

國立臺灣師範大學
理學院資訊工程學系

碩士論文

Department of Computer Science and Information Engineering

College of Science, National Taiwan Normal University

Master's Thesis

基於深度學習之籃球攻防戰術軌跡生成系統

Basketball Offense and Defense Strategy Movement

Trajectory Generation Based on Deep Learning

研究生：沈哲緯 撰

Shen, Jhe-Wei

指導教授：方瓊瑤 博士

Advisor: Fang, Chiung-Yao, Ph.D.

中華民國 一百一十二 年七月

July 2023

摘要

全球觀看籃球比賽的人數總計約超過 22 億人，根據外國媒體 Sports Show 在 2020 年公布全球最受歡迎的運動賽事，籃球在所有球類中排名第三，可看出籃球是一項非常熱門的運動。近年來運動分析的研究相當熱門，透過將生成對抗網路應用在籃球領域能夠幫助球隊提升籃球攻防戰術的素養，開發出基於深度學習之籃球攻防戰術軌跡生成系統。本系統開發目的為進攻球隊使用者在分析研究防守球隊可能會出現的防守方法時，通常只能使用經驗判斷推測，若透過本系統自動產生防守戰術軌跡供進攻球隊參考，進攻球隊可更加理解實戰中可能會遇到的防守戰術，可提升球員的戰術素養讓球隊提早思考應對方法。

本系統透過使用者將一段真實籃球比賽攻防片段輸入，系統主要分為兩個子系統：投影轉換子系統與防守戰術軌跡生成子系統。投影轉換子系統主要分為三個步驟，第一為球場上球員與球的偵測方法，接著界定球場的範圍。第二為場上球員分隊使用球衣顏色做為辨別的依據。接著為 3D 球員座標投影計算出單應矩陣將對應的 3D 座標映射在 2D 戰術板球場座標系中並記錄為檔案作為防守戰術軌跡生成子系統的輸入。最後一個步驟使用生成對抗網路來進行防守戰術軌跡生成。

本研究實驗結果顯示，透過影像處理得到球場邊線同時界定新的球場範圍可有效省略透過觀察手動決定球場頂點的步驟，減少時間成本。加入球員分隊的功能計算該區域內的色調特徵與顏色強度特徵，使用 *K-means clustering* 將該二類特徵將場上球員分成兩隊，以利最後映射至平面戰術板座標系還原出真實比賽的情況。映射結果的球員正確率達到了 77.2%，籃球則為 61.0%。本系統結合了真實籃球比賽片段與防守戰術軌跡生成系統產生虛擬的防守戰術軌跡。

關鍵字：籃球運動、攻防戰術、運動科技、影像處理、軌跡生成、投影轉換、生成對抗網路

Abstract

Basketball has a vast global audience of 2.2 billion, ranking as the third most popular sport. Recent sports analysis research leverages Generative Adversarial Networks (GANs) to develop a deep learning system for generating basketball offensive and defensive tactics. This system's aim is to provide offensive teams with auto-generated defensive tactics trajectories, improving understanding of potential defensive strategies, enhancing players' skills, and enabling more effective team strategies.

The system has two main subsystems: the Projection Transformation Subsystem and the Defensive Tactics Trajectories Generation Subsystem. The Projection Transformation Subsystem involves three steps: player and ball detection on the court, defining court boundaries, and distinguishing players based on jersey colors. 3D player coordinates are projected onto a 2D tactical board coordinate system via homography, and this data is used for the Defensive Tactics Trajectories Generation Subsystem, which employs Generative Adversarial Networks to generate defensive tactics trajectories.

Experimental results indicate that image processing for court boundaries and player teams significantly reduces time costs. The inclusion of the player team function enables calculation of region color and intensity features, with K -means clustering dividing players into teams for mapping to a flat tactical board coordinate system, replicating real game scenarios. Player mapping accuracy reached 77.2%, while basketball detection accuracy was 61.0%. This system combines real basketball game segments with the defensive tactics generation system to create virtual defensive tactics trajectories.

Keywords: Basketball, Offensive and defensive tactics, Sports technology, Image processing, Trajectory generation, Projection transformation, Generative Adversarial Networks

致謝

隨著論文即將完成，這兩年的研究所生涯也即將結束，深深感謝這一段旅程中給我非常多指導、幫助的老師同學。首先，我最感謝我的指導教授方瓊瑤教授，在過去兩年中，對我的耐心指導、鼓勵和建議指正，教導了我關於研究方面的知識，也常常關心我們的日常狀況。在論文寫作和研究實驗中有時遇到困難與問題時，會適時地引導我找到正確的方向，使研究可以順利進行，讓論文得以順利完成。

也特別感謝陳世旺教授，每週開會時總是會給予許多寶貴的建議和提問，提醒一些自己沒注意到的細節，老師對研究的熱情還有吸取新知識的態度讓我非常敬佩，也期許能學習老師的態度用在以後的工作與人生中。還要感謝口試委員黃仲誼博士、羅安鈞博士，在繁忙之中抽出時間提供寶貴建議，讓我研究不足的部分加以補充，使成果更加完善。

此外，我要感謝實驗室的學長姐們，包括博士班的孟霖學長，碩士班的皓中學長、后玲學姊、展毓學長，還有雅雯學姊，在學業上給了我很多建議與幫助。同時感謝同屆的同學育德、好涓和柏恩，在這兩年的時間給了我建議和陪伴，讓我在實驗室的日子而感到不那麼辛苦。也感謝實驗室的聖傑學弟、鈺瑄學弟和柏丞學弟，幫忙處理一些大小事。

最後要感謝我的家人，包括父母親與妹妹，在整個過程中給予支持和鼓勵，提供照顧讓我心無旁騖地完成碩士學業，將這篇論文獻給所有給予我幫助和鼓勵的人，謝謝你們的支持。

沈哲緯 謹致

國立臺灣師範大學 資訊工程學系研究所

中華民國 112 年 7 月

目錄

摘要	i
Abstract	ii
致謝	iii
目錄	iv
圖目錄	vi
表目錄	viii
第 1 章 緒論	1
第一節 籃球戰術簡介	2
第二節 研究動機與目的	3
第三節 研究困難	5
第四節 研究貢獻	6
第五節 論文架構	7
第 2 章 文獻探討	8
第一節 籃球進攻戰術	8
第二節 人體與物件偵測技術	13
第三節 移動軌跡偵測技術	17
第四節 籃球攻防戰術生成技術	19
第 3 章 籃球攻防戰術軌跡生成系統	23
第一節 系統流程	23
第二節 球員和球的偵測改良	28
第三節 球員分隊	29
第 4 章 實驗結果與討論	33
第一節 資料庫介紹與研究設備	33
第二節 球場範圍界定分析	33

第三節 球員分隊功能分析	36
第四節 3D 球員座標至 2D 戰術板座標系映射正確率	38
第五節 生成防守戰術軌跡結果	39
第 5 章 結論與未來工作	41
第一節 結論	41
第二節 未來工作	42
參考文獻	43



圖目錄

圖 1.1：部分知名球星.....	2
圖 1.2：戰術板.....	4
圖 1.3：比賽狀況圖.....	4
圖 2.1：進攻戰術示意圖(一).....	9
圖 2.2：進攻戰術示意圖(二).....	10
圖 2.3：進攻戰術示意圖(三).....	10
圖 2.4：進攻戰術示意圖(四).....	11
圖 2.5：進攻戰術示意圖(五).....	11
圖 2.6：進攻戰術示意圖(六).....	12
圖 2.7：進攻戰術示意圖(七).....	13
圖 2.8：Faster R-CNN 的主要架構.....	14
圖 2.9：Mask R-CNN 的主要架構.....	15
圖 2.10：以 Top-down 概念和跳躍連接技術所設計的 FPN 架構.....	16
圖 2.11：Janssen 提出之籃球球員與籃球位置自動標示系統範例示意圖.....	18
圖 2.12：Nguyen 等人提出的 Efficient Convolution Operators 架構圖.....	19
圖 2.13：Chen 等人提出之籃球攻防戰術範例.....	19
圖 2.14：Chen 等人提出之籃球攻防戰術模擬系統架構.....	20
圖 2.15：Hsieh 等人提出之籃球攻防戰術範例.....	21
圖 2.16：Hsieh 等人提出之籃球攻防戰術模擬系統架構.....	21
圖 3.1：系統總流程圖.....	24
圖 3.2：系統細節功能流程圖.....	24
圖 3.3：FPN(Feature Pyramid Network)架構圖.....	25
圖 3.4：球場影像物件偵測結果圖.....	25
圖 3.5：鳥瞰圖與頂點標示圖.....	26

圖 3.6：Chen 等人提出之籃球防守戰術軌跡生成子系統架構.....	27
圖 3.7：座標記錄檔案.....	27
圖 3.8：球場範圍界定範例圖.....	29
圖 3.9：球員分隊結果圖與色調值直方圖.....	30
圖 3.10：採用不同特徵之球員分隊範例.....	31
圖 3.11：不同聚類數之球員分隊測試.....	31
圖 4.1：球場範圍界定前後圖.....	33
圖 4.2：球場偵測失敗範例圖.....	34
圖 4.3：球場界定頂點前後範圍圖(一).....	35
圖 4.4：投影至平面戰術板坐標系圖(一).....	35
圖 4.5：球場界定頂點前後範圍圖(二).....	36
圖 4.6：投影至平面戰術板坐標系圖(二).....	36
圖 4.7：不同聚類數之球員分隊測試.....	37
圖 4.8：分隊過程與可視化.....	38
圖 4.9：籃球映射結果與 ground truth 比較結果圖.....	39
圖 4.10：真實情況與生成戰術比較圖.....	40

表目錄

表 1.1：全球最受歡迎球類估計人數.....	1
表 2.1：籃球進攻戰術中英文名稱對照以及執行人數列表	8
表 4.1：使用色調特徵與加上顏色強度特徵正確率前後比較	37
表 4.2：聚類數量選擇正確率之比較.....	37
表 4.3：聚類數量固定時加入相似程度正確率之比較.....	38
表 4.4：3D 球員座標至 2D 戰術板座標系映射正確率	39



第 1 章 緒論

籃球是一項非常吸引人的運動，根據外國媒體 Sports Show 在 2020 年公布全球最受歡迎的運動賽事 [1]，全球觀看籃球比賽的人數總計約超過 22 億人，在所有球類中排名第三，可看出其受歡迎程度(如表 1.1 所示)。其中職業籃球聯盟的比賽總是能吸引大量球迷的關注，每支不同的球隊都會有各自的支持者。目前國際業餘籃球協會 (FIBA) 已經擁有 178 個會員國，根據歷史競賽成績，美國一直是最具統治力的隊伍，被譽為「籃球王國」。

美國的 National Basketball Association (NBA) 職業聯賽在世界各國的職業聯賽中最為著名，NBA 職業籃球已經有 70 年的歷史，是世界上競技水準最高的職業籃球聯盟。在比賽中，球員展現各自不同的籃球攻防技巧，這些技巧的融合與運用展現出令人著迷且熱血沸騰的球賽，其部分知名職業聯賽籃球明星如 Michael Jordan[2]、Kobe Bryant[3]，分別如圖 1.1(a)、(b)所示，更是兼具籃球攻防技巧與個人魅力，吸引了數以百萬計的球迷。

表 1.1 全球最受歡迎球類估計人數 [1]。

排名	運動名稱	球迷人數估計
1	足球	35.0 億
2	板球	25.0 億
3	籃球	22.0 億
4	曲棍球	20.0 億
5	網球	10.0 億
6	排球	9.0 億
7	乒乓球	8.5 億
8	棒球	5.0 億
9	美式足球	4.1 億
10	高爾夫球	3.9 億

在台灣，近年籃球運動的發展也越來越蓬勃，目前國內有三個職業聯賽，分

別為 P. League+、T1 League、Super Basketball League(SBL)，每種職業籃球聯賽都有各自特色與球迷。在 2022 年 11 月更有史無前例的 NBA 現役球星 Dwight Howard[4](圖 1.1(c))加盟 T1 League 的桃園永豐雲豹隊[4]，2023 年前 NBA 台裔球星林書豪[5] (圖 1.1(d))也加盟了 P. League+的高雄鋼鐵人隊，讓台灣的籃球發展更加受到世界的矚目。




圖 1.1 部分知名球星。(a) Michael Jordan[2]，(b) Kobe Bryant[3]，
(c) Dwight Howard[4]，(d) 林書豪[5]。

第一節 籃球戰術簡介

籃球比賽由兩支隊伍各上場五名球員進行對抗，輪流進行攻防，持球隊伍為進攻方，透過將球投入防守方籃框來取得分數。球場上人數眾多且空間有限，因此進攻和防守戰術變得尤為重要。透過攻防戰術的應用，可以使球隊進攻更高效，也能讓防守變得更加地嚴密，取得更多優勢，甚至能在短時間內改變籃球比賽的情況。

籃球攻防戰術的定義為籃球比賽中隊員透過跑動與其他隊友相互配合，來形成有組織的進攻或防守，目的是為了更好的發揮自身球隊的特長或技巧，讓自身隊伍在比賽中取得優勢地位。而籃球攻防戰術又有很多種類，不同的攻防戰術又會衍生出不同的變化。值得一提的是有些特定的戰術，是針對特定類型的球員所設計。舉例而言，NBA 金州勇士隊的知名球星 Stephen Curry 因三分球神準，在三分線外只要有一點空檔便可以把籃球投進，故球隊的教練為 Curry 量身打造 Elevator(電梯戰術)，透過兩名隊友到罰球線兩側為 Curry 創造僅能有一個人通過的空間，Curry 通過後立刻把該空間擋住，順便擋住尾隨的防守者。由於 NBA 的防守通常採用人盯人戰術，所以電梯戰術利用隊友的掩護就能夠替 Curry 擺脫防守者，創造出良好的出手空間。

一般而言，籃球場上每位球員皆有各自功能性的位置，分別稱為控球後衛、得分後衛、小前鋒、大前鋒、中鋒。在攻防戰術的設計規劃中，不同位置的球員要完成特定的工作來幫助隊伍成功執行戰術。

第二節 研究動機與目的

前面提到籃球是團隊運動且籃球場上的攻防轉換快速且頻繁，所以透過不同球員之間的配合可以讓隊伍更加穩定的運作，這時進攻或防守的策略就會變得格外重要。透過各種攻防戰術的應用，可使進攻隊伍間配合更好且容易得分，也可讓防守隊伍更具壓迫性，讓對手難以取分。

