

媒體情緒於企業違約預警：
基於公開資訊語意分析 (post-print)
**Media Sentiment in Corporate Default
Prediction: using Semantic Analysis of Public
Information (post-print)**

呂朋怡*

Peng-I Lu

黃立新**

Li-Xin Huang

陳威光***

Wei-Kuang Chen

江彌修****

Mi-Hsiu Chiang

* 國立政治大學金融學系

Department of Money and Banking, National Chengchi University

** 國立政治大學金融學系

Department of Money and Banking, National Chengchi University

*** 國立政治大學金融學系

Department of Money and Banking, National Chengchi University

**** 通訊作者：國立政治大學金融學系，臺北市文山區指南路二段 64 號；電話：(02)29393091

分機:81265；傳真：+886-2-9398004；Email：mhchiang@nccu.edu.tw

Department of Money and Banking, National Chengchi University

摘 要

本文建立基於公開新聞資訊媒體情緒量化指標的企業違約預警模型。採用美國多數著名報社之新聞文本，我們以 VADER 的文字探勘技術萃取攸關企業信用風險之資訊內涵，進而構建基於情感傾向、強度以及新聞報導量的媒體情緒量化指標 (SENTI)。羅吉斯迴歸模型之下的實證結果顯示，納入媒體情緒量化指標能有效提升模型違約預警的準確度。特別地，本文發現公開新聞資訊之負向報導有助於降低財務危機企業被誤判為不具財務危機企業的可能(其模型之型一誤差從而降低)，進一步的數值結果更表明，誤差極小化之下所求取的最適違約判別臨界值，能有效降低型一誤差從而產生更優化的實質損失分類預測效果，此研究發現呼應了 Begley et al. (1996)的實證結果。

關鍵詞：情感分析、媒體情緒量化指標、企業違約預警、最適臨界值

Abstract

This paper proposes a corporate default prediction model where media sentiment is derived from public news. Using prevalent news media of several major newspaper publishers in the U.S., we apply the VADER (Valence Aware Dictionary for sEntiment Reasoning) text mining technique to extract information that associate with the firms' default risk, and the SENTI indicator—characterized by the news contents' emotion tendency, intensity, and coverage—is then derived to quantify media sentiment. Our logistic regression results show that, incorporating SENTI can enhance the accuracy performance of corporate default prediction. In particular, with negative media sentiment, a lower probability of the model in predicting default firms as non-default ones can be observed - resulting in the model's Type-I forecasting error being decreased accordingly. Further numerical evidence confirms that, when adopting an optimal threshold subject to minimized errors, a significant decrease in Type-I error can be arrived at, giving rise to the best classification forecasts of default loss scenarios. This finding is consistent with that of Begley et al. (1996).

Keywords: Sentiment Analysis, Quantitative Indicators of Media Sentiment, Corporate Default Prediction, Optimal Threshold

壹、前言

企業信用風險 (credit risk) 的評估提供市場參與者確切的企業信用風險揭露及違約預警。信用風險模型可大致分為兩類，結構化模型 (structural model) 和縮減式模型 (reduced-form model)。結構化模型以企業的資產價值為基礎，結合資本結構進行信用風險評估 (諸如 Black and Scholes, 1973; Merton, 1974)。縮減式模型，也被稱為違約強度模型 (intensity model)，以企業自身及相關市場因素來鑒別違約強度 (諸如 Ohlson, 1980; Campbell et al., 2008; Duan et al., 2012)，本文的模型歸屬於縮減式模型。上述文獻皆以財務變數作為預測企業違約，然而近年來開始有學者以公司治理變數、基於新聞報導產生之變數等非財務指標捕捉企業財務危機之徵兆(王明昌等, 2015; Daily and Dalton, 1994; Dechow et al., 1996; Brazel et al., 2009)，本文以公開媒體資訊所萃取之情緒指標 (SENTI) 歸屬於非財務指標。傳統的財務指標及公司治理變數依賴於企業或權威機構定期公佈，無法連續反應企業信用風險之變動，而在實務界與學術界則出現利用公開資訊的定性資料 (qualitative data)¹ 對企業持續觀察之趨勢。

實務上，國際著名信用評級機構，諸如穆迪 (Moody)、標準普爾 (Standard & Poor's) 以及惠譽 (Fitch) 等，給出信用評等標明企業潛在的違約幾率。為生成客觀且獨立的企業信用評級，評級機構使用專家評等法處理定性資料。然而，受限於人工作業，評估流程耗時且成本高昂，評估範圍更無法全面覆蓋媒體上的公開資訊。在學術界，諸多研究提出證據支持公開媒體資訊隱含企業違約機率的信息。公開媒體或企業財務報表中的定性資訊蘊含企業的基本面訊息 (Tetlock, 2007; Tetlock et al., 2008)，其資訊的公開影響股票價格進而影響企業資產價值，因此企業的信用狀況及違約機率發生改變 (Odders-White and Ready, 2006)。另一方面，媒體的關注及報導使 CDS 市場反應更加強烈 (Norden, 2008)，而負面媒體情緒加大了信用風險 (Tsai et al., 2016)。因此，我們通過文字探勘 (text mining) 的技術，以機器量化公開資訊並萃取信息，從而更科學合理的評估企業信用風險。

文字探勘是一項應用於文字內容的數據挖掘 (data mining) 技術，可以有效重組非結構的文本並提取出有價值的資訊 (Manning and Schütze, 2002)。以文字探勘在財務領域的應用為例，諸如 Magnusson et al. (2005), Davis et al. (2012), Forss

¹ 諸如企業年度和季度報告、電話會議、管理層訪談等等。

and Sarlin (2018) 等利用文字探勘技術分析多種來源的公開資訊，這些文獻發現媒體上的文字資料之於企業的信用狀況具高度預測能力。其中，Henselmann and Scherr (2012), Hajek et al. (2016) 以企業年報萃取信用違約相關的資訊，並證實文字探勘技術對於信用違約的預測能力。以單一新聞網作為來源，Tetlock (2007), Lu et al. (2013) 及 Tsai et al. (2016) 皆證明公開新聞資訊對於企業違約機率或信用風險有一定的解釋能力。

情感分析 (sentiment analysis) 則是文字探勘的其中一種形式，其主要關注的是文章的極性 (正向或負向)，即作者在文章中透露的樂觀或悲觀的態度。Tsai et al. (2016) 使用 Loughran and McDonald (LM) 的商業特徵詞詞典 (Loughran and McDonald, 2011) 計算文章中的負向詞以產生負向情緒變數，並以 CDS 數據進行分析，發現更多的新聞報導量、更負向的新聞情緒以及在企業的公開文件中 (如 10-K 和 10-Q) 更多的風險因素披露總量皆會增加 CDS 發行商的信用風險。Lopatta et al. (2017) 由 Davis et al. (2012) 的研究結果進行延伸，使用 LM 詞典分析 10-K 文件，發現財務危機企業比同行在文章中使用的消極詞彙明顯更多²。另外，企業在發生危機事件日至往前一年的期間，10-K 文件包含的訴訟詞彙數量顯著增加；訴訟詞彙數量與財務危機事件的顯著關聯亦存在於危機事件日前四年左右，然而在事件日前一年至三年的期間內卻未被發現，這是由於 LM 詞典未能辨別公司是訴訟方還是被訴訟方的研究限制所致。此外，LM 詞典僅能歸類字詞之極性 (正向或負向) 卻無法解釋單詞情緒強度的差異。舉例來說，「The food here is exceptional」與「The food here is okay」這兩句話對於 LM 詞典而言皆包含了一個正向詞，皆視為相同程度正向的句子，而實際上前者傳達了更加正向的訊息。既有文獻顯現，在未考慮情緒強度下，負向的詞彙影響股票市場 (Tetlock, 2007; Tetlock et al., 2008)，CDS 市場 (Hull et al., 2004; Norden and Weber, 2004; Tsai et al., 2016)。本文實驗性的採用 VADER (Valence Aware Dictionary for sEntiment Reasoning) 文字探勘技術，嘗試在情感分析中納入情緒強度，探索負向詞彙對企業信用的影響是否與文獻一致，並考察正向詞彙在情緒強度的輔助下是否有助於鑒別非財務危機企業。

² 根據聯邦政府法規定，任何有公開交易行為的企業需揭露資訊，如年度報表，10-K 的格式，內容包括了企業整體的生意及財務狀況，也需附上已通過審計師審計的年度財務報表。一般來說，企業在結束財務年度後 90 天內，需向美國證券交易委員會 (SEC, U.S. Securities and Exchange Commission) 繳交年報 10-K。

Hutto and Gilbert (2014)提出了一個基於規則 (rule-based) 的情感分析模型稱之為 VADER，其使用定性和定量方法的結合以產生情感詞庫（以及情感詞的情緒測量結果），並將這些情感詞與五項基於文法和句法的規則相結合以產生情感分析模型。作者亦將 VADER 情感詞庫與其他七個完善且被廣泛使用的情感分析詞典³進行了比較，發現 VADER 情感詞庫所形成的文章極性分類正確性在多個領域（包含社交媒體文本、電影評論、產品評論、紐約時報社論）中皆有傑出的表現，甚至在社交媒體領域的極性分類優於真人進行分類。因此，本文嘗試將傳統的財務危機預測模型與基於詞庫的 VADER 情感分析工具相結合，從大量的公開新聞資料中尋找媒體情緒訊號，建構媒體情緒量化指標以檢視公開資訊對於企業財務危機的解釋與預測能力。

在運用文字探勘技術萃取新聞資訊的同時，也不應該忽略媒體的偏見與企業的媒體管理等潛在問題。媒體對於企業新聞的報導是具有選擇性與偏見的 (Gentzkow and Shapiro, 2006)，其傾向性的來源是基於媒體的自身利益極大化 (Gentzkow and Shapiro, 2010)。Reuter and Zitzewitz (2006)與 Gurun and Butler (2012)實證發現媒體偏見與區域性的廣告支出呈正比，表明媒體承受廣告收入的壓力並因此受到企業操弄。王明昌等(2015)利用台灣 TEJ 資料庫構建基於新聞數量的新聞特徵變數，實證結果顯示，企業在財務危機事件日的前一季會進行媒體管理，釋放正面資訊以稀釋負面信息；然而，負面新聞在財務危機事件日前一年開始，會在各季持續揭露，並不存在負面資訊遏制策略。因此，本研究認為應該納入多來源的媒體公開資訊，以改善單一新聞資訊來源所存在的偏見與報導覆蓋面不足之疑慮；同時，在媒體情緒量化指標的構建上，應該將媒體報導數量納入考量。

同樣利用 TEJ 資料庫，Lu et al. (2013)，Lu et al. (2015) 以中文文本為基礎，運用文字探勘的技術分析台灣市場的違約預警。他們都在羅吉斯模型下，採用財務指標以及基於文字探勘的非財務指標作為模型變數。為了驗證文字探勘所形成之指標之穩健性，Lu et al. (2013)將違約幾率分為四個季度測試不同區間下之穩健性，Lu et al. (2015)構建一系列 DIDC (DIDC, dmDIDC, ΔDIDC, ΔdmDIDC) 媒體情緒指標以檢驗穩健性。本文借鑒兩者之方式，構建了一些列 (SENTI,

3 詞典包含：Linguistic Inquiry Word Count (LIWC)、General Inquirer (GI)、Affective Norms for English Words (ANEW)、SentiWordNet (SWN)、SenticNet (SCN)、基於 WordNet 的 Word-Sense Disambiguation (WSD)以及 Hu and Liu (2004)之情感詞典。

dmSENTI, Δ SENTI, Δ dmSENTI) 媒體情緒指標，並檢驗指標在多期之違約預測模型下之穩健性。特別的，Lu et al. (2013)，Lu et al. (2015) 採取與大多數文字探勘文獻一致的基於詞彙的頻數構建量化的指標，而本文實驗性的以 VADER 文字探勘技術構建以文本為基礎衡量單位的媒體情緒量化指標。詞頻的處理方式將多個文本視為一篇長度不斷累加的文本，既忽略了不同文本之間的差異，也忽略了單一文本內的文章結構。而 VADER 文字探勘技術則是以語法規則進行文字探勘，深入到文本的字裡行間，在文章結構之層面進行探索並形成體現文章的情感傾向與強度的分數，再以文本為單位元構建媒體情緒指標，同時兼顧了文本之間的差異性。

