

應用卷積神經網路於鵝隻停留模式分析之研究

郭旻蒼¹、蔡秉承²、李昌叡¹、施富邦³、謝廣文^{4*}

摘 要 隨著生物安全意識及產業規模的提高，家禽產業朝向非開放式及自動化的方向發展。而近年來機器學習技術的發展，也使得卷積神經網路技術在各領域的應用範圍大幅擴展。本研究針對禽舍內的鵝隻進行停留模式分析，此研究包含圖像擷取系統、位置偵測系統以及停留時間計算系統三大部分。圖像擷取系統使用一個樹莓派搭配兩個網路攝影機，以五秒的間隔擷取鵝隻圖像，並上傳至網路連接儲存設備。位置偵測系統使用 Faster R-CNN 卷積神經網路演算法，停留時間計算系統則使用位置偵測系統得出的鵝隻位置，進行不同時間個別鵝隻間重疊率的計算，並計算停留時間。本研究開發之鵝隻停留模式分析系統，其中的鵝隻位置偵測模型經試驗評估準確度及涵蓋率皆能達到 90% 以上。

關鍵詞：鵝、卷積神經網路、停留時間、停留模式

Analysis of Goose Non-moving Pattern Using Convolutional Neural Networks

Min-Tsang Kuo¹, Ping-Cheng Tsai², Chang-Jui Li¹, Fu-Pang Shih³ and Kuang-Wen Hsieh^{4*}

ABSTRACT With the awareness of bio-safety and the development of the scale, poultry owners begin to avoid contact between poultry and wild birds and improve automation. In recent years, the development of machine learning has expanded the application range of Convolutional Neural Networks in various fields. This work will analyze the non-moving pattern of goose in wet-pad poultry houses. In the study, a raspberry-pi and two cameras were used to capture goose images with a five-second interval and upload it to the Network Attached Storage. The Position Detection System uses Faster R-CNN to create a model for finding the location of the goose in the image. The Dwell Time Calculation System uses the goose position obtained by the Position Detection System to calculate the overlap rate of individual geese at different times and calculate the dwell time. The Goose Dwell Pattern Analysis System developed in this study, in which the goose position detection model can achieve more than 90% both precision and recall.

Keywords: goose, convolutional neural networks, dwell time, non-moving pattern

¹ 國立中興大學生物產業機電工程學系碩士。Master, Dept. of Bio-Industrial Mechatronics Engineering, National Chung Hsing University, Taiwan.

² 國立中興大學生物產業機電工程學系碩士班研究生。Master student, Dept. of Bio-Industrial Mechatronics Engineering, National Chung Hsing University, Taiwan.

³ 國立中興大學生物產業機電工程學系博士班研究生。Doctoral student, Dept. of Bio-Industrial Mechatronics Engineering, National Chung Hsing University, Taiwan.

⁴ 國立中興大學生機系副教授兼系主任。Associate Professor as Chair, Dept. of Bio-Industrial Mechatronics Engineering, National Chung Hsing University, Taiwan.

* 通訊作者。Corresponding author, Email: cwshieh@dragon.nchu.edu.tw.

一、前言

台灣水禽產業的飼養設施，傳統上大多以開放式的禽舍為主，這種飼養方法時常可以發現野鳥進入飼養區域與家禽搶食，因此很容易受到野鳥糞便、羽毛所帶來之致病原的影響。

在 2015 年初開始爆發的禽流感疫情，對台灣水禽產業造成了很大的傷害。光是在 2015 年一年之間，就共有 1004 處禽隻飼養場域被檢測出受到高致病性禽流感病毒的感染。

而造成當年禽流感大爆發的原因主要可分為三大部分，一是病毒藉由候鳥及留鳥的移動，快速地在各縣市之間傳播，二是不同家禽種類的飼養設施距離太過接近，由於鴨隻較無明顯臨床症狀，若較晚發現並通報禽流感疫情，容易造成周邊禽場的損失，三為傳統禽場大多採用成本較低的開放式禽舍，導致飼養之禽隻接觸到病原體的機率較高，造成了廣大的災情(何，2018)。

為了改善開放式禽舍造成疾病快速傳播問題，政府近年來大力推動非開放式禽舍的普及，與開放式相比起來，非開放式禽舍能夠大幅降低設施內飼養禽隻與外界野鳥的接觸機會，以增進禽舍內的生物安全。

