




ระบบจำแนกท่าทางการนอนโดยใช้การเรียนรู้ของเครื่องจักร  
SLEEPING POSTURES CLASSIFICATION SYSTEM USING MACHINE LEARNING



พิศุทธิ พรปรีดาวรรณ

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2563

ระบบจำแนกท่าทางการนอนโดยใช้การเรียนรู้ของเครื่องจักร



ปริญญาานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมชีวการแพทย์  
คณะวิศวกรรมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ  
ปีการศึกษา 2563  
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

SLEEPING POSTURES CLASSIFICATION SYSTEM USING MACHINE LEARNING



PISUT PORNPREEDEAWAN

A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of MASTER OF ENGINEERING  
(M.Eng. (Biomedical Engineering))

Faculty of Engineering, Srinakharinwirot University

2020

Copyright of Srinakharinwirot University

ปริญญานิพนธ์

เรื่อง

ระบบจำแนกท่าทางการนอนโดยใช้การเรียนรู้ของเครื่องจักร

ของ

พิศุทธิ์ พรปรีดาวรรณ

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมชีวการแพทย์

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าปริญญานิพนธ์

ที่ปรึกษาหลัก

ประธาน

(ผู้ช่วยศาสตราจารย์ ดร.ดิเรก เสือสีนาค)

(รองศาสตราจารย์ ดร.ชูชาติ ปิณฑุรจน์)

ที่ปรึกษาร่วม

กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.สุชาดา ตันตีสถิระพงษ์)

(รองศาสตราจารย์ ดร.ทีฆพันธ์ เจริญพงษ์)

ชื่อเรื่อง	ระบบจำแนกท่าทางการนอนโดยใช้การเรียนรู้ของเครื่องจักร
ผู้วิจัย	พิศุทธิ พรปรีดาวรรณ
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
ปีการศึกษา	2563
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. ดิเรก เสือสีนาค
อาจารย์ที่ปรึกษาร่วม	ผู้ช่วยศาสตราจารย์ ดร. สุชาดา ต้นตีสถิระพงษ์

การนอนหลับเป็นกิจกรรมการพักผ่อนที่สำคัญในการดำเนินชีวิตประจำวันของมนุษย์ ในขณะเดียวกันท่าทางการนอนของมนุษย์สามารถใช้สำหรับการวินิจฉัยความผิดปกติทางการแพทย์และสามารถบ่งบอกถึงความเสี่ยงในการเกิดอุบัติเหตุที่อันตรายถึงชีวิตอย่างการพลัดตกจากเตียงได้ งานวิจัยนี้นำเสนอการพัฒนาาระบบจำแนกท่าทางการนอนจำนวน 5 ท่าทาง ได้แก่ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นิ่ง และนอนขอบเตียงด้วยการเรียนรู้ของเครื่องจักร ระบบที่พัฒนาประกอบไปด้วยเซ็นเซอร์วัดแรงกดจำนวน 100 ตัว วงจรขยายและปรับแต่งสัญญาณด้วยออปแอมป์ การแปลงสัญญาณอนาล็อกเป็นดิจิทัล การประมวลผลด้วยไมโครคอนโทรลเลอร์ และการจัดเก็บข้อมูลท่าทางการนอนด้วยโปรแกรม MATLAB เพื่อนำข้อมูลมาหาอัลกอริทึมที่เหมาะสมที่สุด ผลการวิจัยพบว่าการพัฒนาระบบจำแนกท่าทางการนอนด้วยอัลกอริทึม Coarse Gaussian SVM มีประสิทธิภาพความแม่นยำที่ดีที่สุดได้แก่ 97.9%, 92.4% และ 94.0% ด้วยชุดข้อมูลสำหรับฝึกสอน, ตรวจสอบ และทดสอบตามลำดับ ซึ่งงานวิจัยนี้มีจุดเด่นด้านการใช้เซ็นเซอร์ในจำนวนที่น้อย โดยยังคงความสามารถในการจำแนกท่าทางการนอนได้อย่างแม่นยำ และสามารถบอกท่าทางที่มีความเสี่ยงต่อการเกิดการพลัดตกจากเตียง เพื่อใช้สำหรับพัฒนาระบบแจ้งเตือนก่อนการพลัดตกจากเตียงต่อไปในอนาคต

คำสำคัญ : ท่าทางการนอน, พลัดตกจากเตียง, การเรียนรู้ของเครื่องจักร

Title	SLEEPING POSTURES CLASSIFICATION SYSTEM USING MACHINE LEARNING
Author	PISUT PORNPREEDEAWAN
Degree	MASTER OF ENGINEERING
Academic Year	2020
Thesis Advisor	Assistant Professor Dr. Direk Sueseenak
Co Advisor	Assistant Professor Dr. Suchada Tantisatirapong

Sleep is an important resting activity in the daily lives of human beings. In the same way, the human sleeping posture can be used to diagnose certain medical disorders and indicate the risk of fatal accidents for the elderly, such as falling out of bed. In this research, using machine learning, a sleeping posture classification system was developed to classify five sleeping postures: supine, left lateral sleeping position, right lateral sleeping position, sitting, and lying on the edge of the bed. This system consists of 100 pressure sensors, the circuit for amplifying and adjusting the signal with an op-amp, analog to digital conversion, microcontroller processing, and storing sleeping posture data with the MATLAB program. Several machine learning algorithms were compared to find the one that best appropriates the dataset. In this experiment, the best accuracy performances were achieved by the Coarse Gaussian SVM algorithm of 97.9%, 92.4%, and 94.0%, with training, validation, and testing, respectively. The highlight of this research was using a small number of pressure sensors while still being able to accurately classify sleeping postures and can indicate the risk of falling out of bed. To be used to develop the notification system before falling out of bed in the future.

Keyword : Sleeping posture, Falling out of bed, Machine learning

## กิตติกรรมประกาศ

งานวิจัยนี้เสร็จสมบูรณ์ได้ด้วยความกรุณาจาก รองศาสตราจารย์นายแพทย์ฉัตรชัย เอก  
ปัญญาสกุล คณบดีบัณฑิตวิทยาลัย

ขอขอบคุณ ผู้ช่วยศาสตราจารย์ ดร.ดิเรก เสือสีนาค ผู้ช่วยศาสตราจารย์ ดร.สุชาดา ตัน  
ติสธิระพงษ์ และคณะอาจารย์ทุกท่าน ที่ได้ให้คำแนะนำ คำปรึกษา และมอบความรู้ความสามารถ  
ในการดำเนินการวิจัยจนสำเร็จลุล่วง

ขอขอบคุณสำนักงานการวิจัยแห่งชาติ(วช.) และมหาวิทยาลัยศรีนครินทรวิโรฒ ผู้มอบทุน  
สนับสนุนงานวิจัยจนสำเร็จลุล่วง

ขอขอบคุณเจ้าหน้าที่ เพื่อนร่วมงาน ที่บัณฑิตวิทยาลัยสำหรับการช่วยเหลือในขั้นตอน  
ต่างๆและเป็นกำลังใจในการดำเนินการวิจัยจนสำเร็จลุล่วง


พิศุทธิ พรปรีดาวรรณ

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	ง
บทคัดย่อภาษาอังกฤษ .....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ .....	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ .....	ฎ
บทที่1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตงานวิจัย .....	3
บทที่2 ทฤษฎีและทบทวนวรรณกรรมที่เกี่ยวข้อง.....	4
2.1 ลักษณะท่าทางการนอน.....	4
2.1.1 ท่านอนหงาย .....	4
2.1.2 ท่านอนตะแคง .....	4
2.1.3 ท่านอนคว่ำ.....	4
2.2 การพลัดตก .....	5
2.3 วงจรเซ็นเซอร์ .....	5
2.3.1 วงจรขยายสัญญาณแบบกลับเฟส (INVERTING OP-AMP CIRCUIT) .....	5
2.3.2 วงจรขยายสัญญาณแบบไม่กลับเฟส (NON-INVERTING OP-AMP CIRCUIT).....	6
2.3.3 วงจรแบ่งแรงดัน (VOLTAGE DIVIDER).....	7
2.4 ขนาดมาตรฐานของเตียง.....	7

2.5 การเรียนรู้ของเครื่องจักร (Machine Learning).....	8
2.5.1 โครงข่ายประสาทเทียม (Neural Network) .....	8
2.5.2 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) .....	11
2.5.3 การเรียนรู้เพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbor: KNN).....	12
2.5.4 การเรียนรู้ต้นไม้ตัดสินใจ (Decision Tree).....	14
2.5.5 การวิเคราะห์จำแนกกลุ่ม (Discriminant Analysis) .....	15
2.5.6 การจำแนกของเบย์ (Naive Bayes Classification) .....	15
2.6 การทบทวนวรรณกรรมที่เกี่ยวข้อง (Literature Review) .....	16
บทที่3 วิธีการดำเนินงาน.....	20
3.1 การออกแบบระบบแจ้งเตือนการพลัดตกจากเตียง .....	20
3.2 การออกแบบระบบการวัดและบันทึกแรงกด.....	22
3.3 การติดตั้งเซ็นเซอร์.....	23
3.4 การเก็บข้อมูลการนอนจากกลุ่มตัวอย่าง.....	27
3.5 การออกแบบระบบจำแนกท่าทางการนอน.....	28
3.5.1 การเก็บข้อมูล (Data recording) .....	30
3.5.2 การเตรียมข้อมูล (Pre-processing) .....	31
3.5.3 การจำแนกข้อมูลด้วยการเรียนรู้ของเครื่องจักร .....	32
3.6 การตรวจสอบประสิทธิภาพของระบบ .....	37
บทที่4 ผลการดำเนินงาน .....	38
4.1 ผลการออกแบบระบบการวัดและบันทึกแรงกด .....	38
4.2 ผลการออกแบบแผ่นวงจรพิมพ์.....	38
4.3 ผลการติดตั้งเซ็นเซอร์.....	39
4.4 การแสดงผลจากเซ็นเซอร์.....	39

4.5 ผลการจำแนกข้อมูลด้วยการเรียนรู้ของเครื่องจักร .....	47
บทที่5 อภิปรายผล และสรุปผลการวิจัย .....	69
5.1 อภิปรายผล .....	69
5.2 สรุปผลการวิจัย.....	71
5.3 ข้อเสนอแนะ.....	72
บรรณานุกรม .....	74
ประวัติผู้เขียน.....	79



## สารบัญตาราง

หน้า

ตาราง 1 การเปรียบเทียบตัวอย่างงานวิจัยที่ถูกนำเสนอการจำแนกท่าทางการนอนด้วยประเภทอุปกรณ์สวมใส่ตัวแบบไม่สวมใส่ โดยกำหนดให้ $n/a$ คือ ไม่พบข้อมูล, $N_T$ คือ จำนวนกลุ่มตัวอย่าง และ $T_p$ คือ จำนวนชุดข้อมูล.....	19
ตาราง 2 คุณสมบัติของเซ็นเซอร์แรงกด .....	23
ตาราง 3 อายุ น้ำหนัก และส่วนสูงของกลุ่มตัวอย่าง จำนวน 30 คน .....	27
ตาราง 4 ตารางแสดงอัลกอริทึมที่ถูกเลือกใช้จาก Classification Learner .....	36
ตาราง 5 การเปรียบเทียบเซ็นเซอร์แรงกดด้วยค่า Root mean squared error และ Repeatability .....	38
ตาราง 6 การเปรียบเทียบการเรียนรู้ของเครื่องจักรทั้งหมดที่ถูกใช้ในการจำแนกท่าทางการนอน	66
ตาราง 7 การแสดงผลความแม่นยำของข้อมูลทดสอบและส่วนเบี่ยงเบนมาตรฐานของ Sensitivity .....	67
ตาราง 8 การแสดงผลความแม่นยำของข้อมูลทดสอบและส่วนเบี่ยงเบนมาตรฐานของ Precision .....	68
ตาราง 9 การเปรียบเทียบงานวิจัยนี้กับงานวิจัยก่อนหน้า .....	69

## สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 ตัวอย่างวงจรถยายสัญญาณแบบกลับเฟส (INVERTING OP-AMP CIRCUIT).....	6
ภาพประกอบ 2 ตัวอย่างวงจรถยายสัญญาณแบบไม่กลับเฟส (NON-INVERTING OP-AMP CIRCUIT) .....	6
ภาพประกอบ 3 ตัวอย่างวงจrab่งแรงดัน (VOLTAGE DIVIDER) .....	7
ภาพประกอบ 4 ตัวอย่างโครงสร้างของ Neural Network.....	10
ภาพประกอบ 5 หลักการสร้างโมเดลของ Neural Network .....	10
ภาพประกอบ 6 ตัวอย่างการแยกคลาสของ Support Vector Machine แบบ Linear .....	11
ภาพประกอบ 7 ตัวอย่างโมเดล K-Nearest Neighbor.....	13
ภาพประกอบ 8 ตัวอย่างโมเดล Decision Tree.....	14
ภาพประกอบ 9 ขั้นตอนการทำงานของระบบ .....	20
ภาพประกอบ 10 ขั้นตอนการทำงานของระบบแจ้งเตือนการพลัดตกจากเตียง.....	20
ภาพประกอบ 11 ขั้นตอนการออกแบบระบบการวัดและบันทึกแรงกด.....	22
ภาพประกอบ 12 Schematics diagram จากโปรแกรม Altium Designer ของระบบวัดแรงกด .	22
ภาพประกอบ 13 การออกแบบแผ่นวงจรพิมพ์แบบ CAD (ก) ด้านบน(Top layer) และ (ข) ด้านล่าง(Bottom layer).....	23
ภาพประกอบ 14 ตำแหน่งการติดตั้งเซ็นเซอร์แรงกด .....	24
ภาพประกอบ 15 ตัวอย่างการติดตั้งจุดรวมแรงบนเซ็นเซอร์แรงกด.....	25
ภาพประกอบ 16 การคลุมเซ็นเซอร์แรงกดด้วย Protective sheet.....	26
ภาพประกอบ 17 การคลุมชิ้นงานด้วยผ้าคลุมเตียงก่อนเริ่มเก็บข้อมูล .....	26
ภาพประกอบ 18 อุปกรณ์สำหรับนำส่งข้อมูลเข้าคอมพิวเตอร์ 10 port USB 3.0 hub .....	27
ภาพประกอบ 19 อุปกรณ์ป้องกันสำหรับกลุ่มตัวอย่าง .....	28

ภาพประกอบ 20 การทำงานของ Finite State Machine.....	29
ภาพประกอบ 21 ขั้นตอนการออกแบบระบบจำแนกท่าทางการนอน.....	29
ภาพประกอบ 22 ภาพตัวอย่างการเก็บข้อมูลจากกลุ่มตัวอย่าง.....	30
ภาพประกอบ 23 ตัวอย่างท่าทางการนอน (ก) นอนหงาย (ข) นอนตะแคงซ้าย (ค) นอนตะแคงขวา (ง) นิ่ง และ (จ) นอนชอบเตียง.....	31
ภาพประกอบ 24 ขั้นตอนการทำงานของเตรียมข้อมูล.....	32
ภาพประกอบ 25 การออกแบบโครงข่ายประสาทเทียม.....	33
ภาพประกอบ 26 หน้าต่างการตั้งค่าตัวแปรใน Classification Learner.....	35
ภาพประกอบ 27 หน้าต่าง toolbox model type สำหรับใช้เลือกอัลกอริทึม.....	36
ภาพประกอบ 28 ตัวอย่างตาราง Confusion matrix.....	37
ภาพประกอบ 29 แผ่นวงจรมิมพ์ (ก) ก่อนติดตั้งอุปกรณ์ (ข) หลังติดตั้งอุปกรณ์.....	38
ภาพประกอบ 30 การติดตั้งเซ็นเซอร์แรงกดบนแผ่นยางพารา.....	39
ภาพประกอบ 31 แผนภาพแรงกดท่านอนหงายจากกลุ่มตัวอย่างที่1.....	40
ภาพประกอบ 32 แผนภาพแรงกดท่านอนตะแคงซ้ายจากกลุ่มตัวอย่างที่1.....	40
ภาพประกอบ 33 แผนภาพแรงกดท่านอนตะแคงขวาจากกลุ่มตัวอย่างที่1.....	41
ภาพประกอบ 34 แผนภาพแรงกดท่านิ่งจากกลุ่มตัวอย่างที่1.....	41
ภาพประกอบ 35 แผนภาพแรงกดท่านอนชอบเตียงจากกลุ่มตัวอย่างที่1.....	42
ภาพประกอบ 36 แผนภาพแรงกดท่านอนหงายจากกลุ่มตัวอย่างที่2.....	42
ภาพประกอบ 37 แผนภาพแรงกดท่านอนตะแคงซ้ายจากกลุ่มตัวอย่างที่2.....	43
ภาพประกอบ 38 แผนภาพแรงกดท่านอนตะแคงขวาจากกลุ่มตัวอย่างที่2.....	43
ภาพประกอบ 39 แผนภาพแรงกดท่านิ่งจากกลุ่มตัวอย่างที่2.....	44
ภาพประกอบ 40 แผนภาพแรงกดท่านอนชอบเตียงจากกลุ่มตัวอย่างที่2.....	44
ภาพประกอบ 41 แผนภาพแรงกดท่านอนหงายจากกลุ่มตัวอย่างที่3.....	45

ภาพประกอบ 42 แผนภาพแรงกดทำนองบนตะแคงซ้ายจากกลุ่มตัวอย่างที่ 3 .....	45
ภาพประกอบ 43 แผนภาพแรงกดทำนองบนตะแคงขวาจากกลุ่มตัวอย่างที่ 3.....	46
ภาพประกอบ 44 แผนภาพแรงกดทำนองจากกลุ่มตัวอย่างที่ 3.....	46
ภาพประกอบ 45 แผนภาพแรงกดทำนองบนขอบตี้ยางจากกลุ่มตัวอย่างที่ 3 .....	47
ภาพประกอบ 46 Confusion matrix ของ Neural Network (Hidden layer 200 nodes) .....	48
ภาพประกอบ 47 Confusion matrix ของ Neural Network (Hidden layer 300 nodes) .....	49
ภาพประกอบ 48 Confusion matrix ของ Neural Network (Hidden layer 400 nodes) .....	50
ภาพประกอบ 49 Confusion matrix ของ Linear SVM .....	51
ภาพประกอบ 50 Confusion matrix ของ Quadratic SVM .....	52
ภาพประกอบ 51 Confusion matrix ของ Cubic SVM .....	53
ภาพประกอบ 52 Confusion matrix ของ Fine Gaussian SVM.....	54
ภาพประกอบ 53 Confusion matrix ของ Medium Gaussian SVM.....	55
ภาพประกอบ 54 Confusion matrix ของ Coarse Gaussian SVM .....	56
ภาพประกอบ 55 Confusion matrix ของ Fine KNN .....	57
ภาพประกอบ 56 Confusion matrix ของ Medium KNN.....	58
ภาพประกอบ 57 Confusion matrix ของ Coarse KNN .....	59
ภาพประกอบ 58 Confusion matrix ของ Cosine KNN.....	60
ภาพประกอบ 59 Confusion matrix ของ Weighted KNN .....	61
ภาพประกอบ 60 Confusion matrix ของ Fine Decision Tree .....	62
ภาพประกอบ 61 Confusion matrix ของ Linear Discriminant .....	63
ภาพประกอบ 62 Confusion matrix ของ Quadratic Discriminant .....	64
ภาพประกอบ 63 Confusion matrix ของ Gaussian Naive Bayes.....	65

## บทที่ 1

### บทนำ

#### 1.1 ที่มาและความสำคัญ

การนอนหลับเป็นอีกหนึ่งในกิจกรรมการพักผ่อนที่สำคัญที่สุดในการดำเนินชีวิตประจำวันของมนุษย์ เนื่องจากสามารถช่วยให้ร่างกายได้รับการซ่อมแซม สร้างระบบภูมิคุ้มกัน ลดระดับความเครียด และทำให้ระบบต่าง ๆ ในร่างกายทำงานในวันถัดไปได้เป็นอย่างดี ซึ่งท่าทางการนอนหลับของมนุษย์สามารถเป็นประโยชน์ต่อการวินิจฉัยความผิดปกติในทางการแพทย์บางประเภทได้(1) เช่น ภาวะหยุดหายใจขณะหลับ(2) อาการแผลกดทับ(1, 3) อาการนอนกรน อาการกรดไหลย้อน หรือ ตรวจสอบคุณภาพการนอนหลับ(4) ที่แสดงถึงความเพียงพอในการนอนหลับระหว่างคืน เนื่องจากการนอนหลับที่ไม่เพียงพอมีความสัมพันธ์ต่อทั้งสุขภาพทางกายและสุขภาพจิตโดยเฉพาะในกลุ่มผู้สูงอายุ(5) อีกทั้งยังสามารถใช้บ่งบอกถึงความเสี่ยงในการเกิดอุบัติเหตุอย่างการพลัดตกจากเตียงจากตำแหน่งการนอนได้