採用 1997 年至 2016 年資料區間的美國上市企業為研究對象，我們參考 Ohlson (1980) 區分樣本內外的資料選取方式，以樣本內企業資料建構基於羅吉斯模型的企業財務預警。藉由比較樣本外資料之所財務危機預測的準確度，本文進而探究以文字探勘所萃取出之媒體情緒量化指標 (SENTI)，是否能夠有效提升企業財務危機預測。在實證架構上，我們參考 Lu et al. (2013) 的多期之違約預測模型與 Lu, Wei and Chang (2015) 之構建一系列 SENTI (SENTI, dmSENTI, Δ SENTI, Δ dmSENTI)，用以驗證指標的穩健性。就預警模型在分類預測的準確度衡量上，我們以分類正確率 (classification accuracy)、CAP 曲線 (cumulative accuracy profile) 和 AR 值 (accuracy ratio) 來驗證預測之績效。在財務危機預測指標的選擇上，本文則採用了 Duan et al. (2012) 包含總體經濟與企業屬性等十二項變數 (以下簡稱 Duan 變數)。我們使用最大概似估計法 (MLE) 估計出羅吉斯模型之參數，並分別使用 Wald 檢定法與 AIC (Akaike Information Criterion) 以及 BIC (Bayes Information Criterion) 來檢定個別參數之顯著性與整體模型之適合度 (goodness-of-fit)，以驗證研究變數是否能真實解釋企業的違約。

本研究有三個主要的發現，首先，本研究以 VADER 文字探勘技術印證了多元公開資訊增益企業信用風險評估的效用。我們發現除了過去文獻使用官方報表的語言進行分析之外，亦可使用新聞媒體的報導進行情感分析，以加強預測企業違約機率的準確度；由於綜合多家新聞媒體報導所產生的分析角度較為多元，可以彌補部分企業在官方檔中掩蓋負向消息的事實。其次，負向報導有助於財務危機企業的識別。我們的實證結果顯示，媒體情緒越悲觀企業越有可能發生財務危機，符合面臨財務危機的企業負向新聞較多的現實情境，此發現也與 Lopatta et

al. (2017) 的結果相呼應；在模型中加入媒體情緒量化指標後，財務危機企業被誤判為非財務危機企業的機率降低(模型的型一誤差降低)，分類準確度也進一步提升。VADER 情感詞庫僅為一般性之情感詞庫，並未針對財務危機這項主題進行相關情感詞之蒐集。然而，透過 VADER 情感詞庫所產生的有效的分辨各情感詞之強度以及基於句法規則的特性，本文所萃取的媒體情緒量化指標能顯著降低型一誤差，呼應既有文獻負向報告蘊含企業基本面資訊的研究發現。另一方面，納入情緒指標致使非財務危機企業被誤判為財務危機企業的可能增加(型二誤差增加)，實證結果表示即使在情緒強度的輔助之下，正向報導也未能提升對非財務危機企業的識別。最後，本研究通過兩種違約判別臨界值之比較，發現使用 Begley et al. (1996) 建議之極小化型一型二誤差總和的最適臨界值，能夠明顯降低型一誤差，從而具較好的分類預測效果。在實務中，錯將財務危機企業誤判為非財務危機企業(型一誤差)造成的實質損失更為嚴重，因此採用最適臨界值能產生優化的實質損失分類預測結果。

本文後續之結構安排如下：第 2 章我們闡述模型的樣本、變數選擇以及資料整理過程，研究變數包含 Duan et al. (2012) 之十二項財務危機預測指標以及由公開新聞資料萃取出來的媒體情緒量化指標。第 3 章為研究方法，我們將研究變數納入羅吉斯模型，並以分類正確率、CAP 曲線和 AR 值驗證模型之績效。第 4 章為本文之數值結果及分析，我們分別解釋各項研究變數對於模型的貢獻度，並且探討媒體情緒量化指標對於模型的增額解釋力。第 5 章為本文之結論。

貳、樣本資料與財務危機預測指標

一、資料來源

本文以美國上市企業為研究對象，資料區間為 1997 年至 2016 年，分別計算每個月的數據資料，僅包含在納斯達克證券交易所 (Nasdaq)、美國證券交易所 (AMEX) 以及紐約證券交易所 (NYSE) 交易的企業。文本數據來自紐約時報網站和 US Newsstream 資料庫。股市數據來自 CRSP 資料庫 (monthly and daily files)。會計數據來自 Compustat 資料庫 (quarterly file)。為了避免前視偏誤 (look-ahead bias)，首先處理了 Compustat 中財務報表的公告日期，本文將財報期間的最後一天加上三個月，當作該財報開始使用的月份，並且在新財報公佈前，視該財報將

繼續使用。本文使用的企業違約資料以及違約距離數據來自於 CRI 資料庫，CRI 資料庫之違約資料整合來自 Bloomberg、Compustat、CRSP、Moody 報告、交易所網站和眾多新聞來源。本研究依據 CRI 資料庫提供之企業違約日期，定義該月第一天至最後一天中，如有發生違約事件，則判斷該月為違約。

本文區分樣本內 (in-sample) 和樣本外 (out-of-sample) 企業，使用樣本內企業資料建構羅吉斯模型預警企業財務危機，使用樣本外資料驗證模型對財務危機預測的精確度。羅吉斯模型中，樣本內財務危機企業資料係採納 1997 年至 2010 年內發生違約之企業，取其違約時點前 6 個月平均的資料；樣本內非財務危機企業部分，參考 Ohlson (1980) 之資料選取方法，從 Compustat 資料庫獲得一批非財務危機企業樣本，將 1997 年 7 月至 2016 年 12 月以一個月為切割點，產生 234 個數據點，每間樣本企業通過隨機抽樣的方式獲得一個數據點，並蒐集該數據點前 6 個月平均的資料。樣本外企業則是採納 2011 年至 2016 年內財務危機企業與非財務危機企業，其選取資料之方式與樣本內企業相同。

二、財務危機預測指標

在財務危機預測指標的選擇上，本文採用 Duan et al. (2012) 十二項變數之外，我們參照 Lu, Wei and Chang (2015) 之 Table 1，加入 Figlewski et al. (2012) 所建議的失業率 (unemployment) 和通貨膨脹率 (inflation) 兩個變數，並進而使用媒體情緒量化指標 (SENTI) 進行違約預警模型之初步建構。因此，本節將主要介紹 Duan 變數之資料來源、及其變數定義與處理過程以及媒體情緒指標之資料來源與其處理過程。

(一) Duan 變數

Duan et al. (2012) 以美國上市櫃企業為研究對象，選取幾項過去文獻常用的總體經濟變數以及企業屬性變數，建立羅吉斯模型並驗證模型是否能夠有效預測企業未來多期之違約機率。Duan 變數分別為一年 S&P500 指數報酬率 (SP500)、三個月美國國庫券利率 (Treasury rate)、違約距離之過去一年歷史平均 (DTD_{level})、違約距離之趨勢 (DTD_{trend})、現金及短期投資與資產市值總額比之過去一年歷史平均 ($CASH/TA_{level}$)、現金及短期投資與資產市值總額比之趨勢 ($CASH/TA_{trend}$)、淨收入與資產總額比之過去一年歷史平均 (NI/TA_{level})、淨收入與資產總額比之趨勢 (NI/TA_{trend})、企業規模之過去一年歷史平均 ($SIZE_{level}$)、企業規模之趨勢

($SIZE_{trend}$)、普通股權益市值與帳面價值比 (M/B) 和獨特性波動 (SIGMA)。研究結果發現，企業的槓桿、流動性、盈利能力和波動性是四個預測企業違約的重要因素，其餘之變數也有一定的解釋能力。

Duan et al. (2012) 提出了部分企業屬性變數在水準 (level) 和趨勢 (trend) 方面的影響，作者認為某企業的企業屬性變數在一段時間內的歷史平均值，可以與其他企業進行區分。另外，當前企業屬性變數相對於其自身的歷史平均值的價值，也可以揭示其當前的勢頭並為未來走勢提供方向。例如：其他情況相同，如果一家企業的 DTD 在過去幾個月中一直在惡化，而另一家企業的 DTD 有所改善那麼兩家擁有相同 DTD 的企業可能會面臨不同的違約可能性。實證分析確實表明，企業的違約距離以及其他幾個變數在水準和趨勢上，對於違約之預測都有顯著之效果。

此外，Figlewski et al. (2012) 認為總體經濟因素對企業信用有重大影響的意見，我們遵循其推薦引入失業率以及通貨膨脹率兩個總體經濟變數。更高的失業率可能引致信用降級以及違約機率的升高，通貨膨脹率更是被廣泛參考的重要經濟因數。通貨膨脹率以每月物價指數變動百分比為衡量。

由於 Duan et al. (2012) 之研究變數涵蓋範圍廣，且實證結果顯示其研究變數能夠精準的預測企業違約之發生，因此，本文首先將使用 Duan 變數、失業率與通貨膨脹率初步建立違約預警模型，表 1 為各項解釋變數的說明內容。

表 1：解釋變數說明

變數名稱	說明	預期符號
Unemployment	失業勞動人口占總勞動人口比例	+
Inflation	美國物價指數的每月變動比例	-
SP500	前 12 個月 SP500 指數報酬率	Na
Treasury rate	3 個月美國國庫券利率	-
DTD_{level}	前 12 個月違約距離 (distance to default) 之平均	-
DTD_{trend}	當月 DTD 值與 DTD_{level} 之差	-
$CASH/TA_{level}$	前 12 個月現金及短期投資與資產市值總額比率 (cash and short-term investments /total assets) 之平均	-

CASH/TA _{trend}	當月 CASH/TA 值與 CASH/TA _{level} 之差	-
NI/TA _{level}	前 12 個月淨收入與資產總額比率 (net income / total assets) 之平均	-
NI/TA _{trend}	當月 NI/TA 值與 NI/TA _{level} 之差	-
SIZE _{level}	前 12 個月 SIZE 之平均 (SIZE: 企業普通股權益市值與 SP500 企業平均普通股權益市值之比率再取對數), 代表企業規模	Na
SIZE _{trend}	當月 SIZE 值與 SIZE _{level} 之差	-
M/B	普通股權益市值與帳面價值比率	Na
SIGMA	12 個月的獨特性波動 (idiosyncratic volatility), 將前 12 個月的個別企業股票月報酬與大盤月報酬 (CRSP value-weighted monthly return) 進行迴歸, 迴歸後殘差之標準差即為 SIGMA, 少於 12 個月報酬資料取為 missing data	+

特別的, 我們對 SP500, $Size_{level}$ 以及 M/B 的符號不做預判, 並以 Na 標示。傳統的財務直覺往往認定過去 12 個月的標普 500 指數的報酬率 (SP500), 企業規模 ($Size_{level}$) 以及普通股權益市值與帳面價值比率 (M/B) 的係數應為負, 然則近年來的研究提出了相反的觀點: 其中, Duffie et al. (2009) 指出, 當股市經歷了牛市階段, 個別企業的違約距離往往高估其財務健康的程度, 因而權益市場總體的報酬率影響個體企業發生財務危機的途徑更需要考慮個體企業與指數的相關性。另外, 與本文尤其相關的 Duan et al. (2012) 的研究發現, 在多種不同時間長度的區間測試下, SP500 在絕大多數區間內與違約強度呈顯著正相關。此外, 傳統的財務直覺傾向於認定企業規模 ($Size_{level}$) 越大則越不容易倒閉, 然而 Duffie et al. (2007) 發現在其他共變數存在的情境下, 企業規模並不是違約風險的顯著決定因素。Duan et al. (2012) 的實證發現, 在非常短期與非常長期的區間測試下, 企業規模與違約風險的關係並不顯著; 特別是在中期的測試區間內, 正向顯著影響雖然存在, 但是可以歸結為混淆效應 (confounding effect)。最後, M/B 表示普通股權益市值與帳面價值比率, 此比率同時衡量市場的錯誤定價與未來增長的機會。如果錯誤定價作用主導, 則違約強度隨 M/B 增加而增加。反之, 若未來增長的機會主導, 傳統的財務直覺傾向於認定違約強度與 M/B 則負向相關,

