

การประยุกต์ใช้งานการประมวลผลภาพสำหรับหุ่นยนต์ให้อาหารโคนมอัตโนมัติ

อมรเทพ สอนศิลปพงศ์^{1,*}, ชัดชัย แก้วตา², สราวุธ กรวิรัตน์³ และ รณชัย สังหมื่นเม้า⁴

¹ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน วิทยาเขตขอนแก่น

² คณะวิทยาการคอมพิวเตอร์ มหาวิทยาลัยราชภัฏอุบลราชธานี

^{3, 4} คณะวิศวกรรมศาสตร์และเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยกาฬสินธุ์

*ผู้ประสานงานบทความต้นฉบับ: amornthep.so@rmu.ac.th

(รับบทความ: 27 มิถุนายน 2566; แก้ไขบทความ: 29 สิงหาคม 2566; ตอรับบทความ: 30 สิงหาคม 2566)

บทคัดย่อ

ปัจจุบันเกษตรกรประสบปัญหาต้นทุนการผลิตเพิ่มสูงขึ้น ปัญหาการขาดแคลนแรงงานภาคเกษตร ขาดการใช้เทคโนโลยี และผลผลิตส่วนใหญ่ยังไม่มีคุณภาพได้มาตรฐาน งานวิจัยนี้ได้ศึกษาและพัฒนาระบบสมาร์ตฟาร์มสำหรับการให้อาหารโคนมอัตโนมัติ โดยนำองค์ความรู้ด้านเทคโนโลยีสารสนเทศควบคู่ อีเล็กทรอนิกส์อัจฉริยะ มาพัฒนาระบบสำหรับการให้อาหารโคนมในโรงเรือน โดยงานวิจัยนี้ได้มีการประยุกต์ใช้ปัญญาประดิษฐ์ในการประมวลผลภาพสำหรับการวิเคราะห์สถานะคงอยู่ของโคนมปัจจุบัน เพื่อให้ระบบระบุพิกัดตำแหน่งของหุ่นยนต์ในโรงเรือน และการให้อาหารทำงานได้อย่างมีประสิทธิภาพเป็นระบบอัตโนมัติ สามารถลดการใช้พลังงานของหุ่นยนต์สำหรับการให้อาหารโคนม ช่วยให้เกษตรกรมีประสิทธิภาพในการบริหารจัดการเพิ่มขึ้น จากผลการทดลองผลการประเมินประสิทธิภาพการประมวลผลภาพสำหรับการวิเคราะห์สถานะคงอยู่ของโคนมปัจจุบันพบว่าเทคนิค MobileNetV2 เป็นเทคนิคที่เหมาะสมมากที่สุดสำหรับการประยุกต์ใช้งาน ซึ่งมีขนาดน้อยที่สุด 14 เมกะไบต์ มีความเร็วมากที่สุดในการตอบสนองที่ 0.001 วินาที และมีความแม่นยำอยู่ที่ 97.22 เปอร์เซ็นต์

คำสำคัญ: เกษตรอัจฉริยะ การประมวลผลภาพ หุ่นยนต์และระบบอัตโนมัติ

การอ้างอิงบทความ: อมรเทพ สอนศิลปพงศ์ และคณะ, "การประยุกต์ใช้งานการประมวลผลภาพสำหรับหุ่นยนต์ให้อาหารโคนมอัตโนมัติ," วารสารวิศวกรรมและเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยกาฬสินธุ์, ปีที่ 1, ฉบับที่ 4, หน้า 33-43, 2566.

Applying Image Processing techniques for Automated Dairy Feeding Robots

Amornthep Sonsilphong^{1,*}, Chutchai Kaewta², Sarayut Gonwirat³ and Ronnachai Sangmuenmao⁴

¹ Faculty of Engineering, Rajamangala University of Technology Isan Khon Kaen Campus

² Faculty of Computer Science, Ubon Ratchathani Rajabhat University

^{3,4} Faculty of Engineering and Industrial Technology, Kalasin University

* Corresponding Author: amornthep.so@rmuti.ac.th

(Received: June 27, 2023; Revised: August 29, 2023; Accepted: August 30, 2023)

Abstract

At present, farmers are facing problems with increasing production costs, agricultural labor shortage problems, lack of technology and most of the products are not of standard quality. This research has studied and developed a smart farm system for the automatic feeding of dairy cows. By bringing knowledge of information technology together with intelligent electronics to develop a smart system for feeding dairy cows in-house. This research has applied AI to image processing to analyze the current cow status and the positioning of robots in the cow house. The main purpose is to improve the efficient feeding and minimize the energy consumption of the smart farm system for the automatic feeding of dairy cows. The experimental assessment results of the image processing efficiency for the analysis of the current cattle state showed that the MobileNet technique was the most suitable for the application. It has the smallest size of 14 megabytes, has the fastest response time of 0.001 seconds, and an accuracy of 97.22 percent.

Keywords: Smart Farm, Image Processing, Robot and Automation

Please cite this article as: A. Sonsilphong, et al., "Applying Image Processing techniques for Automated Dairy Feeding Robots," *The Journal of Engineering and Industrial Technology, Kalasin University*, vol. 1, no. 4, pp. 33-43, 2023.

