

การติดตามเป้าหมายพรางตัวโดยใช้การผสานกล้องถ่ายภาพความร้อน และกล้องภาพสีจริง

Camouflaged Target Tracking using a Thermal Imaging and a True Color Camera Fusion

วีระพัฒน์ ชูสินวรสกุล¹ ประสาทพร วงษ์คำช้าง¹ พงศกร บำรุงไทย² และชำนาญ เพชรโชติ¹

Veerapat Choosinworasakul¹, Prasatporn Wongkamchang¹,

Pongsakon Bamrungthai² and Chamnan Pedchote¹

¹สำนักบัณฑิตศึกษา โรงเรียนนายเรืออากาศนวมินทกษัตริยาธิราช

¹Graduate School, Navaminda Kasatriyadhiraj Royal Air Force Academy

²ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา

²Department of Mechanical Engineering, Faculty of Engineering,

Kasetsart University Sriracha Campus

Received: December 4, 2024

Revised: March 3, 2025

Accepted: March 10, 2025

บทคัดย่อ

งานวิจัยนี้นำเสนอการพัฒนาอัลกอริทึมสำหรับการติดตามวัตถุที่พรางตัว ด้วยการbinทดสอบติดตามเป้าหมายด้วยอากาศยานไร้คนขับ โดยใช้การผสานข้อมูลจากกล้องภาพสีจริง (RGB) และกล้องถ่ายภาพความร้อน (thermal) ที่ติดตั้งบนอากาศยานไร้คนขับเพื่อเพิ่มประสิทธิภาพในการติดตามเป้าหมายที่มีลักษณะซับซ้อนและกลมกลืนกับสภาพแวดล้อม การใช้กล้อง RGB ช่วยให้รายละเอียดเชิงพื้นที่ที่ชัดเจน ขณะที่กล้องถ่ายภาพความร้อนสามารถตรวจจับการแผ่รังสีความร้อนของวัตถุ ซึ่งมีประโยชน์ในสภาพแวดล้อมที่มีแสงน้อยหรือเมื่อวัตถุพรางตัว โดยทำการบันทึกและส่งภาพวิดีโอแบบเรียลไทม์จากกล้องทั้ง 2 ชนิดไปยังสถานีควบคุมภาคพื้นดิน (ground control station) เพื่อให้ผู้ควบคุมสามารถติดตาม และวิเคราะห์ข้อมูลจากระยะไกลได้ โดยงานวิจัยนี้ได้เลือกใช้อัลกอริทึมที่มีพัฒนาการผสานข้อมูลจากทั้งสองแหล่งให้มีความแม่นยำในการติดตามมากขึ้น โดยการใช้อัลกอริทึมในการติดตามเป้าหมาย 4 แบบ คือ Boosting CSR-DCF KCF และ MOSSE ผลการทดลองชี้ให้เห็นว่าอัลกอริทึม Boosting สามารถระบุตำแหน่งวัตถุได้แม่นยำที่สุด โดยผลการประเมินประสิทธิภาพแสดงให้เห็นว่าค่า Mean Center Location Error: mCLE ต่ำที่สุดมีค่าเท่ากับ 43.46 และค่า AUC Score สูงสุดเท่ากับ 0.154 นอกจากนี้ ค่า Distance Precision: DP เท่ากับ 0.1085 และ Overlap Precision: OP เท่ากับ 0.0651 ซึ่งมีความแม่นยำที่สูงขึ้นด้วยเช่นกัน ซึ่งแสดงให้เห็นถึงความสามารถในการติดตามวัตถุได้อย่างมีประสิทธิภาพและสม่ำเสมอในการติดตามวัตถุที่พรางตัวในสภาพแวดล้อมที่ยากต่อการมองเห็น

คำสำคัญ การประมวลผลภาพ วัตถุซ่อนพราง ระบบติดตามวัตถุ อากาศยานไร้คนขับ

Abstract

This research presents the development of an algorithm for tracking camouflaged objects through flight tests using an unmanned aerial vehicle (UAV) by fusing data from a true color (RGB) camera and a thermal imaging camera mounted on the UAV to enhance the tracking performance of targets that are complex and blend into the environment. The RGB camera provides clear spatial details, while the thermal camera can detect the thermal radiation emitted by objects, which is useful in low-light conditions or when the object is camouflaged. Real-time video feeds from both camera types are transmitted to a ground control station (GCS), enabling remote monitoring and analysis by operators. The developed algorithm combines data from both sources to achieve tracking accuracy by using four tracking algorithms: Boosting, CSR-DCF, KCF, and MOSSE. Experimental results indicate that the boosting algorithm achieves the highest tracking accuracy, with the performance metrics indicating a lowest Mean Center Location Error (mCLE) of 43.46 and a highest AUC Score of 0.154. Additionally, the Distance Precision (DP) of 0.1085 and Overlap Precision (OP) of 0.154 scores demonstrate improved accuracy, highlighting the effectiveness and consistency of the algorithm in tracking camouflaged objects in challenging environments where visibility is limited.

Keyword: image processing, camouflage object, tracking system, unmanned aerial vehicle



บทนำ

การพรางมีความสำคัญมากในวงการทหาร เสื้อลายพรางมีได้มีจุดมุ่งหมายเพื่อความสวยงามของผู้สวมใส่ แต่มีความหมายตามชื่อ คือ พรางตัวไว้หลบการสังเกตการณ์จากศัตรูในยามสู้รบให้มองเห็นยากขึ้น ไม่โดดเด่นจนเกินไป การสู้รบในอดีต เช่น สงครามเวียดนามมักต่อสู้กันในบริเวณป่าเขา ซึ่งมีต้นไม้อยู่มาก เสื้อลายพรางของทหารในหลายประเทศจึงมักมีโทนสีเขียวเพื่อกลมกลืนกับสภาพแวดล้อม ถ้าเราสามารถพัฒนาการพรางความร้อนจากกล้องอินฟราเรดและนำไปใช้ในสงครามได้จริง ทหารจะสามารถพรางตัวจากการตรวจจับด้วยกล้องอินฟราเรดจากทหารฝ่ายศัตรูและจากอากาศยานบนฟ้า เช่น UAV ที่ใช้กล้องอินฟราเรดตรวจจับความร้อนบริเวณพื้นดินทหารที่มีเทคโนโลยีการพรางความร้อนจากกล้องอินฟราเรดจะได้เปรียบในการรบมาก (Chotsisuparat, 2020) จะเห็นได้ว่า ปัจจุบันการซ่อนพรางมีการพัฒนาที่มากขึ้น มีเทคโนโลยีการพรางความร้อน ระบบ Sensor เองจึงจำเป็นต้องพัฒนาในการตรวจจับโดยอาศัยเทคโนโลยีมีลติสเปกตรัมในการตรวจจับ

คลื่นรังสีที่ตกกระทบของวัตถุซ่อนพรางเพื่อประสิทธิภาพในการตรวจจับต่อไป การตรวจจับและติดตามเป้าหมายที่พรางตัวเป็นความท้าทายที่สำคัญในงานด้านวิทยาการคอมพิวเตอร์และเทคโนโลยีการตรวจจับ โดยเฉพาะในด้านความปลอดภัย การเฝ้าระวัง และการช่วยเหลือกู้ภัย เนื่องจากเป้าหมายที่พรางตัวมักมีลักษณะที่ผสมกลมกลืนกับสิ่งแวดล้อม ทำให้ระบบตรวจจับที่ใช้กล้องธรรมดาเพียงอย่างเดียวไม่สามารถแยกแยะได้อย่างชัดเจน การผสานข้อมูลจากหลายแหล่ง (multi-modal data fusion) จะช่วยปรับปรุงประสิทธิภาพของแบบจำลองภาพในงานต่าง ๆ เช่น การตรวจจับวัตถุ (Zhang et al., 2023) หนึ่งในวิธีที่มีประสิทธิภาพในการติดตามเป้าหมายที่พรางตัว คือ การใช้การผสานข้อมูลระหว่างกล้องถ่ายภาพความร้อน (thermal imaging camera หรือ Forward Looking Infrared: FLIR) และกล้องภาพสีจริง (RGB camera หรือ visible camera) ซึ่งทั้งสองประเภทมีข้อได้เปรียบที่ต่างกัน กล้องภาพสีจริงสามารถให้รายละเอียดที่ชัดเจนของสภาพแวดล้อมที่ปรากฏในสีส้น และรายละเอียดเชิงพื้นที่ ขณะที่กล้องถ่ายภาพความร้อนสามารถตรวจจับการแผ่รังสีความร้อน