然而 Duan et al. (2012) 的結果顯示在絕大多數區間內違約強度與 M/B 成正比，此結果呼應了 Campbell et al. (2008) 的研究發現。基於上述的既有研究發現，在本文中我們對 SP500, $Size_{level}$ 以及 M/B 的符號不做預判，並以 Na 標示。

在數據處理過程方面，本研究首先剔除資料不全的樣本企業⁴，剩下的樣本企業資料如存在缺失值，則使用線性插補法處理缺失值，以遺漏值前後各一筆的有效數據進行線性插補，若有連續兩筆遺漏值時，這兩筆遺漏值與前後各一筆的有效數據亦會呈現線性的趨勢。表 2 為剔除資料不全的企業後，模型中財務危機企業與非財務危機企業的分佈型態，樣本內 2808 家上市企業中，有 604 家為財務危機企業；樣本外 899 家企業中，有 95 間家為財務危機企業。除此之外，為了要避免極端值的影響，本研究使用 Winsorize 方法，將企業屬性變數數據縮尾在 99.5 百分位數以及 0.5 百分位數，大於 99.5 百分位數之數值以 99.5 百分位數對應值取代，小於 0.5 百分位數之數值以 0.5 百分位數對應值取代。

表 2 財務危機企業與非財務危機企業分佈

	1997-2010	2011-2016
財務危機企業	604	95
非財務危機企業	2204	804
總數	2808	899

(二) 媒體情緒量化指標

情感分析是繼文字探勘之後，近年被熱烈討論的議題，而情感分析是指用自然語言處理 (natural language processing, NLP)、文字探勘以及計算機語言學等方法來識別原素材中主觀訊息。目前實現情感分析的方法主要有兩種：一種是基於原有詞庫的非監督方法，例如：如 LIWC、ANEW、AFINN、VADER、SentiWordNet 等，此種方法主要依賴包含大量帶有情感極性的詞庫；另一種方法是監督方法，此種方法透過機器學習演算法從大量帶有標註的數據中提取特徵來訓練並建構分類器，例如：SVM (support vector machine)、NaïveBayes、Decision Tree 等，最常使用的特徵是 N-grams 的存在與否或使用頻率，然而這種方法在訓練階段需要大量帶標注的數據，因此對於 CPU 處理、內存需求以及訓練時間而言計算開

⁴ 本研究觀察每間企業之十二項研究變數，如有任何一個變數之所有數據點皆無資料(missing data)，則將該企業定義為資料不全之企業，並且從樣本中剔除。

銷較大，且在一類文本中訓練得到的模型無法良好的處理其他類型的數據。因此，本研究傾向於使用非監督式方法，基於規則模型進行情感分析。

Hutto and Gilbert (2014) 建立的 VADER 情感分析工具為非監督式方法之一，屬基於 VADER 情感分析詞庫和特定句法規則的文本情感識別方法。為了準確區別這些詞彙之極性以及情緒強度，開發者讓十位專業評估人員人工評價這些字彙，使每個情緒詞彙平均分數皆不為零且標準差小於 2.5，最後產生超過 7500 個常用情感詞的評分（包含形容詞、名詞和副詞等），其分佈從 -4 到 4 表示極度負向到極度正向。值得指出的是，VADER 情感詞典不同於其他情感詞典，包含了常用的表情符號之評分（例如：），表示笑臉），考慮了常用英文縮寫詞的情感（例如 WTF、LOL 等）以及常用情感俚語（例如 nah、giggly 等）。在實證結果中發現，VADER 文本識別方法應用在分析推特上的評論、電影評論以及紐約時報社論等不同類型的數據中，精準度皆優於 LIWC、ANEW、General Inquirer 及 SentiWordNet 在內的十一種典型情感分析模型。基於前述理由，本文將使用 VADER 作為情感分析之主要工具。

進行情感分析前，需先蒐集足夠的新聞資料以利分析。紐約時報 (The New York Times) 是一份在美國紐約出版的日報，在全世界發行，具有相當大的影響力，為美國高級報紙、嚴肅刊物的代表，長期來看擁有很好的公信力與權威性。紐約時報將自己看做是一份「報紙記錄」，這個政策的結果是除紐約當地的新聞外，紐約時報較少首先報導一個事件。而假如它真的首先報導一個事件，那麼這個報導具極高的可靠性，且往往被世界上其它報紙和新聞社直接作為新聞來源。US Newsstream 為 ProQuest 資料庫平臺中的子資料庫，為讀者提供美國重大新聞即時資訊，包含大量重要報紙、新聞快訊、博客、期刊及新聞網站的回溯全文內容，最早回溯至 1980 年。對於學術界，US Newsstream 提供洛杉磯時報 (Los Angeles Times)，芝加哥論壇報 (Chicago Tribune) 以及華爾街日報 (The Wall Street Journal) 的獨家閱覽權限。

本文根據前述方法剔除資料不全企業後，產生樣本內 2808 間企業，樣本外 899 間企業，蒐集相關新聞並透過 Python 之 NLTK 庫進行完整的情感分析。VADER 情感分析工具除了包含情感詞庫亦具備五項句法規則，計算了詞語之間的敏感程度，這種方法超越了典型僅基於情感詞庫所產生的模型中所能捕捉的內容，五項句法規則之詳細說明如表 3。

表 3 VADER 句法規則

標點符號	例如句子出現驚嘆號(!)，會增加句子的情緒強度
大寫	若句子包含大小寫，那麼全大寫的情感詞會增加情緒強度，例如「GREAT」比「great」有更高的情感評分
程度副詞	例如「extremely good」就比「good」的正向情感要強得多
連詞	例如「The food here is great, but the service is horrible」當句子存在轉折連詞 but，則 but 後接續的文句將佔主導地位
否定詞	例如「isn't」會導致隨後的情感極性產生反轉

VADER 情感分析工具包含 3 個主要的面向：(A) 文本預處理、(B) 評分作業以及 (C) 評分後作業，完整的分析流程彙整如圖 1。文本的預處理過程是使用機器學習作用於文本分類的基礎操作，由於網路新聞是非結構化數據及其特殊性，機器並不能直接理解，所以需要一系列的預處理操作後，轉換為機器可以處理的結構化數據。具體步驟如下：(A1) 使用 NLTK 庫進行文章分句，接著，一次輸入一句，透過 NLTK 庫裡的 Sentiment 工具包的 SentimentIntensityAnalyzer 情感分析器實現 VADER 情感評分過程；(A2) VADER 將句子根據空格斷詞、表情符號轉換為文字以及將句中多餘的標點符號刪除後即完成文本預處理。接下來便是進行情感評分的規則。雖然情感分析對象的細微性最小是詞彙，然而表達一個情感的最基本的單位則是句子。詞彙雖然能描述情感的基本資訊，但是單一的詞彙缺少對象和關聯程度，並且不同的詞彙組合在一起所得到的情感程度可能不同甚至情感傾向相反，以句子為最基本的情感分析細微性是較為合理的。因此，VADER 基於五項句法規則產生出單句的情感評分。步驟如下：(B1) 首先將單句中所有單詞與 VADER 情感詞庫進行比對，如句中有單詞出現在情感詞庫中則依據詞庫中該詞之分數給予評分；(B2) 檢查單句中是否存在全大寫之情感詞、(B3) 程度副詞、(B4) 否定詞以及 (B5) 連詞以分別進行分數之調整；(B6) 調整完分數後便進行單句分數之加總；(B7) 再檢查句尾是否存在強調語氣之標點符號，如有則加強分數。最後，(C1) 單句評分完成後，以(1)式進行分數標準化。

$$score_{norm} = \frac{score}{\sqrt{score^2 + alpha}}, \alpha = 15 \quad (1)$$

(1)式中， α 為接近最大期望值之值，如標準化後的分數 $score_{norm}$ 大於 1 則調整分數為 1，如 $score_{norm}$ 小於 -1 則調整分數為 -1。如此便完成 VADER 情感分析工具之評分流程，在附錄中我們以一個實際例子來呈現以上評分過程。

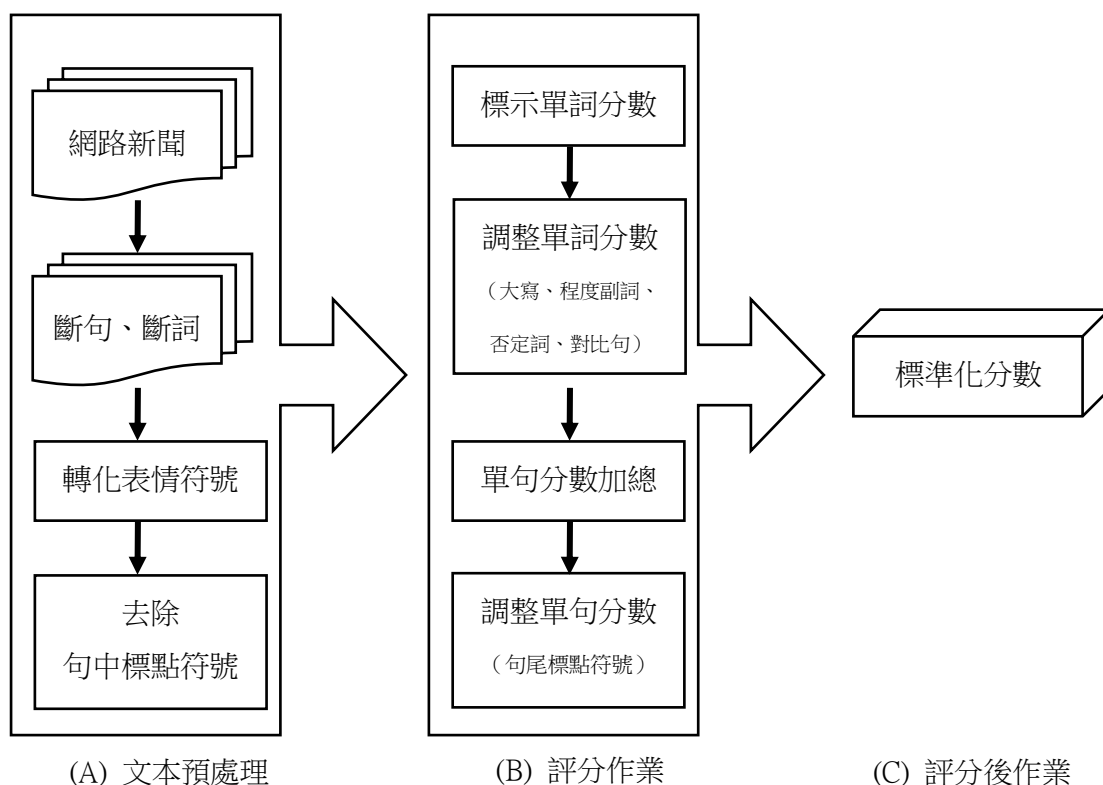


圖 1 VADER 情感分析流程

使用 VADER 情感分析工具將句子標準化評分後，本研究進一步將文章中所有句子之情緒評分加總，並且加上加權過後的文章標題分數，之後再進行平均，產生每篇文章之最終情緒評分 ($score_{final}$)，公式如下：

$$score_{final} = \frac{score_{title} \times 5 + (score_1 + score_2 + \dots + score_n)}{5 + n} \quad (2)$$