จากการวิเคราะห์ข้อมูลมรณบัตร พบว่าการพลัดตกหกล้มมีแนวโน้มเพิ่มสูงขึ้นอย่างต่อเนื่อง โดยทั่วโลกมีผู้เสียชีวิตจากการพลัดตกหกล้มในปี 2002 ประมาณ 319,000 คน และเพิ่มขึ้นเป็น 424,000 คน ในปี 2012 และสำหรับประเทศไทยมีผู้สูงอายุเสียชีวิตกว่า 1,000 คน โดยผู้สูงอายุมีอัตราการเสียชีวิตจากการพลัดตกหกล้มสูงกว่ากลุ่มช่วงอายุอื่นถึง 3 เท่า(6) เนื่องจากผู้สูงอายุส่วนมากมีโรคประจำตัวและมีมวลกระดูกที่น้อยลง(7) อาการบาดเจ็บที่พบได้บ่อยจากการพลัดตก เช่น อาการฟกช้ำ อาการหักของกระดูกสะโพกหรือศีรษะ(8) ซึ่งการอยู่ในตำแหน่งที่ใกล้ขอบเตียงมากจนเกินไปมีโอกาสเสี่ยงต่อการพลัดตกจากเตียงมากกว่าปกติ(9)

ในหลายปีที่ผ่านมาได้มีการนำเสนองานวิจัยมากมายที่ใช้อุปกรณ์และกระบวนการที่หลากหลายในการพัฒนาระบบสำหรับจำแนกท่าทางการนอนแบบอัตโนมัติ เพื่อใช้ในการติดตามดูแลผู้ป่วยหรือผู้สูงอายุที่นอนอยู่บนเตียง โดยสามารถแบ่งอุปกรณ์ออกได้เป็น 3 ประเภท คือ 1. ประเภทไม่มีอุปกรณ์สัมผัสตัว จะถูกนำเสนอในรูปแบบการใช้กล้องความลึก(Depth camera) หรือ กล้องอินฟราเรด(Infrared camera) ติดตั้งภายในห้องเพื่อรับภาพจากผู้นอน โดยผู้ที่นำเสนออุปกรณ์ประเภทนี้จะพบข้อจำกัดทางด้านความเป็นส่วนตัวของผู้นอน และปัญหาการลดลงของค่าความแม่นยำที่เกิดจากสัญญาณรบกวนภายในภาพและเมื่อใช้งานร่วมกับผ้าห่ม(10, 11) 2. ประเภทอุปกรณ์สัมผัสตัวโดยการสวมใส่ จะถูกนำเสนอในรูปแบบการใช้เซ็นเซอร์ประเภทเซ็นเซอร์วัดความเร่ง(Accelerometer) ติดตั้งตามตำแหน่งต่าง ๆ บนร่างกายของผู้นอน เช่น หน้าอก ข้อมือ

เอว หรือเสื้อผ้า โดยผู้ที่นำเสนออุปกรณ์ประเภทนี้จะพบข้อจำกัดในด้านความไม่สบายตัวจากการติดตั้งอุปกรณ์บนร่างกายของผู้นอน(3)

และสุดท้ายประเภทอุปกรณ์สัมผัสตัวแบบไม่สวมใส่ จะถูกนำเสนอการจำแนกท่าทางการนอนโดยใช้เซ็นเซอร์ตรวจวัดแรงกดที่ติดตั้งไว้ในพูกที่นอน สำหรับรับค่าแรงกดจากน้ำหนักของผู้นอนที่กระจายลงบนตัวเซ็นเซอร์ ซึ่งอุปกรณ์ประเภทนี้เมื่อเปรียบเทียบกับประเภทอื่น ๆ จะช่วยแก้ปัญหาในด้านความเป็นส่วนตัว ความไม่สบายตัวที่เกิดจากการติดเซ็นเซอร์บนร่างกาย และสามารถลดปัญหาความผิดพลาดที่อาจเกิดขึ้นจากสิ่งกีดขวางที่ส่งผลต่ออุปกรณ์เช่น ผ้าห่ม เสื้อผ้า หรือคุณภาพของภาพในกรณีที่ใช้กล้อง โดยอุปกรณ์ประเภทนี้จะถูกนำไปใช้สำหรับคำนวณระยะเวลาและตำแหน่งของแรงกดที่อาจส่งผลต่อการเกิดแผลกดทับ(1, 12-14) การตรวจสอบท่าทางการนอนสำหรับวิเคราะห์คุณภาพการนอน(4) และการตรวจสอบท่าทางหรือตำแหน่งท่านอนที่เสี่ยงต่อการพลัดตกจากเตียง(9) เป็นต้น

จากงานวิจัยก่อนหน้าของเราเรื่องระบบแจ้งเตือนการพลัดตกจากเตียง(15) เป็นการใช้เซ็นเซอร์แรงกดร่วมกับเซ็นเซอร์อัลตราโซนิกอย่างละ 6 ตัว โดยใช้กระบวนการ Finite State Machine(FSM) ในการจำแนกท่าทางการนอนและการพลัดตกจากเตียง พบว่างานวิจัยดังกล่าวยังคงขาดความเสถียรและความยืดหยุ่นในการจำแนกท่าทางและการพลัดตกจากเตียงจะทำได้หลังจากเกิดขึ้นไปเรียบร้อยแล้ว ทำให้ไม่สามารถเข้าช่วยเหลือได้ในทันที

งานวิจัยนี้เป็นการพัฒนาต่อยอดระบบจำแนกท่าทางการนอนสำหรับตรวจสอบท่าทางการนอนแบบอัตโนมัติก่อนจะเกิดการพลัดตกจากเตียง โดยใช้เซ็นเซอร์แรงกดเรียงเป็นเมตริก 10 x 10 รวมทั้งสิ้น 100 ตัว ซึ่งจะถูกติดตั้งกระจายทั่วบนแผ่นพูกยางพาราด้วยระยะห่างที่เท่ากัน และถูกวางไว้ใต้ผ้าปูที่นอน น้ำหนักของผู้นอนที่กระจายลงบนเซ็นเซอร์จะถูกแสดงเป็นข้อมูลที่อยู่ในลักษณะค่าอาร์เรย์แรงกด สำหรับใช้ในการสร้างโมเดลในการจำแนกท่าทางการนอน จำนวน 5 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นิ่ง และท่านอนขอบเตียงด้วยการเรียนรู้ของเครื่องจักร โดยเราได้เปรียบเทียบอัลกอริทึมการเรียนรู้ของเครื่องจักรหลายตัว เพื่อหาอัลกอริทึมที่เหมาะสมกับชุดข้อมูลของเรามากที่สุด

## 1.2 วัตถุประสงค์

เพื่อออกแบบและพัฒนาระบบจำแนกท่าทางการนอน จำนวน 5 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นิ่ง และนอนขอบเตียง ด้วยการเรียนรู้ของเครื่องจักร

### 1.3 ขอบเขตงานวิจัย

1. งานวิจัยนี้ใช้เซ็นเซอร์แรงกดเรียงเป็นเมตริก 10 x 10 รวมทั้งสิ้น 100 ตัว ซึ่งจะถูกติดตั้งกระจายทั่วบนแผ่นฟูกยางพาราด้วยระยะห่างที่เท่ากัน และถูกวางไว้ใต้ผ้าปูที่นอน สำหรับเก็บข้อมูล

2. งานวิจัยนี้ใช้งานร่วมกับเตียงเดี่ยวขนาดมาตรฐาน ความกว้างและยาว 3.5 x 6.5 ฟุต เท่านั้น

3. งานวิจัยนี้เก็บข้อมูลการนอนจากกลุ่มตัวอย่างชายหญิงสุขภาพดี อายุ 18 - 75 ปี จำนวนอย่างน้อย 30 คน โดยบันทึกท่าทางละ 1 นาที จำนวน 3 ครั้ง

4. งานวิจัยนี้จะสร้างโมเดลสำหรับจำแนกท่าทางการนอน จำนวน 5 ท่าทาง ได้แก่ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นั่ง และนอนขอบเตียง ด้วยการเรียนรู้ของเครื่องจักร โดยท่านอนขอบเตียงของงานวิจัยนี้จะทำการจำแนกด้านซ้ายเพียงด้านเดียว

5. งานวิจัยนี้ได้รับการรับรองจริยธรรมการทำวิจัยในมนุษย์ หมายเลขจริยธรรม SWUEC 274/2563 โดยคณะกรรมการจริยธรรมการวิจัย มหาวิทยาลัยศรีนครินทรวิโรฒ

## บทที่ 2

### ทฤษฎีและทบทวนวรรณกรรมที่เกี่ยวข้อง

#### 2.1 ลักษณะท่าทางการนอน

##### 2.1.1 ท่านอนหงาย

ท่านอนหงายเป็นการนอนโดยแขนขนานราบไปกับลำตัว หรือกางแขนและขาให้อยู่ในระดับที่รู้สึกสบาย การนอนในท่านี้สามารถช่วยป้องกันอาการปวดคอและหลัง ช่วยลดอาการกรดไหลย้อน โดยระดับของหลอดอาหารต้องอยู่สูงกว่าระดับกระเพาะอาหาร และทำให้ใบหน้าไม่สัมผัสกับหมอนซึ่งอาจเป็นสาเหตุของริ้วรอยและปัญหาผิวหนังใบหน้าได้ อย่างไรก็ตามผู้ที่มีอาการนอนกรนและมีภาวะหยุดหายใจขณะหลับ การนอนในท่านี้อาจทำให้อาการแย่ลงได้ เนื่องจากการยุบตัวของทางเดินหายใจ ดังนั้นควรเลือกทำอื่นแทน เช่นท่านอนตะแคง(16)

##### 2.1.2 ท่านอนตะแคง

การนอนตะแคงเป็นอีกหนึ่งท่านอนที่สามารถพบเห็นได้บ่อยตามอายุที่มากขึ้น โดยเฉพาะการนอนตะแคงด้านขวา(17, 18) สำหรับผู้ที่มีอาการปวดคอและหลัง อาการนอนกรน และมีภาวะหยุดหายใจขณะหลับ การนอนในท่านี้สามารถช่วยลดอาการเหล่านี้ได้ แต่อย่างไรก็ตามการนอนตะแคงขวาอาจทำให้อาการกรดไหลย้อนแย่ลง และในทางกลับกันการนอนตะแคงซ้ายจะช่วยให้เลือดไหลเวียนไปเลี้ยงที่รกได้ดี ทำให้เหมาะสำหรับสตรีมีครรภ์ ดังนั้นควรเลือกด้านที่เหมาะสมกับสุขภาพของตัวเอง

##### 2.1.3 ท่านอนคว่ำ

การนอนในท่านี้เป็นท่านอนที่ค่อนข้างแย่มากที่สุดในบรรดาทุกท่า เนื่องจากการนอนในท่านี้คอจะถูกดันไปด้านหลังของร่างกาย ทำให้ไม่สามารถรักษาระดับของกระดูกสันหลังและคอให้อยู่ในแนวเดียวกันได้ และทำให้กระดูกสันหลังโค้งเหมือนงอหลังตลอดทั้งคืน จึงเป็นสาเหตุของอาการปวดคอและหลัง นอกจากนี้ ท่านอนคว่ำยังทำให้ใบหน้าสัมผัสกับหมอนโดยตรง ซึ่งอาจเป็นสาเหตุให้ใบหน้าเกิดริ้วรอยและสิวได้ อย่างไรก็ตามผู้ที่มีอาการนอนกรนและมีภาวะหยุดหายใจขณะหลับในระดับที่ไม่รุนแรงมาก หากนอนตะแคงแล้วรู้สึกไม่สบายตัว ท่านอนคว่ำสามารถก็เป็นอีกทางเลือกหนึ่งของการลดอาการดังกล่าวแทนได้

## 2.2 การพลัดตก

เกิดจากการที่ผู้ป่วยเปลี่ยนตำแหน่งร่างกายจากความสูงระดับหนึ่งไปอีกระดับหนึ่งโดยการก้าวขึ้น ไถล หรือล้ม ซึ่งเป็นเหตุการณ์ที่มักเกิดขึ้นโดยไม่ได้ตั้งใจ และไม่สามารถควบคุมได้ ส่งผลทำให้ร่างกายของผู้ป่วยได้รับบาดเจ็บ เช่น ตกจากบันได เก้าอี้ รถเข็น หรือเตียง เป็นต้น โดยพบว่ามักเกิดขึ้นกับผู้ป่วยที่มีอายุ 60 ปีขึ้นไป โดยผลกระทบที่เกิดขึ้นกับผู้ที่พลัดตกหกล้ม(19) คือ

- เพิ่มขึ้นขั้นตอนการตรวจวินิจฉัยและรักษาอาการบาดเจ็บที่เกิดขึ้น
- เพิ่มระยะเวลาการนอนในโรงพยาบาล
- เกิดความเครียด ความวิตกกังวลแก่ผู้ป่วย ครอบครัว และผู้ดูแล
- เสียค่าใช้จ่ายในการดูแลรักษามากขึ้น
- ส่งผลต่อชื่อเสียง และความเชื่อมั่นต่อสถานดูแล

จากการวิเคราะห์ข้อมูลมรณบัตรของสำนึกโรคไม่ติดต่อ กรมควบคุมโรค กระทรวงสาธารณสุข พบว่าอัตราการเสียชีวิตจากการพลัดตกหกล้มในผู้สูงอายุนั้นสูงกว่า ทุกกลุ่มช่วงอายุถึง 3 เท่า และมีแนวโน้มที่จะเพิ่มขึ้นอย่างต่อเนื่อง โดยเฉพาะกลุ่มอายุ 80 ปีขึ้นไป ได้เพิ่มขึ้นกว่า 3 เท่า ขณะที่กลุ่มอายุ 60 - 69 ปี และ 70 - 79 ปี เพิ่มขึ้น 2 เท่าในช่วงระยะเวลา 8 ปี และเพศชายมีอัตราการเสียชีวิตจากการพลัดตกหกล้มสูงกว่าเพศหญิงถึง 3 เท่า (6)

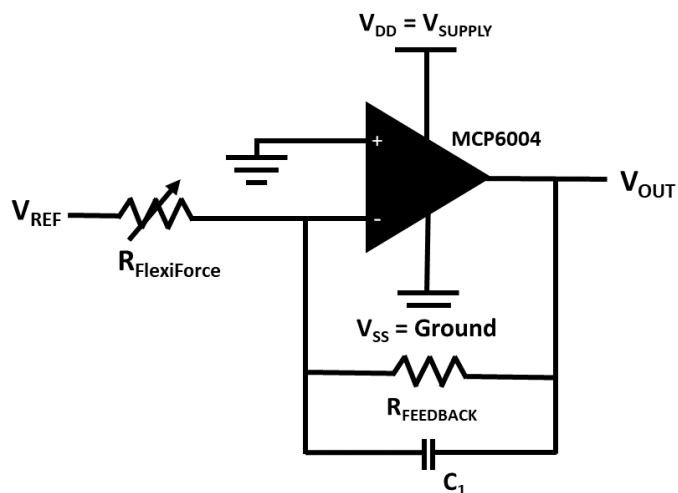
## 2.3 วงจรเซ็นเซอร์

วงจรที่แนะนำสำหรับการใช้งานร่วมกับเซ็นเซอร์แรงกด ประกอบไปด้วย 3 รูปแบบ โดยในแต่ละรูปแบบถูกใช้เพื่อปรับความไว ทำให้เซ็นเซอร์สามารถวัดค่าได้อย่างเต็มประสิทธิภาพตามที่ควรจะเป็น(20)

### 2.3.1 วงจรขยายสัญญาณแบบกลับเฟส (INVERTING OP-AMP CIRCUIT)

วงจรนี้เป็นการใช้โพเทนชิออมิเตอร์(potentiometer) มาเป็นตัวต้านทานแบบป้อนกลับเพื่อใช้สำหรับการเปลี่ยนความไวของแรง แสดงดังภาพประกอบ 1


การใช้งานวงจรรูปแบบนี้จะได้รับแรงดันผลลัพธ์จากเซ็นเซอร์ที่มีความเป็นเส้นตรง (linearity) ได้เป็นอย่างดีเมื่อเทียบกับแรงที่มากระทำ แต่จะมีความซับซ้อนและราคาที่สูงกว่าเมื่อเทียบกับวงจร วงจรแบ่งแรงดัน (Voltage Divider) และต้องใช้ร่วมกับแหล่งจ่ายไฟคู่(20)



ภาพประกอบ 1 ตัวอย่างวงจรรขยายสัญญาณแบบกลับเฟส (INVERTING OP-AMP CIRCUIT)

### 2.3.2 วงจรรขยายสัญญาณแบบไม่กลับเฟส (NON-INVERTING OP-AMP CIRCUIT)

วงจรมีลักษณะใกล้เคียงกับวงจรรขยายสัญญาณแบบกลับเฟสแต่จะได้รับค่าที่มีความคงที่และสามารถใช้งานได้กับแหล่งจ่ายไฟเดี่ยวได้(20) แสดงดังภาพประกอบ 2



ภาพประกอบ 2 ตัวอย่างวงจรรขยายสัญญาณแบบไม่กลับเฟส (NON-INVERTING OP-AMP CIRCUIT)

### 2.3.3 วงจรแบ่งแรงดัน (VOLTAGE DIVIDER)

วงจรมีไว้สำหรับแบ่งค่าแรงดัน มีราคาที่ถูก ใช้งานง่าย และใช้แหล่งจ่ายไฟเดียว แต่ผลลัพธ์เชิงเส้นจะมีค่าที่น้อยกว่า 2 รูปแบบที่เหลือ(20) แสดงดังภาพประกอบ 3 ซึ่งวงจรมีจะใช้กฎของโอห์มมาประยุกต์ แสดงดังสมการที่ 1


$$V_{out} = \frac{V_{ref} \times R_2}{(R_1 + R_2)} \quad (1)$$

กำหนดให้  $V_{out}$  คือ แรงดันขาออก หน่วย โวลต์(V)

$V_{ref}$  คือ แรงดันจากแหล่งจ่าย หน่วย โวลต์(V)

$R_1, R_2$  คือ ค่าความต้านทานของตัวต้านทานที่ 1 และ 2 หน่วย โอห์ม

(Ω)



ภาพประกอบ 3 ตัวอย่างวงจรแบ่งแรงดัน (VOLTAGE DIVIDER)

### 2.4 ขนาดมาตรฐานของเตียง

โดยปกติแล้วเตียงผู้ป่วยจะมีขนาดใกล้เคียงกับเตียงเดี่ยวทั่วไป คือ มีความกว้างและยาวอยู่ที่ 3.5 x 6.5 ฟุต หรือประมาณ 90 x 200 เซนติเมตร ซึ่งเพียงพอสำหรับคนที่มีค่าดัชนีมวลกาย (BMI) ปกติ เนื่องจากขนาดของเตียงมีผลต่อการปรับเปลี่ยนท่าทางการนอน หากเตียงมีขนาดที่แคบเกินไป พื้นที่ที่ไม่เพียงพอ อาจทำให้รู้สึกไม่สบายตัว ซึ่งอาจส่งผลเสียต่อประสิทธิภาพการนอนหลับ หรือการพักรักษาตัวในโรงพยาบาลได้ โดยผู้ป่วยที่มีค่าดัชนีมวลกายสูงกว่าปกติ หรือผู้ป่วยที่ได้รับการผ่าตัดช่องท้อง หากมีพื้นที่ในการเปลี่ยนท่าทางที่ไม่เพียงพอ อาจทำให้เกิดการเกร็งของกล้ามเนื้อหน้าท้องจนเกิดการบาดเจ็บได้(21)

## 2.5 การเรียนรู้ของเครื่องจักร (Machine Learning)

เป็นการเรียนรู้ของอุปกรณ์ที่ได้รับการฝึกฝนให้เรียนรู้ซ้ำแล้วซ้ำเล่าด้วยข้อมูลจาก data scientist จนสามารถค้นหารูปแบบในการจำแนกประเภทสิ่งใดสิ่งหนึ่งได้ ซึ่งสามารถทดสอบได้ด้วยการนำข้อมูลที่คล้ายๆกับที่เคยสอนใส่เข้าไป กระบวนการนี้จะสามารถบอกได้ว่าข้อมูลนี้อยู่ในประเภทไหน เช่นเดียวกับการเรียนรู้ของมนุษย์ที่ได้รับประสบการณ์มากมายจนสามารถคาดเดาสิ่งที่จะเกิดขึ้นต่อไปได้ แต่อย่างไรก็ตาม ทั้งมนุษย์และเครื่องจักร หากพบข้อมูลที่ยังไม่เคยเจอมาก่อนในครั้งแรก มักเป็นเรื่องยากที่จะคาดเดาได้เช่นกัน โดยสามารถแบ่งออกได้เป็น 3 ประเภท ขึ้นอยู่กับการฝึกสอน(22) คือ

1) การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นการเรียนรู้ที่มีความคล้ายคลึงกับการเรียนรู้ของมนุษย์ คือเรียนรู้จากข้อมูลที่ได้รับมา (Input) จากนั้นสร้างโมเดลที่สอดคล้องกับผลลัพธ์ที่ถูกต้อง (Output) เช่น มีข้อมูลภาพสุนัขและแมว แล้วทำการสอนที่ละภาพว่าภาพไหนเป็นภาพสุนัข และภาพไหนเป็นภาพแมว ทำให้เมื่อเจอภาพใหม่จะสามารถจำแนกได้ว่ามันคือภาพอะไร

2) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการเรียนรู้ที่ได้รับเฉพาะอินพุตโดยไม่มีการกำหนดถึงผลลัพธ์ (Output) ว่าคืออะไร ทำให้ระบบต้องค้นหารูปแบบการแยกประเภทด้วยตัวเอง เช่น มีนักเรียนจำนวน 100 คน แล้วให้ทำการแบ่งกลุ่ม เป็น 2 กลุ่ม โดยไม่ได้ระบุว่าใช้เกณฑ์อะไร ทำให้ระบบต้องหาความแตกต่างด้วยตัวเอง

