

機器學習應用於微機電麥克風產品測試震動盤機台的性能提升

蔡健忠 陳仁杰

明新科技大學 光電系統工程系
新竹縣新豐鄉新興路 1 號 光電系統工程系

1 : cctsai@must.edu.tw

2 : ryan7299@gmail.com

摘要

目前微機電系統在半導體產業所占的地位已經愈來愈重要，這些產品在各項電子產品的終端應用上，佔有一席之地。因此，提高產出、降低生產成本就成為各家設計公司以及生產工廠進入微機電系統市場最重要的課題。本研究利用 5 百萬筆的原始測試數據進行比較與驗證分析，再透過機器學習(ML)中隨機森林法來調控測試機台參數並達到預期最佳 UPH(Units per hour)並藉由 streamlit 智慧介面同步顯示，優化生產機台參數的最佳設定值以及 UPH 的等級。結果顯示隨機森林演算法所預測的震動盤的圓震及直震的最佳震動頻率，可讓每小時產品測試數量(UPH)有效從約 86 顆提升至 111 顆。

關鍵字：數據科學，機器學習，微機電麥克風

Machine learning is applied to MEMS microphone products to test the performance improvement of the vibrating disk machine

Chien-Chung Tsai , Jen-Chieh Chen

Minghsin University of Science and Technology Department of Electro-Optical Engineering , Hsinchu , Taiwan

1 : cctsai@must.edu.tw

2 : ryan7299@gmail.com

Abstract

At present, the position of MEMS in the semiconductor industry has become more and more important, and these products have a place in the terminal applications of various electronic products. Therefore, increasing output and reducing production costs have become the most important issues for design companies and production plants to enter the MEMS market. This research uses 5 million original test data for comparison and verification analysis, and then uses the random forest method in machine learning (ML) to adjust the parameters of the test machine and achieve the expected best UPH (Units per hour) and rely on the wisdom of streamlit. The interface displays synchronously to optimize the best setting value of the production machine parameters and the level of UPH. The results show that the

optimal vibration frequency of the circular and direct vibrations of the vibration plate predicted by the random forest algorithm can effectively increase the number of product tests per hour (UPH) from about 86 to 111.

Keywords: Data science, machine learning, MEMS microphones

一、前言

近年來，由於微機電技術(MEMS, Micro-electro-mechanical Systems)的不斷進步，使得消費市場對於微機電的產品應用則越來越多。除了早期許多人在玩的 Wii 有內建 ADI 公司的加速度感應器外，也有許多噴墨印表機的噴墨頭，也是採用 MEMS 技術開發的案例。此外，安全氣囊感應器、汽車的胎壓計、TI 公司的 DMD 投影技術、MEMS 麥克風、GPS 的 MEMS 陀螺儀等，也都是 MEMS 技術在消費市場應用的範例。

自 2003 年 Motorola V 系列手機開始採用樓氏電子的 MEMS 麥克風後，創下驚人的暢銷紀錄，因此也奠定了 MEMS 麥克風的市場基礎。然而 MEMS 麥克風取代 ECM 麥克風的趨勢在近年來一直緩步成長，直到 2010 年 Apple 的 iPhone 4 採用微陣列式麥克風來達到降低背景噪音的功能、提供更佳的通話品質後，引發大多數智慧型手機紛紛跟進採用兩個或兩個以上 MEMS 麥克風的設計，此一風潮，並已逐步向 Feature Phone、平板電腦、以及筆記型電腦擴展。根據市場估計 2010 年 MEMS 麥克風佔整體麥克風市場出貨量的二成，2010 年的成長潛力占前年 MEMS 麥克風的 57.7%；主因基於 MEMS 麥克風優於 ECM 麥克風的各項優點：更優異的聲學特性，更小的尺寸，更高的環境適應力以及更穩定的產品品質...等，隨著 MEMS 麥克風的成本逐步降低，MEMS 麥克風的市佔率以及市場規模，皆將快速的大幅成長，廣泛的應用於各式的產品中[1]。

振動盤是應用在工業自動化領域的一種輔助送料裝置，通過振動可以將各種零部件有序的排列整齊，準確的輸送到下道工序。根據振動的動力來源可分為電磁式[2]與壓電式[3]兩種，提升振動盤的生產效率除了機構之外，另一個關鍵的部分則是震動的頻率。

隨著工業 4.0 的發展，人們在機械系統故障診斷的預防中，廣泛地研究了各種基於人工智能(AI)的異常診斷和預測技術。藉由數據科學的整理與統計，首先從數據分析的世界中，所有的領域基本上可以當作一個金字塔。從底部開始，因為數據科學需要大量的數據，所以我們需要用適當的方式來獲取並存儲數據，往上層看，金字塔中間部分是將搜集的數據加以分析。往金字塔頂端，當我們遇到更深入的問題無法用簡單的技術得

