



# 運用機器學習法預測經濟成長率之初探

蔡佩珍\*

壹、前言

參、研究方法

貳、文獻回顧

肆、結論與建議

## 摘 要

伴隨經濟日益複雜，傳統計量對經濟成長率預測之績效恐受影響，為使政府確實掌握經濟動向，本研究針對 OECD 研究報告（2020）提出的自適應樹演算法進行探討，其兩大結論如下：

- 一、自適應樹演算法在預測短期經濟成長率部分，表現相當良好，且與 OECD 指標模型之預測結果大致相同。
- 二、相對於常見的隨機森林、梯度增強樹兩項機器學習法，自適應樹演算法之預測績效明顯為佳。

目前國內運用機器學習法預測經濟成長率之作法尚未成熟，對此，本文除建議可參照前述 OECD 所提的自適應樹演算法外，亦提出下列建議：

- 一、為使預測結果更合理化，運用任一機器學習法時，須搭配相關的統計推論。
- 二、為提升機器學習模型結果之準確性，建議使用多種機器學習方法加以驗證。

\* 作者為經濟發展處專員。本文係筆者個人觀點，不代表國發會意見，若有疏漏之處當屬筆者之責。

## An Exploratory Research on Machine Learning to Predict Economic Growth Rate

Pei-Chen Tsai

*Officer*

*Economic Development Department, NDC*

### Abstract

As the economic environment becomes more and more complex, the accuracy of traditional measurement on economic growth rate forecasts may decrease. In this study we analyze the adaptive tree that is a new approach to economic forecasting proposed in the OECD research report ( 2020 ). Main conclusions are as follows:

1. The adaptive Trees forecast perform well in the short run, and the forecast results broadly in line with the OECD's Indicator Model.
2. The performance of Adaptive Trees generally performs better than Random Forests and Gradient Boosted Trees.

At present, the use of machine learning methods to predict economic growth rates is not yet mature in Taiwan. For this reason, we make the following suggestions:

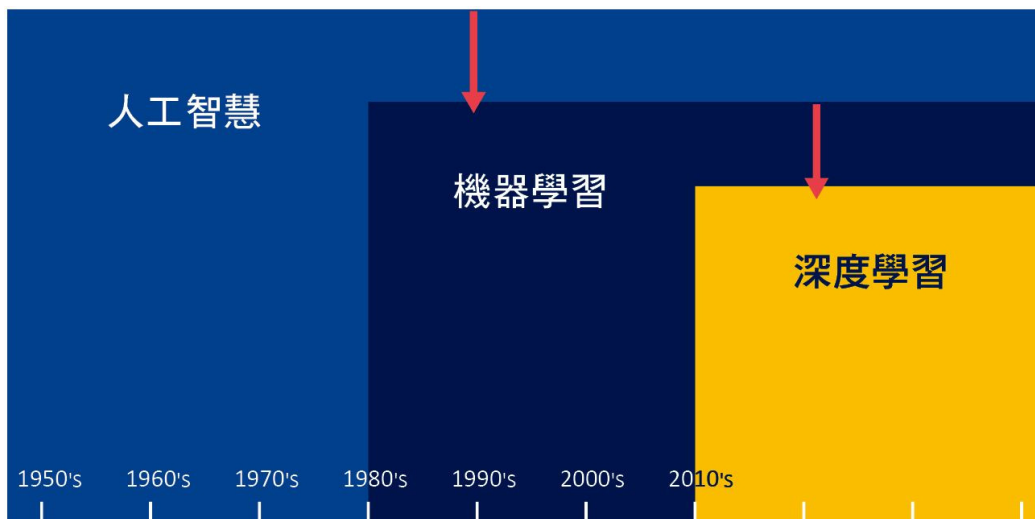
1. To make the prediction results more reasonable, using the machine learning methods to predict economic indicators should be accompanied by relevant statistical inferences simultaneously.
2. To improve the accuracy of the machine learning model results, it is necessary to use a variety of machine learning methods to verify.