3) การเรียนรู้แบบเสริมกำลัง (Reinforcement learning) เป็นการเรียนรู้ที่ใช้อินพุตกับเอาต์พุตบางส่วน และทำการให้คะแนนความสำคัญในการสร้างโมเดล โดยทั่วไปจะใช้เมื่อต้องการการโต้ตอบที่เหมาะสมที่สุดในแต่ละสถานการณ์ เช่นการควบคุมและการเล่นเกม

โดยในงานวิจัยนี้จะใช้การเรียนรู้ของเครื่องจักรประเภท Supervised Learning ประเภทต่างๆ เพื่อหากระบวนการสร้างโมเดลที่มีความแม่นยำสูงและเหมาะสมกับชุดข้อมูลของเรามากที่สุด ดังนี้

### 2.5.1 โครงข่ายประสาทเทียม (Neural Network)

เป็นกระบวนการที่สามารถเปรียบเทียบได้กับการทำงานของสมองคน โดยโหนด (node) เป็นเหมือนกับตัวเส้นประสาท และค่าน้ำหนัก (connection weight หรือ  $w$ ) เป็นเหมือนกับการเชื่อมต่อกันของแต่ละเส้นประสาท ซึ่งแสดงถึงความเกี่ยวข้องหรือมีความสำคัญกับข้อมูลนั้นๆมากแค่ไหน(22) โดยมีพื้นฐานจากสมการเส้นตรง แสดงดังสมการที่ 2

$$v = wx + b \quad (2)$$

กำหนดให้  $v$  คือ ข้อมูลเอาต์พุต (output)

$w$  คือ ค่าถ่วงน้ำหนัก (weight) หรือค่าความรู้ที่ได้เรียนรู้จากการจดจำ

$x$  คือ ข้อมูลอินพุต (input)

$b$  คือ ค่าความเอนเอียงหรือไบอัส (bias) เป็นค่าที่เพิ่มเข้าไปเพื่อปรับให้ค่าที่คำนวณออกมาถูกต้องมากยิ่งขึ้น

เมื่อเราต้องการผลลัพธ์เราจะนำ  $v$  จากสมการที่ 2 มาใส่ใน Activation Function ซึ่งเป็นฟังก์ชันใดๆที่จะทำให้ผลลัพธ์ออกมาในแบบที่เราต้องการขึ้นอยู่กับการออกแบบโมเดลของเรา แสดงดังสมการที่ 3

$$y = \varphi(v) \quad (3)$$

กำหนดให้  $y$  คือ ค่าเอาต์พุต (Output)


$\varphi(v)$  คือ ฟังก์ชันใดๆของ Activation Function

ภายใน Neural Network จะมีลักษณะเหมือนโครงข่ายการทำงานของสมองมนุษย์ ซึ่งจะประกอบด้วย Layer 3 ประเภท แสดงดังภาพประกอบ 4

1) Input Layer คือ ชั้นข้อมูลที่เราจะนำไปสอนให้กับโมเดล จำนวน node จะขึ้นอยู่กับจำนวน input ว่ามีข้อมูลลักษณะอะไรบ้างสำหรับการวิเคราะห์

2) Hidden Layer คือ ชั้นที่อยู่ระหว่างกลาง ซึ่งจะมีผลอย่างมากต่อประสิทธิภาพในการเรียนรู้ของโมเดล โดยเราสามารถกำหนดจำนวน node และจำนวนชั้นได้ ซึ่งยิ่งกำหนดในปริมาณที่เยอะก็จะยิ่งเพิ่มความสามารถในการจำแนกข้อมูลที่มีความซับซ้อนได้มากขึ้น แต่ต้องแลกมาด้วยระยะเวลาในการจำแนกที่นานขึ้นด้วยเช่นกัน


3) Output Layer คือ ชั้นผลลัพธ์ที่เราจะได้จากกระบวนการนี้ จำนวน node ในชั้นนี้จะขึ้นอยู่กับจำนวน Class ที่เราต้องการจะจำแนก



ภาพประกอบ 4 ตัวอย่างโครงสร้างของ Neural Network

โดยหลักการสร้างโมเดลของ Neural Network จำเป็นจะต้องมีชุดข้อมูลเรียนรู้ (training data) ซึ่งประกอบไปด้วย ข้อมูลอินพุต (Input) และผลลัพธ์ที่ถูกต้อง (Correct output) สำหรับฝึกสอนโมเดล โดยในตอนแรกค่า weight จะเป็นค่าๆหนึ่งที่อาจจะถูกสุ่มขึ้นมา เพื่อนำไปคำนวณด้วยกระบวนการ Activation Function ต่างๆ เพื่อให้ได้มาซึ่งผลลัพธ์ (Output) ผลลัพธ์ที่ได้จะถูกนำไปเทียบกับผลลัพธ์ที่ถูกต้อง โดยความต่างที่ได้คือ error

ค่าความผิดพลาด (Error) ที่ได้รับจากการเทียบกับผลลัพธ์ที่ถูกต้อง จะถูกย้อนกลับ ไปปรับปรุงค่า weight ในชั้นต่างๆ ตาม Learning rate ที่ถูกกำหนด กระบวนการนี้ถูกเรียกว่า Backpropagation แล้วทำวนซ้ำจนกว่าผลลัพธ์จะลู่เข้าค่าใดค่าหนึ่ง แสดงดังภาพประกอบ 5



ภาพประกอบ 5 หลักการสร้างโมเดลของ Neural Network

### 2.5.2 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM)

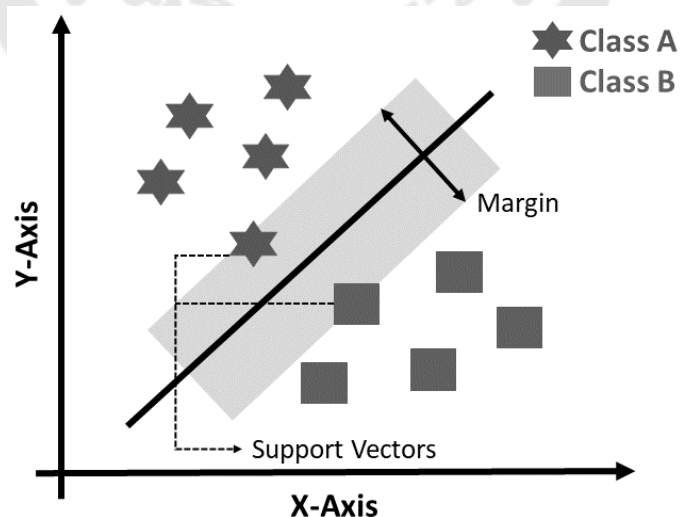
เป็นกระบวนการจำแนกข้อมูลโดยใช้เส้นแบ่งข้อมูลที่ทำให้แต่ละ class สามารถแยกออกจากกันได้ชัดเจนที่สุด ซึ่งสามารถทำได้ทั้งแบบ Linear และ Non Linear ในกรณีที่ เป็น Linear จะใช้พื้นฐานจากสมการเส้นตรงของ linear classifier(23, 24) ดังสมการที่ 4 โดยกำหนดให้  $W$  คือ ค่าน้ำหนักของเวกเตอร์ (Weight vector) และ  $X$  คือ ข้อมูลอินพุต (input)

$$w^T x + w_0 = 0 \quad (4)$$

เพื่อสร้างเส้น Margin ขึ้นมาจาก data train โดยเส้นที่ใช้ในการแบ่งที่ดีที่สุดควรมี Margin กว้างที่สุดที่ทำให้เกิด error rate ที่ต่ำที่สุด เพื่อป้องกันการเกิด overfitting ซึ่งค่าจุดที่อยู่ในช่วงเส้น Margin จะถูกเรียกว่า support vector แสดงดังภาพประกอบ 6 เมื่อนำข้อมูลที่ใช้ทดสอบมาใส่ในสมการ จะได้ผลลัพธ์เป็น +1 หรือ -1 ขึ้นอยู่กับว่าเราตั้งให้ผลลัพธ์นั้นอยู่คลาสไหน (กรณีที่มีเพียง 2 คลาส) (23) แสดงดังสมการ 5 โดยกำหนดให้  $\omega 1$  คือ คลาส 1 และ  $\omega 2$  คือ คลาส 2

$$w^T x + w_0 \geq 1, \forall x \in \omega 1 \quad (5)$$

$$w^T x + w_0 \leq -1, \forall x \in \omega 2$$



ภาพประกอบ 6 ตัวอย่างการแยกคลาสของ Support Vector Machine แบบ Linear

โดยอัลกอริทึม Support Vector Machine จาก Classification Learner App ในโปรแกรม MATLAB ประกอบด้วย 6 ชนิด คือ Linear SVM, Quadratic SVM, Cubic SVM, Fine Gaussian SVM, Medium Gaussian SVM และ Coarse Gaussian SVM ซึ่งทั้ง 6 ชนิดนี้มีความเหมือนกัน คือ ถ้าเป็นการจำแนกแบบ 2 คลาส(Binary) จะมีความเร็วในการจำแนกที่เร็ว และใช้หน่วยความจำปานกลาง แต่หากเป็นการจำแนกแบบหลายคลาส(Multiclass) จะทำให้ความเร็วในการจำแนกช้า และใช้หน่วยความจำที่เยอะ และมีความแตกต่าง(25) ดังนี้

- Linear SVM เป็นโมเดลเพียงตัวเดียวในกลุ่มที่มีการตีความ (Interpretability) ที่ง่าย โดยอัลกอริทึมตัวนี้มีความยืดหยุ่นต่ำ เนื่องจากเป็นเพียงการแบ่งแต่ละคลาสด้วยการแยกเชิงเส้นแบบง่าย
- Quadratic SVM เป็นโมเดลอัลกอริทึมตัวนี้มีความยืดหยุ่นปานกลาง โดยสามารถสร้างความแตกต่างระหว่างคลาสได้จากการตั้งค่า kernel เป็นฟังก์ชันกำลังสอง
- Cubic SVM เป็นโมเดลอัลกอริทึมตัวนี้มีความยืดหยุ่นปานกลาง โดยสามารถสร้างความแตกต่างระหว่างคลาสได้จากการตั้งค่า kernel เป็นฟังก์ชันกำลังสาม
- Fine Gaussian SVM เป็นโมเดลอัลกอริทึมที่มีความยืดหยุ่นของแบบจำลองที่สูง และจะลดลงด้วยการตั้งค่ามาตราส่วนของ kernel โดยสามารถสร้างความแตกต่างละเอียดระหว่างคลาสได้จากการตั้งค่า kernel เป็น  $\sqrt{P}/4$
- Medium Gaussian SVM เป็นโมเดลอัลกอริทึมที่มีความยืดหยุ่นของแบบจำลองปานกลาง โดยสามารถสร้างความแตกต่างระดับกลางระหว่างคลาสได้จากการตั้งค่า kernel เป็น  $\sqrt{P}$
- Coarse Gaussian SVM เป็นโมเดลอัลกอริทึมที่มีความยืดหยุ่นของแบบจำลองต่ำ โดยสามารถสร้างความแตกต่างหยาบระหว่างคลาสได้จากการตั้งค่า kernel เป็น  $\sqrt{P} \times 4$  โดย P คือจำนวนของตัวทำนาย

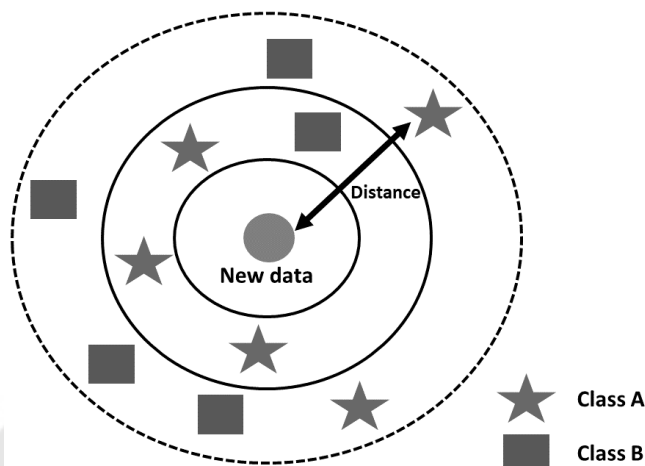
### 2.5.3 การเรียนรู้เพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbor: KNN)

เป็นกระบวนการจำแนกข้อมูลที่สำคัญการเทียบเคียงกับข้อมูลกลุ่มตัวอย่างที่ถูกฝึกสอนทั้งหมด โดยคำนวณจากระยะห่างของข้อมูลที่เราต้องการจำแนก(24, 26) แสดงดังสมการที่ 6 จากกลุ่มตัวอย่างที่ใกล้ที่สุดตามจำนวน k ที่ถูกกำหนดไว้ ดังนั้นข้อมูลที่อยู่กลุ่มเดียวกันก็ควรอยู่ในระยะห่างที่ใกล้เคียงกัน แสดงดังภาพประกอบ 7

$$distance(x_1, x_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (6)$$

กำหนดให้  $x_1, x_2$  คือ จุดพิกัดของข้อมูลอินพุตในกลุ่มที่ 1 และกลุ่มที่ 2

$n$  คือ จำนวนมิติของจุดพิกัดอินพุต



ภาพประกอบ 7 ตัวอย่างโมเดล K-Nearest Neighbor


โดยอัลกอริทึม K-Nearest Neighbor จาก Classification Learner App ในโปรแกรม MATLAB ประกอบด้วย 6 ชนิด คือ Fine KNN, Medium KNN, Coarse KNN, Cosine KNN, Cubic KNN และ Weighted KNN ซึ่งทั้ง 6 ชนิดนี้มีความเหมือนกัน คือ มีความเร็วในการจำแนกปานกลาง, ใช้หน่วยความจำปานกลาง และมีการตีความ (Interpretability) ที่ยาก และมีความแตกต่าง(25) ดังนี้

- **Fine KNN** เป็นโมเดลที่มีการแยกแยะรายละเอียดระหว่างคลาสอย่างละเอียด โดยมีจำนวนเพื่อนบ้านเท่ากับ 1
- **Medium KNN** เป็นโมเดลที่มีความแตกต่างปานกลางระหว่างคลาส โดยมีจำนวนเพื่อนบ้านเท่ากับ 10
- **Coarse KNN** เป็นโมเดลที่มีความแตกต่างระหว่างคลาสที่หยาบ โดยมีจำนวนเพื่อนบ้านเท่ากับ 100
- **Cosine KNN** เป็นโมเดลที่มีความแตกต่างปานกลางระหว่างคลาส โดยใช้ตัววัดระยะทางแบบโคไซน์(Cosine) และมีจำนวนเพื่อนบ้านเท่ากับ 10
- **Cubic KNN** เป็นโมเดลที่มีความแตกต่างปานกลางระหว่างคลาส โดยใช้หน่วยเมตริกระยะทางแบบลูกบาศก์(Cubic) และมีจำนวนเพื่อนบ้านเท่ากับ 10
- **Weighted KNN** เป็นโมเดลที่มีความแตกต่างปานกลางระหว่างคลาส โดยใช้น้ำหนักระยะทาง และมีจำนวนเพื่อนบ้านเท่ากับ 10

### 2.5.4 การเรียนรู้ต้นไม้ตัดสินใจ (Decision Tree)

เป็นกระบวนการจำแนกที่มีรูปแบบโครงสร้างเป็นลำดับชั้นโดยมีลักษณะคล้ายกับต้นไม้กลับหัว ประกอบด้วย ส่วนบนสุดคือราก (Root) ที่แสดงถึงข้อมูลที่เราจะใช้สอนโมเดล ส่วนล่างสุดคือใบ (Leaf node) ที่แสดงถึงกลุ่มของข้อมูล (class) หรือผลลัพธ์ (output) ที่เราต้องการ โดยภายในต้นไม้จะมีโหนด (node) และคุณสมบัติ (attribute) เป็นตัวแปรที่ใช้ในการทดสอบ ซึ่งในแต่ละกิ่ง (branch) แสดงถึงค่าที่เป็นไปได้ของคุณสมบัติที่ถูกทดสอบ(27, 28)

การทำงานของกระบวนการนี้จะเป็นการทำงานในรูปแบบการสร้างกฎคล้าย if-else แยกแขนงแยกย่อยลงลึกไปเรื่อยๆจากโหนดรากผ่านกิ่งลงไปสู่ใบ ซึ่งเราสามารถกำหนดความลึกนี้ได้ แต่หากโครงสร้างมีความลึกมากเกินไป อาจเกิดการ overfitting ได้ แสดงดังภาพประกอบ 8



ภาพประกอบ 8 ตัวอย่างโมเดล Decision Tree

โดยอัลกอริทึม Decision Tree จาก Classification Learner App ในโปรแกรม MATLAB ประกอบด้วย 3 ชนิด คือ Coarse Tree, Medium Tree และ Fine Tree ซึ่งทั้ง 3 ชนิดนี้มีความเหมือนกัน คือ มีความเร็วในการจำแนกที่เร็ว, ใช้หน่วยความจำน้อย และมีการตีความ (Interpretability) ที่ง่าย และมีความแตกต่าง(25) ดังนี้

- **Coarse Tree** เป็นโมเดล Decision Tree ที่มีความยืดหยุ่นต่ำ มีจำนวนใบที่ค่อนข้างน้อย โดยมีจำนวนการแยก (splits) ได้สูงสุดเท่ากับ 4
- **Medium Tree** เป็นโมเดล Decision Tree ที่มีความยืดหยุ่นปานกลาง มีจำนวนใบในระดับปานกลางทำให้แยกคลาสได้ละเอียดขึ้น โดยมีจำนวนการแยก (splits) ได้สูงสุดเท่ากับ 20

- **Fine Tree** เป็นโมเดล Decision Tree ที่มีความยืดหยุ่นสูง มีใบจำนวนมากในการสร้างความแตกตึกในแต่ละคลาสได้ดี โดยมีจำนวนการแยก(splits) ได้สูงสุดเท่ากับ 100

### 2.5.5 การวิเคราะห์จำแนกกลุ่ม (Discriminant Analysis)

เป็นกระบวนการทำนายข้อมูลด้วยค่าของตัวแปรตาม แล้วทำการจำแนกประเภทเป็นกลุ่มด้วยตัวแปรอิสระหรือตัวแปรทำนาย โดยแต่ละตัวควรจะต้องไม่มีความเกี่ยวพันกันมากเกินไป การประมาณค่าจะใช้ Least squares เพื่อหาค่าความน่าจะเป็นแล้วทำการแบ่งกลุ่มจากคะแนนที่ได้รับ(29) โดยโมเดลนี้เป็นไปดังสมการที่ 7

$$D = b_0 + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_kx_k \quad (7)$$

กำหนดให้  $D$  คือ ค่าคะแนนของ discriminant

$b$  คือ ค่าสัมประสิทธิ์ของตัวแปรอิสระ

$x$  คือ ค่าตัวแปรอิสระ

โดย อัลกอริทึม Discriminant Analysis จาก Classification Learner App ในโปรแกรม MATLAB ประกอบด้วย 2 ชนิด(25) ดังนี้

- **Linear Discriminant** เป็นอัลกอริทึมที่มีความเร็วในการจำแนกที่เร็ว, ใช้หน่วยความจำน้อย, มีการตีความ (Interpretability) ที่ง่าย และเป็นการสร้างโมเดลแบบขอบเขตเชิงเส้นในการแบ่งแต่ละคลาส
- **Quadratic Discriminant** เป็นอัลกอริทึมที่มีความเร็วในการจำแนกที่เร็ว, ใช้หน่วยความจำปานกลาง, มีการตีความ (Interpretability) ที่ง่าย และเป็นการสร้างโมเดลแบบขอบเขตไม่เชิงเส้นในการแบ่งแต่ละคลาส เช่น วงรี พาราโบลา หรือไฮเพอร์โบลา

### 2.5.6 การจำแนกของเบย์ (Naive Bayes Classification)

เป็นกระบวนการจำแนกข้อมูลโดยใช้หลักพื้นฐานความน่าจะเป็นตามกฎของเบย์ (Bayes' Theorem) แสดงดังสมการที่ 8 เข้ามาช่วยในการตั้งสมมติฐานที่ทำให้การเกิดขึ้นของเหตุการณ์ต่าง ๆ เป็นอิสระต่อกัน (Independence) ซึ่งมีการออกแบบและการทำงานที่เรียบง่ายและสามารถนำไปใช้กับสถานการณ์ได้หลากหลาย(30)

$$P(h|D) = \frac{P(D|h) P(h)}{P(D)} \quad (8)$$

จากสมการ กำหนดให้  $P(h)$  คือความน่าจะเป็นที่จะเกิดเหตุการณ์  $h$  และ  $P(h|D)$  คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์  $h$  เมื่อเกิดเหตุการณ์  $D$  จากตัวแปรที่กำหนดทำให้แนวคิดของ Bayes' Theorem นั้นเราสามารถทำนายเหตุการณ์ที่พิจารณาได้จากการเกิดของเหตุการณ์ต่าง ๆ

โดยอัลกอริทึม Naive Bayes จาก Classification Learner App ในโปรแกรม MATLAB ประกอบด้วย 2 ชนิด(25) ดังนี้