到答案時，將用機器學習與深度學習 (Deep learning) 來嘗試解決。我們將所有領域分層從下至上分別為：數據蒐集 (Data collection)、數據儲存 (Data storage)、資料分析 (Data analysis)、機器學習 (Machine learning)、與深度學習 (Deep learning)。每個領域在不同的產業中都有不同的重要性與用法，其中在數據分析 Data analysis 的領域更分為多個層次。首先，在最底層的是數據搜集 Data collection，他是所有分析與應用的基礎。數據分析其實是最被廣泛應用卻也是最模糊定義的領域，其中包含數據探索、可視化、商業報告、數據發現、分段、聚合和預測等。在不同的商業領域中也有不同的解釋與應用[4]。

機器學習這一名詞於 1959 年，由美國 IBM 專家，電腦遊戲和人工智能領域的先驅 Arthur Samuel 所提出(Samuel, 1959)[5]，1998 年再由 Ron Kohavi 定義機器學習一詞[6]。1990 年機器學習方法便的廣泛，如貝爾實驗室的何天琴(Tim Kam Ho) (1995)發表了一篇隨機決策森林(Random Decision Forests)的方法[7]及 1997 年 Hochreiter and Schmidhuber 發表長短期記憶(Long Short-Term Memory, LSTM)文獻[8]。

機器學習是人工智慧的一個分支。人工智慧在研究歷史有著一條從以「推理」為重點，再以「知識」為重點，再以「學習」為重點的自然、清晰的脈絡。顯然，機器學習是實現人工智慧的一個重要途徑，即以機器學習為目的解決人工智慧中的問題。近 30 多年機器學習已發展為一門多領域交叉學科，涉及統計學、概率論、凸分析、逼近論、計算複雜性理論等多門學科。機器學習理論主要是以分析和設計一些讓電腦可以自動「學習」的演算法。機器學習演算法是可以從資料中自動分析得到規律，再利用規律對未知資料進行預測的演算法。因為學習演算法中涉及大量的統計學理論，因此機器學習與推斷統計學聯絡尤為密切，也可稱為統計學習理論。演算法設計方面，機器學習理論關注則可實現的，行之有效的學習演算法。許多推論問題屬於無程式可循難度，所以部分的機器學習研究是先以開發容易處理的近似演算法。

機器學習可分為以下三類：監督式學習、非監督式學習及強化式學習，其監督式學習則為電腦從標籤化 (labeled) 的資訊中分析模式後做出預測的學習方式。標記過的資料就好比標準答案，電腦在學習的過程透過對比誤差，一邊修正去達到更精準的預測，這樣的方式讓監督式學習有準確率高的優點。[9]

監督式學習方式需要倚靠大量的事前人工作業，將所有可能的特質標記起來，這過程相當繁複。當範圍擴大、資訊量增加，會更難去對資料標記出所有特徵，所以在面對未知領域時，幾乎是完全無法運作。

常見的監督學習法技術有邏輯迴歸(Logistic Regression, LR)，K 最近鄰(K Nearest Neighbor, KNN)[10]，內核支援向量機(Kernel Supporting Vector Machine, k-SVM) [11]，單純貝氏(Naive Bayes)，決策樹(Decision Tree, DT)[12]以及隨機森林(Random Forester, RF)[13] 6 種演算法。

二、研究動機與方法

目前微機電系統在半導體產業所占的地位已經愈來愈重要，這些產品在各項電子產品的終端應用上，也佔有一席之地。因此，提高產出、降低生產成本就成為各家設計公司以及生產工廠進入微機電系統市場最重要的課題。但在驗證調整機台最佳化以及優化測試程式的過程所花費的時間與測試樣本的成本相當龐大。因此本研究利用數據科學在大量的資料中依數據科學的方法進行比較分析及驗證，並使用機器學習分類演算法[14]，預測並驗證機台最佳操作參數。因此，本研究嘗試透過 5KK 的原始資料，以數據科學及機器學習(ML)中六種具代表的分類演算法來預測 UPH 等級，藉此找出模型最佳演算法，以此方法達到縮短驗證時間，減少測試樣本數量，最終提高產能表現的結果。

本研究為提升產品測試產能，因此須將測試機台調整至最佳狀況。首先，將震動盤上光纖檢測機的設置數量進行分析，使機台達到最有效的篩選速率。接著嘗試利用數據科學與機器學習法找出圓震頻率及直震頻率的最佳參數，提升 MEMS 麥克風產品測試產能，如圖 1 所示。