在比賽中雙方實力勢均力敵的情況下，籃球攻防戰術的重要性將會扮演至關重要的角色，在關鍵時刻甚至可能會左右比賽最終的勝負。透過戰術的應用，可減少球員單打獨鬥的狀況，讓進攻與防守更加流暢因此，觀察學習籃球比賽中攻防轉換的內容是教練和球員不可或缺的訓練項目。

進攻球隊想得知進攻時防守球隊防守的方法，通常只能透過教練或球員自身的經驗判斷或臨場反應，並且在電子籃球戰術板(圖 1.2(a)或真實籃球戰術板(圖 1.2(b)表現出來。因為場上會有多位球員同時移動，所以要求教練使用雙手在戰術板上同時移動這麼多位球員的標示並不切實際，若以循序的方式展現則球員們會比較不易即時理解，因此，透過程式讀取場上所有球員的位置與移動方向並同時顯示在螢幕上會更好反映真實比賽情況。


另一方面，隨著影音科技的發展，越來越多的籃球比賽被拍攝並上傳到網路

平台，例如不同職業聯賽的比賽影片。而智慧型運動分析系統也越來越熱門，許多球隊都會觀察自身或對手的比賽錄像來分析擬定進攻或防守的策略。透過防守軌跡生成系統自動模擬生成在給定特定進攻戰術的條件下，提供適當可能的防守戰術，對於球員的訓練將會有事半功倍的效果。

綜上所述，本研究期望開發一套輸入籃球比賽片段，能夠自動地生成防守戰術的籃球攻防戰術軌跡生成系統。系統輸入一段真實的籃球比賽片段[5](圖 1.3(a))，產生與前者相同的進攻戰術條件下，生成防守戰術的平面戰術板片段[6](圖 1.3(b))，以期達到在特定的進攻戰術下，自動輸出對應的防守戰術供使用者作參考。



(a) (b)
圖 1.2 戰術板[3]。(a) 電子戰術板，(b) 真實戰術板。



(a) (b)
圖 1.3 比賽狀況圖。(a) 真實影像[5]，(b) 平面戰術板[6]。

第三節 研究困難

本研究因需對真實影片進行投影轉換座標，以擷取場中每位球員的位置，因此在場景的拍攝角度上要求較嚴格。拍攝時要求儘量避免遮擋掩蔽的情況發生，以期能正確辨識影像中之球員與球，得到正確的投影座標。以下為本研究需要解決的幾項主要問題：

1. 籃球比賽攻防戰術軌跡生成之參考文獻較少

本研究題目較為少見，目前較少籃球比賽攻防戰術自動偵測或軌跡生成的相關研究發表。因此在參考資料上，主要參酌應用於其他領域的深度學習技術，例如生成對抗網路，調整並改良使之能用於攻防戰術軌跡生成系統。另外，部份將真實的籃球比賽透過平面轉換為平面的球員移動軌跡參考資料[Moh9]的準確率也並不高，相關文獻將於第二章中詳細說明。

2. 影像中籃球不易正確偵測

在真實的籃球比賽過程中要時刻都正確偵測到籃球具相當難度。在攝影機的位置固定的情況下，就算鏡頭的拍攝角度能進行調整，球員仍可能會背對著鏡頭持球或運球，此時籃球會被球員身體遮擋造成無法正確辨識，想要時刻取得籃球的位置便會有一定的難度。

另外一個籃球不易偵測的原因在於籃球屬於小物件，所以在辨識時相對於大物件因在影像中所佔面積較小，故得到的資訊會比較少。特別是在物件高速移動下，小物件比較難被辨認且容易被誤判。本研究採用物件偵測辨識率較高的 Resnet101 與 Feature Pyramid Networks(FPN)來解決此一問題。

3. 球場上球員分隊的問題

本研究目的為將真實比賽片段中球員的座標映射至平面戰術板座標系，所以必須解決球員分隊的問題否則映射後無法得知該點球員之對伍。本研究使用 Bounding box 區域內色調特徵(Hue histogram)與顏色強度特徵(Intensity value of RGB)，並採用 K-means clustering 方法將場上球員分為兩隊。

4. 球場範圍界定問題

在籃球比賽中前排觀眾席與球場內的球員距離並不會很遠，甚至很靠近。如何將觀眾席與場外的球員分隔開來也是一項課題。最基本的方法為手動分隔出球場範圍，但因為不同比賽片段中攝影機鏡頭角度有微小區別，所以需要進行校正。

因此，本研究利用邊緣偵測的方法找出球場的底線，並利用兩側的端點當作球場頂點以找出更符合真實情況的球場範圍。

5. 不同比賽片段攝影鏡頭拍攝角度問題

籃球比賽的球場由兩個半場組成，通常攝影機拍攝時只會將鏡頭的視角放在正在進行攻防的半場，攻防交換時再轉動攝影鏡頭拍攝另一個半場。由於攝影鏡頭不會拍到完整的籃球場，所以如何將拍攝到部分球場的影像正確投影在球場平面圖上也是一項需解決的問題。本研究採用 Homography(單應矩陣)解決此問題，透過真實球場的四個頂點與平面戰術板的四個頂點計算出 Homography(單應矩陣)，進行球場內球員點對點的映射。

綜合以上研究困難，使用物件偵測辨識率較高的 Resnet101 與 Feature Pyramid Networks(FPN)來解決影像中籃球不易正確偵測，並利用 Bounding box 區域內的 HIS 模型中的色調特徵(Hue histogram)與顏色強度特徵(Intensity value of RGB)作為特徵值解決球員分隊問題。

接著使用邊緣偵測的方法找出球場的底線，並利用兩側的端點當作球場頂點解決球場範圍決定問題。最後用計算 Homography(單應矩陣)處理不同比賽片段攝影鏡頭拍攝角度問題。利用上述解決方案，本研究開發一套基於深度學習之籃球攻防戰術軌跡生成系統。

第四節 研究貢獻

本研究之貢獻為研發了一套基於深度學習之籃球攻防戰術軌跡生成系統，同時改良了將真實籃球影像透過平面投影的技術，並且與生成對抗網路做結合，使其能夠將真實的比賽片段作為輸入，並產生虛擬的防守戰術供使用者做為參考。以下說明本研究主要貢獻：

使用投影轉換子系統進行輸入比賽片段與防守戰術軌跡生成子系統之間的嫁接。整體架構由投影轉換子系統和防守戰術軌跡生成子系統組合而成，主要的改良為(1)使用邊緣偵測找出球場邊線頂點，取代原來手動觀察輸入座標的方法。(2)加入球員分隊功能，使用 Bounding box 區域內 HSI 模型中的色調特徵(Hue histogram)與顏色強度特徵(Intensity value of RGB)作為特徵值，使用 K-means clustering K 設為 2 的方法將場上球員分為兩隊。

第五節 論文架構

本論文共分為五個章節，第一章說明研究動機和研究困難；第二章為文獻探討；第三章則介紹本研究的系統流程；第四章是實驗結果與討論；最後，第五章為結論與未來工作。



第 2 章 文獻探討

籃球攻防戰術軌跡生成系統主要可分為兩個子系統，投影轉換子系統與防守戰術軌跡生成子系統。其中投影轉換子系統可以借鑑物件偵測與矩陣映射的技術。另外，籃球攻防戰術軌跡生成可以將球員與籃球的位置座標結果利用深度學習技術來完成。本章將會介紹與研發籃球攻防戰術軌跡生成系統相關的技術。

第一節 籃球進攻戰術

本節介紹部分常用且經典的籃球進攻戰術，表 2.1 列出 12 種常見進攻戰術之中英文戰術名稱以及戰術執行人數，分別為輪式進攻戰術(Wheel offense)、背擋戰術(Back pick)、擋拆戰術(Pick and roll)、假擋外拉戰術(Slip and pop)、反向掩護戰術(Veer screen)、電梯戰術(Elevator)、低位掩護戰術(Pin down)、折曲進攻戰術(Flex)、鷹式進攻戰術(Hawk)、鐵鎚戰術(Hammer)、展開掩護戰術(Flare screen)、以及交叉掩護戰術(Cross screen)。以下針對表 2.1 中的 12 種進攻戰術進行介紹。

表 2.1 籃球進攻戰術中英文名稱對照以及執行人數列表。

編號	中文進攻戰術名稱	英文進攻戰術名稱	進攻戰術執行人數
1	輪式進攻戰術	Wheel offense	5 人
2	背擋戰術	Back pick	3 人
3	擋拆戰術	Pick and roll	2 人
4	假擋外拉戰術	Slip and pop	2 人
5	反向掩護戰術	Veer screen	3 人
6	電梯戰術	Elevator	4 人
7	低位掩護戰術	Pin down	3 人
8	折曲進攻戰術	Flex	4 人
9	鷹式進攻戰術	Hawk	3 人
10	鐵鎚戰術	Hammer	3 人
11	展開掩護戰術	Flare screen	3 人
12	交叉掩護戰術	Cross screen	3 人

1. 輪式進攻戰術(Wheel offense)

輪式進攻戰術是一個適合五人合力執行的進攻戰術。進攻方的五位球員藉由持續性的跑動、擋人、切入等動作，在籃筐附近或外線創造得分機會。跑動的路線以罰球線為中心，形成一個輪轉的形式，故稱為輪式進攻。圖 2.1(a)為輪式進攻戰術的示意圖，圖中藍色圓圈為進攻球員，實線箭頭為球員移動方向，虛線箭頭為籃球移動方向(以下本節中圖 2.1 至圖 2.7 之符號表示皆同義)。由圖 2.1(a)中可以觀察到當 1 號球員將球傳給 2 號球員，同時 3、4、5 號球員在罰球線附近像輪子般跑位，尋找最合適的進攻機會。

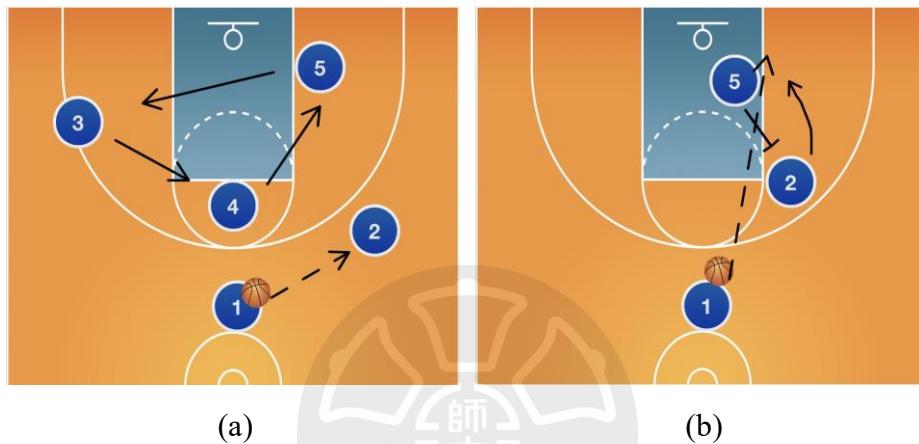


圖 2.1 進攻戰術示意圖(一)。(a) 輪式進攻戰術，(b) 背擋戰術。

2. 背擋戰術(Back pick)

背擋戰術為三人小組執行的進攻戰術。當場上防守者的視線放在持球者身上時，一位進攻方無球球員為另一位隊友在防守者的盲側設置掩護。進攻球員將利用掩護，切入內線並輕鬆接到傳球，最後上籃終結。圖 2.1(b)為背擋戰術的示意圖，5 號球員往防守者的背後設立一個掩護，其身後的空間得以讓 2 號球員空手切入接球，之後 1 號球員將球傳給 2 號球員，2 號球員可獲得出手投籃的機會。

3. 擋拆戰術(Pick and roll)

擋拆戰術為最基本的掩護戰術，由兩人小組執行。許多進攻戰術都是由擋拆戰術變化而來。一名進攻方無球球員為另一名持球隊友設置掩護，使持球者可通過防守，若內線防守球員未上前補防，持球者可獲得空檔出手;若內線防守者上前補防可能的投籃者，做完單擋的進攻球員即可下滑禁區，取得另一個接球進攻的機會。圖 2.2(a)為擋拆戰術的示意圖，2 號球員為 1 號球員設立一個掩護，1 號球員就可以擺脫防守進行切入或跳投。




圖 2.2 進攻戰術示意圖(二)。(a) 擋拆戰術，(b) 假擋外拉戰術(1)，(c) 假擋外拉戰術(2)。

4. 假擋外拉戰術(Slip and pop)

假擋外拉戰術由兩人小組執行。未持球的進攻預備者先假裝上前做一個單擋，在單擋即將成形的剎那，持球者運球快速離開單擋位置(Slip)，預備攻擊者立即放棄形成單擋的機會往反方向的空檔移動(pop)，而獲得接球投籃的機會。圖 2.2(b)為假擋外拉戰術示意圖，2 號球員先為 1 號球員設立一個假掩護，在掩護即將到位的時候拉開至空檔區域迷惑防守者，同時 1 號球員同時也往角落移動，最後再將籃球傳給 2 號球員完成出手投籃。

5. 反向掩護戰術(Veer screen)

反向掩護戰術由三人小組執行。一名進攻方無球球員先上前為隊友做有球掩護，吸引防守者注意，再為另一位無球隊友做無球掩護，取得在弧頂出手的機會。如圖 2.3(a)所示在反向掩護戰術中，5 號球員實際上操作了兩次單擋，第一次在弧頂為持球的 1 號球員單擋，第二次在側邊與 2 號球員做交叉反擋(圖 2.3(b))，2 號球員擺脫防守在弧頂取得機會完成出手投籃。




圖 2.3 進攻戰術示意圖(三)。(a) 反向掩護戰術(1)，(b) 反向掩護戰術(2)。

6. 電梯戰術(Elevator)

電梯戰術為一個由四人小組執行的進攻戰術。一名射手通過由兩位隊友設立的雙掩護並獲得外線的出手機會。此戰術是由 NBA 金州勇士隊的教練 Steve Kerr 為當家射手 Stephen Curry 打造的專用戰術。圖 2.4 為電梯戰術示意圖，1 號球員往 45 度角移動吸引注意力，同時 2 號球員悄悄溜進底線(圖 2.4(a))，通過由 4 號球員與 5 號球員設立的掩護空隙，通過後這兩位隊友像電梯門一樣把空隙關閉，同時 1 號球員將籃球傳給再弧頂獲得空檔的 2 號球員(圖 2.4(b))，得到輕鬆投籃的機會。

