

# 不同卷積神經網路用於製作桌球戰術情報蒐集系統的 效益：系統性回顧

陳羿揚\*

閩南師範大學體育學院

\*通訊作者：陳羿揚  
通訊地址：363000 福建省漳州市薌城區縣前直街 36 號  
E-mail: hc7022709@gmail.com  
DOI:10.6167/JSR.202512\_34(2).0006  
投稿日期：2025 年 3 月 接受日期：2025 年 6 月

## 摘 要

本研究目的在於探討近年影像動作辨識系統協助桌球戰術情報蒐集的效益；分別在 Google Scholar、PubMed、Scopus 與 Airiti Library 華藝線上圖書館以「桌球」、「動作辨識」、「深度學習」、「卷積神經網路」、「人工神經網路」、「運動學」為中、英文關鍵字，搜尋 2019 年 1 月至 2025 年 1 月共 6 年期間的實證性論文，釐清動作辨識系統如何應用於辨別桌球動作姿態、採用哪種學習模型、哪種提取法與觀測指標、數據資料庫、參與者背景與辨識數量、辨識結果代表的意義、動作姿態種類；提供教練團、情報蒐集與運科人員作為學習操作動作辨識系統前之參考依據與研究人員後續研究參考依據。結果得知，製作桌球影像動作辨識系統流程以卷積神經網路搭配慣性測量單元 (inertial measurement unit, IMU) 與適當提取法為主要趨勢；可觀測職業、半職業、業餘至學生層級的網路賽事影片、實際規劃實驗與 3D 桌球數據集作為資料庫驗證系統辨別效益；且一次最多可分析 10,000 筆資料與 9 種動作姿態；且辨別正手、反手擊球與無旋轉的球體落點與軌跡為最多，最高可達 98.80% 準確率、95.17% 精確率、100.00% 召回率與 97.86% F1 分數。表示採用卷積神經網路製作的動作辨識系統已可取代傳統戰術情報蒐集，自動辨別與分類桌球動作姿態、球體落點與飛行軌跡來提升情報蒐集效益。

**關鍵詞：**深度學習、穿戴裝置、準確率、召回率、自動化

## 壹、前言

桌球競賽擬定戰術前皆會事先設立賽會目標範圍、蒐集國內外相關資料、文獻、對手歷屆比賽影片、備齊各種技術分析表等，並在現場藉由技術分析表、發球搶攻戰術分析表或以攝影機實況紀錄，使用觀察法 (observational method) 將對手動作姿態、慣用習性、球體落點與軌跡等所得資料加以敘述統計，作為傳統對戰組合戰術情報蒐集 (以下簡稱情蒐) 依據，並根據事後分析結果得出結論，再提出相關建議供教練團開會擬定應對策略 (王李中羿、莊哲偉，2024；王明月等，2010；孫明德等，2022；許吉越等，2018；熊志超等，2020)；此方式有著能借助影片重複回放確認記錄的動作姿態種類、球體落點、軌跡與拍數等物理參數正確性，再轉換為次數解析對戰組合的對慣用賽習性，從而擬定因應策略的優勢，但同時伴隨著需耗費大量時間比對影片、人力、物力與可能因為情蒐人員桌球觀念不一致，導致傳統情蒐過程容易出現誤判、主觀認定或遺漏重要資料機率等劣勢。倘若欲降低上述劣勢，提升情蒐效益與更精確解析對手慣用習性，解決策略應可導入由深度學習 (deep learning) 模型製作的影像動作辨識系統 (以下簡稱動作辨識系統)，協助情蒐人員提取動作姿態關鍵特徵，分類競賽影片中的攻、守動作姿態、球體落點與軌跡，如此才能有效提高桌球情蒐效率，供教練團更客觀擬定戰術因應策略。

製作桌球動作辨識系統核心原理是

模擬人類神經網路來建立人工神經網路，藉由穿戴在參與者身上的慣性測量單元 (inertial measurement unit, IMU) 搭配影片錄製，透過加速規、陀螺儀產生的加速度、角速度等物理參數採集大量動作姿態、球體落點、軌跡等資料進行特徵學習 (Gao et al., 2019)，接著進行人體或物體訊息資料前處理，確保資料品質和一致性，包含運用平滑濾波器 (smoother) 去除影像雜訊，接著以手動或自動資料標註 (Dhiman et al., 2023; Li et al., 2022)；再透過旋轉、翻轉等模擬不同遮擋情況增加影像資料多樣性，防止模型過擬合 (fitting) 與提高模型的魯棒性 (robustness) (Maddalena & Petrosino, 2018)，接著將連續的資料分段，提取出特定時間範圍內的數據，或比對 IMU 的物理參數將特定事件與姿態變化分段，再進行資料標準化、空間、時間特徵提取、資料降維 (data dimension reduction) 等運算，並從原始數據中提取有用訊息，再視需求選用適當神經網路：包含卷積神經網路 (convolutional neural network, CNN)、循環神經網路 (recurrent neural network, RNN)、圖神經網路 (graph neural networks, GNN)、支持向量機 (support vector machine, SVM)、隨機決策森林 (random decision forests) 等機器學習 (machine learning) 或深度學習算法進行模型設計與訓練 (Maddalena & Petrosino, 2018)，爾後使用測試數據集比對準確率 (accuracy)、精確率 (precision)、召回率 (recall)、F1 分數 (F1 score)、AUC-ROC 曲線 (area under the curve of ROC) 等指標驗證性能 (Gomez-Gonzalez et al., 2019; He & Li,

2024; L. Ma & Tong, 2024; Ning et al., 2023; Shi, 2025)，作為製作或改良桌球動作辨識系統檢測依據。

目前用於辨別桌球動作姿態主流趨勢，主要討論如何製作或改良系統來提升辨別效益，或搭配 IMU 錄製影片後，驗證與釐清哪種特徵提取法（以下簡稱提取法）才能更有效提升辨識成功率；然而動作辨識系統的製作多數來自電機工程與資訊工程領域工程師與研究員，且論文皆發表至理工科相關領域，使得情蒐人員或運動科學相關人員難能在體育與運動科技領域檢索到相關論文，且此領域論文多數屬於驗證系統效益的實證研究，使得情蒐與運動科學人員需耗費大量時間閱讀，才能實際瞭解動作辨識系統如何應用於辨別桌球動作姿態，可採用哪種深度學習模型、基於哪種提取法與觀測指標、數據資料庫來源、參與者背景與辨識數量、辨識結果代表的意義、動作姿態種類；為了提供情蒐人員與運動科學人員，在操作動作辨識系統前有充分認知，透過系統性彙整近年動作辨識系統用於辨別桌球動作姿態、球體運動學的相關實證研究，釐清現今研究現況與深度解析具體適用方式有其必要性，可提供教練團與情蒐人員瞭解以 CNN 製作的動作辨識系統如何提升情蒐效益，與在操作動作辨識系統前瞭解實務應用範圍。同時提供相關研究人員在製作系統前，作為評估硬體、軟體與人力資源運用的合理性和後續研究參考依據。

基於上述，本研究參考系統性回顧與

統合分析首選報告項目聲明書 (preferred reporting items for systematic reviews and meta-analysis, PRISMA) 建議進行相關流程，並分為文獻檢索策略、文獻篩選、選擇過程與數據蒐集過程，及品質風險評估等進行說明，具體目的如下：

- 一、以系統性回顧釐清 2019 年 1 月至 2025 年 1 月共 6 年，動作辨識系統用於桌球動作姿態的研究現況。
- 二、解析此類主題實驗設計、動作辨識系統、提取法、數據資料庫來源、參與者背景、器材、測試數量與辨識結果差異。
- 三、提出此類主題未來研究方向與相關建議。

## 貳、方法

### 一、文獻檢索策略

本文檢索的文獻資料庫、擬定的關鍵字、審查納入和排除的條件標準，皆事先經由 2 位在大專院校從事教職的教師，1 位具有 6 年桌球課程教學經驗，另一位任教 5 年運動生物力學與運動科技相關課程，及一位工程科學博士，與 3 位運動生物力學碩士共同商討後，在正式搜尋文獻前將英文關鍵字設定為“table tennis”、“motion recognition”、“deep learning”、“convolutional neural network”、“artificial neural network”、“kinematics”，中文關鍵字為「桌球」、「動作辨識」、「深度學習」、「卷積神經網

路」、「人工神經網路」、「運動學」。事先採用 Google Scholar 作為資料庫以英文關鍵字進行檢索，發現2016年中檢索出40篇，2017年共76篇，2018年共91篇，上述雖與動作辨識主題相關，但討論的運動項目都與桌球無關，2019年共129篇，且已開始討論動作辨識系統如何應用於測得桌球軌跡等相關主題；因此擬定檢索起始至結束年限從2019年1月至2025年1月共6年，作為本研究擬定資料庫搜尋時間。

正式搜尋時以 Google Chrome 分別在 Google Scholar、Scopus、PubMed 中檢索英文文獻，在 Airiti Library 華藝線上圖書館中檢索中文文獻，並在相對應的資料庫中輸入中、英文關鍵字進行搜尋。使用 Google Scholar 進行英文文獻檢索時，依序在左側欄位點按「按照關聯性排序」，由於本研究期望在 Google Scholar 檢索英文文獻，因此在語言欄位中點選不限語言、不限類型、再排除英文以外語言、排除包含專利、只包含書目與引用資料，只納入英文文獻，再將關鍵字直接輸入搜尋引擎中，並以逗號相隔進行檢索，發現共1,290篇。使用 Scopus 時則將每個關鍵字以“or”相隔，再輸入至「查找包含這些術語的文章」的搜尋引擎中進行檢索，進入下一頁面後在左側年分欄位中按下自訂範圍，接著在右側年分欄位中輸入2019–2025點按搜尋，發現共26篇。使用 PubMed 時，同樣將每個關鍵字以“or”相隔，再輸入至搜尋引擎中，接著在左側欄位輸入2019–2025年，並在「文本可用性」中勾選「免費全文」與「全文」，接著在「文章類型」中勾選「驗證研究」，發現共436篇。另

外，在 Airiti Library 華藝線上圖書館的搜尋引擎中選按「進階查找」，並添加5個新欄位，在欄位2至6中左側點選 AND，中間欄位點選「文章篇名、關鍵字、摘要」，右側欄位依序放入關鍵字，下方文章類型中勾選「所有類型」，出版日期欄位選按「自訂範圍」並輸入2019–2025年，再勾選「繁體中文」與「臺灣」接著按查詢，發現共0篇。4個資料庫共計1,752篇。

