

運用機器學習方法認定景氣轉折點^{*}

廖 銘 傳^{**}

壹、前言
貳、文獻回顧
參、研究方法

肆、實證分析
伍、結論與建議

摘 要

本研究使用 Giusto and Piger (2017) 的學習向量法，依據臺灣景氣循環特性調整認定程序，即時認定景氣轉折點。實證分析顯示，運用學習向量法認定轉折點，具有較佳的即時性，僅落後 2 個月至 11 個月，即可認定該次或相近的景氣轉折點，有助於政府即時掌握景氣趨勢。

學習向量法的即時認定程序中，若景氣狀態改變未滿 5 個月，則暫不認定轉折點，能減少誤判轉折點的可能性。相較於 Bry and Boschan (1971)、Harding and Pagan (2002) 方法，學習向量法的認定誤差較小，且傾向認定較少的小循環。

不同的初始值及參數設定，經常會影響機器學習方法分析結果。本研究的學習向量法使用簡單隨機抽樣，執行 1,000 次不同初始值的轉折點認定程序，能避免初始值選擇問題；調整學習向量法及其延伸、變數落後期、編碼向量修正率、門檻值的參數設定值，結果顯示不同參數設定對轉折點認定能力影響不大，學習向量法具有相當的穩健性。

^{*} 本文參加國發會 2019 年研究發展作品評選，榮獲經濟財金政策及法制類甲等獎。

^{**} 作者為經濟發展處科員。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。



Using Machine Learning Method to Identify Taiwan's Business Cycle Turning Points

Ming-Chuan Liao

Officer

Economic Development Department, NDC

Abstract

In this study, we adjust the Learning Vector Quantization (LVQ) method of Giusto and Piger (2017) to identify turning points based on Taiwan's business cycle characteristics. Empirical analysis shows that the use of the LVQ method to identify turning points has better timeliness. We can identify turning points with a lag between 2 and 11 months, which will help the government monitor economic situation in real time.

In our identification procedure of LVQ method, if expansions or contractions change less than 5 months, the turning point will not be identified. The adjustment reduces the possibility of erroneous judgment. Compared with the methods of Bry and Boschan (1971) and Harding and Pagan (2002), the identification error of the LVQ method is smaller.

Different initial values and parameter settings often affect the analysis results of machine learning methods. We use simple random sampling for 1,000 different initial values to execute the turning points identification procedure, which can avoid the problems of initial value selection. In addition, we set different parameters of the LVQ method, such as extensions of LVQ method, lagging periods of codebook vector, decay rates and threshold values. The result shows that different parameter settings have little effect on the capability of identifying turning points, and the LVQ method is considerably robust.

壹、前言

一、研究緣起

景氣循環 (business cycles) 為總體經濟活動之波動現象，包含由谷底復甦至高峰的擴張期 (expansion)，及由高峰衰退至谷底的收縮期 (contraction)，如何認定景氣轉折點 (turning point)，為定義景氣循環之關鍵問題。我國景氣循環峰谷認定作業，係依據 OECD 的建議，俟轉折點出現並維持一段時間的穩定後，綜合出口、生產等各方面表現，由國發會 (以下稱本會) 參酌專家學者、政府機關的意見進行事後認定。

目前本會認定景氣轉折點之方法，主要依據美國國家經濟研究局 (National Bureau of Economic Research, NBER)、OECD 等作法，以綜合指數法、擴散指數法、主成份分析法、單變量馬可夫轉換模型分別認定景氣轉折點，其中綜合指數法、主成份分析法可採用 Bry and Boschan (1971) 或 Harding and Pagan (2002) 方法，分別進行峰谷認定。

由於上述峰谷認定方法，須等待轉折點出現，並維持一段時間後始能完成，認定的時間與實際發生轉折點的時點，存在相當的時間落差。若能提升景氣循環認定的即時性 (timeliness)，將有助於政府及時掌握景氣趨勢與發展，並能依據當前經濟情勢，制定適當的總體經濟政策。

二、研究目的

目前本會使用之峰谷認定方法，包含 Bry and Boschan (1971)、Harding and Pagan (2002) 方法、主成份分析法、單變量馬可夫轉換模型等，認定時間與實際發生轉折點的時點，存在



相當的時間落差，本研究的目的之一，是要提升轉折點認定的即時性。

另隨著資訊科技發展、電腦運算能力增強、資料儲存成本降低，大數據方法的應用開始蓬勃發展，其中機器學習（machine learning）方法開始運用在各種領域，其目標是分析現存資料獲得規律，進一步對未知資料進行預測與推論。

目前國內結合機器學習與經濟預測的研究尚少，本研究另一個目的，是嘗試利用機器學習方法當中的學習向量法（Learning vector quantization, LVQ），依據臺灣景氣循環特性調校參數，協助認定我國景氣轉折點。

貳、文獻回顧

景氣轉折點相關的文獻，分為事前（ex-ante）預測與事後（ex-post）認定，其中事前預測使用具有領先性的經濟與金融變數進行預測，而事後認定則是觀察一個總和（aggregated）經濟變數之趨勢或多個非總和（disaggregated）經濟變數之分配後，依據某些方法認定景氣轉折點。

在事前預測的文獻方面，如 Berge（2015）考慮經濟變數的非線性變化，運用模型選擇方法，挑選較佳的預測模型；Chauvet and Potter（2005）擴展 probit 模型，考慮多個斷點及序列相關誤差，結果為修正後的 probit 模型預測表現較佳；Kauppi and Saikkonen（2008）則使用動態 probit 模型預測美國景氣衰退期，其樣本內配適、樣本外預測結果均較靜態 probit 模型好；Ng（2013）結合機器學習中的 boosting 與羅吉斯迴歸，預測景氣衰退的機率；Rudebusch and Williams（2009）則使用殖利率曲線預測景氣衰退。

在景氣轉折點的事後認定方面，若以使用總和經濟變數或非總和經濟變數區分，前者以一個綜合各種表現的經濟變數，如GDP、同時指標、基準數列，直接認定景氣轉折點；後者則是運用多個面向的經濟變數，分別認定轉折點之後，再認定整體的景氣轉折點。

