

國立成功大學
交通管理科學研究所
碩士論文

應用 ARIMA 與 CART 之混合模型預測波羅的海
乾散貨指數

Using ARIMA and CART Hybrid Model to Predict
Baltic Dry Index

研究生：劉姿妤

指導教授：沈宗緯 博士

中華民國一百零八年七月

國立成功大學

碩士論文

應用ARIMA與CART之混合模型預測波羅的海乾散貨指數

Using ARIMA And CART Hybrid Model To Predict Baltic Dry Index

研究生：劉姿妤

本論文業經審查及口試合格特此證明

論文考試委員：

許 幸 延

林秉良

沈宗緯

指導教授：沈宗緯

系(所)主管：陳勁甫

中 華 民 國 108 年 7 月 15 日

摘要

國際貿易以海運為主，其中不定期國際散裝海運市場的運費起伏變動大且不易預測，使得投資不定航面臨較高的風險與不確定性，而波羅的海乾散貨指數 (Baltic Dry Index, BDI) 則是判斷不定航市場重要的指標。

在 BDI 預測方法中，可大致分為兩大類，傳統時間序列預測與非線性 (non-linear) 和資料探勘方法預測。因 BDI 屬於非穩定的時間序列資料，而傳統時間序列預測雖能準確的進行線性趨勢預測，但對於擁有非線性特徵之 BDI 之預測，其準確性較差。而機器學習方法近年來逐漸應用於非線性及非定態的時間序列資料預測。本研究結合時間序列模型中之 ARIMA (Autoregressive Integrated Moving Average model) 與機器學習方法中的分類迴歸樹 (Classification and Regression Tree, CART) 模型，採用分類迴歸樹可以找出重要的解釋變數，補足單純使用時間序列模型時較為缺乏的變數解釋。

本研究先以基於 Loess 函數的季節與趨勢分解方法 (Seasonal and Trend decomposition using Loess, STL) 將 BDI 分解為三部分：趨勢、季節、剩餘，以 ARIMA 校估並預測趨勢，以 CART 校估並預測剩餘部分，並以 CART 解釋影響季節的重要解釋變數再以平均絕對百分比誤差 (Mean Absolute Percentage Error, MAPE) 評估其預測準確度。最後比較本研究所提出之混合模型、單一 ARIMA 模型和單一 CART 模型對 BDI 進行預測之結果，結果顯示，混合模型的預測準確度較其它兩者高，且預測結果能明顯的表現出季節性與趨勢之特性，研究結果可提供海運業者做為經營與決策不定航市場方針之參考。

關鍵字：時間序列、預測、波羅的海乾散貨指數、STL 分解法、分類與迴歸樹、自我迴歸移動平均整合模型、混合模型

Using ARIMA and CART Hybrid Model to Predict Baltic Dry Index

Zi-Yu Liu

Tsung-Wei Shen

Department of Transportation and Communication Management

SUMMARY

International trade mainly relies on maritime transportation. The Baltic Dry Index (BDI) is an important indicator representing the freight rate of the dry bulk shipping market. However, analysis of this trend and the seasonal fluctuation patterns of the BDI have long been considered challenging. This research seeks to predict these elements by combining traditional time series model and data mining techniques into the hybrid model. Specifically, this work employs Seasonal and Trend decomposition using Loess (STL) to decompose the time series data into three components: the trend, seasonality, and reminders. The trend is predicted by an Autoregressive Integrated Moving Average (ARIMA) model, while the remainder is predicted by Classification And Regression Tree (CART) model. These two techniques were adopted because the ARIMA model is useful for trend prediction and the CART performs well when predicting non-linear time series data. BDI data collected between 1998 and 2016 was used to train and test the performance of the proposed method. The results show that combining the CART and ARIMA models enhances predictive performance not only with regards to the trend, but also to the fluctuations of the BDI. This was verified by the mean absolute percentage error, which showed that the overall prediction effect was good. The proposed method will provide a strategic analysis tool for dry bulk shipping carriers that can be used as a part of their greater decision-support system.

Key words: BDI, prediction, ARIMA, CART, hybrid model

INTRODUCTION

The dry bulk shipping market is a major component of the international shipping market, and of great interest to stakeholders such as ship owners, investors, and shippers. The Baltic Dry Index (BDI) reflects the dry bulk shipping market's characteristics of seasonality, cyclicalities, and high volatility, as well as its relationship to macroeconomic shocks.

For stakeholders, accurate prediction of the BDI's frequent fluctuations is a non-trivial task. However, because the BDI has been considered a non-stationary and non-linear rate series (Goulielmos & Psifias, 2009), the prediction of future rates is still challenging. From past to now, there are two key methods of predicting the BDI: traditional time series model and non-linear or machine learning model.

Traditional time series model is to estimate the future value based on the past or current value, Autoregressive Integrated Moving Average Model (ARIMA) is the most common method of traditional time series. It can precisely predict the short term (such as daily or weekly), but is not accurate enough for long-term prediction (Ho, Xie, & Goh, 2002). In addition, ARIMA is useful for predicting stationary/linear time series data, but has trouble in non-stationary/nonlinear time series data. However, the BDI is non-stationary and non-linear; therefore, the stationary and linear conditions are not met.

Non-linear and machine learning methods are gradually gaining the attention of researchers (Zeng, Qu, Ng, & Zhao, 2016). In the field of machine learning, Artificial Neural Networks (ANN) and Support Vector Machines (SVM) have been used in the analysis and prediction of BDI. Li and Parsons (1997) applied ANN in an investigation of the short-term and long-term prediction potentials of the tanker

freight rate, as well as a comparison of the prediction performances of ANN and the Autoregressive Moving Average (ARMA) model. The final comparison showed that ANN was significantly better than the time series model, especially for long-term prediction. Han, Yan, Ning, and Yu (2014) found that although ANN has good nonlinear approximation ability, its model structure is difficult to determine and easily affected by over- or under-training. Therefore, wavelet transform and SVM are proposed for predicting the BDI. Bao, Pan, and Xie (2016) also combined SVM with Correlation-based Feature Selection (CFS), which adding important factors related to BDI in SVM; the prediction accuracy produced by using SVM with CFS is better than when using ANN alone.

In the past literature of predicting BDI, traditional time series and machine learning methods perform well for linear and nonlinear data, respectively; but they are not all suitable for all problems, thus a hybrid model comes out. A hybrid model is proposed for solving complex problems with linear and nonlinear data, serving as an effective way of improving prediction accuracy (Zhang, 2003). In stock price forecasting, Pai and Lin (2005) used the hybrid model with ARIMA and SVM for predictions, and found that the hybrid model of ARIMA and SVM is better than single ARIMA model or single SVM model in the prediction performance. Faruk (2010) and Cadenas and Rivera (2010) also used a hybrid model with ARIMA and ANN to predict water quality and wind speed, and the hybrid model can better capture linear and nonlinear than single ARIMA model or single ANN model. All proved that the hybrid model performed well for their predictions, but in predicting BDI, to the authors' knowledge, there is still no relevant literature using hybrid model.

This study mainly decomposes BDI by season and trend using Loess (STL), analyzes the seasonality and trend characteristics of the index, and constructs a hybrid

model using the Autoregressive Integrated Moving Average model (ARIMA) and the Classification and Regression Tree (CART) to predict long-term (one-year) BDI, and then evaluates its prediction accuracy using the Mean Absolute Percentage Error (MAPE) calculation. Finally, the results of predicting BDI using the hybrid model proposed in this study are compared against the single ARIMA model and the single CART model used on their own. The results show that the prediction accuracy of the hybrid model is higher than the other two, and the prediction results can clearly show the characteristics of seasonality and trends in the market. The proposed method will provide a strategic analysis tool for dry bulk shipping carriers that can be used as a part of their greater decision-support system.

MATERIALS AND METHODS

First, pre-processing BDI time series data. Because most economic time series including BDI have trend and seasonal cycle characteristics, if the trend and seasonal characteristics in the original data can be separately extracted and used for analysis before the model is established, the accuracy of the prediction will be better than the direct use of the original data (Angelopoulos, 2017). In order to propose trends and seasonal periods in the BDI time series data, the STL decomposition method will be used to decompose the BDI into trends, seasons and remainders. Second, because CART cannot predict the trend, ARIMA is used for forecasting trend, while CART will predict the remainder. As for the seasonal part, it does not predict but finds the important variables that affect the seasonality of BDI. Finally, the predicted values of the various parts are added together to become a complete BDI prediction and the prediction results are judged by MAPE.

RESULTS AND DISCUSSION




圖 4-24 三種模型預測結果與測試資料 2015 年的比較⁴³

Figure1. Comparison of prediction results of three models and real data in 2015

Table1. Comparison of MAPE in 2015

表 4-13 2015 年 MAPE 的比較⁴³

	SARIMA model	CART model	Hybrid model
MAPE	21%	92%	16%




圖 4-25 三種模型預測結果與測試資料 2016 年的比較⁴³

Figure2. Comparison of prediction results of three models and real data in 2016

Table2. Comparison of MAPE in 2016

表 4-14 2016 年 MAPE 的比較

	SARIMA model	CART model	Hybrid model
MAPE	34%	59%	20%

CONCLUSION

The hybrid model is used to predict the decomposed BDI time series for one year. The trend is predicted by the ARIMA model, and the remainder is based on the seasonality, trend, and the previous period of BDI and the same period of last year as the classification factor of CART to make prediction. Seasonal factors are repeated values for 12 months (one year), so CART is only used to find important variables that affect seasonality without prediction, and learned that the international iron ore price index and the international steel price index are important variables affecting the seasonality of BDI. In 2015 and 2016, MAPE is predicted to be 16% and 20%, respectively, and the forecast is reasonable and can clearly see the seasonal and trend characteristics of BDI.

致謝

時光飛逝，轉眼間兩年的研究生生涯已結束，能完成這本論文主要感謝指導老師 沈宗緯 老師。從論文題目的決定到論文的完成，沈老師都始終給予我細心的指導和適時提供建議與方向，且不厭其煩的指導及修正，使我的論文能順利完成，在此致上最真誠的謝意。除了感謝指導老師外，也非常感謝口委林東盈老師和許聿廷老師的建議與指導，使論文更加的完整。

在這兩年多的求學時間中，感謝研究所的同學不時提供具有建設性的建議供我做為參考以及協助我解決技術上的困難，讓我的碩士論文能夠順利地進行。

最後也最重要的是，感謝我的媽媽，在求學期間給予我無限的支持，讓我能無後顧之憂，專心的讀書並好好地完成論文。在此謹以此學位獻給我親愛的媽媽和所有關心我的人！



劉姿妤 謹誌

國立成功大學 交通管理科學所

中華民國 108 年 8 月

目錄

第一章 緒論	1
1.1 研究背景與動機	1
1.2 研究目的	3
1.3 資料範圍	4
1.4 研究內容與流程	4
第二章 文獻回顧	6
2.1 BDI 之影響因素	6
2.2 BDI 趨勢及季節性	8
2.3 BDI 之預測方法	9
2.4 小結	12
第三章 研究方法	14
3.1 研究工具	15
3.2 STL 分解法	15
3.3 ARIMA	16
3.4 CART	19
3.5 混合模型	20
3.6 判斷預測準確度之指標	21
第四章 實證分析	22
4.1 資料蒐集	22

