

แบบจำลองสำหรับการวิเคราะห์ตำแหน่งการตกของลูกแบดมินตันด้วยเทคนิคการตรวจจับวัตถุแบบเรียลไทม์

มธุรส ผ่านเมือง¹, และ ชนิกานต์ รอดมรรณ^{2*}

¹ภาควิชาเทคโนโลยีและสื่อสารการศึกษา คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี จังหวัดปทุมธานี 12110 ประเทศไทย

^{2*}ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ กรุงเทพมหานคร 10800 ประเทศไทย

* ผู้นิพนธ์ประสานงาน อีเมล: chonnikarn.r@sci.kmutnb.ac.th DOI: 10.14416/JASET.KMUTNB.2025.03.006

รับเมื่อ 15 ธันวาคม 2568 แก้ไขเมื่อ 27 ธันวาคม 2568 ตอรับเมื่อ 29 ธันวาคม 2568

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบปัญญาประดิษฐ์สำหรับตรวจจับและวิเคราะห์ตำแหน่งการตกของลูกแบดมินตัน เพื่อช่วยเพิ่มประสิทธิภาพในการวางแผนการเล่นและการฝึกซ้อม (Scouting) โดยคณะผู้วิจัยได้พัฒนาแบบจำลองตรวจจับวัตถุด้วยสถาปัตยกรรม YOLOv8 และทำการเปรียบเทียบประสิทธิภาพของโมเดลในเงื่อนไขต่าง ๆ ผลการวิจัยพบว่า โมเดลที่ผ่านการฝึกสอนด้วยชุดข้อมูลภาพจำนวน 9,800 ภาพ และกำหนดรอบการเรียนรู้ที่ 300 รอบ (Epochs) ให้ประสิทธิภาพสูงสุด โดยมีค่า Precision ร้อยละ 95 ค่า Recall ร้อยละ 92 และค่าความคลาดเคลื่อน (Validation Loss) ต่ำสุดที่ 2.07 เมื่อนำแบบจำลองดังกล่าวมาพัฒนาเป็นเว็บแอปพลิเคชันและทดสอบการใช้งานจริงร่วมกับกลุ่มผู้เชี่ยวชาญและนักศึกษาในสาขาวิทยาศาสตร์การกีฬา พบว่า ระบบสามารถระบุตำแหน่งการตกของลูกแบดมินตัน จำแนกพื้นที่ในสนาม และแสดงผลสถิติได้อย่างถูกต้อง โดยผู้ใช้งานมีความพึงพอใจในภาพรวมอยู่ในระดับดี โดยเฉพาะในด้านประโยชน์ต่อการเรียนรู้และความสะดวกในการนำข้อมูลไปใช้ อย่างไรก็ตาม ระบบยังมีข้อจำกัดด้านความเร็วในการประมวลผลและความเสถียรในการติดตามวัตถุในบางสถานการณ์

คำสำคัญ: ปัญญาประดิษฐ์, การตรวจจับวัตถุ, แบดมินตัน, YOLOv8, การวิเคราะห์เกมกีฬา

A Model for Analyzing Shuttlecock Landing Position Using Real-Time Object Detection Techniques

Mathuros Panmuang¹, and Chonnikarn Rodmorn^{2*}

¹Department of Educational Technology and Communications, Faculty of Technical Education, Rajamangala University of Technology Thanyaburi, Pathum Thani, 12110 Thailand

^{2*}Department of Applied Statistics, Faculty of Applied Science, King Mongkut's University of Technology North Bangkok, Bangkok, 10800 Thailand

* Corresponding Author, E-mail: chonnikarn.r@sci.kmutnb.ac.th DOI: 10.14416/JASET.KMUTNB.2025.03.006

Received 15 December 2025; **Revised** 27 December 2025; **Accepted** 29 December 2025

ABSTRACT

This research aims to develop an Artificial Intelligence (AI) system for detecting and analyzing badminton shuttlecock positions to enhance the efficiency of game planning and training (Scouting). The researchers developed an object detection model based on the YOLOv8 architecture and conducted comparative performance tests under various conditions. The results indicated that the model trained with a dataset of 9,800 images for 300 epochs yielded the highest performance, achieving a Precision of 95%, a Recall of 92%, and a minimum Validation Loss of 2.07. When integrated into a web application and tested by experts and sports science students, the system demonstrated the ability to accurately identify shuttlecock landing positions, classify court zones, and display statistical results. Overall user satisfaction was rated at a good level, particularly regarding its utility for learning and the convenience of data utilization. However, limitations regarding processing speed and tracking stability in certain scenarios remain.

KEYWORDS: Artificial intelligence, Object detection, Badminton, YOLOv8, Sports analysis

Please cite this article as: M. Panmuang and C. Rodmorn, "A Model for Analyzing Shuttlecock Landing Position Using Real-Time Object Detection Techniques," *Journal of Applied Science and Emerging Technology*, vol 24, no 3, pp. 1-15, ID. 265289, December 2025

1. บทนำ

ในปัจจุบัน การแข่งขันกีฬาเบดมินตันมีระดับความเข้มข้นสูงอย่างต่อเนื่อง การวิเคราะห์ข้อมูลเชิงกลยุทธ์ได้กลายเป็นองค์ประกอบสำคัญในการพัฒนาสมรรถนะของนักกีฬาและเพิ่มขีดความสามารถในการแข่งขันอย่างยั่งยืน การตัดสินใจเชิงกลยุทธ์ภายในสนามจึงไม่อาจอาศัยเพียงสัญชาตญาณหรือประสบการณ์ของนักกีฬาและผู้ฝึกสอนเท่านั้น หากแต่จำเป็นต้องอาศัยข้อมูลเชิงปริมาณที่มีความถูกต้องและความน่าเชื่อถือสูง เพื่อสะท้อนรูปแบบการเล่นและพฤติกรรมเชิงการแข่งขันอย่างเป็นระบบ อย่างไรก็ตาม แนวทางการวิเคราะห์การแข่งขันแบบดั้งเดิมซึ่งอาศัยการสังเกตและการประเมินเชิงอัตวิสัยของผู้ฝึกสอนยังคงมีข้อจำกัดที่สำคัญหลายประการ ทั้งในด้านความต่อเนื่องของการวิเคราะห์ ความแม่นยำในการตีความเหตุการณ์ในสนาม ตลอดจนข้อจำกัดด้านเวลาและทรัพยากรในการจัดการข้อมูลวิดีโอที่มีปริมาณมากและมีความซับซ้อนสูง ข้อจำกัดดังกล่าวส่งผลให้การนำข้อมูลที่ได้ไปใช้ประโยชน์เชิงกลยุทธ์ยังไม่สามารถตอบสนองต่อความต้องการของการแข่งขันในระดับสูงได้อย่างเต็มประสิทธิภาพ

ความก้าวหน้าของเทคโนโลยีคอมพิวเตอร์วิทัศน์ (Computer Vision) และการเรียนรู้เชิงลึก (Deep Learning) ได้เข้ามามีบทบาทสำคัญในการวิเคราะห์ข้อมูลด้านกีฬา โดยเฉพาะอย่างยิ่งในงานตรวจจับและติดตามการเคลื่อนที่ของวัตถุที่มีขนาดเล็กและมีความเร็วสูง เช่น ลูกเบดมินตัน งานวิจัยที่ผ่านมาหลายฉบับได้แสดงให้เห็นถึงศักยภาพของเทคนิคการตรวจจับวัตถุในการระบุและติดตามตำแหน่งของลูกเบดมินตันจากวิดีโอการแข่งขัน (Cao et al., 2021; Lai et al., 2025) อย่างไรก็ตาม ความท้าทายที่สำคัญของการตรวจจับวัตถุในลักษณะดังกล่าวยังคงอยู่ที่ ปัญหาการตรวจจับพลาดในบางเฟรม (Missed detections) ซึ่งมีสาเหตุจากปัจจัยหลายประการ อาทิ ความเร็วของลูกที่สูง มุมมองของกล้องที่จำกัด หรือสภาพแสงที่ไม่เอื้ออำนวย ส่งผลให้ข้อมูลเส้นทางการเคลื่อนที่ขาดความต่อเนื่องและลดความน่าเชื่อถือในการนำไปใช้วิเคราะห์เชิงลึก เพื่อลดข้อจำกัดดังกล่าว งานวิจัยในกีฬาที่มีลักษณะใกล้เคียงกัน เช่น กีฬาเทนนิส ได้เสนอแนวทางการผสมผสานเทคนิคการเรียนรู้เชิงลึกเข้ากับอัลกอริทึม Kalman Filter เพื่อประมาณค่าและเติมเต็มตำแหน่งของลูกในเฟรมที่ไม่สามารถตรวจจับได้โดยตรง แนวทางดังกล่าวช่วยให้สามารถ

สร้างเส้นทางการเคลื่อนที่ของลูกได้อย่างต่อเนื่องและมีความสมบูรณ์มากยิ่งขึ้น (อภิสิทธิ์ เปรมปรีดี และคณะ, 2567) ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่า การตรวจจับวัตถุเพียงอย่างเดียวอาจไม่เพียงพอ หากขาดกระบวนการประมวลผลและวิเคราะห์ข้อมูลเชิงพลวัตที่สามารถนำผลลัพธ์เชิงเทคนิคไปต่อยอดให้เกิดคุณค่าเชิงกลยุทธ์

นอกเหนือจากการติดตามตำแหน่งและเส้นทางการเคลื่อนที่ของลูกเบดมินตันแล้ว งานวิจัยที่ได้รับการเผยแพร่ในช่วงที่ผ่านมาได้ขยายขอบเขตการวิเคราะห์ไปสู่การทำความเข้าใจเหตุการณ์ที่เกิดขึ้นภายในสนามแข่งขัน อาทิ การระบุช่วงเวลาการตีลูก (Shot Refinement) และการจำแนกประเภทของช็อต (Shot Recognition) โดยอาศัยข้อมูลท่าทางการเคลื่อนไหวก่อนของผู้เล่นร่วมกับตำแหน่งของลูกชนไก่ (Hsu et al., 2023) นอกจากนี้ ยังมีความพยายามในการพัฒนาแบบจำลองที่มีโครงสร้างน้ำหนักเบาเพื่อรองรับการประมวลผลแบบเรียลไทม์ ซึ่งเหมาะสมต่อการใช้งานในสถานการณ์จริง (Kim & Cheng, 2023) แม้งานวิจัยดังกล่าวจะสะท้อนถึงความก้าวหน้าอย่างมีนัยสำคัญในเชิงเทคนิค แต่ผลลัพธ์ส่วนใหญ่มีแนวโน้มไปที่ตัวชี้วัดเชิงเทคนิค เช่น ความแม่นยำในการตรวจจับ หรือความถูกต้องในการจำแนกประเภทของช็อต ซึ่งยังไม่สามารถตอบโจทย์การวิเคราะห์เชิงกลยุทธ์ในเชิงพื้นที่ได้อย่างเป็นรูปธรรม

