

## การจำแนกสัญญาณไฟฟ้ากล้ามเนื้อตามเวลาจริงเพื่อควบคุมมือหุ่นยนต์ Real-Time Classification of EMG Signals for Controlling Robot Gripper

เมธาวัดน์ คุณาพิพัฒน์<sup>1</sup>, กิตติคุณ ทองพูล<sup>2\*</sup>, ปรมินทร์ เณรานนท์<sup>1</sup> พรชัย พุกภักขิทรานนท์<sup>2</sup>  
Methawat Kunapipat<sup>1</sup>, Kittikhun Thongpull<sup>2</sup>, Paramin Neranon<sup>1</sup> Pornchai Phukpattaranont<sup>2</sup>

<sup>1</sup>ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ ต.คอหงส์ อ.หาดใหญ่ จ.สงขลา 90112 ประเทศไทย

<sup>2</sup>ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ ต.คอหงส์ อ.หาดใหญ่ จ.สงขลา 90112 ประเทศไทย

<sup>1</sup>Department of Mechanical Engineering, Faculty of Engineering, Prince of Songkla University, Hatyai, Songkhla 90110, Thailand

<sup>2</sup>Department of Electrical Engineering, Faculty of Engineering, Prince of Songkla University, Hatyai, Songkhla 90110, Thailand

\*Corresponding author. e-mail: Kittikhun.t@psu.ac.th

(Received: 30 April 2020, Revised: 21 September 2020, Accepted: 15 October 2020)

### บทคัดย่อ

บทความนี้นำเสนอระบบการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อเพื่อนำข้อมูลไปใช้ในการสร้างต้นแบบของการจดจำรูปแบบสัญญาณไฟฟ้ากล้ามเนื้อเพื่อจำแนกท่าทางมือ โดยใช้ข้อมูลกล้ามเนื้อ 5DT เพื่อตรวจจับข้อมูลท่าทางมือและบล็อกแขน MYO เพื่อรับสัญญาณไฟฟ้ากล้ามเนื้อ อุปกรณ์ที่เพิ่มเติมเข้ามาเพื่อช่วยในการอ้างอิงกลุ่มของข้อมูลเพื่อให้ระบบมีความรวดเร็ว แม่นยำ และมีความสะดวกสบายในการใช้งาน ระบบนี้สามารถจำแนกสัญญาณไฟฟ้ากล้ามเนื้อจาก 3 ท่าทางมือประกอบด้วย ท่ากำมือ ท่าแบมือ และท่าพักมือ นอกจากนี้ระบบยังคำนึงถึงผลกระทบของการเคลื่อนที่แขนต่อสัญญาณไฟฟ้ากล้ามเนื้อ โดยใช้ตัวจำแนกสัญญาณคือ Support Vector Machine (SVM), Linear Discriminant Analysis (LDA) และ Artificial Neural Network (ANN) ระบบพัฒนาขึ้นเมื่อทำการเก็บข้อมูลที่ไม่ใช้อุปกรณ์เพิ่มเติมจะให้ประสิทธิภาพในการจำแนกสัญญาณไฟฟ้ากล้ามเนื้ออยู่ที่ 95.95% ส่วนเบี่ยงเบนมาตรฐานที่  $\pm 1.13\%$  ด้วยตัวจำแนกสัญญาณแบบ ANN และในกรณีที่ใช้อุปกรณ์เพิ่มเติมช่วยในการเก็บข้อมูลจะให้ประสิทธิภาพในการจำแนกสัญญาณไฟฟ้ากล้ามเนื้ออยู่ที่ 97.37% ส่วนเบี่ยงเบนมาตรฐานที่  $\pm 2.83\%$  การบันทึกข้อมูลแบบใช้กรณีใช้อุปกรณ์ช่วยในการเก็บข้อมูลใช้เวลาการบันทึกประมาณ 5 นาทีต่อหนึ่งอาสาสมัครและการบันทึกข้อมูลแบบไม่ใช้อุปกรณ์จะใช้เวลาประมาณ 12 นาทีต่อหนึ่งอาสาสมัคร ซึ่งเห็นได้ว่าระบบที่นำเสนอช่วยให้การบันทึกสัญญาณไฟฟ้ากล้ามเนื้อมีความรวดเร็วมากขึ้นถึง 2.4 เท่า

**คำสำคัญ:** การจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ, ซัพพอร์ตเวกเตอร์แมชชีน, การวิเคราะห์การจำแนกประเภทเชิงเส้น, โครงข่ายประสาทเทียม, บล็อกแขนมายโอ, ข้อมูลกล้ามเนื้อไฟฟ้ที่ดี

### Abstract

This paper presents the acquisition system that is able to classify hand gestures using electromyography (EMG) signals from a MYO armband and/or the finger positions using a 5DT data glove. Both devices make the EMG recording system easier because the hand gesture is identified automatically by the data captured from the 5DT data glove. The recorded EMG data can be analyzed using classification techniques, including Support Vector Machine (SVM), Linear Discriminant Analysis (LDA), and Artificial neural network (ANN), for creating the hand gesture prediction model. The proposed system can classify three gestures, including rest hand, close hand, and open hand. The recorded data using the MYO armband, the 5DT data glove, and the ANN technique provide maximum accuracy of 95.95% with  $\pm 1.13$  SD while the captured data using the MYO solely with ANN deliver maximum accuracy of 97.37% with  $\pm 2.83$  SD. Due to overlap variance, both performances are not significantly different. The distance-based method is also used for analyzing the system. The time consumption to record the relevant information using the MYO armband and the 5DT data glove is approximately 5 minutes.

However, the recorded system using the MYO armband solely takes around 12 minutes due to manual data registration process. Subsequently, the time consumptions of these two systems show that the data recording system based on both devices is 2.4 times faster than that of using the MYO armband only.

**Keywords:** Electromyography Classification, Support Vector Machine (SVM), Linear Discriminant Analysis (LDA), and Artificial neural network (ANN), a MYO armband, a 5DT data glove

## 1. บทนำ

สัญญาณไฟฟ้ากล้ามเนื้อ (Electromyography, EMG) ถูกนำมาใช้อย่างแพร่หลายในปัจจุบันเพื่อใช้ในงานต่าง ๆ เช่น การจำแนกท่าทางมือ (Barrios, 2010; Gauthaam, & Kumar, 2011) และการตรวจวัดความผิดปกติของกล้ามเนื้อเพื่อนำไปวินิจฉัย เป็นต้น สัญญาณไฟฟ้ากล้ามเนื้อสามารถใช้แสดงผลการออกแรงมัดกล้ามเนื้อทางกายภาพอย่างทันทีทันใด นอกจากนี้สัญญาณไฟฟ้ากล้ามเนื้อยังเป็นสัญญาณที่มีค่าความต่างศักย์สูงที่สุดในร่างกายเมื่อเทียบกับสัญญาณอื่นๆ เช่น สัญญาณไฟฟ้าจากสมอง สัญญาณไฟฟ้าหัวใจ จึงนิยมนำไปประยุกต์ใช้กับอุปกรณ์ต่าง ๆ เช่น การควบคุมมือหุ่นยนต์ การควบคุมเก้าอี้อัตโนมัติ การใช้ควบคุมกับอุปกรณ์บำบัดทางการแพทย์ เป็นต้น สมอง เส้นประสาทและกล้ามเนื้อเป็นเนื้อเยื่อที่ไวต่อสิ่งเร้า สามารถสร้างสัญญาณไฟฟ้าและส่งสัญญาณไฟฟ้าเมื่อถูกกระตุ้นด้วยสิ่งเร้าออกไปตามเส้นประสาทซึ่งสัญญาณไฟฟ้ากล้ามเนื้อ (Raez et al., 2006) เป็นสัญญาณไฟฟ้าทางชีวการแพทย์ที่มักถูกนำไปวิเคราะห์และวินิจฉัยกิจกรรมที่เกิดขึ้นในเส้นประสาทหรือมัดกล้ามเนื้อซึ่งมีความคล้ายกับการตรวจคลื่นไฟฟ้าหัวใจ แต่มีความแตกต่างกันที่ขนาดของความต่างศักย์ไฟฟ้า และขนาดความถี่สัญญาณไฟฟ้ากล้ามเนื้อมีความต่างศักย์ไฟฟ้าเพียงไม่กี่มิลลิโวลต์ และความถี่ตอบสนองอยู่ในช่วงไม่กี่พันเฮิรตซ์