- **Gaussian Naive Bayes** เป็นอัลกอริทึมที่เมื่อเป็นข้อมูลปกติจะมีความเร็วในการจำแนกปานกลาง และใช้หน่วยความจำน้อย แต่หากเป็นข้อมูลที่มีมิติที่สูง จะทำให้มีความเร็วในการจำแนกช้า และใช้หน่วยความจำปานกลาง, มีการตีความ (Interpretability) ที่ง่าย และเป็นการสร้างโมเดลที่ไม่สามารถเปลี่ยนแปลงพารามิเตอร์ใดๆ เพื่อควบคุมความยืดหยุ่นของแบบจำลองได้
- **Kernel Naive Bayes** เป็นอัลกอริทึมที่มีความเร็วในการจำแนกที่ช้า, ใช้หน่วยความจำปานกลาง, มีการตีความ (Interpretability) ที่ง่าย และเป็นการสร้างโมเดลที่สามารถเปลี่ยนการตั้งค่าสำหรับชนิดของ Kernel และตัว Support เพื่อควบคุมวิธีการกระจายตัวในการทำนายแต่ละคลาสได้

## 2.6 การทบทวนวรรณกรรมที่เกี่ยวข้อง (Literature Review)

ในช่วงหลายปีที่ผ่านมาได้มีการนำเสนองานวิจัยที่ใช้อุปกรณ์ประเภทอุปกรณ์สัมผัสตัวแบบไม่สวมใส่ ด้วยกระบวนการที่หลากหลายในการพัฒนาระบบสำหรับจำแนกท่าทางการนอนแบบอัตโนมัติ เพื่อใช้ในการติดตามดูแลผู้ป่วยหรือผู้สูงอายุที่นอนอยู่บนเตียง แสดงดังตาราง 1

Barsocchi P และคณะ(12) ได้นำเสนอ An unobtrusive sleep monitoring system for the human sleep behavior understanding ในปี 2016 มีเป้าหมายในการตรวจสอบสถานะและตำแหน่งการนอน จำนวน 4 ท่าทาง คือ นอนหงาย นอนคว่ำ นอนตะแคงซ้าย และนอนตะแคงขวา ด้วย Force Sensing Resistor(FSR) จำนวน 48 ตัว ติดตั้งบนเตียงในระดับอก หลัง และหัวเข่า และใช้ sampling rate ที่ 10 Hz งานวิจัยนี้สนับสนุนการป้องกันการเกิดแผลกดทับ โดยใช้ Multiclass logistic regression ใน Weka ในการจำแนก ผลลัพธ์ในงานวิจัยนี้ได้รับความแม่นยำที่ 88-95%

Xu X และคณะ(14) ได้นำเสนอ Body-Earth Mover's Distance A Matching-Based Approach for Sleep Posture Recognition ในปี 2016 มีเป้าหมายในการจำแนกท่าทางการนอนจำนวน 6 ท่าทาง คือ นอนหงาย นอนคว่ำ นอนตะแคงซ้าย นอนตะแคงขวา นอนขดซ้าย และนอนขดขวา ด้วย pressure sensor 64 x 128 เพื่อประเมินคุณภาพการนอนหลับ และป้องกันการเกิดแผลกดทับ โดยงานวิจัยนี้มีการเตรียมข้อมูลด้วย Threshold Filtering ในการกรองข้อมูลแต่ละจุด Gaussian Filtering ในการลบสัญญาณรบกวน Long Tail Removal ในการตัดส่วนที่ไม่จำเป็นออกให้ภาพมีความกะทัดรัดและง่ายต่อการวิเคราะห์ และ Rotation ในการหมุนภาพให้อยู่ตรงกลาง และใช้ค่าดัชนีมวลกาย(BMI) ในการปรับข้อมูลให้เป็นมาตรฐาน โดยจะถูกจำแนกท่าทางด้วย K-Nearest Neighbours (KNN) และได้รับผลลัพธ์ความแม่นยำที่ 91.21%

Pouyan MB และคณะ(1) ได้นำเสนอ A Pressure Map Dataset for Posture and Subject Analytics ในปี 2017 มีเป้าหมายในการจำแนกท่าทางการนอนเพื่อนำไปวิเคราะห์ประสิทธิภาพการนอน และการเกิดแผลกดทับ โดยใช้ชุดข้อมูลออนไลน์จาก PmatData สำหรับจำแนกท่าทางการนอนทั้งหมด 3 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย และนอนตะแคงขวา โดยใช้ Deep learning ในการสร้างโมเดล ซึ่งภายในประกอบด้วย 1 input, 3 hidden layers (20, 20 และ 10 node) และ 1 output และใช้ 10 cross validation ผลลัพธ์ในงานวิจัยนี้ได้รับความแม่นยำจากท่านอนหงาย 85.5% นอนตะแคงขวา 80.4% และนอนตะแคงซ้าย 82.3%

Sri-ngernyuang C และคณะ(9) ได้นำเสนอ Neural Network for On-bed Movement Pattern Recognition ในปี 2018 มีเป้าหมายในการตรวจสอบท่าทางการนอน จำนวน 5 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นั่ง และขอบเตียง ด้วยเซ็นเซอร์ 12 x 12 (144ตัว) สำหรับตรวจสอบการพลัดตกจากเตียง พร้อมส่งสัญญาณแจ้งเตือนด้วยระบบ IoT ไปที่ nurse station โดยใช้ Artificial Neural Networks (ANN) ในโปรแกรม MATLAB ซึ่งจากข้อมูลที่มีทั้งหมดจะถูกแบ่งเป็น train 70% validation 15% และ test 15% ผลลัพธ์ในงานวิจัยนี้ได้รับความแม่นยำในการ train, validation และ test เท่ากับ 99.5, 89.1 และ 87.0% ตามลำดับ

Dhamchatsoontree S และคณะ(4) ได้นำเสนอ i-Sleep: Intelligent Sleep Detection System for Analyzing Sleep Behavior ในปี 2019 มีเป้าหมายในการเปรียบเทียบความแม่นยำที่ดีที่สุดที่สุดจาก Machine learning จำนวน 7 แบบ คือ Gaussian Naive Bays, Bernoulli Naive Bays, Neural Network, Support Vector Machine (SVM), Logistic Regression, Random Forest และ K-Nearest Neighbours (KNN) สำหรับจำแนกท่าทางการนอนหลับจำนวน 6 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นั่ง เปลี่ยนท่าทาง และลุกออกจากเตียง ด้วย

เซ็นเซอร์แรงกด  $8 \times 6$  เพื่อนำไปคำนวณหาค่าดัชนีคุณภาพการนอนหลับ และส่งข้อมูลที่ได้เข้าแอปพลิเคชันแบบเรียลไทม์ โดยการเก็บข้อมูลในงานวิจัยนี้จะใช้ผู้ทดลอง จำนวน 35 คน นอนในท่าต่างๆเป็นเวลา 1 นาที ในขณะที่เซ็นเซอร์จะอ่านทุกๆ 10 วินาที ซึ่งค่าที่ได้อาจมีบางส่วนที่ขาดหายไปทำให้ต้องใช้ค่าเฉลี่ยเติมเข้าไปทดแทน ซึ่งจากข้อมูลทั้งหมดจะถูกแบ่งเป็น ข้อมูลฝึกสอน 80% และข้อมูลทดสอบ 20% ผลลัพธ์ในงานวิจัยนี้สรุปได้ว่า K-Nearest Neighbours (KNN) มีความแม่นยำที่ดีที่สุด ซึ่งได้รับความแม่นยำจากการใช้ข้อมูลดิบ 86.7% ใช้แผนภาพช่องสี่ 88.8% และข้อมูลที่ถูกทำให้เป็นมาตรฐาน 86.7%

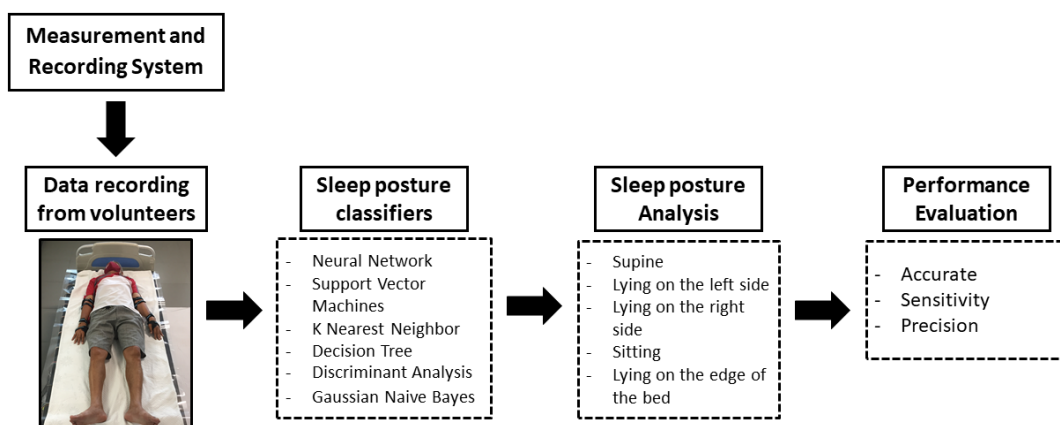
Matar G และคณะ (13) ได้นำเสนอ Artificial neural network for in-bed posture classification using bed-sheet pressure sensors ในปี 2020 มีเป้าหมายในการตรวจจับท่าทางการนอน จำนวน 4 ท่าทาง คือ นอนหงาย นอนคว่ำ นอนตะแคงซ้าย และนอนตะแคงขวา ด้วย pressure sensor เมตริก  $64 \times 27$  และใช้ sampling frequency 35 Hz โดยมุ่งเน้นเรื่องการเกิดแผลกดทับ และการแยกระหว่างท่านอนหงายกับคว่ำ โดยงานวิจัยนี้ได้เลือกใช้การเตรียมข้อมูลด้วยพีเจอร์ Histogram of Oriented Gradients (HoG) สำหรับดึงลักษณะเด่นของภาพด้วยสี ภาพและพื้นผิว และ local binary pattern สำหรับดึงลักษณะในการจำแนกพื้นผิว เมื่อรวม 2 พีเจอร์เข้าด้วยกันจะช่วยเพิ่มประสิทธิภาพการตรวจจับ ก่อนจะใช้ neural network ในการจำแนก ซึ่งได้รับผลลัพธ์ความแม่นยำในการทดสอบที่ 97.9% และ Cohen's Kappa coefficient ที่ 97.2%

ตาราง 1 การเปรียบเทียบตัวอย่างงานวิจัยที่ถูกนำเสนอการจำแนกท่าทางการนอนด้วยประเภทอุปกรณ์สวมใส่แบบไม่สวมใส่ โดยกำหนดให้  $n/a$  คือ ไม่พบข้อมูล,  $N_T$  คือ จำนวนกลุ่มตัวอย่าง และ  $T_p$  คือ จำนวนชุดข้อมูล

งานวิจัย, ปี	ชุดข้อมูล	จำนวนเซ็นเซอร์	วิธีการจำแนก	จำนวนท่าทาง	ความแม่นยำ (%)
Barsocchi, P., et al. Conference Paper 2016	$N_T = n/a$ $T_p = 72000$	48	Machine learning (logistic regression)	4(นอนหงาย, นอนคว่ำ, นอนตะแคงซ้าย และ นอนตะแคงขวา)	91.4
Barsocchi, P., et al. Journal Article 2016	$N_T = 14$ $T_p = 1848$	64 x 128	K-Nearest Neighbors (KNN)	6(นอนหงาย, นอนคว่ำ, นอนตะแคงซ้าย, นอนตะแคงขวา, นอนคดตัวซ้าย และนอนคดตัวขวา)	91.21
Sri-ngemyuang, C., et al. (Thailand) Conference Paper 2018	$N_T = 6$ $T_p = n/a$	12 x 12	Artificial Neural Network (ANN)	5(นอนหงาย, นอนตะแคงซ้าย, นอนตะแคงขวา, นิ่ง และนอนมุ่มเตี้ย)	87.0
Dhamchatsoontree, S., et al. (Thailand) Conference Paper 2019	$N_T = 35$ $T_p = 1983$	8 x 6	K-Nearest Neighbors (KNN)	6(นอนหงาย, นอนตะแคงซ้าย, นิ่ง, เปลี่ยนท่า และลุกออกจากเตียง)	ข้อมูลดิบ : 91.1, โล่ระดับสี : 88.8 และข้อมูล มาตรฐาน : 86.7
Matar, G., et al. Journal Article 2020	$N_T = 12$ $T_p = 1116$	64 x 27	Artificial Neural Network (ANN)	4(นอนหงาย, นอนคว่ำ, นอนตะแคงซ้าย และ นอนตะแคงขวา)	97.9

### บทที่ 3 วิธีการดำเนินงาน

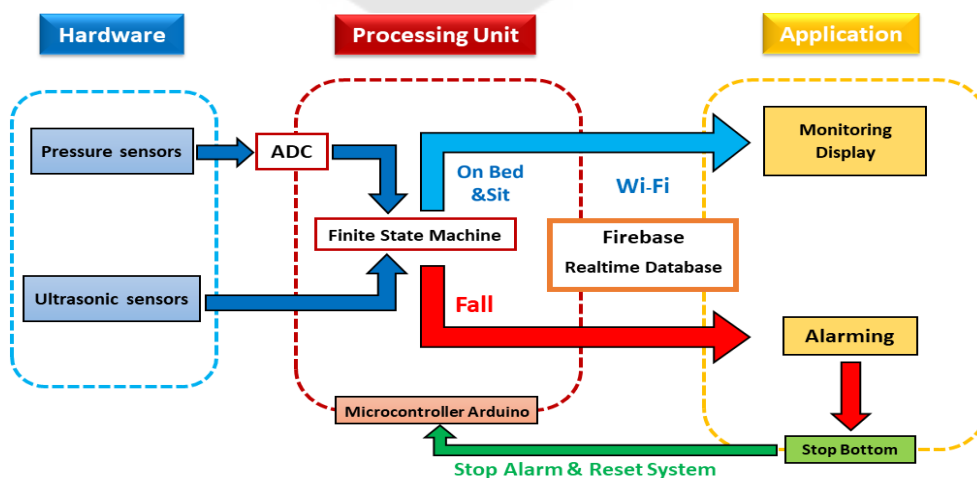
งานวิจัยนี้เป็นการออกแบบและพัฒนาระบบจำแนกท่าทางการนอนด้วยการเรียนรู้ของเครื่องจักร โดยจะทำการออกแบบโครงสร้างทางด้านฮาร์ดแวร์ ได้แก่ ระบบการวัดและบันทึกแรงกด การออกแบบแผ่นวงจรพิมพ์ การติดตั้งเซ็นเซอร์ การเก็บผลการนอนจากกลุ่มตัวอย่าง และการออกแบบระบบจำแนกท่าทางการนอน แสดงดังภาพประกอบ 9 ซึ่งมีรายละเอียดดังนี้



ภาพประกอบ 9 ขั้นตอนการทำงานของระบบ

#### 3.1 การออกแบบระบบแจ้งเตือนการพลัดตกจากเตียง

จากงานวิจัยก่อนหน้าเรื่องระบบแจ้งเตือนการพลัดตกจากเตียง(15) เป็นการใช้เซ็นเซอร์แรงกดร่วมกับเซ็นเซอร์อัลตราโซนิกอย่างละ 6 ตัว สำหรับจำแนกสถานะการนอน 3 ท่า คือ นอนบนเตียง นิ่ง และการพลัดตกจากเตียง แสดงดังภาพประกอบ 10



ภาพประกอบ 10 ขั้นตอนการทำงานของระบบแจ้งเตือนการพลัดตกจากเตียง

ในงานวิจัยข้างต้นได้ใช้เซ็นเซอร์แรงกดของ DFRobot มาทำการต่อวงจรผ่านตัวต้านทานเพียงอย่างเดียว โดยได้ทำการทดสอบประสิทธิภาพด้วย Universal Testing Machine(UTM) (31) ซึ่งการทดสอบประกอบไปด้วย Root Mean Square Error และ Repeatability ในขณะเดียวกันงานวิจัยของ Burinthorn และคณะ(32) ที่นำเสนอการทดสอบประสิทธิภาพของเซ็นเซอร์แรงกดของ Tekscan ด้วยวงจรแบบเดียวกัน พบว่าเซ็นเซอร์แรงกดของ Tekscan มีค่า Root mean squared error ที่น้อยกว่าของ DFRobot เป็นอย่างมาก แต่วงจรโดยรวมของทั้งสองงานวิจัยมีความเหมือนกัน คือ ยังคงมีความไม่เสถียร และมีความหน่วงของระบบ อีกทั้งยังพบว่าการใช้เซ็นเซอร์แรงกดในจำนวนที่น้อย ส่งผลให้ระบบของงานวิจัยก่อนหน้านี้ยังคงขาดความยืดหยุ่นในการจำแนกท่าทาง

โดยการคำนวณค่า Root Mean Square Error(33) แสดงดังสมการที่ 9

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_{ref}(i\Delta T) - F(i\Delta T))^2} \quad (9)$$

กำหนดให้  $F_{ref}$  คือ แรงกดที่วัดจากอุปกรณ์อ้างอิง  
 $F$  คือ แรงกดจากเซ็นเซอร์แรงกด  
 $i$  คือ จำนวนข้อมูล  
 $\Delta T$  คือ เวลาในการสุ่มตัวอย่าง  
 $N$  คือ จำนวนข้อมูลทั้งหมด


และการคำนวณค่า Repeatability(34) แสดงดังสมการที่ 10

$$Repeatability = \frac{1}{N+1} \sum_{i=0}^N \left( \frac{|F(i\Delta T) - \overline{F(i\Delta T)}|}{Fa(iTs)} \right) \times 100 \quad (10)$$

กำหนดให้  $N$  คือ จำนวนการทำซ้ำ  
 $\overline{F(i\Delta T)}$  คือ ค่าเฉลี่ยของข้อมูลที่วัดได้


### 3.2 การออกแบบระบบการวัดและบันทึกแรงกด

การออกแบบแผ่นวงจรพิมพ์ของระบบจำแนกท่าทางการนอน ภายในประกอบไปด้วย เซ็นเซอร์แรงกดของ Tekscan, วงจรขยายสัญญาณแบบไม่กลับเฟส (Non-Inverting Op-Amp), ไมโครคอนโทรลเลอร์ ESP32-DEV-KIT และ อุปกรณ์สำหรับนำส่งข้อมูลเข้าคอมพิวเตอร์ แสดงดัง ภาพประกอบที่ 11




ภาพประกอบ 11 ขั้นตอนการออกแบบระบบการวัดและบันทึกแรงกด

วงจรขยายสัญญาณแบบไม่กลับเฟส (Non-Inverting Op-Amp) จะถูกนำมาใช้แก้ไข ปัญหาที่เกิดขึ้นจากงานวิจัยก่อนหน้าทั้งสอง(15, 32) เพื่อปรับค่า sensitivity โดยมีวงจรแบ่ง แรงดัน (Voltage divider) สำหรับปรับค่าอ้างอิง ทำให้เซ็นเซอร์แรงกดสามารถวัดค่าแรงกดได้ใน ประสิทธิภาพระดับสูงสุดที่เซ็นเซอร์สามารถรับได้(20) ประกอบไปด้วย ตัวต้านทาน(R), ตัวเก็บ ประจุ(C) และวงจรรวม(IC) ซึ่งถูกออกแบบด้วยโปรแกรม Altium Designer ดังภาพประกอบ 12



ภาพประกอบ 12 Schematics diagram จากโปรแกรม Altium Designer ของระบบวัดแรงกด

แผ่นวงจรพิมพ์ที่ได้รับการออกแบบเสร็จแล้วจะถูกนำมาพัฒนาเป็นแผ่นปริ้นสำหรับติดตั้งไมโครคอนโทรลเลอร์ ESP32-DEV-KIT และอุปกรณ์ต่างๆ โดยในแผ่นปริ้น 1 แผ่น สามารถติดตั้งเซ็นเซอร์แรงกดได้เป็นจำนวน 10 ตัว แสดงภาพประกอบ 13



(ก)

(ข)

ภาพประกอบ 13 การออกแบบแผ่นวงจรพิมพ์แบบ CAD (ก) ด้านบน(Top layer) และ (ข) ด้านล่าง(Bottom layer)

### 3.3 การติดตั้งเซ็นเซอร์


งานวิจัยนี้ใช้เซ็นเซอร์แรงกดของ Tekscan รุ่น Flexiforce A301 สามารถรับแรงได้ 445 นิวตัน เซ็นเซอร์ชนิดนี้มีขนาดที่เล็กบาง ทำให้สามารถนำมาใช้ร่วมกับการวัดแรงกดที่ต้องการลดการสัมผัสกับผู้ใช้ได้เป็นอย่างดี โดยสามารถปรับปรุงประสิทธิภาพได้ด้วยการเปลี่ยนขนาดของค่าความต่างศักย์และขนาดของตัวต้านทาน (35) คุณสมบัติของเซ็นเซอร์แสดงดังตาราง 2

ตาราง 2 คุณสมบัติของเซ็นเซอร์แรงกด

คุณสมบัติ (Properties)	พารามิเตอร์ (Parameter)
Sensor Thickness	0.203 mm (0.008 in.)
Sensor Length	25.4 mm
Sensing Size (Diameter/Width)	9.7 mm
Standard Force	445 N
Linearity (Error)	< $\pm 3\%$ of Full Scale
Repeatability	< $\pm 2.5\%$
Hysteresis	< 4.5 %
Response Time	< 5 $\mu\text{sec}$

ที่ ม ๑ (35) : Tekscan Inc. FlexiForce A301 Sensor 2020 [Available from: <https://www.tekscan.com/products-solutions/force-sensors/a301?tab=specifications-performance>].

