

A COMPARATIVE STUDY OF FOOTBALL MATCH OUTCOME PREDICTIONS USING DEEP LEARNING BY COMBINING STATISTICAL DATA AND PLAYER HEATMAPS

Bhanupun PUNPRUKSA¹

1 Faculty of Commerce and Accountancy, Chulalongkorn University, Thailand;

6680293826@student.chula.ac.th

ARTICLE HISTORY

Received: 1 September 2025

Revised: 22 September 2025

Published: 7 October 2025

ABSTRACT

The objective of this research was to compare the performance of MLP, CNN, and Multimodal Neural Network (MMNN) models in predicting the outcomes of English Premier League football matches. The study used statistical data, player heatmap data, and multimodal data integration through Early Fusion, Late Fusion, and heatmap conversion into structured numerical data based on field segmentation. The results revealed that the CNN model using statistical data combined with heatmap-based positional data divided into four field zones achieved the highest test accuracy at 63.50%, and consistently outperformed other models in terms of precision, recall, and F1 score. Furthermore, feature importance was analyzed using the SHAP (SHapley Additive exPlanations) technique, which indicated that defensive features of the home team, such as blocks, clearances, and aerial duel won, had the greatest influence on model prediction. In contrast, the positional features of the away team were found to have the least impact. These findings can be applied to the development of tactical analytics systems to support strategic decision-making and match preparation for football teams.

Keywords: Football Result Prediction, Statistical Analysis, Heatmap, Deep Learning

CITATION INFORMATION: Punpruksa, B. (2025). A Comparative Study of Football Match Outcome Predictions Using Deep Learning by Combining Statistical Data and Player Heatmaps. *Procedia of Multidisciplinary Research*, 3(10), 22

การเปรียบเทียบการทำนายผลการแข่งขันฟุตบอลโดยใช้การเรียนรู้เชิงลึก จากการผสมผสานข้อมูลทางสถิติ และแผนที่ความร้อนของผู้เล่น

ภาณุพันธุ์ พันธุ์พฤษฯ¹

1 คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย; 6680293826@student.chula.ac.th

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง MLP, CNN และ Multimodal Neural Network (MMNN) ในการทำนายผลการแข่งขันฟุตบอลพรีเมียร์ลีกอังกฤษ โดยใช้ข้อมูลทางสถิติ ข้อมูลแผนที่ความร้อนของผู้เล่น และการผสมผสานข้อมูลทั้งสองรูปแบบ ผ่านแนวทาง Early Fusion, Late Fusion และการแปลง Heatmap เป็นข้อมูลเชิงตัวเลขแบบแบ่งพื้นที่สนาม ผลการวิจัยพบว่า แบบจำลอง CNN ที่ใช้ข้อมูลทางสถิติร่วมกับข้อมูลตำแหน่งเชิงพื้นที่จากแผนที่ความร้อนที่แบ่งสนามออกเป็น 4 ส่วน มีค่าความแม่นยำสูงสุดที่ 63.50% และให้คะแนน Precision, Recall และ F1 Score สูงกว่าแบบจำลองอื่นๆ อย่างต่อเนื่อง นอกจากนี้ ยังได้วิเคราะห์ความสำคัญของฟีเจอร์ด้วยเทคนิค SHAP ซึ่งชี้ให้เห็นว่าฟีเจอร์ที่เกี่ยวข้องกับเกมรับของทีมเหย้า เช่น การบล็อก การเคลียร์บอล และการดวลลูกกลางอากาศ มีผลต่อการทำนายมากที่สุด ขณะที่ตำแหน่งของผู้เล่นทีมเยือนมีอิทธิพลน้อยที่สุด ผลการศึกษานี้สามารถนำไปประยุกต์ใช้ในการออกแบบระบบวิเคราะห์เชิงกลยุทธ์ เพื่อช่วยในการวางแผนการแข่งขันและปรับปรุงกลยุทธ์ของทีมในเชิงลึกต่อไป

คำสำคัญ: การทำนายผลฟุตบอล, การวิเคราะห์เชิงสถิติ, แผนที่ความร้อน, การเรียนรู้เชิงลึก

ข้อมูลการอ้างอิง: ภาณุพันธุ์ พันธุ์พฤษฯ. (2568). การเปรียบเทียบการทำนายผลการแข่งขันฟุตบอลโดยใช้การเรียนรู้เชิงลึกจากการผสมผสานข้อมูลทางสถิติ และแผนที่ความร้อนของผู้เล่น. *Procedia of Multidisciplinary Research*, 3(10),

