



แบบจำลองการจำแนกอากาศยานขับไล่โจมตีบนพื้นฐานข้อมูลของเป้าหมายไม่ทราบฝ่าย
โดยใช้โครงข่ายประสาทเทียม

A Model of Fighter Aircraft Classification Based on Information of Unknown Target Using Artificial Neural Networks

ปัทกร อันชื่น^{1*} และ นันทิพัฒน์ พิศุทธางกูร^{2*}

Patikorn Anchuen^{1*} and Nuntipat Phisutthangkoon^{2*}

¹สำนักบัณฑิตศึกษา โรงเรียนนายเรืออากาศนวมินทกษัตริยาธิราช กรุงเทพมหานคร 10220

²ภาควิชาคอมพิวเตอร์ กองวิชาคณิตศาสตร์และคอมพิวเตอร์ กองการศึกษา โรงเรียนนายเรืออากาศนวมินทกษัตริยาธิราช กรุงเทพมหานคร 10220

¹Office of Graduate Studies, Navaminda Kasatriyadhiraj Royal Air Force Academy, Bangkok 10220, THAILAND

²Department of Computer Science, Navaminda Kasatriyadhiraj Royal Air Force Academy, Bangkok 10220, THAILAND

*Corresponding author e-mail: nuntipat_phis@taf.mi.th, patikorn_an@taf.mi.th

ARTICLE INFO	ABSTRACT
Article history:	Identifying an aircraft from unknown-target information
Received: July 12, 2022	using radar is an important mission for national security to decide
Revised: October 11, 2022	military strategy. The fighter aircraft is primarily designed to air
Accepted: October 20, 2022	combat missions, which can inflict severe damage and is an
Available online: October xx, 2022	important factor in a tactical advantage. Analyzing unknown-
DOI: xxxxxxxxxxxxxxxxxxxxxxxxx	target information via radar system requires highly experienced
Keywords: fighter aircraft, radar	experts and military intelligence to identify fighter aircraft types.
system, data mining, neural	However, training experts to analyze data accurately can be time-
networks, smart weapon systems	consuming and costly. Therefore, the fighter aircraft classification
	requires modern approaches to comply with smart weapon
	systems for learning complex information to support the
	decision-making expert and solve the shortage of human
	resources. This paper generates the classification model of fighter
	aircraft based on unknown-target information using Feed-forward

Back-propagation Neural Networks to learn complex information. Besides, this concept solves the shortage of skilled personnel. The created model is efficient and flexible, with learning and testing data with 95.38% and 86.30% accuracy, respectively.

บทคัดย่อ

การระบุอากาศยานจากข้อมูลเป้าหมายไม่ทราบฝ่ายด้วยการใช้เรดาร์เป็นภารกิจที่สำคัญต่อความมั่นคงของประเทศเพื่อตัดสินใจเชิงกลยุทธ์ทางทหาร เนื่องจากอากาศยานขับไล่โจมตี (Fighter Aircraft) ถูกออกแบบเพื่อภารกิจในมิติการต่อสู้ทางอากาศเป็นหลัก สามารถสร้างความเสียหายที่รุนแรงและเป็นปัจจัยที่สำคัญต่อความได้เปรียบทางยุทธวิธี การวิเคราะห์ข้อมูลเป้าหมายไม่ทราบฝ่ายผ่านระบบเรดาร์ (Radar System) จำเป็นต้องใช้ผู้เชี่ยวชาญที่มีประสบการณ์สูงและข้อมูลข่าวสารทางทหารเพื่อระบุประเภทของอากาศยานขับไล่โจมตี อย่างไรก็ตามการฝึกอบรมผู้เชี่ยวชาญให้สามารถวิเคราะห์ข้อมูลได้อย่างแม่นยำ ทำให้เสียเวลาและค่าใช้จ่ายสูง ดังนั้นการจำแนกอากาศยานขับไล่โจมตีจำเป็นต้องอาศัยวิธีการที่ทันสมัยเพื่อสอดคล้องกับระบบอาวุธฉลาด (Smart Weapon Systems) สำหรับใช้ในการเรียนรู้ข้อมูลที่มีความซับซ้อนเพื่อช่วยสนับสนุนการตัดสินใจให้กับผู้เชี่ยวชาญ อีกทั้งสามารถแก้ปัญหาการขาดแคลนทรัพยากรมนุษย์ งานวิจัยนี้สร้างแบบจำลองการจำแนกอากาศยานขับไล่โจมตีบนพื้นฐานข้อมูลเป้าหมายไม่ทราบฝ่ายโดยใช้วิธีโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีการแพร่กระจายย้อนกลับเพื่อเรียนรู้ข้อมูลที่มีความซับซ้อนได้อย่างมีประสิทธิภาพ อีกทั้งยังช่วยแก้ปัญหาการขาดแคลนบุคลากรผู้เชี่ยวชาญ แบบจำลองที่ถูกสร้างให้ประสิทธิภาพและความยืดหยุ่นเมื่อทดสอบกับข้อมูลที่ใช้ในการเรียนรู้และข้อมูลที่ใช้ในการทดสอบมีความแม่นยำถึง 95.38% และ 86.30% ตามลำดับ

คำสำคัญ: อากาศยานขับไล่โจมตี ระบบเรดาร์ เหมือนข้อมูล โครงข่ายประสาทเทียม ระบบอาวุธที่ชาญฉลาด

บทนำ

ปัจจุบันการพัฒนาอาวุธที่มีอำนาจการทำลายล้างสูงตลอดทั้งขีดความสามารถของอากาศยานที่ส่งผลต่อภัยคุกคามทางอากาศยิ่งทวีความรุนแรงเพิ่มขึ้น ด้วยกลยุทธ์ในการสกัดกั้นและทำลายอากาศยานฝ่ายตรงข้ามที่มีประสิทธิภาพจะช่วยลดหรือป้องกันความเสียหายที่อาจส่งผลต่อความมั่นคงของชาติ การตัดสินใจอย่างพลวัตในเชิงกลยุทธ์ทางทหารจำเป็นต้องได้รับการตรวจสอบและพิสูจน์ตัวตนของเป้าหมายไม่ทราบฝ่ายผ่านระบบเรดาร์ (Radar System) โดยมีกระบวนการห้ข้อมูลจากเจ้าหน้าที่ผู้เชี่ยวชาญ ระบบตรวจจับจากเรดาร์มีการประมวลผลข้อมูลจากการทำงานโดยมีการส่งสัญญาณคลื่นแม่เหล็กไฟฟ้าในช่วงความถี่ที่เหมาะสมต่อการตรวจจับไปยังทิศทางที่ถูกกำหนดไว้ล่วงหน้าและรับสัญญาณสะท้อนกลับ เพื่อนำข้อมูลจากเรดาร์มาทำการแปลงให้อยู่ในคุณลักษณะที่เหมาะสม [1] เช่น ความเร็ว ความสูง ทิศทาง และพิกัด แม้ว่าภัยคุกคามทางอากาศสามารถเกิดขึ้นได้ทั้งจากอากาศยานที่มีนักบินและอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) ซึ่งแต่ละประเภทส่งผลต่อการเลือกวิธีปฏิบัติการทางอากาศเพื่อตอบโต้ภัยคุกคามที่แตกต่างกัน [2] ในขณะเดียวกันอากาศยานขับไล่โจมตี (Fighter Aircraft) แต่ละรุ่นมีขีดความสามารถในการรบที่แตกต่างกัน เช่น มีพิสัยการบินระยะไกล สามารถบินได้ทะลุกำแพงเสียง สามารถปฏิบัติการได้ทั้งทิ้งระเบิดและการโจมตีทางอากาศ โดยปัจจัยเหล่านี้มีความสำคัญต่อความได้เปรียบทางยุทธวิธี จึงจำเป็นที่จะต้องมีการค้นหาและพิสูจน์ฝ่ายที่มีประสิทธิภาพเพื่อตัดสินใจเลือกใช้กลยุทธ์ตอบโต้ที่เหมาะสม

