



การประมาณแรงกล้ามเนื้อด้วยคลื่นไฟฟ้ากล้ามเนื้อ
ในการทำกายภาพบำบัดกล้ามเนื้อแขน

Muscle Force Estimation with Surface Electromyography in Upper Limb
Stroke Rehabilitation

ธนัท ธนอัสวพล

Tanat Tanausavaphol

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมเครื่องกล
มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Mechanical Engineering
Prince of Songkla University

2562

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์



การประมาณแรงกล้ามเนื้อด้วยคลื่นไฟฟ้ากล้ามเนื้อ

ในการทำกายภาพบำบัดกล้ามเนื้อแขน

Muscle Force Estimation with Surface Electromyography in Upper Limb
Stroke Rehabilitation

ธนัท ธนอัสวพล

Tanat Tanausavaphol

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา

วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมเครื่องกล

มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Mechanical Engineering
Prince of Songkla University

2562

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์

ชื่อวิทยานิพนธ์ การประมาณแรงกล้ามเนื้อด้วยคลื่นไฟฟ้ากล้ามเนื้อในการทำกายภาพบำบัดกล้ามเนื้อ
แขน

ผู้เขียน นายธนัท ธนอัศวพล

สาขาวิชา วิศวกรรมเครื่องกล

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

คณะกรรมการสอบ

.....
(ผศ.ดร.ภาสกร เวสสะโกศล)

.....ประธานกรรมการ
(รศ.ดร.พนัส นัถฤทธิ์)

อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม

.....กรรมการ
(ผศ.ดร.ภาสกร เวสสะโกศล)

.....
(ดร.ปรมินทร์ เณรานนท์)

.....กรรมการ
(ดร.ปรมินทร์ เณรานนท์)

บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ อนุมัติให้รับวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษา ตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชา วิศวกรรมเครื่องกล

.....
(ศาสตราจารย์ ดร.ดำรงศักดิ์ ฟ้ารุ่งแสง)

คณบดีบัณฑิตวิทยาลัย

ขอรับรองว่า ผลงานวิจัยนี้เป็นผลมาจากการศึกษาวิจัยของนักศึกษาเอง และได้แสดงความขอบคุณ
บุคคลที่มีส่วนช่วยเหลือแล้ว

ลงชื่อ

.....

(ผศ.ดร.ภาสกร เวสสะโกศล)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

ลงชื่อ

.....

(นายธนัท ธนอัสวพล)

นักศึกษา

ข้าพเจ้าขอรับรองว่า ผลงานวิจัยนี้ไม่เคยเป็นส่วนหนึ่งในการอนุมัติปริญญาในระดับใดมาก่อน
และไม่ได้ถูกใช้ในการยื่นขออนุมัติปริญญาในขณะนี้

ลงชื่อ

.....

(นายธนัท ธนอัสวพล)

นักศึกษา

ชื่อวิทยานิพนธ์	การประมาณแรงกล้ามเนื้อด้วยคลื่นไฟฟ้ากล้ามเนื้อในการทำ กายภาพบำบัดกล้ามเนื้อแขน
ผู้เขียน	นายธนัท ธนอัสวพล
สาขาวิชา	วิศวกรรมเครื่องกล
ปีการศึกษา	2562

บทคัดย่อ

ปัจจุบันมีการนำเทคโนโลยีมาประยุกต์ใช้กับการแพทย์ในหลากหลายด้าน เช่น การนำหุ่นยนต์มาใช้เพื่อช่วยทำกายภาพบำบัดฟื้นฟูกล้ามเนื้อของผู้ป่วยโดยอาศัยแรงของกล้ามเนื้อในการควบคุมการเคลื่อนไหวของหุ่นยนต์สำหรับบำบัดฟื้นฟูผู้ป่วย ซึ่งระบบการควบคุมหุ่นยนต์จำเป็นต้องมีเซ็นเซอร์แรงแบบหลายแกน ซึ่งมีราคาแพงและไม่สะดวกในการทำงานเนื่องจากจำเป็นต้องต่อร่วมกับชุดวงจรควบคุมแรงซึ่งมีความซับซ้อน ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อนำเสนอวิธีการพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับประมาณแรงกล้ามเนื้อด้วยวิธีโครงข่ายประสาทเทียมและวิธีซัพพอร์ตเวกเตอร์แมชชีนโดยอาศัยความสัมพันธ์ระหว่างแรงกล้ามเนื้อและสัญญาณไฟฟ้ากล้ามเนื้อ ซึ่งมีการนำวิธีการดังกล่าวไปใช้กับต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ

มีการทดลองเบื้องต้นประกอบด้วย การสอบเทียบเซ็นเซอร์เพื่อให้ตรวจวัดได้อย่างถูกต้องในสภาพแวดล้อมที่ใช้งาน และมีการทดลองเพื่อควบคุมแรงต้านทานการเคลื่อนที่ของเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ อีกทั้งยังมีการทดลองเพื่อตรวจสอบตำแหน่งวัดสัญญาณไฟฟ้ากล้ามเนื้อที่เหมาะสม โดยพิจารณาเปรียบเทียบทั้งสองตำแหน่งได้แก่ กล้ามเนื้อส่วน Forearm muscle และ Biceps/Triceps muscles ตลอดจนมีการทดลองเพื่อหาจำนวนชุดข้อมูล (Sample size) ที่เหมาะสมซึ่งใช้สำหรับการคำนวณคุณลักษณะเฉพาะของข้อมูล โดยพิจารณาจากจำนวนชุดข้อมูลที่ให้ความแม่นยำในการทำนายแรงมากที่สุดและใช้เวลาในการคำนวณน้อย ซึ่งมีการกำหนดใช้จำนวนชุดข้อมูลในการทดลองได้แก่ 50 100 150 และ 200 จากนั้นจึงทำการทดลองหลักเพื่อทำนายแรงกล้ามเนื้อโดยแบ่งออกเป็น 2 รูปแบบ ได้แก่ แบบออฟไลน์และแบบตามเวลาจริงซึ่งในงานวิจัยนี้จะแบ่งการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ออกเป็น 2 การทดลองเพื่อตรวจสอบปัจจัยที่ส่งผลต่อประสิทธิภาพเชิงความแม่นยำของแบบจำลองทางคณิตศาสตร์ในการทำนายแรงกล้ามเนื้อได้แก่ การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน

ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที และการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที โดยใช้ระดับแรงต้านทานการเคลื่อนที่ซึ่งให้ค่าความคลาดเคลื่อนน้อยที่สุดจากการทดลองก่อนหน้านี้ จากนั้นจึงทำการทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงเพื่อเปรียบเทียบความแม่นยำในการทำนายแรงระหว่างแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยวิธีโครงข่ายประสาทเทียมและวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เรเดียลเบสิสเคอร์เนลฟังก์ชัน โดยทำการทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน และใช้ความเร็วในการเคลื่อนที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที ผลการทดลองแสดงให้เห็นว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้อัลกอริทึมทั้งสองสามารถทำนายแรงได้ถูกต้อง โดยความแม่นยำในการทำนายแรงจะเป็นปฏิภาคผกผันกับความต้านทานการเคลื่อนที่และความเร็วของแขนในการเคลื่อนที่ด้ามจับ และพบว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับให้ผลการทำนายแรงที่แม่นยำมากกว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีน ดังนั้นวิธีการประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อด้วยอัลกอริทึมทั้งสองสามารถนำไปใช้กับต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติเพื่อลดต้นทุนของอุปกรณ์ในการทำกายภาพบำบัดฟื้นฟูแขนได้ในอนาคต

คำสำคัญ: การติดต่อสื่อสารระหว่างมนุษย์กับหุ่นยนต์ การทำนายแรง โครงข่ายประสาทเทียม ซัพพอร์ตเวกเตอร์แมชชีน สัญญาณไฟฟ้ากล้ามเนื้อ

Thesis Title	Muscle Force Estimation with Surface Electromyography in Upper Limb Stroke Rehabilitation
Author	Mr. Tanat Tanausavaphol
Major Program	Mechanical Engineering
Academic year	2019

Abstract

In today's world, technology plays an important role in every industry as well as in our personal lives. One of the entire applications is a medical technology used for physiotherapy of upper limbs. The rehabilitation activities involve the muscle force stimulation using robot-assisted-exercise-based rehabilitation. However, the development of autonomous robotic trainers always requires multi-axis force sensors, which are so costly. Typically, the force sensors are associated with their specific controller boxes, which are slightly complex systems. Therefore, this research aims to develop EMG-based muscle force estimation using artificial neural networks and support vector machine methods. This technique was successfully implemented in the prototype device of the one-DOF assistive robot for upper limb rehabilitation.

Initially, a set of pilot experiments was carried out i.e. (1) the force sensor calibration test, (2) frictional force calibration test (in case of resistance applied against the robot movement), (3) the experiment to identify the appropriate EMG electrode locations by comparing two muscle positions consisting of the forearm muscles and the Biceps/Triceps muscles, and (4) the test to determine the sample sizes for calculating the features of the data set. Afterwards, the substantive experiments have been delivered. There are off-line and real-time muscle force prediction tests based on the artificial neural networks and support vector machine algorithms. According to the off-line EMG-based force estimation, it revealed two preliminary tests consisting of the first test involving to the study of the relation between the qualitative performance

of the model estimations and the various frictional forces applied and the second relating to the investigation of the relationship between the model estimation performances and the hand movement speeds. Additionally, the real-time muscle force experiment was introduced to compare the accuracy of model force estimation between the artificial neural network model and support vector machine schemes based on radial basis kernel function.

The experimental results show that mathematical models developed based on both methods can be considered acceptable for the EMG-based force estimation in the upper-limb treatment. The efficiency of the off-line force prediction is inversely proportional to the frictional forces and the velocity of the hand movement. In addition, the result of real-time estimation found that the mathematical models developed using the artificial neural network method were superior in the force estimating than mathematical models developed using the support vector machine. Therefore, the EMG-based muscle force estimation using both methods can be further implemented in the one-DOF upper limb rehabilitation robot.

Keywords: Human robot interaction, Force estimation, Artificial neural network, Support vector machine, Electromyography

กิตติกรรมประกาศ

ข้าพเจ้าขอแสดงคำขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.ภาสกร เวสสะโกศล อาจารย์ที่ปรึกษาหลักวิทยานิพนธ์ ดร.ปรมินทร์ เณรานนท์ อาจารย์ที่ปรึกษาร่วมวิทยานิพนธ์ และ รองศาสตราจารย์ ดร.พรชัย พฤษภักทรานนท์ ที่ได้กรุณาให้การสนับสนุนและฝึกฝนระเบียบวิธีคิดในการทำวิจัย เสียสละเวลาในการให้คำปรึกษา แนะนำความรู้ แนวคิด เอกสาร ข้อเสนอแนะที่มีประโยชน์ในการทำวิจัยเป็นอย่างดีรวมถึงการช่วยเหลือแก้ไขปัญหาต่าง ๆ ตลอดจนตรวจทานและ ดำเนินแก้ไขวิทยานิพนธ์ให้ดำเนินไปอย่างสมบูรณ์

ขอขอบพระคุณ รองศาสตราจารย์ ดร.พนัส นัถฤทธิ์ ประธานกรรมการสอบ วิทยานิพนธ์ ที่เสียสละเวลา ให้คำปรึกษา คำแนะนำ และข้อเสนอแนะของงานวิจัย

ขอขอบพระคุณ คณาจารย์และบุคลากรในภาควิชาวิศวกรรมเครื่องกลทุกๆ ท่านที่ ให้ความรู้ และการช่วยเหลือในด้านต่างๆ มาโดยตลอด

ขอขอบพระคุณ ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ วิทยาเขตหาดใหญ่ ที่ให้ความอนุเคราะห์สำหรับสถานที่และอุปกรณ์ เครื่องมือในการทำวิจัย

ขอขอบพระคุณ คุณประนอม ภักดีรัฐรัตน์ ที่ช่วยดำเนินงานเอกสารต่างๆ

ขอขอบคุณนักศึกษาบัณฑิตวิศวกรรมเครื่องกลทุกท่าน

ธนัท ธนอัครพล

สารบัญ

	หน้า
บทคัดย่อ	(5)
Abstract	(7)
กิตติกรรมประกาศ	(9)
สารบัญ	(10)
รายการตาราง	(13)
รายการภาพประกอบ	(15)
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ	1
1.2 เอกสารงานวิจัยที่เกี่ยวข้อง	2
1.3 วัตถุประสงค์ ขอบเขต และประโยชน์ที่คาดว่าจะได้รับ	8
1.3.1 วัตถุประสงค์ของโครงการ	8
1.3.2 ขอบเขตของโครงการ	9
1.3.3 ประโยชน์ที่คาดว่าจะได้รับ	10
1.4 ภาพรวมของวิทยานิพนธ์	10
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง	12
2.1 ทำออกกำลังกายเพื่อฟื้นฟูก้ามเนื้อแขน	12
2.2 สัญญาณไฟฟ้าก้ามเนื้อ	13
2.3 การตรวจวัดสัญญาณไฟฟ้าก้ามเนื้อ	14
2.4 โครงข่ายประสาทเทียม	15
2.5 Support Vector Machine	17
2.6 การควบคุมความเร็วมอเตอร์กระแสตรงด้วยวิธีการมอดูเลชันทางความกว้าง ของพัลส์	18
2.7 หลักการ Force/position control	19
2.8 ระบบควบคุมแบบสัดส่วน-ปริพันธ์-อนุพันธ์	20
บทที่ 3 ระเบียบวิธีวิจัย	22
3.1 การออกแบบเครื่องมือทำกายภาพบำบัดก้ามเนื้อแขนใน 1 มิติ	22

สารบัญ (ต่อ)

	หน้า
3.2 การออกแบบการทำงานของระบบในการเคลื่อนที่ 1 มิติ	23
3.3 ส่วนประกอบของเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ	27
3.4 การสอบเทียบเซ็นเซอร์	34
3.4.1 การสอบเทียบเซ็นเซอร์ตรวจวัดแรง	34
3.4.2 การสอบเทียบเซ็นเซอร์ตรวจวัดรอบการหมุน	36
3.5 การออกแบบชุดโปรแกรมต่อประสานกับผู้ใช้	38
3.6 การประมวลผลข้อมูล	41
3.7 การออกแบบอัลกอริทึมด้วยวิธี ANN และ SVM	49
3.8 ตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ	55
3.8.1 ตรวจสอบสัญญาณไฟฟ้ากล้ามเนื้อที่ได้จากการออกแรงในทิศทางที่ แตกต่างกัน	57
3.8.2 ตรวจสอบสัญญาณไฟฟ้ากล้ามเนื้อที่ได้จากท่าทางของแขนที่แตกต่าง กัน	58
3.8.3 ตรวจสอบสัญญาณไฟฟ้ากล้ามเนื้อที่ได้จากแรงบีบนิ้วมือที่แตกต่างกัน	60
3.9 การควบคุมการเคลื่อนที่ของด้ามจับ	61
บทที่ 4 วิธีการทดลองและผลการทดลอง	67
4.1 การออกแบบทดลองสำหรับประมาณแรงจากสัญญาณไฟฟ้ากล้ามเนื้อ	67
4.2 การออกแบบขั้นตอนการทดลอง	69
4.3 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความ ต้านทานการเคลื่อนที่ของด้ามจับ	71
4.4 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความเร็วใน การเคลื่อนที่ของด้ามจับ	74
4.4.1 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วใน การเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อ วินาที โดยใช้ความต้านทานการเคลื่อนที่คงที่ 2 นิวตัน	75

สารบัญ (ต่อ)

	หน้า
4.4.2 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที โดยใช้ความต้านทานการเคลื่อนที่คงที่ 3 นิวตัน	78
4.4.3 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที โดยใช้ความต้านทานการเคลื่อนที่คงที่ 4 นิวตัน	80
4.5 การทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงโดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับ	83
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	85
5.1 สรุปผลการวิจัย	85
5.2 ปัญหาและแนวทางแก้ไข	86
5.3 แนวทางการพัฒนาต่อไป	87
อ้างอิง	89
ภาคผนวก	94
ภาคผนวก ก. ข้อมูลจำเพาะเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ (Specification)	95
ภาคผนวก ข. ส่วนประกอบของเครื่อง	101
ภาคผนวก ค. บทความทางวิชาการ	108
ประวัติผู้เขียน	134

รายการตาราง

ตารางที่		หน้า
2-1	ขนาดแรงดันไฟฟ้าและความถี่ตอบสนองสัญญาณไฟฟ้ากล้ำมเนื้อ หัวใจ และสมอง	14
3-1	การเปรียบเทียบระหว่างน้ำหนักของวัตถุและน้ำหนักจากการตรวจวัด	35
3-2	การเปรียบเทียบระหว่างระยะทางที่ด้ามจับเคลื่อนที่จริงกับระยะทางจากการตรวจวัด	37
3-3	ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของแบบจำลองทางคณิตศาสตร์ที่ขนาดตัวอย่าง ได้แก่ 50 100 150 และ 200	42
3-4	เวลาในการคำนวณ 1 คุณลักษณะที่ จำนวนชุดข้อมูล 50 100 150 และ 200	43
3-5	อันดับความแม่นยำของวิธีการคัดแยกลักษณะเด่นของสัญญาณบนแกนเวลาและบนแกนความถี่	45
3-6	ตารางเวลาในการคำนวณของวิธีการคัดแยกลักษณะเด่นของสัญญาณบนแกนเวลาและบนแกนความถี่	46
3-7	เปรียบเทียบความแม่นยำในการทำนายที่จำนวนโหนดแตกต่างกัน	51
3-8	เปรียบเทียบความแม่นยำในการทำนายที่ฟังก์ชันการแปลงแตกต่างกัน	51
3-9	เปรียบเทียบความแม่นยำในการทำนายที่อัลกอริทึมการเรียนรู้แตกต่างกัน	51
3-10	พารามิเตอร์สำหรับปรับใช้ในการฝึกสอนโครงข่ายประสาทเทียม	52
3-11	เปรียบเทียบความแม่นยำในการทำนายที่พารามิเตอร์ C แตกต่างกัน	54
3-12	เปรียบเทียบความแม่นยำในการทำนายที่พารามิเตอร์ Degree แตกต่างกัน	54
3-13	พารามิเตอร์สำหรับปรับใช้ในการฝึกสอนวิธีซัพพอร์ตเวกเตอร์แมชชีน	54
3-14	ความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่	64
3-15	ค่าคงที่แรงต้านทานการเคลื่อนที่ที่ความต้านทานการเคลื่อนที่ 2 3 4 และ 5 นิวตัน	66
4-1	ความสัมพันธ์ระหว่างแรงและแรงต้านทานการเคลื่อนที่ของด้ามจับ	69
4-2	ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน	72
4-3	ค่าเบี่ยงเบนมาตรฐานที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน	72

รายการตาราง (ต่อ)

ตารางที่		หน้า
4-4	ค่าราคที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 2 นิวตัน	75
4-5	ค่าเบี่ยงเบนมาตรฐานที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 2 นิวตัน	75
4-6	ค่าราคที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 3 นิวตัน	78
4-7	ค่าเบี่ยงเบนมาตรฐานที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 3 นิวตัน	78
4-8	ค่าราคที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 4 นิวตัน	80
4-9	ค่าเบี่ยงเบนมาตรฐานที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 4 นิวตัน	80
4-10	ค่าราคที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที	83
4-11	ค่าเบี่ยงเบนมาตรฐานที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที	83

รายการภาพประกอบ

รูปที่		หน้า
1-1	การทดลอง 1-DOF (QARM1)	3
1-2	การทดลอง 1-DOF exoskeleton	4
1-3	การทดลองเคลื่อนไหวแบบสัมผัส	5
1-4	การทดลองทำนายแรงบีบนิ้วมือและตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ	6
1-5	รูปแบบท่าทางในออกกำลังกายแขน	7
2-1	ตำแหน่งกล้ามเนื้อโทรเซ็บส์และกล้ามเนื้ออินพราสไปนาทัส	12
2-2	ท่าออกกำลังกายเพื่อฟื้นฟูกล้ามเนื้อซึ่งเคลื่อนไหวบนระนาบแนวนอน	13
2-3	ความสัมพันธ์ระหว่าง Motor unit และ สัญญาณไฟฟ้ากล้ามเนื้อ	13
2-4	ลักษณะของอิเล็กโทรดแต่ละชนิดที่ใช้ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ	15
2-5	โครงสร้างของโครงข่ายประสาทเทียม	16
2-6	ไฮเปอร์เพลนที่เป็นไปได้และไฮเปอร์เพลนที่ดีที่สุด	17
2-7	สัญญาณพัลส์ที่ตีวตีไซเคิล 25 50 และ 75 เปอร์เซ็นต์	18
2-8	บล็อกไดอะแกรมวิธีการควบคุมระบบหุ่นยนต์แบบ External force control	20
3-1	เครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ	22
3-2	อุปกรณ์สำหรับต่อร่วมกับเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ	23
3-3	เซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Myo armband)	24
3-4	แหล่งจ่ายไฟ 12 VDC	25
3-5	โน้ตบุ๊ก (Laptop)	25
3-6	บล็อกไดอะแกรมการทำงานของระบบสำหรับการเคลื่อนที่ 1 มิติ	26
3-7	บล็อกและรางสไลด์	27
3-8	สายพานส่งกำลังและพูลเลย์	27
3-9	มอเตอร์กระแสตรง 12 โวลท์	28
3-10	เซ็นเซอร์ตรวจวัดแรง (Loadcell)	28
3-11	ลิมิตสวิทช์ (Limit switch)	29
3-12	เซ็นเซอร์ตรวจวัดรอบการหมุน (Encoder)	29

รายการภาพประกอบ (ต่อ)

รูปที่	หน้า	
3-13	ด้ามจับ	30
3-14	เซ็นเซอร์ตรวจวัดแรงบีบ (Force sensor resistor)	30
3-15	ลำโพงบัสเซอร์ (Buzzer module)	31
3-16	รอกและเชือก	31
3-17	ไมโครคอนโทรลเลอร์ Arduino Mega 2560	32
3-18	วงจรขับเคลื่อนมอเตอร์ L298N	33
3-19	วงจรขับเคลื่อนมอเตอร์ IBT-2	33
3-20	แผนผังขั้นตอนการสอบเทียบเซ็นเซอร์ตรวจวัดแรง	34
3-21	การเปรียบเทียบแรงที่ได้จากการตรวจวัดและน้ำหนักของวัตถุ	35
3-22	แผนผังขั้นตอนการสอบเทียบเซ็นเซอร์ตรวจวัดรอบการหมุน	36
3-23	การเปรียบเทียบระยะทางที่ได้จากการตรวจวัดและระยะทางที่ด้ามจับเคลื่อนที่จริง	37
3-24	ชุดโปรแกรมต่อประสานกับผู้ใช้โดยใช้ภาพ	38
3-25	ขั้นตอนการประมวลผลข้อมูล	41
3-26	กราฟเส้นแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของแบบจำลองทางคณิตศาสตร์ที่ขนาดตัวอย่าง ได้แก่ 50 100 150 และ 200	42
3-27	วิธีการคัดแยกลักษณะเฉพาะของสัญญาณ	48
3-28	ขั้นตอนการเรียนรู้ของอัลกอริทึม	48
3-29	ขั้นตอนการทำนายของอัลกอริทึม	49
3-30	โครงสร้างโครงข่ายประสาทเทียมในการทดลอง	52
3-31	โครงสร้างวิธีซัพพอร์ตเวกเตอร์แมชชีนในการทดลอง	53
3-32	ตำแหน่งติดตั้งเซ็นเซอร์ (a) Forearm muscle (b) Biceps/Triceps muscles (c) ตำแหน่งช่องสัญญาณของเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ	56
3-33	ตำแหน่งด้ามจับในการทดลอง	56
3-34	ขนาดสัญญาณไฟฟ้ากล้ามเนื้อตรวจวัดจากตำแหน่ง (a).Forearm muscle (b).Biceps/Triceps muscles	57
3-35	ขนาดสัญญาณไฟฟ้ากล้ามเนื้อจากการออกแรงดึง (a, b) และผลึก (c, d) ซึ่งตรวจวัดจากตำแหน่ง (a, c).Forearm muscle (b, d).Biceps/Triceps muscles	59

รายการภาพประกอบ (ต่อ)

รูปที่		หน้า
3-36	ขนาดสัญญาณไฟฟ้ากล้ามเนื้อจากการออกแรงบีบนิ้วมือและมือออกแรงบีบนิ้วมือซึ่งตรวจวัดจากตำแหน่ง (a).Forearm muscle (b).Biceps/Triceps muscles	60
3-37	ขนาดของแรงต้านทานการเคลื่อนที่ขณะได้รับแรงกระทำภายนอก	62
3-38	โปรไฟล์แรงเสียดทานของด้ามจับที่ใช้ในการทดลอง	62
3-39	บล็อกไดอะแกรมการควบคุมการเคลื่อนที่ของด้ามจับในระบบการเคลื่อนที่ 1 มิติ	63
3-40	แผนผังการทดลองตรวจสอบความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่	64
3-41	ความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่	65
4-1	ขั้นตอนการรับค่าชุดข้อมูลสำหรับใช้เพื่อฝึกสอนและทดสอบอัลกอริทึมทั้งแบบออฟไลน์และแบบออนไลน์	71
4-2	แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน ในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์	73
4-3	แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 2 นิวตันในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์	76
4-4	แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 3 นิวตันในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์	79
4-5	แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 4 นิวตันในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์	81
4-6	แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน ในขั้นตอนการทดสอบอัลกอริทึมแบบตามเวลาจริง	84

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

หุ่นยนต์เริ่มเข้ามามีบทบาทกับชีวิตประจำวันของมนุษย์เรื่อยมา เช่น หุ่นยนต์บริการ และ หุ่นยนต์สำหรับการใช้งานในคลินิก เป็นต้น โดยมีการพัฒนาเทคโนโลยีอย่างต่อเนื่องตั้งแต่อดีตจนถึงปัจจุบัน แต่วิธีการที่มนุษย์ใช้สำหรับควบคุมหุ่นยนต์ยังคงเป็นปัญหาสำคัญ ซึ่งส่วนประกอบสำคัญในการควบคุมคือส่วนต่อประสานระหว่างมนุษย์กับหุ่นยนต์ [1] ในบทความนี้ได้เสนอวิธีการประมาณแรงจากสัญญาณไฟฟ้ากล้ามเนื้อของแขนเพื่อเป็นสัญญาณอินพุตสำหรับต่อประสานระหว่างมนุษย์กับหุ่นยนต์

วิธีการที่มนุษย์ควบคุมหุ่นยนต์มีการใช้สัญญาณไฟฟ้ากล้ามเนื้อ (Electromyography : EMG) สำหรับเป็นสัญญาณอินพุตอย่างแพร่หลาย เช่น ในด้านการประยุกต์ใช้กับหุ่นยนต์เพื่อการฟื้นฟูสมรรถภาพ การสื่อสารระหว่างมนุษย์กับหุ่นยนต์ และการเล่นเกม เป็นต้น อย่างไรก็ตามเนื่องจากสัญญาณไฟฟ้ากล้ามเนื้อมีความซับซ้อนไม่สามารถนำมาใช้เพื่อควบคุมหุ่นยนต์ได้โดยตรง ดังนั้นจึงต้องมีวิธีการเพื่อตรวจสอบความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและสัญญาณที่เกี่ยวข้องกับการเคลื่อนไหวของมนุษย์เพื่อนำไปใช้เป็นสัญญาณอินพุตสำหรับต่อประสานระหว่างมนุษย์กับหุ่นยนต์ เช่น ท่าทางของแขน แรงแบบมือ เป็นต้น


ปัจจุบันมีการนำเทคโนโลยีมาประยุกต์ใช้ร่วมกับการแพทย์ในหลากหลายด้าน ซึ่งในด้านหนึ่งคือการนำหุ่นยนต์มาประยุกต์ใช้เพื่อช่วยทำกายภาพบำบัดฟื้นฟูกล้ามเนื้อแขนของผู้ป่วยซึ่งมีรูปแบบการทำงานของหุ่นยนต์ 2 รูปแบบ ได้แก่ การช่วยบำบัดแบบพาสซีฟ (Passive assist therapy) ใช้ในกรณีที่แขนผู้ป่วยอ่อนแรงจนกระทั่งไม่สามารถออกแรงกระทำต่อหุ่นยนต์ โดยมีหลักการทำงานคือ หุ่นยนต์ประคองแขนผู้ป่วยเคลื่อนที่ไปยังทิศทางที่โปรแกรมไว้ และการช่วยบำบัดแบบแอกทีฟ (Active assist therapy) ใช้ในกรณีที่ผู้ป่วยสามารถออกแรงแขนเพื่อกระทำต่อหุ่นยนต์ โดยมีหลักการทำงานคือ ผู้ป่วยออกแรงกระทำต่อหุ่นยนต์เพื่อควบคุมหุ่นยนต์ให้เคลื่อนที่ไปยังทิศทางที่ผู้ป่วยออกแรง ซึ่งโดยส่วนมากหุ่นยนต์เพื่อการฟื้นฟูสมรรถภาพมักใช้แรงของกล้ามเนื้อเพื่อกระตุ้นการเคลื่อนไหวของหุ่นยนต์สำหรับบำบัดฟื้นฟูผู้ป่วย อย่างไรก็ตามวิธีการสำหรับการตรวจวัดแรงของแต่ละบุคคลที่กระทำโดยกล้ามเนื้อจำเป็นต้องมีเซ็นเซอร์แรงพิเศษ ซึ่งมีราคาแพงและไม่สะดวกในการ

ใช้งาน [2] ดังนั้นงานวิจัยนี้จึงมุ่งเน้นพัฒนาต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ โดยมีรูปแบบการทำงานด้วยการช่วยบำบัดแบบแอกทีฟ (Active assist therapy) เท่านั้นและเพื่อศึกษาความสัมพันธ์ระหว่างแรงของแขนในแนวแกน 1 มิติและสัญญาณไฟฟ้ากล้ามเนื้อของมนุษย์ ภายใต้การเปลี่ยนแปลงของระดับความการเคลื่อนที่และความต้านทานเคลื่อนที่ของด้ามจับ เพื่อนำสัญญาณแรงที่ได้จากการประมาณโดยใช้ความสัมพันธ์ดังกล่าวเป็นสัญญาณอินพุตสำหรับการควบคุมหุ่นยนต์ในขั้นตอนการทำกายภาพบำบัดโดยอาศัยหุ่นยนต์

1.2 เอกสารงานวิจัยที่เกี่ยวข้อง


สัญญาณไฟฟ้ากล้ามเนื้อ คือ ความต่างศักย์ทางไฟฟ้าของกล้ามเนื้อซึ่งบ่งบอกระดับความตึงของกล้ามเนื้อจากการเกร็งของเส้นใยกล้ามเนื้อ ซึ่งเกิดจากการสั่งงานโดยเซลล์ประสาทสั่งการ (Motor neuron) ผ่านกระแสประสาทไปยังเส้นใยกล้ามเนื้อนั้น จึงอาจกล่าวได้ว่าสัญญาณไฟฟ้ากล้ามเนื้อเปรียบเสมือนภาพสะท้อนของกิจกรรมทางไฟฟ้าของกล้ามเนื้อ [3] ดังนั้นจึงมีงานวิจัยเพื่อตรวจสอบความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและแรงที่เกี่ยวข้องกับการเคลื่อนไหวของแขนมนุษย์อย่างมากมายเพื่อใช้ประโยชน์จากความสัมพันธ์ดังกล่าวสำหรับประยุกต์ใช้ในงานด้านต่างๆ เช่น การประยุกต์ใช้กับหุ่นยนต์เพื่อการฟื้นฟูสมรรถภาพ การสื่อสารระหว่างมนุษย์กับหุ่นยนต์ และการเล่นกีฬา เป็นต้น โดยจากการทบทวนวรรณกรรมพบงานวิจัยที่ตรวจสอบความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและแรงที่เกี่ยวข้องกับการเคลื่อนไหวของแขนมนุษย์ รวมไปถึงรูปแบบการเคลื่อนไหวของแขนเพื่อการทำกายภาพบำบัดฟื้นฟูสมรรถภาพแขนดังนี้

จากการศึกษาของ Farid Mobasser and Keyvan Hashtrudi-Zaad ในงานวิจัยเรื่อง Hand Force Estimation using Electromyography Signals [4] ได้มีการทำนายแรงข้อมือจากพารามิเตอร์ที่เกี่ยวข้องกับข้อศอก ได้แก่ สัญญาณไฟฟ้ากล้ามเนื้อจากกล้ามเนื้อต้นแขน มุมและความเร็วเชิงมุมของข้อศอกโดยวิธีโครงข่ายประสาทเทียมแบบหลายชั้น และวิธีโครงข่ายประสาทเทียมแบบเรเดียลเบสิสฟังก์ชัน ในขณะที่ข้อศอกมีการยึดและงอแขนในแนวระนาบนอน (Horizontal plane) ภายใต้เงื่อนไขการหดตัวของกล้ามเนื้อแบบ isometric, isotonic และ light load ดังรูปที่ 1-1 ผลการทดลองระบุว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีทั้ง 2 สามารถทำนายแรงได้โดยมีเปอร์เซ็นต์ RMSE ภายใต้เงื่อนไขการหดตัวแบบ isometric, isotonic และ light load น้อยกว่า 10% 10% และ 20% ตามลำดับ และค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ยไม่เกิน 1 นิวตัน




รูปที่ 1-1 การทดลอง 1-DOF (QARM1) [4]

จากการศึกษาของ Javad Hashemi และคณะในงานวิจัยเรื่อง Enhanced Dynamic EMG-Force Estimation Through Calibration and PCI Modeling [5] ได้มีการทำนายแรงข้อมือภายใต้การหดตัวของกล้ามเนื้อแบบ Concentric, Eccentric และ Dynamic ซึ่งพัฒนาแบบจำลองทางคณิตศาสตร์โดยใช้วิธี Parallel cascade identification (PCI) จากชุดข้อมูลที่เกี่ยวข้อง ได้แก่ มุมของข้อศอกและสัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดที่ตำแหน่งกล้ามเนื้อ biceps brachii และ triceps brachii ซึ่งมีการสอบเทียบข้อมูลก่อนนำมาใช้เพื่อพัฒนาแบบจำลองทางคณิตศาสตร์โดยใช้วิธี angle-based EMG amplitude calibration เพื่อลดความผิดพลาดในการทำนายแรงจากผลกระทบของมุมข้อศอกที่เปลี่ยนแปลง ในการทดลองมีการตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อภายใต้เงื่อนไข ได้แก่ แรงคงที่และความเร็วคงที่ แรงไม่คงที่และความเร็วไม่คงที่ ในขณะที่ข้อศอกมีการยืดและงอแขนในแนวระนาบนอน (Horizontal plane) ดังรูปที่ 1-2 ผลการทดลองระบุว่าวิธี angle-based EMG amplitude calibration สามารถลดความผิดพลาดในการทำนายแรงจากผลกระทบของมุมข้อศอกที่เปลี่ยนแปลงและเพิ่มประสิทธิภาพในการทำนายแรงข้อมือโดยใช้วิธี parallel cascade identification (PCI) ซึ่งทำนายแรงได้โดยมีเปอร์เซ็นต์ RMSE ภายใต้เงื่อนไข แรงคงที่และความเร็วคงที่ 8.3% และ 10.3% ภายใต้การหดตัวของกล้ามเนื้อแบบ Concentric และ Eccentric ตามลำดับ และ 33.3% สำหรับการหดตัวของกล้ามเนื้อแบบไดนามิก




รูปที่ 1-2 การทดลอง 1-DOF exoskeleton [5]

จากการศึกษาของ Songyuan Zhang และคณะในงานวิจัยเรื่อง Muscle Strength Assessment System Using sEMG-Based Force Prediction Method for Wrist Joint [6] ได้มีการทำนายแรงข้อมือภายใต้การหดตัวของกล้ามเนื้อแบบ isometric โดยเคลื่อนไหวนิ้วแบบสัมผัสลง (downward touch motions) ซึ่งพัฒนาแบบจำลองทางคณิตศาสตร์โดยใช้วิธีโครงข่ายประสาทเทียมจากชุดข้อมูลซึ่งประกอบด้วย มุมของข้อมือและข้อศอกซึ่งตรวจวัดโดยใช้เซ็นเซอร์ MTx แรงซึ่งตรวจวัดโดยใช้เซ็นเซอร์ตรวจวัดแรงยี่ห้อ ThinNANO, BL AUTOTECH, LTD., Japan และสัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดโดยใช้อิเล็กโทรด (Ag/AgCl, size: 26 9 14 mm, Oisaka Development Ltd., Japan) ติดตั้งที่ตำแหน่งกล้ามเนื้อ Forearm muscle 4 จุด โดยชุดข้อมูลดังกล่าวมีการสอบเทียบด้วยวิธี Bayesian linear regression algorithm ดังรูปที่ 1-3 ผลการทดลองระบุว่า RMSE ซึ่งบ่งบอกถึงค่าความคลาดเคลื่อนในการทำนายของแบบจำลองทางคณิตศาสตร์มีค่าไม่เกิน 2.5 นิวตัน



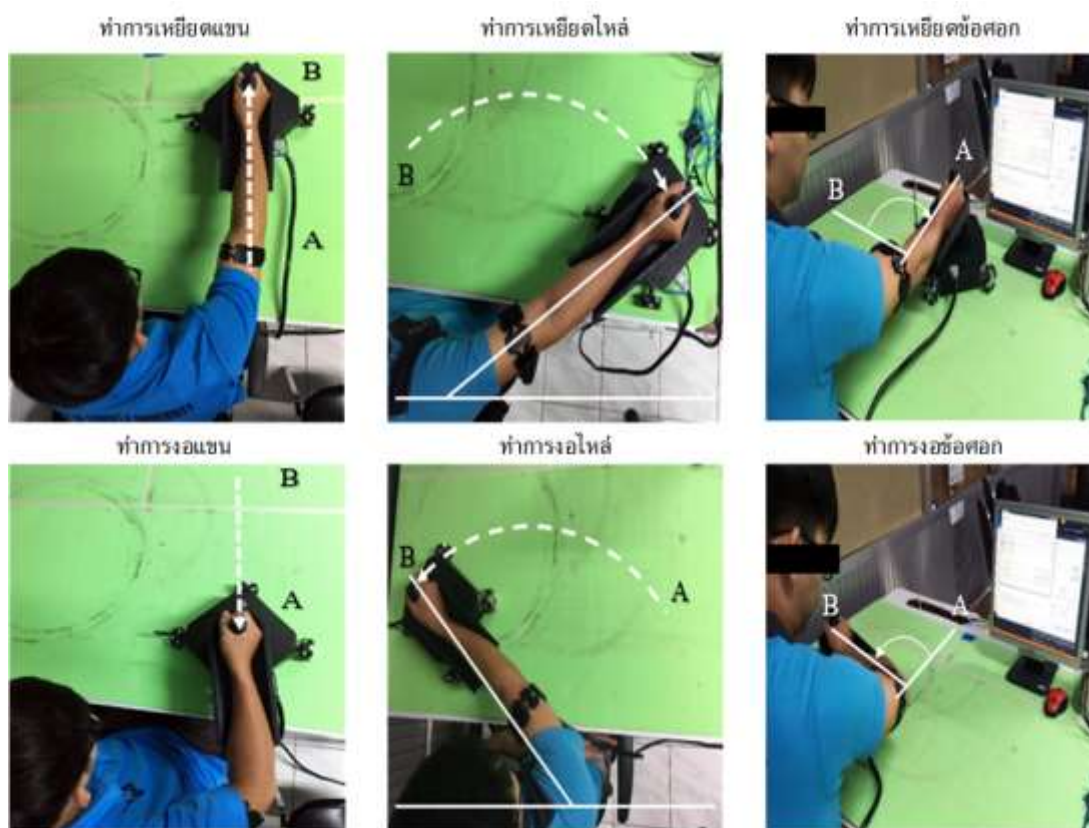
รูปที่ 1-3 การทดลองเคลื่อนไหวแบบสัมผัสลง [6]

จากการศึกษาของ [Changmok Choi](#) และคณะในงานวิจัยเรื่อง Real-time pinch force estimation by surface electromyography using an artificial neural network [7] ได้มีการทำนายแรงบีบนิ้วมือ (palmar pinch force) ภายใต้การหดตัวของกล้ามเนื้อแบบ isometric ซึ่งพัฒนาแบบจำลองทางคณิตศาสตร์โดยใช้วิธีโครงข่ายประสาทเทียมจากชุดข้อมูลซึ่งประกอบด้วยสัญญาณไฟฟ้ากล้ามเนื้อที่ตรวจวัดจากตำแหน่งมัดกล้ามเนื้อ 6 ตำแหน่ง แสดงดังรูปที่ 1-4 ได้แก่ Extensor Digitorum (ED), Abductor Pollicis Longus (APL), flexor digitorum superficialis (FDS) , Dorsal Interosseous (DI), Abductor Pollicis Brevis (APB) และ Adductor Pollicis (AP) ซึ่งเลือกจากกล้ามเนื้อ 15 ตำแหน่งโดยวิธี ADAM Interactive Anatomy software product (A.D.A.M. Inc., USA) ผลการทดลองระบุว่า normalized root mean squared error NRMSE ซึ่งบ่งบอกถึงความคลาดเคลื่อนในการทำนายของแบบจำลองทางคณิตศาสตร์มีค่า 0.081 ± 0.023 ค่าสหสัมพันธ์ correlation (CORR) มีค่า 0.968 ± 0.017



รูปที่ 1-4 การทดลองทำนายแรงบีบนิ้วมือและตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ [7]