(2)式中， n 代表內文中共有 N 條句子。本研究認為文章標題的正負情緒較為重要，因此將標題之情緒分數當作成 5 條內文情緒分數之總和。借鑑 Antweiler and Frank (2004) 之作法，媒體情緒變數 (SENTI) 可以建構如下：

$$SENTI_i = \frac{N_{pos,i} - N_{neg,i}}{N_{pos,i} + N_{neg,i}} \quad (3)$$

$\begin{cases} N_{pos,i}: \text{第 } i \text{ 家企業 } score_{final} > 0 \text{ 之文章數，代表正向文章數量} \\ N_{neg,i}: \text{第 } i \text{ 家企業 } score_{final} < 0 \text{ 之文章數，代表負向文章數量} \end{cases}$

$SENTI_i$ 越大代表媒體情緒越樂觀；越小則說明媒體情緒越悲觀，其中， $SENTI_i$ 的

取值範圍為(-1, 1)。然而，考量到媒體報導數量之多寡，也可以一定程度上表現出媒體情緒之強烈，因此參照金雪軍等(2013)之作法，我們在(3)式之基礎上構建出第 i 家企業樣本期間之媒體情緒變數，公式如下：

$$SENTI_i = \frac{N_{pos,i} - N_{neg,i}}{N_{pos,i} + N_{neg,i}} \times \ln(N_{pos,i} + N_{neg,i}) \quad (4)$$

(4)式中， $\ln(N_{pos,i} + N_{neg,i})$ 考慮了新聞報導數量的影響，也是加權的作用，代表媒體情緒之強烈程度。

Lu, Wei and Chang (2015)透過計算文章違約詞頻及非違約詞頻產生 DIDC (distress intensity of default-corpus)變數。作者指出媒體新聞明顯會受整體經濟以及市場氣氛所影響，財務危機企業之 DIDC 變數應與整體企業平均之 DIDC 有所差異(deviation)，因此產生 dmDIDC (de-mean DIDC)變數以計算每間企業 DIDC 與整體企業平均 DIDC 之差異。另外，作者認為企業本身 DIDC 的變化也顯示企業是否正在經歷困難的時期，因此構建了 $\Delta DIDC$ 與 $\Delta dmDIDC$ 。本文參考 Lu, Wei and Chang (2015)之研究方法，產生三個由媒體情緒指標(SENTI)所衍生的相關變數(dmSENTI、 $\Delta SENTI$ 、 $\Delta dmSENTI$)，以下為此三項變數之計算方法：

$$meanSENTI_m = mean \sum_{i=1}^I SENTI_{i,m} \quad (5)$$

$$dmSENTI_{i,m} = SENTI_{i,m} - meanSENTI_m \quad (6)$$

$$\Delta SENTI_{i,m} = SENTI_{i,m} - SENTI_{i,m-1} \quad (7)$$

$$\Delta dmSENTI_{i,m} = dmSENTI_{i,m} - dmSENTI_{i,m-1} \quad (8)$$

(5)式中， $meanSENTI_m$ 為 m 月所有企業媒體情緒指標(SENTI)之平均。(6)式中， $dmSENTI_{i,m}$ 代表第 i 間企業在 m 月之媒體情緒指標(SENTI)與該月所有企業的平均媒體情緒指標(meanSENTI)之差值。(7)式中， $\Delta SENTI_{i,m}$ 代表 i 企業 m 月之媒體情緒指標(SENTI)與該企業前一個月媒體情緒指標(SENTI)之差值。(8)式中， $\Delta dmSENTI_{i,m}$ 為 i 企業 m 月之 $dmSENTI$ 與前一個月 $dmSENTI$ 之差值。

參、研究方法

一、樣本前測

在基本資料前測檢定方面，本研究使用 Kolmogorov-Smirnov 檢定對每個變數進行常態性檢定，觀察構成模型的變數是否為常態分配。對於非常態分配的變數，使用羅吉斯模型會比使用傳統的多變數區別分析模型更為適宜，因此決定模型前需要檢測變數是否服從常態分配。首先，建立虛無假設為：

H_0 : 單一研究變數(X)符合常態分配

假若研究變數(X)符合常態分配，則可得理論上服從常態分配時之累積機率為 $F_0(X)$ ，而實際觀察到研究變數(X)的次數分配的累積機率為 $F_n(X)$ 。圖 2 為 K-S 檢定之說明圖，經由比較理論上服從常態分配與樣本實際分配的差異，檢定樣本所來自的母群體是否為常態分配。檢定方式即為計算 $F_n(X)$ 與 $F_0(X)$ 之絕對差額中的最大值，公式如下：

$$D = \text{Max}|F_n(X) - F_0(X)| \quad (5)$$

(5)式中，當 D 大於顯著水準下的臨界值時，可拒絕接受虛無假設而傾向支持對立假設，即拒絕研究變數(X)為常態分配的假設，傾向支持為非常態性分配。反之則無法推翻虛無假設，因此接受這些樣本企業之某單一研究變數(X)呈現常態分佈的情況。

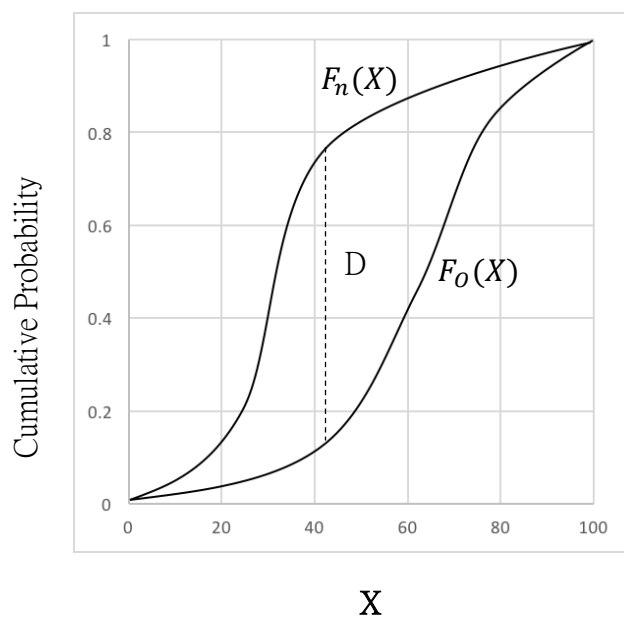


圖 2 K-S 檢定說明圖

二、違約預警模型

羅吉斯模型是建構於一個應變數 (dependent variable) 與多個自變數 (independent variables) 之間的關係，係由線性迴歸模型引申而出。其模型與傳統線性迴歸 (linear regression) 的差別在於，羅吉斯模型的自變數對應變數的影響是以指數的方式做變動，因此不需要常態分配的假設，且應變數不需具備連續性的假設。因此，當我們在探討應變數是離散狀態或只有兩類時，以羅吉斯模型分析，是十分合適的方法。首先，羅吉斯模型由多變數線性方程式轉變而來：

$$Y_{i,t}^* = \alpha + \beta' x_{i,t-1} + \varepsilon_i \quad (6)$$

其中， α 為常數項； β' 為各解釋變數之估計參數向量； $x_{i,t-1}$ 為第*i*間企業在違約時點 (*t*) 前六個月資料平均後之解釋變數向量； ε_i 為第*i*間企業解釋變數之殘差項，並假設其服從羅吉斯分配 (logistic distribution)； $Y_{i,t}^*$ 為無法觀測的隱藏變數 (latent variable)。

接著，將可觀測的到的變數「是否發生違約」表示為 $Y_{i,t}$ ， $Y_{i,t} = 1$ 代表*i*企業在時間點*t*發生違約， $Y_{i,t} = 0$ 代表*i*企業在時間點*t*未發生違約。則 $Y_{i,t}$ 與 $Y_{i,t}^*$ 的關係定義如下：

$$Y_{i,t} = \begin{cases} 1, & \text{if } Y_{i,t}^* > 0 \\ 0, & \text{if } Y_{i,t}^* \leq 0 \end{cases}$$

因此，發生違約之條件機率即可表示如下：

$$\begin{aligned} P(Y_{i,t} = 1 | x_{i,t-1}) &= P(Y_{i,t}^* > 0) = P(\alpha + \beta' x_{i,t-1} + \varepsilon_i > 0) \\ &= P(\varepsilon_i > -(\alpha + \beta' x_{i,t-1})) = P(\varepsilon_i \leq \alpha + \beta' x_{i,t-1}) \end{aligned} \quad (7)$$

假設 ε_i 服從羅吉斯分配 (logistic distribution)，故在給定解釋變數 $x_{i,t-1}$ 下發生違約之機率即可表示為：

$$P(Y_{i,t} = 1 | x_{i,t-1}) = \frac{e^{\alpha + \beta' x_{i,t-1}}}{1 + e^{\alpha + \beta' x_{i,t-1}}} \quad (8)$$

(8)式中，機率估計值介於 0 到 1 之間，此機率函數為非線性關係，經由轉換並取對數，則可表示為如下：

$$\ln\left(\frac{P}{1-P}\right) = \alpha + \beta' x_{i,t-1} \quad (9)$$

從(9)式中可以看出， $\frac{P}{1-P}$ 為一家企業發生違約之機率相對於不發生違約之機率強

度，也就是所謂的勝算比 (odds)。當 $\alpha + \beta'x_{i,t-1}$ 越大，即違約強度越大時，企業發生的違約機率(P)也越大。

由於此機率函數已非線性函數，不適合以 OLS 估計參數，因此，必須使用最大概似估計法 (MLE) 估計之，概似函數如下：

$$\mathcal{L} = \prod_{i=1}^n \left(\frac{e^{\alpha + \beta'x_{i,t-1}}}{1 + e^{\alpha + \beta'x_{i,t-1}}} \right)^{Y_{i,t}} \left(\frac{1}{1 + e^{\alpha + \beta'x_{i,t-1}}} \right)^{1 - Y_{i,t}} \quad (10)$$

(10)式中， $Y_{i,t}$ 為可觀察之企業違約變數， $Y_{i,t} = 1$ 代表*i*企業在時間點*t*發生違約， $Y_{i,t} = 0$ 代表*i*企業在時間點*t*未發生違約； n 為樣本企業之家數。

本研究使用最大概似估計法 (MLE) 估計出羅吉斯模型之參數，接著分別使用 Wald 檢定法與 AIC (Akaike Information Criterion) 以及 BIC (Bayes Information Criterion) 來檢定個別參數之顯著性與整體模型之適合度 (goodness-of-fit)，驗證研究變數是否能解釋企業發生違約。

三、模型績效評估

(一) 臨界值計算

本研究以 Begley et al. (1996)之判斷準則，分割出財務危機企業與非財務危機企業，亦利用此方法決定違約發生之臨界值。在羅吉斯模型中，計算出預期第 i 家企業發生違約之機率值(P_i)，本研究將給定一個臨界值 P ，使其介於 0 到 1 之間，作為模型估計是否為財務危機企業的判斷值，若 $P_i \geq P$ 則將該企業分類為財務危機企業，若 $P_i < P$ 則分類為非財務危機企業。

使用任何一點作為臨界值皆會使樣本產生型一誤差 (Type I Error) 以及型二誤差 (Type II Error)，如下表 4：

表 4 型一誤差與型二誤差

	非財務危機企業 (實際)	財務危機企業 (實際)
非財務危機企業 (預期)	正確判斷(A)	型一誤差(B)
財務危機企業 (預期)	型二誤差(C)	正確判斷(D)