## 二、文獻篩選

將搜尋到的1,752篇文獻初步排除非採用桌球運動為專項、單純以數學及物理公式推導、僅以數學公式推算球體軌跡、演算法原理介紹、非討論動作辨識相關主題、同時觀測多種不同專項、家庭安全監控、生活動作辨識與手勢識別、機器人手臂製作。細部一：排除書籍、會議摘要、專利、學位論文、回顧性論文、未經完整審查的預印本、因版權問題僅能閱讀摘要之學術期刊。細部二：排除英文與中文以外語言、無摘要或無全文之學術期刊。細部三：排除未符合自變項為比較或驗證不同、單一辨識系統與分類策略、排除內文中未明確說明辨別的桌球球路、依變項為至少具備一種或一種以指標，且需在文中提出實際應用層面、預期能為桌球相關產業帶來的具體效益、排除4個資料庫中重複的論文，作為本研究納入資格標準依據。

## 三、選擇過程與數據蒐集過程

將檢索後的1,752篇相關文獻經由6位審查員，依序初步與細部納入和排除的

條件逐一過濾，包含樣本特性（作者、發表年分）、實驗設計、樣本與資料來源、動作辨識判定成功率指標、研究結果與實務貢獻等，並在每階段篩選後，需將符合的文獻提供給每位審查員重複確認，至少4位審查員同意後，才將文獻納入本研究進行深度分析，期刊論文篩選流程，如圖1。

#### 四、研究品質風險評估

採用文獻質量風險評估量表 (Jadad

Quality Scale) 將納入的 14 篇比對研究內容 (表 1)，根據量表標準評估內容品質，分析共 4 個維度，將符合的內容給予適當分數 (Jadad et al., 1996)。前 3 個維度依序為實驗時參與者選擇中是否採隨機序列、隱藏分配與盲法試驗 (blinded experiment)，符合標準最高皆得 2 分，不清楚則得 1 分，不恰當得 0 分。第 4 個維度則為是否敘述了參與者撤出或退出的理由，描述得 1 分，未描述得 0 分，總分 1-3 分為低質量，4-7

圖 1  
期刊論文篩選流程

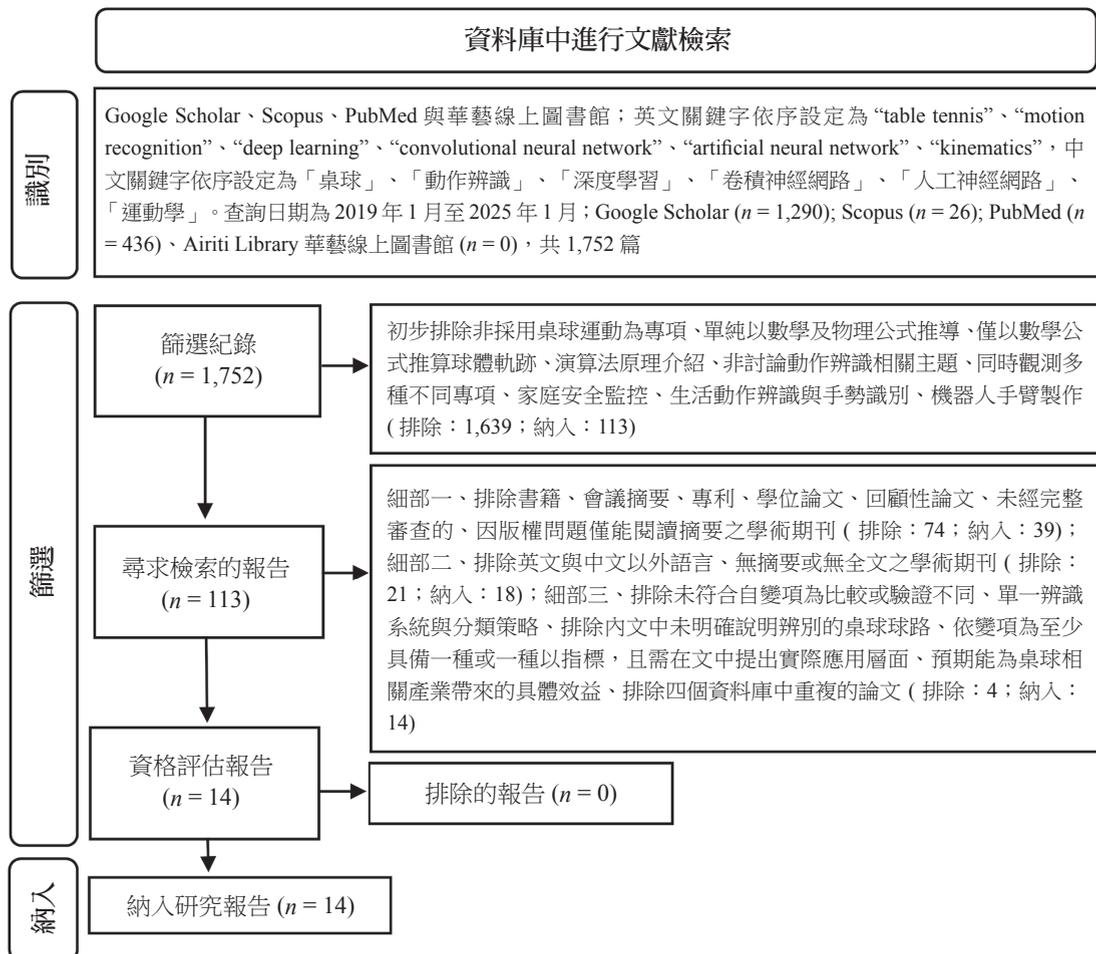


表 1  
文獻風險評估

| 作者 (年分)                      | 隨機序列        | 隱藏分配        | 盲法測試        | 撤出或退出 | 總分          |
|------------------------------|-------------|-------------|-------------|-------|-------------|
| Yanan et al. (2021)          | 1           | 1           | 1           | 0     | 3           |
| Liu and Ding (2022)          | 0           | 0           | 0           | 0     | 0           |
| Ning et al. (2023)           | 0           | 0           | 0           | 0     | 0           |
| Shi (2025)                   | 1           | 1           | 1           | 0     | 3           |
| He and Li (2024)             | 1           | 1           | 1           | 0     | 3           |
| Gomez-Gonzalez et al. (2019) | 0           | 0           | 0           | 0     | 0           |
| P. Wang et al. (2019)        | 0           | 0           | 0           | 0     | 0           |
| Zou et al. (2024)            | 1           | 1           | 0           | 0     | 2           |
| L. Ma and Tong (2024)        | 1           | 1           | 0           | 0     | 2           |
| Fujihara et al. (2025)       | 0           | 0           | 0           | 0     | 0           |
| Hegazy et al. (2020)         | 1           | 1           | 0           | 0     | 2           |
| Hegazy et al. (2021)         | 1           | 1           | 1           | 0     | 3           |
| Ning et al. (2024)           | 1           | 1           | 1           | 0     | 3           |
| Zhang et al. (2019)          | 1           | 1           | 1           | 0     | 3           |
| 平均數 ± 標準差                    | 0.64 ± 0.49 | 0.64 ± 0.49 | 0.43 ± 0.51 | 0 ± 0 | 1.71 ± 1.38 |

註：依照納入順序進行排序。

分為高質量 (Clark et al., 1999; Olivo et al., 2008)。經評估後發現，隨機序列維度與隱藏分配維度中所得平均分數皆為  $0.64 \pm 0.49$  分，盲法測試維度為  $0.43 \pm 0.51$  分，撤出或退出維度為  $0 \pm 0$  分，單篇最高分數為 3 分，最低則為 0 分，平均總分為  $1.71 \pm 1.38$  分。

整體而言，此類主題著重在討論需搭配何種提取法與如何提升系統辨識效益，來製作或改善桌球動作辨識系統。研究中可能因為採用機械手臂、發球機或桌球數據集取代實際招募參與者進行實驗影像錄製，而對於參與者是否採隨機序列、隱藏分配與盲法試驗等涉略較少，因此多數皆被評估為不清楚，使納入本研究的文獻品質屬於低質量。

## 參、結果

將 14 篇研究依目的、自變項與依變項區分 (表 2)。以目的而言，有 6 篇討論如何製作桌球軌跡捕捉系統為最多；其次為 4 篇以 IMU 搭配 CNN 製作桌球動作辨識系統，少數為各 2 篇以製作桌球落點捕捉系統，與製作桌球動作辨識系統。顯見，近年製作桌球動作辨識系統主要趨勢為討論如何客觀捕捉球體飛行軌跡與動作姿態為主。原因可能為桌球勝負的關鍵在於接發球得分、開局領先、逆轉、前三板得分和減少非受迫性失誤，達成上述關鍵條件皆需事先判斷對手動作姿態，與球體飛行軌跡才能實踐 (蔡亞倫等, 2023)；造就多數研究皆討論如何更客觀捕捉動作姿態與球體飛行軌跡，來提升比賽獲勝率。

表 2  
實驗設計比較

| 作者 (年分)                      | 目的                        | 自變項  | 依變項                      |
|------------------------------|---------------------------|--|--------------------------|
| Yanan et al. (2021)          | IMU 搭配 CNN 製作桌球動作辨識系統     | 不同神經網路 (MDFF-CNN、傳統 CNN、Inception-CNN)、不同提取法 (K-近鄰、SVM、單純貝氏分類器、隨機決策森林)     | F1 分數                    |
| Liu and Ding (2022)          | 使用 CNN 與複合式網路製作預測桌球飛行軌跡系統 | 不同提取法 (YOLOv3、YOLOv3-tiny、YOLOv4、one-stage Yolo)                           | 辨識時間、準確率                 |
| Ning et al. (2023)           | 製作桌球落點捕捉系統                | 不同幀數 (30、60、120 fps)、不同提取法 (ViBe、YOLO v5、DRC)、不同捕捉時機 (即時、非即時)              | 準確率                      |
| Shi (2025)                   | 製作桌球動作辨識系統                | 不同數據集 (TTSD、TTTD)、不同提取法 (SVM-KPCA、SVM-GA、AdaBoost-RF、SVM 結合 AdaBoost)      | 準確率、辨識時間                 |
| He and Li (2024)             | 製作桌球軌跡捕捉系統                | 不同提取法 (YOLOv4、YOLOv4-tiny、YOLOv3、OLOv4-Tiny 結合 SPM GRU 模型)、不同光線環境 (正常光、弱光) | 精確率、準確率、F1 分數            |
| Gomez-Gonzalez et al. (2019) | 製作桌球軌跡捕捉系統                | 不同相機數 (4、8、15、30 臺)、不同異常率 (1、5、10、25、50%)                                  | 球體落點誤差 (公分)、辨識失敗率        |
| P. Wang et al. (2019)        | 製作桌球軌跡捕捉系統                | 驗證以均值漂移法 (mean-shift)、背景相減法 (background subtraction) 製作的動作辨識系統的辨識效益        | 準確率                      |
| Zou et al. (2024)            | 製作桌球軌跡捕捉系統                | 不同面向 (側面、選手視角、面向選手)  | 準確率、召回率、F1 分數            |
| L. Ma and Tong (2024)        | 製作桌球動作辨識系統                | 驗證製作的動作辨識系統遷移學習後的辨識效益  | 準確率、AUC-ROC 曲線、召回率、F1 分數 |
| Fujihara et al. (2025)       | 製作桌球動作辨識系統                | 驗證以多標籤筆畫分類法製作的動作辨識系統的辨識效益  | 準確率、F1 分數                |
| Hegazy et al. (2020)         | IMU 搭配 CNN 製作桌球動作辨識系統     | 不同人體肢體分類法 (獨立模型、運動模型)、不同提取法 (FastDTW、K-近鄰、SVM、單純貝氏分類器)                     | 精確率、召回率、F1 分數、準確率        |
| Hegazy et al. (2021)         | IMU 搭配 CNN 製作桌球動作辨識系統     | 不同提取法 (FastDTW、K-近鄰、SVM、單純貝氏分類器、RNN)                                       | 準確率、辨識時間                 |