การป้องกันภัยทางอากาศเป็นวิธีการเพื่อทำลายหรือลดประสิทธิภาพในการโจมตีของฝ่ายตรงข้ามในระหว่างที่ถูกคุกคาม โดยมีอยู่ด้วยกัน 4 ส่วนที่สำคัญ คือ การค้นหา (Detection) การพิสูจน์ฝ่าย (Identification) การสกัดกั้น (Interception) และการทำลาย (Destruction) [3] การวิเคราะห์เป้าหมายไม่ทราบฝ่าย เพื่อสนับสนุนการตัดสินใจมีการดำเนินการ 4 ขั้นตอน ได้แก่ การวิเคราะห์แบบอากาศยานขั้นต้น การตรวจสอบความถูกต้อง การนำข้อมูลเข้าระบบ และการวิเคราะห์ข้อมูลเชิงสถิติ [4] แม้จะมีระบบการป้องกันภัยทางอากาศที่มีประสิทธิภาพ แต่ยังคงต้องพึ่งพาเจ้าหน้าที่วิเคราะห์ข้อมูลที่มีความเชี่ยวชาญสูง อย่างไรก็ตามในการสร้างผู้เชี่ยวชาญอาจต้องใช้เวลาในการฝึกอบรมเป็นเวลานาน ก่อให้เกิดความขาดแคลนเจ้าหน้าที่ในการปฏิบัติงานเฉพาะนี้ ดังนั้นเพื่อแก้ปัญหาการขาดแคลนเจ้าหน้าที่ตลอดทั้งการช่วยสนับสนุนการตัดสินใจ จำเป็นต้องอาศัยการทำเหมืองข้อมูล (Data Mining) ซึ่งเป็นหนึ่งในวิธีการแก้ปัญหาเพื่อให้ได้มาซึ่งองค์ความรู้สำหรับการสนับสนุนการตัดสินใจ [5]

จากงานวิจัยที่ผ่านมาได้มีการศึกษาที่เกี่ยวข้องกับการทำเหมืองข้อมูลเพื่อสกัดองค์ความรู้ที่ซ่อนอยู่ภายในข้อมูลขนาดใหญ่ (Big Data) มาใช้งานด้วยการประยุกต์ใช้เทคนิคทางคณิตศาสตร์และการเรียนรู้ของเครื่อง (Machine Learning) สำหรับใช้งานทางด้านการจำแนกข้อมูล (Classification) [6] ในอดีตได้มีการพัฒนาระบบสังเกตการณ์อากาศยานแบบอัตโนมัติเพื่อแยกชนิดอากาศยานและกิจกรรมจากภาพถ่าย โดยมีการแยกชนิดประกอบด้วย อากาศยานปีกหมุน อากาศยานเครื่องยนต์เดี่ยว อากาศยานเครื่องยนต์คู่ และอากาศยานไอพ่น โดยมีการพิจารณากิจกรรมประกอบด้วย Take Off Landing Touch-and-go และ Low Approach [7] ต่อมาได้มีการเสนอการสร้างแบบจำลองเพื่อจำแนก Aircraft Economic บนพื้นฐานของ Support Vector Machine (SVM) และ Feed-forward Neural Network โดยผลลัพธ์ทั้งสองขั้นตอน

วิธีสามารถจำแนกอากาศยานได้อย่างแม่นยำ [8-10] จากนั้นได้มีการพัฒนาขั้นตอนวิธี Fault Detection ที่มีความคล้ายกับขั้นตอนวิธีแรนดอมฟอเรสต์ (Random Forest) เพื่อนำไปใช้ในการตรวจสอบ UAV [11] นอกจากนี้ยังได้พัฒนาระบบจำแนกอากาศยานขับไล่โจมตีแบบอัตโนมัติจากการใช้รูปภาพเพื่อจำแนกแบบอากาศยาน ประกอบด้วย P51 Mustang G1-Fokker MiG25-F และ Mirage 2000 โดยใช้วิธี Feed-forward Neural Network แบบ Three-layer Network ซึ่งสามารถจดจำรูปแบบได้ถึง 91% [12] มีการศึกษาเปรียบเทียบประสิทธิภาพของขั้นตอนวิธี ได้แก่ นาอ์ฟเบย์ (Naïve Bayes) ต้นไม้ตัดสินใจ (Decision Tree) Random Forest และ ID3 โดยใช้เครื่องมือ RapidMiner พบว่าขั้นตอนวิธี Random Forest และ ID3 ให้ความถูกต้องแม่นยำมากที่สุด [13] ได้มีการนำขั้นตอนวิธี Deep Convolutional Neural Network (DCNN) มาจำแนกประเภทของอากาศยานจากภาพถ่ายดาวเทียมแบบสำรวจระยะไกลโดยมีความแม่นยำถึง 96.8% [14] จากงานวิจัยที่ผ่านมา ยังไม่มีการสร้างแบบจำลองเฉพาะด้านเพื่อใช้จำแนกประเภทอากาศยานขับไล่โจมตีที่มีประสิทธิภาพและมีความซับซ้อนต่ำ แม้ว่าจะมีการศึกษาการสร้างแบบจำลองด้วยคุณลักษณะของข้อมูลที่แตกต่างตามวัตถุประสงค์ของแต่ละงานด้วยการเปรียบเทียบขั้นตอนวิธีที่เหมาะสมจากตัวชี้วัดความถูกต้อง พบว่าขั้นตอนวิธีที่มีความซับซ้อนสูงให้ความแม่นยำในการทำนายมากกว่า ในขณะที่เดียวกันขั้นตอนวิธีที่มีความซับซ้อนต่ำให้ประสิทธิภาพในการจำแนกที่ดีจากข้อมูลที่มีคุณลักษณะที่แตกต่างกันอย่างสิ้นเชิงแต่กลับพบว่าข้อมูลที่มีคุณลักษณะที่คล้ายคลึงกันไม่สามารถจำแนกได้อย่างมีประสิทธิภาพ

งานวิจัยนี้ได้สร้างแบบจำลองการจำแนกอากาศยานขับไล่โจมตีบนพื้นฐานข้อมูลเป้าหมายไม่ทราบฝ่ายโดยการประยุกต์ใช้วิธีโครงข่ายประสาทเทียมที่มีความสามารถในการเรียนรู้คล้ายกับพฤติกรรมของมนุษย์ และสามารถเรียนรู้พฤติกรรมที่ซับซ้อน อีกทั้งยังมีความ

ยี่ดหฺุ่นสูงต่อการนำไปใช้งาน การสร้างแบบจำลองด้วยวิธีการโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีการเรียนรู้แบบแพร่ย้อนกลับ (Feed-forward Backpropagation Neural Networks) แม้อาจจะเป็นเพียงวิธีพื้นฐานแต่สามารถเรียนรู้ข้อมูลที่มีความซับซ้อนได้อย่างมีประสิทธิภาพจากการเลือกปรับค่าพารามิเตอร์ภายในขั้นตอนวิธี และการแปลงข้อมูลให้เหมาะสม ทำให้สามารถสร้างแบบจำลองที่สามารถนำไปใช้งานเพื่อช่วยสนับสนุนการตัดสินใจและลดปัญหาการขาดแคลนบุคลากรผู้เชี่ยวชาญ โดยสอดคล้องกับระบบอาวุธที่ชาญฉลาด (Smart Weapon Systems) นอกจากนี้ในทางเทคนิคการสร้างแบบจำลองในงานวิจัยยังมีความซับซ้อนที่ต่ำเมื่อเทียบกับการเรียนรู้เชิงลึก (Deep Learning) ซึ่งโครงสร้างที่ถุกนำเสนอในงานวิจัยนี้ใช้เพียงหนึ่งชั้นซ่อนแต่ยังคงประสิทธิภาพที่ดีจากกระบวนการปรับค่าพารามิเตอร์ให้เหมาะสมกับข้อมูลที่ใช้ในการเรียนรู้