จากการศึกษาของ [Peerayuth Saekow](#) และคณะในงานวิจัยเรื่อง A Newly Design of a Portable Rehabilitation Robot for Upper Limb [8] ได้มีการตรวจสอบตำแหน่งกล้ามเนื้อที่ได้รับการกระตุ้นเมื่อออกกำลังกายแขนด้วยท่าทางการเหยียดและงอที่แตกต่างกัน 3 รูปแบบ ได้แก่ การเหยียดแขนและการงอแขน การเหยียดไหล่และการงอไหล่ การเหยียดข้อศอกและการงอข้อศอก ดังแสดงในรูปที่ 1-5 ผลการทดลองระบุว่าการออกกำลังกายแขนด้วยท่าทางการเหยียดแขนและการงอแขนสามารถช่วยกระตุ้นเพื่อฟื้นฟูที่ตำแหน่งกล้ามเนื้อไตรเซ็ปส์ และการออกกำลังกายแขนด้วยท่าทางการเหยียดไหล่และการงอไหล่ และท่าทางการเหยียดข้อศอกและการงอข้อศอกสามารถช่วยกระตุ้นเพื่อฟื้นฟูที่ตำแหน่งกล้ามเนื้อไตรเซ็ปส์และไบเซ็ปส์



รูปที่ 1-5 รูปแบบท่าทางในออกกำลังกายแขน [8]

จากการทบทวนวรรณกรรมพบว่ามีงานวิจัยในประเทศไทยและต่างประเทศเพื่อตรวจสอบความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและแรงที่เกี่ยวข้องกับการเคลื่อนไหวของแขนมนุษย์ เช่น แรงข้อมือ แรงบีบนิ้วมือ และแรงกด โดยใช้วิธีโครงข่ายประสาทเทียมอย่างแพร่หลาย ซึ่งผลจากงานวิจัยต่างๆ พบว่าวิธีโครงข่ายประสาทเทียมสามารถตรวจสอบความสัมพันธ์ที่ซับซ้อนได้อย่างถูกต้อง อย่างไรก็ตามวิธีโครงข่ายประสาทเทียมยังมีข้อด้อยในแง่ของการเกิดปัญหา overfitting ได้ง่าย

แต่ยังไม่พบงานวิจัยสำหรับตรวจสอบความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและการออกแรงแขนมนุษย์ภายใต้การหดตัวของกล้ามเนื้อแบบ Isotonic (การหดตัวของกล้ามเนื้อในลักษณะความตึงในกล้ามเนื้อคงที่และมีการเคลื่อนไหวของข้อต่อ) ด้วยวิธีการเคลื่อนที่แบบตึงและผลัก ซึ่งใช้ท่าทางการออกกำลังกายแขนด้วยการเหยียดแขนและงอแขนซึ่งสามารถช่วยกระตุ้นเพื่อฟื้นฟูกล้ามเนื้อที่ตำแหน่งกล้ามเนื้อโทรเซบส์ได้ อย่างไรก็ตามเนื่องจากความสัมพันธ์ของขนาดของสัญญาณไฟฟ้ากล้ามเนื้อและการออกแรงแขนมนุษย์ด้วยวิธีการเคลื่อนที่แบบตึงและการเคลื่อนที่แบบ

ผลึกค่อนข้างมีความซับซ้อน ดังนั้นงานวิจัยนี้จะมุ่งเน้นไปสู่การพัฒนาแบบจำลองทางคณิตศาสตร์ ภายใต้การเคลื่อนที่ของแขนเฉพาะแบบหลักด้วยวิธีโครงข่ายประสาทเทียมและวิธีซัพพอร์ตเวกเตอร์แมชชีน ซึ่งวิธีซัพพอร์ตเวกเตอร์แมชชีนมีข้อดีกว่าวิธีโครงข่ายประสาทเทียมในแง่ของการเกิดปัญหา overfitting น้อยกว่า รวมถึงมีการพัฒนาต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ ซึ่งมีรูปแบบการช่วยบำบัดแบบแอคทีฟ และกำหนดรูปแบบการเคลื่อนที่ของแขนด้วยการเหยียดแขน และการงอแขน เพื่อพัฒนากล้ามเนื้อแขนในตำแหน่งไตรเซ็ปส์ (Triceps muscle)

ระบบมีความยืดหยุ่นในการทำงานโดยสามารถกำหนดระดับความต้านทานการเคลื่อนที่และความเร็วในการเคลื่อนที่ที่ตามจับเพื่อรองรับการใช้งานของผู้ป่วยแต่ละรายที่มีความสามารถในการออกแรงที่แตกต่างกันได้ เช่น สำหรับผู้ป่วยที่ออกแรงได้น้อยก็สามารถใช้งานที่ความเร็วในการเคลื่อนที่และระดับความต้านทานการเคลื่อนที่น้อย และเมื่อผู้ป่วยสามารถออกแรงได้มากขึ้นก็สามารถใช้งานที่ความเร็วในการเคลื่อนที่และระดับความต้านทานการเคลื่อนที่มากยิ่งขึ้นได้ตลอดจนมีการตรวจสอบความเป็นไปได้ในแง่ของความแม่นยำสำหรับการทำนายแรงแบบตามเวลาจริงโดยการใช้แบบจำลองทางคณิตศาสตร์ที่พัฒนาเพื่อทำนายแรงจากสัญญาณไฟฟ้ากล้ามเนื้อทดแทนการใช้เซ็นเซอร์ตรวจวัดแรงแบบหลายแกนที่มีการใช้งานอย่างแพร่หลายโดยเฉพาะในด้านอุปกรณ์การแพทย์สำหรับการทำกายภาพบำบัดฟื้นฟู ซึ่งข้อพิจารณาของเซ็นเซอร์ตรวจวัดแรงพิเศษ คือ มีราคาค่อนข้างสูง และต้องใช่วงจรสำหรับขยายสัญญาณร่วมด้วยซึ่งยากต่อการติดตั้งและพกพาจึงเป็นข้อจำกัดเมื่อใช้งานจริง

1.3 วัตถุประสงค์ ขอบเขต และประโยชน์ที่คาดว่าจะได้รับ

งานวิจัยนี้มีการออกแบบและพัฒนาระบบสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อโดยมีวัตถุประสงค์ ขอบเขต และประโยชน์ที่คาดว่าจะได้รับ ดังนี้

1.3.1 วัตถุประสงค์ของโครงการ

1) เพื่อพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับทำนายแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อในการทำกายภาพบำบัดกล้ามเนื้อแขนโดยใช้วิธีโครงข่ายประสาทเทียมและวิธีซัพพอร์ตเวกเตอร์แมชชีน ซึ่งสามารถนำไปใช้งานได้ 2 รูปแบบคือ แบบออฟไลน์และแบบออนไลน์

2) เพื่อศึกษาและตรวจสอบปัจจัยเบื้องต้นที่ส่งผลต่อประสิทธิภาพเชิงความแม่นยำของแบบจำลองทางคณิตศาสตร์ในการทำนายแรง

3) เพื่อพัฒนาต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ ด้วยรูปแบบการช่วยบำบัดแบบแอกทีฟ และใช้สำหรับควบคุมพารามิเตอร์ที่ใช้เป็นเงื่อนไขในการทดลองและเก็บบันทึกชุดข้อมูลเพื่อนำไปใช้พัฒนาแบบจำลองทางคณิตศาสตร์สำหรับทำนายแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อ

1.3.2 ขอบเขตของงานวิจัย

1) ต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ มีรูปแบบการช่วยบำบัดแบบแอกทีฟ (Active assist therapy) และกำหนดรูปแบบการเคลื่อนที่ของแขนด้วยการเหยียดแขนและการงอแขน เพื่อพัฒนากล้ามเนื้อแขนในตำแหน่งไตรเซ็ปส์/ไบเซ็ปส์ (Triceps/Biceps muscles)

2) ออกแบบและพัฒนาแบบจำลองทางคณิตศาสตร์ให้สามารถใช้เพื่อทำนายแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อได้ทั้งแบบออฟไลน์และแบบตามเวลาจริง

3) สร้างต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติที่สามารถเคลื่อนที่ได้ในระยะเวลาเคลื่อนที่ 0-40 เซนติเมตร ซึ่งครอบคลุมระยะความยาวแขนข้างขวาของมนุษย์ทั้งเพศชายและเพศหญิง โดยแขนข้างขวาของมนุษย์เพศชายและมนุษย์เพศหญิงมีความยาวแขนอยู่ในช่วง 20-30.5 และ 19-31 เซนติเมตร ตามลำดับ [9]

4) ต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติสามารถปรับค่าความต้านทานการเคลื่อนที่ (Friction) ของด้ามจับได้ 4 ระดับ ได้แก่ 2, 3, 4 และ 5 นิวตัน

5) ต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติมีจุดอ้างอิงการเคลื่อนที่ซึ่งเคลื่อนที่ด้วยความเร็วคงที่และสามารถปรับค่าความเร็วได้ โดยใช้สำหรับเป็นจุดอ้างอิงให้ผู้ใช้อุปกรณ์ออกแรงกระทำต่อด้ามจับให้เคลื่อนที่ด้วยความเร็วใกล้เคียงจุดอ้างอิงการเคลื่อนที่

6) ออกแบบและพัฒนาชุดโปรแกรมต่อประสานกับผู้ใช้งาน (Graphic user interface) เพื่อความสะดวกในการใช้งานสำหรับการควบคุมระบบสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อ

7) มีระบบบันทึกและแสดงผลข้อมูล (Data logger and Monitoring) ที่เกี่ยวข้องกับการใช้งาน ได้แก่ แรง ความเร็ว ระยะทาง ความต้านทานการเคลื่อนที่ แรงบีบนิ้วมือ และ สัญญาณไฟฟ้ากล้ามเนื้อ

1.3.3 ประโยชน์ที่คาดว่าจะได้รับ

1) ได้ต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ ซึ่งสามารถนำไปใช้เพื่อฟื้นฟูสมรรถภาพกล้ามเนื้อแขนด้วยรูปแบบการช่วยบำบัดแบบแอคทีฟ (Active assist therapy) อีกทั้งยังสามารถประยุกต์ใช้แบบจำลองทางคณิตศาสตร์สำหรับการทำนายแรงทดแทนการใช้เซ็นเซอร์ตรวจวัดแรงแบบหลายแกน ทำให้สามารถลดต้นทุนของอุปกรณ์ในการทำกายภาพบำบัดฟื้นฟูแขนได้ในอนาคต

2) ได้ต้นแบบวิธีการพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับทำนายแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อและสามารถนำไปประยุกต์ใช้เพื่อพัฒนาต่อในระบบอื่นๆ ได้

1.4 ภาพรวมของวิทยานิพนธ์

ภาพรวมที่นำเสนอเป็นการอธิบายโดยรวมของแต่ละบทในวิทยานิพนธ์ที่มีการออกแบบและพัฒนาระบบสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อ การทดลองและสรุปผลการทดลองดังนี้

บทที่ 1 กล่าวถึงที่มาและความสำคัญของการใช้แบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีการต่างๆ เพื่อตรวจสอบความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและแรง สำหรับประยุกต์ใช้ในงานด้านต่างๆ เช่น การประยุกต์ใช้กับหุ่นยนต์เพื่อการฟื้นฟูสมรรถภาพ การสื่อสารระหว่างมนุษย์กับหุ่นยนต์ และการเล่นเกม เป็นต้น นอกจากนี้ในบทนี้มีการนำเสนอเอกสารที่เกี่ยวข้องกับงานวิจัยเพื่อตรวจสอบความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและแรงที่เกี่ยวข้องกับการเคลื่อนไหวของแขนมนุษย์ภายใต้การเคลื่อนที่ในรูปแบบต่างๆ และทำการออกกำลังกายแขนเพื่อช่วยฟื้นฟูกล้ามเนื้อแขนที่ตำแหน่งใดๆ เพื่อเป็นแนวทางสำหรับการออกแบบและพัฒนาแบบจำลองทางคณิตศาสตร์และต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติในงานวิจัยนี้ รวมถึงวัตถุประสงค์ ขอบเขต และผลที่คาดว่าจะได้รับจากงานวิจัยนี้

บทที่ 2 กล่าวถึงทฤษฎีที่เกี่ยวข้องซึ่งช่วยให้สามารถออกแบบและพัฒนาระบบสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อรวมถึงโครงสร้างในการบันทึกข้อมูลการเคลื่อนที่ได้อย่างสอดคล้องกับวัตถุประสงค์ โดยมีการนำเสนอในหัวข้อต่างๆ ได้แก่ สาเหตุของการใช้สัญญาณไฟฟ้ากล้ามเนื้อเพื่อทำนายแรง วิธีการและเครื่องมือสำหรับตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ วิธีการที่ใช้ในการพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับตรวจสอบความสัมพันธ์ของแรงและสัญญาณไฟฟ้ากล้ามเนื้อ วิธีการสำหรับควบคุมความเร็วมอเตอร์ในการออกแบบระบบการเคลื่อนที่ใน

แนวแกน 1 มิติ และวิธีการออกแบบระบบสำหรับควบคุมหุ่นยนต์ โดยทฤษฎีที่เกี่ยวข้องทำให้สามารถพัฒนาระบบสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อรวมไปถึงต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อเนื้อแขนใน 1 มิติ ซึ่งใช้สำหรับบันทึกชุดข้อมูลการเคลื่อนที่ได้สอดคล้องกับแนวคิดในการออกแบบระบบ

บทที่ 3 กล่าวถึงระเบียบวิธีวิจัยซึ่งนำเสนอขั้นตอนดำเนินการในงานวิจัยตั้งแต่เริ่มต้น โดยกล่าวถึงแนวคิดในการออกแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อเนื้อแขนใน 1 มิติ รายละเอียดและส่วนประกอบของอุปกรณ์ รวมไปถึงหลักการทำงานของระบบสำหรับการบันทึกชุดข้อมูล การควบคุมความต้านทานการเคลื่อนที่ในการทดลอง ขั้นตอนการสอบเทียบเซ็นเซอร์ก่อนใช้งาน การออกแบบส่วนต่อประสานระหว่างผู้ใช้ ขั้นตอนการประมวลผลข้อมูล ตลอดจนการทดลองเพื่อเลือกพารามิเตอร์ที่เกี่ยวข้องในการประมวลผลข้อมูลและตำแหน่งติดตั้งเซ็นเซอร์ที่เหมาะสมในการทดลอง

บทที่ 4 กล่าวถึงการออกแบบขั้นตอนการทดลองประมาณแรงกล้ามเนื้อทั้งแบบออฟไลน์และแบบตามเวลาจริง และผลการทดลองซึ่งบ่งบอกถึงความแม่นยำของแบบจำลองทางคณิตศาสตร์ที่พัฒนาสำหรับทำนายแรงจากสัญญาณไฟฟ้ากล้ามเนื้อทั้งแบบออฟไลน์และแบบตามเวลาจริง รวมไปถึงความสัมพันธ์ระหว่างประสิทธิภาพในการทำนายแรงของแบบจำลองทางคณิตศาสตร์กับพารามิเตอร์ที่ส่งผลกระทบต่อความคลาดเคลื่อนในการทำนายแรง

บทที่ 5 กล่าวถึงสรุปผลการวิจัย ปัญหาและแนวทางการแก้ไขในงานวิจัย ตลอดจนแนวทางในการปรับปรุงแก้ไขและพัฒนาต่อไป

ส่วนเอกสารผลการตีพิมพ์เผยแพร่วิทยานิพนธ์ ได้นำเสนอในส่วนของภาคผนวกท้ายเล่มวิทยานิพนธ์นี้

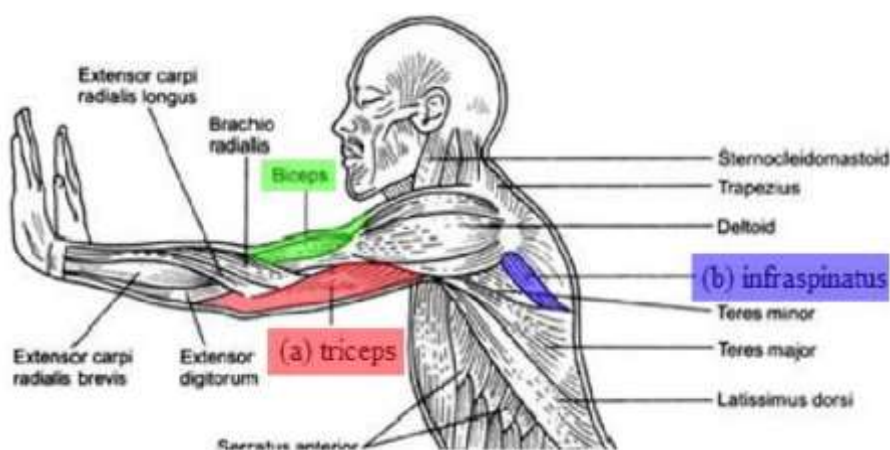
บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

การพัฒนาระบบสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อและเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ จำเป็นต้องเข้าใจทฤษฎีและหลักการที่เกี่ยวข้องหลายส่วนด้วยกัน ดังนั้นในบทนี้จะกล่าวถึงทฤษฎีที่เกี่ยวข้องกับงานวิจัย เพื่อให้มีความเข้าใจหลักการและแนวคิดสำหรับพัฒนาระบบให้ตรงตามวัตถุประสงค์ของงานวิจัย เช่น ตำแหน่งมัดกล้ามเนื้อหลักของแขน ทำออกกำลังกายเพื่อฟื้นฟูกล้ามเนื้อแขน ประเภทและหลักการของอัลกอริทึม การประมวลผลข้อมูล และปัจจัยที่ส่งผลให้เกิดความผิดพลาดในการทำนายแรง รวมไปถึงการออกแบบระบบควบคุมหุ่นยนต์

2.1 ทำออกกำลังกายเพื่อฟื้นฟูกล้ามเนื้อแขน


ทำออกกำลังกายแขนที่แตกต่างกันจะส่งผลให้เกิดการกระตุ้นกล้ามเนื้อแขนในตำแหน่งที่แตกต่างกัน ซึ่งจากการศึกษาพบว่าตำแหน่งกล้ามเนื้อแขนที่มีการกายภาพบำบัดฟื้นฟูอยู่บ่อยครั้งได้แก่ กล้ามเนื้อไตรเซ็ปส์ (Triceps muscle) และกล้ามเนื้ออินฟราสไปนาทิส (infraspinatus) [10] ซึ่งตำแหน่งของกล้ามเนื้อแสดงดังรูปที่ 2-1



รูปที่ 2-1 ตำแหน่งกล้ามเนื้อไตรเซ็ปส์และกล้ามเนื้ออินฟราสไปนาทิส [10]

การทำกายภาพบำบัดฟื้นฟูกล้ามเนื้อไตรเซ็ปส์ (Triceps muscle) สามารถทำได้โดยใช้ท่าการออกกำลังกายแบบการเหยียดแขนและการงอแขน ในขณะที่การทำกายภาพบำบัดฟื้นฟูกล้ามเนื้ออินฟราสไปนาทิส (infraspinatus) ใช้ท่าการออกกำลังกายแบบการกางแขนและการหุบแขน ซึ่งท่า

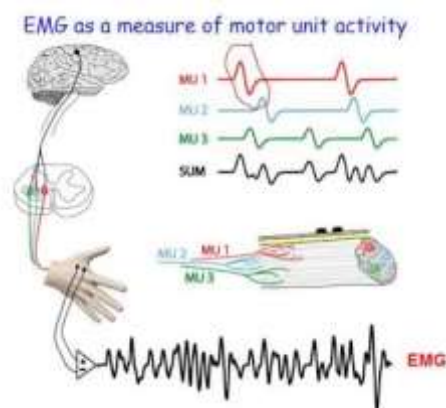
การออกกำลังกายทั้งสองลักษณะนี้มีการเคลื่อนไหวอยู่ในระนาบแนวนอน (Horizontal plane) คือ ระนาบที่มีรูปแบบการเคลื่อนไหวด้วยรูปแบบการเหยียด การงอ การกางออก และการหุบ ซึ่งแสดงดังรูปที่ 2-2



รูปที่ 2-2 ท่าออกกำลังกายเพื่อฟื้นฟูกล้ามเนื้อซึ่งเคลื่อนไหวบนระนาบแนวนอน [11]

2.2 สัญญาณไฟฟ้ากล้ามเนื้อ

สัญญาณไฟฟ้ากล้ามเนื้อ คือ ความต่างศักย์ทางไฟฟ้าของกล้ามเนื้อซึ่งบ่งบอกระดับความตึงของกล้ามเนื้อจากการเกร็งของเส้นใยกล้ามเนื้อ ซึ่งเกิดจากการสั่งงานโดยเซลล์ประสาทสั่งการ (Motor neuron) ผ่านกระแสประสาทไปยังเส้นใยกล้ามเนื้อนั้น โดยแต่ละมัดกล้ามเนื้อประกอบไปด้วยเส้นใยกล้ามเนื้อจำนวนมากหลายล้านเส้นดังรูปที่ 2-3 จึงอาจกล่าวได้ว่าสัญญาณไฟฟ้ากล้ามเนื้อเปรียบเสมือนภาพสะท้อนของกิจกรรมทางไฟฟ้าของกล้ามเนื้อ ดังนั้นจึงมีการนำสัญญาณไฟฟ้ากล้ามเนื้อมาใช้ประโยชน์ในหลากหลายด้าน ซึ่งในด้านหนึ่งคือการใช้ในทางการแพทย์เพื่อช่วยในการวินิจฉัยอาการผิดปกติของผู้ป่วย เช่น อาการของโรคที่เกิดจากเส้นประสาทสั่งการบาดเจ็บไม่สามารถควบคุมอวัยวะได้ เป็นต้น



รูปที่ 2-3 ความสัมพันธ์ระหว่าง Motor unit และ สัญญาณไฟฟ้ากล้ามเนื้อ [12]

2.3 การตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ

เนื้อเยื่อสมอง เส้นประสาท และกล้ามเนื้อมีการสร้างและส่งผ่านสัญญาณไฟฟ้า เมื่อถูกกระตุ้นด้วยสิ่งเร้า ดังนั้นวิธีการตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Electromyography : EMG) คือ เทคนิคการบันทึกสัญญาณไฟฟ้าเนื่องจากการหดตัวของกล้ามเนื้อซึ่งเกิดจากการทำงานของหน่วยยนต์ (Motor unit) ภายใต้การควบคุมของเซลล์ประสาทสั่งการ (Motor neuron) ผ่านกระแสประสาท ซึ่งมีหลักการเดียวกันกับวิธีการตรวจวัดสัญญาณไฟฟ้าหัวใจ (Electrocardiogram : ECG/EKG) และวิธีการตรวจวัดสัญญาณไฟฟ้าสมอง (Electroencephalogram : EEG) แตกต่างกันเพียงเฉพาะขนาดของศักย์ไฟฟ้าและความถี่ของสัญญาณไฟฟ้า ซึ่งแสดงดังตารางที่ 2-1

ตารางที่ 2-1 ขนาดแรงดันไฟฟ้าและความถี่ตอบสนองสัญญาณไฟฟ้ากล้ามเนื้อ หัวใจ และสมอง [13]

ชนิดของสัญญาณไฟฟ้า	ความถี่ตอบสนอง (Hz)	แรงดันไฟฟ้า (mV)
สัญญาณไฟฟ้าสมอง	0.02-100	0.001-0.100
สัญญาณไฟฟ้าหัวใจ	0.1-30	0.020-3.000
สัญญาณไฟฟ้ากล้ามเนื้อ	2-10,000	0.003-5.000

การตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อจำเป็นต้องใช้อุปกรณ์สำหรับตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ ซึ่งมีส่วนประกอบสำคัญ ได้แก่ อิเล็กโทรดสำหรับบันทึกสัญญาณไฟฟ้ากล้ามเนื้อ และวงจรไฟฟ้าสำหรับกรองและขยายสัญญาณไฟฟ้ากล้ามเนื้อ โดยทั่วไปอิเล็กโทรดที่ใช้ในการตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อจะแบ่งเป็นสองชนิด คือ อิเล็กโทรดแบบเข็ม (Needle electrode) สำหรับใช้แทงเข้าไปในกล้ามเนื้อเพื่อตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อโดยตรงและอิเล็กโทรดแบบวางบนผิวหนัง (Surface electrode) ซึ่งเป็นแผ่นขั้วไฟฟ้าสำหรับวางบนผิวหนังบริเวณที่ต้องการตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อดังแสดงในรูปที่ 2-4




รูปที่ 2-4 ลักษณะของอิล็กโทรดแต่ละชนิดที่ใช้ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ [14]

2.4 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial neural network : ANN) คือ ระบบการคำนวณที่สร้างโดยมีแนวคิดเลียนแบบการทำงานของระบบสมองมนุษย์ [15] ซึ่งมีการเชื่อมต่อกันระหว่างเซลล์ประสาท (neurons) และ จุดประสานประสาท (synapses) จนเป็นเครือข่ายที่ทำงานร่วมกัน เช่นเดียวกับกับโครงข่ายประสาทเทียมที่มีการทำงานร่วมกันระหว่างโหนด (Node) ในแต่ละชั้น (Layer) เพื่อใช้ประโยชน์ในการคาดคะเนเหตุการณ์จากข้อมูลที่มี ซึ่งโครงสร้างของโครงข่ายประสาทเทียมประกอบด้วยชั้นจำนวน 3 ชั้นที่เชื่อมต่อกันแสดงดังรูปที่ 2-5 โดยมีรายละเอียดดังนี้

- ชั้นของอินพุต (Input layer) เป็นชั้นเริ่มต้นสำหรับนำเข้าข้อมูลเพื่อส่งต่อไปยัง ชั้นซ่อน (Hidden layer) โดยในชั้นอินพุตประกอบด้วยโหนด (Node) ซึ่งมีจำนวนเท่ากับจำนวนข้อมูลอินพุต (Input data)
- ชั้นซ่อน (Hidden layer) เป็นชั้นที่อยู่ระหว่าง ชั้นของอินพุต (Input layer) และชั้นของเอาต์พุต (Output layer) ซึ่งในโครงสร้างของโครงข่ายประสาทเทียมอาจมีชั้นซ่อน (Hidden layer) ได้มากกว่า 1 ชั้น โดยในชั้นนี้มีการปรับค่าน้ำหนัก (Weight) และค่าไบอัส (Bias) ซึ่งเป็นตัวแปรสำหรับคำนวณข้อมูลเอาต์พุต (Output data) จากข้อมูลอินพุต (Input) ผ่านฟังก์ชันกระตุ้น (Activation function) ซึ่งมีหน้าที่ประมวลผลเพื่อปรับตัวแปรข้างต้นให้สามารถคำนวณข้อมูลเอาต์พุตจากข้อมูลอินพุตได้อย่างเหมาะสมเพื่อส่งต่อไปยังชั้นของเอาต์พุต (Output layer) โดยฟังก์ชันกระตุ้นมีหลายประเภท เช่น Binary step function, Sigmoid function, Tanh function, linear function เป็นต้น

- ชั้นของเอาต์พุต (Output layer) เป็นชั้นสำหรับรวมผลลัพธ์ที่ได้จากชั้นซ่อน (Hidden layer) และแปลงข้อมูลเพื่อส่งออกข้อมูล โดยโหนด (Node) ในชั้นนี้มีจำนวนเท่ากับข้อมูลเอาต์พุต (Output data)



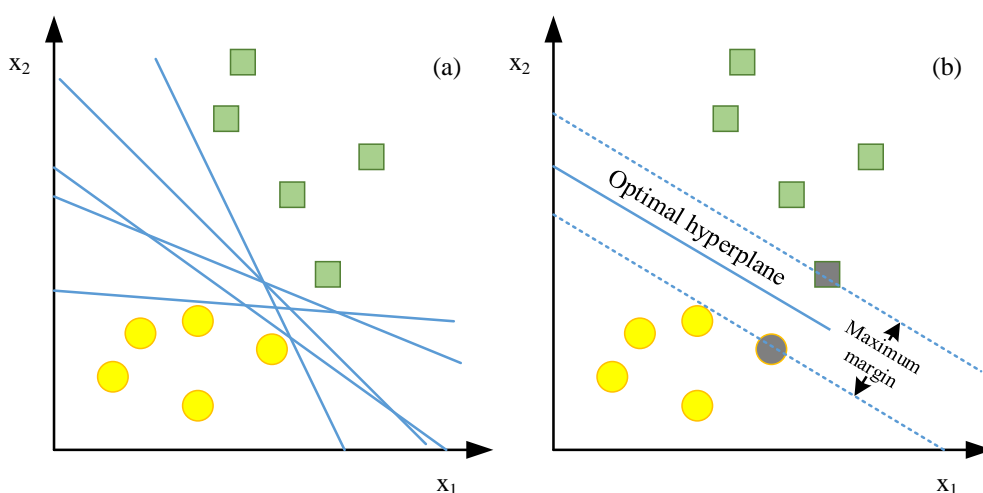
รูปที่ 2-5 โครงสร้างของโครงข่ายประสาทเทียม

การพัฒนาแบบจำลองทางคณิตศาสตร์จากชุดข้อมูล (Dataset) โดยใช้วิธีโครงข่ายประสาทเทียมจำเป็นต้องมีขั้นตอนสำหรับการเรียนรู้ของระบบโครงข่ายประสาทเทียมซึ่งแบ่งเป็น 3 รูปแบบ ดังนี้ [16]

- 1) การเรียนรู้แบบมีผู้สอน (Supervised Learning) โครงข่ายประสาทเทียมจะได้รับการฝึกสอนด้วยข้อมูลนำเข้าและค่าส่งออกที่ต้องการ สำหรับปรับค่าน้ำหนักและค่าไบอัส เพื่อให้ค่าส่งออกที่ได้มีความใกล้เคียงกับค่าส่งออกที่ต้องการมากที่สุด
- 2) การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning) การเรียนรู้แบบนี้จะ คล้ายคลึงกับการเรียนรู้แบบมีผู้สอน แต่ต่างกันตรงที่การเรียนรู้แบบนี้จะใช้ข้อมูลนำเข้าและใช้คะแนน (Score) แทนค่าส่งออก
- 3) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการเรียนรู้เพื่อปรับค่าน้ำหนักและค่าไบอัสซึ่งจะตอบสนองจากข้อมูลอินพุตเท่านั้น โดยไม่ได้ใช้ค่าส่งออกร่วมด้วยในการฝึกสอน วิธีการเรียนรู้แบบนี้จะใช้การจัดแบ่งกลุ่ม โดยพิจารณาตามรูปแบบของข้อมูลอินพุต

2.5 Support Vector Machine

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) เป็นเทคนิคซึ่งสามารถนำมาช่วยแก้ปัญหาในการจำแนกกลุ่มข้อมูล โดยอาศัยหลักการคือการให้ข้อมูลอินพุตที่ใช้ฝึกสอนเป็นเวกเตอร์ในสเปซ N มิติ เรียกว่า เวกเตอร์อินพุต (Input vector) เช่น กรณีข้อมูลอินพุตที่ใช้ฝึกสอนเป็นเวกเตอร์ในสเปซ 2 มิติ และ 3 มิติ สามารถเขียนในรูปเวกเตอร์อินพุตโดยแสดงเป็นพิกัดจุดอยู่ในระนาบ (x, y) และ (x, y, z) ตามลำดับ จากนั้นนำเวกเตอร์อินพุต (Input vector) ไปใช้สำหรับหาสัมประสิทธิ์ของสมการเพื่อสร้างเส้นแบ่งแยกกลุ่มข้อมูล (Hyperplane) ที่สามารถแบ่งแยกกลุ่มของเวกเตอร์อินพุตออกเป็นประเภทต่าง ๆ ได้ดีที่สุดดังรูปที่ 2-6 ในกรณีที่เป็น 2 มิติ และ 3 มิติ ไฮเปอร์เพลน คือเส้นตรงและระนาบ ตามลำดับ [17]



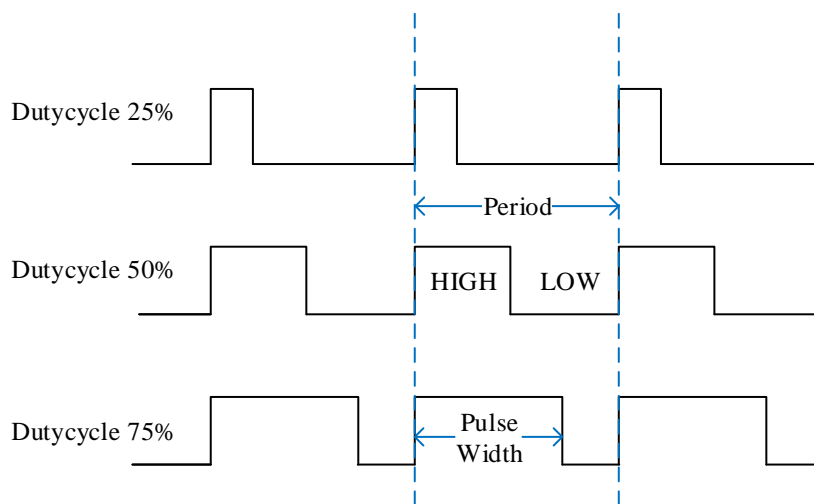
รูปที่ 2-6 ไฮเปอร์เพลนที่เป็นไปได้และไฮเปอร์เพลนที่ดีที่สุด

ในข้อมูลสองกลุ่มจับกลุ่มในตำแหน่งต่างๆแบบเชิงเส้น (Linear) สามารถใช้เทคนิควิธีแบบเชิงเส้นในการสร้างเส้นแบ่งแยกกลุ่มข้อมูล (Hyperplane) ได้ แต่ในกรณีที่ข้อมูลสองกลุ่มจับกลุ่มในตำแหน่งต่างๆแบบไม่เชิงเส้น (Non-Linear) จำเป็นต้องมีการใช้ฟังก์ชันเคอร์เนล (Kernel function) สำหรับทำแมพ (Map) ข้อมูลอินพุตให้มีมิติเพิ่มมากขึ้น (Higher dimensional space) ทำให้สามารถแบ่งกลุ่มข้อมูลโดยใช้เทคนิควิธีแบบเชิงเส้นในการสร้างเส้นแบ่งแยกกลุ่มข้อมูลได้ โดยเคอร์เนลฟังก์ชันมีหลายประเภท เช่น เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ฟังก์ชันเชิงเส้น (Linear function) และฟังก์ชันพหุนาม (Polynomial function) เป็นต้น

2.6 การควบคุมความเร็วมอเตอร์กระแสตรงด้วยวิธีการมอดูเลชันทางความกว้างของพัลส์

การควบคุมความเร็วมอเตอร์กระแสตรงสามารถทำได้โดยการปรับเพิ่มหรือลดแรงดันที่จ่ายให้มอเตอร์ อย่างไรก็ตามในทางปฏิบัติค่อนข้างมีความซับซ้อนในการใช้วงจรเพื่อปรับเพิ่มหรือลดแรงดัน ดังนั้นในการควบคุมความเร็วมอเตอร์กระแสตรงจึงนิยมใช้เทคนิคที่เรียกว่าวิธีการมอดูเลชันทางความกว้างของพัลส์ (Pulse width modulation: PWM) ซึ่งหลักการของวิธีการคือการสร้างสัญญาณพัลส์สถานะ HIGH และ LOW สลับกันที่ความถี่คงที่ แต่มีการควบคุมความกว้างของคาบเวลาในสถานะ HIGH ซึ่งเรียกว่า ดิวตี้ไซเคิล (Duty cycle) คือค่าเปอร์เซ็นต์ความกว้างของคาบเวลาในสถานะ HIGH ของสัญญาณพัลส์ต่อความกว้างของคาบเวลาทั้งหมด [18] ซึ่งสามารถคำนวณจากสมการ 2.1 โดยสัญญาณพัลส์ที่ดิวตี้ไซเคิล 25 50 และ 75 เปอร์เซ็นต์แสดงดังรูปที่ 2-7

$$DutyCycle(\%) = \left(\frac{PulseWidth}{Period} \right) \times 100 \quad (2.1)$$

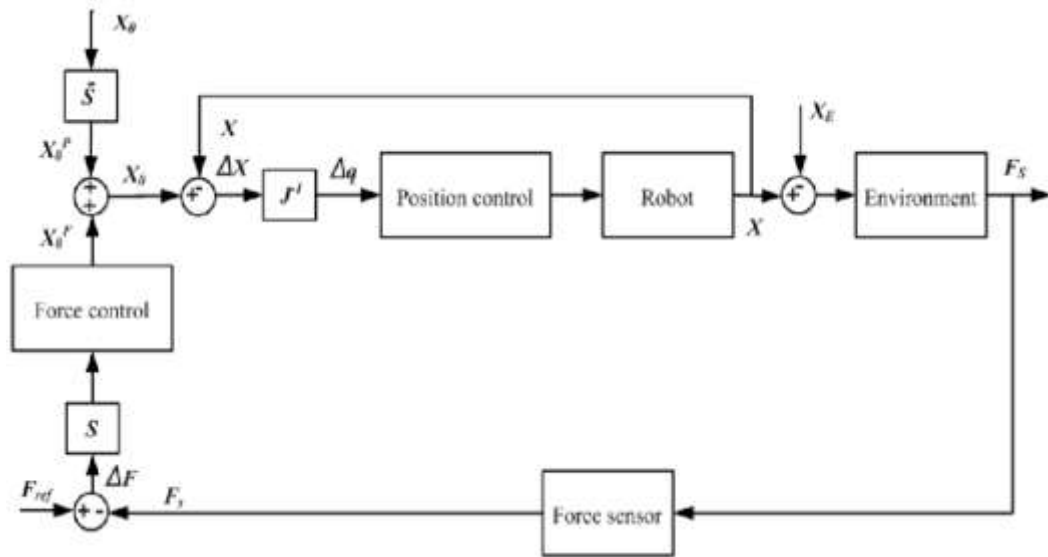


รูปที่ 2-7 สัญญาณพัลส์ที่ดิวตี้ไซเคิล 25 50 และ 75 เปอร์เซ็นต์

2.7 หลักการ Force/position control

ตั้งแต่อดีตจนถึงปัจจุบันมีการพัฒนารูปแบบการควบคุมการทำงานของระบบหุ่นยนต์เรื่อยมา ซึ่งรูปแบบการควบคุมหุ่นยนต์รูปแบบหนึ่งคือการควบคุมให้หุ่นยนต์สามารถมีปฏิสัมพันธ์กับสิ่งแวดล้อมได้ โดยใช้แรงสัมผัสซึ่งเรียกรูปแบบการควบคุมหุ่นยนต์ดังกล่าวว่า Force/position control ทำให้สามารถควบคุมการเคลื่อนที่ของหุ่นยนต์ด้วยแรงภายนอกที่กระทำได้ มีงานวิจัยที่นำเสนอวิธีการควบคุมหุ่นยนต์ด้วยรูปแบบการควบคุมโดยใช้ Force/position control ด้วยอัลกอริทึมแรงหลากหลายรูปแบบ เช่น งานวิจัยของ Alexander Winkler และ Jozef Suchy [19] ได้นำเสนอวิธีการควบคุมแบบ Implicit Force Control งานวิจัยของ Salisbury และคณะ [20] นำเสนอวิธีการควบคุมแบบ Active compliant motion งานวิจัยของ Hogan และคณะ [21] นำเสนอวิธีการควบคุมแบบ Impedance control งานวิจัยของ Volpe และ Khosla [22] นำเสนอวิธีการควบคุมแบบ Explicit force control งานวิจัยของ Railbert และคณะ [23] นำเสนอวิธีการควบคุมแบบ Hybrid force/position control

อีกหนึ่งวิธีซึ่งมีการนำมาใช้เพื่อควบคุมระบบหุ่นยนต์ในงานวิจัยนี้คือ วิธี External force control ซึ่งนำเสนอโดย De Schutter and Van Brussel [24] โดยหลักการของวิธีการดังกล่าวคือการปรับค่าคงที่ (Gain) ที่เหมาะสมซึ่งใช้สำหรับประมวลผลในระบบการควบคุมหุ่นยนต์เพื่อให้ระบบการควบคุมหุ่นยนต์มีความเสถียรและแม่นยำ ซึ่งการปรับเปลี่ยนค่าคงที่ (Gain) ที่แตกต่างกันจะส่งผลทำให้ระบบมีการตอบสนองที่แตกต่างกัน เช่น การปรับค่าคงที่ (Gain) น้อยเกินไปจะทำให้ระบบมีการตอบสนองต่ำ และการปรับค่าคงที่ (Gain) มากเกินไปจะทำให้ระบบมีการตอบสนองอย่างรวดเร็วจนเกิดการโอเวอร์ชูต (Overshoot) มากทำให้เกิดการสั่น (Oscillations) นำไปสู่ความไม่เสถียรของระบบการควบคุมหุ่นยนต์ ซึ่งขั้นตอนสำหรับวิธีการควบคุมระบบหุ่นยนต์แบบ External force control แสดงด้วยบล็อกไดอะแกรมดังรูปที่ 2-8 ซึ่งประกอบด้วย ลูปสำหรับควบคุมระบบ 2 ลูป ได้แก่ ลูปภายนอกสำหรับควบคุมแรงและลูปภายในสำหรับควบคุมตำแหน่ง โดยผลลัพธ์ที่ได้จากลูปภายนอกคือ ΔF จากนั้นเปลี่ยนเป็นอินพุต X_0^F สำหรับลูปภายในเพื่อประมวลผลควบคุมหุ่นยนต์ให้เคลื่อนที่ไปยังตำแหน่งที่ต้องการ



รูปที่ 2-8 บล็อกไดอะแกรมวิธีการควบคุมระบบหุ่นยนต์แบบ External force control [24]

