

南華大學科技學院資訊管理學系

碩士論文

Department of Information Management

College of Science and Technology

Nanhua University

Master Thesis

結合卷積神經網路與遞歸神經網路預測刀具健康度

Combining Convolutional Neural Network and  
Recurrent Neural Network to Predict Cutter Usage

鐘才淵

Tsai-Yuan Chung

指導教授：洪銘建 博士

Advisor: Ming-Chien Hung, Ph.D.

中華民國 110 年 12 月

December 2021

# 南華大學

科技學院資訊管理學系

碩士學位論文

結合卷積神經網路與遞歸神經網路預測刀具  
健康度

Combining convolutional neural network and recurrent neural network to  
predict cutter usage

研究生：鍾才燦

經考試合格特此證明

口試委員：翁富美

謝定功

洪銘建

指導教授：洪銘建

系主任(所長)：陳信良

口試日期：中華民國 110 年 12 月 25 日

# 著作財產權同意書

## 南華大學資訊管理學系碩士論文著作財產權同意書

立書人：  鏡才啊  之碩士畢業論文

中文題目：

結合卷積神經網路與遞歸神經網路預測刀具健康度

英文題目：

Combining convolutional neural network and recurrent neural network to predict cutter usage

指導教授：  洪銘建   博士

學生與指導老師就本篇論文內容及資料其著作財產權歸屬如下：

- 共同享有著作權
- 共同享有著作權，學生願「拋棄」著作財產權
- 學生獨自享有著作財產權

學 生：  鏡才啊   (請親自簽名)

指導老師：  洪銘建   (請親自簽名)

中華民國 111 年 01 月 12 月

## 致謝

經過這兩年的研究，碩士生涯已接近尾聲，還記得當初在抉擇繼續研讀與就業的人生十字路口的情景至今仍近在眼前。在學校學習和生活期間，我不僅學習了專業知識，也學會了人與人之間的溝通。首先感謝資管系各位師長和同學，陳信良主任的引薦下，讓我進入了資管系碩士班，碩士期間在各位授課老師以及指導教授洪銘建教授的指導中，使我對於研究有更深一步的了解，且在各位老師嚴謹的教學中與堅如磐石的專業知識，都是促成我學習的動力。藉此引發我自學的能力，學習如何撰寫程式和培養邏輯訓練，再來也要感謝碩士班的邱宏彬及陳宗義導師，謝謝您們對於碩士班學生的關心，每學期的都會安排活動讓大家在繁忙中利用課餘聯繫感情。

感謝我實習的個案公司歐權科技，在我碩士期間因指導教授安排下，機緣巧合至台中實習，在實習的過程讓我學習到在學界無法接觸到的課題，從中了解公司業務與未來發展，公司也對我研究項目進行技術指導，在研究過程中給予了我明確目標、資料收集、數據整理以及數據預測演算...等皆全程的悉心指導和幫助，讓我能順利完成研究。

最後感謝家人的辛勤養育與栽培，在就讀碩士時全力支持著我，讓我無後顧之憂，並無時無刻給予鼓勵跟關懷，造就我完成論文最大的動力。

# 結合卷積神經網路與遞歸神經網路預測刀具健康度

學生：鐘才淵

指導教授：洪銘建博士

南華大學 資訊管理學系碩士班

## 摘要

工業 4.0 旨在推動智慧化與自動化等概念，並導入物聯網、人工智慧、大數據等現代相關資訊技術，為此台灣政府也積極對於傳統產業進行輔導與轉型工作，現今台灣傳統產業人才斷層嚴重，關於精密零件產品品值以往皆由資深師傅判斷，且判斷依據不一，新一代技術人員無法得知加工刀具之磨耗狀況，導致產出產品精度不合格之不良品；因此為了提升傳產數位能量，經由數據導入智慧化與自動化是不可或缺的關鍵。

本研究將以個案公司-歐權科技為例，改善其成品良率不佳、製造現場回饋能力不足等問題，藉由個案公司刀具視覺檢測儀進行數據收集與判斷刀具磨耗程度，因此本研究將利用個案公司所提供之刀具視覺檢測儀來量測刀具磨耗與使用情形，並記錄刀具於加工機加工完後之刀長、刀徑等數據，而為了能夠預測刀具的使用壽命、刀具健康度，因此本研究特地鎖定於同一種加工料件材質—「轉塔」上使用三種加工刀具進行加工時的各種量測數據進行分析，即可透過數位化方式跳脫以往由加工機操作員以目視、觸摸方式進行判斷換刀依據。

本研究使用長短期記憶神經網路(Long Short-Term Memory ,LSTM)作為迴歸分析(Regression Analysis)模型來預測未來的刀長、刀徑變化，將歷史數據輸入至神經網路模型後，學習出刀長、刀徑隨著使用時間而磨耗的變化曲線，對接下來的刀長、刀徑進行預測，當預測長度低於設立的門檻值時，便可知道此把刀具將會於下一次使用中到達使用壽命。

關鍵詞：刀具健康度預測、卷積神經網路、遞歸神經網路

Combining convolutional neural network and recurrent neural network to predict  
cutter usage

Student: Chung Tsai-Yuan

Supervisor: Dr. Hong Mingjian

Department of Information Management

Nanhua University

Master Thesis

## ABSTRACT

Industry 4.0 aims to promote concepts such as intelligence and automation and introduce modern related information technologies such as the Internet of Things, artificial intelligence, and big data. For this reason, the Taiwanese government is also actively counseling and transforming traditional industries. Nowadays, there is a severe gap in talents in conventional industries in Taiwan. Regarding the product value of precision parts, the product value has been judged by senior masters in the past, and the judgment basis is different. The new generation of technicians cannot know the wear condition of the processing tools, resulting in the production of defective products with unqualified product accuracy; therefore, to transfer the production and improve the number Energy, intelligence and automation through data import is the indispensable key.

This study will take the case company-AutoCam Technology as an example to assist the case company in improving the problem of poorly finished product yield and insufficient feedback capabilities at the manufacturing site. The case company's tool visual inspection instrument collects data and determines the degree of tool wear. Therefore, This research will use the tool visual inspection instrument provided by the

case company to measure the tool wear and usage, and record the tool length and diameter after the tool is processed on the processing machine, in order to be able to predict the tool life, tool Health, therefore, this research is specifically focused on the same processing material material-the analysis of various measurement data when using three processing tools on the turret can be digitalized to escape the previous visual inspection by the processing machine operator, Touch the way to judge the basis of tool change.

This study uses LSTM as a regression analysis model to predict future tool length and diameter changes. After inputting historical data into the neural network model, we learn the change curve of tool length and tool diameter wear over time., Predict the next tool length and tool diameter. When the predicted length is lower than the established threshold, you can know that this tool will reach its service life in the next use.

Keywords: Cutter Usage Prediction, Convolutional Neural Network, Recurrent Neural Network

# 目錄

著作財產權同意書.....	I
致謝 .....	II
摘 要 .....	III
ABSTRACT .....	IV
目錄 .....	VI
圖目錄.....	VIII
表目錄.....	X
第一章、緒論.....	1
第一節、研究背景.....	1
第二節、研究動機.....	3
第三節、研究目的.....	4
第四節、研究限制.....	4
第五節、論文架構.....	5
第二章 文獻探討.....	6
第一節、刀具磨耗探討.....	6
第二節、相關刀具檢測探討.....	9
第三節、人工智慧探討.....	13
第四節、遞歸神經網路探討.....	17
第五節、長短期記憶神經網路探討.....	19

第六節、卷積神經網路.....	22
第七節、長短期記憶架構之卷積遞歸神經網路.....	24
第三章 研究方法.....	27
第一節、研究概述.....	27
第二節、目標選定與數據收集.....	29
第三節、資料預處理.....	35
第四節、資料分析.....	37
第五節、刀具數據模型訓練.....	44
第六節、模型特徵分析.....	49
第七節、回歸模型評估方式.....	52
第四章 研究結果.....	54
第五章 結論.....	60
參考文獻.....	62
英文文獻.....	62
中文文獻.....	64

## 圖目錄

圖 1 2018 年全球排名前 15 大主要生產工具機國家.....	1
圖 2 刀具磨耗型態示意圖 .....	6
圖 3 加工產生摩擦、高溫示意圖 .....	7
圖 4 視覺影像量測示意圖 .....	11
圖 5 刀具視覺檢測儀示意圖 .....	12
圖 6 人工智慧發展史.....	15
圖 7 基本的神經網路模型圖 .....	17
圖 8 遞歸神經網路模型架構圖 .....	17
圖 9 長短期記憶構造示意圖 .....	19
圖 10 影像之卷積神經網路示意圖 .....	22
圖 11 最大池化運作示意圖 .....	23
圖 12 CONV-LSTM 架構圖 .....	24
圖 13 研究架構圖 .....	28
圖 14 加工料件(轉塔)示意圖.....	29
圖 15 加工刀具示意圖 .....	30
圖 16 刀具量測儀示意圖 .....	31
圖 17 平面銑刀刀具影像差異圖 .....	31
圖 18 刀長的量測範圍 .....	33
圖 19 刀徑的量測範圍 .....	33
圖 20 刀具量測數據搜集 .....	34
圖 21 箱形圖示意圖 .....	37
圖 22 平面銑刀刀具量測儀量測原始資料 .....	38
圖 23 平面銑刀刀具健康度.....	38
圖 24 平面銑刀刀長與刀徑磨耗箱型圖 .....	39

圖 25 銑刀刀具量測儀量測原始資料 .....	40
圖 26 銑刀刀具健康度 .....	40
圖 27 銑刀刀長與刀徑磨耗箱型圖 .....	41
圖 28 精搪刀刀具量測儀量測原始資料 .....	42
圖 29 精搪刀健康度 .....	42
圖 30 精搪刀刀長與刀徑磨耗箱型圖 .....	43
圖 31 重塑輸入資料以符合卷積核 .....	44
圖 32 平面銑刀磨耗面積計算 .....	45
圖 33 銑刀磨耗面積計算 .....	46
圖 34 精搪刀磨耗面積計算 .....	46
圖 35 平面銑刀模型特徵重要度 .....	50
圖 36 鎢鋼銑刀模型特徵重要度 .....	50
圖 37 精搪刀模型特徵重要度 .....	51
圖 38 神經網路架構圖 .....	56
圖 39 平面銑刀訓練 LOSS 圖 .....	57
圖 40 銑刀訓練 LOSS 圖 .....	58
圖 41 精搪刀訓練 LOSS 圖 .....	58
圖 42 平面銑刀健康度與可加工次數預測結果 .....	59
圖 43 銑刀健康度與可加工次數預測結果 .....	59
圖 44 精搪刀健康度與可加工次數預測結果 .....	59

## 表目錄

表 1 人工智慧的發展 .....	14
表 2 原始數據欄位介紹 .....	32
表 3 刀具影像量測 .....	35
表 4 異常值數據 .....	36
表 5 缺失值數據 .....	36
表 6 預處理後數據 .....	36
表 7 平面銑刀刀具量測儀影像分類混淆矩陣 .....	47
表 8 銑刀刀具量測儀影像分類混淆矩陣 .....	47
表 9 精搪刀刀具量測儀影像分類混淆矩陣 .....	47
表 10 數據欄位介紹 .....	48
表 11 回歸進行評估方式 .....	52
表 12 三把刀具的 RMSE 結果計算.....	57
表 13 刀具使用次數預測結果 .....	57

# 第一章、緒論

## 第一節、研究背景

工業 4.0 起源於德國，最早是在 2011 年的漢諾威工業展(Hannover Messe)提出，根據在 2019 年的德國漢諾威工業展中，各廠商雖然不再以「Industry 4.0 Ready」做為吸引參展群眾目光的標語(張惟翔，2021)，因應全球數位化、物聯網時代，且競爭激烈，對於工具機產業也不例外，近年來因原物料成本上漲、整體經濟成長趨緩等因素，導致台灣許多企業、人才開始外移(李秀員，2020)，令台灣傳統產業紛紛倒閉迫使將工廠遷移至國外。

Gardner Publication, Inc. 2018 年全球工具機產業調查結果顯示 2018 年全球工具機產值約為 946 億 USD，相較 2017 年則是成長 4.6%，而工具機產值排名前 15 大市場的生產金額加總，佔整體工具機生產市場比高達 93%，台灣在全球工具機產值排名第七，但 2018 年下半年因受到美中貿易大戰及全球經貿多變和不穩定情況下，亞洲經濟受到不小衝擊，以中國大陸為主要機械出口國產值明顯衰退，因此機械新產品研發方向如自動化、客製化、智慧化已成為必備條件，使廠商具有接急單和短單的快速應對市場的能力。

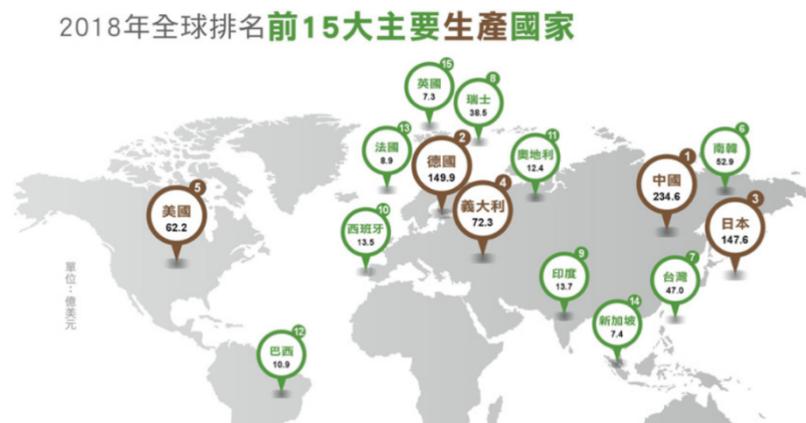


圖 1 2018 年全球排名前 15 大主要生產工具機國家

圖片來源：Inc.,TMBA,2019

根據德國政府率先提出工業 4.0 概念推動智慧化、自動化等概念，導入物聯網(Internet of Things, IoT)、人工智慧(Artificial Intelligence, AI)、大數據(Big Data)等現代相關新資訊技術(游曉珊，2017)，為此，台灣政府也積極對於傳統產業進行輔導與轉型工作，設法解決現今傳產人力成本過高與缺工等問題(郭晉源、吳慧娜，2013)，並將產品的關鍵成功因素具體分析；現今台灣傳統產業人才斷層嚴重，關於精密零件產品品值以往皆由資深師傅判斷，且判斷依據不一，新一代技術人員無法得知加工刀具之磨耗狀況，導致產出產品精度不合格之不良品；因此為了提升傳產數位能量，經由數據導入智慧化與自動化是不可或缺的關鍵。

現今社會技術進步，對於製造業要求越來越高，因此客戶需求也越發提高，對於產品交期、產量、品質的要求也跟著提升。為此，製造業者當前的必須以更高效管理、減少依賴人工；而這兩年受新冠肺炎疫情影響，加上這幾年客戶型態亦出現改變，從原先大批量下單演變成少量多樣，在這日益競爭的環境之下，許多企業開始進行數位轉型，試圖透過轉型策略與組織變革來提升整體企業能力(陳奕廷，2021)，本研究將以歐權科技為例，協助個案公司進行改善成品良率不穩定、製造現場回饋能力不足等問題，因此本研究將對個案公司重點產品-四五軸分度盤之關鍵零組件「轉塔」進行加工數據搜集分析，在藉由刀具視覺檢測儀判斷刀具磨耗程度，最後再以人工智慧之深度學習方式達成加工刀具數據壽命預測之目的。

## 第二節、研究動機

近年來，研究者以切削時的順暢程度為基礎，藉由感應主軸阻抗的波動，及刀尖振動頻率的異常，來定義不良切削的發生，並依嚴重程度發出警示、中止加工、或更換刀具(陳建立，2012)，而這類作法個案公司皆有執行，從主軸電流類比訊號分析、振動值進行傅立葉轉換分析等，雖然作法精確，發生異常時雖然能即時停機，但不良之加工皆已發生，再採任何措施都已是亡羊補牢。以往的檢測方法為等到機台發出明顯的振動或噪音時，才將機台停機進行加工品質檢查，但是此種方法通常發現得太晚(魏新偉，2021)，若能在料件加工前指派刀具時確定刀片狀態，將可避免撞刀、停機、及重工等狀態出現。

在判斷刀具壽命、刀具健康度傳統方式皆以手感觸摸、眼睛目視等方法來判定加工刀具可用程度，如此一來也造就了每位機台操作者判定方式不盡相同，且將產生資訊不對稱，為了提高加工效率，生產線必須減少機台停機的次數來增加機台稼動率，而在加工過程中刀具的損壞，機台會因此停機或是產生故障等問題，往往會導致工件良率降低甚至報銷，對加工成本的增加，有相當程度的影響(賴陽，2020)；能夠正確掌握刀具壽命，不僅能讓操作者知道刀具剩餘壽命，更可為換刀事先做準備，也可保持產品良率，近而達到降低等待浪費，讓刀具使用率最大化(梁榮濱，2006)。為此，本研究將進行個案公司廠內關鍵零組件所使用之加工刀具進行刀具使用壽命預測研究。

在精密加工中，選擇合理的刀具是需根據加工料件要求、技術要求、設備條件等因素，本次主要加工料件為分度盤<sup>2</sup>中關鍵零組件—「轉塔」，而加工時長約一小時，並有八種刀進行料件加工，因此本研究因基於平面銑刀、銑刀、精搪刀為轉塔關鍵刀具加工製成，故選訂其三把加工刀具作

為研究對象進行分析，並預測刀具於在正常使用下的磨耗程度，以利個案公司提升製造現場回饋能力，並增加成品良率、OEE 等效益。

### 第三節、研究目的

本研究將利用歐權科技所提供之刀具視覺檢測儀來量測刀具磨耗與使用情形，並記錄刀具於加工機加工完後之刀長、刀徑等數據，而為了能夠預測刀具的使用壽命、刀具健康度，因此本研究特地鎖定於同一種加工料件材質—轉塔<sup>2</sup>上使用三種加工刀具，並利用刀具視覺檢測儀進行量測加工時的各種數據再加以分析，即可透過數位化方式跳脫以往由加工機操作員以目視、觸摸方式進行換刀判斷依據。具體研究目標為進行刀具健康度模式建構。

### 第四節、研究限制

因本研究之研究刀具種類規格繁多，且使用刀具加工料件原理大致皆相同，故無法逐一分析，因此本研究以業界常用之三種刀具作為研究對象；並鎖定於同一種加工料件材質上進行加工時的各種量測數據，以利後續進行數據分析、預測刀具健康度，並訂定以下限制：

- I. 僅以加工轉塔之三把刀具—平面銑刀、銑刀、精搪刀作為數據搜集與分析依據。
- II. 僅假設刀具組裝與刀片品質皆為正常狀況下加工之數據搜集。

1. 分度盤:為加工中心重要零組件之一，適用於 CNC 機床、研磨機等，銑削料件皆需使用分度盤進行分度。

2. 轉塔：機床上用樞軸轉動的分度盤之關鍵零組件，可迅速轉到設定之工作位置。

## 第五節、論文架構

本論文分為六個章節，說明如下：

### I. 第一章為緒論：

本節將說明本論文之研究動機、文獻回顧、研究限制等，並說明本研究論文之整體架構。

### II. 第二章為文獻探討：

本節包含刀具磨耗之探討與刀具相關檢測探討；人工智慧與各類神經網路包含：卷積神經網路(Convolutional Neural Network, CNN)、遞歸神經網路(Recurrent Neural Networks, RNN)、長短期記憶神經網路(Long Short-Term Memory, LSTM)、卷積之長短期記憶神經網路 Convolutional LSTM, Conv-LSTM)等相關文獻探討。

### III. 第三章為研究方法：

本章介紹量測方式、刀具數據確認、整體研究流程與架構，並對刀具數據做分析，分別為平面銑刀、銑刀、精搪刀等原始數據分析，最後將對刀具數據進行 Conv-LSTM 網路模型建立。

