

國立臺灣大學管理學院會計學研究所

碩士論文

Department of Accounting

College of Management

National Taiwan University

Master Thesis



利用深度學習預測審計失敗--以台灣為例

Predict Audit Failure Using Deep Learning Algorithm—

Take Taiwan as Example

徐佳揚

Hsu, Chia-Yang

指導教授：吳琮璠 博士

Advisor: Chung-Fern Wu, Ph.D.

中華民國 110 年 1 月

January 2021

國立臺灣大學（碩）博士學位論文
口試委員會審定書

利用深度學習預測審計失敗--以台灣為例
Predict Audit Failure Using Deep Learning
Algorithm—Take Taiwan as Example

本論文係徐佳揚君（R07722005）在國立臺灣大學會計學系、所完成之碩（博）士學位論文，於民國 110 年 1 月 7 日承下列考試委員審查通過及口試及格，特此證明

口試委員：

吳峰 王

（簽名）

（指導教授）

吳峰 王

許子怡

吳松

系主任、所長

劉順仁

（簽名）

（是否須簽章依各院系所規定）



中文摘要

利用台灣上市、櫃公司財務報表重編作為審計失敗的指標，並依照 Fully Connected Feedforward Network 架構架設深度學習模型，用以預測可能發生審計失敗的查核案件，並利用半監督式學習與 Voting 等方式強化預測效果。與對照組邏輯斯回歸模型相比，預測能力顯著提升。

程式碼: https://github.com/R07722005/Audit_Failure_Prediction

關鍵字：會計師、審計失敗、深度學習、機器學習

英文摘要

Used financial statement restatements of Taiwanese listed companies as indicator of audit failure, and built a Deep learning models based on Fully Connected Feedforward Network framework to predict audit failure, then used semi-supervised learning and Noting methods to improve prediction outcome. The predictive ability was significantly improved compared with the logistic regression model of the control group.

Code: https://github.com/R07722005/Audit_Failure_Prediction

Keywords: Auditor, Audit Failure, Deep Learning, Machine Learning

感謝詞

感謝林鈺澄、卓訓輔、黃亭硯、張哲瑋、王思源、王智生與沈家睿，沒有你們我肯定沒有辦法完成這篇論文。感謝家人一路上的陪伴，也紀念我在天上的家人。



Nobody exists on purpose, nobody belongs anywhere, everybody's gonna die.

Come watch TV.

—Morty Smith

目錄



口試委員會審定書	I
中文摘要	III
英文摘要	IV
感謝詞	V
圖目錄	IX
表目錄	X
第一章 緒論	1
第一節 研究背景與動機	1
第二節 研究目的	2
第三節 研究架構	3
第二章 文獻回顧	4
第一節 審計失敗	4
第二節 審計失敗的傳染效果	5
第三節 裁決性應計數	6
一、 Johns Model	6
二、 Modified Johns Model	7
三、 加入 ROA 的 Modified Johns Model	7
第三章 深度學習	8
第一節 名稱的由來	8
第二節 Activation Function	9
第三節 深度學習架構	10
一、 Input layer	11
二、 Hidden layer	11



三、	Output layer	11
四、	Fully Connected Feedforward Network	12
第四節	Loss Function	13
第五節	Gradient Descent	14
第六節	Backpropagation.....	15
第七節	小結	17
第四章	研究方法	18
第一節	資料整理	18
一、	審計失敗	18
二、	裁決性應計數	19
三、	審計失敗傳染效果	20
四、	整理結果	21
第二節	模型架構	22
第三節	訓練模型	24
一、	資料清洗	25
二、	訓練資料抽選	25
三、	半監督式學習	26
四、	訓練過程	28
五、	Voting.....	30
第五章	研究結果	32
第一節	實驗組	32
第二節	對照組	32
第三節	實驗組與對照組比較	35
第四節	模組的優點與缺點	37
第六章	結論	38

第一節	研究結論	38
第二節	研究建議	38
參考資料	39
附錄	41
	Confusion Matrix.....	41
	Zmijewski (1984) index	42
	其他參數	43