根據行政院農業委員會畜產產品生產量值統計資料庫顯示，台灣養鵝產業在 2014 年的年產值達到了約 27.38 億元的規模，雖然因為禽流感疫情的影響，2015 年的產值跌落到約 9.79 億元，但目前呈現穩定成長的趨勢，在 2017 年的統計中，可以看到年產值已達到約 15.41 億元的規模(行政院農業委員會，2019)。

禽類在患病的情況下，常可發現有蹲伏、嗜睡、腹瀉、羽毛皺褶的明顯臨床症狀(Lu et al., 2014; McFerran and Smyth, 2000)。為了觀察禽隻是否有因患病而產生的異常行為，在臺灣水禽產業傳統飼養管理上，以人員進入現場禽舍觀察禽隻生活情況為主。但是因為鵝隻生性敏感容易受到驚嚇，一旦受到驚嚇可能數天難以平靜(尤，2010)。在人為干擾之下可能會造成鵝隻有緊迫的狀況發生，影響到鵝隻生活品質或是異常行為判斷的正確性。

機器視覺與影像處理在農業與工業上已經有許多應用的案例，在現今農業人力不足的情況下，若能將相關技術應用於畜牧管理，就能夠達到降低生產成本、減少所需人力的效果。目前臺灣家禽飼養場域已逐漸開始導入攝影設備協助飼養管理，管理人員只要在辦公室內就能夠監視現場禽舍內部狀況，不但可減少人力成本，

也能夠降低管理人員進入現場禽舍的頻率，減少對於飼養禽隻的干擾以及意外帶入病原的機會，對於生物安全防治上有正面效果。

但目前已投入影像擷取設備協助管理畜牧生產之案例，大多數必須仰賴人工觀察畫面狀況才能發現異常狀況，還無法達到自動化監控的程度。

自 2012 年以來迅速發展的機器學習(machine learning)技術，由於卷積神經網路(convolutional neural networks, CNN)在物件偵測(object detection)問題上的解決能力有了突破性成長，近幾年也有很多研究單位嘗試將 CNN 相關技術運用於農產畜牧業中。2015 年 Girshick 提出了 R-CNN 的改良版演算法 Fast R-CNN，為了改善 R-CNN 因運算量較大而造成速度較慢的問題，作了架構和方法上的調整，使用運算量較小的 softmax 函數取代 SVM 分類器，並將精確定位物件位置的定界框迴歸(bounding box regression)運算放在卷積層運算之後，使其能和骨幹共用卷積層的特徵。同在 2015 年時 Ren 等人提出了 Faster R-CNN 演算法，此演算法改進了 Fast R-CNN 中定界框迴歸的部分，提出區域建議網路(region proposal network, RPN)，改善了原先計算時間較長的問題，也增加了整體判斷的精確度。若是能夠成功地利用 CNN 偵測出影像擷取設備取得之現場禽舍圖像中的動物物件，就能夠進一步整合更多的技術，來達到畜牧管理監控自動化的目標。

在 2011 年 Powers 在研究中整理了幾種常用的評估指標，在二變數二元分類問題中，可以依照真實情況、判斷結果兩個變數的二元分類結果數量，計數(count)出混淆矩陣(confusion matrix)，再根據混淆矩陣中四種不同情況的結果數量，計算出準確度(accuracy)跟涵蓋率(recall)，作為評估物件偵測能力的指標。

在應用上在 2018 年 Lin 等人在研究中使用了 Faster R-CNN，找出雞隻在圖像中的位置，並監測雞隻活動的情況，探討環境溫溼度與雞隻活動力之間的關係。在 2018 年謝姓學者提出了一種基於 Faster R-CNN 的鵝隻圖像辨識系統，使用嵌入式系統控制 4 台架設於現場禽舍的攝影機，擷取圖像後透過網路上傳至雲端儲存裝置，並透過 Faster R-CNN 搭配 VGG-16 骨幹建立圖像辨識系統，對白羅曼鵝生活圖像進行物件偵測，達到了 81%的準確度以及 82%的涵蓋率。

本研究之目的為開發一個鵝隻停留模式分析系統，使用攝影機在環境較為嚴苛的禽舍現場自動拍攝鵝隻生活圖像，並應用在物件偵測問題上有良好準確度的

Faster R-CNN 找出鵝隻在圖像中的位置。接著透過比較圖像序列中的鵝隻所在位置，判斷鵝隻是否處於停留狀態，並將停留鵝隻的位置資訊記錄下來，最後分析其停留模式。