อุปกรณ์ที่ใช้วัดสัญญาณไฟฟ้ากล้ามเนื้อประกอบไปด้วย 2 ชนิด คือ 1) ตัวรับสัญญาณหรืออิเล็กโทรดถูกใช้เป็นอุปกรณ์สำหรับวัดสัญญาณไฟฟ้าจากมัดกล้ามเนื้อที่สามารถวัดได้จากทั้งภายในและนอกผิวหนัง โดยส่วนมากการวัดนอกผิวหนังจะถูกนำมาใช้เนื่องจากไม่เป็นอันตรายผู้ถูกตรวจวัดสัญญาณไฟฟ้าและสามารถใช้ได้ง่าย และ 2) วงจรขยายสัญญาณ เนื่องจากสัญญาณไฟฟ้ากล้ามเนื้อมีความต่างศักย์น้อยมากจึงทำให้ต้องใช้วงจรขยายสัญญาณ จากการทบทวนวรรณกรรมที่เกี่ยวข้อง ระบบการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อได้ถูกพัฒนาขึ้นเพื่อใช้ในการควบคุมอวัยวะเทียม (Hakonen et al., 2015; Oskoei, & Hu, 2007) แต่การจำแนกสัญญาณไฟฟ้ากล้ามเนื้อก็ยังมีความจำกัด (Castellini et al., 2004) เนื่องจากมีมือเทียมเพียง 25 เปอร์เซนต์ที่ใช้งานได้จริงเท่านั้นจากจำนวนที่

มีการใช้งานเชิงพาณิชย์ทั้งหมด (Jiang et al., 2012; Wright et al., 1995) ด้วยเหตุนี้จึงทำให้มีช่องว่างอย่างมากระหว่างการทดลองตามเงื่อนไขในอุดมคติและการทดลองตามการใช้งานจริง (Castellini et al., 2004; Jiang et al., 2012) และยังมีสาเหตุอื่น ๆ ที่ส่งผลกระทบต่อประสิทธิภาพของการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ เช่น การเคลื่อนไหวของแขน (Fougner et al., 2011) ความคลาดเคลื่อนของตำแหน่งอิเล็กโทรด (Young et al., 2012) และการออกแรงที่ไม่คงที่ระหว่างกิจกรรมต่างๆ (Al-Timemy et al., 2016) ผลกระทบของการเคลื่อนที่แขนก็เป็นหนึ่งสาเหตุที่ส่งผลกระทบต่อประสิทธิภาพของการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ นักวิจัยได้ใช้เซนเซอร์วัดความเร่ง (Accelerometer) ตรวจจับการเคลื่อนที่ร่วมกันกับการวัดสัญญาณไฟฟ้ากล้ามเนื้อ (Fougner et al., 2011) เพื่อใช้เสริมการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อด้วยการเคลื่อนที่ของแขนหลายตำแหน่ง ส่งผลให้การบันทึกการเคลื่อนที่ของแขนถูกนำมาใช้เพื่อพัฒนาประสิทธิภาพของการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ (Agamemnon et al., 2019; Jianwei et al., 2014)

ในการลดผลกระทบของการใช้อิเล็กโทรด องค์ประกอบต่างๆ ของอิเล็กโทรด (ขนาด, ความคลาดเคลื่อนของตำแหน่ง, จำนวนช่องทางการรับสัญญาณ, และระยะห่างระหว่างอิเล็กโทรด) ถูกนำมาทดสอบเช่นกัน ในการศึกษาระยะห่างของอิเล็กโทรด 2 – 4 เซนติเมตร และการวางอิเล็กโทรดมีผลต่อความแรงของสัญญาณไฟฟ้ากล้ามเนื้ออย่างมีนัยสำคัญ นอกจากนี้การใช้สัญญาณไฟฟ้ากล้ามเนื้อที่มีความหนาแน่นสูง (High-density EMG, HD-EMG) ทำงานร่วมกับขั้นตอนวิธีพิเศษ เช่น Spatial correlation (Stango et al., 2015) และ Common spatial patterns (Pan et al., 2015) ได้รับเสนอเพื่อปรับปรุงความหนาแน่นของการเก็บข้อมูลที่มีเงื่อนไขไม่แน่นอน การจำแนกสัญญาณไฟฟ้ากล้ามเนื้อถูกใช้เพื่อประเมินผลกระทบของแรงที่เปลี่ยนแปลงต่อความแม่นยำของการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ การทดลองลักษณะเด่นแบบทั่วไป ประกอบไปด้วย time domain features, autoregressive coefficients หรือ wavelet transform-based features ถูกนำมาใช้เป็นลักษณะเด่นเพื่อทำให้การ


จำแนกสัญญาณไฟฟ้าได้ง่ายขึ้น เนื่องจากสัญญาณไฟฟ้ากล้ามเนื้อมีความซับซ้อนและไม่สามารถนำมาใช้ได้โดยตรง การบันทึกสัญญาณไฟฟ้ากล้ามเนื้อโดยทั่วไปจะเป็นการบันทึกสัญญาณไฟฟ้าเพียงอย่างเดียว อาจเกิดข้อผิดพลาดได้เนื่องจากไม่สามารถระบุท่าทางมือขณะบันทึกได้ ทำให้ต้องทำการทดลองใหม่หากมีการเปลี่ยนแปลงท่าทางระหว่างการบันทึกสัญญาณ ทำให้การบันทึกข้อมูลใช้เวลาเพิ่มขึ้นและเพิ่มภาระในการตรวจสอบข้อมูลและประมวลผล นอกจากนี้ยังต้องทำการบันทึกข้อมูลแต่ละท่าแยกออกจากกันซึ่งจำเป็นต้องอาศัยความชำนาญการของผู้ปฏิบัติงาน เกิดความยุ่งยากมีโอกาสเกิดความผิดพลาดในชุดข้อมูลได้และใช้เวลาในการรวบรวมข้อมูลที่ยาวนาน จากปัญหาทั้งหมดที่กล่าวมาคณะผู้เขียนได้ศึกษาแนวทางในการพัฒนาระบบบันทึกสัญญาณไฟฟ้ากล้ามเนื้อแขนเพื่อแก้ปัญหาดังกล่าวโดยอาศัยการทำงานร่วมกันระหว่างเซ็นเซอร์สองชนิดคือ เซ็นเซอร์วัดสัญญาณไฟฟ้ากล้ามเนื้อและเซ็นเซอร์วัดท่าทางของมือ

ระบบการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อที่ได้รับการพัฒนาในบทความนี้ใช้อุปกรณ์ 2 ชนิด คือ ปลอกแขน MYO (Myo Gesture Control Armband, 2018) เป็นอุปกรณ์สำหรับที่ใช้ในการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อจากแขนและถุงมือข้อมูล 5 DT (Data Gloves 5DT, 2018) เป็นอุปกรณ์ที่ใช้เก็บข้อมูลนิ้วมือ ข้อมูลท่าทางมือจากถุงมือจะช่วยทำให้กระบวนการฝึกฝนข้อมูลง่ายขึ้นและลดระยะเวลาในการทำงานของระบบโดยใช้ปลอกแขน MYO และถุงมือข้อมูลร่วมกัน อีกทั้งยังทำการทดลองบันทึกโดยใช้ข้อมูลจากปลอกแขน MYO เพียงอย่าง


เดียวเช่นกัน เพื่อนำไปเปรียบเทียบประสิทธิภาพของระบบการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อและการใช้เวลาในการบันทึกข้อมูลทั้งสองชุดโดยใช้เทคนิคการจำแนกสัญญาณ 3 วิธี ดังนี้ Support Vector Machine (SVM) (Cortes, & Vapnik, 1995), Linear Discriminant Analysis (LDA) (Zhang et al., 2012) และ Artificial Neural Network (ANN) (Capa et al., 2014) ในการเปรียบเทียบประสิทธิภาพการทำงาน และทำการเปรียบเทียบประสิทธิภาพของระยะของกลุ่มข้อมูลใน Feature Space และยังทำการเปรียบเทียบเวลาในการบันทึกข้อมูลอีกด้วย

## 2. การพัฒนาระบบบันทึกสัญญาณไฟฟ้ากล้ามเนื้อร่วมกับถุงมือข้อมูลสำหรับอ้างอิงท่าทางของมือ

การบันทึกสัญญาณไฟฟ้ากล้ามเนื้อแบบทั่วไปใช้เพียงสัญญาณไฟฟ้ากล้ามเนื้อ อาจทำให้เวลาในการบันทึกข้อมูลใช้เวลานานเกินไป และมีความซับซ้อนในการใช้งาน ดังนั้นเพื่อลดปัญหาดังกล่าวงานวิจัยนี้จึงพัฒนาระบบบันทึกสัญญาณไฟฟ้ากล้ามเนื้อโดยใช้อุปกรณ์เพิ่มเติม คือ ถุงมือข้อมูล 5DT ทำให้สามารถระบุท่าทางมือได้อย่างอัตโนมัติ ส่งผลทำให้มีความสะดวกในการจัดการข้อมูลใช้งานง่ายขึ้นและไม่ต้องอาศัยผู้เชี่ยวชาญในการเก็บสัญญาณ ระบบบันทึกสัญญาณไฟฟ้ากล้ามเนื้อที่นำเสนอแสดงในรูปที่ 1 เป็นการนำอุปกรณ์ที่มีราคาถูกและหาซื้อได้ทั่วไปต่อการใช้งานมาประยุกต์ใช้งาน



รูปที่ 1 โครงสร้างระบบการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อ



รูปที่ 2 หน้าต่างผู้ใช้งานของระบบบันทึกสัญญาณไฟฟ้ากล้ามเนื้อ

ระบบจำแนกสัญญาณไฟฟ้ากล้ามเนื้อจะแสดงภาพบน หน้าต่างผู้ใช้งาน ดังแสดงรูปที่ 2 ซึ่งแสดงข้อมูลที่จำเป็น ระหว่างการบันทึกและระหว่างการวิเคราะห์ข้อมูล โดยมีข้อมูล สัญญาณไฟฟ้ากล้ามเนื้อทั้ง 8 ช่องสัญญาณ ข้อมูลท่าทางนิ้วมือ จากถุงมือ และโมเดลของข้อมูลที่ใช้ในการฝึกสอนระบบการ จำแนกสัญญาณไฟฟ้ากล้ามเนื้อออกเป็นท่าทางที่บันทึกไว้ การ ทำงานของการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อแยกเป็น 3 ขั้นตอน คือ การบันทึกข้อมูล การเตรียมข้อมูล และการจำแนก สัญญาณไฟฟ้ากล้ามเนื้อ

## 2.1 การบันทึกข้อมูล


### 2.1.1 สัญญาณไฟฟ้ากล้ามเนื้อ

ปลอกแขน MYO ดังแสดงในรูปที่ 3 ประกอบไปด้วย 8 ช่องสัญญาณ ด้วยอัตราการซิกตัวอย่าง 200 Hz ปลอกแขน MYO จะถูกวางไว้บนปลายแขนที่ห่างจากข้อศอกประมาณ 3 เซนติเมตร เนื่องจากเป็นจุดที่เหมาะสมในการวัดสัญญาณไฟฟ้า กล้ามเนื้อ ช่องสัญญาณของปลอกแขนจะถูกวางบนมัด

กล้ามเนื้อ Extensor carpi radialis longus and brevis, Extensor digit minimi, Extensor carpi ulnaris, Brachioradialis, Flexor carpi radialis, Palmaris longus, Flexor carpi ulnaris และ Pronator teres (Wright et al., 1995; Fougner et al., 2011; Agamemnon et al., 2019; Nguyen, 2018) ตามลำดับตามช่องสัญญาณ 1-8 ดังรูปที่ 4



รูปที่ 3 ปลอกแขน MYO (Karen et al., 2018)



รูปที่ 4 มัดกล้ามเนื้อ (Nguyen, 2018)



รูปที่ 5 ถุงมือ 5DT (Data Gloves 5DT, 2018)

## 2.1.2 ท่าทางของมือ

ข้อมูลจากนิ้วมือที่ตรวจจับได้จากถุงมือ 5DT ดังแสดงในรูปที่ 5 ด้วยอัตราการการชักตัวอย่าง 200 Hz ข้อมูลท่าทางมือถูกจำแนก 3 ท่าทาง คือ กำมือ แบมือ และพักมือ ดังแสดงในรูปที่ 6 นอกจากนี้ยังศึกษาผลกระทบจากการเคลื่อนไหวของท่อนแขนต่อสัญญาณไฟฟ้ากล้ามเนื้อเพื่อจำลองสภาวะแปรปรวน ที่อาจจะส่งผลให้เกิดความผิดพลาดในการจำแนกสัญญาณไฟฟ้า

กล้ามเนื้อระหว่างการทำงานจริง (Gu et al., 2018) ดังแสดงในรูปที่ 7



รูปที่ 6 ท่าทางมือ ได้แก่ (a) ท่ากำมือ (b) ท่าพักมือ และ (c) ท่าแบมือ



รูปที่ 7 มุมของแขนที่ใช้ในการเคลื่อนที่ระหว่างการบันทึกข้อมูล

## 2.2 การเตรียมข้อมูล

### 2.2.1 สัญญาณไฟฟ้ากล้ามเนื้อ

หน้าตาวิเคราะห์ข้อมูลขนาดความยาว 100 ข้อมูลและมี ส่วนทับซ้อนกันของข้อมูล 50 เปอร์เซ็นต์ถูกนำมาใช้ในการแบ่ง ข้อมูลที่วัดจากจากปลอกแขน MYO จำนวน 8 ช่องสัญญาณ ข้อมูลที่เก็บเข้ามานั้นจะถูกนำมาใช้ในการคำนวณ 5 ลักษณะ เติ่นทางเวลา (Phinyomark et al., 2012) ประกอบด้วย ค่าเฉลี่ยสัมบูรณ์ (Mean Absolute Value, MAV), ความแปรปรวน (Variance, VAR), รากที่สองของค่าเฉลี่ยกำลังสอง (Root Mean Square, RMS), ความยาวคลื่น (Waveform Length, WL) และความแตกต่างของค่าเฉลี่ยสัมบูรณ์ (Difference of Mean Absolute Value, DMAV) ตามลำดับ ดังสมการที่ (1) – (5) โดย N คือจำนวนข้อมูล และ  $x_i$  คือ ค่าของสัญญาณไฟฟ้ากล้ามเนื้อลำดับที่  $i$  และหลังจากคำนวณ ลักษณะเด่นแล้ว ค่าที่ได้จะถูกนำไปสร้างเป็นเวกเตอร์เพื่อนำไปใช้เป็นข้อมูลขาเข้าของตัวจดจำรูปแบบของสัญญาณไฟฟ้ากล้ามเนื้อเพื่อทำการฝึกฝนและทำนายท่าทางของมือในรูปแบบที่บันทึกไว้