บทนำ

การแข่งขันฟุตบอลเป็นกีฬาที่ได้รับความนิยมสูงสุดในระดับโลก โดยเฉพาะพรีเมียร์ลีกอังกฤษ (English Premier League) ที่มีทั้งจำนวนแฟนบอล การลงทุน และข้อมูลสถิติที่ครอบคลุม ทำให้แต่ละแมตช์ไม่เพียงเป็นกิจกรรมกีฬา แต่ยังเป็นแหล่งข้อมูลเชิงลึกที่สามารถนำมาวิเคราะห์เพื่อวางแผนเชิงกลยุทธ์และพัฒนาแบบจำลองการทำนายผลการแข่งขัน ปัจจุบันเทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะ Machine Learning และ Deep Learning ได้ถูกนำมาใช้กับข้อมูลสถิติและผลการแข่งขันในอดีต แต่ยังคงขาดการศึกษาเกี่ยวกับการใช้ข้อมูลตำแหน่งผู้เล่นผ่านแผนที่ความร้อน (Heatmap) และวิธีการผสานข้อมูล เช่น Early Fusion, Late Fusion หรือการแปลง Heatmap เป็นข้อมูลเชิงตัวเลข จากบริบทนี้ งานวิจัยมุ่งเปรียบเทียบประสิทธิภาพของแบบจำลอง MLP (Multilayer Perceptron), CNN (Convolutional Neural Network) และ MMNN (Multimodal Neural Network) ในการทำนายผลการแข่งขันฟุตบอล โดยมีการเปรียบเทียบการใช้ข้อมูลประเภทต่างๆ ได้แก่ ข้อมูลทางสถิติ ข้อมูลแผนที่ความร้อน และการผสานข้อมูลทั้งสองประเภท ผ่านวิธี Early Fusion, Late Fusion และการแปลง Heatmap เป็นตัวเลขแบบแบ่งพื้นที่สนาม งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพของแบบจำลองแต่ละประเภทในการทำนายผลการแข่งขันฟุตบอล วิเคราะห์ผลของการใช้ข้อมูลประเภทต่างๆ และวิธีการผสานข้อมูลต่อความแม่นยำของแบบจำลอง และวิเคราะห์ความสำคัญของฟีเจอร์ที่มีผลต่อการทำนายของแบบจำลองผ่านเทคนิค SHAP (SHapley Additive exPlanations) เพื่อนำเสนอแนวทางพัฒนาแบบจำลองที่มีประสิทธิภาพ และเป็นเครื่องมือสนับสนุนการตัดสินใจเชิงกลยุทธ์ในวงการฟุตบอลต่อไป

การทบทวนวรรณกรรม

ในช่วงที่ผ่านมา มีความพยายามในการทำนายผลการแข่งขันฟุตบอลหลากหลายรูปแบบ งานวิจัยหลายชิ้นได้ประยุกต์ใช้แบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) เพื่อทำนายผลการแข่งขันฟุตบอลในพรีเมียร์ลีกอังกฤษ และลีกยุโรปอื่นๆ โดย (Pugsee & Pattawong, 2019) ได้นำข้อมูลเชิงสถิติต่างๆ รวมถึงบทวิเคราะห์จากผู้เชี่ยวชาญ มาประยุกต์ใช้ในการทำนายผลการแข่งขัน พบว่าแบบจำลองป่าสุ่ม (Random Forest) ให้ความแม่นยำ (Accuracy) สูงสุดที่ 70% ต่อมา (Kusmakar et al., 2020) ได้นำแบบจำลอง เวกเตอร์สนับสนุน (Support Vector Machine: SVM) มาประยุกต์ใช้ร่วมกับข้อมูลเรียลไทม์การครองบอล ในการทำนายผลการแข่งขัน โดยได้ผลลัพธ์ที่ความแม่นยำ 81.9% หลังจากขยายขอบเขตข้อมูลเป็น 1,941 แมตช์ (Beal et al., 2021) ได้นำข้อมูลเชิงสถิติและบทวิเคราะห์ผู้เชี่ยวชาญมาใช้ร่วมกับแบบจำลองป่าสุ่ม (Random Forest) และได้ผลลัพธ์ความแม่นยำที่ 63.19% (Rodrigues & Pinto, 2022) ได้ศึกษาข้อมูลการแข่งขันจำนวน 1,900 นัด และพบว่าแบบจำลองป่าสุ่ม (Random Forest) ให้ความแม่นยำที่ 65.26% (Chazan-Pantzalisb & Tjortjis, 2022) ได้วิเคราะห์ข้อมูลทีมและผู้เล่นในลีกยุโรป 4 ลีกใหญ่ โดยให้ความแม่นยำสูงสุดที่แตกต่างกันไปในแต่ละลีก นอกจากนี้ (Radhika & Masood, 2022) ได้ใช้แบบจำลอง รีเกรสชันโลจิสติก (Logistic Regression) ในการทำนายตารางคะแนนพรีเมียร์ลีก โดยได้ความแม่นยำเกิน 80%