จากการทบทวนวรรณกรรม พบว่ายังมีความขัดแย้งขององค์ความรู้ที่สำคัญ กล่าวคือ การขาดแบบจำลองที่สามารถนำข้อมูลจากกระบวนการตรวจจับวัตถุแบบเรียลไทม์มาสังเคราะห์เพื่อวิเคราะห์ตำแหน่งสุดท้ายที่ลูกเบดมินตันตกกระทบพื้นสนาม ซึ่งถือเป็นผลลัพธ์ที่สะท้อนเจตนาเชิงกลยุทธ์และประสิทธิภาพของการตีในแต่ละช็อตได้อย่างชัดเจน การวิเคราะห์ตำแหน่งลูกตกในพื้นที่ไม่เพียงช่วยอธิบายรูปแบบการโจมตีและการกระจายการใช้งานพื้นที่ของผู้เล่นเท่านั้น แต่ยังสามารถเปิดเผยจุดอ่อนในการป้องกันของคู่ต่อสู้ ซึ่งเป็นข้อมูลเชิงกลยุทธ์ที่มีคุณค่าสูงต่อการวางแผนและการปรับกลยุทธ์การแข่งขัน

ด้วยเหตุนี้ งานวิจัยฉบับนี้จึงมุ่งพัฒนาแบบจำลองสำหรับการวิเคราะห์ตำแหน่งการตกของลูกเบดมินตัน โดยอาศัยเทคนิคการตรวจจับวัตถุแบบเรียลไทม์จากวิดีโอการแข่งขัน โดยเริ่มจากการระบุตำแหน่งของลูกในแต่ละเฟรม จากนั้นนำข้อมูลเชิงตำแหน่งมาวิเคราะห์เพื่อหาจุดสิ้นสุดของการเคลื่อนที่ในแต่ละช็อต และทำการจำแนกตำแหน่งการตกใน

เชิงพื้นที่ของสนาม ผลลัพธ์ที่ได้จะถูกส่งเคราะห์ให้อยู่ในรูปของข้อมูลเชิงสถิติและการวิเคราะห์เชิงพื้นที่ ซึ่งสามารถนำไปใช้งานได้จริงผ่านระบบเว็บแอปพลิเคชัน เพื่อสนับสนุนการตัดสินใจของนักกีฬาและผู้ฝึกสอน ความเป็นนวัตกรรมของงานวิจัยนี้อยู่ที่การเชื่อมโยงข้อมูลเชิงเทคนิคจากกระบวนการตรวจจับวัตถุแบบเรียลไทม์เข้ากับการวิเคราะห์เชิงกลยุทธ์ที่สามารถนำไปปฏิบัติได้จริง โดยเปลี่ยนผลลัพธ์จากการตรวจจับให้กลายเป็นเครื่องมือสำหรับการวิเคราะห์รูปแบบการเล่นเชิงพื้นที่ ซึ่งไม่เพียงช่วยยกระดับการฝึกซ้อมและการแข่งขันในระดับบุคคลเท่านั้น แต่ยังมีศักยภาพในการต่อยอดไปสู่การพัฒนากีฬาเบดมินตันในระดับสโมสรระดับชาติ และระดับนานาชาติในอนาคต

2. การทบทวนวรรณกรรม

2.1 ความท้าทายและเทคนิคพื้นฐานในการตรวจจับวัตถุขนาดเล็กที่เคลื่อนที่เร็ว

งานวิจัยนี้มุ่งเน้นการแก้ปัญหาเชิงเฉพาะในสาขาคอมพิวเตอร์วิทัศน์ ได้แก่ การตรวจจับและติดตามวัตถุขนาดเล็กที่เคลื่อนที่เร็ว (Small and Fast Moving Object Detection and Tracking) ซึ่ง Mirzaei et al. (2023) พบว่าเป็นปัญหาที่มีความซับซ้อนสูง เนื่องจากวัตถุมีขนาดเล็กมากเมื่อเทียบกับพื้นที่ภาพ มีลักษณะภายนอกที่จำกัดและมักได้รับผลกระทบจากภาพเบลออันเกิดจากการเคลื่อนที่ (Motion blur) เพื่อตอบสนองต่อความท้าทายดังกล่าว งานวิจัยที่ผ่านมาได้เสนอแนวทางแก้ไขในหลายระดับ ดังนี้

- การปรับปรุงสถาปัตยกรรมของแบบจำลองสำหรับการตรวจจับวัตถุขนาดเล็ก โดย Sun et al. (2022) ได้นำเสนออัลกอริทึม RSOD ซึ่งปรับปรุง YOLOv3 ด้วยการดึงคุณลักษณะจากชั้นที่ตื้นกว่า (Shallower layer) ซึ่งมีความละเอียดเชิงพื้นที่สูงขึ้น ส่งผลให้ประสิทธิภาพในการตรวจจับวัตถุขนาดเล็กเพิ่มขึ้น

- การแก้ปัญหาภาพเบลอจากการเคลื่อนที่ Rozumnyi et al. (2021) ได้นำเสนอแนวทาง FMODEtect ซึ่งผสานเทคนิคการแยกวัตถุออกจากพื้นหลัง (Matting) และการลดความเบลอ (Deblurring) เพื่อเพิ่มความแม่นยำในการระบุตำแหน่งของวัตถุที่เคลื่อนที่ด้วยความเร็วสูง

- การเพิ่มประสิทธิภาพด้านความเร็วเพื่อรองรับการประมวลผลแบบเรียลไทม์ โดย Srigrarom & Chew (2020) เสนอระบบไฮบริดที่ใช้การตรวจจับการเคลื่อนไหวเพื่อคัดกรองวัตถุในเบื้องต้น ก่อนยืนยันผลด้วยแบบจำลองเชิงลึก ซึ่งสอดคล้องกับแนวคิดของ Kim & Cheng (2023) ที่เน้นการใช้แบบจำลองน้ำหนักเบา (Lightweight Model) เช่น YOLOv5 เพื่อรักษาสสมดุลระหว่างความเร็วและความแม่นยำ แนวทางที่ได้รับความนิยมในการแก้ปัญหาการติดตามวัตถุประเภทนี้คือแนวคิดแบบ Track-by-Detection ซึ่งเริ่มจากการตรวจจับวัตถุในแต่ละเฟรม ก่อนทำการเชื่อมโยงข้อมูลข้ามเฟรม (Mirzaei et al., 2023) ทั้งนี้ สถาปัตยกรรมในตระกูล YOLO (You Only Look Once) ได้รับการยอมรับอย่างกว้างขวางในฐานะเทคโนโลยีพื้นฐานที่เหมาะสม เนื่องจากสามารถรักษาความสมดุลระหว่างความแม่นยำในการตรวจจับและความเร็วในการประมวลผลได้อย่างมีประสิทธิภาพ

2.2 การประยุกต์ใช้เทคโนโลยีเพื่อวิเคราะห์กีฬาเบดมินตัน

จากรากฐานทางเทคนิคด้านการตรวจจับและติดตามวัตถุขนาดเล็กที่เคลื่อนที่เร็ว งานวิจัยในกลุ่มนี้ได้นำแนวคิดแบบ Track-by-Detection และสถาปัตยกรรม YOLO มาประยุกต์ใช้กับการวิเคราะห์กีฬาเบดมินตันโดยเฉพาะ ซึ่งสามารถจำแนกงานวิจัยตามวัตถุประสงค์ได้ ดังนี้

- การตรวจจับและติดตามลูกเบดมินตัน (Detection and Tracking) โดยงานวิจัยของ Cao et al. (2021) ถือเป็นหนึ่งในงานบุกเบิกที่แสดงให้เห็นถึงศักยภาพของ YOLO ในการตรวจจับลูกเบดมินตันสำหรับงานด้านหุ่นยนต์ ต่อมา Lai et al. (2025) ได้พัฒนาระบบ YO-CSA-T ที่ใช้ YOLOv8 ร่วมกับกลไก Attention เพื่อเพิ่มความแม่นยำในการตรวจจับ อย่างไรก็ตาม การตรวจจับเพียงอย่างเดียวมักประสบปัญหาการสูญหายของข้อมูลในบางเฟรม งานวิจัยของ อภิสิทธิ์ เปรมปรีดี และคณะ (2567) รวมถึง Shah et al. (2020) จึงได้นำอัลกอริทึม Kalman Filter มาใช้เพื่อประมาณค่าและเติมเต็มตำแหน่งของลูกในเฟรมที่ขาดหาย ช่วยเปลี่ยนข้อมูลตำแหน่งให้เป็นเส้นทางการเคลื่อนที่ที่มีความต่อเนื่องและน่าเชื่อถือมากยิ่งขึ้น

- การวิเคราะห์ขั้นสูงและการทำนาย (Advanced Analysis and Prediction) เมื่อสามารถระบุตำแหน่งลูกได้อย่างแม่นยำ งานวิจัยได้ต่อยอดไปสู่การวิเคราะห์เชิงลึกและ

การทำนาย โดย Shah et al. (2020) ใช้ข้อมูลตำแหน่งจาก YOLOv3 ร่วมกับโครงข่ายประสาทเทียมเพื่อทำนายตำแหน่งที่ลูกตก (Fall point prediction) ขณะที่ Singh (2021) มุ่งเน้นการทำนายเส้นทางการเคลื่อนที่ในอนาคต (Trajectory prediction) นอกจากนี้ Hsu et al. (2024) ได้พัฒนาอัลกอริทึม Shot refinement โดยผสานข้อมูลตำแหน่งลูกกับท่าทางการเคลื่อนไหวของผู้เล่นเพื่อระบุจังหวะการตี (Hit Moment) ส่วน Wang (2021) และ Zhao (2023) ได้นำเทคนิคการเรียนรู้ของเครื่องมาใช้ในการจำแนกประเภทการตีและรูปแบบการเคลื่อนที่ของผู้เล่น

- การประยุกต์ใช้งานจริง (Practical application) ความแม่นยำในการระบุตำแหน่งลูกแบดมินตันมีความสำคัญอย่างยิ่งต่อการตัดสินใจผลการแข่งขัน Kopania et al., (2022) จึงได้พัฒนาระบบ Instant Review เพื่อสนับสนุนการตัดสินใจของกรรมการ โดยใช้เทคโนโลยีคอมพิวเตอร์วิทัศน์ในการตรวจสอบตำแหน่งที่ลูกตกกระทบพื้นสนาม งานวิจัยดังกล่าวสะท้อนให้เห็นถึงบทบาทสำคัญของการวิเคราะห์ตำแหน่งลูกในบริบทการใช้งานจริง และยืนยันถึงความจำเป็นของระบบที่สามารถระบุจุดตกได้อย่างแม่นยำและเชื่อถือได้