1. บทนำ

อาหารและการให้อาหารเป็นปัจจัยที่สำคัญในการเลี้ยงสัตว์ เนื่องจากต้นทุนในการเลี้ยงสัตว์ประมาณ 60 - 70% เป็นต้นทุนค่าอาหารที่สัตว์ต้องใช้ในการดำรงชีพ การเจริญเติบโต และการให้ผลผลิตต่าง ๆ ดังนั้นการให้อาหารในปริมาณที่เหมาะสม เพื่อให้สัตว์ได้รับโภชนาการตามความต้องการในแต่ละช่วงอายุ และระยะเวลาให้ผลผลิตจึงเป็นสิ่งจำเป็น ทั้งนี้ควรคำนึงถึงลักษณะการพัฒนาของท่อทางเดินอาหารในแต่ละระยะเจริญเติบโตด้วย ในปัจจุบันการใช้เทคโนโลยีได้เริ่มอย่างแพร่หลายขยายไปสู่การจัดการเกษตรที่แตกต่างจากรูปแบบเดิมที่เน้นใช้แรงงานคนให้เปลี่ยนไปใช้นวัตกรรม ที่เรียกว่าสมาร์ทฟาร์มหรือเกษตรอัจฉริยะ (Smart Farming) ซึ่งเป็นรูปแบบการบริหารจัดการฟาร์มโดยใช้เทคโนโลยีสารสนเทศเข้ามาช่วยตามขั้นตอนกระบวนการต่างๆ เช่น การวิเคราะห์และสนับสนุนการตัดสินใจ (Decision Support System) การสั่งงานแบบอัตโนมัติด้วยระบบไมโครโพรเซสเซอร์ (Microprocessor System) และแก้ไขปัญหาอย่างระบบอัจฉริยะ (Intelligence System) เป็นต้น

แนวคิดที่สามารถบริหารจัดการเพื่อช่วยให้ความยืดหยุ่นได้ตลอด ลดข้อจำกัดด้านแรงงาน ระบบให้อาหารอัตโนมัติบริษัท Lely Vector [1] ซึ่งเป็นแนวคิดที่พัฒนาขึ้นโดยความร่วมมือจากปัญหาของเกษตรกร โดยมีความสามารถของระบบการให้อาหารโคนม คือ การเปลี่ยนประเภทการป้อนอาหารง่ายและรวดเร็ว เปลี่ยนแปลงเวลาหรือชนิดในการให้อาหารโคนมได้ การให้อาหารมีความแม่นยำได้ปริมาณที่พอเหมาะกับโคนมแต่ละชนิด โดยการตั้งค่าและการใช้งานของระบบไม่มีความซับซ้อนและยุ่งยาก มีความยืดหยุ่นในการให้อาหารโคนม สามารถวางแผนงานและตั้งค่าในการให้อาหารโคนมได้ ลดการใช้แรงงาน และสามารถกำหนดเส้นทางหรือจุดในการให้อาหารโคนมได้ การให้อาหารเป็นตามความต้องการของโคนม เพื่อให้โคนมมีการเจริญเติบโตได้ตามมาตรฐาน

ซึ่งหุ่นยนต์ให้อาหารจากบริษัทดังกล่าวมีราคาสูงหากมีการนำเข้ามาใช้งานในประเทศไทย


งานวิจัยนี้จึงมีแนวคิดศึกษาและพัฒนาระบบสมาร์ทฟาร์มสำหรับการให้อาหารโคนมอัตโนมัติ ซึ่งเป็นการนำเอาระบบเทคโนโลยีสารสนเทศควบคู่อิเล็กทรอนิกส์อัจฉริยะ และหุ่นยนต์มาควบคุมการทำงานให้อาหารโคนมอัตโนมัติและเก็บข้อมูลในระบบฐานข้อมูล แสดงผลรายงานข้อมูลต่างๆ ในการให้อาหารผ่านเครือข่ายอินเทอร์เน็ตเพื่อสรรพสิ่ง (Internet of Things : IoT) หรือการตั้งค่าสั่งการแบบอัตโนมัติ ตามแนวคิดระบบสมาร์ทฟาร์มอัจฉริยะ ซึ่งระบบนี้จะช่วยอำนวยความสะดวกแก่เกษตรกรและทดแทนการใช้แรงงานผู้ดูแลฟาร์มโคนม รวมถึงเป็นการบริหารจัดการฟาร์มโคนมอย่างมีประสิทธิภาพ โดยบทความนี้จะมุ่งเน้นพัฒนาหุ่นยนต์ให้อาหารอัตโนมัติ โดยมีการวิเคราะห์หาลักษณะตำแหน่งของโคนม โดยมีการประยุกต์ใช้ปัญญาประดิษฐ์มาเพิ่มประสิทธิภาพในการประมวลผลภาพ มีความยืดหยุ่นเหมาะสมกับหน่วยประมวลผลของหุ่นยนต์ที่มีข้อจำกัด และเคลื่อนที่ไปยังจุดที่ให้อาหารในโรงเรือนโคนมได้อย่างถูกต้องและมีประสิทธิภาพ