นอกจากแบบจำลองการเรียนรู้ของเครื่องแล้วยังมีบางงานวิจัยที่ใช้ การเรียนรู้เชิงลึก (Deep Learning) โดย (Rahman, 2020) ได้นำเสนอการทำงานเพื่อทำนายผลการแข่งขันฟุตบอลระดับนานาชาติ โดยใช้แบบจำลอง โครงข่ายประสาทเทียมเชิงลึก (Deep Neural Networks) และ โครงข่ายประสาทเทียมทั่วไป (Artificial Neural Networks) ซึ่งใช้ชุดข้อมูลต่างๆ รวมถึงอันดับ ผลงานของทีม และผลการแข่งขันที่ผ่านมา แบบจำลองนี้วิเคราะห์ข้อมูลการกีฬา เพื่อสร้างการทำนายที่แม่นยำ โดยคำนึงถึงปัจจัยต่างๆ เช่น ผลงานของทีม การเปลี่ยนแปลงผู้เล่นล่าสุด (Recent Player Changes) และสถานที่แข่งขัน (Venue) เมื่อใช้สถาปัตยกรรม DNN กับการแข่งขันฟุตบอลโลก (FIFA World Cup 2018) พบว่าสามารถทำนายความแม่นยำได้ 63.3%

หลังจากนั้น (Satyapanich & Somkheawwan, 2023) ได้เปรียบเทียบแบบจำลอง โพรเซปตรอนหลายชั้น (Multilayer Perceptron) และ โครงข่ายคอนโวลูชันนัล (Convolutional Neural Networks) ในการทำนายผลการแข่งขันฟุตบอลใน

พรีเมียร์ลีกอังกฤษ โดยวิเคราะห์ข้อมูลการแข่งขันที่ผ่านมาโดยไม่พิจารณาข้อมูลของเกมปัจจุบัน พบว่าแบบจำลอง CNN ให้ความแม่นยำ 55.31% และหากทำนายเฉพาะผลชนะของทีมเจ้าบ้าน จะให้ความแม่นยำถึง 71.52% ซึ่งมากกว่าอัตราความแม่นยำของผู้เชี่ยวชาญ งานวิจัยนี้ใช้ข้อมูลจากฤดูกาล 2018-2022 ที่รวบรวมจากเว็บไซต์ FotMob.com โดยใช้ค่าสถิติต่างๆ ของทั้งสองทีม เช่น การครองบอล (Ball Possession), การจ่ายบอล (Passing), การยิงทั้งหมด (Total Shots) และผลงานของผู้เล่นที่เฉลี่ยจากการแข่งขัน 5 นัดที่ผ่านมา

สมมติฐานการวิจัย

- 1) การใช้ข้อมูลทางสถิติของทีมและผู้เล่นร่วมกับข้อมูลแผนที่ความร้อนของผู้เล่น จะช่วยเพิ่มความแม่นยำในการทำนายผลการแข่งขันฟุตบอลได้
- 2) แบบจำลองการเรียนรู้เชิงลึก Multimodal Neural Networks (MMNNs) โดยองค์ประกอบหลักคือ Convolutional Neural Networks (CNNs) สามารถประมวลผลข้อมูลทั้งสองประเภทนี้ได้อย่างมีประสิทธิภาพ และให้ผลลัพธ์ที่แม่นยำกว่าการใช้ข้อมูลทางสถิติหรือแผนที่ความร้อนเพียงอย่างเดียว
- 3) การใช้เทคนิคการรวมข้อมูลแบบ Early Fusion หรือ Late Fusion จะส่งผลต่อประสิทธิภาพและความแม่นยำในการทำนายผลการแข่งขันฟุตบอลที่แตกต่างกัน

วิธีดำเนินการวิจัย

การวิจัยครั้งนี้เป็นการวิจัยเชิงปริมาณ (Quantitative Research) โดยใช้วิธีการทดลอง (Experimental Method) ร่วมกับการวิเคราะห์ข้อมูลเชิงปริมาณจากชุดข้อมูลทุติยภูมิ (Secondary Data) ที่ได้จากการแข่งขันฟุตบอลพรีเมียร์ลีกอังกฤษ (English Premier League) ฤดูกาล 2018-2023 รวมจำนวน 5 ฤดูกาล ประชากรที่ใช้ในการวิจัย คือ แมตช์การแข่งขันในพรีเมียร์ลีกทั้งหมดในช่วงเวลาดังกล่าว โดยมีการคัดเลือกเฉพาะแมตช์ที่มีข้อมูลครบถ้วนทั้งในส่วนของ ข้อมูลทางสถิติของทีม และ แผนที่ความร้อนของผู้เล่น (Player Heatmap) ทั้งทีมเหย้าและทีมเยือน รวมถึงผลการแข่งขันเป็นหมวดหมู่ (ชนะ / เสมอ / แพ้) รวมทั้งสิ้น 1,900 แมตช์ ในการออกแบบโมเดลและประเมินผลการทำนาย ใช้วิธีการ แบ่งชุดข้อมูลออกเป็น 2 ชุด ได้แก่ ชุดฝึก (Training Set) และชุดทดสอบ (Test Set) โดยใช้วิธีแบ่งตามช่วงเวลา (Time-Based Split) คือ ใช้ข้อมูลจาก 4 ฤดูกาลแรก (2018-2022) สำหรับฝึกโมเดล และใช้ข้อมูลจากฤดูกาลล่าสุด (2022-2023) สำหรับทดสอบโมเดล