ร้อนของวัตถุต่าง ๆ ทำให้สามารถตรวจจับวัตถุที่มีอุณหภูมิต่างจากพื้นหลังได้ (Bamrungthai & Wongkamchang, 2018) วัตถุที่มีอุณหภูมิใกล้เคียงกับพื้นหลังยากที่จะตรวจจับได้ด้วยภาพอินฟราเรดความร้อน และไม่สามารถตรวจจับผ่านกระจกได้ ดังนั้นในสถานการณ์ที่ท้าทาย เช่น เซอร์แบบใดแบบหนึ่งเพียงอย่างเดียว เช่น กล้องถ่ายภาพความร้อนหรือกล้องภาพสีจริง ไม่สามารถตอบสนองความต้องการได้ จึงจำเป็นต้องผสานข้อมูลจากทั้งสองแบบเพื่อสร้างระบบตรวจจับวัตถุเคลื่อนที่มีประสิทธิภาพและเชื่อถือได้ (Mangale & Khambete, 2016) การใช้การผสานข้อมูลหลายรูปแบบในการติดตามเป้าหมายโดยเฉพาะเป้าหมายที่พรางตัวเช่นงานของ Shen et al. (2021) ได้นำเสนอวิธีการตรวจจับเป้าหมายพรางตัวโดยใช้วิธี CEM นอกจากนี้ยังมีการฝึกโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ในการวิเคราะห์ภาพแต่ละภาพแยกกัน และค้นหารูปทรงเฉพาะที่ปรากฏ เพื่อตรวจจับและติดตามวัตถุในสถานะที่ซับซ้อน (Kowalski et al., 2021) ในสถานะการมองเห็นที่เชื่อถือได้ในสภาพแสงจำกัดเป็นสิ่งที่ท้าทาย โดยมีงานวิจัยที่เสนอวิธีการที่ใช้การเรียนรู้เชิงลึกสำหรับการรวมภาพที่ได้จากกล้องภาพสีจริง และภาพจากกล้องถ่ายภาพความร้อน โดยเน้นที่การสร้างภาพรวมที่มีความคล้ายคลึงกับภาพสีจริง (Red-Green-Blue: RGB) พร้อมทั้งเพิ่มรายละเอียดที่มีข้อมูลสำคัญในบริเวณเป้าหมาย คือ การสร้างภาพที่ดูเป็นธรรมชาติและเข้าใจง่าย ซึ่งให้ข้อมูลมากกว่ากล้อง RGB (Shopovska et al., 2019.) การผสานภาพ (fusion) ระหว่าง Thermal และ RGB เพื่อระบุและติดตามวัตถุที่พรางตัว อีกทั้งยังใช้ Deep Learning และ Correlation Filters เพื่อเพิ่มความแม่นยำของระบบในการตรวจจับการซ่อนพราง แต่ยังใช้เวลาประมวลผลที่นาน (Mangale & Khambete, 2016) ยิ่งไปกว่านั้น ในปัจจุบันระบบสามารถปรับให้เหมาะกับการปฏิบัติการทางทหาร โดยใช้ UAV เพื่อติดตามบุคคลที่ซ่อนตัวในป่า แต่ใช้พลังประมวลผลสูง มีข้อจำกัดด้านพลังงาน (Liu et al., 2023) อย่างไรก็ตาม การผสานข้อมูลจากกล้องภาพสีจริงและกล้องถ่ายภาพความร้อนสำหรับการติดตามเป้าหมายที่พรางตัวยังคงมีความท้าทาย เนื่องจากข้อมูลจากกล้องทั้งสองประเภทมีลักษณะข้อมูลที่ต่างกัน และต้องการการออกแบบอัลกอริทึมเฉพาะที่สามารถเรียนรู้คุณสมบัติจากข้อมูลที่หลากหลาย และผสานเข้าด้วยกันได้อย่างเหมาะสม

งานวิจัยนี้จึงมุ่งเน้นการติดตามเป้าหมายที่พรางตัว โดยใช้อัลกอริทึมการประมวลผลภาพ เพื่อวิเคราะห์ประสิทธิภาพของตัวติดตามเป้าหมาย โดยอาศัยการประมวลผลข้อมูลจากการผสานข้อมูลระหว่างกล้องถ่ายภาพความร้อน และกล้องภาพสีจริงเพื่อให้ระบบสามารถแยกแยะเป้าหมายจากพื้นหลังได้อย่างมีประสิทธิภาพ ลดการใช้พลังประมวลผลที่สูง เพิ่มประสิทธิภาพสำหรับการทำงานแบบเรียลไทม์เหมาะสำหรับการติดตั้งบน UAV ที่ต้องการติดตามบุคคลที่พรางตัว

วิธีดำเนินการวิจัย

การดำเนินงานของวิจัยนี้จะเริ่มตั้งแต่การศึกษางานวิจัยที่เกี่ยวข้องและรวบรวมทฤษฎีต่าง ๆ กำหนดขอบเขตการทำงาน ออกแบบการทดลองและทดสอบโปรแกรมการติดตามวัตถุ ซึ่งมีรายละเอียด ดังนี้

1. การออกแบบการทดลองการบินทดสอบติดตามเป้าหมาย

การบินทดสอบติดตามเป้าหมายนั้นมีขั้นตอนการบินดังภาพ 1 โดยประกอบไปด้วยหลายขั้นตอนที่สำคัญ ดังนี้ เริ่มจากอากาศยานไร้คนขับเริ่มบินขึ้น (take off) จากพื้นดินในลักษณะการบินแนวตั้ง ซึ่งเป็นขั้นตอนเริ่มต้นก่อนเข้าสู่การค้นหาและติดตามเป้าหมาย หลังจากขึ้นบินในระดับความสูงที่กำหนดเท่ากับ 30 เมตร อากาศยานไร้คนขับจะเข้าสู่การบินเคลื่อนที่ไปข้างหน้าเพื่อค้นหาพื้นที่เป้าหมาย โดยในขั้นตอนนี้จะทำการสำรวจบริเวณโดยรอบ เพื่อค้นหาเป้าหมายที่ต้องการติดตาม ซึ่งอาจเป็นบุคคลหรือวัตถุที่อยู่ในพื้นที่ซับซ้อน เช่น พื้นที่ป่าหรือสวน


เมื่อบินมาถึงพื้นที่ที่คาดว่าเป้าหมายอาจจะซ่อนอยู่ อากาศยานไร้คนขับจะเข้าสู่ขั้นตอนการค้นหาเป้าหมายอย่างละเอียด (search a target) โดยใช้กล้องทั้งกล้องภาพสีจริงและกล้องถ่ายภาพความร้อน เพื่อเพิ่มความแม่นยำในการตรวจจับเป้าหมาย การใช้กล้องถ่ายภาพความร้อนทำให้สามารถตรวจจับวัตถุที่มีความแตกต่างทางความร้อนจากพื้นหลังได้ง่ายขึ้น เมื่อพบเป้าหมายแล้วอากาศยานไร้คนขับจะทำการบินไปอยู่เหนือเป้าหมาย และติดตามเป้าหมาย (tracking the target) อย่างต่อเนื่อง โดยทำการ