### IV. 第四章為研究結果：

本節將呈現刀具數據預測結果。

## 第二章 文獻探討

### 第一節、刀具磨耗探討

#### 一、刀具壽命定義

依據 ISO 於 1993 年定義，刀具壽命是指刀腹之磨耗量到達 0.3mm 時之切削時間或最大磨耗量  $VB_{max}$  超過 0.6mm，則刀具使用已達刀具壽命(ISO, 1993)。工具機使用之刀具在整個切削過程中，是一極其重要的角色，所有金屬料件皆由刀具進行切削產生。Taylor 在 1906 年提出「 $VT_n=C$ 」公式，表示工具壽命切削速度的關係，除了切削速度會影響刀具壽命之外，通常切削角度和工件材料也會造成影響，過低的進給率會讓銑削加工效率降低且磨耗速率變快；過高的進給率則會有破壞刀具的風險 Zuperl(2006)；而刀具經過持續切削中，必定出現磨耗、崩刀、斷刀等情形(呂定憲, 2019)，需時常進行刀具補正或換刀，若更換刀具的時間早，將增加刀具成本；反之更換刀具過晚，將影響加工產品的精度，使得生產產品良率降低，而這些將耗費料件重工時間以及大量生產的成本(李慶鴻等人, 2019)。

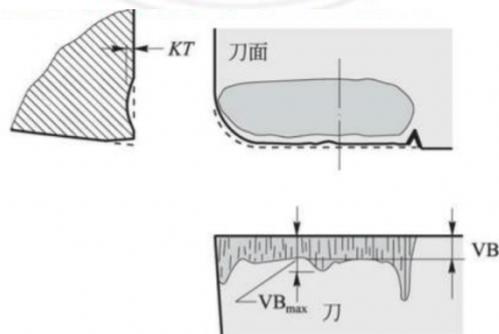


圖 2 刀具磨耗型態示意圖

圖片來源：<https://www.slideserve.com/avidan/ch05>

## 二、刀具磨耗探討

刀具出現磨耗情形是在切削時所產生熱以及與料件摩擦時產生的物理、化學作用的結果(碧威公司，2012)，刀具從初始進行加工到所經過的切削時間稱為刀具壽命，刀具壽命定義意指刀具損壞程度的某個預定值、某種現象的出現作為判斷依據，如：斷刀、崩刃等(藍天雄，2007)，在刀具切削過程中，刀具加工部位因與加工料件不斷受力所產生的高溫 and 摩擦造成磨損，等磨耗到一定程度刀具即無法進行原本加工作業，稱為刀具使用的總壽命。在實際生產過程中，通常現場會依照現有加工條件，將生產成本壓低或提高生產率等原則，因此影響刀具壽命因素種類繁多，其中可判斷影響主要因素為以下：刀具材料與料件之配合情形、切削厚度、切削速度、切削寬度(王宸威等人，2019)。



圖 3 加工產生摩擦、高溫示意圖

圖片來源：<https://kknews.cc/news/o2xo8xm.html>

刀具磨耗檢測一般可分為直接量測以及間接量測兩種；直接量測為利用視覺影像直接進行量測刀具的磨耗面積或深度..等數據資訊，這種方式取得的數據也最為直接準確，但實際加工環境中有油氣、粉塵等干擾且需先將機台停機才能進行量測，因此造成機台使用效率降低。而間接量測是利用各類感測器檢測，因刀具加工時轉速、進給率程度

皆不同，感測器輸出訊號就有差異，此方式可間接判斷刀具壽命，但準確度通常不高，以下為學者對於刀具磨耗相關研究之探討。

林昶甫(2021)在五軸機磨耗檢測系統研究中結合快速區域卷積類神經網路以進一步修正各軸向的誤差，精進後的五軸刀具檢測系統可進行多軸的位移，將定位誤差降至 0.05 mm，此研究根據不同磨耗面積以及利用定位 PIN 驗證，精確度可達 96%；劉旭晟(2020)在預測刀具剩餘使用壽命研究中採用決策樹作為分類的演算法並以回歸演算選用支援向量回歸機，研究中透過拍攝刀具影像之磨耗程度定義三種磨耗程度，分別為：初始加工(輕度)、正常加工(中度)、即將損壞(重度)，此研究證明了相同參數間的重要性，結果顯示：自我測試中有 94% 的分辨率，而在實際測試中單一切削參數的測試使用決策樹有 85% 的分辨率，而不同參數合併測試為使用主成份分析後最高分辨率為 88%，最後刀具剩餘使用壽命絕對誤差也低於 10% 以下；范遠哲(2019)在建構刀具磨耗量預測模型研究運用灰簡易模型、迴歸分析等方法做研究，將搜集到的機台加工參數匯入撰寫好的機台加工數據前處理程式中，在依整理好之數據，建構出三個刀具磨耗預測模型，再以平均絕對百分比誤差來比較預測之準確度，此研究結果表示以自迴歸分析建構的預測模型準確度最佳。根據這幾位學者對於刀具磨耗之研究，本研究將採取收集刀具數據方式並運用演算法對個案公司刀具進行刀具壽命預測。

## 第二節、相關刀具檢測探討

刀具檢測方式有許多，其中一種是使用機器學習去預測接下來訊號的趨勢，用來得知未來刀具磨耗狀態。另一種為控制，透過過去加工產生之數據(刀長、刀徑...等)，預測未來刀具磨耗狀態來調整加工參數，此兩種方法都可以用來檢測刀具磨耗 Zuperl(2006)。

### 一、電流鉤錶信號檢測

此運用是將 CNC 加工機上加裝電流鉤錶與電流擷取卡等感測器模組，撈取加工機主軸電流訊號，加以分析。Altintas(1992)以當主軸轉速作為研究數據，當轉速低於感測器頻寬時，電流即可反應切削狀態；陳翰霖(2021)在應用考慮刀具磨耗之學習控制技術於銑削加工研究中設計槽、端銑之間的進給率互相轉換之函數，利用該函數以及先前建立之學習控制參數，亦能利用進給率作為刀具磨耗監測指標，並且透過調整進給率將主軸電流維持於參考電流附近。此研究透過參數的控制，將電流維持於參考值附近，當進給率達下限時，刀具磨耗也可以維持於實驗設定範圍內，防止刀具過度磨耗；黃門(2016)在以電流及振動訊號監測微銑削刀具磨耗研究中利用特徵向量的方法分析振動的頻域訊號，將刀具磨耗的嚴重程度分成三個或兩個階段，觀察到電流隨著刀具磨耗的變化，並將主軸電流值進行迴歸分析處理進行刀具磨耗的預測，根據工件表面粗糙度的變化設立閾值，當主軸電流預測的磨耗達到設定的閾值時更換刀具，以此達到穩定表面精度的效果；Patra et al. (2007)在研究中表示，在切削條件(轉速、進給率)，在主軸電流的研究中對鑽頭磨損的影響，將訓練好的類神經網路於新的切削條件下進行測試，實驗結果發現與鑽頭磨損值吻合，說明了以電流感應器信號能有效的預測在廣泛的切削條件下刀具。

## 二、振動信號檢測

加速規原理是運用彈簧質量受到加速度的時候，當此彈簧受到的加速度對質量塊產生的施力與彈簧的拉伸力平衡時，質量塊與基座之的距離會因為加速度的大小而改變(簡日章，2010)。常用加速規種類有以具壓電效應之陶瓷材料所製成的電容式(Capacitive)加速規以及其感測雜訊、有效頻寬、線性度…等特性較佳的壓電式 (Piezoelectric)加速規兩種類型，適用於精密振動量測(鄭志鈞等人，2019)，以下為學者對於振動檢測相關研究之探討。

Gomes(2021)利用加速規以及麥克風擷取銑削振動以及聲音訊號做研究，並取頻率相關特徵以及統計數值當特徵值，這些特徵在進行標準化後數值落在 0 ~ 1 之間，最後輸入 SVM 模型進行磨耗分類。黃琮舜(2021)嘗試在 CNC 加工機上安裝一套振動訊號收集系統，用來監測加工時刀具所產生的振動力，此研究運用方根法所抓取訊號之特徵值法進行判斷，並以傅立葉轉換與特徵值融合方法，採用機器學習來進行分析，平均準確率可達 85.4%與 94.16%左右；林錦宏(2021)在研究中擷取主軸的軸承振動值，透過機器學習的技術來做錯誤診斷，並使用卷積模糊類神經網路模型以及 5 種融合方法在主軸的軸承振動錯誤診斷，此研究將傳統的卷積層更改為兩層向量的卷積層，大幅降低了模型的參數量；Patange(2019)以振動訊號數據量測做研究，此研究運用統計數值當特徵值，最後利用演算法決策樹特徵選取後分別輸入決策樹、隨機森林、Logistic Model Tree Classifier 模型做訓練，研究結果顯示決策樹準確率 85%、隨機森林 88.2%、Logistic Model Tree Classifier 88.3%。

### 三、視覺影像檢測

視覺影像測量儀應用於檢測各種形狀複雜刀具的輪廓和表面形狀，是加工產業不可缺少的一種計量檢驗設備；其工作原理是將量測刀具放置於工作台上，由 LED 表面光或輪廓光照明後，經變焦距物鏡與彩色 CCD 攝影機攝取量測之影像如圖 4，經由工作台帶動光學尺在 X、Y 軸座標上進行移動來尋找刀具最大輪廓並生成刀具相關數據。以下為學者對於視覺影像量測相關研究之探討。

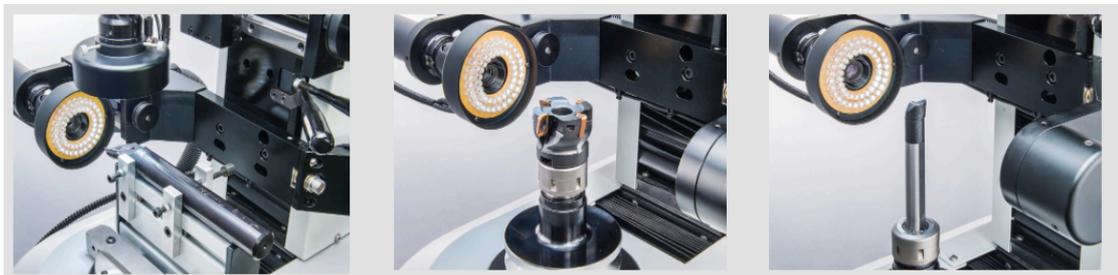


圖 4 視覺影像量測示意圖

圖片來源：[http://www.keejaan.com/c\\_kj-1000a.html](http://www.keejaan.com/c_kj-1000a.html)

洪裕富(2021)在工具機刀具視覺檢測系統研究與開發研究中將刀具檢測系統架設在老舊的機台內，進行刀具尺寸和刀具磨耗量測，在與電腦連接將數據進一步分析，並且通過磨耗補償實驗觀察系統在磨耗量測和工件補償上的情況，最後通過測量五種不同規格的刀具尺寸與德國 Zoller 機臺進行比較；許家愷(2016)在銑削刀具磨耗最佳檢測環境配置參數研究中結合田口品質工程的參數設計方法，配置自製光罩背景顏色與光條亮度範圍及間距之水準，並建構刀具磨耗檢測穩定性之最佳化環境配置參數，此研究以光罩機構進行銑削之刀具磨耗研究，經由互補性氧化金屬半導體(Complementary Metal-Oxide Semiconductor, CMOS)擷取影像後，利用影像處理技術找出磨耗特徵與缺陷區域，透過校正片進行單位轉換將 Pixel 轉換為 mm，即可得到磨損面積、長度、寬度之大小，並搭配測量顯微鏡量測進行比較分析；陳正和、黃彥翔

(2013)在研究加入模式匹配(Pattern Matching)原理，檢測設備及環境設計出一個具有高機動性與可用性的光罩機構，為了使分析磨耗更為精確，在分析中結合兩種不同的運算方法，大幅提高檢測磨耗的精準度；Jurkovic et al. (2005)利用機器視覺針對拋棄式刀片做研究，此研究以模擬方式實際架設檢驗系統，配合雷射對刀具進行檢驗，可得到刀具磨耗的範圍大小以及刀具磨耗深度，並依照量測結果判斷該刀具為前傾面磨耗或離隙面磨耗。

本次研究將使用此方式進行量測，運用個案公司檢測儀器「刀具視覺檢測儀」如下圖 5，量測加工刀具刀長、刀徑等數據，此儀器量測規格為行程：X軸-20~130 mm、Y軸60~400 mm，解析度0.001mm，影像倍率 50x，刀具視覺檢測儀特性如下：

- 系統自動擷取刀長刀徑、角度與圓弧以利數據收集
- 檢測儀固定倍率以及固定焦距
- 量測時搭配 LED 表面光可進行刀具表面與輪廓量測
- 可產生 CNC 碼與數控機床連線作刀具補正



圖 5 刀具視覺檢測儀示意圖

圖片來源：[http://www.kecjaan.com/c\\_kj-340a.html](http://www.kecjaan.com/c_kj-340a.html)

### 第三節、人工智慧探討

1956年 John McCarthy 提出人工智慧來描述機器模仿人類認知能力，而現今人工智慧技術發展迅速，各個領域都紛紛投入各種人工智慧相關技術，如：製造業、醫學、農業、等領域，而率先使用人工智慧技術就意味著採用先進的製造技術，例如人工智慧技術是一個新出現的行業趨勢，人工智慧技術代表了處理高維問題和資料的機會。

李開復、王詠剛(2017)表示，企業機構假設能夠熟練人工智慧操作數據分析的結果，並透過感知環境的變化做出行動，並解決各種問題，將可獲取最大效益。近年技術領域的進展反而更使人工智慧越發的難以定義，因人工智慧下各子分類技術過於不同，人工智慧目前仍多為特定演算法總稱(Gasser et al., 2017)。

以下為學者對於人工智慧研究之探討，許家豪(2020)在基於人工智慧邊緣運算之跌倒偵測方法實現研究中提出兩種人工智慧演算法，即基於人體姿態辨識之跌倒偵測技術(Pose-Estimation based Fall Detection Algorithm, PEFDA)、與基於人體外形辨識之跌倒偵測技術(Object Detection based Fall Detection Algorithm, ODFDA)，此研究提出的兩種跌倒偵測方法皆能成功辨識出老人跌倒之事件，且正確率高皆於 97%；何宣儀(2020)在應用人工智慧技術於圖書館紙本採購研究中建構基於集成學習 stacking 方法的精準採購模型，準確率達 78.2%，此研究也進行交叉驗證，而驗證結果組合模型 stacking 方法比單一學習更能有效預測適合採購的紙本書籍，以達到精準採購之預測。

表 1 人工智慧的發展

年代	事件
1940 年～ 1960 年代	電腦發明後科學家把重心擺在定理問題與通用問題求解；例如：西洋棋、西洋象棋、數字理論證明等研究。
1960 年～ 1970 年代	研究重心轉變成使電腦擁有理解能力，在此時期，人工智慧語言 LISP 被開發出來。
1970 年～ 1980 年代	利用述語邏輯(Predicate Logic)開發出來的 PROLOG 語言問世，針對特定問題領域所開發出專家系統。
1980 年～ 1990 年代	「此階段著重在研究各種行事之學習系統，如類比研究法、指點學習法等」，如：IBM 成功的讓計算機的並行處理能力提高，使得計算機的運算速度大幅提升。
21 世紀	人工智慧的發展方向轉變為大數據，IBM 的沃森系統掀起風潮，沃森的能力包括理解、推理和學習。

資料來源：楊鈞淋(2018)取自 <https://www.shs.edu.tw/works/essay/2018/03/2018032821594726.pdf>

## 一、人工智慧三次浪潮

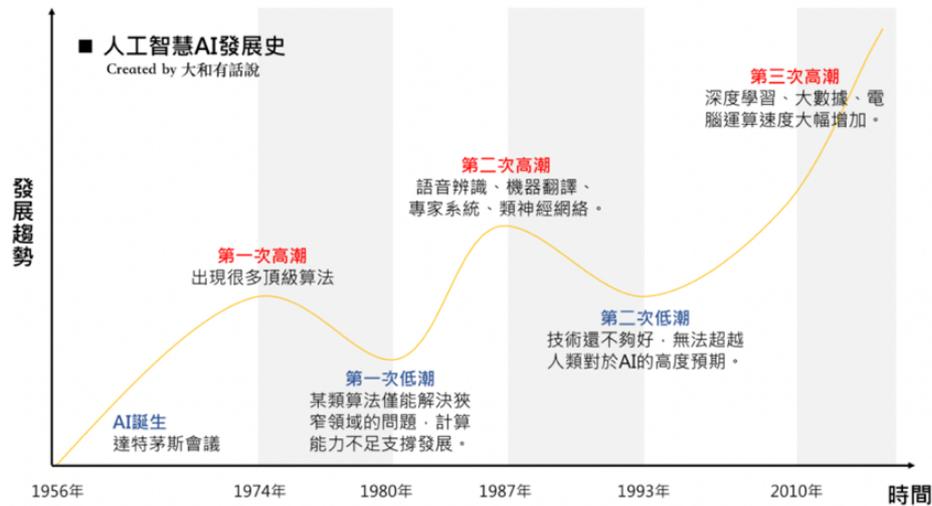


圖 6 人工智慧發展史

圖片來源：蕭佑和(2018)取自 <https://dahetalk.com/2018/04/08/>

- 1950~1960 年出現第一次高潮，由於此次出現是在網路之前，所以被稱為「古典人工智慧」，這時期所出現的符號主義(Symbolism)與聯結主義(Connectionism)分別是日後「專家系統」與「深度學習」的雛形。
- 1980 年代出現了第二次的高潮，人工智慧的熱潮隨著電腦的普及，這時期所進行的研究應用於語音辨識、機器翻譯、神經網路等，皆是以灌輸「專家知識」作為規則。
- 2010 年代出現了第三次熱潮，這時代有著高性能電腦、網際網路、大數據、感測器等物聯網技術的普及以及計算成本有的下降趨勢，就此引發應用於「機器學習」興起。

## 二、AI 人工智慧技術

- 遺傳演算法(Genetic Algorithm ; GA)

又稱為演化式演算法(Evolutionary Algorithm)，此演算法是由達爾文演化論所啟發的一種人工智慧。它透過達爾文「適者生存」的規則，將「優秀的個體」轉換成「好的答案」，並透過演化的方式用演算法來找出最佳解(Goldberg,1989)；林豈(2019)在銑削加工過程之表面粗糙度預測及加工參數最佳化之研究中也使用基因遺傳演算法與粒子群演算法獲得最佳化加工參數組合。

- 專家系統

專家系統(Expert System)是早期人工智慧的一個重要分支，可以看作為具有專業知識與經驗的系統，此系統一般採用人工智慧中的知識表示和知識推理技術來模擬，通常由領域專家才能解決的複雜問題。只不過，專家系統只能針對專家預先考慮過的狀況來準備對策，它並沒有自行學習的能力，因此還是有其侷限性。

- 類神經網路

從第三次人工智慧浪潮所興起的機器學習(Machine Learning)有許多種手法，其中最受矚目的，莫過於「深度學習」(Deep Learning)了。所謂深度學習，是透過模仿人腦的「類神經網路」(Neural Network)來學習大量資料的手法，類神經網路也擁有許多與人類大腦相同功能的特性，其中最重要的三項功能為:學習、回想與歸納推演。

#### 第四節、遞歸神經網路探討

遞歸神經網路又稱循環神經網路，其優點是可以將先前的預測結果考慮到目前的預測當中，林子鈞(2020)，因此 RNN 被廣泛運用在語音辨識、翻譯、預測字詞等領域，模型一般而言是將輸入  $x_i$  乘上權重  $w_{ih}$  再加上 bias  $\theta_g$ ，最後經過一活化函數(Activation Function)  $f$  而得到輸出  $y_o$ ，其網路架構於圖 7 所示。