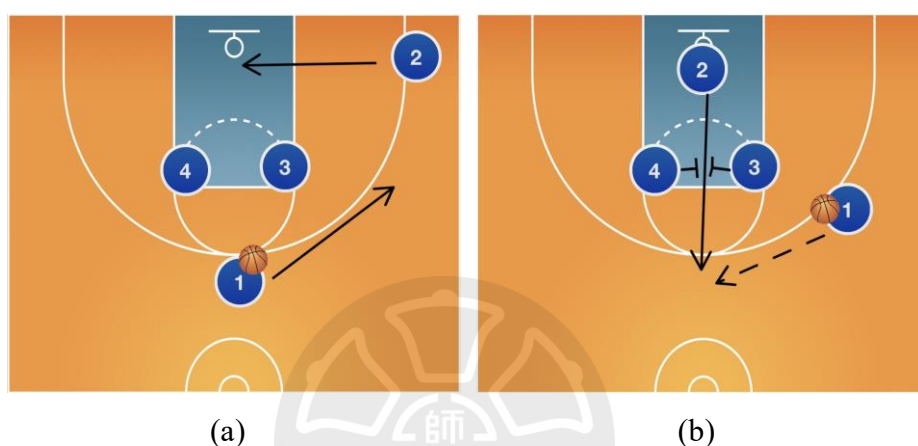


圖 2.4 進攻戰術示意圖(四)。(a) 電梯戰術(1)，(b) 電梯戰術(2)。

7. 下擋戰術(Pin down)

下擋戰術為一個由兩人小組執行的進攻戰術。一名進攻球員保持面向底線的掩護方式，為另一位隊友創造外線出手機會。圖 2.5(a)為下擋戰術示意圖，圖中 3 號球員為 2 號球員做一次擋人掩護，2 號球員擺脫防守後到弧頂，同時 1 號球員將球傳給 2 號球員，完成出手投籃。

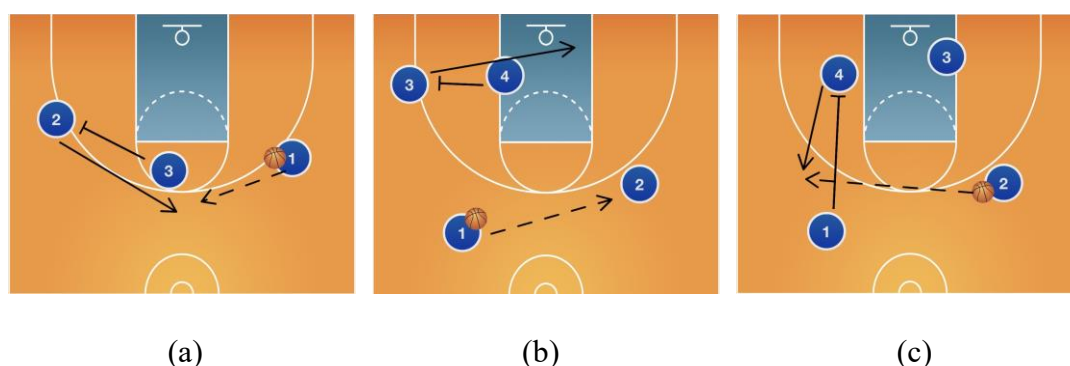


圖 2.5 進攻戰術示意圖(五)。(a) 下擋戰術，(b) 曲折進攻戰術(1)，(c) 曲折進攻戰術(2)。

8. 曲折進攻戰術(Flex)

曲折進攻戰術為一個由三人小組執行的進攻戰術。透過大量跑動，連續循環地進行橫向掩護加上縱向掩護，不斷地為隊友創造得分機會。圖 2.5(b)、(c)為曲折進攻戰術示意圖，首先 4 號球員先為 3 號球員設立一個橫向掩護，3 號球員往底線移動，有機會時接球完成進攻(圖 2.5(b))。如果沒有就執行戰術的後半部分 1 號球員將球傳給 2 號球員，接著往底線為 4 號球員設立一個縱向掩護，4 號球員上拉到三分線接球(圖 2.5(c))，完成出手投籃。

9. 鷹式進攻戰術(Hawk)

鷹式進攻戰術為一個由三人小組執行的進攻戰術。弧頂的進攻球員藉由罰球線附近的掩護空切到籃下進行上籃。圖 2.6(a)為鷹式進攻戰術示意圖，圖中 1 號球員在球場 45 度角附近緩慢前進吸引注意，同時 3 號球員在罰球線附近為 2 號球員設立一個單擋，以便 2 號球員擺脫防守往籃下切入完成進攻。




圖 2.6 進攻戰術示意圖(六)。(a) 鷹式進攻戰術，(b) 鐵鎚戰術(1)，(c) 鐵鎚戰術(2)。

10. 鐵鎚戰術(Hammer)

此戰術為 NBA 的聖安東尼奧馬刺的知名戰術，由三人小組執行。傳球者和接球者分居球場兩側，藉由長距離的傳球為弱邊接球者製造投籃空檔。圖 2.6(b)、(c)為鐵鎚戰術示意圖。圖 2.6(b)中 3 號球員先為持球的 1 號球員設立一個單擋，接著 1 號球員往底線移動吸引防守，同時 2 號球員往底線移動，這時 1 號球員由一邊底角將球傳給另一邊底角的 2 號球員完成出手投籃(圖 2.6(c))。

11. 展開掩護戰術 (Flare screen)

展開掩護戰術為一個由三人小組執行的進攻戰術。接應球的球員獲得一個面向傳球球員的掩護，並往外線的側翼移動，藉此增加接應球員與防守球員的距離，

並得到空間以獲得投籃的機會。圖 2.7(a)為展開掩護戰術的示意圖，圖中 3 號球員為 2 號球員設立一個掩護，2 號球員繞過掩護尋找空檔，1 號球員同時將球傳給 2 號球員完成出手投籃。

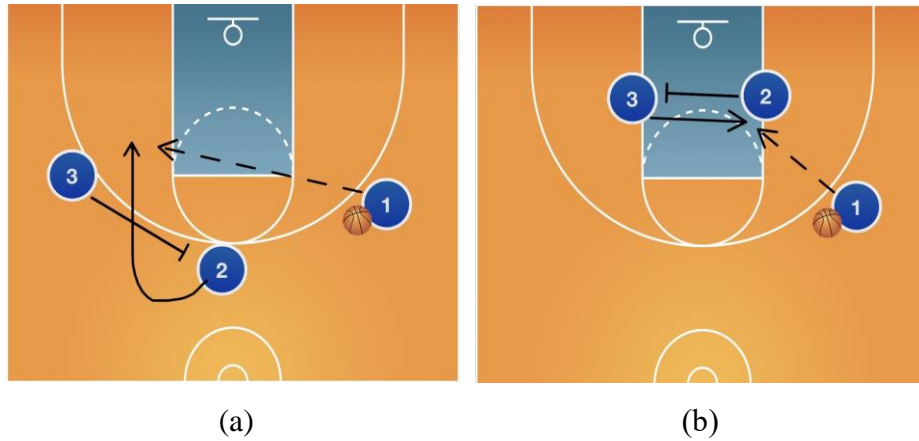


圖 2.7 進攻戰術示意圖(七)。(a) 展開掩護戰術，(b) 交叉掩護。

12. 交叉掩護(Cross screen)

交叉掩護戰術為一個由三人小組執行的進攻戰術。該戰術應用在掩護球員從強邊往弱邊前進時，提供接球球員一個從弱邊甩掉防守者並接球的機會。這種情況很常發生在禁區，利用中鋒與對方矮小球員兩者之間身材差距的優勢進行進攻。此戰術大部分不會擺脫掉防守者，主要目的為製造錯位進攻。圖 2.7(b) 為交叉掩護戰術示意圖，2 號球員幫 3 號球員設立一個掩護牽制原先 3 號球員防守者，接著 3 號球員移動到低位另一側迫使對手較矮小的球員來進行換防，同時 1 號球員將球傳給 3 號球員進行單打終結。

籃球進攻戰術並不局限於上述的十二種戰術，進攻時球員也可以因時因地制宜調整戰術。例如因應防守方的不同防守戰術，可以使用對應的進攻戰術來進行應對。實際上各種進攻戰術都有其適合應用的情況，可破解不同的防守戰術在比賽中取得優勢。

第二節 人體與物件偵測技術

在 1998 年時，Y. Lecum 提出了深度學習卷積神經網路(Convolutional Neural Network, CNN)稱為 Lenet-5[Lec1]。Lenet-5 的架構由數層卷積層(Convolution layer)及全連結層(Full connection layer)組成，該架構顯示出卷積神經網路的主要設計精神，卷積層的主要功能為卷積(Convolution)和降維(Subsampling)，全連接層的

主要目的則在物件分類和偵測。有許多研究者投入 CNN 的基本架構改良進而研發許多耳熟能詳的經典網路。

近年來，利用 CNN 的基本架構進行物件偵測的技術其中一種發展面向為 Region-based Convolved Neural Network(R-CNN)系列[Gir2]。R-CNN 顧名思義其特色為在影像中找出適當的 Region of interest(又稱 Proposal)。這些 Proposals 的個數非常多，每張影像可能達到數千個，每個 proposal 中都可能包括某種擬偵測或辨識的物件。將 proposals 經裁切與變形縮放後調整成統一的大小輸入 CNN 進行物件分類或辨識，可以有效提高物件的辨識率。但因為一張影像中擷取的 Proposals 數量很大，無論在訓練或辨識上都很費時。R.Girshick[Gir3]因此提出 Fast R-CNN 架構來改良 R-CNN 的問題。在 Fast R-CNN 中，提高卷積層特徵擷取的速度，利用卷積運算中共用參數的特性降低運算量。另外，S.Ren 等人[Ren4]於 2017 年提出 Faster R-CNN 架構來改善 R-CNN 與 Fast R-CNN 中 proposals 生成方式，如圖 2.8 所示。Faster R-CNN 的主要改良方式為加入一個 Region Proposal Network(RPN)架構，RPN 採用 Non-maximum suppression 技術來保留具局部最大值的 Proposal 來降低 Proposals 的個數。




圖 2.8 Faster R-CNN 的主要架構[Ren4]。

另一方面，語意分割神經網路模型亦可以用來進行物件的偵測。語意分割技術可以將影像分割為不同的區域，若在語意分割之後將分割好的區域適當的合併

成物件，則可以偵測出物件。He 等人提出的 Mask R-CNN[He5]架構即為改良 Faster R-CNN 卻具語意分割功能的神經網路模組。Mask R-CNN(如圖所示)除提供物件類別(class)和物件邊框(box) 的輸出結果外，還對每一個 ROI 提供物件遮罩(mask)的預測結果。Mask R-CNN 架構若依功能可分為四個部分，分別為：Convolutional backbone、RPN、RoI Align、以及 head。Convolutional backbone 負責擷取物件特徵並輸出特徵圖，同時將這些特徵圖輸入 RPN。

RPN 則根據特徵圖來判斷並擷取影像中的前景區域塊，這些區域塊即是 ROI。RoIAlign 使用雙線性內插法目的在固定並統一 ROI 尺寸，head 部份包含三個輸出分支，分別為 class、box、以及 mask。值得一提的是由於 Mask R-CNN 使用 RoIAlign 統一 ROI 尺寸，改善 faster R-CNN 中框選辨識物體位置偏差的問題，因此當 ROI 輸入 mask 分支預測物件遮罩時正確率至少提高 10%。




圖 2.9 Mask R-CNN 的主要架構[He5]。

而除了上面介紹的神經網路以外，還有許多不同架構和改良的方式值得探討。2017 年 Lin 等人[Lin6]提出一種利用 CNN 模型來高效擷取影像中不同尺度的特徵的方法，稱為 Feature Pyramid Networks(FPN)。不同大小物體在影像中的尺寸都不同，所以在進行辨識的動作時，僅僅在單一尺度下進行特徵擷取的動作，效果往往都不會太好。因此 Lin 等人利用 CNN 依序產出不同階段的特徵圖(feature maps)，又需要讓金字塔中的每一層特徵圖都有意義存在。該研究結合 Top-down 的概念和跳躍連接(Skip-connection)的技術，得到效果較佳的 Feature Pyramid Networks，即特徵金字塔網路，以解決不同大小物體特徵的問題，在物體特徵的擷取方面得到更好的效果。




圖 2.10 以 Top-down 概念和跳躍連接技術所設計的 FPN[Lin8]的架構。

在此架構圖可以觀察到原本的影像經過不斷的 Sampling 會得到更高維度的特徵圖(feature map)，之後較高維度的特徵圖會往下 Upsampling 之後跟下一層低維度的特徵圖對應點相加，得到新的特徵圖，這樣的設計可以同時考慮不同尺度大小的特徵。

傳統的深度神經網路模型通過堆疊多個卷積層和非線性激活函數來提取特徵。然而隨著網路層數的增加，模型的準確率會飽和或下降，即添加更多層並不能提升性能。這是由於深層網路中的參數的梯度難以正確傳遞，導致網路的訓練過程變得不易。ResNet(Residual Neural Network)[He7]是一種深度卷積神經網路模型，由微軟研究院於 2015 年提出。其主要概念是引入殘差學習的技術來解決上述問題。殘差塊允許資訊在網路中直接跳躍連接。這樣的設計使得網路可以輕鬆地學習殘差，不需要通過多個層逐步堆疊。透過殘差連接，網路中的參數的梯度能夠更順利地傳播，使得網路的訓練變得更加容易和穩定。

ResNet 的架構有多個變種，其中較為經典的是 ResNet-50 和 ResNet-101。ResNet 後面的數字表示網路中殘差塊的數量。這些模型通常在大規模影像數據集上進行預訓練，可以應用於電腦視覺領域，如影像分類、目標檢測、影像分割等。

近年來，Facebook AI Research 開發一種基於 Pytorch 框架包含多種預訓練模型的電腦視覺框架 Detectron2。Detectron2 提供一系列各種物件偵測和影像分割演算法的實用模組。它不僅支持多種經典深度學習模型，如 Faster R-CNN、Mask

R-CNN、ResNet 等，同時也提供可構建自定義模型的功能。該功能可讓使用者能夠自行快速搭建、訓練物件偵測和影像分割系統。

上述文獻中所述的深度學習神經網路模型皆可以用來偵測影像中的物件，且經許多研究驗證其實用性及穩定性。本研究中的球員偵測與籃球偵測皆屬於物件偵測的範圍。由於 Detectron2 可讓使用者能夠輕鬆地構建、訓練適合個別任務的深度學習模型，所以本研究選擇 Detectron2 框架搭配 Resnet101-FPN 預訓練模型當作球員與籃球偵測的方法。

