



การพัฒนาการจดจำท่ามือด้วยถุงมือเซนเซอร์แบบ 16 จุดหมุน อิสระร่วมกับการโครงข่ายประสาทแบบคอนโวลูชัน Grasp Recognition Development Using 16 Degree of Freedom Sensors and Convolutional Neural Network

ชนะ จันทศรี และ จักรี ศรีนนท์ฉัตร*

Chana Chansri and Jakkree Srinonchat*

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

39 หมู่ 1 ถนนรังสิต-นครนายก อำเภอธัญบุรี จังหวัดปทุมธานี 12110

Faculty of Engineering, Rajamangala University of Technology Thanyaburi

39 Moo 1, Rangsit-Nakhornnayok Road, Thanyaburi, Pathum Thani, 12110

*E-mail: jakkree.s@en.rmutt.ac.th, Tel.: +668-9777-5038

บทคัดย่อ

ในปัจจุบันการนำระบบเซนเซอร์ต่างๆ ไปใช้เชื่อมต่อข้อมูลระหว่างมือของมนุษย์กับคอมพิวเตอร์สำหรับพัฒนาระบบรู้จำท่ามือยังเป็นสิ่งที่ท้าทาย เนื่องจากระบบเซนเซอร์ยังไม่สามารถตอบสนองความแม่นยำในการจดจำท่ามือที่ดีพอสำหรับระบบการมองเห็นของระบบคอมพิวเตอร์เพื่อนำไปใช้งานควบคุมระยะไกลและการสื่อสาร ดังนั้น งานวิจัยนี้นำเสนอการพัฒนาการจดจำท่ามือด้วยถุงมือเซนเซอร์แบบ 16 จุดหมุนอิสระร่วมกับการโครงข่ายประสาทแบบคอนโวลูชัน เซนเซอร์วัดค่าการโค้งงอของวัตถุถูกนำไปติดตั้งตามจุดหมุนของมือมนุษย์บนถุงมือจำนวน 16 จุดหมุนอิสระ เพื่อให้สามารถตรวจวัดการงอของข้อนิ้วมือแต่ละจุดในขณะใช้มือจับวัตถุ วงจรสำหรับอ่านค่าเซนเซอร์แบบ 16 จุดหมุนอิสระและวงจรรับเฟิร์มแวร์แบบปรับค่าถูกพัฒนาขึ้นใช้ในงานวิจัยนี้ เพื่อทำงานร่วมกับไมโครคอนโทรลเลอร์ Arduino Nano สำหรับบันทึกผลข้อมูลสัญญาณของเซนเซอร์แต่ละจุดเข้าสู่คอมพิวเตอร์ จากนั้นสัญญาณเหล่านี้จะถูกแปลงเป็นข้อมูลภาพด้วยวิธี Nearest Interpolation และ Color Mapping หลังจากนั้นใช้เทคนิคโครงข่ายประสาทแบบคอนโวลูชันเพื่อจดจำท่ามือจับ การจับวัตถุจริงด้วยท่ามือจับที่ใช้ในงานในชีวิตประจำวันด้วย 20 ท่ามือ จำนวน 4,000 ครั้ง ถูกนำมาใช้ในการทดสอบถุงมือเซนเซอร์ที่ออกแบบ ซึ่งผลการทดลองพบว่าระบบที่นำเสนอสามารถทำงานได้เป็นอย่างดีและมีประสิทธิภาพในการจดจำ 99.70%

คำสำคัญ: ถุงมือเซนเซอร์; การจดจำท่ามือจับ; ความต้านทานแบบโค้งงอ; โครงข่ายประสาทแบบคอนโวลูชัน

ABSTRACT

It is recently challenging to use various sensors to interface data in Human-Computer Interaction (HCI) for developing hand gesture recognition systems. However, the previous sensor system has not met the hand gesture recognition accuracy for the machine vision. Therefore, this article presents the

development of hand gesture recognition with a 16 Degree of Freedom (Dof) glove sensor combined with a convolution neural network. The flex sensors were installed to 16 points of the pivot point of the human hand on the glove so that each knuckle flex could be measured while holding the object. The 16 independent sensor multiplexer circuits and the adjustable buffer circuit were developed for use in this research to work with the Arduino Nano microcontroller to acquire each sensor's signal data to the computer. These signals are then converted to image data using Nearest interpolation and Color Mapping. The convolutional neural network techniques are used to recognize the hand gesture recognition systems. There were 4,000 hands-on captures of 20 hand grasps that were used to test the proposed system. The result indicated that the proposed system works very well, and recognition efficiency is 99.70%.

Keywords: Glove Sensor; Hand Grasp Recognition; Flex Sensor; Convolution Neural Network


1. บทนำ

เทคโนโลยีการจดจำท่ามือถูกนำมาใช้ในการปฏิสัมพันธ์ระหว่างมนุษย์กับเครื่องจักร มีการประยุกต์ใช้สำหรับงานที่หลากหลาย เช่น การจดจำภาษามือ [1], การควบคุมโดรน [2], การควบคุมแขนหุ่นยนต์ [3], การเชื่อมต่อกับระบบเสมือนจริง [4], การควบคุมหุ่นยนต์อุตสาหกรรม [5], การใช้งานทางการแพทย์ [6]–[8], และอุปกรณ์เชื่อมต่อสำหรับหุ่นยนต์ปฏิบัติการระยะไกล (Teleoperation) ที่ใช้สำหรับการทำงานในสภาพแวดล้อมที่เป็นอันตราย [9]–[10] เป็นต้น มีหลายวิธีในการจดจำท่าทางของมือ เช่น การมองเห็นตาม [11]–[12], การใช้สัญญาณชีวภาพ [13]–[14] และการอ่านข้อมูลจากถุงมือเซนเซอร์ [1], [15]–[31] เป็นต้น ซึ่งถุงมือเป็นอุปกรณ์ที่ถูกพัฒนามาใช้งานเป็นอุปกรณ์เชื่อมต่อระหว่างมือของมนุษย์กับระบบคอมพิวเตอร์ (Human Interface Device: HMI) ข้อดีของเซนเซอร์แบบถุงมือ คือ อัตราส่วนสัญญาณต่อสัญญาณรบกวน (SNR) ที่เชื่อถือได้ หลักการทำงานของถุงมือเซนเซอร์ คือ มีเซนเซอร์ฝังอยู่ในถุงมือเพื่อจับการงอของข้อนิ้วและฝ่ามือ [1], [15]–[31] สิ่งสำคัญคือ เซนเซอร์ชนิดถุงมือนี้นี้ควรมีคุณสมบัติที่นุ่มและยืดหยุ่นได้ ซึ่งจะไม่ทำให้เกิดความเครียดและอาการบาดเจ็บที่จะเกิดขึ้นกับมือ ง่ายต่อการจัดการขณะใช้งาน

จากหลักการพื้นฐานของถุงมือ HMI ที่ใช้การอ่านมุมของข้อนิ้วมือที่เปลี่ยนแปลงไปจึงมีการพัฒนาถุงมือที่ใช้หลักการอ่านค่ามุมที่หลากหลาย เช่น การใช้เซนเซอร์แบบ