วิธีดำเนินการวิจัย

ข้อมูลที่ถูกคัดเลือกจากระบบเรดาร์

ข้อมูลจากระบบวิเคราะห์ความเคลื่อนไหวกำลังทางอากาศถูกเก็บรวบรวมไว้ในฐานข้อมูลขนาดใหญ่เพื่อใช้ในการวิเคราะห์ทางสถิติ โดยมีเจ้าหน้าที่ผู้เชี่ยวชาญวิเคราะห์ข้อมูลรูปแบบการบินของอากาศยานที่ตรวจพบจากระบบเรดาร์ด้วยค่าคุณลักษณะพื้นฐาน โดยข้อมูลค่าคุณลักษณะและผลลัพธ์จากการวิเคราะห์ของผู้เชี่ยวชาญสามารถแสดงได้ดังตารางที่ 1 ซึ่งประกอบไปด้วย 11 ตัวแปร ได้แก่ ความเร็วของอากาศยาน ความสูงที่ถูกตรวจพบ ทิศทางที่ถูกตรวจพบ วันในสัปดาห์ ช่วงเวลา รหัสสนามบินที่เครื่องออกเดินทาง (Take Off) รหัสสนามบินที่เครื่องลงสู่พื้นดิน (Landing) ความสูงที่หายจากระบบเรดาร์ ทิศทางที่หายจากระบบเรดาร์ รหัสสัญชาติ และแบบอากาศยานขับไล่โจมตี

ตารางที่ 1 ข้อมูลที่ถูกคัดเลือกจากระบบเรดาร์

ตัวแปร	ความหมาย	ช่วงของข้อมูล
Velocity	ความเร็วของอากาศยาน	[2-3000] กิโลเมตรต่อชั่วโมง
FoundHeight	ความสูงที่ถูกตรวจพบ	[220-38000] ฟุต
FoundDirection	ทิศทางที่ถูกตรวจพบ	[N, NW, W, SW, S, SE, E, NE]
FoundDay	วันในสัปดาห์	[Mon, Tue, Wed, Thu, Fri, Sat, Sun]
FoundTime	ช่วงเวลา	[0-23]
StartAirport	รหัสสนามบินที่เครื่อง Take Off	[1-21]
StopAirport	รหัสสนามบินที่เครื่อง Landing	[1-21]
HideHeight	ความสูงที่หายจากระบบเรดาร์	[220-38000] ฟุต
HideDirection	ทิศทางที่หายจากระบบเรดาร์	[N, NW, W, SW, S, SE, E, NE]
CountryCode	รหัสสัญชาติ	[1, 2, 3]
Fighter Aircraft Model	แบบอากาศยานขับไล่โจมตี	[Chendu F-7s, F/A-18D Hornet, Hawk Mk 208, JF-17, MiG-29s, Nanchang A-5C, Pilatus PC-7, Su-30MKM, Yak-130, Unknown]



รูปที่ 1 ข้อมูลที่ถูกเก็บรวบรวมจากระบบเรดาร์และผู้เชี่ยวชาญ


การได้มาซึ่งข้อมูลจะถูกดำเนินการผ่านกระบวนการวิเคราะห์เป้าหมายไม่ทราบฝ่ายที่ตรวจพบจากระบบเรดาร์ทางทหารที่เป็นระบบการเฝ้าตรวจสอบน่านฟ้าตลอดเวลา เมื่อมีการตรวจพบเป้าหมายไม่ทราบฝ่ายจากระบบเรดาร์ จะได้มาซึ่งข้อมูลเพื่อนำไปวิเคราะห์และระบุแบบอากาศยานในขั้นต้นจากเจ้าหน้าที่ผู้เชี่ยวชาญวิเคราะห์แบบอากาศยานดังรูปที่ 1 ด้วยข้อมูลที่แสดงบนจอภาพของระบบบัญชาการและควบคุมทางอากาศ (Air Command and Control System: ACCS) จากนั้นจะถูกตรวจสอบและวิเคราะห์ข้อมูลเพิ่มเติมเพื่อให้ข้อมูลมีความถูกต้องมากยิ่งขึ้นและทำการบันทึกข้อมูลดังกล่าว อย่างไรก็ตามข้อมูลที่เป็นส่วนสำคัญถูกคัดเลือกมาใช้กับงานวิจัยนี้ประกอบไปด้วย {Velocity, FoundHeight, FoundDirection, FoundDay, FoundTime, StartAirport, StopAirport, HideHeight, HideDirection, CountryCode} และแบบอากาศยานจะถูกพิจารณาเฉพาะอากาศยานขับไล่โจมตี โดยมีการพิจารณาทั้งหมด 10 แบบ ได้แก่ {Chendu F-7s, F/A-18D Hornet, Hawk Mk 208, JF-17, MiG-29s, Nanchang

A-5C, Pilatus PC-7, Su-30MKM, Yak-130, Unknown} ในงานวิจัยนี้จะพิจารณาค่าคุณลักษณะโดยนำค่าคุณลักษณะแต่ละตัวแปรมาสร้างแบบจำลองและตรวจสอบความถูกต้องของแบบจำลอง เมื่อพบว่าค่าคุณลักษณะใดที่ให้ความถูกต้องของแบบจำลองมากกว่า 20% จะถูกนำไปพิจารณาเป็นค่าคุณลักษณะที่สำคัญ

อย่างไรก็ตามผลการวิเคราะห์อากาศยานจากผู้เชี่ยวชาญเป็นเพียงการทำนายจากข้อมูลทางคุณลักษณะที่ได้รับจากระบบเรดาร์ซึ่งเป็นข้อมูลทางเดียว และอาจจะมีความเป็นเท็จสูง จึงจำเป็นต้องมีการดำเนินการเพื่อตรวจสอบความถูกต้องโดยใช้ข้อมูลร่วมกับด้านการข่าวจากแหล่งอื่นเพื่อพิจารณา เมื่อผ่านการตรวจสอบความถูกต้องเรียบร้อยแล้ว เจ้าหน้าที่จะทำการบันทึกข้อมูลเหล่านั้นไว้เป็นชุดข้อมูล เพื่อใช้ในการสนับสนุนการตัดสินใจจากการวิเคราะห์ข้อมูลทางสถิติ

แม้ว่าจะมีระบบการวิเคราะห์ความเคลื่อนไหวทางอากาศที่มีประสิทธิภาพ แต่ในการดำเนินการเหล่านี้จำเป็นต้องพึ่งพาผู้เชี่ยวชาญในการวิเคราะห์แบบอากาศยาน


ยาน เพื่อเป็นข้อมูลในการตัดสินใจในเชิงกลยุทธ์ทางทหาร ผู้เชี่ยวชาญเหล่านี้ล้วนได้รับการฝึกอบรมและมีประสบการณ์ในการทำงานจึงสามารถที่จะวิเคราะห์ได้อย่างแม่นยำ ในขณะที่เดียวกันการสร้างผู้เชี่ยวชาญเฉพาะด้านจำเป็นต้องใช้เวลานานในการเรียนรู้ และมีแนวโน้มที่บุคลากรดังกล่าวขาดแคลน ดังนั้นการสร้างแบบจำลองเพื่อใช้ในการจำแนกอากาศยานขับไล่โจมตี จึงเป็นสิ่งจำเป็นเพื่อแก้ปัญหาเหล่านี้ได้ในเบื้องต้น ฐานข้อมูลขนาดใหญ่ที่ถูกเก็บรวบรวมค่าคุณลักษณะที่สำคัญจากระบบเรดาร์และผลการวิเคราะห์แบบอากาศยานจะถูกนำมาใช้ในการสร้างแบบจำลองเพื่อนำไปใช้ในการจำแนกอากาศยานขับไล่โจมตีดังที่แสดงในรูปที่ 2 ระหว่างการดำเนินการตรวจสอบอากาศยานไม่ทราบฝ่ายจะใช้เพียงข้อมูลคุณลักษณะที่ถูกคัดเลือกส่งให้กับแบบจำลองเพื่อจำแนกอากาศยานขับไล่โจมตี สำหรับเป็นข้อมูลในการสนับสนุนการตัดสินใจจากแบบจำลองที่ใช้ค่าคุณลักษณะที่สามารถทดแทนผู้เชี่ยวชาญเหล่านั้นได้