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (1)$$

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2 \quad (2)$$

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3)$$

$$WL = \frac{1}{N} \sum_{i=1}^N |x_{i+1} - x_i| \quad (4)$$

$$DMAV_i = MAV_i - MAV_{i-1} \quad (5)$$

## 2.2.2 ท่าทางของมือ

ค่าเฉลี่ยการเคลื่อนที่เป็นตัวกรองที่ใช้ค่าเฉลี่ยของข้อมูลช่วงหนึ่ง (Steven, 2003) ถูกใช้เป็นตัวกรองสัญญาณรบกวนของข้อมูลจากนิ้วมือซึ่งตรวจจับได้จากถุงมือ 5DT หน้าต่างวิเคราะห์ข้อมูลขนาดความยาว 100 ข้อมูลพร้อมกับข้อมูลทับซ้อน 50 เปอร์เซ็นต์โดยที่ ข้อมูล 5 ชุดแรกถูกนำมาเฉลี่ยกันและเมื่อถุงมือทำการบันทึกข้อมูลท่าทางมือเต็มหน้าต่าง ข้อมูลท่าทางในหน้าต่างที่มีจำนวนมากที่สุดจะถูกโหวตให้ค่าของข้อมูลแสดงเป็นทีนั้น ๆ และข้อมูลดังกล่าวถูกใช้ในการบันทึกข้อมูลท่าทางมือ เพื่อนำไปใช้ในการจดจำรูปแบบมือเพื่อใช้เป็นตัวอ้างอิงในการจดจำลักษณะสัญญาณไฟฟ้ากล้ามเนื้อ

## 2.3 การประเมินคุณภาพของข้อมูล

การประเมินคุณภาพถูกใช้ในการวิเคราะห์ประสิทธิภาพของข้อมูล (Keinosuke, 1990) เพื่อยืนยันว่าข้อมูลที่ใช้นำไปใช้ได้จริง การประเมินคุณภาพข้อมูลประกอบไปด้วย 2 วิธีดังนี้

### 2.3.1 การประเมินความหนาแน่นของข้อมูล

การประเมินความหนาแน่นของข้อมูลวัดได้จากการกระจายตัวของข้อมูล มีการวิเคราะห์ได้หลากหลายแบบ เช่น การลดจำนวนลักษณะเด่นแบบ PCA (Tipping, & Bishop, 1999) เป็นการประเมินข้อมูลของความหนาแน่นโดยการแปลงข้อมูลเรียงตามการกระจายตัวของข้อมูล และการลดจำนวนลักษณะเด่นแบบ Feature Selection เช่น Mutual Information (MI) (Al-Ani, & Deriche, 2002) เป็นการวิเคราะห์ความเกี่ยวข้องระหว่างลักษณะเด่น 2 ชนิด และ ANOVA F-value เป็นการวัดการกระจายข้อมูลของลักษณะเด่น เป็นต้น Feature Selection เป็นเทคนิคการลดลักษณะเด่นให้เหมาะสมหลังจากนั้นข้อมูลที่ได้จะถูกจำแนกต่อไปโดยใช้เทคนิคการจำแนกสัญญาณแบบ SVM แบบ LDA และแบบ ANN

### 2.3.2. วิธีการประเมินด้วยระยะทาง

ระยะทางระหว่างลักษณะเด่นถูกใช้ในประเมินคุณภาพ ถูกคำนวณผ่านเมตริกด้วยการคำนวณแบบ Euclidean Distance ที่แสดงในสมการที่ (10) วิธีการนี้ไม่จำเป็นต้องใช้เทคนิคการจำแนกสัญญาณในการวิเคราะห์ข้อมูล เนื่องจากไม่ขึ้นกับการจำแนกสัญญาณและไม่จำเป็นต้องตั้งค่าตัวแปรใด ๆ วิธีการนี้ใช้เมตริกซ์ในการคำนวณระยะทางระหว่างลักษณะเด่น ดังสมการที่ (6) โดยที่  $X_j, X_i \in X$  ของ  $|X|$  ระยะทางที่คำนวณได้ขึ้นกับเงื่อนไขดังนี้

$$d(X_i, X_j) \geq 0 \quad (6)$$

$$d(X_i, X_j) = 0, \text{ if } X_i = X_j \quad (7)$$

$$d(X_i, X_j) = d(X_j, X_i) \quad (8)$$


$$d(X_i, X_j) \leq d(X_i, X_j), d(X_j, X_j)w \quad (9)$$

$d$  คือค่าระยะทางระหว่างข้อมูล,  $X$  คือเมตริกซ์ชุดข้อมูล,  $i$  คือแถวของเมตริกซ์,  $j$  คือหลักของเมตริกซ์และ  $W$  คือเวกเตอร์ค่าน้ำหนัก การวัดระยะทาง Euclidean Metric เป็นการคำนวณพื้นฐานการคำนวณระยะทางเมื่อเทียบกับการคำนวณแบบอื่น (de Sá, 2012) โดย  $\|x_j - x_i\|_e$  คือระยะทาง Euclidean,  $x_{i,m}$  คือข้อมูลในแถว  $i$  และหลัก  $m$  และ  $x_{j,m}$  ข้อมูลในแถว  $j$  และหลัก  $m$

$$\|x_j - x_i\|_e = \sqrt{\sum_{m=1}^{|X|} (x_{i,m} - x_{j,m})^2} \quad (10)$$

### 2.3.2.1. การประเมินการทับซ้อนกันของข้อมูล

วิธีการวิเคราะห์ข้อมูลที่อยู่รอบตัวของลักษณะเด่นนั้น ๆ จะถูกนำมาเข้าใช้ในการคำนวณพื้นที่ซ้อนทับของข้อมูล (Overlapping Region,  $Q_{ov}$ ) (Konig et al., 1998) เป็นค่าที่บอกระยะทางเฉลี่ยระหว่างข้อมูลต่างกลุ่ม โดยที่ประสิทธิภาพสูงสุดหมายความว่าไม่มีการทับซ้อนกันของข้อมูลต่างกลุ่มกันตามพื้นฐานของกลุ่มข้อมูล k-Nearest Neighbors (k-NN) (Roberto et al., 2010) ที่มีสมาชิกจำนวน  $k$  ตัวเป็นกลุ่มเดียวกันทั้งหมด ( $\omega_i = \omega_j$ ) หรือรอบตัวของลักษณะเด่นนั้นไม่มีข้อมูลในกลุ่มอื่น ( $\omega_i \neq \omega_j$ ) ดังแสดงในรูปที่ 8 ที่คำนวณพื้นที่ทับซ้อนได้ตามสมการ (11)