โรตารี (Rotary) [16]–[18] ซึ่งใช้ตัวความต้านทานแบบปรับค่าได้ (Variable resistor) เป็นตัวทรานสดิวเซอร์ มีข้อดีคือสามารถวัดมุมได้แม่นยำแต่มีข้อเสียตรงที่มีประกอบด้วยส่วนที่แข็งซึ่งค่อนข้างยุ่งยากสำหรับการสวมใส่ เช่น เซนเซอร์แบบโค้งงอ (Bend sensor, Flex sensor) [1], [16], [19]–[25] เป็นเซนเซอร์ชนิดที่ใช้หลักการวัดการโก่งตัวของแผ่นตัวนำ ซึ่งค่าความต้านทานเปลี่ยนแปลงไปตามมุมและรัศมีการโค้งงอของอุปกรณ์ เซนเซอร์ชนิดนี้มีการใช้กันอย่างแพร่หลายสำหรับผลิตภัณฑ์เชิงพาณิชย์ เช่น CyberGlove III และ 5DT data glove [31]–[32] การใช้ถุงมือชนิดนี้มีข้อดีในการใช้งานคือ มีความทนทานและราคาต่ำ และเซนเซอร์แบบ Flex sensor นี้ยังมีข้อดีที่สามารถออกแบบมาให้ฝังอยู่ภายในถุงมือได้ [24]–[25] เซนเซอร์แสง (Optical sensor) [26]–[27] ซึ่งใช้หลักการหักเหของแสง มีการนำเสนอในงานวิจัยแต่ยังมีข้อเสียหลายอย่าง เช่น ความทนทานต่ำ และบางงานก็มีขนาดใหญ่และแข็งมากไป เซนเซอร์แบบแม่เหล็ก (Hall effect) ซึ่งยังมีข้อด้อยหลายอย่าง เช่น มีลักษณะแข็ง ขนาดใหญ่ และมีความไวต่ำ [28] ยังมีการพัฒนาและชุดวัดความเฉื่อย (inertial measurement units : IMUs) [29]–[30] ใช้สำหรับวัดทิศทางในพื้นที่ 3 มิติ โดยหลอมรวมข้อมูลของมาตรความเร่ง ไจโรสโคป และแมกนีโตมิเตอร์ ซึ่งเป็นเซนเซอร์แม่เหล็กตรวจจับการเคลื่อนไหวในสนามแม่เหล็ก IMU และเซนเซอร์แม่เหล็กสำหรับวัดการเคลื่อนไหวของร่างกาย แต่โครงสร้างยังมีส่วนแข็งที่ค่อนข้างใหญ่ จากงานวิจัยที่

กล่าวมาทั้งหมดพบว่า การพัฒนาเซนเซอร์แบบงู่มือ อุปกรณ์ที่ถูกนำมาใช้มากที่สุดคือการใช้ Flex sensor เนื่องจากมีโครงสร้างที่เรียบง่าย ขนาดพอเหมาะ ติดตั้งง่าย และมีราคาถูก อย่างไรก็ตามงานวิจัยทั้งหลายนี้มักจะติดตั้ง Flex sensor ขึ้นเดียวต่อนิ้วมือหนึ่งนิ้ว [1], [19], [20], [23], [25] หรือ 2 เซนเซอร์ต่อนิ้วมือ [1], [21], [24] จึงไม่สามารถวัดมุมข้อนิ้วในแต่ละจุดได้ การวัดมุมจึงเป็นการวัดการงอของนิ้วทั้งนิ้วรวมกัน ประสิทธิภาพในการจดจำท่ามืออยู่ที่ 89.5% [25] จากการทดสอบด้วยท่ามือ 10 ท่า ซึ่งเป็นการพัฒนาเซนเซอร์แบบ 5 DoF ทำงานร่วมกับการวิเคราะห์ท่ามือด้วย CNN




รูปที่ 1 จุดหมุนของฝ่ามือแบบ 16 DoF [33]

จากงานวิจัยที่กล่าวถึงโครงสร้างของฝ่ามือ พบว่า มือมนุษย์มีจุดหมุนอิสระ (degrees of freedom : DoF) ของมือ 16 จุด [16], [33] ดังรูปที่ 1 ดังนั้นการเก็บข้อมูลจากมือต้องเก็บข้อมูลจาก DoF ทั้ง 16 จุด จึงจะได้ข้อมูลที่สมบูรณ์ในงานวิจัยนี้จึงได้พัฒนาเซนเซอร์งู่มือที่ตรวจจับจุดหมุนทั้ง 16 จุด ตามเฉพาะจุดที่สามารถงอได้ เพื่อนำมาพัฒนาระบบจดจำท่ามือที่มีประสิทธิภาพ

2. อุปกรณ์และเครื่องมือ


งานวิจัยนี้เป็นการพัฒนาระบบจดจำท่ามือจับเพื่อนำไปประยุกต์ใช้กับการปฏิสัมพันธ์ระหว่างมนุษย์กับเครื่องจักร จากงานวิจัยก่อนหน้านี้ได้มีการพัฒนางู่มือที่ติดตั้งเซนเซอร์แบบขึ้นเดียวต่อนิ้วมือ หรือ 2 ขึ้นต่อนิ้วมือ ผลการจดจำท่ามือที่ได้ยังมีความผิดพลาดอยู่มาก ดังนั้นงานวิจัยนี้จึงได้พัฒนางู่มือที่ให้ความสามารถในการอ่านรายละเอียดจากมือเพิ่มขึ้นด้วยการติดตั้งเซนเซอร์ในตำแหน่งจุดหมุนของมือแบบ 16 DoF เพื่อให้สามารถอ่านค่าได้จากจุดหมุนของมือทุกจุดและจดจำท่ามือจับด้วยเทคนิคโครงข่ายประสาทแบบคอนโวลูชัน (Convolution Neural Network: CNN) มาประยุกต์ใช้ โดยทำงานด้วย CNN ชนิด AlexNet [34] เนื่องจากข้อมูลที่ได้จากงู่มือเซนเซอร์ที่พัฒนามีขนาด 16 ช่อง จึงไม่จำเป็นต้องใช้โครงข่าย CNN ที่ซับซ้อน แต่ได้เลือกใช้ CNN ที่ให้ผลการทำงานรวดเร็ว [35] เป็นสำคัญ ขั้นตอนการทำงานของงู่มือเซนเซอร์ ดังรูปที่ 2 ประกอบด้วย 1) งู่มือที่ติดตั้ง Flex sensor แบบ 16 DoF, 2) สวมใส่และจับวัตถุ โดยการทดสอบได้เลือกท่ามือจับวัตถุที่ใช้ในชีวิตประจำวันจำนวน 20 ท่ามือจับ [36]–[37], 3) อ่านค่าสัญญาณที่ได้จากเซนเซอร์ด้วยไมโครคอนโทรลเลอร์ (Microcontroller) โดยอ่านสัญญาณท่าละ 10 วินาที, 4) นำสัญญาณที่อ่านได้ซึ่งเป็นข้อมูลขนาด 1 มิติ จำนวน 16 ข้อมูล มาสร้างเป็นข้อมูลภาพ 2 มิติ ขนาด 227×227 พิกเซล สำหรับเป็น Input ให้กับ CNN, 5) นำชุดข้อมูลที่ได้เข้าเรียนรู้ (Training) กับ CNN จากนั้นนำข้อมูลภาพชุดทดสอบเข้าทดสอบ (Testing) และสุดท้าย 6) รายงานผลการทำนายท่ามือจับซึ่งงานวิจัยนี้ได้ทำการวัดทดสอบเพื่อประเมินประสิทธิภาพของงู่มือเซนเซอร์ที่ได้พัฒนาขึ้นในหัวข้อที่ 4