表 2  
實驗設計比較 (續)

| 作者 (年分)             | 目的                  | 自變項   | 依變項                        |
|---------------------|---------------------|---|----------------------------|
| Ning et al. (2024)  | 製作桌球落點捕捉系統          | 不同提取法 (YOLOv3s、YOLOv5s、YOLOv7tiny、YOLOv8s、DETR、Res2Net 增強 NLAM 和擴張 DASPP) | 精確率、召回率、mAP0.5、mAP0.5:0.95 |
| Zhang et al. (2019) | IMU 搭配 CNN 製作動作辨識系統 | 不同提取法 (K-近鄰、SVM、單純貝氏分類器、邏輯迴歸、決策樹、隨機決策森林、CNN)                              | 精確率、召回率、F1 分數              |

註：1. 依照納入順序進行排序。

2. AdaBoost-RF：adaptive boosting-random forest (自適應增強隨機森林)；AdaBoost：adaptive boosting (自適應增強)；DASPP：dense atrous spatial pyramid pooling (密集空洞空間金字塔池化)；DRC：dynamic range compression (動態色域法)；K-近鄰：K nearest neighbors；NLAM：non-local attention mechanism (非局部注意力機制)；SPM GRU：sequence pattern mining-gated recurrent unit (循序樣式探勘—門控循環單元)；SVM-KPCA：support vector machine-kernel principal component analysis (支持向量機—主成分分析)；SVM-GA：support vector machine-genetic algorithm (支持向量機—遺傳演算法)；TTSD：table tennis stroke dataset (桌球擊球資料集)；TTTTD：table tennis trajectory dataset (桌球球軌跡資料集)；MDFF-CNN (molecular dynamics flexible fitting-convolutional neural network) 為自行研發之 CNN；DETR (detection with transformer) 為物件偵測演算法；FastDTW (FAST dynamic time warping) 為近似演算法；Res2Net 為多尺度特徵法；YOLOv3、YOLOv3s、YOLOv4、YOLOv4-tiny、OLOv4-Tiny、YOLOv5s、YOLOv7tiny 及 YOLOv8s 為目標檢測解決方案。

進一步分析自變項，多數比較不同提取法來瞭解辨識效益。原因為適當提取法可提取出重要特徵，幫助系統更準確識別和分類不同動作姿態，同時有效降低數據維度、減少運算量，確保有用訊息完整性，並且濾除噪音、干擾和雜訊，關注與利用只對動作識別最具影響力的特徵，從而提高系統抗噪性、穩定性與適應性 (Dhiman et al., 2023; Li et al., 2022)。此外，除了比較不同提取法外，同時包含一併比較不同神經網路 (Yanan et al., 2021)、幀數 (Ning et al., 2023)、數據集 (Shi, 2025)、光線環境 (He & Li, 2024)、相機數與異常率 (Gomez-Gonzalez et al., 2019)、攝影面向 (Zou et al., 2024)、人體肢段分類法 (Hegazy et al., 2020) 等變項；僅 2 篇皆無操弄任何自變項，單純驗證製作的動作辨識系統透過遷移學習 (transfer learning) 或多標籤筆畫分類法後能否順利提升辨識效益。

遷移學習為一種機器學習技術，即在某任務中針對新的相關任務加以微調，預先訓練模型來提升辨識效益。舉凡事先辨別桌球正手加轉弧圈動作姿態再進行遷移學習後，可在辨別其餘影像時提升識別此動作姿態的能力；因此，優點能提高辨識速度與準確度，缺點則需耗費大量資料、運算能力和多次迭代 (iteration) (重複改進、優化模型與算法) 才能訓練完成 (Salehi et al., 2023)。而多標籤分類允許每個樣本屬於多個類別，並以特定方式進行分類；舉凡 Fujihara et al. (2025) 以桌球動作名稱字母「筆畫」數區分，來更精確捕捉複雜動作模式。顯見，動作辨識系統應

用於辨別桌球運動姿態已有一定成功率，造就近年更深入從不同神經網路、攝影品質、套裝數據集資源、人體角度等面向搭配適當觀測指標，試圖釐清如何控制或搭配上變項來製作動作辨識系統，應用於辨別桌球動作姿態、球體落點或軌跡；目的皆為了找尋最佳動作辨識模型來提升情蒐效益。

從依變項中可得知，評估桌球動作辨識性能的指標皆至少以一個以上來驗證；其中以系統能夠正確辨別出動作姿態的比例，辨識特定動作姿態時可靠性越高，數值就越高的準確率為主要評估依據 (公式為正確預測的數量除以總預測數量的準確率) (Emanuel et al., 2024)；僅 2 篇未觀測準確率。另外，亦包含了多次的精確率和召回率度量調和平均數的 F1 分數，分數高表示模型在精確率和召回率間取得良好的平衡，既能準確識別正樣本，也能辨別出更多正樣本，反之可能忽略些許正樣本或錯誤標記反樣本 (Kannoja & Jaiswal, 2018)；亦在所有實際正樣本中，被模型正確預測為正樣本比例的召回率；模型預測的所有正樣本中，實際為正樣本比例的精確率 (Hegazy et al., 2020, 2021; Ning et al., 2024; Zhang et al., 2019)；採用曲線下面積評估模型分類能力，曲線越接近左上角，模型性能越好的 AUC-ROC 曲線、評估模型在較低門檻下的檢測性能，適合評估對檢測框精度要求不高的場景，與更全面的性能評估，考慮了不同邊界框重合度 (intersection over union, IoU) 門檻下的檢測效果，適合要求更高應用場景的均值平均精度 0.5 (mean Average

Precision 0.5, mAP 0.5) (表示在 IoU 閾值為 0.5 時計算得到的 mAP) 與 mAP 0.5:0.95 (表示在多個 IoU 閾值從 0.5 到 0.95, 步長為 0.05 下計算得到的平均 mAP) (Ning et al., 2024)。另外, 少數 3 篇以系統辨識時間、1 篇球體落點誤差 (公分)、辨識失敗率為依據進行辨識。

上述指標中雖多數採用準確率、精確率評估系統的效益, 但所有指標皆可能存在互相影響的關係, 因此製作系統時仍需針對製作的需求, 與目標選擇適當指標。舉凡召回率與精確率兩者常呈現反比關係, 主因為模型可能會識別更多的正樣本, 但其中可能包含更多的錯誤預測 (假陽性 [false positive rate, FPR])。換言之, 高召回率可能降低精確率, 解決方式通常可透過 F1 分數來綜合考量 (Kannoja & Jaiswal, 2018)。此外, AUC-ROC 曲線的形狀與召回率、精確率相互關聯; AUC-ROC 曲線較陡峭時, 表示在較低的 FPR 率下就能達到較高的真陽性率 (true positive rate), 同時也代表模型在召回率與精確率之間取得了較好的平衡 (Huisman, 2024)。製作動作辨識系統進行情蒐而言, 可能因為所辨別的动作姿態複雜度, 與攝影機拍攝角度等, 而導致降低召回率 (陳羿揚, 2024; Hegazy et al., 2020; L. Ma & Tong, 2024; Zou et al., 2024)。另外, 在拍攝桌球競賽影片時可能因為場景中的其他物件, 或某些動作技術種類過於相似 (如削球與推擋), 而導致降低精確率 (陳羿揚、黃筱祺, 2023)。此外, 多數需求需要同時辨別大量不同種類動作, 則需著重 AUC-ROC 曲線, 若某

些桌球動作在訓練數據中出現頻率較低, 模型可能會偏向識別較常見的动作, 與不同的決策閾值或特徵選擇不夠精確, 皆可能降低 AUC-ROC 曲線的表现 (Huisman, 2024), 因此若要提升桌球动作辨識的精細度, 則可考慮採用 mAP 0.5:0.95 進行評估, 若以即時动作偵測為目標, 則需確保不會遺漏重要的訊息, 因此召回率可能更加重要 (Ning et al., 2024)。

顯見, 評估桌球动作辨識系統效益並未有固定指標, 但可確定的是準確率、精確率、F1 分數、召回率、AUC-ROC 曲線、mAP 0.5 與 mAP 0.5:0.95 皆為近年在製作桌球动作辨識系統時, 用於驗證系統辨識成功率重要指標, 其中又以準確率與精確率兩項指標為主, 但製作桌球动作辨識系統時, 仍需考量目的與需求選擇適當指標。

## 肆、討論

### 一、動作辨識系統與動作提取法

桌球动作辨識系統的製作可區分成單純採用不同的 CNN, 與 IMU 搭配不同的 CNN 兩方式 (表 3); 納入的研究中共有 7 篇以 CNN 為主要製作趨勢; 4 篇 IMU 搭配 CNN, 其餘各 1 篇分別以時空圖卷積神經網路 (spatio-temporal graph convolutional networks, STGCN)、GNN、RNN。在製作動作辨識系統時, 使用神經網路與不使用各有優劣勢; 相比於傳統機械學習, 神經網路能夠自動提取影像中的關鍵特徵, 減少人工設計特徵的需求, 適應不同動作類型, 有著較好的可解釋性, 並在多種環境