2. การประมวลผลภาพด้วยการประยุกต์ใช้ปัญญาประดิษฐ์

การประยุกต์ใช้ปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง (Machine Learning) ที่หลากหลายงานและใช้งานกว้างขวางเพิ่มขึ้นในปัจจุบัน โดยกระบวนการเรียนรู้เครื่องจักรโดยทั่วไป แสดงได้ดังรูปที่ 1 ก่อนการวิเคราะห์หรือจำแนกข้อมูล จะต้องสร้างคุณลักษณะ (Feature Extraction) และขั้นตอนนี้ต้องพึ่งพาอาศัยวิศวกรผู้เชี่ยวชาญสร้างอัลกอริทึม (Algorithm) เพื่อใช้สร้างคุณลักษณะที่เหมาะสมเป็นอินพุต (Input) ของอัลกอริทึมการเรียนรู้เครื่องจักร และส่งผลให้ได้เอาต์พุต (Output) ที่มีประสิทธิภาพเพิ่มขึ้น ซึ่งกระบวนการสร้างคุณลักษณะนับว่าเป็นข้อจำกัดหนึ่งของการเติบโตการเรียนรู้เครื่องจักร การ

บทความวิจัย (Research Article)

เรียนรู้เชิงลึก (Deep Learning) เป็นหนึ่งในประเภทอัลกอริทึมการเรียนรู้เครื่องจักร ที่ได้รับความนิยมในปัจจุบันเนื่องจากเป็นกระบวนการที่สามารถสร้างคุณสมบัติได้ด้วยตนเองแบบอัตโนมัติ




รูปที่ 1 แสดงกระบวนการประมวลผลระหว่างการเรียนรู้ของเครื่องจักรและการเรียนรู้เชิงลึก [2]

โครงสร้างของการเรียนรู้เชิงลึกมีพื้นฐานมาจากโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ที่ประกอบไปด้วยหลายชั้น โดยหลายชั้นในที่นี้จะอ้างอิงถึงความลึก ซึ่งถูกเรียกอีกชื่อหนึ่งว่าโครงข่ายประสาทเชิงลึก (Deep Neural Network: DNN) ซึ่งโครงข่ายประสาทเชิงลึกมีหลากหลายประเภท ตัวอย่างของโครงข่ายที่เป็นที่นิยม อาทิเช่น Deep Belief Network (DBN), Auto-Encoder (AE), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Long-Short Term Memory (LSTM), Deep Reinforcement Learning (DRL) และ Generative Adversarial Network (GAN) เป็นต้น

2.1 โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN)

โครงข่ายประสาทแบบคอนโวลูชันถูกนำเสนอโดย LeCun, et al. [3] ในปี 1998 และได้ถูกนำไปใช้ทางด้าน คอมพิวเตอร์วิทัศน์ การรู้จำภาพ การแบ่งส่วน (Segmentation) การตรวจจับวัตถุ (Object Detection) และการเรียกคืนรูปภาพ (Image Restoration) เป็นต้น โดยโครงสร้างทั่วไปของโมเดล

แสดงดังรูปที่ 2 ประกอบด้วยชั้นต่างๆ รายละเอียดดังต่อไปนี้



รูปที่ 2 โครงสร้างของโครงข่ายประสาทแบบคอนโวลูชัน [3]

1) คอนโวลูชันแบบขั้น (Convolutional Layer) เป็นขั้นตอนหลักของโครงข่ายประสาทแบบคอนโวลูชัน ใช้สำหรับสร้างแผนที่คุณลักษณะหรือฟีเจอร์แมพ (Feature Map) ด้วยตัวดำเนินการคอนโวลูชัน (*) แสดงดังสมการที่ 1 โดยกำหนดให้ x_n^p คือ อินพุตที่มีจำนวน n ช่อง (Channel) และอยู่ที่ชั้นลำดับที่ p , เคนเนลฟิวเตอร์ (Filter Kernel) K ที่มีขนาด $m \times n$ ช่อง ได้อาต์พุต (Output) หรือฟีเจอร์แมพ x_m^{p+1} ที่มีจำนวน m ช่อง

$$x_m^{p+1} = K_{m,n} * x_n^p \quad (1)$$

เอาต์พุต (Output) ฟีเจอร์แมพที่ได้จากแต่ละชั้นส่วนหนึ่งจะส่งผ่านชั้น Batch Normalization [4] หรือฟังก์ชันกระตุ้น (Activation function) แบบ Rectified Linear Units (ReLU) [5] ดังสมการที่ 2

$$ReLU(x) = \max(0, x) \quad (2)$$

2) Pooling Layer เป็นการคำนวณพื้นที่ย่อย (Spatial Computation) เพื่อช่วยลดจำนวนขนาดของพารามิเตอร์ในโครงข่ายโดยใช้วิธีการ เช่น การหาค่าสูงสุด ค่าต่ำสุดและค่าเฉลี่ย นอกจากนี้ Global Average Pooling (GAP) ที่พบในงานวิจัย Network in Network (NiN) [6] ที่ลดจำนวนมิติได้มากกว่าจากมิติความกว้างและยาว $w \times h$ ทั้งหมดนำมาหา

บทความวิจัย (Research Article)

ค่าเฉลี่ยเหลือหนึ่งค่า ซึ่งโครงสร้างโครงข่ายประสาทแบบคอนโวลูชันปัจจุบันนิยมใช้ GAP แทนชั้น Pooling