2.8 ระบบควบคุมแบบสัดส่วน-ปริพันธ์-อนุพันธ์

ระบบควบคุมแบบสัดส่วน-ปริพันธ์-อนุพันธ์ (Proportional-Integral-Derivative Controller) เป็นวิธีการควบคุมระบบแบบป้อนกลับที่ใช้กันอย่างแพร่หลายเพื่อปรับค่าคงที่ (Gain) ให้เหมาะสมในสถานะการใช้งานจริงสำหรับร่วมประมวลผลในการควบคุมระบบหุ่นยนต์ เช่น การควบคุมความเร็วการหมุนของแกนมอเตอร์ อุ่นหภูมิ และตำแหน่งการเคลื่อนที่ของหุ่นยนต์ เป็นต้น โดยสมการที่ใช้โดยวิธีการควบคุมแบบสัดส่วน-ปริพันธ์-อนุพันธ์แสดงดังสมการดังสมการที่ 2.2 2.3 และ 2.4 [11]

$$U(t) = U_p(t) + U_I(t) + U_D(t) \quad (2.2)$$

$$U(t) = K_p[y_{de}(t) - y(t)] + K_I \int_0^t [y_{de}(\tau) - y(\tau)] d\tau + K_D \frac{d[y_{de}(t) - y(t)]}{dt} \quad (2.3)$$

$$U(t) = K_p e(t) + K_I \int_0^t e(\tau) d\tau + K_D \frac{de(t)}{dt} \quad (2.4)$$

โดยที่ y_{de} คือ ค่า Process output ที่ต้องการ

$y(t)$ คือ ค่า Process output จริง

$e(t)$ คือ ความแตกต่างระหว่างค่าที่ต้องการกับค่าจริงหรือค่าอินพุตของ PID control

- $U(t)$ คือ ค่าเอาต์พุตของ PID control
- K_p คือ ค่าคงที่ Proportional gain
- K_i คือ ค่าคงที่ Integral gain
- K_D คือ ค่าคงที่ Derivative gain
- t, τ คือ เวลาต่อเนื่องและเวลาในการสุ่มตัวอย่าง


บทที่ 3

ระเบียบวิธีวิจัย

3.1 การออกแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ

ต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ (One-DOF Human Robot Interaction) ถูกออกแบบเพื่อจำลองสถานการณ์การออกแรงแขนของมนุษย์กระทำต่อด้ามจับให้เคลื่อนที่ในแนวแกน 1 มิติ สำหรับเก็บข้อมูลเพื่อนำไปใช้ในการพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับประมาณแรงกล้ามเนื้อของมนุษย์ในแนวแกน 1 มิติ โดยรูปที่ 3-1 แสดงเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ ซึ่งการออกแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ มีแนวคิดดังนี้


- สามารถจำลองการเคลื่อนที่ของด้ามจับในแนวแกน 1 มิติจากการออกแรงกระทำของมนุษย์
- สามารถเก็บข้อมูลที่เกี่ยวข้องกับการใช้งาน ได้แก่ สัญญาณไฟฟ้ากล้ามเนื้อ ขนาดและทิศทางของแรงที่กระทำต่อด้ามจับ ระยะทางและความเร็วของด้ามจับ ขนาดของแรงบีบจากนิ้วมือ 4 นิ้ว ซึ่งประกอบด้วย นิ้วชี้ นิ้วกลาง นิ้วนาง และนิ้วก้อย
- สามารถกำหนดแรงต้านทานการเคลื่อนที่ของด้ามจับ
- มีจุดอ้างอิงการเคลื่อนที่สำหรับให้ผู้ใช้งานออกแรงกระทำต่อด้ามจับให้เคลื่อนที่ด้วยความเร็วใกล้เคียงกับจุดอ้างอิงดังกล่าว
- มีเสียงแจ้งเตือนเมื่อผู้ใช้งานออกแรงบีบนิ้วมือรวมทั้ง 4 นิ้ว มากกว่า 1 นิวตัน
- มีอุปกรณ์กำหนดขอบเขตระยะการเคลื่อนที่ของด้ามจับในช่วง 0 – 40 เซนติเมตร



รูปที่ 3-1 เครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ

3.2 การออกแบบการทำงานของระบบในการเคลื่อนที่ 1 มิติ


ระบบสำหรับการเคลื่อนที่ 1 มิติ ออกแบบโดยจำเป็นต้องใช้เครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติต่อร่วมกับอุปกรณ์อื่นๆ เพื่อให้ระบบสำหรับการเคลื่อนที่ 1 มิติสามารถใช้งานได้ ดังรูปที่ 3-2 โดยรายละเอียดของอุปกรณ์ที่ใช้ในการต่อร่วม มีดังนี้



รูปที่ 3-2 อุปกรณ์สำหรับต่อร่วมกับเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ


- a) เซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Myo armband) เป็นอุปกรณ์ที่ถูกพัฒนาโดย Thalmic Labs สำหรับสวมใส่เพื่อตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อด้วยแผ่น Medical Grade Stainless Steel EMG จำนวน 8 แผ่นสำหรับตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อรอบข้อแขนที่สวมใส่ซึ่งใช้หลักการ คือ ขณะกล้ามเนื้อมีการขยับหรือเคลื่อนไหว สมองจะมีการส่งสัญญาณไฟฟ้าส่งงานผ่านเส้นประสาท อาจกล่าวได้ว่าสัญญาณไฟฟ้างดังกล่าวเป็นภาพสะท้อนการเคลื่อนไหวของกล้ามเนื้อ ดังนั้นจึงมีวิธีการเพื่อตรวจวัดสัญญาณไฟฟ้างดังกล่าวที่เรียกว่า Electromyography (EMG) อีกทั้งอุปกรณ์ยังสามารถตรวจวัดค่าอื่นๆ ที่เกี่ยวข้องกับการเคลื่อนไหวด้วย 9-Axis Motion Sensor เป็นเซ็นเซอร์ตรวจจับการเคลื่อนไหว 9 แกน ประกอบด้วย Accelerometer 3 แกน สำหรับตรวจวัดความเร่งในแนวแกนในขณะที่ผู้ใช้แกว่งแขน Gyroscope 3 แกน สำหรับตรวจวัดมุม Row Pitch และ Yaw ในขณะที่ผู้ใช้

หมุนแขน และ Magnetometer 3 แกน สำหรับตรวจวัดความเข้มข้นแม่เหล็กซึ่งบ่งบอกถึงทิศทางการหันของผู้สวมใส่อุปกรณ์ นอกจากนี้อุปกรณ์ยังมีข้อดีในเรื่องของการส่งข้อมูลแบบไร้สายด้วย Bluetooth Low Energy อีกทั้งยังสามารถปรับขนาดยืดและหดเพื่อให้เหมาะสมแก่ผู้สวมใส่ตั้งแต่ 7.5-13 นิ้ว มีขนาดเล็กและมีความหนาเพียง 0.45 นิ้ว น้ำหนักเบาเพียง 93 กรัม สามารถพกพาและติดตั้งได้ง่าย ดังรูปที่ 3-3 ในการทดลองนี้ใช้เซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Myo armband) ซึ่งเป็นเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อชนิดอิเล็กทรอนิกส์แบบวางบนผิวหนัง สำหรับตรวจวัดและเก็บข้อมูลสัญญาณไฟฟ้ากล้ามเนื้อตลอดการทดลอง



รูปที่ 3-3 เซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Myo armband) [25]

- b) แหล่งจ่ายไฟ (Power supply) เป็นอุปกรณ์ที่ทำหน้าที่แปลงพลังงานไฟฟ้าจากรูปแบบหนึ่งไปเป็นอีกรูปแบบหนึ่ง เช่น แปลงพลังงานไฟฟ้ากระแสสลับเปลี่ยนเป็นพลังงานไฟฟ้ากระแสตรง แปลงพลังงานไฟฟ้ากระแสตรงเปลี่ยนเป็นพลังงานไฟฟ้ากระแสสลับ เป็นต้น สำหรับจ่ายแรงดันและกระแสให้กับวงจร ดังรูปที่ 3-4 ในการทดลองนี้ใช้แหล่งจ่ายไฟซึ่งแปลงจากไฟฟ้ากระแสสลับ 220VAC เปลี่ยนเป็น ไฟฟ้ากระแสตรง 12 VDC สำหรับจ่ายแรงดันและกระแสให้กับไมโครคอนโทรลเลอร์และวงจรควบคุมมอเตอร์



รูปที่ 3-4 แหล่งจ่ายไฟ 12 VDC [26]


- c) โน้ตบุ๊ก (Notebook) เป็นคอมพิวเตอร์ขนาดพกพาซึ่งสามารถแสดงผลผ่านจอแสดงผลและสามารถรับหรือส่งข้อมูลระหว่างอุปกรณ์อิเล็กทรอนิกส์ได้ เช่น การสื่อสารระหว่างคีย์บอร์ดกับโน้ตบุ๊ก การสื่อสารระหว่างเมาส์กับโน้ตบุ๊ก เป็นต้น ดังรูปที่ 3-5 ในการทดลองนี้ใช้โน้ตบุ๊กเป็นส่วนแสดงผลชุดโปรแกรมควบคุมการทำงาน (User interface) สำหรับต่อประสานระหว่างระบบสำหรับการเคลื่อนที่ใน 1 มิติกับผู้ใช้งานระบบ



รูปที่ 3-5 โน้ตบุ๊ก (Laptop) [27]

ระบบสำหรับการเคลื่อนที่ 1 มิติ ดังแสดงในรูปที่ 3-6 มีหลักการทำงานคือผู้ใช้ออกแรงผลักกระทำต่อด้ามจับให้เคลื่อนที่ในแนวแกน 1 มิติด้วยความเร็วคงที่ใกล้เคียงความเร็วจุดอ้างอิงการเคลื่อนที่ จากตำแหน่งจุดเริ่มต้น (Start point) ไปยังจุดสิ้นสุด (End point) ซึ่งมีลิมิตสวิตช์ (Limit switch) สำหรับกำหนดขอบเขตการเคลื่อนที่ ณ ตำแหน่งทั้งสองเพื่อป้องกันการชนของด้ามจับ โดยทิศทางและความเร็วการเคลื่อนที่ของด้ามจับจะเป็นปฏิกิริยาโดยตรงกับทิศทางและขนาดของแรงที่ผู้ใช้กระทำตามลำดับ ในระหว่างการเคลื่อนที่ของด้ามจับมีการตรวจวัดค่าสัญญาณต่างๆ ที่เกี่ยวข้อง

กับการทดลองตลอดการเคลื่อนที่ ได้แก่ สัญญาณไฟฟ้ากล้ามเนื้อ ทิศทางและขนาดของแรง ขนาดของแรงบีบนิ้วมือ ระยะทางและความเร็วการเคลื่อนที่ของด้ามจับ โดยใช้เซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Myo armband) เซ็นเซอร์ตรวจวัดแรง (Loadcell) เซ็นเซอร์ตรวจวัดแรงบีบ (Force sensor resistor) และเซ็นเซอร์ตรวจวัดรอบการหมุน (Encoder) ตามลำดับ และมีการควบคุมความเหมาะสมของการออกแรงบีบนิ้วมือในขณะที่เคลื่อนที่ด้ามจับโดยแจ้งเตือนผู้ใช้ด้วยเสียงผ่าน ลำโพงบัสเซอร์ (Buzzer module) เมื่อผลรวมของแรงบีบนิ้วมือทั้ง 4 นิ้ว ประกอบด้วย นิ้วชี้ นิ้วกลาง นิ้วนาง และนิ้วก้อย มีขนาดมากกว่า 1 นิวตัน อีกทั้งยังมีชุดโปรแกรมต่อประสาน (User interface) สำหรับใช้งานฟังก์ชันในการบันทึกค่าสัญญาณที่เกี่ยวข้องไปยังแพลตฟอร์มข้อมูล การประมาณค่าความต้านทานการเคลื่อนที่ของด้ามจับ ณ ขณะใช้งาน และการกำหนดขนาดพารามิเตอร์ในการทดลอง ได้แก่ ขนาดของแรงต้านทานการเคลื่อนที่ของด้ามจับ ความเร็วของจุดอ้างอิงการเคลื่อนที่ ขนาดของตัวอย่างที่ใช้สำหรับการคำนวณลักษณะเด่น จำนวนการซ้อนทับของข้อมูลในการแบ่งข้อมูลที่ซ้อนทับกัน (Overlapping Data Partitioning)



รูปที่ 3-6 บล็อกไดอะแกรมการทำงานของระบบสำหรับการเคลื่อนที่ 1 เมตร

3.3 ส่วนประกอบของเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ

- a) รางสไลด์ (Linear rail) เป็นอุปกรณ์เครื่องมือกลที่มีลักษณะเป็น รางยาว มีปล็อคสี่เหลี่ยมที่เป็นตัวรับน้ำหนักสามารถเลื่อนไปกลับ ได้ ผลิตมาจากเหล็กหรืออลูมิเนียม ภายในจะมีตลับลูกปืนเป็นตัว ขับเคลื่อนให้สามารถเคลื่อนที่ไปตามรางได้อย่างสะดวกรวดเร็ว ดังรูปที่ 3-7 ในการทดลองใช้รางสไลด์กว้าง 30 มิลลิเมตร ยาว 1 เมตรสำหรับเป็นฐานในการเคลื่อนที่ในแนวเส้นตรง



รูปที่ 3-7 บล็อกและรางสไลด์ [28]

- b) สายพานส่งกำลัง(Transmission Belt) จะทำหน้าที่ในการส่งถ่ายกำลังจากที่หนึ่งไปยังอีกที่หนึ่งโดยผ่าน ลูกล้อหรือที่เรียกว่าพูลเล่ (Pulley) ตั้งแต่ 2 ลูกขึ้นไป ลูกล้อหรือพูลเล่(Pulley) ที่เป็นจุดกำเนิดต้นกำลังเรียกว่าพูลเล่ขับ (Drive Pulley) และลูกล้อหรือพูลเล่ (Pulley) ที่รับแรงขับที่ส่งผ่านมาจากสายพานส่งกำลัง (Transmission Belt) เรียกว่า พูลเล่ตาม (Tail Pulley) ดังรูปที่ 3-8 ในการทดลองใช้พูลเล่ขนาด 8 มิลลิเมตรสำหรับส่งกำลังจากมอเตอร์เพื่อเคลื่อนที่ด้ามจับในการทดลอง



รูปที่ 3-8 สายพานส่งกำลังและพูลเล่ [29]

- c) มอเตอร์กระแสตรง 12 โวลต์ (12 VDC Motor) เป็นอุปกรณ์สำหรับแปลงพลังงานไฟฟ้ากระแสตรงให้เป็นพลังงานกลสำหรับขับเคลื่อนตัวถูกขับ โดยมอเตอร์มีขนาดเพลา 6 มิลลิเมตร ดังรูปที่ 3-9 ในการทดลองใช้มอเตอร์ความเร็วรอบ 300 rpm สำหรับขับเคลื่อนด้ามจับ (Handle) และกำหนดความต้านทานการเคลื่อนที่ของด้ามจับ และใช้มอเตอร์ความเร็วรอบ 150 rpm สำหรับขับเคลื่อนจุดอ้างอิงการเคลื่อนที่เพื่อเป็นจุดอ้างอิงความเร็วในการทดลอง



รูปที่ 3-9 มอเตอร์กระแสตรง 12 โวลต์ [30]

- d) เซ็นเซอร์ตรวจวัดแรง (Loadcell) เป็นอุปกรณ์อิเล็กทรอนิกส์ที่ถูกใช้เพื่อแปลงค่าของแรงที่กระทำไปเป็นสัญญาณไฟฟ้า (ทรานส์ซีดีวีเซอร์) การแปลงค่านี้ไม่ใช้การแปลงค่าโดยตรง หากแต่เกิดขึ้นสองขั้นตอน คือ การแปลงค่าทางกลศาสตร์ แรงจะถูกตรวจจับได้จากการเปลี่ยนรูปร่างของสแตนเกจ และสแตนเกจแปลงค่าการเปลี่ยนรูปร่างเป็นสัญญาณไฟฟ้า เซ็นเซอร์ตรวจวัดแรงจะประกอบไปด้วยสแตนเกจสี่ตัวซึ่งจัดเรียงวงจรในรูปแบบของวงจร วิจสโตน บริดจ์ สัญญาณไฟที่จ่ายออกมักจะมีขนาดเพียงไม่กี่มิลลิโวลต์ ดังนั้นจำเป็นต้องมีวงจร HX-711 สำหรับการขยายสัญญาณก่อนนำไปใช้งาน ดังรูปที่ 3-10 ในการทดลองนี้ใช้โหลดเซลล์ขนาดวัดแรงสูงสุดได้ 3 กิโลกรัมเพื่อตรวจวัดแรงในแนวแกน 1 มิติ



รูปที่ 3-10 เซ็นเซอร์ตรวจวัดแรง (Loadcell) [31]

- e) ลิ้มิตสวิตช์ (Limit switch) เป็นอุปกรณ์สำหรับใช้เพื่อจำกัดระยะทาง หลักการทำงานคืออาศัยแรงกดภายนอกมากระทำ เพื่อเปลี่ยนหน้าสัมผัสที่ต่ออยู่กับก้านที่รับแรงกด โดยสวิตช์จะเปิด-ปิด ตามจังหวะของแรงกดภายนอกที่กระทำ ดังรูปที่ 3-11 ในการทดลองนี้ใช้ลิ้มิตสวิตช์เพื่อกำหนดจุดเริ่มต้นและสิ้นสุดระยะการเคลื่อนที่ของด้ามจับ



รูปที่ 3-11 ลิ้มิตสวิตช์ (Limit switch) [32]

- f) เซ็นเซอร์ตรวจวัดรอบการหมุน (Encoder) เป็นอุปกรณ์ในการเข้ารหัสจากระยะทางการหมุนรอบตัวเองและแปลงเป็นรหัสในรูปของสัญญาณไฟฟ้าหลังจากนั้นจะนำรหัสนั้นมาแปลงกลับเพื่อหาค่าต่างๆ เช่น ระยะทางการหมุน, องศาการเคลื่อนที่, ความเร็วรอบ เป็นต้น ดังรูปที่ 3-12 ในการทดลองนี้ใช้เซ็นเซอร์ตรวจวัดรอบการหมุนประเภท Incremental Encoder สำหรับตรวจวัดระยะด้ามจับ ความเร็วด้ามจับ และความเร็วจุดอ้างอิงการเคลื่อนที่ซึ่งหลักการคือเมื่อมีการหมุนของแกนเพลลาจะทำให้มีสัญญาณเอาต์พุตเป็นสัญญาณลูกคลื่นพัลส์สี่เหลี่ยม (Square wave) โดยการหมุน 1 รอบจะกำเนิดสัญญาณ 720 ลูกคลื่นสัญญาณ



รูปที่ 3-12 เซ็นเซอร์ตรวจวัดรอบการหมุน (Encoder) [33]

- g) ด้ามจับ (Handle) เป็นด้ามจับรูปทรงกระบอกถูกออกแบบให้มีส่วนโค้งเว้าเหมาะสมสำหรับจับในขณะที่ฟื้นฟูสมรรถภาพ ดังรูปที่ 3-13 ในการทดลองนี้ด้ามจับถูกใช้เพื่อผู้ทำการทดลองจับยึดเพื่อออกแรงกระทำและต่อประสานระหว่างเซ็นเซอร์ตรวจวัดแรงและเซ็นเซอร์ตรวจวัดแรงบีบนิ้วมือ



รูปที่ 3-13 ด้ามจับ (Handle)

- h) เซ็นเซอร์ตรวจวัดแรงบีบ (Force sensor resistor) เป็นอุปกรณ์ที่ถูกพัฒนามาจากวัสดุประเภทฟิล์มโพลีเมอร์แบบหนา (Polymer Thick Film) หลักการทำงานคือเมื่อมีแรงกดกระทำผ่านฟิล์มแรงดันไฟฟ้าที่ตกคร่อมตัวตรวจจับจะลดลง ดังรูปที่ 3-14 ในการทดลองนี้ใช้เซ็นเซอร์ตรวจวัดแรงบีบรูปทรงกลม ขนาดเส้นผ่านศูนย์กลาง 0.5 นิ้วตรวจวัดแรงกดได้ตั้งแต่ 0.1 ถึง 10 นิวตัน สำหรับตรวจวัดแรงบีบนิ้วมือ 4 นิ้ว ประกอบด้วย นิ้วชี้ นิ้วกลาง นิ้วนาง และนิ้วก้อย



รูปที่ 3-14 เซ็นเซอร์ตรวจวัดแรงบีบ (Force sensor resistor) [34]

- i) ลำโพงบัซเซอร์ (Buzzer module) เป็นอุปกรณ์ที่ให้กำเนิดเสียงทำหน้าที่เปลี่ยนสัญญาณไฟฟ้าให้อยู่ในรูปสัญญาณเสียงมี 2 ประเภท ได้แก่ แบบแอคทีฟ (Active Buzzer) เป็นลำโพงชนิดมีวงจรกำเนิดความถี่อยู่ภายใน สามารถสร้าง สัญญาณเสียงเตือนได้ทันที เพียงแค่จ่ายแรงดันไฟฟ้า และแบบพาสซีฟ (Passive Buzzer) เป็นลำโพงชนิดนี้ต้องจ่ายทั้งแรงดันไฟฟ้ากระแสตรงและสัญญาณความถี่เข้าไปจึงสามารถสร้างสัญญาณเสียงเตือนได้ ลำโพงชนิดนี้สามารถกำเนิดเสียงที่มีความแตกต่างกันตามความถี่ที่ป้อน ดังรูปที่ 3-15 ในการทดลองนี้ใช้ลำโพงบัซเซอร์แบบพาสซีฟเพื่อส่งสัญญาณเสียงแจ้งเตือนเมื่อผู้ใช้ออกแรงบีบนิ้วมือรวม 4 นิ้วประกอบด้วยนิ้วชี้ นิ้วกลาง นิ้วนาง และนิ้วก้อย มากกว่า 1 นิ้วตัน




รูปที่ 3-15 ลำโพงบัซเซอร์ (Buzzer module) [35]

- j) เชือก (Cable) จะทำหน้าที่ในการส่งถ่ายกำลังจากที่หนึ่งไปยังอีกที่หนึ่งโดยผ่าน รอก (Reel) ตั้งแต่ 2 ลูกขึ้นไป รอกขนาด 47 มิลลิเมตร จำนวน 2 ตัว ดังรูปที่ 3-16 ในการทดลองนี้ใช้เชือกสำหรับส่งกำลังจากมอเตอร์เพื่อขับเคลื่อนจุดอ้างอิงการเคลื่อนที่




รูปที่ 3-16 รอกและเชือก



รูปที่ 3-18 วงจรขับมอเตอร์ L298N [37]

m) IBT-2 (BTS7960) เป็นชุดขับมอเตอร์ซึ่งสามารถควบคุมมอเตอร์ได้เพียง 1 ตัว โดยหลักการทำงานคือวงจร H-Bridge ขับกระแสเข้ามอเตอร์ตามขั้วที่กำหนดด้วยลอจิกจากไมโครคอนโทรลเลอร์เพื่อควบคุมทิศทางการหมุนของแกนมอเตอร์ และควบคุมความเร็วของการหมุนแกนมอเตอร์ด้วยความกว้างของสัญญาณพัลส์ (PWM Pulse Width Modulation) เช่นเดียวกับชุดขับมอเตอร์ L298N แต่ชุดขับมอเตอร์ IBT-2 สามารถขับได้ที่กระแสสูงสุดถึง 43 A และมีระบบป้องกันได้แก่ Over-Voltage, Under-Voltage, Over-Temperature ในขณะที่ชุดขับมอเตอร์ L298N ขับกระแสสูงสุดเพียง 2 A ดังรูปที่ 3-19 ในการทดลองนี้ใช้ชุดขับมอเตอร์ IBT-2 สำหรับควบคุมทิศทางและความเร็วของการหมุนแกนมอเตอร์เพื่อเคลื่อนที่จุดอ้างอิงการเคลื่อนที่ตามจับ




n) รูปที่ 3-19 วงจรขับมอเตอร์ IBT-2 [38]

3.4 การสอบเทียบเซ็นเซอร์

การสอบเทียบเซ็นเซอร์ (Sensor calibration) คือ การเปรียบเทียบค่าที่ได้จากเซ็นเซอร์ตรวจวัดกับค่ามาตรฐาน เพื่อให้แน่ใจว่าเซ็นเซอร์ตรวจวัดที่จะนำไปใช้งานมีค่าที่แม่นยำและเชื่อถือได้ โดยในการทดลองมีการสอบเทียบเซ็นเซอร์ ดังนี้

3.4.1 การสอบเทียบเซ็นเซอร์ตรวจวัดแรง

การทดลองมีการใช้เซ็นเซอร์ตรวจวัดแรง (Loadcell) สำหรับตรวจวัดแรงในการทดลอง โดยก่อนการใช้งานเซ็นเซอร์จำเป็นต้องทำการสอบเทียบ (Calibration) เซ็นเซอร์เพื่อให้สามารถตรวจวัดแรงได้อย่างถูกต้องในสภาพแวดล้อมที่เกิดการใช้งานจริง ซึ่งเซ็นเซอร์ตรวจวัดแรง (Loadcell) ที่ใช้ในการทดลองนี้มีการสอบเทียบเซ็นเซอร์โดยใช้ชุดโปรแกรมสอบเทียบอัตโนมัติ HX711.h อย่างไรก็ตามก่อนใช้งานเซ็นเซอร์ตรวจวัดแรงยังคงจำเป็นต้องมีการตรวจสอบความถูกต้องและสอบเทียบโดยใช้การถ่วงน้ำหนักด้วยวัตถุน้ำหนักคงที่อีกครั้งหลังจากการสอบเทียบด้วยชุดโปรแกรมสอบเทียบอัตโนมัติ ดังนั้นจึงมีการทดลองสอบเทียบเซ็นเซอร์และตรวจสอบความถูกต้องโดยใช้วัตถุจำนวน 5 ชิ้น ซึ่งมีน้ำหนักคงที่ ได้แก่ 0.256 0.516 0.751 1.020 และ 1.335 กิโลกรัม (ครอบคลุมช่วงของแรงที่ใช้ในการทดลองหลัก) ซึ่งตรวจวัดจากเครื่องชั่งน้ำหนักที่มีมาตรฐานความถูกต้องโดยแผนผังแสดงขั้นตอนการทดลองดังรูปที่ 3-20 ผลการเปรียบเทียบระหว่างแรงที่ได้จากการตรวจวัดและน้ำหนักของวัตถุแสดงในตารางที่ 3-1 และแสดงในรูปแบบกราฟเส้นดังรูปที่ 3-21 โดยที่กราฟเส้นสีน้ำเงินและสีส้มคือน้ำหนักของวัตถุและน้ำหนักที่ได้จากการตรวจวัดตามลำดับ

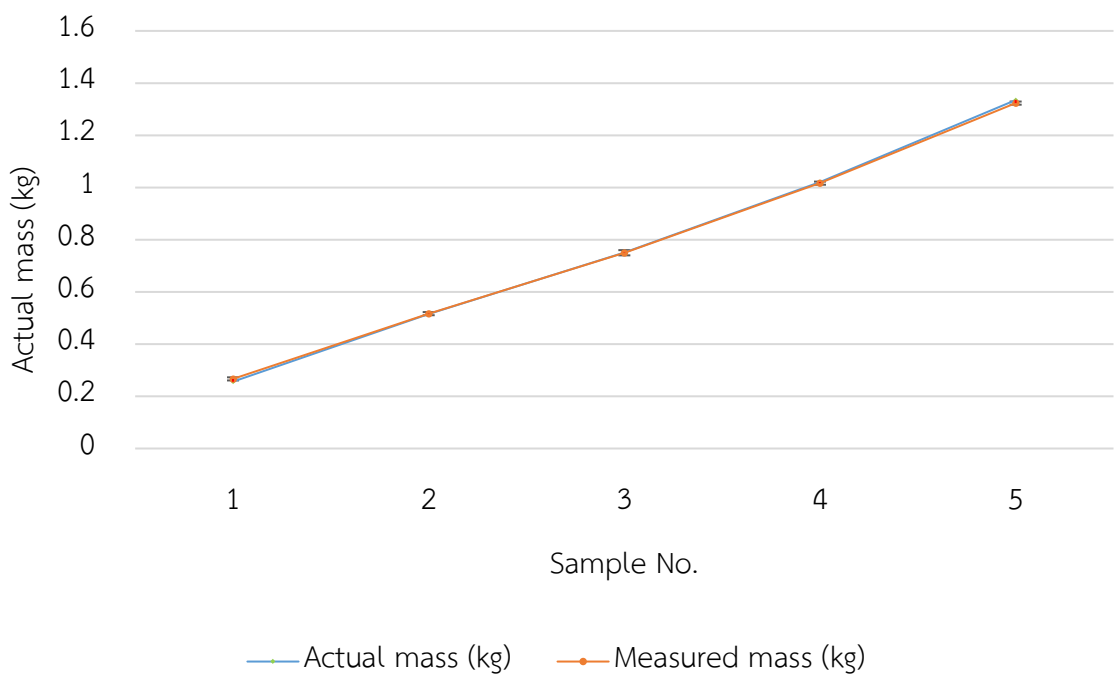


รูปที่ 3-20 แผนผังขั้นตอนการสอบเทียบเซ็นเซอร์ตรวจวัดแรง

ตารางที่ 3-1 การเปรียบเทียบระหว่างน้ำหนักของวัตถุและน้ำหนักจากการตรวจวัด

Sample No.	Actual mass (kg)	Measured mass (kg)	SD
1	0.256	0.270	0.006
2	0.516	0.517	0.006
3	0.751	0.750	0.010
4	1.020	1.017	0.006
5	1.335	1.323	0.006

Comparison between actual force and measured force



รูปที่ 3-21 การเปรียบเทียบแรงที่ได้จากการตรวจวัดและน้ำหนักของวัตถุ

จากความสัมพันธ์ระหว่างแรงจากน้ำหนักของวัตถุและแรงจากการตรวจวัดโดยใช้เซ็นเซอร์ตรวจวัดแรง (Loadcell) ดังแสดงในตารางที่ 3-1 จึงสามารถแสดงความสัมพันธ์ระหว่างแรงจากน้ำหนักของวัตถุและแรงจากการตรวจวัดในรูปแบบสมการความสัมพันธ์ได้ดังสมการที่ 3.1


$$AF = 1.021MF - 0.016 \quad (3.1)$$

โดยที่ AF คือ น้ำหนักวัตถุ มีหน่วยเป็น กิโลกรัม

MF คือ น้ำหนักจากการตรวจวัดโดยใช้เซ็นเซอร์ มีหน่วยเป็น กิโลกรัม

3.4.2 การสอบเทียบเซ็นเซอร์ตรวจวัดรอบการหมุน

การทดลองมีการใช้เซ็นเซอร์ตรวจวัดรอบการหมุน (Encoder) เพื่อนำสัญญาณที่ได้จากการตรวจวัดไปใช้เพื่อคำนวณ ระยะทาง ความเร็ว และ ความเร่ง ของการเคลื่อนที่ของด้ามจับในการทดลอง โดยก่อนการใช้งานเซ็นเซอร์จำเป็นต้องทำการสอบเทียบ (Calibration) เซ็นเซอร์เพื่อให้สามารถตรวจวัดรอบการหมุนได้อย่างถูกต้องในสภาพแวดล้อมที่เกิดการใช้งานจริง ซึ่งในการทดลองนี้มีการทดลองสอบเทียบเซ็นเซอร์โดยกำหนดให้ด้ามจับเคลื่อนที่จากจุดเริ่มต้นไปยังจุดที่กำหนดซึ่งห่างจากจุดเริ่มต้นที่ระยะ 10 20 และ 30 เซนติเมตร ซึ่งแผนผังแสดงขั้นตอนการทดลองสอบเทียบเซ็นเซอร์ตรวจวัดรอบการหมุนแสดงดังรูปที่ 3-22 จากนั้นตรวจสอบความถูกต้องของเซ็นเซอร์ตรวจวัดรอบการหมุนโดยพิจารณาเปรียบเทียบระยะทางที่เคลื่อนที่จริงกับระยะทางจากการตรวจวัดโดยใช้เซ็นเซอร์ตรวจวัดรอบการหมุน ผลการเปรียบเทียบแสดงดังตารางที่ 3-2 และแสดงในรูปแบบกราฟเส้นดังรูปที่ 3-23 โดยที่กราฟเส้นสีน้ำเงินและสีส้มคือระยะทางที่ด้ามจับเคลื่อนที่จริงและระยะทางจากการตรวจวัดตามลำดับ

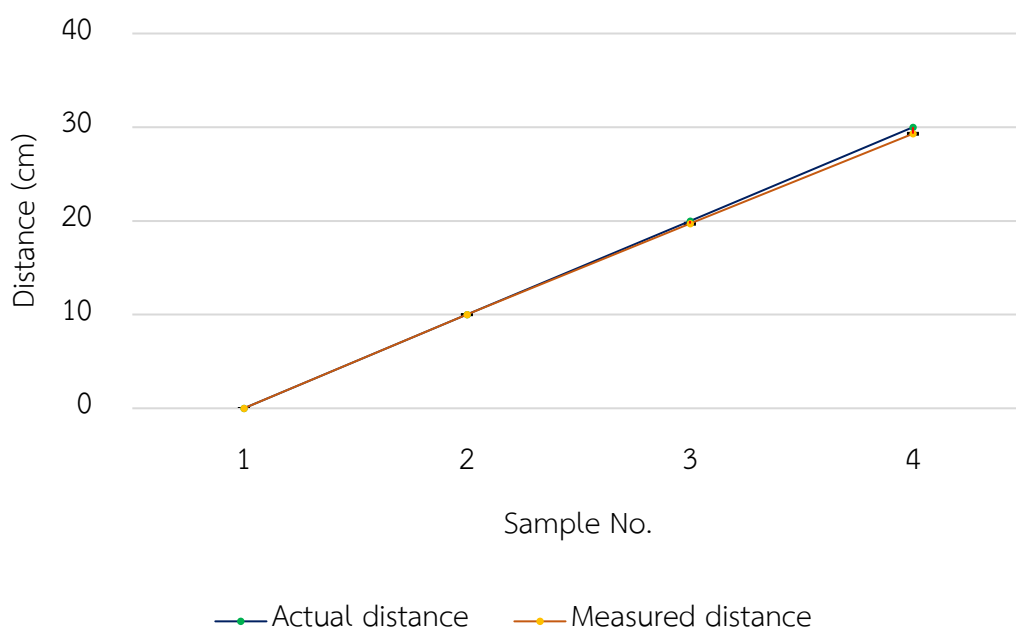


รูปที่ 3-22 แผนผังขั้นตอนการสอบเทียบเซ็นเซอร์ตรวจวัดรอบการหมุน

ตารางที่ 3-2 การเปรียบเทียบระหว่างระยะทางที่ด้ามจับเคลื่อนที่จริงกับระยะทางจากการตรวจวัด

Sample No.	Actual distance (cm)	Measured distance (cm)	SD
1	0	0.000	0.00
2	10	10.050	0.06
3	20	19.775	0.10
4	30	29.375	0.10

Comparison between actual distance and measured distance



รูปที่ 3-23 การเปรียบเทียบระยะทางที่ได้จากการตรวจวัดและระยะทางที่ด้ามจับเคลื่อนที่จริง

จากความสัมพันธ์ระหว่างระยะทางที่ด้ามจับเคลื่อนที่จริงกับระยะทางจากการตรวจวัดโดยใช้เซ็นเซอร์ตรวจวัดรอบการหมุน ดังแสดงในตารางที่ 3-2 จึงสามารถแสดงความสัมพันธ์ระหว่างระยะทางที่ด้ามจับเคลื่อนที่จริงกับระยะทางจากการตรวจวัดในรูปแบบสมการความสัมพันธ์ได้ดังสมการที่ 3.2

$$AD = 1.025MD - 0.111 \quad (3.2)$$

โดยที่ AD คือ ระยะทางที่ด้ามจับเคลื่อนที่จริง มีหน่วยเป็น เซนติเมตร

MD คือ ระยะทางจากการตรวจวัดโดยใช้เซ็นเซอร์ มีหน่วยเป็น เซนติเมตร

3.5 การออกแบบชุดโปรแกรมต่อประสานกับผู้ใช้

ระบบในการเคลื่อนที่ 1 มิติมีฟังก์ชันสำหรับการบันทึกค่าสัญญาณที่เกี่ยวข้องไปยังไฟล์ฐานข้อมูลและการกำหนดขนาดพารามิเตอร์ที่เกี่ยวข้อง ดังนั้นเพื่อความสะดวกในการใช้งานจึงมีการออกแบบส่วนต่อประสานกับผู้ใช้โดยใช้ภาพ (Graphical user interface : GUI) ซึ่งแสดงดังรูปที่ 3-24 โดยมีรายละเอียด ดังนี้



รูปที่ 3-24 ชุดโปรแกรมต่อประสานกับผู้ใช้โดยใช้ภาพ

โดยที่ (1) คือ พื้นที่สำหรับแสดงกราฟสัญญาณแรง

(2) คือ พื้นที่สำหรับแสดงกราฟสัญญาณแรงที่ได้จากการตรวจวัดเปรียบเทียบกับสัญญาณแรงที่ได้จากการประมาณโดยใช้แบบจำลองทางคณิตศาสตร์

(3) คือ พื้นที่สำหรับแสดงกราฟความคลาดเคลื่อนระหว่างสัญญาณแรงที่ได้จากการตรวจวัดเปรียบเทียบกับสัญญาณแรงที่ได้จากการประมาณโดยใช้แบบจำลองทางคณิตศาสตร์

- (4) คือ กล่องข้อความสำหรับป้อนชื่อไฟล์สำหรับเก็บข้อมูลที่เกี่ยวข้องในการทดลอง
- (5) คือ กล่องข้อความสำหรับป้อนขนาดของตัวอย่างที่ใช้สำหรับการคำนวณลักษณะเด่น
- (6) คือ กล่องข้อความสำหรับป้อนจำนวนการซ้อนทับของข้อมูลในการแบ่งสัดส่วนข้อมูลที่ซ้อนทับกัน
- (7) คือ ปุ่ม Start Record คลิกเพื่อเริ่มบันทึกสัญญาณที่เกี่ยวข้องในการทดลอง
- (8) คือ ปุ่ม Stop Record คลิกเพื่อจบการบันทึกสัญญาณที่เกี่ยวข้องในการทดลอง
- (9) คือ ข้อความแสดงสถานะการบันทึกสัญญาณที่เกี่ยวข้องในการทดลอง
- (10) คือ กล่องข้อความสำหรับป้อนชื่อไฟล์ฐานข้อมูลสำหรับบันทึกหรือเรียกใช้ข้อมูลเพื่อประมาณค่าความต้านทานการเคลื่อนที่ของด้ามจับที่ ณ ขณะใช้งาน
- (11) คือ กล่องข้อความสำหรับป้อนค่าความต้านทานการเคลื่อนที่ของด้ามจับ (หากเรียกใช้ฟังก์ชันการประมาณค่าความต้านทานการเคลื่อนที่ของด้ามจับ ค่าจะแสดงในกล่องข้อความอัตโนมัติ)
- (12) คือ ปุ่ม Make database file คลิกเพื่อเริ่มบันทึกสัญญาณที่เกี่ยวข้องสำหรับใช้เพื่อการประมาณค่าความต้านทานการเคลื่อนที่ของด้ามจับ
- (13) คือ ปุ่ม Classify K คลิกเพื่อเรียกใช้ฟังก์ชันการประมาณค่าความต้านทานการเคลื่อนที่ของด้ามจับ
- (14) คือ ปุ่ม Exit คลิกเพื่อออกจากชุดโปรแกรมต่อประสาน
- (15) คือ กล่องข้อความสำหรับป้อนชื่อไฟล์สำหรับสร้างไฟล์ฐานข้อมูลเพื่อนำไปใช้ในการประมาณแรง
- (16) คือ กล่องข้อความสำหรับป้อนชื่อไฟล์สำหรับเรียกใช้ข้อมูลที่เกี่ยวข้องในการทดลองเพื่อบันทึกไปยังไฟล์ฐานข้อมูล

(17) คือ ปุ่ม Train and Test of dataset in training file คลิกเพื่อเริ่มฝึกสอนและทดสอบแบบจำลองทางคณิตศาสตร์โดยเรียกใช้ข้อมูลจากไฟล์ข้อมูลซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (16)

(18) คือ ปุ่ม Train and Test from dataset in database file คลิกเพื่อเริ่มฝึกสอนและทดสอบแบบจำลองทางคณิตศาสตร์โดยเรียกใช้ข้อมูลจากไฟล์ฐานข้อมูลซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (15)

(19) คือ ปุ่ม Take dataset of training file to database file คลิกเพื่อนำข้อมูลจากไฟล์ข้อมูลซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (16) ผสมเข้ากับไฟล์ฐานข้อมูลซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (15)

(20) คือ ปุ่ม Train and Test from dataset in training file and database file คลิกเพื่อเริ่มฝึกสอนและทดสอบแบบจำลองทางคณิตศาสตร์โดยเรียกใช้ข้อมูลจากไฟล์ข้อมูลซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (16) และไฟล์ฐานข้อมูลซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (15)

(21) คือ ปุ่ม Create new database file from dataset in training file คลิกเพื่อนำข้อมูลจากไฟล์ข้อมูลซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (16) เพื่อสร้างไฟล์ฐานข้อมูลใหม่ซึ่งชื่อไฟล์ระบุไว้ในกล่องข้อความที่ (22)

(22) คือ กล่องข้อความสำหรับป้อนชื่อไฟล์ฐานข้อมูลใหม่


(23) คือ กล่องข้อความสำหรับป้อนชื่อไฟล์ผลลัพธ์ในการประมาณแรงแบบตามเวลาจริง (Real-time) ซึ่งเก็บข้อมูลแรงที่ได้จากการตรวจวัดเปรียบเทียบกับสัญญาณแรงที่ได้จากการประมาณโดยใช้แบบจำลองทางคณิตศาสตร์และค่าความคลาดเคลื่อน