3. วิธีการ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองสำหรับการวิเคราะห์ตำแหน่งการตกของลูกแบดมินตัน โดยอาศัยเทคนิคการตรวจจับวัตถุจากวิดีโอแบบเรียลไทม์ กระบวนการดำเนินงานประกอบด้วย การเตรียมและจัดการข้อมูล การฝึกสอนแบบจำลองปัญญาประดิษฐ์ การประเมินประสิทธิภาพของแบบจำลอง และการนำผลลัพธ์ที่ได้ไปประยุกต์ใช้งานผ่านระบบเว็บแอปพลิเคชันเพื่อการวิเคราะห์เชิงกลยุทธ์ ทั้งนี้ การพัฒนาระบบดังกล่าวดำเนินการตามกระบวนการมาตรฐานในการพัฒนาระบบปัญญาประดิษฐ์ที่ได้รับการยอมรับในงานวิจัยระดับสากล แนวทางดังกล่าวสอดคล้องกับ กรอบ การทำงาน ที่นำเสนอ โดย Kamoljitprapa และ Leelasilapasart (2025) ซึ่งได้กำหนดลำดับขั้นตอนการพัฒนาระบบปัญญาประดิษฐ์อย่างเป็นระบบ ตั้งแต่การรวบรวมข้อมูล การเตรียมข้อมูลเบื้องต้น การแบ่งชุดข้อมูลสำหรับการฝึกสอนและการทดสอบ ไปจนถึงการประเมินผลการดำเนินงานของแบบจำลอง ผู้วิจัยได้นำกรอบแนวคิดดังกล่าวมาประยุกต์ใช้เป็นแนวทาง

หลักในการออกแบบและวางแผนการทดลองของงานวิจัยนี้ เพื่อให้กระบวนการดำเนินงานมีความเป็นระบบ มีความน่าเชื่อถือ และสามารถเปรียบเทียบผลลัพธ์กับงานวิจัยที่เกี่ยวข้องได้อย่างเหมาะสม


3.1 ภาพรวมของระบบ

ระบบที่พัฒนาขึ้นประกอบด้วยกระบวนการหลัก 5 ส่วน ได้แก่ 1) การเตรียมและจัดการชุดข้อมูล (Data Preparation) 2) การพัฒนาและการทดลองแบบจำลอง (Model Development & Experiment) 3) การประเมินประสิทธิภาพเชิงเทคนิค (Technical Evaluation) 4) การวิเคราะห์ตำแหน่งการตกและพัฒนาแอปพลิเคชัน (Implementation) และ 5) การประเมินผลโดยผู้เชี่ยวชาญและผู้ใช้งาน (Assessment) ดังรูปที่ 1

ในขั้นตอนการประมวลผล วิดีโอการแข่งขันที่ผู้ใช้อัปโหลดเข้าสู่ระบบจะถูกแยกออกเป็นลำดับของเฟรมภาพ จากนั้นแบบจำลองตรวจจับวัตถุจะทำหน้าที่ระบุตำแหน่งของลูกแบดมินตันในแต่ละเฟรม ผลลัพธ์เชิงตำแหน่งที่ได้จะถูกนำไปวิเคราะห์เพื่อระบุจุดสิ้นสุดของการเคลื่อนที่ในแต่ละช็อต ก่อนทำการจำแนกตำแหน่งการตกของลูกออกเป็นโซนต่าง ๆ ภายในสนามแบดมินตัน ทั้งนี้ ข้อมูลที่ได้จะถูกส่งวิเคราะห์ให้อยู่ในรูปของข้อมูลเชิงสถิติและข้อมูลเชิงกลยุทธ์ ซึ่งสามารถนำไปใช้งานได้จริงเพื่อสนับสนุนการวิเคราะห์รูปแบบการเล่นและการตัดสินใจเชิงกลยุทธ์

3.2 การเตรียมชุดข้อมูล

ชุดข้อมูลที่ใช้ในการฝึกสอนและประเมินประสิทธิภาพของแบบจำลองในงานวิจัยนี้ประกอบด้วยภาพนิ่งจำนวน 9,800 ภาพ ซึ่งสกัดมาจากวิดีโอการแข่งขันแบดมินตันจริง เพื่อให้สะท้อนลักษณะการเคลื่อนไหวของลูกแบดมินตันภายใต้สภาวะการจริง ภาพทั้งหมดผ่านกระบวนการกำกับข้อมูล (Annotation) โดยระบุตำแหน่งของลูกแบดมินตันในแต่ละเฟรมในรูปแบบกรอบสี่เหลี่ยม (Bounding Box) สำหรับงานตรวจจับวัตถุ เพื่อให้การฝึกสอนและการประเมินผลมีความเป็นระบบและสามารถทำซ้ำได้ ชุดข้อมูลถูกแบ่งออกเป็น 3 ส่วน ได้แก่ ชุดฝึกสอน (Training Set) ชุดตรวจสอบความถูกต้อง (Validation Set) และชุดทดสอบ (Test Set) ตามสัดส่วน 70:20:10 ของจำนวนภาพทั้งหมด โดยมีรายละเอียด ดังนี้



รูปที่ 1 กระบวนการพัฒนาระบบ

- Training Set: จำนวน 6,860 ภาพ (ร้อยละ 70) ใช้สำหรับการเรียนรู้และการปรับค่าน้ำหนักของแบบจำลอง
- Validation Set: จำนวน 1,960 ภาพ (ร้อยละ 20) ใช้สำหรับการประเมินประสิทธิภาพระหว่างการฝึกสอน รวมถึงการติดตามแนวโน้มของค่า loss และตัวชี้วัดต่าง ๆ เพื่อหลีกเลี่ยงปัญหาการเรียนรู้มากเกินไป (Overfitting)
- Test Set: จำนวน 980 ภาพ (ร้อยละ 10) ใช้สำหรับการประเมินประสิทธิภาพขั้นสุดท้ายของแบบจำลองกับข้อมูลที่ไม่เคยปรากฏในการฝึกสอนมาก่อน

การแบ่งชุดข้อมูลดังกล่าวได้รับการออกแบบให้แต่ละชุดมีความหลากหลายของฉาก มุมกล้อง และสภาพแสงในส่วนที่ใกล้เคียงกัน เพื่อให้การประเมินผลสามารถสะท้อนความสามารถในการทำงานทั่วไปของแบบจำลองได้อย่างเหมาะสม นอกจากนี้ เพื่อป้องกันปัญหาข้อมูลรั่วไหลระหว่างชุดข้อมูล (Data Leakage) ภาพที่สกัดมาจากวิดีโอเดียวกันจะถูกจัดให้อยู่ภายในชุดข้อมูลเดียวกันเท่านั้น โดยไม่มีการกระจายเฟรมจากวิดีโอเดียวกันไปอยู่ในหลายชุดข้อมูล แนวทางดังกล่าวช่วยลดอคติที่อาจเกิดจากความคล้ายคลึงของข้อมูลระหว่างชุดฝึกสอนและชุดทดสอบ ซึ่งจะส่งผลให้การประเมินประสิทธิภาพของแบบจำลองมีความสมจริงและน่าเชื่อถือมากยิ่งขึ้น

การจัดเตรียมชุดข้อมูลในลักษณะดังกล่าว มีวัตถุประสงค์เพื่อสนับสนุนการฝึกสอนแบบจำลองตรวจจับ

วัตถุที่มีความเสถียร และรองรับการวิเคราะห์ตำแหน่งการตกของลูกแบดมินตันอย่างมีประสิทธิภาพ

3.3 แบบจำลองตรวจจับวัตถุ


งานวิจัยนี้เลือกใช้แบบจำลองการตรวจจับวัตถุเชิงลึกในตระกูล YOLO (You Only Look Once) ซึ่งมีจุดเด่นด้านความเร็วในการประมวลผลและความเหมาะสมต่อการใช้งานแบบเรียลไทม์ แบบจำลองดังกล่าวได้รับการคัดเลือกเนื่องจากมีประสิทธิภาพในการตรวจจับวัตถุขนาดเล็กที่เคลื่อนที่ด้วยความเร็วสูง เช่น ลูกแบดมินตัน ซึ่งสอดคล้องกับลักษณะของปัญหาที่ศึกษาในงานวิจัยนี้

1) หลักการทำงานและสถาปัตยกรรมของ YOLO


YOLO มีหลักการทำงานที่แตกต่างจากแบบจำลองตรวจจับวัตถุแบบสองขั้นตอน (Two-stage detectors) เช่น R-CNN ซึ่งต้องอาศัยกระบวนการสร้างพื้นที่สนใจ (Region proposals) ก่อนทำการจำแนกวัตถุ ส่งผลให้ใช้เวลาในการประมวลผลสูงกว่า ในทางตรงกันข้าม YOLO ใช้แนวคิดการประมวลผลภาพเพียงครั้งเดียว (Single-pass detection) โดยพิจารณาภาพทั้งภาพพร้อมกันและแบ่งภาพออกเป็นตารางขนาด $S \times S$ หากจุดกึ่งกลางของวัตถุตกอยู่ในช่องใด ช่องดังกล่าวจะรับผิดชอบในการทำนายกรอบล้อมวัตถุ (Bounding Box) และค่าความน่าจะเป็นของคลาส (Class Probability) ส่งผลให้สามารถตรวจจับวัตถุได้อย่างรวดเร็วและมีประสิทธิภาพ




รูปที่ 2 ตัวอย่างชุดข้อมูล (Dataset)



(ก)



(ข)



(ค)

รูปที่ 3 หน้าจอการทำงานของเว็บแอปพลิเคชัน

จากการทบทวนพัฒนาการของสถาปัตยกรรม YOLO โดย Jiang et al. (2022) พบว่า โครงสร้างของ YOLO ในเวอร์ชันปัจจุบันสามารถอธิบายได้เป็น 3 ส่วนหลัก ซึ่งมีบทบาทสำคัญต่อประสิทธิภาพในการตรวจจับวัตถุ ดังนี้

1.1) Backbone: ทำหน้าที่สกัดคุณลักษณะเด่น (Feature Extraction) จากภาพต้นฉบับ โดยในเวอร์ชันใหม่ ของ YOLO มักใช้โครงสร้างที่มีประสิทธิภาพด้านการคำนวณ เช่น CSPDarknet หรือ EfficientRep เพื่อช่วยลดภาระการประมวลผล ขณะเดียวกันยังสามารถรักษาข้อมูลเชิงโครงสร้างที่สำคัญของภาพไว้ได้อย่างเหมาะสม

1.2) Neck: ทำหน้าที่รวมและถ่ายทอดคุณลักษณะจากหลายระดับความลึกของโครงข่าย (Feature Aggregation) โดยใช้เทคนิค เช่น Path Aggregation Network (PANet) เพื่อผสานข้อมูลที่มีความละเอียดเชิงพื้นที่แตกต่างกัน แนวทางดังกล่าวช่วยเพิ่มความสามารถในการตรวจจับวัตถุที่มีขนาดแตกต่างกันภายในภาพเดียว