型一誤差指的是將財務危機企業誤分類為非財務危機企業，而發生型一誤差之企業家數與財務危機企業總數之比例，即為型一誤差率 (Type I Error Rate, $\alpha_{in}(P)$)，此誤差在實務上會造成投資人遭受投資損失，或債權人蒙受呆帳損失。公式如下：

$$\alpha_{in}(P) = \frac{B}{B + D} \quad (11)$$

型二誤差則是指將非財務危機企業誤分類為財務危機企業，而發生此誤差之企業家數與非財務危機企業總數之比例，即為型二誤差率 (Type II Error Rate, $\beta_{in}(P)$)，此誤差在實務上將會造成過度保守而產生無法精準投資的情況。公式如下：

$$\beta_{in}(P) = \frac{C}{A + C} \quad (12)$$

本研究的臨界值判斷方法是選用最適臨界值 \hat{P} ，使其樣本內型一誤差率與型二誤差率之合最小，公式如下：

$$\hat{P} = \min_p(\alpha_{in}(P) + \beta_{in}(P)) \quad (13)$$


(二) 分類正確率

本研究採用樣本內資料計算出最適臨界值 \hat{P} ，再透過此臨界值計算出分類正確率，用以檢驗不同模型的配適能力；藉由比較分類正確率，確認加入媒體情緒變數之模型是否能夠增進模型分類預測之準確率。由表 4 所示，分類正確率之公式即為 $(A + D)/(A + B + C + D)$ ，其意義為研究樣本中財務危機企業與非財務危機企業預測結果判斷正確的程度。另外，本研究也比較一般文獻常使用的臨界值 $0.5(\bar{P})^5$ 與本研究計算出的最適臨界值(\hat{P})，檢視何者能夠更為精準的分辨出非財務危機企業與財務危機企業。

(三) CAP 曲線和 AR 值

本研究也將使用 CAP 曲線以及 AR 值作為財務危機企業預測的績效指標。CAP 曲線是基於排序後的累計分佈的對比所形成的曲線，即描述累計財務危機企業比例（縱軸）與累計所有企業比例（橫軸）的關係。AR 值則是 CAP 曲線量化結果。假設樣本外企業總數為 n 家，其中非財務危機企業為 n_0 家，財務危機企業為 n_1 家，在計算出企業違約機率之預測值後，將所有企業之違約機率預測值由大到小排列。假設在前 $v\%$ 的企業家數中有 n_{1v} 家企業實際發生違約，因此可以得到前 $v\%$ 的企業中，財務危機企業涵蓋率為 $c(v) = n_{1v}/n_1$ 。以 $v\%$ 為橫軸， $c(v)$ 為縱軸，則可繪製出 CAP 曲線，如圖 3。圖 3 中，長折線為完美模型所得到的 CAP 曲線；實線為一般違約模型所得到的 CAP 曲線；點線為隨機模型所得到的 CAP 曲線，為 45 度直線，表示模型預測結果是隨機的，沒有預測能力。

⁵ 根據林長瑞(2010)的研究指出,發生危機企業的判別機率設定臨界值為 0.5。



註：長折線為完美模型，實線為一般違約模型，點線為隨機模型。

圖 3 CAP 曲線說明圖

AR 值即是衡量一般的違約模型相對於隨機模型所提升的性能，與完美模型相對於隨機模型所提升性能的比值，公式表示如下：

$$AR = \frac{a_R}{a_P} \quad (14)$$

(14)式中， a_R 代表一般違約模型 CAP 曲線與隨機模型 CAP 曲線之間的面積， a_P 代表完美模型 CAP 曲線與隨機模型 CAP 曲線之間的面積。

肆、實證結果與分析

本研究需要對每家企業獲取對應的 Duan 十二項變數以及 SENTI, dmSENTI, ΔSENTI, ΔdmSENTI 等一系列媒體情緒量化指標。用於模型訓練的樣本內企業共 2808 家，期間為 1997 年至 2010 年，蒐集 23201 篇公開新聞，共產生 36504 個觀察值；作為測試模型的樣本外企業共 899 家，期間為 2011 年至 2016 年，蒐集 6818 篇公開新聞，共產生 11687 個觀察值。

一、樣本前測

表 5 為包含一系列 SENTI 之變數敘述性統計，且以區分財務危機企業 (Distressed)與非財務危機企業(Non-Distressed)之方式列出。樣本企業總數為 2808

家，包含 604 家財務危機企業與 2204 家非財務危機企業；財務危機企業占樣本總數 21.51%，財務危機企業與非財務危機企業比例接近 1:4。各變數之平均值、標準差、最大值、最小值及平均數差異檢驗皆呈現在表 5。Duan 變數中有 11 個在 1%水準下顯著。其中，非財務危機企業的違約距離水準(DTD_{level})與趨勢(DTD_{trend})的平均值與最大值都明顯優於危機企業的相應數值，顯示非財務危機企業違約機率遠小於財務危機企業。在媒體情緒量化指標方面，SENTI 與 dmSENTI 都在 1%水準下顯著。SENTI 表示媒體情緒之情感傾向，非財務危機企業之平均值(1.24)高於財務危機企業之平均值(0.91)；dmSENTI 表示特定企業媒體情緒偏離同期所有企業之媒體情緒之平均值，財務危機企業之平均值(-0.35)低於非財務危機企業之平均值(-0.02)。SENTI 與 dmSENTI 的指標都顯示財務危機企業在總體上以及同期比較上都擁有更負面之媒體情緒。

本研究使用 Kolmogorov-Smirnov 檢定以驗證個別變數是否為常態分配。由表 6 的估計結果可知，包含媒體情緒變數 (SENTI, dmSENTI, Δ SENTI, Δ dmSENTI) 在內的各项變數，在 1%的顯著水準下，皆呈現顯著的情況，因此可以拒絕虛無假設，傾向支援這些變數為非常態性分配。由於多變數區別分析具有解釋變數須符合常態分配之假設，不適合使用這些解釋變數進行建模，因此，本研究採用羅吉斯模型進行實證分析，與 Lu et al. (2013), Lu et al. (2015) 所採用模型一致。

表 5 變數之敘述性統計

Variables	Firm Type	Mean	S.D.	Max	Min	T-test
Unemployment	Distressed	5.38	1.56	10.00	3.80	4.29***
	Non-distressed	5.73	1.79	10.00	3.80	
Inflation	Distressed	2.30	1.33	5.60	-2.10	0.18
	Non-distressed	2.31	1.33	5.60	-2.10	
SP500	Distressed	-0.00	0.19	0.34	-0.39	3.85***
	Non-distressed	0.03	0.18	0.34	-0.39	
Treasury rate	Distressed	3.35	1.92	6.01	0.07	-10.11***
	Non-distressed	2.45	1.95	6.01	0.07	
DTD _{level}	Distressed	0.88	1.07	6.82	-1.92	29.42***
	Non-distressed	4.06	9.60	37.81	-0.91	
DTD _{trend}	Distressed	-0.72	0.63	2.26	-4.53	12.44***
	Non-distressed	-0.03	1.32	6.03	-22.42	
CASH/TA _{level}	Distressed	0.14	0.20	0.91	0.00	3.86***
	Non-distressed	0.18	0.22	1.00	0.00	
CASH/TA _{trend}	Distressed	-0.02	0.06	0.23	-0.40	8.74***
	Non-distressed	0.00	0.06	0.43	-0.65	
NI/TA _{level}	Distressed	-0.08	0.12	0.07	-1.36	20.53***
	Non-distressed	-0.00	0.06	0.55	-1.00	
NI/TA _{trend}	Distressed	-0.04	0.13	0.76	-1.12	10.88***
	Non-distressed	-0.00	0.05	0.72	-0.60	
SIZE _{level}	Distressed	-5.56	1.54	1.50	-9.73	22.67***
	Non-distressed	-3.58	1.99	3.40	-8.63	
SIZE _{trend}	Distressed	-0.87	0.61	0.85	-3.35	46.26***
	Non-distressed	-0.01	0.33	1.59	-1.91	
M/B	Distressed	0.92	19.61	306.69	-340.06	2.75***
	Non-distressed	2.90	14.40	297.56	-427.80	
SIGMA	Distressed	0.29	0.18	1.70	0.05	-30.92
	Non-distressed	0.12	0.09	1.38	0.01	
SENTI	Distressed	0.91	0.94	4.04	-1.60	7.84***
	Non-distressed	1.24	0.91	4.43	-1.61	
dmSENTI	Distressed	-0.35	0.94	2.77	-2.88	7.82***
	Non-distressed	-0.02	0.91	3.20	-2.85	
ΔSENTI	Distressed	0.03	0.59	1.00	-0.98	-0.82
	Non-distressed	0.01	0.57	1.00	-1.00	
ΔdmSENTI	Distressed	0.04	0.59	1.05	-1.05	-0.95
	Non-distressed	0.01	0.57	1.08	-1.06	

註：***表示在 1%顯著水準下是呈現顯著的情況；**表示在 5%顯著水準下是呈現顯著的情況；*表示在 10%顯著水準下是呈現顯著的情況。

表 6 Kolmogorov-Smirnov 檢定

	Kolmogorov-Smirnov test	P 值
Unemployment	0.9999***	0.0000
Inflation	0.7806***	0.0000
SP500	0.3670***	0.0000
Treasury rate	0.5856***	0.0000
DTD _{level}	0.6776***	0.0000
DTD _{trend}	0.0831***	0.0000
CASH/TA _{level}	0.5000***	0.0000
CASH/TA _{trend}	0.4319***	0.0000
NI/TA _{level}	0.4616***	0.0000
NI/TA _{trend}	0.4459***	0.0000
SIZE _{level}	0.8233***	0.0000
SIZE _{trend}	0.2894***	0.0000
M/B	0.5511***	0.0000
SIGMA	0.5070***	0.0000
SENTI	0.4813***	0.0000
dmSENTI	0.0750***	0.0000
ΔSENTI	0.1589***	0.0000
ΔdmSENTI	0.1528***	0.0000

註：***表示在 1%顯著水準下是呈現顯著的情況；**表示在 5%顯著水準下是呈現顯著的情況；*表示在 10%顯著水準下是呈現顯著的情況。

二、違約預警模型

本研究利用樣本內資料建構企業違約機率模型，模型分別為：

Logit1：由 Duan et al. (2012)之十二項變數所形成之基礎羅吉斯模型。

Logit2：加入媒體情緒變數 SENTI 後產生之羅吉斯模型。

Logit3：加入媒體情緒變數 dmSENTI 後產生之羅吉斯模型。

Logit4：加入媒體情緒變數 Δ SENTI 後產生之羅吉斯模型。

Logit5：加入媒體情緒變數 Δ dmSENTI 後產生之羅吉斯模型。

Logit6：同時加入上述四種媒體情緒變數後產生之羅吉斯模型。

Logit1 模型為未加入媒體情緒變數之基礎羅吉斯模型，Logit2 至 Logit5 為分別加入媒體情緒指標 SENTI, dmSENTI, Δ SENTI, Δ dmSENTI 之模型，Logit6 為同時加入 4 個媒體情緒指標之模型。透過這六種模型，檢視 Duan 變數、總體經濟變數失業率與通貨膨脹率是否能夠解釋企業違約之發生，並且探討媒體情緒是否能增加企業違約預測之有效性，更以不同衡量之 SENTI 檢驗媒體情緒指標之穩健性。

模型之估計結果列於表 7，在總體經濟變數方面，失業率與通貨膨脹率之係數皆為負，與 Lu et al. (2015)之結果一致。過去 12 個月 S&P500 指數報酬率 (SP500) 的係數顯著為正，表示股市表現好的時候，企業較有可能發生違約。這個結果看似和直覺相反，然而這項結果與 Duffie et al. (2009) 和 Duan et al. (2012) 之結果一致，他們認為這可能是 S&P500 指數報酬率與其他企業屬性變數之間的相關性所致。Duffie et al. (2009) 解釋可能是因為在股市繁榮後，企業的違約距離被誇大。另外，三個月美國國庫券利率 (Treasury rate) 與企業違約發生呈現顯著正相關，由於高利率會增加企業籌資的成本，企業發生違約的機率也會隨之提高。

在企業屬性變數方面，違約距離之過去 12 個月歷史平均 (DTD_{level}) 和違約距離之趨勢 (DTD_{trend}) 與企業違約發生呈現顯著負相關，代表違約距離越大，企業越不容易發生違約，這個結果與過去文獻一致，也與違約距離之理論基礎吻合。現金及短期投資與資產市值總額比之過去 12 個月歷史平均 ($CASH/TA_{level}$) 以及其趨勢 ($CASH/TA_{trend}$) 與企業違約發生呈現顯著負相關。 $CASH/TA$ 代表企業的流動性情況，當企業有更多流動資產可以應付各項利息和本金的支付，則企業比較有可能避免違約的發生。淨收入與資產總額比之過去 12 個月歷史平均