選擇 Resnet101-FPN 主要是因為籃球比賽影像中之球員與籃球屬於小物件，而 Resnet101-FPN 其小物件偵測成功率相當高。Resnet101-FPN 中以 Resnet101 作為主幹網路，並使用 FPN 作為特徵金字塔網路。主幹網路即為特徵擷取的基礎網路，負責擷取影像中的特徵資訊。而 FPN 是則一種用於目標檢測和影像分割的特徵擷取架構。它通過在主幹網路的不同層之間建立多個尺度的特徵金字塔來擷取不同尺度的物件資訊。FPN 利用結合低層級特徵和高層級特徵來實現多尺度的目標偵測。此模型可以適用於偵測籃球場上的球員和球的任務。由於籃球場上的球員和球可能僅存在不同尺度影像中，FPN 的特徵金字塔結構可以有效不同尺度的物件資訊，提高物件偵測的準確性。

一旦單張影像中球員與籃球被成功地偵測，即能在連續影像序列中利用球員與籃球的位置資訊形成移動軌跡，以利後續的籃球防守戰術軌跡生成。

第三節 移動軌跡偵測技術

籃球攻防戰術表示多以平面戰術板的方式呈現，平面戰術板即為籃球場的地圖，平面圖上以不同顏色的色點來表示進攻與防守二隊的球員。因此在接續上階段人體與物件偵測技術的文獻探討進行籃球攻防戰術分析之文獻探討之前，需先討論介接二者的影像中球員與籃球位置平面圖投影自動標示技術。

影像中球員與籃球位置平面圖投影自動標示技術是視覺化智慧型籃球攻防戰術分析系統開發中必要研發的技術。Janssen[Jan8]於 2019 年提出一輸入籃球比賽影像自動標示球員與籃球位置於球場平面圖的系統。系統首先利用全景分割技術對影像進行分割，其結果如圖 2.11(a)所示。影像在全景分割之後刪除天花板、牆面、以及地板，再利用人體姿態估計 (Human Pose Estimation)技術

擷取出之人體(圖 2.11(b))。另一方面，使用者可事先輸入系統球場的範圍，如圖 2.11(c)中藍色線條所示。將位置落於籃球場上之球員進行鳥瞰投影(圖 2.11(d)、(e))，取出其對應座標，則可標示於球場平面圖中，如圖 2.11(f)之藍色點所示。然而此方法所生成的投影結果，球員與球位置點會隨著時間移動出現異常閃爍跳躍的不穩定狀況，與真實比賽情況有所差距。

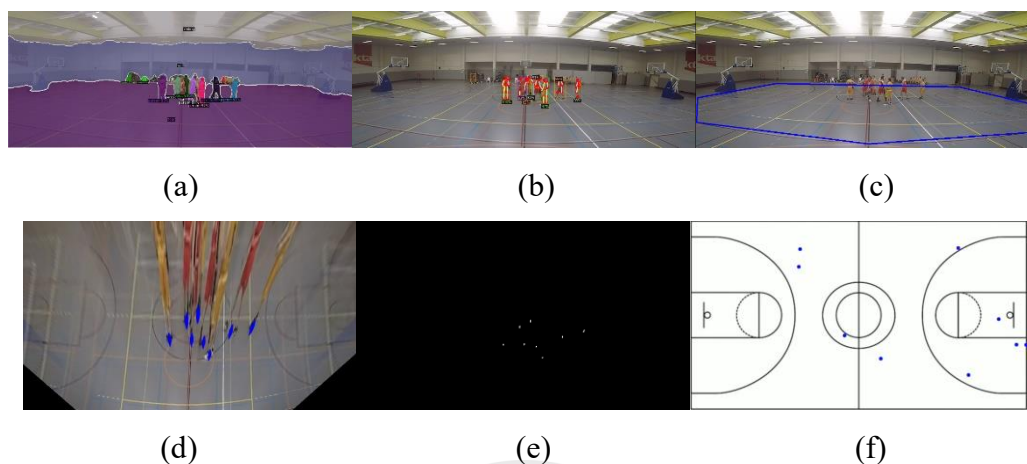


圖 2.11 Janssen 提出之籃球球員與籃球位置自動標示系統範例示意圖。

Mohan[Moh9]於 2021 年亦提出一籃球球員與籃球位置自動標示系統。系統輸入籃球比賽影像序列，序列中每張影像均利用 PyTorch 所提供的物件偵測函數可偵測出影像中籃球球員、籃球、裁判以及場邊觀眾等相關物件，並標示出這些物件的位置。同時，系統亦利用球場的角點做為源點將球場的範圍投影至 2D 球場平面圖，並取得轉置矩陣。最後將落在球場範圍內的人體物件位置依相同的方式投影至 2D 球場平面圖即可。與 Janssen[Jan8]的方法相比較，Mohan 提出的技術其投影後的球員與籃球位置更加穩定且準確，本研究採用該技術並加以改良。

在球類的球員追蹤中，足球比賽也有相關的技術。2019 年 Nguyen[Ngu10]等人提出一種基於影片的足球球員追蹤系統，該系統使用高效卷積運算來分析球員的行為和動態。該系統採用基於深度學習的方法，利用卷積神經網路對比賽影片進行處理和分析。圖 2.12 為該系統的架構圖。Nguyen 等人提到了一種高效的卷積操作 Efficient Convolution Operators(ECO)，該運算方式為在處理卷積層時將卷積運算分解，以降低模型的計算複雜度和參數數量。在實驗中，Nguyen 等人將該系統應用於足球比賽影片的分析，擷取並分析球員的位置、速度、加速度等運動資訊。通過比對實驗結果，該系統與現有的足球比賽影片分析方法相比，具有更高的準確性和效率。不過因為足球場地較寬闊，攝影機位置距場中球員較遠，

球員在影像中的相對移動速度較慢，較不適合使用在攝影機位置距場中球員較近，球員在影像中的相對移動速度較快，並且有大量遮擋情況的籃球比賽。

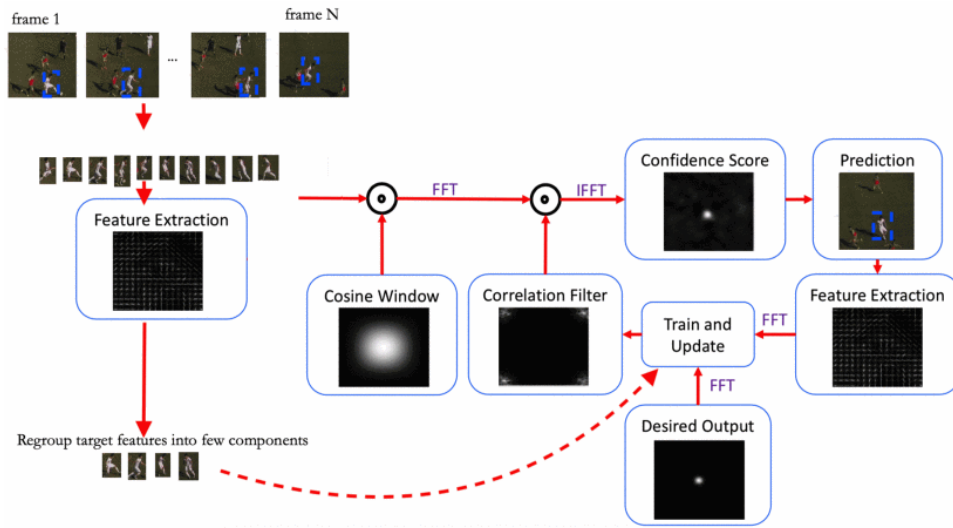


圖 2.12 Nguyen 等人提出的 Efficient Convolution Operators 架構圖[Ngu10]。

球員與籃球位置的自動標示系統可連接人體與物件偵測的深度學習技術與籃球攻防戰術分析技術，是智慧型籃球攻防戰術分析系統自動化中重要的一環。

第四節 籃球攻防戰術生成技術

Chen 等人[Che11]於 2018 年提出一輸入進攻平面圖利用生成對抗網路模擬籃球攻防戰術系統。圖 2.13 為一籃球攻防戰術範例。圖 2.13 的範例中紅色路線為進攻球員的移動軌跡，藍色路線為防守球員的移動軌跡，而綠色路線則為的籃球移動軌跡。為方便可視化，一個進攻戰術分成五個連續的小片段呈現，其中球員的移動軌跡從透明到不透明顯示移動的方向。圖 2.14 則為 Chen 等人所提之籃球攻防戰術模擬系統架構[Che11]。該架構為一生成對抗網路(Generative Adversarial Network, GAN)，其中包含兩個主要部份，生成器(Gen)與鑑別器(Critic)。生成器主要依據輸入的進攻戰術生成球員的防守戰術，鑑別器主要用於評估生成防守戰術的真實性。




圖 2.13 Chen 等人提出之籃球攻防戰術範例[Che11]。

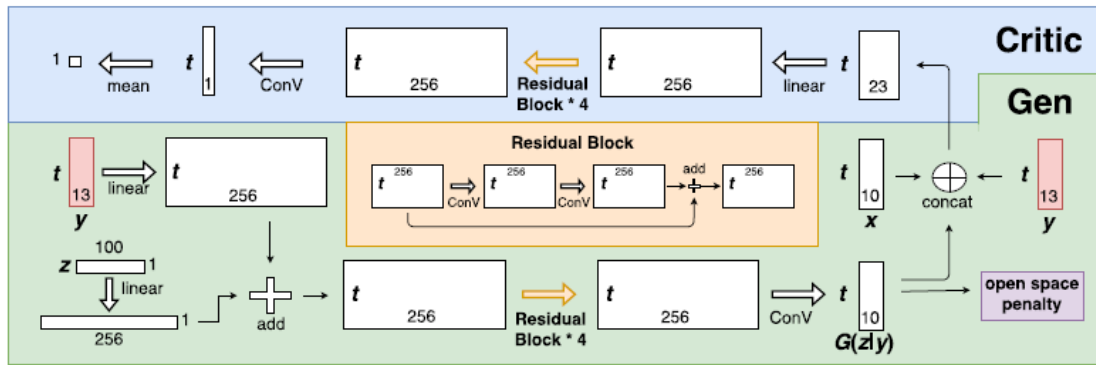


圖 2.14 Chen 等人提出之籃球攻防戰術模擬系統架構[Che11]。

圖 2.14 中生成器的輸入為條件向量 y 和噪音向量 z ，其中 y 是一個 $t \times 13$ 矩陣， t 是籃球比賽的幀數，每一幀皆用一個 13 維的特徵向量表示籃球和五位進攻球員在球場上的位置以及籃球的狀態。生成器首先將 y 和 z 兩個向量線性投影到相同的 256 維，然後將向量 z 加到 y 中每一幀分向量中。這種設計允許噪音向量 z 具有整個軌跡的全域影響力，而不是僅針對個別幀的球員位置。這些輸入資訊經由通過殘差塊(Residual block)和卷積(Conv)後，輸出防守球員的移動軌跡 ($G(z | y)$)。而圖 2.14 中的鑑別器(Critic)則利用籃球，進攻球員、和防守球員的移動軌跡作為輸入，評估生成結果之真實性與合理性。鑑別器的輸出是一個分數，該分數顯示生成之防守戰術與真實籃球比賽攻防戰術之間的相似度。為避免防守方出現大空檔的狀況，Chen 等人在目標函數中添加一懲罰函數(open space penalty)協助系統的學習與訓練。該研究訓練與測試的資料集皆使用 NBA 釋出的 Sport VU 資料集，實驗部分則進行了用戶研究，計有 59 名參與者進行主觀測試。實驗結果表明系統生成的防守戰術具有一定的可信性。因此本研究使用的籃球攻防戰術生成系統採用 Chen[Che11]等人的方法。

Hsieh 等人[Hsi12]於 2019 年提出另一生成對抗網路模擬籃球攻防戰術系統。使用者可以給定一個進攻戰術平面圖(如圖 2.15(a)所示)，而系統將生成對應的防守戰術平面圖(如圖 2.15(b)所示)。圖 2.15(a)中紅色點表示進攻球員的位置，黑色鋸齒狀線條則為進攻球員的移動路線；綠色點為籃球的位置，綠色虛線則為籃球的移動路線。為了清晰顯示動態的防守過程，本範例中圖 2.15(b)將輸出分成

三個連續的片段，其中球員的移動軌跡從透明到不透明顯示移動的方向。在輸出之攻防平面圖中，紅色路線為進攻球員的移動軌跡，藍色路線為防守球員的移動軌跡，而綠色路線則為籃球的移動軌跡。




圖 2.15 Hsieh 等人提出之籃球攻防戰術範例[Hsi12]。(a)使用者輸入進攻戰術平面圖，(b)系統對應防守戰術在三個不同時間點上的平面圖顯示。

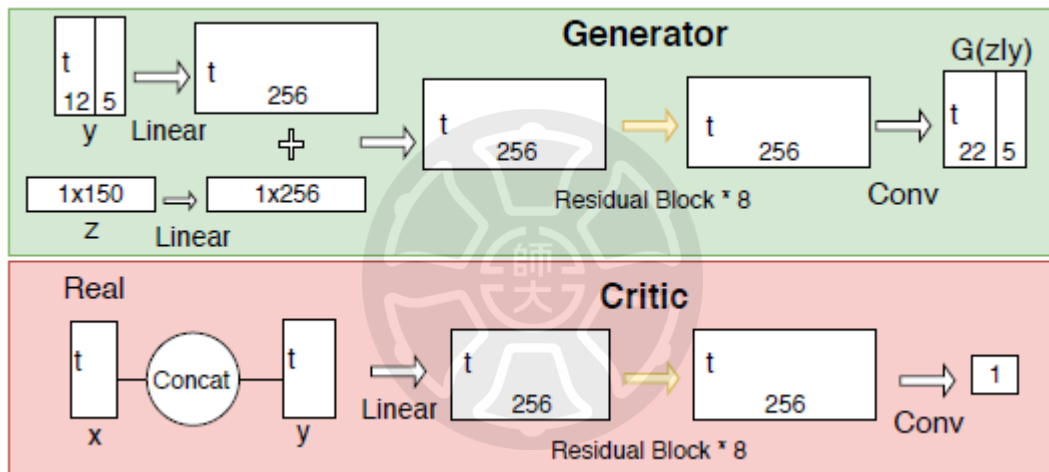


圖 2.16 Hsieh 等人提出之籃球攻防戰術模擬系統架構[Hsi12]。

圖 2.16 所示為 Hsieh 等人所提之籃球攻防戰術模擬系統架構。該架構與 Chen 等人所提之架構類似，其核心為一生成對抗網絡(Generative Adversarial Network, GAN)。生成對抗網絡中生成器(Generator) 主要依據輸入的進攻戰術平面圖生成球員的防守戰術，鑑別器(Critic)主要用於評估輸出之籃球攻防戰術的真實性。圖十八中生成器的輸入為條件向量 y 和噪音向量 z ，其中 y 是一個 $t \times 18$ 矩陣， t 是籃球比賽的幀數，每一幀皆用一個 18 維的特徵向量表示。和圖十六不同的是，18 維的特徵向量中有 12 個維度表示籃球和五位進攻球員在球場上的位置，另外六個維度則代表籃球的狀態。這些輸入資訊經由生成器處理後，輸出結果($G(z | y)$)為一個 $t \times 27$ 的矩陣，其中 t 對應到與輸入相同的幀數，但每一幀包含五位進攻球員、五位防守球員和籃球的位置，以及籃球的狀態。圖十八中的鑑別器則可