รูปที่ 2 การสร้างแบบจำลองจากฐานข้อมูลขนาดใหญ่ เพื่อนำไปใช้งานสำหรับการสนับสนุนการตัดสินใจ

โครงข่ายประสาทเทียมที่ใช้ในงานวิจัย

วิธีโครงข่ายประสาทเทียมสามารถเรียนรู้พฤติกรรมทางกายภาพของระบบที่มีความซับซ้อนระหว่างข้อมูลที่เป็นอินพุตและข้อมูลเป้าหมายโดยจำเป็นต้องอาศัยชุดข้อมูลเพื่อใช้ในกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมเป็นจำนวนมาก ในปัจจุบันโครงข่ายประสาทเทียมได้ถูกพัฒนาให้มีประสิทธิภาพมากยิ่งขึ้น ไม่ว่าจะเป็นทางด้านการเรียนรู้เชิงลึกที่สามารถเรียนรู้จากข้อมูลที่มีความซับซ้อนที่สูงมาก เช่น ข้อมูลรูปภาพ ข้อมูลวิดีโอ และข้อมูลมีลำดับ เป็นต้น วิทยาการทางด้านวิทยาการทางคอมพิวเตอร์ด้วยการใช้ประโยชน์จากการประมวลผลของการจัดจอสามารถปลดล็อคข้อจำกัดในด้านของเวลาในการประมวลผลได้อย่างมีประสิทธิภาพ อย่างไรก็ตามแม้ว่าวิธีการดังกล่าวได้ถูกพัฒนาให้มีประสิทธิภาพมากยิ่งขึ้น แต่ก็ตามมาด้วยความซับซ้อนของขั้นตอนวิธีที่ต้องใช้ทรัพยากรในการประมวลผลสูงและอาจมีข้อจำกัดทางด้านการประมวลผลเมื่อนำไปใช้งาน ในปัจจุบันการมุ่งเน้นไปที่การเรียนรู้ของเครื่องด้วยขั้นตอนวิธีที่ซับซ้อนต่ำแต่ยังคงประสิทธิภาพในการเรียนรู้ข้อมูลที่มีความซับซ้อนสูง จึงได้รับความนิยมอย่างกว้างขวาง โดยที่โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีการเรียนรู้แบบแพร่ย้อนกลับ (Feed-forward Backpropagation Neural Networks) เป็นวิธีพื้นฐานในการสร้างแบบจำลองที่มีประสิทธิภาพ ด้วยการใช้กระบวนการ Back Propagation เพื่อปรับปรุงค่าน้ำหนัก (Weight) และค่าขีดแบ่ง (Bias) ภายในโครงข่ายประสาทเทียม เพื่อให้มีความเหมาะสมและได้มาซึ่งแบบจำลองที่มีประสิทธิภาพ อย่างไรก็ตามการกำหนดค่าตัวแปรภายในโครงข่ายประสาทเทียม เช่น จำนวนชั้นซ่อน จำนวนโหนดในชั้นซ่อน ฟังก์ชันในการตัดสินใจ การปรับข้อมูลให้เหมาะสม การล้างข้อมูล และการกำหนดค่าอัตราการเรียนรู้ ล้วนส่งผลต่อประสิทธิภาพของโครงข่ายประสาทเทียม



รูปที่ 3 โครงสร้างของโครงข่ายประสาทเทียม

ตารางที่ 2 การสกัดฟีเจอร์ข้อมูลที่ถูกคัดเลือกจากระบบเรดาร์ในส่วนของข้อมูลให้อยู่ในรูปแบบตัวเลข

ข้อมูล	ข้อมูลที่ถูกสกัด
[N, NW, W, SW, S, SE, E, NE]	[1,2,3,4,5,6,7,8]
[Mon, Tue, Wed, Thu, Fri, Sat, Sun]	[1,2,3,4,5,6,7]

ตารางที่ 3: การสกัดฟีเจอร์ข้อมูลอากาศยานขับไล่โจมตีเพื่อเป็นค่าเป้าหมายของ Neurons ในชั้นเอาต์พุต

แบบอากาศยานขับไล่โจมตี	เป้าหมายของ Neurons ในชั้นเอาต์พุตในแต่ละโหนด									
	1	2	3	4	5	6	7	8	9	10
Chendu F-7s	1	0	0	0	0	0	0	0	0	0
F/A-18D Hornet	0	1	0	0	0	0	0	0	0	0
Hawk Mk 208	0	0	1	0	0	0	0	0	0	0
JF-17	0	0	0	1	0	0	0	0	0	0
MiG-29s	0	0	0	0	1	0	0	0	0	0
Nanchang A-5C	0	0	0	0	0	1	0	0	0	0
Pilatus PC-7	0	0	0	0	0	0	1	0	0	0
Su-30MKM	0	0	0	0	0	0	0	1	0	0
Yak-130	0	0	0	0	0	0	0	0	1	0
Unknown	0	0	0	0	0	0	0	0	0	1

แม้ว่าปัจจุบันการเรียนรู้เชิงลึก (Deep Learning) จะช่วยการออกแบบและการใช้งาน แต่อย่างไร

ก็ตามคุณลักษณะของชุดข้อมูลที่ถูกนำมาใช้ในการเรียนรู้ เพื่อสร้างแบบจำลองในงานวิจัยนี้สามารถกำหนดจำนวน

ของชั้นซ่อนของโครงข่ายประสาทเทียมเพียง 1 ชั้นเท่านั้น เป็นผลให้ต้องการทรัพยากรในการประมวลผลข้อมูลที่ต่ำ โครงสร้างของโครงข่ายประสาทเทียมในงานวิจัยนี้แสดงดังรูปที่ 3 ซึ่งภายในประกอบไปด้วย 3 ชั้น ได้แก่ ชั้นอินพุต ซึ่งเป็นชั้นในการนำเข้าข้อมูลจากระบบเรดาร์ทั้ง 10 ตัวแปรที่ถูกปรับค่าให้เหมาะสมด้วยการนำไปคูณกับค่า Coefficient สำหรับชั้นซ่อนจะอยู่ระหว่างชั้นอินพุตและเอาต์พุตโดยชั้นนี้สามารถกำหนดให้มากกว่า 1 ชั้นซ่อน ซึ่งขึ้นอยู่กับความซับซ้อนของข้อมูลที่ใช้ในการเรียนรู้ ชั้นเอาต์พุตเป็นชั้นที่นำข้อมูลที่ถูกประมวลผลมาจากชั้นก่อนหน้าไปใช้เพื่อพิจารณาความเป็นไปได้ของข้อมูลในการจำแนกคุณลักษณะของแบบอากาศยานด้วยฟังก์ชัน SoftMax เพื่อแปลงค่าของแต่ละโหนดในชั้นเอาต์พุตออกมาเป็นค่าความน่าจะเป็นให้มีผลรวมเท่ากับ 1 โดยจะพิจารณาเลือกคำตอบจากค่าความน่าจะเป็นที่มากที่สุด

การสกัดข้อมูลและ Pre-processing

การเรียนรู้ของเครื่องจะได้มาซึ่งค่า Coefficients ของ Weight และ Bias เพื่อนำใช้ในการจำแนกอากาศยานขับไล่โจมตี โดยที่ข้อมูลนำเข้าโครงข่ายประสาทเทียม จำเป็นที่จะต้องได้รับการสกัดพีเอเจอร์ให้อยู่ในรูปของตัวเลข ดังนั้นชุดข้อมูลที่ถูกรวบรวมจะถูกแบ่งออกเป็น 2 ส่วน ได้แก่ ข้อมูลอินพุตและข้อมูลเป้าหมาย โดยที่ข้อมูลอินพุตคือ ข้อมูลที่ถูกคัดเลือกจากระบบเรดาร์ดังที่แสดงในตารางที่ 1 ในส่วนข้อมูลที่เป็นข้อความจะถูกสกัดเพื่อให้เป็นรูปแบบตัวเลขได้ดังที่แสดงในตารางที่ 2 นอกจากนี้ ข้อมูลเป้าหมายของแบบอากาศยานขับไล่โจมตีแต่ละแบบ จะถูกแปลงให้อยู่ในรูปของตัวเลข โดยที่โครงสร้างของโครงข่ายประสาทเทียมในงานวิจัยนี้ ได้กำหนดให้มีค่าเอาต์พุตตามจำนวนกรอบของแบบอากาศยานขับไล่โจมตีที่ถูกนำมาพิจารณาทั้งหมด 9 แบบและแบบที่ 10 เป็นไม่ทราบแบบ (Unknown) ซึ่งได้ทำการคัดเลือกชุดข้อมูลที่มีการวิเคราะห์อากาศยานขับไล่โจมตีในอัตราส่วนที่ใกล้เคียงกันโดยมีชุดข้อมูลทั้งหมด 1,000 ชุด โดยการ