圖目錄



Fig. 2-1	財務報表編制至申報流程	5
Fig. 3-1	Sigmoid Function.....	9
Fig. 3-2	ReLU Function	9
Fig. 3-3	轉換前的資料	10
Fig. 3-4	轉換後的資料	10
Fig. 3-5	Fully Connected Feedforward Network.....	12
Fig. 3-6	Loss 值分布圖，上層為 Cross Entropy，下層為平方差公式	14
Fig. 4-1	深度模型架構	24
Fig. 4-2	抽選並創造平衡資料集(取自於 ufoym 的 Github, 2020).....	26
Fig. 4-3	未使用 Pseudo-label 第 20 Epoch 時測試資料的混淆矩陣.....	28
Fig. 4-4	使用 Pseudo-label 後第 49 組模組第 20 Epoch 時測試資料的混淆矩陣..	28
Fig. 4-5	1 號模型 0 至 19 Epoch 的 Loss 值、訓練資料正確率與測試資料正確率	29
Fig. 4-6	0 號模型至 49 號模型在測試質量上的表現	30
Fig. 4-7	25 號模型至 49 號模型 Voting 結果.....	31
Fig. 4-8	25 號模型至 49 號模型經由不同投票門檻產生的預測表現	31
Fig. 5-1	深度學習模型實驗結果	32
Fig. 5-2	對照組 Logit Regression Result.....	34
Fig. 5-3	對照組 ROC curve	35
Fig. 5-4	實驗組與對照組的 Precision-Recall Plot.....	36
Fig. 5-5	對照組預測結果(閾值為 0.009).....	37

表目錄



Tabel 1	審計失敗所使用的重編原因	18
Tabel 2	審計失敗傳染效果應變數	20
Tabel 3	訓練資料與測試資料	21
Tabel 4	實驗設備與軟體	24
Tabel 5	對照組使用的自變數及應變數	33
Tabel 6	模組的優缺點	37
Tabel 7	Confusion Matrix	41
Tabel 8	其他參數	43

第二章 緒論



第一節 研究背景與動機

2001 年 10 月安隆案爆發之後¹，投資大眾對會計師查核簽證產生疑問，認為會計師自律組織並不能發揮效益，出具適當查核報表。於是美國通過著名的沙賓法案(Sarbanes Oxley Act)，並成立公開公司會計監督委員會 (Public Company Accounting Oversight Board, PCAOB)，以法律形式制定審計準則，並要求會計師遵守。

財務報表錯誤與舞弊一直是社會矚目的焦點，台灣也曾出現過多起財報舞弊案例，如博達、力霸案等，而會計師需要針對錯誤或有舞弊的財務報表表示適當的意見以警示投資人，使投資人能夠判斷其投資風險，基於這種信任關係才能促進更多的投資，活絡整體經濟。然而會計師可能因為諸多原因而導致出具無適當的查核意見，造成投資人誤判而損失，這就是審計失敗。台灣上市、櫃財務報表取得會計師查核意見之後，需要將財務報表申報至主管機關審核，但由於台灣上市、櫃公司數量龐大，主管機關僅能以抽查的方式審查，這使得主管機關每年要投入大量人力卻無法涵蓋所有須審查的公司。因此若有能夠預測審計失敗的模型，能縮小需審查的範圍，主管機關便能更精準地抽查財務報表，有效減少審計失敗發生，並改善金融環境，促進整體經濟。國、內外對審計失敗的研究已相當廣泛，舉凡審計品質、會計師與事務所間的傳染效果、會計師是否輪調等問題皆有論文發表，然而真正預測審計失敗的模型卻不多，且多半使用回歸模型，精準度並不高。在此篇論文中以已被分析的審計失敗因子並利用深度學習模型來強化預測效果，訓練出能夠更精準預測可能產生審計失敗的查核案件，作為主管機關選擇審查目標時的依據。

¹ 陳怡均. 2008. 簡介美國 PCAOB 對於公開公司會計師之監理. 金融監督管理委員會 2008 [cited October 16 2008]. Available from [https://www.fsc.gov.tw/fckdowndoc?file=/%E5%AF%A6%E5%8B%99%E6%96%B0%E7%9F%A5%20\(1\).pdf&flag=doc](https://www.fsc.gov.tw/fckdowndoc?file=/%E5%AF%A6%E5%8B%99%E6%96%B0%E7%9F%A5%20(1).pdf&flag=doc).