แบบจำลองที่พัฒนาขึ้นในการวิจัยนี้ ได้แก่ แบบจำลอง MLP (Multilayer Perceptron), แบบจำลอง CNN (Convolutional Neural Network) และแบบจำลอง MMNN (Multimodal Neural Network) ที่ใช้การรวมข้อมูลแบบต้น (Early Fusion) และการรวมข้อมูลแบบปลาย (Late Fusion) โดยใช้ข้อมูล 4 รูปแบบ ได้แก่ 1) ข้อมูลทางสถิติของทีม, 2) ข้อมูลแผนที่ความร้อนแบบภาพ (Heatmap Image), 3) ข้อมูลแผนที่ความร้อนที่ถูกแปลงเป็นข้อมูลเชิงตัวเลข (โดยแบ่งพื้นที่สนามเป็น 2 หรือ 4 ส่วน) และ 4) การผสานข้อมูลระหว่างสถิติและแผนที่ความร้อนด้วยเทคนิค Early Fusion และ Late Fusion

สำหรับข้อมูลทางสถิติที่ใช้ในงานวิจัยนี้ได้มาเว็บไซต์ <http://www.fotmob.com> สำหรับข้อมูลเชิงสถิติ และเว็บไซต์ <http://www.sofascore.com> สำหรับข้อมูลแผนที่ความร้อน ซึ่งข้อมูลทางสถิติครอบคลุมทั้งเกมรุก เกมรับ และพฤติกรรมของผู้เล่น เช่น การยิงประตู (Shots), การส่งบอล (Passes), การครองบอล (Ball Possession), การป้องกัน (Tackles, Clearances) และการทำฟาวล์ เป็นต้น รายละเอียดของตัวชี้วัดถูกแสดงไว้ใน ตารางที่ 1 การประเมินประสิทธิภาพของแบบจำลอง ใช้การวัดค่าความแม่นยำ (Accuracy), ค่าความเที่ยงตรง (Precision), ค่าความระลึก (Recall), คะแนน F1 (F1 Score) และ เวลาในการประมวลผล (Training Time) ซึ่งข้อมูลที่ใช้ในการฝึกโมเดลจะเป็นข้อมูลการแข่งขันของทีมแต่ละทีม ตั้งแต่ 1 แมตช์ก่อนหน้า จนถึง 5 แมตช์ก่อนหน้า สำหรับทั้งทีมเหย้าและทีมเยือน เพื่อศึกษาผลของการแข่งขันก่อนหน้าต่อความสามารถในการทำนายผลการแข่งขันปัจจุบัน โดยการทดลองในลักษณะนี้ถูกนำไปใช้กับแบบจำลองทั้ง MLP, CNN และ MMNN ในทุกรูปแบบข้อมูล

ตารางที่ 1 ความหมายของตัวชี้วัด และค่าของตัวชี้วัดในนัดแรกของทีมเชลซีที่ลงเล่นในฤดูกาล 2018-2019

ตัวชี้วัด	คำอธิบาย	ตัวอย่างข้อมูล
Ball possession	ร้อยละระยะเวลาที่ทีมครอบครองบอลระหว่างการแข่งขัน	63%
Total shots	จำนวนครั้งที่ทีมพยายามทำประตู	7
Shots on target	จำนวนครั้งที่ทีมพยายามทำประตูและตรงกรอบ	4
Big chances	โอกาสในการทำประตูที่ถือว่ามีความน่าจะเป็นสูงที่จะกลายเป็นประตู	3
Big chances missed	โอกาสในการทำประตูที่ไม่สามารถเปลี่ยนเป็นประตูได้	1
Accurate passes	ร้อยละของจำนวนครั้งที่ส่งบอลสำเร็จและแม่นยำจากผู้เล่นคนหนึ่งไปยังอีกคนหนึ่ง	88%
Fouls committed	จำนวนครั้งที่เกิดการฟาวล์เมื่อผู้เล่นละเมิดกติกาการแข่งขัน	8
Corners	จำนวนครั้งของการเตะมุม	5
Accurate long balls	จำนวนครั้งของการส่งบอลระยะไกลที่ทำได้อย่างแม่นยำ	29
Accurate crosses	จำนวนครั้งของการส่งบอลที่ทำได้จากพื้นที่ด้านกว้างเข้าสู่เขตโทษของฝ่ายตรงข้าม	5
Throws	จำนวนครั้งของทุ่มบอลจากข้างสนาม	27
Offsides	จำนวนครั้งที่มีการล้ำหน้าในเกม	1
Tackles won	จำนวนครั้งที่ผู้เล่นแย่งบอลจากคู่ต่อสู้สำเร็จเพื่อควบคุมบอลกลับมา	6
Interceptions	การกระทำในเชิงป้องกันที่ผู้เล่นใช้เพื่อขัดขวางและควบคุมการส่งบอลหรือการเคลื่อนที่ของบอลที่ฝ่ายตรงข้ามตั้งใจ	9
Blocks	การกระทำที่ผู้เล่นใช้เพื่อขัดขวางการยิง การส่งบอล หรือการครองบอลของฝ่ายตรงข้าม	0
Clearances	การกระทำในเชิงป้องกันที่ผู้เล่นใช้เพื่อเตะหรือโหม่งบอลออกจากเขตประตูของตนเอง	21
Keeper saves	จำนวนครั้งที่ผู้รักษาประตูป้องกันไม่ให้ฝ่ายตรงข้ามทำประตูได้	1
Ground duels won	จำนวนครั้งที่ผู้เล่นชนะการปะทะเพื่อแย่งบอลจากฝ่ายตรงข้ามขณะที่บอลอยู่บนพื้น	36
Aerial duels won	จำนวนครั้งที่ผู้เล่นชนะการดวลลูกกลางอากาศกับฝ่ายตรงข้ามได้สำเร็จ	17
Successful dribbles	จำนวนครั้งที่ผู้เล่นสามารถผ่านคู่ต่อสู้ด้วยทักษะการเลี้ยงบอล	17