แบ่งข้อมูล 80 เปอร์เซ็นต์เป็นข้อมูลที่ใช้ในการเรียนรู้ และที่เหลืออีก 20 เปอร์เซ็นต์เพื่อใช้ในกระบวนการทดสอบ ทั้งนี้การกำหนดข้อมูลการเรียนรู้และทดสอบเป็นอัตราส่วนที่เหมาะสมบนพื้นฐานด้วย 5-fold Cross-validation [15] ในการสกัดข้อมูลที่เป็นเป้าหมายจะถูกกำหนดไว้ดังที่แสดงในตารางที่ 3 เพื่อให้ง่ายต่อการจำแนกค่าคุณลักษณะของแต่ละโหนดจะถูกกำหนดให้อยู่ในช่วง 0 ถึง 1 ตัวอย่างเช่น ผลลัพธ์ของโหนดที่ 1 ถึง 10 มีค่าเท่ากับ {0,0,0,0,1,0,0,0,0,0} สามารถตีความได้ว่าเป็นอากาศยานขับไล่โจมตีแบบ MiG-29s


กระบวนการ Pre-processing เป็นกระบวนการแปลงข้อมูลให้เหมาะสมก่อนนำข้อมูลเข้าสู่โครงข่ายประสาทเทียม ในการสกัดพีเอเจอร์ของค่าเป้าหมายในโครงข่ายประสาทเทียมมีค่าอยู่ระหว่างช่วง 0 ถึง 1 ดังนั้น การนำเข้าข้อมูลในชั้นอินพุตควรที่จะมีการแปลงค่าข้อมูลให้อยู่ในช่วง 0 ถึง 1 เช่นเดียวกับชั้นเอาต์พุต เพื่อส่งต่อข้อมูลระหว่างชั้นอินพุตไปยังชั้นซ่อน และชั้นซ่อนไปยังชั้นเอาต์พุต การแปลงค่าเช่นนี้จะทำให้ช่วงข้อมูลมีความสม่ำเสมอ ซึ่งจะส่งผลกระทบต่อประสิทธิภาพในการเรียนรู้ การแปลงข้อมูลให้เหมาะสมกับโครงข่ายประสาทเทียมชั้นอินพุตจะถูกดำเนินการผ่านวิธีการทำ Zero Span [16] ดังที่แสดงในสมการที่ (1)

$$x = \frac{1}{X_{max}-X_{min}}X \quad (1)$$

การสร้างแบบจำลอง

การสร้างแบบจำลองด้วยวิธีโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีการเรียนรู้แบบแพร่ย้อนกลับจะดำเนินการด้วยการป้อนข้อมูลเพื่อให้กระบวนการดำเนินไปข้างหน้าโดยการ Activation ซึ่งมีการส่งข้อมูลและประมวลผลข้อมูลจากชั้นอินพุตไปยังชั้นซ่อนและจากชั้นซ่อนไปยังเข้าเอาต์พุต เพื่อหาค่า Error ระหว่างเป้าหมายที่ใช้ในกระบวนการเรียนรู้กับค่าเอาต์พุต แล้วทำการปรับค่า Coefficients ของ Weight และ Bias ย้อนกลับจากชั้นเอาต์พุตไปชั้นซ่อน และจากชั้นซ่อนไปชั้น

อินพุต ดังที่แสดงในรูปที่ 4 ในงานวิจัยนี้ได้ประยุกต์ใช้วิธีโครงข่ายประสาทเทียมที่ถูกสร้างขึ้นด้วยโปรแกรม MATLAB ที่สามารถปรับจูนการตั้งค่าภายในโครงข่ายประสาทเทียม เช่น การกำหนดอัตราการเรียนรู้เทียบกับการสุ่มค่าเริ่มต้นของค่าถ่วงน้ำหนักให้มีประสิทธิภาพ การเลือกจำนวนชั้นซ่อนในโครงข่ายที่เหมาะสม เป็นต้น [17]



รูปที่ 4 การดำเนินการของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมในงานวิจัยนี้กำหนดให้มีชั้นซ่อนเพียง 1 ชั้น เพื่อให้มีความซับซ้อนต่ำ ในขณะที่การรับค่าของชั้นอินพุตในแต่ละโหนดจะถูกแปลงข้อมูลให้อยู่ในช่วง 0 ถึง 1 ดังนั้น เพื่อส่งต่อข้อมูลระหว่างชั้นอย่างสม่ำเสมอ งานวิจัยนี้มุ่งเน้นไปที่การเลือกฟังก์ชันการตัดสินใจโดยใช้ Sigmoid Function ซึ่งมีช่วงของเรนจ์ระหว่าง 0 ถึง 1 และช่วงของโดเมนตั้งแต่ลบอินฟินิตี้ถึงอินฟินิตี้ โดยฟังก์ชันตัดสินใจสามารถแสดงได้ดังสมการที่ (2)

$$S(x) = \frac{1}{1+e^{-x}} \quad (2)$$

ขั้นตอนในการสร้างแบบจำลองด้วยวิธีโครงข่ายประสาทเทียมมีดังนี้

ขั้นตอนที่ 1: การกำหนดค่าเริ่มต้นของโครงข่ายประสาทเทียม

เป็นการสุ่มค่า Coefficients ของ Weight และ Bias โดยเริ่มต้นจะขึ้นอยู่กับค่าอัตราการเรียนรู้และ

อนุพันธ์ของฟังก์ชันการตัดสินใจซึ่งสามารถคำนวณได้จากอนุพันธ์ของ Sigmoid Function เท่ากับอัตราการเรียนรู้ Learning Rate (α) ดังที่แสดงได้จากสมการที่ (3)

$$\alpha = \frac{e^x}{(1+e^x)^2} \quad (3)$$

เมื่อกำหนดให้อัตราการเรียนรู้เท่ากับ 0.08 ผลลัพธ์ของค่าโดเมนที่ได้จากอนุพันธ์ของ Sigmoid Function ที่ถูกคำนวณจะมีค่าโดยประมาณ -2.4 และ 2.4 ดังนั้นการสุ่มตัวเลข Coefficients ของ Weight และ Bias จำเป็นที่จะต้องมีการกระจายตัวอยู่ระหว่าง -2.4 ถึง 2.4 ต่อจำนวนนิวรอนในชั้นก่อนหน้า (m) เพื่อเป็นการกระจายค่าของข้อมูลให้เหมาะสมกับโครงข่ายประสาทเทียมโดยสามารถแสดงได้ดังสมการที่ (4)

$$-\frac{2.4}{m} \leq w_{ij}, w_{jk}, \theta_j, \theta_k \leq \frac{2.4}{m} \quad (4)$$

ขั้นตอนที่ 2: Activation

ข้อมูลจะถูกใช้ในการสร้างแบบจำลองซึ่งถูกนำมาป้อนเข้าโครงข่ายประสาทเทียมโดยการ Activation จากชั้นอินพุตไปยังชั้นซ่อน และจากชั้นซ่อนไปยังเอาต์พุต โดยการคำนวณ Actual เอาต์พุตของนิวรอนในชั้นซ่อนและเอาต์พุตของนิวรอนในชั้นเอาต์พุต