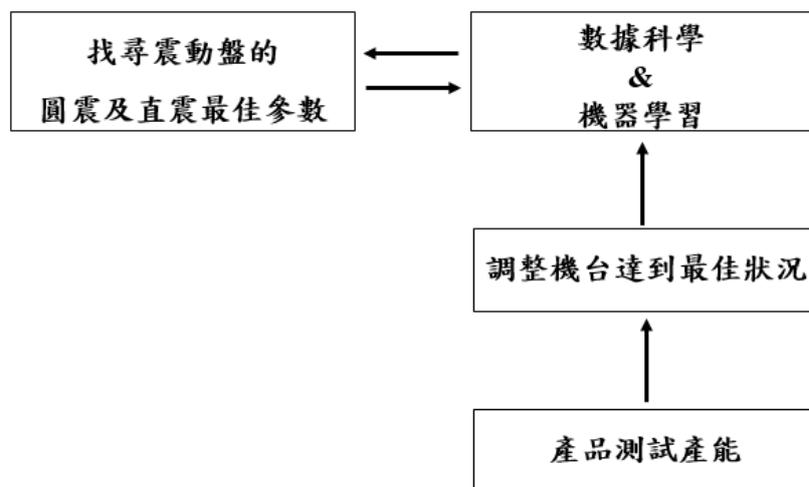


圖1. 系統流程

根據數據科學將原始 120 組數據中變異較大的資料刪除後，讓資料的合理性更高，接著為了讓資料有明顯的區分，需增加資料的數量，透過 Python 隨機產生亂數將資料量增加至 150 組。

另外再使用機器學習法，對此資料進行六種機器學習分類 (Machine learning classification) 法演算，分別是邏輯迴歸 (Logistic Regression, LR)，K 最近鄰 (K Nearest Neighbor, KNN)，內核支援向量機 (Kernel Supporting Vector Machine, k-SVM)，單純貝氏 (Naive Bayes)，決策樹 (Decision Tree, DT)，隨機森林 (Random Forester, RF)。由於機器學習的過程中，有大量的程式碼與數據訊息，在進行資料說明與呈現上往往不具可視化與易讀性，因此本研究藉 streamlit 將分析後的數據以可親性較高且更直觀介面呈現，將有助於研究數據的檢視與分析。

首先將圓震及直震頻率數據集輸入 streamlit 介面，利用 streamlit 平台將數據集傳至網際網路，接著利用數據科學與機器學習法，依實際數據中 UPH 等級 (分成四類) 執行模型演算，訓練數據集訓練模型，測試數據驗證模型。將驗證過的模型用於預測新數據會產生的 UPH 等級。新數據透過模型預測的 UPH 與機台實際之 UPH 再計算誤差，將此誤差傳回模型，修正模型參數以得到模型最佳參數設定，以此循環，模型可不斷學習，得到準確的 UPH 預測，進而確認機台最佳的圓震頻率及直震頻率，以獲得最高的 UPH，本研究流程如圖 2 所示。

