

# 應用超參數選擇於監督式學習之研究

## Research for supervised learning based on hyper-parameters selection

邱機平

明志科技大學電機工程學系

劉奕辰

明志科技大學電機工程學系

### 摘要

本論文透過灰狼演算法(Grey Wolf Optimizer, GWO)搜尋較佳之超參數設定值，並應用於機器學習模型中，以期達到提高現有模型的訓練成效的目的，而應用之機器學習模型包含有隨機森林(Random Forest, RF)、支援向量機(Support Vector Machine, SVM)以及 K 近鄰算法(K-Nearest Neighbors, KNN)等三種，至於搭配使用之標準資料集則是包含有 MNIST 以及波士頓房價等兩種，從計算結果可以知道，若是提供較為適當的超參數設定值，確實可以達到提高機器學習模型訓練成效之需要，除此之外，本論文亦將此一概念應用至自製之手勢資料集，此資料集的目的在於利用手勢分別來呈現數字 0 到 9，此資料集若以年齡方式區分，其包含 12 歲以下 30 筆、12-65 歲 310 筆、以及 65 歲以上 60 筆等影像資料，總計 400 筆原始資料，若以性別區分則包含男性 170 筆與女性 230 筆，同時為達到增進機器學習模型訓練之成效，本論文透過使用旋轉角度技術將原始 400 筆影像資料擴增至 8000 筆影像資料，之後再將此擴增後之影像資料透過 Mediapipe 工具，將每一張影像資料分別進行 21 個手部關鍵點的標記，並儲存成 .csv 檔案格式，再使用人工神經網路(Artificial Neural Networks, ANN)進行測試，從計算結果可以再次驗證，透過提供較為適當的超參數設定值給機器學習模型進行訓練，其影像訓練成效能得以提升；綜合以上結果可知，最佳化方法在超參數上的有效性，同時透過具體的影像識別實例，展現了此方法實際應用的可行性。

關鍵字：機器學習、最佳化方法、超參數選擇、影像識別、手部辨識

### Abstract

To promote the training outcomes, the Grey Wolf Optimizer (GWO) is used in this paper to search the better hyper-parameter settings used in the machine learning model. And, three machine learning models including Random Forest (RF), Support Vector Machine (SVM) and K-Nearest Neighbors (KNN) with two standard datasets, Modified National Institute of Standards and Technology (MNIST) and Boston housing, are used in this paper to compare training performances. The computation results of the proper hyper-parameter settings used in the machine learning model are superior to try-and-error. To verify the importance of the hyper-parameter selection again, this paper finishes the hand gesture dataset and used into Artificial Neural Network (ANN) model. The image in hand gesture dataset is used to represent the numbers from 0 to 9. And, the hand gesture dataset has 400 images and including a wide age group that under 12 years old has 30 images, the 12-65 age group has 310 images and over 65 years old has 60 images. This dataset is also divided by gender, male has 170 images and female has 230 images. All original images are rotated clockwise and counterclockwise to achieve the aim of the number of images augmentation that increases from 400 images to 8000 images. These images are firstly converted to .csv by using the mediapipe tool. For reconfirm the importance of the hyper-parameter selection, these converted data

is as input for Artificial Neural Network (ANN). From the computational results, this study not only confirms the effectiveness of the Grey Wolf Algorithm in hyper-parameter and feature selection but also demonstrates its practical applicability through concrete image recognition examples.

Keywords: Machine Learning, Optimization Methods, Hyper-parameter Selection, Image Recognition, Hand Gesture Recognition

## 1. 動機與目的

近年來，科學技術的演進基於人工智慧技術的發展，越來越趨近於精密，這也導致科學數據產生爆炸的增長，無論是從金融分析、醫療保健、交通建設或是休閒娛樂方面來說皆是如此，然而要具備處理如此龐大數據的分析能力，除了需要持續提升電腦計算能力(Chen et al., 2020; Yuan et al., 2023)外，機器學習模型效能提升的研究(Jordan et al., 2015)尤其重要，至於在機器學習模型研究方面，大多區分為分類系統(classification systems)(Bao et al., 2026; Ehsan et al., 2026; Antimo et al., 2025)以及迴歸系統(regression systems)(Majid et al., 2026; Ivan et al., 2025; Sushil et al., 2025; Sailallah et al., 2025)兩種；分類系統的目的在於針對離散資料(discrete data)進行分群的動作，亦即透過資料分群來理解新資料應屬於哪一群，這大部分均運用至影像識別系統(Ashwin et al., 2025; Luo et al., 2025)，至於迴歸系統則是針對連續資料(continuous data)進行研判資料的趨勢，並藉以分析新資料輸入應產生怎樣的輸出資料(Majid et al., 2026; Shereen et al., 2025; Demirkaya et al., 2025)。

然而機器學習模型之成效與模型超參數(hyper-parameters)的選擇(Feurer et al., 2019)有著密不可分的关系，由於選擇不同的超參數值將會直接關係到機器學習模型的訓練成果，因此，選擇適當的學習率(learning rate)、批量大小(batch size)以及世代(epochs)等超參數值對於提高模型性能便顯得至關重要，然而目前大部分的超參數值的設定方式仍停留在以試錯法(trial and error)(Young et al., 2009)方式，亦即透過使用者對於系統的理解，以經驗值方式進行設定並實驗，試誤法具備相當的直觀性質，不過，由於試錯法需針對機器學習模型進行多次的

計算分析，藉以觀察不同超參數值之設定組合對機器學習模型性能的影響，以確認適當的模型成效，不但費時也可能因為超參數值空間過於龐大，因而導致錯過超參數的最佳組合，所以，有鑑於透過試錯法尋找適當之超參數值的方式缺乏系統性以及科學性，因此，透過具備系統性的搜尋方法找尋最好之超參數設定值(Hou et al., 2026; Zhao et al., 2026)，對於機器學習模型成效將更為急迫性。