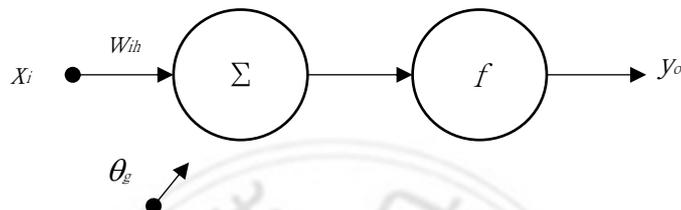


圖 7 基本的神經網路模型圖

為了使神經網路具有記憶的特性，因此設置了一種狀態  $z_t$ ，這種狀態其實是將上一次的輸出重新的傳遞回到輸入端，並且和此次的輸入訊號一起作為兩個輸入訊號的一種有向序列網路，使用狀態  $z_t$  在神經元上記錄訊息，使得這一刻的輸出與上一個時間點的輸出值產生關連，因此遞歸神經網路是具有記憶性的，其網路架構於下圖 8 所示。

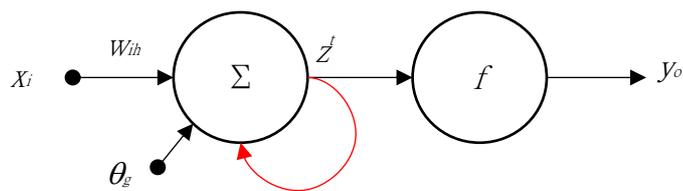


圖 8 遞歸神經網路模型架構圖

接著導入迭代時間  $t$ ，在時間  $t$  的輸入資料  $x_i^t$ ， $\theta_g$  為偏移量， $w_{ih}^t$  為在  $t$  時輸入與神經元之間的權重，神經元的輸出為  $z^t$ ，這一層的輸出  $y_o^t$ ，計算方式如下：

$$y_o^t = f(z^t) \quad (2.1)$$

$$z^t = \theta_g + x_i^t w_{ih}^t + z^{t-1} w_{zh} \quad (2.2)$$

遞歸神經網路的記憶特性使得在時間序列相依性的資料分析上獲得了嶄新的研究方式。但是，當輸入與輸出序列經過跨度很長的時間間隔時，過去的訊息將慢慢的被遺忘掉，此情況稱為長期依賴問題 (Olah,2015)。

以下為學者對於遞歸神經網路相關研究之探討，李承翰(2019)在具特徵選擇之獨立遞歸神經網路於軸承剩餘使用壽命預測研究中使用 IEEE 2012 PHM Data Challenge competition 競賽中所提供之公開資料集，並與當時的冠軍 Sutrisno et al. (2012)、Guo et al. (2017)、遞歸神經網路以及獨立遞歸神經網路共四種方法之結果進行比較，此研究證明以啟發式演算法為基礎的獨立遞歸神經網路可獲得較佳的預測結果；楊紫婕(2019)在應用遞歸神經網路於高頻資料之股價研究探討高頻股價資料結合遞歸神經網路是否能有更佳的預測效果，此研究以台灣 50ETF 為研究對象，運用股票日資料與高頻資料結合技術指標作為輸入的變數資料，此研究結果顯示：在模擬交易結果中得知運用高頻資料的獲利能力優於日資料。

## 第五節、長短期記憶神經網路探討

長短期記憶是遞歸神經網路的一種變體，由 Hochreiter and Schmidhuber 於 1997 年所提出，因其特殊設計而能夠解決遞歸神經網路長期依賴的問題。長短期記憶有三個特殊閘門設計，分別是：輸入門 (Input Gate)、忘記門 (Forget Gate)、輸出門 (Output Gate)，如圖 9 所示。其中可細分為：輸入模塊 (Block Input)、輸入門 (Input Gate)、忘記門 (Forget Gate)、細胞狀態 (Cell State)、輸出門 (Output Gate) 與輸出模塊 (Block Output) 公式如下所示：

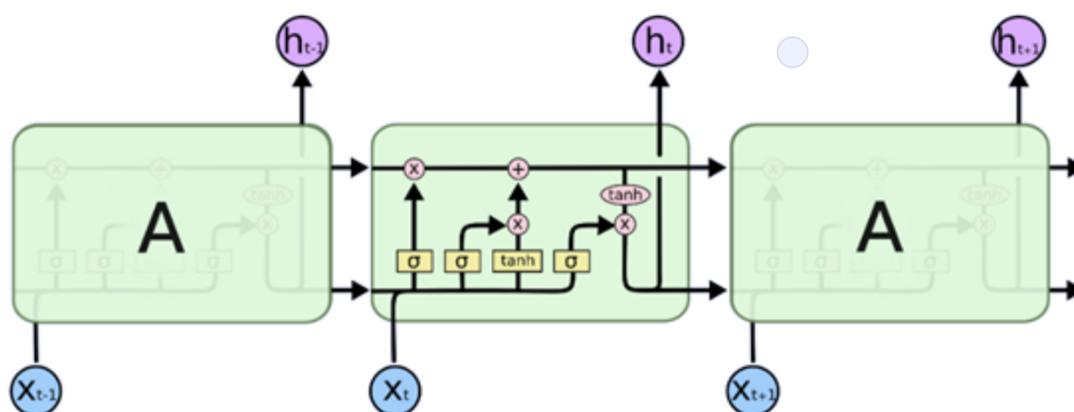


圖 9 長短期記憶構造示意圖

圖片來源：<https://codingnote.cc/zh-tw/p/8153/>

A. 輸入模塊(Block Input ,  $z^t$ )

$$\bar{z}^t = W_z x^t + R_z y^{t-1} + b_z \quad (2.3)$$

$$z^t = g(\bar{z}^t) \quad (2.4)$$

B. 輸入門(Input Gate ,  $i^t$ ) :

$$\bar{i}^t = W_i x^t + R_i y^{t-1} + b_i \quad (2.5)$$

$$i^t = \sigma(\bar{i}^t) \quad (2.6)$$

C. 忘記門(Forget Gate ,  $f^t$ ) :

$$\bar{f}^t = W_f x^t + R_f y^{t-1} + b_f \quad (2.7)$$

$$f^t = \sigma(\bar{f}^t) \quad (2.8)$$

D. 細胞狀態(Cell State ,  $c^t$ ) :

$$c^t = z^t \odot i^t + c^{t-1} \odot f^t \quad (2.9)$$

E. 輸出門(Output Gate ,  $o^t$ ) :

$$\bar{o}^t = W_o x^t + R_o y^{t-1} + b_o \quad (2.10)$$

$$o^t = \sigma(\bar{o}^t) \quad (2.11)$$

F. 輸出模塊(Block Output ,  $y^t$ )

$$y^t = h(c^t) \odot o^t \quad (2.12)$$

其中  $W_z, W_s, W_f, W_o \in \mathbb{R}^{N \times M}$  為輸入權重 ,  $R_z, R_s, R_f, R_o \in \mathbb{R}^{N \times M}$  為遞歸權重 ,  $b_z, b_s, b_f, b_o \in \mathbb{R}^N$  為偏移量。  $\sigma$ 、 $g$  與  $h$  為非線性函數 , 通常會設置為  $\sigma(x) = \left( \frac{1}{1+e^{-x}} \right)$  ,  $g(x) = h(x) = \tanh(x)$ 。  $\odot$  表示為兩個向量的逐點乘積 (Pointwise Multiplication)。

長短期記憶神經網路的核心思想就是細胞狀態(Cell state,  $c^t$ )管維凱(2020)，細胞狀態在長短期記憶神經網路的運作中只有少數的線性交互，如同公式(10)中， $c^t$ 的主要透過加法來更新細胞記憶(Cell Memory)，長短期記憶神經網路的三個閘門用來保護與控制細胞狀態；長短期記憶神經網路運算的第一步是決定會從細胞狀態中遺忘哪些訊息，透過忘記門(Forget Gate)來控制；第二步是決定細胞狀態要更新哪些資訊，透過輸入門(Input Gate)來控制；經由前兩步驟，細胞記憶(Cell Memory)已經確定要忘記與更新什麼樣的資訊，因此到第三步驟則是直接更新細胞狀態即可；最後需要決定輸出值，即是透過輸出門(Output gate)來控制。Fischer et al. (2018) 在研究中提到長短期記憶神經網路本身非常適用於股價趨勢，研究結果長短期記憶神經網路表現優於傳統分類器，長短期記憶神經網路架構已經被證實比傳統 RNN 網路的表現還要來的更好，在 2013 年，使用長短期記憶神經網路對 TIMIT 自然演講資料庫達到 17.7% 的錯誤率記錄 (Alex et al., 2013)。

以下為學者對於長短期記憶神經網路相關研究之探討，黃子峻(2018)使用倒傳遞類神經網路與長短期記憶網路針對主軸與滾珠螺桿的熱變位研究，此研究利用長短期記憶網路在應對不同工況的時候具有較強的適應性及穩定性，訓練時間也較少，因此可視場合來決定需要使用哪一種神經網路；馮子宸、黃華志(2021)進行三軸 CNC 銑床熱變形預估及量測研究中表示，長短期記憶神經網路架構除了用於進行切削實驗的數據有時序性的關係，另一個原因是因為長短期記憶神經網路跟其他神經網路架構相比可以有效的減少梯度消失及梯度爆炸的問題，在經過訓練後長短期記憶神經網路的預測準確值可以達到 83.33%。

## 第六節、卷積神經網路

卷積神經網路由 Yann et al. 在 1995 年提出，是一種主要透過卷積 (Convolution) 與池化 (Pooling) 操作，最後連結一個全連接層所建構的神經網路，如圖 10 所示。卷積神經網路對於特徵提取的效果突出，特別是影像識別相關科學，許多影像分類等模型架構都源自於卷積神經網路，最早被應用於圖像處理，藉由權重共享、空間關聯特性，卷積神經網路在視覺應用上取得了成功 (Alex et al., 2012)。

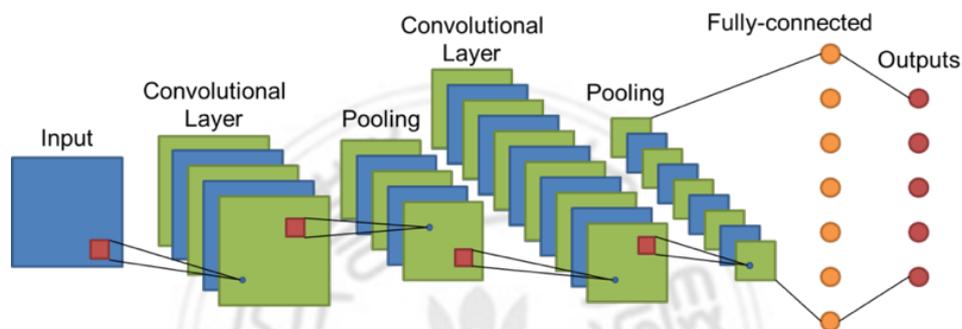


圖 10 影像之卷積神經網路示意圖

圖片來源：<https://chtseng.wordpress.com/2017/09/12/>

卷積 (Convolution) 是對兩個函數進行數學運算以產生第三個函數，其連續的定義如公式 (2.13) 所示：

$$(a * b)(x) = \int_{-\infty}^{\infty} a(\tau)b(x-\tau)d\tau \quad (2.13)$$

$a(x)$  與  $b(x)$  是歐幾里得空間 (Euclidean Space) 上兩個可積分的函數， $a(x)$  為原始輸入資料， $b(x)$  可稱做為卷積核 (Convolution Kernel)。在卷積神經網路的訓練過程中，會不斷的改變卷積核的數值以取得最佳的輸出結果。

池化 (Pooling) 為統計一個區域內某個特徵值的平均值或最大值，並將其輸出。若挑選最大值輸出則稱為最大池化 (Max-Pooling)，反之若挑選平均值輸出則稱為平均池化 (Average-Pooling)。池化的運算有助於降低特徵數量。如圖 11 所示，在輸入資料中挑選最大值輸出，稱為最大池化法。

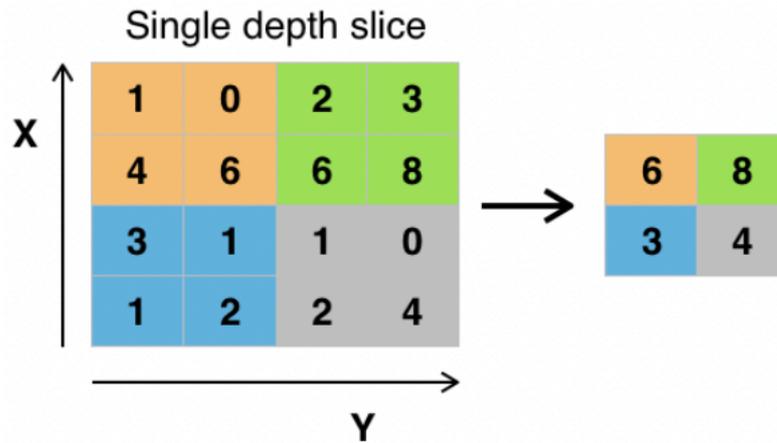


圖 11 最大池化運作示意圖

圖片來源：<https://zh.wikipedia.org/wiki/卷積神經網路>

以下為學者對於卷積神經網路相關研究之探討，蕭嘉榮(2020)利用卷積神經網路模型開發了一種用於草莓病害檢測的新技術，並採用 Resnet50 模型，針對 1,306 張圖像，以 20 個時期進行訓練，準確率達 99.6%。此研究所使用的方法對葉型葉枯萎病、冠型感染葉枯病與果實葉枯萎病有接近 100%之辨識率，灰黴病與白粉病辨識準確率達 98%；黃冠維(2018)在卷積神經網路預測市區道路路況研究中利用車輛偵測器資料轉換為二維時空矩陣，再將時空矩陣輸入卷積神經網路進行預測，此研究顯示預測模式在多數情境下有良好的預測結果，平均之 MAE 為 4.93、MAPE 為 15.5%；吳政德(2017)在利用卷積神經網路預測學習情緒之研究中以 FER2013 基本表情資料庫建立基本情緒辨識模型，在 FER2013 提供之測試資料集下的辨識準確率達 72.01%，其實驗結果分別在三秒、一秒、半秒擷取頻率下預測準確率可達 66%、81%、91%，最後藉由顯著圖技術視覺化出學習情緒之表情特徵對表情資料庫進行辨識，辨識準確率可達五成以上，證明此研究的學習情緒預測模型在不同的個體差異下仍具有一定的預測能力。

## 第七節、長短期記憶架構之卷積遞歸神經網路

透過回顧各類神經網路的相關研究，了解目前機器學習中近代主流的深度學習方法，並且了解卷積神經網路與長短期記憶神經網路演算法能夠各自捕捉空間與時間關係，本研究將進一步回顧兩者融合使用的 Conv-LSTM 演算法，能夠有效的捕捉真實世界中的時空關係，適合用來預測刀具壽命；結合卷積神經網路與遞歸神經網路，稱為 Conv-LSTM 架構。Conv-LSTM 架構如圖 12 所示。第一層為卷積層，其目的是為了提取輸入數據的特徵，例如：刀長、刀徑之特徵等；第二、三層均為 LSTM 層，此設計是希望透過 LSTM 的特性來記憶過去資料，藉由歷史資訊來學習更好的網路，並且使用兩層 LSTM 來加深網路，藉此學習到更加細微的數據；最終連接一個全連接層當作輸出。

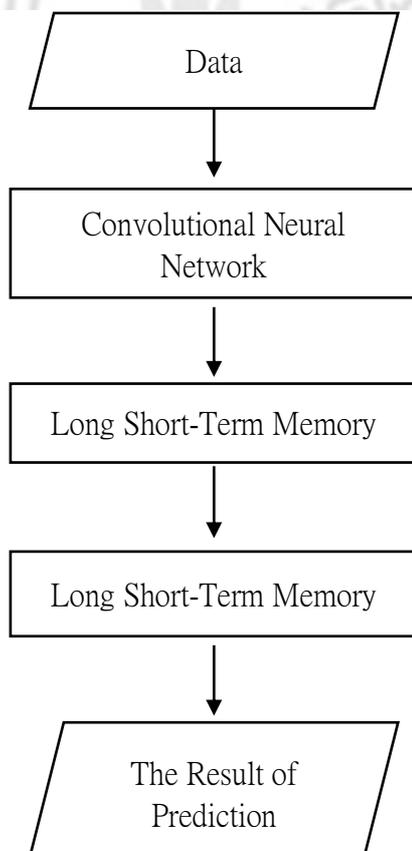


圖 12 Conv-LSTM 架構圖

經由第一層卷積的運算後，藉由卷積的特點來強化輸入數據的特徵，因此接下來直接連接兩層 LSTM 的遞歸神經網路，透過 LSTM 的設計，讓神經網路能夠學習刀具數據的前後關聯性。在兩層 LSTM 之後，連接一個全連接層(Fully Connected Layer)，使輸出為單一個數值，並使用線性激活函數(Linear Activation Function)。

使用的損失函數為均方誤差(Mean-square error, MSE)，在統計學中，均方誤差是用來衡量估計連續變量之性能的重要指標，計算方式如下：

$$\text{MSE} = \frac{1}{N_{total}} \sum_{i=1}^o (Y_i - \hat{Y}_i)^2 \quad (14)$$

$N_{total}$ 表示為所有的樣本數據； $Y_i$ 表示輸出的正確答案，代表下個時間點的長度， $i$ 表示輸出層中第 $i$ 個神經元輸出，其中 $i = 1, 2, \dots, o$ ； $\hat{Y}_i$ 則表示為神經網路預測的輸出。

以下為學者對於長短期記憶架構之卷積遞歸神經網路研究之探討，林柏昇(2018)在研究中使用股票歷史數據來做預測，並利用深度學習預測未來股票價格趨勢，此研究提出基於卷積遞歸神經網路的架構-Conv-LSTM，其中在 RNN 中使用長短期記憶(Long Short-Term Memory，LSTM)的架構，LSTM 改善了傳統 RNN 的長期依賴問題，有效的提升預測的準確性與穩定性；蘇奕中(2019)在研究中也運用 CNN 及 Conv-LSTM 來進行步態特徵的提取攝影機影像，以背景減除的方法來獲得每個時間點目標人物的輪廓影像，此研究將 CNN 和 Conv-LSTM 同時訓練並使用孿生神經網路架構，以 OUISIR, Large Population 的資料集作為訓練資料，結果在千人規模下身份辨識率可達 80%以上；黃麟傑(2021)在使用多種 U-net 深度學習網路在 NBI 影像中偵測早期胃癌病徵區域之研究中將醫生提供胃癌影像和圈選病變區域作為訓練資料，透過深度學習的方式進行訓練，其實驗結果顯示，使用 PSP Bi-Directional Conv-LSTM U-net 的最高平均精準度(Precision Rate)可達到 86%，本研究將參考學者們對於卷積結合長短期記憶神經眼算法之研究解決時間與空間捕捉關係，並將其方法運用至刀具壽命健康度預測研究上。

## 第三章 研究方法

### 第一節、研究概述

在金屬加工中之刀具、刀片是直接影響加工品質之主要因素，以往傳統切削工藝中，刀片與刀具的好壞以往皆由機台操作者以目視、觸感等經驗來決定，此情形人為因素影響極大，導致於機台操作者加工完之料件精度不一致。

本研究將以歐權科技提供之刀具視覺檢測儀來擷取加工後刀具數據、量測加工刀片之精確畫面，藉由影像處理量測刀具輪廓，將刀片磨耗情形予以量化方式表述，並鎖定於同一種材質上使用三種刀具(平面銑刀、銑刀、精搪刀)進行每次加工後的各種量測數據量測與分析，並評估、挑選適合特徵作為訓練樣本，最後運用演算法方式預測出加工刀具健康度。

歐權科技工作項目主要為精密加工，CNC 加工機大多使用捨棄式刀片，並安裝於自動換刀機構(Automatic Tool Changer, ATC<sup>3</sup>)上進行料件加工，依個案公司加工情形、營收判斷，全廠區每月至少丟棄約 5000 片刀片，且刀具款式相同未必加工相同的材質料件，會搭配不同的加工參數(轉速、進給率)加工各類不同材質之料件，其對刀具壽命的影響亦非固定。因此，為使個案公司進行數位化轉型以及掌控刀具剩餘壽命，必須使用更精確的方式來表述刀具狀態，才能有效對應到加工品質加工現場的機台操作者使用目視及觸感搭配經驗來鑑定刀具。為能夠預測刀具的使用壽命，達到以機器輔助人或強化工作品質的效果。