本研究期望能夠達到以下幾項目標：

- (一) 開發一個能夠自動定時地擷取鵝隻生活圖像的系統。
- (二) 開發一個能夠找出鵝隻在圖像中位置的系統。
- (三) 開發一個能夠計算鵝隻停留時間的系統。

二、材料與方法

(一) 實驗對象

本研究的實驗對象為北斗白鵝畜試壹號，其為彰化種畜繁殖場經過多年育種後所培育出來的高體重白羅曼鵝品系，此品系之公鵝有生長速度快的優點。

(二) 實驗場地

本研究實驗場地分為三個區域，分別為現場禽舍、資料中心和訓練中心。現場禽舍與資料中心位於「行政院農業委員會畜產試驗所彰化種畜繁殖場」，以下簡稱為彰化場；訓練中心則位於國立中興大學生物產業機電工程學系。本研究所使用之實驗設備分別架設在三個實驗場地。

(三) 圖像擷取系統

圖像擷取系統由現場禽舍的攝影機、嵌入式系統及資料中心的 NAS 所組成，硬體架構與傳輸介面如圖 1 所示。本研究使用一個 Raspberry Pi 透過 USB 2.0 介面同時連接兩台 C922 Webcam，透過在 Linux 作業系統中執行以 Python 撰寫的圖像擷取程式，自動定時地擷取鵝隻生活圖像，再經過藉由有線網路連接的無線分享器，以符合 IEEE 802.11 b/g/n 通訊協定的無線網路介面，將圖像資料傳送至資料中心內的 NAS 儲存。

(四) 攝影機架設方法

本研究採用將攝影機架設於正上方的俯視角度，來拍攝鵝隻生活影像，實際取得圖像如圖 2 所示。正上方的俯視角度除了能夠避免側面重疊的情況發生，在影像座標系與世界座標的轉換過程中也更加地簡易，只需計算影像涵蓋面積的寬度及長度，就能夠換算特定像素點之間的距離，進而能夠算出圖像中兩點在真實世界中的實際距離。

(五) 取像流程

本研究透過 Python 程式語言，開發一個能夠自動定時擷取圖像的程式，程式詳細執行流程如圖 3 所示。

程式開始後首先會初始化紀錄檔以及攝影機，接著確認時間是否在設定的取像時間範圍內，為了配合現場禽舍人工光源系統之開燈時間，本研究設定取像時間為早上 8 點至下午 6 點，每天 10 小時。

若確認在取像時間內，則控制攝影機同時取像，並嘗試將圖像上傳至 NAS。在完成圖像擷取並將圖像檔案儲存在記憶卡中之後，程式會於紀錄檔中記錄當下的時間資訊。接著嘗試將檔案傳送至 NAS，若是上傳成功也會在紀錄檔中進行記錄，並將 Raspberry Pi 內的圖像檔案刪除，這是為了避免記憶卡的儲存空間資源被耗盡，而無論上傳成功或是失敗，在進行過一次的嘗試後，程式會確認目前時間是否已經超過當次的取像時間間隔。若尚未到達下一次的取像時間則會再一次嘗試上傳圖像。若已到達下一次的取像時間，無論圖像是否皆已上傳成功，程式都會進入拍照程序。

(六) 若時間不在取像時間範圍內，程式會開始檢查資料夾中是否有在取像過後上傳失敗的圖像，由於確認過成功上傳的圖像會被刪除，若有圖像還儲存在記憶卡中，就表示那些圖像是上傳失敗的圖像。程式在這個部分會反覆嘗試上傳圖像，一直到所有的圖像都已經被上傳至 NAS。若確認過所有圖像皆已上傳至 NAS，程式會等位置偵測系統

位置偵測系統開發之目的，是為了將圖像擷取系統所取得的鵝隻生活圖像，應用 CNN 技術進行圖像中物件偵測，找出鵝隻在圖像中的位置，讓後續的停留時間計算系統能夠使用位置資訊來進行停留時間的計算。

在硬體部分，此系統由位於資料中心的 NAS、分析伺服器，以及訓練中心的訓練伺服器所組成。

在流程方面，此系統可分為訓練及應用兩個階段。訓練階段會將鵝隻生活圖像從 NAS 傳送至訓練伺服器，在完成訓練所需資料集的建立之後，接著進行卷積神經網路模型的訓練。在訓練過程完成之後，會將得到的分析模型從訓練伺服器傳送至分析伺服器。應用階段則會使用分析模型，對鵝隻生活圖像進行位置偵測，最後將偵測到的位置結果寫入架設於 NAS 上的資料庫中。