บันทึกและส่งภาพวิดีโอแบบเรียลไทม์จากกล้องทั้ง 2 ชนิด ไปยังสถานีควบคุมภาคพื้นดิน (ground control station) เพื่อให้ผู้ควบคุมสามารถติดตามและวิเคราะห์ข้อมูลจากระยะไกลได้ ภาพที่ได้จากกล้องจะช่วยให้สามารถติดตามการเคลื่อนไหวของเป้าหมายได้อย่างแม่นยำ เมื่อเสร็จสิ้นภารกิจ อากาศยานไร้คนขับจะทำการบินกลับไปยังจุดลงจอดที่กำหนดไว้ และลดระดับลงเพื่อทำการลงจอด (landing) ซึ่งเป็นขั้นตอนสุดท้ายของภารกิจ


ในการทดลองมีการเตรียมสถานการณ์จำลองต่าง ๆ ประกอบด้วย เป้าหมายบุคคลที่ปรากฏตัวดังภาพ 2 (ก) เป็นบุคคลที่สวมผ้าคลุมตาข่ายพรางสีเขียวเพื่อให้กลมกลืนกับสภาพแวดล้อมภายนอก โดยเฉพาะในพื้นที่ที่มีต้นไม้ และพุ่มไม้ โดยกำหนดพื้นที่ทดสอบเป็นไร่มันสำปะหลังที่มีต้นมันสำปะหลังสูงประมาณ 1 เมตร ซึ่งทำให้ยากต่อการตรวจจับในภาพที่ถ่ายด้วยกล้อง RGB แต่สามารถตรวจจับได้ด้วยกล้องถ่ายภาพความร้อนเนื่องจากการแผ่รังสีความร้อนจากร่างกายมนุษย์ ภาพ 2 (ข) เป็นอากาศยานไร้คนขับที่ใช้ในการทดลอง เป็นแบบมัลติโรเตอร์ 4 ใบพัดที่ติดตั้งกล้อง และอุปกรณ์ต่าง ๆ สำหรับการติดตามวัตถุ โดยกล้องที่ติดตั้งนั้นแสดงดังภาพ 2 (ค) เป็นกล้องที่ประกอบด้วย กล้องถ่ายภาพความร้อน ใช้สำหรับตรวจจับการแผ่รังสีความร้อนจากเป้าหมายที่พรางตัว และกล้องภาพสีจริง ใช้สำหรับบันทึกภาพสีจริงของสภาพแวดล้อม ทำให้สามารถตรวจสอบรายละเอียดเชิงพื้นที่ได้อย่างชัดเจน โดยกล้องทั้ง 2 ประเภทนี้ได้เชื่อมต่อเข้ากับระบบส่งสัญญาณภาพ

เพื่อเชื่อมโยงสัญญาณภาพมายังสถานีควบคุมภาคพื้นดิน เพื่อทำการบันทึกและประมวลผลในเวลาจริง


การทดลองในงานวิจัยนี้มีกระบวนการประมวลผลภาพดังภาพ 3 ซึ่งแสดงกระบวนการผสานภาพ (image fusion) ระหว่างภาพ RGB และภาพ Thermal โดยเริ่มจากภาพ RGB และภาพ Thermal ที่ถ่ายจากกล้องที่แตกต่างกัน ภาพ RGB แสดงรายละเอียดที่มองเห็นด้วยตาเปล่า เช่น ลักษณะของต้นไม้และพื้นผิว ส่วนภาพ Thermal แสดงการกระจายของความร้อนในพื้นที่ ซึ่งแสดงเป็นภาพสีโทนเทาเพื่อบอกความแตกต่างของอุณหภูมิในชั้นแรก ภาพ RGB จะถูกปรับขนาด (resize) ให้เท่ากับภาพ Thermal เพื่อให้ทั้งสองภาพมีขนาดสอดคล้องกัน จากนั้นจึงเข้าสู่กระบวนการจัดตำแหน่ง (image alignment) เพื่อให้ตำแหน่งของวัตถุในภาพ RGB และ Thermal ตรงกัน การจัดตำแหน่งนี้มีความสำคัญเนื่องจากหากภาพไม่ตรงกัน การผสานภาพจะไม่แม่นยำและอาจทำให้ข้อมูลสำคัญสูญหายเมื่อจัดตำแหน่งเสร็จสิ้น ภาพ RGB และ Thermal จะถูกผสานเข้าด้วยกันในขั้นตอนการผสานภาพ (image fusion) โดยข้อมูลจากทั้งสองภาพจะถูกรวมเข้าด้วยกัน ทำให้ภาพผลลัพธ์มีทั้งคุณสมบัติของสีจากภาพ RGB และข้อมูลความร้อนจากภาพ Thermal ภาพที่ได้จากการผสานนี้แสดงเป็นภาพ Fused Image ที่มีการเน้นพื้นที่ที่มีอุณหภูมิแตกต่างออกอย่างชัดเจน ทำให้เราสามารถเห็นข้อมูลที่มีรายละเอียดจากทั้งสองภาพในภาพเดียว เช่น วัตถุที่มีความแตกต่างของอุณหภูมิซึ่งอาจถูกแสดงด้วยสีเฉพาะ เช่น สีชมพู เป็นต้น



ภาพ 1 แผนการบินทดสอบการตรวจจับและติดตามบุคคลที่ซ่อนพราง



ภาพ 2 (ก) บุคคลที่ซ่อนพราง (ข) อากาศยานไร้คนขับแบบมัลติโรเตอร์ 4 ใบพัดที่ใช้ในการทดลอง (ค) กล้องที่ประกอบด้วยกล้องถ่ายภาพความร้อนและกล้องภาพสีจริง



ภาพ 3 แผนภาพการผสานภาพระหว่างภาพ RGB และภาพ Thermal

2. การพัฒนาโปรแกรมติดตามเป้าหมายอัตโนมัติ
ในปัจจุบันการพัฒนาโปรแกรมติดตามเป้าหมายอัตโนมัตินั้นมีการพัฒนาอย่างต่อเนื่องโดย Zhang et al. (2021) ได้สรุปผลงานวิจัยเกี่ยวกับการติดตามวัตถุเดี่ยวโดยอัลกอริทึมการติดตามวัตถุถูกแบ่งเป็นสองประเภทหลัก คือ วิธีการโดยใช้ Correlation Filters ตัวอย่างเช่น MOSSE KCF DSST และ ECO ซึ่งใช้ตัวกรองที่คำนวณความคล้ายคลึงกันในโดเมนความถี่ ช่วยให้ทำงานได้รวดเร็วแต่มีปัญหาเกี่ยวกับการเปลี่ยนแปลงที่ซับซ้อนของวัตถุ และวิธีการ Deep Learning-based Trackers เช่น SiamFC MDNet และ SiamRPN ที่ใช้ CNN หรือโครงข่ายประสาทเทียมแบบย้อนกลับ (RNN) เพื่อเพิ่มความทนทานต่อการเปลี่ยนแปลงของวัตถุและสภาพแวดล้อม อย่างไรก็ตาม โครงข่ายเหล่านี้ต้องใช้พลังประมวลผลสูง จึงมีข้อจำกัดสำหรับการทำงานแบบเรียลไทม์