表 3  
製作系統的背景差異

| 作者 (年分)                      | 動作辨識系統                              |   | 提取法 | 數據資料庫 |
|------------------------------|-------------------------------------|---|-----|-------|
|                              | MDFF-CNN、CNN 與 Inception-CNN        | K-近鄰、SVM、單純貝氏分類器、隨機決策森林   |     |       |
| Yanan et al. (2021)          | IMU 搭配 MDFF-CNN、CNN 與 Inception-CNN | K-近鄰、SVM、單純貝氏分類器、隨機決策森林   |     | 實際實驗  |
| Liu and Ding (2022)          | CNN                                 | YOLOv3、YOLOv3-tiny、YOLOv4、One-stage Yolo                          |     | 實際實驗  |
| Ning et al. (2023)           | CNN                                 | ViBe、改進的 ViBe、YOLO v5、DRC   |     | 實際實驗  |
| Shi (2025)                   | STGCN                               | SVM -KPCA、SVM -GA、AdaBoost-RF、SVM 結合 AdaBoost                     |     | 桌球數據集 |
| He and Li (2024)             | CNN                                 | YOLOv4、YOLOv4-tiny、YOLOv3、OLOv4-Tiny 結合 SPM-GRU                   |     | 網路影片  |
| Gomez-Gonzalez et al. (2019) | CNN                                 | 單階段檢測   |     | 實際實驗  |
| P. Wang et al. (2019)        | CNN                                 | 均值漂移法、背景相減法   |     | 實際實驗  |
| Zou et al. (2024)            | GNN                                 | YOLOv8  |     | 網路影片  |
| L. Ma and Tong (2024)        | RNN                                 | Transformer 模型  |     | 桌球數據集 |
| Fujihara et al. (2025)       | CNN                                 | 以字母筆畫進行標籤   |     | 桌球數據集 |
| Hegazy et al. (2020)         | IMU 搭配 CNN                          | FastDTW、K-近鄰、SVM、單純貝氏分類器  |     | 實際實驗  |
| Hegazy et al. (2021)         | IMU 搭配 CNN                          | FastDTW   |     | 實際實驗  |
| Ning et al. (2024)           | CNN                                 | YOLOv3s、YOLOv5s、YOLOv7tiny、YOLOv8s、DETR、Res2Net 增強 NLAM 和擴張 DASPP |     | 桌球數據集 |
| Zhang et al. (2019)          | IMU 搭配 CNN                          | K-近鄰、SVM、單純貝氏分類器、邏輯迴歸、決策樹、隨機決策森林、CNN                              |     | 實際實驗  |

註：1. 依照納入順序進行排序

2. AdaBoost-RF：adaptive boosting-random forest (自適應增強隨機森林)；AdaBoost：adaptive boosting (自適應增強)；DASPP：dense atrous spatial pyramid pooling (密集空洞空間金字塔池化)；DRC：dynamic range compression (動態色域法)；K-近鄰：K nearest neighbors；NLAM：non-local attention mechanism (非局部注意力機制)；SPM GRU：sequence pattern mining-gated recurrent unit (循序模式探勘—門控循環單元)；SVM-KPCA：support vector machine-kernel principal component analysis (支持向量機—主成分分析)；SVM-GA：support vector machine-genetic algorithm (支持向量機—遺傳演算法)；MDFC-CNN (molecular dynamics flexible fitting-convolutional neural network) 為自行研發之 CNN；DETR (detection with transformer) 為物件偵測演算法；FastDTW (FAST dynamic time warping) 為近似演算法；Res2Net 為多尺度特徵法；OLOv4-Tiny、One-stage Yolo、YOLOv3、YOLOv3-tiny、YOLOv4、YOLOv4-tiny、YOLOv5、YOLOv8 為目標檢測解決方案；ViBe 為背景建模和前景檢測演算法。

下保持穩定的辨識能力 (Kulsoom et al., 2022)；但仍有著需要大量的計算資源與存儲空間，對於即時應用可能會造成負擔，需要大量標註數據來進行訓練，可能限制系統的適應性與泛化能力 (Z. Wang et al., 2023)，數據蒐集與標註成本較高與神經網路的決策過程較難解釋，可能影響系統的透明度與可解釋性的劣勢等劣勢 (Huang, 2024)。

細部探究不同神經網路差異，STGCN 為一種將圖結構與時空特徵相結合的神經網路架構，用於捕捉動態數據中的時空依賴關係，適用於處理具有複雜結構和時間依賴性的數據，但有著計算資源需求多、訓練時間長、參數多等限制 (Yu et al., 2018)。而 GNN 則為利用注意力機制來處理圖結構數據的神經網路架構，透過注意力機制計算每個節點的重要性權重動態調整影響力，從不同角度聚合訊息更新節點表示，來提高模型穩定性和表現能力；但有著計算複雜度高、易受噪音影響、訓練不穩定等缺陷 (Vrahatis et al., 2024)。此外，RNN 則為適合處理與分析序列數據的神經網路架構；優點為具有內部循環結構，允許訊息在序列的每個步驟間持續傳遞，使之具有「記憶能力」，來捕捉長期依賴關係；缺點則隨著序列長度增加，梯度更新可能會變得非常小或非常大，導致訓練變得困難，而無法有效學習長期依賴關係；近年提出彌補方式則可引入長短期記憶 (long short-term memory, LSTM) 和門控循環單元 (gated recurrent unit, GRU) 等變體來解決上述限制 (Caterini & Chang, 2018)。

此外，IMU 的作用為藉由加速度計、陀螺儀和磁力計，穿戴至人體可記錄動作過程中產生的加速度、角速度和磁場強度等，作為教學、運動強度監控、疲勞監控、動作技術檢測，可用來提升識別、分析人體動作、製作更自然與直觀的人機交互方式等 (方麒堯等, 2021; 陳羿揚等, 2020; 陳毅等, 2023)。換言之，製作動作辨識系統時搭配 IMU，主要用意在於協助即時蒐集參與者的動作數據，並透過內建感測器提供高精度的動作姿態數據，用於訓練和優化動作辨識模型，從而提高辨識準確度 (Hegazy et al., 2020; Ning et al., 2024)。顯見，目前此類主題主要著重討論單純採用 CNN，或搭配 IMU 採集物理參數，驗證如何才能有效提升辨識效率；少數則採用不同的神經網路製作動作辨識系統，目的皆為了能有效提升桌球動作辨識率。

另外，提升桌球動作辨識效率除了上述提及搭配 IMU 外，選用適當提取法也有助提升辨識效益。納入的研究中多數比對 2 個以上的提取法，來確認辨識效益；有 5 篇針對不同 YOLO 系列 (v3 至 v8)、4 篇採用不同 SVM、各 3 篇單純貝氏分類器與 K-近鄰、2 篇隨機決策森林與 FastDTW (FAST dynamic time warping)；其餘皆為 1 篇的動態色域法 (dynamic range compression, DRC)、單階段檢測 (single shot multibox detector)、均值飄移法、背景相減法、Transformer 模型、以字母筆畫進行標籤、DETR (detection with transformer)、多尺度特徵法 (Res2Net) 增強非局部注意力機制 (non-local attention mechanism, NLAM) 和擴張密集空洞空間金

字塔池化 (dense atrous spatial pyramid pooling, DASPP)、邏輯迴歸 (logistic regression)、決策樹 (decision tree) 等。檢視此類主題中最多使用的 YOLO 系列效益, YOLOv3 為早期經常被使用的版本, 採用多尺度特徵提取方式, 更好的檢測不同大小的物體或動作, 優點為速度快且適合實時應用; 缺點為對小物體的檢測效果不如其他方法 (Masurekar et al., 2020); YOLOv4 則進一步提高檢測精度和效率, 優點為更加精細且速度快, 但有著對硬體要求較高且模型大的缺點; YOLOv5 與 YOLOv8 則為近年最新改良版本, 優點為輕量化, 且具有更高的檢測精度和速度, 適合移動設備; 缺點為對複雜場景的檢測效果可能有所限制 (Zhong et al., 2025)。

此外, 單純貝氏分類器則事先假設特徵之間相互獨立來簡化計算過程, 即使特徵並不完全獨立, 也能有效提升訓練和分類效率; 但由於現實狀況的特徵不見得完全獨立, 可能導致分類效率下降, 而無法捕捉特徵之間的複雜關係 (Qian et al., 2024)。此外, K-近鄰 (K nearest neighbors) 則為簡單且直觀基於距離度量來進行分類或預測的非參數化分類和迴歸方法, 優點為簡單易懂、無需訓練、可適應不同的距離度量方法, 且能適應多類問題; 缺點則為計算量大、內存需求高、對噪聲敏感, 且隨著特徵維度增加, 數據點間的距離變得越相近, 則可能導致分類效果下降 (Cunningham & Delany, 2021)。

綜合上述, 不論採用哪種神經網路搭配 IMU 與提取法整合製作桌球動作辨識系

統皆有優劣差異, 因此資訊工程相關人員與運動科學人員在設計、製作與操作桌球動作辨識系統時, 可參考硬體與軟體設備負荷, 來選擇適當的神經網路與提取法製作動作辨識系統。

## 二、數據資料庫來源

數據資料庫方面 (表 3), 以 8 篇實際進行實驗為主要趨勢, 4 篇採用 3D 桌球數據集 (OpenTTGames) (以下簡稱數據集); 少數 2 篇以網路影片進行分析。實際進行實驗之所以為最大眾, 原因為過程中可透過人工簡化背景複雜性, 利用多個攝影機或搭配 IMU 記錄身體角度、加速度與角速度等, 錄製影像來提升辨識效率; 且鏡頭擺放位置可隨著實驗空間調整與參與者的距離、高度、採樣頻率與解析度, 並提升後續動作辨識準確率 (Du et al., 2021); 缺點則可能需事先設計實驗流程、觀測的動作姿態種類、紀錄次數、場地布置、招募預觀測專項層級的參與者, 且相較直接以網路影片進行整場賽事的分析不符合生態效度與紀錄次數相對少量 (測試數量)。

若以網路影片進行分析優點除了不需事先規劃實驗流程外, 透過比賽的紀錄更加符合戰術情報所需 (He & Li, 2024; Zou et al., 2024); 網路影片雖因為完整記錄實戰賽事而較符合實際狀況, 但缺點則可能無法在整場賽事中, 完全獲得合乎研究需求的適當高度、距離與角度使之產生較低召回率與準確性。另外, 數據集中包含了全高清影像 (full-HD [120 Hz]), 並配有詳細標註訊息與每幀的目標, 可直接準確