1.3) Head: ทำหน้าที่ทำนายผลลัพธ์สุดท้ายของการตรวจจับ ได้แก่ ตำแหน่งของกรอบ (Localization) และการจำแนกประเภทของวัตถุ (Classification) ซึ่งเป็นผลลัพธ์หลักที่นำไปใช้ในกระบวนการวิเคราะห์ตำแหน่งลูกแบดมินตันของงานวิจัย

2) การประยุกต์ใช้การตรวจจับวัตถุขนาดเล็กและการเคลื่อนที่เร็ว

ลูกแบดมินตันถือเป็นวัตถุขนาดเล็ก (Small Object) ที่มีความท้าทายสูงในการตรวจจับจากวิดีโอการแข่งขัน งานวิจัยของ Vijayakumar & Vairavasundaram (2024) ระบุว่า YOLO ในเวอร์ชันล่าสุด เช่น YOLOv8 ได้รับการพัฒนาเพื่อแก้ไขข้อจำกัดของรุ่นก่อนหน้า โดยมีการปรับปรุงโครงสร้างของแบบจำลองให้มีประสิทธิภาพมากยิ่งขึ้น อาทิ การใช้โมดูล C2f ในส่วน backbone เพื่อเพิ่มความสามารถในการสกัดคุณลักษณะที่ซับซ้อน และการประยุกต์ใช้แนวคิดแบบ anchor-free ซึ่งช่วยลดความซับซ้อนในการคำนวณ และเพิ่มความเร็วในการอนุมาน (inference) ทำให้เหมาะสมต่อการตรวจจับวัตถุในวิดีโอแบบเรียลไทม์

นอกจากนี้ การประเมินประสิทธิภาพของแบบจำลองจะอาศัยตัวชี้วัดมาตรฐาน ได้แก่ ค่า Intersection over Union (IoU) และ Mean Average Precision (mAP) ซึ่งใช้วัดความสอดคล้องระหว่างกรอบล้อมวัตถุที่แบบจำลองทำนายได้เทียบกับค่าความเป็นจริง ตัวชี้วัดดังกล่าวมีความสำคัญอย่างยิ่งในบริบทของการแข่งขันกีฬา ซึ่งมักเกิดการบังซ้อนของวัตถุ (Occlusion) และการเปลี่ยนแปลงสภาพแวดล้อมอย่างรวดเร็ว

ตารางที่ 1 แสดงรายละเอียดของแบบจำลองทั้ง 4 ชุด

Model	#Images (Train)	Epochs	Objective
Model 1	4,800	150	ใช้เป็นกรณีฐาน (baseline) เพื่อศึกษาประสิทธิภาพของแบบจำลองภายใต้ปริมาณข้อมูลจำกัดและจำนวนรอบการฝึกสอนเริ่มต้น
Model 2	4,800	200	เพิ่มจำนวนรอบการฝึกสอนเพื่อศึกษาผลของการเรียนรู้เชิงลึกที่มากขึ้นภายใต้ปริมาณข้อมูลเท่าเดิม
Model 3	9,800	250	เพิ่มปริมาณข้อมูลฝึกสอนเพื่อศึกษาผลของความหลากหลายของข้อมูลต่อประสิทธิภาพการตรวจจับ
Model 4	9,800	300	เพิ่มจำนวนรอบการฝึกสอนบนชุดข้อมูลขนาดใหญ่เพื่อค้นหาแบบจำลองที่มีความเสถียรสูงสุด

3) ประสิทธิภาพในการตรวจจับแบบเรียลไทม์

Hussain (2023) ได้เปรียบเทียบพัฒนาการของสถาปัตยกรรม YOLO ตั้งแต่เวอร์ชันที่ 1 ถึงเวอร์ชันที่ 8 พบว่าแนวโน้มการพัฒนาของ YOLO มุ่งเน้นการรักษาสมดุลระหว่างความเร็วในการประมวลผลและความแม่นยำในการตรวจจับ (Speed-Accuracy Trade-off) เพื่อรองรับการนำไปใช้งานจริงบนอุปกรณ์ที่มีทรัพยากรจำกัด เช่น อุปกรณ์ปลายทาง (Edge devices) โดย YOLO เวอร์ชันใหม่ยังมีการปรับปรุงฟังก์ชันการสูญเสีย (Loss Function) และประยุกต์ใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) เช่น Mosaic เพื่อเพิ่มความทนทานของแบบจำลองต่อสภาพแวดล้อมที่หลากหลาย เช่น ความหลากหลายของฉาก มุมกล้อง และสภาพแสง

ดังนั้น การเลือกใช้ YOLO ในงานวิจัยนี้จึงมีความสอดคล้องกับความต้องการของระบบวิเคราะห์ตำแหน่งลูกแบดมินตัน ซึ่งต้องอาศัยทั้งความสามารถในการประมวลผลแบบเฟรมต่อเฟรมด้วยอัตราเฟรมสูง (High FPS) และความแม่นยำในการตรวจจับวัตถุขนาดเล็กที่เคลื่อนที่เร็ว เพื่อให้สามารถนำพิกัดตำแหน่งที่ได้ไปใช้ในการคำนวณตำแหน่งลูกตกในขั้นตอนถัดไปได้อย่างมีประสิทธิภาพ

4) การออกแบบการทดลองและการตั้งค่าแบบจำลอง

เพื่อศึกษาผลของปริมาณข้อมูลฝึกสอนและจำนวนรอบการฝึกสอน (epochs) ต่อประสิทธิภาพในการตรวจจับลูกแบดมินตัน งานวิจัยนี้ได้ออกแบบการทดลองโดยสร้างแบบจำลองจำนวน 4 ชุด (Model 1–4) ซึ่งแตกต่างกันเฉพาะจำนวนภาพฝึกสอนและจำนวน epochs ขณะที่กำหนดค่าการฝึกสอนอื่น ๆ ให้คงที่ทั้งหมด เพื่อให้การเปรียบเทียบผลลัพธ์มีความยุติธรรมและสามารถสรุปผลได้อย่างเป็นระบบ โดยรายละเอียดของการตั้งค่าแบบจำลองแต่ละชุด รวมถึงจำนวนภาพฝึกสอนและจำนวนรอบการฝึกสอน แสดงได้ดังตารางที่ 1

เพื่อควบคุมตัวแปรและลดอคติในการเปรียบเทียบผลการทดลอง งานวิจัยนี้จึงกำหนดค่าพารามิเตอร์การฝึกสอนให้เหมือนกันในทุกแบบจำลอง โดยมีรายละเอียดดังนี้

- Input size: `imgsz = 940` เพื่อรักษารายละเอียดของวัตถุขนาดเล็ก
- Batch size: `batch = 16` เพื่อความเสถียรของกระบวนการเรียนรู้
- Optimizer: AdamW เพื่อลดปัญหาการเรียนรู้มากเกินไป (Overfitting) และเพิ่มความเสถียรของการฝึกสอน
- Initial learning rate: `lr0 = 0.0005` เพื่อให้การปรับค่าน้ำหนักเป็นไปอย่างค่อยเป็นค่อยไป
- Learning rate schedule: Cosine learning rate (`cos_lr = True`) เพื่อการลู่เข้าสู่ค่าที่เหมาะสมอย่างรวดเร็ว
- Mixed precision: `amp = True` เพื่อลดระยะเวลาในการฝึกสอนและใช้ทรัพยากรการคำนวณอย่างมีประสิทธิภาพ
- Pretrained weights: `pretrained = True` เพื่อเริ่มต้นจากค่าน้ำหนักที่ผ่านการเรียนรู้ทั่วไปมาก่อน
- Checkpoint: `save_period = 20` เพื่อบันทึกแบบจำลองเป็นระยะและติดตามแนวโน้มการเรียนรู้ นอกจากนี้ เพื่อเพิ่มความทนทานของแบบจำลองต่อความผันแปรของวิดีโอการแข่งขันจริง เช่น การเอียงของกล้อง การสั่น และการเปลี่ยนแปลงมุมมอง ได้กำหนดเทคนิคการเพิ่มข้อมูล (Data Augmentation) ให้เหมือนกันในทุกแบบจำลอง ได้แก่
 - Degrees = 0.5 (การหมุนภาพ)
 - Translate = 0.05 (การเลื่อนตำแหน่ง ±5%)
 - Scale = 0.3 (การปรับขนาด ±30%)
 - Shear = 0.5 (การเฉือนภาพ)

- Perspective = 0.0002 (การเปลี่ยนมุมมอง)

การควบคุมพารามิเตอร์และเทคนิคการเพิ่มข้อมูลให้เหมือนกันในทุกการทดลองจะช่วยให้สามารถสรุปได้อย่างชัดเจนว่า ความแตกต่างของผลลัพธ์ที่ได้ เกิดจากปริมาณข้อมูลฝึกสอนและจำนวนรอบการฝึกสอนเป็นหลัก มิใช่ผลจากปัจจัยแทรกซ้อนอื่น ๆ ส่งผลให้การเปรียบเทียบประสิทธิภาพของแบบจำลองมีความน่าเชื่อถือมากยิ่งขึ้น

3.4 การประเมินประสิทธิภาพของแบบจำลอง

1) ตัวชี้วัดพื้นฐานในการประเมินความถูกต้องของตำแหน่งที่แบบจำลองทำนายคือค่า Intersection over Union (IoU) ซึ่งคำนวณจากอัตราส่วนระหว่างพื้นที่ที่ซ้อนทับกัน (Area of overlap) ของกรอบล้อมวัตถุที่แบบจำลองทำนาย กับกรอบอ้างอิงจริง (Ground truth) ต่อพื้นที่รวมของกรอบทั้งสอง (Area of Union) โดยค่า IoU มีค่าระหว่าง 0 ถึง 1 ซึ่งในงานวิจัยนี้กำหนดค่าเกณฑ์มาตรฐาน (Threshold) ที่ 0.5 กล่าวคือ หากค่า IoU มีค่ามากกว่าหรือเท่ากับ 0.5 จะถือว่าการตรวจจับนั้นเป็นการตรวจจับที่ถูกต้อง (True Positive)

2) ค่าความแม่นยำ (Precision) นำมาใช้ประเมินคุณภาพของผลการทำนาย โดยพิจารณาสัดส่วนของผลลัพธ์ที่แบบจำลองระบุว่าเป็นลูกเบตมินตันทั้งหมด ซึ่งเป็นการตรวจจับที่ถูกต้องจริง ตัวชี้วัดนี้มีความสำคัญอย่างยิ่งในการลดผลกระทบจากสัญญาณรบกวน (Noise) เนื่องจากสภาพแวดล้อมในการแข่งขันแบดมินตันอาจมีวัตถุหรือแสงสะท้อนที่มีลักษณะใกล้เคียงกับลูกเบตมินตัน หากแบบจำลองมีค่า Precision ต่ำ จะส่งผลให้เกิดการตรวจจับผิดพลาด (False Positive) บ่อยครั้ง และลดความน่าเชื่อถือของข้อมูลที่น่าไปใช้ในการวิเคราะห์ตำแหน่งลูกตก