(24) คือ ปุ่ม Start real-time test คลิกเพื่อเริ่มทดสอบแบบจำลองทางคณิตศาสตร์ตามเวลาจริง

(25) คือ ปุ่ม Stop real-time test คลิกเพื่อจบการทดสอบแบบจำลองทางคณิตศาสตร์ตามเวลาจริง

3.6 การประมวลผลข้อมูล

ข้อมูลที่ได้รับจากระบบสำหรับการเคลื่อนที่ 1 มิติ จะใช้เพื่อพัฒนาอัลกอริทึมในการประมาณแรงกล้ามเนื้อ แต่อย่างไรก็ตามเนื่องจากข้อมูลที่ได้อ่อนข้านี้มีความซับซ้อนและเปลี่ยนแปลงต่อเวลาอย่างรวดเร็ว จึงอาจเกิดความผิดพลาดของข้อมูลขึ้นได้ ดังนั้นการเตรียมข้อมูล (Data preprocessing) จะช่วยลดความผิดพลาดของข้อมูลดังกล่าว ก่อนนำข้อมูลไปใช้เพื่อพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับประมาณแรงกล้ามเนื้อ โดยภาพรวมของขั้นตอนการประมวลผลข้อมูลแสดงดังรูปที่ 3-25



รูปที่ 3-25 ขั้นตอนการประมวลผลข้อมูล

ชุดข้อมูล (Data set) คือ ข้อมูลที่ได้รับจากระบบสำหรับการเคลื่อนที่ 1 มิติ ซึ่งสามารถเก็บข้อมูลได้ด้วยความเร็ว 100 ชุดข้อมูลต่อวินาที โดยชุดข้อมูล 1 ชุดประกอบด้วย สัญญาณไฟฟ้ากล้ามเนื้อ 8 ค่าจากการตรวจวัดด้วยเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Myo armband) ระยะทางและความเร็วของการเคลื่อนที่ด้ามจับจากการตรวจวัดด้วยเซ็นเซอร์ตรวจวัดรอบการหมุน (Encoder) แรงบีบนิ้วมือ 4 นิ้ว จากการตรวจวัดด้วยเซ็นเซอร์ตรวจวัดแรงบีบ (Force sensor resistor) แรงจากการตรวจวัดด้วยเซ็นเซอร์ตรวจวัดแรง (Loadcell) และค่าความต้านทานการเคลื่อนที่ของด้ามจับ (Frictional force)

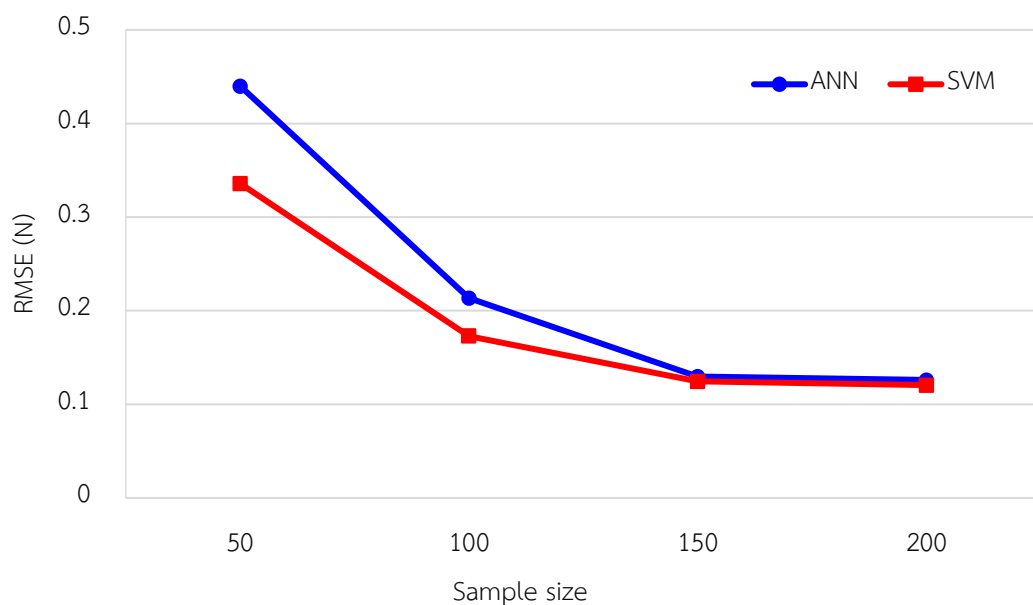
การแบ่งส่วนข้อมูล (Segmentation) คือ การกำหนดลำดับและจำนวนชุดข้อมูลสำหรับการคัดแยกลักษณะเด่น (Feature extraction) โดยจำนวนชุดข้อมูล (Sample size) ที่เหมาะสมจะทำให้สามารถพัฒนาอัลกอริทึมในการทำนายแรงได้อย่างมีประสิทธิภาพ ดังนั้นในงานวิจัยนี้จึงมีการทดลองเบื้องต้น (Pilot study) เพื่อตรวจสอบจำนวนชุดข้อมูล (Sample size) ที่เหมาะสมด้วยวิธีการทดลองผิดพลาดถูก (Trial and error experiment) ซึ่งพิจารณาจากประสิทธิภาพของอัลกอริทึมที่พัฒนาโดยประเมินจากค่าความผิดพลาดเฉลี่ยกำลังสอง (Root mean square error : RMSE) ซึ่งบอกถึงความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย ที่จำนวนชุดข้อมูล (Sample size) แตกต่างกันได้แก่ 50 100 150 และ 200 ผลการทดลองแสดงดังตารางที่ 3-3 และ

แสดงในรูปแบบกราฟเส้นดังรูปที่ 3-26 โดยที่กราฟเส้นสีน้ำเงินและสีแดงบ่งบอกถึงค่าความผิดพลาดเฉลี่ยกำลังสอง (Root mean square error : RMSE) ของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Feedforward back-propagation neural network : BPNN) และวิธีซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) ซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) คือ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF)

ตารางที่ 3-3 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของแบบจำลองทางคณิตศาสตร์ที่ขนาดตัวอย่าง ได้แก่ 50 100 150 และ 200

Algorithms	Sample size = 50		Sample size = 100		Sample size = 150		Sample size = 200	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
RMSE_ANN (N)	0.196	0.440	0.088	0.213	0.064	0.130	0.047	0.126
RMSE_SVM (N)	0.202	0.336	0.092	0.173	0.063	0.125	0.048	0.121

RMSE of both algorithms at various sample sizes



รูปที่ 3-26 กราฟเส้นแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของแบบจำลองทางคณิตศาสตร์ที่ขนาดตัวอย่าง ได้แก่ 50 100 150 และ 200

จากผลการทดลองดังแสดงในรูปที่ 3-26 หากพิจารณาถึงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของชุดข้อมูลที่ใช้ในการฝึกสอน (In sample) ซึ่งบ่งบอกถึงความแม่นยำในการทำนายข้อมูลเอาต์พุตโดยใช้ชุดข้อมูลฝึกสอนจะเห็นว่าแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมและวิธีซัพพอร์ตเวกเตอร์แมชชีนให้ผลการทำนายที่มีความแม่นยำใกล้เคียงกัน อย่างไรก็ตามหากพิจารณาถึงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของชุดข้อมูลที่ใช้ในการทดสอบ (Out sample) ซึ่งบ่งบอกถึงความแม่นยำในการทำนายข้อมูลเอาต์พุตโดยใช้ชุดข้อมูลทดสอบจะเห็นว่าแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมมีความแม่นยำในการทำนายแรงน้อยกว่าแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนที่จำนวนชุดข้อมูล (Sample size) 50 100 ขณะที่จำนวนชุดข้อมูล (Sample size) 150 200 แบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีการทั้งสองมีความแม่นยำในการทำนายแรงใกล้เคียงกัน ดังนั้นจึงสรุปได้ว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีการทั้งสองมีแนวโน้มแม่นยำมากขึ้นเมื่อใช้จำนวนชุดข้อมูล (Sample size) เพิ่มขึ้นจนกระทั่งถึงค่าๆ หนึ่งที่จำนวนชุดข้อมูล 150 และ 200 ซึ่งให้ความแม่นยำใกล้เคียงกัน แต่อย่างไรก็ตามหากใช้จำนวนชุดข้อมูล (Sample size) มากขึ้นเวลาในการประมวลผลก็จะมากขึ้นด้วย ดังแสดงในตารางที่ 3-4 ส่งผลให้เกิดความล่าช้าในการประมวลผลแรงกล้ามเนื้อ ดังนั้นในงานวิจัยนี้จะเลือกใช้จำนวนชุดข้อมูล (Sample size) คือ 150 ชุดข้อมูลต่อการคำนวณ 1 ชุดคุณลักษณะ อีกทั้งระบบสำหรับการเคลื่อนที่ 1 มิติ สามารถเก็บข้อมูลได้ที่ความเร็ว 100 ชุดข้อมูลต่อวินาที ซึ่งอาจทำให้ระบบประมวลผลแรงกล้ามเนื้อเกิดความล่าช้าเนื่องจากความเร็วในการรับข้อมูลที่น้อยกว่าจำนวนชุดข้อมูล (Sample size) สำหรับคำนวณ 1 ชุดคุณลักษณะ ดังนั้นในงานวิจัยนี้จะใช้วิธีการแบ่งส่วนแบบเหลื่อมข้อมูล (Overlapping segmentation) โดยเลื่อนชุดข้อมูลเพียงทีละ 1 ชุดข้อมูลต่อการคำนวณ 1 ชุดคุณลักษณะ เพื่อเพิ่มความเร็วในการประมวลผลทำให้ระบบประมวลผลแรงกล้ามเนื้อสามารถใช้งานได้ตามเวลาจริง (Real-time)

ตารางที่ 3-4 เวลาในการคำนวณ 1 คุณลักษณะที่ จำนวนชุดข้อมูล 50 100 150 และ 200

Sample size	Process time (second)
50	0.5
100	1.0
150	1.5
200	2.0

การคัดแยกคุณลักษณะเด่น (Feature extraction) คือ กระบวนการคัดแยกคุณลักษณะเฉพาะตัวของข้อมูล (Feature) ซึ่งจะต้องเป็นปริมาณที่สามารถวัดค่าได้และมีค่าเป็นตัวเลข เนื่องจากในงานวิจัยนี้มีสัญญาณไฟฟ้ากล้ามเนื้อเป็นส่วนหนึ่งของชุดข้อมูล (Dataset) ซึ่งมีความซับซ้อนและมีลักษณะเฉพาะตัวหลายชนิด เช่น ขนาดของแรงดันสูงสุด ขนาดของแรงดันเฉลี่ยในเวลาหนึ่งหน่วยเวลา ขนาดขององค์ประกอบสัญญาณที่ได้จากการแปลงฟูเรียร์อย่างรวดเร็ว เป็นต้น ดังนั้นเพื่อลดความซับซ้อนและจำแนกคุณลักษณะเฉพาะตัวของสัญญาณไฟฟ้ากล้ามเนื้อจึงมีการประยุกต์ใช้วิธีการคัดแยกคุณลักษณะเด่น (Feature extraction) ผลที่ได้คือคุณลักษณะเฉพาะตัวของข้อมูล ซึ่งหากนำมาจัดวางในรูปแบบเวกเตอร์ก็จะได้เวกเตอร์ของคุณลักษณะเฉพาะ (Feature vector) ซึ่งแสดงค่าคุณลักษณะเฉพาะทั้งหมดที่วัดจากข้อมูลนั้นๆ ที่อยู่ในรูปของเวกเตอร์ การคำนวณทางคณิตศาสตร์เพื่อหาคุณลักษณะเฉพาะตัวต่างๆ มีหลายรูปแบบ โดยสามารถแบ่งออกได้เป็น 3 กลุ่ม ได้แก่ การวิเคราะห์บนแกนเวลา (Time domain) การวิเคราะห์บนแกนความถี่ (Frequency domain) และการวิเคราะห์บนทั้งแกนเวลาและความถี่ (Time-Frequency representation) ซึ่งมีงานวิจัยเพื่อศึกษาเปรียบเทียบการประเมินคุณสมบัติเฉพาะตัวของสัญญาณไฟฟ้ากล้ามเนื้อด้วยวิธีการคัดแยกคุณลักษณะเด่นต่างๆ โดยพิจารณาโดยใช้เกณฑ์ 3 ข้อ ดังนี้

a) พิจารณาเชิงความแม่นยำ

จากงานวิจัยของ A. Phinyomark และคณะ [39–41] ได้เลือกวิธีการทางสถิติอย่างง่าย 2 ตัวมาใช้ในการประเมิน คือ Euclidean Distance และ Standard Deviation โดยนำมาประเมินในรูปของอัตราส่วนระหว่างตัวประเมินทั้งสอง ซึ่งนำมาใช้ในการประเมินวิธีการคัดแยกคุณลักษณะเด่นของสัญญาณบนแกนเวลาและบนแกนความถี่จำนวน 15 ชนิด ซึ่งประกอบด้วย Integral EMG (IEMG), Mean Absolute Value (MAV), Modified Mean Absolute Value 1 (MAV 1), Modified Mean Absolute Value 2 (MAV2), Mean Absolute Value Slope (MAVS), Simple Square Integral (SSI), Variance (VAR), Root Mean square (RMS), Wavelet length (WL), Zero crossing (ZC), Slope sign change (SSC), Willison amplitude (WAMP), Auto-regressive (AR) coefficients, Median Frequency (MDF), Mean Frequency (MNF) เนื่องจากเวลาในการคำนวณที่สูงมากของวิธีการวัดคุณลักษณะเด่นของสัญญาณแบบทั้งแกนเวลาและความถี่และการที่ต้องใช้สมการในการหาค่าตัวแทนของคุณลักษณะสัญญาณบนแกนเวลาและความถี่ทำให้วิธีการคัดแยกคุณลักษณะเด่นของสัญญาณ

ด้วยวิธีในกลุ่มนี้ไม่ได้ถูกพิจารณาในงานวิจัยนี้ ผลการศึกษาจัดอันดับความแม่นยำของวิธีการตัดแยก ลักษณะเด่นของสัญญาณบนแกนเวลาและบนแกนความถี่ด้วยวิธีข้างต้น แสดงดังตารางที่ 3-5

ตารางที่ 3-5 อันดับความแม่นยำของวิธีการตัดแยกลักษณะเด่นของสัญญาณบนแกนเวลาและบนแกนความถี่

วิธีการวัดลักษณะเด่นของสัญญาณ	อันดับความแม่นยำ
Wavelet length (WL)	1
Root Mean square (RMS)	2
Willison amplitude (WAMP)	3

b) พิจารณาเชิงความคงทนต่อสัญญาณรบกวน

จากงานวิจัยของ A. Phinyomark และคณะ [39,42] ได้ปรับปรุงวิธีการวัดลักษณะเด่นของสัญญาณเชิงความถี่สองวิธี คือ Modified Mean Frequency (MMNF) และ Modified Median Frequency (MMDF) และเปรียบเทียบกับ 15 วิธีข้างต้นรวมถึงเพิ่มมาอีก 1 วิธี คือ Histogram of EMG (HIST) พบว่าวิธีที่ปรับปรุงขึ้นมาใหม่ให้ผลการทนต่อสัญญาณรบกวนได้ดีกว่าวิธีการเดิมทั้ง 16 วิธี สำหรับวิธีการเดิมพบว่า วิธีการ Willison Amplitude และวิธีการ HIST ให้ผลทนต่อสัญญาณรบกวนในระดับที่น่าพอใจ

c) พิจารณาเชิงทรัพยากรและเวลาในการคำนวณ

จากงานวิจัยของ A. Phinyomark และคณะ [43, 44] ได้ทดลองหาค่าเวลาในการคำนวณของวิธีการตัดแยกลักษณะเด่นของสัญญาณแต่ละวิธี โดยกำหนดคำนวณสัญญาณไฟฟ้ากล้ามเนื้อจากหนึ่งช่องสัญญาณ ซึ่งมีขนาดของจำนวนข้อมูล 256 จุดข้อมูล ผลการทดลองพบว่าวิธีการตัดแยกลักษณะเด่นของสัญญาณแบบ Integrated EMG ใช้เวลาในการคำนวณน้อยที่สุด โดยเวลาในการคำนวณของวิธีการตัดแยกลักษณะเด่นของสัญญาณแสดงดังตารางที่ 3-6

ตารางที่ 3-6 ตารางเวลาในการคำนวณของวิธีการคัดแยกลักษณะเด่นของสัญญาณบนแกนเวลาและบนแกนความถี่

วิธีการคัดแยกลักษณะเด่น	เวลาในการคำนวณ (วินาที)
1.Integrated EMG (IEMG)	8.1061×10^{-5}
2.Mean Absolute Value (MAV)	8.2789×10^{-5}
3.Modified Mean Absolute Value 1 (MAV1)	8.3020×10^{-5}
4.Modified Mean Absolute Value 2 (MAV2)	8.4786×10^{-5}
5.Mean Absolute Value Slope (MAVS)	10.0950×10^{-5}
6.Simple Square Integral (SSI)	8.1829×10^{-5}
7.Variance (VAR)	8.2405×10^{-5}
8.Root Mean Square (RMS)	9.1045×10^{-5}
9.Waveform length (WL)	8.2213×10^{-5}
10.Zero crossing (ZC)	9.8495×10^{-5}
11.Slope Sign Change (SSC)	9.3196×10^{-5}
12.Willison amplitude (WAMP)	9.3157×10^{-5}
13.Auto-regressive (AR) coefficients	57.419×10^{-5}
14.Median Frequency (MDF)	45.196×10^{-5}
15.Mean Frequency (MNF)	20.7430×10^{-5}
16.Histogram of EMG (HIST)	31.6030×10^{-5}

ในการประเมินหาวิธีการคัดแยกลักษณะเด่นของสัญญาณโดยใช้เกณฑ์ 3 ข้อจะมีการหาวิธีการคัดแยกลักษณะเด่นของสัญญาณทั้งจากการประเมินวิธีการคัดแยกลักษณะเด่นของสัญญาณที่มีการใช้งานอยู่ในปัจจุบัน ด้วยวิธีทางสถิติ และวิธีใช้ตัวจำแนก รวมถึงการปรับปรุงวิธีการคัดแยกลักษณะเด่นของสัญญาณที่มีอยู่เดิมให้มีคุณสมบัติบางประการที่ดีขึ้น อย่างไรก็ตามยังมีข้อจำกัดที่ว่าไม่มีวิธีการคัดแยกลักษณะเด่นของสัญญาณชนิดใดที่จะได้ผลดีที่สุดในทุก 3 ประเด็น ดังนั้นจึงจำเป็นต้องเลือกนำไปประยุกต์ใช้ให้เหมาะสมกับงาน ในงานวิจัยนี้จะใช้วิธีการคัดแยกลักษณะเด่นของสัญญาณไฟฟ้ากล้ามเนื้อ คือ ค่ารากของค่าเฉลี่ยของกำลังสอง (Root mean square) และค่าเฉลี่ยของค่าสัมบูรณ์ (Mean absolute value) ซึ่งพิจารณาเนื่องมาจากวิธีการคัดแยกลักษณะเด่น

ของสัญญาณทั้งสองวิธีมีความซับซ้อนในการคำนวณและใช้เวลาในการคำนวณน้อย และถูกนำมาใช้
อย่างแพร่หลายในการประยุกต์ใช้กับสัญญาณไฟฟ้ากล้ามเนื้อ โดยสูตรในการคำนวณโดยใช้ วิธีการตัด
แยกลักษณะเด่นของสัญญาณไฟฟ้ากล้ามเนื้อ คือ Root mean square (RMS) และ Mean
absolute value (MAV) แสดงดังสมการที่ 3.3 และ 3.4 ตามลำดับและใช้วิธีการตัดแยกลักษณะเด่น
ของสัญญาณอื่นๆ ที่เกี่ยวข้อง คือ ค่าเฉลี่ย (Average) ดังแสดงในรูปที่ 3-27

- d) Root Mean Square (RMS) เป็นการหาค่ารากของค่าเฉลี่ยกำลังสองของสัญญาณไฟฟ้า
กล้ามเนื้อได้ผลลัพธ์ 1 feature vector

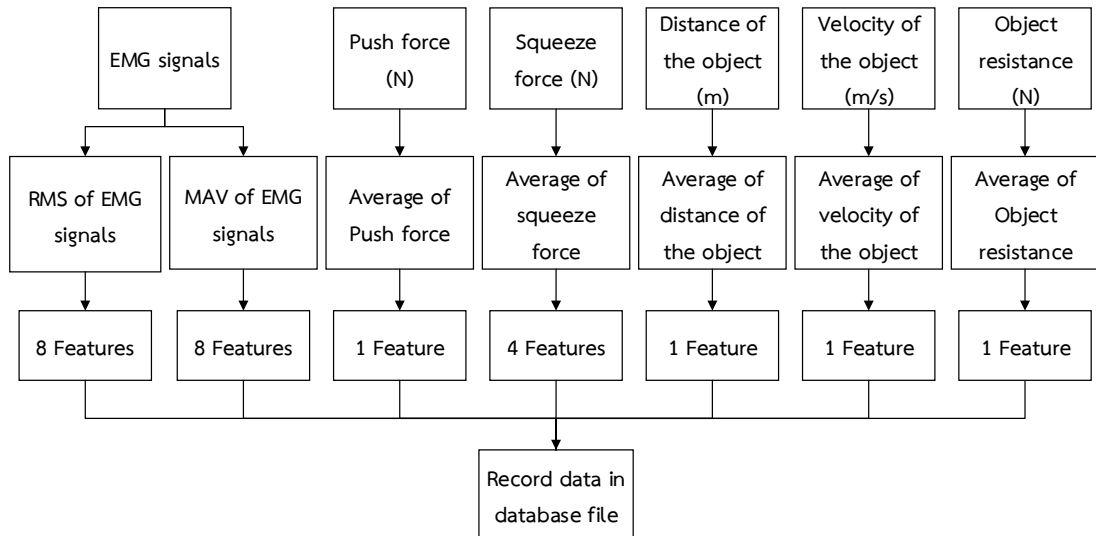
$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (3.3)$$

โดยที่ RMS คือ ค่ารากของค่าเฉลี่ยกำลังสองของสัญญาณไฟฟ้ากล้ามเนื้อ
 x_n คือ ค่าสัญญาณไฟฟ้ากล้ามเนื้อที่ข้อมูลลำดับที่ n
 n คือ ลำดับของข้อมูล
 N คือ ขนาดของข้อมูล

- e) Mean Absolute Value (MAV) เป็นการหาค่าเฉลี่ยของค่าสัมบูรณ์ของสัญญาณไฟฟ้า
กล้ามเนื้อหรืออาจเรียกเป็นอย่างอื่นเช่น Integral of absolute value (IAV) ได้ผลลัพธ์ 1
feature vector

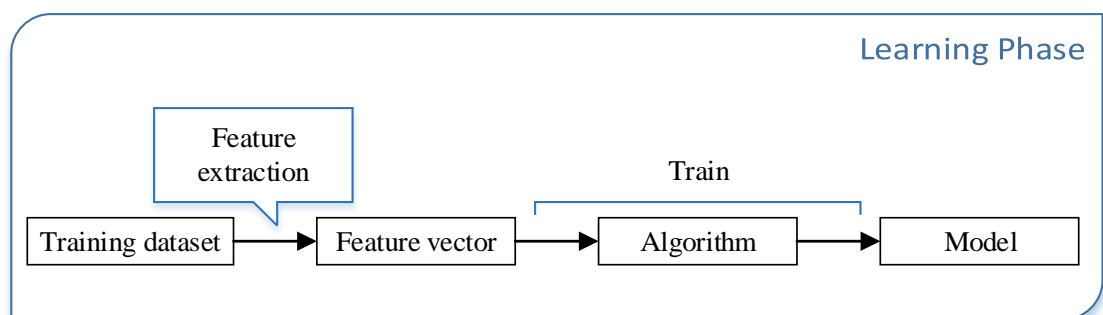
$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (3.4)$$

โดยที่ MAV คือ ค่าเฉลี่ยของค่าสัมบูรณ์ของสัญญาณไฟฟ้ากล้ามเนื้อ
 x_n คือ ค่าสัญญาณไฟฟ้ากล้ามเนื้อที่ข้อมูลลำดับที่ n
 n คือ ลำดับของข้อมูล
 N คือ ขนาดของข้อมูล



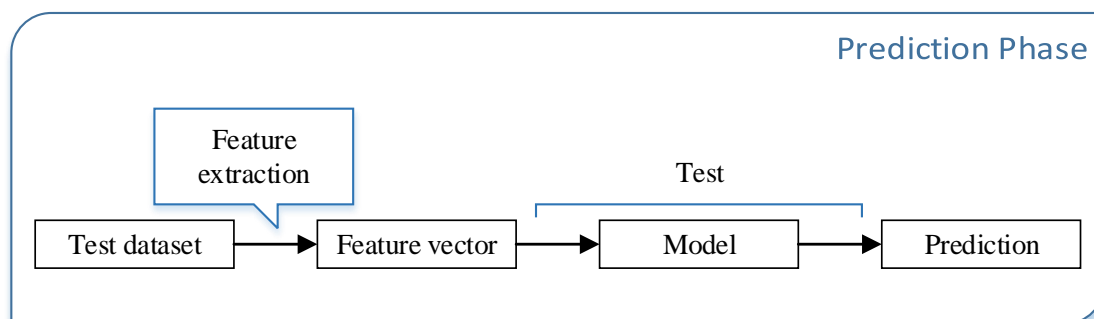
รูปที่ 3-27 วิธีการคัดแยกลักษณะเฉพาะของสัญญาณ

การเรียนรู้ของอัลกอริทึม (Learning algorithms) คือ ขั้นตอนการพัฒนาแบบจำลองทางคณิตศาสตร์ด้วยการฝึกสอน (Train) อัลกอริทึม โดยใช้เวกเตอร์ของลักษณะเฉพาะ (Feature vector) ที่ได้จากชุดข้อมูลสำหรับฝึกสอน (Training dataset) ที่ผ่านวิธีการคัดแยกลักษณะเฉพาะ (Feature extraction) โดยในหนึ่งชุดข้อมูลจะแบ่งออกเป็นสองส่วนคือข้อมูลอินพุต (Input data) สำหรับใช้เพื่อเป็นอินพุต (Input) ของอัลกอริทึม และข้อมูลเป้าหมาย (target data) สำหรับใช้เพื่อเป็นเป้าหมาย (Target) ของอัลกอริทึม เมื่ออัลกอริทึมเกิดการเรียนรู้ด้วยชุดข้อมูลรูปแบบเดิมซ้ำๆ อัลกอริทึมจะเกิดการปรับค่าพารามิเตอร์ที่เกี่ยวข้องจนกระทั่งสามารถนำไปใช้เป็นแบบจำลองทางคณิตศาสตร์ (Model) เพื่อทำนาย (Predict) ข้อมูลเอาต์พุต (Output data) จากข้อมูลอินพุต (Input data) ใหม่ๆ ต่อไป โดยขั้นตอนการเรียนรู้ของอัลกอริทึมแสดงดังรูปที่ 3-28



รูปที่ 3-28 ขั้นตอนการเรียนรู้ของอัลกอริทึม

การทำนายของอัลกอริทึม (Estimation) คือ การนำแบบจำลองทางคณิตศาสตร์ (Model) ที่ผ่านการพัฒนาจากขั้นตอนการเรียนรู้ของอัลกอริทึม (Learning algorithms) มาใช้เพื่อทำนายข้อมูลเอาต์พุต (Output data) โดยใช้เวกเตอร์ของลักษณะเฉพาะ (Feature vector) ที่ได้จากชุดข้อมูลสำหรับทดสอบ (Test dataset) ซึ่งประกอบด้วย ข้อมูลอินพุต (Input data) สำหรับใช้เพื่อเป็นอินพุต (Input) ของอัลกอริทึมในการทำนายข้อมูลเอาต์พุต (Output data) และข้อมูลเป้าหมาย (Target data) สำหรับใช้เพื่อประเมินความถูกต้องของข้อมูลเอาต์พุต (Output) โดยขั้นตอนการทำนายของอัลกอริทึมแสดงดังรูปที่ 3-29



รูปที่ 3-29 ขั้นตอนการทำนายของอัลกอริทึม

3.7 การออกแบบอัลกอริทึมด้วยวิธี ANN และ SVM

การประมาณแรงกล้ำเนื้อจากสัญญาณไฟฟ้ากล้ำเนื้อจำเป็นต้องใช้อัลกอริทึมสำหรับพัฒนาแบบจำลองทางคณิตศาสตร์โดยอัลกอริทึมที่ใช้ต้องสามารถตรวจสอบความสัมพันธ์ที่ซับซ้อนในงานวิจัยเชิงชีวกลศาสตร์ได้ ดังนั้นในงานวิจัยนี้จะใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Feedforward back-propagation neural network : BPNN) และวิธีซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) สำหรับพัฒนาแบบจำลองทางคณิตศาสตร์ โดยข้อดีของอัลกอริทึมทั้งสอง คือ มีประสิทธิภาพในการตรวจสอบความสัมพันธ์ของข้อมูลที่ซับซ้อน สามารถใช้ได้กับชุดข้อมูลที่มีความผิดพลาด และมีการนำไปใช้แก้ปัญหาในงานวิจัยเชิงชีวกลศาสตร์อย่างแพร่หลาย อย่างไรก็ตามวิธีซัพพอร์ตเวกเตอร์แมชชีนมีข้อได้เปรียบมากกว่าวิธีโครงข่ายประสาทเทียมในเรื่องของการเกิดปัญหาการจับตาคู่ที่คุณลักษณะที่ใช้การจำแนกพอดีเกินไปกับชุดข้อมูล (Overfitting) ที่น้อยกว่าและทั้งสองวิธียังมีข้อจำกัดในเรื่องของการใช้เวลาในการฝึกสอนนานและพารามิเตอร์ที่เกี่ยวข้องกับอัลกอริทึมมีความซับซ้อนยากต่อการทำความเข้าใจ

วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Feedforward back-propagation neural network : BPNN) เป็นโครงข่ายประสาทเทียมที่ต้องมีการสอน (Supervised Learning) ซึ่งหนึ่งในปัจจัยสำคัญที่ส่งผลต่อประสิทธิภาพในการทำนายของอัลกอริทึมนอกจากข้อมูลในการฝึกสอนที่ดีแล้ว การกำหนดพารามิเตอร์ในการฝึกสอนที่เหมาะสมก็จะสามารถเพิ่มประสิทธิภาพในการทำนายได้เช่นกัน ดังนั้นในงานวิจัยนี้มีการกำหนดค่าพารามิเตอร์ในการฝึกสอนโครงข่ายประสาทเทียมจากการปรับค่าด้วยวิธีการทดลองผิดการทดลองถูก (Trial and error experiment) ด้วยชุดข้อมูลเบื้องต้นโดยใช้ค่าอ้างอิงน้อยที่สุดจากตัวแปรต้น (Independent Variable) สองตัวแปร ได้แก่ ความต้านทานการเคลื่อนที่คงที่ 2 นิวตันและความเร็วการเคลื่อนที่คงที่ 0.1 เมตรต่อวินาที โดยพิจารณาจากค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกความแม่นยำในการทำนายแรงแบบออฟไลน์ ที่จำนวนโหนดของชั้นซ่อนแตกต่างกันในช่วงระหว่าง 15-20 โหนด (จากการทดลองเบื้องต้นพบว่าเมื่อกำหนดจำนวนโหนดของชั้นซ่อนมากกว่า 20 โหนดแบบจำลองทางคณิตศาสตร์มีความแม่นยำในการทำนายแรงแบบออฟไลน์ใกล้เคียงกันมาก) จากการทดลองพบว่าเมื่อกำหนดใช้จำนวนโหนดของชั้นซ่อน 20 โหนด แบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยวิธีโครงข่ายประสาทเทียมให้ผลการทำนายที่แม่นยำมากที่สุดในขั้นตอนการทดสอบแบบจำลองทางคณิตศาสตร์โดยมีความคลาดเคลื่อนในขั้นตอนการฝึกสอนและทดสอบแบบจำลองทางคณิตศาสตร์ 0.038 และ 0.063 นิวตันตามลำดับ ดังแสดงในตารางที่ 3-7

จากนั้นจึงทำการทดลองทำนายแรงแบบออฟไลน์ที่ฟังก์ชันการแปลง (transfer function) แตกต่างกันได้แก่ linear function (Identity), logistic sigmoid function (Logis), hyperbolic tan function (Tanh) และ rectified linear unit function (Relu) เนื่องจากฟังก์ชันการแปลงข้างต้นมีใช้อย่างแพร่หลายสำหรับการประมาณค่า (Regression) จากผลการทดลองพบว่าโครงข่ายประสาทเทียมที่ใช้ฟังก์ชันการแปลงเป็น linear function ให้ผลการทำนายแรงที่แม่นยำมากที่สุดในขั้นตอนการทดสอบแบบจำลองทางคณิตศาสตร์โดยมีความคลาดเคลื่อนในขั้นตอนการฝึกสอนและทดสอบแบบจำลองทางคณิตศาสตร์ 0.038 และ 0.063 ตามลำดับ ดังแสดงในตารางที่ 3-8 ต่อมาจึงทำการทดลองทำนายแรงแบบออฟไลน์ที่อัลกอริทึมการเรียนรู้แตกต่างกัน (solver) ได้แก่ quasi-Newton methods (lbfgs) , stochastic gradient descent (sgd) และ stochastic gradient-based optimizer (adam) function พบว่าโครงข่ายประสาทเทียมที่ใช้อัลกอริทึมการเรียนรู้ เป็น quasi-Newton methods (lbfgs) ให้ผลการทำนายแรงที่แม่นยำมากที่สุดในขั้นตอนการทดสอบแบบจำลองทางคณิตศาสตร์โดยมีความคลาดเคลื่อนในขั้นตอนการฝึกสอนและทดสอบแบบจำลอง

ทางคณิตศาสตร์ 0.038 และ 0.063 นิวตันตามลำดับ ดังแสดงในตารางที่ 3-9 ดังนั้นในงานวิจัยนี้มีการปรับใช้พารามิเตอร์สำหรับฝึกสอนโครงข่ายประสาทเทียมแสดงดังตารางที่ 3-10

ตารางที่ 3-7 เปรียบเทียบความแม่นยำในการทำนายที่จำนวนโหนดแตกต่างกัน

number of nodes	RMSE	
	Train80%	Test20%
15	0.041	0.068
16	0.039	0.069
17	0.041	0.065
18	0.038	0.066
19	0.039	0.065
20	<u>0.038</u>	<u>0.063</u>

ตารางที่ 3-8 เปรียบเทียบความแม่นยำในการทำนายที่ฟังก์ชันการแปลงแตกต่างกัน

Transfer function	RMSE	
	Train80%	Test20%
identity	<u>0.038</u>	<u>0.063</u>
logis	0.039	0.065
tanh	0.035	0.069
relu	0.034	0.07

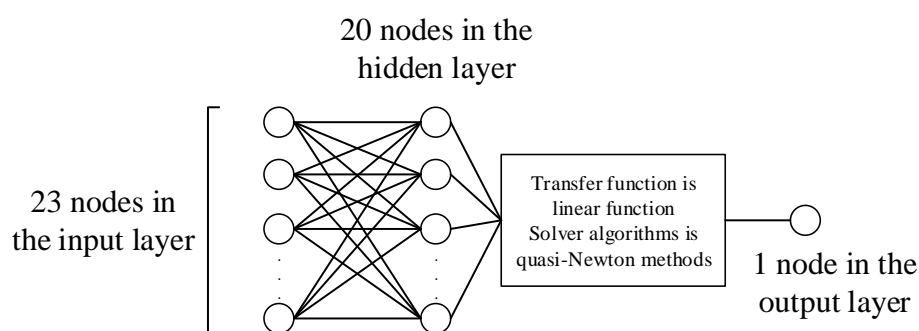
ตารางที่ 3-9 เปรียบเทียบความแม่นยำในการทำนายที่อัลกอริทึมการเรียนรู้แตกต่างกัน

Solver	RMSE	
	Train80%	Test20%
adam	0.07	0.072
lbfgs	<u>0.038</u>	<u>0.063</u>
sgd	0.09	0.071

ตารางที่ 3-10 พารามิเตอร์สำหรับปรับใช้ในการฝึกสอนโครงข่ายประสาทเทียม

Parameters	Amount / Type
Number of inputs	23
Number of epochs	1000
Number of hidden layers	1
Nodes hidden layer	20
Transfer function of hidden layer 1	Linear (Identify)
Transfer function of output layer	Linear (Identify)
Solver	Quasi-Newton methods (lbfgs)

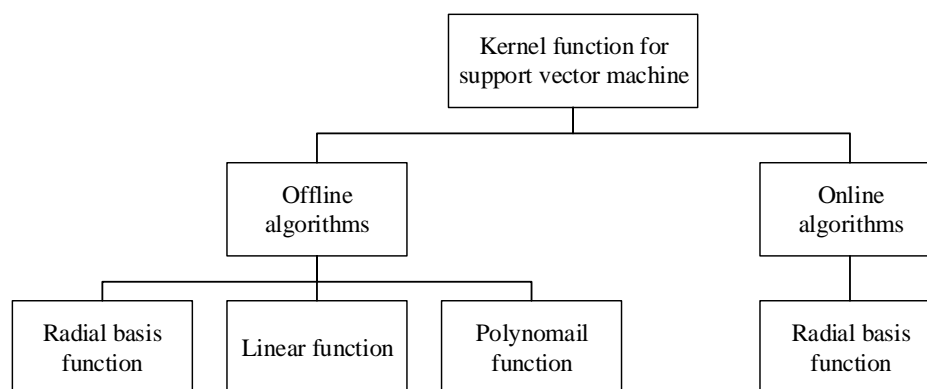
จากการปรับค่าพารามิเตอร์สำหรับใช้ในการฝึกสอนอัลกอริทึมโครงข่ายประสาทเทียมด้วยวิธีการทดลองผิดการทดลองถูก (Trial and error experiment) ทำให้สามารถกำหนดใช้โครงข่ายประสาทเทียมในการทดลอง ซึ่งมีชั้นซ่อน 1 ชั้น โดยมีจำนวนโหนดของชั้นอินพุต ชั้นซ่อน และชั้นเอาต์พุต ได้แก่ 23 20 และ 1 ตามลำดับ โดยใช้ฟังก์ชันการแปลง (transfer function) คือ linear function และใช้อัลกอริทึมการเรียนรู้ คือ Quasi-Newton methods (lbfgs) ดังแสดงรูปที่ 3-30



รูปที่ 3-30 โครงสร้างโครงข่ายประสาทเทียมในการทดลอง

ในการทดลองมีการนำวิธีซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) มาใช้เพื่อพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับประมาณแรงกล้ามเนื้อทั้งแบบออฟไลน์และแบบตามเวลาจริงสำหรับเปรียบเทียบประสิทธิภาพในการทำนายกับแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Feedforward back-propagation neural network

: BPNN) โดยหนึ่งในพารามิเตอร์สำคัญของวิธีซัพพอร์ตเวกเตอร์แมชชีนคือฟังก์ชันเคอร์เนล (Kernel function) ซึ่งเป็นพารามิเตอร์สำหรับกำหนดใช้เพื่อแก้ปัญหาการวิเคราะห์ปัญหาที่ไม่เป็นเชิงเส้น ดังนั้นในงานวิจัยนี้จะกำหนดใช้ฟังก์ชันเคอร์เนล 3 ฟังก์ชันเพื่อฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์ ได้แก่ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ฟังก์ชันเชิงเส้น (Linear function) ฟังก์ชันพหุนาม (Polynomial function) และเนื่องจากในการทดลองประมาณแรงแบบตามเวลาจริงจำเป็นต้องคำนึงถึงเวลาในการประมวลผลข้อมูลดังนั้นเพื่อลดขั้นตอนในการประมวลผลจึงมีการกำหนดใช้ฟังก์ชันเคอร์เนลเพียง 1 ฟังก์ชันเพื่อฝึกสอนและทดสอบอัลกอริทึมแบบตามเวลาจริง คือ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ซึ่งเป็นเคอร์เนลฟังก์ชันที่ใช้กับวิธีซัพพอร์ตเวกเตอร์แมชชีนในการแก้ปัญหาได้อย่างดีและแพร่หลาย ดังแสดงในรูปที่ 3-31



รูปที่ 3-31 โครงสร้างวิธีซัพพอร์ตเวกเตอร์แมชชีนในการทดลอง

ในงานวิจัยมีการปรับค่าพารามิเตอร์อื่นๆ ที่เกี่ยวข้องสำหรับการพัฒนาแบบจำลองทางคณิตศาสตร์ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนด้วยวิธีการทดลองผิดการทดลองถูก (Trial and error experiment) ด้วยชุดข้อมูลเดียวกันซึ่งเก็บข้อมูลที่ความต้านทานการเคลื่อนที่คงที่ 2 นิวตันและความเร็วการเคลื่อนที่คงที่ 0.1 เมตรต่อวินาที โดยพิจารณาจากค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกความแม่นยำในการทำนายแรงแบบออฟไลน์ โดยในการทดลองมีการปรับพารามิเตอร์ C ในแต่ละเคอร์เนลฟังก์ชันแตกต่างกัน ได้แก่ 10 100 500 และ 1000 ซึ่งพารามิเตอร์ข้างต้นบ่งบอกถึงการกำหนดขนาดของขอบเส้นแบ่งแยกกลุ่มข้อมูล พบว่าที่พารามิเตอร์ C มีค่า 500 ให้ผลการทำนายแรงแบบออฟไลน์ที่มีความแม่นยำในขั้นตอนการทดสอบมากที่สุด โดยมีความคลาดเคลื่อนในการทำนายแรงในขั้นตอนการฝึกสอนและทดสอบโดยใช้ฟังก์ชันเคอร์เนลเป็นฟังก์ชันเชิงเส้นที่ 0.035 และ 0.054 นิวตัน เป็นฟังก์ชันพหุนามที่ 0.04 และ 0.059 นิวตัน และเป็นเรเดียลเบซิสฟังก์ชันที่ 0.036 และ 0.059 นิวตันตามลำดับ ดังแสดงใน