## 壹、前言

### 一、機器學習之背景說明

在論述本文主題—機器學習法之前，先說明人工智慧、機器學習與深度學習三者關係：機器學習為一種實現人工智慧的方法，深度學習則是一種實現機器學習的技術；換而言之，深度學習為機器學習的一個子集，機器學習是人工智慧的一個子集（如圖 1）。



資料來源：科學月刊 2018 年 4 月號 580 期。

圖 1 人工智慧、機器學習與深度學習之關係圖

早於 1950 年代即出現人工智慧之概念，發展至 1980 年代時，因科技快速發展，人們蒐集數據更為簡易，且資料格式更多元化，即出現了所謂的大數據，加以開放源碼（Open Sources）的蓬勃發展，致使計算的軟體成本降低，故機器學習的方法開始普及。

演變至今，機器學習已發展成一門多領域交叉科學，<sup>1</sup>並廣泛應用於資料探勘、搜尋引擎、醫學診斷、金融市場分析、機器人等多方面領域，甚至是運用在經濟學等社會科學上。

## 二、研究動機

### (一) 伴隨經濟日益複雜，傳統計量方法已漸失靈

面臨目前日益頻繁且錯綜複雜之交流互動，若出現非線性（經濟變數多重相互作用或不連續性）、未知的結構性變化（經濟變數之機率分配發生轉變）等現象，傳統線性模型則可能無法用來勾勒全部的經濟情境，因而使其經濟預測能力趨弱。此外，70年代以來，面對極大量的數據，若依照傳統的統計假設去建立計量經濟模型，可能就會面臨挑戰，例如：在巨量資料之下，不論以何種機率分配進行假設，可能都會發現有不太合宜的問題；其次，因實證資料數量大增，計量經濟學中之異質性與內生性兩問題，嚴重程度也會因而加劇。

### (二) 機器學習在經濟預測中的應用與局限

近期開始普及的機器學習法，已提供了相關工具來應對前述挑戰。機器學習法的強大之處與特徵，在於它的分類演算法對型態（patterns）之預測能力（Bishop, 2009）。藉由機器學習相關演算法來建構經濟模型，不須以先驗知識為基礎條件，且面對大量且多樣化的非結構化資料，可透過機器學習之統計學習技術（Statistical Learning Techniques），自動找出資料中隱藏的規則與關聯性，並可同時使用交叉驗證來防止過度配適（over-fit）等。

<sup>1</sup> 指的是兩個或多個學科相互合作，在同一個目標下進行的學術活動。



再進一步探討機器學習演算法，可發現該方法和統計學有很大的重疊，多數的機器學習法都存有一個類似的統計架構。然而，兩者最大的區別，在於統計計量是以嚴格的理論假設為立基點，再依據所設定的假設進行統計推論。因此，假若這些假設不正確，最後結果亦會存有問題。而機器學習的方式則在於將少量相關資料的知識轉化為大量的知識，且透過演算過程中的知識不斷累積，對未來的預測就會越準確。因此，機器學習演算的核心特徵就是遞迴（iteration），並再藉由設定限制條件，使整個系統為之優化（optimization）。

然而，運用機器學習法進行經濟預測，仍然還是會存有一定的局限性。第一，該方法樣本內（in-sample）雖然具有完美的預測效果，但未必樣本外（out-of-sample）亦具有好的預測能力。實際上，機器學習法往往會出現過度配適的問題，致使預測結果有偏誤。其次，預測模型的穩定性仍待進一步驗證。在機器學習法中，會將所有可能相關的因素都納入考慮，包括領域適應、轉移學習等，再藉由搜尋尋求考慮因素與應變數之間的所有關聯性，以得到最佳的模型來預測應變數。然而，解釋變數和應變數之間的某些聯繫可能會在不同時空背景下發生變化。第三，使用機器學習預測模型時，可能會發生人為主觀操縱的現象。Bjrkegren & Grissen（2017）指出，在一個使用手機數據預測借款者信用評分之模型中，借款者可能會對貸款提供者感興趣的一些特徵變量進行人為調整，致使預測結果可能與現實不符。