4.2 SARIMA 模型預測 BDI	23
4.2.1 資料判定	24
4.2.2 模型選擇	25
4.2.3 預測	26
4.3 CART 模型預測 BDI	28
4.3.1 模型建構	29
4.3.2 預測	32
4.4 混合模型	35
4.4.1 以 STL 分解 BDI 時間序列	36
4.4.2 影響季節性之重要因素	36
4.4.3 以 ARIMA 模型預測趨勢	37
4.4.4 以 CART 模型預測剩餘	38
4.4.5 ARIMA+CART 之混合模型	40
4.5 總結	47
4.5.1 模型結果比較	47
4.5.2 與過去文獻比較	50
第五章 結論與建議	52
5.1 結論	52
5.2 建議	53
參考文獻	54

中文文獻	54
英文文獻	55



圖目錄

圖 1-1	BDI 趨勢圖	2
圖 3-1	研究方法流程圖	14
圖 3-2	CART 二元分割規則	19
圖 4-1	1997 年-2016 年 BDI 月平均資料	22
圖 4-2	訓練組的 BDI 時間序列資料	24
圖 4-3	對 BDI 進行一次差分處理	25
圖 4-4	2015 年 BDI 預測結果	27
圖 4-5	2015 年 ARIMA 預測結果與實際值比較	27
圖 4-6	2016 年 ARIMA 預測結果與實際值比較	28
圖 4-7	2015 年 CART 模型的分類與預測結果	29
圖 4-8	2015 年 CART 配適值與訓練組	30
圖 4-9	2015 年調整後 CART 模型的分類與預測結果	31
圖 4-10	2015 年調整後 CART 配適值與訓練組	32
圖 4-11	2015 年 CART 預測結果與實際值比較	33
圖 4-12	2015 年 CART 預測結果與實際值比較(2012 年到 2014 年為訓練組)	34
圖 4-13	不同時間段影響 BDI 的重要變數對應圖	35
圖 4-14	對 BDI 進行 STL 分解	36
圖 4-15	2015 年影響季節性之重要變數	37
圖 4-16	預測 BDI 的趨勢	38

圖 4-17	2015 年 CART 模型分類與預測	39
圖 4-18	2015 年調整後 CART 模型的分類與預測結果	39
圖 4-19	2015 年混合模型預測結果與實際值比較	41
圖 4-20	2016 年混合模型預測結果與實際值比較	43
圖 4-21	2003 年混合模型預測結果與實際值比較	44
圖 4-22	2004 年混合模型預測結果與實際值比較	45
圖 4-23	2005 年混合模型預測結果與實際值比較	46
圖 4-24	三種模型預測結果與測試資料 2015 年的比較	48
圖 4-25	三種模型預測結果與測試資料 2016 年的比較	48



表目錄

表 2-1	BDI 之影響因素	7
表 3-1	ARIMA 階數判斷標準	17
表 3-2	MAPE 預測能力之評估標準	21
表 4-1	訓練組與測驗組	23
表 4-2	最適模型選擇	26
表 4-3	CART 超參數選擇	30
表 4-4	2015 年趨勢範圍值	40
表 4-5	2015 年各趨勢間預測準確度比較	40
表 4-6	2015 年 BDI 各部分預測值、預測值與實際值	41
表 4-7	2016 年趨勢範圍值	42
表 4-8	2016 年各趨勢間預測準確度比較	42
表 4-9	2016 年 BDI 各部分預測值、預測值與實際值	43
表 4-10	2003 年 BDI 各部分預測值、預測值與實際值	44
表 4-11	2004 年 BDI 各部分預測值、預測值與實際值	45
表 4-12	2005 年 BDI 各部分預測值、預測值與實際值	46
表 4-13	2015 年 MAPE 的比較	48
表 4-14	2016 年 MAPE 的比較	49
表 4-15	模型比較	49
表 4-16	與過去文獻比較	50

第一章 緒論

1.1 研究背景與動機

國際貿易是指不同國家或地區之間的商品、服務和生產要素交換的活動，也是各國之間分工的表現形式，反映了世界各國在經濟上的相互共存。雖然國際貿易已存在許久，但隨著近代交通、工業化、跨國企業以及全球化等概念和運作上的快速發展，國際貿易對國際的政治、經濟和文化都帶來了根本的改變，實際上，全球化同時意味著國際間的貿易日趨頻繁。隨著時間的經過，國際貿易的發展占國家經濟活動的重要性與日俱增，並對參與貿易的國家乃至世界經濟的發展具有重要作用，像是調節各國市場的供需關係，加強各國經濟聯繫，促進經濟發展。

再加上，近年來，隨著地球村時代的來臨，各國經濟互相關聯，產業全球化分工的態勢也愈趨明顯，使得國際貿易越發興盛，而在傳統貨運方式中，海運具有運量大且相對運費較低的特性，所以國際貿易是以海運為主。根據國際貨幣基金 (IMF) 1996 年的統計得知，全球貿易中海空客貨運所佔比例為 56.8%，其中貨運的比例為 31.4%，而貨運中採用海運運送者則佔 90%，由此可知對於國際貿易而言，海運佔有相當重要的地位。

海運依其船舶經營方式的不同可分為定期航運和不定期航運，定期航運主要是運送價值較高之包裝件貨與工業產品，有固定的航線、船期和停靠港，其航線和船期會事先公布，並以貨櫃船作為其主力，其中，定航的優點之一為有穩定的運費；而不定期航運則是以運送散裝乾貨(如鐵礦、煤炭、穀類和木材等)和石油為主，沒有固定的航線、船期和停靠港，全視貨物流動之需要而決定其航程。

不定期國際散裝海運市場具有國際市場之特性，它所面對的是一種全球性競爭，再加上與定期航運相比，它沒有固定的運價表，其運費通常是由市場船噸供需來決定，且

單一或少部分之船東或傭船人無法主導海運市場的變化，就其市場結構而言，屬於完全競爭市場。其次，海運產業景氣直接受到整個世界經濟景氣週期興衰起伏的影響，常有週期興衰循環，通常會循不景氣、衰退、持平、向榮、過熱之軌跡，重複循環。以週期來說，其常受天候、經濟、政治、港口擁擠、戰爭、天災、國際局勢變化及碼頭工人罷工等影響，其中，政治、戰爭及國際局勢的變化亦影響市場供需，造成運費的起伏變動大，而經濟之興衰亦對市場有影響。除了上述之因素，各國政府政策的取向、裝卸港口擁擠狀況、貨運時機、季節性、船舶本身供需、市場需求、市場壟斷及投機性操作等因素皆會影響海運市場運費之變動(林光、張志清，2014)

由於不定期國際散裝海運市場之運費起伏變動大，其市場充滿高風險性且不易預測，使得不定期航運面臨較高的風險與不確定性(Veenstra & Franses, 1997)，而波羅的海乾散貨指數(Baltic Dry Index , BDI)則反映了運價波動和整個乾散貨市場的狀況，藉由觀察 BDI 的變化，可得知不定期散裝海運市場景氣的好壞，是全球散裝航運運價之重要報價指標，圖 1-1 顯示 2014 年至今的 BDI 走勢。



圖 1-1 BDI 趨勢圖

在 1985 年，波羅的海交易所開始公布每日運費指數 (Baltic Freight Index , BFI)，

該指數是由全球十三條論程傭船路線所組成，但在 1999 年，被波羅的海乾散貨運價指數(Baltic Dry Index , BDI)所取代。一開始，BDI 是由三個子市場所組成，分別是波羅的海海岬型船運價指數(Baltic Capesize Index , BCI)、波羅的海巴拿馬極限型船運價指數(Baltic Panamax Index , BPI)和波羅的海輕便型船運價指數(Baltic Handysize Index , BHI)。之後，經過一段時間的演變，現在的 BDI 依其船舶載重噸之大小，分為四個子市場，依次為波羅的海海岬型船運價指數(BCI)、波羅的海巴拿馬極限型船運價指數(BPI)、波羅的海超輕便極限型船運價指數(BSI)和波羅的海輕便型船運價指數(BHSI)。

波羅的海乾散貨指數作為船東佈設船隊規模和租傭船人傭船決策的重要根據，依據過去歷史資料及預測未來景氣以判斷不定期航運市場景氣好壞，換句話說，BDI 對不定期散裝海運市場而言是不可或缺的。然而，準確預測 BDI 未來的走向對船東和租傭船人來說仍極具挑戰性。因此，本研究將建立混合模型預測 BDI，如果能有效掌握運價的趨勢，就能降低船東和租傭船人的風險，並提供給經營者作為經營與決策不定航市場之參考。

1.2 研究目的

根據前述之研究背景與動機，本研究的主要目的為：

1. 過去使用單一模型方法於時間序列資料預測的結果顯示，傳統時間序列方法及機器學習方法各有其優缺點，因此本研究嘗試提出一混合方法 (Hybrid Method)，亦即對於分解後的趨勢及週期時序資料分別採用 ARIMA 及 CART 構建預測模型。
2. 比較本研究所提出之混合模型結果與直接採用季節性 ARIMA 模型及機器學習 CART 模型之預測結果。
3. 提供影響預測模型之解釋變數，降低船東和租傭船人的風險，並提供給經營者作為經營與決策不定期航運市場之參考。

1.3 資料範圍

本研究在以 CART 進行預測時，將會加入與 BDI 相關之因素，包括國際鋼鐵價格指數、國際煤炭價格指數、國際大豆價格指數、國際玉米價格指數、國際鐵礦砂價格指數、國際燃油價格指數、和中國經濟成長率。除了中國經濟成長率為季資料，其餘皆為日資料，然而本研究於校估及預測皆採用每月 BDI 之平均值，因此變數若為日資料則取月平均數，若變數僅有季資料則該季之各月份均採用該季之數值。受限於部分變數資料更新較遲，研究進行時，所有變數之統計數字以 2016 年 12 月份為最近一個月之資料。

1.4 研究內容與流程

本研究由以下五個部分所構成：

1. 緒論

內容包括研究背景與動機、研究目的、研究範圍與限制、研究內容和研究流程與架構，主要是針對研究背景加以探討，包括海運為何重要、不定期國際散裝海運市場之特色和 BDI 演變史，在界定出本研究的問題，並對本研究的目的與範圍加以確定。

2. 文獻回顧

進行相關文獻蒐集與回顧，包含 BDI 之影響因素、BDI 趨勢及季節性和 BDI 之預測方法。

3. 研究方法

說明本研究欲使用之方法，包括時間序列分解-STL 分解法(Seasonal and Trend decomposition using Loess)、整合移動平均自回歸模型(Autoregressive Integrated Moving Average model, ARIMA)、分類與回歸樹法(Classification and Regression Tree , CART)和平均絕對誤差率(Mean absolute percentage error, MAPE)之模式與應用。

4. 實證分析

使用 R 統計軟體，將蒐集到之 BDI 資料輸入 R 中，並以 STL 分解法進行時間序列的分解，再結合傳統時間序列模型 ARIMA 和資料探勘中之分類與迴歸樹法 (Classification and Regression Tree , CART) 之混合模型進行預測，最後以絕對誤差平均值 (Mean absolute percentage error , MAPE) 評估預測的準確度。