第二節 研究目的

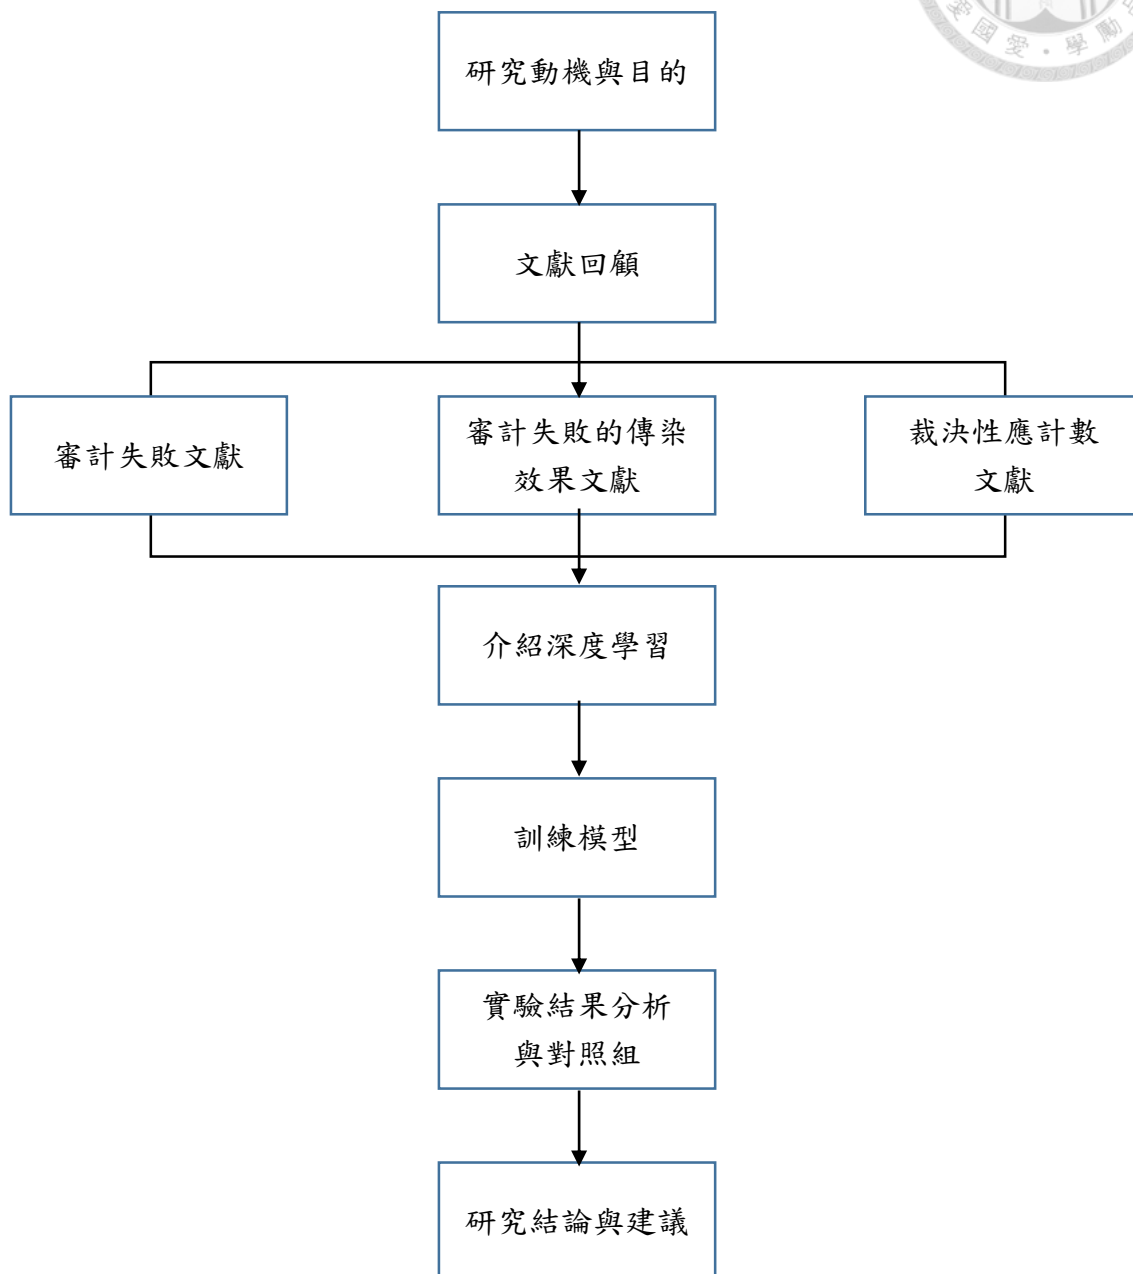
以往的審計失敗相關論文多半是討論哪些因子會增加審計失敗出現的機率，而預測審計失敗多半是使用線性回歸或邏輯斯回歸，準確性並不高。本次研究將訓練一組深度學習模型用以預測審計失敗，並以提升預測準確率為目標，預測下一年中的可能產生的審計失敗，幫助主管機關選擇要抽查的財務報表時能夠縮小抽查的範圍。