ผลการวิจัย

ผลการวิเคราะห์ข้อมูลเชิงสถิติและข้อมูลแผนที่ความร้อน ของการแข่งขันฟุตบอลพรีเมียร์ลีกอังกฤษ พบว่า แบบจำลองที่ใช้ ได้แก่ MLP, CNN และ MMNN มีประสิทธิภาพแตกต่างกันตามลักษณะของข้อมูลและวิธีผสานข้อมูล ดังนี้

- 1) แบบจำลองที่ใช้ข้อมูลทางสถิติเพียงอย่างเดียว พบว่า CNN มีความแม่นยำเฉลี่ยสูงกว่า MLP เล็กน้อย โดยได้ Test Accuracy 54.05% และ 52.70% ตามลำดับ
- 2) แบบจำลองที่ใช้ข้อมูลแผนที่ความร้อนเพียงอย่างเดียว พบว่า CNN ให้ผลต่ำสุด สะท้อนว่าข้อมูล heatmap เพียงอย่างเดียวอาจไม่เพียงพอต่อการทำนายผลการแข่งขัน
- 3) การผสานข้อมูลเชิงตัวเลขและ heatmap พบว่า Late Fusion มีความแม่นยำสูงกว่า Early Fusion (55.68% กับ 53.24% ตามลำดับ)
- 4) การแปลง heatmap ให้อยู่ในรูปแบบเชิงตัวเลข โดยแบ่งสนามเป็น 2 และ 4 ส่วน แล้วรวมกับข้อมูลสถิติ พบว่า การแบ่งเป็น 4 ส่วนให้ผลดีที่สุด โดย CNN รวมข้อมูลสถิติและตำแหน่งสนามแบบ 4 ส่วน มีความแม่นยำสูงสุดที่ 63.50% ในด้าน Precision, Recall และ F1-Score พบว่า CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่ง

ออกเป็น 4 บริเวณ ให้ค่า Precision สูงสุดในกลุ่ม “ชนะ” และ “เสมอ” รวมถึง Recall สูงสุดในกลุ่ม “แพ้” และได้ F1-Score สูงสุดในทุกกลุ่ม แสดงให้เห็นว่าการผสมข้อมูลเชิงตัวเลขกับตำแหน่งแบบมีโครงสร้างช่วยเพิ่มประสิทธิภาพของโมเดลได้อย่างชัดเจน ดังแสดงในตารางที่ 2 ถึง 5

นอกจากนี้ ยังได้มีการวิเคราะห์ความสำคัญของคุณลักษณะ (Feature Importance) โดยใช้เทคนิค SHAP (SHapley Additive exPlanations) เพื่อทำความเข้าใจว่าพีเจอรใดมีผลต่อการตัดสินใจของแบบจำลองมากที่สุด โดยผลการวิเคราะห์พบว่า พีเจอรเกมรับของทีมเหย้า เช่น Home_Blocks_last5, Home_Clearances_last5 และ Home_Aerial Duels Won_last5 เป็นปัจจัยสำคัญอันดับต้นๆ ที่มีผลต่อการทำนายผลการแข่งขัน สะท้อนว่าแบบจำลองให้ความสำคัญกับประสิทธิภาพในการป้องกันของทีมเจ้าบ้านอย่างมีนัยสำคัญ ในทางกลับกัน พีเจอรที่มีผลกับการตัดสินใจน้อยที่สุด ได้แก่ Away_Opponent Final Third Ratio_last5, Away_Own Final Third Ratio_last5 และ Away_Own Midfield Ratio_last5 ซึ่งส่วนใหญ่เป็นพีเจอรที่เกี่ยวข้องกับการกระจายตำแหน่งของผู้เล่นทีมเยือน ในพื้นที่สนาม ดังแสดงในภาพที่ 1 ซึ่งแสดงให้เห็นว่าการเคลื่อนที่ในพื้นที่ของทีมเยือนไม่ใช่ปัจจัยสำคัญที่ส่งผลต่อการตัดสินใจผลการแข่งขันในโมเดลนี้