5. 結論與建議

根據實證分析所得之結果，進行整理，並對未來之相關研究者提出建議



第二章 文獻回顧

2.1 BDI 之影響因素

影響 BDI 變化之因素種類相當的多，且海運景氣波動直接受到整個世界經濟景氣週期興衰起伏的影響，以週期來說，其常受天候、經濟、政治、港口擁擠、戰爭、天災、國際局勢變化及碼頭工人罷工等影響，其中，政治、戰爭及國際局勢的變化亦影響市場供需，造成運費的起伏變動大，而經濟之興衰亦對市場有影響。除了上述之因素，各國政府政策的取向、裝卸港口擁擠狀況、貨運時機、季節性、船舶本身供需、市場需求、市場壟斷等因素皆會影響海運市場運費之變動(林光、張志清，2014)。但在上述因素中，天候、政治、戰爭、天災、政治、各國政府政策的取向及國際局勢的變化無法量化，因此本研究不加以探討。

Papailias, Thomakos, and Liu (2017)蒐集了煤、銅、玉米、棉花、鐵(礦石)、錫、小麥、布倫特原油、英鎊與美元的匯率、美元指數和 10 年期與 2 年期美國國債收益率之間的差異等變量，並以年增長率表示，再與 BDI 之年增長率進行比較，最後發現與 BDI 年百分比變化最重合的變量為銅、煤、錫、原油、鐵和棉花。

呂學樺 (2008)則提出散裝海運市場上的供需問題為影響散裝船運價最重要的因素，並以複迴歸分析對國際鋼鐵價格、西德原油價格、國際鐵礦砂價格、澳洲煤炭價格、穀物價格、澳洲港口擁擠指數、季節性、全球經濟成長率和中國經濟成長率進行分析，最後結果發現，除了西德原油價格和全球經濟成長率外，其餘的因素對 BDI 皆為顯著影響。

梁容禎 (2006) 把影響 BDI 之因素分為五個方面，船噸供給、船噸需求、貨物供給、貨物需求和其他因素，如表 2-1 所示。

表 2-1 BDI 之影響因素

因素歸納	可能影響因素
船噸供給	國際經濟、拆船與新造船數量與載重噸數、乾散貨船噸需求、塞港效應等
船噸需求	散裝貨物需求等
貨物供給	供給國家貨物量變化、運送貨物價格變化等
貨物需求	國家經濟成長、貨載量變化等
其他因素	天災、戰爭、疾病等

資料來源:梁容禎(2006)

在表 2-1 中所提到之貨物為乾散貨船運主要裝載之貨物，包括鐵礦砂、煤礦及穀類，而國家經濟成長條件主要是以中國為主，近年來，中國經濟快速增長，對世界基礎原材料的需求不斷擴大，使其貿易成為目前世界乾散貨運輸價格的主要影響因素。

Alizadeh and Nomikos (2003)應用 GARCH-X 模型分析在二手幹散貨船市場中價格波動與交易量之間的關係，發現價格變化與乾散貨船買賣市場活動之間存在顯著的正相關關係。

從上述四篇文獻中得知，影響 BDI 可量化因素包含散裝貨物需求(銅、煤、錫、原油、鐵、棉花)、運送貨物價格變化(國際鋼鐵價格、國際鐵礦砂價格、穀物價格、澳洲煤炭價格)、塞港效應(澳洲港口擁擠指數)、季節性、國際經濟 (全球經濟成長率、中國經濟成長率)和乾散貨船噸需求(二手幹散貨船市場交易量)。

2.2 BDI 趨勢及季節性

商業週期理論說明經濟的整體移動趨勢，典型的商業周期特徵為波峰和波谷的出現頻率在 3 到 5 年之間，而海運的乾散貨市場亦具備週期循環，因此有許多研究分析其循環特性。由於航運市場的全球化性質以及對地緣政治事件和全球經濟狀況的相關敏感性，其市場週期特性不易掌握，乾散貨市場更是如此。航運週期大約持續 7 年，而海運的乾散貨市場亦具經濟循環之特性，通常會循不景氣、衰退、持平、向榮、過熱之軌跡，反覆演變 (林光，2014)。根據最近的研究表示，從 1993 年至 2015 年 (以月為資料)，顯示 BDI 平均週期為 3 至 5 年 (Papailias, Thomakos, & Liu, 2017)。另外，Chisté and Van Vuuren (2014) 透過 Hodrick–Prescott filter (HP filter) 趨勢提取分析法，發現儘管 7 年的海運週期循環為普遍被人接受的經驗法則，但此研究亦發現 BDI 於 1990-2012 年間具有一個明顯的 4 年週期趨勢。

其次，乾散貨運送的主要對象包含煤炭、原油、鋼鐵、鐵礦石等工業原料，及玉米，小麥等製造食品所需的穀物，因此 BDI 變化也與商品市場密切相關 (Papailias et al., 2017)。在大多數情況下商品具有一些確定性的季節性成分，例如，工業生產和穀物貿易存在季節性因素，而這些季節性可能會影響到運費和價格 (Kavussanos & Alizadeh-M, 2001)，此外，Denning, Riley, and DeLooze (1994) 發現波羅的海運費指數 (BFI) 中存在季節性因素，因此 BDI 不但具有周期趨勢，也具有季節性。

大多數經濟時間序列，包括 BDI，都包含趨勢及季節性周期，因此，若在建立模型前，若能將原始資料去除趨勢及季節性因素再進行分析，其預測準確度將較直接採用未去除趨勢及季節的方法為佳 (Angelopoulos, 2017)。其中，基於 Loess 函數的季節-趨勢分解方法 (Seasonal and Trend decomposition using Loess, STL) 為常被使用於「提取」趨勢與季節部分的方法，Pao and Sullivan (2017) 以 STL 分解美國百貨商店每週銷售量之時間序列資料，並結合自我迴歸移動平均整合模型 (Autoregressive Integrated Moving

Average model, ARIMA)進行預測，結果顯示其預測效果比以原始資料預測佳。此外，Hodrick – Prescott filter (HP filter)(Chisté & Van Vuuren, 2014)和經驗模式分解(Empirical Mode Decomposition, EMD)(Angelopoulos, 2017)皆為適用於趨勢提取的方法，並在與時間序列相關資料中被應用。

2.3 BDI 之預測方法

過去，許多學者致力於建構適合 BDI 預測之模型，而其預測方法的演進可從多變量預測、傳統時間序列預測到现在的非線性(non-linear)和資料探勘方法預測。多變量預測即使用多個自變數來預測目標變數，其中模糊分段迴歸模型已用於波羅的海乾散貨運價市場的分析與預測。

迴歸分析是多變量預測裡最基本且最常見的方法，它的用處在於了解變數間是否有關，並且觀察特定的自變數來預測研究者感興趣的目標變數。在找出與 BDI 這個目標變數有關的自變數中，國際鋼鐵價格、國際原油價格、國際煤礦價格、鐵礦砂價格、穀物價格、澳洲港口擁擠指數、全球的經濟成長率及中國的經濟成長率預測波羅的海乾散貨運價指數皆被選取，在進行完複迴歸分析後，其研究結果顯示，中國的經濟成長率、鋼價、煤價、鐵礦砂價格對波羅的海乾散貨運價指數有顯著影響(呂學樺, 2008)。除了上述八個變數被測試外，鋼鐵貿易量及煤礦貿易量也被測出對 BDI 也有顯著影響(Papailias et al., 2017)。另外，許多學者會直接把 BDI 當作最終要預測的目標變數，但也有把 BDI 結合其組成指數，BCI、BPI 和 BHMI 來進行預測，並與直接用 BDI 做預測之模型進行比較，研究結果發現，在結合的組成指數中，CRU 亞洲鋼鐵指數及 CRB 農業指數顯著影響 BDI，且也證明了直接預測的效果較佳(梁容禎, 2006)。

模糊分段迴歸模型則是由傳統的迴歸分析演變而來，它是把模糊觀點套用於迴歸分析來處理模糊性資料問題。傳統迴歸分析與模糊迴歸分析他們之間不同的地方在於對誤差項的定義，前者定義觀測值與模式估計值間之誤差項，是由於資料在蒐集和處理時的

失誤所造成，而後者則定義為誤差項是由於系統模糊不清所造成。由模糊分段回歸之結果進行分析，可知以二手船價格之 Capesize 船型及新造船價格之 Panamax 船型為影響 BDI 波動最重要之因素。藉上述影響因素投入預測模式中，可得知即時的散裝運輸 BDI (劉虹君, 2006)。

傳統時間序列預測即僅根據歷史時間序列的趨勢發展來預測未來時間序列的趨勢發展的方法，不須像多變量預測，需藉由其餘的自變數來預測目標變數，而其中自我迴歸移動平均整合模型(Autoregressive Integrated Moving Average model, ARIMA)最常被用於 BDI 的分析與預測中。

ARIMA 是傳統時間序列預測中最常被用來預測 BDI 的方法，因為它所需要的資料量比較少，且適合短期預測。陳桓毅 (2006)用 ARIMA 和指數平滑法及灰預測進行 BDI 之預測，並比較在不同預測時間長度的準確度。該研究發現在日預測中，以 ARIMA 較佳；對於週預測及月預測，以灰預測 GM(1,1)模型較佳，然而對於季預測而言，雖然灰預測 GM(1,1)模型較指數平滑法模型為佳，但是兩者之精確度偏低，因此這三種方法，用於 BDI 資料之長期預測皆有其侷限。

由於傳統時間序列適用於穩定的時間序列資料 (Stationary Time Series)，而在不定期散裝海運市場中，BDI 常被視為非穩定的時序資料 (Non-Stationary Time Series)，且 BDI 中包含著經濟起伏與衰退等特徵，因此若以傳統時間序列方法方法(如前述的複迴歸及 ARIMA)似乎難以準確預測(Pao & Sullivan, 2017)。基於此，非線性 (non-linear) 和機器學習 (Machine Learning, ML) 方法逐漸受到研究者的重視(Zeng et al., 2016)。

在機器學習領域中，人工神經網路(artificial neural networks , ANN)、支持向量機(support vector machines , SVM) 皆已被用於 BDI 的分析與預測中。Li and Parsons (1997)應用人工神經網路(Artificial Neural Network, ANN)探討對油輪運費的短期和長期預測的潛力，並且進行了神經網絡與自迴歸滑動平均模型(Autoregressive moving average model, ARMA) 時間序列模型之間預測性能的比較，最後比較結果顯示，神經網絡明顯優

間序列模型，尤其是對於長期預測。Han et al. (2014)發現神經網絡雖具有良好的非線性近似能力，但其模型構造卻很難決定，並且容易受到過度訓練或訓練不足的影響，因此提出以小波變換(wavelet transform)和支持向量機對 BDI 進行預測，並將該方法的結果與人工神經網路進行比較，結果表明，該方法具有較高的準確度，此外，Bao et al. (2016)也把支持向量機與基於相關的特徵選擇(Correlation-based Feature Selection ,CFS)進行結合，並且為了評估支持向量機的預測能力，將它與神經網絡模型進行比較，結果表明，支持向量機模型在趨勢和預測精度方面均有較好的表現。

然而，對決策者而言，更重要的是要解釋影響 BDI 的因素，但使用 ANN 模型或是 SVM 模型則難以提供決策者上述資訊。而分類與迴歸樹(Classification And Regression Tree , CART)則可以解釋影響 BDI 的因素，CART 是用於分析非線性和非平穩資料的一種機器學習方法，它可以減少 ANN 中的低解釋性問題，也可以解決 SVM 在決策階段不明確的問題，且 CART 也已經廣泛應用於各個領域，在醫學方面，決策樹被用來預測大腸癌病患淋巴轉移(張偉斌, 2011)；在金融方面，已被用來預測現金之持有 (王珮紋, 2012)；在天氣方面，氣溫和雨量皆被預測(林宇恆, 2013)；在海運方面，定期航運客戶的保留性則被預測(Lin, L.-H., et al., 2017)，但仍然沒有使用 CART 在預測或分析 BDI 的相關文獻。