รูปที่ 8 การประเมินการซ้อนทับกันของข้อมูล

$$Q_{ov} = \frac{1}{L} \sum_{c=1}^L \frac{1}{N_c} \sum_{j=1}^{N_c} \frac{\sum_{i=1}^k qNN_{ji} + \sum_{i=1}^k n_i}{2 \sum_{i=1}^k n_i} \quad (11)$$


$$n_i = 1 - \frac{qNN_{ji}}{qNN_{jk}} \quad (12)$$

$$qNN_i = \begin{cases} n_i : \omega_i = \omega_j \\ -n_i : \omega_i \neq \omega_j \end{cases} \quad (13)$$

โดย  $N$  คือจำนวนสมาชิกในชุดข้อมูล,  $N_c$  คือจำนวนสมาชิกในแต่ละกลุ่ม,  $L$  คือจำนวนกลุ่มข้อมูล,  $i$  คือลำดับของสมาชิกของกลุ่มข้อมูล  $k$ -NN มีค่าตั้งแต่ 1 ถึง  $k$ ,  $c$  คือลำดับของกลุ่มมีค่าตั้งแต่ 1 ถึง  $L$ ,  $j$  คือ ลำดับของสมาชิกในแต่ละกลุ่มมีค่าตั้งแต่ 1 ถึง  $N_c$  และ  $\omega$  คือเวกเตอร์จำแนกกลุ่มข้อมูล

### 2.3.2.2. การประเมินความอัดแน่นของข้อมูล

วัตถุประสงค์การประเมินผลแบบนี้เป็น การประเมินการอัดแน่นของกลุ่มข้อมูล (Nonparametric Compactness Measure,  $qc$ ) (Konig, 2000) ประกอบด้วย ค่าความอัดแน่นในกลุ่มเดียวกัน และการแยกตัวของข้อมูลต่างกลุ่มดังแสดงในรูปที่ 9 ประสิทธิภาพชุดข้อมูลที่มีค่าความอัดแน่นในกลุ่มเดียวกัน (Intra-Class  $qc_{intra}$ ) สูงเกิดขึ้นเมื่อข้อมูลเกาะติดกันมากและไม่มีส่วนทับซ้อนกับข้อมูลกลุ่มอื่น ค่าความอัดแน่นคำนวณได้ตามสมการ (14) ส่วนประสิทธิภาพของการแยกตัวของข้อมูลต่างกลุ่ม (Inter-Class  $qc_{inter}$ ) จะเกิดขึ้นเมื่อกลุ่มข้อมูลแยกตัวกันอย่างชัดเจน โดยค่าการแยกตัวของข้อมูลต่างกลุ่มคำนวณได้ตามสมการ (15) หากประสิทธิภาพทั้งสองมีค่าสูงจะแสดงให้เห็นว่าข้อมูลมีการแยกกลุ่มกันอย่างชัดเจนและมีการอัดแน่นภายในกลุ่มอย่างมาก



รูปที่ 9 การประเมินความอัดแน่นกันของข้อมูล

$$qc_{intra} = \frac{1}{L} \sum_{c=1}^L \frac{2}{N_c(N_c - 1)} \sum_{i=1}^{N-1} \sum_{j=i+1}^N \delta(\omega_i, \omega_j) \delta(\omega_i, \omega_c) d_{i,j} \quad (14)$$


$$qc_{inter} = \frac{1}{N^B} \sum_{i=1}^{N-1} \sum_{j=i+1}^N (1 - \delta(\omega_i, \omega_j)) d_{i,j} \quad (15)$$

$$N^B = \sum_{i=1}^{N-1} \sum_{j=i+1}^N 1 - \delta(\omega_i, \omega_j) d_{i,j} \quad (16)$$

$$\delta(\omega_i, \omega_j) = \begin{cases} 1 : \omega_i = \omega_j \\ 0 : \omega_i \neq \omega_j \end{cases} \quad (17)$$

## 2.4 การจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ

ลักษณะเด่นตั้งต้นจำนวน 40 ค่า (8 ช่องสัญญาณ  $\times$  5 ลักษณะเด่นต่อช่องสัญญาณ) ถูกคำนวณจากสัญญาณไฟฟ้ากล้ามเนื้อในแต่ละหน้าต่างวิเคราะห์ จากนั้นจะเข้าสู่กระบวนการลดลักษณะเด่น ด้วยเทคนิค Feature Selection (FS) ระเบียบวิธี Mutual Information (MI) ทำการประเมินประสิทธิภาพของการจำแนก ใช้เทคนิคการจำแนกแบบ Support Vector Machine (SVM) (Cortes, & Vapnik, 1995), Radial Basis Function (RBF) Kernel, Penalty Parameter C = 1 และ Gamma = 0.025 นอกจากนี้ใช้เทคนิคการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อแบบ Linear Discriminant Analysis (LDA) (Zhang et al., 2012) ด้วยวิธี Singular Value Decomposition และ Artificial Neural Network (ANN) (Capa et al., 2014) แบบ Multi-Layer Perceptron เพื่อเปรียบเทียบประสิทธิภาพการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ คุณลักษณะของ ANN ที่เลือกใช้ประกอบด้วย ขนาดอินพุตเวกเตอร์เท่ากับ 35 จำนวน Hidden layer เท่ากับ 100 และ 80 ในกรณีชุดข้อมูลแบบบล็อกแซน MYO อย่างเดียว และชุดข้อมูลบล็อกแซน MYO และถุงมือ 5DT ตามลำดับ จำนวนการคำนวณซ้ำ 300 รอบด้วยระเบียบวิธีการเรียนรู้แบบ Quasi-Newton ฟังก์ชันเอาต์พุตแบบ Logistic sigmoid function ขนาดเอาต์พุตเวกเตอร์เท่ากับ สามตามจำนวนท่าทางที่ทำการจำแนก โครงสร้างเครือข่ายประสาทเทียมที่พัฒนาขึ้นแสดงในรูปที่ 10



รูปที่ 10 โครงสร้างในแต่ละชั้นของการคัดแยกแบบ ANN

## 2.5 การควบคุมมือหุ่นยนต์

ผลลัพธ์ของการคัดแยกสัญญาณไฟฟ้ากล้ามเนื้อถูกนำมาใช้ควบคุมมือหุ่นยนต์ โดยในงานวิจัยนี้มีการนำผลลัพธ์จากการคัดแยกสัญญาณไฟฟ้ากล้ามเนื้อไปใช้เพื่อควบคุมมือหุ่นยนต์ AR10 ซึ่งสามารถเคลื่อนที่ได้ 10 องศาอิสระ และสามารถออกท่าทางที่ถูกบันทึกไว้เช่นท่ากำมือ หรือท่าแบมือ ได้ด้วยการส่งการผ่านการสื่อสารแบบ TCP/IP ผลลัพธ์จากการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อในแต่ละรอบการประมวลผลจะถูกนำไปใช้ในการสั่ง