ในงานวิจัยนี้เลือกใช้งานตัวติดตามเป้าหมายอัตโนมัติประเภท Correlation Filters เนื่องจากจะต้องพัฒนาระบบให้สามารถติดตั้งกับอากาศยานไร้คนขับได้ ซึ่งอุปกรณ์จะต้องมีขนาดเล็กและมีน้ำหนักเบา จึงได้เลือกใช้อุปกรณ์ประมวลผลเป็น Raspberry Pi 4B ที่มี RAM ขนาด 8 Gb ติดตั้งโปรแกรม Python และ OpenCV Library version 4.1.1 โดยอัลกอริทึมที่เลือกใช้แบบ Correlation Filters จำนวน 4 แบบ โดยทดสอบทีละอัลกอริทึมโดยมีการเรียงลำดับ ดังภาพ 4 ดังนี้ คือ Kernelized Correlation Filters: KCF (Henriques et al., 2015) ซึ่งเป็นหนึ่งในอัลกอริทึมที่ใช้สำหรับการติดตามวัตถุที่ได้รับความนิยมในปัจจุบัน โดยถูกพัฒนาให้สามารถทำงานได้อย่างรวดเร็วและแม่นยำในการติดตามวัตถุในวิดีโอ ซึ่งเกิดจากการนำ Correlation Filter มาปรับปรุงให้มีประสิทธิภาพมาก

ขึ้นผ่านการใช้ Kernel Trick หรือการเปลี่ยนข้อมูลไปยัง Kernel Space เพื่อช่วยในการประมวลผลลักษณะของวัตถุในลักษณะที่ไม่ใช่เชิงเส้น ทำให้สามารถติดตามวัตถุได้แม้จะมีการเปลี่ยนแปลงสภาพแวดล้อม เช่น แสงหรือรูปร่างของวัตถุ โดยใช้การคำนวณ Cross-Correlation ระหว่างภาพที่มีวัตถุ (target) กับตัวกรองที่ผ่านการฝึกฝนมาในเฟรมก่อนหน้า ผ่าน Fast Fourier Transform: FFT ซึ่งช่วยลดเวลาในการคำนวณ และทำให้เหมาะสำหรับการใช้งานในแบบเรียลไทม์

Bolme et al. (2010) Minimum Output Sum of Squared Error Filter: MOSSE Filter เป็นอัลกอริทึมที่ใช้ Correlation Filter เพื่อติดตามวัตถุ โดย MOSSE ใช้วิธีการสร้างตัวกรองที่สามารถเรียนรู้จากภาพต้นฉบับและลดความแตกต่างระหว่างภาพที่ติดตามและภาพที่ต้องการติดตามอย่างรวดเร็ว ข้อดี MOSSE มีความเร็วในการประมวลผลสูง สามารถใช้ติดตามวัตถุในแบบเรียลไทม์ได้ดี ข้อจำกัด MOSSE Filter อาจไม่สามารถรับมือกับการเปลี่ยนแปลงของรูปร่างวัตถุที่ซับซ้อนได้ดีเมื่อเทียบกับอัลกอริทึมที่ซับซ้อนกว่า

Grabner and Bischof (2006) Boosting-based Trackers เป็นวิธีการใช้ข้อมูลที่ถูกรวบรวมมาสร้างตัวกรองที่ทำให้สามารถติดตามวัตถุในเฟรมต่อเนื่องได้ อัลกอริทึมประเภทนี้จะใช้วิธีการเรียนรู้แบบอิงกับตัวอย่างบวกและลบ (positive and negative samples) ของวัตถุที่ต้องการติดตาม เช่น Online Boosting และ AdaBoost ที่สามารถเรียนรู้ลักษณะของวัตถุขณะติดตามไปพร้อม ๆ กับการทำงานข้อดี Boosting-based Trackers คือ มีความสามารถในการปรับปรุงตัวกรองให้เหมาะสมกับการเปลี่ยนแปลงของวัตถุและสภาพแวดล้อม ส่วนข้อจำกัดของ Boosting-based Trackers อาจมีปัญหาในการติดตามวัตถุเมื่อมีการเปลี่ยนแปลงอย่างรวดเร็ว และลักษณะของวัตถุที่มีการเปลี่ยนแปลงมากเกินไป

Lukezic et al. (2018) Discriminative Correlation Filter with Channel and Spatial Reliability: CSR-DCF เป็นอัลกอริทึมการติดตามวัตถุที่พัฒนาต่อยอดจาก

Discriminative Correlation Filter: DCF โดยเพิ่มแนวคิดของความน่าเชื่อถือในมิติของช่องสัญญาณ (channel reliability) และในมิติของพื้นที่ (spatial reliability) เพื่อปรับปรุงความแม่นยำและความทนทานในการติดตามวัตถุในสภาวะแวดล้อมที่มีการเปลี่ยนแปลงข้อดีของ CSR-DCF คือ มีความแม่นยำในการติดตามสูง ด้วยการประเมินความน่าเชื่อถือในมิติของช่องสัญญาณและพื้นที่ ทำให้ CSR-DCF มีความสามารถในการติดตามวัตถุที่แม่นยำมากยิ่งขึ้น มีความทนทานในสภาพแวดล้อมที่ซับซ้อน CSR-DCF สามารถติดตามวัตถุในสถานการณ์ที่พื้นหลังซับซ้อนหรือมีการเปลี่ยนแปลงสูงได้ดี เนื่องจากสามารถโฟกัสไปยังพื้นที่ที่เกี่ยวข้องกับวัตถุจริง ๆ ถึงแม้ CSR-DCF จะเพิ่มกระบวนการประเมินความน่าเชื่อถือซึ่งใช้เวลาในการประมวลผลมากขึ้น แต่ก็ยังสามารถทำงานได้อย่างรวดเร็วเพียงพอสำหรับการติดตามวัตถุในแบบเรียลไทม์ได้ดีเช่นกัน

3 การวัดประสิทธิภาพการติดตามเป้าหมายแบบอัตโนมัติ

ในการประเมินประสิทธิภาพของอัลกอริทึมการติดตามวัตถุ มีการใช้ตัวชี้วัดหลายประเภทเพื่อวิเคราะห์ความแม่นยำและความสม่ำเสมอของการติดตามวัตถุ ซึ่งตัวชี้วัดที่สำคัญที่นำมาใช้ในงานวิจัยมี ดังนี้

3.1 Mean Center Location Error: mCLE หรือ Average Euclidean Distance ใช้สำหรับวัดความคลาดเคลื่อนของตำแหน่งศูนย์กลางระหว่างกรอบที่ติดตามได้จากอัลกอริทึมและตำแหน่งจริงของวัตถุในภาพ (ground truth) (Wu et al., 2013) โดยการคำนวณค่าเฉลี่ยของระยะห่างนี้ ซึ่งช่วยแสดงถึงความแม่นยำเชิงตำแหน่งของการติดตามได้อย่างเป็นระบบ

$$mCLE = \frac{1}{N} \sum_{i=1}^N \|C_{tracked,i} - C_{groundtruth,i}\| \quad (1)$$

โดยที่ N คือ จำนวนเฟรมทั้งหมด และ $C_{tracked,i}$ กับ $C_{groundtruth,i}$ คือ จุดศูนย์กลางของกรอบการติดตามและ ground truth ตามลำดับ

3.2 Christen et al. (2023) Mean F-Measure:

mFe ใช้ในการวัดประสิทธิภาพโดยรวมของการติดตาม ซึ่งคำนวณจาก Precision และ Recall โดย mFe แสดงถึงความสามารถในการตรวจจับและติดตามวัตถุได้อย่างแม่นยำและครอบคลุม สมการของ F-Measure

$$F - Measure = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2)$$

โดยที่ Precision ใช้วัดอัตราความถูกต้องของกรอบการติดตาม และ Recall สำหรับวัดความครอบคลุมของการติดตามวัตถุในทุกเฟรม ค่า mFe จะแสดงถึงความสามารถในการตรวจจับและติดตามวัตถุอย่างแม่นยำและครอบคลุม