由上述回顧可知，傳統時間序列預測與機器學習方法在各自的線性與非線性預測中表現良好，但是，對於所有想預測的問題而言，它們並非全都適用，因此 Zhang (2003)提出了 ARIMA 與 ANN 的混合模型，用於解決線性和非線性資料的複雜問題，從而有效地提高預測精度，對於具有線性和非線性相關結構的複雜問題，混合模型為一個能提高預測性能的有效方法。在股票預測中，Pai and Lin (2005)以 ARIMA 和 SVM 的混合模型來進行預測，發現預測性能優於單一 ARIMA 模型或單一 SVM 模型。Faruk (2010)和 Cadenas and Rivera (2010)也應用 ARIMA 和 ANN 混合模型分別對水質和墨西哥的風速進行預測，結果皆表明，混合模型可以比單一 ARIMA 模型或單一 ANN 模型更好地捕

獲線性和非線性模式。這些研究都證明了混合模型的預測表現良好，但在海運方面時，據本研究所知，仍然沒有足夠的文獻使用混合模型。

2.4 小結

由文獻整理與研究得知，原物料價格(煤礦及鐵礦砂等)、國際燃油價格、民生基本物資價格(大豆、小麥、玉米等)、新船與二手船價格和國家經濟(中國)這些因素為與 BDI 相關因素中過去文獻最常探討與分析的，再加上 BDI 具有季節性和趨勢的特性，與上述之因素息息相關，因此 BDI 之變動與其重要因素之變動互相關聯。

在 BDI 預測方法中，可大致分為兩大類，傳統時間序列預測與非線性(non-linear)和資料探勘方法預測。因 BDI 屬於非穩定的時序資料，而傳統時間序列預測中，過去常使用的灰預測和 ARIMA 傳統時間序列模型雖能準確的進行線性的時間序列預測，但對於長期的時間序列中所隱藏的非線性關係卻無法準確預測。而非線性方法如機器學習則較易處理此類問題，目前，人工神經網路和支持向量機皆已被應用，但仍有其缺失，特別在時序資料難以被決定究竟是否為穩定或屬於線性問題時。因此，結合傳統時間序列模型與其他機器學習方法的混合模型被認為有較佳的預測準確度與解釋能力。

資料探勘中分類迴歸樹(CART)演算法在解決分類和預測上有著極大的能力，且能改善人工神經網路和支持向量機的缺失。人工神經網路模型具有不能觀察其學習過程，且輸出結果難以解釋的問題，而支持向量機也具有在決策階段不明確的問題。但分類與迴歸樹則能在進行分類預測時，得知哪些因素為預測目標的重要變數，並產生可理解的規則且易於解釋，目前已被應用於許多領域，但在海運方面，還未被用來預測分析 BDI。

綜合以上因素，本研究將先提取 BDI 的趨勢及季節性資料，在所欲使用的預測模型中，將使用混合模型，利用機器學習中的決策樹 CART 演算法對 BDI 之剩餘部分進行預測，並結合傳統時間序列模型 ARIMA 預測趨勢部分，期望此方法能夠降低船東和租

傭船人的風險，並提供海運業者作為經營與決策不定期航運市場方針之參考。



第三章 研究方法

本章將介紹以混合模型預測長期(一年)BDI 所會使用到的方法，包括基於 LOESS 函數的季節性趨勢分解法(Seasonal and Trend decomposition using Loess, STL)、整合移動平均自回歸模型(Autoregressive Integrated Moving Average model, ARIMA)、分類與迴歸樹(Classification and Regression Tree, CART)、混合模型和對預測準確度做判斷的指標：平均絕對誤差率(Mean absolute percentage error, MAPE)和均方根誤差(root mean square error, RMSE)，整體流程如圖 3-1 所示。




圖 3-1 研究方法流程圖

圖 3-1 中，步驟一為預先處理 BDI 時間序列資料，因為包括 BDI 在內的大多數經濟時間序列具有趨勢和季節週期特性，因此，如果原始資料中的趨勢和季節特性可以在模型建立之前分別提取並用於分析和預測，其預測的準確性將優於直接採用原始資料 (Angelopoulos, 2017)，為了提出 BDI 時間序列資料中的趨勢和季節性週期，將會使用 STL 分解法把 BDI 資料分解為趨勢、季節和剩餘三個部分 (Cleveland, Cleveland, McRae, & Terpenning, 1990)。在步驟二中，由於 CART 無法預測趨勢，因此使用 ARIMA 進行預測，而 CART 將預測剩餘部分，至於季節性部分則不進行預測而是找出其影響 BDI 季節性之重要變數。最後在將各部分之預測值相加起來成為一個完整的 BDI 預測值。在步驟三中，將預測結果以 MAPE 和 RMSE 判斷其預測準確度。

3.1 研究工具

本研究使用 R 語言來做分析，R 語言是由紐西蘭奧克蘭大學的羅斯·伊哈卡和羅伯特·傑特曼開發，可在 <https://www.r-project.org/> 免費下載。其主要用於資料探勘、統計分析和繪圖。數字分析與統計學在 R 內建中有相當多種，其功能可以透過用戶撰寫的套件來增強，並應用於人文科學研究、經濟計量、人工智慧和財經分析等各層面。

3.2 STL 分解法

基於 Loess 函數的季節性趨勢分解法 (Seasonal and Trend decomposition using Loess, STL) 是一種通用於分解時間序列的穩健方法，它把一個季節性的時間序列分解為三個部分：趨勢、季節和剩餘。假設把時間序列資料、趨勢部分、季節部分和剩餘部分個別由 Y_t 、 T_t 、 S_t 和 R_t 來表示，且 $t=1$ 到 N ，則

$$Y_t = T_t + S_t + R_t$$

其次，STL 主要可分為內迴圈和外迴圈，其中內迴圈主要是做趨勢配適和季節性部

分的計算，而外迴圈主要是調節穩定性權重。

另外，STL 有以下這些優點：

1. 能處理任何類型的季節性
2. 允許季節性部分隨時間變化，並且使用者可以控制變化率
3. 趨勢部分的平滑度也可以由使用者控制
4. 使用者對異常值可以指定穩健的分解，因此偶爾的異常觀察不會影響趨勢部分和季節性部分的估計，但會影響到剩餘部分

(Cleveland et al., 1990)

3.3 ARIMA

自我迴歸移動平均整合模型(Auto Regressive Integrated Moving Average of order (p, d, q)簡稱為 ARIMA(p, d, q))為現在最常用的時間序列模型之一，是由自我回歸模式(Auto Regression, AR)、差分處理項(Integrated, I)和移動平均模式(Moving Average, MA)所組成，其最先由(Box & Jenkins, 1976)所提出，因此又稱 Box-Jenkins 預測模型，一般的表示式為：

$$y_t = \theta_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1)$$

其中：

y_t 為實際值

ε_t 為在時間段 t 的隨機誤差

p、d、q 為非負整數

p 為自我回歸級數，是模型中使用的滯後數

q 為移動平均級數，是用來確定在模型中先前誤差項的順序

d 是差分階數

ARIMA 模式建立之步驟:

1. 資料判定

在建立 ARIMA 模型時，時間序列資料須為定態資料，若序列資料不平穩或有趨勢，為非定態時，則對其進行差分程序， d 值即代表此序列需要取差分之次數，差分完成後便可轉為定態之資料。

2. 模型判定

利用樣本之自我相關函數(Sample Autocorrelation Function, ACF)與偏自我相關係數(Sample Partial Autocorrelation Function, PACF)來判斷 p 與 q 之階數。透過 ACF 可得知是否受殘差像移動平均之影響，係數 q 為決定殘差像移動平均之落差期數；透過 PACF 則可得知是否受自我相關之影響，係數 p 則為決定自我相關之落差期數。表 3-1 為 p 階與 q 階之階次判斷標準。

表 3-1 ARIMA 階數判斷標準

模型	ACF 圖形	PACF 圖形
AR(p)	逐漸消失	自 p 階後即明顯消失
MA(q)	自 q 階後即明顯消失	逐漸消失
ARMA(p, q)	逐間消失	逐漸消失

在利用 AIC(Akaike Information Criterion)和 SBC(Schwarz Bayesian Criterion)為選擇

最適模型之判斷標準。AIC 較適合評估自我回歸模型，SBC 則較適合於評估準則，當 AIC 與 SBC 值越低，代表其配適度越佳。

3. 參數估計

選擇參數使得隨機誤差之平方加總為最小。

4. 模型檢定

檢定模型之殘差是否符合白噪音，也就是模型之殘差項是否呈現自我相關，若符合則可進行預測，反之則須重新選擇。通常利用 Ljung-Box(1978)提出之修正 Q 統計量為判斷標準，模式檢定公式如下：

假設 $H_0: \alpha_1 = \alpha_2 = \dots = \alpha_n$

修正 Q 統計量公式

$$Q_k = m(m+2) \sum_{n=1}^k (T-n)^{-1} p_e^2(n) \sim X_{k-p-q}^2 \quad (2)$$

其中，m 為序列之觀察數

K 為計算之殘差自我相關值個數

p 與 q 為模型之參數個數

若 $Q > X_{k-p-q}^2$ 則表示殘差項之相關係數過大，該模型不配適，需重新估計。

5. 預測

在完成資料判定、模型判定、參數估計和模型檢定，並決定最適模式後，用此模式進行預測。

而季節性自我迴歸移動平均整合模型(Seasonal Auto Regressive Integrated Moving Average of order (p, d, q)(P,D,Q)m，簡稱為 SARIMA(p, d, q)(P,D,Q)m)為具有季節性的 ARIMA，能處理有季節性特性的時間序列模型。模型中的 p、d 和 q 為非季節性部分，而 P、D 和 Q 為季節性部分，而 m 為其預測週期長度，模型建構方式與 ARIMA 類似。

3.4 CART

分類與迴歸樹(Classification And Regression Tree , CART)是決策樹的一種演算法，由 Breiman, Friedman, Olshen, and Stone (1984)所提出。其決策樹可依據不同的狀態，用“if-then”的規則來進行分類，以提高預測之能力。它結合了分類與迴歸的功能，若最終之節點為連續變量時，其為迴歸樹；若為分類變量，則是分類樹。

CART 是一種二元分割(binary)的方法，若節點為分類變量，以 Gini Index 來當作分割的基準，假設樣本點屬於左邊的機率是 P_L ，則分類示意圖如圖 3-2 所示，其計算機率分布的 Gini Index 定義為：

$$\text{Gini}(P_L) = 2 * P_L * (1 - P_L) \quad (3)$$




圖 3-2 CART 二元分割規則

若節點為連續變量，則其分割的基準為：

$$i(t) = \sum (y - \bar{y}_t)^2 \quad (4)$$

其中， $\bar{y}_t$ 為被分到 t 節點中之樣本平均值，而 y 為在節點 t 中的樣本點

接著，極大的減少節點的不純度(impurity)，生成一個分割點，使節點分割成兩個子

節點 N_L 和 N_R ，其分割點的計算為：

$$i(t) - i(t_L) - i(t_R) \quad (5)$$

在完成樹之建構後，需要進行修剪，以避免過度配適(over-fitting)。其方法有預先修剪和事後修剪這兩種。預先修剪主要是以控制決策樹的生長為目標，運用事先的參數指定，像是決策樹之深度，若其深度達到指定深度則停止生長。事後修剪則是在決策樹長完後，根據其規則，剪去沒有代表性的子節點和葉節點。適當的修剪可提高分類與預測的準確性。