檢測和跟蹤桌球的位置和軌跡、分割出影片中的人、球桌和記分板、對手、識別比賽中的關鍵事件，以提高動作辨識系統的準確性和實時性能，並且有助於自動化分析、協助裁判和運動員訓練等 (Wu et al., 2022)。

綜合上述，不論採用何種方式作為數據資料庫皆能進行動作辨識，因此倘若欲排除外在環境因素，可自行架設適當高度、距離與角度，實際進行實驗同時搭配 IMU 來提高辨識效益，若期望符合實際狀況，並更加貼近戰術情蒐情境，則可考慮以網路影片進行整場賽事分析，若單純評估動作辨識系統效益，則可選用數據集，作為數據資料庫建構之依據。

### 三、參與者背景與辨識數量

此主題僅有 6 篇呈現參與者背景 (表 4)，層級高至低分別為職業、半職業、業餘至學生。顯見，目前所設計出的桌球動作辨識系統，已經可以順利測得不同桌球層級群體的動作姿態。另外，則有 5 篇未實際說明參與者背景，少數 2 篇則採用機械手臂；1 篇採用發球機取代人體測試；其中未說明參與者背景的原因可能為研究中直接採用數據集，以避免同一位參與者在操作相同球路時產生動作差異，而降低系統辨識成功率 (Fujihara et al., 2025)。另一原因為部分研究目的主要討論球體飛行軌跡與落點位置，而非辨別人體動作姿態，因此與技術層級無關才未呈現參與者背景 (Gomez-Gonzalez et al., 2019; Liu & Ding, 2022; Ning et al., 2023)。然而多數研究

中並未實際說明招募參與者的具體人數，推測主因為此類主題多半來自資訊工程領域，而非社會科學領域；比起實際招募更多選手作為參與者，以達到足夠的人數進行統計考驗，更在乎所蒐集的總辨別數量 (事件數)，因此多數研究招募少量參與者，但以欲辨別的動作姿態擊打更多的次數作為樣本數量進行分析。

另外，辨別數量以 2 篇分別採用網路影片與數據集收取 10,000 筆為最多，其次為 2 篇採用實際實驗觀測 2,000 筆職業選手，與 2,275 筆一般大學生擊球為次多；數量在 1,000–1,076 筆則分別以實際實驗與數據集呈現；其餘數量最少為 120 筆至 960 筆區間。然而，辨別的數量在製作動作辨識系統時可視為分析的樣本數，雖然增加分析數量能提高系統覆蓋的完整性，但並非越多越好，原因為隨著辨別量增加，分析所需的時間、人力、硬體設備和軟體性能的負荷也會隨之提高，可能導致資源浪費 (S. Ma et al., 2017)。

綜合上述，目前動作辨識系統已可辨別職業、半職業、業餘至學生層級動作姿態，且一次最多可分析 10,000 筆事件，但並非越多越好；因此在決定分析的辨別數量時，需要考慮上述條件是否可以承受，以避免分析過程中資源的過度消耗，並確保研究的效益不會降低。

### 四、辨識結果

此類主題主要討論桌球動作系統製作完成後系統整體辨識的結果 (表 4)，因此並未逐一呈現不同動作姿態的辨識結

表 4  
參與者背景、測試數量與辨識結果比較

| 作者 (年分)                      | 參與者 / 器材  | 辨識數量   | 辨識結果  |
|------------------------------|-----------|--------|---|
| Yanan et al. (2021)          | 職業選手      | 2,000  | 三種卷神經網路 F1 分數皆在 90.00% 以上，自行研發 CNN 比 CNN 和 Inception-CNN 高 1.7 和 1.6%   |
| Liu and Ding (2022)          | 發球機       | 1,000  | One-stage YoLo 有最佳的辨識反應時間：5.3 ms，與最高的準確率：98.00%   |
| Ning et al. (2023)           | 機械手臂      | 350    | DRC 為最佳，非即時捕捉準確率：93.30%；即時捕捉準確率：78.50%  |
| Shi (2025)                   | 未說明       | 120    | TTSD 數據集中 SVM 結合 AdaBoost 為最佳，準確率：91.00%、運行時間：7.66 s、TTTD 數據集中準確率：89.50%、運行時間：8.15 s  |
| He and Li (2024)             | 業餘、半職業、職業 | 10,000 | 所有模型在弱光環境下準確率均不超過 90.00%，OLOv4-Tiny 結合 SPM-GRU 準確率：89.12%，正常光 YOLOv3 和 YOLOv4 的準確率均有提升，正常光下精確率 YOLOv4：91.51%、準確率 93.34%、F1 分數：95.36%，YOLOv4-tiny 精確率：86.31%、準確率：88.67%、F1：87.54%；YOLOv3 精確率：85.34%、準確率：87.15%、F1 分數：87.33%，OLOv4-Tiny 結合 SPM-GRU 模型精確率：95.17%、準確率：94.86%、F1 分數：96.54% |
| Gomez-Gonzalez et al. (2019) | 機械手臂      | 200    | 隨著相機數的提高異常率、球體落點誤差率則降低，但運算時間增加  |
| P. Wang et al. (2019)        | 未說明       | 未說明    | 準確率無旋轉：95.83%、下旋：92.44%、左旋：89.57%、左下旋：95.90%  |
| Zou et al. (2024)            | 學生、業餘、職業  | 155    | 精確率側面：86.20%、選手視角：95.00%、面向選手：86.20%、整體平均：88.00%，召回率側面：95.40%、選手視角：95.30%、面向選手：86.60%、整體平均：94.60%，F1 分數側面：90.60%、選手視角：95.20%、面向選手：86.40%、整體平均：91.20%  |
| L. Ma and Tong (2024)        | 未說明       | 1,076  | 準確率：98.40%、AUC：95.38%、召回率：94.10%、F1 分數：92.92%   |
| Fujihara et al. (2025)       | 未說明       | 792    | 準確率：87.70%、F1 分數：77.00%   |
| Hegazy et al. (2020)         | 職業球員      | 960    | FastDTW 表現最優越，獨立模型精確率：82.00%、召回率：100.00%、F1：90.00%、準確率：93.06%，運動模型精確率：78.00%、召回率：98.00%、F1 分數：87.00%、準確率：90.88%   |
| Hegazy et al. (2021)         | 職業球員      | 800    | FastDTW 準確率：97.20%、判斷時間：1.38 s、K-近鄰準確率：95.60%、判斷時間：4.14 s、SVM 準確率：86.70%、判斷時間：4.89 s、單純貝氏分類器準確率：78.30%、判斷時間：2.76 s、RNN 準確率：98.80%、判斷時間：6.41 s   |
| Ning et al. (2024)           | 未說明       | 10,000 | Res2Net 增強 NLAM 和擴張 DASPP 為最佳模型，精確率：87.10%、召回率：85.60%、mAP 0.5：87.20%、mAP 0.5：95%、53.60%   |

表 4  
參與者背景、測試數量與辨識結果比較 (續)

| 作者 (年分)             | 參與者 / 器材 | 辨識數量  | 辨識結果   |
|---------------------|----------|-------|--|
| Zhang et al. (2019) | 一般大學生    | 2,275 | 隨機決策森林為最佳, 辨識率: 97.80%、準確率: 97.89%、召回率: 97.79%、F1 分數: 97.86% |

註: 1. 依照納入順序進行排序。  
 2. AdaBoost: adaptive boosting (自適應增強); SPM-GRU: sequence pattern mining-gated recurrent unit (循序樣式探勘—門控循環單元); SVM: support vector machine (支持向量機); AUC 為 AUC-ROC 曲線; FastDTW 為近似演算法。TTSD: table tennis stroke dataset (桌球擊球資料集); TTTD: table tennis trajectory dataset (桌球軌跡資料集); OLOv4-Tiny、YOLOv3、YOLOv4、YOLOv4-tiny、YOLOv3 及 One-stage Yolo 為目標檢測解決方案。

果。其中以準確率而言，RNN 模型呈現的 98.80% 最高；CNN 搭配 DRC，即時捕捉桌球落點的 78.50% 最低；採用 CNN 搭配 DRC 之所以產生較低的準確率，推測原因為此系統因為大量減少了影像處理過程中的計算負擔來提升辨識效率，可能會增加音頻信號中的失真和噪音，且在壓縮影像動態範圍時，導致一些細節訊息的丟失而降低辨識準確度 (Wen et al., 2023)。從精確率而言，最高的為比較不同光害環境下，正常光時採用 OLOv4-Tiny 結合循序樣式探勘—門控循環單元 (sequence pattern mining-gated recurrent unit, SPM-GRU) 模型呈現的 95.17%；最低則為採用 IMU 搭配卷神經網路 FastDTW 模型呈現的 78.00%；檢視 He and Li (2024) 研究中有較高精確率可能原因為，採用了能充分利用實體模型和深度學習演算法的優勢，更準確預測、有效處理各種干擾因素，舉凡光照變化、遮蔽、目標太小等，且適用於低光環境，且有著預測時間很短，能夠滿足即時應用的需求，可以根據實際需求進行改進和擴展的 SPM-GRU 模型。另外，參與者雖包含業餘選手，但多數為半職業、職業等選手，可能因為參與者提供的動作數據品質較為一致，而具有清晰的影像、準確的標籤資訊、多樣化的運動軌跡等；同時不同光照條件、背景、運動軌跡等，使模型能適應不同應用情境，因此提高了數據的多樣性，才造就有較高的準確性。採用 FastDTW 模型之所有較低的精確率，推測原因為 FastDTW 是衡量兩個時間序列的動態時間規整 (dynamic time warping, DTW) 加速版本，顯著減少了計算量，提

高了時間序列匹配的效率，但同時造成某些情況下導致匹配結果不如傳統 DTW 精確 (Hegazy et al., 2020)。

以召回率而言，FastDTW 的 100.00% (即將所有的正樣本都正確分類) 最高，Res2Net 增強 NLAM，和擴張 DASPP 的 85.60% 最低；推測 Hegazy et al. (2020) 採用 FastDTW 算法作為主要分類器，在處理時間序列數據方面表現出色，能夠找到兩個時間序列間最佳對齊方式，此優勢對於捕捉和比較不同選手的擊球動作有正向效益；同時在適應性上，使用了依賴和用戶獨立兩種分類模式，使得模型能適應不同擊球風格和動作特點。另外，數據質量和預處理方面，雖然僅招募了 4 名職業選手，但有著 960 次擊球數據，使數據具有高質量和代表性，能有效訓練和評估模型。此外，研究中將數據進行了預處理，包括擊球分割和降噪，而助於提高數據質量。數據維度方面，球動作涉及到多個關節 (手肘、肩膀、腰部和手腕)，這使得數據維度較高，能夠提供更多關於擊球動作的信息。上述原因皆可能為提高模型的召回率主要因素。然而，造成召回率僅 85.60% 的原因為 Res2Net 需要在不同尺度上進行特徵提取和融合，過程中需調整多個參數 (如空洞率、卷積核大小等)，需要豐富經驗與大量實驗尋找最佳配置。換言之，採用 Res2Net 增強 NLAM 和擴張 DASPP，可能並非最佳配置，才導致有較低的召回率 (Ning et al., 2024)。