ขั้นตอนที่ 3: Weight and Bias Learning

ผลลัพธ์เอาต์พุตของนิวรอนในชั้นเอาต์พุตจะถูกนำมาเปรียบเทียบกับค่าเป้าหมายเพื่อหาค่าความผิดพลาดและทำการปรับค่า Coefficients ของ Weight และ Bias

ขั้นตอนที่ 4: Iteration

การนำข้อมูลในลำดับถัดไปป้อนเข้าโครงข่ายประสาทเทียมในขั้นตอนที่ 2 โดยใช้ค่า Coefficients ของ Weight และ Bias ใหม่เพื่อปรับค่าซ้ำจนครบตามจำนวนชุดข้อมูลที่ใช้ในกระบวนการเรียนรู้ทั้งหมด 800 ชุด ซึ่งจะถูกนับเป็น 1 Epoch และคำนวณค่าความผิดพลาดที่สามารถยอมรับได้ดังสมการที่ (5)

$$MSE = \frac{1}{800} \sum_{p=1}^{800} \sum_{k=1}^{10} e_k(p)^2 \quad (5)$$

ในการเรียนรู้แต่ละ Epoch ค่า Mean of Square Error (MSE) จะเริ่มลดลง ซึ่งจะต้องทำการกลับไปใช้ข้อมูลในชุดแรกเริ่มตั้งแต่ขั้นตอนที่ 2 อีกครั้ง จนกว่าค่า MSE จะเป็นค่าที่ยอมรับได้หรือจนกว่าจะถึงจำนวนรอบ Epoch ที่กำหนดเพื่อให้ได้ Weight และ Bias ที่มีความเหมาะสมต่อการนำไปใช้งาน

ผลการศึกษาและอภิปรายผล


การสร้างแบบจำลองเพื่อจำแนกรุ่นของอากาศยานขับไล่โจมตีด้วยวิธีโครงข่ายประสาทเทียมสำหรับสนับสนุนการตัดสินใจให้กับผู้เชี่ยวชาญ และการอภิปรายผลการทดลองเพื่อแสดงความสัมพันธ์ท่ามกลางข้อมูลจากผลการศึกษา จะถูกนำเสนอพร้อมทั้งการให้รายละเอียดดังต่อไปนี้

ผลลัพธ์จากกระบวนการเรียนรู้

ชุดข้อมูลที่ถูกเก็บรวบรวมจากระบบเรดาร์ และข้อมูลที่ถูกวิเคราะห์จากผู้เชี่ยวชาญจะถูกนำมาใช้เพื่อสร้างแบบจำลองการจำแนกอากาศยานขับไล่โจมตีบนพื้นฐานข้อมูลเป้าหมายไม่ทราบฝ่าย สำหรับค่าคุณลักษณะที่สำคัญได้ถูกคัดเลือกจาก 10 ตัวแปรตามที่ได้กล่าวไว้ก่อนหน้านี้ นอกจากนี้ยังมีการสกัดพีเจอร์บางตัวแปรที่เป็นข้อมูลให้อยู่ในรูปแบบของตัวเลขและปรับข้อมูลให้เหมาะสมด้วยการทำ Zero-span ก่อนนำเข้าโครงข่ายประสาทเทียม

ปัจจัยสำคัญที่ส่งผลต่อประสิทธิภาพของโครงข่ายประสาทเทียมถูกพิจารณาเพื่อตั้งค่าให้เหมาะสมต่อรูปแบบของข้อมูลที่ใช้ในการสร้างแบบจำลอง ในงานวิจัยนี้กำหนดให้จำนวนโหนดในชั้นอินพุตเท่ากับ 10 โหนด ตามจำนวนของตัวแปรต้นและจำนวนโหนดในชั้นเอาต์พุตเท่ากับ 10 โหนด โดยมีการพิจารณาจำนวนชั้นซ่อนเพียง 1 ชั้นเท่านั้น ทั้งนี้เพื่อให้มีความเหมาะสมของโครงข่ายประสาทเทียมน้อยที่สุดแต่ยังคงประสิทธิภาพที่ดี การกำหนดจำนวนโหนดในชั้นซ่อนจำเป็นที่จะต้องได้รับการพิจารณาที่เหมาะสมด้วยวิธี

Trial and Error Method [18] แบบจำลองที่ถูกสร้างขึ้นนี้เป็นการนำโครงข่ายประสาทเทียมมาใช้ในการจำแนก (Classification) ดังนั้น สิ่งสำคัญที่สุดในการวัดประสิทธิภาพของแบบจำลอง คือ ค่าความถูกต้อง (Accuracy) ซึ่งคิดเป็นเปอร์เซ็นต์และ MSE เพื่อวัดค่าความผิดพลาดของข้อมูลในระหว่างการเรียนรู้ จำนวนโหนดในชั้นซ่อนจะถูกเปรียบเทียบกับ MSE และ Accuracy เพื่อค้นหาค่าที่เหมาะสมของจำนวนโหนดที่ต่ำที่สุดแต่ยังคงประสิทธิภาพของความถูกต้องให้ Accuracy มากกว่า 90% ซึ่งเป็นค่าที่ถูกกำหนดจากงานวิจัยนี้ จากรูปที่ 5 แสดงให้เห็นถึงค่า MSE และ Accuracy จากการทดลองด้วยการใช้ข้อมูลของชุดฝึกสอนโดยมีการกำหนดให้การเรียนรู้ 10,000 Epoch แล้วทำการบันทึกข้อมูลของค่า Coefficients ของ Weight และ Bias เพื่อใช้ในการทดสอบ ผลลัพธ์แสดงให้เห็นว่าเมื่อมีการกำหนดจำนวนโหนดในชั้นซ่อนเท่ากับ 50 โหนด จะมีค่า MSE เท่ากับ 0.000301 จากรูปที่ 5 สังเกตได้ว่าค่า MSE จะลดลงตามจำนวนของโหนดในชั้นซ่อนที่เพิ่มขึ้น ในขณะที่ Accuracy จะมีค่ามากกว่า 90% ด้วยการกำหนดโหนดในชั้นซ่อนตั้งแต่ 200 โหนด เป็นต้นไป



รูปที่ 5 ความสัมพันธ์ระหว่างจำนวนโหนดในชั้นซ่อนเทียบกับ MSE และ Accuracy

ในขณะเดียวกันเมื่อมีการเพิ่มจำนวนโหนดในชั้นซ่อนเพิ่มขึ้นค่า Accuracy จะเริ่มมีการเปลี่ยนแปลงเพียงเล็กน้อย แต่กระนั้นการเพิ่มจำนวนโหนดในชั้นซ่อนมากขึ้นจะส่งผลต่อจำนวนของ Weight และ Bias ที่เพิ่ม

มากยิ่งขึ้นด้วยเช่นกันซึ่งความซับซ้อนของแบบจำลองจะเพิ่มขึ้นตามไปด้วยตามที่ได้แสดงในตารางที่ 4 โดยมีจำนวนของ Weight และ Bias เพียง 4,210 ตัว เมื่อกำหนดให้โหนดในชั้นซ่อนเท่ากับ 200 โหนด

ตารางที่ 4 ความสัมพันธ์ระหว่างจำนวนโหนดในชั้นซ่อนและจำนวนของ Weight และ Bias

จำนวนของโหนด ในชั้นซ่อน	จำนวนของ Weight และ Bias
50	1,060
100	2,110
150	3,160
200	4,210
250	5,260
300	6,310

ในการกำหนดค่าพารามิเตอร์ที่เหมาะสมและผลลัพธ์ที่ได้จากการสร้างแบบจำลองสามารถแสดงได้ดังข้อมูลในตารางที่ 5 เมื่อจำนวนโหนดในชั้นซ่อนเท่ากับ 200 โหนด โดยมี MSE เพียง 0.000268 ที่ 10,000 Epoch ซึ่งมีประสิทธิภาพในการทำนายจากข้อมูลที่ใช้เรียนรู้ (Training Accuracy) ถึง 95.38% และข้อมูลที่ใช้