### （三）結合計量經濟學與機器學習法，提升整體預測能力

計量經濟學與機器學習法並非對立，近年來已有許多經濟學家改變傳統經濟學的研究方式，致力於將兩者融合，藉此解決傳

統計量方法所不能解決的問題，並得以確認變數間之因果關係，甚至對處置效果（treatment effects）進行估計等，消除機器學習法的部分侷限。


檢視同時運用機器學習法與計量經濟學兩者之相關文獻後，可發現最常見被用來預測經濟成長的機器學習演算法包括隨機森林（Random Forest）、梯度提升樹（Gradient Boosting Decision Tree, GBDT）、支援向量機（Support Vector Machine, SVM）。此外，甚至是人工智慧機器學習領域中的人工類神經網絡（artificial neural network, ANN），以及極限學習機（extreme learning machine, ELM）等方法也都曾被運用在經濟預測上。而這些相關文獻之研究結果均顯示，結合「預測」與「因果推論」，對經濟成長預測的準確性確實有提升之效果。對此，本文將在第貳章文獻回顧中再做更詳細說明。

#### （四）OECD 近期另再提出新方法

值得關注的是，OECD 在 2020 年的研究報告提出了一種新的演算法，即自適應樹（Adaptive Trees），且其預測效果甚至優於前述幾種常見的方法。為精進我國預測經濟成長之能力，本文將於第參章對此方法進行詳細說明與探討。

### 三、本文架構

以下第貳章先行回顧近年來，各界運用機器學習相關方法，預測經濟成長之文獻；第參章則概述 OECD 2020 年研究報告所提出的新機器學習方法，即自適應數演算法；最後，第肆章為結論與建議。



## 貳、文獻回顧

機器學習法在預測 GDP 及其成長率表現方面，Chang (2018) 運用韓國 2000 年第 2 季至 2017 年第 2 季，共 114 個總體變數，內容涵蓋貿易、工業生產、貨幣、利率、匯率等 5 大類，利用兩階段方式萃取重要經濟變數。具體作法係先利用迴歸決策樹 (regression tree) 的方法將變數排序，<sup>2</sup>再透過隨機森林 (random forest) 挑選重要變數，<sup>3</sup>最後再針對經濟成長季增年率，進行預測績效的評比。該實證結果顯示，在均方根誤差 (MSE) 部分，兩階段方式的數值相較於自我迴歸模型 (AR (4)) 來的小，顯示透過機器學習方法可改進 GDP 的預測能力。其次，Gogas et al. (2015) 以殖利率曲線預測美國實質 GDP 衰退，結果顯示相較於 Logit 迴歸模型或是 Probit 迴歸模型，使用支援向量機 (Support Vector Machine, SVM) 方法之預測正確性更高。<sup>4</sup>此外，Feng and Zhang (2014) 使用人工類神經網絡 (artificial neural network, ANN) 方法和灰色預測 GM (1,1) 模型預測中國經濟成長率，<sup>5</sup>結果顯示人工類神經網絡方法之預測誤差小於 GM (1,1)。

<sup>2</sup> 決策樹分為兩類：分類決策樹與迴歸決策樹，前者可用於處理離散型資料，後者可用於處理連續型資料。

<sup>3</sup> 在機器學習中，隨機森林是一個包含多個決策樹的分類器，並且其輸出的類別是由個別樹輸出的類別的眾數而定。

<sup>4</sup> SVM 是一種監督式學習的方法，其概念係找出一個超平面 (hyperplane)，使之能將兩個不同的集合分開。以二維平面為例，希冀能找出一條線，致使兩種不同的點分開，而且還希望這條線距離這兩個集合的邊界越大越好。

<sup>5</sup> ANN 係一種模仿生物神經網路的結構及功能所產生的數學模型，用於對函式進行評估或近似運算，是目前人工智慧最常使用的一種方法。另，灰色預測法是一種對含有不確定因素的系統進行預測的方法，其基本概念是用原始資料組成原始序列 (0)，經累加生成法生成序列 (1)，藉此弱化原始資料的隨機性，使其呈現出較為明顯的特徵規律，最後再對生成變換後的序列 (1) 建立微分方程型的模型，即為 GM 模型。GM (1,1) 模型表示 1 階、1 個變數的微分方程模型。