以 F1 分數而言，隨機決策森林的 97.86% 最高；以字母筆畫標籤的 77.00% 最低。

Zhang et al. (2019) 有較高的 F1 分數推測採用隨機決策森林具有更完整的泛化能力和穩健性，此外使用均值濾波對原始數據進行平滑化處理，可有效去噪，同時採用滑動時間窗口和方差閾值法進行動作檢測和分割，提高信號質量。在特徵提取方面，使用時域特徵來描述運動訊號片段，能夠有效反映運動訊號特徵，利於模型學習，並使用特徵數據來訓練和測試 K-近鄰、SVM 等模型，可更好利用數據訊息提高模型識別能力。然而 F1 分數為多種因素共同作用的結果，上述僅從部分層面進行分析，可能有其他因素提高 F1 分數的結果，未來還需更進一步確認提高 F1 分數之具體原因。精確率最高的為 OLOv4-Tiny 結合 SPM-GRU 模型的 95.17%；FastDTW 的 78.00% 最低。

整體而言，近年所製作的桌球動作辨識系統，已可達到最高 98.80% 的準確率、95.17% 的精確率、100% 的召回率與 97.86% F1 分數。顯見，透過動作辨識系統進行桌球戰術情報蒐集已有一定成功率，因此應該可以順利取代傳統桌球情報蒐集，解決耗費人力、物力與時間的限制。然而本研究發現僅 1 篇研究中呈現辨識率與判斷時間，建議未來相關研究人員採用的判定依據除了以召回率、準確率評估外，可增加辨識率與判斷時間的評估，來彌補參考依據不足的情況。

## 五、可辨別的動作姿態種類

此類主題可辨別的種類包含正手動作姿態 (正手擊球、正手切球、正手衝弧圈

球、正手加轉弧圈、正手推球、正手輕擊球)與反手動作姿態(反手擊球、反手切球、反手殺球、反手輕擊球)、球體落點和軌跡(上旋、下旋、無旋轉、左旋、右旋、左上旋、左下旋、右上旋、右下旋、擋球、飛行軌跡、落點位置),共計22個項目(表5、表6)。此外,單篇最多可一次辨別9種動作姿態、球體落點或軌跡,其次為7種。其中,正手姿態以5篇正手擊球為最多,占比11.11%,其次為3篇正手推球,占比6.67%,最少則為1篇的正手衝弧圈球,占比2.22%。另外,反手姿態以5篇反手推球為最多,占比11.11%,其次為2篇的反手殺球,占比4.44%,最少為各1篇的反手切球與反手輕擊球,各占比2.22%。多數研究之所以辨別正手與反手擊球,推測主因為此兩技術被認為是初學者必需學習的基本技巧,且在桌球競賽中為

最常被使用,且最有效的擊球方式(Iino & Kojima, 2011)。

另外,球體落點與軌跡種類方面,多數皆採用機械手臂或發球機取代人體實驗,來排除因為人為操作在擊打多次相同技術時,因疲勞導致動作姿態差異,而降低辨識的成功率現象;其中最多以4篇無旋轉的球體辨別落點與軌跡,占比8.89%;其次為各2篇的上旋、下旋、左旋、左下旋與直接在內文中呈現飛行軌跡、落點位置,而並未具體說明擊打的種類,各占4.44%;最少則為各1篇的右旋、左上旋、右上旋、右下旋、擋球,各占2.22%。研究中之所以辨別最多次無旋轉的球體,推測主因可能為研究目的主要為觀測落點與軌跡,而球體的轉速並未在討論的範圍內,因此只以無旋轉進行測試,便能釐清系統辨別的成功率。

表5  
動作姿態種類比較

| 項目     | [1] | [2] | [3] | [4] | [5] | [6] | [7] | [8] | [9] | [10] | [11] | [12] | [13] | [14] | 姿態數量 | %     |
|--------|-----|-----|-----|-----|-----|-----|-----|-----|-----|------|------|------|------|------|------|-------|
| 正手擊球   | ■   | -   | -   | -   | -   | -   | -   | -   | ■   | -    | ■    | ■    | -    | ■    | 5    | 11.11 |
| 正手切球   | ■   | -   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | ■    | 2    | 4.44  |
| 正手衝弧圈球 | ■   | -   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | -    | 1    | 2.22  |
| 正手加轉弧圈 | ■   | -   | -   | -   | -   | -   | -   | -   | ■   | -    | -    | -    | -    | -    | 2    | 4.44  |
| 正手推球   | -   | -   | -   | ■   | -   | -   | -   | -   | ■   | ■    | -    | -    | -    | -    | 3    | 6.67  |
| 正手輕擊球  | -   | -   | -   | -   | -   | -   | -   | -   | -   | ■    | -    | -    | -    | ■    | 2    | 4.44  |
| 反手推球   | ■   | -   | -   | ■   | -   | -   | -   | -   | -   | ■    | -    | ■    | -    | ■    | 5    | 11.11 |
| 反手切球   | -   | -   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | ■    | 1    | 2.22  |
| 反手殺球   | -   | -   | -   | ■   | -   | -   | -   | -   | -   | -    | -    | -    | -    | ■    | 2    | 4.44  |
| 反手輕擊球  | -   | -   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | ■    | 1    | 2.22  |

註：[1] Yanan et al. (2021); [2] Liu and Ding (2022); [3] Ning et al. (2023); [4] Shi (2025); [5] He and Li (2024); [6] Gomez-Gonzalez et al. (2019); [7] P. Wang et al. (2019); [8] Zou et al. (2024); [9] L. Ma and Tong (2024); [10] Fujihara et al. (2025); [11] Hegazy et al. (2020); [12] Hegazy et al. (2021); [13] Ning et al. (2024); [14] Zhang et al. (2019); - 為未辨識的動作姿態; ■ 為辨識的動作姿態; 百分比公式換算為(單一動作總數/總數)×100。

表 6

球體落點與軌跡種類比較

| 項目   | [1] | [2] | [3] | [4] | [5] | [6] | [7] | [8] | [9] | [10] | [11] | [12] | [13] | [14] | 姿態數量 | %    |
|------|-----|-----|-----|-----|-----|-----|-----|-----|-----|------|------|------|------|------|------|------|
| 上旋   | -   | ■   | -   | -   | -   | -   | -   | -   | -   | ■    | -    | -    | -    | -    | 2    | 4.44 |
| 下旋   | -   | ■   | -   | -   | -   | -   | ■   | -   | -   | -    | -    | -    | -    | -    | 2    | 4.44 |
| 無旋轉  | -   | ■   | ■   | -   | -   | ■   | ■   | -   | -   | -    | -    | -    | -    | -    | 4    | 8.89 |
| 左旋   | -   | ■   | -   | -   | -   | -   | ■   | -   | -   | -    | -    | -    | -    | -    | 2    | 4.44 |
| 右旋   | -   | ■   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | -    | 1    | 2.22 |
| 左上旋  | -   | ■   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | -    | 1    | 2.22 |
| 左下旋  | -   | ■   | -   | -   | -   | -   | ■   | -   | -   | -    | -    | -    | -    | -    | 2    | 4.44 |
| 右上旋  | -   | ■   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | -    | 1    | 2.22 |
| 右下旋  | -   | ■   | -   | -   | -   | -   | -   | -   | -   | -    | -    | -    | -    | -    | 1    | 2.22 |
| 擋球   | -   | -   | -   | -   | -   | -   | -   | -   | -   | ■    | -    | -    | -    | -    | 1    | 2.22 |
| 飛行軌跡 | -   | -   | -   | -   | ■   | -   | -   | ■   | -   | -    | -    | -    | -    | -    | 2    | 4.44 |
| 落點位置 | -   | -   | -   | -   | ■   | -   | -   | -   | -   | -    | -    | -    | ■    | -    | 2    | 4.44 |
| 單篇數量 | 5   | 9   | 1   | 3   | 2   | 1   | 4   | 1   | 3   | 5    | 1    | 2    | 1    | 7    |      |      |

註：[1] Yanan et al. (2021)；[2] Liu and Ding (2022)；[3] Ning et al. (2023)；[4] Shi (2025)；[5] He and Li (2024)；[6] Gomez-Gonzalez et al. (2019)；[7] P. Wang et al. (2019)；[8] Zou et al. (2024)；[9] L. Ma and Tong (2024)；[10] Fujihara et al. (2025)；[11] Hegazy et al. (2020)；[12] Hegazy et al. (2021)；[13] Ning et al. (2024)；[14] Zhang et al. (2019)；- 為未辨識的動作姿態；■為辨識的動作姿態；百分比公式換算為 (單一動作總數 / 總數) × 100

綜合上述，目前動作辨識用於辨別桌球動作姿態可順利辨識正手、反手動作姿態、球體落點與軌跡，且共計 22 個項目。單篇最多可一次辨別 9 種；此外在姿態的辨別中以正手與反手擊球為最多，球體落點與軌跡則以無旋轉的球體為最多。顯見，動作辨識系統已經可以取代傳統情蒐，協助更客觀的辨別桌球動作姿態、球體落點與軌跡，來提升情蒐效益。然而，本研究品質風險評估結果屬於低質量研究，因為使用的 CNN 與提取法泛化能力差異，與觀測指標、數據資料庫來源、參與者背景辨識數量動作與姿態種類等異值性影響，而產生辨識結果的不同。因此，對於教練團與情蒐人員而言，本研究期望傳達

以不同 CNN 製作的動作辨識系統，確實可以取代傳統情蒐順利用於辨別桌球動作姿態、球體落點與飛行軌跡來提升情蒐效益。對於相關研究人員而言，本研究結果可提供在製作或操作動作辨識系統前，作為評估硬體、軟體與人力資源運用的合理性，與對於運動科學具體適用的實務應用範圍；未來仍需更多相關更多高品質研究，佐證動作辨識系統用於製作桌球戰術情蒐系統的效益。