3.ATC：自動換刀裝置(Automatic tool changer)簡稱 ATC，是數控工具機上的設備，可以自動更換刀具，提昇設備產能以及增加支援刀具數量。



圖 13 研究架構圖

## 第二節、目標選定與數據收集

### 一、目標加工物選定

本研究選定加工機分度盤核心零組件「轉塔」，作為本次加工使用的加工物，如圖 14，而每一顆轉塔共有加工 24 個孔位，圖 14 中每一個箭頭即為一個加工孔位，每個孔位在加工過程中會使用到數把不同的刀具。即使為同一把刀具，但不同的加工方式、材質皆會影響著相同刀具的使用壽命，因此，為了獲得更合適的量測屬性，首先在每一把刀具的加工材質與加工方式(參數)固定下，進行資料收集，並藉此觀察刀具的磨耗是否具由規律性，以下說明：

1. 為保持實驗規律，在研究期間加工之刀具皆不加工轉塔以外之料件。
2. 為保持實驗規律，CNC 機台只加工同一類型之料件，每顆轉塔加工參數皆為固定。
3. 為實驗數據來源連續性，每次加工完之刀具，必須進行刀具數據量測。

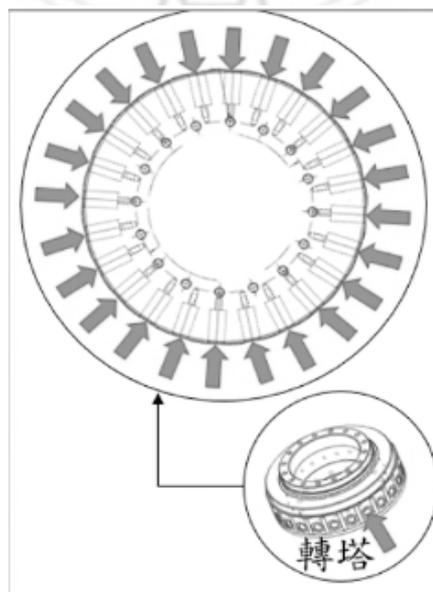


圖 14 加工料件(轉塔)示意圖

## 二、選擇加工刀具

本研究搜集刀具分別為平面銑刀、鎢鋼銑刀、精搪刀三種，如圖 15 所示，三把刀具皆用於同一個待加工孔位的使用，先後順序為平面銑刀、鎢鋼銑刀、精搪刀，每把刀具加工方式、使用參數也不同，因此本研究選定。



圖 15 加工刀具示意圖

平面銑刀為本研究轉塔加工工序第 4 把加工刀具，此刀具運用於在大面積上的平面切削，適用於半加工、精加工、粗加工等製造生產方式，在加工上呈現穩定高效率與卓越加工性能；

銑刀為本研究轉塔加工工序第 5 把加工刀具。而銑削一般在銑床加工中心上進行，一般用於平面、溝槽、成形面以及特殊形面等加工。

精搪刀，以往是料件加工的最後一到工序，也是本研究最後一道工序，此刀具將決定整個零件加工良率。因此實際加工過程精搪刀所扮演的相當重要，一旦有操作不當就可能使加工零件報廢。

### 三、量測刀具方式選定

刀具視覺檢測儀採用光學式量測之儀器，量測方式為將刀具放置於光學鏡頭前，調整光源亮度，並將檢測儀器旋轉刀具一周後，輸出量測到的各類數值，數值誤差範圍  $\leq 0.005\text{mm}$ ，如所示。量測到的結果刀具數據和刀具影像如圖 16 所示。從圖 17 中可以看出平面銑刀在全新、使用中、NG 刀片所呈現的影像有著顯著差異。

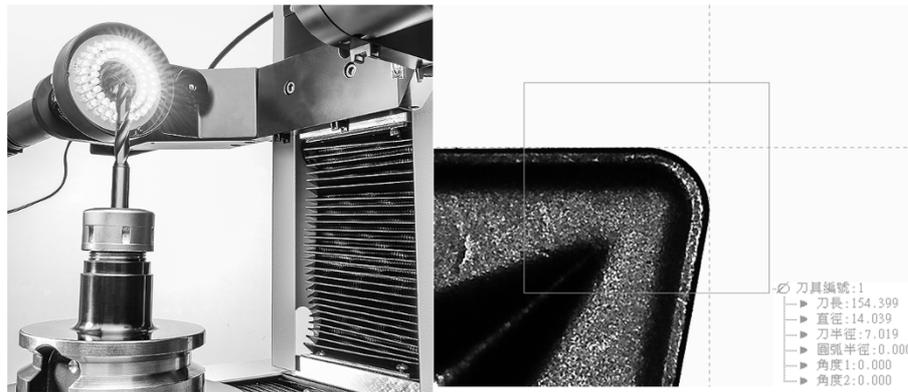


圖 16 刀具量測儀示意圖

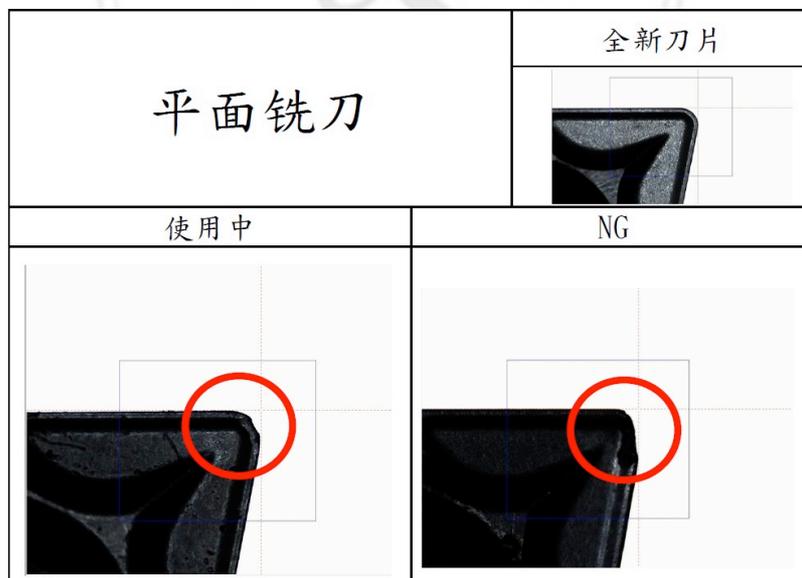


圖 17 平面銑刀刀具影像差異圖

#### 四、、刀具量測特徵

每種刀具的量測特徵於表 2 所列，加工轉塔時所搭配的進給率、轉速會依照不同的刀具進行設定，過往經驗判斷此應為轉塔加工最適化的設備參數。電流值為類比訊號，每加工 1 顆轉塔(約 1 小時，經歷 8 把刀具加工)，每把刀具會有各自的量測電流值，取樣頻率為：約 1000 筆/秒，每把刀具需加工 24 個孔位，故每把刀具之電流值數據會呈現 24 的波峰。平面銑刀：約 3 秒/加工 1 孔，約 11 秒/切換孔位+加工，加工 1 顆轉塔時間約 4 分 23 秒，銑刀：約 16 秒/加工 1 孔，約 24 秒/切換孔位+加工，加工 1 顆轉塔時間約 9 分 20 秒，精搪刀：約 25 秒/加工 1 孔，約 28 秒/切換孔位+加工，加工 1 顆轉塔時間約 11 分 40 秒。

表 2 原始數據欄位介紹

欄位名稱	說明
刀種	平面銑刀 / 鎢鋼銑刀 / 精搪刀。
加工材質	中碳鋼。
刀長(mm)	加工一個轉塔後，刀具量測儀量測刀具的長度。
刀徑(mm)	加工一個轉塔後，刀具量測儀量測刀具的直徑。
刀具影像	加工一個轉塔後，刀具量測儀影像。
刀具影像磨耗等級	加工一個轉塔後，根據刀具量測儀影像判斷刀具影像磨耗等級，等級依照磨耗程度分為非常好、良好、普通、不良、非常不良。
刀具健康度	加工一個轉塔後，根據刀具使用狀況及實際刀具外觀進行刀具健康度評分，範圍為 0 至 10 分。
加工次數	轉塔加工次數。
轉速(rpm)	刀具加工時所設定的設備參數。
進給率(mm/min)	刀具加工時所設定的設備參數。

其中刀長的量測範圍示意圖於圖 18 所呈現，皆是從夾具頂端開始算起向上至刀具的水平最高點。而刀徑的量測範圍於圖 19 所示，將刀具水平方向旋轉一圈後所量測到的直徑最大值則為刀具直徑。



圖 18 刀長的量測範圍



圖 19 刀徑的量測範圍

## 五、收集刀具數據

本研究將每次五軸數控加工機所加工用之刀具，利用刀具視覺檢測儀將平面銑刀、銑刀、精搪刀三把刀具加工後之刀長、刀徑、刀具影像等數據做搜集，從 110 年 1 月刀具量測儀建置完成後至 110 年 8 月底以搜集 1500 顆轉塔量測數據，如下圖 20 所示，並將檔案匯入 python 進行建模、分析以及預測。

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	time step	平面銑刀				銑刀				精搪刀			
2		更換刀具	加工	刀長	刀徑	更換刀具	加工	刀長	刀徑	更換刀具	加工	刀長	刀徑
3	0	1	0	154.275	14.011	1	0	154.182	7.753	1	0	134.176	8.023
4	1	0	1	154.275	14.011	0	1	154.181	7.753	0	1	134.175	8.011
5	2	0	1	154.269	14.015	0	1	154.181	7.753	0	1	134.174	8.009
6	3	0	1	154.274	14.010	0	1	154.181	7.752	0	1	134.173	8.006
7	4	0	1	154.274	14.010	0	1	154.181	7.752	0	1	134.192	7.995
8	5	0	1	154.274	14.009	0	1	154.180	7.752	0	1	134.187	7.985
9	6	0	1	154.273	14.009	0	1	154.180	7.752	0	1	134.187	7.983
10	7	0	1	154.273	14.008	0	1	154.180	7.751	0	1	134.169	7.977
11	8	0	1	154.272	14.004	0	1	154.180	7.751	1	0	133.804	8.020
12	9	0	1	154.272	14.005	0	1	154.180	7.751	0	1	133.803	8.018
13	10	0	1	154.272	14.006	0	1	154.180	7.750	0	1	133.801	8.012
14	11	0	1	154.272	14.006	0	1	154.180	7.751	0	1	133.809	8.000
15	12	0	1	154.272	14.005	0	1	154.179	7.751	0	1	133.800	7.993
16	13	0	1	154.271	14.004	0	1	154.179	7.751	0	1	133.799	7.980
17	14	0	1	154.271	14.004	0	1	154.179	7.750	0	1	133.798	7.977
18	15	0	1	154.271	14.004	0	1	154.179	7.753	0	1	133.797	7.968
19	16	0	1	154.271	14.004	0	1	154.179	7.750	0	1	133.811	7.961
20	17	0	1	154.270	14.003	0	1	154.178	7.749	1	0	134.117	8.019
21	18	0	1	154.270	14.003	0	1	154.178	7.749	0	1	134.116	8.015
22	19	0	1	154.270	14.002	0	1	154.178	7.749	0	1	134.115	8.010
90	87	0	1	154.389	13.971	0	1	154.160	7.732	1	0	134.060	8.022
91	88	0	1	154.389	13.969	0	1	154.160	7.732	0	1	134.059	8.020
92	89	0	1	154.388	13.969	0	1	154.160	7.732	0	1	134.058	8.012
93	90	0	1	154.388	13.969	0	1	154.159	7.732	0	1	134.046	8.007
94	91	0	1	154.388	13.968	0	1	154.159	7.731	0	1	134.057	8.004
95	92	0	1	154.387	13.967	0	1	154.159	7.731	0	1	134.056	8.001
96	93	0	1	154.387	13.967	0	1	154.159	7.731	0	1	134.055	7.999
97	94	0	1	154.387	13.964	0	1	154.159	7.730	1	0	134.054	7.986
98	95	0	1	154.386	13.965	0	1	154.158	7.730	1	0	134.058	8.021
99	96	0	1	154.386	13.964	0	1	154.158	7.730	0	1	134.048	8.018
100	97	0	1	154.386	13.964	0	1	154.158	7.730	0	1	134.056	8.008
101	98	0	1	154.390	13.963	0	1	154.157	7.729	0	1	134.041	7.994
102	99	0	1	154.386	13.963	0	1	154.156	7.729	0	1	134.054	7.992
103	100	0	1	154.385	13.962	0	1	154.156	7.729	0	1	134.054	7.990
104	101	0	1	154.385	13.962	0	1	154.155	7.728	0	1	134.053	7.987
105	102	0	1	154.384	13.961	0	1	154.154	7.728	0	1	134.052	7.985
106	103	1	0	154.204	14.010	0	1	154.154	7.728	0	1	134.051	7.980
107	104	0	1	154.214	14.009	0	1	154.154	7.728	0	1	134.051	7.972
108	105	0	1	154.203	14.009	0	1	154.154	7.728	1	0	134.076	8.023

圖 20 刀具量測數據搜集

## 六、刀具影像收集

本研究將每一次轉塔加工完之料件進行數據收集，其三把刀具影像如表 4 所示，刀具量測採用刀具視覺檢測儀進行影像拍攝及數據收集，平面銑刀、精搪刀量測影像為刀片位置，而銑刀量測為整把刀具，本次研究將收集每次加工頑刀數據以及影像擷取。

表 3 刀具影像量測

平面銑刀影像量測	銑刀影像量測	精搪刀影像量測
		

### 第三節、資料預處理

#### 一、異常值與遺漏值處理

在 Python 中已經匯入刀具數據相關原始資料，而資料有可能有缺失值與異常值導致原始資料無法進行分析，則我們可將資料縮減，如表 4 ~ 6 來去除異常值與缺失值數據，接著由表 5 ~ 6 中可以看到，第 0、2、6 筆資料為缺失值，故第 0、2、6 筆資料皆為無效數據資料須將其移除，而第 3 筆數據資料為異常值，應為數值符號卻呈現亂碼，故第 3 筆資料也是無效數據資料也須將其移除，經由數據預處理完之資料如表 6，只有第 1 筆資料與第 5 筆資料為有效數據資料，將刀具數據預處理完後才能進行演算分析。

#### 二、特徵標準化

當特徵做標準化除了可以優化梯度下降法外還可以提高精準度，有的分類器需要計算樣本間的距離，特徵標準化(Normalization)是將特徵資料按比例縮放，讓資料落在某一特定的區間，因此本研究將使用特徵標準化其中的 Min Max Normalization 方法，將特徵數據按比例縮放到 0 到 1 的區間(或是-1 到 1)。

表 4 異常值數據

time step	平面銑刀				鎢鋼銑刀				精搪刀			
	更 換 刀 具	加 工	刀長	刀徑	更 換 刀 具	加 工	刀長	刀徑	更 換 刀 具	加 工	刀長	刀徑
0	1	0		14.011	1	0	154.182	7.753	1	0	134.176	8.023
1	0	1	154.275	14.011	0	1	154.181	7.753	0	1	134.175	8.011
2	0	1	154.269	14.015	0	1		7.753	0	1	134.174	8.009
3	0	1	154.274	14.010	0	1	154.181	%^*\$	0	1	134.173	8.006
4	0	1	154.274	14.010	0	1	154.181	7.752	0	1	134.192	7.995
5	0	1	154.274	14.009	0	1	154.180	7.752	0	1	134.187	7.985
6	0	1	154.273	14.009	0	1	154.180		0	1	134.187	7.983

表 5 缺失值數據

time step	平面銑刀				鎢鋼銑刀				精搪刀			
	更 換 刀 具	加 工	刀長	刀徑	更 換 刀 具	加 工	刀長	刀徑	更 換 刀 具	加 工	刀長	刀徑
0	1	0		14.011	1	0	154.182	7.753	1	0	134.176	8.023
1	0	1	154.275	14.011	0	1	154.181	7.753	0	1	134.175	8.011
2	0	1	154.269	14.015	0	1		7.753	0	1	134.174	8.009
3	0	1	154.274	14.010	0	1	154.181	%^*\$	0	1	134.173	8.006
4	0	1	154.274	14.010	0	1	154.181	7.752	0	1	134.192	7.995
5	0	1	154.274	14.009	0	1	154.180	7.752	0	1	134.187	7.985
6	0	1	154.273	14.009	0	1	154.180		0	1	134.187	7.983

表 6 預處理後數據

time step	平面銑刀				鎢鋼銑刀				精搪刀			
	更 換 刀 具	加 工	刀長	刀徑	更 換 刀 具	加 工	刀長	刀徑	更 換 刀 具	加 工	刀長	刀徑
1	0	1	154.275	14.011	0	1	154.181	7.753	0	1	134.175	8.011
5	0	1	154.274	14.009	0	1	154.180	7.752	0	1	134.187	7.985

#### 第四節、資料分析

本研究收集到的刀具數據資料為 1500 次轉塔加工(含 30 次平面銑刀換刀、10 次鎢鋼銑刀換刀及 190 次精搪刀換刀)，並開始進行模型建置與刀具壽命資料訓練與預測，並對加工時三把刀具進行原始數據資料分析，包含刀具刀長以及刀徑並分析其數據與刀具健康度；使用箱型圖進行數據離散的圖表，箱形圖優點就是不受異常值的影響，可以以一種相對穩定的方式描述資料的離散分佈情況，透過箱形圖可以進行可視化研究，並讀出該組數據的上四分位數、下四分位數、最大值、最小值、中位數、異常值如下圖 21，繪製箱形圖方法如下：

- 先得知該數據之最大值、最小值、平均值、四分位數等。
- 在坐標軸上根據最大值、上四分位數、中位數、下四分位數、最小值的數值畫出 5 條線段。
- 通過上面提到的四分位距計算溫和異常值和極端異常值的範圍。

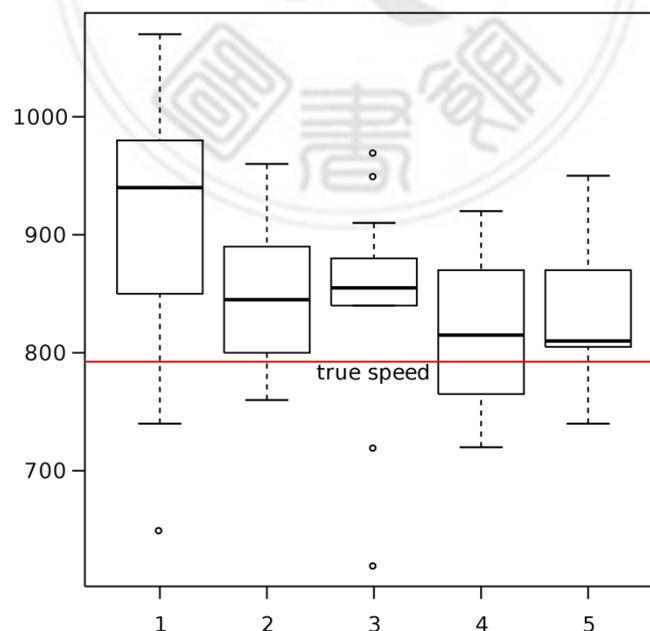


圖 21 箱形圖示意圖

圖片來源：<https://zh.wikipedia.org/wiki/%E7%AE%B1%E5%BD%A2%E5%9C%96>

## 一、平面銑刀數據資料分析

圖 22 中，列出 10 次更換刀具資料，水平軸為依加工時間順序換刀或轉塔加工，綠色虛線為更換新的平面銑刀，垂直軸折線圖為刀具量測儀所量測到的轉塔加工後刀具的刀長(length)與刀徑(diameter)。刀長會因為人員更換刀具導致新刀具的刀長不同。