3) ค่าการเรียกคืน (Recall) ใช้ประเมินความสามารถของแบบจำลองในการตรวจจับวัตถุได้อย่างครบถ้วน โดยพิจารณาว่า จากจำนวนลูกเบตมินตันที่ปรากฏจริงในทุกเฟรมภาพ แบบจำลองสามารถตรวจจับได้คิดเป็นสัดส่วนเท่าใด สำหรับงานวิจัยนี้ ค่า Recall ถือเป็นปัจจัยสำคัญเนื่องจากลูกเบตมินตันมีการเคลื่อนที่ด้วยความเร็วสูงและมักเกิดภาพเบลอจากการเคลื่อนที่ (Motion blur) หากค่า Recall ต่ำ จะบ่งชี้ถึงการตกหล่นของการตรวจจับ (Missed Detection) ซึ่งส่งผลให้ข้อมูลเส้นทางการเคลื่อนที่ของลูกขาดความต่อเนื่องและกระทบต่อความแม่นยำของการวิเคราะห์ตำแหน่งลูกตก

4) ค่าเฉลี่ยความแม่นยำ (Mean Average Precision - mAP) เพื่อสะท้อนภาพรวมของประสิทธิภาพที่สมดุลระหว่างความแม่นยำ (Precision) และความครบถ้วน (Recall) งานวิจัยใช้ดัชนี Mean Average Precision (mAP) ซึ่งคำนวณจากพื้นที่ใต้กราฟความสัมพันธ์ระหว่าง Precision และ Recall (P-R Curve) (Lippi et al., 2021) โดยพิจารณาใน 2 ระดับ ได้แก่

4.1) mAP@0.5: เป็นการประเมินประสิทธิภาพของแบบจำลองที่ค่าเกณฑ์ IoU 0.5 ซึ่งสะท้อนความสามารถในการระบุตำแหน่งและจำแนกวัตถุได้ถูกต้องในระดับมาตรฐาน

4.2) mAP@0.5:0.95: เป็นการประเมินประสิทธิภาพในระดับที่เข้มงวดมากขึ้น โดยคำนวณค่าเฉลี่ยของ mAP ที่ค่า IoU ตั้งแต่ 0.5 ถึง 0.95 (เพิ่มขึ้นทีละ 0.05) ตัวชี้วัดนี้สะท้อนถึงความแม่นยำเชิงตำแหน่งของกรอบล้อมวัตถุ (Bounding Box Tightness) ว่ามีความกระชับและสอดคล้องกับตำแหน่งจริงของลูกเบตมินตันมากเพียงใด

จากตัวชี้วัดดังกล่าว การประเมินประสิทธิภาพของแบบจำลองในงานวิจัยนี้สามารถอธิบายความสัมพันธ์ระหว่างความแม่นยำและความครบถ้วนของการตรวจจับได้อย่างเป็นระบบ ซึ่งสามารถสรุปในรูปแบบสมการมาตรฐานตามแนวทางที่เสนอโดย Malta et al. (2021) ต่อไปนี้

$$Precision = \frac{TP}{TP + FP} \quad (2.1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.2)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

การตรวจจับวัตถุที่ถูกต้อง (True Positive: TP) หมายถึงกรณีที่แบบจำลองสามารถระบุวัตถุเป้าหมายได้อย่างถูกต้องตามตำแหน่งและประเภท ในขณะที่การตรวจจับผิดพลาด (False Positive: FP) หมายถึงกรณีที่แบบจำลองทำนายการมีอยู่ของวัตถุเป้าหมายทั้งที่ไม่ปรากฏจริง หรือระบุวัตถุผิดประเภท ส่วนการตรวจจับตกหล่น (False Negative: FN) หมายถึงกรณีที่แบบจำลองไม่สามารถตรวจจับวัตถุเป้าหมายที่ปรากฏอยู่จริงได้ วิธีการ IoU จะคำนวณจากสัดส่วนของพื้นที่ที่ทับซ้อนกัน

ระหว่างกรอบล้อมวัตถุที่แบบจำลองทำนายกับกรอบอ้างอิงจริง ต่อพื้นที่รวมของกรอบทั้งสอง ทั้งนี้ ความถูกต้องของการตรวจจับจะถูกพิจารณาจากการเปรียบเทียบค่า IoU ที่ได้กับค่าเกณฑ์ (Threshold) ที่กำหนดไว้ โดยหากค่า IoU มีค่ามากกว่าหรือเท่ากับเกณฑ์ดังกล่าว การตรวจจับนั้นจะถูกจัดเป็นการตรวจจับที่ถูกต้อง

3.5 การวิเคราะห์ตำแหน่งการตกของลูกแบดมินตัน

หลังจากระบบสามารถระบุตำแหน่งของลูกแบดมินตันในแต่ละเฟรมได้แล้ว จะดำเนินการวิเคราะห์ลำดับการเคลื่อนที่ของลูกเพื่อระบุจุดสิ้นสุดของแต่ละช็อต โดยกำหนดให้ตำแหน่งสุดท้ายที่ตรวจพบก่อนที่ลูกจะหายไปจากเฟรมหรือก่อนที่จะเกิดการเปลี่ยนแปลงรูปแบบการเคลื่อนที่อย่างมีนัยสำคัญ เป็นตำแหน่งที่ลูกแบดมินตันตกกระทบพื้นสนาม วิธีการดังกล่าวช่วยให้สามารถประมาณตำแหน่งลูกตกได้อย่างสอดคล้องกับพฤติกรรมการเล่นจริงในสถานการณ์การแข่งขัน

เพื่อสนับสนุนการวิเคราะห์เชิงพื้นที่ สนามแบดมินตันถูกแบ่งออกเป็นโซนการเล่นตามแนวสิบลูกและแนวกว้าง ได้แก่ พื้นที่หน้า กลาง และหลัง โดยแยกออกเป็นด้านซ้ายและด้านขวา รวมเป็นทั้งหมด 6 โซน ได้แก่ Front Left (FL), Front Right (FR), Middle Left (ML), Middle Right (MR), Rear Left (RL) และ Rear Right (RR) ตำแหน่งลูกตกที่ตรวจพบจะถูกนำไปจับคู่กับโซนที่สอดคล้องกัน จากนั้นจึงจำแนกผลลัพธ์ของแต่ละช็อตออกเป็นลูก “ดี” (Good) หรือ “เสีย” (Bad) เพื่อสะท้อนผลลัพธ์เชิงกลยุทธ์และประสิทธิภาพของการตีในแต่ละจังหวะ

3.6 การพัฒนาเว็บแอปพลิเคชัน

เพื่อให้แบบจำลองที่พัฒนาขึ้นสามารถนำไปใช้งานได้จริง งานวิจัยนี้ได้พัฒนาเว็บแอปพลิเคชันสำหรับการวิเคราะห์ตำแหน่งการตกของลูกแบดมินตัน โดยระบบถูกออกแบบในลักษณะสถาปัตยกรรมแบบแยกส่วน (Client-Server Architecture) ประกอบด้วยสองส่วนหลัก ได้แก่ ส่วนหน้าบ้าน (Frontend) และส่วนหลังบ้าน (Backend)

ในส่วนหน้าบ้าน ใช้ภาษา HTML, CSS และ JavaScript สำหรับการออกแบบส่วนติดต่อผู้ใช้และการโต้ตอบกับระบบ ส่วนหลังบ้านพัฒนาด้วย Flask ซึ่งเป็นไมโครเฟรมเวิร์กของภาษา Python ทำหน้าที่ควบคุมกระบวนการประมวลผลและเรียกใช้งานแบบจำลอง YOLO ที่ผ่านการฝึกสอนแล้ว โดยแบบจำลองจะถูกโหลดจากไฟล์ที่จัดเก็บไว้บนเซิร์ฟเวอร์

เพื่อนำมาประมวลผลวิดีโอในแต่ละเฟรม และส่งผลลัพธ์กลับไปยังส่วนติดต่อผู้ใช้

ผู้ใช้สามารถอัปโหลดไฟล์วิดีโอการแข่งขันในรูปแบบ .mp4 ผ่านหน้าเว็บ ระบบจะดำเนินการประมวลผลวิดีโอโดยอัตโนมัติ พร้อมแสดงสถานะความคืบหน้าแบบเรียลไทม์ เมื่อการประมวลผลเสร็จสมบูรณ์ ระบบจะสร้างผลลัพธ์ในรูปแบบไฟล์ Microsoft Excel ซึ่งประกอบด้วยข้อมูลตำแหน่งลูกตกในแต่ละโซน รวมถึงสถิติในรูปแบบร้อยละของลูก “ดี” และลูก “เสีย” ข้อมูลดังกล่าวสามารถนำไปใช้สนับสนุนการวิเคราะห์ฟอร์มการเล่น การประเมินจุดแข็ง-จุดอ่อน และการวางแผนกลยุทธ์การแข่งขันของนักกีฬาและผู้ฝึกสอนได้อย่างเป็นรูปธรรม

3.7 การประเมินโดยผู้เชี่ยวชาญและผู้ใช้งาน

ปฏิบัติ ประกอบด้วยผู้ทรงคุณวุฒิจำนวน 3 ท่าน ซึ่งมีความเชี่ยวชาญด้านการเรียนรู้ของเครื่อง (Machine Learning) และวิทยาศาสตร์การกีฬา มุ่งเน้นการพิจารณาความถูกต้องของผลลัพธ์ ความเหมาะสมของกระบวนการวิเคราะห์ และศักยภาพของระบบในการนำไปใช้งานจริง ขณะเดียวกัน ได้มีการประเมินความพึงพอใจของผู้ใช้งานจริง โดยกำหนดกลุ่มตัวอย่างด้วยวิธีการเลือกแบบเจาะจง (Purposive Sampling) จากประชากรที่เป็นนักศึกษาศาสตร์วิทยาศาสตร์การกีฬา ชั้นปีที่ 3 จำนวน 45 คน และคัดเลือกกลุ่มตัวอย่างจำนวน 20 คน ซึ่งเป็นขนาดที่เหมาะสมตามหลักการความอิ่มตัวของข้อมูล (Data Saturation) ที่ระบุว่ากลุ่มตัวอย่างในช่วง 15–20 คน สามารถให้ข้อมูลที่ครอบคลุมและสะท้อนความหลากหลายของพฤติกรรมการใช้งานจริงได้อย่างเพียงพอ โดยเฉพาะในบริบทของการเรียนรู้และการวิเคราะห์ฟอร์มการเล่น ทั้งนี้ การประเมินทั้งสองส่วนดำเนินการโดยใช้แบบสอบถามมาตราส่วนประมาณค่า 5 ระดับ (Likert Scale) ได้แก่ มากที่สุด มาก ปานกลาง น้อย และน้อยที่สุด ครอบคลุมประเด็นด้านความเหมาะสม ความแม่นยำ และความสามารถในการนำระบบไปประยุกต์ใช้งานจริง