另，機器學習法運用在預測外貿表現方面，Marijn A. Bolhuis and Brett Rayner (2020) 透過結合隨機森林、梯度提升樹，以及支援向量機等機器學習法的方式預測輸出實質成長，發現其方法可降低預測誤差；其中，以土耳其為例，相較傳統 OLS 模型，前揭方法可將預測誤差至少降低 30%。此外，Sokolov-Mladenović et al. (2016) 以進出口貿易值預測歐盟 28 個國家經濟成長率，實證結果顯示使用人工類神經網絡方法結合極限學習機 (extreme learning machine, ELM) 之預測準確率佳。<sup>6</sup>

## 參、研究方法

因應近年來日益繁雜的經濟環境，為確實掌握景氣動向，OECD 2020 年之研究報告提出了一種專為預測經濟成長的機器學習方法，即自適應樹 (Adaptive Trees)。該方法最大的特色在於可以透過給予較難預測的觀察資料較大的權重，藉此得以檢測出經濟體系中可能存在的結構性現象。此外，亦可透過決策樹的概念捕捉非線性情境，並運用特徵工程與特徵選擇來判定轉折點。

### 一、資料來源

本研究的對象包括美國、德國、日本、法國、義大利及英國等 6 國。其次，有關各個國家所採用的變數，則是完全仿照 OECD 運用指標模型預測前述 6 國經濟成長率時，所使用的變數 (表 1)；該作法之主要目的是為了要便於比較自適應樹演算法與指標模型兩者的預測表現。最後，樣本訓練期間為 2007 年第 1 季至 2017 年第 1 季。

<sup>6</sup> ELM 又名超限學習機，為人工智慧機器學習領域中的一種人工神經網絡模型，是一種求解單隱層前饋神經網絡的學習算法。





表 1 各國之研究變數

美國	德國	日本
工業生產 消費 就業 建築 存貨 出口 PMI 房屋許可證 房屋價格	工業生產 商業調查預期 出口 製造業訂單 商業調查 PMI (製造業) PMI (服務業) 消費者信心 職位空缺數	工業生產 存貨率 生活支出 求職比例 小企業情緒銷售 商業情緒財務狀況 全國企業短期經濟觀測調查 PMI
法國	義大利	英國
工業生產 家庭消費 輸出趨勢 商業調查 訂單與需求 家庭信心	工業生產 汽車登記 PMI (製造業) 家庭信心 PMI (服務業)	工業生產 零售銷售 房屋價格 商業信心 經濟情緒指標 PMI

資料來源：Nicolas Woloszko, OECD (2020)。

## 二、方法概述

自適應樹演算法 (adaptive trees algorithms) 係專為總體經濟預測所設計的機器學習方法，其主要目的係為了解決傳統預測模型所無法克服的非線性、結構性變化及轉折點等三大問題。具體作法包括：運用迴歸決策樹捕捉非線性資料；對於越難預測的觀察值，給予越大的權重，以解決結構性改變；以及透過特徵工程、特徵選擇兩步驟，偵測出經濟轉折點。詳細步驟說明如下：

### (一) 資料前處理

一般而言，在將研究資料輸入機器學習模型前，需對資料先做一些前置處理，以提升模型的預測效果。重點說明如下：

### 1. 調整統計數據的落後性，並標準化

統計數據的發布通常存有落後性之問題，以工業生產指數為例，當月才發布上個月數字。然而，當一研究使用多項統計數據，其落後期間假若不同，即會出現邊緣參差不齊（ragged-edge）的現象。為解決此問題，在一開始整理資料時，就須全面檢視數據的發布時間，進行位移對齊，以確保資料具時間一致性。其次，再將資料進行標準化，而最簡單的標準化方式，即設定平均值為 0，標準差為 1。