ตารางที่ 2 ผลการเปรียบเทียบค่าความแม่นยำ (Accuracy) และเวลาที่ใช้ในการฝึกของแบบจำลองที่มีประสิทธิภาพสูงสุดในแต่ละประเภท

แบบจำลอง	จำนวนแมทช์	ค่าความแม่นยำ (%)	เวลาที่ใช้ฝึก (นาที)
MLP ที่ใช้ข้อมูลทางสถิติเท่านั้น	5	52.70	80.10
CNN ที่ใช้ข้อมูลทางสถิติเท่านั้น	5	54.05	85.56
CNN ที่ใช้ข้อมูลแผนที่ความร้อนเท่านั้น	2	32.43	46.26
Early Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	5	53.24	610.22
Late Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	5	55.68	603.13
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	5	51.35	108.24
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	5	52.70	108.78
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	5	58.11	108.06
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	5	63.51	138.66

ตารางที่ 3 ผลการเปรียบเทียบค่าเที่ยงตรง (Precision) ของแบบจำลองที่มีประสิทธิภาพสูงสุดในแต่ละประเภท


แบบจำลอง	ชนะ	เสมอ	แพ้
MLP ที่ใช้ข้อมูลทางสถิติเท่านั้น	59.54%	51.66%	47.54%
CNN ที่ใช้ข้อมูลทางสถิติเท่านั้น	65.96%	0.00%	45.85%
CNN ที่ใช้ข้อมูลแผนที่ความร้อนเท่านั้น	0.00%	0.00%	32.43%
Early Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	60.61%	60.00%	46.28%
Late Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	62.85%	62.75%	48.35%
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	53.29%	43.13%	49.86%
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	60.94%	51.85%	48.11%
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	61.70%	65.22%	54.29%
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	69.44%	81.25%	56.15%

ตารางที่ 4 ผลการเปรียบเทียบค่าความระลึก (Recall) ของแบบจำลองที่มีประสิทธิภาพสูงสุดในแต่ละประเภท

แบบจำลอง	ชนะ	เสมอ	แพ้
MLP ที่ใช้ข้อมูลทางสถิติเท่านั้น	45.61%	37.97%	72.50%
CNN ที่ใช้ข้อมูลทางสถิติเท่านั้น	54.39%	0.00%	87.50%
CNN ที่ใช้ข้อมูลแผนที่ความร้อนเท่านั้น	0.00%	0.00%	100.00%
Early Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	46.78%	37.97%	72.50%
Late Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	50.29%	40.51%	73.33%
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	45.24%	34.15%	72.71%
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	45.88%	35.44%	75.42%
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	52.63%	38.46%	78.69%
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	58.68%	32.50%	90.83%

ตารางที่ 5 ผลการเปรียบเทียบคะแนน F1 (F1-Score) ของแบบจำลองที่มีประสิทธิภาพสูงสุดในแต่ละประเภท

แบบจำลอง	ชนะ	เสมอ	แพ้
MLP ที่ใช้ข้อมูลทางสถิติเท่านั้น	51.66%	44.49%	57.42%
CNN ที่ใช้ข้อมูลทางสถิติเท่านั้น	59.60%	0.00%	59.90%
CNN ที่ใช้ข้อมูลแผนที่ความร้อนเท่านั้น	0.00%	0.00%	48.96%
Early Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	52.83%	46.50%	56.49%
Late Fusion ที่ใช้ข้อมูลทางสถิติและแผนที่ความร้อน	55.83%	49.24%	58.29%
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	48.98%	38.07%	59.17%
MLP ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	52.38%	41.94%	58.59%
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 2 บริเวณ	56.79%	48.39%	57.93%
CNN ที่รวมข้อมูลทางสถิติกับข้อมูลตำแหน่งในสนามที่แบ่งออกเป็น 4 บริเวณ	63.50%	46.51%	69.29%



ภาพที่ 1 แสดง SHAP value ซึ่งใช้วัดความสำคัญของตัวแปรต่อการทำนายผลการแข่งขันของแบบจำลอง CNN ที่ใช้เป็นข้อมูลย้อนหลัง 5 แมตช์ โดยแสดงเฉพาะ 5 ฟีเจอร์ที่มีผลกับแบบจำลองมากที่สุด และน้อยที่สุด

สรุปและอภิปรายผลการวิจัย

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง MLP, CNN และ Multimodal Neural Network (MMNN) ในการทำนายผลการแข่งขันฟุตบอลพรีเมียร์ลีกอังกฤษ โดยใช้ข้อมูลทางสถิติ ข้อมูลแผนที่ความร้อน และเทคนิคการผสมข้อมูลในรูปแบบต่างๆ ผลการวิจัยสามารถอภิปรายได้ดังนี้