การให้มือหุ่นยนต์เคลื่อนไหวตามท่าทางดังแสดงตัวอย่างในรูปที่ 11




รูปที่ 11 การทำงานของมือหุ่นยนต์ผ่านการควบคุมด้วยสัญญาณไฟฟ้ากล้ามเนื้อ

### 3. การทดลอง

การทดลองการจดจำรูปแบบสัญญาณไฟฟ้ากล้ามเนื้อต้องการข้อมูลต้นแบบ ซึ่งการเก็บข้อมูลต้นแบบแบ่งเป็น 2 ลักษณะ ประกอบด้วย 1) การเก็บข้อมูลสัญญาณไฟฟ้ากล้ามเนื้อพร้อมกับข้อมูลจากถุงมือข้อมูล 5DT และ 2) การเก็บสัญญาณไฟฟ้ากล้ามเนื้อเพียงอย่างเดียว เพื่อเปรียบเทียบเวลาและประสิทธิภาพในการทำงานของระบบการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ โดยการทดลองทั้งสอง ใช้อาสาสมัครที่มีสุขภาพแข็งแรง 11 คน (ชาย 7 คนและหญิง 4 คน) อายุระหว่าง 20 – 30 ปี เก็บท่าทางมือ 3 ท่า คือ ท่ากำมือ ท่าแบมือ ท่าพักมือ ดังแสดงในรูปที่ 6 นอกจากนี้ยังมีการเก็บข้อมูลในขณะอาสาสมัครเคลื่อนไหวก่อนแขน ดังแสดงในรูปที่ 7 รายละเอียดการทดลองมีดังนี้

การทดลองที่ 1 ข้อมูลต้นแบบจากสัญญาณไฟฟ้ากล้ามเนื้อและข้อมูลจากถุงมือ 5DT โดยข้อมูลจากถุงมือ ช่วยให้ข้อมูลต้นแบบจุดอ้างอิง (Ground Truth) มีความสะดวกในการใช้งานและระบบการบันทึกสัญญาณมีความรวดเร็วมากขึ้น ขั้นตอนการเก็บข้อมูล เบื้องต้นผู้ฝึกฝนแนะนำให้อาสาสมัครแสดงท่าทางมือในลักษณะต่าง ๆ โดยเก็บข้อมูลที่แต่ละท่าแบบต่อเนื่อง ระหว่างการเก็บแต่ละท่าทางผู้ฝึกสอนจะบอกให้อาสาสมัครเคลื่อนที่แขนไปด้วย เพื่อศึกษาความแปรปรวนของการเคลื่อนไหวก่อนแขนต่อสัญญาณไฟฟ้ากล้ามเนื้อ โดยสัญญาณไฟฟ้ากล้ามเนื้อถูกเก็บจำนวน 100 ชุดข้อมูลต่อท่าทาง ในการฝึกสอนโมเดลต้นแบบการจดจำรูปแบบสัญญาณไฟฟ้ากล้ามเนื้อ จะนำข้อมูลที่เก็บมาได้ถูกแบ่งเป็นสองกลุ่ม ส่วนแรก 2,805 ชุดข้อมูล (ร้อยละ 85) ถูกใช้ในการสอนต้นแบบการจดจำรูปแบบสัญญาณไฟฟ้ากล้ามเนื้อ และส่วนที่สอง จำนวน 495 ชุดข้อมูล (ร้อยละ 15) นำไปทดสอบประสิทธิภาพการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ



รูปที่ 12 การเก็บข้อมูลสัญญาณไฟฟ้ากล้ามเนื้อแบบใช้ข้อมูลจากปลอกแขน MYO และข้อมูลจากถุงมือ 5DT


การทดลองที่ 2 การเก็บต้นแบบข้อมูลอาศัย MYO เพียงอย่างเดียว โดย Ground Truth จะใช้เป็นการกำหนดค่าและเก็บข้อมูลแต่ละท่าแยกกัน การเก็บข้อมูลในการทดลองนี้ผู้ทดลองจะถูกเก็บข้อมูลสัญญาณไฟฟ้ากล้ามเนื้อครั้งละท่าทาง โดยในแต่ละการเก็บสัญญาณไฟฟ้ากล้ามเนื้อจะมีการหาจุดเริ่มต้นของสัญญาณด้วยค่าเฉลี่ยสัมบูรณ์ (MAV) เป็นค่าเริ่มต้น (Threshold) ระหว่างการเก็บข้อมูลแต่ละท่าทางผู้ฝึกสอนจะบอกให้อาสาสมัครเคลื่อนที่แขนไปด้วย สัญญาณไฟฟ้ากล้ามเนื้อถูกเก็บจำนวน 100 ชุดข้อมูลต่อท่าทาง หลังจากนั้นนำข้อมูลทั้งหมดไปใช้ในการสอนตัวจดจำสัญญาณไฟฟ้ากล้ามเนื้อ โดยแบ่งข้อมูลเป็นสองกลุ่ม เช่นเดียวกับการทดลองที่ 1 เพื่อฝึกสอนและทดสอบประสิทธิภาพในการจำแนกสัญญาณ

### 4. ผลการทดลอง


จากการทดลองเก็บสัญญาณไฟฟ้ากล้ามเนื้อเพื่อสร้างโมเดลสำหรับการจำแนกท่าทางมือโดยใช้อุปกรณ์ปลอกแขน MYO และการใช้งานร่วมกันระหว่างอุปกรณ์ปลอกแขน MYO กับถุงมือ 5 DT ด้วยการประเมินสัญญาณผ่านเทคนิคการจำแนกสัญญาณ (ANN, LDA และ SVM) ใช้ 26 ลักษณะเด่น เนื่องจากประสิทธิภาพการประเมินด้วยระยะของกลุ่มข้อมูลใน Feature Space ดีที่สุด ดังแสดงในรูปที่ 13 เมื่อเทียบกับการประเมินด้วยระยะข้อมูลใน Feature Space ของข้อมูลลักษณะเด่นทั้งหมด ดังแสดงในรูปที่ 14 โดยการบันทึกสัญญาณไฟฟ้ากล้ามเนื้อกับถุงมือข้อมูล สำหรับเทคนิค ANN ได้รับค่าประสิทธิภาพสูงสุดจากการจำแนกสัญญาณไฟฟ้ากล้ามเนื้ออยู่ที่ร้อยละ 95.95 และค่าประสิทธิภาพเฉลี่ยร้อยละ 93.53 และการประเมินผลด้วยระยะข้อมูลใน Feature Space มีพื้นที่ซ้อนทับเฉลี่ยอยู่ที่ร้อยละ 16.77 แสดงถึงข้อมูลแต่ละ

กลุ่มทับซ้อนกันเฉลี่ยที่ร้อยละ 16.77 และประสิทธิภาพระยะระหว่างกลุ่มข้อมูลใน Feature Space เฉลี่ยอยู่ที่ 2.38 สำหรับการประเมินระยะข้อมูลต่างกลุ่มในระนาบของ Feature Space อยู่ที่ 2.23

