12)$$

โดยที่  $j$  คือ พารามิเตอร์การขยาย หรือ dilation และ  $k$  คือ พารามิเตอร์เลื่อนหรือตำแหน่ง

ในทางปฏิบัติ เราอาจต้องการเห็นถึงข้อมูลทั้งหมดที่ระดับความละเอียด (Resolution) ที่ต้องการ นั่นคือ ที่ระดับความละเอียด (Resolution)  $j$  บางค่าเราจะนิยามปริภูมิย่อย (Subspace)

$$\begin{aligned}
V_j &= \text{Span} \{ \phi_{j,k}(t) \} \\
W_j &= \text{Span} \{ \psi_{j,k}(t) \}
\end{aligned} \quad (3.13)$$

จากนิยามเหล่านี้ การวิเคราะห์ Multiresolution มีข้อกำหนดดังต่อไปนี้


1. ฟังก์ชันสเกลต้องตั้งฉากซึ่งกันและกันสำหรับการเลื่อนไปยังตำแหน่งที่เป็นเลขจำนวนเต็ม
  2. ปริภูมิย่อยที่ถูก Spanned โดยฟังก์ชันสเกลที่สเกลระดับต่ำจะถูกทับซ้อนโดยปริภูมิย่อยที่ถูก Spanned ที่สเกลระดับสูงกว่า จากรูปที่ 3.3 แสดงให้เห็นว่า  $\phi_{-1}(t) = \phi_0(t) + \phi_0(t-1)$  ดังนั้นเราสามารถสรุปได้ว่าปริภูมิย่อย  $V_j$  เป็นสับเซต (Subset) ของปริภูมิย่อย  $V_{j+1}$
  3. มีเพียงฟังก์ชันเดียวเท่านั้นที่เป็นฟังก์ชันร่วมของปริภูมิย่อย  $V_j$  ทั้งหมด คือ  $f(x) = 0$
  4. ฟังก์ชันใดๆ สามารถถูกแสดงที่สเกลระดับใดก็ได้
- ตัวอย่างของข้อกำหนดที่ 2 เป็นดังต่อไปนี้

เราสามารถสร้างสเกลฟังก์ชันของ Haar ที่สเกลที่ 0 ตำแหน่งที่ 0 ได้ดังต่อไปนี้

$$\phi(t) = \phi_{0,0}(t) = \frac{1}{\sqrt{2}} \phi_{1,0}(t) + \frac{1}{\sqrt{2}} \phi_{1,1}(t) \quad (3.14)$$

$$V_2 = V_1 \oplus W_1 = V_0 \oplus W_0 \oplus W_1$$

$$V_1 = V_0 \oplus W_0$$



**รูปที่ 3.3** ความสัมพันธ์ระหว่างพื้นที่ของสเกลฟังก์ชันและเวฟเลตฟังก์ชัน

หรือ อาจจะเขียนใหม่ให้อยู่รูปสมการคอนโวลูชันได้ดังนี้

$$\phi(t) = \sum_n h_\phi[n] \sqrt{2} \phi(2t - n) \quad (3.15)$$

โดยที่  $h_\phi[n] = \{1/\sqrt{2}, 1/\sqrt{2}\}$

ซึ่งเรียกสมการนี้ว่าสมการ Refinement, สมการการวิเคราะห์ Multiresolution หรือสมการ Dilation

สมการ 3.15 มีความหมายทางกายภาพ ดังต่อไปนี้


1. ฟังก์ชัน  $\phi(2t)$  เป็นฟังก์ชันที่มีองค์ประกอบความถี่สูงกว่า  $\phi(t)$

2. เราสามารถคำนวณหาฟังก์ชัน  $\phi(t)$  โดยใช้ตัวกรองความถี่ต่ำ  $h_\phi[n]$  ที่เหมาะสม ฟังก์ชันเวฟเลตก็มีความสัมพันธ์แบบเดียวกัน ดังต่อไปนี้

$$\psi(t) = \sum_n h_\psi[n] \sqrt{2} \phi(2t - n) \quad (3.16)$$

โดยที่  $h_\psi[n] = \{1/\sqrt{2}, 1/\sqrt{2}\}$  ฟิเตอร์ความถี่ต่ำทั้งสองตัวนี้มีความสัมพันธ์กันดังนี้

$$h_\psi[n] = (-1) h_\phi[1-n] \quad (3.17)$$



รูปที่ 3.4 ความสัมพันธ์ระหว่างสเกลฟังก์ชันและเวฟเลตฟังก์ชัน

### 3.15 การแปลงดิสครีตเวฟเลต ( Discrete Wavelet Transform )

ในหัวข้อก่อนหน้าเราได้พูดถึงฟังก์ชันสเกล, ฟังก์ชันเวฟเลต, และคุณสมบัติต่างๆของฟังก์ชันเหล่านี้ เราสามารถประมาณสัญญาณดิสครีตดังสมการ 3.18

$$f[n] = \frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \phi_{j,k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0} W_\psi[j, k] \psi_{j,k}[n] \quad (3.18)$$

ในที่นี้  $f[n]$ ,  $\phi_{j,k}[n]$  และ  $\psi_{j,k}[n]$  คือ ดิสครีตฟังก์ชันที่มีค่าอยู่ระหว่าง  $[0, M-1]$  เป็นฟังก์ชันดิสครีตจำนวนทั้งหมด  $M$  จุด หรือ  $n \in [0, M-1]$  เพราะว่าเซตของ  $\{\phi_{j,k}[n]\}_{k \in \mathbb{Z}}$  และ

$\{\psi_{j,k}[n]\}_{(j,k) \in \mathbb{Z}^2, j \geq j_0}$  ตั้งฉากซึ่งกันและกัน เราสามารถใช้ตัวดำเนินการ Inner Product เพื่อหาสัมประสิทธิ์เวฟเลตดังนี้

$$W_\phi[j_0, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j_0, k}[n] \quad (3.19)$$

$$W_\psi[j, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \psi_{j_0, k}[n], j > j_0 \quad (3.20)$$

ค่าสัมประสิทธิ์  $W_\phi[j_0, k]$  และ  $W_\psi[j, k]$  ถูกเรียกว่าสัมประสิทธิ์การประมาณ และสัมประสิทธิ์ของรายละเอียด ตามลำดับ

### 3.1.6 การแปลงเวฟเลตแบบเร็ว ( Fast Wavelet Transform )

การคำนวณหาค่าสัมประสิทธิ์การประมาณและสัมประสิทธิ์รายละเอียดโดยใช้สมการที่ 3.19 และ 3.20 ที่ค่าสเกล  $j$  ระดับต่ำ ( สเกลหยาบ ) จะใช้เวลานานมาก ดังนั้นเพื่อลดเวลาในการคำนวณวิธีการแปลงเวฟเลตแบบเร็วเป็นวิธีหนึ่งที่ถูกนำเสนอเพื่อใช้สำหรับการแก้ปัญหา การแปลงเวฟเลตแบบเร็วมีการทำงานดังต่อไปนี้ จากสมการ  $\phi(t) = \sum_n h_\phi[n] \sqrt{2} \phi(2t-n)$  เราสามารถที่จะคำนวณฟังก์ชันสเกลที่สเกลเท่ากับ  $j$  ได้ดังนี้

$$\begin{aligned} \phi_{j,k}[n] &= 2^{j/2} \phi[2^j n - k] \\ &= \sum_{n'} h_\phi[n'] \sqrt{2} \phi[2(2^j n - k) - n'] \end{aligned} \quad (3.21)$$

เมื่อกำหนดให้  $n' = m - 2k$  เราจะได้


$$\phi_{j,k}[n] = \sum_m h_\phi[m - 2k] \sqrt{2} \phi[2^{j+1} n - m] \quad (3.22)$$

เมื่อนำสมการที่ 3.22 แทนในสมการที่ 3.19 เราจะได้

$$\begin{aligned}
W_\phi[j, k] &= \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j,k}[n] \\
&= \frac{1}{\sqrt{M}} \sum_n f[n] 2^{j/2} \phi_{j,k}[2^j n - k] \\
&= \frac{1}{\sqrt{M}} \sum_n f[n] 2^{j/2} \sum_m h_\phi[m - 2k] \sqrt{2} \phi[2^{j+1} n - m] \\
&= \sum_m h_\phi[m - 2k] \left( \frac{1}{\sqrt{M}} \sum_n f[n] 2^{(j+1)/2} \phi_{j,k}[2^{j+1} n - m] \right) \\
&= \sum_m h_\phi[m - 2k] W_\phi[j+1, m] \\
&= h_\phi[-n] * W_\phi[j+1, n] \Big|_{n=2k, k \geq 0}
\end{aligned} \tag{3.23}$$

เราสามารถคำนวณค่าสัมประสิทธิ์รายละเอียดด้วยวิธีเดียวกันและได้ผลลัพธ์เป็นดังนี้

$$W_\psi[j, k] = h_\psi[-n] * W_\psi[j+1, n] \Big|_{n=2k, k \geq 0} \tag{3.24}$$




รูปที่ 3.5 บล็อกไดอะแกรมของการแปลงเวฟเลตแบบบิดสคริต

### 3.1.7 Mother Wavelet

**3.1.7.1 Haar Mother Wavelet** เป็นเวฟเลตตัวแรกที่ถูกพัฒนาขึ้นมาและเป็นแบบง่ายที่สุด ซึ่งมีสมการของสเกลและเวฟเลตฟังก์ชัน ดังต่อไปนี้

$$\phi(x) = \begin{cases} 1, & 0 < x < 1 \\ 0, & \text{Elsewhere} \end{cases} \quad (3.25)$$

$$\psi(t) = \begin{cases} 1, & 0 < t < 1/2 \\ -1, & 1/2 < t < 1 \\ 0, & \text{Otherwise} \end{cases} \quad (3.26)$$

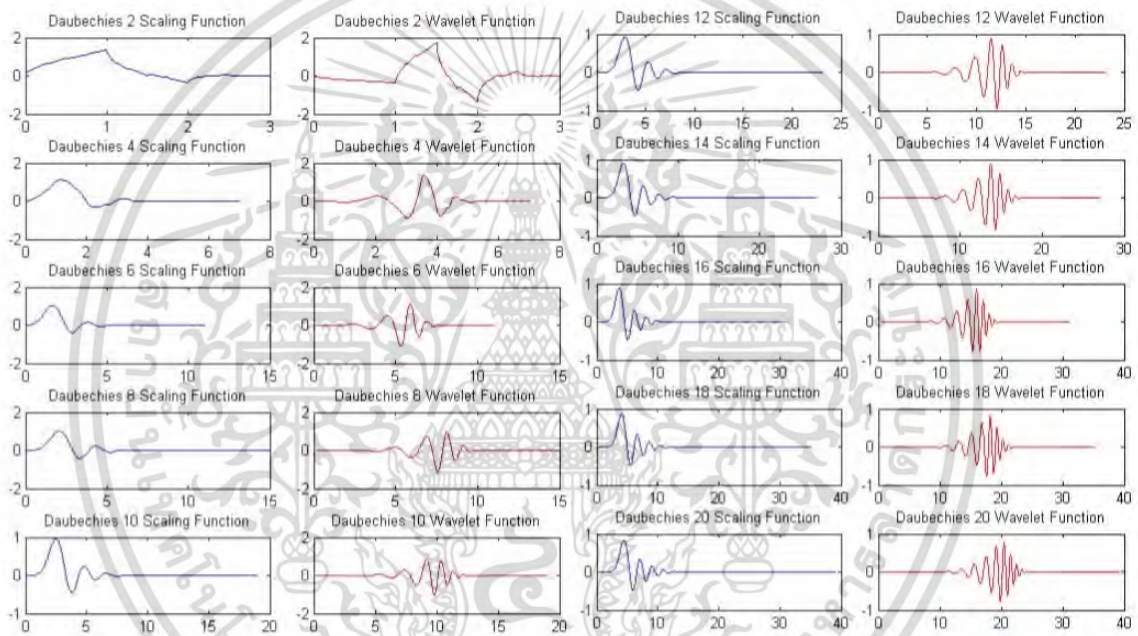


รูปที่ 3.6 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Harr Wavelet

ถึงแม้ว่า Haar Wavelet เป็นเวฟเลตที่ง่ายที่สุดแต่ข้อเสียของ Haar Wavelet คือ Haar Wavelet เป็นฟังก์ชันไม่ต่อเนื่องและไม่สามารถหาอนุพันธ์ได้ Haar Wavelet เหมาะสำหรับการวิเคราะห์สัญญาณที่มีการเปลี่ยนแปลงอย่างรวดเร็ว เช่น ใช้ในการวิเคราะห์เสียงการแตกหักของเครื่องจักร เป็นต้น

### 3.1.7.2 Daubechies Mother Wavelet


เป็นเวฟเลตที่มี Vanishing Moment สูงที่สุด จำนวนของ Vanishing Moment เท่ากับ  $N$  โดยที่จำนวนของสัมประสิทธิ์ ( Tap ) เท่ากับ  $2N$  จำนวนของ Vanishing Moment เป็นคุณสมบัติที่สำคัญอันหนึ่งของการแปลงเวฟเลต ในทางทฤษฎีเวฟเลตที่มี Vanishing Moment มาก จะสามารถใช้แสดงสัญญาณที่มีความซับซ้อนได้อย่างแม่นยำ แต่ข้อเสียคือต้องใช้เวลาในการคำนวณนานเนื่องจากมีจำนวนสัมประสิทธิ์มาก ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Daubechies Wavelet ที่มี Vanishing Moment เท่ากับ  $2, 4, 6, \dots, 20 (D_2, D_4, D_6, \dots, D_{20})$  ค่าสัมประสิทธิ์ของ สเกล และเวฟเลตฟังก์ชันของ Daubechies Wavelet ถูกแสดงในตารางที่ ก.1



รูปที่ 3.7 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet

### 3.1.7.3 Coiflet Mother Wavelet

เป็นฟังก์ชันที่มี Vanishing Moment สูง ถูกออกแบบโดย Ingird Daubichies ตามคำแนะนำของ Ronald Coifman จำนวนของ Vanishing Moment เท่ากับ  $N$  โดยที่จำนวนของสัมประสิทธิ์ เท่ากับ  $6N$  ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Coiflet Wavelet ที่มี Vanishing Moment เท่ากับ 1–5 (*Coif1–Coif5*) ค่าสัมประสิทธิ์ของสเกลและเวฟเลตฟังก์ชันของ Coiflet Wavelet ถูกแสดงในตารางที่ ก.3




รูปที่ 3.8 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Coiflet Wavelet

### 3.1.7.4 Symlet Mother Wavelet

เป็นเวฟเลตที่มีคุณสมบัติที่ดีหลายอย่างคือ ความตั้งฉาก(Orthogonal) และ ความกระชับ (Compact Support) Symlet Wavelet ถูกพัฒนามาจาก Daubechies Wavelet ให้มีจำนวน Vanishing Moment มากขึ้น นอกจากนี้ Symlet Wavelet ยังเป็นเวฟเลตตั้งฉากที่มีรูปร่างเกือบสมมาตรมากที่สุดหรือมีความอสมมาตรน้อยที่สุด [29] ทำให้สเกลฟังก์ชันมีความเป็น Linear Phase สูง ซึ่งมีข้อดีคือ ทำให้สัมประสิทธิ์เวฟเลตหลังจากผ่านการทำ Sub-Sampling ไม่ขึ้นกับการเลื่อนทางเวลา (Time Shift Invariant) รูปที่ 3.8 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet ซึ่ง Symlet Wavelet มีจำนวนของ Vanishing Moment เท่ากับ  $N$  โดยที่จำนวนของสัมประสิทธิ์เท่ากับ  $2N$

ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Symlet Wavelet ที่มี Vanishing Moment เท่ากับ 2–9 (Sym2 – Sym9) ค่าสัมประสิทธิ์ของ สเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet ถูกแสดงในตารางที่ ก.2



รูปที่ 3.9 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet

### 3.1.7.5 Biorthogonal Mother Wavelet

เป็นฟังก์ชันที่ไม่มีคุณสมบัติตั้งฉาก เนื่องจากการออกแบบเวฟเลตฟังก์ชันให้มีคุณสมบัติครบ ทั้ง ความตั้งฉาก ความกระชับ และความสมมาตร เป็นไปไม่ได้ นอกจาก Haar Wavelet แล้วไม่มี Wavelet ตั้งฉากใดที่มีสมมาตร ดังนั้นถ้าต้องการ Wavelet ที่มีความสมมาตรเราจำเป็นต้องเลือกใช้ Biorthogonal Wavelet เพื่อให้การแปลง Biorthogonal Wavelet สามารถสร้างคืนสัญญาณเดิม ได้อย่างสมบูรณ์ (Perfect Reconstruction) สเกลและเวฟเลตฟังก์ชันของ Biorthogonal Wavelet ทางฝั่ง Reconstruction และ ฝั่ง Decomposition เป็นคนละฟังก์ชันกัน (จึงเป็นที่มาของชื่อ Biorthogonal Wavelet) คู่ของสเกลฟังก์ชัน ( $A_w(j)$  และ  $\tilde{A}_w(j)$ ) และคู่ของเวฟเลตฟังก์ชัน ( $D_w(j)$  และ  $\tilde{D}_w(j)$ ) ของ Biorthogonal Wavelet มีคุณสมบัติดังนี้

1. มีคุณสมบัติตั้งฉากระหว่างคู่ฟังก์ชัน

$$\langle A_w(t), \tilde{A}_w(t-k) \rangle = \delta k \quad (3.27)$$

$$\langle D_w(t), \tilde{D}_w(t-k) \rangle = \delta k \quad (3.28)$$

2. มีคุณสมบัติตั้งฉากระหว่างสเกลฟังก์ชันและเวฟเลตฟังก์ชัน


$$\langle A_w(t), D_w(t-k) \rangle = 0 \quad (3.29)$$

$$\langle A_w(t), \tilde{D}_w(t-k) \rangle = 0 \quad (3.30)$$

$$\langle D_w(t), \tilde{A}_w(t-k) \rangle = 0 \quad (3.31)$$

$$\langle \tilde{A}_w(t), \tilde{D}_w(t-k) \rangle = 0 \quad (3.32)$$

เราสามารถกำหนด Vanishing Moment ของสเกลและเวฟเลตฟังก์ชันฝั่ง Reconstruction ( $Nr$ ) และ Vanishing Moment ของสเกลและเวฟเลตฟังก์ชันฝั่ง Decomposition ( $Nd$ ) ได้อิสระจากกัน โดยที่จำนวนสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของฝั่ง Reconstruction เท่ากับ  $2Nr + 1$  และจำนวนสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของฝั่ง Decomposition เท่ากับ  $2Nd + 1$  รูปแบบของการตั้งชื่อของ Biorthogonal Wavelet มีดังนี้คือ **Bior Nr.Nd** ตารางที่ ก.4 แสดงตารางสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชัน ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Biorthogonal Wavelet ที่มี Vanishing Moment ดังต่อไปนี้ 1.1–6.8 (**Bior1.1–Bior6.8**)



รูปที่ 3.10 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Biorthogonal Wavelet

## 3.2 ทฤษฎีการลดมิติ

ในช่วงไม่กี่ปีที่ผ่านมาการวิเคราะห์ข้อมูลหรือกระบวนการจัดการกับข้อมูลจำนวนมากเพื่อค้นหารูปแบบและความสัมพันธ์ที่ซ่อนอยู่ในชุดข้อมูลนั้น (data mining) [30] กลายเป็นแขนงวิชาเฉพาะที่จำเป็น เนื่องจากจำนวนของข้อมูลในปัจจุบันมีขนาดใหญ่ เนื่องจากข้อมูลที่มีขนาดใหญ่จึงกลายเป็นปัญหาหลักต่อประสิทธิภาพในการทำงานของระบบต่างๆ

การลดมิติ คือ กระบวนการของการดึงคุณลักษณะข้อมูลที่สำคัญจากเซตข้อมูลที่มีมิติขนาดใหญ่ โดยแสดงในรูปแบบย่อด้วยมิติที่ต่ำกว่า เพื่อที่จะปรับปรุงความถูกต้องในงานด้านการรู้จำข้อมูล และลดความซับซ้อนในการคำนวณ การลดมิติกลายเป็นกระบวนการที่จะสามารถแสดงข้อมูลได้อย่างดีในปริภูมิมิติที่ต่ำกว่าในหลายงาน เช่น การวิเคราะห์สัญญาณคลื่นหัวใจ และการค้นหาข้อมูลพื้นฐาน นอกจากนี้การลดมิตียังลดจำนวนตัวแปรและปรับปรุงประสิทธิภาพของอัลกอริทึมในการรู้จำข้อมูล ซึ่งกระบวนการของข้อมูลที่มีมิติขนาดใหญ่นำไปสู่ความซับซ้อนที่เพิ่มขึ้นทั้งในการคำนวณ และการรู้จำ มีจำนวนเทคนิคหลากหลายที่ใช้เพื่อลดมิติของเซตข้อมูล [31] ซึ่งแต่ละเทคนิคจะลดมิติของข้อมูลที่มีพื้นฐานอยู่บนเกณฑ์เฉพาะ เมื่อไม่กี่ปีมานี้ PCA และ LDA ถูกพิจารณาเป็นเครื่องมือพื้นฐานของการลดมิติและมีสมรรถภาพสูงสำหรับดึงคุณลักษณะของเวกเตอร์อินพุตที่มีมิติขนาดใหญ่ และอธิบายดังต่อไปนี้


### 3.2.1 การวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis)

การวิเคราะห์องค์ประกอบหลักเป็นวิธีการลดมิติที่เป็นที่รู้จักกันดี และมีบทบาทที่สำคัญในอัลกอริทึมของการรู้จำรูปแบบ (Pattern Recognition) และ Machine Learning จุดมุ่งหมายของการวิเคราะห์องค์ประกอบหลัก คือการอธิบายเมตริกซ์สหสัมพันธ์ (Correlation matrix) ให้ง่ายขึ้น โดยการอธิบายในรูปของตัวแปรที่ลดลง แนวคิดพื้นฐานของการวิเคราะห์องค์ประกอบที่สำคัญคือการค้นหาระนาบใหม่ที่เปลี่ยนคุณลักษณะพื้นฐานให้อยู่ในที่ที่มีมิติต่ำกว่า และยังคงรักษาข้อมูลที่สำคัญของข้อมูลดั้งเดิมไว้ เพื่อที่จะแปลงข้อมูลจากที่มีมิติขนาดใหญ่ในปริภูมิดั้งเดิมไปยังปริภูมิคุณลักษณะใหม่ที่มีมิติลดลง อัลกอริทึมนี้มีพื้นฐานอยู่บนการค้นหาทิศทางมุมฉาก (orthogonal) ซึ่งอธิบายความแปรปรวนมากที่สุดของข้อมูลที่เป็นไปได้ [32] ในเทอมของการลดมิติสามารถถูกกำหนดเป็นปัญหาของการหา  $m$  ทิศทางตั้งฉาก  $\mathbf{w}_i$  ที่น้อยที่สุด การอธิบายค่าความผิดพลาดของฟังก์ชันเป้าหมายแสดงดังสมการที่ 3.33

$$J_{PCA} = E \left\{ \left\| \mathbf{x} - \sum_{i=1}^m \langle \mathbf{w}_i, \mathbf{x} \rangle \mathbf{w}_i \right\|^2 \right\} \quad (3.33)$$

ในฟังก์ชันเป้าหมายนี้ เวกเตอร์ที่ถูกลดคือ โปรเจกชัน  $\chi = (\langle \mathbf{w}_1, \mathbf{x} \rangle, \dots, \langle \mathbf{w}_m, \mathbf{x} \rangle)^T$  ซึ่งสามารถเขียนได้อีกแบบ คือ  $\chi = W^T \mathbf{x}$  โดยที่  $W$  คือ เมตริกซ์  $M \times m$  ซึ่งคอลัมน์เป็น orthonormal  $\mathbf{w}_i$  (หรือเท่ากับ  $W^T W = I$ ) การประมาณเวกเตอร์ดั้งเดิมถูกทำโดย  $\hat{\mathbf{x}} = \sum_{i=1}^m \langle \mathbf{w}_i, \mathbf{x} \rangle \mathbf{w}_i$  หรือ  $\hat{\mathbf{x}} = W \chi$  ในรูปที่ 3.11 แสดงการอธิบายการแปลงการวิเคราะห์องค์ประกอบหลักด้วยกราฟฟิก 2 มิติ

( $\mathbf{x} \in \mathbb{R}^2$ ) พบว่า ความแปรปรวนของข้อมูลในปริภูมิดั้งเดิมถูกจับภาพที่ดีที่สุดโดยปริภูมิที่ถูกหมุนด้วยเวกเตอร์  $\chi = W' \mathbf{x}$



รูปที่ 3.11 การอธิบายการแปลงการวิเคราะห์องค์ประกอบหลักด้วยกราฟฟิก 2 มิติ

$\chi_1$  คือ องค์ประกอบหลักตัวแรกและจะมีทิศทางในความแปรปรวนที่มากที่สุด  $\chi_2$  คือ องค์ประกอบหลักตัวที่ 2 ซึ่งมันจะมีทิศทางตั้งฉากกับตัวแรกและมีทิศทางในความแปรปรวนที่มากเป็นอันดับที่สอง (ในกรณี  $\mathbb{R}^2$  ไม่มีตัวเลือกมาก แต่ในกรณี  $\mathbb{R}^M$  จะมี) สังเกตได้ว่าจะไม่มีการสูญเสียข้อมูลทั่วไปซึ่งเป็นศูนย์กลางจุดเริ่มต้นของปริภูมิเอาต์พุต เราสามารถเขียนฟังก์ชันเป้าหมายอันใหม่ได้ดังสมการที่ 3.34

$$J_{PCA} = \{\|\mathbf{x} - W\chi\|^2\} = E\{\|\mathbf{x} - WW'\mathbf{x}\|^2\} \propto \|X - WW'X\|_F^2 \quad (3.34)$$