3) Fully Connected Layer (FC) เป็น การเชื่อมต่อทุกโหนด (Node) จากชั้นหนึ่งไปยังทุกโหนดของชั้นถัดไปและชั้นสุดท้าย (Output Layer) ของโครงข่ายประสาทแบบคอนโวลูชัน ใช้เพื่อรู้จำกำหนดให้มีจำนวนโหนดเท่ากับจำนวนของประเภทข้อมูล โดยใช้ฟังก์ชัน soft max ในการคำนวณหาเอาต์พุตแสดงดังสมการที่ 3 โดยที่ x_i คือ เวกเตอร์คุณลักษณะ และ i คือ คอมโพเนนต์ของเวกเตอร์ x ลำดับที่ i

$$\text{soft max}(x) = \frac{\exp(x_i)}{\sum_i \exp(x_i)} \quad (3)$$

โครงข่ายประสาทแบบคอนโวลูชันเริ่มได้รับความสนใจและมีอิทธิพลกับงานวิจัยทางการรู้จำภาพเป็นอย่างสูง ตั้งแต่โมเดล AlexNet [7] ที่ใช้เรียนรู้ชุดข้อมูล ImageNet [8] และหลังจากนั้นได้มีการปรับปรุงและพัฒนาโครงสร้างโครงข่ายประสาทแบบคอนโวลูชันรูปแบบอื่นๆ ได้แก่ VGG [9] ที่นำเสนอการใช้คอนโวลูชัน ที่มีขนาดของเคเนล 3×3 เท่านั้น ทำให้จำนวนน้ำหนักพารามิเตอร์ที่ใช้ลดลงทางตรงกันข้าม GoogLeNet [10] เสนอการใช้ขนาดของเคเนลหลากหลายขนาด ทั้งนี้การเพิ่มจำนวนชั้นเป็นอีกหนึ่งรูปแบบโครงสร้างที่ทำให้ประสิทธิภาพเพิ่มขึ้น ดังนั้น InceptionV2 และ InceptionV3 [11] ได้ใช้ Batch Normalization, ResNet [12] และ Inception-ResNet [13] ใช้ Residual Connection ทำให้เพิ่มจำนวนชั้นได้มากกว่า 100 ชั้น

DenseNet [14] ได้เสนอรูปแบบ Dense Blocks ที่รวมคุณลักษณะจากชั้นก่อนหน้านี้ทำให้ชั้นนั้นได้รับข้อมูลเพิ่มขึ้น อีกแนวทางหนึ่งการปรับปรุง คือ การลดขนาดการคำนวณและขนาดจำนวนน้ำหนักพารามิเตอร์ เช่น SqueezeNet [15] และ

InceptionV2 ถึง InceptionV4 ได้ปรับ ใช้เมทริกซ์แบบ Factorization และ MoblieNet [16] ได้ใช้โมดูลคอนโวลูชันแบบ Depthwise Separable และ MobileNetV2 [17] เพิ่มเติม Inverted Residual และ Linear Bottleneck แทนที่รูปแบบคอนโวลูชันมาตรฐาน ในทางตรงกันข้ามการหาโครงสร้างได้เองแบบอัตโนมัติด้วยวิธีที่เรียกว่า การเรียนรู้ของเครื่องแบบอัตโนมัติ (Auto machine learning) พบในงานวิจัยการค้น หา โครงสร้าง (Network Architecture Search: NAS) โดย NASNet [18] ได้ใช้การเรียนรู้แบบเสริมกำลัง (Reinforcement learning) และ RNN เพื่อเสนอรูปแบบของโครงสร้างที่เหมาะสม และโครงข่าย AmoebaNet ค้นหาแบบอัลกอริทึมเชิงวิวัฒนาการ (Evolutionary Algorithm) และ EfficientNet ค้นหาการเพื่อขยายขนาด CNNs ทั้งความกว้าง ยาวและขนาดรีโซลูชัน (Resolution) ของฟิวเตอร์คุณลักษณะ ทั้งนี้รูปแบบ NAS ต่างๆ ที่กล่าวมา ได้เพิ่มประสิทธิภาพการรู้จำสูงขึ้นกว่าโมเดลที่กำหนดโครงสร้างเอง แต่ต้องใช้เวลาประมวลผลนานขึ้น เนื่องจากมีจำนวนโครงสร้างที่ค้นหาความเป็นไปได้ที่หลากหลาย จากที่กล่าวมา โครงสร้างของโครงข่ายประสาทแบบคอนโวลูชันได้ถูกพัฒนาอย่างหลากหลายเพื่อเพิ่มประสิทธิภาพ โดยที่งานวิจัยนี้ได้ นำเสนอ ตัวอย่าง 1 โมเดล MobileNetV2 [17] อธิบายโครงสร้างรายละเอียดดังนี้

2.2 MobileNetV2


เพื่อที่จะใช้งานบนอุปกรณ์เคลื่อนที่ MobileNet [16] ใช้หลักการลดจำนวนขนาดพารามิเตอร์ด้วยวิธีคอนโวลูชันแบบ Depthwise separable ที่ประกอบด้วย Depthwise และ Pointwise Convolution ที่ทำให้การลดจำนวนพารามิเตอร์ลงประมาณ 8 - 9 เท่าจากรูปแบบโครงข่ายประสาทแบบคอนโวลูชันเดิม ส่งผลให้ใช้เวลาการคำนวณน้อยลงแต่ยังคงประสิทธิภาพการรู้จำที่สูง