### 2. 預測插補（Predictive Interpolation）

經濟成長率通常係按季發布，因此若要預測 GDP 成長率，僅能透過具同時性或領先性，且頻率較高之經濟指標才能為之。然而，當使用的變數其資料頻率不同時，若直接將高頻率資料加總成低頻率資料，其作法雖然簡單，但可能卻因而損失部分資訊，甚至改變了資料之生成機制（generating mechanism）。文獻上，對於如何藉由較高頻率資料對較低頻率資料進行預測或即時預報一事，已提出了混合數據抽樣（mixed-data sampling, MIDAS）模型、混合頻率 VARs（mixed frequency VAR, MF-VAR）模型，以及混合頻率因子模型等方法。

自適應樹演算法中，對於預測差補部分，則是透過既有的資料來進行訓練和學習，從資料中找出關聯性和識別出樣式，藉此得到每月的 GDP 成長率。其具體做法是同時運用 XGBoost（Extreme Gradient Boosting）、特徵選擇（Feature Selection）來建構模型，並再以 Gridsearch 的方法選出最佳參數，優化模型。以下將接續說明特徵工程（Feature Engineering）與特徵選擇。



### 3. 特徵工程 ( Feature Engineering )

特徵工程已成為機器學習所有演算法中，處理時間序列資料之標準流程 ( Fulcher, 2018; Christ, Kempa-Liehr and Feindt, 2016; Christ et al., 2018 )。

該流程主要概念係對原始數列資料進行一系列的工程處理，提取其特徵，如最小值、最大值、標準差等，以作為輸入演算法與模型的依據。實際上，特徵工程主要用途為剔除原始資料中之雜質和冗餘，設計更高效的特徵，以描述求解問題與預測模型之間的關聯性。

### 4. 特徵選擇 ( Feature selection )

透過特徵選擇，降低特徵空間 ( feature space ) 維度 ( 即特徵數量 )，不僅能減少機器學習演算法運算時的複雜度，亦可提高評估效能。( Guyon & Elisseeff, 2003 ; Chandrashekar & Sahin, 2014; Cai et al., 2018 )。文獻上，特徵選擇的方法有許多種，自適應樹演算法係藉由 XGBoost 進行特徵之重要性評估。

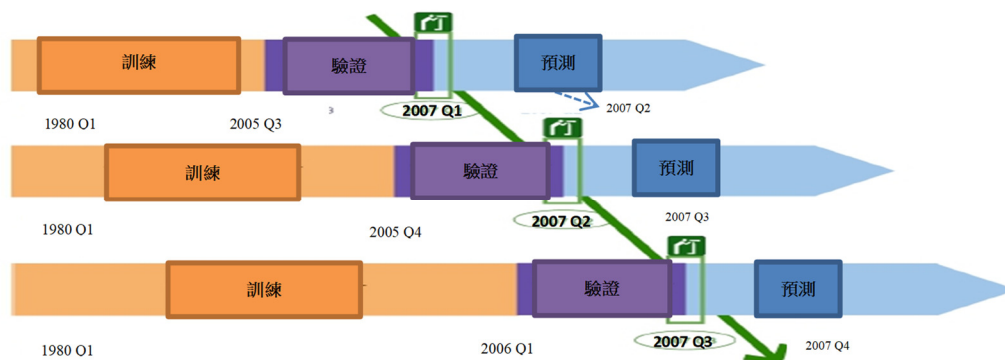
## (二) 訓練與預測

此部分主要係運用 XGBoost，流程大致可區分為訓練 ( Training )、驗證 ( Validation )、預測 ( Predict ) 三部分。其中，訓練係指用部分既有資料建構模型；驗證部分，則是藉由樣本內其他資料，檢視模型之預測表現如何，並同時調整超參數，使模型處於最好的狀態；最後，再進行樣本外預測 ( 如圖 2 )。詳細步驟說明如下：