本論文將透過最佳化方法的使用來進行搜尋監督式學習(Supervised Learning, SL)之超參數值，而在眾多最佳化方法中，由於灰狼演算法(Grey Wolf Optimizer, GWO)(Mirjalili et al., 2014)具備結構簡單、易於實現、快速收斂以及全域搜尋(global search)能力等優點，因而，灰狼演算法早已應用於機器學習模型(Madyavanhu et al., 2024; Xiao et al., 2018)之中，而本論文也將使用灰狼演算法作為搜尋超參數值的演算法，同時，為了驗證灰狼演算法搜尋機器學習模型之超參數值的能力，本論文亦將常用之網格搜索(Grid Search)(Zhao et al., 2024)、隨機搜索(Random Search)(Bergstra et al., 2012)、遺傳演算法(Genetic Algorithm, GA)(Ramachandran et al., 2024)以及粒子群演算法(Particle Swarm Optimization, PSO)(Kennedy et al., 1995)等最佳化方法應用於機器學習模型之超參數值搜尋，至於資料集方面則是使用來自Kaggle(Kaggle, 2026)這個全球最大的數據科學平台的手寫數字數據集(Modified National Institute of Standards and Technology, MNIST)(Kaggle, 2026)以及波士頓房價數據集(Kaggle, 2026)，所使用之機器學習模型方面，則是選擇了隨機森林(Random Forest, RF)(Salman et al., 2024)、支援向量機(Support Vector Machine, SVM)(Kumar et al., 2025)和K-近鄰演算法(K-

Nearest Neighbors, KNN)(Lara et al., 2025)等三種，從計算結果可以知道，透過灰狼演算法搜尋出之超參數值之使用結果優於其他最佳化方法，最後，此一架構將應用於自行收集的手勢資料集中，以便驗證本論文所提出之架構的實際應用成效。

## 2. 文獻探討

### 2.1 機器學習與超參數的關係

機器學習模型的訓練過程，係依據模型超參數的設定值來進行，不同的超參數值可能引導模型訓練產生不同的結果，因此，選擇適當之超參數值於機器學習模型中是十分重要的(Rom et al., 2025)，至於常見的超參數包含學習率(learning rate)、正規化參數(regularization parameter)、批量大小(batch size)、神經網路的層數(layers)和每層的神經元(neuron)數量等，其中以學習率來說，設定太大的學習率值可能會導致機器學習模型在訓練過程中發散，無法收斂，但若是設定太小的學習率值，便可能會導致機器學習模型的訓練時間過長，且有機會產生較差的訓練成果，再以正規化參數來說，正規化的動作將有助於簡化機器學習模型數據間的差異，此降低數據複雜度的動作將能達到延緩過訓練的目的，經過以上說明可以知道，在機器學習過程中，適當的超參數值的選擇對於機器學習成效有著相當重要的地位。

然而超參數空間通常是高維度且屬於非凸的，因此，像是靠經驗調整超參數值或是透過如網格搜索(Grid Search)等傳統之超參數調整方法，在面對處理較大系統時，其機器學習效率變顯得有很大的改善空間；會導致這樣的結果之原因在於靠經驗調整超參數值係依賴於研究人員的經驗和直覺，這並不具備系統性與科學性的特性，且無法保證找到全域最佳結果，至於網格搜索法則是盡可能針對所有超參數配對資料進行訓練和驗證，這樣的作法會有較大機會找到較適當之超參數配對，不過隨之而來的計算成本將會隨著超參數數量的增加而呈指數增長。

為了以較低計算成本獲致較高的機器學習成

效，近年來，機器學習模型透過如遺傳演算法(Genetic Algorithm, GAs)(Shreyas et al., 2025)以及差分進化法(Differential Evolution, DE)(Dan et al., 2005)等相關最佳化技術來針對適當之超參數值做搜尋的動作，透過各種最佳化方法的使用，能夠讓演算法在最短的時間內探索較大之超參數空間，並增加搜尋較好的機器學習訓練成效之可能性，因此，本論文擬透過灰狼演算法(Grey Wolf Optimizer, GWO)的使用，進行適當超參數值的搜尋，並應用至各個機器學習模型中。

灰狼演算法係為學習灰狼群之捕獵行為所演化出之最佳化方法，其主要的觀點在於透過灰狼群體之合作與信息共享的特性，來達到實現全域搜索(global search)和區域搜索(local search)的平衡，其次，灰狼演算法具有結構簡單、參數少以及收斂速度快等優點，適合使用於高維度和非凸系統最佳化問題。

### 2.2 灰狼演算法

灰狼演算法係由 Seyedali 團隊於 2014 年透過觀察灰狼之社會結構以及團隊合作捕抓獵物過程所提出(Mirjalili et al., 2014)，因此，此演算法經過模擬灰狼群在自然界中的追蹤、包圍以及攻擊獵物的過程；灰狼演算法之主要流程如下：

1. 群體初始化(產生初始狼群)：以隨機的概念初始化灰狼群體中，每一隻灰狼依據自己的目標函數值決定在解空間的位置。
2. 選擇領袖群體(目標函數值計算)：在每次疊代中，演算法會根據目前最佳解順序，選擇  $\alpha$ 、 $\beta$  以及  $\delta$  三個領袖，以作為領袖群體。
3. 包圍獵物(灰狼群位置更新)：除領袖群體外，所有灰狼( $\omega$ )會透過領袖群體的指導，作為更新自己的位置達到包圍獵物的目的。
4. 追捕和攻擊(演算法收斂判斷)：透過不斷調整灰狼群的位置向量，達到縮小灰狼群與獵物間的距離，以做為模擬追捕和攻擊獵物的過程，直到捕捉到獵物，亦即演算法收斂到最佳解。