บทความวิจัย (Research Article)

สำหรับเวอร์ชันที่ 2 MobileNetV2 [17] ได้พัฒนาโดยใช้วิธีของ Inverted Residual ซึ่งประกอบด้วยการทำคอนโวลูชันแบบ Depthwise และ Linear Bottleneck และใช้การเชื่อมแบบข้าม (Skip Connection) ตามรูปแบบ ResNet [12] ทั้งนี้ MobileNetV2 มีจำนวนชั้นที่เพิ่มขึ้นจากการรวมทำ Residual Blocks แต่มีจำนวนพารามิเตอร์ใช้น้อยลงกว่า MobileNetV1 ทั้งนี้เนื่องจากการใช้จำนวนช่องที่น้อยลง แต่ทำการขยายช่องเพิ่มขึ้นก่อนการทำคอนโวลูชันแบบ Depthwise

โครงสร้างโดยรวมของ MobileNetV2 แสดงดังรูปที่ 3 (ก) ประกอบด้วยชั้น ได้แก่ Conv3x3, Bottleneck Blocks, Conv1x1, GAP และชั้น FC ด้วยฟังก์ชัน *softmax* โดย Conv3x3 คือคอนโวลูชันแบบมาตรฐาน (Standard Convolution) ที่มีขนาดเคเนล 3x3 และ c32 แทนจำนวน 32 ช่อง ทั้งนี้โครงสร้างหลักของโมเดลนี้คือ Bottleneck block แสดงส่วนประกอบดัง รูปที่ 3 (ข) ตัวอย่างเช่น Bottleneck t6 c96-n3-s1 ประกอบด้วย t6 จำนวนมีการขยายขนาดช่อง เท่ากับ 6 เท่า c96 คือจำนวน 96 ช่อง n3 คือจำนวนครั้งของการทำซ้ำ ของ Blocks นี้จำนวน 3 ครั้ง และ s1 คือ Stride 1 โดยบล็อกแรกของ Bottleneck Block ถ้ามีการใช้ Stride 1 (s1) จะเริ่มด้วย Inverted Residual Block (IRB) ดังแสดงส่วนประกอบของ IRB รูปที่ 3 (ค) ประกอบด้วย การขยายขนาดช่อง (Expand Channel) ด้วยชั้น Conv1x1 ที่คำนวณด้วย Nonlinear ReLU6 ซึ่งคือค่า ReLU Function ที่กำหนดจำกัดค่าสูงสุดที่ค่า 6 จากนั้นต่อด้วยชั้น DwConv3x3 คือ Depthwise convolution ขนาดเคเนล 3x3 และใช้ relu6 สำหรับชั้นสุดท้ายใน IRB ใช้ Linear ด้วย Conv1x1 เพื่อให้จำนวน Channel ลดลงเท่ากับ Input ของ Block ทำให้สามารถ Residual Connection ด้วยตัวดำเนินการบวกได้ ในกรณี Bottleneck BlockStride 2 (s2) จะเริ่มด้วย Transition Block ที่ไม่การทำ

Residual Connection เนื่องจากต้องการลมิติ $w \times h$ ดังรูปที่ 3 (ง)



รูปที่ 3 โครงสร้างของ MobileNetV2 (ก) Core block (ข) Bottleneck Block (ค) Inverted (ง) Transition Block

3. วิธีดำเนินการวิจัย

สิ่งสำคัญที่ควรคำนึงถึงในการพัฒนาระบบสมาร์ตฟาร์มสำหรับการให้อาหารโคนมอัตโนมัติ คือ หุ่นยนต์ให้อาหารโคนมอัตโนมัติ หุ่นยนต์จะช่วยให้ตัวหุ่นเคลื่อนที่ไปตามเส้นทางในระยะห่างที่เหมาะสมในขณะที่มีการให้อาหารด้านหน้าของคอสัตว์ ปริมาณอาหารที่ปล่อยลงไปจะถูกกำหนดโดยระบบซอฟต์แวร์คอมพิวเตอร์ ระบบการระบุพิกัดตำแหน่งจะถูกนำมาใช้เพื่อไปยังจุดที่ต้องการ และระบบประมวลผลภาพเพื่อให้การให้อาหารโคนมเป็นแบบอัตโนมัติจะมาประยุกต์ใช้งาน

ในรายละเอียดต่อไปนี้จะประกอบด้วย หุ่นยนต์ให้
อาหารโคนมอัตโนมัติ แนวคิดของเทคนิคการ
ประมวลผลภาพที่นำมาประยุกต์ใช้งาน อุปกรณ์ที่ใช้
ในการประมวลผลภาพ และการวัดประสิทธิภาพ
(Evaluation Metrics) ดังนี้

3.1 หุ่นยนต์ให้อาหารโคนมอัตโนมัติ

หุ่นยนต์ให้อาหารโคนมอัตโนมัติ จะประกอบด้วย 2 ส่วนหลัก คือ ส่วนโครงสร้างและกลไก และส่วนระบบควบคุม


ต้นแบบหุ่นยนต์ให้อาหารโคนมอัตโนมัติ ประกอบด้วยส่วนของโครงสร้างและกลไกของหุ่นยนต์

บทความวิจัย (Research Article)