#### 1. 使用 XGBoost 建模，藉此捕捉非線性資料的結構

自適應樹演算法採用 XGBoost 建模之主要目的，係為了要藉

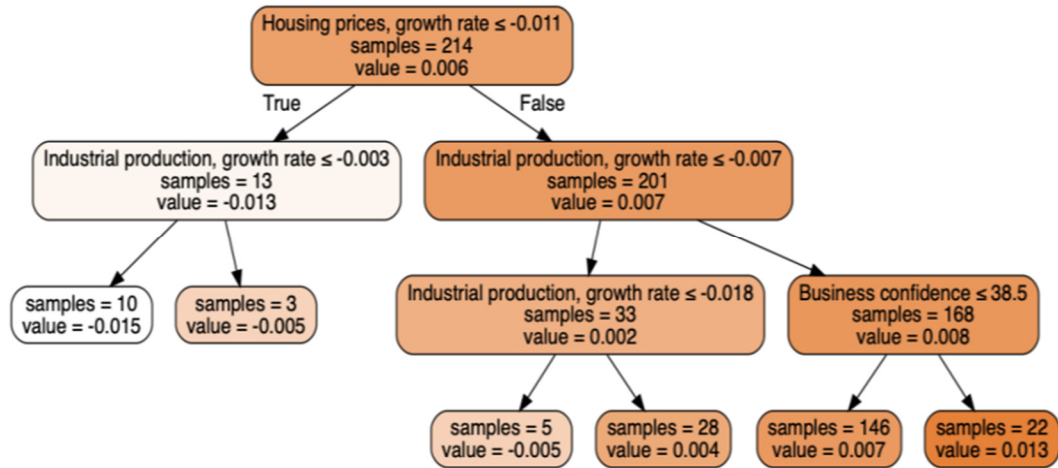
由決策樹之方法來捕捉非線性資料的結構。XGBoost 是以梯度提升樹 (GBDT) 為基礎所改良與延伸的演算法，簡單來說，就是以決策樹為基礎的演算法，屬監督式學習的範疇，其優點包括：容易被理解且建構，故可以有效率地並行處理及驗證資料；其次，因採用正規化的方法，透過限制擬合過程，可避免過度配適之問題；以及能處理涵蓋缺失資料之數據。



資料來源：Nicolas Woloszko, OECD (2019)。

圖 2 訓練與預測之示意圖

本文採用的決策樹為可處理連續型資料的迴歸決策樹 (regression tree)，其主要概念是每個迴歸決策樹對應著輸入空間 (即特徵空間) 的一個劃分，以及在劃分單元上的輸出值。假如我們有  $n$  個特徵，每個特徵有  $S_i (i \in (1, n))$  個輸出值，那我們觀察所有特徵，嘗試用該特徵所有輸出值，對空間進行劃分，直到取到特徵  $j$  的取值  $S_j$ ，使得損失函式最小，這樣就得到了一個劃分點。換言之，在各個節點上，演算法會選擇分割變數與分岔點，以最小化次群組 GDP 成長率之變異數 (如圖 3 所示)。



資料來源：Nicolas Woloszko, OECD (2020)。

圖 3 迴歸決策樹的示意圖

## 2. 採用 Grid Search 調整超參數 ( hyperparameters )

XGBoost 演算法中涉及許多需要微調的超參數，本文所採用的調整方法為窮舉法 ( Grid Search )，即直接指定超參數的組合範圍，每一組參數都訓練完成，再根據驗證集的結果選擇最佳參數。

## 3. 集成學習 ( ensemble learning )

由於單一決策樹的變異數較大，預測能力不穩定，故自適應樹演算法搭配集成學習方法，藉此綜合多顆決策樹的預測結果，降低單一決策樹的變異度或不穩定性，也避免過度配適的問題。

## 4. 自適應提升 ( Adaptive Boosting，縮寫 AdaBoost )

依據個體學習器的生成方式，目前集成學習方法大致可分為 Bagging、Boosting 兩大類；<sup>7</sup>其中，AdaBoost 是 Boosting 發展到

<sup>7</sup> Boosting 係個體學習器間存在依賴關係，必須串行生成的序列化方法；Bagging 係個體學習器間不存在強依賴關係，可同時生成的並行化方法。