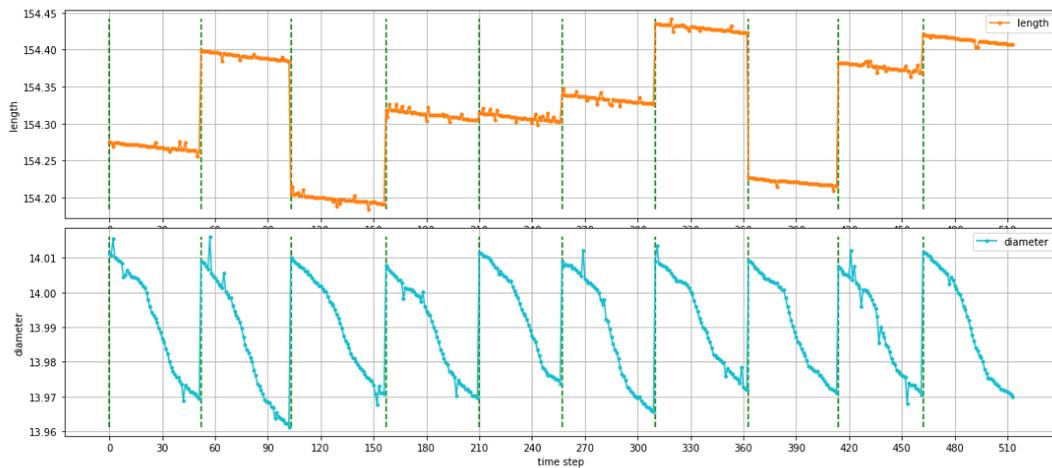


圖 22 平面銑刀刀具量測儀量測原始資料

圖 23 為平面銑刀健康度，列出 10 次更換刀具資料，觀察平面銑刀健康度，與轉塔加工次數呈正相關，最後一次加工的刀具健康度值大部分介於 5 分與 7 分之間。

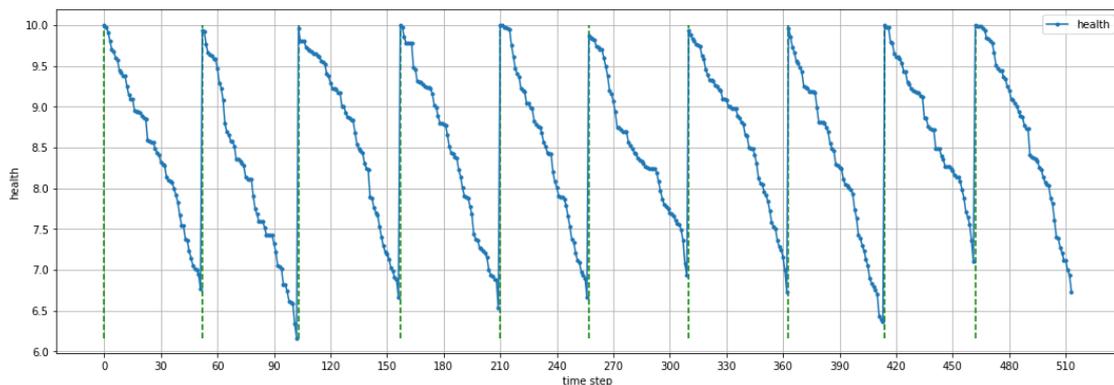


圖 23 平面銑刀刀具健康度

平面銑刀的刀長與刀徑磨耗箱型圖如圖 24，刀長磨耗值大部分介於 0.000 mm 與 0.001 mm 之間，刀徑磨耗值大部分介於 0.001 mm 與 0.002 mm 之間。排除離群值，觀察刀長與刀徑磨耗值，平面銑刀為平面型的刀具，此類型的刀片是使用刀平面來接觸加工物表面，其刀長與刀徑都會因加工而變短，其中刀徑磨耗較為明顯。

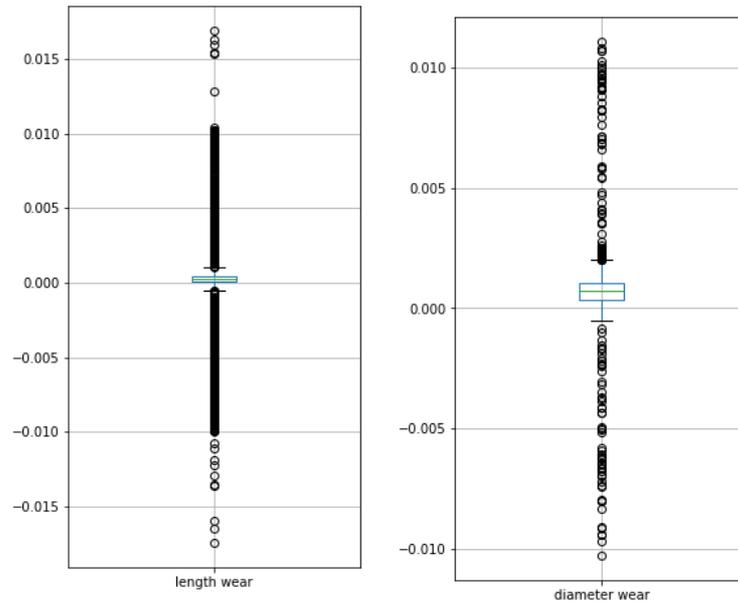


圖 24 平面銑刀刀長與刀徑磨耗箱型圖

## 二、銑刀數據資料分析

在圖 25 中，列出 5 次更換刀具資料，水平軸為依加工時間順序換刀或轉塔加工，綠色虛線為更換新的鎢鋼銑刀，垂直軸折線圖為刀具量測儀所量測到的轉塔加工後刀具的刀長(length)與刀徑(diameter)。刀長會因為人員更換刀具導致新刀具的刀長不同。

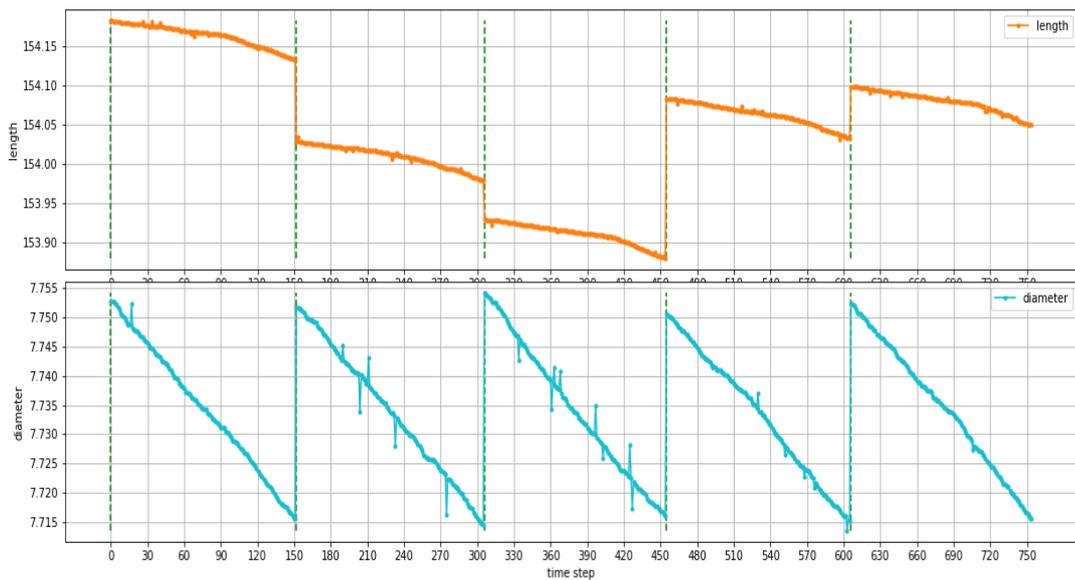


圖 25 銑刀刀具量測儀量測原始資料

圖 26 為鎢鋼銑刀健康度，列出 5 次更換刀具資料，觀察鎢鋼銑刀健康度，與轉塔加工次數呈正相關，最後一次加工的刀具健康度值大部分介於 6 分與 7 分之間。

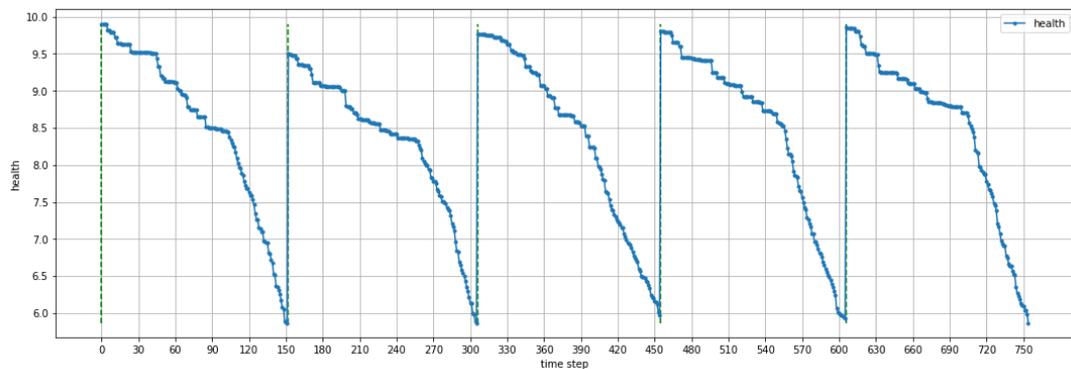


圖 26 銑刀刀具健康度

圖 27 為鎢鋼銑刀的刀長與刀徑磨耗箱型圖，刀長磨耗值大部分介於 0.000 mm 與 0.005 mm 之間，刀徑磨耗值大部分介於 0.001 mm 與 0.004 mm 之間。排除離群值，觀察刀長與刀徑磨耗值，鎢鋼銑刀本身為柱狀刀具，使用上會進行挖深與擴孔的加工，其刀長與刀徑皆會因為加工的使用時間而磨耗。

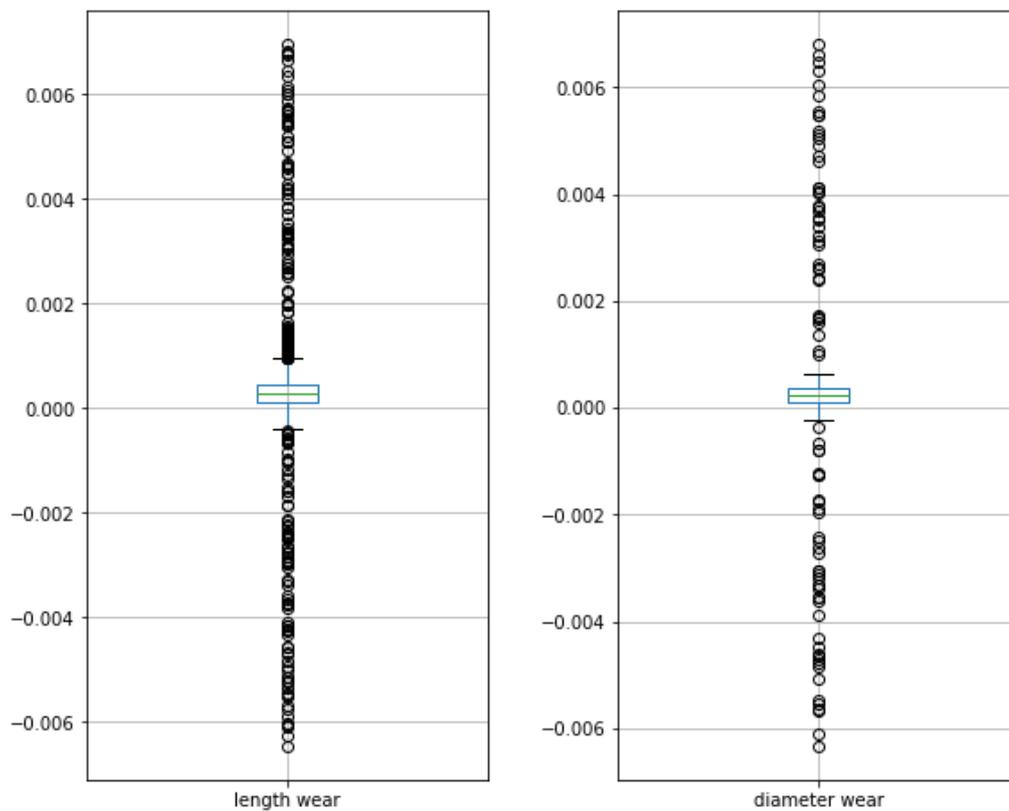


圖 27 銑刀刀長與刀徑磨耗箱型圖

### 三、精搪刀數據資料分析

在圖 28 中，列出 20 次更換刀具資料，水平軸為依加工時間順序換刀或轉塔加工，綠色虛線為更換新的精搪刀，垂直軸折線圖為刀具量測儀所量測到的轉塔加工後刀具的刀長(length)與刀徑(diameter)。刀長會因為人員更換刀具導致新刀具的刀長不同。

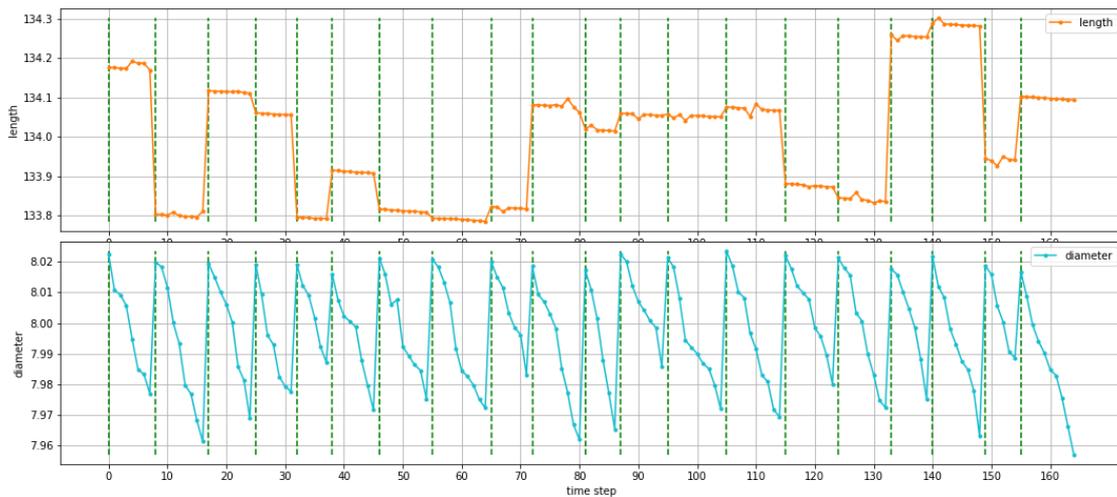


圖 28 精搪刀刀具量測儀量測原始資料

圖 29 為精搪刀健康度，列出 20 次更換刀具資料，觀察精搪刀健康度，與轉塔加工次數呈正相關，最後一次加工的刀具健康度值大部分介於 5 分與 7 分之間。

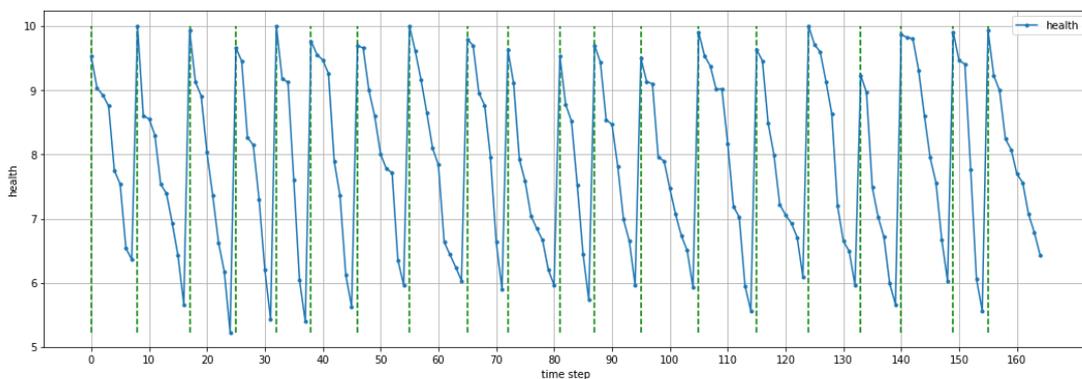


圖 29 精搪刀健康度

圖 30 為精搪刀的刀長與刀徑磨耗箱型圖，刀長磨耗值大部分介於 0.001 mm 與 0.002 mm 之間，刀徑磨耗值大部分介於 0.002 mm 與 0.010 mm 之間。排除離群值，觀察刀長與刀徑磨耗值，精搪刀為平面型刀片，換刀的頻率較高，使用上和平面銑刀相同處皆是使用平面去接觸加工物，其刀長與刀徑都會因加工而變短，其中刀徑磨耗較為明顯，可以明顯看出每一次換新的刀片後，刀徑會因為使用時間而變短。

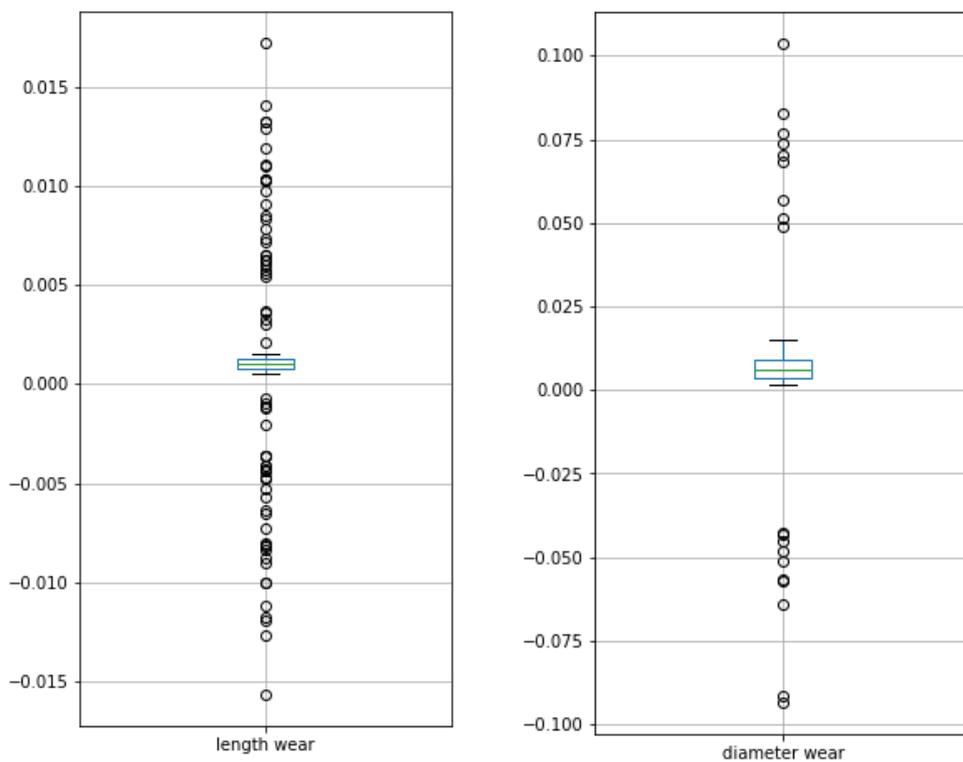


圖 30 精搪刀刀長與刀徑磨耗箱型圖

## 第五節、刀具數據模型訓練

在神經網路開始訓練之前，必須先將輸入數據重新塑造(Reshape)為第一層卷積所能接受的格式。假設收集 1500 顆轉塔加工後刀具的歷史數據，每一筆數據都包含刀長與刀徑共二維，則目前的歷史數據之形式可以簡單表示成： $(100, 1, 2)$ ，若要使用前五筆資料預測最新一筆資料，為了能讓卷積的運算包含前後關係，卷積層所使用的卷積核尺寸(Kernel size)為 $1 \times 5$ ，故輸入數據必須重新塑造為： $(100, 5, 2)$ 。塑造方式如圖 31 所示，將原本只包含單一數值的輸入資料重新塑造為符合卷積核尺寸，第一筆輸入資料  $X = (x_i^0)$ ，重塑後，改變為  $\hat{X} = (x_i^0, x_i^1, x_i^2, x_i^3, x_i^4)$ 。