ตารางที่ 2 การเปรียบเทียบประสิทธิภาพของแบบจำลองตรวจจับวัตถุจำแนกตามขนาดชุดข้อมูลและจำนวนรอบการเรียนรู้

แบบจำลอง	ชุดข้อมูล	Images	Epochs	Val/Loss	Precision	Recall	mAP@50	mAP@50-95
Model 1	Validation	4,800	150	2.17	0.88	0.70	0.85	0.30
Model 2	Validation	4,800	200	2.20	0.92	0.88	0.91	0.34
Model 3	Validation	9,800	250	2.16	0.93	0.89	0.91	0.35
Model 4	Validation	9,800	300	2.07	0.95	0.92	0.92	0.45
Model 4	Test Set	980	300	-	0.91	0.89	0.90	0.41

ตารางที่ 3 สรุปข้อมูลดิบรายฝั่ง (Raw Data Summary)

Side	FL-G	FL-B	FR-G	FR-B	ML-G	ML-B	MR-G	MR-B	RL-G	RL-B	RR-G	RR-B
A	0	0	0	0	0	0	0	0	0	3	2	0
B	0	0	0	0	0	0	0	0	3	0	0	2

ตารางที่ 4 สรุปสถิติโซน (Zone Statistics)

Zone	รายละเอียด	จำนวนลูก	ร้อยละ
FL	หน้า-ซ้าย (Front Left)	0	0.0
FR	หน้า-ขวา (Front Right)	0	0.0
ML	กลาง-ซ้าย (Mid Left)	0	0.0
MR	กลาง-ขวา (Mid Right)	0	0.0
RL	หลัง-ซ้าย (Rear Left)	6	60.0
RR	หลัง-ขวา (Rear Right)	4	40.0
รวม	ทั้งหมด	10	100.0

ตารางที่ 5 ผลการประเมินความแม่นยำในการระบุตำแหน่งการตกและสถานะของลูกแบดมินตัน (Objective Evaluation)

โซน	ผลจากระบบ (ลูก)	ข้อมูลจริงจากผู้เชี่ยวชาญ (ลูก)	จำนวนที่ระบุถูกต้อง (Correct)	ความแม่นยำ (Accuracy %)
RL (หลัง-ซ้าย)	6	6	6	100%
RR (หลัง-ขวา)	4	4	3	75%
รวม	10	10	9	90%

ตารางที่ 6 ระดับความพึงพอใจของผู้ใช้งานต่อระบบตรวจจับลูกแบดมินตัน

รายการประเมิน	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน	ระดับความพึงพอใจ
1. ประโยชน์ต่อการเรียนรู้และการประยุกต์ใช้เทคโนโลยี	4.33	0.47	ดี
2. ความเข้าใจง่ายของขั้นตอนการอัปโหลดวิดีโอและดูผลลัพธ์	4.00	0.00	ดี
3. ความเร็วในการประมวลผลวิดีโอและแสดงผล	3.33	0.47	ปานกลาง
4. ความแม่นยำในการตรวจจับลูกและหาจุดตก	3.33	0.47	ปานกลาง
5. ความสะดวกในการแสดงผลการวิเคราะห์ (เช่น โซนลูกตก, คะแนน)	4.33	0.47	ดี
6. การส่งออกข้อมูลเป็นไฟล์ Excel ทำงานได้ถูกต้องและสะดวก	4.33	0.47	ดี
7. การนำเข้าและส่งออกข้อมูล (Import/Export) ทำได้อย่างราบรื่น	4.00	0.00	ดี
8. ความสามารถของระบบในการวิเคราะห์ลูกและแบ่งโซน	3.33	0.47	ปานกลาง
ค่าเฉลี่ยโดยรวม	3.87	0.35	ดี

4. ผลลัพธ์

4.1 ผลการเปรียบเทียบและคัดเลือกแบบจำลอง

จากการทดลองฝึกสอนแบบจำลองตรวจจับลูกแบดมินตันจำนวน 4 แบบ ซึ่งกำหนดค่าพารามิเตอร์

1) เมื่อเปรียบเทียบ Model 1 และ Model 2 ซึ่งใช้ชุดข้อมูลขนาด 4,800 ภาพเท่ากัน พบว่าการเพิ่ม

การฝึกสอน (Hyperparameters) ให้เหมือนกัน แต่แตกต่างกันในด้านขนาดชุดข้อมูล และจำนวนรอบการฝึกสอนผลการเปรียบเทียบประสิทธิภาพ แสดงได้ดังตารางที่ 2 และสามารถสรุปประเด็นสำคัญได้ดังนี้

1) จำนวนรอบการฝึกสอนจาก 150 เป็น 200 รอบ ส่งผลให้ประสิทธิภาพของแบบจำลองเพิ่มขึ้นอย่างมี

นัยสำคัญ โดยเฉพาะค่า Recall ที่เพิ่มขึ้นจากร้อยละ 70 เป็นร้อยละ 88 และค่า mAP@0.5 ที่เพิ่มขึ้นจากร้อยละ 85 เป็นร้อยละ 91 ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่าแบบจำลองสามารถเรียนรู้ลักษณะของวัตถุได้ครอบคลุมมากขึ้น และลดอัตราการตรวจจับตกหล่น (Missed Detection) ได้อย่างชัดเจนเมื่อได้รับระยะเวลาในการเรียนรู้ที่เหมาะสม

2) ใน Model 3 ซึ่งเพิ่มขนาดชุดข้อมูลเป็น 9,800 ภาพ และฝึกสอนเป็นจำนวน 250 รอบ แสดงให้เห็นว่าค่า Precision เพิ่มขึ้นเป็นร้อยละ 93 และค่า Recall เพิ่มขึ้นเป็นร้อยละ 89 อย่างไรก็ตาม เมื่อพิจารณาความแม่นยำโดยรวม (Accuracy) พบว่าลดลงเล็กน้อยเหลือร้อยละ 73 เมื่อเทียบกับ Model 2 ที่มีค่าร้อยละ 74 ขณะเดียวกัน ค่า mAP@0.5-0.95 ซึ่งสะท้อนความเที่ยงตรงของกรอบล้อมวัตถุ (Bounding Box Tightness) เพิ่มขึ้นเพียงเล็กน้อยเป็นร้อยละ 35 ผลลัพธ์ดังกล่าวอาจเกิดจากความหลากหลายของข้อมูลที่เพิ่มขึ้น ทำให้แบบจำลองต้องใช้จำนวนรอบการฝึกสอนมากขึ้นเพื่อปรับตัวและเข้าสู่สภาวะเสถียร

3) Model 4 ซึ่งใช้ชุดข้อมูลขนาด 9,800 ภาพเท่ากับ Model 3 แต่เพิ่มจำนวนรอบการฝึกสอนเป็น 300 รอบ แสดงให้เห็นถึงประสิทธิภาพสูงสุดในทุกตัวชี้วัด โดยมีค่าความคลาดเคลื่อน (Validation loss) ลดลงต่ำที่สุดที่ 2.07 และมีค่า Precision สูงถึงร้อยละ 95 ค่า Recall ร้อยละ 92 รวมถึงค่า mAP@0.5-0.95 ที่เพิ่มขึ้นอย่างชัดเจนเป็นร้อยละ 45 ผลลัพธ์ดังกล่าวสะท้อนว่าแบบจำลองไม่เพียงสามารถตรวจจับลูกแบดมินตันได้อย่างแม่นยำและครบถ้วนเท่านั้น แต่ยังสามารถระบุตำแหน่งของกรอบล้อมวัตถุ (Bounding Box) ได้อย่างกระชับและสอดคล้องกับตำแหน่งจริงมากที่สุด นอกจากนี้ การพิจารณาแนวโน้มการเรียนรู้ของ Model 4 พบว่าค่าประสิทธิภาพเริ่มคงที่และไม่เปลี่ยนแปลงอย่างมีนัยสำคัญเมื่อเพิ่มจำนวนรอบการฝึกสอนมากกว่านี้ ซึ่งบ่งชี้ว่าแบบจำลองได้เข้าสู่จุดอิ่มตัวของการเรียนรู้ (Learning saturation point) ที่เหมาะสมแล้ว ด้วยเหตุนี้ งานวิจัยจึงเลือก Model 4 เป็นแบบจำลองหลักสำหรับการนำไปพัฒนาและใช้งานในระบบเว็บแอปพลิเคชัน

4) เมื่อนำแบบจำลองดังกล่าวมาประเมินประสิทธิภาพขั้นสุดท้ายกับชุดข้อมูลทดสอบ (Test Set) ซึ่งเป็นข้อมูลที่ไม่เคยปรากฏในการฝึกสอนมาก่อน พบว่าค่า mAP@50 ยังคงอยู่ในระดับสูงที่ 0.90 และค่า mAP@50-95 อยู่ที่ 0.41 การ

ที่ประสิทธิภาพบนชุดข้อมูลทดสอบมีความสอดคล้องและใกล้เคียงกับชุดข้อมูลตรวจสอบ (มีส่วนต่างเพียงร้อยละ 2) เป็นเครื่องบ่งชี้ว่าแบบจำลองมีความสามารถในการนำไปใช้งานทั่วไป (Generalization) ได้เป็นอย่างดี ไม่เกิดปัญหาการเรียนรู้มากเกินไป (Overfitting) และมีความแม่นยำเพียงพอที่จะนำไปใช้เป็นแกนหลักในระบบวิเคราะห์ตำแหน่งการตกของลูกแบดมินตันตามวัตถุประสงค์ของงานวิจัย

4.2 ผลการพัฒนาเว็บแอปพลิเคชัน

ระบบตรวจจับและวิเคราะห์ตำแหน่งการตกของลูกแบดมินตันถูกพัฒนาในรูปแบบเว็บแอปพลิเคชันที่มุ่งเน้นความสะดวกในการใช้งานและการเข้าถึงของผู้ใช้ทั่วไป โดยส่วนติดต่อผู้ใช้ถูกออกแบบให้มีขั้นตอนการใช้งานที่ชัดเจนและเป็นลำดับ เริ่มจากหน้าหลักซึ่งผู้ใช้สามารถอัปโหลดไฟล์วิดีโอการแข่งขันในรูปแบบ .mp4 พร้อมแสดงชื่อไฟล์ที่เลือกและปุ่มเริ่มต้นการประมวลผล