สังเกตว่าเมตริกซ์จำนวนสมาชิกของคลาส ( $U$  ในเวกเตอร์ควอนไทด์) ในกรณีนี้ถูกแทนด้วย  $W'X$  ซึ่งทั่วไปสามารถมีค่าเป็นบวกหรือลบ ดังนั้นมีการสูญเสียความเป็นสมาชิกของมันและถื่อน้ำหนักการรวมกันเชิงเส้นของเวกเตอร์คอลัมน์  $W$  ที่มีการประมาณดีกว่าแต่ละอินพุต  $X$  สุดท้ายฟังก์ชันเป้าหมายของการวิเคราะห์องค์ประกอบหลักสามารถเขียนได้ดังสมการที่ 3.35

$$J_{PCA} = \text{Tr}\{W'\Sigma_X W\} \quad (3.35)$$

โดยที่  $\Sigma_X = \frac{1}{N} \sum_i (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})'$  คือเมตริกซ์ความแปรปรวนของข้อมูลที่ถูกสังเกต

การโปรเจกชันเมตริกซ์ของเวกเตอร์อินพุตไปยังปริภูมิของมิติที่ต่ำกว่า ( $\chi = W' \mathbf{x}$ ) เป็นเทคนิคในการลดมิติที่นิยมทั่วไป องค์ประกอบที่เกี่ยวข้องในการโปรเจกชันการครั้งนี้มีความหมายที่น่าสนใจที่อธิบายไว้ในตัวอย่างต่อไป นี้ สมมติว่าแต่ละเวกเตอร์  $\mathbf{x}$  คือ ถูกโปรเจกแบบตั้งฉากไปยังปริภูมิย่อยที่กำหนดด้วยเวกเตอร์  $\mathbf{w}_i$  แต่ละเวกเตอร์  $\mathbf{w}_i$  มีมิติเท่ากับ  $M$  และ โปรเจกชันของ  $\mathbf{x}$

ไปยังแต่ละ  $w_i$  ให้แนวคิดของวิธีการที่สำคัญคือหัวข้อ  $w_i$  ที่จะเป็นตัวแทน  $x$  หัวข้อที่สำคัญมีค่าการโปรเจกชันที่มีขนาดใหญ่และมีค่ามากในองค์ประกอบที่สอดคล้องกันของ  $x$  ดังแสดงในรูปที่ 3.12



รูปที่ 3.12 โปรเจกชันของเมตริกซ์  $x$  ไปยังปริภูมิใหม่  $W'$

ถึงแม้ว่าการวิเคราะห์องค์ประกอบหลักคือการหาองค์ประกอบของข้อมูลที่ตีในการเปลี่ยนระนาบข้อมูลดั้งเดิมไปยังระนาบคุณลักษณะใหม่ที่มีมิติลดลง แต่มันอาจจะไม่มีประโยชน์สำหรับการรู้จำประเภทของข้อมูล

### 3.2.2 การวิเคราะห์การจำแนกเชิงเส้น (Linear Discriminant Analysis)

การวิเคราะห์การจำแนกแบบเชิงเส้นไม่เหมือนกับการวิเคราะห์องค์ประกอบหลักที่แสดงการหาการเปลี่ยนแปลงระนาบที่เหมาะสมเท่านั้น แต่ยังหาการเปลี่ยนแปลงระนาบที่เหมาะสมสำหรับการแยกแยะข้อมูลอีกด้วย นั่นคือวัตถุประสงค์ของการวิเคราะห์การจำแนกแบบเชิงเส้น เพื่อที่จะหาการแปลงสำหรับการแยกแยะการกระจายข้อมูลให้อยู่ในกลุ่มต่างๆ ซึ่งการลดการกระจายของข้อมูลของกลุ่มที่มีความคล้ายคลึงกันให้อยู่ในปริภูมิใหม่ ถึงแม้ว่าประสิทธิภาพของการวิเคราะห์การจำแนกแบบเชิงเส้นในปัญหาของการรู้จำหรือการคัดแยกประเภทถูกยืนยันด้วยการศึกษาหลายงาน [33][34] ความเป็นไปได้ของการวิเคราะห์การจำแนกแบบเชิงเส้นสำหรับการประยุกต์ที่ซึ่งเซตของข้อมูลการเรียนรู้ที่สมบูรณ์ไม่เป็นประโยชน์ก่อนใช้งานจริง ซึ่งยังคงเป็นปัญหาที่ท้าทาย

วัตถุประสงค์ของการวิเคราะห์การจำแนกแบบเชิงเส้นแบบดั้งเดิม [35] คือ การแยกการกระจายของข้อมูลที่อยู่ในคลาสต่างๆกันให้ห่างกัน ขณะที่การลดการกระจายของข้อมูลในคลาสเดียวกันให้ใกล้กันในปริภูมิใหม่ อันดับแรก เมตริกซ์การกระจายสองแบบคือ  $S_w$  เมตริกซ์การกระจายภายในคลาสเดียวกันและ  $S_b$  เมตริกซ์การกระจายที่อยู่ระหว่างคลาสตามสมการดังต่อไปนี้

$$S_{w_i} = \frac{1}{n_i} \sum_{j=1}^{n_i} (x_j^{(i)} - m_i)(x_j^{(i)} - m_i)^T \quad (3.36)$$

$$S_w = \sum_{i=1}^N n_i \times S_{w_i} = \sum_{i=1}^N \sum_{j=1}^{n_i} (x_j^{(i)} - m_i)(x_j^{(i)} - m_i)^T \quad (3.37)$$

$$S_B = \sum_{i=1}^N n_i (m_i - m_{all})(m_i - m_{all})^T \quad (3.38)$$


โดยที่  $n_i$  เป็นจำนวนของตัวอย่างในคลาสลำดับที่  $i$ ,  $x_j^{(i)} \in \mathbb{R}^d$  แสดงตัวอย่างลำดับที่  $j$  ของคลาสลำดับที่  $i$  และ  $d$  เป็นมิติของพื้นที่คุณลักษณะ  $N$  เป็นจำนวนทั้งหมดของคลาส  $m_i$  เป็นค่าเฉลี่ยของคลาสลำดับที่  $i$  และ  $m_{all}$  เป็นค่าเฉลี่ยของคลาสทั้งหมด โดยที่  $S_{W_i}$  มีค่าเท่ากับเมตริกซ์ความแปรปรวนของคลาสลำดับที่  $i$ ,  $S_W$  คือผลรวมของเมตริกซ์ความแปรปรวนทั้งหมด และ  $S_B$  คือผลรวมของพิสัยระหว่างค่าเฉลี่ยในแต่ละคลาสกับค่าเฉลี่ยรวมทั้งหมดของคลาส เพื่อที่จะบรรลุเป้าหมายของการวิเคราะห์การจำแนกเชิงเส้นพวกเราหาประสิทธิภาพสูงสุดของเมตริกซ์การโปรเจกชัน  $W$  โดยทำให้มีค่ามากที่สุดตามค่ามาตรฐานของ Fisher [36] ตามสมการที่ 3.39

$$J(W) = \frac{W^T S_B W}{W^T S_W W} \quad (3.39)$$

โดยที่  $W^T S_W W$  คือการกระจายในคลาสเดียวกันอันใหม่และ  $W^T S_B W$  คือการกระจายระหว่างคลาสอันใหม่ในปริภูมิคุณลักษณะที่ถูกลดรูปตามลำดับ นั่นคือเมตริกซ์การแปลง  $W$  ถูกใช้เพื่อเพิ่มอัตราของระยะทางระหว่างคลาสดูระยะทางภายในคลาส เพื่อให้การแยกแยะประสบความสำเร็จมากที่สุด ในปริภูมิคุณลักษณะที่ถูกลดรูปตามที่เวกเตอร์คุณลักษณะใหม่  $y$  สามารถหาได้จาก  $y = W^T x$  โดยที่  $x$  คือเวกเตอร์คุณลักษณะดั้งเดิม โดยทั่วไปการแก้สมการหา  $W$  ที่เหมาะสมที่สุดในสมการที่ (3.39) สามารถหาได้จากสมการ 3.40

$$S_B W = \lambda S_W W \quad (3.40)$$

ถ้าการผกผันของ  $S_W$  มีสามารถหาค่าได้  $W$  สามารถหาค่าโดยวิธีการแยกองค์ประกอบไอเกน (Eigen Decomposition) ของ  $S_W^{-1} S_B$  นั่นคือคอลัมน์ของ  $W$  เท่ากับไอเกนเวกเตอร์ที่มีค่าไอเกนไม่เท่ากับศูนย์กับค่าแรก  $N - 1$  ของสมการที่ (3.40)



รูปที่ 3.13 โปรเจกชันของเมตริกซ์  $x$  ไปยังปริภูมิใหม่

สำหรับงานที่เกี่ยวข้องกับการรู้จำรูปแบบจะเจอ 2 ปัญหาที่เป็นที่รู้จักกันดีคือ คำสาปของมิติ (Curse of dimensionality) [37] โดยทั่วไปคำสาปของมิติคือนิพจน์ของปรากฏการณ์ทั้งหมดที่ปรากฏกับข้อมูลที่มีมิติขนาดใหญ่ ซึ่งทำให้เกิดผลลัพธ์และประสิทธิภาพที่แย่สำหรับอัลกอริทึมต่างๆ และ ปัญหาข้อมูลที่น้อยเกินไป (Small Sample Size Problem) [38] สำหรับงานทางด้านความรู้จำรูปแบบ เนื่องจากจำนวนของคุณลักษณะที่มีขนาดใหญ่ แต่จำนวนของรูปแบบสำหรับการเรียนรู้มีน้อยมาก ๆ นี่หมายความว่าเมตริกซ์ความแปรปรวนจะเป็นซิงกูลาร์ (Singular) ทำให้ไม่สามารถหาค่าอินเวอร์สได้ มีตัวอย่างที่สำคัญของปัญหาขนาดข้อมูลที่น้อยเกินไป ยกตัวอย่างเช่น ในการรู้จำใบหน้า เรามีตัวแปรจำนวนมาก (pixel) การใช้การวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis) สามารถลดมิติของข้อมูลให้เหลือน้อยลงได้ แต่อย่างไรก็ตามจำนวนคลาสของตัวอย่างการสอน (Training Sample) จะมีน้อย ถ้าจำนวนของจุดข้อมูลมีน้อยกว่าจำนวนของตัวแปร เมตริกซ์ความแปรปรวนจะกลายเป็นซิงกูลาร์และไม่สามารถหาค่าอินเวอร์สได้ ในกรณีนี้เราต้องการที่จะหาการประมาณ full rank ของเมตริกซ์ความแปรปรวนบางวิธีที่ทำให้สามารถหาอินเวอร์สได้ และทำให้สามารถลดมิติของข้อมูลได้ จาก 2 ปัญหาที่เกิดขึ้นนี้ทำให้ไม่สามารถลดมิติของข้อมูลได้ ดังนั้นเราจึงนำเสนอเทคนิคการลดมิติแบบใหม่ที่สามารถช่วยแก้ปัญหาได้ ซึ่งจะกล่าวในบทที่ 4

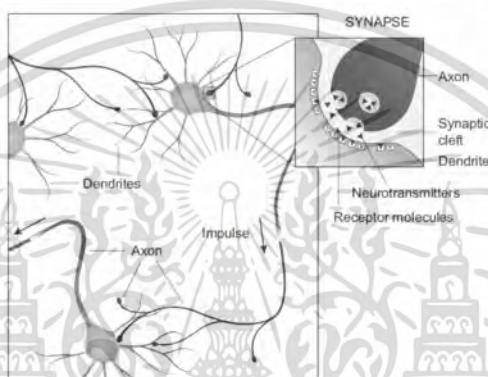
### 3.3 ทฤษฎีโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม [39,40] เป็นเครือข่ายที่มีโครงสร้างและการประมวลผลเหมือนกับสมองในสิ่งมีชีวิตที่มีการปรับเปลี่ยนตัวเองต่อการตอบสนองของอินพุตตามกฎการเรียนรู้ (learning rule) หลังจากที่เครือข่ายได้เรียนรู้สิ่งที่ต้องการแล้ว เครือข่ายนั้นจะสามารถทำงานตามที่กำหนดไว้ได้ เครือข่ายประสาทเทียมได้ถูกพัฒนาคิดค้นจากการทำงานของสมองมนุษย์ โดยสมองมนุษย์ประกอบไปด้วยหน่วยประมวลผลที่เรียกว่านิวรอน (เซลล์ประสาท หรือ neuron) สมองมนุษย์จึงสามารถกล่าวได้ว่าเป็นคอมพิวเตอร์ที่มีการปรับตัว (adaptive) ไม่เป็นเชิงเส้น (nonlinear) และทำงานแบบขนาน (parallel) ในการดูแลจัดการการทำงานร่วมกันของนิวรอนในสมอง การคำนวณเชิงนิวรอนเป็นการคำนวณที่เลียนแบบมาจากการทำงานของสมองมนุษย์นั่นเอง

#### 3.3.1 โครงข่ายประสาทเชิงชีววิทยา (Biological Neural Network)

ระบบประสาทเป็นระบบที่ใหญ่และซับซ้อน สมองเป็นศูนย์กลางของระบบประสาทโดยจะเชื่อมต่อกับประสาทสัมผัส เพื่อรับข้อมูลจากภายนอกเข้าสู่ประสาท แล้วทำการประมวลผลเป็นคำสั่งไปยังอวัยวะต่างๆ โดยปกติสมองประกอบไปด้วยนิวรอนจำนวนมากและมีการเชื่อมต่อกันภายในเครือข่ายย่อยเรียกว่านิวคลีไอ (nuclei) เครือข่ายย่อยจะทำการแยกและปรับข้อมูลจากประสาทสัมผัสก่อนส่งไปยังเครือข่ายย่อยอื่นๆและสุดท้ายกลายเป็นรูปแบบของสัญญาณที่ผ่านการประมวลผลเป็นคำสั่งไปยังอวัยวะต่างๆ

ระบบประสาทประกอบด้วยเซลล์ประสาทที่มีการเชื่อมต่อกันดังรูปที่ 3.14 เซลล์ประสาทสื่อสารกันโดยผ่านสัญญาณทางไฟฟ้าที่เคลื่อนที่ในทิศทางเดียวกัน แต่กึ่งกันไปยังส่วนเซลล์อื่นๆ การเชื่อมต่อระหว่างเซลล์ประสาท ประกอบด้วยส่วนที่มีการแตกแขนงออกไปเป็นที่รู้จักกันในชื่อว่า Dendrites โดย Dendrites ทำหน้าที่รับสัญญาณจากเซลล์ประสาทอื่น ๆ ผ่านส่วนที่เรียกว่า Axon ซึ่ง Axon ถูกสร้างเพื่อการติดต่อระหว่างเซลล์ประสาท และเป็นส่วนที่นำสัญญาณทางไฟฟ้าที่ปล่อยออกมาจากเซลล์ประสาทขาออก ในขณะที่เดียวกันเซลล์ประสาทใดๆ ก็สามารถรับสัญญาณจากเซลล์ประสาทอื่น ๆ




รูป 3.14 รายละเอียดของเซลล์ประสาทชีวภาพ

การส่งสัญญาณทางไฟฟ้าระหว่างเซลล์ประสาทใดๆ ใช้อุปกรณ์ทางไฟฟ้าชีวภาพ ที่เรียกว่า Synapses เป็นสื่อกลาง โดยที่ Synapses จะพบอยู่บริเวณจุดต่อระหว่าง Axon และ Dendrites สัญญาณทางไฟฟ้าที่เข้ามายังจุดนี้จะทำให้ Synapses ถูกกระตุ้นให้เกิดการปล่อยสารเคมีที่เรียกว่า สารสื่อประสาท (Neurotransmitter) ซึ่งสารสื่อประสาทจะกระตุ้นโมเลกุลที่อยู่บน Dendrites ทำให้ไอออนเกิดประจุไฟฟ้าเรียกว่าไอออน (ion) โดยไอออนเหล่านี้จะสร้างแรงดันไฟฟ้าขึ้นระหว่างเยื่อหุ้มเซลล์ที่เดินทางจาก Dendrites ไปยังส่วนของ Axon เพราะฉะนั้นความแตกต่างระหว่างแรงดันไฟฟ้าภายในของตัวเซลล์ประสาทและสภาพแวดล้อมภายนอก มีผลต่อการทำงานของระบบเซลล์ประสาท ซึ่งเป็นที่รู้จักกันในชื่อว่า “ระดับการเปิดใช้งานหรือระดับศักยภาพของเซลล์ประสาท” เซลล์ที่มีการส่งและการรับเซลล์สัญญาณจากประสาทอื่นจะเรียกเซลล์ประสาทนั้นว่า Presynaptic และ Postsynaptic ตามลำดับ

เซลล์ประสาทจะแพร่สัญญาณไฟฟ้าไปตาม Axon และเมื่อความแตกต่างของแรงดันไฟฟ้าระหว่างเยื่อหุ้มเซลล์และบริเวณสิ่งแวดล้อมภายนอกมีขนาดใหญ่กว่าค่าขีดเริ่มที่กำหนดไว้ดังรูปที่ 3.15 ที่แสดงตัวอย่างของสัญญาณที่เกิดขึ้นในระบบประสาท เช่นในสภาพปกติแรงดันไฟฟ้าของเซลล์ประสาทของเยื่อหุ้มสมองของสัตว์เลี้ยงลูกด้วยนมจะอยู่ที่ประมาณ  $-65$  mV เมื่อมีการรับสัญญาณเข้ามาทำให้เกิดระดับแรงดันไฟฟ้าที่กระตุ้นมีค่าเป็นบวก ซึ่งเมื่อแรงดันไฟฟ้าเพิ่มขึ้นถึงค่าขีดเริ่มที่


-55 mV ส่งผลทำให้เกิดระดับการทำงานที่เรียกว่า Action Potential ซึ่งเป็นการเคลื่อนตัวจาก Axon โหลไปยังเซลล์ประสาท Postsynaptic โดยกระบวนการของ Action Potential จะเป็นไปตามขั้นตอนของ Hyperpolarization ซึ่งทำให้เซลล์ประสาทจะกลับไปหาค่าลบอีกครั้ง คือระดับแรงดันไฟฟ้า -65 mV (วิจัยกรพื้นฐานที่ถูกค้นพบเป็นครั้งแรกโดย Hodgkin และ Huxley ในปี 1952) เป็นสาเหตุให้เกิดการไหลเข้าและออกของไอออน โดยไอออนจะไหลผ่านเยื่อหุ้มเซลล์ และสามารถอยู่ได้ระหว่าง 3 ถึง 50 วินาที ทั้งนี้จะขึ้นอยู่กับชนิดของการไหลของไอออน สุดท้ายผลลัพธ์ที่ออกมาจากกระบวนการดังกล่าวคือสัญญาณพัลส์หรือบางทีก็เรียกว่าชีพจร (Spike)



รูปที่ 3.15 สัญญาณทางไฟฟ้าของระบบประสาท

โดยที่เซลล์ประสาทส่วนใหญ่สามารถแผ่คลื่นถึง 250 - 300 พัลส์ต่อวินาที และแม้กระทั่งในกรณีที่ไม่มียินพุทเข้ามา สัญญาณจะอยู่ในสถานะกิจกรรมพักผ่อนจะมีคลื่นประมาณ 10 พัลส์ต่อวินาทีสมองจึงแสดงกิจกรรมที่เกิดขึ้นเองแม้กระทั่งในกรณีที่ไม่มีตัวกระตุ้น ชนิดของเซลล์ประสาทสามารถแบ่งออกเป็น 3 ชนิด ดังรูปที่ 3.16 ซึ่งมีรายละเอียดดังนี้

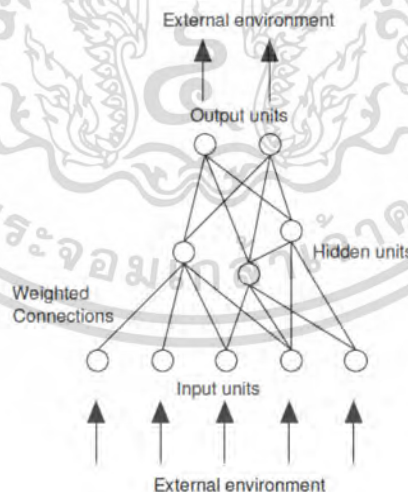
- Sensory neurons คือเซลล์ประสาทรับสัมผัสเป็นเสมือนอุปกรณ์ต่อพ่วงที่มีตรวจจับการป้อนข้อมูลเมื่อสัมผัสกับสภาพแวดล้อมภายนอก การเชื่อมต่อผลลัพธ์ที่สามารถแยกออกจากกัน จะทำให้การติดต่อกับเซลล์ประสาทอื่น ๆ
- Interneurons เป็นเซลล์ประสาทที่สร้างการเชื่อมต่อกับเซลล์ประสาทอื่นๆ แต่ไม่ได้เชื่อมต่อโดยตรงกับสภาพแวดล้อม
- Motor neurons เป็นเซลล์ประสาทที่ทำหน้าที่รับการป้อนข้อมูลจากเซลล์ประสาทหรือจากเซลล์ประสาทอื่น ๆ ในระบบ ช่วยให้ควบคุมสัญญาณมาบรรจบกันจากแหล่งต่าง ๆ ก่อนที่จะถูกส่งไปส่วนอื่น ๆ



รูปที่ 3.16 แบบจำลองของ Sensory neurons, Motor neurons และ Interneurons

### 3.3.2 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียมเป็นการจำลองของการคำนวณที่ดำเนินการโดยซอฟต์แวร์ หรือ สร้างอุปกรณ์ฮาร์ดแวร์เพื่อพยายามที่เลียนแบบพฤติกรรม และคุณลักษณะการปรับตัวของระบบประสาททางชีวภาพ โครงข่ายประสาทเทียมประกอบด้วยหน่วย (units) ที่เชื่อมต่อกันหลายๆ หน่วยหรือเซลล์ประสาทหลายเซลล์ (neurons) ดังรูปที่ 3.17 ซึ่งบางส่วนของหน่วยเหล่านี้ได้รับข้อมูลโดยตรงจากสภาพแวดล้อม หรือบางหน่วยก็รับข้อมูลจากผลกระทบจากปฏิกิริยาของสภาพแวดล้อม (input units) บางหน่วยก็ได้รับผลกระทบโดยตรงจากสิ่งแวดล้อม (output units) และการติดต่อกันจะอยู่ในโครงข่าย (internal, hidden, units)



รูปที่ 3.17 แผนผังโครงข่ายประสาท


วัตถุประสงค์ของการสร้างโครงข่ายประสาทเทียมคือ การทำเครื่องจักรให้มีความสามารถในการเรียนรู้การรู้จำรูปแบบ (Pattern Recognition) และการสร้างความรู้ใหม่ (Knowledge

Extraction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาโครงข่ายไฟฟ้าชีวภาพ (Bioelectric Network) ในสมองซึ่งประกอบด้วย เซลล์ประสาท (Neurons) และจุดประสานประสาท (Synapses) เป็นเสมือนชั้นขาเข้า (Input Layer) ในแต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า Dendrite เป็นเสมือนฟังก์ชันที่ใช้ในการคำนวณเพื่อตัดสินใจ และปลายในการส่งกระแสประสาทเรียกว่า Axon ซึ่งเป็นเหมือนส่วนชั้นขาออก (Output) ของเซลล์ ดังที่ได้กล่าวไว้แล้วในข้างต้น เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่าน Dendrite เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทาง Axon ของมัน

เมื่อหน่วยของเซลล์ประสาทเทียมได้รับการกระตุ้นจากสิ่งแวดล้อม โครงข่ายประสาทเทียมเรียนรู้โดยการปรับเปลี่ยนของค่าความแรงของ Synapses ซึ่งปกติแล้วการเรียนรู้ต้องผ่านการนำเสนอผลการทดลองการทำซ้ำหลายชุดของรูปแบบการป้อนข้อมูล การเรียนรู้จะมีฟังก์ชันหลายประเภทซึ่งแต่ละฟังก์ชันการทำงานจะเฉพาะเจาะจง และจะใช้กับสถาปัตยกรรมเฉพาะ โดยปกติทุกการเชื่อมต่อภายใน Synapses จะปรับเปลี่ยนไปตามกฎการเรียนรู้เดียวกัน

### 3.3.3 โครงข่ายประสาทเทียมอย่างง่าย (Single layer perceptron)

การจำลองโครงข่ายประสาทเทียมด้วยคอมพิวเตอร์ เซลล์ประสาทเทียม (Neurons) จะประกอบด้วยชั้นขาเข้า (Input) และ ชั้นขาออก (output) โดยจำลองให้ชั้นขาเข้าแต่ละอันมีน้ำหนักเป็นตัวกำหนดขนาดของชั้นขาเข้า มีเซลล์แต่ละหน่วยจะมีค่าขีดเริ่มเป็นตัวกำหนดว่าน้ำหนักรวมของชั้นขาเข้า ต้องมากขนาดไหนจึงจะสามารถส่งชั้นขาออกไปยังเซลล์ตัวอื่นได้ เมื่อนำเซลล์แต่ละหน่วยมาต่อกันให้ทำงานร่วมกัน การทำงานนี้ในทางตรรกะแล้วก็จะเหมือนกับปฏิกิริยาเคมีที่เกิดในสมองเพียงแต่ในคอมพิวเตอร์ทุกอย่างแต่เป็นตัวเลขเท่านั้นดังรูปที่ 3.18