รูปที่ 2 ขั้นตอนการทำงานของถุงมือเซนเซอร์ 16 DoF

2.1 เซนเซอร์และการออกแบบวงจร

อุปกรณ์ Flex sensor ที่นำมาใช้มีลักษณะดังรูปที่ 3 โครงสร้างเป็นหมึกพิมพ์นำไฟฟ้าถูกพิมพ์อยู่บนแผ่นฉนวนรองรับ (Substrate) แบบยืดหยุ่น ผงหมึกพิมพ์มีคุณสมบัตินำไฟฟ้า กระบวนการพิมพ์ทำให้ผงหมึกมีการรวมตัวกันอย่างหลวมๆ ในขณะที่แผ่นเซนเซอร์อยู่ในแนวราบปกติจึงมีค่าความต้านทานที่ปลายทั้ง 2 ข้าง ประมาณ $25k\Omega$ [23, 38] เมื่อมีการโค้งตัวของเซนเซอร์ความยาวของเซนเซอร์จะเพิ่มขึ้นผงหมึกที่รวมตัวอยู่จะกระจายตัวออกซึ่งจะทำให้ระยะห่างของผงหมึกมากขึ้น คุณสมบัติการนำไฟฟ้าจึงลดลงทำให้ค่าความต้านทานเพิ่มขึ้น



รูปที่ 3 ลักษณะของ Flex Sensor ที่ใช้งาน



รูปที่ 4 การโค้งตัวและมุมการโค้งตัวของ Flex Sensor

ค่าความต้านทานของ Flex Sensor จะแปรเปลี่ยนไปตามมุมที่เกิดการโค้งตัวดังรูปที่ 4 ซึ่งค่าความต้านทานเป็นดังสมการที่ 1-3 [23]

$$\theta = 0^\circ \rightarrow R_s \approx 25k\Omega \quad (1)$$

$$\theta = 45^\circ \rightarrow 25k\Omega < R_s \ll 125k\Omega \quad (2)$$

$$\theta = 90^\circ \rightarrow 25k\Omega \ll R_s < 125k\Omega \quad (3)$$


ที่มุม 45° ความต้านทานนี้จะอยู่ที่ประมาณ $75k\Omega$ ที่มุม 90° ความต้านทานนี้จะอยู่ที่ประมาณ $125k\Omega$ เมื่อเซนเซอร์ถูกปรับให้อยู่ในแนวราบอีกครั้ง ความต้านทานจะกลับสู่ค่าเดิม ดังนั้นเราจึงสามารถวัดมุมองได้โดยดูจากค่าความต้านทานที่เกิดขึ้น ในทางทฤษฎี ค่าของ R_s ($k\Omega$) สัมพันธ์กับมุมดังนี้

$$R_s = 100 \cdot \frac{\theta}{180} + 25 \quad (4)$$

วงจรบัฟเฟอร์แบบปรับได้ (Adjustable Buffer) [34] ดังรูปที่ 5 สามารถเพิ่มโพเทนชิโอมิเตอร์ (Potentiometer) ลงในวงจรเพื่อปรับช่วงแรงดันขาออก V_{out} โดยสามารถหาค่าได้จากสมการที่ 5

$$V_{out} = \left(\frac{R_s}{R_s + R_1} V \right) \cdot \left(1 + \frac{R_2}{R_3 + R_4} \right) - V_{R4} \quad (5)$$


โดยที่ R_1 คือ ความต้านทานไบอัสให้กับ Flex Sensor มีค่าคงที่และ R_s คือ ความต้านทานไฟฟ้าแผ่นแปรของ Flex Sensor ที่ติดตั้งกับถุงมือ ซึ่งเปลี่ยนค่าตามการโค้งงอที่ทำให้เกิดความเครียดแรงดันตกคร่อม R_s เป็นแรงดันขาเข้า V_{in} ส่งต่อไปที่วงจรขยาย



รูปที่ 5 วงจรบัพเฟอร์แบบปรับได้


ดังนั้นจากสมการที่ 4 และ 5 แสดงถึงความสัมพันธ์เชิงเส้นตรงระหว่างมุม θ และแรงดันแรงดันขาออก V_{out} อย่างไรก็ตาม เมื่อเซนเซอร์ติดเข้ากับนิ้วที่กำลังเคลื่อนที่พบว่าค่าความผิดพลาดของค่าความต้านทานเริ่มต้นของ Flex Sensor แต่ละตัว และมุม θ เริ่มต้นของเซนเซอร์ที่ถูกติดตั้งเข้ากับนิ้วมือแต่ละตัวไม่ได้อยู่ที่ 0 องศา นำไปสู่พฤติกรรมที่คาดเดาไม่ได้ส่งผลให้ค่าแรงดันขาออก V_{out} เริ่มต้นจึงไม่อยู่ในตำแหน่งเดียวกัน ความไม่สอดคล้องกันของแรงดันขาออกของเซนเซอร์ที่ไม่ตรงกันกับค่าทางทฤษฎีสะท้อนถึงการมีอยู่ของความไม่เชิงเส้นและความไม่แน่นอนในตัวเซนเซอร์เอง แต่เหตุการณ์ดังกล่าวก็ไม่ใช่อุปสรรคเมื่อใช้การประมวลผลด้วย CNN เนื่องจากข้อมูลจาก Flex Sensor แต่ละตำแหน่งถือเป็นข้อมูลอิสระต่อกันที่สามารถนำเข้าสู่ระบบเพื่อทดสอบได้โดยตรง โดยการติดตั้งตำแหน่ง

ของ Flex Sensor ในงานวิจัยนี้มีตำแหน่งแต่ละจุดตามข้อนิ้วมือเป็นดังรูปที่ 6



รูปที่ 6 ตำแหน่งติดตั้ง Flex Sensor ทั้ง 16 ตัว

การอ่านค่าการเปลี่ยนแปลงแรงดันขาออก V_{out} จาก Flex sensor แต่ละตัวใช้ IC Multiplexer เบอร์ 74HC4067 ดังรูปที่ 7 เพื่อเลือกตำแหน่งของ Flex sensor ที่ต้องการอ่านค่า Output จาก Multiplexer เข้าสู่วงจรบัพเฟอร์แบบปรับค่าได้ ซึ่งได้เพิ่ม Potentiometer (R_4) ลงไปเพื่อปรับช่วงความไว (Sensitivity) ได้ จากนั้นสัญญาณที่ออกจากวงจรบัพเฟอร์ถูกวัดโดยใช้ตัวแปลง Analog to Digital (A/D) ที่มีอยู่ในอุปกรณ์ Arduino nano microcontroller [39] สัญญาณที่ได้ถูกบันทึกเพื่อนำไปทดสอบในลำดับถัดไป