ให้อาหารโคนมอัตโนมัติ สามารถบรรจ้อาหารโคนมได้ประมาณไม่เกิน 50 กิโลกรัม หุ่นยนต์มีมอเตอร์ขับเคลื่อนและมอเตอร์ป้อนอาหารเป็นชนิดแบบไฟฟ้ากระแสตรง มีขนาดแรงดันไฟฟ้า 12 โวลต์ เพื่อเป็นแหล่งพลังงานในการขับเคลื่อน และเป็นแหล่งพลังงานของวงจรควบคุมอุปกรณ์อิเล็กทรอนิกส์ หุ่นยนต์ใช้ไมโครคอนโทรลเลอร์ Arduino เพื่อควบคุมระบบขับเคลื่อนและระบบป้อนอาหาร โดยที่ไมโครคอนโทรลเลอร์ Arduino จะส่งข้อมูลและรับข้อมูลต่าง ๆ กับไมโครโปรเซสเซอร์ Raspberry Pi เพื่อเชื่อมต่อระบบแสดงผลข้อมูลทั้งหน้าจอแสดงผลข้อมูลของหุ่นยนต์ และหน้าต่างแสดงผลผ่านเครือข่ายอินเทอร์เน็ต


จากการเก็บข้อมูลเพื่อมาออกแบบระบบของโรงเรือนเลี้ยงโคนม ศูนย์วิจัยและพัฒนาการปศุสัตว์ มหาวิทยาลัยกาฬสินธุ์ ได้สอบถามผู้ดูแลในการให้อาหารโคนม พบว่า ในปัจจุบันมีการให้อาหารโคนมอย่างน้อยวันละสองถึงสามครั้ง และต้องใช้แรงงานคนต่อการให้อาหารหนึ่งเป็นเวลาประมาณหนึ่งชั่วโมง ทำให้มีต้นทุนในการผลิตจากแรงงานคน งานวิจัยนี้จึงได้พัฒนาระบบให้อาหารโคนมอัตโนมัติเพื่อลดต้นทุนแรงงานคน

ในระบบการควบคุมหุ่นยนต์ให้อาหารโคนมอัตโนมัติ จะสามารถควบคุม ตั้งค่าหรือตรวจสอบผ่านอินเทอร์เน็ต โดยเครื่องแม่ข่ายจะทำการรับข้อมูลและแสดงผลข้อมูลต่างๆ ผ่านเว็บไซต์ สามารถเข้าถึงข้อมูลได้ทั้งโทรศัพท์เคลื่อนที่ แท็บเล็ต หรือคอมพิวเตอร์ โดยที่หุ่นยนต์จะจัดการผ่านซอฟต์แวร์ผ่านระบบเครื่องแม่ข่ายคลาวด์ และจะมีระบบนำทางโดยใช้เซ็นเซอร์ตรวจจับเส้นแม่เหล็ก โดยมีไมโครคอนโทรลเลอร์อาร์ดูอิโน่ สั่งงานมอเตอร์ล้อทั้งสองด้าน เพื่อให้หุ่นยนต์เดินทางไปยังจุดที่ต้องการป้อนอาหารให้โคนม ดังรูปที่ 4



รูปที่ 4 แผนผังการการเชื่อมต่ออุปกรณ์ควบคุมของหุ่นยนต์

การทำงานของหุ่นยนต์ให้อาหารโคนมอัตโนมัติ โดยที่ไมโครคอนโทรลเลอร์ Arduino ทำหน้าที่เหมือนสมองจะรับค่าจากเซอร์เซอร์จับเส้นแม่เหล็กเพื่อขับเคลื่อนหุ่นยนต์วิ่งไปตามเส้นตามจุดที่ต้องการ โดยจะรับค่าจากระบบระบุจุดตำแหน่งเพื่อให้รู้ว่าหุ่นยนต์จะเคลื่อนที่ไปให้อาหารตรงจุดไหนให้เหมาะสมกับการให้อาหารโคนมมากที่สุดและง่ายต่อการกินอาหารของโคนม หลังจากนั้นหุ่นยนต์จะทำการป้อนอาหารโคนม และดำเนินการให้อาหารให้ครบทุกจุดตามที่กำหนดไว้ดังแสดงในรูปที่ 5




รูปที่ 5 ขั้นตอนการทำงานของหุ่นยนต์

3.2 แนวคิดของเทคนิคการประมวลผลภาพที่นำมาประยุกต์ใช้งาน

ที่ผ่านมาการประยุกต์ใช้ปัญญาประดิษฐ์และการเรียนรู้ของเครื่องที่หลากหลายงานและใช้งานกว้างขวางเพิ่มขึ้นในปัจจุบัน โดยกระบวนการเรียนรู้เครื่องจักรโดยทั่วไป แสดงดังรูปที่ 6 ก่อนการวิเคราะห์หรือจำแนกข้อมูลจะต้องสร้างคุณลักษณะ (Feature Extraction) และขั้นตอนนี้ต้องพึ่งพาอาศัยวิศวกรผู้เชี่ยวชาญสร้างอัลกอริทึม เพื่อใช้สร้างคุณลักษณะที่เหมาะสมเป็นอินพุตของอัลกอริทึมการเรียนรู้เครื่องจักร และส่งผลให้ได้เอาต์พุตที่มีประสิทธิภาพเพิ่มขึ้น ซึ่งกระบวนการสร้างคุณลักษณะนับว่าเป็นข้อจำกัดหนึ่งของการเติบโตการเรียนรู้เครื่องจักร การเรียนรู้เชิงลึกเป็นหนึ่งในประเภทอัลกอริทึมการเรียนรู้เครื่องจักรที่ได้รับความนิยมในปัจจุบัน เนื่องจากเป็นกระบวนการที่สามารถสร้างคุณสมบัติได้ด้วยตนเองแบบอัตโนมัติ