รูปที่ 3.18 แผนผังของเซลล์ประสาทชีวภาพและเซลล์ประสาทเทียม

เซลล์ประสาทเทียมถูกกำหนดโดยคุณลักษณะของชุดของเซลล์ประสาทเทียม (Neuron) โดยที่แต่ละเซลล์ที่มีขนาดมากพอที่จะส่งสัญญาณไปยังชั้นขาออก ผ่านค่าขีดเริ่มที่กำหนดด้วยฟังก์ชันการถ่ายโอน ถ้าเราไม่สนใจความล่าช้าของการส่งข้อมูล ผลลัพธ์ของสัญญาณที่ออกมาจากเซลล์ประสาทเทียม ของสัญญาณขาเข้า  $\vec{x}$  บนเซลล์ประสาท Postsynaptic เท่ากับผลการคูณของ  $\vec{w} \cdot \vec{x}$  โดยกำหนดให้  $\vec{w}$  คือน้ำหนัก Synapses และสามารถเป็นค่าใดๆ ไม่ว่าจะ เป็นค่าลบหรือค่าบวก โดยผลลัพธ์สามารถหาได้ตามสมการ 3.41

$$a_i = \sum_{j=1}^N w_{ij} x_j \quad (3.41)$$

โดยในแต่ละเซลล์ประสาทเทียมจะประกอบด้วยผลจากคูณข้างต้นแล้วผ่านฟังก์ชันการถ่ายโอนตามสมการ

$$y_i = \Phi(a_i) = \Phi\left(\sum_{j=1}^N w_{ij} x_j - \theta_i\right) \quad (3.42)$$

ฟังก์ชันการถ่ายโอน  $\Phi(\cdot)$  จะอธิบายรายละเอียดการตอบสนองของเซลล์ประสาทและสามารถใช้รูปแบบที่แตกต่างกันหลายรูปแบบ โดยในรูปแบบดั้งเดิมที่จัดทำโดย McCulloch และ Pitts ขึ้น ในปี 1943 เซลล์ประสาทเทียมแต่ละตัวมีผลลัพธ์แบบไบนารี (0 หรือ 1) ดังสมการ (3.43) ทำให้ค่าขีดเริ่มที่ใช้เป็นตัวกำหนดเขตยากที่จะบอกว่าเซลล์ประสาทส่งสัญญาณหรือไม่

$$\Phi(a_i) = \begin{cases} 1: \sum_{j=1}^N w_{ij} x_j > \theta_i \\ 0: \text{Otherwise} \end{cases} \quad (3.43)$$

และรูปแบบของฟังก์ชันการถ่ายโอนแบบสองขั้ว(bipolar activation)

$$\Phi(a_i) = \begin{cases} 1: \sum_{j=1}^N w_{ij} x_j > \theta_i \\ -1: \text{Otherwise} \end{cases} \quad (3.44)$$

จากสมการ (3.44) ข้างต้นเซลล์ประสาทสามารถมีสถานะได้เพียงหนึ่งในสองสถานะเท่านั้น และสามารถส่งค่าสัญญาณเพียงหนึ่งบิตของข้อมูลเท่านั้น ในกรณีสำหรับฟังก์ชันการถ่ายโอนแบบต่อเนื่องก็จะทำให้เซลล์ประสาทสามารถอยู่ได้หลายสถานะ เช่นผลลัพธ์ของฟังก์ชันการถ่ายโอนแบบต่อเนื่องซึ่งจะเป็นจำนวนจริง ในด้านชีวภาพจำนวนที่ต่อเนื่องนี้ บ่งชี้ได้ว่าไม่ว่าจะเป็นอัตราการ


กระตุ้นของเซลล์ประสาทจะมีค่ามากกว่าช่วงเวลาสั้นหรือเป็นผลรวมของผล excitatory และ Inhibitory ของผลลัพธ์ของจำนวนของเซลล์ประสาททั้งหมดฟังก์ชันแบบต่อเนื่องอย่างง่ายสามารถทำแบบจำลองเชิงเส้นดังสมการ

$$\Phi(a_i) = ka_i \quad (3.45)$$

โดยกำหนดให้ค่า  $k$  เป็นค่าคงที่ใดๆ ในสถานการณ์ที่ไม่อาจคาดเดา ค่าผลลัพธ์ของเซลล์ประสาทจะเพิ่มขึ้นไปเรื่อยๆ จึงกำหนดขอบเขตของฟังก์ชันกระตุ้นนี้ให้อยู่ภายในช่วงเช่น  $[0, 1]$  หรือ  $[-1, 1]$  นอกจากนี้ยังมีฟังก์ชันถ่ายโอนแบบต่อเนื่องและไม่เชิงเส้นที่ใช้กับสถาปัตยกรรมของระบบประสาทที่ซับซ้อน และหนึ่งในฟังก์ชันที่พบมากที่สุดคือฟังก์ชันซิกมอยด์ (Sigmoid) ดังสมการ (3.46)

$$\Phi(a_i) = \frac{1}{1 + e^{-ka_i}} \quad (3.46)$$

โดยที่กำหนดให้  $k$  เป็นปัจจัยสำหรับการปรับขนาดของความลาดเอียงแสดงในรูปที่ 3.19 (สำหรับ  $K \rightarrow 0$  ฟังก์ชันถ่ายโอนก็จะกลายเป็นฟังก์ชันเชิงเส้น และสำหรับ  $K \rightarrow \infty$  ฟังก์ชันถ่ายโอนก็กลายเป็นฟังก์ชันสองระดับ) ฟังก์ชันซิกมอยด์ มีแนวโน้มจะเป็นฟังก์ชันแบบต่อเนื่องจาก 0 ถึง 1 โดยมีฟังก์ชันที่คล้ายๆ กันคือ  $\tanh(kA)$  ซึ่งเป็นฟังก์ชันแบบต่อเนื่องจาก -1 ถึง 1



รูปที่ 3.19 ฟังก์ชันถ่ายโอน (ก) ฟังก์ชันเชิงเส้น (linear function)  $k = 1$

(ข) ฟังก์ชันระดับ (step function)  $g = 0$

(ค) ฟังก์ชันซิกมอยด์ (sigmoid function)  $k = 1$


กระตุ้นการทำงานของเซลล์ประสาทเทียมจะแปรผันตรงกับความคล้ายคลึงกันระหว่างเวกเตอร์ น้ำหนัก  $w$  และเวกเตอร์อินพุต  $\bar{x}$  ดังรูปที่ 3.20 โดยที่สามารถอธิบายเงื่อนไขด้วยพีชคณิตเชิงเส้นถึงความคล้ายคลึงกันระหว่างเวกเตอร์ทั้งสองด้วยโคไซน์ของมุม  $\alpha$  ระหว่างเวกเตอร์

$$\cos \alpha = \frac{\vec{w} \cdot \vec{x}}{\|\vec{w}\| \|\vec{x}\|}, 0 \leq \alpha \leq \pi \quad (3.47)$$

โดยกำหนดให้  $\|\vec{w}\|$  เป็นความยาวของเวกเตอร์  $w$  ดังนั้นเราสามารถแสดงผลลัพธ์ของเซลล์ประสาทเทียมได้ดังนี้

$$y = \vec{w} \cdot \vec{x} = \|\vec{w}\| \|\vec{x}\| \cos \alpha \quad (3.48)$$


กล่าวคือหากว่าความยาวของเวกเตอร์ทั้งสอง (เวกเตอร์น้ำหนัก  $\vec{w}$  และเวกเตอร์อินพุต  $\vec{x}$ ) มีค่าคงที่ ผลลัพธ์ของการเปลี่ยนแปลงเซลล์ประสาทเทียมขึ้นกับมุมโคไซน์ระหว่างทั้งสองเวกเตอร์ ขนาดของมุมโคไซน์คือสัดส่วนผกผันกับระยะทางเชิงมุมระหว่างชั้นขาเข้าและเวกเตอร์น้ำหนักที่อยู่ในด้านเดียวกัน ซึ่งชั้นขาออกจะมีขนาดเล็กที่สุดเมื่อทั้งสองเวกเตอร์ตั้งฉาก ( $\cos 90^\circ = 0$ ) และจะมีขนาดใหญ่ที่สุดเมื่อทั้งสองเวกเตอร์ในแนวเดียวกัน ( $\cos 0^\circ = 1$ ) โดยในระบบโครงข่ายประสาทเทียมที่มีชั้นขาออกหลายเซลล์ ระดับของการเปิดใช้งานจะเป็นกำหนดว่า เซลล์ประสาทเทียมเซลล์ไหนมีน้ำหนักใกล้เคียงกับรูปแบบของเวกเตอร์ในชั้นขาเข้า (ซึ่งต้องมีความยาวเวกเตอร์เท่ากัน) ถ้าสมมุติให้ฟังก์ชันการเปิดใช้งานเป็นแบบไบนารี ดังนั้นในเซลล์ชั้นขาออก สามารถใช้ในการแยกแยะระหว่างสองชั้นของเวกเตอร์ชั้นขาเข้า ซึ่งจะขึ้นอยู่กับระยะทางเชิงมุมว่ามีขนาดเล็กกว่า  $90$  องศาหรือระยะทางเชิงมุมว่ามีขนาดใหญ่กว่า  $90$  องศา ระหว่างเวกเตอร์ชั้นขาเข้าเวกเตอร์น้ำหนักในแต่ละเซลล์ดังรูปที่ 3.20



**รูปที่ 3.20** (ก-ข) ความสัมพันธ์ระหว่างเวกเตอร์น้ำหนัก และเวกเตอร์ขาเข้าของนิวรอน

จากรูปที่ 3.21 เส้นการแบ่ง (สายหนา) ของพื้นที่ชั้นขาเข้าโดยเซลล์ประสาทเทียมมีสองชั้นขาออก (โดยทั้งสองชุดตั้งค่าขีดเริ่มไว้ที่ 1) มักจะตั้งฉากกับเวกเตอร์น้ำหนักของเซลล์ประสาทเทียมส่วนเส้นบางๆ คือตัวอย่างที่แสดงให้เห็นถึงการกระจายของจุดข้อมูล ซึ่งเซลล์ประสาทเทียมจะเห็นความแตกต่างโดยการตอบสนองที่แตกต่างกันขึ้นอยู่กับชั้นขาเข้าว่าจะอยู่เหนือหรือใต้เส้นแบ่งข้อมูล โดย


รูป ก มีค่าขีดเริ่มกำหนดให้ 1 และรูป ข มีค่าขีดเริ่มกำหนดให้เป็น 0 เรียกรูปแบบเซลล์นี้ว่า linearly separable โดยทั่วไปมักใช้กับเพอร์เซพตรอนชั้นเดียว



รูปที่ 3.21 (ก) การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว ค่าขีดเริ่มต้นเท่ากับ 1  
(ข) การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว ค่าขีดเริ่มต้นเท่ากับ 0

### 3.3.4 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron)

โครงข่ายประสาทเทียมแบบหลายชั้นสามารถแก้ปัญหาที่ไม่สามารถแบ่งแยกได้แบบเชิงเส้น พิจารณาตัวอย่างปัญหา XOR ที่มีคู่ อินพุตและเป้าหมายดังนี้



รูปที่ 3.22 รูปแบบเวกเตอร์อินพุตและเอาต์พุตของฟังก์ชัน XOR


อินพุตและเป้าหมายดังนี้ (ดูรูปที่ 3.22 ประกอบ)

$$\left\{ \begin{matrix} P_1 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, t_1 = [0] \\ P_2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, t_2 = [0] \\ P_3 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, t_3 = [1] \\ P_4 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, t_4 = [0] \end{matrix} \right\}$$


$$\left\{ P_3 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, t_3 = [0] \right\}$$

$$\left\{ P_4 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, t_4 = [0] \right\}$$

มีเครือข่ายแบบหลายชั้นหลากหลายโครงสร้างที่สามารถแก้ปัญหา XOR นี้ได้ โดยปกติแล้วเครือข่ายเพียง 2 ชั้นก็สามารถแก้ปัญหาได้ ตัวอย่างหนึ่งก็คือใช้เครือข่าย 2 ชั้นที่ชั้นแรกประกอบไปด้วย 2 นิวรอน เพื่อสร้างเส้นแบ่งพื้นที่ 2 เส้น เส้นแรกใช้แบ่งอินพุต  $P_1$  ออกจากอินพุตอื่นๆ และเส้นที่สองใช้แบ่งอินพุต  $P_4$  ออก เครือข่ายชั้นที่สองใช้สำหรับรวมเส้นแบ่งพื้นที่จากชั้นแรกเข้าด้วยกันด้วยการกระทำ AND ดังนั้นเครือข่ายชั้นที่สองจึงใช้เพียงนิวรอนเดียว แสดงดังรูปที่ 3.23 แสดงเส้นแบ่งพื้นที่ที่เกิดจากนิวรอนแต่ละนิวรอนในแต่ละชั้นของเครือข่ายดังกล่าว โครงสร้างของเครือข่ายแสดงในรูปที่ 3.24



รูปที่ 3.23 (a) เส้นแบ่งพื้นที่ นิวรอน 1 / ชั้นที่ 1  
(b) เส้นแบ่งพื้นที่ นิวรอน 2 / ชั้นที่ 1  
(c) เส้นแบ่งพื้นที่ในปัญหา XOR จากเครือข่าย 2 ชั้น



รูปที่ 3.24 ตัวอย่างเครือข่ายไปข้างหน้าขนาด 2 ชั้น (ชั้นละ 2 นิวรอนและ 1 นิวรอน)


โครงข่ายประสาทเทียมแบบ Multi-layer Perceptron เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมที่มีโครงสร้างเป็นแบบหลายๆชั้น ดังรูปที่ 3.25 ใช้สำหรับงานที่มีความซับซ้อนได้ผลเป็นอย่างดีโดยมีกระบวนการฝึกฝนเป็นแบบมีผู้สอน (Supervise) และโครงข่ายประสาทเทียมมี 2 ชั้นตอนการทำงานหลักๆ ดังนี้ การป้อนไปข้างหน้า (Feed Forward) แพร่ย้อนกลับ (BackPropagate) สำหรับการส่งผ่านไปข้างหน้า ข้อมูลจะผ่านเข้าโครงข่ายประสาทเทียมที่ชั้นขาเข้า และจะส่งผ่านจากอีกชั้นหนึ่งไปสู่อีกชั้นหนึ่งจนกระทั่งถึงชั้นขาออก ส่วนการส่งผ่านย้อนกลับค่าน้ำหนักการเชื่อมต่อจะถูกปรับเปลี่ยนให้สอดคล้องกับกฎการแก้ข้อผิดพลาด (Error-Correction) คือผลต่างของผลตอบที่แท้จริง (Actual Response) กับผลตอบเป้าหมาย (Target Response) เกิดเป็นสัญญาณผิดพลาด(Error Signal) ซึ่งสัญญาณผิดพลาดนี้จะถูกส่งย้อนกลับเข้าสู่โครงข่ายประสาทเทียมเรียกว่ากระบวนการแพร่ย้อนกลับ (BackPropagate) ในทิศทางตรงกันข้ามกับการเชื่อมต่อและค่าน้ำหนักของการเชื่อมต่อจะถูกปรับจนกระทั่งผลตอบที่แท้จริงเข้าใกล้ผลตอบเป้าหมาย สัญญาณที่มีโครงข่ายประสาทเทียมแบบหลายชั้นมี 2 ประเภทคือ Function Signal และ Error Signal

- Function Signal เป็นสัญญาณเข้าที่มาจากนิวรอนในชั้นก่อนหน้า และจะส่งผ่านไปข้างหน้าจากนิวรอนหนึ่งไปสู่อีกนิวรอนหนึ่ง
- Error Signal เป็นสัญญาณย้อนกลับที่เกิดขึ้นที่นิวรอนในชั้นข้อมูลออกของโครงข่ายประสาทเทียม และถูกส่งผ่านย้อนกลับจากชั้นหนึ่งไปสู่อีกชั้นหนึ่ง

หลักการทำงานของโครงข่ายประสาทเทียมแบบหลายชั้นคือ ในแต่ละชั้นของชั้นซ่อนตัว (Hidden Layer) จะมีฟังก์ชันสำหรับคำนวณเมื่อได้รับสัญญาณ (Output) จากนิวรอนในชั้นก่อนหน้า นี้ เรียกว่า Activation Function โดยในแต่ละชั้นไม่จำเป็นต้องเป็นฟังก์ชันเดียวกันก็ได้ ชั้นซ่อนตัวนั้นมีหน้าที่สำคัญคือ จะพยายามแปลงข้อมูลที่เข้ามาในชั้น (Layer) นั้นๆให้สามารถแยกแยะความแตกต่างโดยใช้เส้นตรงเส้นเดียว (Linearly Separable) และก่อนที่ข้อมูลจะถูกส่งไปถึงชั้นข้อมูลออก (Output Layer) ในบางครั้งอาจจำเป็นต้องใช้ชั้นซ่อนตัวมากกว่า 1 ชั้นในการแปลงข้อมูลให้อยู่ในรูป Linearly Separable

ในการคำนวณหาผลลัพธ์ของปัญหาการจำแนกทำได้โดยการใส่ข้อมูลชั้นขาเข้า ไปในโครงข่ายประสาทเทียมที่เราได้ทำการหาไว้แล้ว จากนั้นให้ทำการเปรียบเทียบค่าของผลลัพธ์ในชั้นขาออก และให้ทำการเลือกค่าของผลลัพธ์ที่มีค่าสูงกว่า (เซลล์ประสาทเทียมที่มีค่าสูงกว่า) และทำการรับค่าของพยากรณ์ที่ตรงกับเซลล์ที่เลือก และให้นำค่าของผลลัพธ์มาเปรียบเทียบกับค่าที่ยอมรับได้ หากค่าของอยู่ในช่วงที่รับได้ (Error น้อยกว่า Error ที่เรากำหนด) ก็ให้ทำการรับข้อมูลชุดถัดไป แต่ถ้าหากค่าของผลลัพธ์มากกว่าค่าที่ยอมรับได้ ให้ทำการปรับค่าน้ำหนักตามขั้นตอนที่ได้กล่าวไว้ข้างต้น เมื่อทำการปรับน้ำหนักเรียบร้อยแล้ว ให้ทำการรับข้อมูลชุดถัดไปและทำตามขั้นตอนซ้ำอีกรอบจนกระทั่งถึงข้อมูลชุดสุดท้าย และเมื่อทำข้อมูลชุดสุดท้ายเสร็จจะนับเป็น 1 รอบของการคำนวณ (1 Epoch) จากนั้นจะทำการหาค่าผิดพลาดรวมเฉลี่ย จากค่าเฉลี่ยของ ที่ได้เก็บค่าเอาไว้ เพื่อใช้ในการ

ตรวจสอบว่าค่า โดยเฉลี่ยในการจำแนกนั้น มีค่าน้อยกว่าค่าผิดพลาดที่ยอมรับได้หรือไม่ ถ้าใช่แสดงว่าโครงข่ายประสาทเทียมที่สร้างขึ้นนั้นสามารถให้ผลลัพธ์ที่ถูกต้องของทุกๆข้อมูลแล้ว จึงทำการจบการเรียนรู้ได้ แต่ถ้าไม่ใช่ ให้กลับไปทำตามขั้นตอนแรก โดยเริ่มรับข้อมูลชุดที่ 1 ใหม่


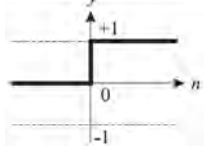



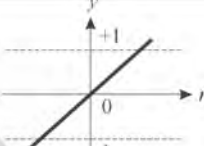

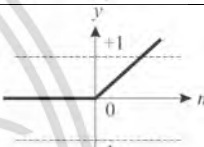
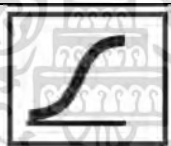


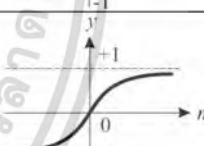

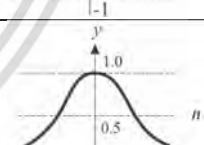


รูป 3.25 โครงข่ายประสาทเทียมแบบหลายชั้น

### 3.3.5 ฟังก์ชันถ่ายโอน (Activation Function or Transfer Function)

ฟังก์ชันการถ่ายโอนเป็นส่วนที่ทำหน้าที่รวมค่าเชิงตัวเลขจากเอาต์พุตของนิวรอน แล้วทำการตัดสินใจว่าให้เอาต์พุตออกไปในรูปแบบใด ฟังก์ชันถ่ายโอนสามารถเป็นได้ทั้งแบบเชิงเส้น หรือไม่เชิงเส้น การเลือกใช้ฟังก์ชันถ่ายโอนจะขึ้นอยู่กับลักษณะของระบบที่นำเอาเครือข่ายประสาทเทียมไปประยุกต์ใช้ ฟังก์ชันถ่ายโอนมีหลายแบบ เช่นฟังก์ชันถ่ายโอนแบบขั้นบันได (Hard-limit) ฟังก์ชันถ่ายโอนแบบบันไดสมมาตร (Symmetrical Hard-limit) ฟังก์ชันถ่ายโอนแบบเชิงเส้น (Linear) ฟังก์ชันถ่ายโอนแบบลอการิทึมมอยด์ (Logarithmic sigmoid) ฟังก์ชันการถ่ายโอนแบบไฮเพอร์บอลิกแทนเจนต์ซิกมอยด์หรือแทนซิกมอยด์ (Hyperbolic tangent sigmoid) และอื่นๆ ซึ่งฟังก์ชันถ่ายโอนแต่ละชนิดมีรายละเอียดดังตารางที่ 2.5

ตารางที่ 3.1 ฟังก์ชันถ่ายโอนแบบต่างๆ

ชื่อฟังก์ชันถ่ายโอน	สมการความสัมพันธ์	สัญลักษณ์	กราฟความสัมพันธ์
<b>Hard limit</b>	$y = 0$ ถ้า $n < 0$ $y = 1$ ถ้า $n \geq 0$		
<b>Symmetrical hard limit</b>	$y = -1$ ถ้า $n < 0$ $y = +1$ ถ้า $n \geq 0$		
<b>Linear</b>	$y = n$		
<b>Positive linear</b>	$y = 0$ ถ้า $n < 0$ $y = n$ ถ้า $n \geq 0$		
<b>Log-sigmoid</b>	$y = \frac{1}{1+e^{-n}}$		
<b>Hyperbolic tangent sigmoid</b>	$y = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		
<b>Radial basis function</b>	$y = e^{-n^2}$		

### 3.3.6 กฎการเรียนรู้ (Learning Rule)

การเรียนรู้ของเครือข่ายประสาทเทียมเปรียบได้กับการเรียนรู้ในระบบประสาทของมนุษย์ การเรียนรู้คือวิถีทางที่สิ่งมีชีวิตจะสามารถได้รับข้อมูลความรู้จากสภาวะแวดล้อม ซึ่งมีผลต่อพฤติกรรมของสิ่งมีชีวิตนั้นๆ การเรียนรู้ทำให้สิ่งมีชีวิตสามารถเก็บและเรียกคืนข้อมูลความรู้ได้ ซึ่งสิ่งนี้รวมแล้วเรียกว่าเป็นความทรงจำ (memory) ในระบบประสาทของมนุษย์ การเรียนรู้เป็นการปรับในส่วนจุดประสานประสาท (synapse) ในลักษณะเดียวกันกับการเรียนรู้ของเครือข่ายประสาทเทียม ที่ซึ่งเป็นกรรมวิธีในการปรับค่าน้ำหนักประสาท (weight) ของเครือข่าย

ในการออกแบบสร้างเครือข่ายประสาทเทียม หลังจากได้ทำการเลือกโครงสร้างของเครือข่าย เช่นจำนวนอินพุต จำนวนเอาต์พุต จำนวนชั้นของเครือข่าย จำนวนนิวรอนในแต่ละชั้น ชนิดของฟังก์ชันการถ่ายโอน ฯลฯ ขั้นตอนต่อไปก็คือการหาพารามิเตอร์ของเครือข่าย อันได้แก่ค่าน้ำหนักประสา (weight) และไบอัส (bias) ขั้นตอนการปรับค่าพารามิเตอร์เหล่านี้เรียกว่ากฎการเรียนรู้ของเครือข่าย (learning rule หรือ training algorithm) จุดประสงค์ของการเรียนรู้ก็เพื่อฝึกสอนให้เครือข่ายทำงานตามที่ต้องการได้ โดยทั่วไปแล้วกฎการเรียนรู้แบ่งเป็นกลุ่มใหญ่ๆ ได้ 2 กลุ่ม คือ การเรียนรู้แบบไม่มีผู้สอน (unsupervised) การเรียนรู้แบบมีผู้สอน (supervised)

### 3.3.6.1 การเรียนรู้แบบไม่มีผู้สอน (unsupervised learning)

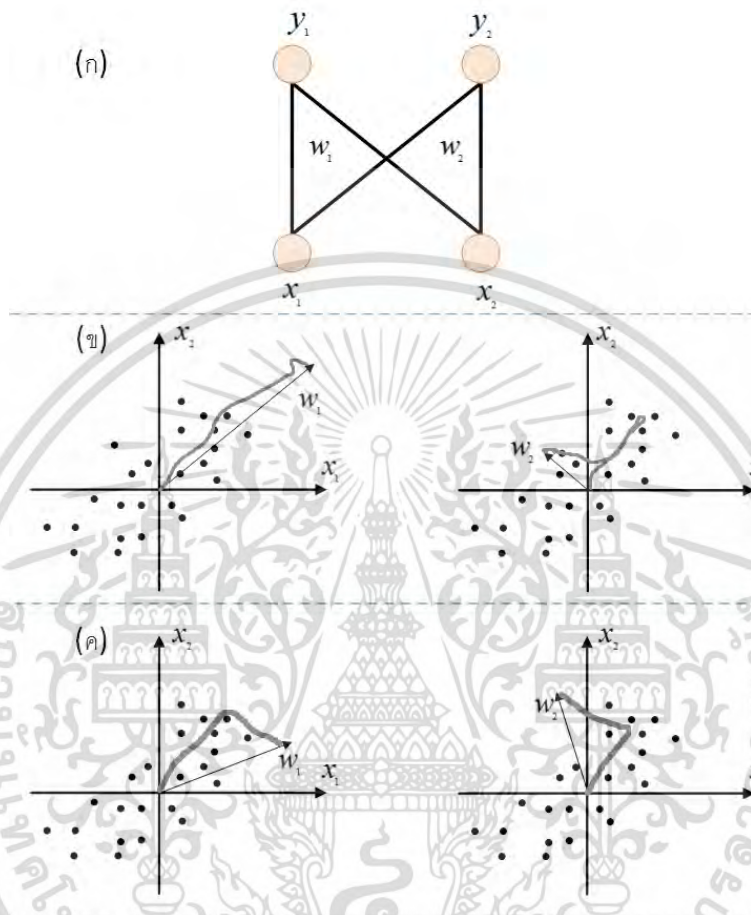
เป็นการเรียนรู้ที่ต้องการเฉพาะข้อมูลอินพุตป้อนเข้าสู่โครงข่าย โดยไม่มีเป้าหมาย (Target) ทางด้านเอาต์พุตและภายในโครงข่ายจะมีจุดร่วมเอาต์พุตอยู่หลายจุดร่วมด้วยกัน โดยแต่ละจุดร่วมจะแทนกลุ่มของข้อมูลที่มีคุณสมบัติเหมือนกัน และเมื่อป้อนอินพุตเข้าสู่โครงข่าย โครงข่ายก็จะทำการคำนวณค่าความสัมพันธ์ที่มีอยู่ภายในเซตของอินพุต โดยอาศัยค่าถ่วงน้ำหนักเป็นตัวแยกความแตกต่างของอินพุตไปเก็บไว้ในจุดร่วมเอาต์พุตของโครงข่าย ซึ่งส่วนใหญ่จะนำมาใช้กับการจำแนกกลุ่ม ข้อดีของการฝึกสอนแบบนี้คือ มีความใกล้เคียงกับโครงข่ายประสาทชีวภาพ แต่ไม่สามารถแก้ปัญหาที่ซับซ้อนมากๆ ได้