ตารางที่ 3-11 และเนื่องจากวิธีซัพพอร์ตเวกเตอร์แมชชีนที่ใช้ฟังก์ชันเคอร์เนลเป็นฟังก์ชันพหุนามมีพารามิเตอร์ degree สำหรับกำหนดใช้ร่วมในการประมวลผล ดังนั้นจึงมีการทดลองปรับพารามิเตอร์ degree แตกต่างกันได้แก่ 2 3 และ 4 พบว่าที่พารามิเตอร์ degree มีค่าเท่ากับ 2 วิธีซัพพอร์ตเวกเตอร์แมชชีนที่ใช้ฟังก์ชันเคอร์เนลเป็นฟังก์ชันพหุนามให้ผลการทำนายแรงแบบออฟไลน์ที่มีความแม่นยำในขั้นตอนการทดสอบมากที่สุด โดยมีความคลาดเคลื่อนในการทำนายแรงในขั้นตอนการฝึกสอนและทดสอบ 0.04 และ 0.059 นวัตกรรมลำดับ ดังแสดงในตารางที่ 3-12 ดังนั้นในงานวิจัยนี้มีการปรับใช้พารามิเตอร์สำหรับฝึกสอนวิธีซัพพอร์ตเวกเตอร์แมชชีนดังแสดงในตารางที่ 3-13

ตารางที่ 3-11 เปรียบเทียบความแม่นยำในการทำนายที่พารามิเตอร์ C แตกต่างกัน

Kernel function	C = 10		C = 100		C = 500		C = 1000	
	Train 80%	Test 20%	Train 80%	Test 20%	Train 80%	Test 20%	Train 80%	Test 20%
Linear	0.039	0.059	0.036	0.057	<u>0.035</u>	<u>0.054</u>	0.034	0.054
Polynomial	0.362	0.214	0.087	0.058	<u>0.040</u>	<u>0.059</u>	0.038	0.061
RBF	0.170	0.100	0.040	0.059	<u>0.036</u>	<u>0.059</u>	0.035	0.057

ตารางที่ 3-12 เปรียบเทียบความแม่นยำในการทำนายที่พารามิเตอร์ Degree แตกต่างกัน

Kernel function	Degree = 2		Degree = 3		Degree = 4	
	Train 80%	Test 20%	Train 80%	Test 20%	Train 80%	Test 20%
Polynomial	<u>0.040</u>	<u>0.059</u>	0.073	0.063	0.260	0.146

ตารางที่ 3-13 พารามิเตอร์สำหรับปรับใช้ในการฝึกสอนวิธีซัพพอร์ตเวกเตอร์แมชชีน

Parameters	Amount / Type
C	500
Degree	2


3.8 ตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ

สัญญาณไฟฟ้ากล้ามเนื้อเป็นภาพสะท้อนของกิจกรรมทางไฟฟ้าของกล้ามเนื้อ โดยเกิดจากสัญญาณคำสั่งจากระบบควบคุมการเคลื่อนไหวของมนุษย์ ดังนั้นสัญญาณไฟฟ้ากล้ามเนื้อสามารถใช้ทำนายแรงที่กระทำโดยกล้ามเนื้อ อย่างไรก็ตามการติดตั้งตำแหน่งของเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อที่เหมาะสมจะทำให้การทำนายแรงมีประสิทธิภาพมากขึ้นเนื่องจากความชัดเจนของขนาดสัญญาณไฟฟ้ากล้ามเนื้อต่อการหดตัวและคลายตัวของกล้ามเนื้อ มีการศึกษาเพื่อตรวจสอบ เช่น งานวิจัยของ Chris Jensen et al. ได้อธิบายถึงความแตกต่างของขนาดสัญญาณเมื่อติดตั้งอิเล็กโทรดในตำแหน่งที่แตกต่างกันบนมัดกล้ามเนื้อ trapezius ขณะยืดแขนและงอแขน [45] ดังนั้นในงานวิจัยนี้จึงได้มีการศึกษานำร่องเพื่อตรวจสอบตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้าที่เหมาะสมโดยพิจารณาเปรียบเทียบเพื่อเลือกตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อโดยคำนึงถึงปัจจัย 3 ข้อที่มีผลกระทบต่อสัญญาณไฟฟ้ากล้ามเนื้อ ดังนี้


- a) ความแตกต่างของสัญญาณไฟฟ้ากล้ามเนื้อระหว่างสัญญาณไฟฟ้ากล้ามเนื้อที่เกิดจากการออกแรงดึงและสัญญาณไฟฟ้ากล้ามเนื้อที่เกิดจากการออกแรงผลักอย่างชัดเจนจะส่งผลให้สามารถทำนายแรงดึง/ผลักได้อย่างแม่นยำมากยิ่งขึ้น
- b) ท่าทางของแขนที่แตกต่างกันมีผลทำให้เกิดความแตกต่างของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งอาจส่งผลให้เกิดความผิดพลาดในการตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อเพื่อทำนายแรงดึง/ผลัก ดังนั้นตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดควรติดตั้งในตำแหน่งที่การเปลี่ยนท่าทางของแขนส่งผลกระทบต่อสัญญาณไฟฟ้ากล้ามเนื้อน้อยที่สุด
- c) แรงบีบนิ้วมือมีผลทำให้เกิดความแตกต่างของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งอาจส่งผลให้เกิดความผิดพลาดในการตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อเพื่อทำนายแรงดึง/ผลัก ดังนั้นตำแหน่งติดตั้งเซ็นเซอร์ตรวจวัดควรติดตั้งในตำแหน่งที่การออกแรงบีบนิ้วมือส่งผลกระทบต่อสัญญาณไฟฟ้ากล้ามเนื้อน้อยที่สุด

จากปัจจัยทั้ง 3 ข้อจึงมีการทดลองเพื่อตรวจสอบโดยพิจารณาติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อที่กล้ามเนื้อ 2 ตำแหน่ง คือ กล้ามเนื้อส่วน Forearm muscle และ Biceps/Triceps muscles เนื่องจากมัดกล้ามเนื้อทั้งสองมีการเปลี่ยนแปลงมากขณะออกแรงดึงหรือออกแรงผลัก โดยตำแหน่งช่องสัญญาณของเซ็นเซอร์และตำแหน่งติดตั้งเซ็นเซอร์แสดงดังรูปที่ 3-32 สำหรับการทดลองมีการกำหนดใช้แรงกระทำต่อด้ามจับในทิศทางดึง/ผลักคงที่ 10 นิวตัน ซึ่งเป็นแรงสูงสุดที่ใช้ในการทดลองหลักในกรณีที่ความเร็วและแรงต้านทานการเคลื่อนที่สูงสุด รวมถึงมีการ

กำหนดใช้ผลรวมของแรงบีบนิ้วมือต่อด้ามจับคงที่สูงสุดที่ยอมรับได้ในการทดลองหลักประมาณ 1 นิวตัน (0.8-1.2 นิวตัน) เนื่องจาก ต้องการลดผลกระทบจากแรงบีบนิ้วมือต่อสัญญาณไฟฟ้ากล้ามเนื้อ ตลอดจนมีการกำหนดจุดเริ่มต้น (Start point) และจุดสิ้นสุด (End point) ซึ่งใช้เพื่อเป็นตำแหน่งในการเคลื่อนที่ของด้ามจับในการทดลอง ดังแสดงในรูปที่ 3-33 โดยจุดสิ้นสุดที่ใช้ในการทดลองขึ้นอยู่กับระยะแขนของผู้ทำการทดลอง



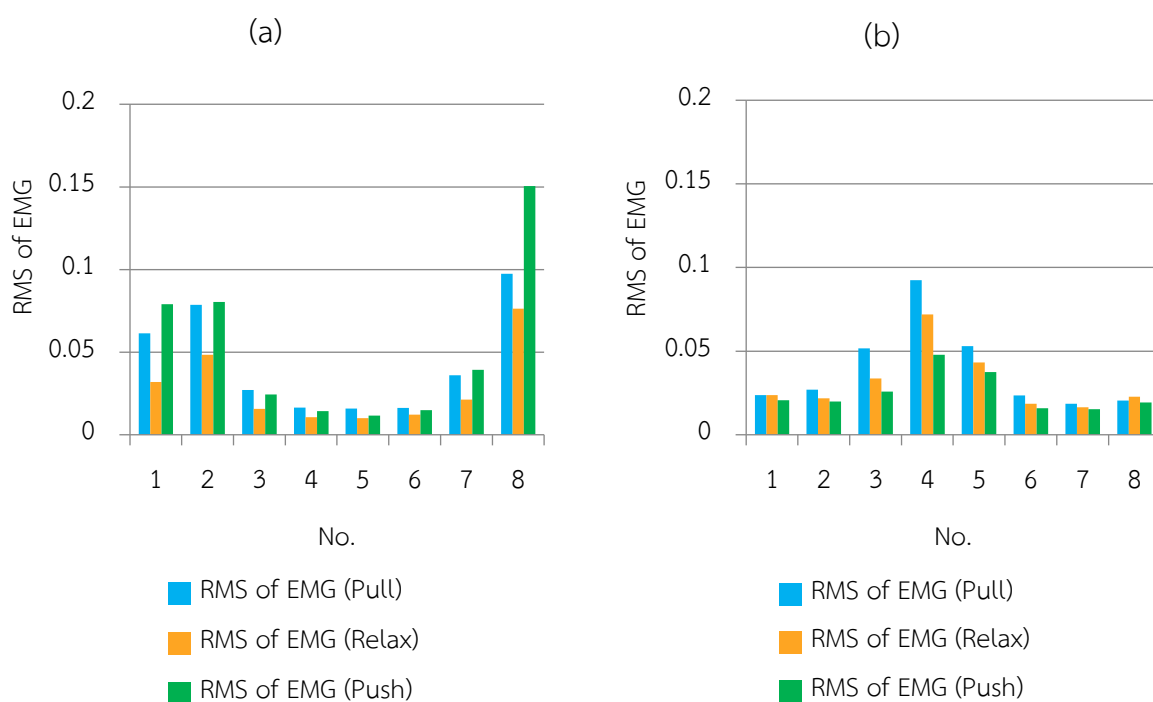
รูปที่ 3-32 ตำแหน่งติดตั้งเซ็นเซอร์ (a) Forearm muscle (b) Biceps/Triceps muscles (c) ตำแหน่งช่องสัญญาณของเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ



รูปที่ 3-33 ตำแหน่งด้ามจับในการทดลอง

3.8.1 ตรวจสอบสัญญาณไฟฟ้ากล้ามเนื้อที่ได้จากการออกแรงในทิศทางที่แตกต่างกัน

โดยมีขั้นตอนการทดลองคือผู้ทดลองออกแรงคงที่ 10 นิวตันกระทำต่อด้ามจับในทิศทางตั้ง ผลักและไม่ออกแรงต่อด้ามจับอยู่หนึ่งที่ตำแหน่งเริ่มต้น (Start point) โดยมีการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อตลอดการทดลองสำหรับใช้เพื่อคำนวณรากของค่าเฉลี่ยกำลังสอง (RMS) ซึ่งบ่งบอกถึงขนาดของสัญญาณไฟฟ้ากล้ามเนื้อ โดยผลการทดลองแสดงด้วยแผนภูมิแท่งดังรูปที่ 3-34 โดยที่แผนภูมิแท่งสีฟ้า สีเขียว และสีส้ม บ่งบอกถึงค่าเฉลี่ยกำลังสอง (RMS) ของสัญญาณไฟฟ้ากล้ามเนื้อจำนวน 8 ช่องสัญญาณขณะออกแรงคงที่ 10 นิวตันกระทำต่อด้ามจับในทิศทางตั้ง ผลักและไม่ออกแรงต่อด้ามจับ ตามลำดับ




รูปที่ 3-34 ขนาดสัญญาณไฟฟ้ากล้ามเนื้อตรวจวัดจากตำแหน่ง (a).Forearm muscle
(b).Biceps/Triceps muscles

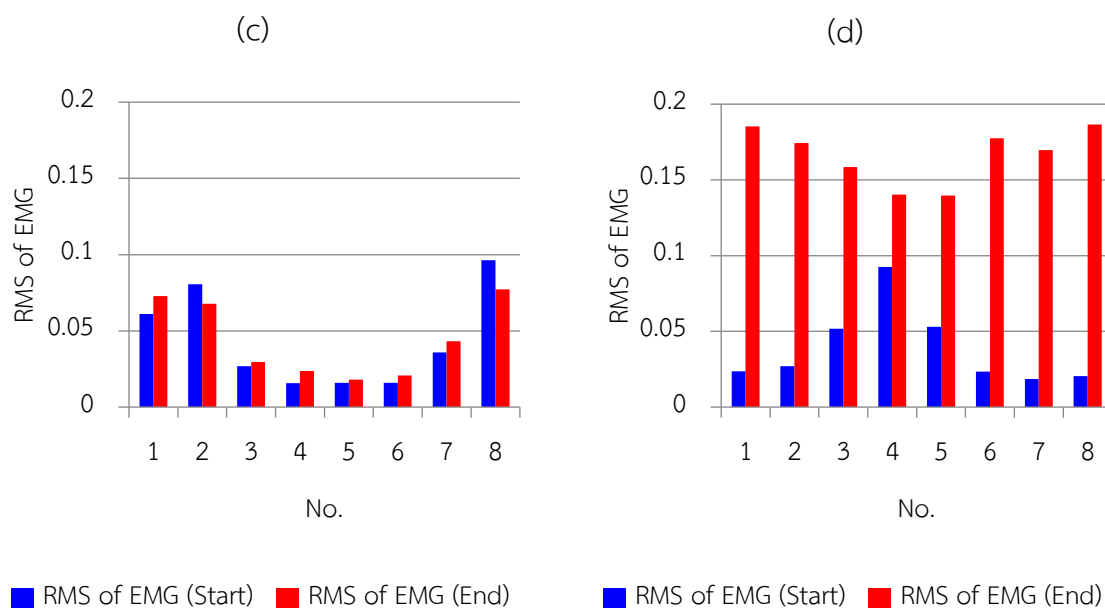
ผลการทดลองแสดงค่ารากของค่าเฉลี่ยกำลังสอง (RMS) ของสัญญาณไฟฟ้ากล้ามเนื้อจาก 8 ช่องสัญญาณที่ตรวจวัดจากกล้ามเนื้อส่วน Forearm muscle และ Biceps/Triceps muscles พบว่าขนาดสัญญาณไฟฟ้ากล้ามเนื้อซึ่งเกิดการตรวจวัดด้วยการออกแรงในทิศทางที่แตกต่างกันมีแนวโน้มที่แตกต่างกันอย่างชัดเจน โดยในการทดลองนี้หากพิจารณาอย่างรอบคอบจะสังเกตเห็นได้ว่าขนาดของ

สัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดที่ตำแหน่งกล้ามเนื้อส่วน Forearm muscle จะเกิดการเปลี่ยนแปลงเนื่องจากทิศทางแรงที่แตกต่างกันในช่องสัญญาณที่ 1 2 3 7 และ 8 ในขณะที่ขนาดของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดที่ตำแหน่งกล้ามเนื้อส่วน Biceps/Triceps muscles จะเกิดการเปลี่ยนแปลงเนื่องจากทิศทางแรงที่แตกต่างกันในช่องสัญญาณที่ 3 4 และ 5 ดังนั้นหากพิจารณาถึงปัจจัยในเรื่องผลกระทบต่อสัญญาณไฟฟ้ากล้ามเนื้อเนื่องจากทิศทางแรงที่แตกต่างกันจึงควรเลือกติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อที่ตำแหน่ง Forearm muscle

3.8.2 ตรวจสอบสัญญาณไฟฟ้ากล้ามเนื้อที่ได้จากท่าทางของแขนที่แตกต่างกัน

โดยมีขั้นตอนการทดลองคือผู้ทดลองออกแรงคงที่ 10 นิวตันกระทำต่อด้ามจับในทิศทางตั้ง และผลักต่อด้ามจับอยู่ต่างตำแหน่งในตำแหน่งเริ่มต้น (Start point) และตำแหน่งสิ้นสุด (End point) โดยมีการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อตลอดการทดลองสำหรับใช้เพื่อคำนวณรากของค่าเฉลี่ยกำลังสอง (RMS) ซึ่งบ่งบอกถึงขนาดของสัญญาณไฟฟ้ากล้ามเนื้อ โดยผลการทดลองแสดงด้วยแผนภูมิแท่ง ดังรูปที่ 3-35 โดยที่แผนภูมิแท่งสีน้ำเงินและสีแดงบ่งบอกถึงค่าเฉลี่ยกำลังสอง (RMS) ของสัญญาณไฟฟ้ากล้ามเนื้อจำนวน 8 ช่องสัญญาณขณะผู้เข้าร่วมการทดลองออกแรงคงที่ 10 นิวตันกระทำต่อด้ามจับที่ตำแหน่งเริ่มต้น (Start point) และตำแหน่งสิ้นสุด (End point) ตามลำดับ






รูปที่ 3-35 ขนาดสัญญาณไฟฟ้ากล้ามเนื้อจากการออกแรงดึง (a, b) และผลึก (c, d) ซึ่งตรวจวัดจากตำแหน่ง (a, c).Forearm muscle (b, d).Biceps/Triceps muscles

ผลการทดลองแสดงค่ารากของค่าเฉลี่ยกำลังสอง (RMS) ของสัญญาณไฟฟ้ากล้ามเนื้อจาก 8 ช่องสัญญาณที่ตรวจวัดจากกล้ามเนื้อส่วน Forearm muscle และ Biceps/Triceps muscles พบว่าขนาดสัญญาณไฟฟ้ากล้ามเนื้อซึ่งเกิดการตรวจวัดด้วยท่าทางแขนที่แตกต่างกันขณะออกแรงดึงและผลึกตามจับมีแนวโน้มที่แตกต่างกันอย่างชัดเจน ดังนั้นจึงสามารถสรุปได้ว่าท่าทางแขนที่แตกต่างกันทำให้เกิดสัญญาณไฟฟ้ากล้ามเนื้อในรูปแบบที่แตกต่างกัน โดยในการทดลองนี้หากพิจารณาอย่างรอบคอบจะสังเกตได้ว่าขนาดของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดที่ตำแหน่งกล้ามเนื้อส่วน Forearm muscle จะเกิดการเปลี่ยนแปลงจากการเปลี่ยนท่าทางแขนน้อยกว่าขนาดของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดที่ตำแหน่งกล้ามเนื้อส่วน Biceps/Triceps muscles ดังนั้นหากพิจารณาถึงปัจจัยในเรื่องผลกระทบต่อสัญญาณไฟฟ้ากล้ามเนื้อจากการเปลี่ยนแปลงของท่าทางแขน จึงควรเลือกติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อที่ตำแหน่ง Forearm muscle

3.8.3 ตรวจสอบสัญญาณไฟฟ้ากล้ามเนื้อที่ได้จากแรงบีบนิ้วมือที่แตกต่างกัน

โดยมีขั้นตอนการทดลองคือผู้ทดลองออกแรงบีบมือคงที่ในช่วง 0.8-1.2 นิวตัน และไม่ออกแรงบีบมือต่อด้ามจับยูนึ่งที่ตำแหน่งสิ้นสุด (End point) โดยมีการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อตลอดการทดลองสำหรับใช้เพื่อคำนวณรากของค่าเฉลี่ยกำลังสอง (RMS) ซึ่งบ่งบอกถึงขนาดของสัญญาณไฟฟ้ากล้ามเนื้อ โดยผลการทดลองแสดงด้วยแผนภูมิแท่งดังรูปที่ 3-36 โดยที่แผนภูมิแท่งสีแดงและสีน้ำเงิน บ่งบอกถึงค่าเฉลี่ยกำลังสอง (RMS) ของสัญญาณไฟฟ้ากล้ามเนื้อจำนวน 8 ช่องสัญญาณขณะผู้เข้าร่วมการทดลองออกแรงบีบมือคงที่ประมาณ 1 นิวตันกระทำต่อด้ามจับ และไม่ออกแรงบีบมือ ตามลำดับ



รูปที่ 3-36 ขนาดสัญญาณไฟฟ้ากล้ามเนื้อจากการออกแรงบีบนิ้วมือและไม่ออกแรงบีบนิ้วมือซึ่งตรวจวัดจากตำแหน่ง (a).Forearm muscle (b).Biceps/Triceps muscles

ผลการทดลองแสดงค่ารากของค่าเฉลี่ยกำลังสอง (RMS) ของสัญญาณไฟฟ้ากล้ามเนื้อจาก 8 ช่องสัญญาณที่ตรวจวัดจากกล้ามเนื้อส่วน Forearm muscle และ Biceps/Triceps muscles พบว่าขนาดสัญญาณไฟฟ้ากล้ามเนื้อซึ่งเกิดการตรวจวัดด้วยแรงบีบนิ้วมือที่แตกต่างกันมีผลทำให้ขนาดของสัญญาณไฟฟ้ากล้ามเนื้อแตกต่างกันอย่างชัดเจน ดังนั้นจึงสามารถสรุปได้ว่าขนาดของแรงบีบนิ้วมือที่แตกต่างกันทำให้เกิดสัญญาณไฟฟ้ากล้ามเนื้อในรูปแบบที่แตกต่างกัน โดยในการทดลองนี้หากพิจารณาอย่างรอบคอบจะสังเกตได้ว่าขนาดของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดที่ตำแหน่ง

กล้ามเนื้อส่วน Forearm muscle จะเกิดการเปลี่ยนแปลงจากการเปลี่ยนแปลงของขนาดแรงบีบนิ้ว มีน้อยกว่าขนาดของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งตรวจวัดที่ตำแหน่งกล้ามเนื้อส่วน Biceps/Triceps muscles ดังนั้นหากพิจารณาถึงปัจจัยในเรื่องผลกระทบต่อสัญญาณไฟฟ้ากล้ามเนื้อเนื่องจากการเปลี่ยนแปลงของขนาดแรงบีบนิ้วมือจึงควรเลือกติดตั้งเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อที่ตำแหน่ง Forearm muscle

3.9 การควบคุมการเคลื่อนที่ของด้ามจับ

การควบคุมการเคลื่อนที่ของด้ามจับใช้หลักการควบคุมระบบหุ่นยนต์แบบ Force/position control ด้วยอัลกอริทึมแรงแบบ External force control ซึ่งมีการประยุกต์ใช้วิธีการปรับค่าคงที่โดยตัวควบคุมแบบสัดส่วน (Proportional control) ซึ่งทำให้สัญญาณเอาต์พุตเป็นสัดส่วนกับสัญญาณอินพุตโดยมีอัตราขยายเป็นตัวกำหนดให้เกิดความแตกต่างซึ่งสามารถเขียนในรูปแบบสมการได้ดังสมการที่ 3.5 และ 3.6


$$U(t) = K_p [F - F_{ref}] \quad (3.5)$$

$$U(t) = K_p e(t) \quad (3.6)$$


โดยที่	F	คือ แรงจากการตรวจวัด มีหน่วยเป็น นิวตัน
	F_{ref}	คือ แรงอ้างอิง มีหน่วยเป็น นิวตัน
	$e(t)$	คือ ความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงอ้างอิง
	$U(t)$	คือ ค่าเอาต์พุตของ Proportional control
	K_p	คือ ค่าคงที่ Proportional gain
	t	คือ เวลาต่อเนื่องและเวลาในการสุ่มตัวอย่าง มีหน่วยเป็น วินาที

ในงานวิจัยนี้มีการปรับค่าคงที่สำหรับวิธีตัวควบคุมแบบสัดส่วน (Proportional control) โดยใช้ ค่าคงที่ Proportional gain ที่ 85 ($K_p=85$) จากวิธีการทดลองผิดพลาดลองถูก (Trial and error experiment) ซึ่งทำให้สามารถแปลงค่าอินพุตของตัวควบคุมแบบสัดส่วนจากแรงภายนอกที่กระทำเป็นค่าเอาต์พุตของตัวควบคุมแบบสัดส่วนคือค่าตำแหน่งการเคลื่อนที่ของด้ามจับที่ต้องการได้

เมื่อวัตถุเคลื่อนที่บนพื้นผิวใดๆ จะมีแรงต้านทานการเคลื่อนที่หรือแรงเสียดทานเสมอในทิศทางตรงกันข้ามกับทิศทางการเคลื่อนที่ ซึ่งแรงเสียดทานแบ่งออกเป็น 2 ประเภท คือ แรงเสียดทานสถิต (Static friction) คือแรงต้านทานการเคลื่อนที่ในสถานะที่วัตถุได้รับแรงกระทำขณะที่วัตถุอยู่นิ่ง จากนั้นเมื่อแรงกระทำต่อวัตถุมีค่ามากกว่าแรงเสียดทานสถิตทำให้วัตถุเริ่มเคลื่อนที่จะทำให้เกิดแรงต้านทานการเคลื่อนที่อีกประเภทหนึ่งคือ แรงเสียดทานจลน์ (Kinetic friction) ซึ่งจะมีขนาดน้อยกว่าขนาดสูงสุดของแรงเสียดทานสถิตแสดงดังแสดงในรูปที่ 3-37 ซึ่งการหาแรงเสียดทานจลน์ในขณะด้ามจับมีการเคลื่อนที่แบบต่อเนื่องตามเวลาจริงค่อนข้างมีความซับซ้อน ดังนั้นการทดลองเพื่อกำหนดแรงต้านทานการเคลื่อนที่ในงานวิจัยนี้จะประมาณให้แรงเสียดทานสถิตของด้ามจับมีขนาดเท่าขนาดแรงเสียดทานจลน์ของด้ามจับดังแสดงในรูปที่ 3-38

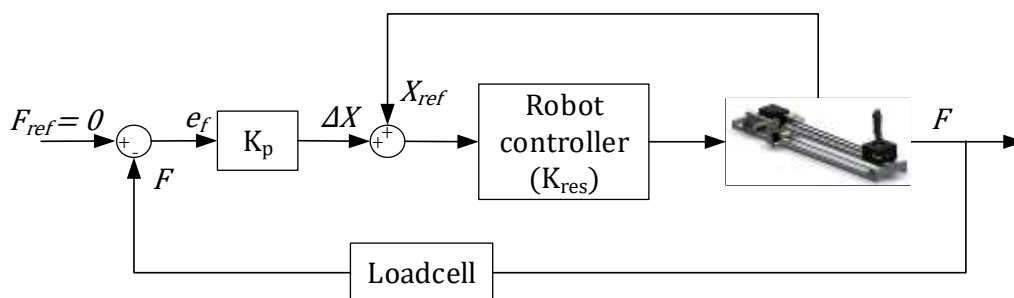


รูปที่ 3-37 ขนาดของแรงต้านทานการเคลื่อนที่ขณะได้รับแรงกระทำภายนอก [46]




รูปที่ 3-38 โปรไฟล์แรงเสียดทานของด้ามจับที่ใช้ในการทดลอง [46]

ระบบในการเคลื่อนที่ 1 มิติออกแบบโดยมีการกำหนดให้ระบบสามารถควบคุมความต้านทานการเคลื่อนที่ของด้ามจับได้ โดยในการทดลองหลักมีการกำหนดใช้แรงต้านทานการเคลื่อนที่ ได้แก่ 2 3 4 และ 5 นิวตัน เนื่องจากขนาดแรงต้านทานการเคลื่อนที่ต่ำกว่า 2 นิวตัน จะทำให้เกิดการเปลี่ยนแปลงของสัญญาณไฟฟ้ากล้ำมเนื้อน้อยมาก และหากมากกว่า 5 นิวตัน จะทำให้ไม่สามารถออกแรงกระทำต่อด้ามจับให้เคลื่อนที่ด้วยความเร็วสูงสุดในการทดลองหลักได้เนื่องจากเป็นข้อจำกัดของอุปกรณ์ ดังนั้นเพื่อควบคุมความต้านทานการเคลื่อนที่ดังกล่าว ชุดโปรแกรมสำหรับควบคุมความเร็วการหมุนของมอเตอร์จึงมีการกำหนดค่าคงที่สำหรับประมวลผลร่วมด้วย ซึ่งค่าคงที่ดังกล่าวเรียกว่า ค่าคงที่แรงต้านทานการเคลื่อนที่ (Resistive gain) โดยที่แต่ละค่าของค่าคงที่แรงต้านทานการเคลื่อนที่将有ขนาดความต้านทานการเคลื่อนที่ของด้ามจับแตกต่างกัน ซึ่งการควบคุมการเคลื่อนที่ของด้ามจับในระบบในการเคลื่อนที่ 1 มิติสามารถแสดงด้วยบล็อกไดอะแกรมดังแสดงในรูปที่ 3-39 ดังนั้นเพื่อควบคุมความต้านทานการเคลื่อนที่ของด้ามจับจึงมีการทดลองเบื้องต้นเพื่อตรวจสอบความสัมพันธ์ระหว่างความต้านทานการเคลื่อนที่ของด้ามจับและค่าคงที่แรงต้านทานการเคลื่อนที่ใดๆ โดยการทดลองนี้กำหนดใช้ค่าคงที่แรงต้านทานการเคลื่อนที่ ได้แก่ 1 1.5 2 2.5 และ 3 ซึ่งทำให้เกิดขนาดความต้านทานการเคลื่อนที่ครอบคลุมสำหรับกำหนดใช้ในการทดลองหลักในช่วงระหว่าง 2 ถึง 5 นิวตัน โดยขั้นตอนการทดลองแสดงดังรูปที่ 3-40



รูปที่ 3-39 บล็อกไดอะแกรมการควบคุมการเคลื่อนที่ของด้ามจับในระบบการเคลื่อนที่ 1 มิติ




รูปที่ 3-40 แผนผังการทดลองตรวจสอบความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่

เริ่มต้นโดยผู้ทดลองออกแรงกระทำต่อด้ามจับในแนวแกน 1 มิติจนกระทั่งด้ามจับเริ่มเคลื่อนที่ จากนั้นขนาดของแรงที่ทำให้ด้ามจับเริ่มเคลื่อนที่จะแสดงบนจอแสดงผล ซึ่งผลการทดลองแสดงดังตารางที่ 3-14 และแสดงในรูปแบบกราฟเส้นดังรูปที่ 3-41

ตารางที่ 3-14 ความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่

Resistive gain	Friction (N)	SD
1.0	5.470	0.533
1.5	3.890	0.476
2.0	2.940	0.268
2.5	2.250	0.236
3.0	1.845	0.340



รูปที่ 3-41 ความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่

จากความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่ดังแสดงในตารางที่ 3-14 สามารถแสดงในรูปแบบสมการความสัมพันธ์ระหว่างแรงต้านทานการเคลื่อนที่และค่าคงที่แรงต้านทานการเคลื่อนที่ดังสมการที่ 3.7

$$Friction = 0.1864K_{res}^2 - 2.0076K_{res} + 7.251 \quad (3.7)$$

โดยที่ Friction คือ แรงต้านทานการเคลื่อนที่ของด้ามจับ มีหน่วยเป็น นิวตัน

K_{res} คือ ค่าคงที่แรงต้านทานการเคลื่อนที่

ดังนั้นจากสมการที่ 3.7 จึงสามารถหาค่าคงที่ค่าคงที่แรงต้านทานการเคลื่อนที่สำหรับกำหนดใช้ในการทดลองเพื่อควบคุมค่าความต้านทานการเคลื่อนที่ของด้ามจับ ได้แก่ 2 3 4 และ 5 ดังแสดงในตารางที่ 3-15

ตารางที่ 3-15 ค่าคงที่แรงต้านทานการเคลื่อนที่ที่ความต้านทานการเคลื่อนที่ 2 3 4 และ 5 นิวตัน

Resistive gain	Friction (N)
2.700	2
1.945	3
1.459	4
1.125	5

บทที่ 4

วิธีการทดลองและผลการทดลอง

ในบทนี้จะอธิบายถึงการออกแบบการทดลองเพื่อตรวจสอบปัจจัยที่มีผลต่อประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ในการประมาณแรงกล้ามเนื้อและเปรียบเทียบแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยวิธีโครงข่ายประสาทเทียมและวิธีซัพพอร์ตเวกเตอร์แมชชีนด้วยชุดข้อมูลที่ได้รับจากระบบในการเคลื่อนที่ 1 มิติโดยการออกแบบขั้นตอนการทดลองประมาณแรงกล้ามเนื้อมีรายละเอียดดังนี้

4.1 การออกแบบทดลองสำหรับประมาณแรงจากสัญญาณไฟฟ้ากล้ามเนื้อ

การทดลองประมาณแรงกล้ามเนื้อจะแบ่งออกเป็น 2 รูปแบบ ได้แก่ แบบออฟไลน์และแบบตามเวลาจริง ซึ่งในงานวิจัยนี้จะมีการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์จำนวน 2 การทดลอง และการทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงจำนวน 1 การทดลอง ซึ่งในแต่ละการทดลองมีการกำหนดใช้ความต้านทานการเคลื่อนที่ของด้ามจับ 2 3 4 และ 5 นิวตัน และความเร็วการเคลื่อนที่ด้ามจับ 0.1 0.15 และ 0.2 เมตรต่อวินาที เนื่องจากช่วงของความต้านทานการเคลื่อนที่ของด้ามจับและความเร็วการเคลื่อนที่ด้ามจับข้างต้นสามารถทำให้ผู้เข้าร่วมการทดลองควบคุมการออกแรงกระทำต่อด้ามจับให้เคลื่อนที่ได้อย่างมีประสิทธิภาพดังที่ได้กล่าวมาข้างต้น ซึ่งช่วยลดเวลาในขั้นตอนการทดลองรวมถึงลดความผิดพลาดในการเก็บข้อมูลจากความล้าและความไม่ชำนาญของผู้เข้าร่วมการทดลอง โดยแต่ละการทดลองมีรายละเอียดและวัตถุประสงค์ดังนี้

4.1.1 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับมีวัตถุประสงค์เพื่อตรวจสอบความสัมพันธ์ระหว่างความต้านทานการเคลื่อนที่และประสิทธิภาพความแม่นยำของแบบจำลองทางคณิตศาสตร์ในการทำนายแรง โดยผู้ทดลองทำการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที และประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์โดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย และค่าเบี่ยงเบน

มาตรฐาน (Standard deviation : SD) ซึ่งบ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย

4.1.2 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความเร็วในการเคลื่อนที่ของด้ามจับมีวัตถุประสงค์เพื่อตรวจสอบความสัมพันธ์ระหว่างความเร็วในการเคลื่อนที่ที่ด้ามจับและประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ในการทำนายแรง โดยผู้ทดลองทำการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ที่ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับแรงต้านทานการเคลื่อนที่ซึ่งให้ค่าความคลาดเคลื่อนน้อยที่สุดจากการทดลองที่ 4.1.1 และประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนในขั้นตอนการฝึกสอนและทดสอบโดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย และค่าเบี่ยงเบนมาตรฐาน (Standard deviation : SD) ซึ่งบ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย

4.1.3 การทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงโดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับมีวัตถุประสงค์เพื่อตรวจสอบประสิทธิภาพในการทำนายแรงที่ระดับความต้านทานการเคลื่อนที่ต่างๆ และเปรียบเทียบความแม่นยำในการทำนายแรงของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีน โดยผู้ทดลองทำการทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที ซึ่งให้ค่าความคลาดเคลื่อนน้อยที่สุดจากการทดลองที่ 4.1.2 และประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบตามเวลาจริงโดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย และค่าเบี่ยงเบนมาตรฐาน (Standard deviation : SD) ซึ่งบ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย

4.2 การออกแบบขั้นตอนการทดลอง

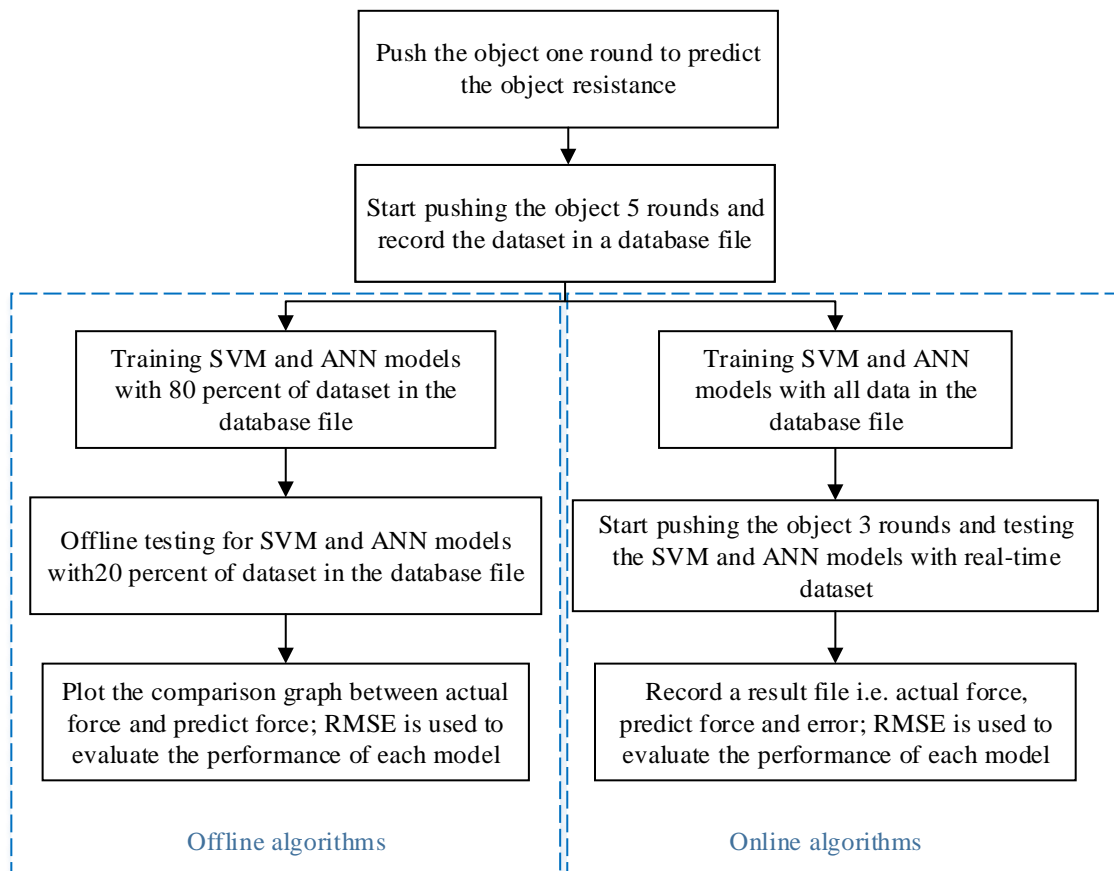
ในหัวข้อนี้กล่าวถึงขั้นตอนการทดลองสำหรับเก็บข้อมูลจากผู้เข้าร่วมการทดลองที่ถนัดมือข้างขวาและประมวลผลข้อมูลเพื่อประมาณแรงกล้ามเนื้อแบบออฟไลน์และแบบตามเวลาจริง โดยเริ่มต้นจากผู้เข้าร่วมการทดลองถูกสุ่มมาจำนวน 10 คน ประกอบด้วย ผู้เข้าร่วมการทดลองสุขภาพดีเพศชาย 4 คน อายุระหว่าง 23-28 ปี มีน้ำหนักระหว่าง 65-84 กิโลกรัม และผู้เข้าร่วมการทดลองสุขภาพดีเพศหญิง 6 คน อายุระหว่าง 21-33 ปี มีน้ำหนัก 43-62 กิโลกรัม ซึ่งแต่ละคนออกแรงผลักดันด้ามจับให้เคลื่อนที่ด้วยความเร็วคงที่ใกล้เคียงความเร็วของจุดอ้างอิงการเคลื่อนที่ไปยังจุดสิ้นสุด (End point) จากนั้นดึงด้ามจับกลับมายังจุดเริ่มต้น (Start point) จำนวน 1 รอบ เพื่อทำนายความต้านทานการเคลื่อนที่ของด้ามจับ ณ ขณะทำการทดลองจากความสัมพันธ์ระหว่างแรงและแรงต้านทานการเคลื่อนที่ของด้ามจับขณะที่เคลื่อนที่ด้วยความเร็วคงที่ 0.1 เมตรต่อวินาที ดังแสดงในตารางที่ 4-1

ตารางที่ 4-1 ความสัมพันธ์ระหว่างแรงและแรงต้านทานการเคลื่อนที่ของด้ามจับ

Friction (N)	Force (N)
2	3.24
3	4.18
4	5.49
5	6.79

เริ่มต้นบันทึกชุดข้อมูลที่เกี่ยวข้องไปยังไฟล์ฐานข้อมูลสำหรับฝึกสอนและทดสอบอัลกอริทึม โดยการผลักดันด้ามจับให้เคลื่อนที่ด้วยความเร็วคงที่ใกล้เคียงความเร็วของจุดอ้างอิงการเคลื่อนที่ไปยังจุดสิ้นสุด (End point) จำนวน 5 ครั้ง ซึ่งในขั้นตอนการเรียนรู้และทำนายของอัลกอริทึมจำเป็นต้องใช้เวกเตอร์ของลักษณะเฉพาะ (Feature vector) ที่ได้จากชุดข้อมูลสองส่วนคือชุดข้อมูลสำหรับฝึกสอนอัลกอริทึม (Training dataset) และชุดข้อมูลสำหรับทดสอบอัลกอริทึม (Test dataset) ซึ่งในงานวิจัยนี้จะใช้หลักการพาเรโต (Pareto principle) ในการแบ่งจำนวนชุดข้อมูลสำหรับฝึกสอนและทดสอบอัลกอริทึม โดยหลักการนี้มีการนำไปใช้ในงานวิจัย [47] เพื่อแบ่งจำนวนชุดข้อมูลสำหรับฝึกสอน 80 เปอร์เซ็นต์ และชุดข้อมูลสำหรับทดสอบ 20 เปอร์เซ็นต์ของข้อมูลทั้งหมด ดังนั้นในงานวิจัยนี้จะแบ่งชุดข้อมูลด้วยจำนวน 80 เปอร์เซ็นต์ของจำนวนชุดข้อมูลทั้งหมดในไฟล์ฐานข้อมูล