ส่วนการเก็บข้อมูลสัญญาณไฟฟ้ากล้ามเนื้อเพียงอย่างเดียวด้วยเทคนิคการจำแนกสัญญาณแบบ ANN ได้รับค่าประสิทธิภาพการทำงานสูงสุดที่ร้อยละ 97.37 และประสิทธิภาพเฉลี่ยที่ร้อยละ 95.12 นอกจากนี้การประเมินผลด้วยระยะข้อมูลใน Feature Space โดยที่คุณภาพของพื้นที่ซ้อนทับข้อมูลอยู่ที่ร้อยละ 14.38 หมายความว่าข้อมูลแต่ละกลุ่มมีส่วนซ้อนทับกันเฉลี่ยเพียงร้อยละ 14.38 และประสิทธิภาพของระยะภายในกลุ่มข้อมูลเฉลี่ยมีค่า 2.31 และการประเมินระยะของข้อมูลต่างกลุ่มมีค่า 2.21 และการประเมินผลด้วยระยะของข้อมูลใน Feature Space ผลทดลองพบว่า การเก็บข้อมูลสัญญาณไฟฟ้ากล้ามเนื้อพร้อมกับข้อมูลจากถุงมือข้อมูล และการเก็บสัญญาณไฟฟ้ากล้ามเนื้อเพียงอย่างเดียวมีประสิทธิภาพไม่แตกต่างกันอย่างมีนัยสำคัญ ดังแสดงในตารางที่ 1 และ ตารางที่ 2 หากเปรียบเทียบประสิทธิภาพการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อการเก็บสัญญาณไฟฟ้าแบบใช้ถุงมือและปลดออกแทนให้ประสิทธิภาพไม่แตกต่างกันอย่างมีนัยสำคัญ นอกจากนี้ยังมีการเทียบความเร็วในการบันทึกข้อมูลแบบที่ใช้ข้อมูลจากถุงมือร่วมกับปลดออกแทนมีระยะเวลาการเก็บข้อมูลเร็วกว่าการเก็บสัญญาณไฟฟ้ากล้ามเนื้อเพียงอย่างเดียวถึง 2.4 เท่า



รูปที่ 13 Scatter Plot ข้อมูลลักษณะเด่นทั้งหมด



รูปที่ 14 Scatter Plot ของข้อมูลลักษณะเด่นที่ผ่านการลดจำนวนแบบ FS

ตารางที่ 1 การประเมินผลด้วยระยะระหว่างข้อมูลใน Feature Space

| อุปกรณ์ที่ใช้ในการบันทึกสัญญาณ | การประเมินประสิทธิภาพระยะระหว่างข้อมูลใน Feature Space |                    |                        |
|--------------------------------|--------------------------------------------------------|--------------------|------------------------|
|                                | การซ้อนทับ                                             | ระยะของข้อมูลภายใน | ระยะของข้อมูลต่างกลุ่ม |
| ปลดออกแทน MYO และถุงมือ 5DT    | 83.23                                                  | 2.38               | 2.23                   |
| ปลดออกแทน MYO อย่างเดียว       | 85.62                                                  | 2.31               | 2.21                   |

ตารางที่ 2 ประสิทธิภาพการทำงานของกรจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ

| อุปกรณ์ที่ใช้ในการบันทึก    | เทคนิคการจำแนก | ประสิทธิภาพสูงสุด | ประสิทธิภาพเฉลี่ย |
|-----------------------------|----------------|-------------------|-------------------|
| ปลดออกแทน MYO และถุงมือ 5DT | SVM            | 94.54             | 91.63±1.46        |
|                             | LDA            | 94.14             | 91.71±2.89        |
|                             | ANN            | 95.95             | 93.53±1.13        |
| ปลดออกแทน MYO อย่างเดียว    | SVM            | 92.52             | 90.64±2.07        |
|                             | LDA            | 93.53             | 92.51±1.96        |
|                             | ANN            | 97.37             | 95.12±2.83        |

## 5. สรุปผล

การบันทึกข้อมูลจากอุปกรณ์ 2 ชนิด คือ ปลอกแขน MYO และถุงมือข้อมูล 5DT ด้วยการใช้เทคนิคการจำแนกแบบ ANN ให้ประสิทธิภาพสูงสุดที่ร้อยละ 95.95 และมีประสิทธิภาพการทำงานเฉลี่ยที่ร้อยละ 93.53 โดยใช้เวลาในการบันทึกข้อมูลประมาณ 5 นาที และการทดลองบันทึกข้อมูลจากปลอกแขน MYO เพียงอย่างเดียวด้วยเทคนิคการจำแนกสัญญาณ ANN ให้ประสิทธิภาพสูงสุดที่ร้อยละ 97.27 และประสิทธิภาพเฉลี่ยที่ร้อยละ 95.12 โดยใช้เวลาในการบันทึกข้อมูลประมาณ 12 นาที ดังนั้นเมื่อเทียบประสิทธิภาพการจำแนกสัญญาณไฟฟ้ากล้ามเนื้อ โดยที่ข้อมูลต้นแบบจากการบันทึกสัญญาณโดยใช้ปลอกแขน MYO และถุงมือข้อมูล 5DT ให้ประสิทธิภาพที่สูงกว่า แต่หากใช้การประเมินจากระยะห่างระหว่างข้อมูลใน Feature Space ข้อมูลที่ใช้ปลอกแขน MYO เพียงอย่างเดียวจะไม่มีแตกต่างกันอย่างมีนัยสำคัญ นอกจากนี้การใช้ถุงมือในการช่วยพัฒนาระบบบันทึกทำให้การบันทึกมีความง่าย ลดความซับซ้อน และลดเวลาการบันทึกสัญญาณได้เร็วขึ้นกว่า 2.4 เท่า

## 6. กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการสนับสนุนจากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์และโครงการส่งเสริมการวิจัยในอุดมศึกษาและพัฒนามหาวิทยาลัยวิจัยแห่งชาติของสำนักงานคณะกรรมการการอุดมศึกษา

## 7. เอกสารอ้างอิง

- Agamemnon, K., Iris, K., Mustafa, E., Kianoush, N., & Sethu, V. (2019). Improved prosthetic hand control with concurrent use of myoelectric and inertial measurements. *Journal of NeuroEngineering and Rehabilitation*, 14, 71.
- Al-Ani, A., & Deriche, M. (2002). Feature selection using a mutual information based measure. In *Object recognition supported by user interaction for service robots*, 4, 82–85.
- Al-Timemy, A. H., Khushaba, R. N., Bugmann, G., & Escudero, J. (2016). Improving the Performance Against Force Variation of EMG Controlled Multifunctional Upper-Limb Prostheses for Transradial Amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 24(6), 650–661.
- Barrios, L. A. (2010). *Real-time control of a multi-fingered robot hand using EMG signals* [Master's thesis]. San Diego State University. <https://digitallibrary.sdsu.edu/islandora/object/sdsu%3A4720>
- Capa, E., Cotur, Y., Gumus, C., Kaplanoglu, E., & Ozkan, M. (2014). *Comparative EMG classification of index finger* (pp. 1–3). Istanbul, Turkey. <https://doi.org/10.1109/BIYOMUT.2014.7026365>
- Castellini, C., Artemiadis, P., Wininger, M., Ajoudani, A., Alimusaj, M., Bicchi, A., Caputo, B., Craelius, W., Dosen, S., Englehart, K., Farina, D., Gijsberts, A., Godfrey, S. B., Hargrove, L., Ison, M., Kuiken, T., Marković, M., Pilarski, P. M., Rupp, R., & Scheme, E. (2004). Proceedings of the first workshop on Peripheral Machine Interfaces: going beyond traditional surface electromyography. *Frontiers in Neurorobotics*, 8, 22.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.
- Data Gloves 5DT. (2018). 5DT. <http://www.5dt.com/data-gloves>
- de Sá, J. P. M. (2012). *Pattern Recognition: Concepts, Methods and Applications*. Springer Science & Business Media.
- Fougner, A., Scheme, E., Chan, A. D. C., Englehart, K., & Staudahl, Ø. (2011). Resolving the Limb Position Effect in Myoelectric Pattern Recognition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(6), 644–651.
- Gautham, M., & Kumar, S. (2011, February). *EMG controlled bionic arm* [Paper presentation]. 2011 National Conference on Innovations in Emerging Technology, Erode, India
- Gu, Y., Yang, D., Huang, Q., Yang W., & Liu, H. (2018). Robust EMG pattern recognition in the presence of confounding factors: Features classifiers and adaptive learning. *Expert Systems with Applications*, 96, 208–217.
- Hakonen, M., Piitulainen, H., & Visala, A. (2015). Current state of digital signal processing in myoelectric interfaces and related applications. *Biomedical Signal Processing & Control*, 18, 334–359.
- Jiang, N., Dosen, S., Muller, K., & Farina, D. (2012). Myoelectric Control of Artificial Limbs amp-Is There a Need to Change Focus?. *IEEE Signal Processing Magazine*, 29(5), 152–150.
- Jianwei, L., Dinghua, Z., Xinjun, S., & Xianyang, Z. (2014). Quantification and solutions of arm movements effect on sEMG pattern recognition. *Biomedical Signal Processing and control. Science Direct*, 13, 189–197.
- Karen, T., Michael, C., Eduardo, R. & Diego, F. (2018). *Stepping-stones to Transhumanism: An EMG-controlled Low-cost Prosthetic Hand for Academia* (pp. 807–812). Funchal, Portugal. <https://doi.org/10.1109/IS.2018.8710489>
- Keinosuke, F. (1990). *Introduction to Statistical Pattern Recognition* (2nd ed.). Academic Press.