3.3 Asha and Narasimhadhan (2016) Distance

Precision: DP Score เป็นตัววัดอัตราส่วนของเฟรมที่มีระยะห่างระหว่างจุดศูนย์กลางของกรอบการติดตามและ Ground Truth น้อยกว่าหรือเท่ากับ threshold ที่กำหนด เช่น 20 พิกเซล ซึ่งเป็นตัวชี้วัดที่เน้นด้านความแม่นยำในเชิงระยะทาง

$$DP = \frac{1}{N} \sum_{i=1}^N \delta(\|C_{tracked,i} - C_{groundtruth}\| \leq \tau) \quad (3)$$

โดยที่ $\delta(\cdot)$ เป็นฟังก์ชันอินดิเคเตอร์ ซึ่งมีค่าเป็น 1 เมื่อเงื่อนไขเป็นจริง และมีค่าเป็น 0 เมื่อเงื่อนไขเป็นเท็จ

τ คือ ค่า threshold ของระยะห่างที่ยอมรับได้ กำหนดในหน่วยพิกเซล

3.4 Asha and Narasimhadhan (2016)

Overlap Precision: OP เป็นตัวชี้วัดที่วัดอัตราส่วนของเฟรมที่มีค่า IoU ระหว่างกรอบการติดตาม และ ground truth สูงกว่า threshold ที่กำหนด ใช้สำหรับแสดงถึงประสิทธิภาพของอัลกอริทึมในการซ้อนทับกับวัตถุจริงได้อย่างแม่นยำ คำนวณจากสมการ

$$OP = \frac{1}{N} \sum_{i=1}^N \delta(IoU_i \geq \theta) \quad (4)$$

โดยที่ θ คือ threshold ของค่า IoU ที่ยอมรับได้

ค่า IoU คำนวณจากสมการ

$$IoU = \frac{AreaofOverlap}{AreaofUnion} \quad (5)$$


3.5 Wu et al. (2013) Area Under the Curve:

AUC Score หรือ AUC Score เป็นการคำนวณพื้นที่ใต้กราฟ Success Rate Plot ซึ่งแสดงถึงประสิทธิภาพโดยรวมของตัวติดตามในแง่ความสม่ำเสมอ และความแม่นยำในระดับ IoU ที่แตกต่างกัน AUC Score ใช้เพื่อวัดความแม่นยำของการซ้อนทับ โดยการคำนวณสามารถประมาณได้ด้วยการหาพื้นที่ใต้กราฟของ Success Rate ในช่วง θ ตั้งแต่ 0 ถึง 1 ดังนี้

$$AUCScore = \int_0^1 S(\theta) d\theta \quad (6)$$

โดยที่ $S(\theta)$ คือ Success Rate ที่ค่า IoU threshold θ

นอกจากนี้การใช้กราฟ Precision Plot: PP และ Success Rate Plot: SP ช่วยให้เห็นภาพรวมของประสิทธิภาพ ความสามารถ และความทนทานของอัลกอริทึมการติดตามวัตถุ (Wu et al, 2013) โดย Precision Plot ใช้ในการประเมินความแม่นยำตามระยะห่างระหว่างการติดตาม และ ground truth ส่วน Success Rate Plot ใช้ค่า IoU เป็นเกณฑ์ ซึ่งช่วยให้นักวิจัยเห็นภาพรวมของความแม่นยำและความสม่ำเสมอในมิติของการซ้อนทับ



ภาพ 4 แผนภาพแสดงการออกแบบโปรแกรมทดสอบคำนวณค่าประสิทธิภาพ

ผลการวิจัย


การบันทึกทดสอบโปรแกรมติดตามเป้าหมายอัตโนมัติจากอากาศยานไร้คนขับ แสดงผลการทดสอบโปรแกรมดังภาพ 5 ซึ่งจะเห็นได้ว่าภาพจากกล้อง Thermal ในภาพ 5 (ก) แสดงค่าความร้อนของวัตถุในฉากที่จับภาพได้ กล้องชนิดนี้ช่วยในการตรวจจับวัตถุที่ซ่อนตัวหรือพรางตัวในสภาพแวดล้อมที่แสงปกติไม่สามารถมองเห็นได้เมื่อเปรียบเทียบกับภาพ 5 (ข) ที่เป็นภาพจากกล้อง RGB ซึ่งแสดงข้อมูลสีตามที่ตามนุษย์มองเห็นได้ โดยกล้องชนิดนี้เหมาะสำหรับการตรวจจับรายละเอียดของพื้นผิวและโครงสร้างในสภาพแสงปกติ อย่างไรก็ตามการตรวจจับบุคคลที่ซ่อนพรางในสภาพแวดล้อมนี้อาจยังไม่ชัดเจนมากนัก เมื่อนำภาพทั้ง 2 ชนิดมาประสาน (fusion) กันจะได้ผลลัพธ์ดังแสดงในภาพ 5 (ค) โดยจะเห็นว่า มีการรวมจุดเด่นของทั้งสองแหล่งข้อมูลเข้าด้วยกัน และภาพ 5 (ง) เป็นผลลัพธ์จากโปรแกรมติดตามเป้าหมายอัตโนมัติที่ใช้ข้อมูลจากภาพฟิวชัน (fused image) ในการติดตามบุคคลที่ซ่อนพราง ระบบสามารถตรวจจับเป้าหมายได้อย่างแม่นยำและทำการติดตามเป้าหมายอย่างต่อเนื่อง โดยในภาพนี้มีการแสดงกรอบสี่เหลี่ยมรอบเป้าหมายและข้อความแสดง

สถานะ Tracking เพื่อระบุว่าโปรแกรมกำลังติดตามเป้าหมายในภาพได้สำเร็จ และแสดงอัตราเฟรม (frame rate) เพื่อแสดงความเร็วของการประมวลผล

ผลการทดสอบประสิทธิภาพของโปรแกรมติดตามเป้าหมายทั้ง 4 ประเภท คือ CSR-DCF Boosting KCF และMOSSE โดยทำการทดสอบประเภทละจำนวน 5 ครั้ง แสดงในตาราง 1 ถึง ตาราง 4 โดยในตาราง 5 จะแสดงค่าเฉลี่ยของตัวติดตามวัตถุทั้ง 4 ประเภท ที่สามารถสรุปประสิทธิภาพของตัวติดตามแต่ละตัว พร้อมด้วยตัวเลขที่เกี่ยวข้องดังนี้ ค่า Mean Center Location Error: mCLE เป็นตัววัดที่แสดงระยะห่างเฉลี่ยระหว่างตำแหน่งที่ตัวติดตามวัตถุคาดการณ์ และตำแหน่งจริงของวัตถุค่า mCLE ที่ต่ำกว่าแสดงว่าตัวติดตามสามารถระบุตำแหน่งได้ใกล้เคียงตำแหน่งจริงมากขึ้น จากผลการทดลองพบว่า Boosting มีค่า mCLE ต่ำที่สุดที่ 43.46 ซึ่งแสดงถึงความแม่นยำเชิงตำแหน่งสูงสุด ขณะที่ KCF มีค่า mCLE สูงสุดที่ 267.35 ซึ่งหมายถึง KCF มีความคลาดเคลื่อนสูง และความแม่นยำน้อยกว่าตัวติดตามอื่น ๆ ในด้าน Distance Precision: DP ซึ่งเป็นตัววัดอัตราส่วนของเฟรมที่ตำแหน่งที่ติดตามอยู่ภายในระยะที่กำหนดจากตำแหน่งจริง ค่า