รูปที่ 7 วงจรมัลติเพล็กซ์สำหรับอ่านค่าสัญญาณจากถุงมือเซนเซอร์

2.2 ถุงมือเซนเซอร์

เนื่องจาก Flex Sensor มีคุณสมบัติที่โค้งตัวได้จึงสามารถนำมาติดตั้งบริเวณจุดหมุนที่ข้อนิ้วมือและข้อมือจำนวน 16 DoF ซึ่งขณะการจับวัตถุหรือจัดการของมือ เซนเซอร์จะมีการโค้งตัวรองรับกับการจัดเรียงนิ้วมือไปตามรูปทรงของวัตถุทำให้เกิดการเปลี่ยนแปลงความต้านทาน ซึ่งจะมีค่าเฉพาะตัวแตกต่างกันไปตามแต่ละท่ามือ ถุงมือเซนเซอร์ที่พัฒนาขึ้นเพื่อใช้ในการทดลองในงานวิจัยนี้เป็นดังรูปที่ 8




รูปที่ 8 ถุงมือที่ติดตั้ง Flex Sensor แบบ 16 DoF

2.3 ท่าจับมือวัตถุ

การทดสอบประสิทธิภาพถุงมือเซนเซอร์ที่พัฒนาขึ้นเพื่อจดจำท่ามือจากถุงมือแบบ 16 DoF งานวิจัยนี้จึงได้ศึกษารูปแบบของท่ามือขณะจับวัตถุเพื่อนำไปใช้ในการควบคุมการจับวัตถุของระบบหุ่นยนต์ได้ Minjie Cai และคณะ [36] และ Thomas Feix และคณะ [37] ได้แบ่งรูปแบบท่ามือในการจับวัตถุออกเป็น 20 ท่า ประกอบด้วยท่า Large Diameter, Medium Wrap, Small Diameter, Fixed Hook, Index Finger Extension, Thump Index Finger, Thump 2 Finger, Thump 3 Finger, Thump 4 Finger, Writing Tripod, Tip Pinch, Power Sphere, Power Disk, Precision Disk, Tripod, Lateral Tripod, Parallel Extension, Extension Type, Literal Pinch และ Ring ท่าทางการจับวัตถุแบบต่างๆ แสดงดังรูปที่ 9 ในแต่ละท่าจับ

มีลักษณะการงอนิ้วที่แตกต่างกัน ซึ่งจุดหมุนของข้อนิ้วในแต่ละจุดที่ติดตั้ง Flex sensor ไว้จะทำให้ค่าความต้านทานเปลี่ยนแปลงไปตามด้วย โดยจะเพิ่มขึ้นเมื่อมีการงอนิ้วมากขึ้น ลักษณะความเปลี่ยนแปลงนี้ทำให้เราสามารถเปรียบเทียบรูปแบบของท่ามือแต่ละท่าได้



รูปที่ 9 ท่ามือจับ 20 ท่า ที่ใช้ในการทดลอง [36], [37]

3. วิธีการ

การทดสอบประสิทธิภาพถุงมือเซนเซอร์ที่ได้พัฒนาขึ้น มีกระบวนการทำงานในแต่ละขั้นตอนดังต่อไปนี้ เพื่อประเมินสมรรถนะของถุงมือเซนเซอร์ในขณะการนำไปใช้จับวัตถุที่เกิดขึ้นจริงในชีวิตประจำวัน


3.1 วิธีการทดลอง

รูปแบบของท่าจับมือขึ้นอยู่กับวัตถุที่กำลังดำเนินการจับ ดังนั้นเพื่อให้สอดคล้องกับท่ามือที่ใช้ จึงได้ทำการจัดวัตถุที่เหมาะสมกับการใช้ท่ามือจับในแต่ละท่า จำนวนท่าละ 5 ชนิด ทำการจับวัตถุแต่ละชนิดจำนวน 40 ครั้ง รวมหนึ่งท่ามือจะมีจำนวน 200 ข้อมูล ดังนั้นในการทดลองได้ใช้ 20 ท่ามือ รวมเป็นทั้งหมด 4000 ข้อมูล ซึ่งถูกกำหนดเป็นชุดข้อมูลที่นำไปทดสอบกับ CNN ต่อไป

3.2 สัญญาณเซนเซอร์และภาพ

สัญญาณการเปลี่ยนแปลงที่ได้จากเซนเซอร์จะถูกทำ A/D ด้วยไมโครคอนโทรลเลอร์แล้วนำเข้าและบันทึกด้วยโปรแกรม MATLAB R2021a โดยทำการบันทึกข้อมูลเป็น

เวลา 10 วินาทีต่อข้อมูล จำนวนชักตัวอย่าง (Sampling) 120 จุดต่อวินาที ลักษณะสัญญาณที่ได้เป็นดังรูปที่ 10



รูปที่ 10 สัญญาณที่ได้จากการอ่านเซนเซอร์แต่ละตัว

จากนั้นทำการจัดเรียงข้อมูลเป็นเมทริกซ์

$$I = \begin{bmatrix} T_1(1) & T_1(2) & T_1(3) & \dots & T_1(1200) \\ T_2(1) & T_2(2) & T_2(3) & \dots & T_2(1200) \\ T_3(1) & T_3(2) & T_3(3) & \dots & T_3(1200) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ W(1) & W(2) & W(3) & \dots & W(1200) \end{bmatrix} \quad (6)$$

เมื่อจัดเรียงเมทริกซ์ข้อมูลที่ได้จากเซนเซอร์เป็นข้อมูลภาพจะได้ดังรูปที่ 11 โดยแต่ละแถวจะเป็นตำแหน่งของเซนเซอร์ ซึ่งมีจำนวน 16 แถวและในแนวคอลัมน์จะเป็นข้อมูลที่เกิดขึ้นตามเวลา 0-10 วินาที จำนวน 1200 คอลัมน์



รูปที่ 11 รูปจากการจัดเรียงเมทริกซ์ข้อมูลขนาด 16x1200

เนื่องจากในงานวิจัยนี้ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน โมเดล AlexNet โดยวิธี Transfer learning มาทำการทดสอบ ซึ่งโมเดล AlexNet แบบ Transfer learning กำหนดขนาดภาพอินพุตอยู่ที่ $227 \times 227 \times 3$ (ภาพสีมีขนาด 3 เลเยอร์) ดังนั้นจึงต้องทำการแปลงข้อมูลภาพจาก $16 \times 1200 \times 1$ (ภาพระดับสีเทามีขนาด 1 เลเยอร์ ในรูปที่ 11) ไปเป็นภาพขนาด $227 \times 227 \times 3$ เพื่อให้มีขนาดภาพ

เป็นไปตามข้อกำหนดขนาดอินพุตของ AlexNet โดยในงานนี้เลือกใช้วิธีการ Nearest interpolation ในการขยายขนาดภาพ เนื่องจากภาพที่ได้จากการแปลงด้วยวิธี Nearest interpolation ไม่ทำให้เกิดการรบกวนของข้อมูลในแต่ละช่องสัญญาณ ภาพที่ขยายจึงยังคงมี 16 ช่องแต่มีขนาดเป็นไปตามข้อกำหนดของ AlexNet โดยวิธีการแปลงขนาดภาพด้วยวิธี Nearest interpolation เป็นดังสมการที่ 7

$$I'(x',y') = I(\text{round}\{f_x^{-1}(x',y')\}, \text{round}\{f_y^{-1}(x',y')\}) \quad (7)$$


