

# Financial index prediction based on machine learning

## 基於機器學習進行金融指數預測

組別：A89 組員：何知諺 指導教授：翁詠祿

### Abstract

近年來機器學習興起，應用層面由影像處理、醫療用途到金融產業皆能見其蹤影。本專題基於機器學習模型進行金融指數預測，旨在設計一套「股價預測系統」，其功能包含讀取股票資訊、股價時間軸切割、資料預處理、股票預測及資料視覺化。

以精準預測股價為目標，試圖解釋不同機器學習模型預測結果的差異。取得股票歷史數據後透過設計好的系統切割時間序列，接著使用資料科學及統計學理論進行資料預處理，再將經過前處理的資料送進不同的機器學習模型如：Polynomial regression、XGBoost、LSTM，觀察訓練後的模型是否能順利測試資料。模型得依據過去五天的股票資訊，預測後一天股價數值，最後使用MSE 評估預測數值和實際股價的距離。實驗結果顯示，機器學習模型確實能準確預測未來股價。期望研究成果最終能應用於交易市場，提供強度更高的股票交易策略。

### Introduction

本專題嘗試使用機器學習預測股票市場走向，由財金平台 Investing.com 取得金融歷史數據，使用 polynomial regression、XGBoost regression、LSTM regression 進行迴歸分析，並透過 Python 中相關 package 完成資料預處理，期望能以過去資訊精準畫出股票未來走勢圖，將研究成果運用於交易程式。

## 一、系統設計

### 1.1 資料愈處理

#### A.標準化(Standardization)

建立機器學習模型時，會使用梯度下降法(Gradient Descent)計算最佳解，若梯度等高線為窄長型將造成收斂緩慢甚至無法收斂的情形。透過 feature 標準化，將梯度等高線圖轉換成同心圓，得增加收斂

速度，大幅降低機器學習模型訓練時間。此外，各個 feature 間的數值大小範圍不同，造成訓練時無意間提高比重，透過標準化資料，此問題得以解決，更能提高模型表現。

## B. Polynomial Features transform

許多機器學習模型如 support vector machine、logistic regression、Linear regression 皆為線性，無法擬合非線性資料。顯然地，股票數據並非線性，為了讓線性模型得以使用，其一做法是將 feature 投影到更高維度，使其呈線性分布，或是加入各個 feature 的高次方項作為新的 feature。

## 1.2 機器學習模型

### A. polynomial regression

線性模型進行的預測方式，是計算輸入特徵的加權總合，再加上偏差項(bias)的常數。將原特徵項的高次項加入，作為新的特徵項，即為多項式迴歸。模型訓練過程採用梯度下降(Gradient Decent)，它可以幫助模型找到最佳參數，以線性迴歸為例，透過 training data 進行梯度下降，模型得找出參數向量的最佳數值。最後透使用 MSE 評估模型對 test data 的表現。

### B. XGBoost

Boost 泛指將弱學習模型組合成強學習模型的方法，本次使用的 XGBoost(Extreme Gradient Boosting)，組合多棵迴歸樹決定 sample 最後預測結果，本演算法由 C++ 撰寫因此速度快。每棵迴歸樹的節點由 sample 的 feature 決定，葉子則是 sample 在這棵樹得到的分數，最後將每一棵樹的分數相加。

### C. LSTM

深度學習模型—RNN(Recurrent Neural Network)，在處理時間序列資料時，會遺失先前的資訊，為了解決這個問題，有了 LSTM(Long Short Term Memory networks)長短期記憶模型的提出。在 LSTM 細胞中，input gate 和 forget gate 皆會根據當前輸入和先前狀態學習辨識重要輸入，並且將其存入長期狀態，以取得更多脈絡。本專題目標藉機器學習分析過往股票資訊與預測未來走勢，LSTM 是當前分析時間序列資料常見的深度學習模型，非常值得進行實作並予以探討。

## 二、實驗結果

取得股票資訊後進行資料處理，基於 polynomial regression、XGBoost、LSTM 三種 model 對元大電子科技基金、中華電信、S&P500 三檔股票進行預測並計算 test data MSE。

表 1 模型預測結果

Model \ 股票	元大電子科技基金	中華電信	S&P500
polynomial regression	0.01073	0.02177	0.00497
XGBoost	0.05043	0.02795	0.09414
LSTM	0.01931	0.02168	0.03878