- **การสกัดของข้อมูล (Feature Detection)** เช่นการตรวจสอบคุณสมบัติทั่วไปหรือคุณสมบัติที่โดดเด่นที่ช่วยให้โครงข่ายจำแนกรูปแบบของชั้นขาเข้า ซึ่งจากแบบจำลองทางคณิตศาสตร์ของการเรียนรู้แบบไม่มีผู้สอนจะใช้หลักสถิติ เช่นการคำนวณของความสัมพันธ์ ดัชนีประมาณค่าพารามิเตอร์ของฟังก์ชันความหนาแน่นของความน่าจะเป็น จากรูปแบบของการป้อนข้อมูลและการวิเคราะห์องค์ประกอบหลัก เพื่อที่จะทำให้การดำเนินการเหล่านั้นแจ่มแจ้งรูปแบบของชั้นขาเข้าให้มีประสิทธิภาพ ชั้นขาเข้าจะต้องมีความซ้ำซ้อนของข้อมูลเพื่อใช้ในการตรวจสอบของโครงสร้างให้ดีขึ้น การแยกองค์ประกอบหลักเป็น ความสำคัญลำดับแรกของการพิจารณาการกระจายดังสมการ (3.49)

$$\Delta w_{ij} = \eta y_i \left( x_j - \sum_{k=1}^N w_{kj} y_k \right), \quad (3.49)$$

โดยกำหนดให้  $i$  และ  $k$  คือดัชนีที่ชี้ไปยังส่วนเอาต์พุตทั้งสอง ส่วนพจน์  $\sum_{k=1}^N w_{kj} y_k$  นี้จะพิจารณาถึงน้ำหนักทั้งหมดของโครงข่าย ซึ่งจากรูปที่ 3.26 การสกัดคุณลักษณะเด่นขององค์ประกอบหลักของการกระจายรูปแบบของชั้นขาเข้าด้วยสองชั้นขาออก โดยที่ภาพ (ก) แสดงถึงโครงข่ายประสาท ส่วนภาพ (ข) และ (ค) แสดงถึงการปรับเปลี่ยนของน้ำหนักเวกเตอร์ของโครงข่ายประสาทเทียม โดยที่ภาพ (ข) จะแสดงถึงอินพุตที่ได้ผ่านการฝึกสอนด้วยกฎ Oja สำหรับ  $N$  เอาต์พุต ส่วน (ค) แสดงถึงแสดงถึง

การปรับเปลี่ยนของน้ำหนักเวกเตอร์ของอินพุตที่ได้ผ่านการฝึกสอนด้วยกฎ Sanger สำหรับ  $N$  เอาท์พุต



รูปที่ 3.26 (ก) โครงข่ายประสาทเทียม

(ข) โครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบ Oja

(ค) โครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบ Sanger

- การสกัดของข้อมูลแบบหลายชั้น (**multilateral Feature Detection**) สถาปัตยกรรมประยุกต์ของรูปแบบหลายชั้นโดย Linsker แต่ละชั้นจะถูกจัดเป็นเมตริกซ์ 2D ของเซลล์ประสาทเทียมที่มีการเชื่อมต่อกับความน่าจะเป็นของ Neurons ชั้นก่อนหน้านี้จะอธิบายโดยการกระจายของแบบ Gaussian 2D สมการ (3.50)

$$y_i = k_i \sum_j w_{ij} x_j, \quad (3.50)$$

และใช้สมการของกระบวนการเรียนรู้ดังสมการ (3.51)

$$\Delta w_{ij} = k_2 y_i x_j + k_3 x_j + k_4 y_j + k_5, \quad (3.51)$$


โดยกำหนดให้  $k_{1-5}$  คือค่าคงที่และ  $k_2 > 0$  น้ำหนักจะถูกตัดไปให้อยู่ในช่วง  $[w_{ij}^+, w_{ij}^-]$  เพื่อหลีกเลี่ยงการปรับน้ำหนักแบบไม่มีที่สิ้นสุด

### 3.3.6.2 การเรียนรู้แบบมีผู้สอน (supervised)

การเรียนรู้โดยวิธีนี้จะกำหนดเซตของการสอนให้กับโครงข่าย ซึ่งภายในเซตประกอบด้วย ข้อมูลอินพุตและเอาต์พุตที่ต้องการ  $\{p_1, t_1\} \{p_2, t_2\} \dots \{p_Q, t_Q\}$  เรียกว่า คู่ของการฝึกสอน (Training pairs) โดยที่  $p_i$  เป็นอินพุตตัวที่  $i$  และ  $t_i$  เป็นคู่เป้าหมายของอินพุต  $i$  นั้นๆ เมื่อทำการป้อนอินพุตให้กับโครงข่าย โครงข่ายก็จะทำการประมวลผลจนได้คำตอบ ซึ่งคำตอบที่ได้จากโครงข่ายนี้จะถูกนำมาคำนวณค่าความผิดพลาด (Error) คือ ค่าความแตกต่างระหว่างคำตอบที่ได้จากโครงข่ายกับคำตอบเป้าหมายของอินพุตชุดเดียวกัน ว่ามีค่ามากน้อยเท่าไร ถ้ายังมีค่าความผิดพลาดสูงกว่าที่กำหนด ก็จะทำให้การฝึกสอนรอบใหม่ให้กับโครงข่าย เพื่อทำการปรับค่าถ่วงน้ำหนัก และทำการฝึกสอนต่อไปจนกระทั่งค่าความผิดพลาดระหว่างคำตอบที่ได้จากโครงข่ายกับคำตอบเป้าหมายของอินพุตชุดเดียวกันก็มีค่าน้อยพอที่จะยอมรับได้ จึงหยุดทำการฝึกสอนโครงข่ายดังรูปที่ 3.27 อธิบายได้ดังสมการ 3.52 กำหนดให้  $b_{ko}$  และ  $z_{ko}$  เป็นค่ากำหนดและค่าที่ได้จริงของเซลล์ประสาทเทียมในชั้นขาออกตามลำดับ สำหรับการตรวจสอบค่าที่สอนนั้นจะตรวจสอบค่าตามสมการ 3.52 โดยกำหนดให้  $k$  คือลำดับของกิจกรรมในชั้นขาออก  $b_{ko}=1$  ที่ค่า  $k=0$  และนอกเหนือจากนี้ให้  $b_{ko}=0$  ค่าผิดพลาดของชั้นตอนป้อนไปข้างหน้า (Feed Forward) ของรูปแบบที่  $k^{th}$  ได้ตามสมการ (3.52)

$$E_k = 0.5 \sum_{o=1}^q (b_{ko} - z_{ko})^2, \quad (3.52)$$

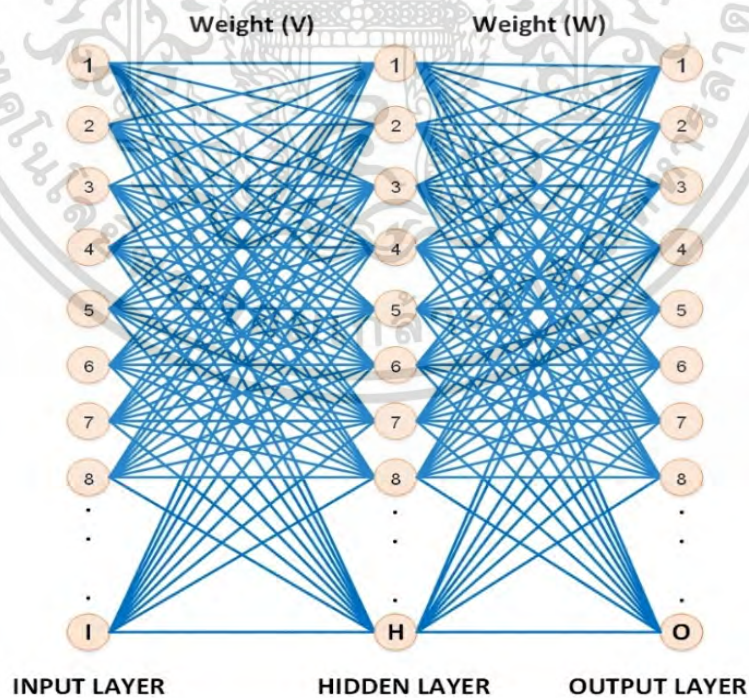
กำหนดให้  $k$  เป็นค่าที่อยู่ในช่วง  $\{1, 2, \dots, q\}$  ในขั้นตอนการเรียนรู้ ลำดับแรกน้ำหนักทุกตัวจะถูกสุ่มเพื่อกำหนดค่าเริ่มต้น  $z_{ko}$  จะถูกคำนวณจากขั้นตอนของกระบวนการป้อนไปข้างหน้า (Feed Forward) และค่าผิดพลาดของแต่ละรูปแบบก็จะคำนวณจากสมการที่ 3.52 ลำดับต่อมา ทุกตัวของน้ำหนักจะถูกปรับจนกว่าค่าของค่าผิดพลาดจะเข้าสู่ศูนย์หรือเข้าค่าที่กำหนดโดยใช้กระบวนการแพร่ย้อนกลับ (BackPropagate)



รูปที่ 3.27 ขั้นตอนการเรียนรู้แบบมีผู้สอน

### 3.3.7 Back Propagation Neural Network, BPNN

พื้นฐานโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back Propagation Neural Network, BPNN) เป็นระบบคณิตศาสตร์ที่ใช้ต้นแบบจากโครงข่ายประสาทของสิ่งมีชีวิตโดยมีการเชื่อมกันระหว่างเซลล์ประสาทเทียม (Neuron) โครงสร้างของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในวิทยานิพนธ์เล่มนี้ประกอบด้วยสามชั้นดังนี้ ชั้นขาเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นขาออก (Output Layer) ดังแสดงในรูปที่ 3.28 และทุกชั้นจะประกอบด้วยเซลล์ประสาทเทียมหลายตัว โดยกำหนดให้  $I$ ,  $H$  และ  $O$  เป็นจำนวนเซลล์ของชั้นขาเข้า ชั้นซ่อน และชั้นขาออก ตามลำดับ



รูปที่ 3.28 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN)

ในที่นี้  $I$  เป็นจำนวนข้อมูลของสัญญาณการเคลื่อนไหว และ  $O$  เป็นจำนวนรูปแบบของสัญญาณที่ต้องรู้จำ ประสิทธิภาพของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับนี้จะขึ้นอยู่กับ การเลือกจำนวนเซลล์ประสาทเทียมของชั้นซ่อน ( $H$ ) ถ้า  $I$  มีจำนวนน้อยจะทำให้เกิดปัญหาที่เรียกว่า Under Fitting ซึ่งเป็นปัญหาที่เกิดขึ้นเมื่อจำนวนเซลล์ในชั้นซ่อนมีค่าน้อยและไม่พอเพียงที่จะตรวจจรูปแบบสัญญาณที่มีความซับซ้อนของสัญญาณขาเข้าได้ ในทางตรงข้ามหากจำนวน  $H$  มีค่ามากก็อาจนำไปสู่ปัญหาใหญ่สองประการคือ โครงข่ายประสาทเทียมจะใช้เวลาในการเรียนรู้รูปแบบของสัญญาณนานมาก ประการต่อมาจะเกิดปัญหาที่เรียกว่า Over Fitting ซึ่งปัญหานี้จะเกิดขึ้นเมื่อโครงข่ายประสาทเทียมใช้หน่วยความจำมากเพื่อการประมวลผลสัญญาณ แต่ไม่มีสัญญาณเพียงพอที่จะสอนเซลล์ทุกตัวในชั้นซ่อนได้

ในแต่ละเซลล์ประสาทเทียมของแต่ละชั้น ในโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) จะถูกเชื่อมซึ่งกันและกัน แต่ละเส้นเชื่อมมีน้ำหนักเป็นตัวกำหนดขนาด โดยน้ำหนักในแต่ละเส้นเชื่อมจะถูกเก็บในหน่วยความจำของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) มี 2 ขั้นตอนการทำงานหลักๆ ดังนี้ การป้อนไปข้างหน้า (Feed Forward) แพร่ย้อนกลับ (BackPropagate)

ในขั้นตอนของการป้อนไปข้างหน้า (Feed Forward) คุณลักษณะของ  $n$  จะถูกป้อนเข้าไปในชั้นของชั้นขาเข้า จากนั้นผลลัพธ์ของชั้นซ่อนและชั้นของขาออกสามารถคำนวณได้ดังสมการ (3.53)

และ (3.54)

$$y_h = f_{sig} \left( \sum_{i=1}^n x_i v_{ih} \right), \quad (3.53)$$

$$z_o = f_{sig} \left( \sum_{h=1}^p y_h w_{ho} \right) \quad (3.54)$$

ตามลำดับ กำหนดให้  $f_{sig}(x) = (1 + e^{-x})^{-1}$  โดย  $x_i$  คือค่าของสัญญาณในชั้นขาเข้าในลำดับที่  $i^{th}$  ส่วน  $v_{ih}$  คือน้ำหนักของเส้นเชื่อมต่อระหว่างชั้นเซลล์ของชั้นขาเข้าลำดับที่  $i^{th}$  และ ชั้นเซลล์ของชั้นซ่อนลำดับที่  $h^{th}$  ส่วน  $y_h$  คือค่าของเซลล์ในชั้นซ่อนลำดับที่  $h^{th}$  และส่วน  $w_{ho}$  คือน้ำหนักของเส้นเชื่อมต่อระหว่างชั้นเซลล์ของชั้นซ่อนลำดับที่  $h^{th}$  และชั้นเซลล์ของชั้นขาออก ลำดับที่  $o^{th}$  และสุดท้าย  $z_o$  คือค่าเซลล์ของชั้นขาออก

น้ำหนักของเส้นเชื่อมต่อทุกเส้นสามารถปรับโดยอาศัยการแพร่ย้อนกลับจากชั้นขาออกไปยังชั้นขาเข้าเพื่อให้ได้ค่าผิดพลาด (Error) ที่กำหนดไว้ดังสมการ (3.55), (3.56), (3.57) และ (3.58)

$$w_{ho}^{new} = w_{ho}^{old} + \eta \sum \delta_o y_h, \quad (3.55)$$

$$\delta_o = z_o(1 - z_o)(b_o - z_o), \quad (3.56)$$

$$v_{ih}^{new} = v_{ho}^{old} + \eta \sum \delta_h x_i, \quad (3.57)$$

$$\delta_h = y_h(1 - y_h) \sum_{h=1}^q w_{oh} \delta_o \quad (3.58)$$


โดยกำหนดให้  $w_{ho}^{new}$  และ  $v_{ih}^{new}$  คือค่าน้ำหนักใหม่ที่ถูกรับปรับในแต่ละรอบของการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับในชั้นซ่อนและชั้นของขาออกตามลำดับ และ  $w_{ho}^{old}$  และ  $v_{ih}^{old}$  คือค่าน้ำหนักในแต่ละรอบก่อนหน้านั้นในชั้นซ่อนและชั้นของขาออกตามลำดับ  $\delta_o$  และ  $\delta_h$  เป็นค่า Gradient ในชั้นซ่อนและชั้นของขาออกตามลำดับและ  $\eta$  เป็นค่าอัตราการเรียนรู้ซึ่งปกติแล้วมีค่าอยู่ระหว่าง 0 ถึง 1



## บทที่ 5

### การทดลองและผลการทดลอง

การทดลองสำหรับวิทยานิพนธ์ฉบับนี้แบ่งออกเป็น 2 การทดลอง ได้แก่ การรู้จำกิจกรรมในชีวิตประจำวันและเหตุการณ์การหกล้มของมนุษย์ (Human Physical Activity recognition) และการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวัน (Human Falling Detection) โดยจะดำเนินการตามขั้นตอนต่อไปนี้ การทดลองเริ่มจากการเก็บสัญญาณจากอาสาสมัคร 5 คน ต่อมาทำการดึงคุณลักษณะของสัญญาณโดยใช้การแปลงเวฟเลต และทำการลดมิติของคุณลักษณะเวฟเลตโดยใช้วิธีที่นำเสนอ สุดท้ายใช้โครงข่ายประสาทเทียมแบบหลายชั้นในการรู้จำกิจกรรม ดังแสดงในรูปที่ 5.1 เพื่อที่จะประเมินประสิทธิภาพของอัลกอริทึมที่นำเสนอ ความแม่นยำของการรู้จำและจำนวนตัวดำเนินการที่ใช้ทั้งหมดถูกนำมาใช้ในประเมินประสิทธิภาพของการรู้จำสำหรับเปรียบเทียบการใช้พารามิเตอร์ที่แตกต่างกันของ mother wavelets, vanishing moments, อัตราการลดมิติ และจำนวนโหนดในชั้นซ่อนของโครงข่ายประสาทเทียม ดังจะอธิบายต่อไปนี้



รูปที่ 5.1 ขั้นตอนการทดลองสำหรับวิทยานิพนธ์ฉบับนี้


#### 5.1 การประเมินประสิทธิภาพ

ประสิทธิภาพของอัลกอริทึมที่นำเสนอขึ้นอยู่กับ 4 พารามิเตอร์ ได้แก่ 1) vanishing moments of the mother wavelet (จำนวนความยาวฟิลเตอร์) 2) ระดับการแยกองค์ประกอบเวฟเลต 3) อัตราการลดมิติ และ 4) จำนวนของโหนดในชั้นซ่อนดังแสดงในตารางที่ 5.1

ตารางที่ 5.1 แสดงพารามิเตอร์ที่ใช้ในการทดลอง

	พารามิเตอร์
<b>Wavelets and Vanishing Moments</b>	'db2', 'db4', 'db6', ..., 'db20', 'coif1', ..., 'coif5', 'sym2', 'sym3', ..., 'sym9', 'bior1.1', 'bior1.3', 'bior1.5', 'bior2.2', 'bior2.4', 'bior2.6', 'bior2.8', 'bior3.1', 'bior3.3', 'bior3.5', 'bior3.7', 'bior3.9', 'bior4.4', 'bior5.5', และ 'bior6.8'
ระดับการแยกองค์ประกอบเวฟเลต	ระดับที่ 1 และ ระดับที่ 2
อัตราการลดมิติ	4, 8, และ 16
จำนวนของโหนดในชั้นซ่อน	1, 2, 3, ..., และ 40

ระบบของอัลกอริทึมที่ดีในอุดมคติจะต้องมีค่าความแม่นยำสูงและต้องใช้ตัวดำเนินการในการคำนวณน้อย จากรูปที่ 5.2 effectiveness หมายถึงความแม่นยำ และ efficiency หมายถึงเวลาที่ใช้ในการคำนวณ ทำให้สามารถแบ่งกราฟแสดงถึงประสิทธิภาพการทำงานได้เป็น 4 ช่วง โดยช่วงที่เหมาะสมต่อการใช้งานมากที่สุดควรเป็นช่วง High effectiveness และ High efficiency ซึ่งหมายความว่าอัลกอริทึมจะมีความแม่นยำสูงและใช้เวลาในการคำนวณที่รวดเร็ว



รูปที่ 5.2 กราฟแสดงการประเมินประสิทธิภาพของระบบที่นำเสนอ

แต่อย่างไรก็ตามโดยทั่วไปในการใช้งานจริง ถ้าต้องการให้อัลกอริทึมมีความแม่นยำสูงจะต้องแลกกับการที่ต้องใช้ตัวดำเนินการเพิ่มมากขึ้น ดังนั้นเพื่อหาจุดสมดุลระหว่างความแม่นยำกับตัวดำเนินการในวิทยานิพนธ์ฉบับนี้จึงเสนอตัวชี้วัดใหม่ Performance Evaluation (Pe) เพื่อใช้ประเมินประสิทธิภาพ

ของอัลกอริทึมที่นำเสนอ โดยใช้เปอร์เซ็นต์ของความแม่นยำเฉลี่ย ( $\% \overline{\text{Pr}}$ ) [42] และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้ ( $\% \text{Op}$ ) สำหรับชีวิตความแม่นยำและเวลาที่ใช้ในการคำนวณตามลำดับ  $\% \overline{\text{Pr}}$  สามารถคำนวณได้ดังสมการที่ 5.1

$$\% \overline{\text{Pr}} = \frac{\sum_{i=c}^C \frac{\#TP_c}{\#TP_c + \#FP_c}}{C} \times 100 \quad (5.1)$$

โดยที่  $C$  คือจำนวนของกิจกรรมทางกายภาพทั้งหมด,  $\#TP_c$  (True Positives) คือ จำนวนของสัญญาณการเคลื่อนไหวของกิจกรรมคลาสที่  $c$  ที่จำได้ถูกต้อง,  $\#FP_c$  (False Positives) คือ จำนวนของสัญญาณการเคลื่อนไหวของกิจกรรมคลาสที่  $c$  ที่จำผิดไปเป็นคลาสอื่น

ตัวชี้วัดเวลาในการคำนวณ คือจำนวนตัวดำเนินการที่ใช้ในขั้นตอนการทดลองประกอบด้วยจำนวนตัวดำเนินการการบวกและการคูณทั้งหมดที่ใช้ในขั้นตอนการดึงคุณลักษณะโดยใช้การแปลงเวฟเวต การลดมิติโดยใช้วิธีที่นำเสนอ และการรู้จำกิจกรรมโดยใช้โครงข่ายประสาทเทียม โดยกำหนดให้  $l_s$  แทนจำนวนสัญญาณอินพุต (1248),  $l_f$  แทนจำนวนของความยาวฟิลเตอร์ของเวฟเลต,  $l_{d1}$  แทนการแยกองค์ประกอบเวฟเลตระดับที่ 1 เท่ากับ 1,  $l_{d2}$  แทนการแยกองค์ประกอบเวฟเลตระดับที่ 2 เท่ากับ 0 ถ้าไม่มีการแปลงเวฟเลตระดับที่ 2 หรือเท่ากับ 0.5 ถ้ามีการแปลงเวฟเลตระดับที่ 2,  $h$  แทนจำนวนของโหนดในชั้นซ่อน และ  $t$  เป็นจำนวนของโหนดในชั้นเอาต์พุต ดังนั้นจำนวนตัวดำเนินการที่ใช้ในการแปลงเวฟเลตเท่ากับ  $4 \times l_s \times l_f \times (l_{d1} + l_{d2})$ , จำนวนตัวดำเนินการที่ใช้ในวิธีการลดมิติที่นำเสนอเท่ากับ  $3 \times l_s$  และจำนวนตัวดำเนินการที่ใช้ในโครงข่ายประสาทเทียมแบบหลายชั้นเท่ากับ  $2(l_s/2r \times h + h \times t)$  และกำหนดให้  $\#Op_{\max}$  แทนจำนวนของตัวดำเนินการที่ใช้ทั้งหมดที่มากที่สุด  $\% \text{Op}$  เปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้สามารถคำนวณได้ดังสมการที่ 5.2

$$\% \text{Op} = \frac{(4 \times l_s \times l_f \times (l_{d1} + l_{d2})) + 3 \times l_s + 2(l_s/2r \times h + h \times t)}{\#Op_{\max}} \times 100 \quad (5.2)$$

จากรูปที่ 5.2  $Pe$  คือระยะทางจากจุดที่เปอร์เซ็นต์ของความแม่นยำเฉลี่ย ( $\% \overline{\text{Pr}}$ ) เท่ากับ 100 และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้ ( $\% \text{Op}$ ) เท่ากับ 0 ไปยังจุดของเปอร์เซ็นต์ของความแม่นยำเฉลี่ย ( $\% \overline{\text{Pr}}$ ) และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้ ( $\% \text{Op}$ ) เท่ากับ ค่าจากผลการทดลอง ดังนั้นอัลกอริทึมจะมีประสิทธิภาพสูงที่สุดก็ต่อเมื่อ  $Pe$  มีค่าต่ำที่สุด  $Pe$  สามารถคำนวณได้ดังสมการที่ 5.3

$$Pe = \sqrt{(100 - \%Pr)^2 + (\%Op)^2} \quad (5.3)$$

## 5.2 การวัดและจัดเก็บข้อมูลสัญญาณการเคลื่อนไหว

สำหรับการทดลอง เราเก็บข้อมูลจากอาสาสมัครสุขภาพดี 5 คน ผู้ชายจำนวน 4 คน และผู้หญิงจำนวน 1 คน มีอายุระหว่าง 21 ถึง 25 ปี โดยติดเครื่องจัดเก็บสัญญาณไว้ที่เอวด้านขวาดังแสดงในรูปที่ 4.2 และอาสาสมัครจะทำกิจกรรมดังที่กำหนดไว้ ซึ่งประกอบด้วยกิจกรรมทางกายภาพในชีวิตประจำวัน 5 กิจกรรมได้แก่ 1.) ลุกขึ้นจากที่นอน 2.) ล้มตัวลงนอนบนที่นอน 3.) ลุกขึ้นจากเก้าอี้ 4.) นั่งลงบนเก้าอี้ 5.) การเดิน และเหตุการณ์การหกล้ม 5 เหตุการณ์ ได้แก่ 1.) หกล้มไปด้านหน้า 2.) หกล้มไปด้านหลัง 3.) หกล้มไปด้านซ้าย 4.) หกล้มไปด้านขวา และ 5.) หกล้มในขณะที่กำลังลุกขึ้นยืน โดยที่อาสาสมัครแต่ละคนจะทำกิจกรรมแต่ละกิจกรรมเป็นจำนวน 30 ครั้ง ซึ่งจำนวนของสัญญาณการเคลื่อนไหวของแต่ละกิจกรรมจะมี 150 สัญญาณ ดังนั้นจำนวนสัญญาณการเคลื่อนไหวจากกิจกรรมทั้งหมดจะมี 1500 สัญญาณดังแสดงในตารางที่ 5.2