本次研究以 Python 中的 Pytorch 套件為核心，以 Fully Connected Feedforward Network 架構設計深度學習模型，並加入半監督式學習與 Voting 等技術強化預測結果。模型的自變數來自台灣經濟新報 TEJ+ 中現有的資料，與過往已被分析的審計失敗因子，為了創造資料取得容易、訓練容易的深度學習模型，且成果超越其他預測模型。

總以上所述，本研究將以以下幾個目標訓練模型：

- (一) 使用台灣經濟新報 TEJ+ 中現有的資料與過往已被分析的審計失敗因子
- (二) 以 Fully Connected Feedforward Network 架構設計深度學習模型
- (三) 預測結果的正確率、Sensitivity、Precision 要比邏輯斯回歸模型更高

第三節 研究架構



第三章 文獻回顧



第一節 審計失敗

依照吳琮璠教授 (2001)²在審計學中對審計失敗的定義，審計失敗指：「查核人員未依照一般公認審計準則執行查核工作，出具不當的查核報告。」需要注意審計失敗並非企業失敗，企業失敗指企業因為內在或外在的因素而倒閉或重整²，企業失敗並不直接導致審計失敗。在查核時會計師應「盡專業上應有之注意，蒐集足夠及適切的查核證據，出具適當意見」²，當企業失敗產生時，若會計師依照其專業出具適當查核意見，則不能稱之為審計失敗。證券交易法中亦規定³若公司公開說明書有虛偽或隱匿之情事，會計師對善意第三人所受之損失負連帶賠償責任，但會計師若如能證明已經合理調查，並有正當理由確信其簽證或意見為真實者則免責。由此可見審計失敗著重於是否出具適當的報告，而非企業本身營利狀況的好壞。

台灣財務報表發布需要經過三個步驟，由公司編製，經過會計師查核，再申報主管機關審查。證券交易法第 14 條規定：「財務報告應經董事長、經理人及會計主管簽名或蓋章，並出具財務報告內容無虛偽或隱匿之聲明。」其表示財務報表的編製階段，需要公司潔身自愛，讓財務報表內容無虛偽或隱匿之情事，再經過會計查核。而依照證券交易法第 32 條規定，會計師需要近專業上應有之注意查核財務報表，並對財務報表出具適當意見。最後財務報表經查核後申報主管機關審查，依證券交易法施行細則第 6 條規定，未依有關法令編製而應予更正者，應照主管機關所定期限自行更正，且依證券交易法第 39 條規定，若發行人申報之財務報表發現有不符法令規定之事項，得以命令糾正、限期改善並處罰。由上述可知若財務報表有虛偽或隱匿，經查核後申報審查，主管機關有權利要求公司重編，且公司與會計師都要受處罰，只有在會計師依照專業之注意出具適當之意見時才能免罰。換句