ใช้ในการทดสอบ (Testing Accuracy) ถึง 86.30% ตามลำดับ ในขณะที่ความถูกต้องของแบบจำลอง (Accuracy) เท่ากับ 93.50% ดังที่แสดงได้ตามตารางที่ 6 จากการคำนวณ Confusion Matrix ซึ่งในแต่ละแบบอากาศยานขับไล่โจมตีที่ถูกคาดการณ์ในแต่ละคลาส (Predicted Class) มีความแม่นยำต่ำสุดเท่ากับ 80% ในแบบอากาศยาน JF-17 และมีความแม่นยำสูงที่สุดเท่ากับ 100% ในแบบอากาศยาน Nanchang A-5C

ตารางที่ 5 ข้อมูลของแบบจำลองการที่ถูกสร้างด้วยวิธีโครงข่ายประสาทเทียม

จำนวนของโหนด ในชั้นซ่อน	จำนวนของ Weight และ Bias
Input Node	10
Hidden Node	200
Hidden Layer	1
Output Node	10
MSE	0.000268
Epoch	10000
Accuracy	93.50%
Training Accuracy	95.38%
Testing Accuracy	86.30%


ตารางที่ 6 Confusion Matrix ของแบบจำลองการจำแนกอากาศยานขับไล่โจมตี

	Chendu F-7s	F/A-18D Hornet	Hawk Mk 208	JF-17	MiG-29s	Nanchang A-5C	Pilatus PC-7	Su-30MKM	Yak-130	Unknown	Predicted Class (%)
Chendu F-7s	125	0	0	0	4	4	4	0	0	0	91.2
F/A-18D Hornet	0	118	2	0	3	0	0	0	0	0	95.9
Hawk Mk 208	0	3	121	0	0	0	3	5	0	0	91.7
JF-17	0	0	0	4	0	0	1	0	0	0	80.0
MiG-29s	2	0	0	3	126	3	0	0	0	0	94.0
Nanchang A-5C	0	0	0	0	0	67	0	0	0	0	100.0
Pilatus PC-7	7	0	0	0	5	0	124	0	0	0	91.2

	Chendu F-7s	F/A-18D Hornet	Hawk Mk 208	JF-17	MiG-29s	Nanchang A-5C	Pilatus PC-7	Su-30MKM	Yak-130	Unknown	Predicted Class (%)
Su-30MKM	0	5	7	0	0	0	0	126	0	0	91.3
Yak-130	0	0	0	4	0	0	0	0	124	0	96.9
Unknown	0	0	0	0	0	0	0	0	0	0	0.0
Actual Class (%)	93.3	93.7	93.1	36.4	91.3	90.5	93.9	96.2	100.0	0.0	93.5

จากข้อมูลที่ใช้ในการเรียนรู้และประสิทธิภาพโดยรวมด้วยวิธีการ 5-fold Cross-validation ซึ่งเป็นการแบ่งข้อมูลออกเป็น 5 กลุ่มโดยมีการสลับการใช้ชุดทดสอบที่แตกต่างกัน 5 ชุดซึ่งให้ความถูกต้องสูงถึง

93.5% และเมื่อนำไปใช้กับข้อมูลที่ไม่ได้ผ่านการเรียนรู้แบบจำลองมีการจำแนกอากาศยานขับไล่โจมตีได้ถูกต้องถึง 86.3%



รูปที่ 6 ตัวอย่างการจำแนกอากาศยานขับไล่โจมตีบนพื้นฐานข้อมูลเป้าหมายไม่ทราบฝ่าย

การนำไปใช้งาน

ผลลัพธ์ที่ได้จากกระบวนการสร้างแบบจำลองถูกนำไปใช้งานเมื่อมีข้อมูลค่าคุณลักษณะของเป้าหมายไม่ทราบฝ่ายที่ได้รับจากระบบเรดาร์ 10 ตัวแปร จะถูกแปลงเป็นข้อมูลเชิงตัวเลขแล้วป้อนเข้าแบบจำลองเพื่อคำนวณทางคณิตศาสตร์จากการป้อนข้อมูลเข้าไปในชั้นอินพุตและถูกส่งต่อไปยังชั้นซ่อน และจากชั้นซ่อนถูกส่งต่อมายังชั้นเอาต์พุตเพื่อคำนวณค่าตัวเลขของแต่ละโหนด จากนั้นตัวเลขที่ถูกคำนวณออกมาในแต่ละโหนด

จะถูกป้อนเข้า SoftMax Function ที่ถูกวางไว้ที่ชั้นสุดท้ายของโครงข่ายประสาทเทียมเพื่อคำนวณค่าความน่าจะเป็นของแต่ละโหนดในชั้นเอาต์พุตให้มีผลรวมเท่ากับ 1 โดยเลือกคำตอบของอากาศยานขับไล่โจมตีจากโหนดที่มีค่าความน่าจะเป็นมากที่สุด เมื่อนำแบบจำลองการจำแนกอากาศยานขับไล่โจมตีไปใช้งานโดยจะต้องป้อนข้อมูลตัวแปรให้ครบทั้ง 10 ตัวแปร แบบจำลองจะทำการจำแนกข้อมูลเพื่อสนับสนุนการตัดสินใจโดยข้อมูลถูกป้อนดังรูปที่ 6 ซึ่งวัตถุไม่ทราบฝ่ายที่ถูกตรวจพบนั้นมี

ความเร็ว 480 กิโลเมตรต่อชั่วโมง ตรวจพบในวัน Tuesday ตรวจพบเวลา 11 (หน่วย) ตรวจพบที่ทิศ NW และอื่น ๆ ผลลัพธ์ที่ได้จากการจำแนกถูกตัดสินใจได้ว่า เป้าหมายไม่ทราบฝ่ายนั้นคืออากาศยานขับไล่โจมตีรุ่น MiG-29s

ตารางที่ 7 Class ของอากาศยานขับไล่โจมตีที่ถูกทำนายจากข้อมูลของเรา

Input Parameters	Chendu F-7s	F/A-18D Hornet	Hawk Mk 208	JF-17	MIg-29s	Nanchang A-5C	Pilatus PC-7	Su-30MKM	Yak-130	Unknown
Velocity	200	210	450	400	480	150	180	150	250	n/a
FoundHeight	17,000	16,000	15,000	15,000	27,000	15,000	18,000	20,000	18,000	n/a
FoundDirection	5	1	7	4	2	6	2	4	1	n/a
FoundDay	2	3	5	4	2	5	3	5	2	n/a
FoundTime	10	7	8	12	11	11	10	9	6	n/a
StartAirport	114	114	140	140	1	108	114	140	114	n/a
StopAirport	114	109	140	140	4	108	114	140	106	n/a
HideHeight	5,000	8,000	3,000	4,000	3,000	6,000	3,000	10,000	4,000	n/a
HideDirection	8	1	2	3	2	6	2	4	1	n/a
CountryCode	2	2	1	1	2	2	2	1	2	n/a
Predicted Class (%)	0.76	0.85	0.79	0.61	0.84	0.95	0.75	0.71	0.87	n/a

นอกจากนี้การคาดการณ์ในแต่ละคลาสอากาศยานขับไล่โจมตีทั้ง 9 แบบ สามารถแสดงตัวอย่างได้ดังตารางที่ 7 โดยที่ข้อมูลค่าคุณลักษณะทั้ง 10 ตัวแปร ถูกป้อนเข้าแบบจำลองเพื่อเลือกคำตอบของอากาศยานขับไล่โจมตีจากโหนดที่มีค่าความน่าจะเป็นมากที่สุด ในขณะที่ข้อมูลนำเข้าที่ไม่สอดคล้องกับขอบเขตที่กำหนดจะถูกตัดสินใจให้เป็น Unknown Class ซึ่งมีความหมายว่าแบบจำลองไม่สามารถจำแนกประเภทของอากาศยานขับไล่โจมตีได้