優化器使用 Adam，網路的迭代次數為 100 次，且設定訓練提早結束(Early stopping)條件，避免過擬合(Overfitting)

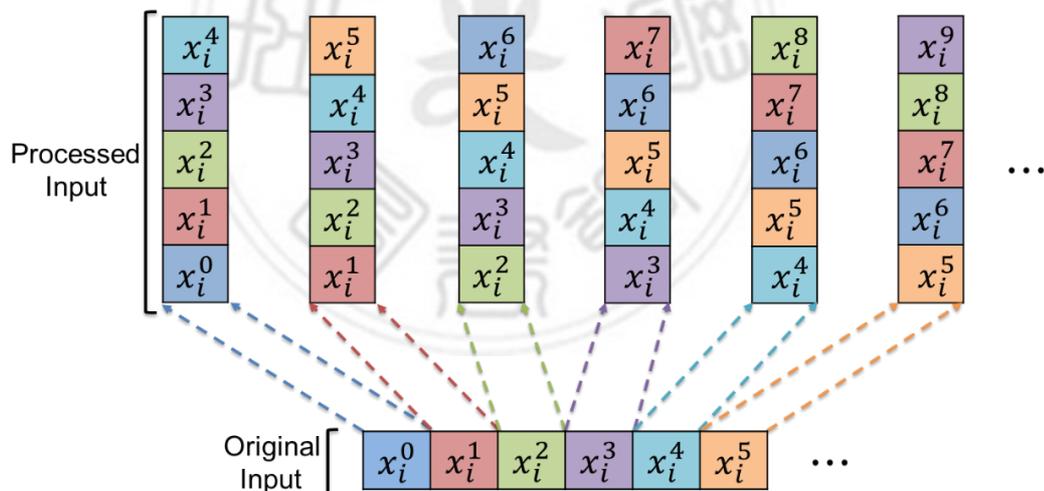


圖 31 重塑輸入資料以符合卷積核

原始數據刀長因人為操作因素導致新刀具刀長不固定，因此不考慮刀長變數。每一次加工磨耗值使用移動平均方法調整離群值，若磨耗值為負值則調整為 0，刀長磨耗值計算為刀具加工後刀具量測儀量測刀長與未加工刀具量測儀量測刀長差異值，刀徑磨耗值計算為刀具加工後刀具量測儀量測刀徑與未加工刀具量測儀量測刀徑差異值。

刀具磨耗面積使用刀具量測儀影像計算磨耗面積，如圖 32 至圖 34。平面銑刀與精搪刀磨耗部位為刀具影像右上角，影像前處理將雜訊去除，使用邊緣偵測演算法、霍夫轉換演算法偵測刀具輪廓與線條，計算加工後磨耗面積。鎢鋼銑刀磨耗部位為刀具表面，影像前處理將顏色轉換、雜訊去除、去除背景，計算加工後磨耗面積。

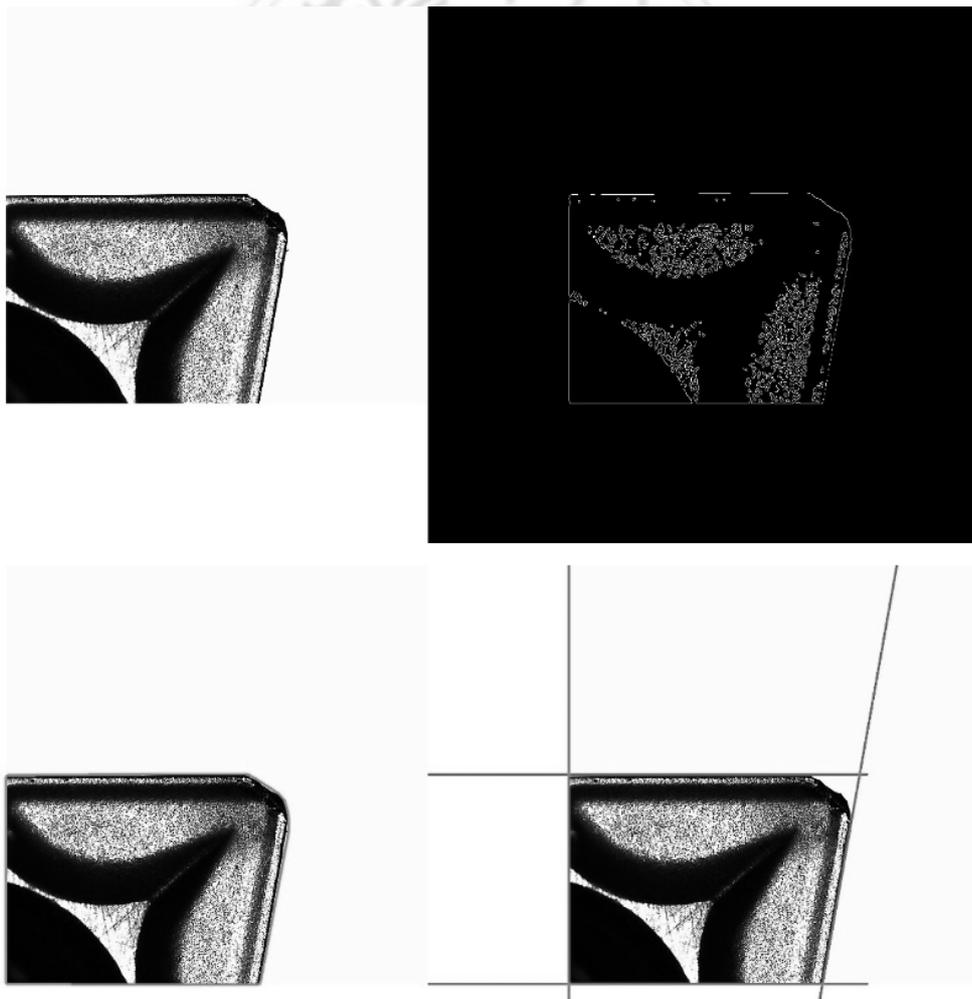


圖 32 平面銑刀磨耗面積計算

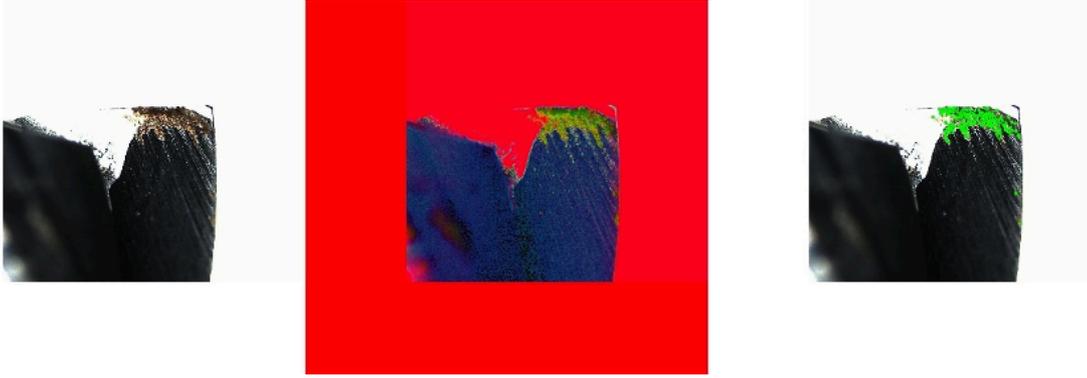


圖 33 銑刀磨耗面積計算

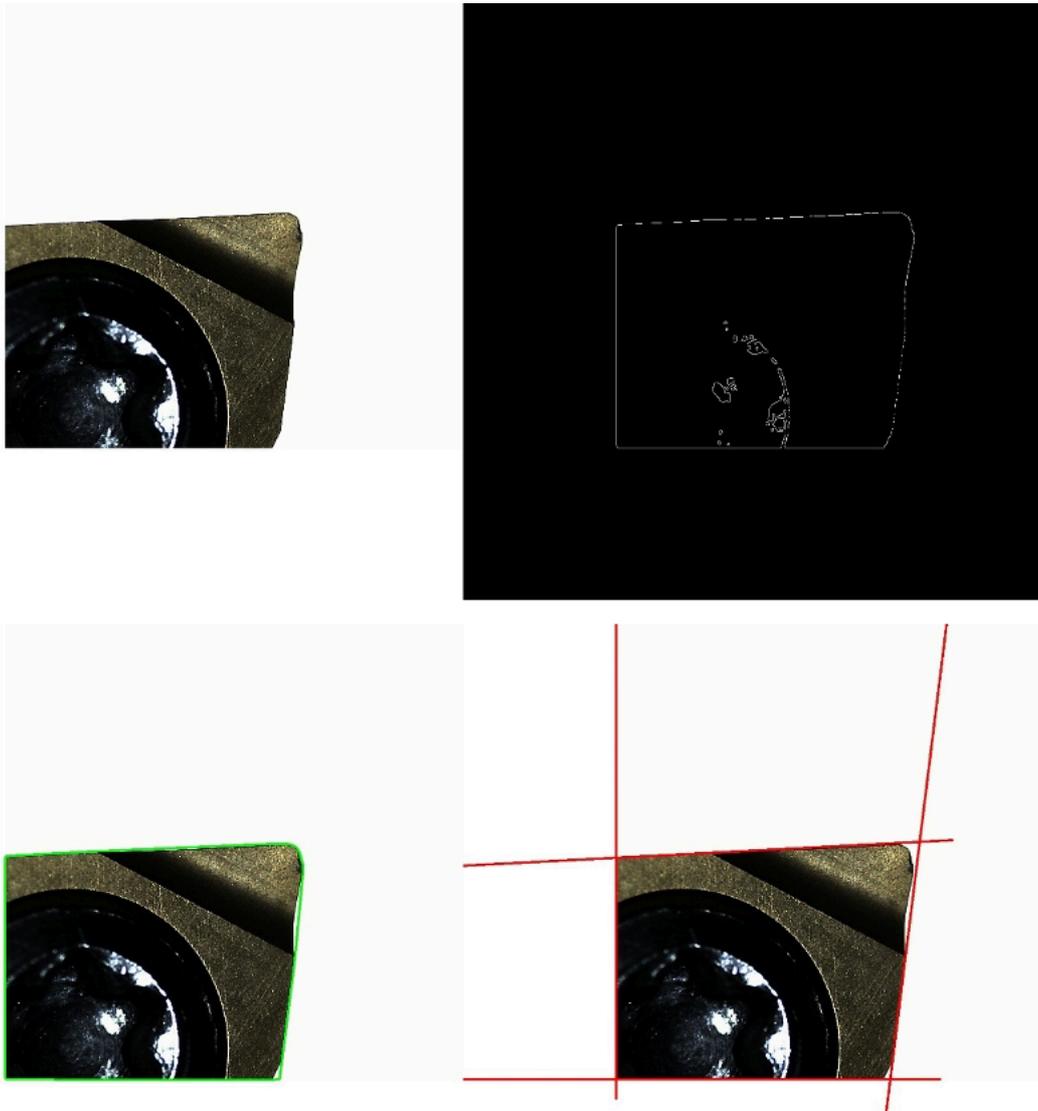


圖 34 精搪刀磨耗面積計算

刀具影像磨耗等級為使用刀具量測儀影像等級分類器分類結果，影像分類使用神經網路 Inception V3，每一把刀具前 1,200 筆資料為訓練集，後 300 筆資料為測試集，三把刀具分類結果如表 7 至表 9 平面銑刀準確率約 94.87%，鎢鋼銑刀準確率約 94.73%，精搪刀準確率約 95.00%。

表 7 平面銑刀刀具量測儀影像分類混淆矩陣

		Predicted label				
		非常良好	良好	普通	不良	非常不良
True label	非常良好	93.94%	5.79%	0.28%	0.00%	0.00%
	良好	0.21%	97.47%	2.32%	0.00%	0.00%
	普通	0.00%	4.60%	94.31%	1.09%	0.00%
	不良	0.00%	0.00%	2.84%	90.34%	6.82%
	非常不良	0.00%	0.00%	0.00%	0.00%	100.00%

表 8 銑刀刀具量測儀影像分類混淆矩陣

		Predicted label				
		非常良好	良好	普通	不良	非常不良
True label	非常良好	91.67%	5.00%	3.33%	0.00%	0.00%
	良好	1.51%	96.81%	1.68%	0.00%	0.00%
	普通	0.00%	1.62%	94.55%	3.84%	0.00%
	不良	0.00%	0.00%	2.50%	92.50%	5.00%
	非常不良	0.00%	0.00%	0.00%	0.00%	100.00%

表 9 精搪刀刀具量測儀影像分類混淆矩陣

		Predicted label				
		非常良好	良好	普通	不良	非常不良
True label	非常良好	91.80%	8.20%	0.00%	0.00%	0.00%
	良好	2.62%	95.77%	1.61%	0.00%	0.00%
	普通	0.00%	2.02%	94.95%	3.03%	0.00%
	不良	0.00%	0.00%	1.16%	97.11%	1.73%
	非常不良	0.00%	0.00%	0.00%	7.41%	92.59%

表 10 為資料數據欄位，輸入資料特徵為七維(刀徑、刀長磨耗值、刀徑磨耗值、刀具磨耗面積、刀具影像磨耗等級、轉塔加工次數與最後一次加工)，輸出資料為一維(刀具健康度)，使用前五筆歷史資料預測加工後刀具健康度。

原始數據為刀長與刀徑二維，新增特徵刀長磨耗修正、刀徑磨耗修正與轉塔加工次數，其中磨耗修正為加工後磨耗量測為負值則修正為 0，故輸入資料調整為五維(刀長、刀徑、刀長磨耗修正、刀徑磨耗修正與轉塔加工次數)，輸出資料為二維(刀長磨耗修正、刀徑磨耗修正)，使用前五筆歷史資料預測加工後刀長與刀徑的磨耗。

表 10 數據欄位介紹

	欄位名稱
1	刀長(mm)
2	刀長磨耗修正(mm)
3	刀徑(mm)
4	刀徑磨耗修正(mm)
5	轉塔加工次數

## 第六節、模型特徵分析

本研究將觀察模型特徵重要度，了解影響模型決策的因子，確認模型的合理性，進而優化改善模型。Deep SHAP 演算法結合 DeepLIFT 與 Shapley value 讓深度神經網路模型的特徵具有可讀性。Shapley value 是由 Lloyd Stowell Shapley 在合作賽局理論 (cooperative game theory) 提出來解決方案，用於計算合作玩家之間的貢獻與收益分配問題。DeepLIFT (Deep Learning Important Features) 計算每個 Feature 的改變對於模型輸出改變的影響。

本研究使用 SHAP Value 透過計算資料中的特徵對模型預測的貢獻，分析模型中訓練資料特徵的重要度，圖 35~37 為平面銑刀、鎢鋼銑刀及精搪刀模型之特徵重要程度，特徵依序為刀長磨耗值、刀徑、刀徑磨耗值、刀具加工次數、最後一次加工、刀具磨耗面積、刀具影像磨耗等級，經研究觀察，發現刀具加工次數與刀具影像磨耗等級這兩個特徵影響模型較多。