งานวิจัยนี้ได้ใช้การเรียนรู้เชิงลึกเพื่อแก้ปัญหาในการประมวลผลภาพโคนมในคอก ซึ่งใช้โมเดล CNN สำหรับการค้นหาคุณลักษณะและการรู้จำภาพ การแบ่งส่วน (Segmentation) การตรวจจับวัตถุ (Object Detection) และการเรียกคืนรูปภาพ (Image Restoration) เป็นต้น โดยโครงสร้างทั่วไปของโมเดลแสดง ดังรูปที่ 6 ประกอบด้วยชั้นต่าง ๆ ดังนี้



รูปที่ 6 โครงสร้างของ CNN [3]

3.3 อุปกรณ์ที่ใช้ในการประมวลผลภาพ

Raspberry Pi 4 Model B คือ บอร์ดคอมพิวเตอร์ขนาดเล็กที่สามารถเชื่อมต่อกับจอมอนิเตอร์คีย์บอร์ดและเมาส์ได้ สามารถนำมาประยุกต์ใช้ในการทำโครงงานทางด้านอิเล็กทรอนิกส์

การเขียนโปรแกรม และยังสามารถประมวลผลข้อมูลได้อย่างมีประสิทธิภาพ มีขนาดหน่วยความจำหลัก 4 กิกะไบต์ และความเร็วของหน่วยประมวลผล 64 บิต 1.5 กิกะเฮิรตซ์ แต่มีขนาดเล็กจึงเหมาะสมในการติดตั้งเพื่อใช้ประมวลผลภาพในหุ่นยนต์ ดังรูปที่ 7



รูปที่ 7 Raspberry Pi 4 Model B [19]

ข้อมูลที่ใช้ในการทดลองนี้รวบรวมจากหุ่นยนต์ภาพโคนมในคอกในโรงเรียนที่ศูนย์วิจัยและฝึกอบรมสุสีห์ มหาวิทยาลัยกาฬสินธุ์ ซึ่งมีทั้งหมด 99 ภาพ เพื่อฝึกสอนให้คอมพิวเตอร์เรียนรู้ เป็นจำนวน 100 รอบ แล้วจึงนำภาพที่เหลืออีก 42 ภาพมาทดสอบความถูกต้องในการจำแนก ดังข้อมูลในตารางที่ 1

ตารางที่ 1 จำนวนข้อมูลที่ใช้ในการฝึกสอนและทดสอบ

กระบวนการ	จำนวนรูป		
	ไม่มีวัว	มีวัว	รวม
การฝึกสอน	16	83	99
การปรับเทียบ	6	36	42
การทดสอบ	10	26	36
รวม	32	146	178

3.4 การวัดประสิทธิภาพ (Evaluation Metrics)

จากรูปแบบปัญหาของงานวิจัยนี้ ประกอบด้วยวิธีการประเมินประสิทธิภาพ การวัดค่าความถูกต้องการรู้จำ (Accuracy Recognition: AR) ค่าความถูกต้องการรู้จำเป็นวิธีวัดค่าความถูกต้องของการรู้จำของโมเดล

บทความวิจัย (Research Article)

การเรียนรู้เชิงลึกที่ประยุกต์ใช้งาน โดยงานวิจัยนี้ได้ใช้เพื่อการวัดประสิทธิภาพการรู้จำโคนมในโรงเรือน ดังแสดงสมการที่ 4 ที่อัตราส่วนร้อยละของจำนวนข้อมูลภาพที่โมเดลตอบได้ถูกต้องต่อจำนวนข้อมูลภาพที่ใช้ทดสอบทั้งหมด

$$AR = \frac{\text{\#correctly recognized samples}}{\text{\#all tested samples}} \times 100 \quad (4)$$

4. ผลการวิจัย

4.1 ผลการเปรียบเทียบผลของอัลกอริทึมการประมวลผลภาพ

จากการทดลองการวิเคราะห์ภาพโคนมเพื่อให้หุ่นยนต์ป้อนอาหารในแต่ละจุด โดยเป็นการเปรียบเทียบของแต่ละอัลกอริทึมการประมวลผลภาพเพื่อหาอัลกอริทึมที่มีความเหมาะสมมากที่สุดพบว่าอัลกอริทึม MobileNetV2 มีความเหมาะสมมากที่สุดทั้งในด้านขนาดของอัลกอริทึมที่มีค่าน้อยที่สุด มีความเร็วสูงสุด และมีความแม่นยำอยู่ในระดับที่ดี ดังแสดงในตารางที่ 2