เมื่อผู้ใช้เริ่มการตรวจจับ ระบบจะเข้าสู่สถานะการประมวลผลโดยอัตโนมัติ พร้อมแสดงแถบสถานะความคืบหน้า (Progress Bar) และข้อความแจ้งเตือนเพื่อให้ผู้ใช้รับทราบถึงสถานะของระบบระหว่างการทำงาน เมื่อกระบวนการประมวลผลเสร็จสิ้น ระบบจะแสดงข้อความยืนยันความสำเร็จ และทำการสร้างผลลัพธ์ในรูปแบบไฟล์ Microsoft Excel ซึ่งถูกดาวน์โหลดให้แก่ผู้ใช้โดยอัตโนมัติ

ตัวอย่างส่วนติดต่อผู้ใช้และผลลัพธ์ที่ได้จากระบบแสดงไว้ดังภาพตัวอย่างเมื่อการประมวลผลเสร็จสมบูรณ์ ระบบจะสร้างและดาวน์โหลดไฟล์ผลลัพธ์ในรูปแบบ Microsoft Excel ซึ่งภายในประกอบด้วยตารางสรุปข้อมูลดิบและสถิติการกระจายตำแหน่งการตกของลูกแบดมินตันในเชิงพื้นที่ ตัวอย่างตารางผลลัพธ์ที่ได้จากระบบ แสดงได้ดังตารางที่ 3 และตารางที่ 4

คำอธิบายด้วยย่อ

- ตำแหน่ง F = หน้า (Front), M = กลาง (Mid), R = หลัง (Rear)
- ทิศทาง L = ซ้าย (Left), R = ขวา (Right)
- ผลลัพธ์ G = ลูกดี (Good), B = ลูกเสีย (Bad)
- ตัวอย่างเช่น RL-G หมายถึง ลูกตกที่โซนหลัง-ซ้าย และเป็นลูกดี

จากตารางที่ 3 แสดงให้เห็นข้อมูลดิบของตำแหน่งการตกของลูกแบดมินตันที่จำแนกตามฝั่งสนามและผลลัพธ์ของ

แต่ละข้อ ในขณะที่ยังมีตารางที่ 4 แสดงการสรุปสถิติการกระจายตัวของตำแหน่งการตกของลูกในเชิงพื้นที่ ผลลัพธ์ชี้ให้เห็นว่าลูกแบดมินตันส่วนใหญ่ตกในพื้นที่ด้านหลังของสนาม โดยเฉพาะโซนหลัง-ซ้าย (RL) คิดเป็นร้อยละ 60 และโซนหลัง-ขวา (RR) คิดเป็นร้อยละ 40 ซึ่งสะท้อนรูปแบบการเล่นที่เน้นการตีลูกยาวไปยังพื้นที่ท้ายสนามเพื่อกดดันคู่ต่อสู้ในเชิงกลยุทธ์

จากการสรุปผลเชิงสถิติของตำแหน่งการตกของลูกจากตารางที่ 3 และตารางที่ 4 ผู้วิจัยได้ดำเนินการประเมินความแม่นยำเชิงวัตถุวิสัย (Objective Evaluation) โดยนำวิดีโอทดสอบไปให้ผู้เชี่ยวชาญด้านกีฬาแบดมินตันทำการตรวจสอบและระบุตำแหน่งที่เกิดการตกที่แท้จริง (Ground Truth) จากนั้นจึงนำข้อมูลดังกล่าวมาเปรียบเทียบกับตำแหน่งที่พิกัดที่ได้จากการคำนวณของแบบจำลอง ซึ่งแสดงผลการเปรียบเทียบดังตารางที่ 5

จากตารางที่ 5 ผลการเปรียบเทียบแสดงให้เห็นว่าจากเหตุการณ์ที่เกิดขึ้นทั้งหมด 10 ครั้ง ระบบสามารถตรวจจับและระบุโซนการตกได้ถูกต้องแม่นยำจำนวน 9 ครั้ง คิดเป็นความแม่นยำร้อยละ 90 โดยจุดที่เกิดความคลาดเคลื่อนมักอยู่ในโซนหลัง (Rear Zone) เนื่องจากเป็นช่วงที่ลูกมีความเร็วลดลงและเปลี่ยนทิศทางการเคลื่อนที่อย่างรวดเร็ว (Deceleration) อย่างไรก็ตาม ค่าความแม่นยำในระดับดังกล่าวยืนยันได้ว่าแบบจำลองที่พัฒนาขึ้นมีความน่าเชื่อถือและสามารถนำไปใช้ในการวิเคราะห์เชิงกลยุทธ์เพื่อสะท้อนภาพรวมการเล่นได้อย่างมีประสิทธิภาพตามเป้าหมายของงานวิจัย

4.3 ผลการประเมินประสิทธิภาพโดยผู้เชี่ยวชาญ

จากการประเมินระบบตรวจจับตำแหน่งลูกแบดมินตันโดยผู้เชี่ยวชาญจำนวน 3 ท่าน พบว่าประสิทธิภาพโดยรวมของระบบอยู่ในระดับดี โดยมีคะแนนเฉลี่ยเท่ากับ 4.25 จากคะแนนเต็ม 5 คะแนน ผลการประเมินดังกล่าวสะท้อนให้เห็นว่าระบบสามารถตอบสนองต่อการใช้งานพื้นฐานได้อย่างเหมาะสม โดยเฉพาะในด้านการถูกต้องของการวิเคราะห์ตำแหน่งเชิงพื้นที่ของลูกแบดมินตัน และการนำเสนอรายงานผลลัพธ์ในรูปแบบที่เข้าใจง่ายและสามารถนำไปใช้ประโยชน์ได้จริง

อย่างไรก็ตาม ผู้เชี่ยวชาญได้ให้ข้อเสนอแนะเพื่อการพัฒนาระบบเพิ่มเติมในสองประเด็นสำคัญ ประเด็นแรกคือด้านความเร็วในการประมวลผล โดยระบบยังมีความล่าช้า

(Latency) ในขั้นตอนการอัปโหลดไฟล์วิดีโอและการประมวลผลผลลัพธ์ โดยเฉพาะในกรณีที่ไฟล์วิดีโอมีขนาดใหญ่หรือมีความละเอียดสูง ประเด็นที่สองคือความคลาดเคลื่อนของผลการตรวจจับในบางสถานการณ์ เมื่อเปรียบเทียบกับ การตรวจสอบด้วยสายตามนุษย์ (Human Visual Inspection) โดยเฉพาะในจังหวะที่ลูกแบดมินตันมีความเร็วสูงหรือเกิดการซ้อนทับกับเส้นสนาม ซึ่งเป็นประเด็นที่สามารถนำไปใช้เป็นแนวทางในการพัฒนาระบบให้มีความแม่นยำและเสถียรยิ่งขึ้นในอนาคต

4.4 ผลการประเมินความพึงพอใจของกลุ่มตัวอย่าง

จากผลการประเมิน พบว่าผู้ใช้งานมีความพึงพอใจต่อระบบโดยรวมอยู่ในระดับดี (ค่าเฉลี่ย 3.87 จาก 5 คะแนน) ซึ่งสะท้อนให้เห็นว่าระบบสามารถตอบสนองต่อความต้องการด้านการใช้งาน การเรียนรู้ และการวิเคราะห์ข้อมูลเชิงกลยุทธ์ได้อย่างเหมาะสม เมื่อพิจารณารายชื่อ พบว่าผู้ใช้งานให้คะแนนในระดับดีใน 5 ประเด็นหลัก ได้แก่ 1) ประโยชน์ต่อการเรียนรู้และการประยุกต์ใช้เทคโนโลยี 2) ความเข้าใจง่ายของขั้นตอนการอัปโหลดวิดีโอและดูผลลัพธ์ 3) ความสะดวกในการแสดงผลการวิเคราะห์ 4) การส่งออกข้อมูลเป็นไฟล์ Excel ทำงานได้ถูกต้องและสะดวก และ 5) การนำเข้าและส่งออกข้อมูล (Import/Export) ทำได้อย่างราบรื่น

อย่างไรก็ตาม รายการที่ได้รับคะแนนต่ำที่สุดซึ่งอยู่ในระดับปานกลาง ได้แก่ ความเร็วในการประมวลผล ความแม่นยำในการตรวจจับลูก และความสามารถในการวิเคราะห์แบ่งโซนสนาม ซึ่งสอดคล้องกับผลการประเมินโดยผู้เชี่ยวชาญในก่อนหน้านี้ โดยชี้ให้เห็นว่าระบบยังมีข้อจำกัดด้านประสิทธิภาพการประมวลผลและความคลาดเคลื่อนในการตรวจจับในบางสถานการณ์ ซึ่งเป็นประเด็นที่ควรได้รับการพัฒนาเพิ่มเติมในงานวิจัยระยะถัดไป

5. การอภิปราย

ผลการวิจัยจากการพัฒนาและทดสอบระบบตรวจจับตำแหน่งลูกแบดมินตันด้วยเทคโนโลยีปัญญาประดิษฐ์แสดงให้เห็นว่า แบบจำลองที่ใช้สถาปัตยกรรม YOLOv8 (Model 4) มีศักยภาพสูงในการตรวจจับลูกแบดมินตัน โดยมีค่า Precision สูงถึงร้อยละ 95 และค่า Recall ร้อยละ 92 ซึ่งสอดคล้องกับแนวคิด Track-by-Detection ที่ Mirzaei et al. (2023) และ Cao et al. (2021) ระบุว่าเป็นแนวทางที่มี

ประสิทธิภาพในการแก้ปัญหาการติดตามวัตถุขนาดเล็กที่เคลื่อนที่รวดเร็ว นอกจากนี้ การเลือกใช้ YOLOv8 ยังสอดคล้องกับข้อเสนอแนะของ Kim & Cheng (2023) ที่เน้นย้ำถึงความสำคัญของแบบจำลองน้ำหนักเบาที่สามารถรองรับการประมวลผลแบบเรียลไทม์และการนำไปใช้งานจริง

อย่างไรก็ตาม ผลการประเมินจากทั้งผู้เชี่ยวชาญและผู้ใช้งานจริงชี้ให้เห็นว่าระบบยังมีข้อจำกัดด้านความเสถียรของการติดตามลูกและความแม่นยำในการระบุจุดตกในบางสถานการณ์ โดยเฉพาะกรณีที่ลูกแบดมินตันเคลื่อนที่ด้วยความเร็วสูงหรือเกิดภาพเบลอจากการเคลื่อนที่ (Motion Blur) ซึ่งเป็นความท้าทายเดียวกับที่ Mirzaei et al. (2023) และ Rozumnyi et al. (2021) ได้กล่าวถึงในงานวิจัยก่อนหน้า ในประเด็นความพยายามแก้ไขด้วยเทคนิคการลดความเบลอ (Deblurring)