(七) 資料集的建立方式

監督式學習方法，需要透過人類對想要偵測的物件進行樣本標記的動作，再將這些經過標記的樣本範例輸入演算法中進行訓練，在根據試算結果來更新演算法內的參數，也就是學習的動作。然而監督式學習很大程度上受到輸入的訓練資料影響，若是圖像中想要分析的類

別沒有被包含在訓練資料中，很容易就會造成判斷失誤的情況發生。

為了測試一個卷積神經網路模型對未學習過之待測物的推廣能力，通常我們會將資料分為兩個資料集：訓練資料集 (training dataset) 以及驗證資料集 (validation dataset)，訓練資料集與驗證資料集中的資料互不重複，如此一來便可測試訓練得到的分析模型，在面對未學習過的圖像資料上的物件偵測有效性。

(八) 鵝隻停留時間計算系統

鵝為警戒性高的群居動物，通常不會在同一位置長時間停留，停留時間計算系統將利用位置偵測系統所推

論出的鵝隻位置，計算出鵝隻在特定位置的停留時間，並嘗試分析鵝的停留模式。

在流程方面，分析伺服器會由架設在 NAS 上的位置資料庫讀取一段時間的鵝隻位置資訊，並在計算完一個批次的停留時間後將其上傳至同樣架設在 NAS 上的停留時間資料庫。

(九) 停留時間資料庫架構

停留時間資料庫使用一個資料表來儲存一個月內的所有停留事件，資料表部分截圖如圖 4 所示。一個資料表中則以 10 個欄位儲存一個停留事件，欄位對應儲存內容如表 1 所示。

待直到取像時間開始。




圖 1、現場禽舍硬體架構與傳輸介面圖

Fig. 1 Hardware architecture and transmission interface of the poultry house



圖 2、俯視角度攝影機拍攝圖

Fig. 2 Photographing from the top angle




圖 3、圖像擷取系統詳細流程圖

Fig. 3 Flow chart of the image capture system

圖 4、鵝隻停留時間資料庫部分截圖

Fig. 4 A part of database of the dwell time of goose

ID	tm_y	tm_m	tm_d	start_h	start_m	start_s	stay_event	terminal_id	total_stay_time
100401	2019	4	6	11	30	33	22993	23016	11
100402	2019	4	6	11	30	33	22994	23003	5
100403	2019	4	6	11	30	44	23013	23031	10
100404	2019	4	6	11	30	49	23020	23094	42
100405	2019	4	6	11	30	54	23030	23039	6

表 1、鵝隻停留時間資料庫欄位介紹表

Table 1 Introduction of the field of the database of the dwell time of goose

欄位名稱	儲存內容	欄位名稱	儲存內容
ID	不重複序號	start_m	開始停留一分
tm_y	停留發生年份	start_s	開始停留一秒
tm_m	停留發生月份	stay_event	停留開始位置 ID
tm_d	停留發生日期	terminal_id	停留最後位置 ID
start_h	開始停留一時	total_stay_time	累計停留時間

三、結果與討論

(一) 位置偵測準確度試驗結果

在準確度曲線圖中，如圖 5 所示，藍色的曲線代表了訓練資料集的準確度(training precision)，對應的是右邊的座標軸，橘色的曲線則是驗證資料集的平均準確度(mAP)，對應左邊的座標軸。觀察圖 5 可以發現，約在第 670 個 epoch 前，兩個資料集的準確度變化趨勢是相同的。但在 670 epoch 之後，訓練資料集準確度呈現上升的趨勢，但是驗證資料集準確度卻是呈現下降的趨勢，這種現象被稱為過擬合(overfitting)，指的是模型權重開始過度擬合訓練資料集的使用情境，但是對未訓練樣本的推廣能力反而下降的情況。

而使用 CNN 主要是為了應用在未訓練過樣本的判斷，所以應該選擇推廣能力良好的權重。於是本研究決定選用在開始發生過擬合現象之前，在驗證資料集中準

確度最高的模型權重，因此第 610 個 epoch 的模型權重，將作為分析模型在後續處理中被使用。

(二) 各資料集之混淆矩陣

為了評估分析模型的物件偵測能力，準此分析模型對訓練資料集的 800 張鵝隻圖像進行推論，在 PASCAL VOC 公開挑戰賽所使用的標準，IOU 門檻 0.5 的條件下，對分類結果計數得到混淆矩陣，如表 2 所示。確度試驗使用訓練資料集及驗證資料集，對位置偵測結果進行計數得到混淆矩陣，並計算分析模型的準確度及涵蓋率。