圖 1 所示為灰狼群包圍獵物的示意圖；其中，領袖群體  $\alpha$ 、 $\beta$  與  $\delta$  的選擇方式，係透過

目前目標函數值最好(亦即最接近獵物)的三隻灰狼來擔任，至於圖中的  $\omega$  即為灰狼群其他的灰狼。

### 2.3 灰狼演算法應用於超參數優化

灰狼演算法在這裡係作為選擇超參數值的工具，其工作流程圖如圖 2 所示；圖 2 為應用灰狼演算法於超參數選擇之流程圖，此流程圖開始時，先將經過初始設定之超參數值作為機器學習模型訓練時的設定值使用，此機器學習模型可以使用任一模型，而其差異僅在需要選擇的超參數不同而已，機器學習模型訓練完成後，灰狼演算法即可依據測試集的評估資料，適當調整超參數值的大小，至於評估基準方面則可以依據任務的不同進行調整，比如說分類問題的模型訓練可以使用準確率做為訓練成果的參考指標，或是迴歸問題的模型訓練則可以考慮如均方誤差(Mean Squared Error, MSE)以及平均絕對百分比誤差(Mean Absolute Percentage Error, MAPE)等做為訓練成果的參考指標，當然，應對不同的目的則可以使用不同的評估指標；以下簡單介紹本論文使用之隨機森林(Random Forest, RF)、支持向量機(Support Vector Machine, SVM)以及 K-近鄰演算法(K-Nearest Neighbors, KNN)等三種機器學習模型。

### 2.4 隨機森林(Random Forest, RF)

隨機森林(Salman et al., 2024)主要係使用於分類以及迴歸問題方面，並透過多棵決策樹(decision trees)所組成，然而每顆決策樹均獨立針對數據資料進行預測，之後再針對所有的預測結果透過投票方式或計算平均值方式，來得出最終的預測結果，因此，隨機森林是屬於集成學習(ensemble learning)方法。




圖 1 灰狼群包圍獵物的示意圖(劉奕辰, 2024)

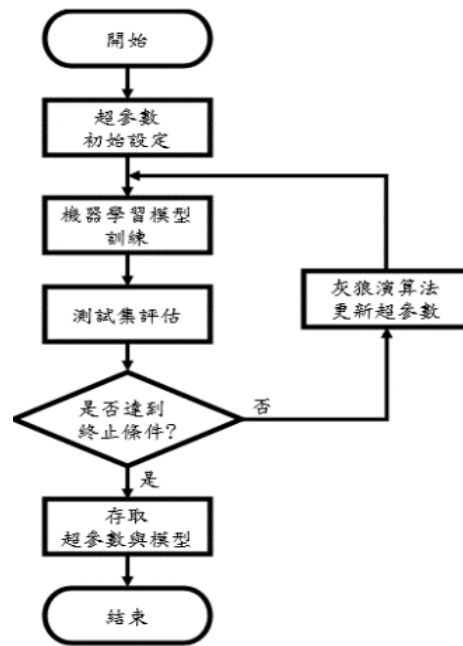


圖 2 應用灰狼演算法於超參數選擇之流程圖

隨機森林操作之流程如下：

1. 隨機抽樣(bootstrap sampling)：隨機森林模型操作時，首先會從訓練資料集中以隨機方式選擇部分資料作為每顆決策樹的訓練集。
2. 隨機選擇特徵(random feature selection)：將每個節點處的所有特徵中，以隨機方式選擇一部分特徵來決定分裂。
3. 構建決策樹：基於重複操作流程 1 以及 2 的動作，達到建構多棵決策樹的目的。
4. 預測：分類問題使用投票方式，以多數決定最終的分類結果，至於迴歸問題方面，則可以使用計算平均值方式，來得出最終的預測結果。

### 2.5 支援向量機(Support Vector Machine, SVM)

支持向量機(Kumar et al., 2025)主要是使用於分類問題與迴歸分析的一種監督式學習模型，其作法係藉由尋找最好的超平面的方式，達到將數據資料分開並最大化分類邊界的間隔。

支持向量機操作之流程如下：

1. 選擇超平面：在高維度空間中藉由尋找適當超平面方式，達到將數據資料區分為不同的類別。
2. 最大化間隔：尋找能夠最大化兩類數據資料間隔的超平面，而此間隔稱為 margin。

3. 支持向量：超平面的決定僅僅依靠於最靠近超平面的數據資料，而這些數據資料則稱為支持向量。
4. 非線性問題：支持向量機透過使用核技巧(kernel trick)的方式，將線性不可分問題之數據映射到更高維度的空間之中，並於高維度空間中進行線性分隔。

## 2.6 K 最近鄰演算法(K-Nearest Neighbors, KNN)

K-近鄰演算法(Lara et al., 2025)與支持向量機一樣，廣泛使用於分類問題與迴歸分析的一種相當簡單且直觀之監督式學習模型；此演算法的核心思維係依據鄰近的數據資料達到預測未知數據資料的類別(分類問題)或值(迴歸問題)，由於 K-近鄰演算法並不需要先假設數據資料的分佈情況，因此屬於是一種非參數學習演算法，也就是當給定一個未知類別(值)的數據資料時，K-近鄰演算法會查找訓練集中與該資料最近的 K 個資料鄰居，然後再根據這些資料鄰居所提供的訊息達到預測未知資料的類別或是數值。