โดย $I'(x',y')$ คือ ภาพที่ได้หลังจากแปลงขนาด

I คือ ภาพที่แปลงขนาด

x' คือ ค่าในตำแหน่งพิกัดแกน X ของภาพต้นฉบับ

y' คือ ค่าในตำแหน่งพิกัดแกน Y ของภาพต้นฉบับ

ขั้นตอนสุดท้ายจะแปลงเป็นข้อมูลภาพสีด้วยวิธี Color mapping ดังรูปที่ 12 ซึ่งภาพที่ได้จะถูกกำหนดขนาดที่ 227×227 pixels และเป็นภาพ 3 เลเยอร์นำไปเป็นชุดข้อมูลสำหรับทดสอบด้วย CNN ต่อไป




รูปที่ 12 รูปสีขนาด 227x227 pixels ที่ได้จากการแปลงภาพด้วยวิธี Color mapping

3.3 โครงข่ายประสาทแบบคอนโวลูชัน

โครงข่ายประสาทแบบคอนโวลูชันมีหลากหลายรูปแบบ ปัจจุบันนิยมใช้ในงานด้านการเรียนรู้ของคอมพิวเตอร์เป็นอย่างมากโดยเฉพาะการประยุกต์ใช้ด้านเรียนรู้เชิงลึกกับระบบแมชชีนวิชัน ซึ่งในงานวิจัยนี้เลือกใช้โครงข่ายที่นำมาทดสอบคือ AlexNet เนื่องจากมีความรวดเร็วในการทำงาน โครงข่ายประสาทนี้กำหนดขนาดภาพ

อินพุตเป็น $227 \times 227 \times 3$ โครงสร้างสถาปัตยกรรมประกอบด้วยชั้น (Layer) ทั้งหมด 8 ชั้น เป็นชั้น คอนโวลูชัน 5 ชั้นและเป็น ชั้น Fully connected 3 ชั้น ซึ่งในงานนี้ได้กำหนดจำนวนคลาสของท่ามือจับไว้จำนวน 20 class ในส่วนของ SoftMax จึงได้กำหนดเอาต์พุตเป็น 20 class เช่นกัน โดยมีรูปแบบสถาปัตยกรรมดังรูปที่ 13



รูปที่ 13 รูปแบบสถาปัตยกรรมของ AlexNet

พารามิเตอร์ที่ใช้ในการเรียนรู้สำหรับข้อมูลภาพที่ได้เป็นดังตารางที่ 1 โดยเป็นพารามิเตอร์ที่ได้ทดสอบแล้วพบว่า เป็นค่าที่เหมาะสมที่สุดสำหรับงานวิจัยนี้ และในการทดสอบเรียนรู้ได้ใช้ GPU VNIDIA GEFORCE GTX 1650 เป็นหน่วยประมวลผลในการดำเนินงาน ใช้เวลาในการคำนวณ 468 ms/ภาพ เมื่อทำการทดสอบสามารถให้ผลการทำนายที่รวดเร็วโดยใช้เวลาไม่ถึง 1 วินาทีต่อภาพ

ตารางที่ 1 พารามิเตอร์ที่ใช้ในการเรียนรู้


พารามิเตอร์	ค่า
Class	20
Image	4000
Initial Learning Rate	0.001
Epochs	50
Stochastic Gradient Descent with Momentum	0.9
MiniBatchSize	16
LearnRateDropFactor	0.1
LearnRateDropPeriod	8

4. ผลการวิจัยและการอภิปรายผล


เมื่อได้ข้อมูลภาพจากการแปลงสัญญาณขณะทดสอบใช้ถู่มือเซนเซอร์จับวัตถุ โดยใช้ท่ามือจับจำนวน 20 ท่ามือ แล้วนำภาพที่ได้แปลงให้เป็นขนาด 227×227 pixels และมี 3 เลเยอร์ เพื่อให้เหมาะสำหรับการเรียนรู้ของโครงข่ายประสาทแบบคอนโวลูชัน โดยได้ผลการทดลองในแต่ละขั้นตอนดังต่อไปนี้

4.1 สัญญาณที่ได้จากท่าจับ

ผลของการเปลี่ยนแปลงความต้านทานถูกบันทึกในรูปแบบของแรงดันเอาต์พุต ซึ่งเปลี่ยนแปลงตามการงอนิ้วมือ ซึ่งในรูปที่ 14 เป็นตัวอย่างสัญญาณที่ได้ในบางท่ามือจับวัตถุ พบว่า เมื่อมีการงอนิ้วมือที่แตกต่างกันทั้งลักษณะและความสูงของเส้นกราฟย่อมแตกต่างกัน ดังนั้น เมื่อมีการจับวัตถุซึ่งท่ามือที่ใช้ในการจับวัตถุจะสามารถวิเคราะห์ได้จากลักษณะกราฟที่เกิดขึ้น โดยลักษณะท่ามือจับแบบ Large Diameter, Medium Wrap และ Small Diameter จะมีลักษณะในการจับที่เหมือนกัน แตกต่างกันแค่ขนาดของวัตถุ ซึ่งสังเกตได้ว่าความสูงของกราฟที่เกิดจากท่า Small Diameter จะสูงที่สุด รองลงมาคือ Medium Wrap และต่ำสุดคือ Large Diameter เนื่องจากท่าจับแบบ Small Diameter จะมีมุมองศาที่เกิดขึ้นมากที่สุด เป็นผลให้ความสูงของสัญญาณมากที่สุดตามไปด้วย ในขณะที่เดียวกันสำหรับท่ามือจับอื่นๆ รูปแบบและมุมองศาของนิ้วมือจะแตกต่างกันไป กราฟที่ได้จึงแตกต่างกัน




รูปที่ 14 ตัวอย่างกราฟที่เกิดขึ้นจากท่ามือจับวัตถุที่แตกต่างกัน



รูปที่ 14 (ต่อ) ตัวอย่างกราฟที่เกิดจากท่ามือจับวัตถุที่แตกต่างกัน

4.2 ภาพที่ได้จากการแปลงสัญญาณ

ข้อมูลที่อ่านได้จากเซนเซอร์แต่ละตัวเป็นข้อมูล 1 มิติ ขนาด 16 ช่อง ในรูปที่ 14 ข้อมูลของสัญญาณดังกล่าวถูกนำมาเปลี่ยนเป็นข้อมูลภาพ ซึ่งมีลักษณะ 2 มิติ 3 ชั้น เพื่อเป็นอินพุตของโครงข่ายประสาทแบบคอนโวลูชัน เมื่อถูกแปลงเป็นข้อมูลภาพจะได้ดังรูปที่ 15 ซึ่งเป็นภาพที่เกิดจากการใช้ถุงมือเซนเซอร์จับวัตถุในท่ามือต่างๆ ผลของการเปลี่ยนแปลงความต้านทานที่ถูกบันทึกในรูปแบบของแรงดันเอาต์พุต ซึ่งเปลี่ยนแปลงตามการงอนิ้วมือ เมื่อนำข้อมูลนั้นมาเปลี่ยนเป็นข้อมูลภาพพบว่าเมื่อมีการงอนิ้วมือที่แตกต่างกันทั้งลักษณะและสีของภาพจะเปลี่ยนแปลงไป และในแต่ละท่ามือจับวัตถุก็จะได้ภาพที่มีลักษณะและสีแตกต่างกัน