評估生成器的輸出戰術平面圖($G(z | y)$)之真實性與合理性。具體來說，它評估輸出的進攻戰術是否滿足給定的條件 y ，其產出的對應防守戰術是否合理，以及生成的籃球狀態是否正確。

另一方面，該研究[Hsi13]為提高籃球攻防戰術模擬的真實性，使用了四個損失函數來幫助模型的訓練，包含 Dribbler loss、Defender loss、Ball passing loss、以及 Acceleration loss。其中 Dribbler loss 的功能為防止球離開運球者，Defender loss 則使運球球員總是會有防守球員防守，Ball passing loss 用以確保籃球軌跡為直線，而 Acceleration loss 功能在盡量減少球員不必要的動作。實驗顯示損失函數的改良可以有效地防止防守球員在場上出現防守異常的行為，此方法雖然與 Chen 等人[Che12]的研究同為防守戰術軌跡生成，但此方法輸入為草圖，與影像不匹配，故最終使用 Chen 等人[Che12]的研究為本研究防守戰術軌跡生成的方法。

以上所述為基本籃球進攻戰術相關文獻探討。本研究於人體與物件偵測採用 Facebook AI Research 開發的 Detectron2、移動軌跡偵測採用 Mohan[Moh9] 提出的籃球球員與籃球位置自動標示技術，另外，籃球防守戰術生成則採用 Chen 等人[Che11]提出的籃球攻防戰術生成模型。由於本研究採用的這些技術來源不同且皆為獨立開發，在輸出入訊息格式定義上具差異性，因此如何將這些技術整合並界接成一套完整的籃球攻防戰術軌跡生成系統則成為本研究主要的重點。

第 3 章 籃球攻防戰術軌跡生成系統

本系統的輸入為一段真實籃球比賽片段，透過籃球攻防戰術軌跡生成系統產生一段在平面戰術板上所表示的防守戰術軌跡。因此系統的主要架構由投影轉換子系統與防守戰術軌跡生成子系統所組合而成。投影轉換子系統的功能為將影像中的球員與球轉換為平面戰術板座標系並存檔使其能夠成為防守戰術軌跡生成子系統的輸入；防守戰術軌跡生成子系統使用生成對抗網路來生成與真實情況不同的防守戰術軌跡。

本研究之主要任務為將輸入比賽片段與防守戰術軌跡生成子系統使用投影轉換子系統串接，進行的系統整合並改良一些細節使投影的正確率提升。本章將會介紹基於深度學習之籃球攻防戰術軌跡生成系統流程和本研究所改良之相關技術。

第一節 系統流程

基於深度學習之籃球攻防戰術軌跡生成系統之流程如圖 3.1 所示，本系統主要分為兩個子系統：投影轉換子系統與防守戰術軌跡生成子系統。投影轉換子系統主要分為三個步驟(如圖 3.2 紫色部分所示)，分別為球場上球員與球的偵測、場上球員分隊及 3D 球員座標投影至 2D 戰術板座標系；產生球員座標檔案後，最後一個步驟使用生成對抗網路來進行防守戰術軌跡生成(如圖 3.2 綠色部分所示)。

本系統一開始輸入使用者提供之真實籃球比賽片段，使用 Detectron2 模型庫內預先訓練好的模型 Resnet101X FPN(Feature Pyramid Network)來進行影像中所有物件的偵測，再來界定球場的範圍以便將場上的球員與場外的觀眾進行區隔，方便後續進行將場上真實座標投影在戰術板球場上的工作。將場上的球員與觀眾區隔開之後需要對場上的球員進行分隊的動作，本研究使用球衣顏色做為辨別的依據，並使用色調特徵(Hue histogram)與區域內顏色強度特徵(Intensity value of RGB)進行 K-means clustering。最後進行將真實比賽 3D 座標投影在 2D 戰術板座標系的工作。首先透過真實球場的四個頂點與平面戰術板的四個頂點計算出 Homography(單應矩陣)將對應的 3D 座標映射在 2D 戰術板球場座標系中並記錄

為檔案作為防守戰術軌跡生成子系統的輸入。在防守戰術軌跡生成子系統中，系統使用 NBA 的 Sport VU 資料集進行訓練，再將前半部分投影系統得到的座標當作輸入生成相對應的防守戰術軌跡。

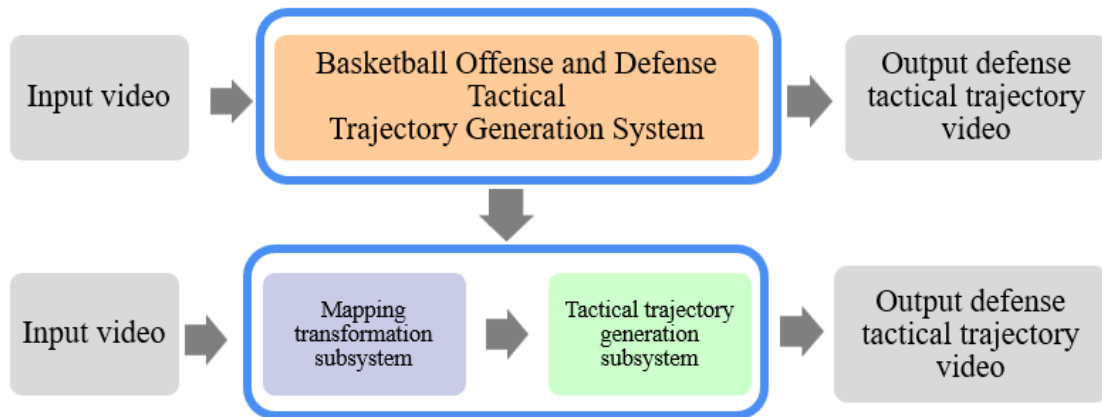


圖 3.1 系統總流程圖。

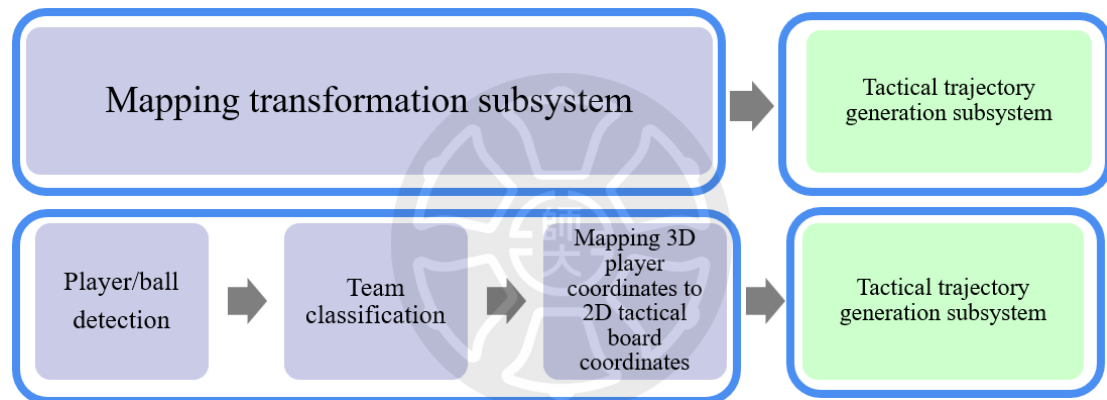


圖 3.2 系統細節功能流程圖。

以下針對投影轉換子系統進行詳細的說明。如前所述，投影轉換子系統主要分為三個步驟，分別為球員與球的偵測、球員分隊、投影至戰術板座標系。

(1) 球員和球的偵測

本系統物件的偵測使用 Detectron2 模型庫內預先訓練好的模型 Resnet101 X FPN 來進行偵測，該架構由 Backbone 網路 Resnet101 模型搭配上特徵圖融合網路 FPN (Feature Pyramid Network) 模型二大部份組成。使用 FPN (Feature Pyramid Network) 融合特徵圖的原因為籃球與球員在影像中屬於尺度不同的物件，而 FPN (Feature Pyramid Network) 網路的優點為特徵金字塔與特徵融合(如圖 3.3 所示)，特徵金字塔可以在不同尺度上偵測和分類物件。這對於偵測籃球場上的球員和球這樣具有不同尺度物件的任務非常重要。透過在多個層級上生成特徵圖，

使得模型能夠在不同的尺度上捕捉物件的細節與資訊。而透過特徵金字塔將不同尺度的特徵圖進行特徵融合，將低層的細節特徵和高層的特徵結合。這種特徵融合能夠提高對不同尺度物件的檢測準確性。對於籃球場上的球員和球物件尺度的差距較大時，使用 FPN(Feature Pyramid Network)可以更好地結合不同尺度的特徵圖，使得模型能夠更準確地偵測。

選擇 Resnet101 作為 Backbone 網路的原因為球場上的球員與籃球在整張影像中分別屬於中等物件與小型物件並且在運動狀態影像會比較模糊，所以需要使用精度較高的模型來提取特徵圖，Resnet 後面的數字代表層數，層數越高精確度越高但執行時間也會隨之增加。

偵測完影像中的所有物件後(如圖 3.4 所示)需要將球場上的球員與球和球場外的觀眾做區分，所以需要界定球場的範圍。界定球場的範圍最簡易的方法為直接給定球場的四個座標點。本研究改良了原先透過觀察人工給定座標的方法，將在後面的章節進行較詳細的介紹。

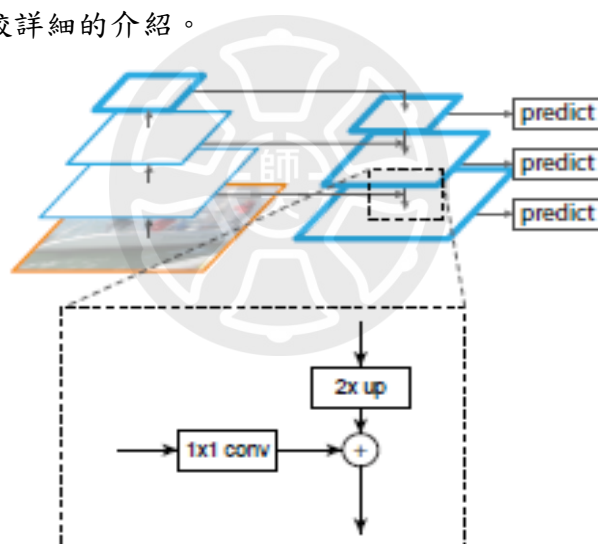


圖 3.3 FPN(Feature Pyramid Network)架構圖。



圖 3.4 球場影像物件偵測結果圖。

(2) 球員分隊

籃球比賽為兩支隊伍輪流進行進攻和防守，單獨的球員追蹤技術無法區分球隊表示球場上的真實比賽情況，因此本研究利用球衣顏色當作依據對場上球員進行分隊的動作。該技術為本研究的改良技術，將在後面的章節進行較為詳細的介紹。

(3) 3D 球員座標至 2D 戰術板座標系的映射

當偵測完場上的球員與球並且球員的分隊工作完成時，接著進行將 3D 球員座標至 2D 戰術板座標系的映射。本研究參考了 Mohan[Moh9]於 2021 年提出之方法，將 3D 真實球場轉換為由上往下觀察的鳥瞰圖(Bird's eye view projection)(如圖 3.5(a)所示)。透過使用真實球場的四個頂點與平面戰術板的四個頂點(如圖 3.5(b)、(c)所示)計算出 Homography(單應矩陣)，該矩陣描述這兩平面之間的映射關係，是一種在平面空間中對影像進行投影變換的方法，應用於影像校正等領域。

透過計算原影像中的頂點與目標圖像中對應的頂點之間的單應性矩陣，可以將源圖像映射到目標圖像的座標空間中，並且在影像中實現平移、旋轉、縮放等操作。本研究將 3D 籃球場視為一個平面，2D 戰術板視為另一個平面，將對應的 3D 球員座標映射至 2D 戰術板球場座標系中。而該矩陣可透過球場上頂點座標的對應位置來進行計算取得。

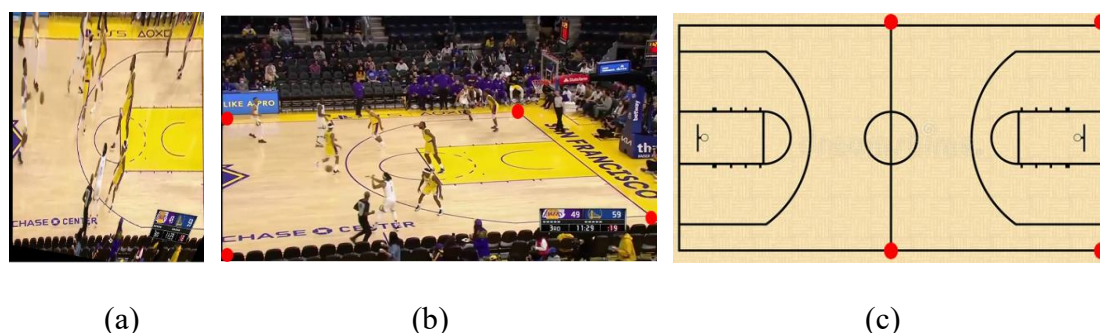


圖 3.5 鳥瞰圖與頂點標示圖。(a) 鳥瞰圖，(b) 真實比賽頂點標示圖，(c) 平面戰術板頂點標示圖。

(4) 防守戰術軌跡生成

防守戰術軌跡生成子系統引用 Chen[Che11]等人於 2018 年所提出的 Basketball Defense GAN，架構圖如圖 3.6 所示。該系統的輸入為進攻球員在平面戰術板的座標(如圖 3.7 所示)，其中 0~2 列代表的分別為 x、y、z 座標，而第 0 行代表籃