## 伍、結語

採用 CNN 製作的動作辨識系統，已經可以順利用於辨別桌球動作姿態、球體落點與飛行軌跡，因此確實可以取代傳統

情蒐來提升工作效益。現今製作流程皆以 CNN 搭配 IMU 與適當提取法為趨勢，並藉由職業、半職業、業餘至學生層級的網路賽事影片、實際規劃實驗與數據集作為資料庫加以驗證系統辨別的效益；且一次最多可分析 10,000 筆資料，同時最多一次可辨別 9 種動作姿態，並以正手、反手擊球與無旋轉的球體落點與軌跡為最多，且不論採用哪種神經網路搭配 IMU 與提取法整合製作桌球動作辨識系統皆有優劣差異；辨別結果已可達到最高 98.80% 的準確率、95.17% 的精確率、100.00% 的召回率與 97.86% F1 分數。可見，動作辨識系統已可更迅速與簡便的幫助教練團與情蒐小組，解決傳統情蒐需耗費大量時間比對影片、人力、物力與可能因為情蒐人員桌球觀念不一致導致誤判等限制；並針對小學、高齡者等不同技術層級與年紀之參與者進行分析，從中瞭解不同年齡層最適用的動作辨識系統製作的配置。此外，採用的判定依據除了以召回率、準確率評估外，可增加辨識率與判斷時間的評估，來彌補參考依據不足的情況。再者，辨別的動作種類中，雖已經可以分類出不同種類、球體落點與軌跡；但缺乏人體移動位置、揮拍速度等重要參數，未來皆可進一步探究。

## 利益衝突

本研究無任何利益衝突。

## 參考文獻

1. 王李中羿、莊哲偉 (2024)。比較兩種不同技術分析方式對桌球技術登錄結果之影

響。《運動研究》，33(2)，109–125。https://doi.org/10.6167/JSR.202412\_33(2).0006

[Wang Li, C.-Y., & Chuang, C.-W. (2024). Comparison of two different analysis methods' impact on table tennis technical performance recording. *Journal of Sports Research*, 33(2), 109–125. https://doi.org/10.6167/JSR.202412\_33(2).0006]

2. 王明月、陳淑滿、黃俊發 (2010)。桌球比賽暫停時機運用之分析。《運動研究》，19(1)，1–10。https://doi.org/10.6167/JSR/2010.19(1)1

[Wang, M.-Y., Chen, S.-M., & Huang, C.-F. (2010). Analysis of using time out in table tennis competition. *Journal of Sports Research*, 19(1), 1–10. https://doi.org/10.6167/JSR/2010.19(1)1]

3. 方麒堯、陳韋翰、相子元 (2021)。運動軌跡追蹤系統之發展與回顧。《中華體育季刊》，35(2)，125–136。https://doi.org/10.6223/qcpe.202106\_35(2).0006

[Fang, C.-Y., Chen, W.-H., & Shiang, T.-Y. (2021). A review development of motion tracking system. *Quarterly of Chinese Physical Education*, 35(2), 125–136. https://doi.org/10.6223/qcpe.202106\_35(2).0006]

4. 孫明德、許家維、蔡亞倫、許銘華 (2022)。桌球選手廖振瑋在男單比賽前五板之技戰術特徵分析。《興大體育學刊》，21，25–34。

[Sun, M.-T., Hsu, C.-W., & Tsai, Y.-L. (2020). Analysis of the technical and tactical characteristics of the first five strokes of the men's singles match of Cheng-Ting Liao. *Journal of NCHU Physical Education Research*, 21, 25–34.]

5. 許吉越、翁文修、余信毅、李坤哲 (2018)。高中桌球選手比賽技戰術分析。《運動與遊憩研究》，13(2)，116–129。https://doi.org/10.29423/JSRR.201812\_13(2).09  
[Hsu, C.-Y., Weng, W.-H., & Hsin, Y.-Y., & Kung, C.-L. (2018). Analysis of skills and tactics of high school table tennis players's. *Journal of Sport and Recreation Research*, 13(2), 116–129. https://doi.org/10.29423/JSRR.201812\_13(2).09]
6. 陳羿揚 (2024)。影像動作辨識系統用於羽球競賽對情蒐工作的效益：系統性回顧。《中華體育季刊》，38(2)，131–150。https://doi.org/10.6223/qcpe.202406\_38(2).0003  
[Chen., Y.-Y. (2024). Effect of video action recognition system on badminton competition information: A systematic review. *Quarterly of Chinese Physical Education*, 38(2), 131–150. https://doi.org/10.6223/qcpe.202406\_38(2).0003]
7. 陳羿揚、莎麗娃、邱文信 (2020)。三軸加速規用於評估身體活動量的方法與應用。《華人運動生物力學期刊》，17(1)，45–53。https://doi.org/10.3966/207332672020031701006  
[Chen., Y.-Y., Sha, L., & Chiu, W. H. (2020). Investigate the method and application of three-axis accelerometer for assessing physical activity. *Chinese Journal of Sports Biomechanics*, 17(1), 45–53. https://doi.org/10.3966/207332672020031701006]
8. 陳羿揚、黃筱祺 (2023)。影像動作辨識系統用於區分籃球動作技能與輔助判定爭議球的效益：系統性回顧。《中華體育季刊》，37(3)，223–240。https://doi.org/10.6223/qcpe.202309\_37(3).0002  
[Chen., Y.-Y., & Huang, X.-Q. (2023). Effect of video action recognition system on differentiating basketball motor skills and assisting in determination of disputed balls: A systematic review. *Quarterly of Chinese Physical Education*, 37(3), 223–240. https://doi.org/10.6223/qcpe.202309\_37(3).0002]
9. 陳毅、陳韋翰、陳鋒、劉強、詹明昇、相子元 (2023)。以穿戴式裝置比較不同層級棒球打者軀幹及手部之揮棒技術。《體育學報》，56(2)，179–190。https://doi.org/10.6222/pej.202306\_56(2).0004  
[Chen, Y., Chen, W.-H., Chen, F., Liu, C., Chan, M.-S., & Shiang, T.-Y. (2023). Comparison of the swing techniques of the torso and hands between baseball batters of different skill levels using wearable devices. *Physical Education Journal*, 56(2), 179–190. https://doi.org/10.6222/pej.202306\_56(2).0004]
10. 熊志超、周資眾、許銘華 (2020)。40+ 競技桌球銜接技術對高水準運動員戰術發揮的影響。《中華體育季刊》，34(4)，273–285。https://doi.org/10.6223/qcpe.202012\_34(4).0006  
[Hung, C.-C., Chou, T.-C., & Hsu, M.-H. (2020). The impact of 40+ competitive table tennis connecting techniques on the tactics of high-level athletes. *Quarterly of Chinese Physical Education*, 34(4), 273–285. https://doi.org/10.6223/qcpe.202012\_34(4).0006]
11. 蔡亞倫、許銘華、邱靖華 (2023)。勝敗場觀點分析奧運奪牌桌球選手競技表現之影響。《運動教練科學》，71，35–50。https://doi.org/10.6194/SCS.202309\_(71).0004  
[Tsai, Y.-L., Hsu, M.-H., & Chiu, C.-H. (2023). Analyzing the impact of the competitive performance of Olympic medal-

- winning table tennis players from the perspective of victory and defeat. *Sports Coaching Science*, 71, 35–50. [https://doi.org/10.6194/SCS.202309\\_\(71\).0004](https://doi.org/10.6194/SCS.202309_(71).0004)]
12. Caterini, A. L., & Chang, D. E. (2018). Recurrent neural networks. In *Deep neural networks in a mathematical framework* (pp. 59–79). Springer. [https://doi.org/10.1007/978-3-319-75304-1\\_5](https://doi.org/10.1007/978-3-319-75304-1_5)
  13. Clark, H. D., Wells, G. A., Huët, C., McAlister, F. A., Salmi, L. R., Fergusson, D., & Laupacis, A. (1999). Assessing the quality of randomized trials: Reliability of the Jadad scale. *Controlled Clinical Trials*, 20(5), 448–452. [https://doi.org/10.1016/S0197-2456\(99\)00026-4](https://doi.org/10.1016/S0197-2456(99)00026-4)
  14. Cunningham, P., & Delany, S. J. (2021). K-nearest neighbour classifiers-a tutorial. *ACM Computing Surveys (CSUR)*, 54(6), 1–25. <https://doi.org/10.1145/3459665>
  15. Dhiman, G., Kumar, A. V., Nirmalan, R., Sujitha, S., Srihari, K., Yuvaraj, N., Arulprakash, P., & Raja, R. A. (2023). Multi-modal active learning with deep reinforcement learning for target feature extraction in multi-media image processing applications. *Multimedia Tools and Applications*, 82(4), 5343–5367. <https://doi.org/10.1007/s11042-022-12178-7>
  16. Du, Y., Zhao, Q., & Lu, X. (2021). Semantic extraction of basketball game video combining domain knowledge and in-depth features. *Scientific Programming*, 2021(1), Article 9080120. <https://doi.org/10.1155/2021/9080120>
  17. Emanuel, R. H. K., Docherty, P. D., Lunt, H., & Möller, K. (2024). The effect of activation functions on accuracy, convergence speed, and misclassification confidence in CNN text classification: A comprehensive exploration. *The Journal of Supercomputing*, 80(1), 292–312. <https://doi.org/10.1007/s11227-023-05441-7>
  18. Fujihara, Y., Shimada, T., Kong, X., Tanaka, A., Nishikawa, H., & Tomiyama, H. (2025). Stroke classification in table tennis as a multi-label classification task with two labels per stroke. *Sensors*, 25(3), Article 834. <https://doi.org/10.3390/s25030834>
  19. Gao, Z., Xuan, H.-Z., Zhang, H., Wan, S., & Choo, K.-K. R. (2019). Adaptive fusion and category-level dictionary learning model for multiview human action recognition. *IEEE Internet of Things Journal*, 6(6), 9280–9293. <https://doi.org/10.1109/JIOT.2019.2911669>
  20. Gomez-Gonzalez, S., Nemmour, Y., Schölkopf, B., & Peters, J. (2019). Reliable real-time ball tracking for robot table tennis. *Robotics*, 8(4), Article 90. <https://doi.org/10.3390/robotics8040090>
  21. He, F., & Li, Y. (2024). Modeling of SPM-GRU ping-pong ball trajectory prediction incorporating YOLOv4-Tiny algorithm. *PLoS One*, 19(9), Article e0306483. <https://doi.org/10.1371/journal.pone.0306483>
  22. Hegazy, H., Abdelsalam, M., Hussien, M., Elmosalamy, S., Hassan, Y. M. I., Nabil, A. M., & Atia, A. (2020). Ipingpong: A real-time performance analyzer system for table tennis stroke's movements. *Procedia Computer Science*, 175, 80–87. <https://doi.org/10.1016/j.procs.2020.07.014>
  23. Hegazy, H., Abdelsalam, M., Hussien, M., Elmosalamy, S., Hassan, Y. M. I., Nabil, A., & Atia, A. (2021). Multi-sensor fusion