DP ที่สูงกว่าสะท้อนถึงความแม่นยำที่ดีขึ้นในการติดตามวัตถุใกล้ตำแหน่งจริง จากผลการทดลอง Boosting มีค่า DP สูงสุดที่ 0.1085 ซึ่งหมายถึงความสามารถในการติดตามวัตถุในระยะใกล้ตำแหน่งจริงได้ดีกว่า ในขณะที่ KCF มีค่า DP ต่ำสุดที่ 0.0883 แสดงถึงความแม่นยำในการติดตามในระยะใกล้ที่ด้อยกว่าตัวติดตามอื่น ๆ ส่วนค่า Overlap Precision: OP เป็นตัววัดอัตราส่วนของเฟรมที่ตัวติดตามวัตถุสามารถครอบคลุมตำแหน่งจริงของวัตถุได้อย่างแม่นยำ โดยคำนวณจากค่า IoU: Intersection over Union ระหว่างกรอบติดตามและกรอบจริง ค่า OP ที่สูงหมายถึงความสามารถในการครอบคลุมวัตถุที่ดีขึ้นจากผลการทดลอง Boosting มีค่า OP สูงสุดที่ 0.0651 ซึ่งแสดงถึงความสามารถในการครอบคลุมตำแหน่งจริงของวัตถุได้ดีที่สุด ส่วน KCF มีค่า OP ต่ำสุดที่ 0.0507 แสดงถึงความแม่นยำในการครอบคลุมวัตถุที่ต่ำกว่าตัวติดตามอื่น ค่า AUC Score เป็นตัวชี้วัดที่แสดงถึงความสม่ำเสมอ

ของประสิทธิภาพในการติดตามวัตถุ โดยพิจารณาค่า IoU หลายระดับ ค่า AUC Score ที่สูงแสดงถึงความสามารถในการติดตามที่เสถียรและแม่นยำโดยรวม ผลการทดลองพบว่า Boosting มีค่า AUC Score สูงสุดที่ 0.154 ซึ่งบ่งชี้ว่ามีความสม่ำเสมอในการติดตามที่ดีกว่าตัวติดตามอื่น ๆ ขณะที่ KCF มีค่า AUC ต่ำสุดที่ 0.0923 แสดงถึงความสม่ำเสมอในการติดตามที่ต่ำที่สุด และค่า Mean F-Measure (mFe) เป็นการรวมค่าระหว่าง precision และ recall เพื่อประเมินความแม่นยำในการตรวจจับและติดตามวัตถุค่า mFe ที่สูงบ่งชี้ว่าตัวติดตามสามารถตรวจจับและติดตามวัตถุได้อย่างครอบคลุมและแม่นยำ ในการทดลองนี้ Boosting มีค่า mFe สูงสุดที่ 0.1202 แสดงถึงความสามารถในการติดตามที่ครอบคลุมและแม่นยำที่สุดในขณะที่ KCF มีค่า mFe ต่ำสุดที่ 0.0892 แสดงว่าความสามารถในการติดตามโดยรวมต่ำกว่าตัวติดตามอื่น ๆ



(ก)



(ข)



(ค)



(ง)

ภาพ 5 โปรแกรมการติดตามบุคคลที่ซ่อนพรางแบบอัตโนมัติ (ก) แสดงค่าความร้อนของวัตถุในฉากที่จับภาพได้ (ข) ภาพจากกล้อง RGB ซึ่งแสดงข้อมูลสีตามที่ตามนุษย์มองเห็นได้ (ค) เมื่อนำภาพจากกล้อง Thermal และกล้อง RGB มาประสาน (fusion) (ง) ผลลัพธ์จากโปรแกรมติดตามเป้าหมายอัตโนมัติที่ใช้ข้อมูลจากภาพฟิวชัน (fused image)

ตาราง 1

ผลการทดสอบประสิทธิภาพของ CSR-DCF

CSR-DCF	Mean Center Location Error (mCLE)	Distance Precision (DP)	Overlap Precision (OP)	AUC Score	Mean F-Measure (mFe)
ครั้งที่ 1	44.5127	0.0812	0.0487	0.1274	0.0984
ครั้งที่ 2	46.3800	0.0957	0.0621	0.1368	0.1127
ครั้งที่ 3	45.8459	0.0894	0.0579	0.1342	0.1073
ครั้งที่ 4	43.7659	0.0983	0.0635	0.1395	0.1152
ครั้งที่ 5	45.5102	0.0984	0.0643	0.1416	0.1144

ตาราง 2

ผลการทดสอบประสิทธิภาพของ Boosting

Boosting	Mean Center Location Error (mCLE)	Distance Precision (DP)	Overlap Precision (OP)	AUC Score	Mean F-Measure (mFe)
ครั้งที่ 1	43.2110	0.0974	0.0543	0.1425	0.1098
ครั้งที่ 2	43.5795	0.1103	0.0684	0.1563	0.1224
ครั้งที่ 3	43.3420	0.1068	0.0627	0.1508	0.1187
ครั้งที่ 4	43.6783	0.1135	0.0698	0.1594	0.1251
ครั้งที่ 5	43.5130	0.1145	0.0703	0.1605	0.1250

ตาราง 3

ผลการทดสอบประสิทธิภาพของ KCF

KCF	Mean Center Location Error (mCLE)	Distance Precision (DP)	Overlap Precision (OP)	AUC Score	Mean F-Measure (mFe)
ครั้งที่ 1	266.1254	0.0798	0.0419	0.0835	0.0807
ครั้งที่ 2	267.8763	0.0912	0.0523	0.0948	0.0916
ครั้งที่ 3	267.3421	0.0874	0.0498	0.0913	0.0875
ครั้งที่ 4	266.9876	0.0905	0.0537	0.0961	0.0934
ครั้งที่ 5	268.4276	0.0926	0.0553	0.0953	0.0928

ตาราง 4


ผลการทดสอบประสิทธิภาพของ MOSSE

MOSSE	Mean Center Location Error (mCLE)	Distance Precision (DP)	Overlap Precision (OP)	AUC Score	Mean F-Measure (mFe)
ครั้งที่ 1	48.7660	0.0897	0.0518	0.1352	0.1046
ครั้งที่ 2	49.2379	0.1023	0.0654	0.1489	0.1184
ครั้งที่ 3	48.8762	0.0978	0.0609	0.1443	0.1137
ครั้งที่ 4	49.2580	0.1035	0.0667	0.1507	0.1198
ครั้งที่ 5	48.8553	0.1057	0.0662	0.1534	0.1200


ตาราง 5

ค่าเฉลี่ยของผลการทดสอบประสิทธิภาพของ Tracking Algorithm

Tracking Algorithm	Mean Center Location Error (mCLE)	Distance Precision (DP)	Overlap Precision (OP)	AUC Score	Mean F-Measure (mFe)
CSR-DCF	45.2029	0.0926	0.0593	0.1359	0.1096
Boosting	43.4648	0.1085	0.0651	0.1539	0.1202
KCF	267.3518	0.0883	0.0506	0.0922	0.0892
MOSSE	48.9987	0.0998	0.0622	0.1465	0.1153



(ก)



(ข)

ภาพ 6 (ก) กราฟเปรียบเทียบค่า Success Rate: SR (ข) กราฟเปรียบเทียบค่า Precision Plot: PP

จากกราฟ Success Rate Plot ในภาพ 6(ก) แสดงถึงอัตราความสำเร็จของการติดตามวัตถุเมื่อเปรียบเทียบกับระนาบที่ติดตามกับกรอบจริง (IoU) โดยมีแกน x เป็น IoU Threshold และแกน y เป็น Success Rate ซึ่งแสดงอัตราส่วนของเฟรมที่การติดตามมีค่า IoU สูงกว่าค่า threshold ที่กำหนด จากกราฟจะเห็นได้ว่า ตัวติดตามแบบ Boosting และ CSR-DCF มีค่า Success Rate สูงสุดในช่วงค่า IoU ต่ำ แสดงถึงความแม่นยำในการติดตามในช่วงต้นได้ดี แต่ค่า Success Rate จะลดลงเมื่อค่า IoU Threshold สูงขึ้น ส่วนตัวติดตามแบบ MOSSE มีค่า Success Rate ใกล้เคียงกับ Boosting และ CSR-DCF ในช่วงต้น แต่ลดลงเร็วกว่าเล็กน้อยเมื่อค่า IoU สูงขึ้น ในขณะที่ตัวติดตามแบบ KCF มีค่า Success Rate ต่ำสุดในทุกช่วงของ IoU Threshold แสดงถึงข้อจำกัดในการติดตามวัตถุอย่างแม่นยำเมื่อเทียบกับตัวติดตามอื่น ๆ โดยสรุปจะเห็นว่าตัวติดตามแบบ Boosting และ CSR-DCF มีความแม่นยำในการติดตามวัตถุสูงสุดในช่วงค่า IoU ต่ำ ขณะที่ KCF มีประสิทธิภาพต่ำสุดตลอดช่วงค่า IoU ทั้งหมด