使用總和經濟變數的文獻方面，Bry and Boschan (1971) 提出以 12 個月移動平均、Spencer 曲線將數列平滑化，並依據MCD (months for cyclical dominance) 數值大小，計算不同期數的移動平均，辨認對應之循環轉折點，再以一些限制條件 (如全循環不得少於 15 個月、擴張期或收縮期不得少於 5 個月等) 認定整體景氣轉折點。Harding and Pagan (2002) 修正 Bry and Boschan (1971) 的方法，提出無母數轉折點認定方法，該方法適用於季資料及月資料。Chauvet (1998)、Kim and Nelson (1998)、Chauvet and Hamilton (2006)、Chauvet and Piger (2008)、Fossati (2016) 提出修正後的動態因子模型 (dynamic factor model)、馬可夫狀態轉換模型 (Markov switching model)、馬可夫動態因子轉換 (Markov-switching dynamic factor, DFMS) 模型或無母數認定方法，事後認定景氣轉折點。

使用非總和經濟變數的文獻方面，Burns and Mitchell (1946) 先行認定大量的非總和經濟變數個別轉折點，再以這些轉折點的集中趨勢，認定整體景氣循環轉折點；Stock and Watson (2014) 改進 Burns and Mitchell (1946) 的方法，以分層隨機抽樣建立轉折點的抽樣分配，並以抽樣分配的眾數認定為景氣轉折點。



隨著大數據時代的來臨，機器學習演算法密集應用在各領域，並取得了一定的成果。Giusto and Piger (2017) 使用學習向量法 (Learning Vector Quantization)，即時認定美國景氣循環轉折點，主要概念是將景氣循環的擴張期及收縮期視為兩種狀態，把認定轉折點轉換為分類 (classification) 問題，並以美國 NBER 認定景氣轉折點參考的非總和數列 (非農就業人數、工業生產指數、排除移轉性收入的實質個人所得、實質製造業銷售額) 做為分類依據，認定美國最近 5 次景氣衰退的轉折點。

參、研究方法

一、Bry and Boschan (1971) 認定方法

Bry and Boschan (1971) 於美國 NBER 提出一種景氣循環認定方法，主要概念是以 12 個月移動平均值、利用 Spencer 曲線平滑化之數列、依據 MCD 數值大小計算 3 至 6 個月的短期移動平均值，辨認對應之循環轉折點。

再以一些限制條件，如短期移動平均數列的轉折點，必須是前後 4 個月的最大值或最小值、轉折點不能出現在數列的最前 6 個月或最後 6 個月、第一個高峰 (谷底) 不能低於 (高於) 前面的數值、最後一個高峰 (谷底) 不能低於 (高於) 後面的數值、全循環週期不得少於 15 個月、擴張期或收縮期不得少於 5 個月等，決定最終認定的景氣轉折點，詳細步驟如表 1。

表1 Bry and Boschan (1971) 轉折點認定方法

I	判定數列極端值 (extreme value)，並以適當數值取代。
II	計算數列之 12 個月移動平均值，判定區域極大值 (極小值)。 A. 若該月數值高於 (低於) 前後 5 個月，則辨認為區域極大值 (極小值)。 B. 若區域內有多重極大值 (極小值)，選擇最大 (小) 的極大值 (極小值)，並強制要求區域極大值、極小值交替出現。
III	透過 Spencer 曲線，判定對應的轉折點。 A. 依據 II 計算之 12 個月移動平均數列，辨認選擇的轉折點是前後 5 個月的最大值 (最小值)。 B. 刪除較短循環之較低的高峰及較高的谷底，強制要求全循環週期至少 15 個月。
IV	根據 MCD (month of cyclical dominance) 數值大小，判定 3 個月至 6 個月之短期移動平均轉折點。 A. 辨認 Spencer 曲線選擇的轉折點，是前後 5 個月的最大值 (最小值)。
V	判定未經平滑化數列之轉折點。 A. 辨認短期移動平均轉折點，是前後 4 個月的最大值 (最小值)。 B. 刪除在數列開始後 6 個月或結束前 6 個月之轉折點。 C. 若數列開始至第一個高峰 (谷底)，有任何數值高 (低) 於高峰 (谷底)，則刪除第一個高峰 (谷底)；若最後一個高峰 (谷底) 至數列結束，有任何數值高 (低) 於高峰 (谷底)，則刪除最後一個高峰 (谷底)。 D. 刪除全循環週期少於 15 個月的循環。 E. 刪除擴張期或收縮期少於 5 個月的時期。
VI	公布最終轉折點。

資料來源：Bry and Boschan (1971) 第 21 頁表 1。

二、Harding and Pagan (2002) 認定方法

Bry and Boschan (1971) 認定方法的步驟中，需要使用 15 期資料計算 Spencer 曲線，由於所需的資料期間較長，一般僅用在月資料分析。Harding and Pagan (2002) 修正 Bry and Boschan (1971) 的認定方法，提出一種無母數轉折點認定方法，刪除 Spencer 曲線的平滑化過程，故能運用在月資料或季資料分析。主要概念為先決定可能的轉折點集合，確保高峰與谷底交替出



現，再考量循環的持續時間、深度及完整性，去除不必要的轉折點，詳細步驟如表 2。

Harding and Pagan (2002) 並提出衡量景氣循環特性的指標，如景氣擴張與蕭條的持續時間 (duration)、景氣擴張與蕭條的平均深度 (amplitude)，可計算擴張與蕭條期間的累計動能 (cumulative movements) 與超額累計動能 (excess cumulative movements)，其中後者可協助了解，相較於固定的經濟成長或衰退率，真實成長 (衰退) 多增加 (減少) 的動態走勢。