(三) 訓練資料集

經過了 900 個 Epoch 的模型訓練過程後，選擇了第 610 個 epoch 的模型權重作為分析模型，並用觀察表 2 可以發現在 800 張鵝隻圖像中，總共成功偵測到了 1831 個鵝隻物件，錯誤偵測到的鵝隻物件為 1 個，計算得到了 99.9%的準確度；而漏偵測鵝隻物件為 2 個，計算得到 99.8%的涵蓋率。




圖 5、訓練資料集與驗證資料集準確度曲線

Fig. 5 The curve of the training precision and the mAP

表 2、訓練資料集混淆矩陣

Table 2 Confusion matrix of the training precision

混淆矩陣	實際是鵝	實際非鵝
偵測是鵝	1831	1
未偵測到	2	-

(四) 驗證資料集

驗證資料集部分同樣使用 PASCAL VOC 的 IOU 門檻 0.5，對不包含在訓練資料集內的 200 張鵝隻圖像進行混淆矩陣的計數，詳細結果如表 3 所示。

在驗證資料集中總共成功偵測到了 450 個鵝隻物件，漏偵測鵝隻物件為 1 個，涵蓋率為 99.8%；而錯誤偵測到的鵝隻物件為 6 個，準確度部分則是 98.7%。

(五) 停留模式分析結果

此部分使用鵝隻位置偵測系統所訓練出的分析模型，對 2019 年 4 月 6 號到 2019 年 4 月 19 日，14 日間的鵝隻生活圖像進行推論，取得 1,007,118 筆鵝隻位置資訊後，透過停留時間計算系統算出資料庫內所有

鵝隻的位置重疊率，並計算停留時間以進行停留模式的分析。

(六) 停留事件筆數

在透過停留時間計算系統的運算後，最後得到 101,326 筆停留事件，各日筆數分布如表 4 所示。

可以觀察到，在每日總停留事件數上，呈現數量逐漸提升的趨勢，數量最少的為 4 月 7 日統計到的 6,041 筆，最多的則是 4 月 14 日的 8,468 筆，差異達到了 2,427 筆。

除了每日數量上的差異，本試驗也以各個取像時段作為分類，進行了停留事件發生數量的統計，詳細資料如表 5 所示。

表 3、驗證資料集混淆矩陣

Table 3 Confusion matrix of the mPA

混淆矩陣	實際是鵝	實際非鵝
偵測是鵝	450	6
未偵測到	1	-

表 4、單日總停留事件筆數

Table 4 The quantity of non-moving event for one day

日期	停留事件筆數	日期	停留事件筆數
2019/4/6	6,488	2019/4/13	7,458
2019/4/7	6,041	2019/4/14	8,468
2019/4/8	6,328	2019/4/15	7,991
2019/4/9	6,155	2019/4/16	8,073
2019/4/10	6,176	2019/4/17	8,158
2019/4/11	6,798	2019/4/18	8,001
2019/4/12	7,171	2019/4/19	8,020

表 5、各時段停留事件筆數

Table 5 The quantity of non-moving event for each time

時段	停留事件筆數	時段	停留事件筆數
08-09	9,327	13-14	10,572
09-10	9,877	14-15	10,159
10-11	10,159	15-16	10,408
11-12	10,369	16-17	10,344
12-13	10,441	17-18	9,670

在本研究統計得出的數據中，可以觀察到在剛開始取像的早上 8 點到 9 點，以及將要結束取像的晚上 5 點到 6 點，停留事件發生數量上相對較少，但由於數量上的差異並不明顯，無法觀察到明顯的規律。

另外，本試驗也以週日別作為分類，統計了試驗期間週一到週日的事件發生數，同樣因為差異不明顯，並沒有發現明顯的規律，詳細資料如表 6 所示。

(七) 停留時間長度分布

在分析 14 日間的停留事件資料後，得到了最長的停留時間為開始於 4 月 7 日 11 點 17 分 41 秒的停留事件，總共停留了 2780 秒。而數量最多的停留時間長度為最短的 5 秒，共有 52,952 筆，對應每個停留時間長度的總事件發生數量分布如圖 6 所示。