球，1~5 行代表進攻球員，6~10 行代表防守球員。該座標檔案可以透過前面所提之投影轉換子系統所得，輸入圖 3.6 紅色框選部分與噪聲(Noise)作為防守戰術軌跡生成子系統的生成條件，經過生成器(Generator)生成與原先不同的防守戰術軌跡。

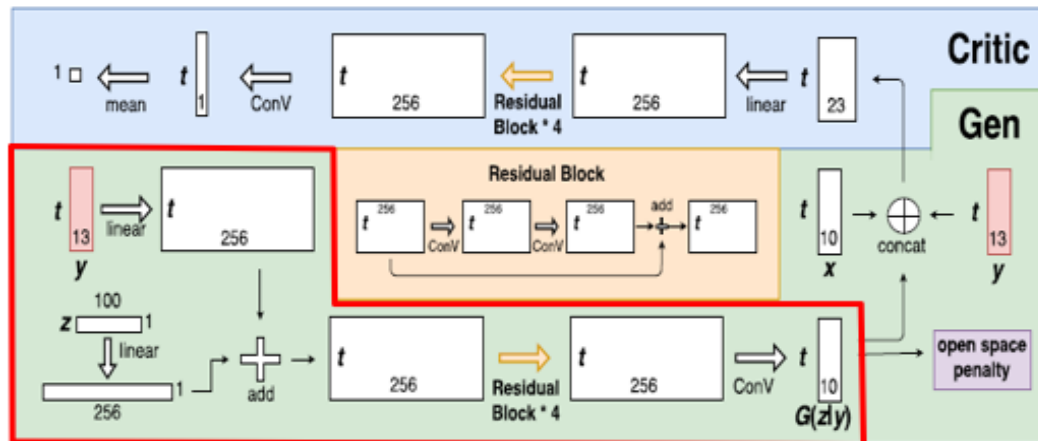


圖 3.6 Chen 等人提出之籃球防守戰術軌跡生成子系統架構[Che11]。

	x	y	z
0	89.02	31.57	6.2
1	57.78	11.97	0
2	76.11	31.57	0
3	74.72	14.60	0
4	93.33	21.31	0
5	69.44	44.07	0
6	75.69	14.34	0
7	60.66	10.78	0
8	36.11	47.36	0
9	50.28	60.52	0
10	63.88	53.94	0

圖 3.7 座標記錄檔案。

以上所述為系統流程以及相關步驟簡介，本章後續章節將詳細說明球員與球的偵測、球員分隊、3D 球員座標至 2D 戰術板座標系的映射以及防守戰術軌跡生成之具體方法。其中第二章節說明球場範圍決定改良；第三章節說明球員分隊功能。

第二節 球員和球的偵測改良

本系統需要界定真實球場的範圍，以利區分場上球員與場外觀眾和增加後續投影至平面戰術板的正確性。使用者輸入的比賽片段攝影機拍攝角度大致相似，因此初始給定固定的四個球場邊界座標點可以涵蓋籃球場大致地範圍。但籃球場的真實範圍在不同的影像片段還是會有些微差異，這些差異足以影響投影的準確性及區分籃球場內外的物件，透過手動標示方法修改球場邊界的座標點較繁瑣而無效率。

以下為一組實驗範例，顯示本系統採用在預設固定的四個球場邊界座標點(如圖 3.8(a)所示)進行真實球場界定使其更符合真實球場範圍的過程。真實球場界定主要目標為找出球場外側的兩個座標點，因為球場外側的邊緣輪廓更加明顯。首先使用 Canny edge detection 進行邊緣偵測(如圖 3.8(b)所示)，接著使用 Hough Transform for lines 在影像中偵測出所有直線線段(如圖 3.8(c)所示)。找出影像中所有直線線段之後，在所有線段中找出球場底線以得到球場外側的頂點座標。

過濾線段的方法為透過實驗設定適合的線段長度與斜率閾值，使用長度閾值的原因為籃球場的邊線在球場影像中具較長線段性質；使用斜率閾值的原因則為而且職業比賽的攝影機拍攝角度大致固定，故球場邊線的斜率亦具相當之一致性。

另外，由於籃球場底線與罰球線平行(如圖 3.8(d)所示)，所以長度與斜率閾值同時使用可以最好的過濾出底線邊線。經過實驗發現最適合的線段長度閾值約為 300、斜率閾值約為 0.3。接著找出線段的兩側的端點取代預設頂點當作新的球場頂點(如圖 3.8(e)所示)。最後，將找出的端點與右側兩個初始點做相連，界定真實的球場範圍(如圖 3.8(f)所示)。




圖 3.8 球場範圍界定範例圖。(a) 預設頂點圖，(b) 經過 Canny edge detection，(c) 進行 Hough Transform for lines，(d) 底線與罰球線段，(e) 過濾線段並取得端點，(f) 球場範圍界定結果圖。

第三節 球員分隊

為了最後在戰術板座標系區分出不同的球隊球員，本系統加入了球員分隊的功能。球員分隊的依據是使用 Bounding box 內球衣的顏色。透過縮小前面偵測物件 Bounding box 其長寬各二分之一，並微調位置使其盡量涵蓋球衣的面積。接著統計調整過後 Bounding box 區域中 HSI 模型中的色調特徵，並使用 *K*-means clustering 將這些區域分為兩個聚類(clusters)，分別為兩支比賽球隊球員。*K*-means clustering 是一種常用的無監督學習方法，用於將相似的資料對象歸類到同一聚類中。該演算法的原理為透過迭代的方式將資料集分成 *K* 個聚類，每個聚類由一

個中心點表示。演算法的目標是最小化資料點到其所屬聚類的中心點的距離平方和，以獲得最優的聚類結果。

K -means clustering 演算法的步驟如下：首先，選擇 K 個初始聚類中心。接著迭代計算每筆資料與聚類中心的距離，並將資料重新分配到最近的聚類中心。接下來更新每個聚類的中心，將其移動到聚類內所有資料的平均位置。這些步驟循環執行，直到滿足收斂條件，即聚類中心不再變化或達到預定的迭代次數。而此方法常用的距離衡量方法是歐式距離，用於衡量資料之間的相似度。通過計算資料的特徵值之間的歐式距離，可以確定它們在特徵空間中的相似度。選擇合適的 K 值是 K -means clustering 演算法的關鍵，本研究的 K 值設為 2。

圖 3.9(a) 所示為一實驗結果範例，場上十名球員能依照球衣顏色被正確分為兩隊。圖 3.9(b) 所示則為該範例 Bounding box 內球員色調(Hue)的特徵直方圖，直方圖線條的顏色代表球員被分類到的隊伍，橫軸為色調值的大小，縱軸為色調值直方圖正規化後的結果。實驗顯示白色球衣的色調值大約位於 0~10 之間，而黃色球衣的色調值大約位於 25~40 之間，所以 3.9(b) 中可以觀察到在色調值為 0~10 這個區間有一部分的數據值非常高而一部分的值非常低。圖 3.9(a) 中的球員也順利被分為不同的兩支隊伍，因此這是一個成功的案例。

圖 3.9(a) 實驗範例黃色球衣的球員身上的白色區域很少，所以跟白色球衣的隊員有很大差距。由此可推斷，此方法分類成功的關鍵是球衣的顏色受到越少的干擾項影響越好，因為當作判斷依據的 Bounding box 雖然儘量落在球衣區域，但其實聚類的結果還是會受到手臂、地板、球衣背號或一些身上的護具顏色所干擾。因此，若球衣的色調值跟這些干擾項的色調值較為靠近時，代表色調值直方圖會分布的較混亂而容易造成誤判。

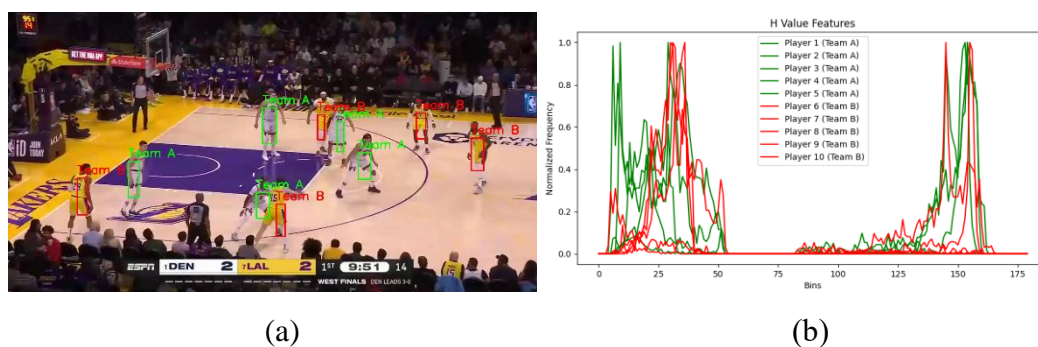


圖 3.9 分隊結果圖與色調值直方圖。(a) 分隊結果圖，(b) 色調值直方圖。

為了提升正確率，本研究同時使用該區域內的顏色強度特徵(Intensity value of RGB)與前述的色調特徵(Hue histogram)一起當作球員分隊的區分標準。採用顏色強度特徵的原因為在區域內的大部分面積還是被球衣所佔據，所以顏色強度特徵可以有效降低區域內所包含手臂或者球衣背號因素的影響，讓相同隊伍的顏色強度特徵靠近。圖 3.10 所示為另一組實驗範例。圖 3.10(a)為僅使用色調特徵的球員分隊結果，可以觀察到聚類的結果並不佳；而圖 3.10(b)為在相同狀況下色調特徵加上顏色強度特徵之聚類結果，最後結果球員被正確分隊。實驗結果顯示在使用色調特徵加上顏色強度特徵的狀況下正確率比僅使用色調特徵其正確率提高了約 10%。

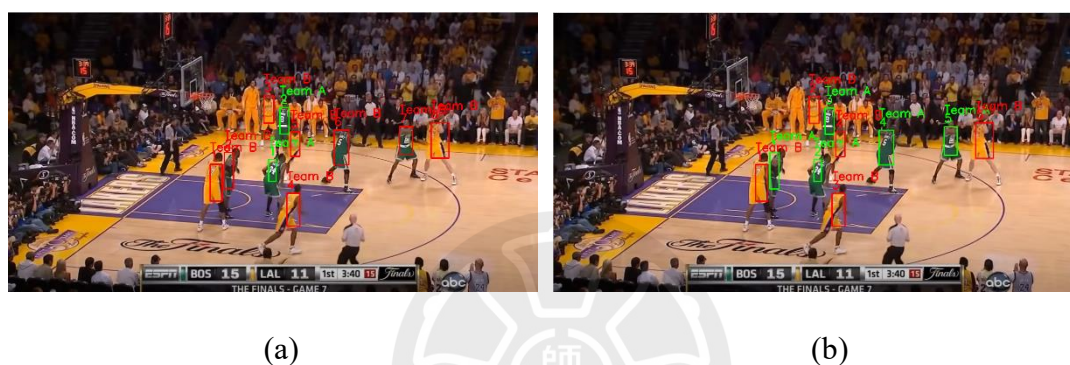


圖 3.10 採用不同特徵之球員分隊範例。(a) 僅用色調特徵之聚類結果，(b) 色調特徵加上顏色強度特徵之聚類結果。



圖 3.11 不同聚類數之球員分隊測試。(a) 聚類數 $K=2$ 之球員分隊結果，(b) 聚類數 $K=3$ 之球員分隊結果。

然而本研究利用界定球場範圍的概念來區隔場上球員與場外非球員，所以部分較靠近球場範圍的觀眾或裁判也可能會被誤判為場上球員，因此需要一項機制來將場內球員與被誤判為球員的裁判與觀眾做區隔。最直觀的方法為將 K -means clustering 的聚類數 K 設為 3，這三個聚類分別代表兩支比賽球隊球員與非球員

(例如裁判與觀眾)。本研究進行了不同聚類數($K=2$ 以及 $K=3$)的實驗測試，如圖 3.11 所示。圖 3.11(a)所示為 $K=2$ 之球員分隊結果；而圖 3.11(b)所示為 $K=3$ 之球員分隊結果。可以觀察到與 $K=2$ 相比，令 $K=3$ 不僅無法將裁判與觀眾另行區分，且原先正確的球員分隊結果也會遭到混淆與干擾(如圖 3.11(b))。故本研究最後決定將聚類數 K 設為 2，在這種情況下若有超過十筆的球員資料輸入，系統將會分別選擇五筆最靠近二聚類中心的資料視為該隊球員，而將其他多餘的資料捨棄。最後將分隊完成的兩支球隊球員座標分別進行紀錄。

整體而言，本研究在輸入影片投影轉換至平面戰術板座標系的過程中，首先使用 Resnet101X FPN(Feature Pyramid Network)進行影像上的物件偵測，接著透過邊緣偵測的方法找出球場邊線頂點座標以決定球場範圍。同時縮小偵測到的球員 Bounding box 範圍使其能儘量覆蓋位於球衣的區域，再計算該區域內的色調特徵與顏色強度特徵，使用 K -means clustering 分類該二類特徵將場上球員分成兩隊。最後將原先影像轉為鳥瞰圖(Bird's eye view projection)，透過原始影像球場與欲映射之平面戰術板座標系兩者的球場頂點座標計算出單應矩陣，將原始影像球場中球員的座標映射至平面戰術板座標系並記錄儲存座標，作為防守戰術軌跡生成的條件輸入，最終生成與原先防守戰術不同的比賽狀況並在平面戰術板表現。

第 4 章 實驗結果與討論

本章節將進行實驗結果與討論，共劃分為三節。本章第一節為介紹資料庫介紹與研究設備；第二節探討球場範圍界定分析之改良結果；第三節探討球員分隊功能分析；第四節為 3D 球員座標至 2D 戰術板座標系映射正確率；最後第五節為生成防守戰術軌跡結果。


第一節 資料庫介紹與研究設備

本研究之防守軌跡生成系統使用的是 2016 年由 NBA(National Basketball Association)開發的資料庫，利用先進的運動追蹤技術捕捉並分析 NBA 比賽中的各種運動數據。該系統使用一組高解析度攝影機和軟體來記錄球場上每個球員和籃球的位置，為每秒紀錄 25 幀的資料，包含了該年度的數十場不同比賽。