สำหรับฝึกสอนอัลกอริทึมแบบออฟไลน์และชุดข้อมูลจำนวน 20 เปอร์เซ็นต์ของจำนวนชุดข้อมูลทั้งหมดในไฟล์ฐานข้อมูลสำหรับทดสอบอัลกอริทึมแบบออฟไลน์ ซึ่งในหนึ่งชุดข้อมูลจะประกอบด้วยข้อมูลอินพุต (Input data) ได้แก่ สัญญาณไฟฟ้ากล้ามเนื้อ ระยะทางและความเร็วของการเคลื่อนที่ ด้ามจับ แรงบีบนิ้วมือ ค่าความต้านทานการเคลื่อนที่ของด้ามจับ และข้อมูลเป้าหมาย (Target data) คือแรง และใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ระหว่างข้อมูลเอาต์พุต (Output data) และข้อมูลเป้าหมาย (Target data) สำหรับประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ สำหรับการเรียนรู้และการทำนายของอัลกอริทึมแบบตามเวลาจริง (Real-time) จะใช้เวกเตอร์ของลักษณะเฉพาะ (Feature vector) ที่ได้จากจำนวนชุดข้อมูลทั้งหมดในไฟล์ฐานข้อมูลเพื่อฝึกสอนอัลกอริทึมแบบออนไลน์ โดยข้อมูลอินพุต (Input data) ประกอบด้วย สัญญาณไฟฟ้ากล้ามเนื้อ ระยะทางและความเร็วของการเคลื่อนที่ที่ด้ามจับ แรงบีบนิ้วมือ และค่าความต้านทานการเคลื่อนที่ของด้ามจับ ข้อมูลเป้าหมาย (Target data) คือแรง หลังจากเสร็จสิ้นการฝึกสอนผู้เข้าร่วมการทดลองจะออกแรงผลักด้ามจับให้เคลื่อนที่ด้วยความเร็วคงที่ใกล้เคียงความเร็วของจุดอ้างอิงการเคลื่อนที่ไปยังจุดสิ้นสุด (End point) จำนวน 3 ครั้งเพื่อทดสอบอัลกอริทึมแบบออนไลน์โดยรับค่าชุดข้อมูลใหม่ ณ ขณะใช้งานเพื่อใช้เป็นชุดข้อมูลสำหรับป้อนให้แบบจำลองทางคณิตศาสตร์เพื่อทำนายข้อมูลเอาต์พุต (Output data) จากนั้นประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์โดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ระหว่างข้อมูลเอาต์พุต (Output data) และข้อมูลเป้าหมาย (Target data) เช่นเดียวกับการทดสอบอัลกอริทึมแบบออฟไลน์ ซึ่งขั้นตอนการทดลองเพื่อรับค่าชุดข้อมูลสำหรับใช้เพื่อฝึกสอนและทดสอบอัลกอริทึมทั้งแบบออฟไลน์และแบบออนไลน์สามารถแสดงด้วยบล็อกไดอะแกรมดังรูปที่ 4-1



รูปที่ 4-1 ขั้นตอนการรับค่าชุดข้อมูลสำหรับใช้เพื่อฝึกสอนและทดสอบอัลกอริทึมทั้งแบบออฟไลน์และแบบออนไลน์

4.3 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับ

ในหัวข้อนี้จะกล่าวถึงผลการทดลองจากการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับมีวัตถุประสงค์เพื่อตรวจสอบความสัมพันธ์ระหว่างความต้านทานการเคลื่อนที่และประสิทธิภาพในการทำนายแรง โดยผู้ทดลองทำการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที และประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์โดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนายดังแสดงในตารางที่ 4-2 และแสดง

ในรูปแบบแผนภูมิแท่งดังแสดงในรูปที่ 4-2 โดยแผนภูมิแท่ง สี่น้ำเงิน สีเขียว สีเทา และสีเหลืองซึ่งบ่งบอกถึงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) ได้แก่ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ฟังก์ชันเชิงเส้น (Linear function) ฟังก์ชันพหุนาม (Polynomial function) ตามลำดับ ในส่วนของค่าเบี่ยงเบนมาตรฐาน (Standard deviation : SD) ซึ่งบ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย จากผู้เข้าร่วมการทดลอง 10 คนซึ่งแสดงดังตารางที่ 4-3


ตารางที่ 4-2 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน

Classifier	friction = 2 N		friction = 3 N		friction = 4 N		friction = 5 N	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.053	0.087	0.058	0.112	0.108	0.360	0.272	0.345
RBF	0.056	0.087	0.061	0.121	0.135	0.273	0.175	0.200
Linear	0.050	0.078	0.053	0.113	0.122	0.329	0.129	0.328
Polynomial	0.099	0.117	0.076	0.141	0.148	0.275	0.164	0.215

ตารางที่ 4-3 ค่าเบี่ยงเบนมาตรฐานที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน

Classifier	friction = 2 N		friction = 3 N		friction = 4 N		friction = 5 N	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.012	0.037	0.007	0.065	0.032	0.188	0.319	0.163
RBF	0.012	0.019	0.008	0.060	0.029	0.078	0.085	0.011
Linear	0.010	0.026	0.010	0.054	0.038	0.135	0.050	0.154
Polynomial	0.020	0.041	0.008	0.065	0.030	0.079	0.071	0.065

RMSE values carried out by ANN and SVM algorithms at various frictional forces



รูปที่ 4-2 แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน ในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์

จากผลการทดลองในตารางที่ 4-2 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ที่ระดับความต้านทานการเคลื่อนที่น้อยๆ มีแนวโน้มทำนายแรงได้แม่นยำมากกว่าที่ระดับความต้านทานการเคลื่อนที่มากสอดคล้องกันทั้งสองอัลกอริทึมในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์ซึ่งสามารถสังเกตได้ชัดเจนเมื่อแสดงในรูปแบบแผนภูมิแท่งดังรูปที่ 4-2 โดยที่ระดับแรงต้านทานการเคลื่อนที่ 2 และ 3 นิวตัน แบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยอัลกอริทึมทั้งสองสามารถทำนายแรงได้อย่างแม่นยำใกล้เคียงกันโดยมีความคลาดเคลื่อนอยู่ในช่วง 0.05-0.15 นิวตัน และที่ระดับแรงต้านทานการเคลื่อนที่ 4 และ 5 นิวตันแบบจำลองทางคณิตศาสตร์สามารถทำนายแรงได้แม่นยำน้อยลงโดยมีความคลาดเคลื่อนอยู่ในช่วง 0.20-0.35 นิวตัน จึงสามารถสรุปได้ว่าประสิทธิภาพในการทำนายของอัลกอริทึมเป็นปฏิภาคผกผันกับระดับแรงต้านทานการเคลื่อนที่ อีกทั้งยังพบว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) เป็นเรเดียลเบสฟังก์ชัน (Radial basis function : RBF) ให้ความแม่นยำมากกว่าวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) เป็นฟังก์ชันเชิงเส้น (Linear function) และฟังก์ชันพหุนาม (Polynomial function)

4.4 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความเร็วในการเคลื่อนที่ของด้ามจับ

ในหัวข้อนี้จะกล่าวถึงผลการทดลองจากการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความเร็วในการเคลื่อนที่ของด้ามจับมีวัตถุประสงค์เพื่อตรวจสอบความสัมพันธ์ระหว่างความเร็วในการเคลื่อนที่ของด้ามจับและประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ในการทำนายแรง โดยผู้ทดลองทำการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับแรงต้านทานการเคลื่อนที่ 2 นิวตันซึ่งให้ค่าความคลาดเคลื่อนน้อยที่สุดจากการทดลองที่ 4.3 จากนั้นประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์โดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย ดังแสดงในตารางที่ 4-4 และแสดงในรูปแบบแผนภูมิแท่งดังแสดงในรูปที่ 4-3 โดยแผนภูมิแท่ง สีน้ำเงิน สีเขียว สีเทา และสีเหลืองจะบ่งบอกถึงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) ได้แก่ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ฟังก์ชันเชิงเส้น (Linear function) และฟังก์ชันพหุนาม (Polynomial function) ตามลำดับ ในส่วนของค่าเบี่ยงเบนมาตรฐาน (Standard deviation : SD) ซึ่งบ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนาย จากผู้เข้าร่วมการทดลอง 10 คนซึ่งแสดงในตารางที่ 4-5

4.4.1 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที โดยใช้ความต้านทานการ เคลื่อนที่คงที่ 2 นิวตัน


ตารางที่ 4-4 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้าม
จับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่
2 นิวตัน

Classifier	velocity = 0.1 m/s		velocity = 0.15 m/s		velocity = 0.2 m/s	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.089	0.106	0.099	0.274	0.055	0.148
RBF	0.100	0.087	0.131	0.237	0.114	0.146
Linear	0.094	0.099	0.107	0.259	0.055	0.127
Polynomial	0.125	0.099	0.359	0.412	0.454	0.409

ตารางที่ 4-5 ค่าเบี่ยงเบนมาตรฐานที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1
0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 2 นิวตัน

Classifier	velocity = 0.1 m/s		velocity = 0.15 m/s		velocity = 0.2 m/s	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.037	0.046	0.027	0.107	0.008	0.052
RBF	0.052	0.025	0.041	0.129	0.039	0.071
Linear	0.052	0.020	0.040	0.129	0.013	0.043
Polynomial	0.039	0.032	0.053	0.124	0.080	0.105

RMSE values carried out by ANN and SVM algorithms at constant frictional force of 2 newtons under various object velocities



รูปที่ 4-3 แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 2 นิวตันในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์

จากผลการทดลองในตารางที่ 4-4 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) จะสังเกตได้ว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.1 0.15 และ 0.2 เมตรต่อวินาที แบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยอัลกอริทึมทั้งสองสามารถทำนายแรงโดยมีความคลาดเคลื่อนอยู่ในช่วง 0.08-0.11 0.23-0.42 และ 0.13-0.41 นิวตัน ตามลำดับ ซึ่งแสดงในรูปแบบแผนภูมิแท่งดังรูปที่ 4-3 ดังนั้นหากเรียงลำดับความแม่นยำในการทำนายแรงที่ระดับความเร็วการเคลื่อนที่ของด้ามจับต่างๆ ที่ระดับความต้านทานการเคลื่อนที่คงที่ 2 นิวตัน จะได้ว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับที่ 0.1 เมตรต่อวินาทีให้ผลการทำนายแรงแม่นยำมากกว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.2 เมตรต่อวินาที และ 0.15 เมตรต่อวินาที ตามลำดับ ดังนั้นในการทดลองนี้จึงยังไม่สามารถสรุปถึงความสัมพันธ์ระหว่างประสิทธิภาพในการทำนายแรงของอัลกอริทึมและระดับความเร็วในการเคลื่อนที่ของด้ามจับ

จึงได้มีการทดลองเพิ่มเติมโดยใช้ระดับความต้านทานการเคลื่อนที่คงที่ ได้แก่ 3 4 และ 5 นิวตัน แต่เนื่องจากข้อจำกัดของอุปกรณ์ในการทดลองทำให้ไม่สามารถทำการทดลองได้ที่ระดับความเร็วการเคลื่อนที่ของด้ามจับที่ 0.2 เมตรต่อวินาทีขณะที่ระดับแรงต้านทานการเคลื่อนที่ 5 นิวตัน ดังนั้นจึงมีการทำการทดลองที่ระดับความต้านทานการเคลื่อนที่ 3 และ 4 นิวตันเท่านั้นโดยผู้ทดลองทำการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับแรงต้านทานการเคลื่อนที่ 3 และ 4 นิวตัน จากนั้นประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์โดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนายดังแสดงในตารางที่ 4-6 และตารางที่ 4-8 และแสดงในรูปแบบแผนภูมิแท่งดังแสดงในรูปที่ 4-4 และรูปที่ 4-5 ที่ระดับความต้านทานการเคลื่อนที่ 3 และ 4 นิวตัน ตามลำดับ โดยแผนภูมิแท่ง สีน้ำเงิน สีเขียว สีเทา และสีเหลืองจะบ่งบอกถึงค่ารากที่สองของความคลาดเคลื่อนกำลังสองของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) ได้แก่ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ฟังก์ชันเชิงเส้น (Linear function) และฟังก์ชันพหุนาม (Polynomial function) ตามลำดับ ในส่วนของค่าเบี่ยงเบนมาตรฐาน (Standard deviation : SD) ซึ่งบ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนายจากผู้เข้าร่วมการทดลอง 10 คน ซึ่งแสดงในตารางที่ 4-7 และตารางที่ 4-9

4.4.2 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที โดยใช้ความต้านทานการ เคลื่อนที่คงที่ 3 นิวตัน


ตารางที่ 4-6 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 3 นิวตัน

Classifier	velocity = 0.1 m/s		velocity = 0.15 m/s		velocity = 0.2 m/s	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.058	0.112	0.071	0.187	0.074	0.389
RBF	0.061	0.121	0.139	0.204	0.270	0.392
Linear	0.053	0.128	0.072	0.181	0.102	0.404
Polynomial	0.076	0.141	0.299	0.350	0.443	0.432

ตารางที่ 4-7 ค่าเบี่ยงเบนมาตรฐานที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 3 นิวตัน

Classifier	velocity = 0.1 m/s		velocity = 0.15 m/s		velocity = 0.2 m/s	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.007	0.065	0.008	0.063	0.019	0.304
RBF	0.008	0.060	0.036	0.100	0.032	0.134
Linear	0.010	0.050	0.012	0.067	0.033	0.305
Polynomial	0.008	0.065	0.071	0.128	0.079	0.170

RMSE values carried out by ANN and SVM algorithms at constant frictional force of 3 newtons under various object velocities



รูปที่ 4-4 แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 3 นิวตันในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์

จากผลการทดลองในตารางที่ 4-6 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) จะสังเกตได้ว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.1 0.15 และ 0.2 เมตรต่อวินาที แบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยอัลกอริทึมทั้งสองสามารถทำนายแรงโดยมีความคลาดเคลื่อนอยู่ในช่วง 0.1-0.15 0.18-0.35 และ 0.38-0.43 นิวตัน ตามลำดับ ซึ่งแสดงดังรูปที่ 4-4 หากเรียงลำดับความแม่นยำในการทำนายแรงที่ระดับความเร็วการเคลื่อนที่ของด้ามจับต่างๆ ที่ความต้านทานการเคลื่อนที่คงที่ 3 นิวตัน พบว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับที่ 0.1 เมตรต่อวินาทีแม่นยำมากกว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.15 เมตรต่อวินาที และ 0.2 เมตรต่อวินาที ตามลำดับ ดังนั้นในการทดลองนี้สามารถสรุปได้ว่าประสิทธิภาพในการทำนายของอัลกอริทึมเป็นปฏิภาคผกผันกับระดับความเร็วการเคลื่อนที่ของด้ามจับ

4.4.3 การทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์ที่ระดับความเร็วในการเคลื่อนที่ ด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที โดยใช้ความต้านทานการ เคลื่อนที่คงที่ 4 นิวตัน


ตารางที่ 4-8 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 4 นิวตัน

Classifier	velocity = 0.1 m/s		velocity = 0.15 m/s		velocity = 0.2 m/s	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.108	0.360	0.120	0.355	0.032	0.477
RBF	0.135	0.273	0.310	0.579	0.313	0.653
Linear	0.122	0.329	0.140	0.363	0.126	0.822
Polynomial	0.148	0.275	0.411	0.636	0.350	0.549

ตารางที่ 4-9 ค่าเบี่ยงเบนมาตรฐานที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 4 นิวตัน

Classifier	velocity = 0.1 m/s		velocity = 0.15 m/s		velocity = 0.2 m/s	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.032	0.188	0.049	0.193	0.005	0.522
RBF	0.029	0.078	0.040	0.336	0.170	0.425
Linear	0.038	0.135	0.059	0.272	0.080	0.962
Polynomial	0.030	0.079	0.065	0.321	0.182	0.390

RMSE values carried out by ANN and SVM algorithms at constant frictional force of 4 newtons under various object velocities



รูปที่ 4-5 แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความเร็วการเคลื่อนที่ของด้ามจับแตกต่างกัน ได้แก่ 0.1 0.15 และ 0.2 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่คงที่ 4 นิวตันในขั้นตอนการทดสอบอัลกอริทึมแบบออฟไลน์

จากผลการทดลองในตารางที่ 4-8 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนในการทำนายแรงของแบบจำลองทางคณิตศาสตร์ในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์ จะสังเกตได้ว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.1 0.15 และ 0.2 เมตรต่อวินาที แบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยอัลกอริทึมทั้งสองสามารถทำนายแรงโดยมีความคลาดเคลื่อนอยู่ในช่วง 0.27-0.36 0.35-0.63 และ 0.48-1.02 นิวตันตามลำดับ ซึ่งแสดงในรูปแบบแผนภูมิแท่งดังรูปที่ 4-5 ดังนั้นหากเรียงลำดับความแม่นยำในการทำนายแรงที่ระดับความเร็วการเคลื่อนที่ของด้ามจับต่างๆ ที่ความต้านทานการเคลื่อนที่คงที่ 4 นิวตัน จะได้ว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับที่ 0.1 เมตรต่อวินาทีให้ผลการทำนายแรงแม่นยำมากกว่าที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.15 เมตรต่อวินาที และ 0.2 เมตรต่อวินาที ตามลำดับเช่นเดียวกับการทดลองที่ระดับความต้านทานการเคลื่อนที่คงที่ 3 นิวตัน ดังนั้นในการทดลองนี้สามารถสรุปได้ว่าประสิทธิภาพในการทำนายของอัลกอริทึมเป็นปฏิภาคผกผันกับระดับความเร็วการเคลื่อนที่ของด้ามจับ

จากการทดลอง 4.4.1 4.4.2 และ 4.4.3 ประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับและการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความเร็วในการเคลื่อนที่ของด้ามจับให้ผลการทดลองซึ่งสามารถสรุปได้ว่าประสิทธิภาพในการทำนายแรงของอัลกอริทึมเป็นปฏิภาคผกผันกับทั้งความต้านทานการเคลื่อนที่และความเร็วการเคลื่อนที่ของด้ามจับ อีกทั้งยังพบว่าในการทดลองที่ 4.4.1 และ 4.4.2 แบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) เป็นเรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) มีความแม่นยำในการทำนายแรงมากกว่าวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) เป็น ฟังก์ชันเชิงเส้น (Linear function) และฟังก์ชันพหุนาม (Polynomial function) อย่างไรก็ตาม การทดลองที่ 4.4.3 แบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) เป็นเรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) มีความแม่นยำในการทำนายแรงมากที่สุดที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.1 เมตรต่อวินาที แต่แม่นยำเป็นอันดับ 2 ที่ระดับความเร็วการเคลื่อนที่ของด้ามจับ 0.15 และ 0.2 เมตรต่อวินาที เมื่อเปรียบเทียบกับแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) เป็น ฟังก์ชันเชิงเส้น (Linear function) และฟังก์ชันพหุนาม (Polynomial function) ดังนั้นเพื่อให้ได้ผลการทำนายแรงที่มีความแม่นยำและมีผลกระทบจากระดับความเร็วการเคลื่อนที่ของด้ามจับน้อยที่สุดในการทดลองต่อไปคือการทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงโดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับจะใช้ความเร็วการเคลื่อนที่ของด้ามจับคงที่ที่ระดับ 0.1 เมตรต่อวินาที และเนื่องจากในการทดลองประมาณแรงแบบตามเวลาจริงจำเป็นต้องคำนึงถึงเวลาในการประมวลผลข้อมูลดังนั้นเพื่อลดขั้นตอนในการประมวลผลจึงมีการกำหนดใช้ฟังก์ชันเคอร์เนลเพียง 1 ฟังก์ชันเพื่อฝึกสอนและทดสอบอัลกอริทึมแบบตามเวลาจริง คือ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ซึ่งให้มีความแม่นยำในการทำนายแรงมากที่สุดเมื่อเปรียบเทียบกับฟังก์ชันเชิงเส้น (Linear function) และฟังก์ชันพหุนาม (Polynomial function) อีกทั้งยังเป็นเคอร์เนลฟังก์ชันที่ใช้กับวิธีซัพพอร์ตเวกเตอร์แมชชีนในการแก้ปัญหาได้อย่างดีและแพร่หลาย

4.5 การทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงโดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับ

ในหัวข้อนี้จะกล่าวถึงผลการทดลองจากการทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงโดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับมีวัตถุประสงค์เพื่อตรวจสอบประสิทธิภาพในการทำนายแรงที่ระดับความต้านทานการเคลื่อนที่ต่างๆ และเปรียบเทียบความแม่นยำในการทำนายแรงของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีน โดยผู้ทดลองทำการทดลองประมาณแรงกล้ามเนื้อแบบตามเวลาจริงที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที ซึ่งให้ค่าความคลาดเคลื่อนน้อยที่สุดจากการทดลองที่ 4.4 และประเมินประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ในขั้นตอนการฝึกสอนและทดสอบ อัลกอริทึมแบบตามเวลาจริงโดยใช้ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ดังแสดงในตารางที่ 4-10 และแสดงในรูปแบบแผนภูมิแท่งดังแสดงในรูปที่ 4-6 โดยแผนภูมิแท่ง สีน้ำเงินและสีเขียวจะบ่งบอกถึงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน (Kernel function) คือ เรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) ในส่วนของค่าเบี่ยงเบนมาตรฐาน (Standard deviation : SD) ซึ่งบ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนระหว่างแรงจากการตรวจวัดและแรงจากการทำนายจากผู้เข้าร่วมการทดลอง 10 คนซึ่งแสดงในตารางที่ 4-11


ตารางที่ 4-10 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที

Algorithms	friction = 2 N	friction = 3 N	friction = 4 N	friction = 5 N
RMSE_ANN (N)	0.113	0.148	0.298	0.423
RMSE_SVM_RBF (N)	0.124	0.175	0.316	0.539

ตารางที่ 4-11 ค่าเบี่ยงเบนมาตรฐานที่ระดับความต้านทานการเคลื่อนที่ที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน โดยใช้ความเร็วในการเคลื่อนที่ที่ด้ามจับคงที่ 0.1 เมตรต่อวินาที

Algorithms	friction = 2 N	friction = 3 N	friction = 4 N	friction = 5 N
SD_ANN (N)	0.070	0.108	0.311	0.245
SD_SVM_RBF (N)	0.078	0.129	0.194	0.333

RMSE values of real-time force estimation carried out by SVM using kernel function of radial basis function and ANN algorithms under various frictional forces



รูปที่ 4-6 แผนภูมิแท่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยที่ระดับความต้านทานการเคลื่อนที่แตกต่างกัน ได้แก่ 2 3 4 และ 5 นิวตัน ในขั้นตอนการทดสอบอัลกอริทึมแบบตามเวลาจริง

จากผลการทดลองในตารางที่ 4-10 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) ซึ่งบ่งบอกถึงความคลาดเคลื่อนในการทำนายแรงของแบบจำลองทางคณิตศาสตร์ในขั้นตอนการฝึกสอนและทดสอบอัลกอริทึมแบบออฟไลน์ จะสังเกตเห็นว่าที่ระดับความต้านทานการเคลื่อนที่ 2 3 4 และ 5 นิวตัน แบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยอัลกอริทึมทั้งสองสามารถทำนายแรงโดยมีความคลาดเคลื่อนใกล้เคียงกันอยู่ในช่วง 0.11-0.12 0.15-0.17 0.30-0.32 และ 0.42-0.54 นิวตัน ตามลำดับ ซึ่งแสดงในรูปแบบแผนภูมิแท่งดังรูปที่ 4-6 หากพิจารณาเปรียบเทียบความแม่นยำในการทำนายแรงระหว่างแบบจำลองทางคณิตศาสตร์ที่พัฒนาจากทั้งสองอัลกอริทึมสามารถสรุปได้ว่าในขั้นตอนการทดสอบอัลกอริทึมแบบตามเวลาจริงของแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับทำนายแรงได้แม่นยำมากกว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีน ที่ระดับความต้านทานการเคลื่อนที่ 2 3 4 และ 5 นิวตัน ได้แก่ 9.73 18.24 6.04 และ 27.42 เปอร์เซ็นต์ตามลำดับ

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้ได้นำเสนอวิธีการพัฒนาแบบจำลองทางคณิตศาสตร์สำหรับการประมาณแรงกล้ามเนื้อในแนวแกน 1 มิติ ทั้งแบบออฟไลน์และแบบตามเวลาจริงจากสัญญาณไฟฟ้ากล้ามเนื้อโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีน ซึ่งในงานวิจัยมีการพัฒนาต้นแบบเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติซึ่งมีรูปแบบการช่วยบำบัดแบบแอกทีฟ และกำหนดรูปแบบการเคลื่อนที่ของแขนด้วยการเหยียดแขนและการงอแขน เพื่อพัฒนากล้ามเนื้อแขนในตำแหน่งไตรเซ็ปส์ อีกทั้งยังใช้สำหรับควบคุมพารามิเตอร์ที่ใช้เป็นเงื่อนไขในการทดลองและเก็บบันทึกข้อมูลเพื่อนำไปใช้พัฒนาแบบจำลองทางคณิตศาสตร์สำหรับทำนายแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อ รวมถึงมีการทดลองเบื้องต้นก่อนทำการทดลองจริงซึ่งประกอบด้วยการทดลองสอบเทียบเซ็นเซอร์ก่อนการนำมาใช้งานเพื่อให้สามารถตรวจวัดได้อย่างถูกต้องในสภาพแวดล้อมที่เกิดการใช้งานจริง ได้แก่ การสอบเทียบเซ็นเซอร์ตรวจวัดแรง การสอบเทียบเซ็นเซอร์ตรวจวัดรอบการหมุน และมีการทดลองเพื่อตรวจสอบความสัมพันธ์ระหว่างค่าคงที่แรงต้านทานการเคลื่อนที่และแรงต้านทานการเคลื่อนที่สำหรับกำหนดใช้เพื่อควบคุมแรงต้านทานการเคลื่อนที่ของเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ อีกทั้งยังมีการทดลองเพื่อตรวจสอบตำแหน่งตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อที่เหมาะสม โดยพิจารณาถึงตำแหน่งที่เกิดการเปลี่ยนแปลงของสัญญาณไฟฟ้ากล้ามเนื้อจากท่าทางแขนและแรงบีบนิ้วมือน้อยกว่าและเกิดการเปลี่ยนแปลงของสัญญาณไฟฟ้ากล้ามเนื้อจากแรงกระทำในรูปแบบการผลักมากกว่า ซึ่งเปรียบเทียบที่สองตำแหน่งได้แก่ กล้ามเนื้อส่วน Forearm muscle และ Biceps/Triceps muscles พบว่ากล้ามเนื้อส่วน Forearm muscle เหมาะสมสำหรับติดตั้งเพื่อตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อมากกว่ากล้ามเนื้อส่วน Biceps/Triceps muscles ตลอดจนมีการทดลองเพื่อตรวจสอบจำนวนชุดข้อมูล (Sample size) ที่ใช้สำหรับการคำนวณคุณลักษณะเฉพาะของข้อมูลที่เหมาะสม โดยพิจารณาจากจำนวนชุดข้อมูลที่ให้ความแม่นยำในการทำนายแรงมากที่สุดและใช้เวลาในการคำนวณน้อย ซึ่งมีการกำหนดใช้จำนวนชุดข้อมูลในการทดลองได้แก่ 50 100 150 และ 200 ชุด พบว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีการทั้งสองมีแนวโน้มแม่นยำมากขึ้นเมื่อใช้จำนวนชุดข้อมูล (Sample size) เพิ่มขึ้น

จนกระทั่งถึงค่าๆ หนึ่งที่จำนวนชุดข้อมูล 150 และ 200 ชุด ซึ่งให้ความแม่นยำใกล้เคียงกัน แต่อย่างไรก็ตามหากใช้จำนวนชุดข้อมูล (Sample size) มากขึ้นเวลาในการประมวลผลก็จะมากขึ้นด้วย ส่งผลให้เกิดความล่าช้าในการประมวลผลกล้ามเนื้อ ดังนั้นในงานวิจัยนี้จะเลือกใช้จำนวนชุดข้อมูล (Sample size) คือ 150 ชุดข้อมูลต่อการคำนวณ 1 ชุดคุณลักษณะ จากนั้นจึงทำการทดลองเพื่อตรวจสอบปัจจัยที่มีผลต่อประสิทธิภาพของแบบจำลองทางคณิตศาสตร์ในการประมวลผลกล้ามเนื้อ และเปรียบเทียบแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยวิธีโครงข่ายประสาทเทียมและวิธีซัพพอร์ตเวกเตอร์แมชชีนด้วยชุดข้อมูลที่ได้รับจากระบบในการเคลื่อนที่ 1 มิติ โดยผู้เข้าร่วมการทดลองจำนวน 10 คน ประกอบด้วย ผู้เข้าร่วมการทดลองสุขภาพดีเพศชาย 4 คน อายุระหว่าง 23-28 ปี มีน้ำหนักระหว่าง 65-84 กิโลกรัม และผู้เข้าร่วมการทดลองสุขภาพดีเพศหญิง 6 คน อายุระหว่าง 21-33 ปี มีน้ำหนัก 43-62 กิโลกรัม ซึ่งการทดลองประมวลผลกล้ามเนื้อจะแบ่งออกเป็น 2 รูปแบบ ได้แก่ แบบออฟไลน์และแบบตามเวลาจริง ซึ่งในงานวิจัยนี้จะแบ่งการทดลองประมวลผลกล้ามเนื้อแบบออฟไลน์ออกเป็น 2 การทดลอง และการทดลองประมวลผลกล้ามเนื้อแบบตามเวลาจริง 1 การทดลองผลการทดลองซึ่งแสดงค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยซึ่งบ่งบอกถึงความคลาดเคลื่อนระหว่างแรงที่ได้จากการตรวจวัดและแรงที่ได้จากการทำนาย แสดงให้เห็นว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้อัลกอริทึมทั้งสองสามารถทำนายแรงแบบตามเวลาจริงทดแทนการใช้เซ็นเซอร์ตรวจวัดแรงได้จริงโดยมีความคลาดเคลื่อนในการทำนายแรงไม่เกิน 15 เปอร์เซ็นต์ ภายใต้การเคลื่อนที่ด้วยความเร็วการเคลื่อนที่ไม่เกิน 0.1 เมตรต่อวินาที ที่ระดับความต้านทานการเคลื่อนที่ไม่เกิน 5 นิวตัน อีกทั้งยังพบว่าความแม่นยำในการทำนายแรงจะเป็นปฏิภาคผกผันกับความต้านทานการเคลื่อนที่และความเร็วในการเคลื่อนที่ต่ำลง และแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับให้ผลการทำนายแรงที่แม่นยำมากกว่าแบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีน

5.2 ปัญหาและแนวทางแก้ไข

1) ในขั้นตอนการเก็บข้อมูลซึ่งจำเป็นต้องตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อพบว่ามีความผิดพลาดในการเก็บข้อมูลซึ่งเนื่องมาจากความล้าของกล้ามเนื้อแขนเมื่อออกแรงต่อเนื่องเป็นระยะเวลานาน ดังนั้นเพื่อแก้ไขปัญหานี้จึงมีการเว้นช่วงพักฟื้นเพื่อให้กล้ามเนื้อแขนคลายความเมื่อยล้าก่อนที่จะทำการทดลองต่อไป

2) ในขั้นตอนการเก็บข้อมูลซึ่งผู้เข้าร่วมการทดลองจำเป็นต้องผลักด้ามจับไปยังจุดสิ้นสุด (End point) พบว่าระยะช่วงแขนของผู้เข้าร่วมการทดลองแต่ละคนแตกต่างกัน ซึ่งผู้เข้าร่วมการทดลองต้องยื่นแขนมากเกินกว่าระยะช่วงแขนของตนอาจทำให้เกิดความผิดพลาดในตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อเนื่องจากท่าทางแขน ดังนั้นเพื่อแก้ไขปัญหาลักษณะนี้จึงมีการกำหนดให้ผู้เข้าร่วมการทดลองยื่นแขนไปจนสุดระยะแขนของผู้เข้าร่วมการทดลองเท่านั้น

3) ในขั้นตอนการเก็บข้อมูลซึ่งผู้เข้าร่วมการทดลองต้องผลักด้ามจับให้เคลื่อนที่ด้วยความเร็วคงที่ใกล้เคียงความเร็วจุดอ้างอิงการเคลื่อนที่ ซึ่งเป็นเรื่องยากสำหรับผู้เข้าร่วมการทดลองที่ยังไม่คุ้นชินในการควบคุมแรงผลักให้คงที่ต่อด้ามจับที่กำลังเคลื่อนที่อาจทำให้เกิดความผิดพลาดในการเก็บข้อมูลเนื่องมาจากสัญญาณไฟฟ้ากล้ามเนื้อที่ไม่คงที่ตามแรงผลักของผู้เข้าร่วมการทดลอง ดังนั้นเพื่อแก้ไขปัญหาลักษณะนี้ในงานวิจัยนี้มีการกำหนดให้ผู้เข้าร่วมการทดลองใช้งานระบบเคลื่อนที่ 1 มิติจนกระทั่งคุ้นชินก่อนทำการทดลองจริง

5.3 แนวทางการพัฒนาต่อไป

1) พัฒนาแบบจำลองทางคณิตศาสตร์สำหรับทำนายแรงกล้ามเนื้อให้สามารถทำนายแรงกล้ามเนื้อได้ในหลายมิติมากยิ่งขึ้น

2) ประยุกต์ใช้แบบจำลองทางคณิตศาสตร์สำหรับทำนายแรงกล้ามเนื้อในรูปแบบต่างๆ เพื่อทดแทนการใช้เซ็นเซอร์ตรวจวัดแรงหลายแกนซึ่งมีราคาแพงและยากต่อการพกพา เช่น การใช้แบบจำลองทางคณิตศาสตร์เพื่อทำนายแรงกับอุปกรณ์ทางการทำกายบำบัดฟื้นฟูกล้ามเนื้อแขน การใช้แบบจำลองทางคณิตศาสตร์ เพื่อทำนายแรงกับการสื่อสารระหว่างมนุษย์กับหุ่นยนต์ เป็นต้น

3) จากการทดลองจากการทดลองประมาณแรงกล้ามเนื้อแบบออฟไลน์โดยเปลี่ยนแปลงความต้านทานการเคลื่อนที่ของด้ามจับในหัวข้อที่ 4.3 พบว่าที่ระดับความต้านทานการเคลื่อนที่ 4 และ 5 นิวตัน แบบจำลองทางคณิตศาสตร์ที่พัฒนาโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน เป็นเรเดียลเบซิสฟังก์ชัน (Radial basis function : RBF) และฟังก์ชันพหุนาม (Polynomial function) มีความแม่นยำในการทำนายแรงมากขึ้นขณะที่แบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับและวิธีซัพพอร์ตเวกเตอร์แมชชีนซึ่งใช้เคอร์เนลฟังก์ชัน เป็นฟังก์ชันเชิงเส้น (Linear function) มีความแม่นยำในการทำนายแรงน้อยลง ดังนั้นจึงเป็นหัวข้อที่น่าสนใจเพื่อตรวจสอบสาเหตุของแนวโน้มดังกล่าวในอนาคต

4) ประยุกต์ใช้วิธีการลดคุณลักษณะเด่นของข้อมูลอินพุตในการพัฒนาแบบจำลองทางคณิตศาสตร์ซึ่งสามารถช่วยลดเวลาในการประมวลผลข้อมูล อีกทั้งช่วยลดอุปกรณ์ในการเก็บข้อมูลที่เกี่ยวข้อง จากการศึกษาแนวโน้มเบื้องต้นพบว่าค่าแรงบีบนิ้วมืออาจจะเป็นพารามิเตอร์หนึ่งที่สามารถละไว้ ดังนั้นหากสมมติฐานเป็นจริงก็จะสามารถลดข้อจำกัดในการใช้งานอุปกรณ์เฉพาะแขนข้างขวา เนื่องจากไม่มีการใช้งานเซ็นเซอร์ตรวจวัดแรงบีบนิ้วมือ แต่ในงานวิจัยนี้ได้มีการทดลองเบื้องต้นเพื่อลดจำนวนข้อมูลอินพุตที่ใช้ โดยใช้ข้อมูลอินพุตในการพัฒนาแบบจำลองทางคณิตศาสตร์เพื่อทำนายแรงแบบออฟไลน์ ได้แก่ สัญญาณไฟฟ้ากล้ามเนื้อที่ช่องสัญญาณ 1 2 3 7 และ 8 พบว่าไม่มีความแตกต่างอย่างมีนัยสำคัญในแง่ของ เวลาในการฝึกสอน และความแม่นยำในการทำนายเมื่อเปรียบเทียบกับแบบจำลองทางคณิตศาสตร์ซึ่งพัฒนาโดยไม่ลดจำนวนข้อมูลอินพุต อย่างไรก็ตามการประยุกต์ใช้วิธีการลดคุณลักษณะเด่นของข้อมูลอินพุตในการพัฒนาแบบจำลองทางคณิตศาสตร์เพื่อทำนายแรงแบบตามเวลาจริงเป็นหัวข้อที่น่าสนใจเพื่อศึกษาโดยละเอียดเพิ่มเติมในอนาคต

อ้างอิง

- [1] P. K. Artemiadis and K. J. Kyriakopoulos, “EMG-Based Control of a Robot Arm Using Low-Dimensional Embeddings,” *IEEE Trans. Robot.*, vol. 26, no. 2, pp. 393–398, Apr. 2010.
- [2] Fengjun Bai and Chee-Meng Chew, “Muscle force estimation with surface EMG during dynamic muscle contractions: A wavelet and ANN based approach,” in *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka, 2013, pp. 4589–4592.
- [3] P. Konrad, “A Practical Introduction to Kinesiological Electromyography,” p. 61.
- [4] F. Mobasser and K. Hashtrudi-Zaad, “Hand Force Estimation using Electromyography Signals,” in *Proceedings of the 2005 IEEE International Conference on Robotics and Automation*, Barcelona, Spain, 2005, pp. 2631–2636.
- [5] J. Hashemi, E. Morin, P. Mousavi, and K. Hashtrudi-Zaad, “Enhanced Dynamic EMG-Force Estimation Through Calibration and PCI Modeling,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 23, no. 1, pp. 41–50, Jan. 2015.
- [6] S. Zhang et al., “Muscle Strength Assessment System Using sEMG-Based Force Prediction Method for Wrist Joint,” *J. Med. Biol. Eng.*, vol. 36, no. 1, pp. 121–131, Feb. 2016.
- [7] C. Choi, S. Kwon, W. Park, H. Lee, and J. Kim, “Real-time pinch force estimation by surface electromyography using an artificial neural network,” *Med. Eng. Phys.*, vol. 32, no. 5, pp. 429–436, Jun. 2010.
- [8] Peerayuth Saekow Paramin Neranon and Pruittikorn Smithmaitrie, “A Newly Design of a Portable Rehabilitation Robot for Upper Limb,” in *Proceeding of the International Conference on Mechanical Engineering*, 2018.
- [9] N. Zarzycka and S. Zaluska, “[Measurements of the forearm i inhabitants of the Lublin region],” *Ann. Univ. Mariae Curie Sklodowska [Med.]*, vol. 44, pp. 85–92, 1989.

- [10] W. Kaewboon, P. Phukpattaranont, and C. Limsakul, "Upper limbs rehabilitation system for stroke patient with biofeedback and force," in The 6th 2013 Biomedical Engineering International Conference, Amphur Muang, Krabi, Thailand, 2013, pp. 1–5.
- [11] Peerayut Saekow, "An Autonomous Assistive Robot for Upper Limb Rehabilitation," Prince of SongKla University, 2018.
- [12] D. D. MRIDHA and <https://www.kernelbd.com>, "EMG," DR. DEBASISH MRIDHA. [Online]. Available: <http://drmridtha.com/services/emg>. [Accessed: 26-Oct-2019].
- [13] Joseph Goodgold and Arthur Eberstein, *Electrodiagnosis of neuromuscular diseases*. 1972.
- [14] A. J. R. (Ph D.), *Clinical Electrophysiology: Electrotherapy and Electrophysiologic Testing*. Lippincott Williams & Wilkins, 2008.
- [15] "Artificial neural network," Wikipedia. 21-Oct-2019.
- [16] "Machine learning," Wikipedia. 20-Oct-2019.
- [17] N. N. Punnee Sittidech, "Using Support Vector Machine and Back Propagation Neural Network for Classification of Ischemic Heart Disease and other Forms of Heart Disease," in *Proceedings of The 4th Science Research Conference*, 2012, pp. 69–74.
- [18] "Pulse-width modulation," Wikipedia. 25-Oct-2019.
- [19] A. Winkler and J. Suchý, "Implicit Force Control of a Position Controlled Robot – A Comparison with Explicit Algorithms," vol. 9, no. 6, p. 7, 2015.
- [20] J. Salisbury, "Active stiffness control of a manipulator in cartesian coordinates," in *1980 19th IEEE Conference on Decision and Control including the Symposium on Adaptive Processes*, Albuquerque, NM, USA, 1980, pp. 95–100.
- [21] N. Hogan, "Impedance Control: An Approach to Manipulation," in *1984 American Control Conference*, San Diego, CA, USA, 1984, pp. 304–313.
- [22] R. Volpe and P. Khosla, "A theoretical and experimental investigation of explicit force control strategies for manipulators," *IEEE Trans. Autom. Control*, vol. 38, no. 11, pp. 1634–1650, Nov. 1993.