3.5 混合模型

由於 BDI 時間序列包括季節性、趨勢和由隨機事件引起的剩餘等各種特徵，因此 BDI 的行為不易被單一模型（如 ARIMA 或 CART）捕獲。雖然 ARIMA 和 CART 模型分別在線性和非線性領域中表現良好，但它們並不適合於處理所有的情況。因此，具有線性和非線性模型能力的混合模型是預測 BDI 時間序列的良好選擇，本文提出的混合模型是由 ARIMA 模型和 CART 模型所組成，其模型可由下列公式所示：

$$Y_t = L_t + N_t \quad (6)$$

其中， L_t 代表線性部分， N_t 代表非線性部分。第一個 ARIMA 模型是用於模擬線性部分，因此 BDI 的趨勢部分交由 ARIMA 處理，然後 BDI 值在減去固定的季節性和由線性處理的趨勢部分後，殘差將只包含屬於非線性關係的剩餘， Y_t 是混合模型在時間 t 時的預測值，而 e_t 是 ARIMA 模型在時間 t 的殘差，其公式為：

$$e_t = Y_t - \hat{L}_t - S_t \quad (7)$$

其中， $\hat{L}_t$ 是 ARIMA 模型在時間 t 時的預測值， S_t 是季節性在時間 t 時的值，殘差則由 CART 來建構模型以預測非線性關係的剩餘。

3.6 判斷預測準確度之指標

MAPE

平均絕對百分比誤差(Mean Absolute Percentage Error , MAPE)的基本概念為計算預測值與實際值之差距來評估預測準確度，其公式如式：

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| * 100\% \quad (8)$$

其中， y_t 為實際值， $\hat{y}_t$ 為預測值

因其為絕對值，不受實際值與預測值之單位與大小影響，能客觀的判斷兩者之間的差異。根據 Lewis 所訂最有效之評估標準，將 MAPE 的預測準確度分為四種，如表 3-2 所示

表 3-2 MAPE 預測能力之評估標準

MAPE 值	預測能力
<10%	高度精確
10%~20%	良好
20%~50%	合理
>50%	不正確

RMSE

均方根誤差(root-mean-square error, RMSE)是一種常用的測量數值之間差異，在不同的時間下，以一個量值來表現其預測的能力，其公式如式：

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2} \quad (9)$$

第四章 實證分析

4.1 資料蒐集

本研究蒐集了 1997 年 1 月到 2016 年 12 月的每日 BDI 資料，但在每日資料中有時會有資料缺失，因此取其月平均作為研究目標，圖 4-1 為 1997 年 1 月到 2016 年 12 月的 BDI 月平均資料。




圖 4-1 1997 年-2016 年 BDI 月平均資料

除了 BDI 每日資料的蒐集，同時也蒐集了與 BDI 相關之因素，並在應用 CART 模型時進行分析預測，包括國際鋼鐵價格指數、國際煤炭價格指數、國際大豆價格指數、國際鐵礦砂價格指數、國際玉米價格指數、國際燃油價格指數和中國經濟成長率。除了中國經濟成長率為每季紀錄，其餘的皆為每日紀錄，為了與 BDI 的時間長度相同，皆會取其月平均做為資料的時間長度。因 BDI 相關因素過去資料的蒐集只記錄到 2017 年 6 月，因此全部資料皆只蒐集到 2016 年 12 月。

在本研究中，會對資料進行分組，分為訓練組與測驗組。訓練組中的資料用於模型的建構，而測驗組中的資料則是用已建構完成的模型進行預測。海運的乾散貨市場具有週期循環，Papailias et al. (2017)發現從 1993 年至 2015 年，BDI 的平均週期為 3 至 5 年，因此本研究以 5 年為一個周期循環，而訓練組也以 5 年為一個基準，表 4-1 為研究中將測試的訓練組與測驗組。

表 4-1 訓練組與測驗組

訓練組	測驗組
1998 年到 2002 年	2003 年
1999 年到 2003 年	2004 年
2000 年到 2004 年	2005 年
2010 年到 2014 年	2015 年
2011 年到 2015 年	2016 年

因 2007 年至 2008 年發生了全球金融危機，為了避免特殊事件影響到資料的訓練與預測，資料的分析預測會略過全球金融危機的前後(2006 年-2009 年)。其次，除了主要分析預測 2015 年和 2016 年，也會對 2003 年至 2005 年進行分析預測，以求混合模型在不同時間段的準確性。

4.2 SARIMA 模型預測 BDI

以季節性自我迴歸移動平均整合模型(Seasonal Auto Regressive Integrated Moving Average of order (p, d, q)(P,D,Q)m，簡稱為 SARIMA(p, d, q)(P,D,Q)m)對 BDI 時間序列進行預測，在應用 SARIMA 預測時間序列前，需先符合 SARIMA 模型的假設，資料為穩定且為單變量，其建構模型的步驟分別為：

1. 判別資料是否穩定
2. 選擇最適模型
3. 預測

4.2.1 資料判定

在步驟一中，我們要先判別訓練組(2010 年-2014 年)的 BDI 時間序列資料(圖 4-2)是否穩定，以迪基-福勒檢驗(Dickey-Fuller Test)作為判斷方法。




圖 4-2 訓練組的 BDI 時間序列資料

在迪基-福勒檢驗中，虛無假設為資料不是穩定的而對立假設則為資料是穩定的，當 p -value 值小於 α ，則拒絕虛無假設，代表其資料是穩定的。對 BDI 時間序列資料進行檢定後，其 p -value 值為 0.4999，大於 $\alpha = 0.05$ ，因此判定其資料為不穩定，需進行差分處理，使其資料趨於穩定。

對 BDI 時間序列進行一次差分處理，意即把後一個數值減去前一個數值，使原本有季節性和趨勢的非平穩時間序列轉換為平穩的時間序列，圖 4-3 為進行一次差分後的時

間序列，可以看到資料已沒有往上或往下的趨勢，而是在 0 上下起伏，因此可以判別，在進行一次差分後($d=1$)，資料已穩定。進行迪基-福勒檢驗後，其 p -value 值為 0.01，小於 $\alpha = 0.05$ ，因此可以判定資料是穩定的。




圖 4-3 對 BDI 進行一次差分處理

4.2.2 模型選擇

在步驟二中，我們以 `auto.arima` 自動生成預測模型，`auto.arima` 會自動處理非季節性部分(p,d,q)和季節性部分(P,D,Q)的參數選擇，在生成的模型中以 AIC(Akaike Information Criterion)為選擇最適模型的判斷標準，當 AIC 值越低，代表其配適度越佳。在表 4-2 中，模型(0,1,0)(1,0,0)[12]的 AIC 值為最小，因此選擇 (0,1,0) (1,0,0)[12]為最適模型。

表 4-2 最適模型選擇

模型(p,d,q)(P,D,Q)m	AIC 值
(2,1,2)(1,0,1)[12]	874.6027
(1,1,0)(1,0,0)[12]	875.2073
(0,1,1)(0,0,1)[12]	874.5327
(0,1,0)(1,0,0)[12]	874.3729
(0,1,0)(0,0,1)[12]	874.8817

4.2.3 預測

最後，以最適模型(0,1,0)(1,0,0)[12]對 2015 年的 BDI 進行預測(圖 4-4)。在圖 4-4 中，藍色的線為預測結果，灰色區域表示預測值的 95%信賴區間，而長期預測通常具有更多的不確定性，因此隨著時間序列資料的增加，信賴區間也越來越寬，這代表著估計值的誤差變得越來越大。

圖 4-5 為預測結果與實際結果(2015 年)的對照，從圖中可以發現，以 SARIMA 模型所做出的預測有趨勢以及季節性的特徵，但其季節性特徵在七月到八月時與實際值相比有明顯的落差，以乾散貨市場的淡旺季而言，在七月和八月為其淡季，但在 2015 年卻成為一整年中指數最高的月份。以 MAPE 值做判斷，其 MAPE 值為 21%，預測合理。




圖 4-4 2015 年 BDI 預測結果




圖 4-5 2015 年 ARIMA 預測結果與實際值比較

接著，以同樣的 SARIMA 模型(0,1,0)(1,0,0)[12]對 2016 年的 BDI 進行預測，並與

2016 年的 BDI 實際值進行比較，結果如圖 4-6 所示。在圖 4-6 中，預測結果趨於一直線，無法凸顯出其季節性與趨勢的特徵，其次，以 MAPE 值判斷其模型準確度，其值為 34%，雖為合理預測但錯誤率偏高。




圖 4-6 2016 年 ARIMA 預測結果與實際值比較

4.3 CART 模型預測 BDI

以分類與迴歸樹(Classification And Regression Tree , CART)對 BDI 時間序列進行預測，CART 主要是以規則的方式來傳達，這些規則經由不斷詢問問題，到最後能得到所需要的結果，在解決分類和預測上有著極大的能力，因此，把與 BDI 相關的因素之過去資料加入 CART 模型中以進行分類和預測。

加入 CART 模型中的 BDI 相關因素過去資料包括國際鋼鐵價格指數、國際煤炭價格指數、國際大豆價格指數、國際鐵礦砂價格指數、國際玉米價格指數、國際燃油價格指數和中國經濟成長率的前一期與去年同期。

4.3.1 模型建構

把影響因素與欲預測之目標(BDI)輸入 R 後，開始對其進行分類與預測之建模。與其他非線性方法像是類神經網路或是支持向量機相比，使用 CART 進行預測的優勢在於可以得知其預測的過程且不需要太多參數上的選擇。以預測 2015 年為例，圖 4-7 為 2015 年 CART 的分類預測結果，從圖中可以得知，CART 的預測過程以國際鐵礦砂去年同期價格指數是否大於等於 99、國際燃油去年同期價格指數是否大於等於 94 和國際玉米價格去年同期價格指數是否小於 320 作為分類預測的分割點，把符合條件的因素分到同一個節點，並計算該節點中 BDI 的平均值作為最終模型的預測數值。在第一個深藍色的節點中，1500 代表 2010 年到 2014 年所有 BDI 的平均值，100% 為訓練組中所有的 BDI 個數；在深綠色的節點中，1198 代表訓練組中被分到國際鐵礦砂去年同期價格指數大於等於 99 的 BDI 平均值，82% 為訓練組中有約 49 個 BDI 被分類到這個節點，其餘的以此類推。




圖 4-7 2015 年 CART 模型的分類與預測結果

圖 4-8 為模型配適值與 BDI 訓練組的比較，虛線為配適值，實線為實際值。從圖上可以看出配適值的趨勢走向大致上與實際值一致，MAPE 值為 16%，模型預測能力良好。

從配適值的趨勢可以看出它的分類預測並不是那麼細緻，為了使預測的準確度提高，我們再把分類更加細項化，因此可以加入 CART 的超參數: maxdepth 和 minsplit 使其預測的準確度提高。




圖 4-8 2015 年 CART 配適值與訓練組

Maxdepth 為樹的最大深度，minsplit 為每一個節點至少需要的資料筆數，表 4-3 為 CART 超參數的選擇。從表 4-3 可以發現當 minsplit 為 2 到 4 中的任意一個數，而 maxdepth 大於等於 5 時，模型配適值與 BDI 訓練組的 mape 值皆為 9.45%，若是 maxdepth 小於 5，則預測的錯誤率會提高，但當 maxdepth 固定設為 5，而 minsplit 超過 4，其預測的錯誤率也會提高，因此本研究將 minsplit 設為 3，而 maxdepth 設為 5。