表 2 Harding and Pagan (2002) 轉折點認定方法

I	找出極端值，並以適當的數值取代。
II	依據 I 的結果，找出移動平均數列的初步極大值 (極小值)。 A. 觀察調整極端值後的數列，若某季數值比前後 z 季數值高 (低)，該季即被認定為區域極大值 (極小值)。 B. 強制要求區域極大值、極小值交替出現，以數值較高 (低) 者優先考量。
III	透過數列初步決定轉折點。 A. 依據 II 建構的移動平均數列，再做一次 II A。某季數值比前後 z 季數值高 (低)，該季即被認定為區域極大值 (極小值)。 B. 捨棄週期過短的極大值 (極小值)，強制要求全循環週期不得少於 y 個季度。
IV	決定數列的轉折點。 A. 依據 III 建構的移動平均數列，若某季數值比前後 x 季數值高 (低)，該季即被認定為轉折點。 B. 捨棄數列開始 x 季內與結束前 x 季內出現的轉折點。 C. 當開始與結束兩端的高峰 (谷底) 數值比最鄰近的高峰 (谷底) 數值低 (高)，則捨棄開始與結束兩端的高峰 (谷底)。 D. 高峰與谷底要依序出現，若連續二個高峰 (谷底) 被選取時，捨棄較低 (高) 的時點。 E. 這一期谷底要比上一期高峰低。 F. 若全循環週期少於 y 個季度，則予以捨棄。 G. 若擴張期或收縮期少於 x 個季度，則予以捨棄。 H. 其它設定，如高峰與谷底差距太大 (如金融危機)，則不受上述 F、G 的限制。
V	公佈最終轉折點。

資料來源：黃裕烈 (2016) 第 19 頁表 3。

三、Giusto and Piger (2017) 學習向量法

(一) 學習向量法概述

學習向量法是一種解決分類問題的演算法，透過定義編碼向量 (codebook vector) 代表不同類別，而每種類別可以有多個編碼向量作為代表。具體的分類方法為，建立一組編碼向量後，計算觀測值與每個編碼向量的距離，再將觀測值分類至距離最近的編碼向量所屬類別。

舉例來說，編碼向量 A、B 分別代表類別 1 及類別 2，欲將觀測值 x 進行分類，則計算 x 與編碼向量 A、B 的距離，結果 x 距離編碼向量 A 較近，則將 x 分類至類別 1；同理，將 y 分類至類別 2。(詳圖 1)

學習向量法的概念，主要是以編碼向量捕捉各類別的特性，再以各個觀測值與編碼向量的相似程度，評估觀測值所屬的類別，故學習向量法的關鍵，即是如何建立有代表性的編碼向量。




圖 1 學習向量法分類示意圖



(二) 學習向量法演算法

學習向量法的演算法，是先設定一組編碼向量初始值，再運用已知類別的訓練資料 (training data)，逐步修正編碼向量的數值。若某觀測值與最接近的編碼向量為同個類別，則修正編碼向量的位置，使其接近觀測值；反之若為不同類別，則使編碼向量遠離觀測值 (詳圖 2)；藉由演算法反覆迭代運算，達到預設的收斂條件後，即可使用此組編碼向量進行分類。




圖 2 編碼向量 m_c^g 修正示意圖

學習向量法的數學模式方面，假設訓練資料共有 N 個觀測值，每個觀測值有 m 個變數，以 x_n 代表某觀測值，其中 $x_n \in \mathbf{R}^m$ ， $n = 1, \dots, N$ ；為簡化演算法內容，假設僅有 2 種類別，以 C_k 代表類別，其中 $k = 1, 2$ 。

關於編碼向量部分，以 m_i 代表編碼向量， $\bar{N}$ 表示編碼向量個數，其中 $m_i \in \mathbf{R}^m$ ， $i = 1, \dots, \bar{N}$ ， $\bar{N} \in [2, N]$ 。演算法迭代次數方面，設定 g 代表第 g 次迭代，其中 $g = 1, \dots, G$ ； α^g 為介於 0 至 1 之間的遞減數列， α 代表編碼向量的修正率。

學習向量法的演算法步驟如下 (詳圖 3):




圖 3 學習向量法演算法流程圖



1. 令 $n = 1$ 、 $g = 1$ 。
2. 定義最接近觀測值 x_n 的編碼向量為 m_c^g ，其中

$$c = \operatorname{argmin}_{i \in \{1, \dots, N\}} \{\|x_n - m_i^g\|\}$$

3. 使用以下規則，修正編碼向量 m_c^g 的位置：

$$\begin{cases} m_{c+1}^g = m_c^g + \alpha^g (x_n - m_c^g) & \text{若 } x_n \text{ 與 } m_c^g \text{ 是相同分類} \\ m_{c+1}^g = m_c^g - \alpha^g (x_n - m_c^g) & \text{若 } x_n \text{ 與 } m_c^g \text{ 是不同分類} \end{cases}$$

4. 依據不同情況，決定演算法迭代過程：
 - (1) 若 $n + 1 \leq N$ ，則令 $n = n + 1$ ，重複步驟 2。
 - (2) 若 $n + 1 > N$ 且 $g \leq G$ ，則令 $n = 1$ ， $g = g + 1$ ，重複步驟 2。
 - (3) 若為其他狀況，則停止迭代，訓練完成編碼向量。

(三) 學習向量法分類預測

使用訓練資料的 N 個觀測值，訓練完成編碼向量 m_i 後，即產生一組分類規則，當有未知類別的新觀測值 x_{N+1} 出現時，便可預測 x_{N+1} 的類別。具體作法為計算 x_{N+1} 與所有編碼向量的距離，將 x_{N+1} 的類別，預測為距離最近的編碼向量 m_c 之類別，其中

$$c = \operatorname{argmin}_{i \in \{1, \dots, N\}} \{\|x_{N+1} - m_i\|\}$$

(四) Giusto and Piger (2017) 轉折點認定程序假設

為充分運用資訊，Giusto and Piger (2017) 觀察美國 NBER 發布景氣峰谷的規則，設定轉折點認定程序的假設，使分析者能在較短的區間內，尋找景氣轉折點：

- ◆ 一旦美國 NBER 公布新的高峰或谷底日期，則假設該日期為已知。
- ◆ 若有新的高峰日期，美國 NBER 將在 12 個月內公布。
- ◆ 一旦美國 NBER 公布新的轉折點，則假設擴張期或收縮期至少 6 個月。

舉例來說，若分析者在 1980 年 12 月進行轉折點認定，最後收集到 1980 年 11 月資料，此時美國 NBER 最近於 1980 年 6 月 3 日，認定 1980 年 1 月為高峰。由於假設收縮期至少 6 個月，故 1980 年 2 月至 7 月為收縮期，分析者將在 1980 年 8 月至 11 月尋找谷底。