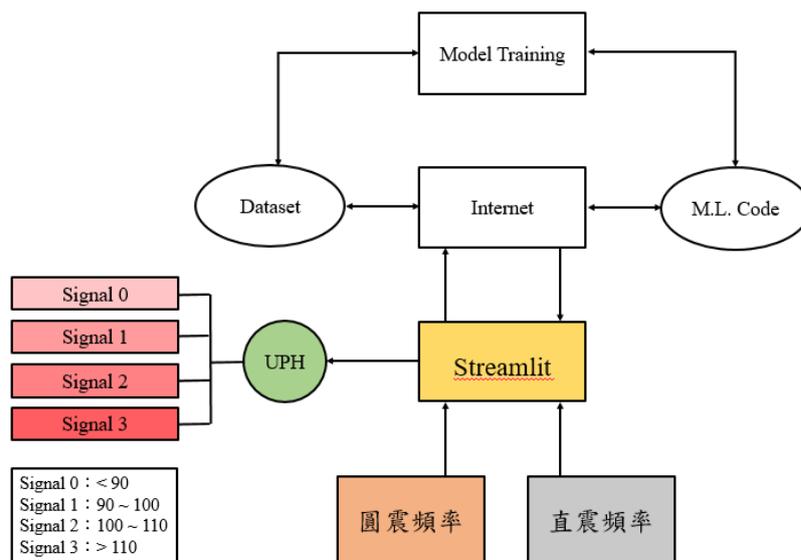


圖2. 研究流程圖

三、結果與討論

機台故障狀況（機況）常發生於旋轉異常及 IC 取/放異常，其最優先可先在震動盤上探討光纖感應器的數量，在震動盤上除了將 IC 運轉到測試區外，關鍵則是光纖檢測器，由於初期只設定一組，經常會將 IC 正反面不一致，導致 IC 在進入直震時則因為正反面產生的高低差導致 IC 在軌道卡到的情況。為了避免機況發生因此嘗試將檢測器由 1 組增加至 5 組，但因為篩檢過多，導致判斷過嚴如正面被誤判為反面，造成許多誤載也降低 UPH，不同光纖感應器的數量對應 UPH 結果，如表 1 所示。其中，在震動盤上設置 3 組檢測器，一組偵測 IC 是否有直立，另二組則是雙重判斷 IC 的正反面，如圖 3 所示，不僅可有效的降低機況問題且 UPH 可達到 111 顆。由此可知震動盤的頻率若能與光纖感測器的數量搭配得宜，不僅能避免機況發生以及篩檢過多的情況同時也提升 UPH。

表 1. 光纖檢測器組數之 UPH

光纖檢測器(組)	傳送時間(s)	辨識時間(s)	測試時間(s)	UPH
1	2	2	30	106
2	1.3	2	30	108
3	0.5	2	30	111
4	0.9	2	30	109
5	1	2	30	109



圖3. 震動盤上三組光纖檢測器實體圖

由 20K 筆的測試數據中，隨機抓取 20K、10K、5K 及 1K 筆測試數據中，比對調整

光纖檢測器的組數，與 IC 傳送時間的差異，如圖 4 所示，隨著光纖檢測器數量由 1 遞增至 3 組的過程中，檢測條件逐漸滿足該製程的運行，結果使得 IC 傳送時間由原本的 2 秒大幅減少了 75%，僅須 0.5 秒即可完成，但當光纖檢測器數量繼續增加的同時，檢測條件與程序也增加了，最後使得 IC 傳送時間不僅沒有減少反而增加了。

隨著測試樣本數的由 1K 遞增至 20K 筆，IC 傳送時間的整體變化趨勢均一致。除此之外，當光纖檢測器數量為 1 組時，IC 傳送時間隨著測試樣本數的遞增（由 1K 遞增至 10K 筆）僅微幅降低，但當測試樣本數達到 20K 筆時，IC 傳送時間不僅沒有降低反而是趨近於 1K 筆測試數結果，由此可知當測試樣本的變異性低則可降低樣本數。

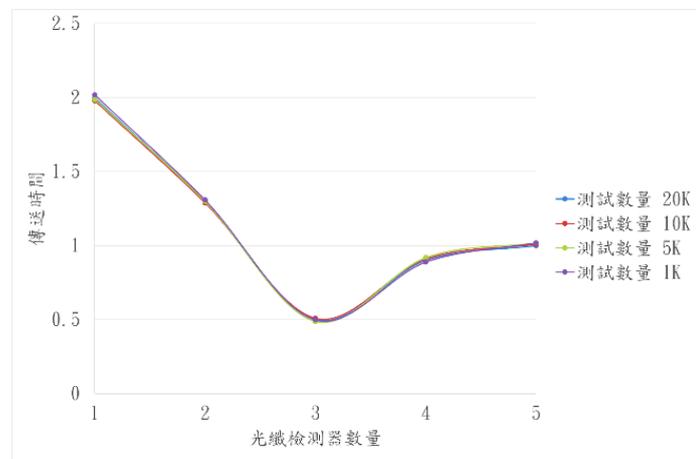


圖4. 光纖檢測器組數之對應的傳送時間

圖 4 主要說明二件事，一為測試數量 1K 至 20K 其傳送時間差異不大，只有小數點第三位的差異，不影響 UPH。再則是光纖檢測器數量可明顯地觀察到傳送時間的差異，從 0.5 秒至 2 秒的明顯差異。

從上述資料顯示，降低機況發生將能有效提升產能，本研究透過 5 百萬(5KK)筆的原始數據進行分析，發現機況對於產能有直接的影響，其中機台參數設定與產能有直接關聯性，而以直震與圓震的頻率為關鍵的參數設定，透過隨機森林的結果發現直震與圓震的頻率可以有效預測 UPH 等級，有助於未來機台設計上能有效提出最佳參數設定，預估產能情況，以下就研究結果依序詳細說明。

調整震動盤旋轉的速度，可將震動盤可分為圓震及直震二個部件，而震動盤的直徑愈大，旋轉的速度就愈慢，簡單來說因為 IC 需要繞的圈圈較大，經過驗證後直徑 25 公

分則最符合目前 IC 的尺寸。平震則是愈短愈快，但平震的長度則會受限於機構，因此最佳的長度為 23 公分。除了機構之外，另一個關鍵的部分則是震動的頻率。設定的太低則會震不動，設定的太高則會跳動太大反而影響 IC 的傳送因而降低產能，因此，找出最佳頻率可提升原有產能。