本研究將資料集中數十場比賽切分為一萬多個比賽片段作為防守軌跡生成系統的訓練集，而使用者輸入比賽片段再經過投影轉換的結果作為生成的測試集，本研究實驗使用的硬體規格為 AMD Ryzen 5 5500 處理器與 Nvidia GeForce RTX3090。

第二節 球場範圍界定分析

本節分析在本系統投影轉換子系統將場內球員與場外觀眾區分之球場範圍界定實驗之探討。比較經過此方法後的球場範圍與原先範圍之差別與討論。由於影像中球場邊緣的端點很容易觀察，以肉眼決定出 ground truth 以計算正確率。




(a)

(b)

圖 4.1 球場範圍界定前後圖。(a) 預設頂點圖，(b) 球場範圍界定結果圖。

圖 4.1(a)(b)為經過自動尋找頂點改良後的前後對照圖，本實驗範例為理想的實驗結果，透過長度與斜率閾值同時使用可最佳的過濾出底線邊緣，經過實驗發現最適合的長度閾值為 300、斜率閾值為 0.3。實驗結果可以發現經過調整後的球場邊界與真實球場範圍更加符合。而系統需要在初始狀況中決定預設的頂點原因為當無法正確找出底線正確的端點時，系統會使用預設的頂點來防止界定錯誤的球場範圍產生，以下為一組偵測失敗的實驗案例，圖 4.2 為無法正確偵測到球場底線與兩側端點的兩組實驗範例，在 4.2(a)中由於有球員遮擋住底線的位置所以造成偵測出的球場邊界不完整分為上下兩段，此狀況的解決方法為透過判斷偵測到所有端點的 y 座標，取最高與最低值為最終的頂點，但因為底線線段被分割會造成長度與其他的錯誤線段比較靠近，所以對於長度的閾值需要界定得更準確。

而在 4.2(b)的失敗實驗範例中，可以發現球場底線的線段在一開始邊緣偵測的步驟就無法尋找到正確的 edge，經過實驗發現的主要原因可能為影像解析度，因輸入的比賽片段為連續影片分別擷取每張 frame，而在攝影鏡頭會移動的狀況下，會造成影像的解析度不夠高而有模糊的情況，因此在未來工作的部分可以考慮先加入一些前處理，使影像中的資訊能更容易地被偵測出來。另一個原因為球場邊線的顏色本身不易偵測，經過一些實驗表明，球場底線邊緣為淺色，例如白和黃或者與球場內的顏色較為接近時，會造成邊緣不易完整被正確偵測。此時系統會使用一開始給定的四個頂點座標為偵測球場的範圍。



(a)

(b)

圖 4.2 球場偵測失敗範例圖。(a) 範例圖(一)，(b) 範例圖(二)。

圖 4.3 為球場界定頂點前後範圍圖。本段的實驗結果為比較新增球場界定功能(如圖 4.4(a)所示)與給定固定頂點(如圖 4.4(b)所示)的投影轉換至戰術版平面座標系可視化前後比對範例。圖 4.4(a)(b)中的綠點座標對應圖 4.3 中的綠色隊伍球

員，而紅點座標對應圖 4.3 中的黃色隊伍球員。由圖 4.4 界定新的球場頂點座標優化球場範圍後，可以透過觀察兩張圖發現界定球場的真實範圍對投影轉換的正確率具有一定程度的幫助，正確的球場範圍對球員在場上的絕對位置或者相對位置都會有影響，我們可以觀察到圖 4.4(a)中在使用頂點座標由初始給定與真實球場範圍有差異時，最下方的紅色球員點已經在三分線的位置了與真實情況不符合，而經過球場界定功能更新頂點座標後球員位置與真實情況更加接近。



圖 4.3 球場界定頂點前後範圍圖(一)。




圖 4.4 投影至平面戰術板坐標系圖(一)。(a) 頂點座標由初始給定，(b) 使用球場界定功能更新頂點座標後。

在圖 4.3 與 4.4 的範例中，初始給定與經過界定後的座標差距不算太多因此投影結果雖肉眼可見但其實誤差不多。圖 4.5 與 4.6 為另一組球場界定頂點前後差距比較大的實驗範例，圖中的綠點座標對應圖 4.3 中的綠色隊伍球員，而紅點座標對應圖 4.3 中的黃色隊伍球員。可以發現在圖 4.5 中頂點座標由初始給定與真實球場範圍的誤差相聚較大，初始給定的座標明顯與真實球場範圍不符。圖 4.6(a)(b)中最大的差距在最上方的白隊球員在圖 4.6(a)的投影中直接消失了，因為這位球員的位置是位於判斷範圍之外的，而其他球員的相對位置雖然差不多，但整體都有水平移動的現象，與真實影像的絕對位置差距較大。




圖 4.5 球場界定頂點前後範圍圖(二)。




圖 4.6 投影至平面戰術板坐標系(二)。(a) 頂點座標由初始給定，(b) 使用球場界定功能更新頂點座標後。

第三節 球員分隊功能分析

本節將分析在本系統使用球員分隊功能的實驗結果正確率與過程的探討。在區分場上球員的球隊時分隊的依據為使用 Bounding box 內球衣的顏色，透過縮小前面偵測物件 Bounding box 並微調位置使其盡量覆蓋於球衣，接著統計調整過後 Bounding box 區域中 HSI 模型中的色調特徵(Hue histogram)與顏色強度特徵(Intensity value of RGB)，並使用 K-means clustering 技術將這些區域分為兩個或三個聚類(clusters)分別進行實驗，最終分為兩支比賽球隊球員。

如表 4.1 所示首先探討的研究為僅使用色調特徵(Hue histogram)與加上顏色強度特徵(Intensity value of RGB)前後正確率之比較。實驗共挑選了 100 個不同比賽的片段，每個片段都有十位球員需要進行區分，總計分類次數共計 1000 次。由實驗結果可觀察到與僅使用色調特徵(Hue histogram)相比，加上顏色強度特徵(Intensity value of RGB)後正確率提升約 10%，對球員分類的效果更加穩定及可靠。

表 4.1 使用色調特徵與加上顏色強度特徵正確率前後比較。

使用特徵	分隊準確率
色調特徵(Hue histogram)	77.2%
色調特徵(Hue histogram)+顏色強度特徵(Intensity value of RGB)	87.6%

而接下來討論的部分為 *K*-means clustering 技術將需要被區分的區域分為兩個聚類(clusters)與三個聚類(clusters)的實驗結果。表 4.2 為分為三個聚類時(clusters)正確率與分為兩個聚類(clusters)的正確率比較，實驗共挑選了 50 個不同比賽的片段，每個片段都有十位球員需要進行區分，並且實驗範例有挑選包含球員以外的干擾項，如裁判與觀眾。透過 4.7(b)中的結果可觀察出在需要被區分的 Bounding box 中，在區域中顏色非大部分均勻的狀況下分為三個聚類時(clusters)正確率與分為兩個聚類(clusters)正確率較不理想。




圖 4.7 不同聚類數之球員分隊測試。(a) 聚類數 $K=2$ 之球員分隊結果，(b) 聚類數 $K=3$ 之球員分隊結果。

表 4.2 聚類數量選擇正確率之比較。

K 的數量	分隊正確率
$K=2$	75.5%
$K=3$	62.4%

最後本系統使用的方法為將 K 的數量固定為 2，並且加入另一項機制為當場上有干擾項時，意思為有超過十個物件需要區分隊伍時，依照計算與聚類中心點的特徵值歐式距離，來衡量彼此之間的相似程度，尋找同個聚類內最相似的五項資料，剔除多餘的資料。表 4.3 的實驗資料與表 4.2 相同，分別在於 K

固定為 2 的狀況下，加入尋找同個聚類內最相似的五項資料的方法與未加入的正確率比較，在表 4.3 內表示為 *K=2。

表 4.3 聚類數量固定時加入相似程度正確率之比較。

使用方法	分隊正確率
K=2	75.5%
*K=2	83.8%

而結束球員分隊的工作後，系統會將不同球隊的球員座標分類再一起，圖 4.8(a)、(b)、(c) 為一項成功的實驗範例與投影至平面戰術板座標系並進行可視化的結果。最終經過投影輸出座標至防守戰術軌跡系統作為生成虛擬防守戰術軌跡的條件。

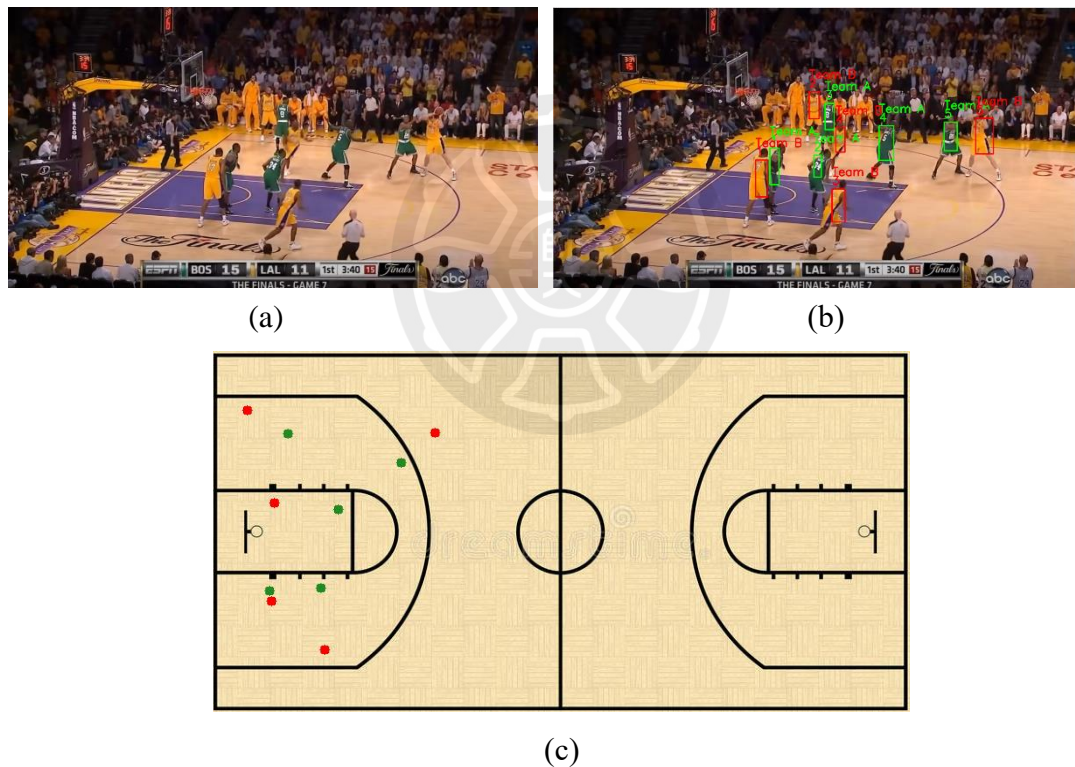


圖 4.8 分隊過程與可視化。(a) 輸入影像，(b) 分隊結果，(c) 平面戰術板座標系可視化。

第四節 3D 球員座標至 2D 戰術板座標系映射正確率

本節探討原始輸入影片經過投影轉換子系統後輸出的座標與 ground truth 比較之正確率。實驗使用一段 NBA 比賽的片段，將該片段切分為 100 張 frames，每張 frame 都有十位球員與籃球需要進行比較球員計算正確率的總數量為 1000，

籃球為 100，表 4.4 為該連續片段映射與 ground truth 比較之正確率結果，允許一定程度的誤差，球員映射的正確率約為 77.2%，而籃球映射的正確率約為 61.0%。球員與籃球映射的正確率差距的原因主要為籃球與球員為小物體，本身正確率與球員相比就會比較低，且籃球有高度的問題，如圖 4.9 所示，當籃球在空中本身具有高度時，映射的結果通常與真實情況有所差距，因此透過觀察並微調映射後籃球的 y 座標，使其與真實情況更加接近。

表 4.4 3D 球員座標至 2D 戰術板座標系映射正確率。

物件	映射正確率
球員	77.2%
籃球	61.0%

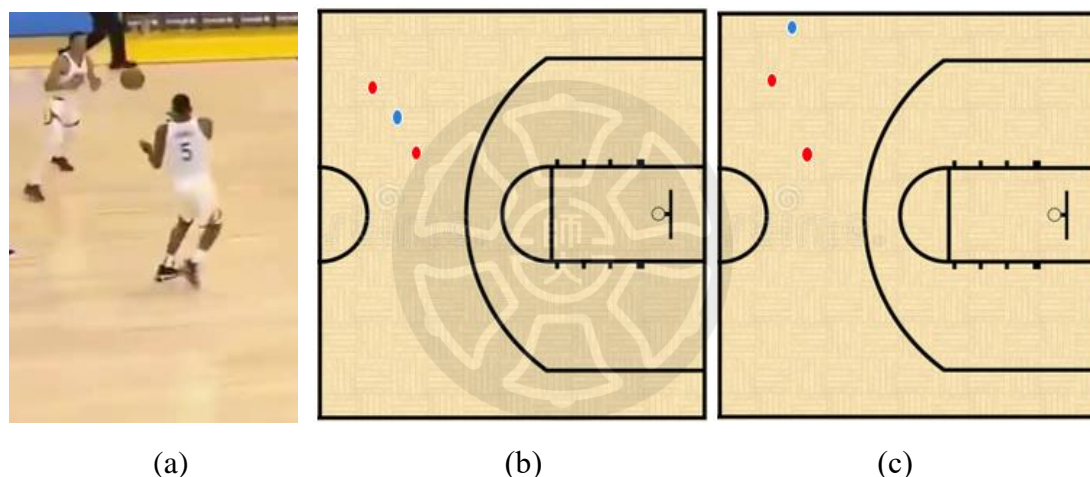


圖 4.9 籃球映射結果與 ground truth 比較結果圖。(a) 輸入影像，(b) ground truth，(c) 系統映射結果。

第五節 生成防守戰術軌跡結果

本節探討將輸入影片經由投影轉換子系統映射至 2D 戰術板座標系的結果並生成防守戰術軌跡與 ground truth 的比較結果，輸入進攻影片的範例進攻球隊使用的戰術為擋拆戰術。圖 4.10(a)、(b)、(c)、(d)、(e)分別代表真實片段、ground truth、投影轉換子系統映射結果、生成防守戰術軌跡結果(1)、生成防守戰術軌跡結果(2)。其中綠色點代表籃球，紅色點 A1~A5 代表進攻球員，藍色點 B1~B5 代表防守球員，而對應顏色的線段代表該點的移動軌跡。由左至右分別代表場上初始狀況、擋拆戰術發生時、球員出手投籃。