若分析者在 2005 年 12 月進行轉折點認定，最後收集到 2005 年 11 月資料，此時美國 NBER 最近於 2003 年 7 月 17 日，認定 2001 年 11 月為谷底。由於假設新的高峰將在 12 個月內公布，故往前推算 12 個月以前皆為擴張期，2001 年 12 月至 2004 年 11 月為擴張期，分析者將在 2004 年 12 月至 2005 年 11 月尋找高峰。

(五) Giusto and Piger (2017) 即時認定轉折點規則

由於景氣循環有一定的持續性，Giusto and Piger (2017) 依據 Chauvet and Piger (2008) 的作法，設定即時認定轉折點的規則為：

- ◆ 若連續 3 個月為新的景氣狀態，則將原來景氣狀態最後 1 個月認定為轉折點。



四、本研究之學習向量法

(一) 研究假設

本研究依據臺灣景氣循環認定程序及特徵，調整 Giusto and Piger (2017) 認定方法，即時認定景氣轉折點。在景氣循環週期方面，參考 Banerji (1999) 的持續性原則、Bry and Boschan (1971) 認定方法及本會之實務經驗，假設擴張期、收縮期長度至少 5 個月，相關假設如下：

- ◆ 一旦本會公布景氣高峰或谷底，則將已知的擴張期或收縮期加入訓練資料，往後認定景氣轉折點。
- ◆ 一旦本會公布新的轉折點，則假設擴張期或收縮期至少 5 個月。

(二) 認定流程及規則

依據前一節的假設及參考 Giusto and Piger (2017) 認定原則，本研究的景氣轉折點認定流程（詳圖 4）及規則如下：

- ◆ 採用即時認定原則，每次納入 1 個新觀測值認定景氣狀態，若有轉折點出現，則以最早認定日期的結果為主。
- ◆ 若景氣狀態改變未滿 5 個月，就回復到原來的狀態，則將景氣狀態改變期間視為短期波動，不認定景氣轉折點。
- ◆ 若連續 5 個月為新的景氣狀態，則將原來景氣狀態最後 1 個月認定為轉折點。




圖 4 學習向量法景氣轉折點認定流程



(三) 參數設定

使用學習向量法認定景氣轉折點，必須事先決定參數，本研究主要參考 Giusto and Piger (2017) 的設定，並參酌本會進行峰谷認定的經驗調整，以下就實證分析的詳細設定，包括變數及其落後期、編碼向量個數、編碼向量修正率、編碼向量初始值、最大迭代次數、學習向量法執行次數與門檻值說明如下：

- ◆ 變數及其落後期：以同時指標構成項目進行李節調整、去除長期趨勢與平滑化、標準化後計算月增率，本研究使用標準化變數月增率及落後 1 期月增率進行分析。
- ◆ 編碼向量個數 $\bar{N}$ ：參考 Giusto and Piger (2017) 的設定，擴張期、收縮期編碼向量個數皆為收縮期個數，故編碼向量個數 $\bar{N}$ 為 2 倍收縮期個數。
- ◆ 編碼向量修正率 α ：參考 Giusto and Piger (2017) 的設定， $\alpha = 0.3$ ，代表編碼向量修正率， $\alpha^g = (0.3)^g$ 則表示編碼向量的修正幅度，隨迭代次數增加而變小。
- ◆ 編碼向量初始值：參考 Giusto and Piger (2017) 的設定，收縮期編碼向量初始值，使用訓練資料收縮期的實際觀測值；擴張期編碼向量初始值，則自擴張期的實際觀測值以簡單隨機抽樣選取。
- ◆ 最大迭代次數 G ：Kohonen (2012) 指出，須使用適當的迭代次數，以避免演算法過度學習，造成分類的正確性降低。本研究參考 R 套件 `class` 的預設值，將最大迭代次數設定為觀測值個數的 100 倍。

- ◆ 學習向量法執行次數：編碼向量初始值的一部分，由簡單隨機抽樣選取，為避免抽樣誤差對推論造成影響，本研究對於每個新觀測值，皆以學習向量法執行 1,000 次景氣循環認定程序，並計算新觀測值為收縮期的機率。
- ◆ 門檻值：得到每個新觀測值的收縮期機率後，必須設定門檻值，以認定該月份是否為收縮期。本研究參考 Giusto and Piger (2017) 的設定，若該月份有 80% 的執行次數為收縮期，則認定該月份為收縮期。

五、轉折點認定能力評估

使用各種方法認定景氣轉折點後，可轉換認定期間之景氣狀態為擴張期或收縮期，將認定景氣轉折點視為分類問題。認定結果之正確性，可將認定之景氣狀態與本會峰谷認定結果進行比較，並使用傳統類別分析之混淆矩陣呈現（詳表 3）。

混淆矩陣將認定結果與真實景氣狀態以表格呈現，並定義真陽（True Positive, TP）、真陰（True Negative, TN）、偽陽（False Positive, FP）、偽陰（False Negative, FN）等 4 種狀態，以描述認定結果是否正確，上述 4 種狀態定義如下：

- ◆ 真陽：認定為擴張期，且實際為擴張期。
- ◆ 真陰：認定為收縮期，且實際為收縮期。
- ◆ 偽陽：認定為擴張期，且實際為收縮期。
- ◆ 偽陰：認定為收縮期，且實際為擴張期。



表 3 混淆矩陣狀態

		真實	
		擴張期	收縮期
認定	擴張期	真陽 (True Positive, TP)	偽陽 (False Positive, FP)
	收縮期	偽陰 (False Negative, FN)	真陰 (True Negative, TN)

藉由混淆矩陣可進一步定義準確性 (accuracy)、敏感度 (sensitivity) 及明確度 (specificity)，由於上述指標皆經過標準化，故可跨方法比較認定能力，準確性、敏感度及明確度定義如下：