從 5KK 筆的原始測試數量中，機台的圓震頻率及直震頻率都依據廠商建議範圍內進行執行，設定值為圓震頻率 150 至 300Hz 以及直震頻率 130 至 280Hz 區間，在此設定範圍內隨機搭配的組合造成測試過程中機況頻頻發生。

本研究初始收集實際震動盤的圓振及直振頻率與相對應輸出的 UPH 值，共計 120 筆，建立一原始數據集。首先，將 UPH 分成四類，差：Poor (藍色, $UPH < 90$, 0)，普：Average (綠色, $90 < UPH < 100$, 1)，佳：Good (黃色, $100 < UPH < 110$, 2)，優：Excellent (紅色, $UPH > 110$, 3)，做為監督式機器學習法的標籤(Label)，圓振及直振頻率做為模型演算的特徵(features)。透過數據可視化，如圖 5 所示，四種等級 UPH 的數據點散亂分布，以混淆矩陣方法評估模型與數據集相關的參數，準確度(Accuracy)，精確度(Precision)與召回度(Recall)，其結果顯示均不足 0.35，如圖 6 所示，表示使用原始 120 筆數據，以習知最佳機器學習模型分類演算法-隨機森林法(Random Forester)，並無法進行有效的學習，因此依數據科學，刪除此特徵數據平均值正負 5%範圍之外的離異值(Outlier)後，取得原數據集中的 18 筆作為合適數據，其混淆矩陣方法評估模型與數據集相關的參數，準確度 0.875，精確度 0.689 與召回度 0.75，均大幅提升，如圖 7，8 所示。

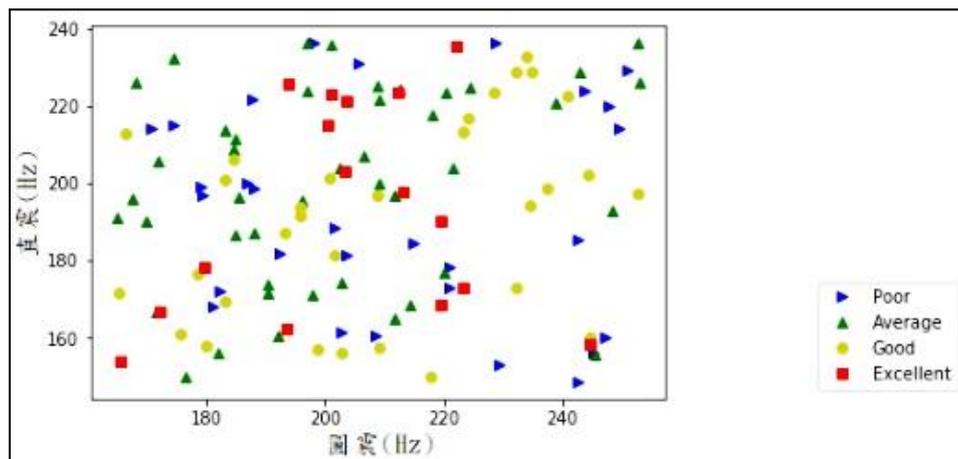


圖5. 120 筆可視化數據集

```
[[ 2  9  3  0]
 [ 1 10  0  3]
 [ 1  8  2  3]
 [ 1  4  0  1]]
Accuracy score: 0.3125
Precision score: 0.3163594470046083
Recall score: 0.2916666666666667
```

圖6. 120 筆準確度分析結果

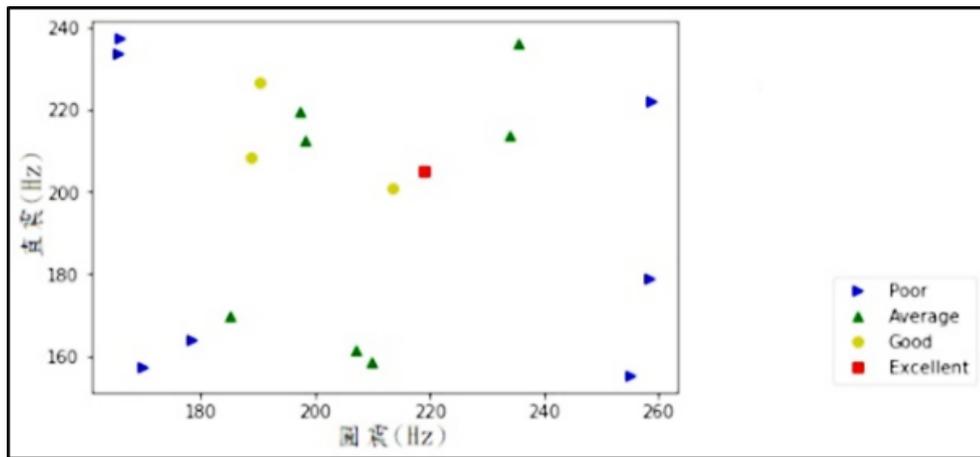


圖7. 18 筆可視化數據集

```
[[ 3  0  0  0]
 [ 0  3  0  0]
 [ 0  1  0  0]
 [ 0  0  0  1]]
Accuracy score: 0.875
Precision score: 0.6875
Recall score: 0.75
```