เซ็นเซอร์แรงกดจะถูกเรียงเป็นเมตริกขนาด 10 x 10 รวม 100 ตัว โดยจะถูกติดตั้งกระจายด้วยระยะห่างเท่าๆ กันครอบคลุมทั่วทั้งแผ่นยางพาราโดยใช้กาวสองหน้า การติดตั้งนี้อ้างอิงระยะห่างตามการใช้งานร่วมกับเตียงเดี่ยวขนาดมาตรฐาน 3.5 x 6.5 ฟุต หรือประมาณ 90 x 200 เซนติเมตร แสดงดังภาพประกอบ 14 โดยกากบาท คือ เซ็นเซอร์แรงกด



ภาพประกอบ 14 ตำแหน่งการติดตั้งเซ็นเซอร์แรงกด

ในกรณีที่พื้นที่สัมผัสของวัตถุที่กดลงไป มีขนาดใหญ่กว่าพื้นที่รับแรงจะทำให้เกิดการถ่ายโอนของแรงขึ้น ส่งผลให้เซ็นเซอร์วัดค่าได้ไม่ถูกต้อง ดังนั้นการมีจุดรวมแรงจะช่วยแก้ปัญหาที่เกิดขึ้นได้(36) เราจึงติดตั้งจุดรวมแรงบนเซ็นเซอร์ทุกตัว แสดงดังภาพประกอบ 15



ภาพประกอบ 15 ตัวอย่างการติดตั้งจุดรวมแรงบนเซ็นเซอร์แรงกด

ในบางครั้งแรงที่ถูกกดลงบนเซ็นเซอร์มีลักษณะเป็นแรงเฉือน ทำให้วัสดุของเซ็นเซอร์อาจเกิดการเสียรูป จุดรวมแรงเป็นสิ่งที่สามารถช่วยลดผลกระทบนี้ได้ แต่เนื่องจากจุดรวมแรงมีลักษณะนูนสูงขึ้นมา ทำให้แรงเฉือนยังคงเกิดขึ้น เราจึงใช้ Protective sheet คลุมเพื่อช่วยแยกแรงเฉือนออกจากเซ็นเซอร์และทำให้เซ็นเซอร์สามารถส่งแรงได้อย่างเป็นปกติ(36) ก่อนจะคลุมอีกชั้นด้วยผ้าคลุมเตียง เพื่อลดความรู้สึกไม่สบายตัวของกลุ่มตัวอย่างเมื่อนอนทับบนเซ็นเซอร์ แสดงดังภาพประกอบ 16-17



ภาพประกอบ 16 การคลุมเซ็นเซอร์แรงกดด้วย Protective sheet



ภาพประกอบ 17 การคลุมชั้นงานด้วยผ้าคลุมเตียงก่อนเริ่มเก็บข้อมูล

จากขั้นตอนการติดตั้งเซ็นเซอร์ที่กล่าวมาข้างต้น สามารถสรุปได้ว่า ในแต่ละแถวจะมีเซ็นเซอร์แรงกดจำนวน 10 ตัว โดยจะถูกรวมกันที่ไม่โครคอนโทรลเลอร์บนแผ่นปรีนของแต่ละแถว ดังนั้นงานวิจัยนี้จึงใช้ไมโครคอนโทรลเลอร์จำนวน 10 ตัวในการทำงานพร้อมกัน โดยไมโครคอนโทรลเลอร์ทุกตัวจะได้รับไฟเลี้ยงและส่งข้อมูล ผ่านสาย USB ไปยัง 10 port USB 3.0 hub ก่อนจะเชื่อมต่อไปยังคอมพิวเตอร์ แสดงดังภาพประกอบ 18



ภาพประกอบ 18 อุปกรณ์สำหรับนำส่งข้อมูลเข้าคอมพิวเตอร์ 10 port USB 3.0 hub

ค่าที่ได้รับจากเซ็นเซอร์เกิดจากการเปลี่ยนแปลงของค่าความต้านทานซึ่งเป็นสัดส่วนผกผันตามค่าแรงที่กดลงบนเซ็นเซอร์(14) ซึ่งค่าที่ได้จะถูกเปลี่ยนจากค่าอนาล็อกเป็นค่าดิจิทัลด้วย AD Convertor ภายในไมโครคอนโทรลเลอร์ เพื่อใช้ในการวิเคราะห์บนคอมพิวเตอร์ต่อไป

### 3.4 การเก็บข้อมูลการนอนจากกลุ่มตัวอย่าง

งานวิจัยนี้จะเก็บรวบรวมข้อมูลแรงกดจากน้ำหนักตัวของกลุ่มตัวอย่างจำนวน 30 คน เป็นชายและหญิงสุขภาพดีและไม่มีอาการบาดเจ็บ มีอายุ น้ำหนัก และส่วนสูง แสดงดังตาราง 3

ตาราง 3 อายุ น้ำหนัก และส่วนสูงของกลุ่มตัวอย่าง จำนวน 30 คน

	อายุ (ปี)	น้ำหนัก (kg.)	ส่วนสูง (cm.)
Min	20	47	155
Max	69	107	176
Mean	29.7	65.5	163.5
S.D.	14.27	15.43	6.72

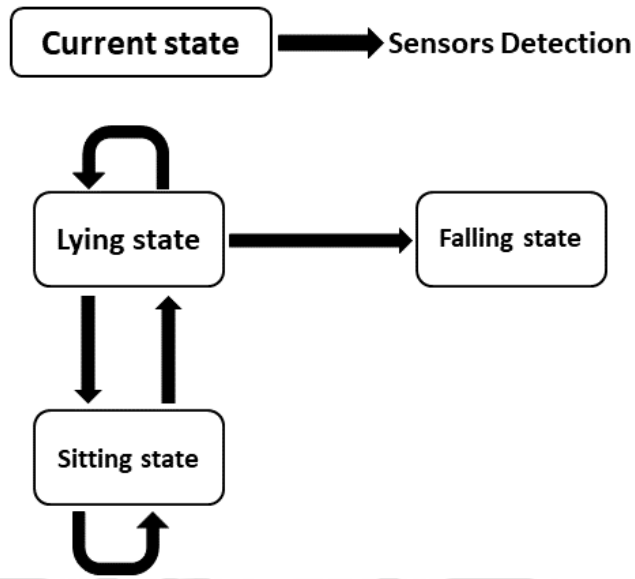
การเก็บรวบรวมข้อมูลในงานวิจัยนี้จะเป็นไปอย่างถูกต้องตามหลักจริยธรรม ตามใบรับรองหมายเลขจริยธรรม SWUEC 274/2563 โดยคณะกรรมการจริยธรรมการวิจัย มหาวิทยาลัยศรีนครินทรวิโรฒ ซึ่งกลุ่มตัวอย่างทุกคนจะต้องเซ็นเอกสารเพื่อรับทราบรายละเอียดก่อนเข้ารับการเก็บข้อมูลและต้องสวมใส่อุปกรณ์ป้องกันที่จัดเตรียมไว้ เพื่อป้องกันอันตรายที่อาจเกิดขึ้น แสดงดังภาพประกอบ 19 แล้วทำการนอนบนเตียงเดี่ยวขนาดมาตรฐานและทำท่าทางจำนวน 5 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นั่ง และนอนขอบเตียง โดยจะทำการบันทึกท่าทางละ 1 นาที จำนวนท่าละ 3 ครั้ง



ภาพประกอบ 19 อุปกรณ์ป้องกันสำหรับกลุ่มตัวอย่าง


### 3.5 การออกแบบระบบจำแนกท่าทางการนอน

ในงานวิจัยก่อนหน้า(15) เราใช้กระบวนการ Finite State Machine(FSM) ในการจำแนกสถานะท่าทาง 3 สถานะ คือ นอนบนเตียง นั่ง และพลัดตกจากเตียง โดยตั้งเงื่อนไขอย่างเป็นลำดับขั้น ตามการทำงานของเซ็นเซอร์แรงกดและเซ็นเซอร์อัลตราโซนิกแต่ละตัวร่วมกันในระบบ แสดงดังภาพประกอบ 20 ซึ่งผลลัพธ์ที่ได้จากกระบวนการนี้ยังคงขาดความยืดหยุ่นในการจำแนกและการตรวจพบการพลัดตกจากเตียงสามารถทำได้หลังจากเกิดขึ้นไปแล้ว



ภาพประกอบ 20 การทำงานของ Finite State Machine

ดังนั้นเราจึงพัฒนาระบบจำแนกท่าทางการนอนที่สามารถจำแนกท่าทางการนอนได้ครอบคลุมมากกว่าเดิม และต้องการให้สามารถตรวจพบท่าที่มีความเสี่ยงต่อการพลัดตกจากเตียง อย่างเช่น ท่านอนขอบเตียง เพื่อเป็นการป้องกันก่อนที่การพลัดตกจากเตียงจะเกิดขึ้นโดยใช้การเรียนรู้ของเครื่องจักร ขั้นตอนการออกแบบระบบจำแนกท่าทางการนอนในงานวิจัยนี้ แสดงดังภาพประกอบ 21




ภาพประกอบ 21 ขั้นตอนการออกแบบระบบจำแนกท่าทางการนอน

### 3.5.1 การเก็บข้อมูล (Data recording)

กลุ่มตัวอย่างจะถูกสวมใส่อุปกรณ์ป้องกันที่คอ ข้อศอก ข้อมือ และหัวเข่า แล้วทำการนอนบนเตียงเดี่ยวขนาดมาตรฐานที่ติดตั้งอุปกรณ์เสร็จเรียบร้อยแล้ว โดยในงานวิจัยนี้จะให้กลุ่มตัวอย่างแต่ละคนทำท่าทางจำนวน 5 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นั่ง และนอนขอบเตียง ซึ่งท่านอนขอบเตียงจะทำเพียงด้านซ้ายเพียงด้านเดียว ในการเก็บข้อมูลเราจะทำการบันทึกข้อมูลท่าทางละ 1 นาที จำนวน 3 ครั้ง โดยใช้อัตราการสุ่มตัวอย่าง (sampling frequency) ที่ 10 Hz แสดงดังภาพประกอบ 22 - 23



ภาพประกอบ 22 ภาพตัวอย่างการเก็บข้อมูลจากกลุ่มตัวอย่าง



(ก)

(ข)

(ค)



(ง)




(จ)

ภาพประกอบ 23 ตัวอย่างท่าทางการนอน (ก) นอนหงาย (ข) นอนตะแคงซ้าย (ค) นอนตะแคงขวา (ง) นั่ง และ (จ) นอนขอบเตียง

### 3.5.2 การเตรียมข้อมูล (Pre-processing)

ข้อมูลดิบที่ได้จากการเก็บข้อมูลจะอยู่ในลักษณะค่าดิจิทัลจากเซ็นเซอร์แต่ละตัวซึ่งจะแสดงออกมาเป็นอาร์เรย์เมตริกขนาด  $10 \times 10$  ที่มีค่าเริ่มต้นตัวละประมาณ 1000 เนื่องจากเซ็นเซอร์แต่ละตัวมีการตอบสนองที่ต่างกันเล็กน้อยทำให้ไม่สามารถลบด้วยค่าคงที่เพียงอย่างเดียวได้ ดังนั้นเราจึงใช้ข้อมูลที่ถูเก็บจากเตียงเปล่า(ไม่มีกลุ่มตัวอย่างนอน) มาหาค่าเฉลี่ยและบวกด้วยค่าคงที่สำหรับป้องกันความผิดพลาด ด้วยวิธีการนี้เราจะได้รับเกณฑ์(threshold) สำหรับนำมาลบกับข้อมูลที่ถูเก็บมา(มีกลุ่มตัวอย่างนอนในแต่ละท่าทาง) เพื่อเป็นการตั้งข้อมูลที่เก็บมาจากเซ็นเซอร์แต่ละตัวให้มีค่าเริ่มต้นที่ศูนย์ ในจุดที่ไม่มีแรงกด(4) แสดงดังภาพประกอบ 24



ภาพประกอบ 24 ขั้นตอนการทำงานของเตรียมข้อมูล

เมื่อกำหนดให้ข้อมูลที่ถูกเก็บมามีค่าเริ่มต้นที่ศูนย์ เราพบว่าข้อมูลบางชุดที่มีค่าเป็นศูนย์ทั้งหมดภายในเมตริก หรือก็คือเป็นช่วงเวลาที่เซ็นเซอร์ทุกตัวไม่ตรวจพบแรงกด ซึ่งสาเหตุสามารถเกิดขึ้นได้จากการสูญหายของตัวเซ็นเซอร์เอง หรือกลุ่มตัวอย่างขยับตัวระหว่างกรเก็บข้อมูล หรือลักษณะทางกายภาพของตัวกลุ่มตัวอย่างที่ร่างกายผอมบางหรือมีน้ำหนักตัวที่น้อยจนเกินไป


ปัญหานี้จะถูกแก้ไขโดยใช้ข้อมูลสำรองที่ถูกเก็บเตรียมไว้ หรือใช้ค่าเฉลี่ยจากชุดข้อมูลรอบๆ มาแทนที่ข้อมูลที่เป็นศูนย์ทั้งหมดนี้ได้ ซึ่งปัญหานี้เกิดขึ้นเพียงเล็กน้อยเมื่อเทียบกับข้อมูลทั้งหมดที่เราเก็บมา ทำให้ไม่มีผลกระทบต่อการวิเคราะห์ที่จะเกิดขึ้นต่อไป

### 3.5.3 การจำแนกข้อมูลด้วยการเรียนรู้ของเครื่องจักร

งานวิจัยนี้ได้รับการพัฒนาระบบจำแนกท่าทางการนอนจำนวน 5 ท่าทาง คือ ท่านอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นั่ง และท่านอนขอบเตียง ด้วยโปรแกรม MATLAB ชุดข้อมูลที่ถูกเก็บมาจากกลุ่มตัวอย่างจะถูกแบ่งเพื่อใช้สำหรับขั้นตอนการฝึกสอน(train), ตรวจสอบ(validate) และทดสอบ(test) เป็น 70% 15% และ 15% ตามลำดับ โดยเราได้ใช้การเรียนรู้ของเครื่องจักรประเภทต่างๆ เพื่อหากระบวนการที่เหมาะสมกับข้อมูลของเรามากที่สุด ประกอบด้วยโครงข่ายประสาทเทียม(Neural Network) และ Classification Learner โดยมีรายละเอียดดังนี้

## 1. โครงข่ายประสาทเทียม (Neural Network)

การออกแบบโครงข่ายประสาทเทียม ประกอบไปด้วย Input layer จำนวน 100 node, Hidden layer และ Output layer จำนวน 5 node แสดงดังภาพประกอบ 25



ภาพประกอบ 25 การออกแบบโครงข่ายประสาทเทียม

ค่า Weight(W) จะถูกเริ่มต้นจากการสุ่มค่าขึ้นมา เพื่อใช้ในการฝึกสอนโมเดล โดยกระบวนการ back propagation จะถูกนำมาใช้ในการปรับปรุค่า W เพื่อให้เกิดค่าความผิดพลาด (Error) ในแต่ละ layer ที่น้อยที่สุด ภายในแต่ละ layer ของโมเดลที่ถูกออกแบบ เราใช้ฟังก์ชันต่างๆ สำหรับการฝึกสอนโมเดล ดังนี้

(1) ใช้ Sigmoid Function เป็น Activation Function จาก Input layer ไปยัง Hidden layer แสดงดังสมการที่ 11 ผลลัพธ์ที่ได้จะอยู่ในช่วงตั้งแต่ 0 จนถึง 1 โดยกำหนดให้  $x$  คือ ข้อมูลอินพุตจากการเก็บข้อมูล

$$\varphi(x) = \frac{1}{1+exp^{-x}} \quad (11)$$

(2) ใช้ Softmax Function เป็น Activation Function จาก Hidden layer ไปยัง Output layer แสดงดังสมการ 12 ฟังก์ชันนี้เหมาะกับการใช้งานร่วมกับ multiclass classification โดยส่วนมากจะอยู่ใน Layer สุดท้ายๆ เพื่อให้ผลลัพธ์ออกมาเป็น Probability โดยที่ผลลัพธ์ของแต่ละ class จะมีผลรวมเท่ากับ 1 (22)

$$\varphi(v_i) = \frac{e^{v_i}}{\sum_{k=1}^M e^{v_k}} \quad (12)$$

กำหนดให้  $v_i$  คือ ผลรวมถ่วงน้ำหนักของโหนดเอาต์พุตที่  $i$   
 $M$  คือ จำนวนของโหนดเอาต์พุต

แต่ในระหว่างการฝึกสอนโมเดล เราพบว่าในบางครั้งการใช้ Softmax Function จะเกิดปัญหาที่ทำให้เกิดผลลัพธ์เป็น NaN ทำให้โมเดลไม่สามารถใช้งานได้ ซึ่งอาจเกิดขึ้นได้จาก Input ที่มีตัวเลขจำนวนมาก หรือ มีค่าติดลบมากเกินไป ทำให้เมื่อทำการยกกำลังแล้วเกิด ช่วงตัวเลขทศนิยมที่มีขนาดเกินกว่าที่จำกัด จนเกิดเป็น Error ได้ ดังนั้นเราจึงใช้สมการ Numerical Stability แสดงดังสมการที่ 13 ก่อนเข้า Softmax Function เพื่อแก้ปัญหาดังกล่าวได้(37) โดยกำหนดให้  $\mathbf{x}$  คือ ข้อมูลเอาต์พุตจาก Activation Function ก่อนหน้า

$$\mathbf{x} = \mathbf{x} - \max(\mathbf{x}) \quad (13)$$

(3) ใช้ Cross-Entropy Function ในการพิจารณา error ในชั้น Output layer แสดงดังสมการที่ 14-15 เนื่องจากฟังก์ชันนี้มีความไวต่อค่า error มากกว่าเมื่อเทียบกับ Quadratic Function ทำให้ฟังก์ชันนี้มีประสิทธิภาพในการฝึกสอนโมเดลได้ดีกว่าส่งผลให้ learning rules เข้าใกล้ค่าที่ถูกต้องได้ดี(22)

$$E = -d \ln(y) - (1 - d) \ln(1 - y) \quad (14)$$


$$E = \begin{cases} -\ln(y) & d = 1 \\ -\ln(1 - y) & d = 0 \end{cases} \quad (15)$$

กำหนดให้  $y$  คือ ผลลัพธ์ของเอาต์พุตโหนด (Output node)  
 $d$  คือ ผลลัพธ์ที่ถูกต้องจากชุดข้อมูล train

ในการสร้างโมเดล เราได้ทำการทดลองโดยการเปลี่ยน node ใน Hidden layer ตั้งแต่ 200, 300 และ 400 node เพื่อดูความเปลี่ยนแปลงของค่าความแม่นยำที่เกิดขึ้น


## 2. การจำแนกอื่น ๆ (Others Classification)

กระบวนการนี้เราได้เลือกใช้อัลกอริทึมประเภทต่างๆ ที่มีอยู่ใน toolbox ภายในโปรแกรม MATLAB ที่เรียกว่า Classification Learner App(38) เพื่อสร้างโมเดลขึ้นมาจากชุดข้อมูลที่ถูกแบ่งไว้ใช้สำหรับ train โมเดล ชุดข้อมูลในกระบวนการนี้จะถูกเรียงเป็น 101 คอลัมน์ โดยมีข้อมูลจากเซ็นเซอร์แต่ละตัว 100 คอลัมน์และมีคอลัมน์สุดท้ายเป็นข้อมูลผลลัพธ์ที่ถูกต้อง (Correct data) และกำหนด 5 Cross-validation folds เพื่อช่วยป้องกันการเกิด overfitting โดยการแบ่งชุดข้อมูลที่มีออกเป็นส่วนๆ แล้วทำการประเมินความแม่นยำในแต่ละส่วนนั้นๆ แสดงดังภาพประกอบ 26



ภาพประกอบ 26 หน้าต่างการตั้งค่าตัวแปรใน Classification Learner

ต่อมาเราจะทำการเลือกอัลกอริทึมจาก toolbox model type โดยเราเลือกใช้ All linear เพื่อดูแนวโน้มความแม่นยำของทุกอัลกอริทึมที่มี โดยการกดคำสั่ง Train เพื่อสร้างโมเดล แสดงดังภาพประกอบ 27



ภาพประกอบ 27 หน้าต่าง toolbox model type สำหรับใช้เลือกอัลกอริทึม

หลังจากการสร้างโมเดลด้วยกระบวนการนี้ เราจะได้รับความแม่นยำของแต่ละอัลกอริทึม เราจึงเลือกอัลกอริทึมที่ได้รับความแม่นยำจากการ train ที่มีค่าใกล้เคียงหรือมากกว่า 90% ขึ้นไปเพื่อนำไปใช้ในขั้นตอน validate และ test ต่อไป โดยอัลกอริทึมที่ถูกเลือกใช้แสดงดังตาราง 4