在使用 Excel 對圖 6 內資料進行曲線擬合(fit)之後，發現可以使用乘幂公式擬合資料分布，其決定係數(coefficient of determination)為 0.9404，因此本研究推測鵝隻停留時間長度(x)與事件發生頻率(y)符合幂次定律，擬合得到之公式如式 1 所示。

$$y = 3,594,333.12 x^{-2.277} \quad (1)$$

為了瞭解各種長度的停留事件發生頻率，本試驗也統計了各種停留時間長度事件發生數量，並計算在試驗進行的 14 日間所占的比例，詳細資料如圖 7 所示。

可以發現時間長度最短的 5 秒，占了所有發生事件的 52.3%，而停留時間不長於 30 秒的事件更是占了全體的 91.5%，而且根據停留時間計算系統的計算結果，96.5%的鵝隻不會在同一個位置停留超過一分鐘。

但是值得注意的是，根據本研究統計得到的數據中，雖然 99.82%的鵝隻停留時間不會超過五分鐘，但在試驗期間的 140 個小時，也累計發生了 183 筆累計時間超過五分鐘的停留事件，平均不到一小時發生一次。在未來的應用情境中，在此部分探討的短時間停留事件，是否在真正需要分析的數據範圍之內，是一個需要評估的問題點。

表 6、各週日別停留事件筆數

Table 6 The quantity of non-moving event for each day of the week

週日別	週日	週一	週二	週三	週四	週五	週六
事件數	14,509	14,319	14,228	14,334	14,799	15,191	13,946




圖 6、各停留時間長度事件發生數量分布圖

Fig. 6 Distribution of the dwell time and the non-moving event




圖 7、各停留時間長度事件發生數量百分比

Fig. 7 The percentage of the length of the dwell time of the non-moving event

以下圖表由於停留時間長度原始資料類別數量較多，在圖表上較不易呈現，於是大略分為四大類：30 秒以下、30 秒到 60 秒間、60 秒以上以及全體事件。另外，因 30 秒以上停留事件筆數較少，故在以下圖表中對應左側縱座標軸，數量較多的 30 秒以下與全體事件數對應的則是右側的縱座標軸。

針對不同日期的停留時間長度分布情況，由圖 8 可以發現，30 秒以下事件發生數量基本上和全體事件總數呈現相同的趨勢，而 30 秒以上事件在 4 月 9 日到 4 月 11 日間，和其他 11 天相比有較少的數量，而另外

11 天雖然也有上下波動的情況，但是並沒有觀察到很明顯的趨勢。而 4 月 9 日到 4 月 11 日間長時間停留事件數量較少的原因，在經過與現場管理人員的確認後，得知那三日內有啄羽的行為發生，於是造成鵝隻有騷動、較不平靜的狀況發生。

圖 9 為各個時段中不同時間長度停留事件的發生數量分布，在各時段數量分布上並沒有發現明顯的差異。而各週日別的事件數量分布如圖 10 所示，在 35 秒以上事件的部分，可以看到在週三到週五相對較少一點，推測是受到前面提到之啄羽事件的影響。




圖 8、各停留時間長度事件單日發生數

Fig. 8 The quantity of each dwell time of the non-moving event for each day




圖 9、各停留時間長度事件各時段發生數量

Fig. 9 The quantity of the dwell time of the non-moving event for each time




圖 10、各停留時間長度事件各時段發生數量

Fig. 10 The quantity of the dwell time of the non-moving event foreach day of the week

四、結論

本研究應用 Faster R-CNN 演算法，開發了一套鵝隻停留模式分析系統，其達到目標條列如下：

(一) 開發一個圖像擷取系統，能夠自動定時地以 5 秒的時間間隔擷取鵝隻生活圖像，並從現場禽舍透過網路上傳到資料中心內的網路連接儲存設備，在試驗進行的 14 日間總共取得了 192,179 張鵝隻生活圖像。

(二) 開發一個位置偵測系統，能夠偵測圖像內鵝隻位置並寫入資料庫，偵測位置使用之卷積神經網路模型，經試驗測試後能在 IOU 門檻為 0.5 的情況下，達到 98.7% 的準確度和 99.8% 的涵蓋率。在試驗期間共偵測得到 1,007,118 筆鵝隻位置資訊。