K-近鄰演算法預測未知資料的類別或是數值的方式如下：

1. 分類問題：一般採取投票制，亦即將出現次數最多的類別指定為未知資料點的類別(值)。
2. 迴歸問題：一般採取計算這些資料鄰居值的平均數或是中位數作為預測值。

K-近鄰演算法操作之流程如下：

1. 超參數 K 值：首先選擇 K 個需要考慮的最近資料鄰居。
2. 計算距離：計算每個未知資料樣本與訓練集中所有資料樣本的距離，而常用的距離度量包括歐幾里得距離、曼哈頓距離以及明可夫斯基距離等三種。
3. 搜尋 K 個最近資料鄰居：依據所計算的距離資料，找出最近的 K 個訓練資料樣本。
4. 預測：應用多數投票法於分類問題中以決定未知資料樣本的類別，或是應用 K 個最近鄰居的平均值於迴歸問題上進行預測。

## 3. 研究方法

### 3.1 機器學習模型之超參數範圍

本論文使用手寫數字(MNIST)資料集以及波士頓房價(Boston Housing)資料集做為驗證本論文所提方法之可行性，至於搭配最佳化方法應用之機器學習模型則有隨機森林、支援向量機以及 K-近鄰演算法等三種；各個機器學習模型使用之超參數範圍(Yang, 2020)如下所示：

#### 1. 隨機森林：

決策樹數量(n\_estimators)：10 至 100 之間

決策樹最大深度(max\_depth)：5 至 50 之間

內部節點最小取樣數(min\_samples\_split)：2 至 11 之間

外部節點最小取樣數(min\_samples\_leaf)：1 至 11 之間

評估標準(criterion)：'gini'以及'entropy'

最大特徵數量(max\_features)：1 至 64 之間

#### 2. 支援向量機：

懲罰參數(C)：0.1 至 50 之間

核函數(kernel)：'liner'、'poly'、'rbf' 以及 'sigmoid'

#### 3. K-近鄰演算法：

鄰居數量(n\_neighbors)：1 至 20 之間

### 3.2 最佳化方法之參數設定

為驗證應用灰狼演算法進行搜尋機器學習模型超參數值的效能，因而包含網格搜索、隨機搜索、遺傳演算法以及粒子群演算法等四種常見的最佳化方法亦應用於搜尋機器學習模型超參數值，以達到驗證灰狼演算法的實用性與可行性的目的；五種最佳化方法均設定最大疊代數值為 50 代，網格搜索以及隨機搜索的交叉驗證參數(cv)值設定為 5，至於其他演算法的族群大小(population size)均設定為 10。

首先使用手寫數字(Modified National Institute of Standards and Technology, MNIST)資料集作為驗證五種最佳化方法的測試資料集，此資料集是一個包含手寫 0 到 9 的數字灰階影像資料，其中包

含訓練機器學習模型的訓練資料 60,000 筆影像資料以及評估模型的性能的測試資料 10,000 筆影像資料，每張影像資料均為 28 x 28 的畫素資料，因為此資料為灰階影像，所以，每一畫素資料的值均介於 0 (代表白色)到 255 (代表黑色)之間；圖 3 所示為 MNIST 資料集中的部分影像資料。

由於本論文透過網格搜索、隨機搜索、基因演算法、粒子群演算法以及灰狼演算法等五種最佳化方法，分別針對隨機森林、支援向量機以及 K-近鄰演算法等三種機器學習模型進行超參數選擇，來比較使用 MNIST 資料集時，其最佳化超參數值後之測試準確率，計算流程圖如圖 2 所示，亦即在圖 2 流程圖中，將機器學習模型分別使用隨機森林(如圖 4 所示)、支援向量機(如圖 5 所示)以及 K-近鄰演算法(如圖 6 所示)等三種，而在每一種機器學習模型使用時，將圖 2 的灰狼演算法部分，分別使用網格搜索、隨機搜索、遺傳演算法、粒子群演算法以及灰狼演算法等五種最佳化方法，並記錄各個機器學習模型如下所示之訓練結果；相關測試結果：

1. 隨機森林：透過應用網格搜索、隨機搜索、遺傳演算法、粒子群演算法以及灰狼演算法等五種最佳化方法所搜尋到的超參數值於隨機森林模型之測試準確率分別為 93.32%、93.38%、93.83%、93.73% 以及 96.52%。
2. 支援向量機：透過應用網格搜索、隨機搜索、遺傳演算法、粒子群演算法以及灰狼演算法等五種最佳化方法所搜尋到的超參數值於支援向量機模型之測試準確率分別為 97.44%、97.35%、97.44%、97.44% 以及 98.20%。
3. K-近鄰演算法：透過應用網格搜索、隨機搜索、遺傳演算法、粒子群演算法以及灰狼演算法等五種最佳化方法所搜尋到的超參數值於 K-近鄰演算法模型之測試準確率分別為 96.22%、96.33%、96.83%、96.83% 以及 97.20%。

如前所述之計算結果可以知道，在使用 MNIST 資料集進行訓練時，透過灰狼演算法選擇之超參數值，相較於其他四種最佳化方法有較好的測試結果。

透過波士頓房價資料集的使用以達到再次驗證應用灰狼演算法於機器學習模型有較好的訓練成效；波士頓房價資料集是屬於一個分類問題，此資料集廣泛應用於機器學習以及統計分析領域，係為做為房價預測的經典資料集，其中包含有 506 個樣本資料且每個樣本資料包含有 14 個特徵，這些特徵代表著房產資料相關之犯罪率、住宅平均房間數、到波士頓五個就業中心的加權距離以及該地區的房價中位數等屬性資料，且房價中位數通常作為機器學習模型預測的目標變量。