Konig, A. (2000). Dimensionality reduction techniques for multivariate data classification, interactive visualization, and analysis-systematic feature selection vs. extraction. *Fourth International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technologies. Proceedings*, 1, 44–55.

Konig, A., Eberhard, M., & Wenzel, R. (1998). A transparent and flexible development environment for rapid design of cognitive systems. *24th EUROMICRO Conference*, 2, 655–662.

Myo Gesture Control Armband. (2018). *MYO Alpha*. <https://www.myo.com>

Nguyen, N. T. N. (2018). *Developing A low-cost Myoelectric Prosthetic hand*. Metropolis University of Applied Sciences.

Oskoei, M. A., & Hu, H. (2007). Myoelectric control systems-A survey. *Biomedical Signal Processing and Control*, 2, 275–294.

Pan, L., Li, J., Xia, W., Zhang, D., & Dong, L. (2015). An effective method, composed of LAMP and dCAPS, to detect different mutations in fenoxaprop-P-ethyl-resistant American sloughgrass (*Beckmannia syzigachne* Steud.) populations. *Pesticide Biochemistry and Physiology*, 117, 1–8.

Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2012). Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*, 39(8), 7420–7431.

Raez, M. B. I., Hussain, M. S., & F. Mohd-Yasin. (2006). Techniques of EMG signal analysis: detection. *Biological Procedures Online*, 8, 11–35.

Roberto, A., Jose, M.S., & Rosa, M.V. (2010). Edited Nearest Neighbor Rule for Improving Neural Networks Classifications. *Advance in neural networks*, 6063, 303-310.

Stango, A., Negro, F., & Farina, D. (2015). Spatial Correlation of High Density EMG Signals Provides Features Robust to Electrode Number and Shift in Pattern Recognition for Myocontrol. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23(2), 189–198.

Steven, W. S. (2003). *The Scientist and Engineer's Guide to Digital Signal Processing's Table of Content*. California Technical Publishing.

Tipping, M. E., & Bishop, C. M. (1999). Mixtures of Probabilistic Principal Component Analysers. *Neural computation*, 11(2), 443-482.

Wright, T. W., Hagen, A. D., & Wood, M. B. (1995). Prosthetic usage in major upper extremity amputations. *Journal of Hand Surgery*, 20(4), 619–622.

Young, A. J., Hargrove, L. J., & Kuiken, T. A. (2012). Improving Myoelectric Pattern Recognition Robustness to Electrode Shift by Changing Interelectrode Distance and Electrode Configuration. *IEEE Transactions on Biomedical Engineering*, 59(3), 645–652.

Zhang, D., Xiong, A., Zhao, X., & Han, J. (2012). *PCA and LDA for EMG-based control of bionic mechanical hand* (pp. 960-965). Shenyang, China. <https://doi.org/10.1109/ICInfA.2012.6246955>

## 8. ประวัติผู้เขียน



เมธาวัฒน์ คุณาพิพัฒน์ ได้วุฒิทางการศึกษาระดับปริญญาตรี (B.Eng) ในสาขาวิชาวิศวกรรมเมคาทรอนิกส์ จากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ ได้ดำเนินงานวิจัยที่เกี่ยวข้องกับ EMG signal measurement and analysis, EMG signal processing, และ Machine Learning.



กิตติคุณ ทองพูล ได้วุฒิทางการศึกษาระดับปริญญาตรี (B.Eng) ในสาขาวิชาวิศวกรรมไฟฟ้า ในปี พ.ศ. 2551 และปริญญาโท (M. Eng) ในสาขาวิชาวิศวกรรมไฟฟ้า ในปี พ.ศ. 2553 จากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ และสำเร็จการศึกษาในระดับปริญญาเอก (Dr.-Ing) ในสาขาวิชา Electrical engineering จากมหาวิทยาลัย Technische Universitat Kaiserslautern ประเทศเยอรมนี ดำรงตำแหน่งอาจารย์ประจำภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ ตั้งแต่ปี พ.ศ. 2553 เป็นต้นมา และมำงานวิจัยที่เกี่ยวข้องกับ Bio-medical Instrumentation, Multi-Sensor Fusion และ Machine Learning.



ปรมินทร์ เนรนันท์ ได้วุฒิทางการศึกษาระดับปริญญาตรี (B.Eng) ในสาขาวิชาวิศวกรรมเมคาทรอนิกส์ ในปี พ.ศ. 2546 และปริญญาโท (M. Eng) ในสาขาวิชาวิศวกรรมไฟฟ้า ในปี พ.ศ. 2549 จากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ หลังจากนั้นในปี พ.ศ. 2558 ได้สำเร็จการศึกษาในระดับปริญญาเอก (Ph.D.) ในสาขาวิชา Mechanical and systems engineering จากมหาวิทยาลัยนิวคาสเซิล (Newcastle University) ประเทศสหราชอาณาจักร (United Kingdom) ได้เป็นอาจารย์ประจำภาควิชาวิศวกรรมเครื่องกล สาขาวิศวกรรมเมคาทรอนิกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ ตั้งแต่ปี พ.ศ. 2549 เป็นต้นมา และมำงานวิจัยที่เกี่ยวข้องกับ Human-robot interaction, Robotic position-based force control, Mechatronic system and robotics.



พรชัย พฤษภัทรนันท์ ได้วุฒิทางการศึกษาระดับปริญญาตรี (B.Eng) และปริญญาโท (M. Eng) ในสาขาวิชาวิศวกรรมไฟฟ้า ในปี พ.ศ. 2536 และ พ.ศ. 2540 ตามลำดับ จากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ หลังจากนั้นในปี พ.ศ. 2547 ได้สำเร็จการศึกษาในระดับปริญญาเอก (Ph.D.) ในสาขาวิชา Electrical and Computer Engineering จากมหาวิทยาลัยมินเนโซตา (University of Minnesota) ประเทศสหรัฐอเมริกา (USA) ปัจจุบันดำรงตำแหน่งรองศาสตราจารย์ ประจำภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัย สงขลานครินทร์ งานวิจัยที่สนใจ ได้แก่ การวิเคราะห์สัญญาณและภาพเพื่อการประยุกต์ใช้ในการแพทย์