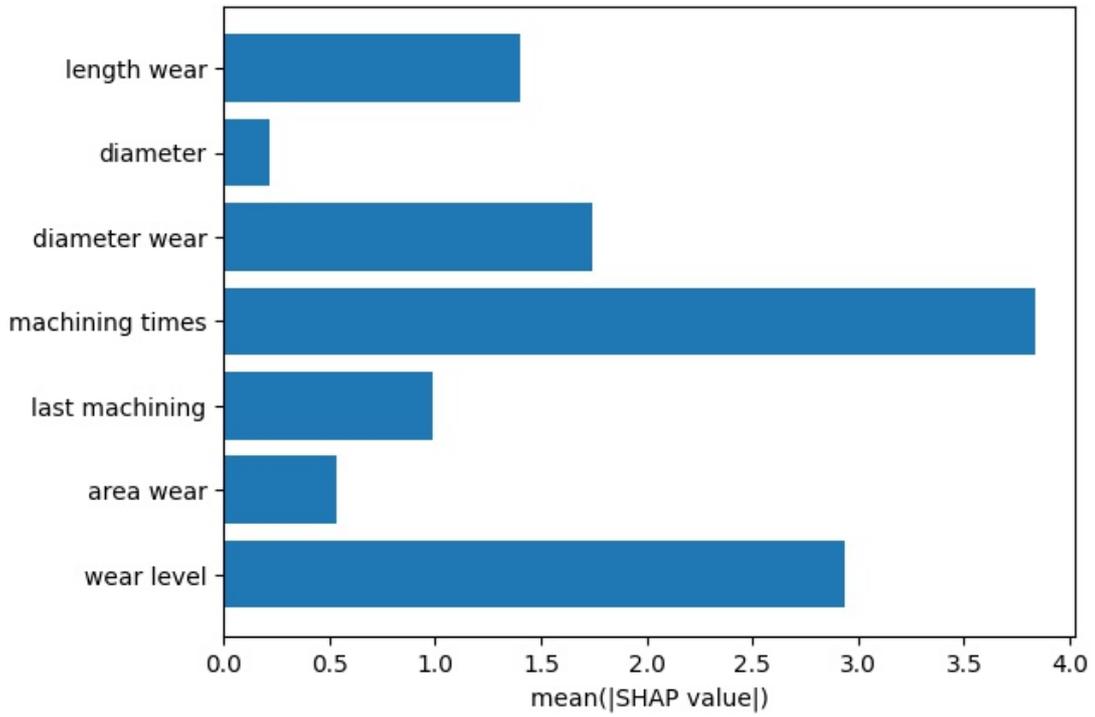


圖 35 平面銑刀模型特徵重要度

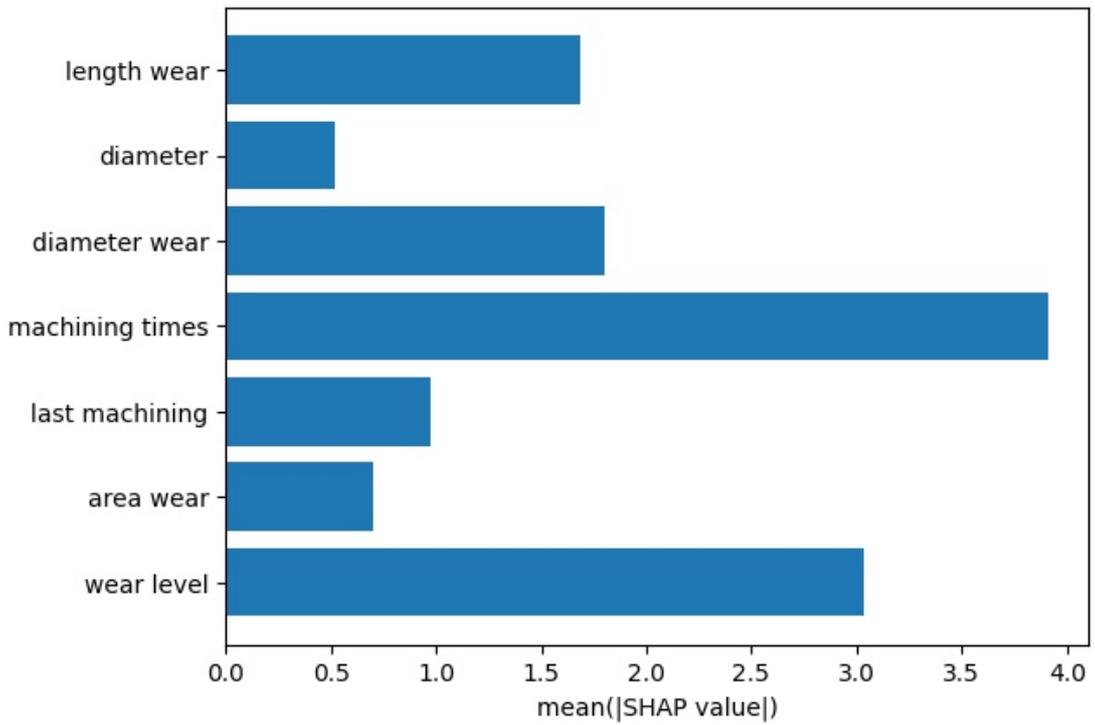


圖 36 鎢鋼銑刀模型特徵重要度

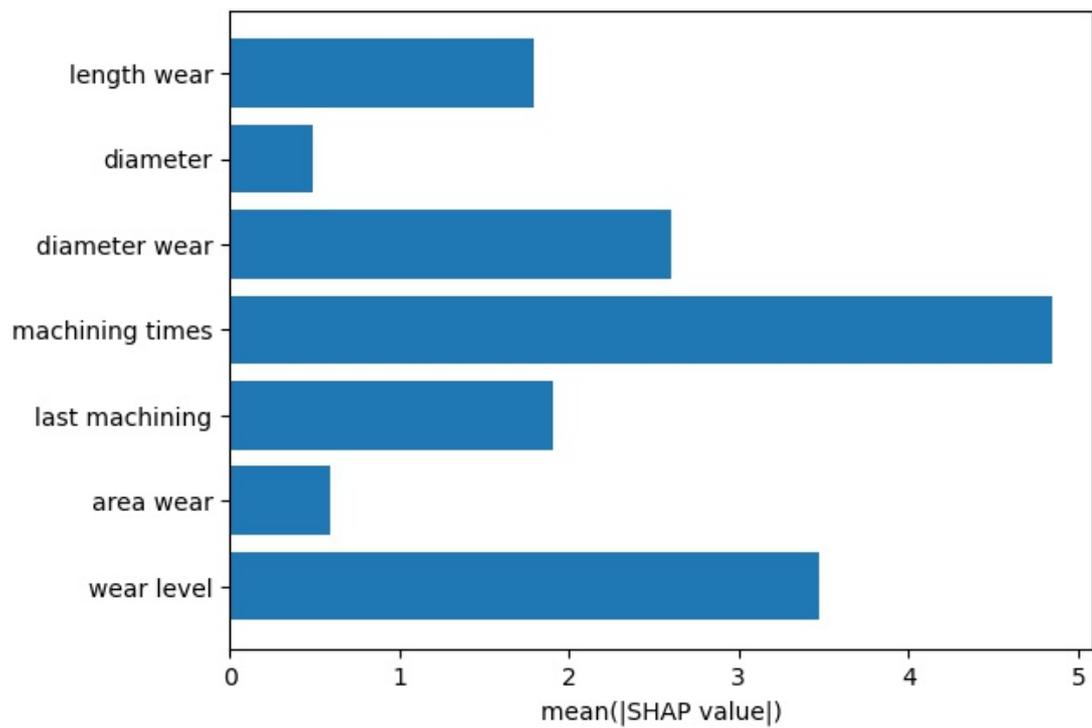


圖 37 精搪刀模型特徵重要度。



## 第七節、回歸模型評估方式

關於機器學習模型評價指標大概分為三種(迴歸、分類、聚類)，本研究因隨著刀具數據資料增加，則預測誤差應該要減少；而因為刀具壽命預測模型所輸出的是使用次數(數值)，屬於監督式學習中的一個分支：迴歸模型(Regression Model)，因此本研究將針對迴歸進行評估方式分析，如下表 11 所示，經分析各位學者研究，本研究決定使用 RMSE 作為機器學習模型預測結果衡量的標準。

表 11 迴歸進行評估方式

評估方式	介紹	文獻探討
平均絕對誤差 (Mean absolute error, MAE)	<p>平均絕對誤差又稱為 L1 範數損失。用於評估預測結果和真實數據集的接近程度，其值越小說明擬合效果越好。</p> <ul style="list-style-type: none"> <li>是絕對誤差的平均值(絕對值後所求的平均值)</li> <li>能更好地反映預測值誤差的實際情況(幫助測量)</li> </ul> $MAE = \sum_{i=1}^n  f_i - y_{i1}  = \frac{1}{n} \sum_{i=1}^n  e_i $	<ul style="list-style-type: none"> <li>廖家穎(2021)在「以黃金和原油期貨預測台灣股票報酬」研究使用 MAE 計算預測誤差值與樣本外 R 平方統計量用來評估各種預測模型之績效，組成迴歸模型對於股票報酬做樣本內的配適與樣本外的預測。</li> <li>賴思汝(2021)在「基於特徵融合與支持向量迴歸的短期金融時間序列預測模型」研究中與未使用降維技術和有使用降維技術但未使用特徵融合技術，這兩類模型做比較，在以 R-square、MSE、MAE 等衡量指標做為評估。</li> </ul>
均方誤差 (Mean Square Error, MSE)	<p>在一般的實驗誤差中，可以假定為滿足常態分佈，其密度函數可以寫為：<math>\sigma</math> 為一參數，描述分佈的集中與分散，稱為標準偏差，其平方亦即誤差平方的平均故稱均方誤差。</p> <ul style="list-style-type: none"> <li>衡量「平均誤差」的一種較方便的方法，</li> </ul>	<ul style="list-style-type: none"> <li>李宗穎(2021)在「應用混合神經網路模型於銷售預測」研究中利用多元線性迴歸與非線性的極限梯度提升(Extreme Gradient Boosting)進行資料增量，最後再利用多層感知器與 LSTM 預測未來的營業額，最後利用 MAE、MSE 評比。</li> </ul>

評估方式	介紹	文獻探討
	<p>MSE 可以評價資料的變化程度。</p> <ul style="list-style-type: none"> <li>常被用作線性迴歸的損失函數。</li> </ul> $MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$	<ul style="list-style-type: none"> <li>郭軒宏(2021)在「應用 BI-LSTM 模型配合三大法人籌碼面預測台灣指數期貨之研究」中，應用 BI-LSTM 模型進行預測，在依不同變數及模型進行分組，分別為實驗組一、實驗組二、實驗組三以及實驗組四，評估指標使用 MSE、MAE、RMSE 作為判斷標準。</li> </ul>
<p>均方根誤差 (Root Mean squared error, RMSE)</p>	<p>常用來作為機器學習模型預測結果衡量的標準。MSE 加了個根號，它只考慮誤差的平均大小，不考慮其方向，再加上 MSE 的數學特性很好，這使得計算梯度變得更容易。這樣數量級上比較直觀，如：RMSE=10，可以認為迴歸效果相比真實值平均相差 10。</p> $RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}$	<ul style="list-style-type: none"> <li>段志奇(2021)在「應用長短期記憶模型與迴歸分析於鐵道運輸載客量預測分析」研究中以應用長短期記憶模型與迴歸分析預測及分析捷運旅客料，並使用 RMSE 評估。</li> <li>Caneca(2021)在「結合 PSO 及 LSTM 於預測服務處理的時間-使用急診室中風治療案例研究」中使用處理時間及每個活動群集的編號建立機器學習 LSTM 演算法預測模型，並使用方均根誤差評估預測模型的準確率，並得到 26% 的預測錯誤。</li> <li>黃鑫(2021)在「結合經驗模態分解與深度學習於匯率預測之研究」中提出 LSTM-Attention 結合經驗模態分解的模型並且與 LSTM 等模型的效能進行比較，並比較評估指標，最後 RMSE 與 MAPE 皆優於其他比較模型。</li> </ul>

## 第四章 研究結果

本研究使用 LSTM 作為迴歸分析(Regression Analysis)模型來預測未來的刀長、刀徑變化，將歷史數據輸入至神經網路模型後，學習出刀長、刀徑隨著使用時間而磨耗的變化曲線，對接下來的刀長、刀徑進行預測，當預測長度低於設立的門檻值時，便可知道此把刀具將會於下一次使用中到達使用壽命，本研究模型將使用數據前 80%做訓練，數據後 20%做為測試集，而研究模型訓練完成時的模型評估標準使用均方根誤差(Root Mean Square Error, RMSE)作為迴歸分析的效能指標，其研究結果依訓練 loss 圖顯示，本研究所訓練之模型皆有完美擬合。

### 一、資料集切割

因為資料為時序性，取資料前 80%加工資料為訓練集，後 20%加工資料為測試集，將每一把刀具前 1200 次加工與換刀作為訓練樣本，後 300 次加工與換刀為測試樣本進行預測。

### 二、評估標準

本研究預測結果好壞的評判標準在這裡採用 RMSE 作為迴歸分析的效能指標，RMSE 是一種常用的測量數值之間差異的量度，其數值常為模型預測的量或是被觀察到的估計量。方均根偏移代表預測的值和觀察到的值之差的樣本標準差(sample standard deviation)，當這些差值是以資料樣本來估計時，他們通常被稱為殘差；當這些差值不以樣本來計算時，通常被稱為預測誤差(prediction errors)。方均根偏移主要用來聚集預測裡誤差的大小，通常是在不同的時間下，以一個量值來表現其預測的能力。方均根偏移是一個好的準度的量度，但因其與數

值範圍有關，因此被限制只能用來比較不同模型間某個特定變數的預知誤差，其計算方式如下：

$$\text{RMSE} = \left( \frac{\sum_{o=1}^m (Y_o - Y'_o)^2}{N} \right)^{\frac{1}{2}} \quad (15)$$

其中  $Y_o$  為神經網路的輸出， $Y'_o$  表示為期望的輸出值。

### 三、預測結果

平面銑刀與鎢鋼銑刀輸入資料使用特徵包含刀長、刀徑、刀長磨耗修正、刀徑磨耗修正共四維，神經網路架構如圖 38。精搪刀換刀頻率不固定，加入轉塔加工次數特徵共五維，而神經網路架構第一層為輸入層為 5x7(數字 5 為運用前四筆數據預測下一筆數據；7 為特徵數)，因第二層為卷積層必須將其轉為 1x4 以符合卷積層格式，三、四層為 LSTM 層，本研究透過 LSTM 的特性來記憶過去資料，藉由歷史資訊來學習更好的網路，並且使用兩層 LSTM 來加深網路，藉此學習到更加細微的數據，而將其兩層轉為 1x32 是因需將其轉為類別或是回歸；最終連接一個全連接層當作輸出。

平面銑刀、鎢鋼銑刀、精搪刀的 RMSE 結果計算於表 12 所列，其訓練 loss 圖分別繪製於至圖 39 至圖 41，其刀具健康值與可加工次數預測結果分別繪製於圖 42 至 44，圖中上半部藍色為真實刀具健康度，紅色為刀具健康度預測值，圖中下半部草綠色為真實可加工次數，粉紅色為刀具可加工次數預測值，本研究依可視化 Loss 圖觀察結果顯示，本研究之數據有著完美擬合。