ตาราง 4 ตารางแสดงอัลกอริทึมที่ถูกเลือกใช้จาก Classification Learner

Training method				
Support Vector Machine (SVM)	K-Nearest Neighbor (KNN)	Decision Tree	Discriminant Analysis	Naive Bayes
Linear	Fine	Fine	Linear	Gaussian Naive Bayes
Quadratic	Medium		Quadratic	
Cubic	Coarse			
Fine Gaussian	Cosine			
Medium Gaussian	Weighted			
Coarse Gaussian				

### 3.6 การตรวจสอบประสิทธิภาพของระบบ

ในงานวิจัยนี้เราได้เลือกใช้ตาราง Confusion matrix สำหรับตรวจสอบประสิทธิภาพ ความถูกต้องของระบบ ภายในตารางจะประกอบไปด้วยข้อมูลการจำแนกท่าทางการนอนจำนวน 5 ท่าทาง หรือ 5 Class ข้อมูลจะถูกเปรียบเทียบระหว่างผลลัพธ์ของท่าทางที่ได้รับจากโมเดลแต่ ละชนิดด้วยขั้นตอน train, validation และ test (Output Class) กับท่าทางที่เกิดขึ้นจริง(Target Class) แสดงดังภาพประกอบ 28 โดยสีเขียวแสดงถึงตำแหน่งที่จำแนกข้อมูลถูกต้อง และสีแดง แสดงถึงข้อมูลที่จำแนกผิดพลาด

		Target Class					
		Class1	Class2	Class3	Class4	Class5	
Output Class	Class1						Precision (%)
	Class2						
	Class3						
	Class4						
	Class5						
		Sensitivity(%)					Accuracy(%)

ภาพประกอบ 28 ตัวอย่างตาราง Confusion matrix

โดยการคำนวณความแม่นยำของแต่ละท่าทางจะถูกคำนวณดังสมการ 16-18

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (16)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (17)$$

$$Precision = \frac{TP}{TP+FP} \quad (18)$$

กำหนดให้ True Positive (TP) คือ ระบบจำแนกท่าทางเป้าหมายถูกต้องเมื่อเทียบกับท่าทางที่เกิดขึ้นจริง

True Negative (TN) คือ ระบบจำแนกท่าทางอื่นๆถูกต้องเมื่อเทียบกับท่าทางที่เกิดขึ้นจริง

False Positive (FP) คือ ระบบจำแนกท่าทางเป้าหมายผิดพลาดเมื่อเทียบกับท่าทางที่เกิดขึ้นจริง

False Negative (FN) คือ ระบบจำแนกท่าทางอื่นๆผิดพลาดเมื่อเทียบกับท่าทางที่เกิดขึ้นจริง

## บทที่ 4 ผลการดำเนินงาน

### 4.1 ผลการออกแบบระบบการวัดและบันทึกแรงกด


การทดสอบประสิทธิภาพของเซ็นเซอร์แรงกด DFRobot และ Tekscan ด้วยเครื่องอ้างอิง Universal Testing Machine(UTM) จะได้ผลลัพธ์ของการทดสอบด้วยค่า Root Mean Square Error(RMSE) ที่แสดงถึงการเปรียบเทียบค่าที่อ่านได้จากเซ็นเซอร์เทียบกับเครื่องอ้างอิง และค่า Repeatability ที่แสดงถึงความสามารถในการทำซ้ำของตัวเซ็นเซอร์ แสดงดังตาราง 5 พบว่าถึงแม้เซ็นเซอร์จาก DFRobot จะได้รับ Repeatability ที่น้อย แต่กลับได้รับค่า RMSE ที่มีความผิดพลาดที่ค่อนข้างสูง ในขณะที่เดียวกันเซ็นเซอร์แรงกดของ Tekscan ได้รับค่า RMSE ที่ใกล้เคียงกับเครื่องอ้างอิงเป็นอย่างมาก แสดงให้เห็นว่า เซ็นเซอร์แรงกดของ Tekscan มีความน่าเชื่อถือที่มากกว่า

ตาราง 5 การเปรียบเทียบเซ็นเซอร์แรงกดด้วยค่า Root mean squared error และ Repeatability


ชนิดของเซ็นเซอร์	Root Mean Squared Error: RMSE (%)	Repeatability (%)
DFRobot	23.98	0.27
Tekscan	0.14	12.57

### 4.2 ผลการออกแบบแผ่นวงจรพิมพ์

จากการออกแบบและพัฒนาแผ่นวงจรพิมพ์ เราจะได้รับแผ่นวงจรพิมพ์สำหรับติดตั้งอุปกรณ์ต่างๆที่ใช้ในงานวิจัยนี้ แสดงดังภาพประกอบ 29



(ก)



(ข)

ภาพประกอบ 29 แผ่นวงจรพิมพ์ (ก) ก่อนติดตั้งอุปกรณ์ (ข) หลังติดตั้งอุปกรณ์

#### 4.3 ผลการติดตั้งเซ็นเซอร์


เมื่อเซ็นเซอร์แรงกดถูกติดตั้งพร้อมกับจุดรวมแรงบนแผ่นยางพาราตามที่ได้ออกแบบไว้ แสดงดังภาพประกอบ 30 หลังจากนั้นจะทำการคลุมเซ็นเซอร์ด้วย Protective sheet และผ้าคลุมเตียง เราจะได้รับอุปกรณ์สำหรับการเก็บผลการนอนจากกลุ่มตัวอย่างในงานวิจัยนี้




ภาพประกอบ 30 การติดตั้งเซ็นเซอร์แรงกดบนแผ่นยางพารา

#### 4.4 การแสดงผลจากเซ็นเซอร์


จากข้อมูลแรงกดที่เราเก็บมาจากกลุ่มตัวอย่าง เราได้นำข้อมูลเหล่านี้มาพล็อตเป็นแผนภาพแรงกดสำหรับดูตำแหน่งเซ็นเซอร์แรงกดที่ถูกใช้งาน เพื่อแสดงให้เห็นลักษณะท่าทางการนอนในแต่ละท่าทางที่เกิดขึ้น เราจะยกตัวอย่างแผนภาพที่เกิดขึ้นจากกลุ่มตัวอย่าง จำนวน 3 คน จากทั้งหมด ในการเก็บข้อมูลท่าทางการนอน จำนวน 5 ท่าทาง ท่าทางละ 3 ครั้ง ดังนี้




ภาพประกอบ 31 แผนภาพแรงกดทำนองนหงายจากกลุ่มตัวอย่างที่ 1




ภาพประกอบ 32 แผนภาพแรงกดทำนองนตะแคงซ้ายจากกลุ่มตัวอย่างที่ 1




ภาพประกอบ 33 แผนภาพแรงกดทำนองคนตะเคียงขวาจากกลุ่มตัวอย่างที่ 1




ภาพประกอบ 34 แผนภาพแรงกดทำนองจกกลุ่มตัวอย่างที่ 1




ภาพประกอบ 35 แผนภาพแรงกดทำนองนอนขอบเตียงจากกลุ่มตัวอย่างที่ 1




ภาพประกอบ 36 แผนภาพแรงกดทำนองนอนหงายจากกลุ่มตัวอย่างที่ 2




ภาพประกอบ 37 แผนภาพแรงกดท่านอนตะแคงซ้ายจากกลุ่มตัวอย่างที่ 2




ภาพประกอบ 38 แผนภาพแรงกดท่านอนตะแคงขวาจากกลุ่มตัวอย่างที่ 2




ภาพประกอบ 39 แผนภาพแรงกดทำนั้งจากกลุ่มตัวอย่างที่2




ภาพประกอบ 40 แผนภาพแรงกดทำนอนขอบเตียงจากกลุ่มตัวอย่างที่2




ภาพประกอบ 41 แผนภาพแรงกดทำนองนหงายจากกลุ่มตัวอย่างที่ 3




ภาพประกอบ 42 แผนภาพแรงกดทำนองนตะแคงซ้ายจากกลุ่มตัวอย่างที่ 3



ภาพประกอบ 43 แผนภาพแรงกดทำนองตะเคียวจากกลุ่มตัวอย่างที่ 3



ภาพประกอบ 44 แผนภาพแรงกดทำนองจกกลุ่มตัวอย่างที่ 3



ภาพประกอบ 45 แผนภาพแรงกดดันนอนชอบเพียงจากกลุ่มตัวอย่างที่ 3


จากภาพประกอบ 31-45 แสดงให้เห็นว่าท่าทางการนอนที่เกิดขึ้น ถึงแม้ว่าจะเป็นท่าทางการนอนเดียวกันแต่ก็มีการเปลี่ยนแปลงของตำแหน่งเซ็นเซอร์ที่ถูกใช้งานที่ต่างกัน เกิดจากลักษณะโครงสร้างของร่างกายและน้ำหนักของกลุ่มตัวอย่างแต่ละคน และจากการเก็บข้อมูลท่าทางละ 3 ครั้งจากกลุ่มตัวอย่างคนเดียวกันก็ยังคงมีความแตกต่างกันเล็กน้อย เนื่องจากแต่ละครั้งเป็นท่าที่เกิดขึ้นคนละช่วงเวลา ส่งผลให้ข้อมูลที่เราได้รับมีความแตกต่างกันในทุกๆครั้งที่ทำการเก็บข้อมูล

#### 4.5 ผลการจำแนกข้อมูลด้วยการเรียนรู้ของเครื่องจักร


จากงานวิจัยก่อนหน้านี้ที่เราใช้ด้วยกระบวนการ Finite State Machine ในการจำแนกสถานะการนอน 3 ท่า คือ นอนบนเตียง นิ่ง และพลัดตกจากเตียง ซึ่งผลลัพธ์ความแม่นยำที่ได้รับจากกระบวนการนี้คือ 86.67% เนื่องจากระบบมีความล่าช้าและไม่มีความยืดหยุ่นในการจำแนกส่งผลให้กระบวนการนี้ได้รับผลลัพธ์ที่ยังไม่ดีพอสำหรับใช้งานจริง

ในงานวิจัยนี้ การจำแนกข้อมูลด้วยการเรียนรู้ของเครื่องจักรจากอัลกอริทึมประเภทต่างๆ ดังตาราง 3 ผลลัพธ์ของการตรวจสอบประสิทธิภาพของระบบจำแนกจะถูกแสดงในรูปแบบตาราง confusion matrix ในขั้นตอน train, validation และ test เพื่อดูค่าความแม่นยำในการจำแนกของแต่ละท่าทาง(Class) โดยกำหนดให้ Class ที่ 1-5 คือ ท่านอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นิ่ง และนอนชอบเตียงตามลำดับ ดังนี้


ผลลัพธ์การจำแนกทำทางการนอนด้วย Neural Network ซึ่งประกอบไปด้วย 200, 300 และ 400 nodes ใน Hidden layer แสดงดังภาพประกอบ 46-48



ภาพประกอบ 46 Confusion matrix ของ Neural Network (Hidden layer 200 nodes)



ภาพประกอบ 47 Confusion matrix ของ Neural Network (Hidden layer 300 nodes)



ภาพประกอบ 48 Confusion matrix ของ Neural Network (Hidden layer 400 nodes)

## ผลลัพธ์การจำแนกทำทางการนอนด้วย Linear SVM แสดงดังภาพประกอบ 49

1	36651 19.4%	212 0.1%	139 0.1%	68 0.0%	20 0.0%	98.8% 1.2%
2	363 0.2%	37548 19.9%	8 0.0%	23 0.0%	50 0.0%	98.8% 1.2%
3	145 0.1%	8 0.0%	36935 19.5%	123 0.1%	8 0.0%	99.2% 0.8%
4	601 0.3%	23 0.0%	716 0.4%	37567 19.5%	10 0.0%	96.5% 3.5%
5	40 0.0%	9 0.0%	2 0.0%	19 0.0%	37712 20.0%	99.8% 0.2%
	97.0% 3.0%	99.3% 0.7%	97.7% 2.3%	99.4% 0.6%	99.8% 0.2%	98.6% 1.4%
	1	2	3	4	5	
	Target Class					


1	6098 16.9%	3 0.0%	7 0.0%	603 1.7%	0 0.0%	90.9% 9.1%
2	185 0.5%	6384 17.7%	1 0.0%	52 0.1%	3 0.0%	96.4% 3.6%
3	526 1.5%	2 0.0%	7124 19.8%	605 1.7%	0 0.0%	86.3% 13.7%
4	391 1.1%	811 2.3%	68 0.2%	5920 16.4%	47 0.1%	81.8% 18.2%
5	0 0.0%	0 0.0%	0 0.0%	20 0.1%	7150 19.9%	99.7% 0.3%
	84.7% 15.3%	88.7% 11.3%	98.9% 1.1%	82.2% 17.8%	99.3% 0.7%	90.8% 9.2%
	1	2	3	4	5	
	Target Class					

1	6384 17.7%	51 0.1%	554 1.5%	83 0.2%	33 0.1%	89.9% 10.1%
2	629 1.7%	7106 19.7%	242 0.7%	7 0.0%	583 1.6%	82.9% 17.1%
3	42 0.1%	0 0.0%	6384 17.7%	138 0.4%	1 0.0%	97.2% 2.8%
4	142 0.4%	14 0.0%	20 0.1%	6971 19.4%	0 0.0%	97.5% 2.5%
5	3 0.0%	29 0.1%	0 0.0%	1 0.0%	6583 18.3%	99.5% 0.5%
	88.7% 11.3%	98.7% 1.3%	88.7% 11.3%	96.8% 3.2%	91.4% 8.6%	92.9% 7.1%
	1	2	3	4	5	
	Target Class					

ภาพประกอบ 49 Confusion matrix ของ Linear SVM

ผลลัพธ์การจำแนกทำทางการนอนด้วย Quadratic SVM แสดงดังภาพประกอบ

50



ภาพประกอบ 50 Confusion matrix ของ Quadratic SVM

## ผลลัพธ์การจำแนกทำทางการนอนด้วย Cubic SVM แสดงดังภาพประกอบ 51


Output Class	1	2	3	4	5	
1	37392 19.8%	0 0.0%	17 0.0%	47 0.0%	11 0.0%	99.8% 0.2%
2	6 0.0%	37795 20.0%	0 0.0%	4 0.0%	3 0.0%	100.0% 0.0%
3	24 0.0%	0 0.0%	37715 20.0%	47 0.0%	1 0.0%	99.8% 0.2%
4	348 0.2%	4 0.0%	68 0.0%	37698 19.9%	7 0.0%	98.9% 1.1%
5	30 0.0%	1 0.0%	0 0.0%	4 0.0%	37778 20.0%	99.9% 0.1%
	98.9% 1.1%	100.0% 0.0%	99.8% 0.2%	99.7% 0.3%	99.9% 0.1%	99.7% 0.3%
	Target Class					

Output Class	1	2	3	4	5	
1	6126 17.0%	16 0.0%	0 0.0%	615 1.7%	0 0.0%	90.7% 9.3%
2	322 0.9%	6090 16.9%	2 0.0%	30 0.1%	2 0.0%	94.5% 5.5%
3	240 0.7%	2 0.0%	7192 20.0%	30 0.1%	0 0.0%	96.4% 3.6%
4	511 1.4%	1092 3.0%	6 0.0%	6520 18.1%	10 0.0%	80.1% 19.9%
5	1 0.0%	0 0.0%	0 0.0%	5 0.0%	7188 20.0%	99.9% 0.1%
	85.1% 14.9%	84.6% 15.4%	99.9% 0.1%	90.6% 9.4%	99.8% 0.2%	92.0% 8.0%
	Target Class					

Output Class	1	2	3	4	5	
1	5029 14.0%	57 0.2%	892 2.5%	82 0.2%	7 0.0%	82.9% 17.1%
2	1831 5.1%	7136 19.8%	499 1.4%	7 0.0%	45 0.1%	75.0% 25.0%
3	103 0.3%	0 0.0%	5743 16.0%	32 0.1%	0 0.0%	97.7% 2.3%
4	219 0.6%	2 0.0%	66 0.2%	7075 19.7%	596 1.7%	88.9% 11.1%
5	18 0.1%	5 0.0%	0 0.0%	4 0.0%	6552 18.2%	99.6% 0.4%
	69.8% 30.2%	99.1% 0.9%	79.8% 20.2%	98.3% 1.7%	91.0% 9.0%	87.6% 12.4%
	Target Class					


ภาพประกอบ 51 Confusion matrix ของ Cubic SVM

ผลลัพธ์การจำแนกทำทางการนอนด้วย Fine Gaussian SVM แสดงดัง  
ภาพประกอบ 52




ภาพประกอบ 52 Confusion matrix ของ Fine Gaussian SVM

ผลลัพธ์การจำแนกทำทางารนด้วย Medium Gaussian SVM แสดงดัง  
ภาพประกอบ 53



ภาพประกอบ 53 Confusion matrix ของ Medium Gaussian SVM

ผลลัพธ์การจำแนกทำทางการนอนด้วย Coarse Gaussian SVM แสดงดังภาพประกอบ 54



ภาพประกอบ 54 Confusion matrix ของ Coarse Gaussian SVM

## ผลลัพธ์การจำแนกทำทางการนอนด้วย Fine KNN แสดงดังภาพประกอบ 55

Output Class	1	2	3	4	5	
1	37800 20.0%	0 0.0%	14 0.0%	570 0.3%	3 0.0%	98.5% 1.5%
2	0 0.0%	37800 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	37786 20.0%	128 0.1%	0 0.0%	99.7% 0.3%
4	0 0.0%	0 0.0%	0 0.0%	37102 19.6%	1 0.0%	100.0% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	37796 20.0%	100% 0.0%
	100% 0.0%	100% 0.0%	100.0% 0.0%	98.2% 1.8%	100.0% 0.0%	99.8% 0.4%
	Target Class	1	2	3	4	5

Output Class	1	2	3	4	5	
1	6064 16.8%	917 2.5%	9 0.0%	475 1.3%	38 0.1%	80.8% 19.2%
2	395 1.1%	4601 12.8%	12 0.0%	131 0.4%	14 0.0%	89.3% 10.7%
3	236 0.7%	85 0.2%	6191 17.2%	420 1.2%	7 0.0%	89.2% 10.8%
4	451 1.3%	1405 3.9%	973 2.7%	6069 16.9%	310 0.9%	65.9% 34.1%
5	54 0.1%	192 0.5%	15 0.0%	105 0.3%	6831 19.0%	94.9% 5.1%
	84.2% 15.8%	63.9% 36.1%	86.0% 14.0%	84.3% 15.7%	94.9% 5.1%	82.7% 17.3%
	Target Class	1	2	3	4	5

Output Class	1	2	3	4	5	
1	6367 17.7%	343 1.0%	934 2.6%	607 1.7%	855 2.4%	69.9% 30.1%
2	297 0.8%	6173 17.1%	715 2.0%	65 0.2%	626 1.7%	78.4% 21.6%
3	154 0.4%	88 0.2%	5259 14.6%	140 0.4%	148 0.4%	90.8% 9.2%
4	337 0.9%	545 1.5%	265 0.7%	6129 17.0%	23 0.1%	84.0% 16.0%
5	45 0.1%	51 0.1%	27 0.1%	259 0.7%	5548 15.4%	93.6% 6.4%
	88.4% 11.6%	85.7% 14.3%	73.0% 27.0%	85.1% 14.9%	77.1% 22.9%	81.9% 18.1%
	Target Class	1	2	3	4	5

ภาพประกอบ 55 Confusion matrix ของ Fine KNN

## ผลลัพธ์การจำแนกทำทางการนอนด้วย Medium KNN แสดงดังภาพประกอบ 56


1	37443 19.8%	233 0.1%	195 0.1%	548 0.3%	133 0.1%	97.1% 2.9%
2	75 0.0%	37382 19.8%	28 0.0%	26 0.0%	21 0.0%	99.6% 0.4%
3	89 0.0%	64 0.0%	37468 19.8%	123 0.1%	25 0.0%	99.2% 0.8%
4	154 0.1%	83 0.0%	102 0.1%	37074 19.6%	77 0.0%	98.9% 1.1%
5	39 0.0%	38 0.0%	7 0.0%	29 0.0%	37544 19.9%	99.7% 0.3%
	99.1% 0.9%	98.9% 1.1%	99.1% 0.9%	98.1% 1.9%	99.3% 0.7%	98.9% 1.1%
	1	2	3	4	5	
	Target Class					

1	6221 17.3%	859 2.4%	10 0.0%	286 0.8%	254 0.7%	81.5% 18.5%
2	348 1.0%	4585 12.7%	4 0.0%	62 0.2%	9 0.0%	91.6% 8.4%
3	127 0.4%	61 0.2%	6387 17.7%	603 1.7%	6 0.0%	88.9% 11.1%
4	462 1.3%	1670 4.6%	797 2.2%	6165 17.1%	56 0.2%	67.4% 32.6%
5	42 0.1%	25 0.1%	2 0.0%	94 0.2%	6875 19.1%	97.8% 2.2%
	86.4% 13.6%	63.7% 36.3%	88.7% 11.3%	85.6% 14.4%	95.5% 4.5%	84.0% 16.0%
	1	2	3	4	5	
	Target Class					

1	6527 18.1%	684 1.9%	1197 3.3%	169 0.5%	540 1.5%	71.6% 28.4%
2	183 0.5%	5804 16.1%	667 1.9%	39 0.1%	454 1.3%	81.2% 18.8%
3	95 0.3%	88 0.2%	5005 13.9%	282 0.8%	45 0.1%	90.6% 9.2%
4	345 1.0%	590 1.6%	316 0.9%	6701 18.6%	83 0.2%	83.4% 16.6%
5	50 0.1%	34 0.1%	15 0.0%	9 0.0%	6078 16.9%	98.3% 1.7%
	90.7% 9.3%	80.6% 19.4%	69.5% 30.5%	93.1% 6.9%	84.4% 15.6%	83.7% 16.3%
	1	2	3	4	5	
	Target Class					