模型對三檔股票的預測結果一致，polynomial regression 可得到最佳結果，最為適合分析股票類別的線圖。如同預期，雖然 XGboost 在分類標籤方面的應用能有絕佳的表現，但在迴歸分析中表現並非突出。LSTM 亦能有效 fit 模型，相對於線性迴歸單純的數學式，它的運算更為複雜，模型可改良的空間更多，未來的研究得持續優化。各模型表現結果可能也與資料預處理的方式有所關聯。

## 三、研究結果

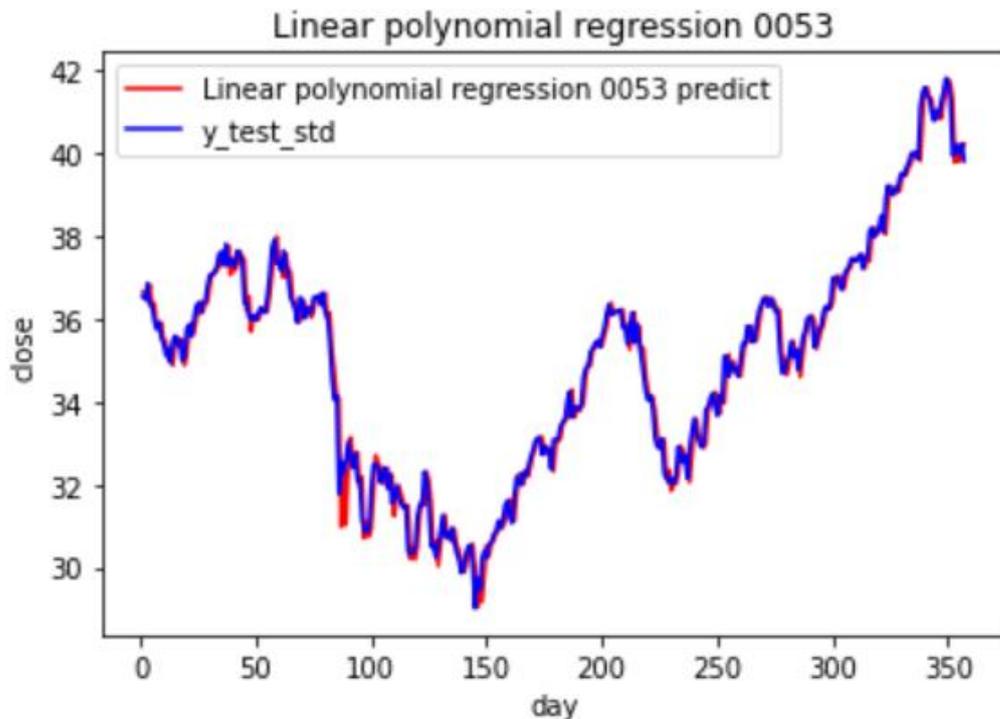


圖 1 polynomial regression 預測元大電子基金股價走勢

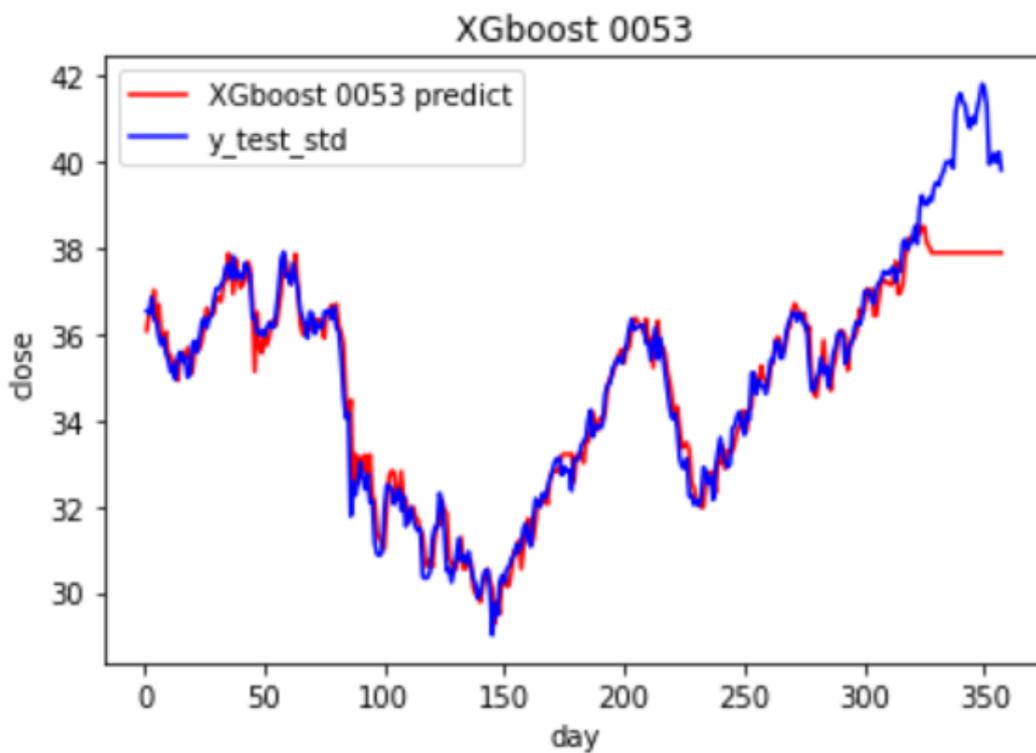