นอกจากนี้ การที่ระบบยังมีการตรวจจับตกหล่นในบางเฟรม (Missed Detection) ซึ่งสะท้อนผ่านค่า Recall แสดงให้เห็นถึงความจำเป็นในการประยุกต์ใช้เทคนิคเสริมเพื่อเติมเต็มข้อมูลที่ขาดหายไป ดังเช่นงานวิจัยของ Lai et al. (2025) ที่เสนอการใช้กลไก Attention เพื่อเพิ่มความแม่นยำ หรือแนวทางของ อภิสิทธิ์ เปรมปรีดี และคณะ (2567) และ Shah et al. (2020) ที่ประยุกต์ใช้ Kalman Filter เพื่อประมาณค่าตำแหน่งและสร้างเส้นทางการเคลื่อนที่ของลูกให้มีความต่อเนื่องมากยิ่งขึ้น

ในด้านการประยุกต์ใช้งานจริง ผลการประเมินความพึงพอใจของผู้ใช้งานยืนยันว่าระบบมีคุณค่าอย่างมากต่อการเรียนรู้และการวิเคราะห์เกมกีฬา โดยเฉพาะการสรุปผลในรูปแบบข้อมูลเชิงสถิติและการส่งออกไฟล์ Excel ซึ่งช่วยอำนวยความสะดวกในการวิเคราะห์เชิงลึกและการวางแผนกลยุทธ์การแข่งขัน ผลลัพธ์ดังกล่าวสอดคล้องกับแนวคิดของระบบสนับสนุนการตัดสินใจ (Instant Review System) ที่ Kopania et al. (2022) ระบุว่าการระบุตำแหน่งลูกอย่างแม่นยำมีบทบาทสำคัญต่อการตัดสินใจผลการแข่งขัน

แม้ว่าระบบที่พัฒนาขึ้นยังมีข้อจำกัดในบางประเด็น แต่ผลการทดลองและการประเมินทั้งเชิงเทคนิคและเชิงผู้ใช้งานแสดงให้เห็นถึงศักยภาพของแนวทางการวิเคราะห์ตำแหน่งลูกแบดมินตันด้วยเทคโนโลยีคอมพิวเตอร์วิทัศน์ ซึ่งสามารถต่อยอดไปสู่การวิเคราะห์ขั้นสูง เช่น การจำแนกประเภทการตี (Shot Classification) และการวิเคราะห์รูปแบบการเล่น

เชิงกลยุทธ์ ตามแนวทางของ Wang (2021) และ Zhao (2023) ในอนาคต

6. บทสรุป

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์สำหรับการวิเคราะห์ตำแหน่งการตกของลูกแบดมินตัน เพื่อยกระดับประสิทธิภาพในการวิเคราะห์เกม (Scouting) และสนับสนุนการวางแผนกลยุทธ์การแข่งขัน โดยผู้วิจัยได้พัฒนาแบบจำลองตรวจจับวัตถุด้วยสถาปัตยกรรม YOLOv8 และบูรณาการเข้ากับระบบเว็บแอปพลิเคชันที่สามารถใช้งานได้จริง เพื่อแปลงข้อมูลจากวิดีโอการแข่งขันให้เป็นข้อมูลเชิงสถิติและเชิงพื้นที่ที่มีความหมายทางกลยุทธ์

ผลการทดลองแสดงให้เห็นว่า การกำหนดค่าพารามิเตอร์การฝึกสอนที่เหมาะสม โดยเฉพาะการใช้จำนวนรอบการฝึกสอน 300 รอบ ร่วมกับชุดข้อมูลที่มีความหลากหลายและเพียงพอจำนวน 9,800 ภาพ เป็นปัจจัยสำคัญที่ส่งผลให้แบบจำลองมีประสิทธิภาพสูงสุด แบบจำลองที่ได้สามารถตรวจจับลูกแบดมินตันได้อย่างแม่นยำ โดยมีค่า Precision ร้อยละ 95 และมีความครอบคลุมในการตรวจจับด้วยค่า Recall ร้อยละ 92 เมื่อนำแบบจำลองดังกล่าวไปประยุกต์ใช้งานในระบบจริง พบว่าสามารถสนับสนุนการวิเคราะห์รูปแบบการเล่น การระบุโซนการตกของลูก และการจัดทำรายงานสถิติในรูปแบบที่เข้าใจง่ายและสามารถนำไปใช้งานต่อได้อย่างมีประสิทธิภาพ ซึ่งสอดคล้องกับผลการประเมินความพึงพอใจของผู้ใช้งานที่อยู่ในระดับดี ระบบที่พัฒนาขึ้นแสดงให้เห็นถึงศักยภาพของการประยุกต์ใช้คอมพิวเตอร์วิทัศน์และการเรียนรู้เชิงลึกในการวิเคราะห์เกมกีฬาแบดมินตัน และสามารถต่อยอดไปสู่การเป็นเครื่องมือมาตรฐานสำหรับการฝึกซ้อม การวิเคราะห์การแข่งขัน และการพัฒนานักกีฬาในระดับสโมสรระดับชาติ และระดับนานาชาติได้ในอนาคต

อย่างไรก็ตาม งานวิจัยนี้ยังคงมีข้อจำกัดในด้านความเร็วในการประมวลผล และความเสถียรของการติดตามวัตถุในสถานการณ์ที่ลูกแบดมินตันมีความเร็วสูงหรือเกิดภาพเบลอจากการเคลื่อนที่ ซึ่งส่งผลต่อความแม่นยำในการระบุจุดตกในบางกรณี ดังนั้น แนวทางการพัฒนาในอนาคตควรมุ่งเน้นการผสมผสานเทคนิคการประมาณค่าตำแหน่ง เช่น Kalman Filter หรือเทคนิคการประมวลผลภาพขั้นสูง เพื่อ

พัฒนาไปสู่การเป็นเครื่องมือมาตรฐานที่ได้รับการยอมรับในวงการกีฬาแบดมินตันต่อไป

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนสนับสนุนจากคณะวิทยาศาสตร์
ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้า
พระนครเหนือ ตามสัญญาเลขที่ SCI-690031

เอกสารอ้างอิง

- Cao, Z., Liao, T., Song, W., Chen, Z., & Li, C. (2021). Detecting the shuttlecock for a badminton robot: A YOLO based approach. *Expert Systems with Applications*, 164, 113833. <https://doi.org/10.1016/j.eswa.2020.113833>
- Hsu, Y.-H., Yu, C.-C., & Cheng, H.-Y. (2024). Enhancing Badminton Game Analysis: An Approach to Shot Refinement via a Fusion of Shuttlecock Tracking and Hit Detection from Monocular Camera. *Sensors*, 24(13), 4372. <https://doi.org/10.3390/s24134372>
- Hussain, M. (2023). YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. *Machines*, 11(7), 677. <https://doi.org/10.3390/machines11070677>
- Jiang, P., Ergu, D., Liu, F., Cai, Y., & Ma, B. (2022). A Review of Yolo Algorithm Developments. *Procedia Computer Science*, 199, 1066–1073. <https://doi.org/10.1016/j.procs.2022.01.135>
- Kamoljitprapa, P., & Leelasilapasart, P. (2025). Development of Machine Learning Regression Models for CO₂ Emission Forecasting in Thailand. In *7th International Conference on Statistics: Theory and Applications (ICSTA'25)*, Paris, France, pp. 1-7. <https://doi.org/10.11159/icsta.25.146>
- Kim, J., & Cheng, K. (2023). AI-powered badminton video detection: Enhancing gameplay analysis and training. *TechRxiv*. <https://doi.org/10.36227/techrxiv.23708325.v1>
- Kopania, M., Nowisz, J., & Przelaskowski, A. (2022). Automatic Shuttlecock Fall Detection System in or out of a Court in Badminton Games—Challenges, Problems, and Solutions from a Practical Point of View. *Sensors*, 22(21), 8098. <https://doi.org/10.3390/s22218098>
- Lai, Y., Shi, Z., & Zhu, C. (2025). YO-CSA-T: A real-time badminton tracking system utilizing YOLO based on contextual and spatial attention. *arXiv*. <https://doi.org/10.48550/arXiv.2501.06472>
- Lippi, M., Bonucci, N., Carpio, R. F., Contarini, M., Speranza, S., & Gasparri, A. (2021). A yolo-based pest detection system for precision agriculture. In *2021 29th Mediterranean Conference on Control and Automation (MED)*, PUGLIA, Italy, pp. 342–347. <https://doi.org/10.1109/MED51440.2021.9480344>
- Malta, A., Mendes, M., & Farinha, T. (2021). Augmented Reality Maintenance Assistant Using YOLOv5. *Applied Sciences*, 11(11), 4758. <https://doi.org/10.3390/app11114758>
- Mirzaei, B., Nezamabadi-pour, H., Raoof, A., & Derakhshani, R. (2023). Small Object Detection and Tracking: A Comprehensive Review. *Sensors*, 23(15), 6887. <https://doi.org/10.3390/s23156887>
- Prempre, A., Kiatwuthiamorn, J., & Cumpim, C. (2024). Ball Tracking System Using Kalman Filter and Deep Learning. *Journal of Advanced Development in Engineering and Science*, 14(40), 108-133. <https://ph03.tci-thaijo.org/index.php/pitjournal/article/view/592>
- Rozumnyi, D., Matas, J., Sroubek, F., Pollefeys, & Oswald, M.R. (2020). FMODetect: Robust Detection of Fast Moving Objects. In *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 3521-3529.
- Singh, S. (2021). *Using Deep Learning to Predict the Path of a Shuttlecock in Badminton* [Master's thesis]. Arkansas State University.
- Srigarom, S.m & Chew, K.H. (2020). Hybrid motion-based object detection for detecting and tracking of small and fast moving drones. In *2020 International Conference on Unmanned Aircraft Systems (ICUAS)*, Athens, Greece, pp. 615-621. <https://doi.org/10.1109/ICUAS48674.2020.9213912>
- Sun, W., Dai, L., Zhang, X., Chang, P., & He, X. (2022). RSOD: Real-time small object detection algorithm in UAV-based traffic monitoring. *Applied Intelligence*, 52, 8448–8463. <https://doi.org/10.1007/s10489-021-02893-3>
- Vijayakumar, A., & Vairavasundaram, S. (2024). YOLO-based Object Detection Models: A Review and its Applications. *Multimedia Tools and Applications*, 83, 83535–83574. <https://doi.org/10.1007/s11042-024-18872-y>
- Vrajesh, S.R., Amudhan, A.N., Lijiya, A., & Sudheer, A.P. (2020). Shuttlecock Detection and Fall Point Prediction using Neural Networks. In *2020 International Conference for Emerging Technology (INCET)*, Belgaum, India, pp. 1-6. <https://doi.org/10.1109/INCET49848.2020.9154136>
- Wang, W. (2021), Using Machine Learning Algorithms to Recognize Shuttlecock Movements. *Wireless Communications and Mobile Computing*, 9976306. <https://doi.org/10.1155/2021/9976306>
- Zhao, Y. (2023). Automatic shuttlecock motion recognition using deep learning. *IEEE Access*, 11, 111281–111291. <https://doi.org/10.1109/ACCESS.2023.3322455>