- for online detection and classification of table tennis strokes. *International Journal of Intelligent Engineering & Systems*, *14*(2), 201–210. <https://doi.org/10.22266/ijies2021.0430.18>
24. Huang, G. (2024). Dynamic neural networks: Advantages and challenges. *National Science Review*, *11*(8), Article nwae088. <https://doi.org/10.1093/nsr/nwae088>
  25. Huisman, M. (2024). When AUC-ROC and accuracy are not accurate: What everyone needs to know about evaluating artificial intelligence in radiology. *European Radiology*, *34*(12), 7892–7894. <https://doi.org/10.1007/s00330-024-10859-5>
  26. Iino, Y., & Kojima, T. (2011). Kinetics of the upper limb during table tennis topspin forehands in advanced and intermediate players. *Sports Biomechanics*, *10*(4), 361–377. <https://doi.org/10.1080/14763141.2011.629304>
  27. Jadad, A. R., Moore, R. A., Carroll, D., Jenkinson, C., Reynolds, D. J. M., Gavaghan, D. J., & McQuay, H. J. (1996). Assessing the quality of reports of randomized clinical trials: Is blinding necessary? *Controlled Clinical Trials*, *17*(1), 1–12. [https://doi.org/10.1016/0197-2456\(95\)00134-4](https://doi.org/10.1016/0197-2456(95)00134-4)
  28. Kannoja, S. P., & Jaiswal, G. (2018). Effects of varying resolution on performance of CNN based image classification: An experimental study. *International Journal of Computer Sciences and Engineering*, *6*(9), 451–456. <https://doi.org/10.26438/ijcese/v6i9.451456>
  29. Kulsoom, F., Narejo, S., Mehmood, Z., Chaudhry, H. N., Butt, A., & Bashir, A. K. (2022). A review of machine learning-based human activity recognition for diverse applications. *Neural Computing and Applications*, *34*(21), 18289–18324. <https://doi.org/10.1007/s00521-022-07665-9>
  30. Li, X., Li, C., Rahaman, M. M., Sun, H., Li, X., Wu, J., Yao, Y., & Grzegorzec, M. (2022). A comprehensive review of computer-aided whole-slide image analysis: From datasets to feature extraction, segmentation, classification and detection approaches. *Artificial Intelligence Review*, *55*(6), 4809–4878. <https://doi.org/10.1007/s10462-021-10121-0>
  31. Liu, Q., & Ding, H. (2022). Application of table tennis ball trajectory and rotation-oriented prediction algorithm using artificial intelligence. *Frontiers in Neurorobotics*, *16*, Article 820028. <https://doi.org/10.3389/fnbot.2022.820028>
  32. Ma, L., & Tong, Y. (2024). TL-CStrans net: A vision robot for table tennis player action recognition driven via CS-Transformer. *Frontiers in Neurorobotics*, *18*, Article 1443177. <https://doi.org/10.3389/fnbot.2024.1443177>
  33. Ma, S., Bargal, S. A., Zhang, J., Sigal, L., & Sclaroff, S. (2017). Do less and achieve more: Training CNNs for action recognition utilizing action images from the web. *Pattern Recognition*, *68*, 334–345. <https://doi.org/10.1016/j.patcog.2017.01.027>
  34. Maddalena, L., & Petrosino, A. (2018). Background subtraction for moving object detection in RGBD data: A survey. *Journal of Imaging*, *4*(5), Article 71. <https://doi.org/10.3390/jimaging4050071>
  35. Masurekar, O., Jadhav, O., Kulkarni, P., & Patil, S. (2020). Real time object detection

- using YOLOv3. *International Research Journal of Engineering and Technology (IRJET)*, 7(3), 3764–3768.
36. Ning, T., Fu, M., Wang, Y., Duan, X., & Abedin, M. Z. (2024). Application of deep learning for automatic detection of table tennis balls from an intelligent serving machine. *Applied Soft Computing*, 167(Pt. B), Article 112329. <https://doi.org/10.1016/j.asoc.2024.112329>
  37. Ning, T., Wang, C., Fu, M., & Duan, X. (2023). A study on table tennis landing point detection algorithm based on spatial domain information. *Scientific Reports*, 13(1), Article 20656. <https://doi.org/10.1038/s41598-023-42966-6>
  38. Olivo, S. A., Macedo, L. G., Gadotti, I. C., Fuentes, J., Stanton, T., & Magee, D. J. (2008). Scales to assess the quality of randomized controlled trials: A systematic review. *Physical Therapy*, 88(2), 156–175. <https://doi.org/10.2522/ptj.20070147>
  39. Qian, H., Pan, Y., Wang, X., & Li, Z. (2024). Research on the optimization of belief rule bases using the Naive Bayes theory. *Frontiers in Energy Research*, 12, Article 1396841. <https://doi.org/10.3389/fenrg.2024.1396841>
  40. Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjally, A., Alsolai, H., Siddiqui, T., & Mellit, A. (2023). A study of CNN and transfer learning in medical imaging: Advantages, challenges, future scope. *Sustainability*, 15(7), Article 5930. <https://doi.org/10.3390/su15075930>
  41. Shi, F. (2025). A motion capture framework for table tennis using optimized SVM and adaboost algorithms. *Informatika*, 49(6), 191–204. <https://doi.org/10.31449/inf.v49i6.6809>
  42. Vrahatis, A. G., Lazaros, K., & Kotsiantis, S. (2024). Graph attention networks: A comprehensive review of methods and applications. *Future Internet*, 16(9), Article 318. <https://doi.org/10.3390/fi16090318>
  43. Wang, P., Zhang, Q., Jin, Y., & Ru, F. (2019). Studies and simulations on the flight trajectories of spinning table tennis ball via high-speed camera vision tracking system. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 233(2), 210–226. <https://doi.org/10.1177/1754337118815021>
  44. Wang, Z., Yang, Y., Liu, Z., & Zheng, Y. (2023, May 23). *Deep neural networks in video human action recognition: A review*. arXiv. <https://doi.org/10.48550/arXiv.2305.15692>
  45. Wen, R., Wang, J., Xie, Y., & Tian, W. (2023). A CNN compression method via dynamic channel ranking strategy. *International Journal of Computational Intelligence and Applications*, 22(4), Article 2350025. <https://doi.org/10.1142/S1469026823500256>
  46. Wu, F., Wang, Q., Bian, J., Ding, N., Lu, F., Cheng, J., Dou, D., & Xiong, H. (2022). A survey on video action recognition in sports: Datasets, methods and applications. *IEEE Transactions on Multimedia*, 25, 7943–7966. <https://doi.org/10.1109/TMM.2022.3232034>
  47. Yanan, P., Jilong, Y., & Heng, Z. (2021). Using artificial intelligence to achieve auxiliary training of table tennis based on inertial perception data. *Sensors*, 21(19), Article 6685. <https://doi.org/10.3390/s21196685>

48. Yu, B., Yin, H., & Zhu, Z. (2018). Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. In J. Lang (Ed.), *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence* (pp. 3634–3640). International Joint Conferences on Artificial Intelligence. <https://doi.org/10.24963/ijcai.2018/505>
49. Zhang, H., Fu, Z., & Shu, K.-I. (2019). Recognizing ping-pong motions using inertial data based on machine learning classification algorithms. *IEEE Access*, *7*, 167055–167064. <https://doi.org/10.1109/ACCESS.2019.2953772>
50. Zhong, J., Qian, H., Wang, H., Wang, W., & Zhou, Y. (2025). Improved real-time object detection method based on YOLOv8: A refined approach. *Journal of Real-Time Image Processing*, *22*(1), Article 4. <https://doi.org/10.1007/s11554-024-01585-8>
51. Zou, T., Wei, J., Yu, B., Qiu, X., Zhang, H., Du, X., & Liu, J. (2024). Fast moving table tennis ball tracking algorithm based on graph neural network. *Scientific Reports*, *14*(1), Article 29320. <https://doi.org/10.1038/s41598-024-80056-3>

# The Efficacy of Different Convolutional Neural Networks in Developing a Table Tennis Tactical Information Collection System: A Systematic Review

**Yi-Yang Chen**\*

School of Physical Education, Minnan Normal University

\*Corresponding Author: Yi-Yang Chen

Address: No. 36, Xianqianzhi St., Xiangcheng Dist., Zhangzhou City 363000, Fujian Province, P. R. China (P. R. C)

E-mail: hc7022709@gmail.com

DOI:10.6167/JSR.202512\_34(2).0006

Received: March, 2025 Accepted: June, 2025

## Abstract

The purpose of this study was to explore the effectiveness of recent video action recognition systems in supporting table tennis tactical intelligence collection. Empirical studies were retrieved from sources such as Google Scholar, PubMed, Scopus, and Airiti Library through the use of Chinese and English keywords such as “table tennis,” “motion recognition,” “deep learning,” “convolutional neural networks,” “artificial neural networks,” and “kinematics.” The search spanned a six-year period, from January 2019 to January 2025. The study aimed to clarify how motion recognition systems were applied to identify table tennis movement postures, the adopted learning models, the extraction methods and observation indicators utilized, the data repositories employed, the participants’ backgrounds and the quantity of recognition, the meanings represented by the recognition results, and the categories of movement postures. The findings provided a reference for coaches, intelligence analysts, and sports scientists regarding how to operate motion recognition systems, as well as for researchers conducting subsequent studies. The development of a table tennis motion recognition system based on convolutional neural network (CNN), integrated with inertial measurement unit (IMU) and optimized feature extraction methods, demonstrates robust automatic identification of key visual features across diverse motion types and environmental conditions. This approach significantly reduces manual feature engineering while maintaining high interpretability. The system was validated using a comprehensive dataset comprising online match footage and 3D experimental data spanning professional, semi-professional, amateur, and student levels. It supports batch analysis of up to 10,000 samples across nine distinct motion postures. The model achieves peak performance in detecting forehand,

backhand, and non-spin ball trajectories, with a maximum accuracy of 98.80%, precision of 95.17%, recall of 100.00%, and an F1-score of 97.86%. These results suggest that CNN-based motion recognition systems can effectively replace traditional tactical data collection methods, enabling automated classification of stroke types, ball landing points, and flight trajectories to enhance strategic analysis in table tennis.

**Keywords:** deep learning, wearable devices, accuracy, recall, automation