² 吳琮璠教授. 2001. 審計學--新觀念與本土化. 台北市: 吳琮璠教授. 頁 76

³ 證交法 32 條

話說，除因會計原則改變、會計個體變更造成的財務報表重編，或有會計師能證明自己已盡專業上應有之注意的狀況外，財務報表重編可以當成審計失敗的指標。並可運用財務報表重編當作應變數來訓練模型並用以預測審計失敗。

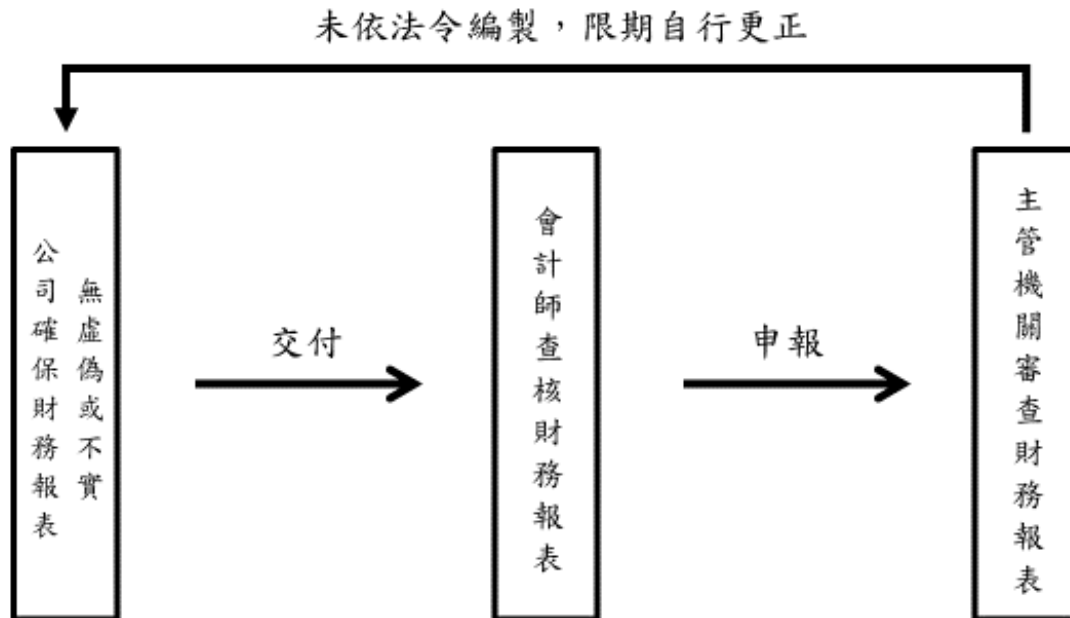



Fig. 2-1 財務報表編制至申報流程

第二節 審計失敗的傳染效果

審計失敗的傳染效果係指若一件審計失敗發生時，與其有一定關聯性的審計案件的審計品質也會下降，造成發生審計品質的可能性升高。在 Li et al. (2015)⁴ 的研究中，傳染效果分為垂直傳染與水平傳染，並又以會計師或會計師事務所的傳染效果做區分。垂直傳染效果指會計師或事務所曾經發生過審計失敗，接下來數年間該會計師或事務所所執行的查核案件審計品質也會下降，出現審計失敗的可能性較其他查核案件更高。而水平傳染效果指會計師或事務所發生過審計失敗的年度，當年同會計師或事務所所執行的查核案件審計品質也會下降，出現審計失敗的可能性較同年度其他查核案件更高。

⁴ Li, L., B. Qi, G. Tian, and G. Zhang. 2015. The Contagion Effect of Low-Quality Audits along Individual Auditors. Available at SSRN 2478348.



Li et al. (2015)⁴ 分析中國證券監督管理委員會(CSRC)與中國註冊會計師協會(CICPA)中有關於會計師相關的資料，發現不論會計師層級或事務所層級皆出現水平及垂直傳染。會計師與事務所層級的垂直傳染約會影響四年，若一件查核案件其執行查核的會計師或事務所若在前四年間出現審計失敗，則該案件出現審計失敗的可能性提升。而會計師與事務所層級的水平傳染則是讓當年度該會計師或事務所執行的其他查核案件出現審計失敗的可能性提高。