รูปที่ 15 ตัวอย่างภาพที่เกิดจากท่ามือจับวัตถุที่แตกต่างกัน

ลักษณะท่ามือที่แตกต่างกันจะให้ภาพที่แตกต่างกันอย่างชัดเจน แม้ว่าลักษณะท่ามือจับจะเป็นท่าที่คล้ายกัน เช่น Large Diameter, Medium Wrap และ Small Diameter แต่เนื่องจากมุมองศานิ้วมือที่ต่างกัน ทำให้ภาพที่ได้แตกต่างกันอย่างชัดเจน เมื่อมีการงอนิ้วมือมาก ความสว่างของภาพก็สูงขึ้น และเมื่อเปรียบเทียบท่ามือจับที่แตกต่างกัน เช่น Ring Fixed Hook และ Index Finger Extension ภาพที่ได้ก็มีความแตกต่างกันอย่างชัดเจน ทั้งในด้านลักษณะของภาพและความสว่างของภาพที่เกิดขึ้น ดังนั้นการแปลงเป็นภาพสีที่มีความแตกต่างของระดับสีในแต่ละช่องเป็นสิ่งที่ไม่งานวิจัยนี้ให้ตั้งสมมติฐานว่า CNN จะสามารถดึงค่าคุณลักษณะและจำแนกท่าทางของมือได้


4.3 ผลการจดจำ

เพื่อทดสอบประสิทธิภาพการใช้งานจริงของถุงมือเซนเซอร์ที่พัฒนาขึ้น จึงได้ทดสอบการจดจำท่ามือจากการจับวัตถุ 20 ท่ามือ โดยแบบจำลอง CNN ถูกนำมาใช้สำหรับการจดจำท่าทางของมือ ซึ่งได้รับการเรียนรู้และตรวจสอบโดยใช้ข้อมูลจากการจับวัตถุจริงท่ามือละ 5 ชนิด ทำการจับชนิดละ 40 ครั้งรวมเป็นท่าละ 200 ครั้ง ทำให้มีข้อมูลการจับวัตถุทั้งหมด 4000 ข้อมูล ซึ่งนำมาแบ่งออกเป็น 50% สำหรับสอนให้ระบบเรียนรู้และอีก 50% สำหรับทดสอบทำการทดสอบ 10 ครั้ง โดยได้ผลการทดสอบเป็นเมทริกซ์ความสับสนดังในรูปที่ 16 และกราฟแสดงความถูกต้องในการจดจำท่ามือจับ 20 ท่า ดังรูปที่ 17 ซึ่งมีความถูกต้องเฉลี่ยเท่ากับ 99.70% โดยท่ามือที่มีความถูกต้อง 100% มี 12 ท่า คือ Large Diameter, Thump Index Finger, Thump 4 Finger, Writing Tripod, Tip Pinch, Power Sphere, Power Disk, Precision Disk, Lateral Tripod, Parallel Extension, Literal Pinch และ Ring ส่วนท่ามือที่ค่าความถูกต้องในการทำนายต่ำสุด คือ Small Diameter มีค่าความถูกต้อง 98.4%



รูปที่ 16 ความถูกต้องของการจดจำท่ามือจับ แสดงโดยเมทริกซ์ความสับสนที่ได้รับ

เมื่อพิจารณาผลการทดลองที่ได้พบว่าการทำนายของ Small Diameter บางครั้งถูกทำนายเป็นท่า Fixed Hook สาเหตุเนื่องจาก 2 ท่านี้มีการจัดเรียงนิ้วมือขณะจับวัตถุที่คล้ายกันมาก และท่าที่ถูกทำนายผลบวกสูงมากที่สุด คือ ท่า Power Disk และท่า Tip Pinch ซึ่งท่ามือจับมีการจัดเรียงนิ้วและองศาของนิ้วมือบางครั้งคล้ายกับท่า Small Diameter และ Thumb 3 Finger ตามลำดับ



รูปที่ 17 ความถูกต้องของการจดจำแต่ละท่ามือจับวัตถุ

4.4 อภิปรายผล

สัญญาณที่ได้จากถุงมือเซนเซอร์ซึ่งอ่านผ่านวงจรมัลติเพล็กซ์และวงจรรับฟเฟอร์แบบปรับได้ วงจรได้ออกแบบมาให้มีความไวอยู่ในช่วง 0-5 โวลต์ เพื่อให้เหมาะกับวงจร

A/D ในไมโครคอนโทรลเลอร์ ช่วงไดนามิกของสัญญาณจากการอนั้ว 0-90 องศาอยู่ที่ 1.5 โวลต์ ซึ่งในส่วนที่ออกแบบนี้ดีกว่างานของ [22], [24-25] ซึ่งไม่มีวงจรรับฟเฟอร์ ค่าความผิดพลาดของค่าความต้านทานเริ่มต้นของ Flex Sensor แต่ละตัวและมุมเริ่มต้นของเซนเซอร์ที่ถูกติดตั้งเข้ากับนิ้วมือแต่ละตัวไม่ได้อยู่ที่ 0 องศา ส่งผลให้ค่าแรงดันขาออก V_{out} เริ่มต้นจึงไม่อยู่ในตำแหน่งเดียวกัน อีกสิ่งหนึ่งคือ ค่าความไม่เชิงเส้นและความไม่แน่นอนของค่าความต้านทานของเซนเซอร์อันเกิดมาจากการกระบวนการผลิต จึงส่งผลให้เกิดเหตุการณ์ดังกล่าว แต่ลักษณะของสัญญาณที่ได้ก็พบเจอเช่นเดียวกันกับงาน [23], [25] ซึ่งไม่มีผลกับกระบวนการวิเคราะห์ของงานวิจัยนี้ เนื่องจากการใช้โครงข่าย CNN เป็นส่วนรู้จำ ซึ่งข้อมูลภาพ Input ที่ป้อนเข้า CNN จากเซนเซอร์แต่ละตัวมีความอิสระต่อกัน การจับวัตถุแต่ละท่ามือมีการจัดเรียงนิ้วและมุมองศาของนิ้วมือแตกต่างกันทำให้สัญญาณที่ได้จาก Flex Sensor จึงแตกต่างกันเมื่อทำการแปลงเป็นข้อมูลภาพทำให้ผลที่ได้มีความชัดเจนในด้านความแตกต่างของภาพ ประสิทธิภาพในการจดจำท่ามือจับในงานวิจัยนี้อยู่ที่ 99.7% จากการทดสอบด้วยท่ามือจับ 20 ท่า ซึ่งพิสูจน์ได้อย่างชัดเจนว่าการใช้ถุงมือเซนเซอร์แบบ 16 DoF ร่วมกับโครงข่าย CNN ให้ประสิทธิภาพสูงกว่าถุงมือเซนเซอร์แบบจุดเดียวต่อนิ้ว (5 DoF) [21], [25] หรือเซนเซอร์ถุงมือแบบ 2 จุดต่อนิ้ว (10 DoF) [22], [24] ผลการทำนายที่ผิดพลาดเล็กน้อยเกิดจากท่ามือที่มีลักษณะคล้ายกัน ดังนั้น การเพิ่มจำนวนเซนเซอร์ให้ครบตามจำนวนจุดหมุนของนิ้ว (16 DoF) ให้ผลดีกว่าเซนเซอร์ถุงมือแบบจุดเดียวต่อนิ้ว (5 DoF) และเซนเซอร์ถุงมือแบบ 2 จุดต่อนิ้ว (10 DoF) เมื่อใช้วิธี CNN ในการวิเคราะห์