圖8. 18 筆準確度分析結果

經過數據清理，模型評估參數均有大幅度的提升，其中準確度已提升至 87.5%，但因為篩選過程大幅的縮減數據量使得數據樣本所涵蓋的範圍縮減，所以須採擴張數據集的方法，合理的增加樣本數。擴張數據集是依數據科學中統計學擴散數值的原理，就 18 筆合適數據，在直震與圓震頻率實際誤差範圍，透過 Python 程式隨機產生亂數的方式，增加直震與圓震頻率特徵數據 132 筆，以符合統計學擴散數值的概念。四種等級 UPH 的標籤數據同步產生 132 筆，整合原有的 18 筆，得到一擴張數據集共 150 筆，每筆資

料有特徵值 2 個，標籤值 1 個，總計數據量 450 個數值，數據分布可視化圖，如圖 9 所示。數據量依統計學擴張後，準確度提升到 0.926、精確度 0.95、召回度 0.95，如圖 10 所示。此時模型評量的各項數據均已高於 90% 以上，而召回度極為重要，召回度代表模型的可信度(可靠度)，表示本研究所提出的模型偽陰數據比例低，預測真陽的數據相對可靠度高，召回度提升到 0.95，意指沒有因為數據清理再重整的擴張而使可靠度降下來。顯示模型已可準確預測新特徵數據輸入後的 UPH 值，以此新特徵數據設定下，振動盤實際輸出的 UPH 做驗證，藉此可再調用模型參數，依上述步驟，再提升模型預測的準確度等指標，找到最佳 UPH 時的直震與圓震頻率值，以提升振動盤的 UPH 性能。

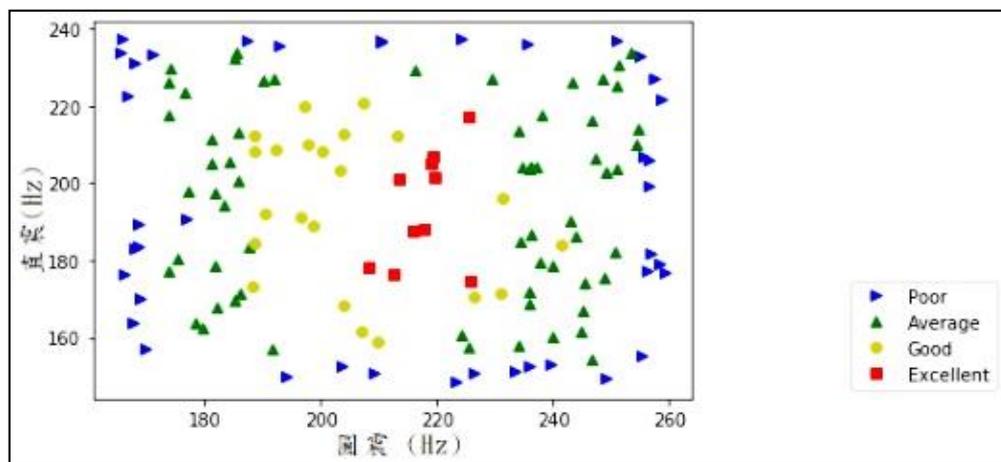


圖9. 150 筆可視化數據集

```
[[ 7  1  0  0]
 [ 1 13  0  0]
 [ 0  0  3  0]
 [ 0  0  0  2]]
Accuracy score: 0.9259259259259259
Precision score: 0.9508928571428572
Recall score: 0.9508928571428572
```

圖10. 150 筆準確度分析結果

藉由上述結果，未來可再利用 Streamlit 人機智能界面，透過調整圓震頻率及直震頻率方式快速取得預測的結果，如圖 11 所示。



圖 11. 150 筆準確度分析結果

研究中運用邏輯回歸(Logistic Regression) 等六種機器學習分類方法進行演算。利用機器學習中監督式學習(Supervised Learning) 的概念，將資料集隨機分為訓練、測試兩部分；如訓練部份占 85%，則測試部分 15%，其中訓練資料以 ML 分類法，做 UPH 等級分類的模型訓練，測試資料則用來檢測 UPH 等級分類的模型準確性。如表 2 所示，使用集成學習演算法中隨機森林法準確率最高，平均準確度(Mean Accuracy)可達 94.55%，標準偏差(Standard Deviation, SD)也以隨機森林演算法為 3.15%最佳，數據分析中以平均準確度表示各演算法評量的良窳，平均準確度為準確度、精確度以及召回度 3 個數值的平均值。