圖 3 部分 MNIST 資料集之影像資料

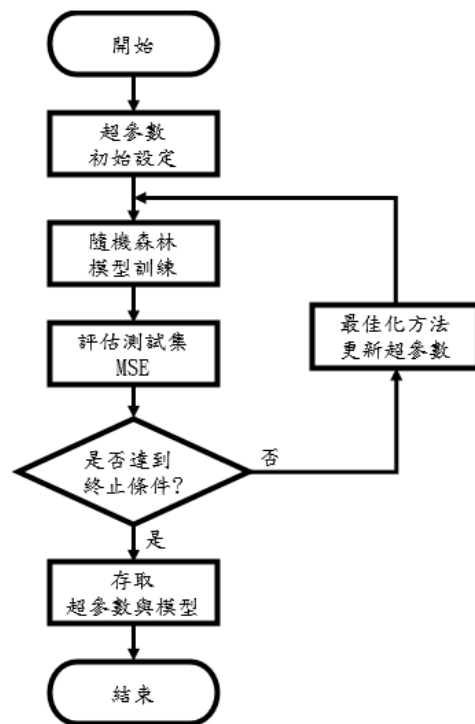


圖 4 最佳化方法應用於隨機森林之流程圖

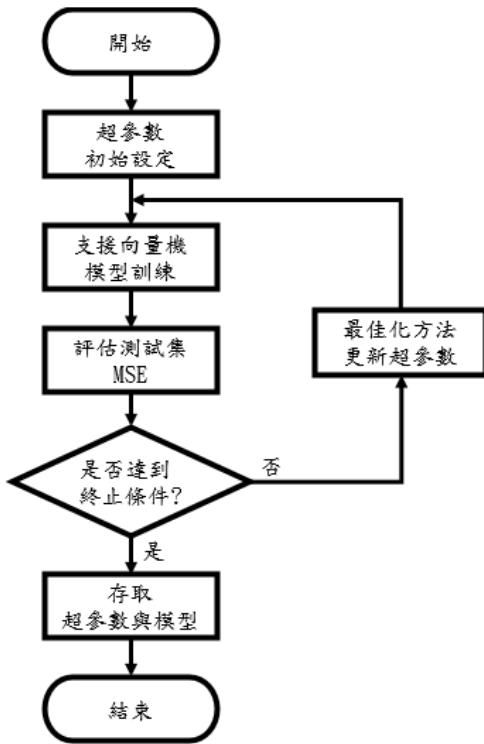


圖 5 最佳化方法應用於支援向量機之流程圖

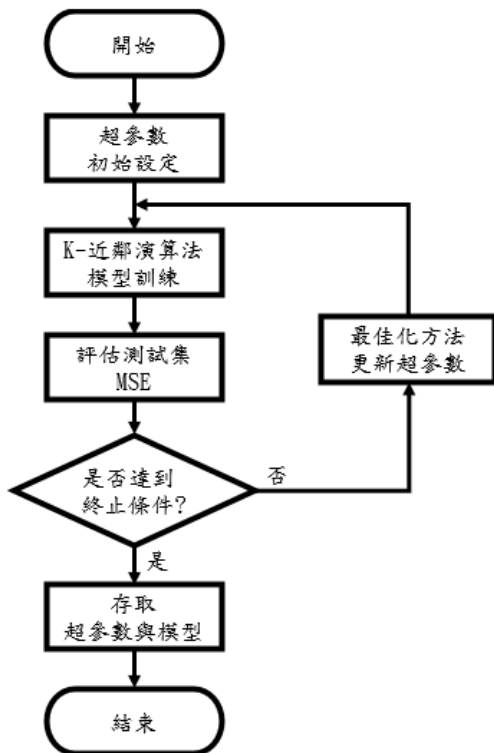


圖 6 最佳化方法應用於 K-近鄰演算法之流程圖

以波士頓房價(波士頓房價資料集的部分資料如圖 7 所示)作為比較各個機器學習模型的訓練成效之資料集,並透過使用各個最佳化方法進行搜尋最佳超參數值於機器學習模型中的方式(如圖 4 至圖 6),不過,不同於先前 MNIST 資料集比較測試準確率,在這裡則是透過比較方均根誤差(Mean Square Error, MSE)做為比較基準;相關測試結果如下所示:

1. 隨機森林: 透過應用網格搜索、隨機搜索、遺傳演算法、粒子群演算法以及灰狼演算法等五種最佳化方法所搜尋到的超參數值於隨機森林模型之測試準確率分別為 29.02、27.92、26.95、25.69 以及 9.603。
2. 支援向量機: 透過應用網格搜索、隨機搜索、遺傳演算法、粒子群演算法以及灰狼演算法等五種最佳化方法所搜尋到的超參數值於支援向量機模型之測試準確率分別為 67.07、61.40、60.17、58.72 以及 24.46。
3. K-近鄰演算法: 透過應用網格搜索、隨機搜索、遺傳演算法、粒子群演算法以及灰狼演算法等五種最佳化方法所搜尋到的超參數值於 K-近鄰演算法模型之測試準確率分別為 81.53、80.77、80.77、80.74 以及 21.65。

本論文所提之概念經由以上 MNIST 資料集以及波士頓房價資料集的測試後,可以得到以下兩個結論:

1. 透過最佳化方法搜尋到的超參數值並使用於機器學習模型中,具備可靠性、科學性 且比像是試誤法等傳統方法更能獲致較佳的訓練成效。
2. 灰狼演算法在本論文中所呈現出的效能,相較於其他四種最佳化方法的效果更佳。

	CRIM	ZN	INDUS	CHAS	NOX	RM	AGE	DIS	RAD	TAX	PTRATIO	B	LSTAT	Price
0	0.00632	18.0	2.31	0.0	0.538	6.575	65.2	4.0900	1.0	296.0	15.3	396.90	4.98	24.0
1	0.02731	0.0	7.07	0.0	0.469	6.421	78.9	4.9671	2.0	242.0	17.8	396.90	9.14	21.6
2	0.02729	0.0	7.07	0.0	0.469	7.185	61.1	4.9671	2.0	242.0	17.8	392.83	4.03	34.7
3	0.03237	0.0	2.18	0.0	0.458	6.998	45.8	6.0622	3.0	222.0	18.7	394.83	2.94	33.4
4	0.06905	0.0	2.18	0.0	0.458	7.147	54.2	6.0622	3.0	222.0	18.7	396.90	5.33	36.2