ภาพประกอบ 56 Confusion matrix ของ Medium KNN

ผลลัพธ์การจำแนกทำทางการนอนด้วย Coarse KNN แสดงดังภาพประกอบ 57



ภาพประกอบ 57 Confusion matrix ของ Coarse KNN

## ผลลัพธ์การจำแนกทำทางการนอนด้วย Cosine KNN แสดงดังภาพประกอบ 58

Output Class	1	2	3	4	5	Accuracy
1	37470 19.8%	250 0.1%	182 0.1%	562 0.3%	134 0.1%	97.1% 2.9%
2	64 0.0%	37374 19.8%	29 0.0%	37 0.0%	35 0.0%	99.6% 0.4%
3	97 0.1%	49 0.0%	37485 19.8%	113 0.1%	16 0.0%	99.3% 0.7%
4	124 0.1%	81 0.0%	97 0.1%	37050 19.6%	56 0.0%	99.0% 1.0%
5	45 0.0%	46 0.0%	7 0.0%	38 0.0%	37559 19.9%	99.6% 0.4%
	99.1% 0.9%	98.9% 1.1%	99.2% 0.8%	98.0% 2.0%	99.4% 0.6%	98.9% 1.1%
Target Class	1	2	3	4	5	


Output Class	1	2	3	4	5	Accuracy
1	6275 17.4%	759 2.1%	11 0.0%	710 2.0%	151 0.4%	79.4% 20.6%
2	297 0.8%	4641 12.9%	4 0.0%	94 0.3%	7 0.0%	92.0% 8.0%
3	394 1.1%	10 0.0%	6411 17.8%	164 0.5%	5 0.0%	91.8% 8.2%
4	204 0.6%	1765 4.9%	771 2.1%	6170 17.1%	20 0.1%	69.1% 30.9%
5	30 0.1%	25 0.1%	3 0.0%	62 0.2%	7017 19.5%	98.3% 1.7%
	87.2% 12.8%	64.5% 35.5%	89.0% 11.0%	85.7% 14.3%	97.5% 2.5%	84.8% 15.2%
Target Class	1	2	3	4	5	

Output Class	1	2	3	4	5	Accuracy
1	6605 18.3%	594 1.7%	1427 4.0%	238 0.7%	328 0.9%	71.9% 28.1%
2	221 0.6%	6088 16.9%	655 1.8%	50 0.1%	596 1.7%	80.0% 20.0%
3	86 0.2%	46 0.1%	4872 13.5%	405 1.1%	7 0.0%	90.0% 10.0%
4	259 0.7%	439 1.2%	235 0.7%	6502 18.1%	19 0.1%	87.2% 12.8%
5	29 0.1%	33 0.1%	11 0.0%	5 0.0%	6250 17.4%	98.8% 1.2%
	91.7% 8.3%	84.6% 15.4%	67.7% 32.3%	90.3% 9.7%	88.8% 13.2%	84.2% 15.8%
Target Class	1	2	3	4	5	

ภาพประกอบ 58 Confusion matrix ของ Cosine KNN

## ผลลัพธ์การจำแนกทำทางการนอนด้วย Weighted KNN แสดงดังภาพประกอบ

59



ภาพประกอบ 59 Confusion matrix ของ Weighted KNN

ผลลัพธ์การจำแนกท่าทางการนอนด้วย Fine Decision Tree แสดงดัง  
ภาพประกอบ 60


1	32404 17.1%	690 0.4%	1723 0.9%	198 0.1%	29 0.0%	92.5% 7.5%
2	117 0.1%	32029 16.9%	177 0.1%	138 0.1%	91 0.0%	98.4% 1.6%
3	67 0.0%	22 0.0%	27095 14.3%	31 0.0%	24 0.0%	99.5% 0.5%
4	5121 2.7%	5008 2.6%	8786 4.6%	37338 19.8%	4998 2.6%	61.0% 39.0%
5	91 0.0%	51 0.0%	19 0.0%	95 0.1%	32658 17.3%	99.2% 0.8%
	85.7% 14.3%	84.7% 15.3%	71.7% 28.3%	98.8% 1.2%	86.4% 13.6%	85.5% 14.5%
	1	2	3	4	5	
	Target Class					

1	6329 17.6%	215 0.6%	253 0.7%	103 0.3%	2 0.0%	91.7% 8.3%
2	604 1.7%	4933 13.7%	175 0.5%	56 0.2%	4 0.0%	85.5% 14.5%
3	140 0.4%	3 0.0%	4864 13.5%	42 0.1%	1 0.0%	96.3% 3.7%
4	123 0.3%	1796 5.0%	1886 5.2%	6947 19.3%	265 0.7%	63.1% 36.9%
5	4 0.0%	253 0.7%	22 0.1%	52 0.1%	6928 19.2%	95.4% 4.6%
	87.9% 12.1%	68.5% 31.5%	67.6% 32.4%	96.5% 3.5%	96.2% 3.8%	83.3% 16.7%
	1	2	3	4	5	
	Target Class					

1	6994 19.4%	32 0.1%	700 1.9%	285 0.8%	11 0.0%	87.2% 12.8%
2	40 0.1%	6574 18.3%	675 1.9%	145 0.4%	1038 2.9%	77.6% 22.4%
3	37 0.1%	31 0.1%	5803 16.1%	49 0.1%	7 0.0%	97.9% 2.1%
4	97 0.3%	369 1.0%	20 0.1%	6640 18.4%	2526 7.0%	68.8% 31.2%
5	32 0.1%	194 0.5%	2 0.0%	81 0.2%	3618 10.1%	92.1% 7.9%
	97.1% 2.9%	91.3% 8.7%	80.6% 19.4%	92.2% 7.8%	50.2% 49.8%	82.3% 17.7%
	1	2	3	4	5	
	Target Class					

ภาพประกอบ 60 Confusion matrix ของ Fine Decision Tree

ผลลัพธ์การจำแนกท่าทางการนอนด้วย Linear Discriminant แสดงดัง  
ภาพประกอบ 61



ภาพประกอบ 61 Confusion matrix ของ Linear Discriminant

ผลลัพธ์การจำแนกท่าทางการนอนด้วย Quadratic Discriminant แสดงดัง  
ภาพประกอบ 62


1	33850 17.9%	703 0.4%	221 0.1%	550 0.3%	108 0.1%	95.5% 4.5%
2	1605 0.8%	35528 18.8%	24 0.0%	512 0.3%	335 0.2%	93.5% 6.5%
3	1316 0.7%	37 0.0%	36565 19.3%	367 0.2%	27 0.0%	95.4% 4.6%
4	646 0.3%	14 0.0%	983 0.5%	35397 18.7%	23 0.0%	95.5% 4.5%
5	381 0.2%	1518 0.8%	7 0.0%	974 0.5%	37307 19.7%	92.8% 7.2%
	89.6% 10.4%	94.0% 6.0%	96.7% 3.3%	93.6% 6.4%	96.7% 1.3%	94.5% 5.5%
	1	2	3	4	5	
	1	2	3	4	5	

1	6104 17.0%	42 0.1%	5 0.0%	123 0.3%	22 0.1%	97.0% 3.0%
2	436 1.2%	6750 18.8%	1 0.0%	1414 3.9%	42 0.1%	78.1% 21.9%
3	625 1.7%	7 0.0%	7133 19.8%	217 0.6%	0 0.0%	89.4% 10.6%
4	24 0.1%	401 1.1%	61 0.2%	5446 15.1%	14 0.0%	91.6% 8.4%
5	11 0.0%	0 0.0%	0 0.0%	0 0.0%	7122 19.6%	99.8% 0.2%
	84.8% 15.2%	93.8% 6.3%	99.1% 0.9%	75.6% 24.4%	98.9% 1.1%	90.4% 9.6%
	1	2	3	4	5	
	1	2	3	4	5	

1	6445 17.9%	394 1.1%	1365 3.8%	1034 2.9%	113 0.3%	68.9% 31.1%
2	105 0.3%	6788 18.9%	33 0.1%	39 0.1%	1037 2.9%	84.8% 15.2%
3	646 1.8%	1 0.0%	5802 16.1%	221 0.6%	4 0.0%	86.9% 13.1%
4	0 0.0%	0 0.0%	0 0.0%	5905 16.4%	2 0.0%	100.0% 0.0%
5	4 0.0%	17 0.0%	0 0.0%	1 0.0%	6044 16.8%	99.6% 0.4%
	89.5% 10.5%	94.3% 5.7%	80.6% 19.4%	82.0% 18.0%	83.9% 16.1%	86.1% 13.9%
	1	2	3	4	5	
	1	2	3	4	5	

ภาพประกอบ 62 Confusion matrix ของ Quadratic Discriminant

## ผลลัพธ์การจำแนกท่าทางการนอนด้วย Gaussian Naive Bayes แสดงดัง ภาพประกอบ 63



ภาพประกอบ 63 Confusion matrix ของ Gaussian Naive Bayes

จากภาพประกอบ 46-63 แสดงให้เห็นถึงเปอร์เซ็นต์ความถูกต้องของแต่ละโมเดลระบบจำแนกท่าทางการนอนที่เกิดขึ้น โดยเปอร์เซ็นต์ความแม่นยำของทุกอัลกอริทึมของขั้นตอน train, validation และ test ที่ถูกใช้ในงานวิจัยนี้ แสดงดังตาราง 6 เพื่อง่ายต่อการเปรียบเทียบ

ตาราง 6 การเปรียบเทียบการเรียนรู้ของเครื่องจักรทั้งหมดที่ถูกใช้ในการจำแนกท่าทางการนอน

กระบวนกรจำแนก		Accuracy of Train (%)	Accuracy of Validation (%)	Accuracy of Test (%)
Neural Network	Hidden Layers 200 nodes	70.0	70.3	71.2
	Hidden Layers 300 nodes	82.1	81.0	80.9
	Hidden Layers 400 nodes	88.3	82.2	81.9
SVM	Linear	98.6	90.8	92.9
	Quadratic	99.6	92.8	89.9
	Cubic	99.7	92.0	87.6
	Fine Gaussian	99.8	54.3	49.7
	Medium Gaussian	99.5	89.9	85.6
	Coarse Gaussian	97.9	92.4	94.0
KNN	Fine	99.6	82.7	81.9
	Medium	98.9	84.0	83.7
	Coarse	98.3	84.4	81.5
	Cosine	98.9	84.8	84.2
	Weighted	99.8	83.8	85.0
Decision Tree	Fine	85.5	83.3	82.3
Discriminant Analysis	Linear	91.7	88.2	91.5
	Quadratic	94.5	90.4	86.1
Gaussian Naive Bayes		90.4	86.2	82.2

ต่อมาเราจะนำข้อมูลความแม่นยำเฉพาะในส่วนของขั้นตอน test จากตาราง 6 มาแสดงให้เห็นถึงเปอร์เซ็นต์ความถูกต้องของแต่ละท่าทางการนอนพร้อมกับคำนวณส่วนเบี่ยงเบนมาตรฐาน(S.D.) เพื่อดูความกระจายตัวของเปอร์เซ็นต์ที่เกิดขึ้นในแต่ละท่าทางแสดงดังตาราง 7-8

$$\text{Standard Deviation}(SD) = \sqrt{\frac{\sum(x_i - \mu)^2}{n}} \quad (19)$$

จากสมการที่ 19 กำหนดให้  $x_i$  คือ ข้อมูลเปอร์เซ็นต์ของแต่ละท่าทาง,  $\mu$  คือ ค่าเฉลี่ยประชากรของข้อมูลเปอร์เซ็นต์ของแต่ละท่าทาง และ  $n$  จำนวนท่าทางการนอน

ตาราง 7 การแสดงผลความแม่นยำของข้อมูลทดสอบและส่วนเบี่ยงเบนมาตรฐานของ Sensitivity

กระบวนการจำแนก	Sensitivity (%)					Accuracy (%)	S.D.
	นอนหงาย (7200)	นอนตะแคงซ้าย (7200)	นอนตะแคงขวา (7200)	นั่ง (7200)	นอนขอบเตียง (7200)		
Neural Network	200 nodes	2378 (33.0%)	6149 (85.4%)	5346 (74.3%)	4651 (64.6%)	7106 (98.7%)	71.2 22.2
	300 nodes	2545 (35.3%)	5934 (82.4%)	6461 (89.7%)	7032 (97.7%)	7153 (99.3%)	80.9 23.6
	400 nodes	2141 (29.7%)	6814 (94.6%)	6558 (91.1%)	6916 (96.1%)	7052 (97.9%)	81.9 26.2
SVM	Linear	6384 (88.7%)	7106 (98.7%)	6384 (88.7%)	6971 (96.8%)	6583 (91.4%)	92.9 4.6
	Quadratic	5116 (71.1%)	7167 (99.5%)	5920 (82.2%)	7055 (98.0%)	7100 (98.6%)	89.9 12.7
	Cubic	5029 (69.8%)	7136 (99.1%)	5743 (79.8%)	7075 (98.3%)	6552 (91.0%)	87.6 12.6
	Fine Gaussian	7111 (98.8%)	2689 (37.3%)	2778 (38.6%)	3397 (47.2%)	1921 (26.7%)	49.7 28.4
	Medium Gaussian	6967 (96.8%)	5890 (81.8%)	6075 (84.4%)	5818 (80.8%)	6079 (84.4%)	85.6 6.4
	Coarse Gaussian	6907 (95.9%)	7145 (99.2%)	6366 (88.4%)	6924 (96.2%)	6506 (90.4)	94.0 4.5
KNN	Fine	6367 (88.4%)	6173 (85.7%)	5259 (73.0%)	6129 (85.1%)	5548 (77.1%)	81.9 6.5
	Medium	6527 (90.7%)	5804 (80.6%)	5005 (69.5%)	6701 (93.1%)	6078 (84.4%)	83.7 9.3
	Coarse	6555 (91.0%)	5924 (82.3%)	5087 (70.7%)	5849 (81.2%)	5941 (82.5%)	81.5 7.2
	Cosine	6605 (91.7%)	6088 (84.6%)	4872 (67.7%)	6502 (90.3%)	6250 (86.8%)	84.2 9.7
	Weighted	6483 (90.0%)	5979 (83.0%)	5108 (70.9%)	6761 (93.9%)	6269 (87.1%)	85.0 4.1
Decision Tree	Fine	6994 (97.1%)	6574 (91.3%)	5803 (80.6%)	6640 (92.2%)	3618 (50.2%)	82.3 18.9
Discriminant Analysis	Linear	6981 (97.0%)	7047 (97.9%)	6096 (84.7%)	6306 (87.6%)	6522 (90.6%)	91.5 5.8
	Quadratic	6445 (89.5%)	6788 (94.3%)	5802 (80.6%)	5905 (82.0%)	6044 (83.9%)	86.1 5.7
Gaussian Naive Bayes		6020 (83.6%)	6425 (89.2%)	5648 (78.4%)	5565 (77.3%)	5940 (82.5%)	82.2 4.7

ตาราง 8 การแสดงผลความแม่นยำของข้อมูลทดสอบและส่วนเบี่ยงเบนมาตรฐานของ Precision

Classifier method	Precision (%)					Accuracy (%)	S.D.	
	นอนหงาย	นอนตะแคงซ้าย	นอนตะแคงขวา	นั่ง	นอนขอบเตียง			
Neural Network	200 nodes	56.0	80.3	68.1	54.8	91.5	71.2	12.9
	300 nodes	91.6	67.2	85.2	75.7	95.1	80.9	10.3
	400 nodes	89.8	66.5	87.5	80.4	97.0	81.9	10.3
SVM	Linear	89.9	82.9	97.2	97.5	99.5	92.9	6.2
	Quadratic	83.1	76.7	98.7	95.7	99.6	89.9	9.2
	Cubic	82.9	75.0	97.7	88.9	99.6	87.6	9.2
	Fine Gaussian	28.4	97.1	97.0	99.9	100	49.7	28.1
	Medium Gaussian	59.2	96.1	98.3	99.7	100.0	85.6	15.8
	Coarse Gaussian	91.7	86.3	95.8	98.6	99.8	94.0	4.9
KNN	Fine	69.9	78.4	90.8	84.0	93.6	81.9	8.6
	Medium	71.6	81.2	90.8	83.4	98.3	83.7	9.0
	Coarse	76.1	75.4	82.9	82.0	94.9	81.5	7.0
	Cosine	71.9	80.0	90.0	87.2	98.8	84.2	9.1
	Weighted	75.1	82.5	91.5	83.0	98.1	85.0	8.0
Decision Tree	Fine	87.2	77.6	97.9	68.8	92.1	82.3	10.4
Discriminant Analysis	Linear	87.5	88.4	90.8	92.9	99.8	91.5	4.4
	Quadratic	68.9	84.8	86.9	100.0	99.6	86.1	11.4
Gaussian Naive Bayes		65.6	79.2	78.7	100.0	99.5	82.2	13.3

## บทที่ 5

### อภิปรายผล และสรุปผลการวิจัย

#### 5.1 อภิปรายผล

ในงานวิจัยนี้เราใช้เซ็นเซอร์แรงกดเรียงเป็นเมตริก  $10 \times 10$  รวมทั้งหมด 100 ตัว เนื่องจากเราต้องการติดตั้งเซ็นเซอร์ให้สามารถครอบคลุมได้ทั้งเตียง โดยยังคงสามารถรับข้อมูลแรงกดจากน้ำหนักของกลุ่มตัวอย่างได้ จากผลลัพธ์การทดลองในหัวข้อ “4.4 การแสดงผลจากเซ็นเซอร์” แสดงให้เห็นว่าการใช้เซ็นเซอร์ในจำนวน 100 ตัว สามารถนำมาใช้สำหรับการจำแนกท่าทางการนอนและแสดงผลการทำทางการนอนเป็นแผนภาพแรงกดได้อย่างชัดเจน

ตาราง 9 การเปรียบเทียบงานวิจัยนี้กับงานวิจัยก่อนหน้า

งานวิจัย, ปี	ชุดข้อมูล	จำนวนเซ็นเซอร์	วิธีการจำแนก	จำนวนท่าทาง	ความแม่นยำ (%)
1) Barsocchi, P และคณะ Conference Paper 2016	$N_T = n/a$ $T_p = 72000$	48	Machine learning (logistic regression)	4(นอนหงาย, นอนคว่ำ, นอนตะแคงซ้าย และ นอน ตะแคงขวา)	91.4
2) Barsocchi, P และคณะ Journal Article 2016	$N_T = 14$ $T_p = 1848$	$64 \times 128$	K-Nearest Neighbors (KNN)	6(นอนหงาย, นอนคว่ำ, นอนตะแคงซ้าย, นอน ตะแคงขวา, นอนคตตัว ซ้าย และนอนคตตัวขวา)	91.21
3) Sri-ngemyuang, C และคณะ (ประเทศไทย) Conference Paper 2018	$N_T = 6$ $T_p = n/a$	$12 \times 12$	Artificial Neural Network (ANN)	5(นอนหงาย, นอนตะแคง ซ้าย, นอนตะแคงขวา, นิ่ง และนอนมุมเดียว)	87.0
4)Dhamchatsoontree, S และคณะ(ประเทศไทย) Conference Paper 2019	$N_T = 35$ $T_p = 1983$	$8 \times 6$	K-Nearest Neighbors (KNN)	6(นอนหงาย, นอนตะแคง ซ้าย, นิ่ง, เปลี่ยนท่า และ ลุกออกจากเตียง)	ข้อมูลดิบ : 91.1, ไต่ระดับสี : 88.8 และข้อมูล มาตรฐาน : 86.7
5) Matar, G และคณะ Journal Article 2020	$N_T = 12$ $T_p = 1116$	$64 \times 27$	Artificial Neural Network (ANN)	4(นอนหงาย, นอนคว่ำ, นอนตะแคงซ้าย และ นอน ตะแคงขวา)	97.9
งานวิจัยนี้	$N_T = 30$ $T_p = 270,000$	$10 \times 10$	Support Vector Machine (SVM)	5(นอนหงาย, นอนตะแคง ซ้าย, นอนตะแคงขวา, นิ่ง และนอนขอบเตียง)	94.0

จากตาราง 9 เมื่อเปรียบเทียบกับงานวิจัยก่อนหน้าในส่วนของจำนวนเซ็นเซอร์แรงกดที่ ถูกใช้งาน จะพบว่าเซ็นเซอร์แรงกดมีการใช้งานตั้งแต่ขนาด  $8 \times 6$  จนไปถึง  $64 \times 128$  ตัว โดยงานวิจัยนี้ เราสามารถให้เซ็นเซอร์แรงกดขนาด  $10 \times 10$  ในการจำแนกท่าทางการนอนจำนวน 5 ท่าทาง โดยยังคงได้รับค่าความแม่นยำสูงสุดจากอัลกอริทึม Coarse Gaussian SVM อยู่ที่ 94.0% ทำให้งานวิจัยนี้มีจุดเด่นในการใช้เซ็นเซอร์ที่น้อย โดยยังคงความสามารถในการจำแนกท่าทางการนอนได้แม่นยำเทียบเท่ากับงานวิจัยที่ใช้เซ็นเซอร์ในจำนวนที่มากกว่าได้