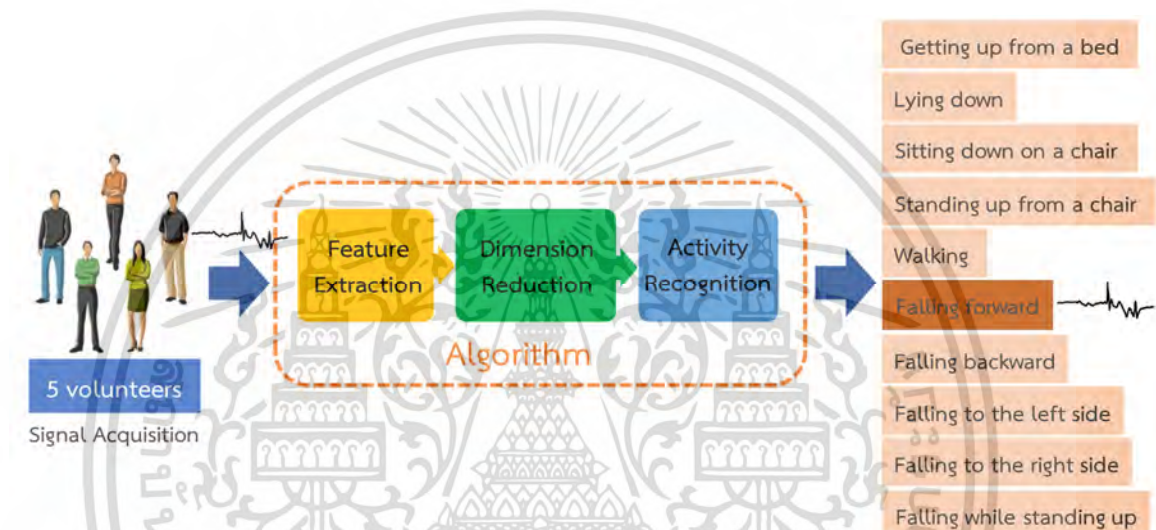
ตารางที่ 5.2 แสดงจำนวนสัญญาณการเคลื่อนไหวของแต่ละกิจกรรมจากอาสาสมัครทั้งหมด 5 คน

จำนวนการทำกิจกรรม ประเภทกิจกรรม	คนที่ 1	คนที่ 2	คนที่ 3	คนที่ 4	คนที่ 5
หกล้มไปด้านหน้า	30	30	30	30	30
หกล้มไปด้านหลัง	30	30	30	30	30
หกล้มไปด้านซ้าย	30	30	30	30	30
หกล้มไปด้านขวา	30	30	30	30	30
หกล้มในขณะที่กำลังลุกขึ้นยืน	30	30	30	30	30
ลุกขึ้นจากที่นอน	30	30	30	30	30
ล้มตัวลงนอนบนที่นอน	30	30	30	30	30
ลุกขึ้นจากเก้าอี้	30	30	30	30	30
นั่งลงบนเก้าอี้	30	30	30	30	30
การเดิน	30	30	30	30	30

### 5.3 การทดลองและผลการทดลอง


#### 5.3.1 การทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ (Human Physical Activity Recognition)

การทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์จะจดจำกิจกรรมทั้งหมด 10 กิจกรรม ได้แก่ 1.) หกล้มไปด้านหน้า 2.) หกล้มไปด้านหลัง 3.) หกล้มไปด้านซ้าย 4.) หกล้มไปด้านขวา และ 5.) หกล้มในขณะที่กำลังลุกขึ้นยืน 6.) ลุกขึ้นจากที่นอน 7.) ล้มตัวลงนอนบนที่นอน 8.) ลุกขึ้นจากเก้าอี้ 9.) นั่งลงบนเก้าอี้ 10.) การเดิน ดังแสดงในรูปที่ 5.3




รูปที่ 5.3 การรู้จำกิจกรรมในชีวิตประจำวันและเหตุการณ์การหกล้มของมนุษย์

จากขั้นตอนการทดลอง สัญญาณการเคลื่อนไหวสามแกนมีความยาวสัญญาณเท่ากับ 1248 จุด จากนั้นทำการดึงคุณลักษณะของสัญญาณด้วยการแปลงเวฟเลตที่ระดับ 1 และ 2 จะได้สัญญาณคุณลักษณะเวฟเลต 1248 สัมประสิทธิ์เท่ากันหมด ดังแสดงในรูปที่ 5.4 และ 5.5 ตามลำดับ



รูปที่ 5.4 ตัวอย่างสัญญาณคุณลักษณะเวฟเลตของสัญญาณการหกล้มไปด้านหน้า 1248 สัมประสิทธิ์ของการแปลงเวฟเลตระดับที่ 1 จากเซ็นเซอร์วัดความเร่ง 3 แกน



รูปที่ 5.5 ตัวอย่างสัญญาณคุณลักษณะเวฟเลตของสัญญาณการหกล้มไปด้านหน้า 1248 สัมประสิทธิ์ของการแปลงเวฟเลตระดับที่ 2 จากเซ็นเซอร์วัดความเร่ง 3 แกน

ต่อมาเลือกสัญญาณคุณลักษณะเวฟเลตของสัญญาณการเคลื่อนไหวแบบสุ่มจำนวน 75 สัญญาณจากแต่ละกิจกรรม เพื่อใช้คำนวณหา  $w$  ของการลดมิติที่นำเสนอ และใช้เป็นข้อมูลในการฝึกสอนโครงข่ายประสาทเทียม และใช้สัญญาณคุณลักษณะเวฟเลตของสัญญาณการเคลื่อนไหวจำนวน 75 สัญญาณจากแต่ละกิจกรรมที่เหลือ สำหรับทดสอบประสิทธิภาพของอัลกอริทึมที่นำเสนอ ดังแสดงในตารางที่ 5.3

ตารางที่ 5.3 แสดงรายละเอียดการใช้สัญญาณการเคลื่อนไหวของการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์

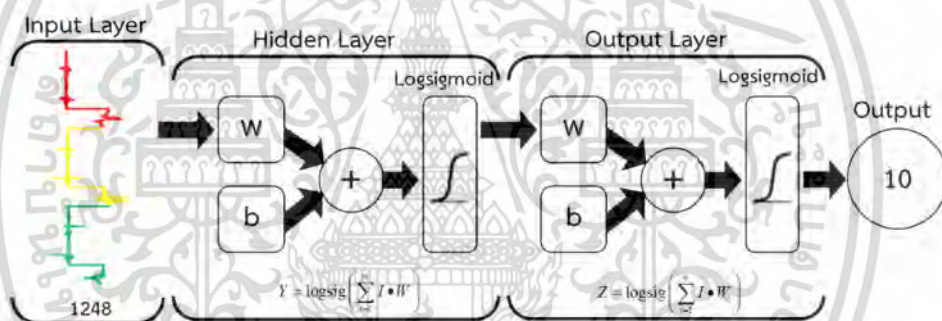
ประเภทกิจกรรม	จำนวนสัญญาณทั้งหมด	จำนวนสัญญาณฝึกสอน	จำนวนสัญญาณทดสอบ
หกล้มไปด้านหน้า	150	75	75
หกล้มไปด้านหลัง	150	75	75
หกล้มไปด้านซ้าย	150	75	75
หกล้มไปด้านขวา	150	75	75
หกล้มในขณะที่กำลังลุกขึ้นยืน	150	75	75
ลุกขึ้นจากที่นอน	150	75	75
ล้มตัวลงนอนบนที่นอน	150	75	75
ลุกขึ้นจากเก้าอี้	150	75	75
นั่งลงบนเก้าอี้	150	75	75
การเดิน	150	75	75

สำหรับโครงสร้างของโครงข่ายประสาทเทียม สัญญาณคุณลักษณะเวฟเลตของสัญญาณการเคลื่อนไหวที่ถูกลดมิติจะเป็นตัวกำหนดจำนวนโหนดชั้นอินพุทของโครงข่ายประสาทเทียมซึ่งเท่ากับจำนวนสัมประสิทธิ์ของคุณลักษณะเวฟเลตที่ถูกลดมิติแล้ว ดังแสดงในตารางที่ 5.4


ตารางที่ 5.4 แสดงความสัมพันธ์ระหว่างอัตราการลดมิติ จำนวนสัมประสิทธิ์ของคุณลักษณะเวฟเลต และจำนวนโหนดชั้นอินพุทของโครงข่ายประสาทเทียม

อัตราการลดมิติ	จำนวนสัมประสิทธิ์ของคุณลักษณะเวฟเลตที่ถูกลดมิติ	จำนวนโหนดชั้นอินพุทของโครงข่ายประสาทเทียม
n/a	1248	1248
4	312	312
8	156	156
16	78	78

และจำนวนโหนดในชั้นเอาต์พุทของโครงข่ายประสาทเทียมจะเท่ากับจำนวนกิจกรรมที่ทำการรู้จำซึ่งในการทดลองนี้เท่ากับ 10 นอกจากนี้การทดลองของเราได้เปรียบเทียบการใช้ฟังก์ชัน activation ที่ต่างกันในชั้นเอาต์พุทดังแสดงในรูปที่ 5.6 และ 5.7




รูปที่ 5.6 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองรู้จำกิจกรรมทางกายภาพของมนุษย์ โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติและใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท



รูปที่ 5.7 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองรู้จำกิจกรรมทางกายภาพของมนุษย์ โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติและใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

### 5.3.1.1 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต



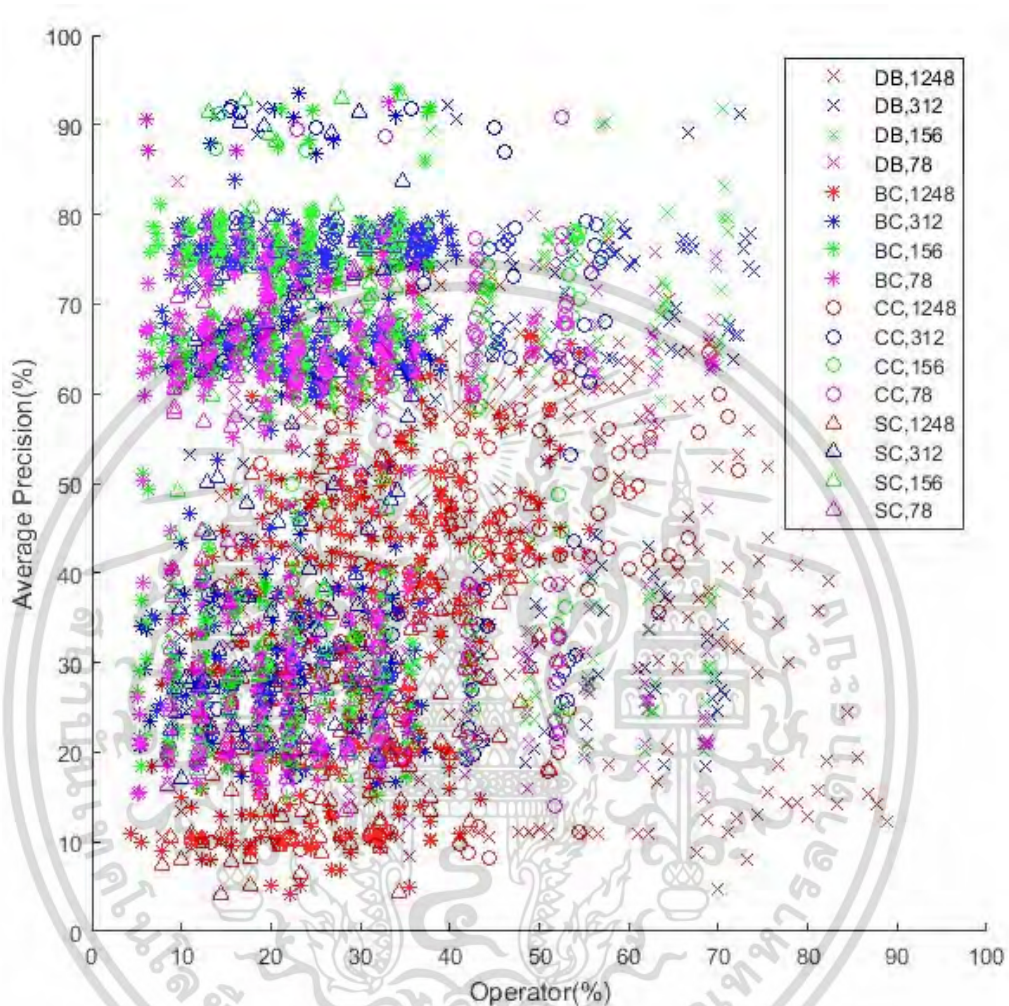
รูปที่ 5.8 กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต

ตารางที่ 5.5 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท

Mother Wavelet	อัตราการลดมิติ	ความยาวฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Daubechies	n/a	4	1248-26-10	78.517	18.971	28.661
	4	8	312-28-10	91.711	14.543	16.74
	8	4	156-38-10	91.125	8.903	12.571
	16	8	78-38-10	87.777	12.023	17.145
Coiflet	n/a	12	1248-22-10	79.339	25.608	32.903
	4	6	312-34-10	90.053	13.183	16.515
	8	6	156-30-10	92.479	10.531	12.941
	16	6	78-36-10	78.161	9.726	23.907
Symlet	n/a	4	1248-30-10	81.718	21.207	28
	4	4	312-30-10	91.149	10.393	13.651
	8	4	156-34-10	92.631	8.608	11.331
	16	4	78-40-10	92.309	7.664	10.858
Biorthogonal	n/a	6	1248-32-10	88.835	24.543	26.963
	4	2	312-30-10	93.369	8.175	10.526
	8	2	156-36-10	91.492	6.538	10.73
	16	2	78-40-10	91.791	5.446	<b>9.851</b>
<b>Biorthogonal</b>	16	18	78-30-10	<b>95.124</b>	22.801	23.317

Note that: n/a = do not use the proposed dimension reduction.

### 5.3.1.2 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต




รูปที่ 5.9 กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต

ตารางที่ 5.6 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท

Mother Wavelet	อัตราการลดมิติ	ความยาวฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Daubechies	n/a	4	1248-26-10	74.111	21.189	33.455
	4	4	312-38-10	91.031	13.756	16.421
	8	4	156-32-10	79.222	10.679	23.362
	16	4	78-34-10	83.651	9.648	18.984
Coiflet	n/a	6	1248-22-10	61.009	22.280	44.908
	4	6	312-26-10	91.622	15.366	17.502
	8	6	156-36-10	91.252	14.301	16.765
	16	12	78-32-10	89.422	22.879	25.206
Symlet	n/a	6	1248-40-10	62.025	32.343	49.882
	4	6	312-34-10	90.207	16.511	19.197
	8	6	156-20-10	91.425	13.121	15.674
	16	6	78-30-10	77.814	12.819	25.623
Biorthogonal	n/a	2	1248-36-10	72.147	23.452	36.411
	4	4	312-34-10	87.986	13.183	17.836
	8	2	156-36-10	81.194	7.647	20.301
	16	2	78-26-10	90.544	6.008	<b>11.203</b>
<b>Biorthogonal</b>	16	18	78-34-10	<b>93.974</b>	34.118	34.646

**5.3.1.3 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน**  
 โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน **linear** ในชั้นเอาต์พุท




**รูปที่ 5.10** กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

ตารางที่ 5.7 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

Mother Wavelet	อัตราการลดมิติ	ความยาวฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Daubechies	n/a	4	1248-16-10	84.751	13.381	20.288
	4	4	312-20-10	91.603	8.962	12.281
	8	4	156-24-10	93.539	7.871	10.183
	16	4	78-26-10	92.146	7.117	10.599
Coiflet	n/a	6	1248-14-10	85.614	14.481	20.412
	4	6	312-14-10	90.704	10.322	13.891
	8	6	156-6-10	91.779	8.761	12.014
	16	6	78-20-10	91.835	9.101	12.227
Symlet	n/a	4	1248-12-10	83.131	11.145	20.218
	4	4	312-14-10	92.500	8.103	11.042
	8	4	156-10-10	91.533	6.838	10.883
	16	4	78-38-10	93.219	7.586	10.175
Biorthogonal	n/a	2	1248-16-10	87.120	11.162	17.044
	4	2	312-8-10	90.680	5.027	10.589
	8	2	156-22-10	92.511	5.505	9.295
	16	2	78-40-10	93.086	5.446	<b>8.801</b>
<b>Biorthogonal</b>	16	18	78-32-10	<b>94.777</b>	22.879	23.468

**5.3.1.4 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน**  
 โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน **linear** ในชั้นเอาต์พุต



**รูปที่ 5.11** กราฟแสดงการเปรียบเทียบผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุต

ตารางที่ 5.8 ผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

Mother Wavelet	อัตราการลดมิติ	ความยาวฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Daubechies	n/a	4	1248-12-10	85.879	13.363	19.441
	4	4	312-10-10	90.374	9.749	13.701
	8	4	156-18-10	91.802	9.646	12.659
	16	4	78-14-10	90.764	8.866	12.803
Coiflet	n/a	6	1248-14-10	85.932	17.808	22.695
	4	6	312-18-10	91.592	14.221	16.521
	8	6	156-14-10	91.406	12.679	15.317
	16	6	78-26-10	92.417	12.663	14.760
Symlet	n/a	4	1248-10-10	82.593	12.245	21.282
	4	4	312-12-10	91.737	10.036	13.000
	8	4	156-28-10	91.814	10.384	13.222
	16	4	78-40-10	92.179	9.883	12.603
Biorthogonal	n/a	2	1248-20-10	87.426	14.508	19.198
	4	2	312-8-10	92.559	6.136	10.795
	8	2	156-12-10	92.653	5.876	9.408
	16	2	78-40-10	93.487	6.555	<b>9.240</b>
Coiflet	16	30	78-22-10	<b>95.030</b>	52.435	52.670

**5.3.1.5** สรุปผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว **3** แกน โดยใช้การแปลงเวฟเลต วิธีการลดมิติที่นำเสนอและโครงข่ายประสาทเทียม

ตารางที่ **5.9** สรุปผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ที่มีประสิทธิภาพดีที่สุด

Activation Function in Output Layer	Decomposition Level	Mother Wavelet	อัตรา การลดมิติ	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Log-sigmoid	1	BC1.1	16	40	91.791	5.446	9.851
Log-sigmoid	2	BC1.1	16	26	90.544	6.008	11.203
Linear	1	BC1.1	16	40	93.086	5.446	<b>8.801</b>
Linear	2	BC1.1	16	40	93.487	6.555	9.240

ตารางที่ **5.10** สรุปผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ที่มีความแม่นยำสูงที่สุด

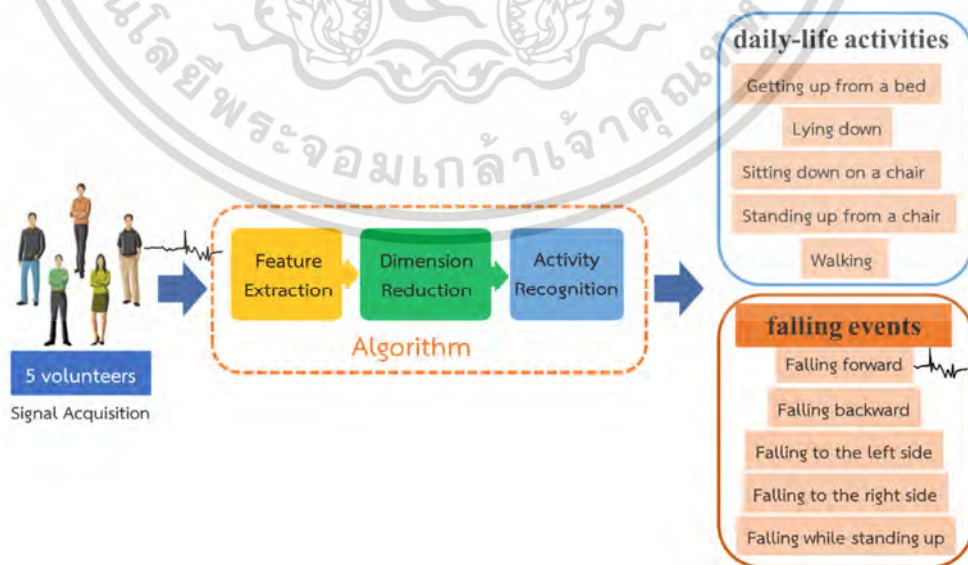
Activation Function in Output Layer	Decomposition Level	Mother Wavelet	อัตรา การลดมิติ	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Log-sigmoid	1	BC2.8	16	30	<b>95.124</b>	22.801	23.317
Log-sigmoid	2	BC2.8	16	34	93.974	34.118	34.646
Linear	1	BC2.8	16	32	94.777	22.879	23.468
Linear	2	CC5	16	22	95.030	52.435	52.670

จากผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ในตารางที่ 5.9 สรุปได้ว่าการรวมกันของพารามิเตอร์นี้ให้ค่า  $P_e$  มีค่าต่ำที่สุดเท่ากับ 8.801 คือ การใช้สัญญาณการเคลื่อนไหว 3 แกน ที่ดึงคุณลักษณะโดยใช้การแปลงเวฟเลตระดับ 1 ด้วย Biorthogonal1.1 และลดมิติโดยวิธีที่นำเสนอด้วยอัตราการลดมิติเท่ากับ 16 และจดจำกิจกรรมโดยใช้โครงข่ายประสาทเทียมที่ชั้นเอาต์พุตเป็นฟังก์ชัน linear และมีจำนวนโหนดในชั้นซ่อนเท่ากับ 40 จะให้ค่าเปอร์เซ็นต์ของความแม่นยำเฉลี่ยเท่ากับ 93.086% และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้เท่ากับ 5.446%

นอกจากนี้จากตารางที่ 5.10 สรุปได้ว่าการรวมกันของพารามิเตอร์ที่ให้ค่าความแม่นยำสูงที่สุดคือ การใช้สัญญาณการเคลื่อนไหว 3 แกน ที่ดึงคุณลักษณะโดยใช้การแปลงเวฟเลตระดับ 1 ด้วย Biorthogonal2.8 และลดมิติโดยวิธีที่นำเสนอด้วยอัตราการลดมิติเท่ากับ 16 และจดจำกิจกรรมโดยใช้โครงข่ายประสาทเทียมที่ชั้นเอาต์พุตเป็นฟังก์ชัน log-sigmoid และมีจำนวนโหนดในชั้นซ่อนเท่ากับ 30 จะให้ค่าเปอร์เซ็นต์ของความแม่นยำเฉลี่ยเท่ากับ 95.124% และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้เท่ากับ 22.801%

### 5.3.2 การจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวัน (Human Falling Detection)

การทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวันจะจดจำกิจกรรมทั้งหมด 2 กิจกรรม ได้แก่ กลุ่มเหตุการณ์การหกล้ม 5 เหตุการณ์ ได้แก่ 1.) หกล้มไปด้านหน้า 2.) หกล้มไปด้านหลัง 3.) หกล้มไปด้านซ้าย 4.) หกล้มไปด้านขวา และ 5.) หกล้มในขณะที่กำลังลุกขึ้นยืน และกลุ่มกิจกรรมทางกายภาพในชีวิตประจำวัน 5 กิจกรรม ได้แก่ 1.) ลุกขึ้นจากที่นอน 2.) ล้มตัวลงนอนบนที่นอน 3.) ลุกขึ้นจากเก้าอี้ 4.) นั่งลงบนเก้าอี้ 5.) การเดิน ดังแสดงในรูปที่ 5.12



รูปที่ 5.12 การทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวัน


ในการทำงานเดียวกันกับการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ จากขั้นตอนการทดลอง สัญญาณการเคลื่อนไหวสามแกนมีความยาวสัญญาณเท่ากับ 1248 จุด จากนั้นทำการดึงคุณลักษณะของ สัญญาณด้วยการแปลงเวฟเลตที่ระดับ 1 และ 2 จะได้สัญญาณคุณลักษณะเวฟเลต 1248 สัมประสิทธิ์ เท่ากันหมด ดังแสดงในรูปที่ 5.4 และ 5.5 ตามลำดับ

ต่อมาเลือกสัญญาณคุณลักษณะเวฟเลตของสัญญาณการเคลื่อนไหวแบบสุ่มจำนวน 75 สัญญาณ จากแต่ละกิจกรรม เพื่อใช้คำนวณหา  $w$  ของการลดมิติที่นำเสนอ และใช้เป็นข้อมูลในการฝึกสอน โครงข่ายประสาทเทียม และใช้สัญญาณคุณลักษณะเวฟเลตของสัญญาณการเคลื่อนไหวจำนวน 75 สัญญาณจากแต่ละกิจกรรมที่เหลือ สำหรับทดสอบประสิทธิภาพของอัลกอริทึมที่นำเสนอ ดังแสดงใน ตารางที่ 5.3