1) แบบจำลอง CNN ที่ผสมข้อมูลทางสถิติกับตำแหน่งของผู้เล่นในสนาม ซึ่งถูกแปลงจากแผนที่ความร้อนและแบ่งพื้นที่ออกเป็น 4 ส่วน ให้ผลการทำนายที่แม่นยำที่สุด โดยมีค่าความแม่นยำ (Accuracy) สูงถึง 63.50% ซึ่งสอดคล้องกับสมมติฐานที่ตั้งไว้ เนื่องจากแบบจำลอง CNN มีความสามารถในการเรียนรู้ลักษณะเชิงพื้นที่ (spatial structure) ได้ดี ประกอบกับการแบ่งพื้นที่สนามอย่างมีโครงสร้าง ช่วยให้โมเดลสามารถแยกแยะพฤติกรรมการเล่นของแต่ละทีมได้อย่างมีประสิทธิภาพมากยิ่งขึ้น ทั้งในเชิงรุกและเชิงรับ

2) การใช้ SHAP (SHapley Additive exPlanations) เพื่อวิเคราะห์ความสำคัญของฟีเจอร์ พบว่า ฟีเจอร์ที่เกี่ยวข้องกับเกมรับของทีมเหย้า เช่น จำนวนการบล็อก, การเคลียร์บอล และการดวลลูกกลางอากาศที่ชนะ มีอิทธิพลอย่างมากต่อการทำนายของแบบจำลอง ทำให้เข้าใจได้ว่าแบบจำลองเรียนรู้อะไรและให้ความสำคัญกับส่วนใดของข้อมูล

3) ผลการเปรียบเทียบระหว่างเทคนิคการผสมข้อมูล Early Fusion และ Late Fusion พบว่า Late Fusion ให้ผลลัพธ์ที่ดีกว่าในภาพรวม ทั้งในด้านค่าความแม่นยำ ค่าความเที่ยงตรง และค่า F1 Score ซึ่งแสดงให้เห็นว่า การให้โมเดลย่อยเรียนรู้จากแต่ละโมดัลแยกกันก่อนแล้วจึงรวมผลลัพธ์ เป็นแนวทางที่เหมาะสมกับข้อมูลที่มีโครงสร้างแตกต่างกัน

4) ผลการวิจัยครั้งนี้สอดคล้องกับแนวทางของงานวิจัยในด้าน Multimodal Learning หลายฉบับ เช่น Ngiam et al. (2011) และ Baltrušaitis et al. (2019) ที่ชี้ว่า การผสมข้อมูลอย่างเหมาะสมสามารถเพิ่มประสิทธิภาพของโมเดลได้อย่างมีนัยสำคัญ โดยเฉพาะเมื่อข้อมูลแต่ละประเภทมีลักษณะแตกต่างกันอย่างชัดเจน

โดยสรุป งานวิจัยนี้แสดงให้เห็นว่า การออกแบบแบบจำลองเชิงลึกที่เหมาะสมกับลักษณะข้อมูล และการเลือกเทคนิคการผสมข้อมูลที่เหมาะสม มีผลอย่างมากต่อความสามารถของโมเดลในการทำนายผลการแข่งขันฟุตบอล และยังสามารถต่อยอดเป็นเครื่องมือเชิงกลยุทธ์เพื่อสนับสนุนการวิเคราะห์เกมในระดับทีมอาชีพได้อย่างมีประสิทธิภาพในอนาคต

ข้อเสนอแนะที่ได้รับจากการวิจัย

จากผลการวิจัยเรื่องการเปรียบเทียบการทำนายผลการแข่งขันฟุตบอลโดยใช้การเรียนรู้เชิงลึกจากการผสมข้อมูลทางสถิติและแผนที่ความร้อนของผู้เล่น พบว่าการใช้ข้อมูลแผนที่ความร้อนที่ถูกแปลงเป็นเชิงตัวเลขแบบแบ่งพื้นที่สนาม

สามารถเพิ่มประสิทธิภาพของแบบจำลองได้ดี โดยเฉพาะในแบบจำลอง CNN เมื่อแบ่งสนามออกเป็น 4 ส่วน เพื่อให้การวิจัยในอนาคตสามารถพัฒนาแบบจำลองได้แม่นยำและครอบคลุมยิ่งขึ้น ผู้วิจัยมีข้อเสนอแนะดังนี้