本研究數據集在利用隨機森林演算法時，發現樹的節點(n_estimators)=為 100，且測試部分(test size)為 15%時，平均準確度最高，如表 2 及圖 12 所示，其測試部分為 15%，也就是 100 筆裡面 15 筆來當測試，85 筆來當訓練得到的結果。

表 2. 機器學習六種分類演算法模型準確度比較表

	平均準確度(%)	標準偏差(%)
邏輯迴歸	49.17	6.83
K 最近鄰	64.11	10.90
內核支援向量機	49.17	6.83
單純貝氏	55.43	8.90
決策樹	88.34	3.93
隨機森林	94.55	3.15

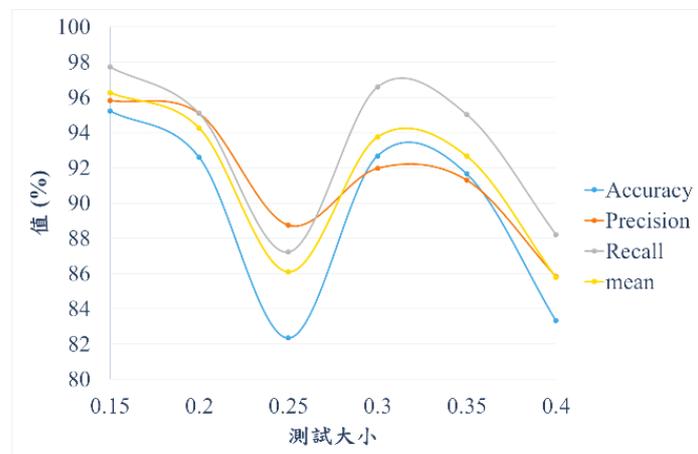


圖12. 測試大小模擬結果

依照預測結果，套至本研究的機台參數，得到實際的值。實驗中將直震頻率設定在 195Hz，圓震頻率由 145 至 255Hz 區間調整，如圖 13 所示，由圓震頻率在 210Hz 時，傳送速度為最短 0.5 秒，其換算 UPH 則為 111，將原本的 86，在同樣的測試時間、辨識時間之下，傳送時間不僅大幅減少，UPH 相對提升。當圓震頻率在最佳的參數時，傳送時間就可以縮短。

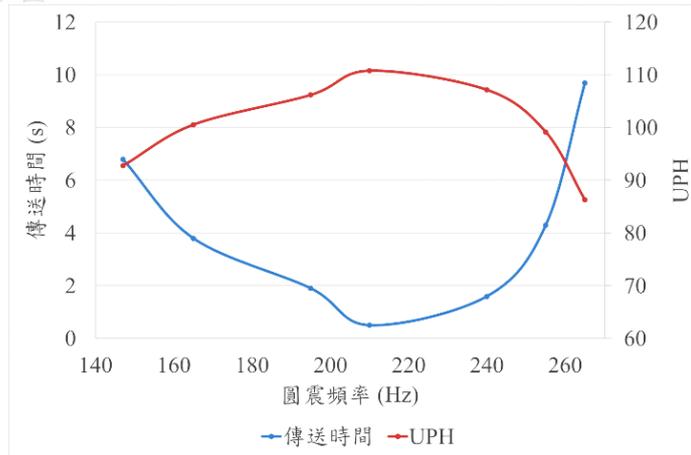


圖13. 圓震頻率與 UPH 對應圖

藉由上述，圓震頻率外，再進行直震頻率驗證，將圓震頻率設定在 210Hz，然而直震頻率設定在 145 至 265Hz，如圖 14 所示，當直震頻率在 195Hz 時，傳送速度為最短 0.5 秒，其 UPH 可達到 111，但圖 14 顯示，UPH 最慢為 93，依據這數據得知，圓震頻率相較於直震頻率更為影響 UPH。