- [23] M. H. Raibert and J. J. Craig, "Hybrid Position/Force Control of Manipulators," *J. Dyn. Syst. Meas. Control*, vol. 103, no. 2, pp. 126–133, Jun. 1981.
- [24] J. De Schutter and H. Van Brussel, "Compliant Robot Motion II. A Control Approach Based on External Control Loops," *Int. J. Robot. Res.*, vol. 7, no. 4, pp. 18–33, Aug. 1988.
- [25] "Myo Gesture Control Armband tech specs," Welcome to Myo Support. [Online]. Available: <http://support.getmyo.com/hc/en-us/articles/202648103-Myo-Gesture-Control-Armband-tech-specs>. [Accessed: 27-Oct-2019].
- [26] "Lighting Plus LED Power supply switching 12V 10A 120W." [Online]. Available: <https://www.thianthong.com/lighting-plus-led-power-supply-switching-12v-10a-120w.html>. [Accessed: 28-Oct-2019].
- [27] TechXcite.com, "Notebook: Acer Aspire S3 Ultrabook," TechXcite.com, 06-Sep-2011. [Online]. Available: <https://www.techxcite.com/topic/6902.html>. [Accessed: 28-Oct-2019].
- [28] "Hiwin motion control and system : products HGH35CA." [Online]. Available: https://www.hiwin.de/en/Products/Linear_Guideways/Series_HG_QH/4268. [Accessed: 28-Oct-2019].
- [29] "2GT-20 Teeth Aluminum Timing Pulley Wheel 5mm Inner For 3D Printer." [Online]. Available: <https://www.daraz.com.bd/products/creality-3d-2gt-20-teeth-aluminum-timing-pulley-wheel-5mm-inner-for-3d-printer-i114594516-s1032210232.html/>. [Accessed: 28-Oct-2019].
- [30] "DC 12V High Torque Electric Gear Box Motor Speed Reduction." [Online]. Available: <https://www.daraz.pk/products/-i102524636-s1248315682.html/>. [Accessed: 28-Oct-2019].
- [31] Banggood.com, "Small Scale Load Cell Weighing Pressure Sensor With HX711," www.banggood.com. [Online]. Available: <https://fr.banggood.com/5Pcs-5KG-Small-Scale-Load-Cell-Weighing-Pressure-Sensor-With-AD-HX711AD-Adapter-p-1136341.html>. [Accessed: 28-Oct-2019].
- [32] "Limit Switch – Estore Oman." .

- [33] “NIB Omron Rotary Encoder E6B2-CWZ6C 5-24VDC 1200P/R - Free Shipping - ThanksBuyer.” [Online]. Available: <https://www.thanksbuyer.com/nib-omron-rotary-encoder-e6b2-cwz6c-5-24vdc-1200p-r-22960>. [Accessed: 28-Oct-2019].
- [34] “Force sensitive resistor 0.5 inches,” aliexpress.com. [Online]. Available: https://th.aliexpress.com/item/32841242867.html?src=ibdm_d03p0558e02r02&sk=&aff_platform=&aff_trace_key=&af=&cv=&cn=&dp=. [Accessed: 28-Oct-2019].
- [35] “High Quality Passive Buzzer Module,” Micro Products, 30-Nov-2016. [Online]. Available: <http://www.microproducts.net/products/high-quality-passive-buzzer-module-for-arduino-new-diy-kit/>. [Accessed: 28-Oct-2019].
- [36] W. Developer, “The Official Arduino MEGA 2560 Schematics Diagram | 14core.com.” .
- [37] G. BALUTA, “OPEN-LOOP CONTROL OF A BIPOLAR STEPPER MOTORS USING THE SPECIALIZED INTEGRATED CIRCUITS,” *Ann. Dunarea Jos*, vol. 2004, Dec. 2004.
- [38] “HiLetgo BTS7960 43A High Power Motor Driver Module.” [Online]. Available: <https://www.amazon.com/HiLetgo-BTS7960-Driver-Arduino-Current/dp/B00WSN98DC>. [Accessed: 28-Oct-2019].
- [39] A. Phinyomark, C. Limsakul, and P. Phukpattaranont, “EMG denoising estimation based on adaptive wavelet thresholding for multifunction myoelectric control,” in *2009 Innovative Technologies in Intelligent Systems and Industrial Applications*, Kuala Lumpur, Malaysia, 2009, pp. 171–176.
- [40] A. Phinyomark, C. Limsakul, and P. Phukpattaranont, “EMG Signal Estimation Based on Adaptive Wavelet Shrinkage for Multifunction Myoelectric Control,” p. 6.
- [41] A. Phinyomark, S. Hirunviriyaya, C. Limsakul, and P. Phukpattaranont, “Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation,” p. 5.
- [42] K. Veer and T. Sharma, “A novel feature extraction for robust EMG pattern recognition,” *J. Med. Eng. Technol.*, vol. 40, no. 4, pp. 149–154, May 2016.


- [43] A. Phinyomark, M. Phothisonothai, C. Limsakul, and P. Phukpattaranont, "DETRENDED FLUCTUATION ANALYSIS OF ELECTROMYOGRAPHY SIGNAL TO IDENTIFY HAND MOVEMENT," p. 7, 2009.
- [44] A. Phinyomark, M. Phothisonothai, C. Limsakul, and P. Phukpattaranont, "Effect of Trends on Detrended Fluctuation Analysis for Surface Electromyography (EMG) Signal," p. 7.
- [45] C. Jensen, O. Vasseljen, and R. H. Westgaard, "Estimating maximal EMG amplitude for the trapezius muscle: On the optimization of experimental procedure and electrode placement for improved reliability and increased signal amplitude," *J. Electromyogr. Kinesiol.*, vol. 6, no. 1, pp. 51–58, Mar. 1996.
- [46] P. Neranon, "Human-Robot Interaction using a Behavioural Control Strategy," p. 268.
- [47] A. Alqahtani and A. Whyte, "Estimation of life-cycle costs of buildings: regression vs artificial neural network," *Built Environ. Proj. Asset Manag.*, vol. 6, no. 1, pp. 30–43, Feb. 2016.

ภาคผนวก


ภาคผนวก ก.

ข้อมูลจำเพาะเครื่องมือทำกายภาพบำบัดกล้ามเนื้อแขนใน 1 มิติ (Specification)


ตาราง ก-1 รายละเอียดของเซ็นเซอร์ตรวจวัดแรง (Loadcell)

	Model	YZC-131
	Material	Aluminium
	Operating Voltage	Maximum Operating Voltage: 10 VDC
		Recommended: 5 VDC
	Dimensions in mm (LxWxH)	75 x 12.7 x 12.7
	Weighing Range	0~3 kg
	Rated Output	1.0 ± 0.1mV / V
	Non Linear Output	± 0.03% F.S
	Hysteresis	0.03% F.S
	Repeatability	0.03% F.S
	Creep	(5 minutes) 0.05% F.S
	Cable Length	18 cm
	Zero Balance	± 0.1 mV / V
	Input Impedance	1066 ± 10% Ω
	Output Impedance	1000 ± 10% Ω
	Operating Temperature Range	-21° ~ 40° C
Weight (gm)	27	
Protection	IP65	
Insulation Resistance	2000 MΩ	


ตาราง ก-2 รายละเอียดของมอเตอร์กระแสตรง 12 โวลท์

	Name	DC Geared Motor
	Rated Voltage	DC 12V
	Output Speed	150, 300 RPM
	Shaft Diameter	6mm
	Gearbox Part Diameter	37mm
	Motor Part Diameter	34.5mm
	Total Length (Approx.)	80mm
	Material	Metal, Electronic
	Color	Silver Tone
	Weight	196g


ตาราง ก-3 รายละเอียดของวงจรรีบมอเตอร์ L298N

	Driver Model	L298N 2A
	Driver Chip	Double H Bridge L298N
	Motor Supply Voltage (Maximum)	46V
	Motor Supply Current (Maximum)	2A
	Logical Voltage	5V
	Driver Voltage	5-35V
	Driver Current	2A
	Logical Current	0-36mA
	Maximum Power (W)	25W
	Length (mm)	44 mm
	Width (mm)	44 mm
	Height (mm)	28 mm
	Weight (Kg)	25 gm

ตาราง ก-4 รายละเอียดของวงจรขับมอเตอร์ IBT-2


	Input voltage (V)	6 – 27
	Maximum current (A)	43
	Input level (V)	3.3 – 5
	Duty cycle	0 – 100%
	Path resistance	16 m Ω at 25°C.
	Low quiescent current	7 μ A at 25°C
	Operating Frequency (kHz)	25
	Dimensions (mm)	50 x 50 x 43
	Weight (gm)	67

ตาราง ก-5 รายละเอียดของไมโครคอนโทรลเลอร์ Arduino Mega 2560


	Model Type	Arduino MEGA 2560
	Microcontroller Chip	ATmega2560
	Operating Voltage	5V
	Input Voltage (Recommended)	7V to 12V
	Input Voltage (limit)	6V-20V
	Analog I/O Pins	16
	Digital I/O Pins	54 (of which 15 provide PWM output)
	Clock Speed	16 MHz
	Flash Memory	256 KB of which 8 KB used by bootloader
	SRAM	8 KB
	EEPROM	4 KB
	DC Current for 3.3V Pin	50 mA

	DC Current per I/O Pin	40 mA
	Dimensions in mm (LxWxH)	102x54x14
	Weight (gm)	34


ตาราง ก-6 รายละเอียดของพูลเลย์ GT2

	Material	Aluminium
	Inner Diameter (ID) (mm)	6
	Outer Diameter (OD)(mm)	16
	No. of teeth	20
	Weight (gm)	6

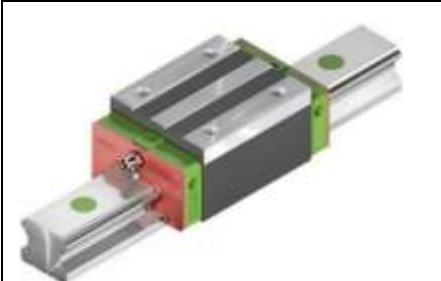
ตาราง ก-7 รายละเอียดของลำโพงบี๊เซอร์ (Buzzer module)

	Operating Voltage	DC 3.3~5.5 V
	Wire Length(mm)	200
	Length (mm)	33
	Width (mm)	14
	Height (mm)	12
	Weight (gm)	6


ตาราง ก-8 รายละเอียดของเซ็นเซอร์ตรวจวัดแรงบีบ (Force sensor resistor)

	Shape	Circular
	Sensing Area diameter (mm)	14
	Min Pressure	100 gm
	Max Pressure	10 Kg
	Diameter (mm)	18
	Length (mm)	60
	Weight (gm)	2

ตาราง ก-9 รายละเอียดของรางสไลด์ (Linear rail)


	Model	HGR30R1000H
	Material	Stainless Steel
	Bearing Material	Stainless Steel
	Dimensions in mm (LxWxH)	1000 x 28 x 26
	Weight (gm)	4470

ตาราง ก-10 รายละเอียดของเซ็นเซอร์ตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Myo armband)


	Arm size (in)	Expandable between 7.5 - 13 forearm circumference
	Weight (gm)	93
	Thickness (in)	0.45
	Sensors	Medical Grade Stainless Steel EMG sensors, Highly sensitive nine-axis IMU containing three axis gyroscope, three axis accelerometer, three-axis magnetometer
	LEDs	Dual Indicator LEDs
	Processor	ARM Cortex M4 Processor
	Haptic Feedback	Short, Medium, Long Vibrations

ภาคผนวก ข.


ส่วนประกอบของเครื่อง




รูปที่ ข-1 ส่วนประกอบของเครื่อง




รูปที่ ข-2 ฐานรองรับเซ็นเซอร์ตรวจวัดแรง (Loadcell)




รูปที่ ข-3 รอก (Reel)




รูปที่ ข-4 ชุดครอบวงจรควบคุม




รูปที่ ข-5 รางสไลด์ขนาด 30 มิลลิเมตร (Linear rail)




รูปที่ ข-6 ชุดครอบวงจรถาวรจัดแรง



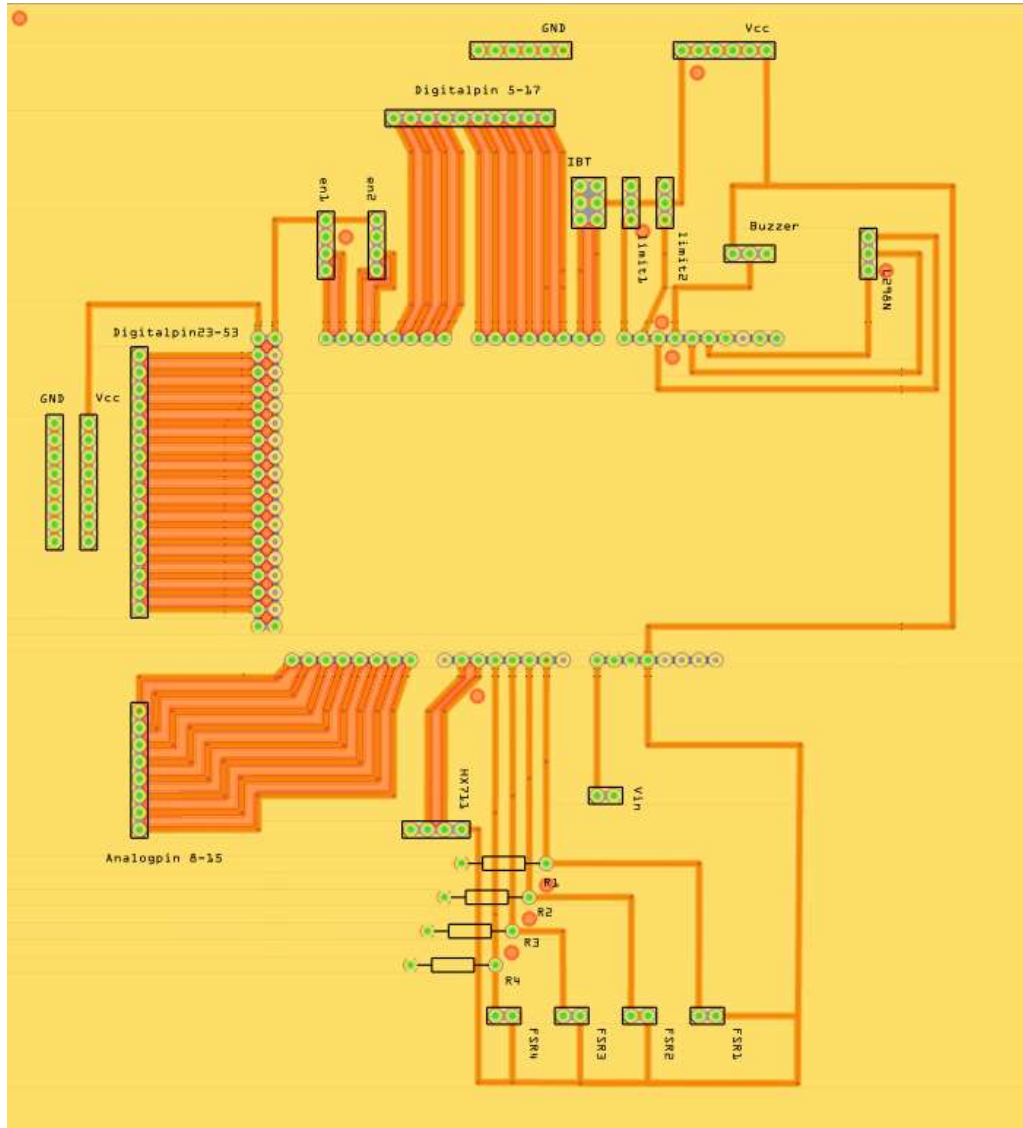
รูปที่ ข-7 ฐานเครื่อง



รูปที่ ข-8 มู่เต๋ย 20 ฟันรุ่น GT2



รูปที่ ข-9 ด้ามจับ



รูปที่ ข-10 วงจรควบคุม

ภาคผนวก ค.

บทความทางวิชาการ

บทความวิชาการเรื่อง Muscle Force Estimation with Surface Electromyography in Upper Limb Stroke Rehabilitation ซึ่งได้แนบไว้ข้างล่างโดยบทความนี้ได้รับการตอบรับในที่ประชุมวิชาการระดับชาติ การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 32 ระหว่างวันที่ 3 – 6 กรกฎาคม 2561

บทความวิชาการเรื่อง EMG – based Force Estimation for Dynamic Muscle Contractions in Physical Human-Robot Interaction ซึ่งได้แนบไว้ข้างล่างโดยบทความนี้อยู่ในขั้นตอน การพิจารณาบทความเพื่อการตีพิมพ์เผยแพร่ในวารสารทางวิชาการ Journal of Mechanical Engineering Research and Developments

AMM – 178 การประชุมวิชาการเครื่องช่วยวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 32

3 – 6 กรกฎาคม 2561 จังหวัดมุกดาหาร



การประมาณแรงกล้ามเนื้อด้วยคลื่นไฟฟ้ากล้ามเนื้อในการทำกายภาพบำบัดกล้ามเนื้อแขน

Muscle Force Estimation with Surface Electromyography In Upper Limb Stroke Rehabilitation

ธนัท ธนอัศวพล*, ปริณันท์ เณรานนท์, ภาสกร เวลสะโกศล และ พรชัย พงศ์ภักดิ์ทรานนท์

ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ 15 ด.กาญจนวนิชย์ อ.หาดใหญ่ จ.สงขลา 90110

*ติดต่อ: index_nat@hotmail.com, 074-287035

บทคัดย่อ

การประมาณแรงของกล้ามเนื้อมนุษย์เป็นสิ่งสำคัญในการศึกษาด้านชีวกลศาสตร์และอุปกรณ์ช่วยทำกายภาพบำบัด ดังนั้นจุดมุ่งหมายของบทความนี้เพื่อพัฒนาอัลกอริทึมที่มีประสิทธิภาพในการประมาณแรงจากกล้ามเนื้อมนุษย์แทนการใช้เซ็นเซอร์ตรวจวัดแรง/แรงบิดหลายแกนเพื่อประยุกต์ใช้กับหุ่นยนต์ช่วยในการฟื้นฟูสมรรถภาพ โดยได้นำวิธีโครงข่ายประสาทเทียม (ANN) มาใช้ในการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ (EMG) ของกล้ามเนื้อแขนมนุษย์ที่ตรวจวัดโดยใช้สายรัดข้อแขน Myo ที่มีช่องวัดสัญญาณ 8 ช่องและอัตราการสุ่มตัวอย่าง 200 เฮิร์ตซ์ วิธีโครงข่ายประสาทเทียม (ANN) ได้รับการสอนโดยใช้สัญญาณไฟฟ้ากล้ามเนื้อและแรงกระทำที่วัดได้จากเซ็นเซอร์แรง / แรงบิดหลายแกน โดยผู้ทดลองออกแรงเคลื่อนไหวที่วัดได้ในระดับแรงที่แตกต่างกัน 2, 4, 6, 8, 10 นิวตัน ซึ่งวัดจากเซ็นเซอร์แรง/แรงบิดหลายแกนที่ติดตั้งไว้กับวัตถุ พร้อมกับเก็บค่าและแสดงกราฟของสัญญาณไฟฟ้ากล้ามเนื้อตลอดการทดลองในแต่ละระดับแรง ในการศึกษาวิธีโครงข่ายประสาทเทียมได้ถูกนำมาใช้เพื่อทำนายแรงจากกล้ามเนื้อที่แตกต่างกันของผู้เข้าร่วมทดลอง 20 คน จากนั้นจึงคำนวณความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) ระหว่างแรงจากการทำนายและแรงที่วัดได้ เพื่อตรวจสอบอัลกอริทึมผลการทดลองแสดงให้เห็นว่าประสิทธิภาพของวิธีการที่นำเสนอสามารถยอมรับได้ในการทำนายแรงกล้ามเนื้อมนุษย์เพื่อประยุกต์ใช้ในหุ่นยนต์ช่วยในการฟื้นฟูสมรรถภาพ

คำหลัก: การประมาณแรงกล้ามเนื้อ, MYO armband, สัญญาณไฟฟ้ากล้ามเนื้อ, โครงข่ายประสาทเทียม

Abstract

Human muscle force estimation is crucial in biomechanics studies and assistive rehabilitation devices fields. The aim of this paper is therefore to develop an efficient algorithm to estimate force exerted by human muscles in the robotic assisted rehabilitation instead of using multi-axis force/torque sensor. Artificial neural networks (ANN) approach was successfully implemented to classify the electromyography (EMG) signals of human's hand muscles obtained through a Myo™ armband with 8 channels of EMG electrodes with the sampling rate of 200 Hz. Each electrode provides information regarding muscles contraction performed during the execution of the movement. The artificial neural networks (ANN) approach was trained by EMG signals and measured forces which were adopted by the ATI Gamma multi-axis force/torque sensor. A set of experiments was carried out in which an object attached by the multi-axis force/torque sensor is located on a rectilinear bar. A human participant was required to push and pull the object in various constant applied forces of 2, 4, 6, 8, 10 N along with simultaneous capturing and monitoring of the forearm EMG signals. Twenty healthy participants were randomly recruited in this study and subsequently ANN was utilized to predict the individual muscle forces. By using root mean square error (RMSE) to validate the proposed model, experimental results illustrated that the performance of the proposed method can be acceptable for prediction the human applied force in upper-limb stroke rehabilitation.

Keywords: Muscle force estimation, MYO armband, Electromyography signal, Artificial neural network



1. บทนำ

ประเทศไทยมีสาเหตุการเสียชีวิตหรือพิการจากโรคหลอดเลือดในสมองตีบตันสูงเป็นอันดับ 3 ในผู้ชายและอันดับ 2 ในผู้หญิงและยังมีแนวโน้มเพิ่มขึ้นเรื่อย ๆ [1] ดังนั้นการศึกษาระบบการช่วยฟื้นฟูสมรรถภาพกล้ามเนื้อของผู้ป่วยโดยนำเทคโนโลยีมาประยุกต์ใช้ร่วมกับการแพทย์จึงเป็นสิ่งจำเป็น ปัจจุบันศูนย์วิจัยและบริษัทต่าง ๆ ได้มีการพัฒนาหุ่นยนต์ในการฟื้นฟูกล้ามเนื้อแขนและขาของผู้ป่วยโดยอาศัยการเคลื่อนที่ซ้ำ ๆ เพื่อช่วยกระตุ้นและฟื้นฟูกล้ามเนื้อแขนผู้ป่วย แต่หุ่นยนต์อัตโนมัติสำหรับการฟื้นฟูกล้ามเนื้อแขนยังมีราคาสูง จึงมีใช้เฉพาะโรงพยาบาลใหญ่ ๆ จึงไม่เพียงพอต่อความต้องการ โดยส่วนประกอบของหุ่นยนต์อัตโนมัติสำหรับการฟื้นฟูกล้ามเนื้อแขน ส่วนหนึ่งที่มีราคาสูง คือ เซ็นเซอร์ตรวจวัดแรงกระทำ ซึ่งทำให้อุปกรณ์มีราคาสูงตามไปด้วย

สัญญาณไฟฟ้ากล้ามเนื้อ คือ ความต่างศักย์ทางไฟฟ้าของกล้ามเนื้อซึ่งเป็นผลรวมที่เกิดจากหลายๆ หน่วยของเซลล์กล้ามเนื้อ โดยเกิดจากการส่งงานของสมองผ่านทางเส้นประสาทที่ควบคุมกล้ามเนื้อ ในด้านการแพทย์สามารถใช้สัญญาณไฟฟ้าจากกล้ามเนื้อที่วัดได้จากตัวผู้ป่วยช่วยในการวินิจฉัยอาการผิดปกติที่เกิดขึ้น เช่น อาการของโรคที่เกิดจากเส้นประสาทสั่งการบาดเจ็บไม่สามารถควบคุมอวัยวะได้ เป็นต้น อาจกล่าวได้ว่าสัญญาณไฟฟ้ากล้ามเนื้อสามารถบ่งบอกกิจกรรมที่มนุษย์กระทำได้ ดังนั้นจึงมีงานวิจัยจำนวนมากที่ศึกษาความสัมพันธ์ระหว่างสัญญาณไฟฟ้ากล้ามเนื้อและแรงกล้ามเนื้อขึ้น เพื่อพัฒนาอัลกอริทึมสำหรับการประมาณแรงกล้ามเนื้อซึ่งเป็นประโยชน์สำหรับการพัฒนาอุปกรณ์ช่วยเหลือในการทำกายภาพบำบัดสำหรับผู้ป่วยที่จำเป็นต้องฟื้นฟูแขนโดยการทำการกายภาพบำบัด

สัญญาณไฟฟ้ากล้ามเนื้อสามารถตรวจวัดได้หลายวิธี เช่น ตรวจวัดโดยติดอิเล็กโทรด ซึ่งอาจเป็นชนิดเข็ม

(Needle electrode) หรือชนิดพื้นผิว (Surface electrode) ไว้ที่บริเวณกล้ามเนื้อเพื่อบันทึกค่า แต่ในงานวิจัยนี้มีการตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อจากปลอกแขนตรวจวัด (Myo Armband) เนื่องจาก มีความสะดวกในการติดตั้งและใช้งาน และตรวจวัดแรงที่เกิดขึ้นโดยใช้ เซ็นเซอร์วัดแรงหลายแกน (ATI Gamma multi-axis force/torque) ขณะออกกำลังกาย จากนั้นนำข้อมูลที่บันทึกได้มาคำนวณเพื่อหาลักษณะเด่นของสัญญาณไฟฟ้ากล้ามเนื้อ และแรงที่วัดได้เพื่อเป็นข้อมูลอินพุตและข้อมูลเป้าหมายสำหรับใช้สอนโครงข่ายประสาทเทียม ตามลำดับ สำหรับพัฒนาอัลกอริทึมเพื่อประมาณแรงกล้ามเนื้อ

ชนิดการหดตัวของกล้ามเนื้อสามารถแบ่งได้ตามลักษณะการเคลื่อนไหว 2 ชนิด คือ Static contraction ไม่มีการเคลื่อนไหวของข้อต่อให้เห็นแต่มีความตึงในกล้ามเนื้อ และ Dynamic contraction มีการเคลื่อนไหวของข้อต่อและมีความตึงในกล้ามเนื้อ

บทความนี้ศึกษาและนำเสนอวิธีการประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อขณะหดตัวแบบ Static contraction โดยพัฒนาอัลกอริทึมที่มีประสิทธิภาพในการประมาณแรงจากกล้ามเนื้อมนุษย์เพื่อประยุกต์ใช้กับหุ่นยนต์ช่วยในการฟื้นฟูสมรรถภาพ โดยได้นำวิธีโครงข่ายประสาทเทียม (ANN) มาใช้ในการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ (EMG) แบบ offline algorithm

A. Phinyomark และคณะ[5] ศึกษาความแม่นยำของวิธีการวัดลักษณะเด่นบนแกนเวลาและแกนความถี่ของสัญญาณ 15 วิธี พบว่าวิธี Wavelet length (WL), Root mean square (RMS), Willison amplitude (WAMP) ให้ความแม่นยำสูงสุด 3 อันดับ ตามลำดับ U.Naeem [3] ศึกษาเปรียบเทียบประสิทธิภาพของวิธีการประมาณแรงกล้ามเนื้อ โดยเปรียบเทียบระหว่างวิธี Fuzzy Muscle Force Estimator (NMFE) และ วิธี



Back-Propagation Artificial Neural Networks (BPANN) พบวิธี NMFE มีความเสถียรและรวดเร็วกว่าวิธี BPANN แต่ วิธีBPANN มีความซับซ้อนน้อยกว่า วิธี NMFE D.T.Maclsaac และคณะ[6] นำเสนอแนวทางสำหรับประเมินความล้าของกล้ามเนื้อโดยใช้ myoelectric signal (MES) และใช้วิธีโครงข่ายประสาทเทียมในการปรับค่าพารามิเตอร์อินพุทของฟังก์ชันซึ่งกำหนดค่าพารามิเตอร์ myoelectric ให้เป็นดัชนีความล้า พบว่า วิธีโครงข่ายประสาทเทียมแบบ Multi layer perceptron (MLP) สามารถสร้างฟังก์ชันสำหรับประเมินความล้าได้อย่างมีประสิทธิภาพ Andreia S. P. Sousa[7] ศึกษาและเปรียบเทียบข้อดีข้อเสีย และข้อจำกัดของวิธีการ electromyographic amplitude normalization U.Naeem และคณะ [4]ได้ศึกษาการประมาณแรงกล้ามเนื้อเนื่องจากสัญญาณ EMG โดยใช้วิธี Back Propagation Artificial Neural Networks (BPANN)โดยใช้ Rectified smooth electromyogram (RSEMG)ซึ่งสามารถประมวลผลได้จากสัญญาณไฟฟ้ากล้ามเนื้อเป็นอินพุทสำหรับประมาณแรงกล้ามเนื้อ โดยผลการประมาณแรงกล้ามเนื้อที่ได้จะถูกเปรียบเทียบกับแรงกล้ามเนื้อที่ได้จาก Hill-Type model เพื่อทดสอบประสิทธิภาพของแบบจำลองพบว่าวิธีการที่นำเสนอสามารถประมาณแรงกล้ามเนื้อได้อย่างมีประสิทธิภาพ

2. วิธีการดำเนินการ

2.1 การวัดลักษณะเด่นของสัญญาณ (Feature extraction)

สัญญาณไฟฟ้ากล้ามเนื้อสามารถตรวจวัดได้หลายวิธี และค่อนข้างมีความซับซ้อน ดังนั้นในการวิเคราะห์สัญญาณไฟฟ้ากล้ามเนื้อจึงได้มีการใช้วิธีการวัดลักษณะเด่นของสัญญาณไฟฟ้ากล้ามเนื้อด้วยวิธีต่าง ๆ เพื่อให้สัญญาณไฟฟ้ากล้ามเนื้อที่มีความซับซ้อนหลายค่า เหลือเพียงค่าตัวเลขที่สามารถนำมาเปรียบเทียบได้ โดยในงานวิจัยนี้ จะใช้ลักษณะเด่นเพื่อลดความซับซ้อน [2] ดังนี้

1. Root Mean Square (RMS) เป็นการหาค่ารากของค่าเฉลี่ยของกำลังสองของสัญญาณไฟฟ้ากล้ามเนื้อซึ่งสามารถคำนวณได้จากสมการ

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \rightarrow (1)$$

N = จำนวนข้อมูลตัวอย่าง

X_i = ข้อมูลตัวอย่างลำดับที่ i

2. Mean Absolute Value (MAV) เป็นการหาค่าเฉลี่ยของค่าสัมบูรณ์ของสัญญาณไฟฟ้ากล้ามเนื้อหรืออาจเรียกเป็นอย่างอื่นเช่น Integral of absolute value (IAV) ซึ่งสามารถคำนวณได้จากสมการ

$$MAV = \frac{1}{N} \sum_{i=1}^N |X_i| \rightarrow (2)$$

N = จำนวนข้อมูลตัวอย่าง

X_i = ข้อมูลตัวอย่างลำดับที่ i

3. Rate Root Mean Square เป็นสัดส่วนค่ารากของค่าเฉลี่ยของกำลังสองของสัญญาณไฟฟ้า แต่ละช่องสัญญาณต่อผลรวมทั้งหมดของสัญญาณ 8 ช่องซึ่งสามารถคำนวณได้จากสมการ

$$Rate\ RMS\ (n) = \frac{RMS(n)}{\sum_{n=1}^8 RMS(n)} \times 100 \rightarrow (3)$$

4. Rate Mean Absolute Value เป็นสัดส่วนค่าเฉลี่ยของค่าสัมบูรณ์ของสัญญาณไฟฟ้ากล้ามเนื้อ แต่ละช่องสัญญาณต่อผลรวมทั้งหมดของสัญญาณ 8 ช่องซึ่งสามารถคำนวณได้จากสมการ

$$Rate\ MAV\ (n) = \frac{MAV(n)}{\sum_{n=1}^8 MAV(n)} \times 100 \rightarrow (4)$$

2.2 ออกแบบการทดลอง

- ออกแบบการทดลองเพื่อเก็บค่าสัญญาณไฟฟ้ากล้ามเนื้อโดยออกแรงดึงและแรงผลักวัตถุอยู่ในระดับแรง 2, 4, 6, 8, 10 ตามลำดับ โดยเก็บข้อมูลในแต่ละระดับแรงจำนวน ระดับแรงละ 1000 ข้อมูล และออกแรงดึงและแรงผลักสลับกันต่อเนื่องตั้งแต่ 0-10 นิวตัน เก็บข้อมูล 6000 ข้อมูล โดยระหว่างการทดลอง เก็บค่าแรงบัพโดยใช้ Force sensor resistor ตลอดจนการทดลองและแจ้งเตือนผ่าน หลอดไฟ LED เมื่อแรงบัพมีค่า



มากกว่า 1 นิ้วต้น เพื่อลดความผิดพลาดจากสัญญาณไฟฟ้าซึ่งเกิดจากแรงบีบมือ



รูปที่ 1 แสดงแบบการทดลองสำหรับเก็บค่าสัญญาณไฟฟ้ากล้ามเนื้อ

- ออกแบบโปรแกรมและ Graphical user interface สำหรับเก็บค่าและคำนวณลักษณะเด่นของสัญญาณไฟฟ้ากล้ามเนื้อในการทดลอง เพื่อความสะดวกและรวดเร็วในการเก็บข้อมูลและประมวลผลข้อมูล โดย GUI มีฟังก์ชันสำหรับ พล็อตกราฟ แรง, แรงบีบ, สัญญาณไฟฟ้ากล้ามเนื้อ บันทึกผล และประมวลผล ซึ่งสามารถเปลี่ยนแปลงจำนวนข้อมูล (Window range) สำหรับคำนวณคุณลักษณะเด่นได้โดยบทความนี้เลือกใช้จำนวนข้อมูลในการคำนวณคุณลักษณะเด่นของสัญญาณไฟฟ้ากล้ามเนื้อจำนวน 200 ข้อมูล และคุณลักษณะเด่นของแรงและแรงบีบใช้วิธี Moving Average ในการคำนวณ



รูปที่ 2 แสดง GUI สำหรับเก็บค่าแรง, แรงบีบ, สัญญาณไฟฟ้ากล้ามเนื้อจากการทดลอง

- ติดตั้ง Myo armband สำหรับวัดสัญญาณไฟฟ้ากล้ามเนื้อซึ่งมีช่องวัดสัญญาณ 8 ช่อง และความเร็วในการเก็บข้อมูล 200 ข้อมูลต่อวินาที ที่บริเวณ Flexor carpi ulnaris แสดงดังรูปที่ 3




รูปที่ 3 แสดงตำแหน่งติดตั้งปลอกแขนตรวจวัดสัญญาณไฟฟ้ากล้ามเนื้อ [3]

2.3 EMG Signals processing

สัญญาณไฟฟ้ากล้ามเนื้อที่มีสัญญาณรบกวนอยู่ด้วยดังนั้นจึงต้องแยกสัญญาณรบกวนออกเพื่อให้ได้สัญญาณไฟฟ้ากล้ามเนื้อที่ถูกต้องสำหรับการประมาณแรงกล้ามเนื้อ โดยในงานวิจัยนี้เลือกใช้การประมวลผลสัญญาณโดยการผ่านวงจรกรองความถี่สูงผ่าน (25 Hz) จากนั้นสัญญาณจะถูกแก้ไขโดยค่าสัมบูรณ์เพื่อเปลี่ยนสัญญาณค่าลบเป็นค่าบวกแล้วจึงผ่านวงจรกรองความถี่ต่ำผ่าน (9 Hz) สัญญาณที่ได้จากการประมวล เรียกว่า Rectified smooth EMG signal (RSEMGs) ซึ่งใช้เป็นอินพุตสำหรับโครงข่ายประสาทเทียมเพื่อประมาณค่าแรงกล้ามเนื้อต่อไป



รูปที่ 4 แสดงขั้นตอนการประมวลผลสัญญาณไฟฟ้ากล้ามเนื้อ [3]




รูปที่ 5 บล็อกไดอะแกรมการประมวลผลสัญญาณไฟฟ้ากล้ามเนื้อ [3]

2.4 Artificial neuron network

โครงข่ายประสาทเทียมถูกสร้างขึ้นโดยเลียนแบบการทำงานของสมองมนุษย์ซึ่งมีการทำงานแบบขนานจำนวนมาก ในงานวิจัยนี้เลือกใช้วิธีโครงข่ายประสาทเทียมเพื่อพัฒนาอัลกอริทึมสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อโดยใช้โครงข่าย




ประสาทเทียมแบบเพอร์เซปตรอนหลายชั้น (Multi-layer perceptron Neural Network) หรือโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Feed Forward Back-Propagation Neural Network) ซึ่งเป็นโครงข่ายประสาทเทียมที่ต้องการสอน (Supervised Learning)



รูปที่ 6 แสดงส่วนประกอบโครงข่ายประสาทเทียม

พารามิเตอร์	จำนวน/ประเภท
จำนวนอินพุต	36
จำนวนรอบ	1000
Hidden layer	2 hidden layer
Nodes hidden layer	16
Function hidden layer 1	Log-sigmoid (Log-sig)
Function hidden layer 2	Log-sigmoid (Log-sig)
Function output layer	Linear (Purelin)

รูปที่ 7 แสดงค่าพารามิเตอร์ที่กำหนดใช้กับโครงข่ายประสาทเทียม



รูปที่ 8 แสดงขั้นตอนการประมวลผลสัญญาณไฟฟ้ากล้ามเนื้อเพื่อประมาณแรงกล้ามเนื้อ [4]


โดยค่าพารามิเตอร์ที่กำหนดใช้กับโครงข่ายประสาทเทียมในงานวิจัยนี้ได้ทดลองปรับค่าโดยวิธีลองผิดลองถูก (Trial and error) โดยพิจารณาถึงความแม่นยำในการทำนายและเวลาที่ใช้ในการประมวลผลเพื่อความเหมาะสมสำหรับอัลกอริทึมสำหรับประมาณแรงกล้ามเนื้อจากสัญญาณไฟฟ้ากล้ามเนื้อ

3. ผลการทดลอง

3.1 การสอนโครงข่ายประสาทเทียม

Supervised Learning การเรียนแบบมีการสอนเป็นการเรียนแบบที่มีการตรวจคำตอบเพื่อให้โครงข่ายประสาทเทียมปรับตัว ชุดข้อมูลที่ใช้สอนโครงข่ายประสาทเทียมจะมีคำตอบไว้คอยตรวจสอบว่าโครงข่ายประสาทเทียมให้คำตอบที่ถูกต้องหรือไม่ ถ้าคำตอบไม่ถูก โครงข่ายประสาทเทียมก็จะปรับตัวเองเพื่อให้ได้คำตอบที่ดีขึ้น


ในงานวิจัยนี้ใช้สัญญาณ RSEMG ซึ่ง หาได้จากสัญญาณ EMG และค่าเฉลี่ยแรงบีบจากวิธี Moving average เป็นอินพุตสำหรับสอนโครงข่ายประสาทเทียม และใช้ค่าเฉลี่ยแรงจากวิธี Moving average เป็นเป้าหมายสำหรับสอนโครงข่ายประสาทเทียม ซึ่งการสอนโครงข่ายประสาทเทียมจะแบ่งข้อมูลออกเป็น 3 ส่วน คือ Training, Validation และ Test เป็นสัดส่วน 70,15,15 เปอร์เซ็นต์ ตามลำดับโดยข้อมูล Training ใช้เพื่อสอนโครงข่ายประสาทเทียม Validation ใช้เพื่อตรวจสอบความถูกต้องโครงข่ายประสาทเทียม Test ใช้เพื่อทดสอบโครงข่ายประสาทเทียม โดยความแม่นยำในการสอนโครงข่ายประสาทเทียมสามารถดูได้จาก Performance และ Regression หลังจากเสร็จสิ้นกระบวนการสอน




รูปที่ 9 กราฟความสัมพันธ์ระหว่างประสิทธิภาพและจำนวนรอบระหว่างการสอน



รูปที่ 9 แสดงถึงค่า Performance ซึ่งบ่งบอกถึงความผิดพลาดระหว่างข้อมูลเอาท์พุทจากโครงข่ายประสาทเทียมและข้อมูลเป้าหมายในระหว่างการสอนจนสิ้นสุดการสอนซึ่งในงานวิจัยนี้เลือกใช้ Performance แบบ Mean square error ซึ่งในการทดลองครั้งนี้หลังจากสอนโครงข่ายประสาทเทียมเสร็จสิ้น มีค่า Performance อยู่ที่ 0.005



รูปที่ 10 กราฟแสดง Regression ของข้อมูลเป้าหมาย
รูปที่ 10 แสดงถึงค่า Regression โดยบ่งบอกถึงความแม่นยำของข้อมูลเอาท์พุทจากโครงข่ายประสาทเทียมเทียบกับข้อมูลเป้าหมาย ซึ่งในการทดลองครั้งนี้หลังจากสอนโครงข่ายประสาทเทียมเสร็จสิ้น มีค่า Regression ของข้อมูล training, validation, test อยู่ที่ 0.99



รูปที่ 11 แสดงกราฟเปรียบเทียบระหว่างแรงจากการวัดและแรงจากการประมาณโดยโครงข่ายประสาทเทียม
รูปที่ 11 กราฟเปรียบเทียบแรงจากการวัดและแรงจากการประมาณโดยใช้โครงข่ายประสาทเทียมในการทดลองออกแรงต่อเนื่องแบบคิงและผลก็สลับกันที่ระดับแรง 0-10N โดยใช้ค่า Root mean square error เพื่อ

บ่งบอกความผิดพลาดของข้อมูล ซึ่งการทดลองนี้มีค่า RMSE อยู่ที่ 0.06



รูปที่ 12 แสดงกราฟเปรียบเทียบระหว่างแรงจากการวัดและแรงจากการประมาณโดยโครงข่ายประสาทเทียม
รูปที่ 12 กราฟเปรียบเทียบแรงจากการวัดและแรงจากการประมาณโดยใช้โครงข่ายประสาทเทียมในการทดลองออกแรงคงที่ในระดับแรง 2, 4, 6, 8, 10 นิวตัน โดยใช้ค่า Root mean square error เพื่อบ่งบอกความผิดพลาดของข้อมูล ซึ่งการทดลองนี้มีค่า RMSE อยู่ที่ 0.005

4. สรุปผล

งานวิจัยนี้ศึกษาการใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับเพื่อประมาณแรงของกล้ามเนื้อ โดยใช้ลักษณะเด่นของสัญญาณ RSEMG ที่ผ่านการประมวลผลจากสัญญาณไฟฟ้ากล้ามเนื้อและแรงจากการวัดเป็นอินพุตและเป้าหมายสำหรับสอนโครงข่ายประสาทเทียมตามลำดับ ผลลัพธ์แสดงให้เห็นว่าการประมาณแรงกล้ามเนื้อโดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับมีความแม่นยำใกล้เคียงค่าแรงจากการวัดในแบบออนไลน์ แต่ยังมีข้อจำกัดในเรื่องความเร็วในการเก็บข้อมูลและประมวลผลสำหรับนำไปต่อยอดเพื่อพัฒนาอัลกอริทึมประมาณแรงแบบต่อเนื่องตามเวลาจริง (Real-time)



5. กิตติกรรมประกาศ

งานวิจัยเรื่องการประมาณแรงกล้ามเนื้อด้วยคลื่นไฟฟ้ากล้ามเนื้อในการทำกายภาพบำบัดกล้ามเนื้อแขนเกิดขึ้นได้จากทุนสนับสนุนงานวิจัยและทุนโครงการปริญญาตรี-โท 5 ปี สำหรับนักศึกษาระดับปริญญาโทจากมหาวิทยาลัยสงขลานครินทร์ และขอขอบคุณ รศ.ดร.พรชัย พุกพงษ์ทรานนท์, ดร.ปรมินทร์ เณรานนท์ และ ผศ.ดร.ภาสกร เวสสุขโกศล อาจารย์ที่ปรึกษา ที่ช่วยให้คำปรึกษาและแนะนำแก่งานวิจัยในเรื่องต่าง ๆ

6. อ้างอิง

- [1] . <http://www.thaincd.com/information-statistic/non-communicable-disease-data.php>
- [2]. K. Wansitta, Ph. Pornchai, and L. Chusuk "Upper Limbs Rehabilitation System for Strock Patient with Biofeedback and force", Biomedical Engineering International Conference (BMEICON-2013)
- [3]. U. Naeem, "Artificial Simulation Models to Estimate Muscle Force & Fatigue" , 2014 LAP Lambert Academic Publishing
- [4]. U.J.Naeem, C. Xiong and A. A. Abdullah, "EMG-muscle force estimation model based on back-propagation neural network" , 2012 IEEE International Conference on Virtual Environments Human-Computer Interfaces and Measurement Systems (VEHIMS) Proceedings, Tianjin, 2012, pp. 222-227.
doi: 10.1109/VEHIMS

- [5]. A. Phinyomark, S. Hirunviriya, C. Limsakul and P. Phukpattaranont, "Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation," ECTI-CON2010: The 2010 ECTI International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, Chiang Mai, 2010, pp. 856-860.
- [6]. D. T. MacIsaac, P. A. Parker, K. B. Englehart and D. R. Rogers, "Fatigue estimation with a multivariable myoelectric mapping function," in *IEEE Transactions on Biomedical Engineering*, vol. 53, no. 4, pp. 694-700, April 2006. doi: 10.1109/TBME.2006.870220
- [7]. Sousa Andreia SP, and Joao Manuel RS Tavares. "Surface electromyographic amplitude normalization methods: a review." *Electromyography: New Developments, Procedures and Applications* (2012).