圖 7 波士頓房價資料集的部分資料

#### 4. 實驗設計與結果分析

從先前的討論可以知道，透過灰狼演算法搜尋機器學習模型之超參數值之作法，確實可以獲致不錯的結果，然而所使用之 MNIST 資料集以及波士頓房價資料集均是屬於已經整理過的資料集，在這裡，論文將所提之架構應用到自行建立之手勢資料集中，以再次驗證所提架構之可行性；手勢影像資料集的部分影像資料如圖 8 所示。

本論文建立之手勢資料集係以手勢影像方式呈現數字 0 到 9，此資料集共包含有 400 筆影像資料，同時，為確保此影像資料集的多樣性，因此，影像資料包含性別以及年齡層的區隔；在性別區隔方面，男性 170 筆以及女性 230 筆，而在年齡層區隔方面，則是區分為 10 歲以下 30 筆、11 到 20 歲 110 筆、21 到 40 歲 130 筆、41 到 60 歲 70 筆以及 61 歲以上 60 筆等；然而 400 筆影像資料仍是太少，並不足以作為機器學習模型的訓練資料，因此，透過將影像資料進行順時針旋轉(如圖 9 所示)以及逆時針旋轉(如圖 10 所示)方式，以達到擴增訓練資料的目的，從而增進機器學習模型之訓練成效，在這裡，所有原始影像資料的旋轉角度從 -10 度至 +10 度之間，每次旋轉 1 度，將原始影像資料從 400 筆擴增到 8000 筆，如此做法可以增加影像資料的數量與多樣性，達到提升訓練的效果(Shorten et al., 2019; Yang et al., 2022)。

為了快速且正確的解析手勢資料集中的影像資料特徵值，方便進行機器學習模型訓練，首先使用 Google 的 Mediapipe 工具進行 21 個手部關鍵點的標記的動作；Mediapipe 是 Google 推出之開放原始碼的機器學習框架，主要使用於影像處理、聲音以及文字等多媒體資料中，另外，在 Mediapipe 係由多個功能模組組成，而每個模組僅負責如影像擷取、臉部偵測、手部偵測或是姿勢追蹤等(OXXO, 2026)單一特定功能，因此屬於模組化設計工具，其中 Hands 模組可以偵測並追蹤多隻手掌，藉以輸出 21 個涵蓋了手掌和手指主要部位之手部關鍵點的座標(如圖 11 所示)，也就是當 Mediapipe 偵測手掌後，便會在手掌與手指上產生 21 個具有 x、y、z 座標的節點，而這些節點座標

代表著三維空間的位置，由此，手勢資料集的影像資料可以透過 Mediapipe 中的 Hands 模組之使用，將進行手部關鍵點進行標記，而標記之資料經過手指彎曲角度計算(如圖 12 所示)後，便可以作為後續機器學習模型的訓練資料使用。

人工神經網路(Artificial Neural Networks, ANN)(Chris et al., 1994)係作為手勢資料集訓練的機器學習模型，另外，已經過 Mediapipe 中的 Hands 模



圖 8 手勢影像資料集的部分資料(劉奕辰, 2024)




圖 9 順時針旋轉影像(劉奕辰, 2024)

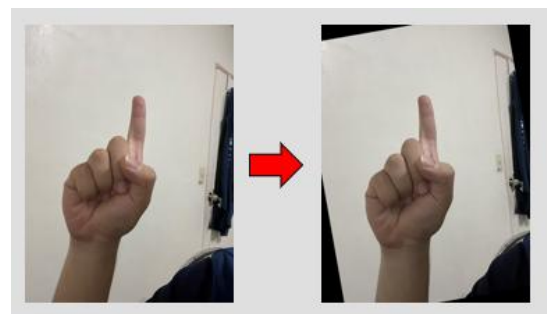


圖 10 逆時針旋轉影像(劉奕辰, 2024)




圖 11 手部關鍵點位置(OXXO, 2026)




圖 12 手指彎曲角度計算示意圖(劉奕辰, 2024)

組解析之五根手指彎曲角度則作為訓練資料，以產生對於手勢數字 0 到 9 的判讀，同時使用灰狼演算法對模型超參數進行選擇，以達到提高機器學習模型之效能，再次驗證所提之研究架構在實際應用的廣泛性，另外，此人工神經網路模型的輸入層次資料為 5 根手指彎曲角度，至於隱藏層次部分則是依序由 128 神經元、64 神經元以及 32 神經元所構成的全連接層次等 3 維度架構組成，最終輸出層次則有 10 個神經元資料作為辨識數字 0 到 9 的預測。

在人工神經網路模型的超參數中，學習率 (learning rate) 對於模型的訓練成效具備相當重要的影響力，因而，若在模型訓練過程中選擇適當之學習率值時，可以讓人工神經網路模型訓練的成效更佳，圖 13 所示為在人工神經網路模型中隨意設定不同學習率值(0.1、0.01 以及 0.0001)時的測試準確率曲線，從此曲線可以看出，相當的模型在不同的學習率下，模型訓練成效有著相當大的差異，圖 13 顯示出學習率值為 0.01 時有較好的表現，因此，在此人工神經網路模型中選擇學習率作為超參數值選擇之對象，並且以灰狼演算法作為搜尋適當學習率值的最佳化演算法；人工神經網路之超參數選擇流程圖，如圖 14 所示，且以下說明本論文所提之研究架構下的參數設定值：