(NI/TA_{level}) 以及其趨勢 (NI/TA_{trend}) 的係數顯著為負，此結果亦與過去文獻結果一致。Bharath and Shumway (2008)發現，除了違約距離之外，淨收入與資產總額比也提供了顯著的預測能力；由於此變數代表企業的獲利能力，進而決定了一間企業最後的生存與否，獲利能力越好的企業還款能力越強，因此不容易發生違約。企業規模之過去 12 個月歷史平均 ($SIZE_{level}$) 以及其趨勢 ($SIZE_{trend}$) 對違約發生呈顯著負向影響。企業規模變數在過去許多文獻皆認為是預測企業違約發生一項重要的指標，大企業通常被認為比小企業擁有更多元化的業務線和財務靈活性，這能夠幫助他們改善財務困境。此外，大企業也更可能從政府的救助中受益，因為它們一旦發生財務危機將會對整體經濟有莫大的衝擊。另一方面，由企業規模之趨勢 ($SIZE_{trend}$) 係數顯著為負可知，企業規模之成長會降低發生違約的可能性。普通股權益市值與帳面價值比 (M/B) 之係數顯著為正，此結果和 Campbell et al. (2008) 和 Duan et al. (2012) 之結果一致。Campbell et al. (2008) 發現財務危機企業的平均 M/B 略高，代表高估市場價值的情況也能夠反映在違約機率上。另外，由於違約距離是用市場價值計算，如果帳面價值也是相關的，則把 M/B 加入模型，將可以作為一個修正變數，使模型更為準確。獨特性波動 ($SIGMA$) 之係數顯著為正。Shumway (2001) 最先使用了這項指標，該研究認為若一家企業的現金流變動程度越大（因此股票報酬變動程度越大），那麼該企業應該有更高的破產可能性，本研究的結果與此論點一致。

此外，本研究也發現媒體情緒指標 $SENTI$ 與 $dmSENTI$ 的之係數為負且在 1%水準下顯著，表示媒體情緒越負面則企業發生財務危機的可能性越大。媒體情緒指標 ($SENTI$) 值越大則代表媒體的正面報導多於負面報導，意即媒體情緒越樂觀，企業發生違約之機率越低；反之，媒體情緒越悲觀時，企業越有可能發生違約。 $dmSENTI$ 表示特定企業之媒體情緒指標與同一時期所有企業之平均媒體情緒指標之差值，實證結果顯現當特定企業相較於平均媒體情緒越低則該企業發生財務危機可能性越大。 $\Delta SENTI$ 與 $\Delta dmSENTI$ 皆為當月媒體情緒指標($SENTI$ 與 $dmSENTI$)較上一個月指標之差，而兩者都不顯著，表示媒體情緒($SENTI$ 與 $dmSENTI$)之變化速率不能用以預測企業違約機率。同時考慮 4 個媒體情緒指標之時，結果如 Logit6 所呈現，所有媒體情緒指標皆不顯著。

表 8 為各模型之 AIC 值與 BIC 值，Logit2 之 AIC 值與 BIC 值皆小於 Logit1 之 AIC 值與 BIC 值，因此顯示加入媒體情緒變數確實能夠有效提升模型的解釋

能力。同時，在媒體情緒指標顯著的 Logit2 與 Logit3 模型中，Logit2 之 AIC 值與 BIC 值也小於 Logit3 對應之數值，所以我們選擇 SENTI 作為後續研究的媒體情緒指標。

為了進一步驗證本研究所構建媒體情緒指標之穩健性，我們參照 Lu et al. (2013) 之作法，以多期之迴歸模型檢驗 SENTI 的違約預測能力。在原先以違約事件前 0~6 個月為資料區間的基礎上，本文嘗試違約事件前 7~12 個月以及 12~18 個月之公開資訊構建 SENTI。在剔除存續區間不足 18 個月的公司後，公司總數為 2669 間，其中違約公司為 516 間，回歸模型結果如表 9 所示。分別使用違約事件前 0~6 個月、7~12 個月以及 12~18 個月之公開資訊所構建之 SENTI，係數皆為負且顯著。實證結果表明，在違約事件前一年半的區間內，SENTI 都能一致地對企業發生財務危機事件進行預警，意即使用 SENTI 能有效幫助預測企業違約之發生。由於 0~6 個月 SENTI 之係數（絕對值）明顯大於另外兩個期間之 SENTI，表明違約事件前半年之媒體情緒量化指標解釋力更強，所有在後續的實證研究中我們將統一使用 0~6 個月的公開資訊所構建的 SENTI 進行模型績效之評估。

表 7 樣本內變數所建構之迴歸模型

	Logit1	Logit2	Logit3	Logit4	Logit5	Logit6
Constant	-2.9797*** (16.3645)	-2.5541*** (11.4951)	-3.1913*** (17.9434)	-2.9731*** (16.2970)	-2.9752*** (16.3152)	-6.6834 (1.4216)
Unemployment	-0.1144* (2.9440)	-0.1266* (3.3990)	-0.1264* (3.3901)	-0.1136* (2.9061)	-0.1138* (2.9132)	-0.1335* (3.7522)
Inflation	-0.096 (1.1644)	-0.0881 (0.9112)	-0.0876 (0.9081)	-0.0943 (1.1207)	-0.0948 (1.1332)	-0.0869 (0.8797)
SP500	2.5809*** (18.8180)	2.4033*** (15.5685)	2.4074*** (15.6220)	2.5748*** (18.7497)	2.5774*** (18.7806)	2.3349*** (14.6124)
Treasury rate	0.3265*** (37.0300)	0.3459*** (39.5079)	0.3456*** (39.4741)	0.3259*** (36.8912)	0.3261*** (36.9099)	0.3491*** (39.9698)
DTD _{level}	-1.0494*** (88.7485)	-1.0377*** (86.5898)	-1.0381*** (86.6468)	-1.0520*** (88.7341)	-1.0512*** (88.6339)	-1.0375*** (86.0515)
DTD _{trend}	-0.6681*** (12.1797)	-0.6323*** (10.5758)	-0.6335*** (10.6208)	-0.6719*** (12.2591)	-0.6708*** (12.2258)	-0.6380*** (10.6804)
CASH/TA _{level}	-1.6746*** (7.7260)	-1.7479*** (8.1041)	-1.7480*** (8.1228)	-1.6804*** (7.7519)	-1.6790*** (7.7442)	-1.7214*** (7.8397)
CASH/TA _{trend}	-3.2478* (3.5848)	-3.7460** (4.6257)	-3.7402** (4.6122)	-3.2541* (3.5991)	-3.2531* (3.5967)	-3.5849** (4.2105)
NI/TA _{level}	-6.3822*** (32.0653)	-6.5546*** (33.0328)	-6.5544*** (32.9774)	-6.3890*** (32.0812)	-6.3879*** (32.0728)	-6.4137*** (31.8174)
NI/TA _{trend}	-2.9759** (6.4061)	-3.0183** (6.5591)	-3.0272** (6.5875)	-2.9996** (6.4874)	-2.9941** (6.4592)	-2.9133** (6.1473)
SIZE _{level}	-0.3324*** (28.3999)	-0.3531*** (30.2623)	-0.3532*** (30.2845)	-0.3315*** (28.2359)	-0.3318*** (28.2843)	-0.3509*** (29.7375)
SIZE _{trend}	-3.2069*** (111.7934)	-3.2078*** (107.5471)	-3.2072*** (107.5067)	-3.2010*** (111.2289)	-3.2027*** (111.2930)	-3.2076*** (107.0757)
M/B	0.0103** (6.5729)	0.0104*** (7.2271)	0.0104*** (7.2150)	0.0102** (6.4060)	0.0102** (6.4415)	0.0109*** (7.5960)
SIGMA	2.6229*** (11.6645)	2.6505*** (11.4501)	2.6499*** (11.4402)	2.6171*** (11.5967)	2.6181*** (11.6076)	2.7407*** (12.0979)
SENTI		-0.5069*** (20.5911)				2.7881 (0.3989)
dmSENTI			-0.5049*** (20.4219)			-3.2951 (0.5564)
ΔSENTI				-0.0607 (0.1447)		-5.2949* (2.7176)
ΔdmSENTI					-0.0422 (0.0703)	5.2315 (2.6620)

註：***表示在 1%顯著水準下是呈現顯著的情況；**表示在 5%顯著水準下是呈現顯著的情況；*表示在 10%顯著水準下是呈現顯著的情況；括號內之數值為 Wald 統計值；Logit1 表示由 Duan(2012)之十二項變數所形成之 Logit 模型。Logit2 表示加入媒體情緒變數(SENTI)後產生之 Logit 模型。Logit3 表示加入媒體情緒變數(dmSENTI)後產生之羅吉斯模型。Logit4 表示加入媒體情緒變數(Δ SENTI)後產生之羅吉斯模型。Logit5 表示加入媒體情緒變數(Δ dmSENTI)後產生之羅吉斯模型。Logit6：同時加入上述四種媒體情緒變數後產生之羅吉斯模型。

表 8 各迴歸模型之 AIC 值與 BIC 值

	Logit1	Logit2	Logit3	Logit4	Logit5	Logit6
AIC 值	816.270	796.357	796.551	818.125	818.201	799.265
BIC 值	905.370	891.223	891.587	913.165	913.238	912.123

註：Logit1 表示由 Duan(2012)之十二項變數所形成之 Logit 模型。Logit2 表示加入媒體情緒變數(SENTI)後產生之 Logit 模型。Logit3 表示加入媒體情緒變數(dmSENTI)後產生之羅吉斯模型。Logit4 表示加入媒體情緒變數(Δ SENTI)後產生之羅吉斯模型。Logit5 表示加入媒體情緒變數(Δ dmSENTI)後產生之羅吉斯模型。Logit6：同時加入上述四種媒體情緒變數後產生之羅吉斯模型。

表 9 樣本內多期之迴歸模型

	Logit2 (0~6 months)	Logit2 (7~12 months)	Logit2 (13~18 months)
Constant	-2.7705*** (13.0539)	-0.8745 (0.8842)	2.0814** (4.8878)
Unemployment	-0.1044 (2.2661)	-0.2797*** (6.9596)	-0.6216*** (27.6621)
Inflation	-0.0378 (0.1586)	0.2358*** (7.6986)	0.0722 (0.7335)
SP500	2.1418*** (11.6403)	0.2801*** (0.2066)	1.2053** (3.9580)
Treasury rate	0.3234*** (33.3948)	0.4365*** (35.9891)	0.2515*** (10.7495)
DTD _{level}	-1.0178*** (79.9596)	-1.1099*** (130.5459)	-0.8986*** (137.9287)
DTD _{trend}	-0.4589** (5.0481)	-0.9022*** (35.2644)	-0.6151*** (22.6666)
CASH/TA _{level}	-1.6416*** (6.9491)	-0.9654* (3.2136)	-0.4122 (0.7413)
CASH/TA _{trend}	-3.8853** (4.6306)	-4.3404*** (8.6537)	-3.6605*** (7.2124)
NI/TA _{level}	-5.2859*** (20.9147)	-6.8112*** (27.1604)	-4.4591*** (12.8071)
NI/TA _{trend}	-3.4867** (8.0708)	-1.1421 (0.4813)	-1.6466 (1.4755)
SIZE _{level}	-0.3549*** (29.5312)	-0.2159*** (13.0286)	-0.1221** (5.5917)
SIZE _{trend}	-3.2500*** (106.3415)	-2.0176*** (56.6944)	-1.6826*** (48.3683)
M/B	0.0103*** (6.8096)	0.0083 (2.6253)	0.0024 (1.4327)
SIGMA	2.8103*** (12.3597)	1.5408*** (9.7244)	3.1043*** (4.1879)
SENTI	-0.5199*** (20.8446)	-0.3793*** (39.7315)	-0.3783** (47.2792)