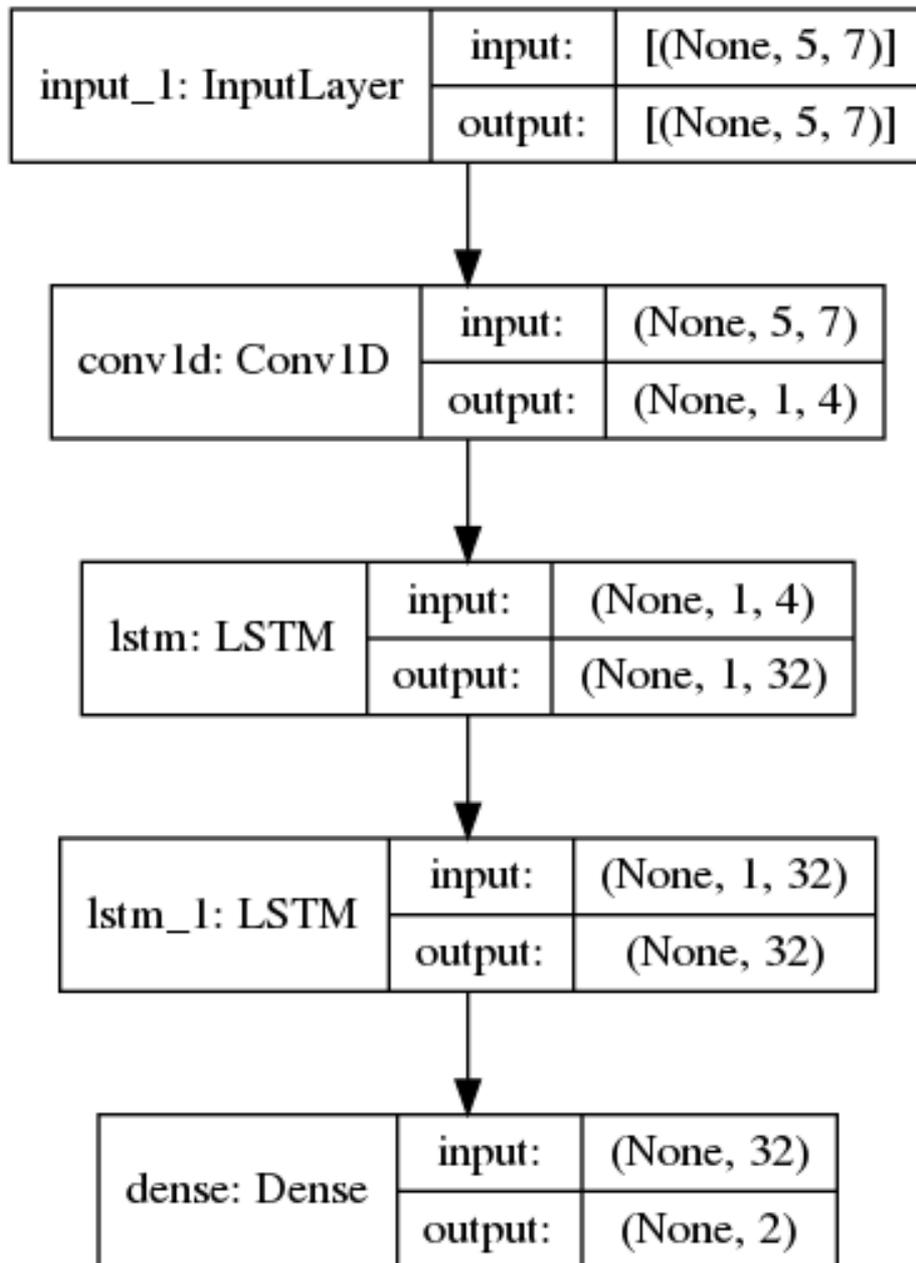


圖 38 神經網路架構圖

表 12 三把刀具的 RMSE 結果計算

刀種	健康度 RMSE	可加工次數 RMSE
平面銑刀	0.3346	2.9704
鎢鋼銑刀	0.3511	4.7505
精搪刀	0.5730	1.0456

表 13 刀具使用次數預測結果

項目	平面銑刀	鎢鋼銑刀	精搪刀
目前使用習慣(次/把)	50	120	5
模型預測使用壽命(次/把)	56	145	9

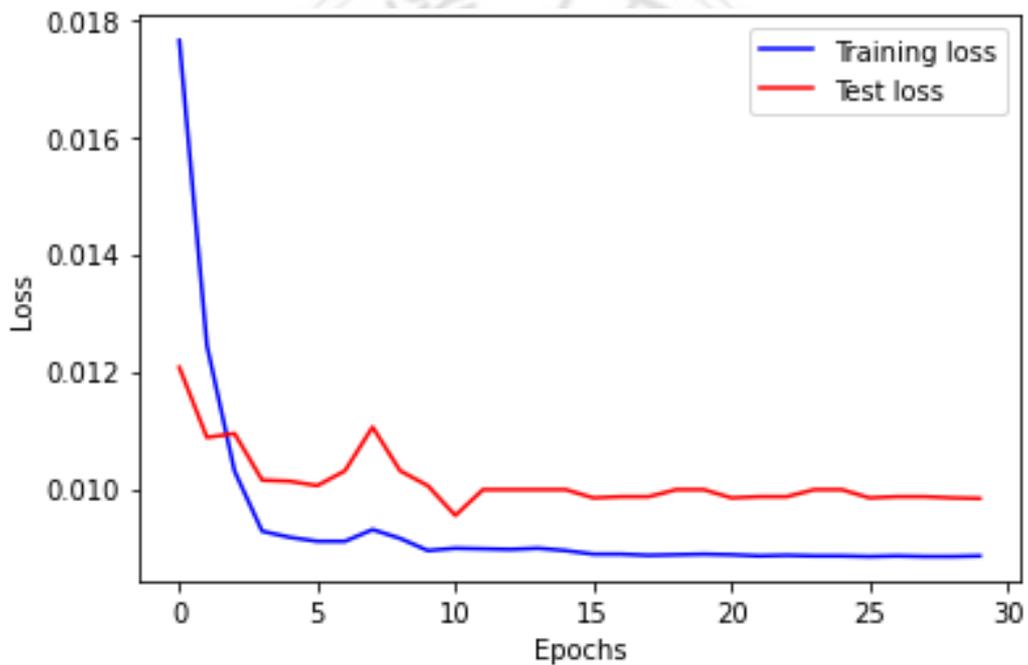


圖 39 平面銑刀訓練 loss 圖

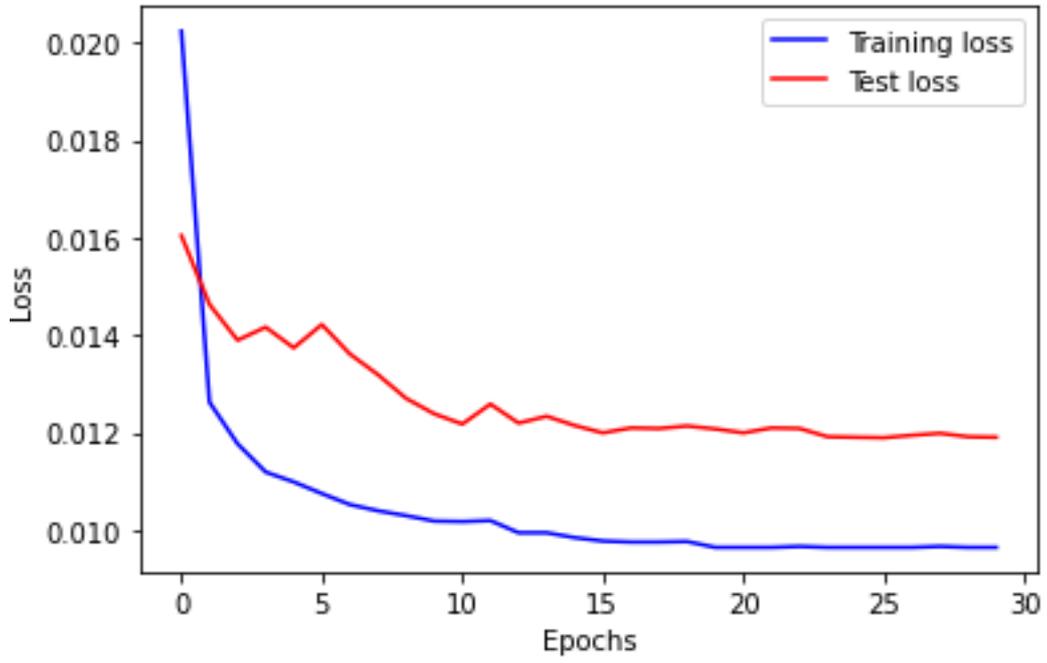


圖 40 銑刀訓練 loss 圖

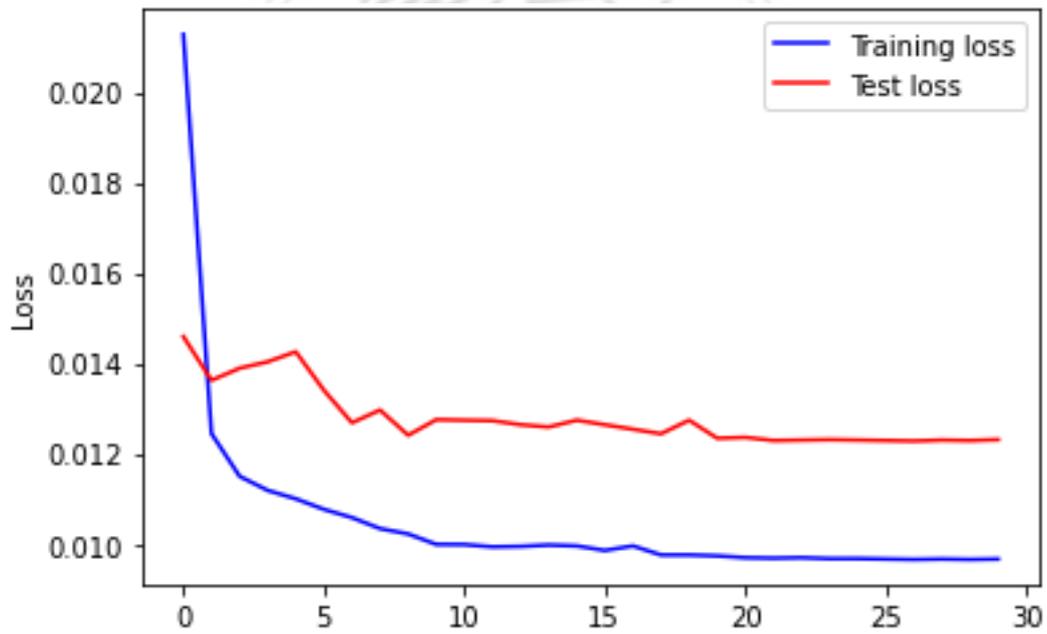


圖 41 精磨刀訓練 loss 圖

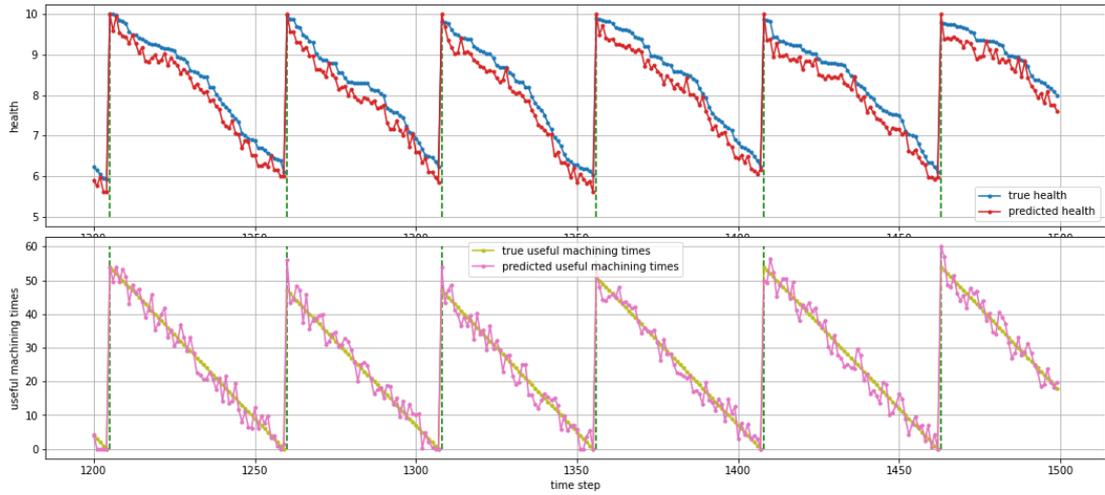


圖 42 平面銑刀健康度與可加工次數預測結果

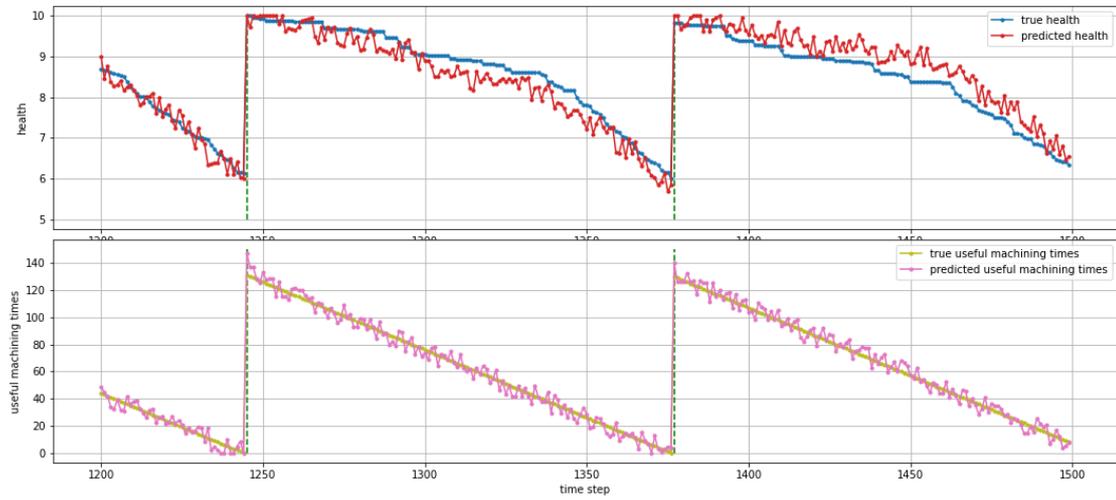


圖 43 銑刀健康度與可加工次數預測結果

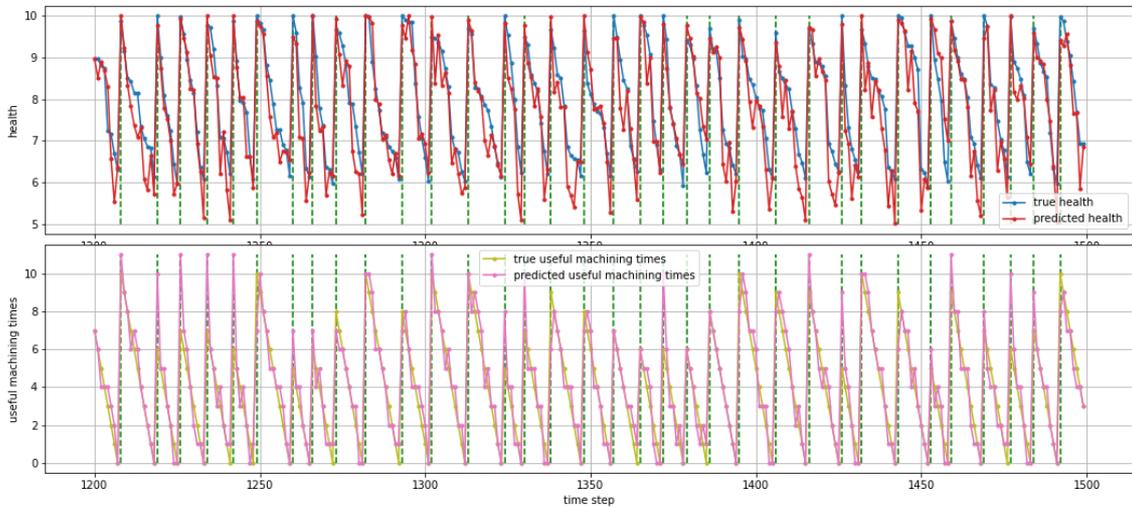


圖 44 精磨刀健康度與可加工次數預測結果

## 第五章 結論

### 一、結論

工具機在切削過程中，刀具磨耗程度會直接影響加工精度品質，為確保產品品質，目前產業普遍做法皆為提前換刀，但生產成本相對提高，若延後換刀則須承擔斷刀、崩刀引起的設備故障與不良品產出，為此本研究藉由刀具視覺檢測儀量測建立刀具使用履歷與壽命預測模型模式建構，在經由 Conv-LSTM 演算法進行刀具模型訓練，最後使用 RMSE 作為驗證效能指標，其結果依可視化 Loss 圖觀察顯示，本研究之數據有著完美擬合；本次研究僅以加工轉塔之三把刀具(平面銑刀、銑刀、精搪刀)作為數據搜集與分析依據並假設刀具組裝與刀片品質皆為正常狀況下加工之數據搜集，其預測模型將改善目前歐權科技刀具使用情形，將精確利用刀具及減少加工品損壞或重工，以下為本研究為個案公司所帶來之效益：

1. 節省刀具使用成本：

個案公司預估年產約 7,000 個轉塔(加工 168,000 孔位)，可節省刀具成本約 1,130,800 元/年。

2. 建立刀具使用履歷：

刀具將具備可溯性，預測出精準汰刀時機，進而縮短產品加工時間。

3. 刀具壽命預測模型建構：

建立加工分度盤關鍵零組件-「轉塔」之刀具壽命預測模型，並可讓未來個案公司開發新產品之加工刀具選用依據。

4. 提升機台稼動率(稼動時間/負荷時間 x 100%)：

研究前設備稼動率為 245 分/350 分 x100% = 70%

研究後設備稼動率為 351 分/390 分  $\times 100\% = 90\%$

5. 提高個案公司產能效率(實際產能/標準產能  $\times 100\%$ ):

加工機台標準生產效率為 1.07 個轉塔/小時;

實際加工時間為 480 分-60 分(休息)-30 分(停機時間)=390 分;

實際產能為 6.3 顆轉塔/ (390 分/60 分) = 0.96 小時;

本研究所提升之產能效率為  $0.96 / 1.07 = 90\%$ 。

6. 增加「轉塔」良率(良品數/實際生產數  $\times 100\%$ ):

研究前: 4.28 顆轉塔/6.30 顆轉塔  $\times 100\% = 68\%$

研究後: 5.67 顆轉塔/6.30 顆轉塔  $\times 100\% = 90\%$

## 二、未來建議

以精密加工廠業來說，一天刀具及拋棄式刀片需求量是非常可觀的，對於一般精密加工廠而言刀具管理是非常重要的，刀具庫存不足即可能影響整體生產線之正常運作，但刀具採購過多時也可能造成庫存浪費，因此本研究未來建議將其結果融入至刀具壽命預測系統將所有工廠刀具進行身份編排管理，並結合公司 ERP、MES 系統進行真正有效的管理，而不是只在刀具使用時間、次數上單一使用的管理，並將其壽命預測模型分享至現有供應商，達到共存共榮，不僅可以藉由此模式之建構增加供應商生產產品良率、達交率，最終個案也可達到供應商進料不檢驗來降低人力成本與檢驗時間。

## 參考文獻

### 英文文獻

- Abhishek D. Patange, Jegadeeshwaran R, & Nilesh Dhobale. “Milling cutler condition monitoring using machine learning approach.” IOP Conference, Series: Materials Science and Engineering. 2019.
- Alex Graves, Abdel-rahman Mohamed & Geoffrey Hinton, “Speech Recognition with Deep Recurrent Neural Networks.” pp.5, 2013.
- Alex Krizhevsky Ilya Sutskever & Geoffrey E. Hinton, “Imagenet classification with deep convolutional neural networks.” In NIPS, 2012.
- Christopher Olah, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 2015.\
- David E. Goldberg, “Genetic Algorithms in Search, Optimization and Machine Learning.” Addison-Wesley Publishing Company, 1989.
- Franci Cus, Uros Zuperl, Elizabeth Kiker & Matjaz Milfelner. “Adaptive controller design for federate maximization of machining process.” Journal of Achievements in Materials and Manufacturing Engineering. AMME, 238-240, 2006.
- ISO 3685. “Tool Life Testing with Single-Point Turning Tools.” ISO/TC 29/SC 9, 1993.
- Jone Jurkovic, Marjan Korosec & Janez Kopac, “New approach in tool wear measuring technique using CCD vision system.” International Journal of Machine Tools & Manufacture, 45, 1023–1030, 2005.
- Karali Patra, Surjya K. Pal & Kingshook Bhattacharyya, “Artificial neural network based prediction of drill flank wear from motor current signals.” vol 7, pp. 929-935, 2007.

- Milla Caroline Gomes, Lucas Costa Brito, & Marcio Bacci da Silva, "Tool wear monitoring in micronilling using Support Vector Machine with vibration and sound sensor." *Precision Engineering*, pp. 137-151, 2021.
- Shyr-Shen Yu, Shao-Wei Chu, Yung-Kuan Chan, & Chuin-Mu Wang, "Share Price Trend Prediction Using CRNN with LSTM Structure." *Smart Science*, vol. 7, no. 3, pp. 189-197, 2019.
- Sepp Hochreiter, Jürgen Schmidhuber, "Long Short-Term Memory. Computation." *Vol 9, No 8*, pp. 1735-1780, 1997.
- Stuart J. Russell & Peter Norvig, "Artificial Intelligence: A Modern Approach 3rd edition." Upper Saddle River. New Jersey: Prentice Hall. ISBN 0-13-604259-7.
- Thomas Fischer & Christopher Krauss, "Deep learning with long short-term memory networks for financial market predictions." *European Journal of Operational Research*. 654- 669, 2018.
- Urs Gasser and Virgilio A.F. Almeida, "A Layered Model for AI Governance". *IEEE Internet Computing* 21. 58-59, 2017.
- Yaan LeCun & Yoshua Bengio, "Convolutional Networks for Images, Speech, and Time-Series." Cambridge, MA: MIT Press, pp. 255–258, 1995.
- Yoshua Bengio, Patrice Simard & Paolo Frasconi, "Learning Long-term Dependencies with Gradient Descent is Difficult." *IEEE Trans. on Neural Networks*, vol. 5, pp. 157–166, 1994.
- Yusuf Altintas. "Prediction of Cutting Forces and Tool breakage in milling from feed drive current measurements." *Journal of Engineering for Industry*. ASME. 386-392, 1992

## 中文文獻

王宸威、吳振偉、許俊生(2019)。刀具很長壽：探討如何有效提高銑刀使用效能。

江陳宗(2017)。內部稽核與人工智慧，證券服務，662期，p.11-13。

何宣儀(2020)。應用人工智慧技術於圖書館紙本採購，國立臺北科技大學資訊與財金管理系碩士論文。

呂定憲(2019)。應用卷積神經網路於CNC攻牙之刀具狀態監測，國立臺灣大學機械工程學研究所學位論文。

李宗穎(2021)。應用混合神經網路模型於銷售預測 -以Rossmann Store Sales為例，國立雲林科技大學工業工程與管理系碩士論文。

李秀員(2020)。跨國家具製造業競爭與發展策略之研究，逢甲大學經營管理碩士在職學位學程碩士論文。

李承翰(2019)。具特徵選擇之獨立遞歸神經網路於軸承剩餘使用壽命預測之研究，國立臺灣科技大學工業管理系碩士論文。

李慶鴻、林俊良、劉建宏(2019)。單機設備或單元智能控制系統先進技術及加值軟體研發專案計畫，p.61。

吳政德(2017)。利用卷積神經網路預測學習情緒之研究，國立中興大學資訊管理學系所碩士論文。

林錦宏(2021)。基於向量之卷積模糊類神經網路於主軸振動錯誤診斷，國立勤益科技大學資訊工程系碩士論文。

林昶甫(2021)。精進五軸刀具磨耗離線檢測系統之量測程序與方法，國立高雄科技大學電機工程系碩士論文。

林子鈞(2020)。以深度學習方法預測大型活動對臺北捷運運量之影響，國立臺灣大學地理環境資源學研究所碩士論文。

林豈臣(2019)。在銑削加工過程之表面粗糙度預測及加工參數最佳化，中興大學機械工程學系所學位論文。

林柏昇(2018)。應用長短期記憶架構之卷積遞歸神經網路於股價預測，國立勤益科技大學資訊工程系碩士論文。

段志奇(2021)。應用長短期記憶模型與迴歸分析於鐵道運輸載客量預測分析，國立宜蘭大學多媒體網路通訊數位學習碩士在職專班碩士論文。

洪裕富(2021)。工具機刀具視覺檢測系統研究與開發，國立中正大學機械工程系研究所碩士論文。

范遠哲(2019)。以大數據分析方法建構刀具磨耗量預測模型，中原大學工業與系統工程研究所碩士論文。

袁奇煒(2020)。基於人工智慧系統應用的智慧醫療服務體系構建研究，國立臺北商業大學高階國際商業創新經營管理碩士在職專班碩士論文。

郭軒宏(2021)。應用BI-LSTM模型配合三大法人籌碼面預測台灣指數期貨之研究，國立臺北科技大學資訊與財金管理系碩士論文。

郭晉源、吳慧娜(2013)。勞動人力供需因素探討：以電子零組件製造業為例，勞動部勞動及職業安全衛生研究所。

許家豪(2020)。基於人工智慧邊緣運算之跌倒偵測方法實現，南臺科技大學電子工程系碩士論文。

許家愷(2016)。應用田口法於機器視覺銑削刀具磨耗最佳檢測環境配置參數之研究，國立勤益科技大學機械工程系碩士論文。

陳翰霖(2021)。應用考慮刀具磨耗之學習控制技術於銑削加工，國立臺灣大學機械工程學研究所碩士論文。

陳奕廷(2021)。實體零售業之數位轉型、平台策略與商業生態系標竿研究，國立臺灣大學國際企業學研究所碩士論文。

陳建立(2002)。以電腦視覺畫面鑑定車削刀片等級之技術研究，朝陽科技大學工業工程與管理系碩士班碩士論文。

梁榮濱(2006)。刀具切削壽命最佳化參數探討，建國科技大學自動化工程系暨機電光系統研究所碩士論文。

- 黃琮舜(2021)。CNC加工機刀具磨耗訊號分析及智能診斷之研究，高苑科技大學機械與自動化工程研究所碩士論文。
- 黃麟傑(2021)。使用多種 U-net 深度學習網路在 NBI 影像中偵測早期胃癌病徵區域之研究，國立雲林科技大學電機工程系碩士論文。
- 黃鑫(2021)。結合經驗模態分解與深度學習於匯率預測之研究國立臺灣科技大學工業管理系碩士論文。
- 黃冠維(2018)。利用卷積神經網路預測市區道路路況之研究，國立交通大學運輸與物流管理學系碩士論文。
- 黃子峻(2018)。深度神經網路應用於雙軸平台之熱誤差估測，國立中正大學機械工程研究所碩士論文。
- 黃門(2016)。以電流及振動訊號監測微銑削刀具磨耗之研究，國立臺灣大學機械工程學研究所碩士論文。
- 張惟翔(2021)。生產物流自動化建置與工業4.0之看法-以台灣汽車及零組件個案為例，國立臺南大學經營與管理學系科技管理碩士班碩士論文。
- 游曉珊(2017)。智慧工廠的商業模式，國立清華大學經營管理碩士在職專班碩士論文。
- 楊紫婕(2019)。應用遞歸神經網路於高頻資料之股價研究，輔仁大學統計資訊學系應用統計碩士班碩士論文。
- 廖家韻(2021)。以黃金和原油期貨預測台灣股票報酬，國立嘉義大學財務金融學系碩士論文。
- 劉旭晟(2020)。決策樹與支持向量回歸於銑削過程之刀具磨耗檢測與應用，國立勤益科技大學機械工程系碩士論文。
- 賴思汝(2021)。基於特徵融合與支持向量迴歸的短期金融時間序列預測模型，國立高雄科技大學金融資訊系碩士論文。

賴陽(2020)。鑽孔加工的刀具壽命預測研究，健行科技大學機械工程系碩士班  
碩士論文。

蕭嘉榮(2020)。人工智慧影像辨識技術應用於草莓病害檢測，國立聯合大學機  
械工程學系碩士班碩士論文。

魏新偉(2021)。運用雲端深度學習智慧化診斷系統分析鋸床鋸帶磨耗衰退性能  
之研究，國立成功大學機械工程學系碩士論文，。

藍天雄(2007)。刀具磨耗考量下之數控削參數最佳化研究，得霖學報第二十一  
期，。

蘇奕中(2019)。基於長短期記憶之卷積神經網路步態識別保全系統，國立成功  
大學工程科學系碩士論文。

Vicki Ismi Caneca(2021)。結合 PSO 及 LSTM 於預測服務處理的時間—使用急診  
室中風治療案例研究，國立臺灣科技大學工業管理系碩士論文。

Machine Tool & Accessory Magazine 工具機與零組件雜誌，2018.06 NO.101。