- ◆ 準確性：景氣狀態認定正確的比率。

$$\text{準確性} = \frac{TP + TN}{TP + TN + FP + FN}$$

- ◆ 敏感度：實際為擴張期的前提下，正確認定為擴張期的比率。

$$\text{敏感度} = \frac{TP}{TP + FN}$$

- ◆ 明確度：實際為收縮期的前提下，正確認定為收縮期的比率。

$$\text{明確度} = \frac{TN}{TN + FP}$$

肆、實證分析

本研究採用 3 種事後認定方法，認定臺灣的景氣循環轉折點，其中 Bry and Boschan (1971) 及 Harding and Pagan (2002) 方法，須以具有代表性的總和經濟變數進行分析，考量數據即時性及避免使用低頻資料，以同時指標不含趨勢指數進行認定。學習向量法則參考 Giusto and Piger (2017) 認定美國景氣循環轉折點的作法，以同時指標構成項目進行即時認定。

本章節包含 Bry and Boschan (1971)、Harding and Pagan (2002)、學習向量法認定結果、實證分析結果比較、學習向量法穩健性分析，相關內容敘述如下：

一、Bry and Boschan (1971)、Harding and Pagan (2002) 認定結果

我國自 1980 年 1 月起，經過 10 次景氣循環，於 2016 年 2 月達到第 14 次循環的谷底（詳表 4），並按月編製景氣對策信號、景氣同時指標，以監測當前景氣狀態。其中同時指標不含趨勢指數為一個具同時性的總和經濟變數，且經過去除長期趨勢，能準確反應當前景氣狀態，本研究使用之 Bry and Boschan (1971)、Harding and Pagan (2002) 方法，便以同時指標不含趨勢指數為對象，進行景氣轉折點之認定。

由於同時指標構成項目中的批發、零售及餐飲業營業額自 1999 年 1 月始有資料，後續學習向量法自 2001 年 10 月起至 2019 年 7 月進行即時認定，為比較學習向量法之認定結果，認定期間設定為 2001 年 10 月至 2019 年 7 月，主要包含第 11 次至第 14 次景氣循環。



表 4 我國自第 5 次景氣循環起之峰谷日期

循環次序	高峰	谷底	持續期間（月數）		
			擴張期	收縮期	全循環
第 5 循環	1980.01	1983.02	59	37	96
第 6 循環	1984.05	1985.08	15	15	30
第 7 循環	1989.05	1990.08	45	15	60
第 8 循環	1995.02	1996.03	54	13	67
第 9 循環	1997.12	1998.12	21	12	33
第 10 循環	2000.09	2001.09	21	12	33
第 11 循環	2004.03	2005.02	30	11	41
第 12 循環	2008.03	2009.02	37	11	48
第 13 循環	2011.02	2012.01	24	11	35
第 14 循環	2014.10	2016.02	33	16	49
平 均			34	15	49

本研究執行 Bry and Boschan (1971)、Harding and Pagan (2002) 方法的軟體方面，前者使用 OECD CACIS 軟體的 Turning-point Detection 程序進行認定，後者則使用 R 軟體的 BCDating 套件進行認定，並與本會峰谷認定結果進行比較。

研究結果顯示，Bry and Boschan (1971)、Harding and Pagan (2002) 方法認定之景氣轉折點相同，其認定誤差介於領先 1 個月至落後 10 個月，且多認定 2002 年 6 月高峰及 2003 年 5 月谷底、2006 年 2 月高峰及 2006 年 10 月谷底的 2 次小循環。(詳表 5、圖 5)

表5 Bry and Boschan (1971)、Harding and Pagan (2002)
與本會認定結果比較

國發會公布			Bry and Boschan (1971)		Harding and Pagan (2012)	
循環	峰谷	實際 轉折點	認定 轉折點	認定 誤差月數	認定 轉折點	認定 誤差月數
			2002.06	-	2002.06	-
			2003.05	-	2003.05	-
第 11 循環	高峰	2004.03	2004.02	+1	2004.02	+1
	谷底	2005.02	2005.06	-4	2005.06	-4
		-	2006.01	-	2006.01	-
		-	2006.10	-	2006.10	-
第 12 循環	高峰	2008.03	2008.03	0	2008.03	0
	谷底	2009.02	2009.02	0	2009.02	0
第 13 循環	高峰	2011.02	2011.01	+1	2011.01	+1
	谷底	2012.01	2012.11	-10	2012.11	-10
第 14 循環	高峰	2014.10	2014.10	0	2014.10	0
	谷底	2016.02	2016.01	+1	2016.01	+1

說明：1. 陰影部分為谷底時點。

2. 認定誤差月數「+」代表領先月數，「-」代表落後月數。




圖 5 Bry and Boschan (1971)、Harding and Pagan (2012)
及本會之峰谷認定結果

二、學習向量法認定結果

(一) 資料來源與變數處理

為即時認定我國景氣循環轉折點，本研究使用同時指標構成項目進行研究，包含工業生產指數、電力（企業）總用電量、製造業銷售量指數、批發、零售及餐飲業營業額、非農業部門就業人數、實質海關出口值、實質機械及電機設備進口值等 7 個總體經濟變數，變數處理說明如下：

- ◆ 季節調整：對具有季節性之變數進行調整，以避免季節性因素影響景氣判斷。

- ◆ 去除趨勢與平滑化：運用二階段 HP (Hodrick-Prescott, 1997) 去除長期趨勢與平滑化。第一階段使用 HP 過濾器，搭配適當參數計算長期趨勢後，去除長期趨勢；第二階段再以 HP 過濾器，搭配短週期之適當參數，對去除長期趨勢之數列進行平滑化。
- ◆ 標準化：每個變數數值大小、單位、波動幅度均不同，計算觀測值與編碼向量的距離時，會受到變數數值大小的影響，故必須進行標準化。標準化程序為，將每個變數減去平均數，再除以平均絕對離差，每個變數將成為平均值 100，具有相同循環振幅之時間數列。
- ◆ 計算月增率 (Month-over-month, MOM)：為捕捉每個變數的變動趨勢，將標準化變數的本月數值與上月數值相比，計算月增率，本研究均使用標準化變數月增率進行分析。