註：***表示在 1%顯著水準下是呈現顯著的情況；**表示在 5%顯著水準下是呈現顯著的情況；*表示在 10%顯著水準下是呈現顯著的情況。

三、評估模型績效

本文使用樣本外企業資料進行模型之績效評估。樣本期間為 2011 年至 2016 年，以隨機程式獲得數據點前 6 個月平均的資料，共產生財務危機企業 95 家，非財務危機企業 804 家，而媒體情緒指標的資料共包含 6818 則新聞。進一步，本研究使用分類正確率、CAP 曲線以及 AR 值三項檢驗方法，比較不同模型之績效。

(一) 最適違約判別臨界值

為將模型運用於違約預測，必須先選擇違約判別臨界值。採用 Begley et al. (1996)之判斷準則，本研究在誤差總和極小化之下以樣本內資料求取最適臨界值 (\hat{P})。我們在表 10 的 Panel B 中展示了給定臨界值下各模型之型一誤差與型二誤差。給定臨界值，計算各臨界值所對應的型一誤差與型二誤差總和所形成的軌跡呈現於圖 5。橫軸為可能的臨界值 $P \in (0,1)$ ，本研究將橫軸以 0.01 為單位分割，產生 101 個臨界值。縱軸為各個臨界值所對應之型一誤差與型二誤差總和。圖 5 紅色垂直線標示了誤差總和極小化之處，其與橫軸之交點即為最適臨界值 (\hat{P})。表 10 的 Panel A 為最適臨界值之計算結果，Logit1 模型的最小誤差總和為 0.1333，最適臨界值為 0.33; Logit2 模型的最小誤差總和為 0.1280，最適臨界值為 0.26。




圖 5 型一誤差與型二誤差總和軌跡圖

表 10 各模型之最適臨界值

Panel A: 最適臨界值與最小誤差總和				
	最小誤差總和		最適臨界值(\hat{P})	
Logit1	0.1333		0.33	
Logit2	0.1280		0.26	

Panel B: 給定臨界值下之型一誤差與型二誤差				
臨界值	Logit1		Logit2	
	Type I	Type II	Type I	Type II
0.0	0.00%	100.00%	0.00%	100.00%
0.02	1.82%	27.04%	1.66%	26.41%
0.04	1.82%	19.83%	1.99%	19.96%
0.06	2.65%	16.42%	2.49%	15.83%
0.08	3.48%	13.52%	2.99%	13.07%
0.10	3.65%	12.07%	3.48%	11.84%
0.20	6.63%	7.49%	6.14%	7.12%
0.30	8.13%	5.22%	8.13%	5.04%
0.40	10.28%	3.49%	10.45%	3.58%
0.50	13.43%	2.54%	13.10%	2.27%
0.60	16.58%	1.95%	15.75%	1.77%
0.70	20.90%	1.27%	20.40%	1.27%
0.80	26.53%	0.91%	26.04%	0.95%
0.90	41.13%	0.41%	40.63%	0.45%
1.00	100.00%	0.00%	100.00%	0.00%

(二) 分類正確率

表 11 為一般臨界值(\bar{P})與最適臨界值(\hat{P})下，各模型之型一誤差、型二誤差、與分類正確率指標，Panel A 為採用一般臨界值之分類結果，Panel B 則是採用最適臨界值之分類結果，Panel C 為不同臨界值之結果比較。分析表 11 本文有如下發現：第一，不論是一般臨界值或是最適臨界值，加入媒體情緒變數之模型能夠明顯的降低財務危機企業被錯誤歸類為非財務危機企業的可能(降低型一誤差)，從而具較高的分類正確率。Panel A 結果顯示，Logit2 模型較 Logit1 模型，型一誤差降低 4.21%，而分類正確率提升 0.33%；Panel B 結果顯示，相較 Logit1 模型，加入媒體情緒變數的 Logit2 模型之型一誤差降低 5.27%，而分類正確率提升 0.12%。另一方面，納入媒體情緒變數之後，非財務危機企業被誤認為財務危機企業的誤差(型二誤差)不僅沒有降低，甚至出現增加的情形。新聞報導的基調通常是正向的，正向詞彙的數目也多於負向詞彙的數目，但正面情緒是相對嘈雜無序的指標 (Tsai et al., 2016)。相對而言，非財務危機企業的正向報告比例高，對應的媒體情緒指標也較高；財務危機企業的負面報導比例高於非財務危機企業，媒體情緒指標相對低。因此，型一誤差降低的實證結果間接表明，在考量情緒強度的文字探勘技術之下，負向報導有助於識別財務危機企業；而型二誤差增加的實證結果表明，正向報導對於鑒別非財務危機經營企業沒有明顯增益，呼應 Tetlock (2007), Tetlock et al. (2008)的負向報導蘊含企業基本面資訊，而正向報導蘊含資訊增量少的研究發現。

第二，相較於一般臨界值模型，使用最適臨界值模型能有效降低型一誤差。Panel C 為最適臨界值模型減去一般臨界值模型的結果。通過使用最適臨界值，Logit1 模型的型一誤差降低 10.52%，而 Logit2 模型的型一誤差降低了 11.58%，Logit1 與 Logit2 模型在分類正確率上分別提升 0.55%與 0.34%。特別的，本研究在樣本外所使用財務危機企業與非財務危機企業比例是更為嚴格的 1:9，雖然型一誤差大幅降低造成型二誤差的小幅增加，但是 Logit1 與 Logit2 模型的分類準確率都因採用最適臨界值而得到改善。實務上將財務危機企業誤判為非財務危機企業的誤差更受重視，因其造成投資人實質投資損失，或是造成債權人蒙受呆帳的損失的風險。因此，本研究認為使用最適臨界值進行模型預測，較一般臨界值產生更符合實務需求的分類預測結果。

整體而言，本研究認為透過 VADER 情感分析工具剖析新聞文章以及採用最

適臨界值，確實能夠有效抓出財務危機企業新聞文章之負向字眼，進而增加模型判別財務危機企業之能力。

表 11 .模型分類正確率

	型一誤差	型二誤差	分類正確率
Panel A: 一般臨界值			
Logit1 ($\bar{P} = 0.5$)	29.47%	1.74%	95.33%
Logit2 ($\bar{P} = 0.5$)	25.26%	1.87%	95.66%
Logit2-Logit1	-4.21%	0.13%	0.33%
Panel B: 最適臨界值			
Logit1 ($\hat{P} = 0.33$)	18.95%	2.36%	95.88%
Logit2 ($\hat{P} = 0.26$)	13.68%	2.86%	96.00%
Logit2-Logit1	-5.27%	0.50%	0.12%
Panel C: 不同臨界值結果比較			
Logit1	-10.52%	0.62%	0.55%
Logit2	-11.58%	0.99%	0.34%

註: Logit1 表示由 Duan et al. (2012)之十二項變數所形成之羅吉斯模型。Logit2 表示加入媒體情緒變數(SENTI)後產生之羅吉斯模型。Panel A 為一般臨界值下的模型結果；Panel B 為最適臨界值下的模型結果。 \bar{P} 為一般臨界值； \hat{P} 為最適臨界值。Panel C 為最適臨界值模型減去一般臨界值模型的結果。

(三) CAP 曲線與 AR 值

摒除違約臨界值選擇的影響，CAP 曲線與 AR 值亦能體現模型的判別能力。圖 6 為各模型所形成之 CAP 曲線圖，是以圖形的方式呈現模型的累計精度。表 10 為各模型之 AR 值，則是以數值呈現基於 CAP 曲線圖的羅吉斯模型與完美模型的比值。AR 值越高代表模型之配適效果越好，包含十二項變數的 Logit1 模型 AR 值為 84.89%，而加入媒體情緒變數之後的 Logit2 則能進一步提升 AR 值至 85.22%。因此，CAP 曲線圖與 AR 值的結果也支持，加入媒體情緒變數進一步提升模型的判別能力。

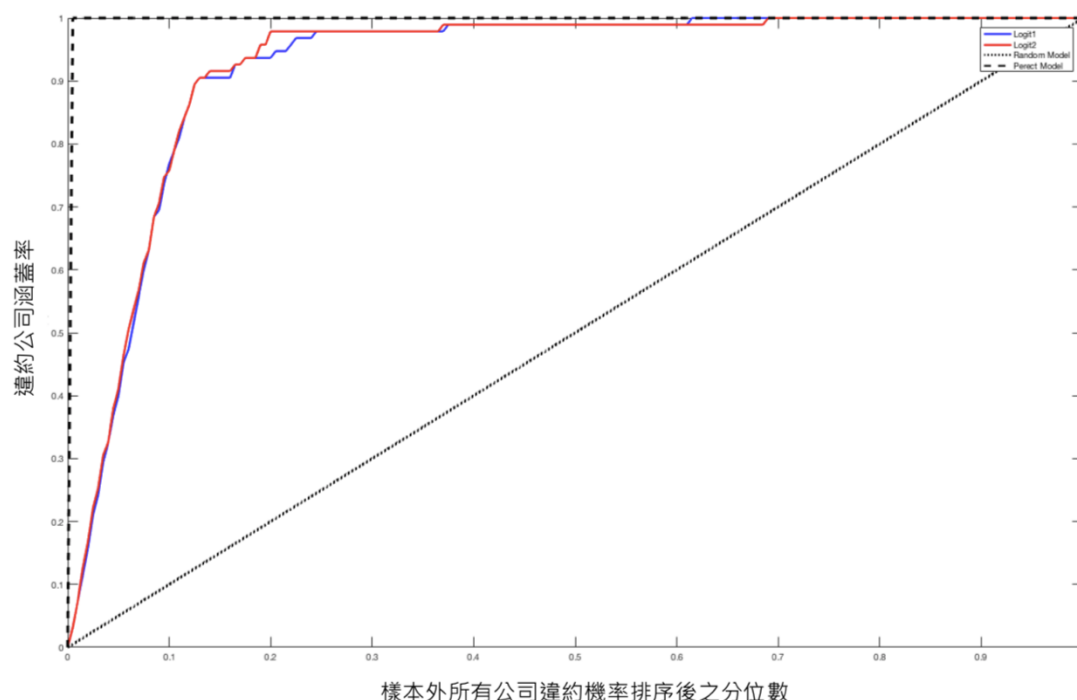


圖 6 各模型之 CAP 曲線

表 12 各模型之 AR 值

	AR 值
Logit1	84.89%
Logit2	85.22%

伍、結論與建議

全球化的影響與複雜金融商品的開發，導致近年來幾次嚴重的金融危機，金融機構開始對於投資人的信用風險有了更嚴格的控管，預測企業違約成為業界和學界重要的課題。既有研究多以企業財務比率、市場價格為主要衡量違約機率的指標，然而隨著文字探勘技術逐漸發展成熟，許多學者也將此技術應用於財務領域。有鑑於此，本文以 VADER 文字探勘技術作為情感分析的主要工具，結合媒體態度傾向、情緒強度以及新聞報導量來量化媒體情緒，嘗試進一步提升企業違約機率預測之準確度。

當然，本研究的實驗性探索亦存在限制。首先，在變數的選擇上，本研究使用財務指標以及媒體情緒指標為代表的非財務指標，在未來研究中還可以加入公司治理之變數，如公司之獨立董事數 (Daily and Dalton, 1994)，董事長兼任總經理、缺乏外部大股東以及內部董事持股比例 (Dechow et al., 1996)。其次，本研究採用 Duan et al. (2012) 之變數，但迴歸模型使用的是羅吉斯模型而非 Duan 的遠期強度模型。使用較為傳統的羅吉斯模型可以使本文聚焦在媒體情緒的萃取與 VADER 技術對文章結構層面的探索，但也因此損失了部分預測準確度，如同以六個月為觀察區間本文之 Logit2 模型之 AR 值低於 Duan et al. (2012) 的 AR 值約 2%。此外，本研究並沒有驗證媒體報導與企業違約事件的因果關係。本文的實證發現媒體情緒指標 SENTI 越悲觀則企業違約機率越大，但並沒有檢驗是媒體的負面報導引起企業違約，亦或是企業出現違約之徵兆引起媒體之報導。