表 4-3 CART 超參數選擇

minsplit	maxdepth	mape	minsplit	maxdepth	mape	minsplit	maxdepth	mape
2	2	17	3	2	17	4	4	9.8
2	3	12	3	3	12	4	5	9.45
2	4	9.8	3	4	9.8	5	4	10.4
2	5	9.45	3	5	9.45	5	5	10.1
2	6	9.45	3	6	9.45	6	5	10.1
2	7	9.45	3	7	9.45	7	5	10.55
2	8	9.45	3	8	9.45	8	4	10.9
2	9	9.45	3	9	9.45	8	5	10.9
2	10	9.45	3	10	9.45	9	5	10.9
2	30	9.45	3	30	9.45	10	5	10.9

圖 4-9 為加入超參數後的 2015 年分類與預測結果，原本一開始國際鐵礦砂去年同期價格指數若是大於等於 99 則停止分類，在加入超參數後，又繼續往下分類，其依序增加的規則為國際鐵礦砂去年同期價格指數是否大於等於 74、國際鐵礦砂前一期價格指數是否小於 167 和前一期國際煤炭價格指數是否大於等於 105，以及國際燃油去年同期價格指數若是大於等於 94 則停止分類，加入參數後，增加了國際玉米去年同期價格指數是否小於 302 和國際大豆去年同期價格指數是否小於 375 等分類標準。




圖 4-9 2015 年調整後 CART 模型的分類與預測結果

加入超參數後的模型配適值與 BDI 訓練組的比較如圖 4-10，虛線為配適值，實線為實際值，可以看出它與實際值的趨勢更加一致，其 MAPE 值為 9%。




圖 4-10 2015 年調整後 CART 配適值與訓練組

4.3.2 預測

最後，以建構完成的樹進行預測，並與實際資料進行比較，結果如圖 4-11。從圖中可以看出，預測值的趨勢為往上升，與實際值的趨勢相反，且六月到十二月的預測值比實際值相比高出許多，其 MAPE 值為 176%，預測極度不合理。

預測極度不合理的主要原因為 CART 是以分類來進行預測，在圖 4-9 可以看到，經過多個因素分割點的分類，最終預測結果的節點裡其數值為 930、1003、1368、1930、1365、1841、1909、2569、3126 和 4051，其中訓練組中被分到 930 這個節點的個數最多，而被分到 1365 這個節點的個數第二多。而各節點中的最終預測值為訓練組中被分到該節點的 BDI 總和的平均值，2010 年的 BDI 其值皆偏高，最高 4051，最低為 1909，2011 年的 BDI 值雖沒像 2010 年的依樣高，但皆超過 1000，造成最終節點的預測值幾乎為 1000 以上。而 2015 年的 BDI 值皆偏低，最高的為 1066，最低為 517。測驗組中 2015 年的 BDI 按照其對應因素並根據建構完成的樹中的分割點去進行分類預測，被分到 930 和 2569 兩個節點的占大多數，1 月到 5 月的 BDI 預測值為 930，6 月到 11 月的 BDI 預測值為 2569，而 12 月的預測值為 3126，其預測結果與實際值相差甚遠。因此，以 CART 進行分類預測其結果易受訓練組的資料影響，進而造成預測的不準確。




圖 4-11 2015 年 CART 預測結果與實際值比較

為了避免 2010 年和 2011 年這兩年的極高值影響到後續的分類與預測，因此嘗試以 2012 年到 2014 年做為訓練，以預測 2015 年並與測驗組進行比較，結果如圖 4-12。從圖中可以看出，整體的預測值還是依樣偏高，但至少比以 2010 年到 2014 年為訓練組的結果好，趨勢沒有不斷的往上升，且 MAPE 值為 92%，雖預測結果仍為不合理，但比之前的 176% 好許多。而這次預測結果的不準確主要原因在於 2012 年到 2014 年間的 BDI 雖不像 2010 年和 2011 年一般非常的高，但其值仍為 1000 以上，甚至 2013 年的 12 月更是高達 2173，但 2015 年的 BDI 整體值偏低，最高值為 1066，出現在 8 月。而圖 4-12 可以看到預測值在 8 月反而是最低的，主要原因為在 2012 年到 2014 年間的 8 月，其值皆非最高，反而在當年間屬於偏低的狀態，因此造成分類預測的不準確。




圖 4-12 2015 年 CART 預測結果與實際值比較(2012 年到 2014 年為訓練組)

CART 除了能得知其預測過程，也能知道哪些因素對目標變數而言是重要因素，圖 4-13 為 2010 年-2014 年和 2011 年-2015 年中影響 BDI 的重要變數對應圖。圖中的紅線把重要變數再區分為相對重要與相對不重要，可以發現國際煤炭去年同期價格指數、國際鋼鐵去年同期價格指數和國際大豆前一期價格指數不論是在 2010 年-2014 年或 2011 年-2015 年皆為相對重要的變數，而其餘的變數則不固定，有的從相對重要變成相對不重要，而有的從相對不重要轉為相對重要。因此，從不同時間段中的重要變數互相對應比較得知，國際煤炭去年同期價格指數、國際鋼鐵去年同期價格指數和國際大豆前一期價格指數為影響目標變數的重要變數。



圖 4-13 不同時間段影響 BDI 的重要變數對應圖

4.4 混合模型

根據研究方法流程圖(圖 3-1),在第一步驟中,使用 STL 對 BDI 時間序列進行分解,把它分解為三個部分:趨勢,季節性和剩餘(噪音)。Angelopoulos (2017)提出構建模型之前可以提取原始資料的趨勢和季節性部分,則預測的準確性將優於直接採用原始資料。因此,在第一步中就先將 BDI 的趨勢和季節性部分提取出來,個別做預測。在第二步驟中,我們使用 ARIMA 模型來預測趨勢,季節性部分因其為 12 個月是一循環,因此季節性的值也會每 12 次重複一遍,所以將不對季節性做預測,但會找出哪些因素對季節性而言是重要變數,剩餘部分則使用 CART 模型來進行預測。最後,在第三步驟中,將季節性、運用 ARIMA 預測的趨勢和運用 CART 預測的剩餘結合起來,成為一個完整的 BDI 預測值,並用 MAPE 與 RMSE 來判斷混合模型預測的準確度。

4.4.1 以 STL 分解 BDI 時間序列




圖 4-14 對 BDI 進行 STL 分解

STL 把 BDI 分解為三個部分，季節性、趨勢和剩餘，圖 4-14 為分解 2010 年到 2014 年的訓練組 BDI。研究週期為 12 個月，因此在季節性的部分可以看出它的年規律，在趨勢的部分，也可以很明顯的看出從 2010 年來，BDI 的整體趨勢是往下降的，但在 2013 年有些微幅上升，但在 2014 年又往下降。把 BDI 時間序列做一個分解可以讓我們對此序列更加理解，並且在之後做預測的部分能個別分析。

4.4.2 影響季節性之重要因素

從圖 4-14 可以看出，季節性部分為一個不斷重複的圖形，其週期為 12 個月一循環，因此季節性的值也會每 12 次重複一遍，所以將不對季節性做預測，但會分析哪些因素

對 BDI 的季節性而言是重要變數。圖 4-15 為影響 BDI 季節性之重要變數，從圖中可以看到，在 2010 年-2014 年和 2011 年-2015 年兩組不同時間段中，影響 BDI 季節性因素的重要程度排序不同，但國際鐵礦砂前一期價格指數在不同的時間段中其重要程度皆為排序第一，而國際鋼鐵前一期價格指數在兩組中也是排序在前的重要因素，因此可以判斷國際鐵礦砂前一期價格指數和國際鋼鐵前一期價格指數為影響 BDI 季節性最主要之重要因素。

2010年-2014年訓練組		2011年-2015年訓練組	
鐵礦砂前一期	401302.7	鐵礦砂前一期	594668.5
煤前一期	370761.3	中國去年同期經濟成長率	526292
鋼鐵前一期	359076.4	大豆去年同期	525841.6
中國前一期經濟成長率	339416.9	鋼鐵前一期	497637.8
大豆前一期	283920.6	國際燃油去年同期	492008.5
大豆去年同期	276478.8	煤前一期	480127.3
煤去年同期	226216.7	玉米去年同期	349172.2
鐵礦砂去年同期	199602.9	國際燃油前一期	296383.4
鋼鐵去年同期	186296.1	鐵礦砂去年同期	280315.7
玉米去年同期	182196.4	煤去年同期	268033.9
國際燃油去年同期	182196.4	鋼鐵去年同期	210471.3
國際燃油前一期	172989.2	中國前一期經濟成長率	208911.4
玉米前一期	146375.5	玉米前一期	117782.4

圖 4-15 影響 BDI 季節性之重要變數

4.4.3 以 ARIMA 模型預測趨勢部分

將第一步驟中，用 STL 分解出來的趨勢以 ARIMA 進行預測，並應用在 R 中的 auto.arima 函數來為 p，d 和 q 選擇最合適的參數，以用於構造 ARIMA 模型。而使用 auto.arima 函數的優點為它可以在 ARIMA 模型中自動為 p，d 和 q 選擇合適的值，最終以 ARIMA(0,2,2) 模型來預測 BDI 時間序列的趨勢。

圖 4-16 中，綠色的線為實際值，紅色線為預測值，由圖中可以看出 2010 年到 2014 年的整體趨勢為下降，在預測 2015 年 BDI 的趨勢部分，其預測結果顯示，在 2015 年 BDI 的整體趨勢為下降。




圖 4-16 預測 BDI 的趨勢

4.4.4 以 CART 模型預測剩餘

在 BDI 的趨勢以 ARIMA 模型進行預測後，BDI 中的剩餘則使用 CART 模型來進行預測，並以季節性、趨勢、BDI 三種變數和其各自的前一期與去年同期做為分類預測之變數。圖 4-17 為 CART 模型的分類與預測結果，由圖可以得知在 2010 年到 2014 年間，BDI 去年同期、趨勢和 BDI 當期為其分割點，首先以 BDI 去年同期之值是否大於等於 890 做為判斷，之後再依 BDI 是否小於 2686 和趨勢是否大於等於 1572 等為其分類標準。




圖 4-17 2015 年 CART 模型分類與預測

接著，在加入超參數使其提升預測的準確度，minsplit 設定為 3，maxdepth 為 5，結果如圖 4-18。從圖 4-18 可以看出，BDI、BDI 去年同期、季節性、季節性去年同期、趨勢和趨勢前一期為其分割點。




圖 4-18 2015 年調整後 CART 模型的分類與預測結果

4.4.5 ARIMA+CART 之混合模型

將上述分別使用傳統時間序列 ARIMA 模型和機器學習 CART 模型進行預測的趨勢和剩餘結合在一起，並再加上季節性，成為一個完整的 BDI 預測值。

因以 ARIMA 預測趨勢是以 99.5% 的信賴區間為範圍，趨勢除了有最適的預測值外，也有預測的最高範圍值和最低範圍值，而在這區間的預測值皆可做為趨勢的預測值，因此將會取其最高、最低和最適之趨勢預測值，並分別與季節性和剩餘結合，最後在進行預測準確度的比較，並選擇 MAPE 最低的為最終預測結果。表 4-4 為 2015 年趨勢間最高範圍值、最低範圍值和最適值以及與季節性和剩餘加總後之預測值和實際值，表 4-5 為以最高範圍值、最低範圍值和最適值之趨勢做為趨勢預測值之最終預測準確度結果，由表中可以得知，以最適之趨勢代表趨勢部分可以獲得較正確的預測結果，其 MAPE 值為 16%。