圖 2 XGBoost 預測元大電子基金股價走勢

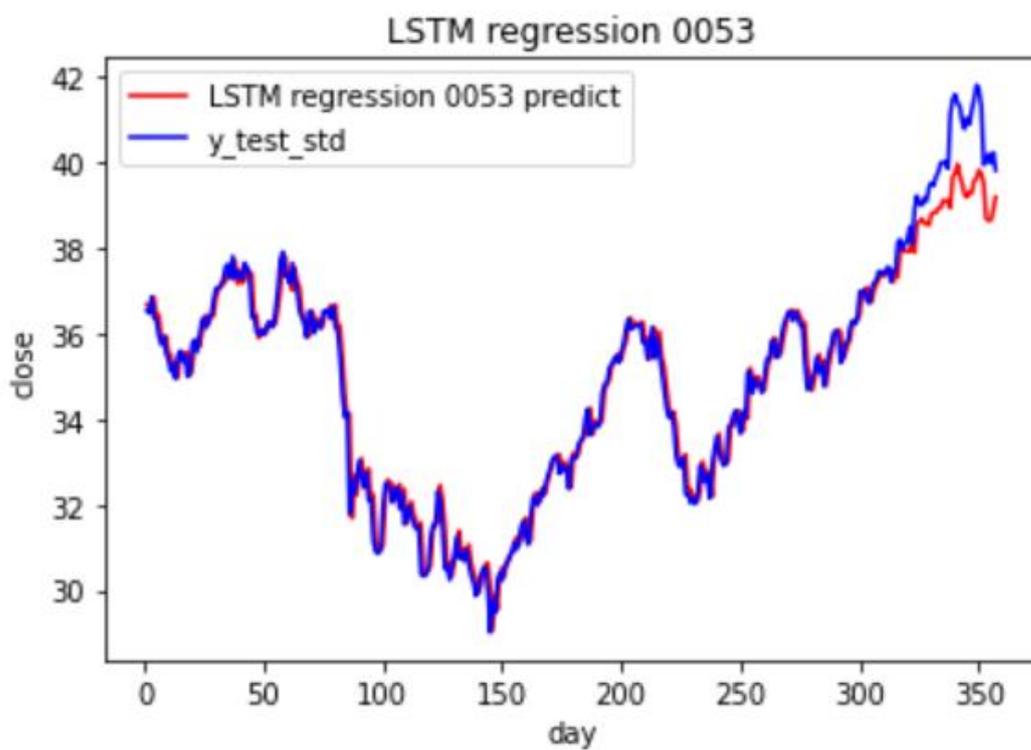


圖 3 LSTM 預測元大電子基金股價走勢

## 心得

為期一年的專題實作，使我習得多項新知。起初，看著國內外開放式課程自學 python、機器學習、股票知識而後進行整合，過程中時常遇上困難，卻因此提升解決問題的能力，尤其如何善用網路資源，並在龐大的資訊中理出思緒、汲取所需。也因為這些經驗，我得以淺嚐研究生的生活，體驗在課業中同時進行研究並且發現問題、解決問題。對於學長和教授撥冗給予專題指導不勝感激，期許自己未來在特定領域有所成後，亦能如此提攜後進。