4.5 งานวิจัยในอนาคต

สำหรับงานวิจัยในอนาคตนั้นได้วางแผนดำเนินงานเพื่อการพัฒนาถุงมือเซนเซอร์แบบใหม่ที่ประกอบด้วยเซนเซอร์วัดมุมแบบ 16 DoF ร่วมกับ Tactile Sensor Array ซึ่งจะทำให้การจับวัตถุในแต่ละครั้งจะได้ข้อมูลใน 2 รูปแบบคือค่ามุมจากการอนั้วที่วัดด้วย Flex Sensor และ Pressure Profile ของวัตถุที่ได้จาก Tactile Sensor หรือที่เรียกอีกอย่างว่า Tactile Image ในงานจะนำข้อมูลทั้ง

2 รูปแบบมาใช้ในวิเคราะห์ร่วมกันเพื่อทำนายวัตถุที่อยู่ในมือด้วยวิธีการ CNN เป็นระบบจดจำวัตถุจากการจับวัตถุที่มีประสิทธิภาพต่อไป

5. สรุปผลการวิจัย

ในการศึกษานี้ได้พัฒนาถุงมือเซนเซอร์แบบ 16 DoF ซึ่งมีลักษณะการทำงานตามมือมนุษย์จริง การพัฒนาได้ประยุกต์ใช้งาน Flex Sensor ซึ่งมีคุณสมบัติค่าความต้านทานจะเปลี่ยนแปลงตามมุมที่เซนเซอร์โค้งตัว เมื่อนำ Flex Sensor ติดตั้งตามจุดหมุนของมือจำนวน 16 จุด จะสามารถวัดการงอของข้อนิ้วมือแต่ละจุดได้และงานวิจัยนี้ได้พัฒนางจรสำหรับอ่านค่าสัญญาณถุงมือเซนเซอร์ด้วยวงจรบัพเฟอร์แบบปรับได้ทำงานร่วมกับไมโครคอนโทรลเลอร์

Arduino Nano เพื่อบันทึกผลข้อมูลเข้าสู่คอมพิวเตอร์ จากนั้นได้ทดสอบประสิทธิภาพในการจดจำท่ามือจับวัตถุที่ใช้ในชีวิตประจำวันโดยการจับวัตถุจริงจำนวน 20 ท่ามือแล้วแปลงสัญญาณจาก Flex Sensor จำนวน 16 ตัว ที่ได้เป็นข้อมูลเมทริกซ์ไปเป็นข้อมูลภาพด้วยวิธี Nearest Interpolation และ Color Mapping แล้วส่งต่อข้อมูลภาพให้กับโครงข่าย CNN แบบ AlexNet เพื่อเรียนรู้และทดสอบถุงมือเซนเซอร์ ซึ่งผลการทดสอบพบว่า มีประสิทธิภาพในการจดจำเฉลี่ย 99.70% ความผิดพลาดเล็กน้อยเกิดจากท่ามือจับวัตถุที่มีลักษณะการจัดเรียงนิ้วในบางท่ามือนคล้ายกัน ดังนั้นถุงมือเซนเซอร์แบบ 16 DoF มีคุณสมบัติเหมาะสมกับการนำไปประยุกต์ใช้สำหรับงานการจดจำท่ามือเนื่องจากมีประสิทธิภาพสูงในการจดจำท่ามือจับได้เป็นอย่างดี

เอกสารอ้างอิง

- [1] M. A. Ahmed, B. B. Zaidan, A. A. Zaidan, M. M. Salih, and M. M. Lakulu, "A Review on Systems-Based Sensory Gloves for Sign Language Recognition State of the Art between 2007 and 2017," *Sensors*, Vol. 18, no. 7, pp. 2208, Jul. 2018.
- [2] B. Hu, and J. Wang, "Deep Learning Based Hand Gesture Recognition and UAV Flight Controls," *International Journal of Automation and Computing*, Vol. 17, no.1, pp.17-29, Feb. 2020.
- [3] S. Sungtaea, T. Rezab, and L. Rezaa, "EMG and IMU based real-time HCI using dynamic hand gestures for a multiple-DoF robot arm," *Journal of Intelligent & Fuzzy Systems*, Vol. 35, no. 1, pp. 861-876, Jul. 2018.
- [4] M. Kim, S. H. Choi, K. B. Park, and J. Y. Lee, "User Interactions for Augmented Reality Smart Glasses: A Comparative Evaluation of Visual Contexts and Interaction Gestures," *Applied Sciences*, Vol. 9, no.15, pp. 3171, Aug. 2019.
- [5] S. Makris, P. Tsarouchi, A. S. Matthaiakis, A. Athanasatos, X. Chatzigeorgiou, M. Stefos, K. Giavridis, and S. Aivaliotis, "Dual arm robot in cooperation with humans for flexible assembly," *CIRP Annals - Manufacturing Technology*, Vol. 66, no. 1, pp. 13-16, May. 2017.
- [6] S. Lee, B. Jamil, S. Kim, and Y. Choi, "Fabric Vest Socket with Embroidered Electrodes for Control of Myoelectric Prosthesis," *Sensors*, Vol. 20, no. 4, pp. 1196, Feb. 2020.
- [7] S. Lee, M. O. Kim, T. Kang, J. Park, and Y. Choi "Knit Band Sensor for Myoelectric Control of Surface EMG-Based Prosthetic Hand," *IEEE Sensors Journal*, Vol. 18, no. 20, pp. 8578-8586, Oct. 2018.