由圖 4.10(b)、(c)可觀察到投影轉換子系統映射結果與 ground truth 差距較大的部分為籃球的軌跡部分相對比較不穩定，原因為籃球投影轉換的正確率較低，且位於球場邊緣的球員相對於球場中央位置也誤差較大。由圖 4.10(c)、(d)、(e)可觀察出生成的防守戰術軌跡與真實情況比較，生成的防守戰術對持球者的防守較嚴密，且每位進攻球員都會受到一定程度的防守，具有一定程度的真實性與可信性。

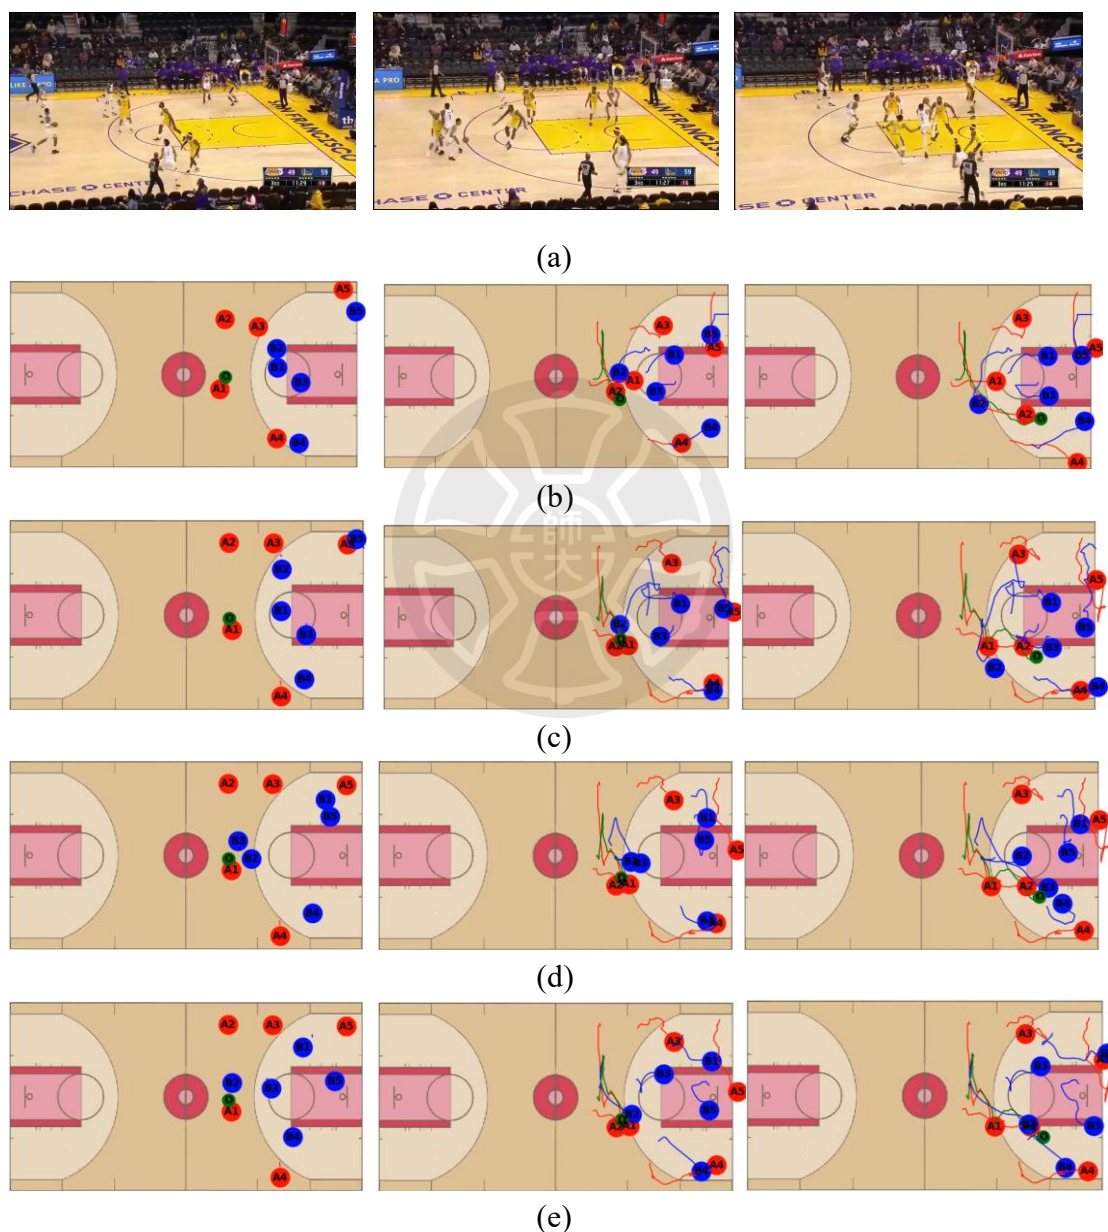


圖 4.10 分隊過程與可視化。(a) 真實片段，(b) ground truth，(c) 投影轉換子系統映射結果，(d) 生成防守戰術軌跡結果(1)，(e) 生成防守戰術軌跡結果(2)。

第 5 章 結論與未來工作

第一節 結論

近年來運動分析的研究相當熱門，透過將生成對抗網路應用在籃球領域能夠幫助球隊提升籃球攻防戰術的素養，開發出基於深度學習之籃球攻防戰術軌跡生成系統。本系統開發目的為進攻球隊使用者在分析研究防守球隊可能會出現的防守方法時，通常只能使用經驗判斷推測，若透過本系統自動產生防守戰術軌跡供進攻球隊參考，進攻球隊可更加理解實戰中可能會遇到的防守戰術，可提升球員的戰術素養讓球隊提早思考應對方法。

本系統透過使用者將一段真實籃球比賽攻防片段輸入，系統主要分為兩個子系統：投影轉換子系統與防守戰術軌跡生成子系統。投影轉換子系統主要分為三個步驟，第一為球場上球員與球的偵測方法為使用預訓練模型 Resnet101X FPN 進行影像中所有物件的偵測，接著界定球場的範圍以便將場上的球員與場外的觀眾進行區隔。第二為場上球員分隊使用球衣顏色做為辨別的依據，並使用色調特徵 (Hue histogram) 與顏色強度特徵 (Intensity value of RGB) 進行 K-means clustering。接著為 3D 球員座標投影對原先影像進行 Bird's eye view projection，將影像轉為鳥瞰圖，再透過真實球場的四個頂點與平面戰術板的四個頂點計算出單應矩陣將對應的 3D 座標映射在 2D 戰術板球場座標系中並記錄為檔案作為防守戰術軌跡生成子系統的輸入。最後一個步驟使用生成對抗網路來進行防守戰術軌跡生成。

本研究實驗結果顯示，透過影像處理得到球場邊線同時界定新的球場範圍可有效省略透過觀察手動決定球場頂點的步驟，減少時間成本。接著加入球員分隊的功能，透過計算該區域內的色調特徵與顏色強度特徵，使用 K-means clustering 分類該二類特徵將場上球員分成兩隊，分隊的成功率可達到最高，以利最後映射至平面戰術板座標系還原出真實比賽的情況。結合了真實籃球比賽片段與防守戰術軌跡生成系統產生虛擬的防守戰術軌跡。

第二節 未來工作

本研究所提出之基於深度學習之籃球攻防戰術軌跡生成系統仍然有許多可優化部分。第一個可優化的項目為處理球員遮擋的問題，籃球是一項激烈的運動，在真實比賽中球員常常需要貼身對抗，而在貼身狀況下會造成物件偵測系統不易辨識。因此在無法順利辨識球員與球的情況下，計算出當下球員與球可能的位置，使其符合球場上真實情況，是一項可優化的任務。

第二個可優化項目為提高物件偵測模型對此籃球比賽辨識率的提高，雖然本研究使用之 Resnet101X FPN 模型對比其他模型相對適合偵測籃球比賽的球員與球。但在球員與球位移速度太快而導致模糊時，正確率就會相應降低。因此若研發專門應用於籃球場上的物件偵測模型，可提升後續投影轉換系統的正確率。

第三個可優化項目為新增其他戰術分析功能模型，本系統著重於投影轉換系統的改良以獲取真實比賽情況的資訊，因此若能加入其他戰術分析功能模型，例如分析場上可能為何種進攻戰術。可使分析球場上狀況功能更加完整，讓使用者有更多應用選擇。

本研究在經過投影轉換系統還無法達到百分之百正確的投影結果，因此產生的結果與真實場上情況還是會有一部分的出入，若想要完全符合真實場上情況依然要進行部分的手動校正。期望未來該結合真實比賽之防守戰術軌跡生成系統可被應用於球隊戰術分析之中，也期待該系統之功能可更加完善。

参考文献

- [Lec1] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998.
- [Gir2] R. Girshick, J. Donahue, T. Darrell and J. Malik, “Region-Based Convolutional Networks for Accurate Object Detection and Segmentation,” *Proceedings of the IEEE*, vol. 38, no. 1, pp. 142-158, 1 Jan. 2016.
- [Gir3] R. Girshick, “Fast R-CNN,” *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, pp. 1440-1448, 2015.
- [Ren4] S. Ren, K. He, R. Girshick and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *Proceedings of the IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137-1149, 1 June 2017
- [He5] K. He, G. Gkioxari, P. Dollár and R. Girshick, “Mask R-CNN,” *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Venice, Italy, pp. 2980-2988, 2017.
- [Lin6] T. Y. Lin, P. Dollar, R. Girshick, K. He, B. Hariharan, and S. Belongie, “Feature Pyramid Networks for Object Detection,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2117-2125, 2017.
- [He7] K. He, X. Zhang, S. Ren and J. Sun, “Deep Residual Learning for Image Recognition,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, pp. 770-778, 2016.
- [Jan8] S. Janssen (2019, Dec. 21). “The journey towards creating a Basketball mini-map” Available: <https://www.linkedin.com/pulse/journey-towards-creating-basketball-mini-map-stephan-janssen> (Dec. 21, 2019).
- [Moh9] G. Mohan (2021, Dec. 24). “Developing a Basketball Minimap for Player Tracking using Broadcast Data and Applied Homography” Available: <https://medium.com/mllearning-ai/developing-a-basketball-minimap-for->

player-tracking-using-broadcast-data-and-applied-homography-433183b9b995 (Dec. 24, 2021).

- [Ngu10] H.T. Nguyen, H.S. Hoang, T.P.D. Chu, Q.D. Vu, and M.H. Luu, “A video-based tracking system for football player analysis using Efficient Convolution Operators,” *Proceedings of 2019 IEEE Conference on Advanced Technologies for Communications (ATC)*, Hanoi, Vietnam, 2019, pp. 149-154.
- [Che11] C. Y. Chen, W. Lai, H. Y. Hsieh, W. H. Zheng, Y. S. Wang, and J. H. Chuang, “Generating Defensive Plays in Basketball Games,” *Proceedings of the 28th ACM International Conference on Multimedia (MM '18)*, 9 pages, New York, 2018.
- [Hsi12] H. Y. Hsieh, C. Y. Chen, Y. S. Wang, and J. H. Chuang, “Basketball GAN: Generating Basketball Play Simulation Through Sketching,” *Proceedings of the 27th ACM International Conference on Multimedia (MM '19)*, 9 pages, New York, 2019.
- [Mil13] A. Miller, “Possession Sketches: Mapping NBA Strategies,” *Proceeding of 2017 Sport Analytics Conference*, Hynes Convention Center, 2017.
- [Nis14] A. Nistala, and J. Guttag, “Using Deep Learning to Understand Patterns of Player Movement in the NBA,” *Proceedings of 2019 MIT SLOGN Sport Analytic Conference*, Boston, 2019.
- [Jav15] L. Javadpour, J. Blakeslee, M. Khazaeli, and P. Schroeder, “Optimizing the best play in basketball using deep learning,” in *Journal of Sports Analytics*, vol. 8, no. 1, pp. 1-7, 2022.
- [Che16] C. H. Chen, T. L. Liu, Y. S. Wang, H. K. Chu, N. C. Tang, and H. Liao, “Spatio-Temporal Learning of Basketball Offensive Strategies,” *Proceedings of the 23rd ACM international conference, Multimedia*, 13 October 2015.
- [Liu17] Y. Liu, P. Sun, N. Wergeles, Y. Shang, “A survey and performance evaluation of deep learning methods for small object detection” *Proceedings of Electrical Engineering and Computer Science (EECS)*, USA, 2021.
- [Yoo18] Y. Yoon, H. Hwang, Y. Choi, M. Joo, H. Oh, I. Park, K. Lee, J. Hwang, “Analyzing Basketball Movements and Pass Relationships Using Realtime Object Tracking Techniques Based on Deep Learning” *Proceedings of IEEE Access*, vol. 7, pp. 56564-56576, 2019.

- [Che19] L. Chen, W. Wang, “Analysis of technical features in basketball video based on deep learning algorithm,” Image Communication, Volume 83, Issue C, Apr 2020.
- [1] 全球最受歡迎運動，第一意料之內，第二竟然是...？, Availble: <https://mag.sportsoho.com/%E5%85%A8%E7%90%83%E6%9C%80%E5%8F%97%E6%AD%A1%E8%BF%8E%E9%81%8B%E5%8B%95>
- [2] Michael Jordan, Availble: <https://cdn.nba.com/manage/2021/08/michael-jordan-looks.jpg>
- [3] Kobe Bryant, Availble: https://imagez.tnz.com/image/1e/4by3/2020/01/26/1e77e10e628e4ccf81a8a21b40f36d3b_md.jpg
- [4] Dwight Howard, Availble: <https://slamdunkhk.com/wp-content/uploads/2022/11/Dwight-Howard-Taiwan-Injury-2-weeks.webp>
- [5] 林書豪, Availble: <https://cdn.ttv.com.tw/manasystem/FileData/News/23015e20-d8a2-43d6-9714-40104c1676f0.jpg>
- [6] 真實籃球比賽, Availble: https://github.com/GauravMohan1/Basketball_Homography/blob/main/college_middle.png
https://github.com/GauravMohan1/Basketball_Homography/blob/main/college_right_half.png
- [7] 戰術板, Availble: https://cdntwrunning.biji.co/800_b5272bba13dd94e97dff9202300e133c.jpg
https://m.media-amazon.com/images/I/61mBOXiq1+L._AC_SX679_.jpg