表 4-4 2015 年趨勢範圍值

month	trend	trend high	trend low	predict high	predict low	predict	real
1	753	776	731	686	641	663	725
2	710	760	660	501	401	451	539
3	667	766	567	762	563	663	576
4	623	786	460	815	489	652	591
5	580	815	344	859	388	624	597
6	536	854	219	968	333	650	699
7	493	900	86	1067	253	660	975
8	449	953	-54	1041	34	537	1066
9	406	1013	-201	1306	92	699	889
10	362	1079	-354	1429	-4	712	793
11	319	1150	-512	1380	-282	549	582
12	276	1228	-677	1404	-501	452	517

表 4-5 2015 年各趨勢間預測準確度比較

	trend	trend high	trend low
MAPE	16%	51%	71%

以最適趨勢做為趨勢部分之代表，並與分解出的季節性和以 CART 預測之剩餘進行結合，表 4-6 為各部分之預測值、完整預測值與實際值。圖 4-19 為 2015 年混合模型預測結果，實線為 BDI 的實際值，虛線為 BDI 的預測值。雖然預測值的走勢與實際值的走勢在 7 月到 9 月有較大的差距，其主要原因是以乾散貨市場的淡旺季而言，在七月和八月為淡季，且在 2010 年-2014 年的訓練組中，除了 2010 年和 2014 年的八月為上升，其餘的皆為下降，但在 2015 年卻成為一整年中指數最高的月份，造成預測上的落差，但在其餘部分兩者的整體走向大致相同。

表 4-6 2015 年 BDI 各部分預測值、預測值與實際值

month	seasonal	trend	remainder	predict	real
1	-221	753	131	663	725
2	-390	710	131	451	539
3	-135	667	131	663	576
4	-102	623	131	652	591
5	-87	580	131	624	597
6	-17	536	131	650	699
7	36	493	131	660	975
8	-43	449	131	537	1066
9	379	406	-86	699	889
10	219	362	131	712	793
11	316	319	-86	549	582
12	45	276	131	452	517




圖 4-19 2015 年混合模型預測結果與實際值比較

接著，對 2016 年之 BDI 進行預測，表 4-7 為 2016 年趨勢間最高範圍值、最低範圍值和最適值以及與季節性和剩餘加總後之預測值和實際值，表 4-8 為以最高範圍值、最低範圍值和最適值之趨勢做為趨勢部分預測值之最終預測準確度結果，由表中可以得知，以最高範圍之趨勢代表趨勢部分可以獲得較正確的預測結果，其 MAPE 值為 21%。

表 4-7 2016 年趨勢範圍值

month	trend	trend high	trend low	predict	predict high	predict low	real
1	506	518	495	325	337	314	386
2	478	504	452	356	382	330	312
3	450	500	400	268	318	218	383
4	421	501	341	330	410	250	615
5	393	507	278	324	438	209	620
6	364	517	211	311	464	158	608
7	336	531	141	381	576	186	707
8	308	548	67	369	609	128	673
9	279	568	-10	503	792	214	828
10	251	592	-90	384	725	43	868
11	223	617	-172	615	1009	220	1072
12	194	646	-257	40	492	-411	1049

表 4-8 2016 年各趨勢間預測準確度比較

	trend	trend high	trend low
MAPE	44%	21%	67%

以最高範圍之趨勢做為趨勢部分代表，並與分解出的季節性和以 CART 預測之剩餘進行結合，表 4-9 為各部分之預測值、完整預測值與實際值。圖 4-20 為 2016 年混合模型預測結果，實線為 BDI 的實際值，虛線為 BDI 的預測值。從圖 4-20 可以看到 BDI 整體預測值與實際值整體走向一致，皆為上升，但在十二月，其預測值與實際值卻落差極大。

表 4-9 2016 年 BDI 各部分預測值、預測值與實際值

month	seasonal	trend high	remainder	predict	real
1	-172	518	-9	337	386
2	-323	504	201	382	312
3	-173	500	-9	318	383
4	-82	501	-9	410	615
5	-60	507	-9	438	620
6	-44	517	-9	464	608
7	54	531	-9	576	707
8	-2	548	63	609	673
9	233	568	-9	792	828
10	142	592	-9	725	868
11	487	617	-95	1009	1072
12	-59	646	-95	492	1049




圖 4-20 2016 年混合模型預測結果與實際值比較

除了預測主要研究目標 2015 年和 2016 年的 BDI 外，本研究也嘗試預測過去不同時間段的 BDI，以證明所提出之混合模型預測方法可應用於不同時間段的預測和確認其預測的準確度。以 1998 年-2002 年、1999 年-2003 年和 2000 年-2004 年三組訓練組用前述方法建立混合模型，並預測 2003 年、2004 年和 2005 年。

圖 4-21 為 2003 年混合模型預測結果與實際值比較，從圖中可以看出預測結果與實際值在季節性與趨勢上的特徵相似。但在十到十二月時，BDI 實際值往上升了許多，從表 4-10 可以發現，實際值從九月的 2463 直接上升到十月的 4163，而在 1998 年-2002 年的訓練組中，BDI 的最高值為 2000 年 10 月的 1734，因此即使預測值高估，也無法達到四千多，進而造成預測與實際上的落差，但 MAPE 值為 24%，代表預測合理。

表 4-10 2003 年 BDI 各部分預測值、預測值與實際值

month	seasonal	trend high	remainder	predict	real
1	3	1347	98	1448	1694
2	-57	1408	98	1449	1674
3	49	1480	98	1627	1850
4	44	1555	98	1697	2064
5	56	1633	98	1787	2227
6	-32	1712	98	1778	2136
7	-86	1792	60	1766	2192
8	-134	1871	157	1894	2286
9	-36	1950	157	2071	2463
10	89	2029	60	2178	4163
11	73	2106	60	2239	4250
12	32	2182	60	2274	4609




圖 4-21 2003 年混合模型預測結果與實際值比較

圖 4-22 為 2004 年混合模型預測結果與實際值比較，從圖中可以看出預測結果與實際值在季節性與趨勢上的特徵相似。但在一月到五月，預測值與實際值的趨勢相反，從表 4-11 可以看到，預測值在一月到五月時，其值為上升，然而實際值在一月到五月是下降，回顧 1999 年-2003 年的訓練組，可以得知除了 2001 年的 BDI 在一月到五月為下降外，其餘的值皆為上升，因此預測結果也顯示在一月到五月時，其趨勢為上升，進而造成預測與實際上的落差，但 MAPE 值為 15%，代表預測良好。

表 4-11 2004 年 BDI 各部分預測值、預測值與實際值

month	seasonal	trend low	remainder	predict	real
1	3	2944	1675	4622	5229
2	-57	3035	1675	4653	5450
3	49	3108	1675	4832	5131
4	44	3171	1675	4890	4489
5	56	3219	1675	4950	3596
6	-32	3256	-34	3190	2902
7	-86	3278	1675	4867	3778
8	-134	3290	1675	4831	4169
9	-36	3290	1675	4929	4141
10	89	3278	1675	5042	4539
11	73	3256	1675	5004	5309
12	32	3224	1675	4931	5519




圖 4-22 2004 年混合模型預測結果與實際值比較

圖 4-23 為 2005 年合模型預測結果與實際值比較，從圖中可以看出預測結果與實際值在季節性與趨勢上的特徵幾乎相似。但其預測值比實際值高出許多，即使選擇最低範圍的趨勢預測值與季節性和剩餘進行加總，得出的預測值仍然比實際值高。造成此現象的主要原因為 2000 年-2004 年的訓練組中，除了 2001 年，BDI 的趨勢皆為上升，在以 ARIMA 預測趨勢部分時，因 2002 年到 2004 年的趨勢皆上升，使得預測 2005 年的趨勢結果也是上升，且得到的趨勢預測值比前三年都還要高。從表 4-12 可以看到，即使趨勢預測值選擇最低範圍，單一趨勢預測值就比 BDI 實際值高，造成整體預測結果比實際值高出許多，MAPE 為 78%，預測不合理。

表 4-12 2005 年 BDI 各部分預測值、預測值與實際值

date	seasonal	trend low	remainder	predict	real
1	-32	4975	2271	7214	4502
2	-66	5140	2271	7345	4532
3	49	5287	1683	7019	4678
4	79	5428	974	6481	4532
5	89	5553	-23	5619	3667
6	-6	5668	-812	4850	2749
7	-65	5768	-812	4891	2220
8	-72	5859	-812	4975	2207
9	-89	5936	-812	5035	2804
10	118	6002	-245	5875	3161
11	19	6057	-812	5264	2916
12	-23	6102	-812	5267	2608




圖 4-23 2005 年混合模型預測結果與實際值比較

應用混合模型對不同時間段的 BDI 進行預測，可以得知除了 2005 年的預測外，其餘的 MAPE 值皆在 25%以下，且預測出的趨勢和季節性特徵都有符合當年實際 BDI 之起伏。混合模型預測與分析的準確度除了特殊原因和趨勢預測的部分外，大致上都能捕獲 BDI 之特性。

4.5 總結

4.5.1 模型結果比較

以 2010 年-2014 年的 BDI 作為訓練組，2015 年的 BDI 為測試組，並用三種模型: ARIMA 模型、CART 模型和混合模型對 2015 年的 BDI 進行預測，並與實際 BDI 值進行比較，結果如圖 4-24 所示。在圖 4-24 中，預測結果與實際資料較為相似的是混合模型，兩者的趨勢皆為下降，且有明顯的季節性和趨勢特徵；季節性 ARIMA 模型的預測結果有些微的季節性與趨勢的特性，而 CART 模型的預測結果雖有些微的季節性但其趨勢與實際趨勢相反，且預測值與實際值相差甚遠，表 4-13 為判斷 2015 年 BDI 預測結果準確度之 MAPE 比較，MAPE 值越低，其預測準確度越好，因此我們可以得知混合模型的預測準確度優於 ARIMA 模型和 CART 模型。

圖 4-25 則是以 2011 年-2015 年的 BDI 做為訓練組，2016 年的 BDI 為訓練組，並用上述同樣的方法對 2016 年的 BDI 進行預測，再與實際 BDI 值進行比較。由圖可知，在預測 2016 年時，混合模型的預測值與實際資料之走勢相同，且有明顯的季節性和趨勢特徵，SARIMA 模型預測值則是趨於一直線，無法表現出其季節性與趨勢特徵，而 CART 模型無法明顯且正確的表現出季節性和趨勢的特徵，表 4-14 判斷 2016 年 BDI 預測結果準確度之 MAPE 比較。