- [8] I. D. Terrer, F. T. Alonso, A. I. R. Guzmán, M. A. Aznar, C. Alcubilla, S. P. Nombela, A. A. Espinosa, B. P. López, and A. G. Agudo, "Upper limb rehabilitation after spinalcord injury: a treatment based on a dataglove and an immersive virtual reality environment," *Disability and Rehabilitation: Assistive Technology*, Vol. 11, no. 6, pp. 462-467, Jul. 2016.
- [9] F. Bin, S. Fuchun, L. Huaping, and G. Di, "A novel data glove using inertial and magnetic sensors for motion capture and robotic arm-hand teleoperation," *Industrial Robot: An International Journal*, Vol. 44, no. 2, pp. 155-165, Mar. 2017.
- [10] M. Kazi and M. Bill, *Robotic Hand Controlled by Glove Using Wireless Communication*, KTH Royal Institute of Technology, SWEDEN.
- [11] S. S. Rautaray and A. Agrawal, "Vision based hand gesture recognition for human computer interaction: a survey," *Artificial Intelligence Review*, Vol. 43, pp. 1-54, Jan. 2015.
- [12] F. Weichert, D. Bachmann, B. Rudak, and D. Fisseler, "Analysis of the Accuracy and Robustness of the Leap Motion Controller," *Sensors*, Vol. 13, no.5, pp. 6380-6393, May. 2013.
- [13] A. J. Yáñez, M. E. Benalcázar, and E. M. Maldonado, "Real-Time Hand Gesture Recognition Using Surface Electromyography and Machine Learning: A Systematic Literature Review," *Sensors*, Vol. 20, no. 9, pp. 2467, Apr. 2020.
- [14] Y. Zhang, Y. Chen, H. Yu, X. Yang, and W. Lu, "Learning Effective Spatial–Temporal Features for sEMG Armband-Based Gesture Recognition," *IEEE Internet of Things Journal*, Vol. 7, no. 8, pp. 6979-6992, Aug. 2020.
- [15] L. Dipietro, A. M. Sabatini, and P. Dario, "A Survey of Glove-Based Systems and Their Applications," *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, Vol. 38, no. 4, pp. 461-482, Jul. 2008.
- [16] J. Henderson, J. Condell, J. Connolly, D. Kelly, and K. Curran, "Review of Wearable Sensor-Based Health Monitoring Glove Devices for Rheumatoid Arthritis," *Sensors*, Vol. 21, no. 5, pp. 1576, Feb. 2021.
- [17] D. Sim, Y. Baek, M. Cho, S. Park, A. S. M. S. Sagar, and H. S. Kim, "Low-Latency Haptic Open Glove for Immersive Virtual Reality Interaction," *Sensors*, Vol. 21, no. 11, pp. 3682, May. 2021.
- [18] Y. Park, J. Lee, and J. Bae, "Development of a Finger Motion Measurement System using Linear Potentiometers," in *Proc. IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)*, pp. 125-130, Jul. 2014.
- [19] J. Bang, J. You, and Y. Lee, "A Prototype of Flex Sensor Based Data Gloves to Track the Movements of Fingers," *Smart Media Journal*, Vol. 8, no. 4, pp. 53-57, Nov. 2019.
- [20] Y. Zheng, Y. Peng, G. Wang, X. Liu, X. Dong, and J. Wang, "Development and evaluation of a sensor glove for hand function assessment and preliminary attempts at assessing hand coordination," *Measurement*, Vol. 93, pp.1-12, Jun. 2016.
- [21] S. Ciotti, E. Battaglia, N. Carbonaro, A. Bicchi, A. Tognetti, and M. Bianchi, "A Synergy-Based Optimally Designed Sensing Glove for Functional Grasp Recognition," *Sensors*, Vol. 16, no. 6, pp. 811, Jun. 2016.

- [22] G. Saggio, "A novel array of flex sensors for a goniometric glove," *Sensors and Actuators A: Physical*, Vol. 205, pp. 119-125, Nov. 2014.
- [23] S. A. S. M. Ali, N. S. Ahmad, and P. Goh "Flex Sensor Compensator via Hammerstein–Wiener Modeling Approach for Improved Dynamic Goniometry and Constrained Control of a Bionic Hand," *Sensors*, Vol. 19, no. 18, pp. 3896, Sep. 2019.
- [24] S. Shin, H. U. Yoon, and B. Yoo "Hand Gesture Recognition Using EGaIn-Silicone Soft Sensors," *Sensors*, Vol. 21, no. 9, pp. 3204, May. 2021.
- [25] S. Lee, Y. Choi, M. Sung, J. Bae, and Y. Choi "A Knitted Sensing Glove for Human Hand Postures Pattern Recognition," *Sensors*, Vol. 21, no. 4, pp. 1364, Feb. 2021.
- [26] E. Fujiwara, D. Y. Miyatake, M. F. M. Santos, and C. K. Suzuki "Development of a Glove-Based Optical Fiber Sensor for Applications in Human-Robot Interaction," in *Proc. ACM/IEEE International Conference on Human-Robot Interaction (HRI)*, pp. 123-124, Mar. 2013.
- [27] Y. Li, H. Di, Y. Xin, and X. Jiang, "Optical fiber data glove for hand posture capture," *Optik*, Vol. 233, pp. 166603, Feb. 2021.
- [28] L. Dipietro, A. M. Sabatini, and P. Dario, "Evaluation of an instrumented glove for hand-movement acquisition," *Journal of Rehabilitation Research and Development*, Vol. 40, no. 2, pp. 179-190, Apr. 2003.
- [29] C. C. Yang and Y. L. Hsu, "A Review of Accelerometry-Based Wearable Motion Detectors for Physical Activity Monitoring," *Sensors*, Vol. 10, no. 8, pp. 7772-7788, Aug. 2010.
- [30] B. S. Lin, I. J. Lee, S. Y. Yang, Y. C. Lo, J. Lee, and J. L. Chen, "Design of an Inertial-Sensor-Based Data Glove for Hand Function Evaluation," *Sensors*, Vol. 18, no. 5, pp. 1545, May. 2018.
- [31] CyberGlove Systems LLC, "MoCap Glove System," 2010. [Online]. Available: <https://static1.squarespace.com/static/559c381ee4b0ff7423b6b6a4/t/5602fbc3e4b07ebf58d47e34/1443036099686/CyberGlove+III+DataSheet.pdf>. [Accessed Oct. 1, 2021].
- [32] 5DT Inc., "5DT Data Glove Ultra Series," Oct. 2004. [Online]. Available: https://www.5dt.com/downloads/dataglove/ultra/5DT_Data_Glove_Ultra_Manual_v1.3.pdf. [Accessed Oct. 1, 2021].
- [33] T. L. Baldi, S. Scheggi, L. Meli, M. Mohammadi, and D. Prattichizzo, "GESTO: a Glove for Enhanced Sensing and Touching Based on Inertial and Magnetic Sensors for Hand Tracking and Cutaneous Feedback," *IEEE Transactions on Human-Machine Systems*, Vol. 47, no. 6, pp. 1066-1076, Dec. 2017.
- [34] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Communications of the ACM*, Vol. 60, no. 6, pp. 84-90, Jun. 2017.
- [35] S. Bianco, R. Cadene, L. Celona, and P. Napolitano, "Benchmark Analysis of Representative Deep Neural Network Architectures," *IEEE Access*, Vol. 6, pp. 64270-6427, Nov. 2018.
- [36] M. Cai, K. M. Kitani, and Y. Sato, "An Ego-Vision System for Hand Grasp Analysis," *IEEE Transactions on Human-Machine Systems*, Vol. 47, no. 4, pp. 524-535, Aug. 2017.

- [37] T. Feix, J. Romero, H. B. Schmiedmayer, A. M. Dollar, and D. Kragic, “The GRASP Taxonomy of Human Grasp Types,” IEEE Transactions on Human-Machine Systems, Vol. 46, no. 1, pp. 66-77, Feb. 2016.
- [38] R. Bray, “Sensor Workshop at ITP: Reports / Flex,” 2012. [Online]. Available: <https://itp.nyu.edu/archive/physcomp-spring2014/sensors/Reports/Flex.html>. [Accessed Oct. 1, 2021].
- [39] Electronics Source Co.,Ltd, “Arduino Nano 3.1,” [Online]. Available: <https://www.es.co.th/Schemetic/PDF/ARMB-0022.PDF>. [Accessed Oct. 1, 2021].