後來最具代表性的一類。在本文提出的自適應樹演算法中，即是採用 AdaBoost 算法。

AdaBoost 係由 Yoav Freund 和 Robert Schapire (1995) 所提出的，其概念是將多個弱分類器組合成強分類器，而實際作法是在每一輪訓練中加入一個新的弱分類器，並賦予每一個訓練樣本一個權重，<sup>8</sup>該權重的數值係代表某一訓練樣本被某個分類器選入訓練集之機率。當某個樣本點已被準確分類，在建構下一個訓練集時，其被選中之機率則就會被調降；反之，若某個樣本點沒有被準確的分類，則它的權重則會被調高。經過一連串的疊代訓練，直到錯誤率降至預定目標或達到指定的最大疊代次數。值得提出的是，自適應樹演算法就是透過這種對於越難預測的觀察值，給予越大權重之方法，解決結構性的問題。

然而，儘管 AdaBoost 算法中使用的分類器可能相對較弱（例如可能出現偏大的錯誤率），但只要它的分類效果比隨機下的結果好，就可改善最終模型結果。加以，相對於大多數其它集成學習方法，AdaBoost 不容易出現過度配適現象。


## 肆、結論與建議

### 一、實證結論

運用自適應樹演算法的優勢，即解決傳統計量無法克服的非線性、結構性轉變、轉折點等三大問題，對美、英、德、法、義、日六國進行虛擬即時的模擬，<sup>9</sup>預測未來 3 至 12 個月的 GDP 成長率。實證結果顯示（詳附件一）：

<sup>8</sup> 本文的權重設定為  $w(t) = e^{-\gamma(t/N-1)}$ 。

<sup>9</sup> 進行即時預測時，若有部分資料缺漏，對於遺漏資料的處理方法，在學術界即稱之為虛擬即時（pseudo real-time）模擬。



- (一) 短期預測部分（包含對未來 3 或 6 個月預測），自適應樹演算法的預測表現不錯，且與 OECD 指標模型之預測績效相當。若觀察各國表現，相較 OECD 的指標模型，英國若採用自適應樹演算法預測，其預測績效較佳；法國、日本與美國之結果相當；但義大利及德國則略差。
- (二) 長期預測部分（包含對未來 1 或 2 年預測），自適應樹演算法的預測績效雖較傳統 AR ( 1 ) 模型略好，並改善幅度偏小，隱含該方法僅較適用於短期預測。
- (三) 觀察所有預測結果，自適應樹演算法之預測績效均明顯優於常見的隨機森林、梯度增強樹兩項演算法。

## 二、政策建議

運用機器學習法預測總體指標係近年興起的方法，就我國而言，相關方法尚未成熟及普遍，本文僅先就 OECD ( 2020 ) 一文進行初探，未來將會再進一步把我國資料應用在機器學習等相關模型上，並進行比較研析。以下僅先提供幾點初步建議：

- (一) 依據本研究結果，機器學習法確實有助於提升預測績效，故建議政府未來可嘗試運用相關方法預測國內經濟動向，如本文所提的自適應樹演算法。
- (二) 機器學習法著重於預測績效，但缺乏統計學之因果推論。為使預測結果具合理性，建議政府未來在運用機器學習演算法預測經濟成長時，須同步搭配統計方法，才能確實掌握未來景氣動向。
- (三) 考量機器學習演算法皆係以黑箱 ( black box ) 模式運作，故在運用此方法預測經濟時，建議應再另外使用其他機器學習方法以做比較，藉此提升該預測模型之準確性。