EMG – based Force Estimation for Dynamic Muscle Contractions
in Physical Human-Robot Interaction

Tanat Tanausavaphol¹, Paramin Neranon^{1}, Passakorn Vessakosol¹, Pornchai Phukpattaranont²*

¹Department of Mechanical Engineering, Faculty of Engineering
Prince of Songkla University, Songkhla, Thailand

²Department of Electrical Engineering, Faculty of Engineering
Prince of Songkla University, Songkhla, Thailand

Corresponding: paramin.n@psu.ac.th

Abstract: Electromyography is a method in the field of electrodiagnostic medicine for monitoring and assessing the electrical activity generated by skeletal muscles themselves. As reviewed, the study of human force estimation based on Electromyographical signals is such a crucial challenge, since it is further complicated by the dynamic nature of the human subject. Consequently, this paper aims to develop an effective algorithm to roughly approximate the human hand applied force during executing rectilinear-motion-machine interaction, in which a test influence variable, namely friction force against the object movement, was additionally exerted. This mathematical algorithm will be further implemented in a newly designed rehabilitation robot using EMG muscle force estimation instead of applying a costly multi-axis force/torque sensor. Artificial neural networks and Support vector machine approaches were successfully applied to distinctly classify the electromyography signals of human's hand muscles detected by eight-channel EMG electrodes. After the set of tests was carried out, root mean square error was individually utilized to evaluate the quantitative performance of each technique. The experimental results illustrated that both approaches were considered acceptable for EMG-based force estimation for dynamic muscle contractions by indicating that the human applied force was validly estimated based on the EMG signals. Additionally, it can be implied that the more the resistant force applied against the object movement, the lower the force model estimated performance.

Keywords: *Electromyography, Muscle force estimation, Artificial neural networks, Support vector machine, Human-robot interaction*

Introduction

Robots are being used more frequently in everyday life tasks (e.g., service robots, robots for clinical applications or industrial robots). Robots have been typically programmed by operators to execute a sequence of predefined functions; however, the new generation of smart robots have been designed to further increase flexibility and to share their workspaces with humans in aiming for complex task improvement. The chief requirement of human-robot interaction (HRI) is to facilitate robots to be able to physically interact and work naturally with humans in a safe and reliable manner. Secondly, the robots themselves should be able to decide their task priority or action levels that can allow them to interact with humans in a timely and speedy manner [1–3].

Stroke is a primary cause of death and the leading cause of permanent disability in adults. There are many stroke survivors, who live with a variety of levels of disability and always need rehabilitation activities on a daily basis. Based on the study of HRI, our research group then promoted an upper-limb rehabilitation robot to provide the improvement of physical functions of stroke patient's muscles. The robot can function like therapists, who actively help patients with exercise-based upper limb rehabilitation with two functions consisting of active and passive therapy. However, a multi-axis force/torque sensor is expensive; subsequently, to overcome the limitation, EMG-muscle force estimation for HRI in the robot-assisted rehabilitation task has been carried out and detailed throughout the paper.

The electromyography is often used as input signals for robot control, such as, in the application of robots for rehabilitation or HRI, which requires the assessment of muscle force from human movements. Therefore, finding an algorithm approach to mathematically determine the force caused by muscle under dynamic muscle contractions is a challenge study. Most of the robot-assisted rehabilitation equipment often uses muscle force to stimulate the movement of the device for treatment of patient users. However, as reviewed, the methods for measuring the individual human muscle force almost require costly multi-axis force sensors [4]. Then to overcome this problem, force estimation using EMG signals is one of the best solutions and significantly leads to cost efficiency. The EMG signals reflect the electrical activity of skeletal muscles and contain information about the structure and function of muscles which particularly make different parts of the body move [5]. Therefore, EMG can be used to predict human muscle force in HRI with strong probability. However, due to the complexity of the electromyography investigation in human muscles, various techniques of detecting the EMG characteristics have been introduced in different ways to an effective EMG measuring system [6].

Linear or nonlinear relationships between EMG and muscle force under the isometric muscle contractions were discovered, in which the joint angle and muscle length do not change during contractions, such as contracting, standing, pushing the wall, etc. Research [7–9] conducted the studies which are the significant steps of muscle force estimation relating to the development of intuitive human- assistive robot interface using EMG, prediction of handgrip forces based on forearm muscle EMG signals, or study of effects of muscle length and tension on rapid isometric contractions using frequency response. Nevertheless, the relationship between the electromyography and muscle force is more complex due to muscle properties, such as the different length of muscles, the speed of muscle flexion and extension or the measuring locations to place EMG sensors[10–12]. However, as extensive review, there are few studies relating to the estimation of human muscle force during dynamically performing human-robot interactive tasks due to the complicated muscular skeleton system, and there is no research paper in consideration of the relationship of the EMG – based force estimation for dynamic muscle contractions in a HRI object manipulating task and variable frictions applied against the object movement. This requires kinetics and muscle dynamics data precisely measured by a set of accurate EMG sensors in order to adopt a good way for a muscle force forecasting under dynamic contractions.

The aim of this paper is, therefore, to develop an efficient algorithm to estimate force exerted by human muscles under dynamic muscle contractions from the EMG signals using an artificial neural network (ANN) and support vector machine (SVM). Both techniques were appropriately executed to examine the complex relationship between muscle force applied to the HRI system and the EMG signals in less complicated. As reviewed, the advantages of both algorithms are high performance and can be productively used with error-prone data sets; the SVM scheme also has more advantages in terms of less over-fitting problems. However, both methods still have some disadvantages in the use of time for long training and the parameters used for training are complex [13–16]. Subsequently, this study additionally explains how to achieve a suitable number of the sample size of training data in HRI. The details are organized in the following sections.

System Design of One-DOF Human-Robot Interaction

Conceptual Design and Test Procedure of One-DOF Human-Machine Interaction

In order to achieve the above objective, the HRI experiment has been conducted to mimic the object manipulating in a one-dimensional axis. A set of one-DOF rectilinear motion machine interaction was initially designed and mainly employed in the study of muscle force estimation of the human arm using surface EMG sensors as depicted in Figure 1. A set of ten human samples were randomly selected to undertake the experiments and first asked to naturally move the object placed on the linear rail in a constrained horizontal path along with various frictions

against the movement applied. The external friction has been exerted to the object movement, and it can be varied from 2-5 N with 1 N resolution. Since there is a significant difference among the lengths of human upper limbs, then the test rig allows the object to be horizontally moved up to around 40 cm. The research [17] reported that the average length of the right arm ends of the males is approximately in the range of 20 to 30.5 cm and women's arm lengths are in the range between 19 and 31 cm [17].



Figure 1: One-DOF rectilinear motion test rig

The schematic block diagram of the test is shown in Figure 2. A one-dimensional force sensor measures the human force applied. A set of grasping force sensors was mounted on the handle in order to detect an individual finger pressing force because the higher the amplitude in grasping force, the inferior the effectiveness of the real-time EMG recording system. The grasping force allowed in the test is between 0.8-1.2 N, and this range of squeezing force was delivered by preliminary tests. If each of the human finger force is higher or lower than the threshold, a buzzer module will be activated to alert the human subject. The speed of object manipulating was strictly set to a constant velocity of 0.1 m/s along with a velocity guide for the human movement measuring by an encoder.

In addition, the HRI experiments also require a linear rail used as a base for the object horizontal movement, two limit switches utilized to limit the object's movement, and a MYOArmband with 8-channel EMG sensors to measure the EMG signals around the human forearm in real-time. Finally, a set of relevant data is used to calculate the set of features shown in Figure 3, consisting of human arm EMG signals, human force applied to the object, grasping force, frictional force, and object displacement and its corresponding velocity were simultaneously captured and monitored under the system control unit. The recorded information (i.e. in samples and out samples) was further used respectively in training and testing the proposed ANN and SVM algorithms. This can be explained using a flowchart diagram illustrated in Figure 4.




Figure 2: Schematic of experimental structure setup.




Figure 3: Block diagram of the data set used for calculating the feature set in the experiments.

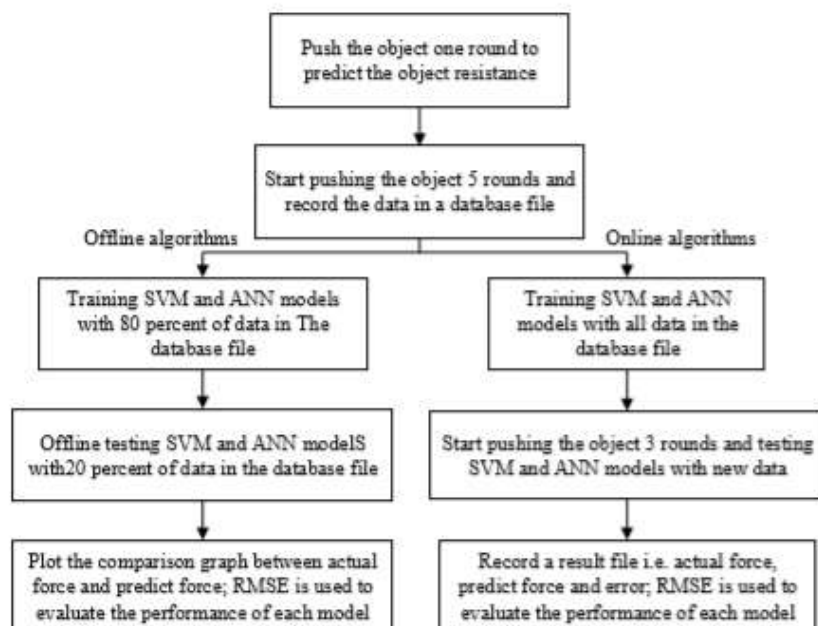


Figure 4: Block diagram of the experimental procedure for data analysis.

According to the experimental procedure, the group of ten participants were randomly selected to perform the HRI tests and initially required to become familiar with the test rig before executing the real tests with 4-5 repetitions. Each human is asked to sit down in comfortable positions in front of the test rig and perform all assigned tasks to the best of their capacity. Only one hand is allowed to grasp the handle with appropriate squeeze force, and twisting or bending the device is not allowed. An individual subject has to push the object towards the endpoint with a constant velocity of 0.1 m/s in the constrained path, according to the movement reference point. To ensure effective data collecting, they have to execute 5 repetition sets of each variable frictional force magnitude applied against the movement. The relevant information was recorded in real-time and divided into two groups made up of an in-sample group (80% of data for online and offline algorithm-training developments) and out-sample group (20% of the data for evaluating the estimated algorithms). Contrastingly, the online feature training was used all measured information. The final step involves the evaluation of ANN and SVM methods in terms of accuracy of the human muscle force estimation using Root Mean Square Error (RMSE) by comparing between the predictive and measured force values based on both on-line and off-line training techniques.

Human muscle force estimation base on ANN and SVM approaches

As mentioned previously, the artificial neural network and support vector machine techniques were used in the prediction of human muscle force. ANN is a mathematical model that mimics biological neural networks, which consists of multiple layers connected together in the model. Each layer has a processing unit which is called a neuron. Layer types are as follows: the input layer which is a layer for importing the initial data into the system for further processing by subsequent layers of artificial, the hidden layer is a layer for learning of artificial neurons by taking in a set of weighted inputs and produce an output through an activation function and, finally the output layer is a layer for produces given outputs [18]. Backpropagation algorithms are a method that is widely used in the training of neural networks (ANNs) effectively according to the gradient descent approach that takes advantage of chain rules. Main features of backpropagation are its iterative, recursive and efficient method for calculating its weights updates to improve the network until it is able to perform the task that has been trained.

The learning algorithm is made up of (1) starting randomly setting the initial network parameters (weights w_{ij} and biases b_j), (2) taking a sample set of input data and then passing them through the designed network to obtain the prediction, (3) comparing these predictions obtained with the target values and calculating the loss function between both of them, (4) performing backpropagation to disseminate this loss to each and every one of the parameters that construct the neural network model, (5) executing this disseminated information to update the

model parameters of the ANN using gradient descent in a manner to reduce total loss for the better ANN model, (6) continuing iterating the previous steps until a good model has been successfully adopted [19].

Support Vector Machine (SVM) is a supervised learning algorithm that is widely used for classification or regression challenges. The purpose of the SVM algorithm is to find the hyperplane in the N -dimensional space (N - number of features) that clearly separates the data point. By separating two classes of data points, there are many possible hyperplanes which can be suitably selected as depicted in Figure 5. The objective of the algorithm is to find the plane with the maximum margin to efficiently distinguish both classes.

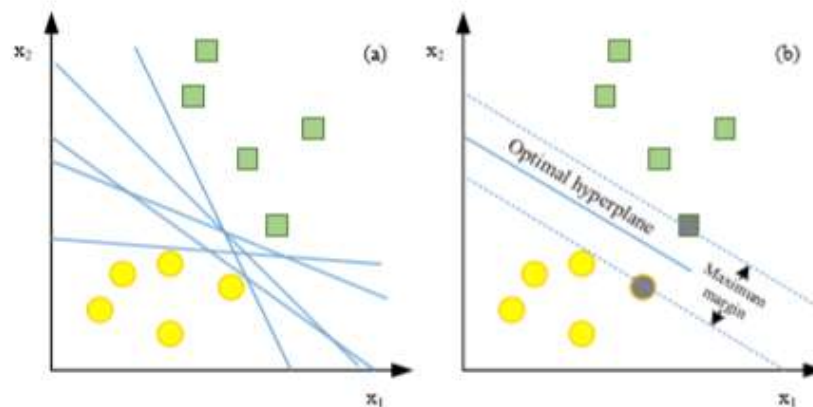


Figure 5: (a) Possible hyperplanes. (b) Optimal hyperplane.

In SVM, it is easy to have a linear hyper-plane between these two classes, but another burning question which arises is, should we need to add this feature manually to have a hyper-plane. SVM has a new technique called the kernel trick. These are functions to transform a low dimensional input space to be a higher-dimensional space. This method is most useful in non-linear separation problems, and engages with complex data transformations, by seeking out the process to significantly separate the data based on the labels or outputs defined.

Pilot Study of the HRI Object manipulating tasks

The pilot study is a small experiment in which the test results and statistical analysis are collected before the appropriate large-scale experiment is conducted. The pilot study in this research consists of two experiments, with the objective to determine the appropriate location for the installation of a sensor to measure the forearm EMG signals and the appropriate sample size to calculate the features. These can be expressed as follows:

1) Amplitudes of EMG signals are regulated relying on many influent factors, and one of the important parameters that makes the difference is the locations of the EMG sensor installation. There are several studies relating electrode sensor locations, such as the research of Chris Jensen et al. [20]. It described the difference in

the EMG amplitude when installing electrodes in different positions on the trapezius muscle bundle while stretching arms and bending arms. Therefore, in this experiment, the objective is to determine the appropriate location for the installation of the MYO 8-channel electrode armband by considering the two significant positions of the upper-limb i.e. the forearm muscles and Biceps/Triceps muscles due to both muscle bundles have mainly changed while performing pulling/pushing the object. It displays in Figure 6, and by considering the EMG electrode locations, two preliminary tests have been undertaken and explained below.




Figure 6: The position of the sensor installation (a) Forearm muscle (b) Biceps/Triceps muscles (c) MYO armband channels position [21].

Preliminary I determines the relations of the different human upper-limb postures precisely influencing through the EMG muscle signals recorded from the human forearm and Biceps/Triceps muscles when the human subject performs pulling and pushing the non-moving object placed on the linear rail of the test rig. The human was initially asked to apply the constant interactive force at 10 N throughout the tests. By realizing the various arm's postures based on the elbow flexion and extension, each subject has to be asked to undertake the HRI tests at the start point toward end point respectively. Additionally, to evaluate the distinct EMG signals in each scenario, RMSE was then employed.

The experimental results showed that RMSE values of the 8-channel EMG electrode signals from both forearm and Biceps/Triceps muscles had distinct EMG profiles in different ways. After careful analysis with regard to the results, the RMSE differences captured at the Biceps/Triceps muscles, while pushing and pulling the static object, were slightly represented superior to those of the forearm location as illustrated in Figure 7. As reviewed, it can be claimed that the lower the changes in the EMG magnitudes of several upper-limb postures, the more the

qualitative performance of the EMG-based force prediction [22]. This is because the study of the relation between the applied forces directly affecting the muscle EMG measurement, without attention paid to human arm postures, has been primarily investigated. Therefore, the EMG MYO armband was suggested to be specifically installed at the human forearm.

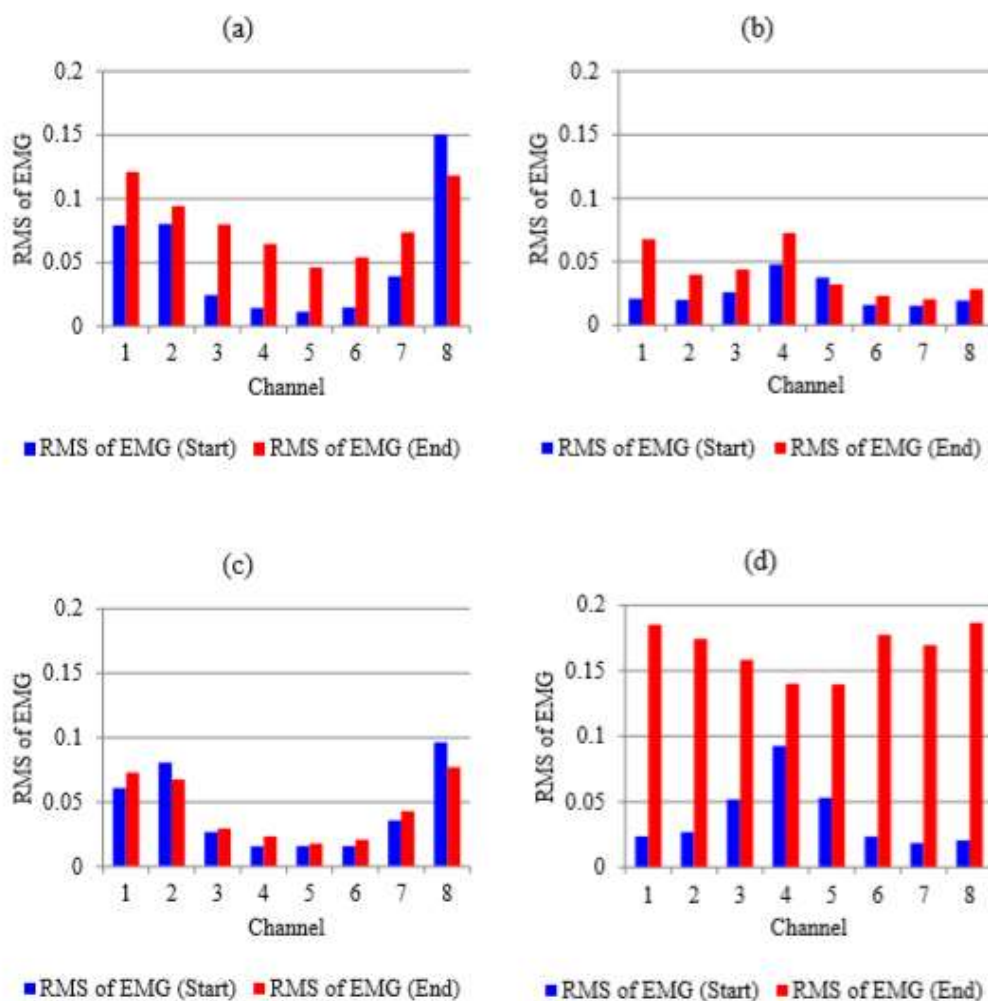


Figure 7: RMS values of the EMG signals when pulling/pushing the object at the start and end points. (a). pushing the object with measuring at the forearm muscles (b). pushing the object with measuring at the Biceps/Triceps muscles (c). pulling the object with measuring at the forearm muscles (d). pulling the object with measuring at the Biceps/Triceps muscles

Preliminary II analyses the effects of hand squeeze force exerted to the handle and the muscle EMG signal regulation can be captured from the human forearm and Biceps/Triceps positions again, while the object is fixed at the endpoint.

Each participant was required to execute the tests by firstly grasp the object with a constant squeeze force of roughly 0.8-1.2 N and loosely grasp the handle. The experimental outcomes reported that there were significant differences while applying the grasping force and without squeeze force in both conditions of mounting the EMG electrodes at the forearm and Triceps/Biceps locations. This can be clearly seen in Figure 8.




Figure 8: RMS values of the EMG signals when squeezing objects at end point. (a). EMGs measured at the forearm muscles (b). EMGs measured at the Biceps/Triceps muscles

Therefore, the recommendations carried out from the pilot study suggest that the MYO electrode sensors should be mounted around the forearm muscles. It is a crucial aspect to strictly bind the human grasping force as recommended (approximately 0.8-1.2 N). This completely used throughout the substantive main HRI object manipulating tests in order to adopt an effective human muscle EMG magnitudes.

2) In the full-scale experimental design, the number of samplesize for calculating the features of the force prediction algorithms should be sufficient to give effectively significant results. Theoretically, it would be as more as possible, since a higher number of data samples utilized in the feature classification are likely to give a more precise prediction of the date; however, it will take much longer to complete the training process. Therefore, this experiment aimed to determine the sample size which is appropriate for determining the features of the muscle force data in training and testing the ANN and SVM algorithms. By comparing the predictive accuracy at the

sample sizes of 50, 100, 150 and 200, again RMSE between the estimated human force and measured force was used to present the investigation of the relationship of the number of samples affecting the model prediction accuracy. The experimental results are shown in Table 1 and graphed in Figure 9

Table 1: The RMSE values of both algorithms at the sample sizes of 50, 100, 150, and 200

Algorithms	Sample size = 50		Sample size = 100		Sample size = 150		Sample size = 200	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
RMSE ANN	0.196	0.440	0.088	0.213	0.064	0.130	0.047	0.126
RMSE SVM	0.202	0.336	0.092	0.173	0.063	0.125	0.048	0.121




Figure 9 The RMSE line graphs of both algorithms at the sample sizes of 50, 100, 150 and 200.

It can be clearly seen that the ANN and SVM algorithms are more accurate when the sample sizes increase, until the RMSE values of the sample sizes were assigned at 150 and 200 samples which remain rather similar. However, as reviewed, too high sample size could cause the feature extraction process to be slightly delayed. It can be noted that this system has a sampling rate of 100Hz, so the process time of one feature set in each sample size is shown in Table 2. Therefore, as shown in the table, it can be summarized that the most effective point of the test is the samples selection 150, and this is because it offers less processing time than that of the 200 samples. Furthermore as the system has a relatively small sampling rate, the overlapping segmentation technique was used to calculate the features by sliding one data per a feature set to increase the efficiency of the system to work continuously in real time.

Table 2: the process time of one feature set at the sample size of 50, 100, 150, and 200.

Sample size	Process time (second)
50	0.5
100	1
150	1.5
200	2

Experimental results

ANN and SVM model specifications

Feedforward back-propagation neural network (BPNN) was used in this research to estimate the human exerted forces while interacting with the HRI rectilinear object moving tasks using the muscle EMG signals based on the off-line and on-line algorithm trainings. The BPNN approach requires supervised learning, where the accuracy of a predictive model respects to the training data and the numbers of relative parameters. The following table summarizes the BPNN model configuration. These were strategically achieved and optimized based on a set of trial and error experiments in the range of hidden layer nodes from 15 to 20 by taking benchmarks of the predictive accuracy measurement and processing time.

Table 3: Parameters to be employed in the neural network training

Parameters	Amount / Type
Number of inputs	23
Number of epochs	1000
Number of hidden layers	1
Nodes hidden layer	20
Transfer function of hidden layer 1	Linear (Identify)
Transfer function of output layer	Linear (Identify)

The SVM technique was subsequently implemented for the dynamic muscle force estimation using both off-line and on-line trainings in order to deliver the comparison of the ANN/SVM forecasting performance. The SVM kernel function was initially defined and made up of radial basis functional, linear, and polynomial models for both off-line data training and algorithm testing. However, the on-line algorithm teaching only engaged with the specifically radial basis function model as a result of processing time reduction to be concerned.

Human muscle force estimation results based on ANN and SVM approaches

A set of ten human samples were required to participate with the rectilinear-motion-machine interaction by manipulating the object on the linear rail in the constrained path along with various frictions (2-5 N) exerted. The experimental results are categorized into two main sections, i.e. off-line and on-line training sections. During performing the tasks, the hand grasping force and the object speed were strictly monitored. By evaluating the qualitative performance of the ANN and SVM techniques in terms of accuracy of the human muscle force estimation, Table 4 shows the comparison computed from RMSE values of the ANN and SVM approaches under the frictional forces of 2,3,4 and 5 N, and their corresponding standard deviation were carried out in Table 5. These can be plotted in Figure 10. The blue bar charts indicate the RMSE of the force estimation based on ANN,

where the orange, gray and yellow bars show RMSE of the force estimation using the radial basis function-based SVM, linear function-based SVM and polynomial function-based SVM respectively.

By considering the tendency of the algorithm's accuracy, it is clearly seen that the less frictional force levels applied to the test rig offered more accurate estimation carried out by both ANN and SVM. The ANN outcomes under the applied resistance of 2 and 3 N were similar to results calculated using the SVM scheme with the range of 0.05-0.15 N. Contrastingly, at frictions of 4 and 5 N, the SVM algorithm was slightly shown more accurate than the ANN in all scenarios, in which the ranges of the RMSE values based on SVM and ANN were approximately 0.2-0.33 N and 0.34-0.36 N. After being carefully analysed, the quantitative measurement of the performance of both methods can be considered acceptable for the EMG-based force estimation; however, the SVM with the radial basis function kernel optimizely provided the lowest RMSE magnitudes in the conditions of 4 and 5 frictional forces applied.

Table 4: RMSE values of the ANN and SVM approaches using the offline training under the various movement frictional forces

Classifier	friction = 2 N		friction = 3 N		friction = 4 N		friction = 5 N	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.053	0.087	0.058	0.112	0.108	0.360	0.272	0.345
RBF	0.056	0.087	0.061	0.121	0.135	0.273	0.175	0.200
Linear	0.050	0.078	0.053	0.113	0.122	0.329	0.129	0.328
Polynomial	0.099	0.117	0.076	0.141	0.148	0.275	0.164	0.215

Table 5: Standard deviation of the ANN and SVM approaches using the offline training under the various movement frictional force

Classifier	friction = 2 N		friction = 3 N		friction = 4 N		friction = 5 N	
	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%	Train80%	Test20%
ANN	0.012	0.037	0.007	0.065	0.032	0.188	0.319	0.163
RBF	0.012	0.019	0.008	0.060	0.029	0.078	0.085	0.011
Linear	0.010	0.026	0.010	0.054	0.038	0.135	0.050	0.154
Polynomial	0.020	0.041	0.008	0.065	0.030	0.079	0.071	0.065




Figure 10: The relationship between the RMSE magnitudes of the force model estimation using ANN and SVM to the frictional forces exerted against the object movement

According to the on-line algorithm training, the same procedure and human participants of the rectilinear object manipulating tasks were again undertaken to provide evaluating of the performance of the ANN and SVM in human force prediction. As the results delivered in the previous substantive tests, in which radial basis kernel-based SVM was reported the most superior performance while having offline training, these tests then allowed only the comparison of the ANN and radial basis function-based SVM strategies. Table 5 illustrates the RMSE values of the ANN and SVM approaches under the several constrained resistances which can be roughly explained in Figure 11. The blue and orange bar charts show the RMSE values by comparing between the predictive and measured force amplituded based on the ANN and SVM using the radial basis function kernel respectively. The results of the on-lining technique show that the qualitative performance of the force prediction techniques is inversely proportional to the magnitude of frictional force applied to the system. Careful observation revealed that the performance of the ANN and SVM with on-line algorithm training are accepted for the human muscle force prediction in the physical HRI test. Additionally, again, after careful analysis with regard to the results, the force prediction based on both schemes contrastingly presented the RMSE values of the ANN is slightly less than those of the SVM method indicating higher capability in dealing with the force estimation of the human muscle in the HRI tasks.

Table 5: RMSE values of the ANN and SVM approaches using the online training under the various movement frictional forces

Algorithms	friction = 2 N	friction = 3 N	friction = 4 N	friction = 5 N
RMSE ANN (N)	0.113	0.148	0.298	0.423
RMSE SVM_RBF (N)	0.124	0.175	0.316	0.539




Figure 11: The relationship between the RMSE magnitudes of the real-time force estimation using ANN and SVM to the frictional forces exerted against the object movement

Conclusion

This paper examines the use of ANN and SVM for optimizely estimating the human muscle forces based on the human forearm EMG signals during dynamic muscle contractions. The on-line and off-line training algorithms of the ANN and SVM techniques were strategically achieved by dealing with data individually captured from a set of random participants. The qualitative performance of the force prediction based on both methods was assessed using on the root mean square error (RMSE) between the estimated and measured forces during on-line and off-line trainings. The pilot study was conducted to convey the substantive tests. The main results were reported that the quantitative measurement of the performance of ANN and SVM can be considered acceptable for the forces prediction based on the human muscle EMG signals. Additionally, it can be claimed that ANN and SVM have higher capability to estimate the dynamic mathematical model of the EMG based force estimation, and this is in agreement with the parallel test outcomes examined by the researchers [23-25]. After careful analysis, the offline training of the proposed approaches provided similar acceptability for the effective force approximation. Contrastingly, the artificial neural network method was slightly superior to the support vector machine in the online training model. Hence, this study is so advantageous to be further used in a newly designed rehabilitation robot based on the EMG muscle force estimation using the MYO armband instead of a costly multi-axis force/torque sensor in the detection system of human applied force. However, the contributions of in this paper still have a limitation in estimating the force of only one dimensional movement. Even so, this idea is still possible to develop further in order to predict the muscle force in more dimensions, and it can be considered as future work.

Acknowledgement

We acknowledge financial support from research grants, research fund from Research and Development Office (RDO) and a 5-year bachelor's-master scholarship program for postgraduate students, Prince of Songkla University. The author would like to thank all the participants in the experiments conducted.

References

- [1] P. K. Artemiadis and K. J. Kyriakopoulos, "EMG-Based Control of a Robot Arm Using Low-Dimensional Embeddings," *IEEE Trans. Robot.*, vol. 26, no. 2, pp. 393–398, Apr. 2010.
- [2] P. J. Xie and J. Haleegoah, "Research on Vision-Based Underwater Robot Positioning and Map Building Technology," p. 6.
- [3] Y. T. Oh, "Study of Driving Torque through Analysis of Dynamic Characteristics on Industrial Robot," p. 8.
- [4] Fengjun Bai and Chee-Meng Chew, "Muscle force estimation with surface EMG during dynamic muscle contractions: A wavelet and ANN based approach," in *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka, 2013, pp. 4589–4592.
- [5] P. Konrad, *The ABC of EMG: a practical introduction to kinesiological electromyography*, Version 1.4. Noraxon USA, Inc, 2006.
- [6] W. Kaewboon, P. Phukpattaranont, and C. Limsakul, "Upper limbs rehabilitation system for stroke patient with biofeedback and force," in *The 6th 2013 Biomedical Engineering International Conference*, Amphur Muang, Krabi, Thailand, 2013, pp. 1–5.
- [7] Tomasz Marek Lubecki, Fengjun Bai, Chee-Meng Chew, and Chee Leong Teo, "Development of intuitive human-machine interface based on Electromyography for assistive robot (KAAD)," in *2011 IEEE/SICE International Symposium on System Integration (SII)*, Kyoto, Japan, 2011, pp. 908–913.
- [8] M. J. M. Hoozemans and J. H. van Dieën, "Prediction of handgrip forces using surface EMG of forearm muscles," *J. Electromyogr. Kinesiol.*, vol. 15, no. 4, pp. 358–366, Aug. 2005.
- [9] C. Disselhorst-Klug, T. Schmitz-Rode, and G. Rau, "Surface electromyography and muscle force: Limits in sEMG–force relationship and new approaches for applications," *Clin. Biomech.*, vol. 24, no. 3, pp. 225–235, Mar. 2009.
- [10] S. Karlsson, Jun Yu, and M. Akay, "Time-frequency analysis of myoelectric signals during dynamic contractions: a comparative study," *IEEE Trans. Biomed. Eng.*, vol. 47, no. 2, pp. 228–238, Feb. 2000.
- [11] D. Staudenmann, I. Kingma, D. F. Stegeman, and J. H. van Dieën, "Towards optimal multi-channel EMG electrode configurations in muscle force estimation: a high density EMG study," *J. Electromyogr. Kinesiol.*, vol. 15, no. 1, pp. 1–11, Feb. 2005.
- [12] D. Staudenmann, I. Kingma, A. Daffertshofer, D. F. Stegeman, and J. H. vanDieën, "Improving EMG-Based Muscle Force Estimation by Using a High-Density EMG Grid and Principal Component Analysis," *IEEE Trans. Biomed. Eng.*, vol. 53, no. 4, pp. 712–719, Apr. 2006.
- [13] U. J. Naeem, C. Xiong, and A. A. Abdullah, "EMG-muscle force estimation model based on back-propagation neural network," in *2012 IEEE International Conference on Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS) Proceedings*, Tianjin, China, 2012, pp. 222–227.
- [14] C. Castellini and R. Koiva, "Using surface electromyography to predict single finger forces," in *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*, Rome, Italy, 2012, pp. 1266–1272.
- [15] F. Xiao, Y. Wang, Y. Gao, Y. Zhu, and J. Zhao, "Continuous Estimation of Elbow Joint Angle by Multiple Features of Surface Electromyographic Using Grey Features Weighted Support Vector Machine," *J. Med. Imaging Health Inform.*, vol. 7, no. 3, pp. 574–583, Jun. 2017.
- [16] Y. Gao, Y. Luo, Q. Li, and J. Zhao, "Continuous Joint Angle Estimation by Least Support Vector Machine from Time-Delayed sEMG Features," in *Proceedings of the 2018 10th International Conference on Bioinformatics and Biomedical Technology - ICBBT '18*, Amsterdam, Netherlands, 2018, pp. 13–17.
- [17] N. Zarzycka and S. Zahuska, "[Measurements of the forearm i inhabitants of the Lublin region]," *Ann. Univ. Mariae Curie Skłodowska [Med.]*, vol. 44, pp. 85–92, 1989.
- [18] M. Mishra and M. Srivastava, "A view of Artificial Neural Network," in *2014 International Conference on Advances in Engineering & Technology Research (ICAEETR - 2014)*, Unnao, India, 2014, pp. 1–3.
- [19] C. Keattisak and N. Supot, "A Comparison of Prediction Palm Oil Time Series Using Polynomial Artificial Neural Network and Artificial Neural Network," presented at the The 12th National Graduate Research Conference (GRC-2011).

- [20] C. Jensen, O. Vasseljen, and R. H. Westgaard, "Estimating maximal EMG amplitude for the trapezius muscle: On the optimization of experimental procedure and electrode placement for improved reliability and increased signal amplitude," *J. Electromyogr. Kinesiol.*, vol. 6, no. 1, pp. 51–58, Mar. 1996.
- [21] H. J. Kim, Y. S. Lee, and D. Kim, "Arm Motion Estimation Algorithm Using MYO Armband," in *2017 First IEEE International Conference on Robotic Computing (IRC)*, Taichung, Taiwan, 2017, pp. 376–381.
- [22] N. Jiang, S. Muceli, B. Graimann, and D. Farina, "Effect of arm position on the prediction of kinematics from EMG in amputees," *Med Biol. Eng. Comput.*, vol. 51, no. 1–2, pp. 143–151, Feb. 2013.
- [23] T. M. Bafithile and Z. Li, "Applicability of ϵ -Support Vector Machine and Artificial Neural Network for Flood Forecasting in Humid, Semi-Humid and Semi-Arid Basins in China," *Water*, vol. 11, no. 1, p. 85, Jan. 2019.
- [24] Electrical Engineering, King Fahd University of Petroleum and Minerals, Saudi Arabia, K. O. Akande, T. O. Owolabi, S. Twaha, and S. O. Olatunji, "Performance Comparison of SVM and ANN in Predicting Compressive Strength of Concrete," *IOSR J. Comput. Eng.*, vol. 16, no. 5, pp. 88–94, 2014.
- [25] B. Yu, Y. T. Wang, J. B. Yao, and J. Y. Wang, "A COMPARISON OF THE PERFORMANCE OF ANN AND SVM FOR THE PREDICTION OF TRAFFIC ACCIDENT DURATION," *Neural Netw. World*, vol. 26, no. 3, pp. 271–287, 2016.

ประวัติผู้เขียน

ชื่อ สกุล นายธนัท ธนอัศวพล

รหัสประจำตัวนักศึกษา 6010120093

วุฒิการศึกษา

วุฒิ	ชื่อสถานศึกษา	ปีที่สำเร็จการศึกษา
วิศวกรรมศาสตรบัณฑิต	มหาวิทยาลัยสงขลานครินทร์	2560

ทุนการศึกษา

- 1) ทุนการศึกษาโครงการปริญญาตรี-โท 5 ปี

การตีพิมพ์เผยแพร่ผลงาน

- 1) T.Tanausavaphol, P.Neranon, P. Vessakosol, and P. Phukpattaranont, “Muscle Force Estimation with Surface Electromyography in Upper Limb Stroke Rehabilitation,” in The 32th Conference of Mechanical Engineering Network of Thailand, Amphur Muang, Mukdahan, Thailand, 2018.
- 2) T.Tanausavaphol, P.Neranon, P. Vessakosol, and P. Phukpattaranont, and Pornchai Phukpattaranont, “EMG-based Force Estimation for Dynamic Muscle Contractions in Physical Human-Robot Interaction,” JMERD, vol. 2019. (Under review : Scopus Q4)