(二) 實證分析結果

由於同時指標構成項目中的批發、零售及餐飲業營業額自 1999 年 1 月始有資料，本研究以 1999 年 1 月至 2001 年 9 月作為訓練資料，利用同時指標構成項目之標準化變數年增率及落後 1 期資訊，進行模擬即時分析¹，自 2001 年 10 月開始，每次加入 1 個月進行即時認定，至 2019 年 7 月截止。

¹ 本研究以 2019 年 8 月編製之 7 月同時指標之構成項目進行分析，使用統計機構發布之修正值進行分析，忽略實際決策使用的資料為初估值，稱為模擬即時分析 (pseudo real-time analysis)。



本研究自行使用 R 軟體，撰寫學習向量法認定程序之程式，主要引用 class 套件的 lvq1、olqv1、lvq2、lvq3 等學習向量法相關函數，並與本會峰谷認定結果進行比較。

研究結果顯示，運用學習向量法，僅須連續 5 個月呈現新的景氣狀態，即可將原本景氣狀態最後 1 個月認定為轉折點。學習向量法落後 2 個月至 11 個月，即可認定該次或相近轉折點，相較於本會現行落後 12 個月至 49 個月，具有較佳的即時性。

學習向量法的認定誤差介於領先 3 個月至落後 6 個月，多認定 2006 年 2 月高峰及 2006 年 10 月谷底的 1 次小循環，表現較 Bry and Boschan (1971)、Harding and Pagan (2002) 方法好。(詳表 6、圖 6)

表 6 學習向量法與本會認定結果比較

國發會公布				學習向量法		
循環	峰谷	實際轉折點	認定落後月數	認定轉折點	認定誤差月數	認定落後月數
第 11 循環	高峰	2004.03	49	2004.09	-6	11
	谷底	2005.02	49	2005.02	0	5
		-		2006.02	-	-
		-		2006.10	-	-
第 12 循環	高峰	2008.03	12	2008.03	0	5
	谷底	2009.02	31	2009.02	0	5
第 13 循環	高峰	2011.02	45	2011.02	0	5
	谷底	2012.01	34	2011.10	+3	2
第 14 循環	高峰	2014.10	15	2015.01	-3	8
	谷底	2016.02	24	2016.02	0	5

說明：1. 陰影部分為谷底時點。

2. 認定落後月數=認定月份-實際轉折點月份；認定誤差月數「+」代表領先月數，「-」代表落後月數。




圖 6 學習向量法及本會峰谷認定結果

三、實證分析比較

為衡量 Bry and Boschan (1971)、Harding and Pagan (2002)、學習向量法與本會峰谷認定結果差異，將認定結果以混淆矩陣呈現，並以準確性、敏感度及明確度評估各種方法之認定能力。

轉折點認定能力評估顯示，學習向量法之準確性為 88.4%，代表即時認定期間有 88.4% 的景氣狀態認定正確，主要誤差來自多認定的 1 次小循環；Bry and Boschan (1971)、Harding and Pagan (2002) 方法之準確性為 78.6%，主要誤差來自多認定的 2 次小循環，顯示學習向量法的認定能力較佳。



學習向量法的敏感度、明確度分別為 93.5%、75.5%，Bry and Boschan (1971)、Harding and Pagan (2002) 方法的敏感度、明確度分別為 71.0%、98.0%。學習向量法的敏感度較高，代表在實際為擴張期的前提下，能認定較多正確的擴張期；Bry and Boschan (1971)、Harding and Pagan (2002) 方法的明確度較高，則代表在實際為收縮期的前提下，能認定較多正確的收縮期。

實證分析結果顯示，Bry and Boschan (1971)、Harding and Pagan (2002) 方法多認定 2 次收縮期，且其餘收縮期長度多較本會認定結果長，導致其明確度高達 98.0%，惟須以將擴張期誤認為收縮期為代價，其敏感度僅為 71.0%。(詳表 7、表 8、表 9)

由於在固定模型方法下，敏感度和明確度為取捨 (trade off) 關係，如何調整適當門檻值，得到可接受之敏感度及明確度，為模型調校之關鍵問題。Menden and Proaño (2017) 提出以損失函數 (loss function) 控制混淆矩陣中的型 I 及型 II 誤差，視研究者主觀認定敏感度及明確度的重要性，以決定適當門檻值，可做為未來研究參考。

表 7 Bry and Boschan (1971)、Harding and Pagan (2002)
認定結果混淆矩陣

		真實	
		擴張期	收縮期
認定	擴張期	88	1
	收縮期	36	48

表 8 學習向量法認定結果混淆矩陣

		真實	
		擴張期	收縮期
認定	擴張期	116	12
	收縮期	8	37

表 9 研究方法認定能力評估

單位：%

編號	研究方法	認定能力評估		
		準確性	敏感度	明確度
1	Bry and Boschan (1971)	78.6	71.0	98.0
	Harding and Pagan (2002)			
2	學習向量法	88.4	93.5	75.5

四、學習向量法穩健性分析

由於機器學習方法參數設定通常會影響分析結果，為檢驗學習向量法的穩健性，以下針對學習向量法及其延伸、變數落後期、編碼向量修正率、門檻值設定不同參數，重新執行景氣轉折點認定程序，以準確性、敏感度及明確度評估其認定能力。

(一) 學習向量法及其延伸

本研究使用的學習向量法為 LVQ1，其延伸尚有 OLVQ1、LVQ2.1 及 LVQ3，主要概念是修改學習向量法的編碼向量修正率，或同時考慮最接近及次接近的編碼向量，修正最接近編碼向量的位置，使其接近觀測值；修正次接近編碼向量的位置，使其遠離觀測值。



分別使用這 3 種延伸的學習向量法，認定景氣轉折點，結果發現 OLVQ1、LVQ3 的準確性與 LVQ1 相近，而 LVQ2.1 的準確性稍微降低，顯示不論使用學習演算法或其延伸，認定景氣轉折點均具有穩健性。(詳表 10)

表 10 學習向量法及其延伸之認定能力評估

編號	參數設定				認定能力評估		
	學習向量法	變數落後期個數	編碼向量修正率	門檻值	準確性	敏感度	明確度
單位	無	月	無	%	%	%	%
1	LVQ1	1	0.3	80	88.4	93.5	75.5
2	OLVQ1	1	0.3	80	88.4	93.5	75.5
3	LVQ2.1	1	0.3	80	83.2	93.5	57.1
4	LVQ3	1	0.3	80	87.3	94.4	69.4