จากกราฟ Precision Plot: PP ดังแสดงในภาพ 6(ข) จะเห็นว่าตัวติดตามวัตถุ 4 ประเภท ได้แก่ Boosting CSR-DCF KCF และ MOSSE โดยมีแกน x เป็น Distance Threshold (pixels) ซึ่งแสดงถึงระยะห่างระหว่างตำแหน่งที่ติดตามกับตำแหน่งจริงในหน่วยพิกเซล และแกน y เป็นค่า Precision ซึ่งแสดงอัตราส่วนของเฟรมที่ตำแหน่งที่ติดตามอยู่ภายในระยะห่างที่กำหนดจากตำแหน่งจริง จากกราฟจะเห็นได้ว่า ตัวติดตามแบบ Boosting มีค่า Precision สูงสุดเมื่อเปรียบเทียบกับตัวติดตามอื่น ๆ ตลอดช่วงของ Distance Threshold โดยเฉพาะอย่างยิ่งในช่วง 30-50 พิกเซลแสดงให้เห็นว่า Boosting มีความแม่นยำในการติดตามวัตถุในระยะใกล้ตำแหน่งจริงได้ดี ในขณะที่ตัวติดตามแบบ CSR-DCF มีค่า Precision ใกล้เคียงกับ Boosting โดยเฉพาะในช่วง 20-40 พิกเซล แต่ในระยะทางที่มากกว่า 40 พิกเซล ตัวติดตามแบบ Boosting ยังคงมีประสิทธิภาพสูงกว่าเล็กน้อย และตัวติดตามแบบ MOSSE มีประสิทธิภาพที่ดีในช่วงต้น โดยมีค่า Precision ใกล้เคียงกับ CSR-DCF และ Boosting แต่เริ่มมีค่าต่ำกว่าเล็กน้อยในตำแหน่งที่ระยะห่างสูงสุด ส่วนตัวติดตามแบบ KCF มีค่า Precision ต่ำสุดในทุกช่วงของ Distance Threshold

ซึ่งบ่งชี้ถึงข้อจำกัดของ KCF ในการติดตามวัตถุอย่างแม่นยำในระยะใกล้ตำแหน่งจริง

สรุปและอภิปรายผลการวิจัย

การทดลองนี้เปรียบเทียบประสิทธิภาพของตัวติดตาม 4 ชนิด คือ Boosting CSR-DCF KCF และ MOSSE โดยพิจารณาตัวชี้วัดหลายประเภท และเทียบกับงานวิจัยที่เกี่ยวข้อง คือค่า Mean Center Location Error: mCLE พบว่า ตัวติดตามแบบ KCF มีประสิทธิภาพในการติดตามในสภาพแวดล้อมไม่ซับซ้อน แต่การทดลองนี้แสดงให้เห็นว่า KCF มีค่า mCLE สูง (267.35) ซึ่งแสดงถึงความแม่นยำต่ำ ขณะที่ตัวติดตามแบบ Boosting มีค่า mCLE ต่ำสุดที่ 43.46 ซึ่งสอดคล้องกับการวิจัยของ Grabner et al. (2008) ที่ระบุว่า Boosting เหมาะกับการติดตามวัตถุที่เคลื่อนไหว สำหรับค่า Distance Precision: DP จากผลการทดลองชี้ว่า Boosting มีค่า DP สูงสุด (0.1085) ซึ่งบ่งบอกถึงความแม่นยำในการติดตามระยะใกล้ตำแหน่งจริง ขณะที่ KCF มีค่า DP ต่ำ (0.0883) ซึ่งสอดคล้องกับการวิจัยของ Kalal et al. (2012) ที่พบว่า KCF มีข้อจำกัดในการติดตามวัตถุที่มีการเคลื่อนไหวที่ซับซ้อน สำหรับค่า Overlap Precision: OP ตัวติดตามแบบ CSR-DCF มีค่า OP สูงกว่า KCF เล็กน้อย (0.0593 เทียบกับ 0.0507) อย่างไรก็ตาม Boosting มีค่า OP สูงสุด (0.0651) แสดงถึงความแม่นยำที่ดีกว่าในกรณีวัตถุถูกบดบังบางส่วน และจากการศึกษา Kristan และคณะ, 2015 พบว่า MOSSE มีความเสถียรแต่ใช้ในสภาพแวดล้อมซับซ้อนได้ไม่ดีนัก ซึ่งจากการทดลองนี้ MOSSE มีค่า AUC Score ปานกลาง (0.1465) ในขณะที่ Boosting มีค่า AUC Score สูงสุด (0.154) ซึ่งสะท้อนความสม่ำเสมอในการติดตามเป้าหมายของ Boosting และจากงานวิจัยของ Christen et al. (2023) แสดงถึงความสำคัญของ F-Measure ในการประเมินการติดตามเป้าหมาย ผลการทดลองนี้พบว่า Boosting มีค่า mFe สูงสุด (0.1202) ซึ่งบ่งบอกถึงความครอบคลุมเป้าหมายและความแม่นยำสูงสุด ขณะที่ KCF มีค่า mFe ต่ำสุด (0.0892) แสดงถึงข้อจำกัดในการรักษาความแม่นยำเมื่อวัตถุหรือสภาพแวดล้อมมีความซับซ้อน

ผลการทดลองชี้ให้เห็นว่าตัวติดตามวัตถุ Boosting มีประสิทธิภาพในการติดตามวัตถุที่ดีกว่าตัวติดตามอื่น ๆ ในหลายตัวชี้วัด แสดงถึงความสามารถในการติดตามวัตถุที่แม่นยำ สมำเสมอ และมีความครอบคลุมสูง โดยได้ค่า mCLE เท่ากับ 43.46 DP เท่ากับ 0.1085 OP เท่ากับ 0.0651 AUC Score เท่ากับ 0.154 และ mFe เท่ากับ 0.1202 ส่วน CSR-DCF และ MOSSE มีประสิทธิภาพใกล้เคียงกันแต่ยังด้อยกว่า Boosting เล็กน้อย โดยที่ CSR-DCF มีค่า mCLE เท่ากับ 45.20 DP เท่ากับ 0.0926 OP เท่ากับ 0.0593 AUC Score เท่ากับ 0.136 และ mFe เท่ากับ 0.1096 ขณะที่ MOSSE มีค่า mCLE เท่ากับ 48.99 DP เท่ากับ 0.0999 OP เท่ากับ 0.0622 AUC Score เท่ากับ 0.1465 และ mFe เท่ากับ 0.1153 ในทางกลับกัน KCF มีผลการทดลองที่ต่ำที่สุดในหลายตัวชี้วัด ซึ่งบ่งชี้ถึงความแม่นยำและความเสถียรในการติดตามวัตถุที่ต่ำกว่าตัวติดตามอื่น ๆ โดยได้ค่า mCLE เท่ากับ 267.35 DP เท่ากับ 0.0883 OP เท่ากับ 0.0507 AUC Score เท่ากับ 0.0923 และ mFe เท่ากับ 0.0892