## 參考文獻

1. 科學月刊，2018年4月號580期。
2. Bishop Christopher M. (2009), "Pattern Recognition and Machine Learning". Springer-Verlag.
3. Björkegren, D., & Grissen, D. (2017), "Behavior Revealed in Mobile Phone Usage Predicts Loan Repayment".
4. Cai, J. et al. (2018), "Feature selection in machine learning: A new perspective", *Neurocomputing*.
5. Chandrashekar, G. and F. Sahin (2014), "A survey on feature selection methods", *Computers and Electrical Engineering*.
6. Chang, Y. (2018), "An approach to improve the predictive power of GDP forecasts using big data analysis methods", Working Paper at 2018 BOK Workshop.
7. Christ, M. et al. (2018), "Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package)", *Neurocomputing*, Vol. 307, pp. 72-77.
8. Christ, M., A. Kempa-Liehr and M. Feindt (2016), "Distributed and parallel time series feature extraction for industrial big data applications", (accessed on 6 April 2019).
9. Feng L, Zhang J (2014), "Application of artificial neural networks in tendency forecasting of economic growth". *Econ Model* 40:76–80.
10. Fulcher, B. (2018), "Feature-Based Time-Series Analysis", in *Feature Engineering for Machine Learning and Data Analytics*, CRC Press, <http://dx.doi.org/10.1201/9781315181080-4>.
11. Gogas, P. et al. (2015), "Yield Curve and Recession Forecasting in a Machine Learning Framework", *Computational Economics*.
12. Guyon, I. and A. Elisseeff (2003), "An Introduction to Variable and Feature Selection", *Journal of Machine Learning Research*, Vol. 3/Mar, pp. 1157-1182, <http://www.jmlr.org/papers/v3/guyon03a.html> (accessed on 6 April 2019).
13. Marijn A. Bolhuis and Brett Rayner (2020), "Deus ex Machina? A Framework for Macro Forecasting with Machine Learning1".
14. Nicolas Woloszko (2020), "Adaptive Trees: a new approach to economic forecasting", OECD Economics Department Working Papers No. 1593.
15. Nicolas Woloszko (2019), "ECONOMIC MODELLING & MACHINE LEARNING, A PROOF OF CONCEPT", NAEC – APRIL 16 2019。





16. Sokolov-Mladenović et al. (2016), “Economic growth forecasting by artificial neural network with extreme learning machine based on trade, import and export parameters”. *Computers in Human Behavior*, Volume 65, December 2016, Pages 43-45.
17. Yoav Freund and Robert Schapire (1995), “A Decision-Theoretic Generalization of on-Line Learning and an Application to Boosting”. 1995. CiteSeerX:10.1.1.56.9855.

附件一、實證結果綜整表（樣本訓練期間：2007年Q1-2017年Q1）

國家	預測時點	自適應樹	指標模型	隨機森林	梯度增強樹
英國	未來3個月	0.63	0.96	1.22	1.37
英國	未來6個月	0.83	1.06	1.37	1.48
英國	未來1年	0.97		1.23	1.31
英國	未來2年	1.12		1.08	1.16
美國	未來3個月	0.72	0.76	0.99	0.94
美國	未來6個月	0.89	0.89	1.02	1.38
美國	未來1年	0.94		0.97	1.08
美國	未來2年	0.99		1.12	1.24
法國	未來3個月	0.72	0.70	1.00	1.02
法國	未來6個月	0.82	0.81	1.00	1.08
法國	未來1年	0.93		0.85	0.87
法國	未來2年	0.89		0.86	0.83
日本	未來3個月	0.93	0.90	1.13	1.16
日本	未來6個月	0.98	1.08	1.04	1.08
日本	未來1年	0.97			
日本	未來2年	1.02			
德國	未來3個月	0.81	0.65	1.15	1.21
德國	未來6個月	0.97	0.97	1.13	1.13
德國	未來1年	1.10		0.99	1.46
德國	未來2年	0.88			
義大利	未來3個月	0.69	0.62	1.01	1.12
義大利	未來6個月	0.90	0.80	0.92	1.04
義大利	未來1年	0.99		1.05	1.52
義大利	未來2年	1.00			

註：自適應樹、指標模型、隨機森林、梯度增強樹4欄數字，係其各自方法之均方根誤差（MSE），相對於AR（1）模型之均方根誤差（MSE）的比例。若該比例越小，表示該方法之預測績效，相對於AR（1）模型越好。

資料來源：Nicolas Woloszko, OECD（2020）。