說明：陰影部分為本研究預設值。

(二) 變數落後期

Giusto and Piger (2017) 使用非農就業人數成長、工業生產指數成長、排除移轉性收入的實質個人所得成長、實質製造業銷售額成長等變數及落後 1 期資訊做為編碼向量，進行學習向量演算法，以即時認定景氣轉折點，惟未探討編碼向量增加落後期資訊，是否對認定轉折點有所幫助。

本研究考量未放入變數落後期、增加落後 1 期到增加落後 9 期資訊，重新執行認定景氣轉折點程序。結果顯示，增加落後 1 期資訊的準確性最高，達到 88.4%；編碼向量增加愈多落後期，未必能使認定結果更好，可能因編碼向量攜帶較多落後期資訊，較無法即時反應景氣變化，進而影響認定效果。(詳表 11)

表 11 增加變數落後期之認定能力評估

編號	參數設定				認定能力評估		
	學習 向量法	變數 落後期 個數	編碼向量 修正率	門檻值	準確性	敏感度	明確度
單位	無	月	無	%	%	%	%
1	LVQ1	0	0.3	80	82.7	91.1	61.2
2	LVQ1	1	0.3	80	88.4	93.5	75.5
3	LVQ1	2	0.3	80	85.5	91.1	71.4
4	LVQ1	3	0.3	80	79.8	87.9	59.2
5	LVQ1	4	0.3	80	83.8	92.7	61.2
6	LVQ1	5	0.3	80	83.2	92.7	59.2
7	LVQ1	6	0.3	80	85.0	94.4	61.2
8	LVQ1	7	0.3	80	86.7	98.4	57.1
9	LVQ1	8	0.3	80	86.7	98.4	57.1
10	LVQ1	9	0.3	80	80.3	92.7	49.0

說明：陰影部分為本研究預設值。

(三) 編碼向量修正率

學習向量法先計算觀測值與所有編碼向量的距離，再逐步調整最接近的編碼向量位置，調整幅度為編碼向量修正率 α 的 g 次方，隨著迭代次數 g 愈大，編碼向量位置調整幅度愈小。Kohonen (2001) 證明選取不同編碼向量修正率，學習向量法的分類結果不會有很大改變，主因迭代次數夠大時，編碼向量調整幅度趨近於 0。

若設定編碼向量修正率 α 從 0.1 增至 0.9 進行驗證，結果顯示與 Kohonen (2001) 的證明相同，修改編碼向量修正率 α ，對景氣轉折點認定準確性影響不大。(詳表 12)



表 12 調整編碼向量修正率之認定能力評估

編號	參數設定				認定能力評估		
	學習 向量法	變數 落後期 個數	編碼向量 修正率	門檻值	準確性	敏感度	明確度
單位	無	月	無	%	%	%	%
1	LVQ1	1	0.1	80	85.0	100.0	46.9
2	LVQ1	1	0.2	80	88.4	93.5	75.5
3	LVQ1	1	0.3	80	88.4	93.5	75.5
4	LVQ1	1	0.4	80	88.4	93.5	75.5
5	LVQ1	1	0.5	80	88.4	93.5	75.5
6	LVQ1	1	0.6	80	88.4	93.5	75.5
7	LVQ1	1	0.7	80	88.4	93.5	75.5
8	LVQ1	1	0.8	80	88.4	93.5	75.5
9	LVQ1	1	0.9	80	88.4	93.5	75.5

說明：陰影部分為本研究預設值。

(四) 門檻值

本研究的即時認定程序，皆以簡單隨機抽樣，選取編碼向量初始值，執行學習向量演算法。在執行 1000 次簡單隨機抽樣後，可得到收縮期機率，當新觀測值收縮期機率大於或等於門檻值，則認定新觀測值為收縮期，故設定不同的門檻值，會影響最終認定擴張期或收縮期之結果。

設定門檻值由 10% 增至 90% 進行穩健性分析，結果顯示不同門檻值的認定能力準確性差異不大。進一步觀察轉折點的收縮期機率，谷底的收縮期機率通常接近 100%，高峰的收縮期機率經常會接近 0%，因此在設定不同門檻值情況下，學習向量法認定能力的準確性沒有很大差異。(詳表 13)

表 13 調整門檻值之認定能力評估

編號	參數設定				認定能力評估		
	學習 向量法	變數 落後期 個數	編碼向量 修正率 α	門檻值	準確性	敏感度	明確度
單位	無	月	無	%	%	%	%
1	LVQ1	1	0.3	10	88.4	92.7	77.6
2	LVQ1	1	0.3	20	87.9	92.7	75.5
3	LVQ1	1	0.3	30	87.9	92.7	75.5
4	LVQ1	1	0.3	40	87.9	92.7	75.5
5	LVQ1	1	0.3	50	87.9	92.7	75.5
6	LVQ1	1	0.3	60	87.9	92.7	75.5
7	LVQ1	1	0.3	70	88.4	93.5	75.5
8	LVQ1	1	0.3	80	88.4	93.5	75.5
9	LVQ1	1	0.3	90	89.0	94.4	75.5

說明：陰影部分為本研究預設值。

伍、結論與建議

一、結論

本研究將機器學習方法，應用於景氣轉折點認定程序，主要使用 Giusto and Piger (2017) 的學習向量法，並依據臺灣景氣循環特性調整。實證分析部分，比較學習向量法、Bry and Boschan (1971)、Harding and Pagan (2002) 方法的認定結果及其準確性；針對學習向量法及其延伸、變數落後期、編碼向量修正率、門檻值設定不同參數，以準確性、敏感度及明確度評估其認定能力，以檢驗學習向量法的穩健性。主要結論分述如下：