โดยสรุปงานวิจัยนี้แสดงให้เห็นว่า อัลกอริทึมประเภท Correlation Filters ที่ใช้มีความสามารถตรวจจับในสภาพแวดล้อมที่ซับซ้อนได้ เหมาะสำหรับ UAV Platform ที่ต้องการติดตามบุคคลที่พรางตัว ที่สามารถทำงานแบบ Real-time ได้ดี จากการบินทดสอบในพื้นที่จริง ซึ่งแตกต่างจากงานวิจัยก่อนหน้านี้ที่ใช้ข้อมูล Dataset OTB-2013

OTB-2015 VOT Challenge Dataset และ KAIST Multispectral Pedestrian Dataset เป็นต้น ในการพัฒนาในอนาคตการผสาน Correlation Filter: CF กับ Deep Learning จะยังคงเป็นแนวทางที่มีศักยภาพในการเพิ่มความแม่นยำของระบบติดตามวัตถุ โดยเฉพาะอย่างยิ่งในสถานการณ์ที่เป้าหมายมีการพรางตัวหรือสภาพแวดล้อมมีการเปลี่ยนแปลงอย่างต่อเนื่อง แนวทางที่สามารถพัฒนาเพิ่มเติม ซึ่งการพัฒนาปัญญาประดิษฐ์ (AI) ร่วมกับ Correlation Filter: CF สามารถยกระดับความแม่นยำในการติดตามวัตถุที่มีการพรางตัวได้โดยอาศัย Deep Learning เป็นเครื่องมือสนับสนุน โดยสามารถประยุกต์ใช้แนวทางต่าง ๆ เช่น การใช้ Convolutional Neural Networks: CNNs หรือ Vision Transformer: ViT เพื่อดึงคุณลักษณะ (feature extraction) ที่มีความทนทานต่อการเปลี่ยนแปลงของสภาพแวดล้อมก่อนส่งผ่านไปยัง CF สำหรับการติดตาม นอกจากนี้ Reinforcement Learning (RL) สามารถถูกนำมาใช้เพื่ออัปเดต CF อย่างปรับตัวได้ (adaptive update) ทำให้สามารถรับมือกับการเปลี่ยนแปลงของเป้าหมายและฉากหลังได้อย่างมีประสิทธิภาพมากขึ้น อีกทั้ง การประยุกต์ใช้ Siamese Network และ Attention Mechanism สามารถช่วยเพิ่มความสามารถในการแยกแยะเป้าหมายจากฉากหลังได้ดีขึ้น ส่งผลให้การติดตามมีความแม่นยำสูงขึ้นในกรณีที่มีการพรางตัวหรือการเปลี่ยนแปลงของลักษณะเป้าหมายอย่างต่อเนื่อง



References

- Asha, C. S., & Narasimhadhan, A. V. (2016). Adaptive learning rate for visual tracking using correlation filters. *Procedia Computer Science*, 89, 614-622. <https://doi.org/10.1016/j.procs.2016.06.023>
- Bamrungrathai, P., & Wongkamchang, P. (2018). Development of a thermal/visible image fusion system for situation awareness. In *2018 5th International Conference on Advanced Informatics: Concept Theory and Applications (ICAICTA)* (pp. 96-100). Krabi: IEEE.
- Bolme, D. S., Beveridge, J. R., Draper, B. A., & Lui, Y. M. (2010). Visual object tracking using adaptive correlation filters. In *2010 IEEE computer society conference on computer vision and pattern recognition* (pp. 2544-2550). San Francisco: IEEE.

- Chotsisuparat, N. (2020). *The numerical studies of the modified van der pol equation in electrical circuits* (Master's thesis). Srinakharinwirot University. Bangkok. (in Thai)
- Christen, P., Hand, D. J., & Kirielle, N. (2023). A review of the F-measure: its history, properties, criticism, and alternatives. *ACM Computing Surveys*, 56(3), 1-24. Retrieved from <https://bit.ly/4m25kQU>
- Grabner, H., & Bischof, H. (2006). On-line boosting and vision. In *2006 IEEE computer society conference on computer vision and pattern recognition (CVPR'06)* (pp. 260-267). New York: IEEE.
- Grabner, H., Grabner, M., & Bischof, H. (2006). Real-time tracking via on-line boosting. In *Proceedings of the British Machine Vision Conference* (p. 6.1-6.10). Edinburgh: BMVA Press
- Henriques, J. F., Caseiro, R., Martins, P., & Batista, J. (2015). High-speed tracking with kernelized correlation filters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(3), 583-596. <https://doi.org/10.1109/TPAMI.2014.2345390>
- Kalal, Z., Matas, J., & Mikolajczyk, K. (2012). Tracking-learning-detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(7), 1409–1422. <https://doi.org/10.1109/TPAMI.2011.239>
- Kowalski, M. Ł., Pałka, N., Młyńczak, J., Karol, M., Czerwińska, E., Życzkowski, M., Ciurapiński, W., Zawadzki, Z., & Brawata, S. (2021). Detection of inflatable boats and people in thermal infrared with deep learning methods. *Sensors*, 21(16), 5330. <https://doi.org/10.3390/s21165330>
- Kristan, M., Matas, J., Leonardis, A., Felsberg, M., Cehovin, L., Fernandez, G., & Pflugfelder, R. (2015). The visual object tracking vot2015 challenge results. In *Proceedings of the IEEE International Conference on Computer Vision Workshops*. Santiago: IEEE
- Lukežič, A., Vojříř, T., Čehovin, L., Matas, J., & Kristan, M. (2018). Discriminative correlation filter tracker with channel and spatial reliability. *International Journal of Computer Vision (IJCV)*, 126, 671–688. <https://doi.org/10.48550/arXiv.1611.08461>
- Mangale, S., & Khambete, M. (2016). Camouflaged target detection and tracking using thermal infrared and visible spectrum imaging. In *Intelligent Systems Technologies and Applications 2016* (pp. 193-207). Cham: Springer International Publishing.
- Shen, Y., Li, J., Lin, W., Chen, L., Huang, F., & Wang, S. (2021). Camouflaged target detection based on snapshot multispectral imaging. *Remote Sensing*, 13(19), 3949. <https://doi.org/10.3390/rs13193949>
- Shopovska, I., Jovanov, L., & Philips, W. (2019). Deep visible and thermal image fusion for enhanced pedestrian visibility. *Sensors*, 19(17), 3727. <https://doi.org/10.3390/s19173727>
- Wu, Y., Lim, J., & Yang, M. H. (2013). Online object tracking: A benchmark. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 2411-2418). Portland: IEEE

- Zhang, J., Yang, G., Liu, A., & Chen, X. (2023, November). A Data Augmentation Method Based on Multi-Modal Image Fusion for Detection and Segmentation. *In 2023 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence (ICSMD)* (pp. 1-5). Xi'an: IEEE.
- Zhang, Y., Wang, T., Liu, K., Zhang, B., & Chen, L. (2021). Recent advances of single-object tracking methods: A brief survey. *Neurocomputing*, 455, 1-11. <https://doi.org/10.1016/j.neucom.2021.05.011>
- Mangale, S., & Khambete, M. (2016). Camouflaged target detection and tracking using thermal infrared and visible spectrum imaging. In: J. Corchado Rodriguez, S. Mitra, S. Thampi, & ES. El-Alfy, (Eds), *Intelligent Systems Technologies and Applications 2016. ISTA 2016. Advances in Intelligent Systems and Computing, vol 530* (pp 193–207). Cham: Springer.
- Yang Liu, Cong-Qing Wang, Bin Xu, and Yong-Jun Zhou (2023). Aerial tracking of camouflaged people in woodlands, *Journal of Electronic Imaging*, 32(6), 063018. <https://doi.org/10.1117/1.JEI.32.6.063018>