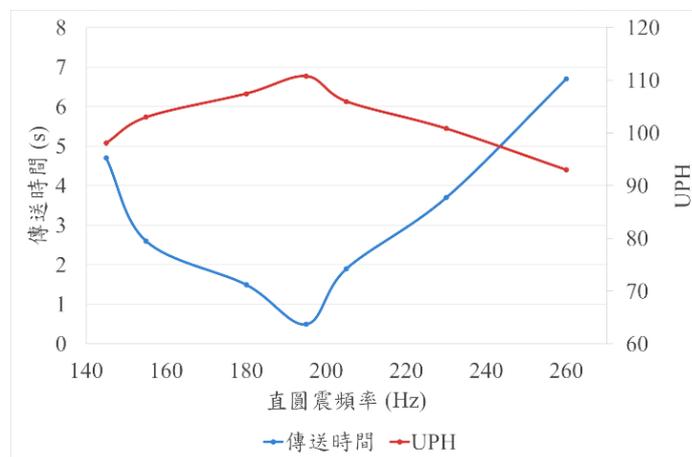


圖14. 直震頻率與 UPH 對應圖

因此數據科學分析後，實際實驗針對目前的震動盤圓震最佳的頻率為 210 ± 15 Hz，直震最佳的頻率為 195 ± 15 Hz，UPH 可達到 111 顆，為最佳產能。因此，我們發現隨機森林的演算法的準確度最高，標準偏差最低，採用此演算法，可預測最佳圓震與直震頻

率，提高 29% 的產能。同時，隨機森林的演算，可使用圓震與直震頻率來預測最佳產能，建立機台有效參數範圍，有效的掌握產能。因此利用此數據科學與機器學習的預測方式，未來在不同的機台上，可運用此方法進行預測。

四、結論

本研究嘗試透過數據科學的預測演算中找到最佳產能的預測範圍，從 5KK 的原始資料分析中，發現機況是造成產能低落的主因，其中圓震盤的頻率為最主要造成機況的因素，因此若要達到最佳產能，則必須找出最佳圓震與直震頻率的參數。研究結果發現，隨機森林最佳平均準確度的演算法，可預測最佳圓震與直震頻率，根據此參數進行設定，產生穩定的振動頻率降低機況的發生，可達到 29% 的產能提升。

此外，研究結果顯示調整測試流程也能夠大幅提升產能，但會有降低良率的風險，因此，採用隨機森林最佳平均準確度演算法可找到最佳圓震與直震頻率的最佳參數，圓震頻率 210Hz 及直震頻率 195Hz 的參數下，可讓每小時產品測試數量 (UPH) 有效從約 86 顆提升至 111 顆，達到有效降低機況並提升 29% 的 UPH。

致謝：

作者感謝詹智鈞先生一同參與文章內容的討論及修正

參考文獻：

1. 吳雅婷。(2020)。MEMS 麥克風供需持盈保泰 網紅應用利基顯形。CTIMES。
<http://www.hope.com.tw/DispArt-tw.asp?O=HK43VAG3EUWARASTDE>
2. Bespalov, A.、Svidrak, I. 和 Boiko, O. (2021)。通過電磁振動增加振動給料機的功能。LNU 獸醫和生物技術科學使者。系列：食品技術，23 (95)，33-37。
<https://doi.org/10.32718/nvlvet-f9506>
3. 李永傑。(2019)。縱扭式壓電振動盤及其激勵電路的研究。碩士論文，陝西師範大學。
4. 諾亞方舟。(2020)。什麼是數據科學？。
<https://noahsark.link/what-is-data-science/>
5. Samuel, A.L. (1959). "Some studies in machine learning using the game of checkers". IBM Journal of research and development, 3, 210-229.

6. Provost, F., & Kohavi, R. (1998). Guest editors' introduction; On applied research in machine learning. *Machine learning*, 30(2), 127-132.
7. Ho, Tin Kam (1995). "Random Decision Forest". Proc. of the 3rd Int'l Conf. on Document Analysis and Recognition, Montreal, Canada, 278-282
8. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
9. Kohavi, R., & John, G. H. (1997). Wrappers for feature subset selection. *Artificial Intelligence*, 97(1-2), 273-324.
10. Huang, S., Chen, K., Liu, C., Liang, A., & Guan, H. (2009). A statistical-feature-based approach to internet traffic classification using machine learning. 2009 International Conference on Ultra Modern Telecommunications & Workshops. IEEE, 1-6.
11. Li, Z., Yuan, R., & Guan, X. (2007). Accurate classification of the internet traffic based on the svm method. 2007 IEEE International Conference on Communications. IEEE, 1373-1378.
12. Hu, L., & Zhang, L. (2012). Real-time internet traffic identification based on decision tree. In *World Automation Congress 2012*. IEEE, 1-3.
13. Lopez-Martin, M., Carro, B., Sanchez-Esguevillas, A., & Lloret, J. (2017). Network traffic classifier with convolutional and recurrent neural networks for Internet of Things. *IEEE Access*, 5, 18042-18050.
14. 羅文榮。植基於主路徑與集群探討機器學習知識領域之研究。國防大學碩士論文，民國一百一十年六月。