人工神經網路模型：

1. 學習率(learning rate)：0.01 至 0.9 之間。

2. 訓練世代(training epoch)：20。

灰狼演算法：

1. 灰狼群大小(population size)：10。
2. 疊代代數(iteration number)：50。

經過圖 14 的架構以及以上參數的設定後，搜尋到學習率值為 0.165 時，人工神經網路模型的測試準確率可以高達到 98.50%，圖 15 則是人工神經網路模型之訓練、測試和驗證準確率曲線，因而可以驗證當選擇適當超參數值時，可以獲致較好之模型訓練成效。

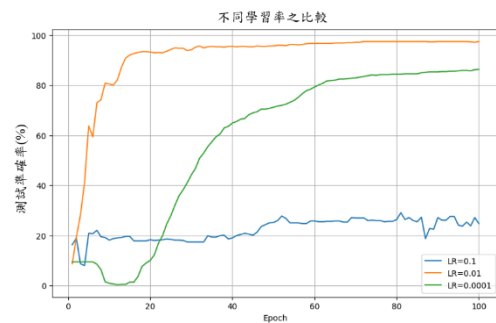


圖 13 不同學習率之比較

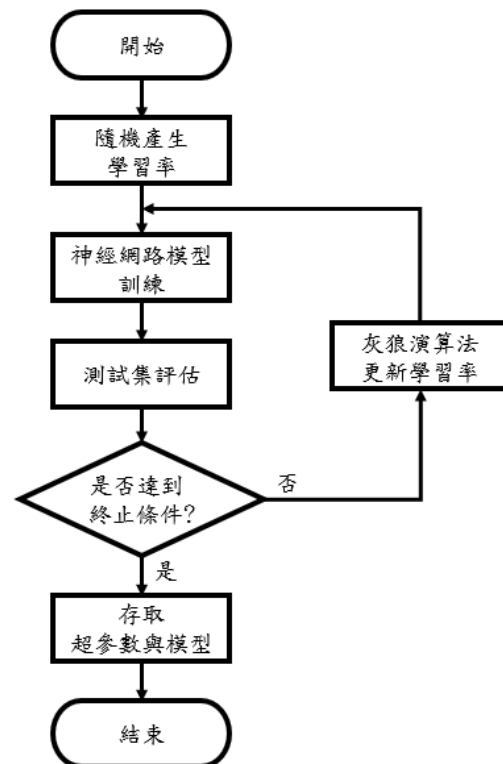


圖 14 人工神經網路之超參數選擇流程圖




圖 15 訓練、測試和驗證準確率曲線

## 結論

本論文透過隨機森林、支援向量機以及 K 近鄰算法等三種機器學習模型的使用，並搭配 MNIST 資料集以及波士頓房價資料集，做為驗證灰狼演算法搜尋機器學習模型超參數值的能力相較於網格搜索、隨機搜索、遺傳演算法以及粒子群演算法等四種常用之最佳化方法為佳，同時，從計算結果可以知道，若是提供較為適當的超參數設定值，確實可以達到提高機器學習模型訓練成效，為了再進一步驗證所提出之研究架構之實用性，本論文透過自行收集之手勢資料集進行驗證，此資料集的目的在於利用手勢分別來呈現數字 0 到 9，影像資料則是以年齡與性別做為收集的基準，以期達到影像資料多樣性，然而僅有 400 筆資料，再透過旋轉角度技術將原始 400 筆影像資料擴增至 8000 筆影像資料，之後再將此擴增後之影像資料透過 Mediapipe 工具，將每一張影像資料分別進行 21 個手部關鍵點的標記，並儲存成 .csv 檔案格式，以作為人工神經網路模型之訓練資料，經訓練之模型的測試準確率達到 98.50%，展現了此方法實際應用的可行性。

## 參考文獻

1. Antimo, A., Daniele D., Gennaro, G., Enrico L., (2025). A comparative study of classical and quantum machine learning techniques for industrial defect classification. 2025 IEEE International Conference on Quantum Artificial Intelligence (QAI), 439-444.

2. Ashwin, M., Parasa, G., Kannamma, R., Vennila, B., Haldorai, A., Sikarwar, S.S., (2025). Image recognition & classification with machine learning. 2025 7<sup>th</sup> International Conference on Information Systems and Computer Networks (ISCON), 1-5.
3. Bao, P.T., My, N.L.H., Thuat, N.K., Quan, L.T., (2026). An approach to attack classification for programmable network infrastructure using machine learning and deep learning solutions. IEEE Access, 14 4886-4916.
4. Bergstra, J., Bengio, Y., (2012). Random search for hyper-parameter optimization. Journal of Machine Learning Research, 13 281-305.
5. Chen, J., Chen Y., Guo, Z., Qiu, W., (2020). Research on high performance computing on power system based on machine learning algorithm. 2020 International Conference on Computer Information and Big Data Application (CIBDA).
6. Chris M.B. (1994). Neural networks and their applications. Review of Scientific Instruments, 65 1803-1832.
7. Dan, S., Wang, Y., Li, C., (2005). DERL: A differential evolution-reinforcement learning framework for efficient hyperparameter optimization in hyperspectral image classification. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 18 26530-26546.
8. Demirkaya, Y., Gencer K., Meydan, S., Guven, M.O., Savran, I. (2025). Forecasting flight delays from operational and weather data: A regression-based machine learning application. 2025 9<sup>th</sup> International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT).
9. Ehsan, M., Niusha, S., James, V., (2026). A systematic review on quantum machine learning applications in classification. IEEE Transactions on