อภิปรายผล

ผลลัพธ์ที่ได้จากการสร้างแบบจำลองพบว่าการจำแนกอากาศยานขับไล่โจมตีมีความซับซ้อนของข้อมูลที่ไม่สามารถประเมินได้ด้วยการเปรียบเทียบความเร็วที่ตรวจพบหรือระดับความสูงที่ตรวจพบ ซึ่งจำเป็นที่จะต้องใช้ขั้นตอนวิธีโครงข่ายประสาทเทียมที่สามารถเรียนรู้ข้อมูลที่ซับซ้อนได้และมีการแยก

Category ของแบบอากาศยานจำนวนมากเมื่อเทียบกับงานวิจัยก่อนหน้านี้ที่มีการจำแนกเพียงประเภทของอากาศยานเท่านั้น [4] โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับที่ถูกนำเสนอในงานวิจัยนี้ตั้งอยู่บนพื้นฐานของการตั้งค่าพารามิเตอร์ภายในโครงข่ายที่เหมาะสมเพื่อให้ได้มาซึ่งแบบจำลองที่มีความซับซ้อนต่ำแต่ยังคงประสิทธิภาพที่สูง การทดลองในงานวิจัยได้ตั้งอยู่บนพื้นฐานของขอบเขตการใช้ชุดข้อมูลที่ถูกใช้เฉพาะอากาศยานขับไล่โจมตีเท่านั้นซึ่งถูกจำกัดเพียง 9 แบบ อย่างไรก็ตามตัวเลขเหล่านี้จะเป็นตัวบ่งบอกถึงประสิทธิภาพและความน่าเชื่อถือของแบบจำลองที่ถูกสร้างขึ้นถึงแม้ว่าการสร้างแบบจำลองด้วยข้อมูลในส่วนที่ใช้ในการเรียนรู้จะมีความแม่นยำถึง 95.38% แต่เมื่อมีการนำข้อมูลที่นอกเหนือจากกระบวนการเรียนรู้มาใช้ทดสอบจะมีความถูกต้องถึง 86.30%

สรุปผล

อากาศยานขับไล่โจมตีได้ถูกพัฒนาให้มีขีดความสามารถในการสร้างความเสียหายที่เป็นภัยต่อความมั่นคงของชาติ การปฏิบัติการป้องกันภัยทางอากาศ สามารถค้นหาเป้าหมายโดยใช้เรดาร์เพื่อวิเคราะห์ข้อมูลจากผู้เชี่ยวชาญที่มีประสบการณ์สูงและแหล่งข่าวที่น่าเชื่อถือเพิ่มเติม อย่างไรก็ตามการประสบปัญหาการขาดแคลนเจ้าหน้าที่ผู้เชี่ยวชาญอาจส่งผลกระทบต่อการสนับสนุนข้อมูลเพื่อการตัดสินใจในเชิงกลยุทธ์ทางทหาร จึงจำเป็นต้องอาศัยกระบวนการในการทำเหมืองข้อมูล (Data Mining) เพื่อสกัดนำองค์ความรู้ที่ได้จากฐานข้อมูลขนาดใหญ่ (Big Data) ที่ถูกเก็บรวบรวมมาใช้ประโยชน์ในการสร้างการตัดสินใจด้วยเครื่องจักร ดังนั้นงานวิจัยนี้ได้สร้างแบบจำลองการจำแนกอากาศยานขับไล่โจมตีบนพื้นฐานข้อมูลเป้าหมายไม่ทราบฝ่าย โดยใช้วิธีโครงข่ายประสาทเทียมที่มีความแม่นยำสูง ด้วยกลไกในการตั้งค่าภายในโครงข่ายประสาทเทียมที่เหมาะสมทำให้แบบจำลองที่ถูกสร้างขึ้นมีความซับซ้อนต่ำแต่ยังคงประสิทธิภาพสูงผลลัพธ์ที่ได้จากการสร้างแบบจำลองนั้นเป็นประโยชน์อย่างยิ่ง โดยสามารถนำไปเป็นต้นแบบสำหรับตัดสินใจแทนผู้เชี่ยวชาญ ซึ่งจะช่วยลดปัญหาการขาดแคลนบุคลากร และสอดคล้องกับระบบอาวุธฉลาด (Smart Weapon Systems) ได้

กิตติกรรมประกาศ

บทความวิจัยนี้ได้รับการสนับสนุนข้อมูลจากระบบวิเคราะห์ความเคลื่อนไหวกำลังทางอากาศประเทศเพื่อนบ้านจากกรมข่าวทหารอากาศเพื่อใช้ในการสร้างแบบจำลองของการจำแนกรุ่นของอากาศยานขับไล่โจมตีและขอขอบพระคุณนาวาอากาศเอก ผู้ช่วยศาสตราจารย์ ภูมิพัฒน์ ดวงกลาง ที่คอยให้คำแนะนำตลอดทั้งช่วยชี้แนะแนวทางในการพัฒนางานวิจัยนี้จนสำเร็จลุล่วง

เอกสารอ้างอิง

1. Skolnik M. Introduction to radar systems. 2nd edition. New York: 1980.
2. Dragan T, Slobodan S, Srdjan B, Milorad M, Branimir K, Zoran R, et al. Failure analysis of the combat jet aircraft rudder shaft. Eng Fail Ana. 2011;18(8):1998-2007.
3. Kishore K. Air defence command – a bold test case. Manohar parrikar institute for defence studies and analyses. 2020.
4. Phummipat D, Rajana K. Models for automatic aircraft type prediction. NKRAFA JST. 2019;15: 1-8.
5. Roopa K, Rama T, Cyril P. Neural network classifier for fighter aircraft model recognition. J Intell Syst. 2018;27(3):447-63.
6. Peerasut T, Sanrach C. The comparison of data classification efficiency to predict scholarship awarded for undergraduate students by data mining techniques. JPRR. 2021;8(2):44-52.
7. Charles H. Development of An Aircraft Operation Classification system for Louisiana's Airports. Tech Report Dept of Elect & Comp Engr and Remote Sensing and Image Processing Lab. Louisiana State University: June 2003.
8. Xiao-jin L, Shu-long Z. The Model of Aircraft Economic Classification Based on Support Vector Machine. 2009 ETP International Conference on Future Computer and

- Communication. 2009. p. 128-30. doi: 10.1109/FCC.2009.9.
9. Xiao-jin L, Shu-long Z. Study on the Support Vector Machine (SVM) Model of Aircraft Economic Classification with Application in China. 2009 International Conference on Electronic Commerce and Business Intelligence. 2009. p. 177-9. doi: 10.1109/ECBI.2009.65.
 10. Osses A, Gómez I, Glisser M, Gerard C, Guzmán R. Classification of Aircrafts using Artificial Neural Networks. Group. 2012.
 11. Sanghyuk L, Wookje P, Sikhang J. Fault detection of aircraft system with random forest algorithm and similarity measure. Sci World J. 2014. doi.org/10.1155/2014/727359
 12. Roopa K, Murthy T, Raj P. Neural network classifier for fighter aircraft model recognition. Int J Intell Syst. 2018;27(3):447-63.
 13. Marzukhi S, Awang N, Alsagoff S, Mohamed H. RapidMiner and machine learning techniques for classifying aircraft data. J Phys: Conf Ser. 2021;1997:012012. doi:10.1088/1742-6596/1997/1/012012
 14. Azam F, Rizvi A, Khan W, Aalsalem M, Yu H, Zikria Y. Aircraft classification based on PCA and feature fusion techniques in convolutional neural network. IEEE Access. 2021;9:161683-94.
 15. Granger C. Strategies for modelling nonlinear time series relationships. The Economic Record. 1993;69(3):233-8.
 16. James F. The equivalence of zero span and zero semispan. Proceedings of the American Mathematical Society. 1984;90(1):133-8.
 17. Peerapong U, Patikorn A, Monthippa U, Arfat A. Estimating and synthesizing QoE based on QoS measurement for improving multimedia services on cellular networks using ANN method. IEEE Trans Netw Serv. 2020;17(1):389-402.
 18. Panchai F, Panchal M. Review on methods of selecting number of hidden nodes in artificial neural network. J Comput Sci Technol. 2014;3(11):455-64.