**ตารางที่ 5.11** แสดงรายละเอียดการใช้สัญญาณการเคลื่อนไหวสำหรับการทดลองการจำแนกการหกล้ม ออกจากกิจกรรมในชีวิตประจำวัน

ประเภทกิจกรรม	กิจกรรม	จำนวน สัญญาณ ทั้งหมด	จำนวน สัญญาณ ฝึกสอน	จำนวน สัญญาณ ทดสอบ
เหตุการณ์การหกล้ม	หกล้มไปด้านหน้า	150	75	75
	หกล้มไปด้านหลัง	150	75	75
	หกล้มไปด้านซ้าย	150	75	75
	หกล้มไปด้านขวา	150	75	75
	หกล้มในขณะที่กำลังลุกขึ้นยืน	150	75	75
กิจกรรมทางกายภาพ ในชีวิตประจำวัน	ลุกขึ้นจากที่นอน	150	75	75
	ล้มตัวลงนอนบนที่นอน	150	75	75
	ลุกขึ้นจากเก้าอี้	150	75	75
	นั่งลงบนเก้าอี้	150	75	75
	การเดิน	150	75	75

สำหรับโครงสร้างของโครงข่ายประสาทเทียม สัญญาณคุณลักษณะเวฟเลตของสัญญาณการเคลื่อนไหวที่ถูกลดมิติจะเป็นตัวกำหนดจำนวนโหนดชั้นอินพุทของโครงข่ายประสาทเทียมซึ่งเท่ากับ จำนวนสัมประสิทธิ์ของคุณลักษณะเวฟเลต ดังแสดงในตารางที่ 5.4 และจำนวนโหนดในชั้นเอาต์พุทของ โครงข่ายประสาทเทียมจะเท่ากับจำนวนกิจกรรมที่ทำการรู้จำซึ่งในการทดลองนี้เท่ากับ 2 นอกจากนี้การ ทดลองของเราได้เปรียบเทียบการใช้ฟังก์ชัน activation ที่ต่างกันในชั้นเอาต์พุตดังแสดงในรูปที่ 5.13 และ 5.14




รูปที่ 5.13 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวันมนุษย์ โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติและใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท



รูปที่ 5.14 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวันมนุษย์ โดยใช้สัญญาณคุณลักษณะเวฟเลตที่ยังไม่ได้ลดมิติและใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

### 5.3.2.1 ผลการทดลองการจำแนกการทกล้อมออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท

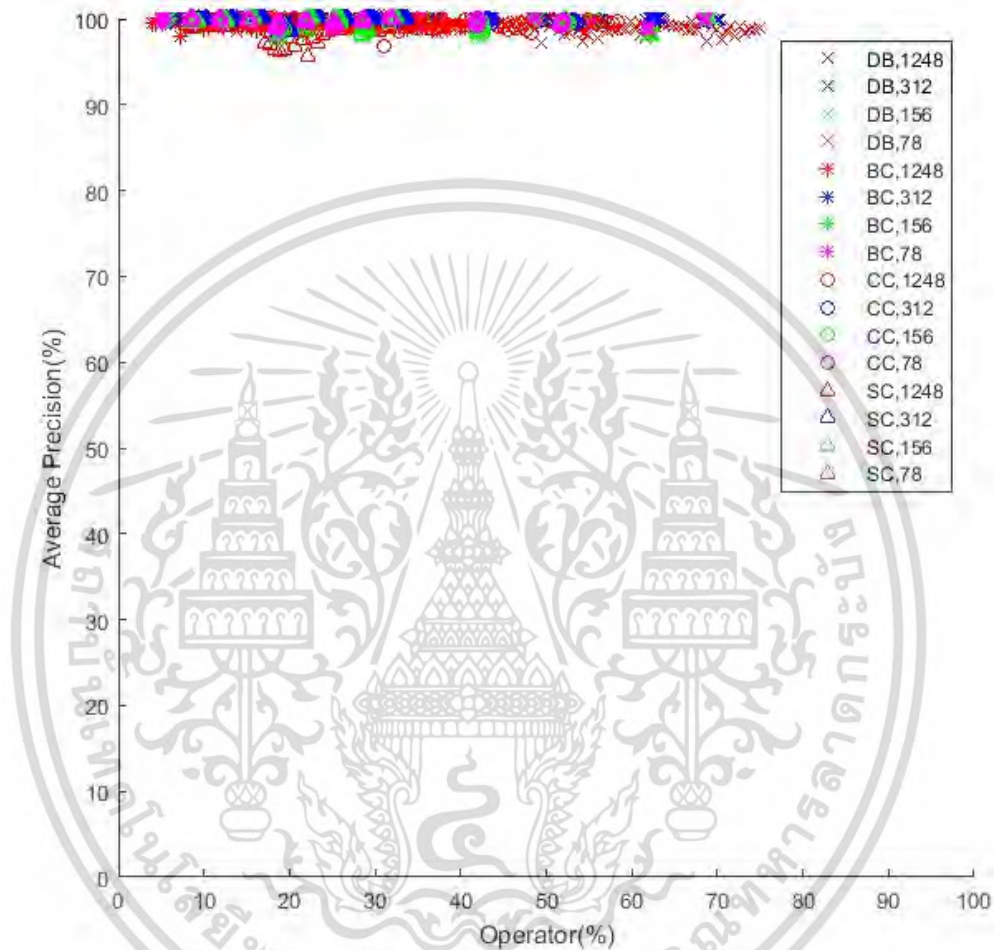


รูปที่ 5.15 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการทกล้อมออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุท

ตารางที่ 5.12 ผลการทดลองการจำแนกการทกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย  
สัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน log-  
sigmoid ในชั้นเอาต์พุท

Mother Wavelet	อัตรา การลดมิติ	ความยาว ฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	%Pr	%Op	Pe
Daubechies	n/a	4	1248-1-2	99.87	5.807	4.993
	4	4	312-1-2	99.87	7.258	6.241
	8	4	156-1-2	99.08	7.177	6.238
	16	4	78-1-2	100	7.137	6.135
Coiflet	n/a	6	1248-1-2	99.47	8.387	7.229
	4	6	312-1-2	99.87	9.838	8.459
	8	6	156-1-2	99.47	9.758	8.405
	16	6	78-1-2	100	9.717	8.354
Symlet	n/a	4	1248-1-2	99.87	5.807	4.993
	4	4	312-1-2	99.21	7.258	6.289
	8	4	156-1-2	99.73	7.177	6.176
	16	4	78-1-2	100	7.137	6.135
Biorthogonal	n/a	2	1248-1-2	99.73	3.226	<b>2.786</b>
	4	2	312-1-2	100	4.678	4.021
	8	2	156-1-2	100	4.597	3.952
	16	2	78-1-2	<b>100</b>	4.557	3.917

### 5.3.2.2 ผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย สัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน **log- sigmoid** ในชั้นเอาต์พุต




รูปที่ 5.16 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-sigmoid ในชั้นเอาต์พุต

ตารางที่ 5.13 ผลการทดลองการจำแนกการทกล้อมออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย  
สัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน log-  
sigmoid ในชั้นเอาต์พุท

Mother Wavelet	อัตรา การลดมิติ	ความยาว ฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	%Pr	%Op	Pe
Daubechies	n/a	4	1248-1-2	99.735	8.387	7.215
	4	4	312-1-2	100	9.838	8.458
	8	4	156-1-2	99.603	9.758	8.398
	16	4	78-1-2	100	9.717	8.354
Coiflet	n/a	6	1248-1-2	99.867	12.257	10.54
	4	6	312-1-2	100	13.709	11.79
	8	6	156-1-2	100	13.628	11.72
	16	6	78-1-2	100	13.588	11.68
Symlet	n/a	4	1248-1-2	99.735	8.387	7.215
	4	4	312-1-2	99.867	9.838	8.459
	8	4	156-1-2	99.735	9.758	8.393
	16	4	78-1-2	100	9.717	8.354
Biorthogonal	n/a	2	1248-1-2	99.472	4.516	<b>3.919</b>
	4	2	312-1-2	99.867	5.968	5.132
	8	2	156-1-2	100	5.887	5.061
	16	2	78-1-2	<b>100</b>	5.847	5.027

### 5.3.2.3 ผลการทดลองการจำแนกการทกล้อมออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท




รูปที่ 5.17 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการทกล้อมออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

ตารางที่ 5.14 ผลการทดลองการจำแนกการทกล้อมออกจากกิจกรรมทางกายภาพของมนุษย์ด้วย  
สัญญาณการเคลื่อนไหว 3 แกน โดยการใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน  
linear ในชั้นเอาท์พุท

Mother Wavelet	อัตรา การลดมิติ	ความยาว ฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	%Pr	%Op	Pe
Daubechies	n/a	4	1248-1-2	99.867	5.807	4.994
	4	8	312-1-2	100	7.258	6.240
	8	4	156-1-2	100	7.177	6.170
	16	8	78-1-2	99.867	7.137	6.137
Coiflet	n/a	12	1248-1-2	99.603	8.387	7.221
	4	6	312-1-2	100	9.838	8.458
	8	6	156-1-2	99.867	9.758	8.390
	16	6	78-1-2	99.867	9.717	8.355
Symlet	n/a	4	1248-1-2	99.735	5.807	4.999
	4	4	312-1-2	100	7.258	6.240
	8	4	156-1-2	99.867	7.177	6.172
	16	4	78-1-2	99.735	7.137	6.142
Biorthogonal	n/a	6	1248-1-2	99.603	3.226	<b>2.802</b>
	4	2	312-1-2	99.867	4.678	4.024
	8	2	156-1-2	99.735	4.597	3.961
	16	2	78-1-2	<b>100</b>	4.557	3.918

### 5.3.2.4 ผลการทดลองการจำแนกการทกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 1 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท



รูปที่ 5.18 กราฟแสดงการเปรียบเทียบผลการทดลองการจำแนกการทกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

ตารางที่ 5.15 ผลการทดลองการจำแนกการทกล้อมออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตระดับที่ 2 และใช้ฟังก์ชัน linear ในชั้นเอาต์พุท

Mother Wavelet	อัตราการลดมิติ	ความยาวฟิลเตอร์	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Daubechies	n/a	4	1248-1-2	99.735	8.387	7.215
	4	8	312-1-2	100	9.838	8.458
	8	4	156-1-2	99.603	9.758	8.398
	16	8	78-1-2	100	9.717	8.354
Coiflet	n/a	12	1248-1-2	99.735	12.257	10.54
	4	6	312-1-2	99.735	13.709	11.79
	8	6	156-1-2	100	13.628	11.72
	16	6	78-1-2	99.735	13.588	11.68
Symlet	n/a	4	1248-1-2	99.735	8.387	7.215
	4	4	312-1-2	100	9.838	8.458
	8	4	156-1-2	99.603	9.758	8.398
	16	4	78-1-2	99.867	9.717	8.355
Biorthogonal	n/a	6	1248-1-2	99.472	4.516	<b>3.919</b>
	4	2	312-1-2	99.735	5.968	5.137
	8	2	156-1-2	99.867	5.887	5.063
	16	2	78-1-2	<b>100</b>	5.847	5.034

**5.3.1.5** สรุปผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ด้วยสัญญาณการเคลื่อนไหว 3 แกน โดยใช้การแปลงเวฟเลตวิธีการลดมิติที่นำเสนอและโครงข่ายประสาทเทียม

ตารางที่ 5.16 สรุปผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ที่มีประสิทธิภาพดีที่สุด

Activation Function in Output Layer	Decomposition Level	Mother Wavelet	อัตรา การลดมิติ	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Log-sigmoid	1	BC1.1	n/a	1	99.735	3.226	<b>2.786</b>
Log-sigmoid	2	BC1.1	n/a	1	99.472	4.516	3.919
Linear	1	BC1.1	n/a	1	99.603	3.226	2.802
Linear	2	BC1.1	n/a	1	99.472	4.516	3.919

ตารางที่ 5.17 สรุปผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมทางกายภาพของมนุษย์ที่มีความแม่นยำสูงที่สุด

Activation Function in Output Layer	Decomposition Level	Mother Wavelet	อัตรา การลดมิติ	โครงข่ายประสาทเทียม (Input-Hidden-Output)	% Pr	% Op	Pe
Log-sigmoid	1	BC1.1	16	1	<b>100</b>	4.557	3.918
Log-sigmoid	2	BC1.1	16	1	100	5.847	5.027
Linear	1	BC1.1	16	1	<b>100</b>	4.557	3.918
Linear	2	BC1.1	16	1	100	5.847	5.034

จากผลการทดลองการจำแนกการหลั้มออกจากกิจกรรมทางกายภาพของมนุษย์ในตารางที่ 5.16 สรุปได้ว่าการรวมกันของพารามิเตอร์นี้ให้ค่า  $P_e$  มีค่าต่ำที่สุดเท่ากับ 2.786 คือ การใช้สัญญาณการเคลื่อนไหว 3 แกน ที่ดึงคุณลักษณะโดยใช้การแปลงเวฟเลตระดับ 1 ด้วย Biorthogonal1.1 และไม่ลดมิติ และจดจำกิจกรรมโดยใช้โครงข่ายประสาทเทียมที่ชั้นเอาต์พุตเป็นฟังก์ชัน log-sigmoid และมีจำนวนโหนดในชั้นซ่อนเท่ากับ 1 จะให้ค่าเปอร์เซ็นต์ของความแม่นยำเฉลี่ยเท่ากับ 99.735% และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้เท่ากับ 3.226%

นอกจากนี้จากตารางที่ 5.17 สรุปได้ว่าการรวมกันของพารามิเตอร์ที่ให้ค่าความแม่นยำสูงที่สุดคือ การใช้สัญญาณการเคลื่อนไหว 3 แกน ที่ดึงคุณลักษณะโดยใช้การแปลงเวฟเลตระดับ 1 ด้วย Biorthogonal1.1 และลดมิติโดยวิธีที่นำเสนอด้วยอัตราการลดมิติเท่ากับ 16 และจดจำกิจกรรมโดยใช้โครงข่ายประสาทเทียมที่ชั้นเอาต์พุตเป็นฟังก์ชัน log-sigmoid หรือ linear และมีจำนวนโหนดในชั้นซ่อนเท่ากับ 1 จะให้ค่าเปอร์เซ็นต์ของความแม่นยำเฉลี่ยเท่ากับ 100% และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้เท่ากับ 4.557%



## บทที่ 6

### สรุปผลการวิจัย

วิทยานิพนธ์ฉบับนี้นำเสนออัลกอริทึมสำหรับรู้จำกิจกรรมทางกายภาพของมนุษย์และสามารถจำแนกเหตุการณ์การหกล้มออกจากกิจกรรมทางกายภาพในชีวิตประจำวันได้อย่างมีประสิทธิภาพ การวิจัยมุ่งเน้น 2 แนวทาง คือ วิทยานิพนธ์ฉบับนี้เสนอวิธีลดมิติแบบใหม่ และการศึกษาอย่างรอบคอบเกี่ยวกับการรวมกันของพารามิเตอร์ระหว่าง mother wavelet, ความยาวฟิลเตอร์ของ mother wavelet, อัตราการลดมิติ และจำนวนโหนดในชั้นซ่อนเพื่อที่จะหาการรวมกันของพารามิเตอร์ที่เหมาะสมที่สุด

จากผลการทดลองการรู้จำกิจกรรมทางกายภาพของมนุษย์ (Human Physical Activity Recognition) ตารางที่ 5.9 เปรียบเทียบพารามิเตอร์ที่เลือกใช้ที่ให้ค่า  $Pe$  มีค่าต่ำที่สุด จากการใช้การแปลงเวฟเลตระดับที่ 1 หรือ 2 และ ใช้ฟังก์ชัน log-sigmoid หรือ linear ในชั้นเอาต์พุท พบว่าทุกการทดลอง สำหรับ Mother Wavelet ใช้ Biorthogonal1.1 และอัตราที่ใช้ในการลดมิติเท่ากับ 16 และเมื่อมีการเปลี่ยนฟังก์ชันในชั้นเอาต์พุทของโครงข่ายประสาทเทียม พบว่าใช้ฟังก์ชัน linear จะให้ผลลัพธ์ที่ดีกว่าใช้ฟังก์ชัน log-sigmoid และการแปลงเวฟเลตที่ระดับ 1 นั้นให้ผลลัพธ์ที่ดีกว่าการแปลงเวฟเลตที่ระดับ 2 นอกจากนี้จากตารางที่ 5.10 เปรียบเทียบพารามิเตอร์ที่เลือกใช้ที่ให้ค่า  $\%Pr$  สูงที่สุด จากการใช้การแปลงเวฟเลตระดับที่ 1 หรือ 2 และ ใช้ฟังก์ชัน log-sigmoid หรือ linear ในชั้นเอาต์พุท ซึ่งคือการแปลงเวฟเลตระดับที่ 1 โดยใช้ Biorthogonal2.8 และอัตราที่ใช้ในการลดมิติเท่ากับ 16 โครงข่ายประสาทเทียมที่ชั้นเอาต์พุทเป็นฟังก์ชัน log-sigmoid และมีจำนวนโหนดในชั้นซ่อนเท่ากับ 30 จะให้ค่าเปอร์เซ็นต์ของความแม่นยำเฉลี่ยเท่ากับ 95.124% และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้เท่ากับ 22.801% สำหรับการใช้งานจริงเราจะต้องเลือกใช้พารามิเตอร์ที่เหมาะสมกับใช้งานมากที่สุดเพราะถ้าต้องการความแม่นยำที่สูงที่สุดนั้นหมายความว่าความตัวดำเนินการในการคำนวณเพิ่มขึ้นด้วย

จากผลการทดลองการจำแนกการหกล้มออกจากกิจกรรมในชีวิตประจำวัน (Human Falling Detection) ในตารางที่ 5.16 เปรียบเทียบพารามิเตอร์ที่เลือกใช้ที่ให้ค่า  $Pe$  มีค่าต่ำที่สุด จากการใช้การแปลงเวฟเลตระดับที่ 1 หรือ 2 และ ใช้ฟังก์ชัน log-sigmoid หรือ linear ในชั้นเอาต์พุท พบว่าทุกการทดลอง สำหรับ Mother Wavelet ใช้ Biorthogonal1.1 และไม่ต้องลดมิติ และการแปลงเวฟเลตที่ระดับ 1 นั้นให้ผลลัพธ์ที่ดีกว่าการแปลงเวฟเลตที่ระดับ 2 แต่การเปลี่ยนฟังก์ชันในชั้นเอาต์พุทของโครงข่ายประสาทเทียม พบว่าใช้ฟังก์ชัน log-sigmoid จะให้ผลลัพธ์ที่ดีกว่าใช้ฟังก์ชัน linear นอกจากนี้จากตารางที่ 5.17 เปรียบเทียบพารามิเตอร์ที่เลือกใช้ที่ให้ค่า  $\%Pr$  สูงที่สุด จากการใช้การแปลงเวฟเลตระดับที่ 1 หรือ 2 และ ใช้ฟังก์ชัน log-sigmoid หรือ linear ในชั้นเอาต์พุท ซึ่งคือที่ การแปลงเวฟเลตระดับ 1 ด้วย Biorthogonal1.1 และลดมิติโดยวิธีที่นำเสนอด้วยอัตราการลดมิติเท่ากับ 16 และรู้จำกิจกรรมโดยใช้โครงข่ายประสาทเทียมที่ชั้นเอาต์พุทเป็นฟังก์ชัน log-sigmoid หรือ linear และมีจำนวน

โหนดในชั้นซ่อนเท่ากับ 1 จะให้ค่าเปอร์เซ็นต์ของความแม่นยำเฉลี่ยเท่ากับ 100% และเปอร์เซ็นต์ของจำนวนตัวดำเนินการที่ใช้เท่ากับ 4.557% สำหรับการจำแนกการหลัดออกจากกิจกรรมในชีวิตประจำวัน ไม่จำเป็นต้องมีการลดมิติของข้อมูลด้วยวิธีที่นำเสนออีกจะให้ประสิทธิภาพสูงที่สุด แต่สำหรับการใช้งานจริงต้องแยกการหลัดได้แม่นยำที่สุดเพราะการหลัดทำให้เกิดผลกระทบร้ายแรงตามมาได้

ดังนั้นจึงสรุปได้ว่าวิธีการลดมิติที่นำเสนอไม่เพียงแต่เพิ่มความแม่นยำในการรู้จำกิจกรรมแต่ยังลดจำนวนตัวดำเนินการในการคำนวณให้กับอัลกอริทึมที่นำเสนอด้วย และสรุปการเลือกใช้การรวมกันของพารามิเตอร์ของอัลกอริทึมที่เหมาะสมกับการใช้งานในการรู้จำกิจกรรมทางกายภาพของมนุษย์และการจำแนกการหลัดออกจากกิจกรรมในชีวิตประจำวัน



## เอกสารอ้างอิง

- [1] กลุ่มสถิติประชากร สำนักสถิติสังคม สำนักงานสถิติแห่งชาติ,สำนักงานสถิติแห่งชาติ, “รายงานผลเบื้องต้นการสำรวจประชากรสูงอายุในประเทศไทยพ.ศ.2557”, กรุงเทพมหานคร, 2557.
- [2] นพ.สมศักดิ์ ชุณหรัศมิ์, “สถานการณ์ผู้สูงอายุไทย พ.ศ.2551”, ครั้งที่ 1, กรุงเทพมหานคร: บริษัท ทีคิวพี จำกัด. 2552.
- [3] นายนิติกร ดรกันยา, “การสำรวจความรุนแรงและความถี่ของการล้ม ของผู้สูงอายุตามสถานที่ต่างๆในวัดภายในเขตจังหวัดนครราชสีมา”, วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมโยธา สำนักวิชาวิศวกรรมศาสตร์, มหาวิทยาลัยเทคโนโลยีสุรนารี, 2555.
- [4] Davide Curone, Gian M. Bertolotti, Andrea Cristiani, Emanuele L. Secco, and Giovanni Magenes, “A Real-Time and Self-Calibrating Algorithm Based on Triaxial Accelerometer Signals for the Detection of Human Posture and Activity”, IEEE Transactions on Information Technology in Biomedicine, vol.14 No.4, pp.1098-1105, 2010.
- [5] Jin wang, Ronghua Chen, Xiangping Sun, Mary F.H She, and Yuchuan Wu, “Recognizing Human Daily Activities from Accelerometer Signal”, Procedia Engineering 15, pp.1780-1786, 2011.
- [6] Lina Tong, Wei Chen, Qunjun Song, and Yunjian Ge, “A research on automatic human fall detection method based on wearable inertial force information acquisition system”, Robotics and Biomimetics (ROBIO), 2009 IEEE International Conference on, pp. 949 – 953, 2009.
- [7] Yanjun Li, Gan Chen, Yueyun Shen, Yihua Zhu and Zhen Cheng, “Accelerometer-based fall detection sensor system for the elderly”, 2012 IEEE 2nd International Conference on Cloud Computing and Intelligence Systems, vol.3, pp. 1216 - 1220, 2012.
- [8] Maarit Kangas, Antti Konttila, Ilkka Winblad, and Timo Jämsä, “Determination of simple thresholds for accelerometry-based parameters for fall detection”, Conf Proc IEEE Eng Med Biol Soc, pp. 1367-1370, 2007.

## เอกสารอ้างอิง(ต่อ)

- [9] Merryn J Mathie, Adelle C F Coster, Nigel H Lovell, and Branko G Celler, **“Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement”**, *Physiol. Meas*, vol.25 No.3, pp. R1-R20, 2004.
- [10] Adna Sengto and Thursak Leauhatong, **“Human falling detection algorithm using back propagation neural network”**, *Biomedical Engineering International Conference (BMEiCON)*, 2012, pp. 1 – 5, 2012.
- [11] Nitipat Nuttitanakul and Thursak Leauhatong, **“A Novel Algorithm For Detection Human Falling from Accelerometer Signal Using Wavelet Transform and Neural Network”**, 2015 7th International Conference on Information Technology and Electrical Engineering (ICITEE), pp. 215 – 220, 2015.
- [12] นพ.อุดม เพชรสังหาร, **“การหกล้มในผู้สูงอายุ”**, *โลกวันนี้วันสุข*. vol.10 No.471, pp. 46, 2557.
- [13] Thurmon E. Lockhart, B.S.I.E., **“Biomechanics of Slips and Falls in the Elderly”**, *Industrial Engineering*, Texas Tech University, 1997.
- [14] สำนักงานสำรวจสุขภาพประชาชนไทย (สสท.), **“รายงานการสำรวจสุขภาพประชาชนไทยโดยการตรวจร่างกาย”**, No.4, 2552.
- [15] เปรมกมล ขวนขวย, **“ปัจจัยที่เกี่ยวข้องกับการหกล้มของผู้สูงอายุที่อาศัยอยู่ในชุมชน”**, วิทยานิพนธ์สาธารณสุขศาสตรมหาบัณฑิต, สาขาชีวสถิติ, บัณฑิตวิทยาลัย, มหาวิทยาลัยขอนแก่น, 2550.
- [16] น.ส.วรัญชกรณ์ พลเขตร์, นายณัฐวุฒิ เจริญไชย, **“เตือน! พลาดตกหกล้ม อุบัติภัยใกล้ตัว”**, *จุลสารงานเฝ้าระวังการบาดเจ็บศูนย์อุบัติเหตุและวิกฤตบำบัดโรงพยาบาลศูนย์ขอนแก่น*, vol.1, 2555.
- [17] Lynn S. Lippert, MS, PT, **“Clinical Kinesiology and Anatomy”**, F. A. Davis Company, Fourth Edition, 2006.
- [18] Simon Johansson, **“A machine-learning based approach to pre-impact fall detection with wearable devices”**, *KTH Industrial Engineering and Management Department of Machine Design*, Sweden 2015.