本研究有三點主要貢獻：首先，媒體公開資訊增益企業信用風險評估。公開新聞經由適當的結構化處理，考量情緒強度的情感分析以及媒體情緒指標的構建，有助於提升違約預警模型的效能。從即時性新聞中萃取攸關企業信用風險之資訊內涵，一定程度上量化難以被直接觀察的企業基本面資訊，本文補充運用定性資料於企業信用風險評估的文獻，亦為金融機構或是研究學者提供參考。其次，本文將媒體情緒指標 SENTI 納入違約預警模型，實證結果顯現負向報導有助於降低模型將財務危機企業誤判為非財務危機企業的機率。公開新聞資訊以正向報導居多，然則既有文獻卻倚重負向報導進行研究。本研究深入文本結構進行探索並考量媒體情緒強度，實證結果支持負向報導之於企業違約預警的作用，更確認正向報導即使在 VADER 輔助之下亦無法改善非財務危機企業被誤判為財務危機

企業的情境。除此之外，本研究比較兩種不同的違約臨界值，發現使用誤差極小化之下所求取的最適違約判別臨界值，能有效降低型一誤差從而產生更優化的實質損失分類預測效果，此研究發現呼應了 Begley et al. (1996)的實證結果。因此，本研究建議銀行進行企業違約機率評估時，使用最適違約判別臨界值進行區分，有助於銀行優化資產配置以及降低產生不良貸款之風險。

本文立旨於透過非結構化的新聞媒體資訊，改善違約預測的準確率。藉由本研究成果，延伸概念至台灣中小企業授信戶。由於中小企業財報透明度低及資訊不對稱，增加金融機構分析時的難度，經由剖析新聞媒體資訊，或可彌補中小企業財報資訊和企業市場價格資訊的不足，提升台灣金融機構對於授信企業信用之判斷。在情感分析方面，本研究使用基於 VADER 已有情感詞庫和規則產生文章之情緒判斷，其詞庫為通用性詞庫適合應用於多種領域的文本判別，卻也會導致專業領域之情感詞不足，因此本文認為後續研究可以延伸 Hutto and Gilbert (2014) 文中所使用的情感詞評分方法，進行財務危機相關情感詞評分以擴增情感詞庫，預期有助於再提高企業違約預測結果之準確性。

附錄

本文使用「VADER isn't easy to use, but it is very SMART!!!」為例子解釋 VADER 情感分析中的單句評分過程。

A1	["VADER isn't easy to use, but it is very SMART!!! "]
A2	["VADER", "isn't", "easy", "to", "use", "but", "it", "is", "very", "SMART", "!!!"]
B1	["easy"]: 1.9 , ["smart"]: 1.7 ["VADER", "isn't", "easy", "to", "use", "but", "it", "is", "very", "smart", "!!!"] score=[0, 0, 1.9 , 0, 0, 0, 0, 0, 0, 0, 1.7 , 0]
B2	["VADER", "isn't", "easy", "to", "use", "but", "it", "is", "very", "SMART", "!!!"] score=[0, 0, 1.9, 0, 0, 0, 0, 0, 0, 0, 1.7+0.733 , 0]
B3	["very"] : 0.293 ["VADER", "isn't", "easy", "to", "use", "but", "it", "is", "very", "SMART", "!!!"] score=[0, 0, 1.9, 0, 0, 0, 0, 0, 0, 0, 2.433+0.293 , 0]
B4	["VADER", "isn't", "easy", "to", "use", "but", "it", "is", "very", "SMART", "!!!"] score=[0, 0, -0.74*1.9 , 0, 0, 0, 0, 0, 0, 0, 2.726, 0]
B5	["VADER", "isn't", "easy", "to", "use", "but", "it", "is", "very", "SMART", "!!!"] score=[0, 0, 0.5*-1.406 , 0, 0, 0, 0, 0, 0, 0, 1.5*2.726 , 0]
B6	score=0.5*-1.406+1.5*2.726= 3.386
B7	["VADER", "isn't", "easy", "to", "use", "but", "it", "is", "very", "SMART", "!!!"] score=3.386+3*0.292= 4.262
C1	score=4.262 , score _{norm} = 4.262/5.759= 0.74

參考文獻

- 王明昌、鄭揚耀及柯建全(2015),「企業財務危機前之媒體管理」, 會計評論, 第 61 期, 77-119。
- 金雪軍、祝宇與楊曉蘭(2013),「網絡媒體對股票市場的影響——以東方財富網股吧為例的實證研究」, 新聞與傳播研究, 第 12 期, 36-51。
- 林長瑞(2010),「預測財務危機公司樣本配置之研究」, 管理與資訊學報, 第 15 期, 1-30。
- Antweiler, W., and Frank, M. Z. (2004), “Is All that Talk Just Noise? The Information Content of Internet Stock Message Boards,” *The Journal of Finance*, 59(3), 1259-1294.
- Black, F., and Scholes, M. (1973), “The Pricing of Options and Corporate Liabilities,” *Journal of Political Economy*, 81(3), 637-654.
- Begley, J., Ming, J., and Watts, S. (1996), “Bankruptcy Classification Errors in the 1980s: An Empirical Analysis of Altman’s and Ohlson’s models,” *Review of Accounting Studies*, 1(4), 267-284.
- Bharath, S.T., and Shumway, T. (2008), “Forecasting Default with the Merton Distance to Default Model,” *The Review of Financial Studies*, 21(3), 1339-1369.
- Brazel, J. F., Jones, K. L., and Zimbelman, M. F. (2009), “Using Nonfinancial Measures to Assess Fraud Risk,” *Journal of Accounting Research*, 47(5), 1135-1166.
- Campbell, J. Y., Hilscher, J., and Szilagyi, J. (2008), “In Search of Distress Risk,” *The Journal of Finance*, 63(6), 2899-2939.
- Daily, C. M., and Dalton, D. R. (1994), “Bankruptcy and Corporate Governance: The Impact of Board Composition and Structure,” *Academy of Management journal*, 37(6), 1603-1617.
- Davis, A.K., Piger, J.M., and Sedor, L.M. (2012), “Beyond the Numbers: Measuring the Information Content of Earnings Press Release Language,” *Contemporary Accounting Research*, 29(3), 845-868.
- Dechow, P. M., Sloan, R. G., and Sweeney, A. P. (1996), “Causes and Consequences of Earnings Manipulation: An Analysis of Firms Subject to Enforcement Actions by the SEC,” *Contemporary Accounting Research*, 13(1), 1-36.
- Duan, J.C., Sun, J., and Wang, T. (2012), “Multiperiod Corporate Default Prediction-a

- Forward Intensity Approach,” *Journal of Econometrics*, 170(1), 191-209.
- Duffie, D., Eckner, A., Horel, G., and Saita, L. (2009), “Frailty Correlated Default,” *The Journal of Finance*, 64(5), 2089-2123.
- Figlewski, S., Frydman, H., and Liang, W. (2012), “Modeling the Effect of Macroeconomic Factors on Corporate Default Credit Rating Transitions,” *International Review of Economics and Finance*, 21, 87–105.
- Forss, T., and Sarlin, P. (2018), “News-sentiment Networks as a Company Risk Indicator,” *Journal of Network Theory in Finance*, 4(1), 65-86
- Gentzkow, M., and Shapiro, J. M. (2006), “Media Bias and Reputation,” *Journal of Political Economy*, 114(2), 280-316.
- Gentzkow, M., and Shapiro, J. M. (2010), “What Drives Media Slant? Evidence from US Daily Newspapers,” *Econometrica*, 78(1), 35-71.
- Gurun, U. G., and Butler, A. W. (2012), “Don't Believe the Hype: Local Media Slant, Local Advertising, and Firm Value,” *The Journal of Finance*, 67(2), 561-598.
- Hajek, P., Olej, V., and Prochazka, O. (2016), “Predicting Corporate Credit Ratings Using Content Analysis of Annual Reports – a Naïve Bayesian Network Approach,” In *FinanceCom 2016* (pp. 47-61), Cham: Springer.
- Henselmann, K., and Scherr, E. (2012), “Content Analysis of XBRL Filings as an Efficient Supplement of Bankruptcy Prediction? Empirical Evidence Based on US GAAP Annual Reports,” Working Paper.
- Hull, J., Predescu, M., and White, A. (2004), “The Relationship between Credit Default Swap Spreads, Bond Yields, and Credit Rating Announcements,” *Journal of Banking & Finance*, 28(11), 2789-2811.
- Hutto, C.J., and Gilbert, E. (2014), “VADER: A Parsimonious Rule-based Model for Sentiment Analysis of Social Media Text,” In *Eighth international AAAI conference on weblogs and social media*.
- Lopatta, K., Gloger, M.A., and Jaeschke, R. (2017), “Can Language Predict Bankruptcy? The Explanatory Power of Tone in 10-K Filings,” *Accounting Perspectives*, 16(4), 315-343.
- Loughran, T., and McDonald, B. (2011), “When Is a Liability not a Liability? Textual

- Analysis, Dictionaries, and 10-Ks,” *The Journal of Finance*, 66(1), 35-65.
- Lu, Y.C., Shen, C.H., and Wei, Y.C. (2013), “Revisiting Early Warning Signals of Corporate Credit Default Using Linguistic Analysis,” *Pacific-Basin Finance Journal*, 24(C), 1-21.
- Lu, Y. C., Wei, Y. C., and Chang, T. Y. (2015), “The Effects and Applicability of Financial Media Reports on Corporate Default Ratings,” *International Review of Economics & Finance*, 36, 69-87.
- Magnusson, C., Arppe, A., Eklund, T., Back, B., Vanharanta, H., and Visa, A. (2005), “The Language of Quarterly Reports as an Indicator of Change in the Company’s Financial Status,” *Information & Management*, 42(4), 561-574.
- Manning, C.D., Schütze, H., (2002), *Foundations of Statistical Natural Language Processing (2nd Edition with Corrections)*, Cambridge, Massachusetts: MIT Press.
- Merton, R. C. (1974), “On the Pricing of Corporate Debt: The Risk Structure of Interest Rates,” *The Journal of Finance*, 29(2), 449-470.
- Norden, L. (2008), “Credit Derivatives, Corporate News, and Credit Ratings,” *SSRN eLibrary*.
- Norden, L., and Weber, M. (2004), “Informational Efficiency of Credit Default Swap and Stock Markets: The Impact of Credit Rating Announcements,” *Journal of Banking & Finance*, 28(11), 2813-2843.
- Odders-White, E. R., and Ready, M. J. (2006), “Credit Ratings and Stock Liquidity,” *The Review of Financial Studies*, 19(1), 119-157.
- Ohlson, J.A. (1980), “Financial Ratios and the Probabilistic Prediction of Bankruptcy,” *Journal of Accounting Research*, 18(1), 109-131.
- Reuter, J., and Zitzewitz, E. (2006), “Do Ads Influence Editors? Advertising and Bias in the Financial Media,” *The Quarterly Journal of Economics*, 121(1), 197-227.
- Shumway, T. (2001), “Forecasting Bankruptcy more Accurately: A Simple Hazard Model,” *The Journal of Business*, 74(1), 101-124.
- Tetlock, P.C. (2007), “Giving Content to Investor Sentiment: The Role of Media in the Stock Market,” *The Journal of Finance*, 62(3), 1139-1168.
- Tetlock, P.C., Saar-Tsechansky, M., and Macskassy, S. (2008), “More than Words:

Quantifying Language to Measure Firms' Fundamentals,” *The Journal of Finance*, 63(3), 1437-1467.

Tsai, F.T., Lu, H.M., and Hung, M.W. (2016), “The Impact of News Articles and Corporate Disclosure on Credit Risk Valuation,” *Journal of Banking & Finance*, 68(7), 100-116.