- Artificial Intelligence, 7 4-21.
10. Feurer, M., Hutter, F., (2019). Hyperparameter optimization. Automated machine learning: Methods, systems, challenges, 3-33.
  11. Hou, X., Zhao, H., Long, X., (2026). Hyperparameter optimization method for affine projection algorithm based on deep unrolling. IEEE Signal Processing Letters, 33 206-210.
  12. Ivan, K.S., Moses, L.S., Daniel N., (2025). Road traffic congestion prediction using discrete event simulation and regression machine learning models. 2025 Winter Simulation Conference (WSC), 2730-2739.
  13. Jordan, M.I., Mitchell, T.M., (2015). Machine learning: Trends, perspectives, and prospects. Science, 225-260.
  14. Kaggle (2026). Boston housing dataset. <https://www.kaggle.com/c/boston-housing> .
  15. Kaggle (2026). Kaggle <https://www.kaggle.com> .
  16. Kaggle (2026). MNIST dataset <https://www.kaggle.com/datasets/hojjatk/mnist-dataset> .
  17. Kennedy, J., Eberhart, R., (1995). Particle Swarm Optimization. Proceedings of ICNN'95 - International Conference on Neural Networks, 1942-1948.
  18. Kumar, G.R., Soni, T., Manwal, M., Bansal G., (2025). Machine learning in healthcare: Effective stroke prediction using support vector machines. 2025 6<sup>th</sup> International Conference on IoT Based Control Networks and Intelligent Systems (ICICNIS), 1163-1166.
  19. Lara A.M., Eduard P., Rafael Š., Božidar F.G., (2025). Application of k-nearest neighbor machine learning algorithm in high voltage circuit breaker monitoring system by analyzing spring mechanism motor current. 2025 5<sup>th</sup> International Conference on Smart Grid Metrology (SMAGRIMET).
  20. Luo, W., Zhao, Q., (2025). Blood diseases image classification with machine learning. 2025 IEEE 8<sup>th</sup> International Conference on Mechatronics and Computer Technology Engineering (MCTE), 120-126.
  21. Madyavanhu, N., Kumar, V., (2024). Multi-resource balance Virtual Machine Consolidation Based on Extreme Learning Machine and Improved Grey Wolf Optimizer. 2024 6<sup>th</sup> International Conference on Computational Intelligence and Communication Technologies (CCICT), 183-192.
  22. Majid P. (2026). Machine learning regression model on FPG. Fundamentals of VHDL for FPGA Programming Using Vivado.
  23. Mirjalili, S., Mirjalili, S.M., Lewis, A., (2014). Grey wolf optimizer. Advances in Engineering Software, 69 46-61.
  24. OXXO (2026). Media Pipe 手勢辨識 <https://steam.oxxostudio.tw/category/python/ai/ai-mediapipe-2023-hand.html> .
  25. Ramachandran, S., Jayalal, M.L., Vasudevan, M., Das, S., Jehadeesan, R., (2024). Combining Machine Learning techniques and Genetic Algorithm for predicting run times of High Performance Computing jobs. Applied Soft Computing, 165.
  26. Rom, A.R.M., Ibrahim S., Fadzil A.F.A., Mangshor, N.N.A., Ghani, N.A.M., (2025). A Review of Hyperparameter Tuning Methods in Machine Learning. 2025 6<sup>th</sup> International Conference on Artificial Intelligence and Data Sciences (AiDAS).
  27. Sailellah, H.R.P., Santoso, G., Setyorini, (2025). Estimating round-trip using machine learning models: A comparative study of SVM, GAM, and linear regression. 2025 IEEE 9<sup>th</sup> International Conference on Software Engineering & Computer Systems (ICSECS), 553-558.
  28. Salman, H.A., Kalakech, A., Steiti, A., (2024).

- Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning*, 69-79.
29. Shereen, M.K., Liu, X., Wu, X., Naseem A., Uzair, M., (2025). Machine learning-based prediction of antenna gain and S11 using regression models: A case study on Y-shaped microstrip patch antenna design. 2025 IEEE International Conference on Recent Advances in Systems Science and Engineering (RASSE).
  30. Shorten, C., Khoshgoftaar, T.M., (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6 1-48.
  31. Shreyas, S., Brahmam M.G., Nayak, R., Vilay, A.R., Joshi, M.M., (2025). A case study on nifty 50 using genetic algorithm-based hyperparameter optimization for stock price prediction. 2025 IEEE Silchar Subsection Conference (SILCON).
  32. Sushil B., Sharma I., Sunaina M., Rohit, M., Kaur, H., (2025). Predicting stock price using linear regression: A machine learning approach. 2025 IEEE 5<sup>th</sup> International Conference on ICT in Business Industry & Government (ICTBIG).
  33. Xiao, J., Zou, G., Xie, J., Qiao, L., Huang, B., (2018). Identification of shaft orbit based on the grey wolf optimizer and extreme learning machine. 2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC 2018), 1147-1150.
  34. Yang, L., Shami, A., (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415 295-316.
  35. Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J., Shen, F., (2022). Image data augmentation for deep learning: A survey. *Computer Vision and Pattern Recognition*.
  36. Young H.P. (2009). Learning by trial and error. *Games and economic behavior*, 65 626-643.
  37. Yuan, X., Pu, L., Jiao, L., Wang, X., Yang, M., Xu, J., (2023). When computing power network meets distributed machine learning: An efficient federated split learning framework. 2023 IEEE/ACM 31<sup>st</sup> International Symposium on Quality of Service (IWQoS).
  38. Zhao, J., Fan, J., Wang, J., (2026). AVNPSO: Hyperparameter optimization of encoder-decoder networks for image segmentation. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 10 557-570.
  39. Zhao, Y., Zhang, W., Liu, X., (2024). Grid search with a weighted error function: Hyper-parameter optimization for financial time series forecasting. *Applied Soft Computing*, 154.
  40. 劉奕辰 (2024). 應用進化演算法於機器學習的超參數之研究，明志科技大學碩士論文。