## เอกสารอ้างอิง(ต่อ)

- [19] C. Bouten, K. Koekkoek, M. Verduin, R. Kodde, and J. Janssen, **“A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity”**, IEEE Transactions on Biomedical Engineering, vol. 44, no. 3, pp. 136–147, 1997.
- [20] S. Bonnet, P. Couturier, F. Favre-Reguillon, and R. Guillemaud, **“Evaluation of postural stability by means of a single inertial sensor”**, vol. 26 III, pp. 2275–2278, 2004.
- [21] Liu and T. Lockhart, **“Trunk angular kinematics during slip-induced backward falls and activities of daily living”**, Journal of Biomechanical Engineering, vol. 136, no. 10, 2014.
- [22] A. Bourke and G. Lyons, **“A threshold-based fall-detection algorithm using a bi-axial gyroscope sensor”**, Medical Engineering and Physics, vol. 30, no. 1, pp. 84–90, 2008.
- [23] D. Rodríguez-Martin, C. Pérez-López, A. Samà, J. Cabestany, and A. Català, **“A wearable inertial measurement unit for long-term monitoring in the dependency care area”**, Sensors (Switzerland), vol. 13, no. 10, pp. 14079–14104, 2013.
- [24] N. Noury, P. Rumeau, A. Bourke, G. ÓLaighin, and J. Lundy, **“A proposal for the classification and evaluation of fall detectors”**, IRBM, vol. 29, no. 6, pp. 340–349, 2008.
- [25] Maarit Kangas, **“Development of Accelerometry-Based Fall Detection”**, Faculty of Medicine, University of Oulu, Oulu 2011.
- [26] Hristijan Gjoreski, Mitja Lustrek and Matjaz Gams, **“Accelerometer Placement for Posture Recognition and Fall Detection”**, Intelligent Environments (IE), 2011 7th International Conference on, pp. 47 – 54, 2011.
- [27] Omar Aziz and Stephen N. Robinovitch, **“An Analysis of the Accuracy of Wearable Sensors for Classifying of Falls in Humans”**, IEEE Transactions on Neural system and Rehabilitation Engineering, vol.19, No.6, 2011.
- [28] Chun-Lin, Liu, **“A Tutorial of the Wavelet Transform”**, <http://disp.ee.ntu.edu.tw/tutorial/WaveletTutorial.pdf>, February 23, 2010.

## เอกสารอ้างอิง(ต่อ)

- [29] R.J.E. Merry, **“Wavelet Tutorial and Applications a literature study”**, Department of Mechanical Engineering, Eindhoven University of Technology, 2005.
- [30] Michel VERLEYSEN, **“Learning high-dimensional data”**, Limitations and Future Trends in Neural Computation, S. Ablameyko et al. (Eds.),IOS Press, pp. 141-162, 2003.
- [31] Arunasakthi. K and KamatchiPriya. L, **“A Review on Linear and Non-Linear Dimensionality Reduction Techniques”**, Machine Learning and Applications: An International Journal (MLAIJ) vol.1, No.1, September 2014.
- [32] C.O.S. Sorzano, J. Vargas, A. Pascual-Montano, **“A survey of dimensionality reduction techniques”**, Machine Learning (stat.ML), 2014.
- [33] Tao Li, Shenghuo Zhu, and Mitsunori Ogihara, **“Using discriminant analysis for multi-class classification: an experimental investigation”**, Knowledge and Information Systems, vol.10, No.4, pp. 453–472, 2006.
- [34] Adil Mehmood Khan, Young-Koo Lee, Sungyoung Y. Lee, and Tae-Seong Kim, **“A Triaxial Accelerometer-Based Physical-Activity Recognition via Augmented-Signal Features and a Hierarchical Recognizer”**, IEEE Transactions on Information Technology in Biomedicine, vol.14, No. 5, pp.1166-1172, 2010.
- [35] YP Chen, JY Yang, SN Liou, GY Lee, and JS Wang , **“Online Classifier Construction Algorithm for Human Activity Detection Using A Tri-Axial Accelerometer”**, Applied Mathematics Computation, vol.205, No.2, pp. 849-860, 2008.
- [36] Xiaoxun Zhang and Yunde jia. **“A Linear Discriminant Analysis Framework Based on Random Subspace for Face Recognition”**, Pattern Recognition, pp. 2585 – 2591, 2007.
- [37] Michel Verleysen and Damien François, **“The Curse of Dimensionality in Data Mining and Time Series Prediction”**, J. Cabestany, A. Prieto, and D.F. Sandoval (Eds.), pp. 758 – 770, 2005.

## เอกสารอ้างอิง(ต่อ)

- [38] Intelligent Data Analysis and Probabilistic Inference Lecture 16, **“Lecture 16: Small Sample Size Problems and Covariance Estimation”**, pp.1-5,  
[http://www.doc.ic.ac.uk/~dfg/ProbabilisticInference/old\\_IDAPILecture16.pdf](http://www.doc.ic.ac.uk/~dfg/ProbabilisticInference/old_IDAPILecture16.pdf).
- [39] **“Bio-Inspired Artificial Intelligence Theories, Methods, and Technologies”**,  
 Dario Floreano Claudio Mattiussi The MIT Press Cambridge, Massachusetts  
 London, England, 2008.
- [40] ผศ.ดร.อาทิตย์ ศรีแก้ว, **“ปัญญาเชิงคำนวณ COMPUTATIONAL INTELLIGENCE”**, 2552.
- [41] ETT CO.,LTD, **“คู่มือ MODULE ET-MMA7331L”**,  
<http://www.thaieasyelec.net/archives/Manual/ET-MMA7331.pdf>.
- [42] Bendi Venkata Ramana, Prof. M.Surendra Prasad Babu, and Prof. N. B. Venkateswarlu, **“A Critical Study of Selected Classification Algorithms for Liver Disease Diagnosis”**, International Journal of Database Management Systems ( IJMS ), Vol.3, No.2, 2011.

## ภาคผนวก ก

**ตารางที่ ก.1** ค่าสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet ตั้งแต่ D2-D20

DB2		DB4		DB6		DB8	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
-0.12940952	-0.482962913	-0.010597402	-0.230377813	-0.001077301	-0.111540743	-0.000117477	-0.054415842
0.224143868	0.836516304	0.032883012	0.714846571	0.004777258	0.49462389	0.000675449	0.312871591
0.836516304	-0.224143868	0.030841382	-0.630880768	0.000553842	-0.751133908	-0.00039174	-0.675630736
0.482962913	-0.129409523	-0.187034812	-0.027983769	-0.031582039	0.315250352	-0.004870353	0.585354684
		-0.027983769	0.187034812	0.027522866	0.226264694	0.008746094	0.015829105
		0.630880768	0.030841382	0.097501606	-0.129766868	0.013981028	-0.284015543
		0.714846571	-0.032883012	-0.129766868	-0.097501606	-0.044088254	-0.000472485
		0.230377813	-0.010597402	-0.226264694	0.027522866	-0.017369301	0.128747427
				0.315250352	0.031582039	0.128747427	0.017369301
				0.751133908	0.000553842	0.000472485	-0.044088254
				0.49462389	-0.004777258	-0.284015543	-0.013981028
				0.111540743	-0.001077301	-0.015829105	0.008746094
						0.585354684	0.004870353
						0.675630736	-0.00039174
						0.312871591	-0.000675449
						0.054415842	-0.000117477
DB10		DB10		DB12		DB12	
Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)	Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)
-1.33E-05	-0.071394147	-0.026670058	0.029457537	-1.53E-06	1.08E-02	-0.013112258	-0.041546277
9.35887E-05	0.093057365	0.1881768	0.033212674	1.28E-05	-9.64E-02	0.109566273	-0.012218649
-0.00011647	0.12736934	-0.527201189	-0.003606554	-2.42415E-05	5.36E-03	-0.377355135	0.012840825
-0.00068586	-0.195946274	0.688459039	-0.010733175	-8.85041E-05	0.182478606	0.657198723	0.006711499
0.001992405	-0.249846424	-0.281172344	-0.001395352	0.000388653	-0.023779257	-0.515886478	-0.002248607
0.001395352	0.281172344	-0.249846424	0.001992405	6.54513E-06	-0.316178454	-0.044763886	-0.002179504
-0.01073318	0.688459039	0.195946274	0.000685857	-0.002179504	-0.044763886	0.316178454	-6.54513E-06
0.003606554	0.527201189	0.12736934	-0.000116467	0.002248607	0.515886478	-0.023779257	0.000388653
0.033212674	0.1881768	-0.093057365	-9.35887E-05	0.006711499	0.657198723	-0.182478606	8.85041E-05
-0.02945754	2.67E-02	-7.14E-02	-1.33E-05	-0.012840825	0.377355135	5.36E-03	-2.42415E-05
				-0.012218649	0.109566273	9.64E-02	-1.28E-05
				0.041546277	0.013112258	1.08E-02	-1.53E-06

## ตารางที่ ก.1 (ต่อ)

DB14		DB14		DB16		DB16	
Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)	Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)
-1.79E-07	2.70E-02	-0.006461153	0.030185352	-2.11E-08	-3.69E-02	-0.003189221	-0.01029766
1.72E-06	5.52E-02	0.062364759	-0.00561505	2.31E-07	-7.59E-03	0.034907714	0.013993769
-4.39E-06	-7.15E-02	-0.254850268	-0.012789493	-7.36E-07	7.59E-02	-0.165064283	0.006990015
-1.0337E-05	-0.086748412	0.554305618	-0.000746219	-1.04E-06	-0.006239723	0.430312723	-0.00364428
6.8755E-05	0.139989017	-0.631187849	0.003849639	1.13366E-05	-0.132388306	-0.637356332	-0.003128023
-4.1777E-05	0.138395214	0.218670688	0.001061691	-1.39457E-05	0.027340264	0.440290257	0.000407897
-0.00038683	-0.21803353	0.271688552	-0.000708021	-6.1036E-05	0.211190694	0.089751089	0.000941022
0.000708021	-0.271688552	-0.21803353	-0.000386832	0.000174787	-0.027918208	-0.327063311	0.000114242
0.001061691	0.218670688	-0.138395214	4.17772E-05	0.000114242	-0.327063311	0.027918208	-0.000174787
-0.00384964	0.631187849	0.139989017	6.8755E-05	-0.000941022	-0.089751089	0.211190694	-6.1036E-05
-0.00074622	0.554305618	0.086748412	1.03372E-05	0.000407897	0.440290257	-0.027340264	1.39457E-05
0.012789493	0.254850268	-7.15E-02	-4.39E-06	0.003128023	0.637356332	-0.132388306	1.13366E-05
-0.00561505	0.062364759	-5.52E-02	-1.72E-06	-0.00364428	0.430312723	0.006239723	1.04E-06
-0.03018535	0.006461153	2.70E-02	-1.79E-07	-0.006990015	0.165064283	7.59E-02	-7.36E-07
				0.013993769	0.034907714	7.59E-03	-2.31E-07
				0.01029766	0.003189221	-3.69E-02	-2.11E-08
DB18		DB18		DB20		DB20	
Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)	Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)
-2.51E-09	2.67E-02	-0.00157631	-0.006262168	-3.00E-10	-8.79E-03	-0.000779954	0.013810526
3.07E-08	-2.37E-02	0.019288532	-0.013051481	4.06E-09	3.23E-02	0.010549395	0.006721627
-1.18E-07	-4.45E-02	-0.103588466	-0.00011863	-1.81E-08	5.87E-03	-0.06342378	-0.004420542
-7.69E-08	5.71E-02	0.314678941	0.004943344	2.01E-10	-6.17E-02	0.219942114	-0.003581494
1.77E-06	0.064887216	-0.571826808	0.001118733	2.63E-07	5.63E-03	-0.472696185	0.000831562
-3.3326E-06	-0.106752247	0.571801655	-0.001340596	-6.85E-07	0.102291719	0.610493239	0.00139256
-8.5206E-06	-0.092331884	-0.147223112	-0.000628466	-1.01199E-06	-2.47E-02	-0.361502299	5.34976E-05
3.74124E-05	0.167081313	-0.293654041	0.000213582	7.24125E-06	-0.155458751	-0.139212088	-0.000385105
-1.5359E-07	0.149533976	0.216480934	0.000198649	-4.37614E-06	0.039850246	0.3267868	-0.000101533
-0.00019865	-0.216480934	0.149533976	-1.53592E-07	-3.71059E-05	0.228291051	-0.016727088	6.77428E-05
0.000213582	-0.293654041	-0.167081313	-3.74124E-05	6.77428E-05	-0.016727088	-0.228291051	3.71059E-05
0.000628466	0.147223112	-0.092331884	-8.5206E-06	0.000101533	-0.3267868	0.039850246	-4.37614E-06
-0.0013406	0.571801655	0.106752247	3.33263E-06	-0.000385105	-0.139212088	0.155458751	-7.24125E-06
-0.00111873	0.571826808	0.064887216	1.77E-06	-5.34976E-05	0.361502299	-2.47E-02	-1.01199E-06
0.004943344	0.314678941	-5.71E-02	7.69E-08	0.00139256	0.610493239	-0.102291719	6.85E-07
0.00011863	0.103588466	-4.45E-02	-1.18E-07	-0.000831562	0.472696185	5.63E-03	2.63E-07
-0.01305148	0.019288532	2.37E-02	-3.07E-08	-0.003581494	0.219942114	6.17E-02	-2.01E-10
0.006262168	0.00157631	0.026670706	-2.51E-09	0.004420542	0.06342378	5.87E-03	-1.81E-08
				0.006721627	0.010549395	-3.23E-02	-4.06E-09
				-0.013810526	0.000779954	-8.79E-03	-3.00E-10

ตารางที่ ก.2 ค่าสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet ตั้งแต่ Sym2-Sym9

Sym2		Sym3		Sym4		Sym5	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
-0.12940952	-0.482962913	0.035226292	-	-0.075765715	-0.032223101	0.027333068	-0.019538883
			0.332670553				
0.224143868	0.836516304	-0.085441274	0.806891509	-0.029635528	-0.012603967	0.029519491	-0.021101834
0.836516304	-0.224143868	-0.13501102	-	0.497618668	0.099219544	-0.039134249	0.17532809
			0.459877502				
0.482962913	-0.129409523	0.459877502	-0.13501102	0.803738752	0.297857796	0.199397534	0.016602106
		0.806891509	0.085441274	0.297857796	-0.803738752	0.72340769	-0.633978963
		0.332670553	0.035226292	-0.099219544	0.497618668	0.633978963	0.72340769
				-0.012603967	0.029635528	0.016602106	-0.199397534
				0.032223101	-0.075765715	-0.17532809	-0.039134249
						-0.021101834	-0.029519491
						0.019538883	0.027333068
Sym6		Sym7		Sym8		Sym9	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0.015404109	0.007800708	0.002681815	-0.010268177	-0.003382416	-0.00188995	0.001400916	-0.00106949
0.003490712	0.001767712	-0.001047385	0.004010245	-0.000542132	-0.000302921	0.000619781	-0.000473154
-0.11799011	-0.044724902	-0.012636303	0.107808238	0.031695088	0.014952258	-0.013271968	0.010264064
-0.04831174	-0.021060293	0.030515513	-0.14004724	0.007607487	0.003808752	-0.01152821	0.008859267
0.491055942	0.072637523	0.067892694	-0.288629632	-0.143294238	-0.04913718	0.030224879	-0.062077789
0.787641141	0.337929422	-0.049552835	0.767764317	-0.061273359	-0.02721903	0.000583463	-0.018233771
0.337929422	-0.787641141	0.017441255	-0.536101917	0.481359651	0.051945838	-0.054568958	0.191550831
-0.07263752	0.491055942	0.536101917	0.017441255	0.777185752	0.364441895	0.238760915	0.035272488
-0.02106029	0.048311743	0.767764317	0.049552835	0.364441895	-0.777185752	0.717897083	-0.617338449
0.044724902	-0.117990111	0.288629632	0.067892694	-0.051945838	0.481359651	0.617338449	0.717897083
0.001767712	-0.003490712	-0.14004724	-0.030515513	-0.02721903	0.061273359	0.035272488	-0.238760915
-0.00780071	0.015404109	-0.107808238	-0.012636303	0.04913718	-0.143294238	-0.191550831	-0.054568958
		0.004010245	0.001047385	0.003808752	-0.007607487	-0.018233771	-0.000583463
		0.010268177	0.002681815	-0.014952258	0.031695088	0.062077789	0.030224879
				-0.000302921	0.000542132	0.008859267	0.01152821
				0.00188995	-0.003382416	-0.010264064	-0.013271968
						-0.000473154	-0.000619781
						0.00106949	0.001400916

**ตารางที่ ก.3** ค่าสัมประสิทธิ์สเกลและเวฟเลตของฟังก์ชัน Coiflet Wavelet ตั้งแต่ Coif1-Coif5

Coif1		Coif2		Coif3		Coif4	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
-0.01565573	0.07273262	-0.000720549	-0.016387336	-3.46E-05	0.003793513	-1.78E-06	-8.92E-04
-0.07273262	0.337897662	-0.001823209	-0.041464937	-7.10E-05	0.007782596	-3.26E-06	-1.63E-03
0.384864847	-0.85257202	0.005611435	0.067372555	0.000466217	-0.023452696	3.12299E-05	0.007346166
0.85257202	0.384864847	0.023680172	0.386110067	0.001117519	-0.065771911	6.2339E-05	0.016068944
0.337897662	0.07273262	-0.059434419	-0.812723635	-0.002574518	0.06112339	-0.000259975	-0.0266823
-0.07273262	-0.015655728	-0.076488599	0.417005184	-0.009007976	0.405176902	-0.000589021	-0.0812667
		0.417005184	0.076488599	0.015880545	-0.793777223	0.001266562	0.056077313
		0.812723635	-0.059434419	0.034555028	0.428483476	0.003751436	0.415308407
		0.386110067	-0.023680172	-0.082301927	0.071799822	-0.005658287	-0.782238931
		-0.067372555	0.005611435	-0.071799822	-0.082301927	-0.015211732	0.434386056
		-0.041464937	0.001823209	0.428483476	-0.034555028	0.025082262	0.066627474
		0.016387336	-0.000720549	0.793777223	0.015880545	0.039334427	-0.096220442
				0.405176902	0.009007976	-9.62E-02	-3.93E-02
				-0.06112339	-0.002574518	-6.66E-02	2.51E-02
				-0.065771911	-0.001117519	0.434386056	0.015211732
				0.023452696	0.000466217	0.782238931	-0.005658287
				0.007782596	7.10E-05	0.415308407	-0.003751436
				-0.003793513	-3.46E-05	-0.056077313	0.001266562
						-0.0812667	0.000589021
						0.0266823	-0.000259975
						0.016068944	-6.2339E-05
						-0.007346166	3.12299E-05
						-0.001629492	3.25968E-06
						0.000892314	-1.78499E-06
Coif5							
Scale	Scale ( ต่อ )	Scale ( ต่อ )	Wavelet	Wavelet ( ต่อ )	Wavelet ( ต่อ )		
-9.52E-08	2.43E-03	4.22E-01	0.000212081	-0.774289604	0.001662864		
-1.67E-07	6.76E-03	-5.20E-02	0.00035859	0.437991626	-0.000638131		
2.06376E-06	-0.009164231	-0.091920011	-0.002178236	0.062035964	-0.00030226		
3.73466E-06	-0.019761779	0.028168029	-0.004159359	-0.105574209	0.000140541		
-2.1315E-05	0.032683574	0.023408157	0.010131118	-0.041289209	4.13404E-05		
-4.134E-05	0.041289209	-0.010131118	0.023408157	0.032683574	-2.1315E-05		
0.000140541	-0.105574209	-0.004159359	-0.028168029	0.019761779	-3.73466E-06		
0.00030226	-0.062035964	0.002178236	-0.091920011	-0.009164231	2.06376E-06		
-0.00063813	0.437991626	0.00035859	5.20E-02	-6.76E-03	1.67E-07		
-0.00166286	0.774289604	-0.000212081	4.22E-01	2.43E-03	-9.52E-08		

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**ตารางที่ ก.4** ค่าสัมประสิทธิ์สเกลของฟังก์ชัน Biorthogonal Wavelet ตั้งแต่ Bior1.1 - Bior6.8

Bior1.1		Bior1.3		Bior1.5		Bior2.2	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0.707106781	-0.707106781	-0.088388348	0	0.016572815	0	0	0
0.707106781	0.707106781	0.088388348	0	-0.016572815	0	-0.176776695	0.353553391
		0.707106781	-0.707106781	-0.121533978	0	0.353553391	-0.707106781
		0.707106781	0.707106781	0.121533978	0	1.060660172	0.353553391
		0.088388348	0	0.707106781	-0.707106781	0.353553391	0
		-0.088388348	0	0.707106781	0.707106781	-0.176776695	0
				0.121533978	0		
				-0.121533978	0		
				-0.016572815	0		
				0.016572815	0		
Bior2.4		Bior2.6		Bior2.8		Bior3.1	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0	0	0	0	0	0	-0.353553391	-0.176776695
0.03314563	0	-0.00690534	0	0.001510543	0	1.060660172	0.530330086
-0.06629126	0	0.013810679	0	-0.003021086	0	1.060660172	-0.530330086
-0.1767767	0.353553391	0.04695631	0	-0.012947512	0	-0.353553391	0.176776695
0.419844651	-0.707106781	-0.107723299	0	0.02891611	0		
0.994368911	0.353553391	-0.169871356	0.353553391	0.052998482	0		
0.419844651	0	0.44746601	-0.707106781	-0.134913074	0		
-0.1767767	0	0.966747552	0.353553391	-0.163829183	0.353553391		
-0.06629126	0	0.44746601	0	0.46257144	-0.707106781		
0.03314563	0	-0.169871356	0	0.951642122	0.353553391		
		-0.107723299	0	0.46257144	0		
		0.04695631	0	-0.163829183	0		
		0.013810679	0	-0.134913074	0		
		-0.00690534	0	0.052998482	0		
				0.02891611	0		
				-0.012947512	0		
				-0.003021086	0		
				0.001510543	0		

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.4 ( ต่อ )

Bior3.3		Bior3.5		Bior3.7		Bior3.9	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0.066291261	0	-0.013810679	0	0.003021086	0	-0.000679744	0
-0.19887378	0	0.041432038	0	-0.009063258	0	0.002039233	0
-0.15467961	-0.176776695	0.052480581	0	-0.016831765	0	0.005060319	0
0.994368911	0.530330086	-0.267927179	0	0.074663985	0	-0.020618913	0
0.994368911	-0.530330086	-0.071815532	-0.176776695	0.031332979	0	-0.014112788	0
-0.15467961	0.176776695	0.966747552	0.530330086	-0.301159126	0	0.099134782	0
-0.19887378	0	0.966747552	-0.530330086	-0.026499241	-0.176776695	0.012300136	0
0.066291261	0	-0.071815532	0.176776695	0.951642122	0.530330086	-0.320191968	0
		-0.267927179	0	0.951642122	-0.530330086	0.002050023	-0.176776695
		0.052480581	0	-0.026499241	0.176776695	0.942125701	0.530330086
		0.041432038	0	-0.301159126	0	0.942125701	-0.530330086
		-0.013810679	0	0.031332979	0	0.002050023	0.176776695
				0.074663985	0	-0.320191968	0
				-0.016831765	0	0.012300136	0
				-0.009063258	0	0.099134782	0
				0.003021086	0	-0.014112788	0
						-0.020618913	0
						0.005060319	0
						0.002039233	0
						-0.000679744	0

ตารางที่ ก.4 ( ต่อ )

Bior4.4		Bior5.5		Bior6.8	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0	0	0	-0.013456709	0	0
0.037828456	-0.064538883	0	-0.002694967	0.001908832	0
-0.02384947	0.040689418	0.039687088	0.136706585	-0.001914286	0
-0.1106244	0.418092273	0.007948109	-0.093504697	-0.01699064	0.014426283
0.377402856	-0.788485616	-0.054463788	-0.476803266	0.011934565	-0.014467505
0.852698679	0.418092273	0.345605282	0.89950611	0.049732903	-0.078722001
0.377402856	0.040689418	0.736660181	-0.476803266	-0.077263173	0.040367979
-0.1106244	-0.064538883	0.345605282	-0.093504697	-0.094059203	0.417849109
-0.02384947	0	-0.054463788	0.136706585	0.420796285	-0.758907729
0.037828456	0	0.007948109	-0.002694967	0.825922997	0.417849109
		0.039687088	-0.013456709	0.420796285	0.040367979
		0	0	-0.094059203	-0.078722001
				-0.077263173	-0.014467505
				0.049732903	0.014426283
				0.011934565	0
				-0.01699064	0
				-0.001914286	0
				0.001908832	0

ภาคผนวก ข  
ผลงานวิจัยที่ได้รับการตีพิมพ์

1. Benjawan Prapochanang, Thursdak Leauhatong and Nitipat Nattaitanakul, **“A Novel Dimension Reduction Technique for Physical Activity Recognition from a Waist-Mounted Accelerometer”**, The 4th IIAE International Conference on Industrial Application Engineering 2016 (ICIAE2016), B-Con Plaza, Beppu, Japan, pp.532-536, March 26-30, 2016.





เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

GS16	Industrial Application Technology 2	March 29
Room 32		13:00-14:20
Chair	Chun-Rong Huang, National Chung Hsing University, Taiwan	
GS16-1	<b>Optimization of Sparse Recovery Based on Recursive Unbiased Predictive Risk Estimate</b> Feng Xue Peng Liu Jiaqi Liu	National Key Laboratory of Science and Technology on Test Physics and Numerical Mathematics, China National Key Laboratory of Science and Technology on Test Physics and Numerical Mathematics, China National Key Laboratory of Science and Technology on Test Physics and Numerical Mathematics, China
GS16-2	<b>Simulation of Sugar Cane Harvesting and Transportation in Nakhon Sawan, Thailand</b> Pimpiwat Vilailuck Kanchana Sethanan Karn Moonstri	Khon Kaen University, Thailand Khon Kaen University, Thailand Khon Kaen University, Thailand
GS16-3	<b>Differential Evolution Algorithm for House Size Determination In a Poultry Production</b> Puripat Sriputhimeth Kanchana Sethanan Karn Moonstri	Khon Kaen University, Thailand Khon Kaen University, Thailand Khon Kaen University, Thailand
GS16-4	<b>Trajectory Clustering Using Affinity Propagation with Trajectory Entropy Descriptor</b> Wei-Cheng Wang Chih-Li Chang Wei-An Wang Chun-Rong Huang Wei-Yun Huang	National Cheng Kung University, Taiwan National Chung Hsing University, Taiwan National Chung Hsing University, Taiwan National Chung Hsing University, Taiwan National Chung Hsing University, Taiwan
GS17	Industrial Application Technology 3	March 29
Room 33		13:00-14:20
Chair	Akira Yamawaki, Kyushu Institute of Technology, Japan	
GS17-1	<b>A Novel Dimension Reduction Technique for Physical Activity Recognition from a Waist-Mounted Accelerometer</b> Benjawan Prapochanang Thurdsak Leuchitong Nhitap Nattatamkul	King Mongkut's Institute of Technology Ladkrabang, Thailand King Mongkut's Institute of Technology Ladkrabang, Thailand King Mongkut's Institute of Technology Ladkrabang, Thailand
GS17-2	<b>Wireless Control of Bubble Display with Android Terminal</b> Shogo Maeda Kohei Hada Masahumi Hayashibara Eikou Gonda Hitoshi Miyata	National Institute of Technology, Yonago College, Japan National Institute of Technology, Yonago College, Japan National Institute of Technology, Yonago College, Japan National Institute of Technology, Yonago College, Japan National Institute of Technology, Yonago College, Japan
GS17-3	<b>Luminescence properties of Sm<sup>3+</sup>-doped borosilicate glasses</b> Nattapon Srisittipokakun J. Kaewkhao	Nakhon Pathom Rajabhat University, Thailand Nakhon Pathom Rajabhat University, Thailand
GS17-4	<b>Luminescence Properties of Dy<sup>3+</sup>-doped Lutetium-Calcium-Silico-Borate Glasses for White Light Emitting Applications</b> Keechai Kirdsiri Jakrapong Kaewkhao Hong Joa Kim	Nakhon Pathom Rajabhat University, Thailand Nakhon Pathom Rajabhat University, Thailand Department of Physics, Kyungpook National University, Korea

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## A Novel Dimension Reduction Technique for Physical Activity Recognition from a Waist-Mounted Accelerometer

Benjawan Prapochanang<sup>a,\*</sup>, Thursak Leauhatong<sup>a</sup>, Nitipat Nattaitanakul<sup>a</sup>

<sup>a</sup>Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok and 10520, Thailand

\*Corresponding Author: benjawan\_0407@hotmail.com and s5612705@kmitl.ac.th

### Abstract

This paper proposes a novel dimension reduction technique for physical activity recognition from a waist-mounted accelerometer. Firstly, the wavelet transform is used to extract features from the acceleration signals. Then the proposed technique is used to reduce the dimension of the wavelet features. Finally, the Multi-Layer Perception Neural Network (MLPNN) is used to recognize the physical activities from the reduced features. In our experiments, 5 volunteers who were healthy with the ages between 21 to 25 year old were asked to mount a tri-axial accelerometer at the right side of their waists. Next, the volunteers were asked to perform 5 daily-life physical activities: 1) walking 2) standing up from a chair 3) sitting down on a chair 4) lying down on a bed and 5) getting up from a bed; and 5 falling events: 1) forward fall, 2) backward fall 3) falling to the right side 4) falling to the left side and 5) falling when standing up. In order to evaluate the performance of the proposed algorithm, the precision of the recognition and the total number of the used operators were used. The performance of the recognition with different setting of mother wavelets, vanishing moments, the rate of the dimension reduction, and the number of nodes of the hidden layer were evaluated. From the experiments, the proposed dimension reduction not only reduce the total number of the used operators but also increase the precision of the recognition.

**Keywords:** physical activity recognition, wavelet transform, dimension reduction, neural network.

### 1. Introduction

From the report of World Population Ageing<sup>(1)</sup>, the number of elderly people have been increasing. Falls are their most dangerous problem which causes hip fractures, disabilities, or accidental deaths. For example in USA from 1999 to 2010, the elderly mortalities due to fall-related injuries were reached up to 186,029<sup>(2)</sup>. The falls may be resulted from 2 major causes: 1) physical problems, such as knee surgery, degenerative arthritis, hypertension, or heart disease; and 2) environment problems, such as floor slippery or rough, and level or slope path. In order to reduce the rate of the mortalities or injuries, a system which can

predict or detect the falls efficiently and accurately has to be developed.

From the advances of miniature technologies, inertia wearable sensors such as accelerometers and gyroscopes are widely used to monitor human movements in daily life. Their advantages are cost efficiency, light weight, small size, low power consumption, and convenience in the independent living environment<sup>(3)</sup>. Many researchers have developed algorithms to distinguish daily-life activities from falling events. For example, Y. Li, et al.<sup>(4)</sup> proposed the fall detection method based on Neyman-Pearson detection framework. From the experimental results, the performances obtained by the training data and testing data show a good matching.

In this paper, we proposed an algorithm for physical activity recognition from a waist-mounted accelerometer. The algorithm consists of 3 steps: 1) wavelet transform, 2) the proposed dimension reduction, and 3) physical activity recognition.

### 2. The Signal Acquisition Device

Our signal acquisition device consists of a tri-axial accelerometer (MMA7331L) and a microcontroller with a 10-bit analog-to-digital convertor. The device is mounted to the right side of the waist of the volunteer subjects, and the orientation of the three axes is arranged as shown in Fig. 1.



Fig. 1. The orientation of the three axes of the accelerometer.

From our observations, the frequency range of the acceleration signals of all physical activities and falling events were from 4 to 100 Hz. As a result, the sampling rate of three acceleration signals are set to 200 Hz. According to the experiments of Sengto and Leauhatong<sup>(5)</sup>, a full-scaled

affection of the accelerometer is set to  $\pm 4G$  (where  $G$  represents acceleration due to gravity;  $9.81 \text{ m/s}^2$ ).

From our observations, all of the falling signals can be separated into three parts. The first part is the acceleration signals of some activities that cause the fall such as slip, stumble, sway, and etc. Usually, this part takes one second. The second part is the acceleration signals that is occurred when some parts of body, such as hand, hip, knee, or head, impact the ground. Since the impacts usually cause rapid change of the acceleration of the body, most of the impact signals have one or two peaks within 100-200 millisecond. The third part is the signals of some activities that occur after the impact such as roll or bounce of the body. This part usually takes less than one second. Then we assume that most of the falling activities take 2 seconds.




Fig. 2. An example of the acceleration signals of vertical -, sagittal horizontal -, and frontal horizontal - axes of a forward falling.

According to the aforementioned, the lengths of three acceleration signals are set to 416 samples. Then the total number of the samples used in the proposed algorithm is 1248 samples. An example of the acceleration signal of vertical -, sagittal horizontal -, and frontal horizontal - axes of a forward falling are shown in Fig.2.

### 3. The Physical Activities Recognition

The recognition can be separated into three processes; 1) feature extraction, 2) dimension reduction, and 3) activity recognition. The details of three processes are described as follows.

#### 3.1 The Wavelet Feature Extraction

In the wavelet transform theory<sup>(6,7)</sup>, a signal can be constructed from its approximation and details as follows:

$$x(t) = \sum_{k=0}^{2^j-1} a_{j,k} 2^{-\frac{j}{2}} \phi(2^{-j}t-k) + \sum_{l=1}^j \sum_{k=0}^{2^{j-l}-1} d_{j,l,k} 2^{-\frac{j-l}{2}} \psi(2^{-l}t-k), \tag{1}$$

where  $\phi$  and  $\psi$  are scaling and wavelet functions respectively.  $a$  and  $d$  are approximate and detailed coefficients of  $\phi$  and  $\psi$  functions respectively.  $j$  and  $k$  are integer values which represent dilation and translation

parameters of the transform.  $a$  and  $d$  coefficients can be calculated as follows:

$$a_{j,k} = \langle x(t), \phi_{j,k}(t) \rangle = \sum_n h(n-2k) a_{j-1,n}, \tag{2}$$

$$d_{j,k} = \langle x(t), \psi_{j,k}(t) \rangle = \sum_n g(n-2k) a_{j-1,n}, \tag{3}$$

where  $h(n)$  is the low-pass filter of scaling function, and  $g(n)$  is the high-pass filter of wavelet function. These filters are constructed from the selected wavelet function and its corresponding scaling function as follows:

$$\phi_{j,k} = \sqrt{2} \sum_n h(n) \phi(2t-n), \tag{4}$$

$$\psi_{j,k}(t) = \sqrt{2} \sum_n g(n) \phi(2t-n). \tag{5}$$

Table 1. Properties of different mother wavelets.

WAVELET FAMILY	FILTER LENGTH
Daubechies (db-N)	2N
Coiflets (coif-N)	6N
Symlets (sym-N)	2N
Biorhogonal (bior-Nr-Nd)	max(2Nr, 2Nd)+2

The wavelet coefficients can be used as efficient features; however in order to extract the efficient wavelet features, the mother wavelets and their number of vanishing moments<sup>(8,9)</sup> must be carefully selected. The number of the vanishing moments relates to the order of function that can be approximated by corresponding wavelet. For the analysis of highly transient signals with high complexity, wavelets with more vanishing moments are more suitable as they result in a more compact representation of the signals. The vanishing moments linearly relate to the filter length. Table 1. shows the relation between the filter length and the vanishing moments of the mother wavelets used in this paper, where  $N$  is the number of vanishing moments.

#### 3.2 The Proposed Dimension Reduction

In our experiments, the number of the wavelet features are very large (1248 coefficients), but the number of the training acceleration signals are very small (750 signals). As a result, they lead to two well-known problems called the curse of dimensionality (COD) and the small sampling size (SSS) problem<sup>(10,11)</sup>. In order to improve both of the accuracy and the time complexity, a dimension reduction method must be used. However, most of dimension reduction techniques such as principal component analysis and linear discriminant analysis cannot be used in the SSS problem. Inspired by the LDA<sup>(12)</sup>, this paper proposed a novel technique that can solve both problems. The proposed technique can be described as follows.

Let  $a_1$ ,  $a_2$ , and  $a_j$  be column matrices of the approximate coefficients of the 1-level decomposition of

the vertical-, sagittal horizontal-, and frontal horizontal-axes of an acceleration signal respectively. Let  $d_v$ ,  $d_s$ , and  $d_f$  be column matrices of the detailed coefficients of the 1-level decomposition of the vertical-, sagittal horizontal-, and frontal horizontal-axes of an acceleration signal respectively. Since the number of samples of each axis of the acceleration signals is 416, then the number of coefficients of  $a_v$ ,  $a_s$ ,  $a_f$ ,  $d_v$ ,  $d_s$ , and  $d_f$  are 208.

Let  $r$  be the down sampling ratio. Approximation and detailed column matrices of the  $r$  down sampling at the  $i^{\text{th}}$  position can be described as follows:

$$a_{A_{v,r,i}} = [a_{A_v}(i), a_{A_v}(r+i), a_{A_v}(2r+i), \dots]^T, \quad (6)$$

$$d_{A_{v,r,i}} = [d_{A_v}(i), d_{A_v}(r+i), d_{A_v}(2r+i), \dots]^T \quad (7)$$

where  $A_v \in \{v, s, f\}$ , and  $i \in \{0, 1, \dots, r-1\}$ . As a result for a given  $r$ , the number of the down sampling approximation and detailed matrices is  $2 \times 3 \times r$ , and their dimensions are  $208/r$ .

Given  $A_v$ ,  $r$ , and  $i$ , let  $A_{A_{v,r,i}}$  and  $D_{A_{v,r,i}}$  be respectively the sets of the down sampling approximation and detailed matrices of the  $c^{\text{th}}$  activity. The mean matrices of  $A_{A_{v,r,i}}$  and  $D_{A_{v,r,i}}$  can be calculated as follows:

$$\bar{a}_{A_{v,r,i}} = \frac{1}{n_c} \sum_{A_{A_{v,r,i}} \in A_{A_{v,r,i}}} a_{A_{v,r,i}} \quad (8)$$

$$\bar{d}_{A_{v,r,i}} = \frac{1}{n_c} \sum_{D_{A_{v,r,i}} \in D_{A_{v,r,i}}} d_{A_{v,r,i}} \quad (9)$$

where  $n_c$  is the number of the training acceleration signals of the  $c^{\text{th}}$  activity.

Given  $r$  and  $c$ , the error matrices of the down sampling approximation and detailed matrices can be formulated as follows:

$$E_{v,r} = [\hat{a}_{v,r,0,c}, \dots, \hat{a}_{v,r,r-1,c}, \hat{d}_{v,r,0,c}, \dots, \hat{d}_{v,r,r-1,c}], \quad (10)$$

where

$$\hat{a}_{v,r,i,c} = (a_{A_{v,r,i}} - \bar{a}_{A_{v,r,i}}), \quad (11)$$

$$\hat{d}_{v,r,i,c} = (d_{A_{v,r,i}} - \bar{d}_{A_{v,r,i}}), \quad (12)$$

where  $a_{A_{v,r,i}} \in A_{A_{v,r,i}}$  and  $d_{A_{v,r,i}} \in D_{A_{v,r,i}}$ .

The within-class variance scatter can be calculated as follows:

$$V_r^w = \sum_c n_c \Gamma_c^T E_{v,r} E_{v,r}^T \quad (13)$$

Let  $N$  be the total number of the training acceleration signals. The mean error matrices of the down sampling approximation and detailed matrices can be formulated as follows:

$$\bar{E}_{v,r} = [\bar{\hat{a}}_{v,r,0,c}, \dots, \bar{\hat{a}}_{v,r,r-1,c}, \bar{\hat{d}}_{v,r,0,c}, \dots, \bar{\hat{d}}_{v,r,r-1,c}], \quad (14)$$

where

$$\bar{\hat{a}}_{v,r,i,c} = \bar{a}_{A_{v,r,i}} - \frac{1}{N} \sum_{A_{A_{v,r,i}}} a_{A_{v,r,i}}, \quad (15)$$

$$\bar{\hat{d}}_{v,r,i,c} = \bar{d}_{A_{v,r,i}} - \frac{1}{N} \sum_{D_{A_{v,r,i}}} d_{A_{v,r,i}}, \quad (16)$$

and the between-class variance scatter can be calculated as follows:

$$V_r^b = \sum_c n_c \bar{E}_{v,r}^T \bar{E}_{v,r} \quad (17)$$

The proposed dimension reduction technique is to find the new projection  $w$  that maximization the criteria

$$J(w) = \frac{w^T V_r^b w}{w^T V_r^w w} \quad (18)$$

As a result,  $w$  is the eigenvector of the problem

$$\det((V_r^w)^{-1} V_r^b - \lambda I) = 0. \quad (19)$$

The output of the proposed dimension reduction technique can be calculated as follows:

$$F_r = A_r W, \quad (20)$$

where  $A_r = [a_{v,r,0,c}, \dots, a_{v,r,r-1,c}, d_{v,r,0,c}, \dots, d_{v,r,r-1,c}]$  is the input matrix of the down sampling approximation and detailed coefficients of the test acceleration signals.  $W = [w_1, w_2, w_3]$  is the matrix of the first three eigenvector.  $F_r = [f_{r,1}, f_{r,2}, f_{r,3}]$  is the output matrix of the proposed dimension reduction. Since the number of the columns of  $A_r$  and  $F_r$  are  $2 \times 3 \times r$  and 3 respectively, the dimension reduction ratio equals to  $2r$ .

### 3.3 Activity Recognition

The MLPNN<sup>[13]</sup> is used to recognize the activities. The used network consists of the input, hidden, and output layers. The activation function of the neurons are the log sigmoid,  $f(x) = 1/(1 + \exp(-x))$ . The network was trained by the back propagation algorithm.

The wavelet features whose dimension are reduced by the proposed dimension reduction algorithm are fed to the

input layer. Then the number of the neurons in the input layer equals to the reduced dimension. The number of the neurons in the hidden layer is defined by experiments (see in Section 4). The number of the neurons of the output layer depends on the objective of the recognition.

**4. The Performance Evaluation**

The performance of the proposed algorithm depends on its 4 factors; 1) the mother wavelets, 2) the vanishing moments (the filter length), 3) the dimension reduction ratio, and 4) the number of neurons in the hidden layer. Table 2. shows all of the selected setting of the factors used in this paper.

Table 2. The selected setting of the factors.

Factors	Selected Setting
Wavelets and Vanishing Moments	'db2', 'db4', 'db6', ..., 'db20', 'coif1', ..., 'coif5', 'sym2', 'sym3', ..., 'sym9', 'bior1.1', 'bior1.3', 'bior1.5', 'bior2.2', 'bior2.4', 'bior2.6', 'bior2.8', 'bior3.1', 'bior3.3', 'bior3.5', 'bior3.7', 'bior3.9', 'bior4.4', 'bior5.5', and 'bior6.8'
The dimension reduction ratio	4, 8, and 16
Neurons in hidden layer	1, 2, 3, ..., and 40

The ideal system must provide high accuracy and require low time complexity. However in practical, one has to trade the accuracy for the complexity. In this paper, percent of the average precision ( $\%Pr$ )<sup>(14)</sup> and percent of the used operators ( $\%Op$ ) are used to measure the accuracy and time complexity respectively. Moreover, we proposed a new measurement ( $Pe$ ) to evaluate the performance of the proposed algorithm.

$\%Pr$  can be calculated as follows:

$$\%Pr = \frac{\sum_{c=1}^C \#TF_c}{\sum_{c=1}^C \#TF_c + \#FP_c} \times 100. \tag{21}$$

where  $C$  is the number of physical activity,  $\#TF_c$  is the number of the acceleration signals of the  $c^{th}$  activity which are recognized correctly, and  $\#FP_c$  is the number of the acceleration signals which are recognized to be the  $c^{th}$  activity incorrectly.

The total number of plus and multiply operators used in the wavelet transform, the dimension reduction, and the MLPNN is used to measure the time complexity. Let  $l_x$ ,  $l_y$ ,  $h$ , and  $t$  denote the number of the input signal (1248), the filter length, the number of hidden nodes, and output nodes respectively. The number of the operators used in the wavelet transform equals to  $4 \times l_x \times l_y$ . The number of the operators used in the proposed dimension reduction equals to  $3 \times l_x$ . The number of the operators used in the MLPNN

equals to  $2(l_x/2r \times h + h \times t)$ . Let  $\#Op_{max}$  denote the number of operators used in the combination that have the maximum operators.  $\%Op$  can be calculated as follows:

$$\%Op = \frac{4 \times l_x \times l_y + 3 \times l_x + 2(l_x/2r \times h + h \times t)}{\#Op_{max}} \times 100. \tag{22}$$

$Pe$  is the distance from the point of  $\%Pr=100$  and  $\%Op=0$  to the point of  $\%Pr$  and  $\%Op$  of the evaluated combination. The lower  $Pe$  means the higher performance.  $Pe$  can be calculated as follows:

$$Pe = \sqrt{(100 - \%Pr)^2 + (\%Op)^2}. \tag{23}$$

**5. The Experiments**

5 volunteers who were healthy with the ages between 21 to 25 year old were asked to attach the acquisition device at the right side of their waists as shown in Fig. 1. Next, all of the volunteers were asked to perform 5 daily-life activities: 1) walking 2) standing up from a chair 3) sitting down on a chair 4) lying down on a bed and 5) getting up from a bed; and 5 falling events: 1) falling forward 2) falling backward 3) falling to the right side 4) falling to the left side and 5) falling while standing up. Each volunteer was asked to perform each activity 30 times. Then the total number of the acceleration signals of each activity is 150 times. Next, 15 acceleration signals of each activity from each volunteer were randomly selected to calculate  $W$  of the proposed dimension reduction and to train the MLPNN, and the remaining signals were used to test the performance.

The results of the physical activity experiment are shown in Table 3. Since all of the combinations of the 4 factors are very large, Table 3. only shows the filter lengths, number of the hidden nodes,  $\%Pr$ ,  $\%Op$ , and  $Pe$  of the combinations which have smallest  $Pe$  for the given mother wavelets and dimension reduction ratios. Moreover in order to compare the results of the proposed dimension reduction, the results of the physical activity recognition which does not use the dimension reduction (n/a) are also shown in Table 3. Also, the combination which has the largest  $\%Pr$  is shown at the last row of Table 3.

As shown in Table 3., the proposed dimension reduction not only reduced the  $\%Op$  but also increased the  $\%Pr$ . Moreover, the optimal combination which has the smallest  $Pe$  was the Biorthogonal wavelet whose filter length is 2, the proposed dimension reduction whose ratio is 16, and the MLPNN whose number of hidden nodes is 40. The  $\%Pr$  and  $\%Op$  of the optimal combination were 91.791% and 5.446% respectively. The  $\%Pr$  and  $\%Op$  of the largest  $\%Pr$  combination were 95.124% and 18.971% respectively. As a result, the optimal combination has the better trade-off between the accuracy and time complexity.

Table 3. The summary of the physical activity recognition.

Mother Wavelet	Dimension Reduction Ratio	Filter Length	#Node of Hidden Layer	%Pr	%Op	Pe
Daubechies	n/a	4	26	78.517	18.971	28.661
	4	8	28	91.711	14.543	16.740
	8	4	38	91.125	8.903	12.571
	16	8	38	87.777	13.023	17.145
Coiflet	n/a	12	22	79.339	25.608	32.903
	4	6	34	90.053	13.183	16.515
	8	6	30	92.479	10.531	12.941
	16	6	36	78.161	9.726	23.907
Symlet	n/a	4	30	81.718	21.207	28.000
	4	4	30	91.149	10.393	13.651
	8	4	34	92.631	8.608	11.331
	16	4	40	92.309	7.664	10.858
Biorthogonal	n/a	6	32	88.835	24.543	26.963
	4	2	30	93.369	8.175	10.526
	8	2	36	91.492	6.538	10.73
	16	2	40	91.791	5.446	9.851
Biorthogonal	16	18	30	95.124	22.801	23.317

Note that: n/a = do not use the proposed dimension reduction.

6. Conclusions and Future Works

An efficient physical activity recognition was studied in this paper. The contribution of this paper is twofold. Firstly, this paper proposed a novel dimension reduction technique. The proposed technique not only increase the accuracy of the recognition but also reduce the time complexity. Secondly, this paper carefully studied the combination between the mother wavelets, the filter lengths of the mother wavelet, the dimension reduction ratios, and the number of the nodes in the hidden layer for searching the optimal combination.

In the future works, the additional physical activities such as walking upstairs/downstairs, turning left/right, and 180 degree turning would be experimented. Moreover, the recognition system with the proposed dimension reduction technique would be applied to recognize the physical activities and the falling events of elderly people.

References

(1) United Nations, Department of Economic and Social Affairs, Population Division : "World Population Ageing 2013", United Nations publication, pp. 8-11, 2013

(2) Centers for Disease Control and Prevention, National Center for Injury Prevention and Control, 2013. Web-based Injury Statistics Query and Reporting System (WISQARS). Available at: <http://webappa.cdc.gov/> [Accessed March 4, 2013]

(3) Davide Curone, Gian M. Bertolotti, Andrea Cristiani, Emanuele L. Secco, and Giovanni Magenes : "A Real-Time and Self-Calibrating Algorithm Based on Triaxial Accelerometer Signals for the Detection of Human Posture and Activity". IEEE Transactions on Information Technology in Biomedicine, Vol. 14, No. 4, pp. 1098-1105, 2010

(4) Yanjun Li, Gan Chen, Yueyun Shen, Yihua Zhu, and Zhen Cheng : "Accelerometer-Based Fall Detection Sensor System for The Elderly", Cloud Computing

and Intelligent Systems (CCIS), 2012 IEEE 2nd International Conference on, Vol. 3, pp. 1216-1220, 2012

(5) Songto A. and Leauhatong T. : "Human falling detection algorithm using back propagation neural network", Biomedical Engineering International Conference (BMEICON2012), pp. 1-5, 2012

(6) Chun-Lin and Liu : "A Tutorial of the Wavelet Transform", February 2010

(7) A. Phinyomark1, C. Limsakul, and P. Phukpattaranont : "Application of Wavelet Analysis in EMG Feature Extraction for Pattern Classification", Measurement Science Review, Vol. 11, No. 2, pp. 45-52, 2011

(8) Salem and M.A.-M. : "On the selection of the proper wavelet for moving object detection", Computer Engineering & Systems (ICCES), 2011 International Conference on, pp. 207-212, 2011

(9) S. Patilulkarni, PhD. Ll, and H C Vijay Lakshmi. : "Vanishing Moments of a Wavelet System and Feature Set in Face Detection Problem for Color Images". International Journal of Computer Applications, Vol. 66, No. 16, pp. 0975 – 8887, 2013

(10) A. J. Jain, R. P. W. Duin, and J. Mao : "Statistical pattern recognition: A review." IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 22, No. 1, pp. 4-37, 2000

(11) Wuyi Yang : "Regularized Complete Linear Discriminant Analysis for Small Sample Size Problems", ICIC 2012, CCIS 304, pp. 67-73, 2012

(12) YP Chen, JY Yang, SN Liou, GY Lee, and JS Wang : "Online classifier construction algorithm for human activity detection using a tri-axial accelerometer". Applied Mathematics Computation 205(2), pp. 849-860, 2008

(13) Ercan Ozgan : "Artificial neural network based modelling of the Marshall Stability of asphalt concrete", Expert Systems with Applications 38 (2011), pp. 6025-6030, 2011

(14) Bendi Venkata Ramana, Prof. M.Surendra Prasad Babu, and Prof. N. B. Venkateswari : "A Critical Study of Selected Classification Algorithms for Liver Disease Diagnosis", International Journal of Database Management Systems ( IJDBMS ), Vol.3, No.2, 2011

## ประวัติผู้เขียน

ชื่อ-นามสกุล นางสาวเบญจวรรณ ประไพ์ชนัง  
วัน เดือน ปีเกิด 4 กรกฎาคม 2532  
ที่อยู่ 1089 หมู่ 1 ตำบลเทพารักษ์ อำเภอเมือง จังหวัดสมุทรปราการ  
10270 Email : benjawan\_0407@hotmail.com  
ประวัติการศึกษา ปีพ.ศ. 2554 จบการศึกษาระดับปริญญาตรี สาขาวิชาอิเล็กทรอนิกส์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้