อีกทั้งในส่วนของการนอน หนึ่งในท่านอนที่เราสามารถจำแนกได้ คือ ท่านอนขอบเตียง ทำให้งานวิจัยนี้มีจุดเด่นในการบอกถึงท่าทางที่มีความเสี่ยงต่อการเกิดการพลัดตกจากเตียง เพื่อใช้ในการพัฒนาระบบแจ้งเตือนก่อนการพลัดตกจากเตียง สำหรับป้องกันการเกิดอุบัติเหตุร้ายแรงขณะนอนหลับในกลุ่มผู้สูงอายุได้ในอนาคต

แต่งานวิจัยนี้ยังคงมีข้อจำกัดในส่วนของการไม่สามารถใช้ร่วมกับหมอนได้ เนื่องจากในขั้นตอนการเก็บข้อมูลจากกลุ่มตัวอย่าง เราต้องการใช้ตำแหน่งแรงกดจากส่วนหัวของกลุ่มตัวอย่างในการเป็นอีกหนึ่งจุดสำหรับใช้บอกท่าทางการนอนในขณะนั้น ทำให้การใช้งานจริงอาจเกิดความไม่สบายตัวขึ้นได้ อีกทั้งเราตั้งขอบเขตงานวิจัยให้เก็บข้อมูลท่านอนขอบเตียงจากด้านซ้ายเพียงด้านเดียว เนื่องจากข้อจำกัดในการใช้สถานที่ ทำให้ในอนาคตเราจึงจำเป็นต้องเพิ่มท่านอนขอบเตียงอีกด้านให้สมบูรณ์ พร้อมกับเก็บข้อมูลท่าทางการนอนในแต่ละท่าให้มีความหลากหลายของตำแหน่งการนอนที่มากยิ่งขึ้น และทดลองการจำแนกท่าทางการนอนโดยมีหมอนเป็นส่วนประกอบ

ในอนาคตเรามีความสนใจในการจำแนกท่าทางการนอนในจำนวนที่มากขึ้น โดยเฉพาะท่านอนคว่ำ ที่มีลักษณะและตำแหน่งแรงกดที่คล้ายคลึงกับท่านอนหงายเป็นอย่างมาก ทำให้การพัฒนาต่อยอดจำเป็นต้องใช้กระบวนการที่มีความเหมาะสมในการจำแนกท่าทาง เช่น การใช้กระบวนการสอดแทรก(Interpolation) ในการเพิ่มขอบเขตเซ็นเซอร์แรงกดที่มีอยู่อย่างจำกัด ให้มีขอบเขตของจุดแรงกดที่มากขึ้น, การใช้กระบวนการด้านการประมวลผลภาพ(Image Processing) อย่าง Histogram of Orientation Gradient (HOG) ในการช่วยหาลักษณะเด่น (Feature Extraction) ของข้อมูล และการใช้การเรียนรู้เชิงลึก(Dep learning) เพื่อเพิ่มประสิทธิภาพการเรียนรู้ของระบบจำแนกท่าทางให้ดียิ่งขึ้น

## 5.2 สรุปผลการวิจัย

งานวิจัยนี้เป็นการพัฒนาต่อยอดจากงานวิจัยก่อนหน้าเรื่องระบบแจ้งเตือนการพลัดตกจากเตียง ที่ใช้เซ็นเซอร์แรงกดของ DFRobot ร่วมกับเซ็นเซอร์อัลตราโซนิกอย่างละ 6 ตัว สำหรับจำแนกสถานะการนอน 3 ท่า คือ นอนบนเตียง นั่ง และการพลัดตกจากเตียง ด้วยกระบวนการ Finite State Machine ซึ่งผลลัพธ์ความแม่นยำที่ได้รับจากกระบวนการนี้คือ 86.67% โดยระบบยังคงขาดความยืดหยุ่นในการจำแนก มีความหน่วงในการแจ้งเตือน และการตรวจพบการพลัดตกจากเตียงสามารถทำได้หลังจากเกิดขึ้นไปแล้ว อีกทั้งการทดสอบประสิทธิภาพของเซ็นเซอร์จากตาราง 5 พบว่า เซ็นเซอร์แรงกดของ Tekscan ได้รับค่า Root Mean Squared Error อยู่ที่ 0.14 ซึ่งน้อยกว่าเซ็นเซอร์แรงกดที่เคยใช้เป็นอย่างมาก

จากการศึกษาข้างต้นเราจึงพัฒนาระบบจำแนกท่าทางการนอนด้วยการเรียนรู้ของเครื่องจักรประเภทต่างๆ ด้วยเซ็นเซอร์แรงกดของ Tekscan จัดเรียงเป็นเมตริก 10 x 10 รวมทั้งสิ้น 100 ตัว สำหรับรับข้อมูลแรงกดจากร่างกายของผู้นอนที่กระจายลงบนเซ็นเซอร์ เพื่อนำไปสร้างโมเดลในการจำแนกท่าทางการนอนเป็นจำนวน 5 ท่าทาง คือ นอนหงาย นอนตะแคงซ้าย นอนตะแคงขวา นั่ง และท่านอนขอบเตียง โดยการทดลองนี้ใช้กลุ่มตัวอย่างจำนวน 30 คน เป็นชายและหญิงสุขภาพดีและไม่มีอาการบาดเจ็บ ชุดข้อมูลที่ถูกรวบรวมมาจากกลุ่มตัวอย่างจะถูกแบ่งเพื่อใช้สำหรับขั้นตอนการ train, validation และ test เป็น 70% 15% และ 15% ตามลำดับ โดยเราได้ใช้การเรียนรู้ของเครื่องจักรประเภทต่างๆ ประกอบด้วย Neural Network, Support Vector Machine(SVM), K-Nearest Neighbors(KNN), Decision Tree, Discriminant Analysis และ Gaussian Naive Bayes เพื่อหากระบวนการที่เหมาะสมกับชุดข้อมูลของเรามากที่สุด

จากตาราง 6 แสดงให้เห็นว่า Coarse Gaussian SVM เป็นอัลกอริทึมที่เมื่อเปรียบเทียบกับอัลกอริทึมอื่นๆ ถึงแม้ว่าความแม่นยำในชุดข้อมูล train จะไม่ได้สูงที่สุด แต่กระบวนการนี้สามารถบรรลุผลลัพธ์ความแม่นยำโดยรวมที่ดีที่สุด คือ 97.9% 92.4% และ 94.0% ด้วยชุดข้อมูลสำหรับ train, validation และ test ตามลำดับ แสดงให้เห็นว่ากระบวนการนี้มีความยืดหยุ่นกับชุดข้อมูลที่ยังไม่เคยเจอมาก่อนได้ดีเมื่อเทียบกับกระบวนการที่เหลือ และจากตาราง 7-8 พบว่า Coarse Gaussian SVM สามารถจำแนกท่าทางการนอนแต่ละท่าทางได้ค่าความแม่นยำสูงที่สุด โดยยังคงได้รับส่วนเบี่ยงเบนมาตรฐาน(S.D.)จากการคำนวณ Sensitivity และ Precision ที่น้อยทั้งคู่ แสดงให้เห็นว่าอัลกอริทึมตัวนี้สามารถจำแนกท่าทางการนอนได้ด้วยความแม่นยำที่ใกล้เคียงกันในทุกๆ ท่าทาง

ในอนาคตเรามีความประสงค์ที่จะพัฒนาระบบจำแนกท่าทางการนอนให้สามารถแจ้งเตือนผ่านระบบ Internet of Things (IoT) เมื่อตรวจพบว่าผู้นอนอยู่ในท่านอนขบเตียงซึ่งเป็นท่าที่มีความเสี่ยงที่จะเกิดการพลัดตกจากเตียงได้ และนำระบบที่ถูกพัฒนาขึ้นนี้ไปทดสอบความพึงพอใจโดยการลงพื้นที่จริงในชุมชนผู้สูงอายุ อำเภอองครักษ์ จังหวัดนครนายก เพื่อหาทางพัฒนาต่อยอดต่อไปในอนาคต

### 5.3 ข้อเสนอแนะ

ในอนาคต ระบบจำแนกท่าทางการนอนควรได้รับการเก็บข้อมูลเพิ่มเติมให้มีความหลากหลายที่มากขึ้น และสามารถจำแนกท่าทางการนอนโดยใช้ร่วมกับหมอนได้ เนื่องจากเวลาใช้งานจริง ผู้นอนอาจเกิดความไม่สบายตัวหากนอนบนเตียงโดยไม่มีหมอน รวมไปถึงการเก็บข้อมูลสำหรับการจำแนกท่านอนขบเตียงอีกด้าน เพื่อความสมบูรณ์ของระบบ อีกทั้งยังสามารถใช้กระบวนการสอดแทรก (Interpolation) ซึ่งเป็นหนึ่งในกระบวนการที่ถูกใช้กันอย่างแพร่หลาย ในการพัฒนาต่อยอดสู่การใช้การเรียนรู้เชิงลึก (Deep learning) สำหรับเพิ่มประสิทธิภาพของโมเดลการจำแนกท่าทางการนอนที่ดีขึ้นได้ งานวิจัยนี้มีข้อเสนอแนะสำหรับกลุ่มผู้ใช้งานที่นำอุปกรณ์ไปประยุกต์ใช้ประโยชน์ ได้แก่

1. กลุ่มผู้ใช้งานส่วนบุคคล ได้แก่ บุคคลทั่วไปทุกช่วงอายุ ได้ให้คำแนะนำการใช้ระบบจำแนกท่าทางการนอน ในการติดตามท่าทางการนอนในชีวิตประจำวัน และเฝ้าระวังท่าทางการนอนที่มีความเสี่ยงต่อการเกิดอุบัติเหตุร้ายแรงโดยเฉพาะในกลุ่มผู้สูงอายุอย่างการพลัดตกจากเตียงได้ เนื่องจากยีนนอนใกล้ขบเตียงมากจนเกินไป ความเสี่ยงที่อาจเกิดการพลัดตกจากเตียงจะยิ่งสูงตาม ดังนั้นการรับรู้ก่อนเหตุการณ์นี้จะเกิดขึ้น จึงสามารถช่วยลดความเสียหายและจำนวนผู้เสียชีวิตจากการพลัดตกจากเตียงได้เป็นอย่างมาก

2. กลุ่มผู้ใช้งานในส่วนที่เป็นองค์กร สถานที่ ได้แก่ บ้านผู้สูงอายุ สถานดูแลผู้สูงอายุ หน่วยงานรัฐ หน่วยงานเอกชน โรงพยาบาล อาสาสมัครสาธารณสุขประจำหมู่บ้าน (อสม.) และสำนักงานสาธารณสุขจังหวัด (สสจ.) ได้ให้คำแนะนำเกี่ยวกับงานวิจัยนี้โดยการพัฒนาเป็นอุปกรณ์สำหรับติดตามการนอนในชีวิตประจำวันและเฝ้าระวังความเสี่ยงที่อาจเกิดการพลัดตกจากเตียงได้ โดยสามารถนำไปใช้ในการติดตามผู้สูงอายุได้ทั้งในบ้านผู้สูงอายุหรือสถานดูแลผู้สูงอายุ เนื่องจากอุปกรณ์สามารถนำไปติดตั้งร่วมกับเตียงเดี่ยวได้ทุกเตียงและทุกสถานที่ที่สามารถเคลื่อนย้ายได้ง่าย และมีประสิทธิภาพในการจำแนกท่าทางการนอนเป็นอย่างดี หน่วยงานเอกชน สามารถนำอุปกรณ์ของงานวิจัยนี้ไปพัฒนาต่อยอด เพื่อทำการตลาดรวมกับการบริการของโรงพยาบาล ทั้งในรูปแบบการขายหรือการเช่าอุปกรณ์ หน่วยงานอาสาสมัครสาธารณสุข

ประจำหมู่บ้าน (อสม.) และสำนักงานสาธารณสุขจังหวัด (สสจ.) สามารถนำอุปกรณ์ที่ได้จากงานวิจัยนี้ไปใช้งานในการดูแลสุขภาพของผู้สูงอายุหรือผู้ที่มีความเสี่ยงที่จะพลัดตกจากเตียงในจังหวัดได้ เป็นต้น

3. กลุ่มผู้ใช้งานภาคเอกชน ภาคอุตสาหกรรม และภาคธุรกิจ ได้ให้แนะนำการนำอุปกรณ์จากงานวิจัยนี้ไปพัฒนาเชิงอุตสาหกรรม ได้แก่ การทดสอบมาตรฐานผลิตภัณฑ์อุตสาหกรรม (มอก.) เช่น มอก./ISO 13485 และนำไปพัฒนาเป็นอุปกรณ์ที่สามารถใช้งานร่วมกับเตียงขนาดอื่น เช่น เตียงคู่ หรือเตียงโรงพยาบาล เป็นต้น รูปแบบการเข้าถึงอุปกรณ์ในการจำหน่ายเชิงพาณิชย์ สามารถนำไปจำหน่ายได้หลากหลายช่อง เช่น การขายออนไลน์ การขายขาดให้บุคคล การขายและการเช่าให้กับหน่วยงานหรือองค์กรต่าง ๆ



## บรรณานุกรม

1. Pouyan MB, Birjandtalab J, Heydarzadeh M, Nourani M, Ostadabbas S, editors. A pressure map dataset for posture and subject analytics. 2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI); 2017 16-19 Feb. 2017.
2. Cartwright RD. Effect of sleep position on sleep apnea severity. *Sleep*. 1984;7(2):110-4.
3. Jeng P, Wang L, editors. Stream data analysis of body sensors for sleep posture monitoring: An automatic labelling approach. 2017 26th Wireless and Optical Communication Conference (WOCC); 2017 7-8 April 2017.
4. Dhamchatsoontree S, Sirisin C, Proncharoensukkul M, Wongpatikaseree K, editors. i-Sleep: Intelligent Sleep Detection System for Analyzing Sleep Behavior. 2019 4th International Conference on Information Technology (InCIT); 2019 24-25 Oct. 2019.
5. Choombuathong A, Chalopatham W, Dhongyooyen P, Chokchaiworrarat S, Thamwattana K, Changsap B, et al. Sleep Quality and Factors Related to Sleep and Self-esteem in the Elderly. *Journal of Health Science*. 2015:833-43.
6. Department of Disease Control Ministry of Public Health. Forecast of falls of the elderly (aged 60 and over) in Thailand Year 2017-2021 2016 [cited 2563. Available from: <http://www.thaincd.com/2016/mission/documents-detail.php?id=12095&tid=&gid=1-027>.
7. Colón CJP, Molina-Vicenty IL, Frontera-Rodríguez M, García-Ferré A, Rivera BP, Cintrón-Vélez G, et al. Muscle and Bone Mass Loss in the Elderly Population: Advances in diagnosis and treatment. *Journal of Biomedicine (Sydney, NSW)*. 2018;3:40.
8. Järvinen TL, Sievänen H, Khan KM, Heinonen A, Kannus P. Shifting the focus in fracture prevention from osteoporosis to falls. *Bmj*. 2008;336(7636):124-6.
9. Sri-ngernyuang C, Youngkong P, Lasuka D, Thamrongaphichartkul K, Pingmuang W, editors. Neural Network for On-bed Movement Pattern Recognition. 2018 11th Biomedical Engineering International Conference (BMEiCON); 2018 21-24 Nov. 2018.
10. Mohammadi SM, Alnowami M, Khan S, Dijk D, Hilton A, Wells K, editors. Sleep Posture Classification using a Convolutional Neural Network. 2018 40th Annual

International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2018 18-21 July 2018.

11. Zhao F, Cao Z, Xiao Y, Mao J, Yuan J. Real-Time Detection of Fall From Bed Using a Single Depth Camera. *IEEE Transactions on Automation Science and Engineering*. 2019;16(3):1018-32.
12. Barsocchi P, Bianchini M, Crivello A, Rosa DL, Palumbo F, Scarselli F, editors. An unobtrusive sleep monitoring system for the human sleep behaviour understanding. 2016 7th IEEE International Conference on Cognitive Infocommunications (CogInfoCom); 2016 16-18 Oct. 2016.
13. Matar G, Lina J, Kaddoum G. Artificial neural network for in-bed posture classification using bed-sheet pressure sensors. *IEEE Journal of Biomedical and Health Informatics*. 2019:1-.
14. Xu X, Lin F, Wang A, Hu Y, Huang M, Xu W. Body-Earth Mover's Distance: A Matching-Based Approach for Sleep Posture Recognition. *IEEE Transactions on Biomedical Circuits and Systems*. 2016;10(5):1023-35.
15. Pornpreedawan P, Kanut Puengsiricharoen, Sueaseenak D. Fall notification system. Nakhon Nayok: Srinakharinwirot University; 2019.
16. Tuomilehto H, Seppa J, Partinen M, Uusitupa M. Avoiding the supine posture during sleep for patients with mild obstructive sleep apnea. *American journal of respiratory and critical care medicine*. 2009;180(1):101-2.
17. Gordon S, Buettner PG. Age and lateral sleep position: a pilot study. *Internet Journal of Allied Health Sciences and Practice*. 2009;7(1):13.
18. Lorrain D, De Koninck J, Dionne H, Goupil G. Sleep positions and postural shifts in elderly persons. *Perceptual and motor skills*. 1986;63(2):352-4.
19. Organization WH, Ageing WHO, Unit LC. WHO global report on falls prevention in older age: World Health Organization; 2008.
20. Tekscan Inc. Best Practices for Electrical Integration of the FlexiForce Sensor [Available from: <https://www.tekscan.com/resources/product-guide/best-practices-electrical-integration-flexiforce-sensor>].

21. Wiggermann N, Smith K, Kumpar D. What bed size does a patient need? The relationship between body mass index and space required to turn in bed. *Nursing research*. 2017;66(6):483.
22. Kim P. Matlab deep learning. *With Machine Learning, Neural Networks and Artificial Intelligence*. 2017;130:21.
23. Theodoridis S, Koutroumbas K. *Pattern Recognition, Fourth Edition*: Academic Press, Inc.; 2008.
24. Han J, Kamber M, Pei J. *Data mining concepts and techniques third edition*. The Morgan Kaufmann Series in Data Management Systems. 2011;5(4):83-124.
25. MathWorks®. Choose Classifier Options 2021 [Available from: <https://www.mathworks.com/help/stats/choose-a-classifier.html>].
26. Hasan MJ, Kim J-M. Fault Detection of a Spherical Tank Using a Genetic Algorithm-Based Hybrid Feature Pool and k-Nearest Neighbor Algorithm. *Energies*. 2019;12(6):991.
27. Kingsford C, Salzberg SL. What are decision trees? *Nat Biotechnol*. 2008;26(9):1011-3.
28. Shiomi R, Shimasaki H, Takano H, Taoka H. A study on operating lifetime estimation for electrical components in power grids on the basis of analysis of maintenance records. *Journal of International Council on Electrical Engineering*. 2019;9(1):45-52.
29. Thanut Wongsachue. *Discriminant Analysis 2018* [Available from: <https://www.youtube.com/watch?v=OE7pim8bE3U>].
30. Jason Brownlee. *Naive Bayes for Machine Learning 2016* [Available from: <https://machinelearningmastery.com/naive-bayes-for-machine-learning/>].
31. Qualitest International Inc. *Universal Testing Machine - QM Series* [Available from: <https://www.worldoftest.com/universal-testing-machine-qm-series>].
32. Suksupaet B, Senavongse W, Ritthiwat W, Sueaseenak D, editors. *A Wireless Ground Reaction Force Measurement Device Using Force Sensor*. 2021 13th International Conference on Knowledge and Smart Technology (KST); 2021 21-24 Jan. 2021.

33. Barnston AG. Correspondence among the correlation, RMSE, and Heidke forecast verification measures; refinement of the Heidke score. *Weather and Forecasting*. 1992;7(4):699-709.
34. Kim SJ, Gu GM, Na Y, Park J, Kim Y, Kim J. Wireless Ground Reaction Force Sensing System Using a Mechanically Decoupled Two-Dimensional Force Sensor. *IEEE/ASME Transactions on Mechatronics*. 2020;25(1):66-75.
35. Tekscan Inc. FlexiForce A301 Sensor 2020 [Available from: <https://www.tekscan.com/products-solutions/force-sensors/a301?tab=specifications-performance>].
36. Tekscan Inc. Best Practices for Mechanical Integration of the FlexiForce Sensor [Available from: <https://www.tekscan.com/resources/product-guide/best-practices-mechanical-integration-flexiforce-sensor>].
37. Eli Bendersky's website. The Softmax function and its derivative 2016 [Available from: <https://translate.google.co.th/?hl=th&sl=en&tl=th&text=The%20Softmax%20function%20and%20its%20derivative&op=translate>].
38. MathWorks®. Train Classification Models in Classification Learner App [Available from: <https://www.mathworks.com/help/stats/train-classification-models-in-classification-learner-app.html>].



## ประวัติผู้เขียน

ชื่อ-สกุล	Pisut Pornpreedawan
วัน เดือน ปี เกิด	6 January 1998
สถานที่เกิด	Bangkok Province
วุฒิการศึกษา	Bachelor degree of Engineering (Biomedical Engineering), Srinakharinwirot University
ที่อยู่ปัจจุบัน	44/1 Moo 3 Nong Suang, Nong Chang, Uthai Thani 61110