ตารางที่ 2 ผลการเปรียบเทียบผลของอัลกอริทึมการประมวลผลภาพ

เทคนิคการประมวลผลภาพ	ขนาดไฟล์ (MB)	จำนวนตัวแปร	เวลาการฝึกสอน	เวลาการทดสอบ	วิธีการฝึกสอน	การถ่ายโอนการเรียนรู้
VGG16	528	14,715,714	3m 30s	0.003s	97.22%	97.22%
MobileNetV2	14	2,260,546	1m 44s	<0.001s	72.22%	97.22%
NASNetMobile	23	4,271,830	5m 16s	0.002s	72.22%	100%
EfficientNetB1	31	6,557,801	3m 30s	0.002s	91.67%	97.22%

4.2 ผลการวิเคราะห์ความแม่นยำในการจำแนกภาพ

จากการทดลองกราฟแสดงค่าความแม่นยำในการจำแนกภาพ เส้นสีแดงแสดงค่าความแม่นยำจากชุดฝึกสอนเมื่อใช้เทคนิค MobileNetV2 จำนวนการเรียนรู้ 100 มีค่า 1 และเส้นสีเขียวแสดงค่าความแม่นยำจากชุดทดสอบ 0.9 จะพบว่าเมื่อมีการใช้เทคนิค MobileNetV2 แล้วค่าความแม่นยำในการ

จำแนกภาพจากชุดทดสอบมีค่าสูง ใกล้เคียงกับค่าที่ได้จากชุดฝึกสอน และที่จำนวนการเรียนรู้ 100 จะพบว่าเทคนิค MobileNetV2 ช่วยให้ประสิทธิภาพในการจำแนกภาพหรือค่าในการทำนายถูกต้องสูงขึ้น ดังแสดงรูปที่ 8



รูปที่ 8 กราฟแสดงความสัมพันธ์ระหว่าง accuracy, loss กับ epochs ของเทคนิค MobileNetV2

5. สรุปผลการทดลอง

ระบบสมาร์ตฟาร์มสำหรับการให้อาหารโคนมอัตโนมัติ จะเป็นการประยุกต์ใช้งานการประมวลผลภาพมาช่วยวิเคราะห์สถานะโคนมในแต่ละคอกในโรงเรือนว่ามีโคนมหรือไม่ โดยใช้เทคนิค MobileNet ซึ่งมีความเหมาะสมทั้งในด้านขนาดและความแม่นยำในการใช้งานกับไมโครโพรเซสเซอร์ Raspberry Pi ที่ประสิทธิภาพคำนวณที่จำกัด ซึ่งมีขนาดน้อยที่สุด 14 เมกะไบต์ มีความเร็วมากที่สุดในการตอบสนองที่ 0.001 วินาที และมีความแม่นยำอยู่ที่ 97.22 เปอร์เซ็นต์ เพื่อให้หุ่นยนต์ได้ป้อนอาหารได้อย่างมีประสิทธิภาพ ไม่ให้อาหารตรงคอกที่ยังไม่มีโคนมซึ่งจะช่วยให้ลดการสูญเสียพลังงานของหุ่นยนต์

6. เอกสารอ้างอิง

- [1] LELY VECTOR, "Automatic feeding system," [Online]. Available: <https://www.lely.com/us/>. [Accessed: 10 November 2022].

บทความวิจัย (Research Article)

- [2] S. Dargan, et al., "A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning," *Archives of Computational Methods in Engineering*, vol. 27, no. 4, pp. 1071–1092, 2020.
- [3] Y. LeCun, et al., "Gradient-Based Learning Applied to Document Recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [4] S. Loffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," in *Proceedings of the 32nd International Conference on Machine Learning*, vol. 37, pp. 1-9, 2015.
- [5] V. Nair and G. E. Hinton, "Rectified Linear Units Improve Restricted Boltzmann Machines," in *Proceedings of the 27th International Conference on Machine Learning*, vol. 10, no. 2, pp. 807-814, 2010.
- [6] M. Lin, et al., "Network In Network," *Computer Science*, pp. 1-10, 2013.
- [7] A. Krizhevsky, et al., "ImageNet Classification with Deep Convolutional Neural Networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017.
- [8] J. Deng, et al., "ImageNet: A large-scale hierarchical image database," in *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 248-255, 2009.
- [9] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *Clinical Orthopaedics and Related Research*, pp. 1409-1556, 2015.
- [10] C. Szegedy, et al., "Going deeper with convolutions," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1-9.
- [11] C. Szegedy, et al., "Rethinking the Inception Architecture for Computer Vision," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2818-2826.
- [12] K. He, et al., "Deep Residual Learning for Image Recognition," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770-778.
- [13] C. Szegedy, et al., "Inception-v4, inception-ResNet and the impact of residual connections on learning," in *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, 2017, pp. 4278-4284.
- [14] G. Huang, et al., "Densely Connected Convolutional Networks," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 2261-2269.
- [15] J. Hu, et al., "Squeeze-and-Excitation Networks," in *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, pp. 7132-7141.
- [16] A. G. Howard, et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," *International Journal of Intelligence Science*, vol. 11, no. 1, pp. 1-9, 2017.

บทความวิจัย (Research Article)

- [17] M. Sandler, et al., "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 4510–4520.
- [18] B. Zoph, et al., "Learning Transferable Architectures for Scalable Image Recognition," in *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 8697-8710.
- [19] Cytron Technologies Co. Ltd., "Raspberry Pi 4 Model B 4GB and Kits," [Online]. Available: <https://th.cytron.io/p-raspberry-pi-4-model-b-4gb>. [Accessed: 10 November 2022].