- (一) 運用學習向量法認定景氣轉折點，具有較佳的即時性，僅落後 2 個月至 11 個月，即可認定該次或相近的轉折點，有助於政府即時掌握景氣趨勢。若景氣處於收縮期，政府將能推出反循環之財政政策或貨幣政策，以減緩景氣收縮之衝擊。
- (二) 由於臺灣屬於小型開放經濟體，景氣容易受國際情勢影響而產生波動，本研究依據臺灣景氣循環特性調整認定方法，若景氣狀態改變未滿 5 個月，則暫不認定轉折點，故能減少誤判轉折點的可能性。實證結果顯示，相較於 Bry and Boschan (1971)、Harding and Pagan (2002) 方法，學習向量法的認定誤差較小，且傾向認定較少的小循環。
- (三) 不同的初始值及參數設定，經常會影響機器學習方法分析結果。本研究的學習向量法透過簡單隨機抽樣，執行 1,000 次不同初始編碼向量的轉折點認定程序，能避免初始值選擇問題。參數設定部分，本研究調整學習向量法、變數落後期、編碼向量修正率及門檻值的設定，結果顯示學習向量法具有相當的穩健性，不同參數設定對轉折點認定能力的準確性影響不大。

二、建議

- (一) 本研究將認定景氣轉折點轉換為分類問題，故傳統統計分析的羅吉斯迴歸 (logistic regression)、判別分析 (discriminant analysis) 及機器學習方法當中的決策樹 (decision tree)、類神經網路 (neural network)、支持向量機 (support vector machine) 等，均可做為認定景氣轉折點方法的潛在選項。

- (二) 由於機器學習演算法皆以黑箱 (black box) 模式運作，分析者僅能看見分析結果，而無法窺見其運算過程，故使用機器學習演算法時，須注意結果的合理性，如能結合經濟理論或使用多個模型交叉驗證，則能使結果更具可信度。
- (三) Giusto and Piger (2017) 提到，若能使用主成份分析或因素分析，將大量經濟變數的訊息加入編碼向量，將有助於改善認定景氣轉折點的速度，建議未來研究可加入大量經濟變數，探討對學習向量法的改善效果。



參考文獻

1. 周大森 (2019) , 「運用大量數據認定景氣轉折點」, 國家發展委員會委託研究計畫。
2. 黃裕烈 (2016) , 「精進景氣循環認定之計量方法」, 國家發展委員會委託研究計畫。
3. 劉欣姿 (2019) , 「臺灣第 14 次景氣循環谷底認定之研究」, 經濟研究, 第 19 期, 國家發展委員會。
4. 蔡佩珍 (2017) , 「精進景氣循環認定計量方法－轉折點判定之改善」, 經濟研究, 第 17 期, 國家發展委員會。
5. Banerji, A. (1999) , “The Three Ps: Simple Tools for Monitoring Economic Cycles,” *Business Economics* 34, 72-76.
6. Berge, T. J. (2015) . Predicting recessions with leading indicators: Model averaging and selection over the business cycle. *Journal of Forecasting*, 34 (6) , 455-471.
7. Bry, G. and C. Boschan (1971) . *Cyclical Analysis of Time Series: Procedures and Computer Programs*, New York, NBER.
8. Burns, A. F., & Mitchell, W. C. (1946) . *Measuring business cycles*, New York, NBER.
9. Chauvet, M. (1998) . An econometric characterization of business cycle dynamics with factor structure and regime switching. *International economic review*, 969-996.
10. Chauvet, M., & Potter, S. (2005) . Forecasting recessions using the yield curve. *Journal of Forecasting*, 24 (2) , 77-103.
11. Chauvet, M., & Hamilton, J. D. (2006) . Dating business cycle turning points. *Contributions to Economic Analysis*, 276, 1-54.
12. Chauvet, M., & Piger, J. (2008) . A comparison of the real-time performance of business cycle dating methods. *Journal of Business & Economic Statistics*, 26 (1) , 42-49.
13. Einian, M. BCDating: Business Cycle Dating and Plotting Tools (2019) . URL <https://cran.r-project.org/web/packages/BCDating/index.html>.
14. Fossati, S. (2016) . Dating US business cycles with macro factors. *Studies in Nonlinear Dynamics & Econometrics*, 20 (5) , 529-547.
15. Giusto, A., & Piger, J. (2017) . Identifying business cycle turning points in real time with vector quantization. *International Journal of Forecasting*, 33 (1) , 174-184.

16. Harding, D. and A. Pagan (2002a) . Dissecting the Cycle: A Methodological Investigation. *Journal of Monetary Economics*, 49, 365-381.
17. Harding, D. and A. Pagan (2002b) . A Comparison of Two Business Cycle Dating Methods. *Journal of Economic Dynamics and Control*, 27, 1681-1690.
18. Harding, D. and A. Pagan (2003) . Business Cycles and Turning Points: A Survey of Statistical Techniques. *National Institute Economic Review*, 183, 90-106.
19. Harding, D. and A. Pagan (2005) . A Suggested Framework for Classifying the Modes of Cycle Research. *Journal of Applied Econometrics*, 20, 151-159.
20. Harding, D. and A. Pagan (2006) . Synchronization of Cycles. *Journal of Econometrics*, 132, 59-79.
21. Kauppi, H., & Saikkonen, P. (2008) . Predicting US recessions with dynamic binary response models. *The Review of Economics and Statistics*, 90 (4) , 777-791.
22. Kim, C. J., & Nelson, C. R. (1998) . Business cycle turning points, a new coincident index, and tests of duration dependence based on a dynamic factor model with regime switching. *Review of Economics and Statistics*, 80 (2) , 188-201.
23. Kohonen, T. (2012) . Self-Organizing Maps. Springer, Berlin.
24. Menden, C., & Proaño, C. R. (2017) . Dissecting the financial cycle with dynamic factor models. *Quantitative Finance*, 17 (12) , 1965-1994.
25. Ng, S. (2013) . *Boosting recessions*. *Canadian Journal of Economics*, forthcoming.
26. Ripley, B., & Venables, W. class: Functions for Classification (2019) URL <https://cran.r-project.org/web/packages/class/>.
27. Rudebusch, G. D., & Williams, J. C. (2009) . Forecasting recessions: the puzzle of the enduring power of the yield curve. *Journal of Business & Economic Statistics*, 27 (4) , 492-503.
28. Stock, J. H., & Watson, M. W. (2014) . Estimating turning points using large data sets. *Journal of Econometrics*, 178, 368-381.