- 1) ด้านการใช้ข้อมูลเชิงสถิติ ข้อมูลสถิติมีผลต่อความแม่นยำของการทำนายอย่างชัดเจน โดยแบบจำลอง CNN สามารถดึงคุณลักษณะเชิงลึกจากข้อมูลสถิติได้ดีกว่า MLP ดังนั้นผู้วิจัยและผู้พัฒนาระบบควรให้ความสำคัญกับการเก็บข้อมูลสถิติที่ถูกต้อง ครบถ้วน และมีความละเอียด จะช่วยเพิ่มประสิทธิภาพการทำนายและลดเวลาในการประมวลผล
- 2) ด้านการใช้ข้อมูลแผนที่ความร้อน (Heatmap) การใช้ข้อมูล heatmap เพียงอย่างเดียวให้ความแม่นยำต่ำที่สุด แสดงให้เห็นว่าข้อมูลตำแหน่งผู้เล่นต้องมีการปรับรูปแบบให้อยู่ในเชิงตัวเลขที่มีโครงสร้าง (Structured Numerical Features) เพื่อให้โมเดลเรียนรู้ได้ง่ายขึ้น ผู้วิจัยแนะนำให้ใช้การแบ่งสนามเป็นหลายส่วน (เช่น 4 บริเวณ) เนื่องจากผลการทดลองพบว่าช่วยเพิ่มความแม่นยำของโมเดลได้อย่างมีนัยสำคัญ
- 3) ด้านการผสมผสานข้อมูล (Data Fusion) การผสมผสานข้อมูล Late Fusion ให้ผลลัพธ์ดีกว่า Early Fusion โดยการประมวลผลข้อมูลแต่ละประเภทแยกกันก่อนนำมารวม ผู้วิจัยแนะนำให้ใช้วิธีนี้ในการรวมข้อมูลสถิติกับข้อมูลตำแหน่งผู้เล่นเพื่อเพิ่มประสิทธิภาพการพยากรณ์
- 4) ด้านการประเมินผลหลายมิติ ไม่ควรพิจารณาเพียง Accuracy แต่ควรใช้ Precision, Recall และ F1-Score ร่วมด้วย เพื่อสะท้อนประสิทธิภาพโดยรวมของโมเดล โดยเฉพาะเมื่อข้อมูลไม่สมดุลระหว่างแต่ละคลาส

ข้อเสนอแนะในการวิจัยครั้งต่อไป

- 1) ควรศึกษาการใช้ข้อมูลตำแหน่งของผู้เล่นในรูปแบบที่ละเอียดมากขึ้น เช่น ตำแหน่งการยิง ความถี่ของการสัมผัสบอลในกรอบเขตโทษ หรือความหนาแน่นของผู้เล่นในแต่ละโซน เพื่อสร้างฟีเจอร์เชิงกลยุทธ์ (Tactical Features) ที่สามารถสะท้อนแนวโน้มการเล่นรุก-รับของแต่ละทีมได้อย่างชัดเจน
- 2) ควรเพิ่มขนาดชุดข้อมูล (Dataset Size) และเพิ่มความหลากหลายของลีกและฤดูกาล เช่น การนำข้อมูลจากลีกอื่น (เช่น ลา ลีกา บุนเดสลีกา หรือเซเรียอา) มาวิเคราะห์ร่วมกับพรีเมียร์ลีก เพื่อให้โมเดลสามารถเรียนรู้รูปแบบการเล่นที่หลากหลาย และมีความสามารถในการทำนายแบบครอบคลุม (Generalization) มากยิ่งขึ้น
- 3) ควรนำผลการวิจัยนี้ไปต่อยอดในด้านการวางกลยุทธ์ เช่น การวิเคราะห์จุดแข็ง-จุดอ่อนของทีมคู่แข่ง หรือการพัฒนาเครื่องมือช่วยวิเคราะห์การแข่งขัน เพื่อสนับสนุนการตัดสินใจในวงการฟุตบอลทั้งเชิงวิชาการและเชิงธุรกิจ

เอกสารอ้างอิง

- Beal, R., Middleton, S. E., Norman, T. J., & Ramchurn, S. D. (2021). Combining Machine Learning and Human Experts to Predict Match Outcomes in Football: A Baseline Model. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(17), 15447-15451.
- Baltrušaitis, T., Ahuja, C., & Morency, L. P. (2019). Multimodal Machine Learning: A Survey and Taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(2), 423-443.
- Chazan-Pantazis, V., & Tjortjis, C. (2020). *Sports Analytics for Football League Table and Player Performance Prediction*.
- Kusmakar, S., Shelyag, S., Zhu, Y., Dwyer, D., Gastin, P., & Angelova, M. (2020). Machine Learning Enabled Team Performance Analysis in the Dynamical Environment of Soccer. *IEEE Access*, 8, 90266-90279.
- Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., & Ng, A. (2011). *Multimodal Deep Learning*.
- Pugsee, P., & Pattawong, P. (2019). *Football Match Result Prediction Using the Random Forest Classifier*. Proceedings of the 2nd International Conference on Big Data Technologies, Jinan, China.

- Rahman, M. A. (2020). A deep learning framework for football match prediction. *SN Applied Sciences*, 2(2), 165.
- Rodrigues, F., & Pinto, Â. (2022). Prediction of football match results with Machine Learning. *Procedia Computer Science*, 204, 463-470.
- Satyapanich, T., & Somkheawwan, A. (2023, 14-15 Sept. 2023). *Predicting Game Results for Football League Using Deep Learning*. 2023 27th International Computer Science and Engineering Conference (ICSEC),

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Conflicts of Interest: The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's Note: All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.



Copyright: © 2025 by the authors. This is a fully open-access article distributed under the terms of the Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0).