圖 4-24 三種模型預測結果與測試資料 2015 年的比較

表 4-13 2015 年 MAPE 的比較

	SARIMA 模型	CART 模型	混合模型
MAPE	21%	92%	16%




圖 4-25 三種模型預測結果與測試資料 2016 年的比較

表 4-14 2016 年 MAPE 的比較

	SARIMA 模型	CART 模型	混合模型
MAPE	34%	59%	20%

表 4-15 為模型比較，將上述三種模型以表格呈現比較，並分別對季節性和趨勢的預測進行說明，最後再說明整體模型特性。

表 4-15 模型比較

	SARIMA 模型	CART 模型	混合模型
MPAE	2015 年： 21% 2016 年： 34%	2015 年：92% 2016 年：59%	2015 年：16% 2016 年：20%
RMSE	2015 年：202.5 2016 年：288.3	2015 年：619.2 2016 年：332.6	2015 年：194.3 2016 年：196.8
對季節性特徵的 預測	季節性波動的变化不明顯	季節性波動的变化不明顯	能觀測出明顯的季節性波動變化
對趨勢的預測	趨勢波動的变化不明顯	對於趨勢預測的準確率不佳	有明顯的趨勢變動
整體特性	1. 季節性和趨勢特性表現不明顯 2. 對不同時間段的 BDI 進行預測，其準確度不一致	1. 能得知在預測過程中，哪些因素是影響 BDI 的重要因素(去年同期國際煤炭價格指數、去年同期國際鋼鐵價格指數、前一期國際大豆價格指數)和其預測過程，並易於解釋 2. 因為分類預測易受訓練組中影響變數資料影響，導致預測的不準確	1. 得知在預測過程中，哪些因素是 BDI 季節性的重要因素(前一期國際鐵礦砂價格指數、前一期國際鋼鐵價格指數)，並易於解釋 2. 有明顯的趨勢與季節性變動

4.5.2 與過去文獻比較

將本研究與過去預測 BDI 月平均之文獻進行比較，但本研究所提出之混合模型在過去的文獻中尚未被應用於預測 BDI，因此僅以單一模型進行比較。表 4-16 為本研究所提出之方法與陳桓毅 (2006)和 Bao, Pan, and Xie (2016)兩篇文獻進行比較。

表 4-16 與過去文獻比較

	傳統時間序列 模型	非線性/機器學習 模型	非線性/機器學習 模型	混合模型
文獻	陳桓毅 (2006)	Bao et al. (2016)	Bao et al. (2016)	本研究
方法	ARIMA 模型	類神經網絡 (ANN)	支持向量機 (SVM)結合相關 的特徵選擇	ARIMA 結合 CART
預測目標	BDI 月平均	BDI 月平均	BDI 月平均	BDI 月平均
訓練組	2000/9~2005/8	2000/1~2013/12	2000/1~2013/12	2010/1~2014/12
測驗組	2005/9~2006/3	2014/1~2015/8	2014/1~2015/8	2015/1~2015/12
MAPE	23.45%	無	無	16%
RMSE	無	227.68	151.37	194.3

陳桓毅 (2006)是以傳統時間序列 ARIMA 模型預測 BDI 月平均，並以 MAPE 值作為判別預測準確度的指標，而 Bao, Pan, and Xie (2016)是以非線性/機器學習模型中的支持向量機(SVM) 結合相關的特徵選擇預測 BDI 月平均，與類神經網絡(ANN)進行比較，並以均方根誤差(root mean square error, RMSE) 作為判別預測準確度的指標。

因本研究所訓練與測驗的時間段不包含全球金融危機的前後(2006 年-2009 年)，無法使時間段與欲比較之文獻一致，僅能大致判別混合模型預測準確度是否較差或較好。從表 4-21 中可以看出本研究所提出之混合模型其預測準確度比陳桓毅 (2006)的 ARIMA

模型和 Bao, Pan, and Xie (2016)應用的類神經網絡(ANN)好，但跟支持向量機(SVM)結合相關的特徵選擇以 RMSE 進行比較，本研究所提出之方法預測準確度較差。



第五章 結論與建議

5.1 結論

在 BDI 預測方法中，可大致分為兩大類，傳統時間序列預測與非線性(non-linear)和資料探勘方法預測。因 BDI 屬於非穩定的時序資料，而傳統時間序列預測中，過去常使用的灰預測和 ARIMA 傳統時間序列模型雖能準確的進行線性的時間序列預測，但對於長期的時間序列中所隱藏的非線性關係卻無法準確預測。而非線性方法如機器學習則較易處理此類問題，目前，人工神經網路和支持向量機皆已被應用，但仍有其缺失，特別在時序資料難以被決定究竟是否為穩定或屬於線性問題時。因此，結合傳統時間序列模型與其他機器學習方法的混合模型被認為有較佳的預測準確度與解釋能力。

本研究將 BDI 時間序列以 STL 分解為三個部分，季節性、趨勢和剩餘，並提出結合了傳統時間序列 ARIMA 模型和資料探勘 CART 模型的混合模型進行預測，本研究的主要結論如下：

1. 單一使用季節性 ARIMA 模型(SARIMA)並直接對 BDI 時間序列進行時間長度為一年之預測，在預測 2015 年和 2016 年，MAPE 值分別為 21%和 34%。雖其預測準確度為合理，但在預測 2016 年時其錯誤率偏高，且預測結果趨於一直線，顯示出對不同時間段的 BDI 進行預測，其準確度不一致。
2. 單一使用 CART 模型並直接對 BDI 時間序列進行時間長度為一年之預測，可以得知去年同期國際玉米價格指數、前一期國際燃油價格指數等為影響 BDI 之重要變數，但其預測結果易受訓練組之資料影響，進而影響分類預測的準確度。以預測 2015 年為例，因訓練組中 2010 年和 2011 年之 BDI 值皆偏高，導致分類預測出的結果也偏高，但 2015 年的 BDI 實際上是比較低的，造成其 MAPE 為 176%，預測極度不準確。

3. 以混合模型對分解後的 BDI 時間序列進行時間長度為一年之預測，趨勢以 ARIMA 模型預測，剩餘以季節性、趨勢和 BDI 之前一期與去年同期做為 CART 的分類因素，並以之進行預測，而季節性因是以 12 個月(一年)不斷重複的數值，因此僅以 CART 找出影響季節性的重要變數而不進行預測，並得知國際鐵礦砂前期價格指數和國際鋼鐵前期價格指數為影響 BDI 季節性之重要變數。在預測 2015 年和 2016 年，MAPE 分別為 16%和 20%，預測為合理且能明顯的看出 BDI 的季節性與趨勢特性。此外，以不同的時間段進行預測，除了 2005 年預測結果被趨勢部分影響外，混合模型的預測準確度以 MAPE 值為判斷，大致上都在 25%以下。

5.2 建議

1. 本研究提出之模型為 ARIMA 與 CART 之混合模型，未來研究可再嘗試其他線性與非線性之組合，像是 ARIMA 與類神經網絡(ANN)或是 ARIMA 與支持向量機(SVM)等，並與本研究之結果綜合比較。
2. 本研究所使用之 BDI 相關因素取自於國際權威機構免費網站，仍未完全健全，其中有些無法量化之因素，仍有影響力，故建議未來研究可針對無法量化之因素做進一步的探討。

參考文獻

中文文獻

1. 王珮紋 (2012)，利用資料探勘技術建立現金預測模式：決策樹方法之應用，國立中正大學會計與資訊科技所碩士論文
2. 呂學樺 (2008)，散裝船運市場運價影響因素之分析，國立交通大學運輸科技與管理所碩士論文
3. 林宇恆 (2016)，決策樹結合複迴歸模型預測氣溫與雨量，國立臺灣師範大學電機工程碩士論文
4. 梁容禎 (2006)，波羅的海乾散貨指數影響因素之分析與預測，國立交通大學運輸科技與管理所碩士論文
5. 陳柔安 (2018)，PM2.5 細懸浮微粒之時間序列巨量數據分析應用於污染趨勢與源解析，國立交通大學環境工程系碩士論文
6. 張偉斌, 劉德明, 王照元, 紀櫻珍, 吳忠敏, 王瑋璿, & 張偉嶠. (2011). 建構整合類神經網路與分類迴歸樹在大腸癌病患淋巴轉移之預測. *北市醫學雜誌*, 8(1), 13-22.
7. 陳桓毅 (2006)，散裝航運波羅地海運價指數預測之研究，國立臺灣海洋大學航運管理所碩士論文
8. 程明輝 (2018)，利用資料探勘預測品質模型對面板清洗製程之研究，國立高雄師範大學工業科技教育所碩士論文
9. 廖一夫 (2002)，臺灣銀行業動態化預警模型之研究，國立成功大學政治經濟研究所碩士論文
10. 劉虹君 (2006)，散裝運輸運價指數之預測-模糊分段迴歸，開南管理學院航運與物流

11. 林光、張志清(2014)，*航業經營管理* 八版，臺北：複合文具印刷有限公司

英文文獻

- Angelopoulos, J. (2017). Time–frequency analysis of the Baltic Dry Index. *Maritime Economics & Logistics*, 19(2), 211-233.
- Bao, J., Pan, L., & Xie, Y. (2016). *A new BDI forecasting model based on support vector machine*. Paper presented at the Information Technology, Networking, Electronic and Automation Control Conference, IEEE.
- Box, G. E., & Jenkins, G. M. (1976). Time series analysis: Forecasting and control San Francisco. Calif: Holden-Day.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). Classification and regression trees. Belmont, CA: Wadsworth. *International Group*, 432.
- Cadenas, E., & Rivera, W. (2010). Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA–ANN model. *Renewable Energy*, 35(12), 2732-2738.
- Chistè, C., & Van Vuuren, G. (2014). Investigating the cyclical behaviour of the dry bulk shipping market. *Maritime Policy & Management*, 41(1), 1-19.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL: A Seasonal-Trend Decomposition. *Journal of Official Statistics*, 6(1), 3-73.
- Denning, K. C., Riley, W. B., & DeLooze, J. P. (1994). Baltic freight futures: Random walk or seasonally predictable? *International Review of Economics & Finance*, 3(4), 399-428.
- Faruk, D. Ö. (2010). A hybrid neural network and ARIMA model for water quality time series prediction. *Engineering Applications of Artificial Intelligence*, 23(4), 586-594.
- Goulielmos, A. M., & Psifia, M.-E. (2009). Forecasting weekly freight rates for one-year time charter 65 000 dwt bulk carrier, 1989–2008, using nonlinear methods. *Maritime Policy & Management*, 36(5), 411-436.
- Han, Q., Yan, B., Ning, G., & Yu, B. (2014). Forecasting dry bulk freight index with improved SVM. *Mathematical Problems in Engineering*, 2014.
- Ho, S., Xie, M., & Goh, T. (2002). A comparative study of neural network and Box-Jenkins

- ARIMA modeling in time series prediction. *Computers & Industrial Engineering*, 42(2-4), 371-375.
- Kavussanos, M. G., & Alizadeh-M, A. H. (2001). Seasonality patterns in dry bulk shipping spot and time charter freight rates. *Transportation Research Part E: Logistics and Transportation Review*, 37(6), 443-467.
- Li, J., & Parsons, M. G. (1997). Forecasting tanker freight rate using neural networks. *Maritime Policy & Management*, 24(1), 9-30.
- Pai, P.-F., & Lin, C.-S. (2005). A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega*, 33(6), 497-505.
- Papailias, F., Thomakos, D. D., & Liu, J. (2017). The Baltic Dry Index: cyclicalities, forecasting and hedging strategies. *Empirical Economics*, 52(1), 255-282.
- Veenstra, A. W., & Franses, P. H. (1997). A co-integration approach to forecasting freight rates in the dry bulk shipping sector. *Transportation Research Part A: policy and practice*, 31(6), 447-458.
- Zeng, Q., Qu, C., Ng, A. K., & Zhao, X. (2016). A new approach for Baltic Dry Index forecasting based on empirical mode decomposition and neural networks. *Maritime Economics & Logistics*, 18(2), 192-210.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.