(三) 開發一個停留時間計算系統，能夠計算鵝隻停留時間並寫入資料庫，在試驗期間共記錄了 101,325 筆停留事件，分別在 30 秒以內、60 秒以內、300 秒以內的停留事件佔了整體的 91.5%、96.5%、99.8%。

(四) 研究結果顯示能夠以乘冪公式 $y = 3,594,333.12 x^{-2.277}$ 擬合停留時間長度與發生數量的曲線，推測停留時間長度發生頻率符合冪次定律，停留時間越長的事件發生頻率越低。

(五) 在試驗期間收集的數據中，發現飼養鵝隻群體若有騷動、不平靜的情況發生，30 秒以上停留事件的發生數量會相對較低。

(六) 在試驗期間收集的數據中，並未發現鵝隻會在特定時段有長時間停留的傾向、也未發現鵝隻在特定的週日

別有長時間停留的傾向。

五、建議

在圖像擷取系統試驗中的圖像即時上傳成功率，只達到了 79.5% 的成功率，推測是由於無線網路的連線品質不佳所造成的影響，建議未來實際應用時可以視現場情況考慮以有線網路的方式傳輸圖片，以確保有穩定良好的網路連線品質，或是使用更好的無線網路設備。

本研究開發之位置偵測系統，由於拍攝環境與檢測對象較為單純，故有較好的準確率表現，建議未來可於自然光源環境測試，並嘗試推廣到不同成長階段的鵝隻，能夠更加接近產業現場的需求，增加未來投入實際生產應用的可能性。本研究使用 PASCAL VOC 的 IOU 門檻 0.5 來計數混淆矩陣，建議未來可以使用較新的 COCO 資料集標準作為門檻值。

停留時間計算系統部分，目前是以 10 分鐘的時間間隔作為一個判斷批次的時間長度，建議未來可以視需求調整系統的時間間隔，以符合現場判斷的即時性要求。而在停留狀態判斷部分，目前使用 IOU 門檻 0.9 來作為停留狀態的判斷標準，建議未來可以嘗試不同門檻，以符合實際應用之需求。

另外，本研究並未對非健康鵝隻進行停留模式分析，也尚未找出鵝隻停留時間長度之規律，建議未來可以整合其他資訊進行相關性分析，如環境溫濕度、人為干擾事件發生時間、鵝隻個體之間的距離等。

六、參考文獻

- [1] 尤銘潭。2010。夏季水簾環控下白羅曼鵝肥育期飼養模式之探討。碩士論文。臺中：中興大學動物科學系。
- [2] 行政院農業委員會。2019。畜禽產品生產量值統計資料庫。臺北：行政院農業委員會。網址：<https://agrstat.coa.gov.tw/sdweb/public/inquiry/InquireAdvance.aspx>。上網日期：2019-07-16。
- [3] 何于蓁。2018。台灣地區 2015 年至 2017 年高致病性禽流感疫情之空間分析及影響疫情之環境因素。碩士論文。臺中：中興大學微生物暨公共衛生學研究所。
- [4] 謝承興。2018。應用卷積類神經網路於鵝隻圖像辨識之研究。碩士論文。臺中：中興大學生物產業機電工程學系。
- [5] Girshick, R. 2015. Fast R-CNN. In "2015 IEEE Conference on Computer Vision and Pattern Recognition", 1440-1448. Boston, Massachusetts, IEEE.
- [6] Lu, A., Y. Diao, H. Chen, J. Wang, P. Ge, X. Sun and D. Hao. 2014. Evaluation of histopathological changes, viral load and immune function of domestic geese infected with Newcastle disease virus. Avian Pathology 43(4): 325-332.
- [7] Lin, C. Y., K.W. Hsieh, Y. C. Tsai and Y. F. Kuo. 2018. Monitoring chicken heat stress using deep convolutional neural networks. In "2018 ASABE Annual International Meeting", 1-5. Detroit, Michigan, ASABE.
- [8] McFerran, J. B. and J. A. Smyth. 2000. Avian adenoviruses. Revue Scientifique et Technique-Office International des Epizooties 19(2): 589-598.
- [9] Powers, D. M. 2011. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. Journal of Machine Learning Technologies 2(1): 37-63.
- [10] Ren, S., K. He, R. Girshick and J. Sun. 2017. Faster R-CNN: Towards Real-Time Object Detection

with Region Proposal Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence 39(6): 1137-1149.

2020 年 09 月 26 日 收稿

2021 年 01 月 10 日 修正

2021 年 02 月 08 日 接受