第三節 裁決性應計數

在會計上應計基礎較現金基礎使用廣泛⁵，應計基礎能讓管理階層更容易地將公司內部的資訊向外界透露，然而管理階層也能透過激進的盈餘管理讓財務報表失真，進而造成財報使用者做出錯誤判斷。裁決性應計數(Discretionary Accrual)是衡量盈餘管理的指標，藉由過去一定年間自己的財務資訊或同年間同產業其他公司的財務資訊計算該公司今年度應有的應計數，而偏離預測應計數的數字為裁決性應計數，代表管理階層盈餘管理的程度。裁決性應計數與審計品質有一定的關連性⁵，而依據 DeAngelo (1981)⁶對審計品質的定義為會計師發現並報導財報舞弊與錯誤的能力，這顯出審計品質與審計失敗有關，審計失敗就是低審計品質的表現，會計師無法發現財報舞弊與錯誤導致出不適當之查核意見。由此推論裁決性應計數與審計失敗有所關連。

一、 Johns Model

Jones (1991)⁷ Model 最初的目的是要測試那些公司藉由降低營收來爭取補助款。論文中將總應計數定義為非現金營運資金變動，去除總折舊費用所獲得的值。

⁵ Krishnan, G. V. 2003. Audit quality and the pricing of discretionary accruals. *Auditing: A journal of practice & theory* 22 (1):109-126.

⁶ DeAngelo, L. E. 1981. Auditor size and audit quality. *Journal of accounting and economics* 3 (3):183-199.

⁷ Jones, J. J. 1991. Earnings management during import relief investigations. *Journal of accounting research* 29 (2):193-228.

模型利用不動產、廠房與設備、收入年變動、常數項，並將各項皆除去年總資產來模擬一間公司正常的應計數。不動產廠房與設備是為了控制非裁決性折舊費用，收入年變動則是要控制經濟環境對公司的影響。依照模型計算出該年度正常應計數後，與總應計數之差額極為裁決性應計數。

二、 Modified Johns Model

Dechow et al. (1995)⁸認為單純使用 Johns Model 單純使用收入無法完整詮釋正常的應計數，應將收入年變動減除應收帳款年變動。未修正前的 Johns Model 認為收入是無法被管理階層藉由盈餘管理更改其數值，而 Modified Johns Model 則認為所有賒銷都有盈餘管理的可能，這是因為相較於現金銷貨，管理階層能更輕易地藉由賒銷的收入任列執行盈餘管理，因此收入變動需減除應收帳款變動。

三、 加入 ROA 的 Modified Johns Model

Kothari et al. (2005)⁹認為於眾多偵知裁決性應計數的方法之中，由 Dechow, P. et al 所提出的 Modified Johns Model 解釋能力最高，為了要減少因忽略公司大小而造成的變異數不一致的問題，S.P. Kothari et al. 增加 ROA 項來控制此問題。這也是本次實驗中會使用的裁決性應計數，其公式詳見公式(4.1)

⁸ Dechow, P. M., R. G. Sloan, and A. P. Sweeney. 1995. Detecting earnings management. *Accounting review*:193-225.

⁹ Kothari, S. P., A. J. Leone, and C. E. Wasley. 2005. Performance matched discretionary accrual measures. *Journal of accounting and economics* 39 (1):163-197.

第四章 深度學習



第一節 名稱的由來

1958 年¹⁰由 Frank Rosenblatt 提出名為 Perceptron 的想法，這個演算法類似於線性分類模型，在訓練資料可被線性函數區分時，Perceptron 可以保證在有限的步驟中將此線性函數找出來。然而這個方法卻在 1962 年時遭到 Marvin Minsky 抨擊，他認為 Perceptron 只能在有限的情況下才能運作，不能廣泛地被運用。這也導致 Perceptron 的研究熱潮迅速平息，直到 1980 年代中期才又被人提起。

1980 年代中期¹¹，Multilayer Perceptron 的這個方法被提出，雖然叫做 Multilayer Perceptron，但這個演算法其實不是指很多的 Perceptron 接在一起，而是改用很多層的 Logistic Model 連接¹²。這個演算法又被人稱作 Neural Network，也就是大家現在常使用的「神經網路」一詞。這是因為當時的學者們想要利用 Multilayer Perceptron 來尋找生物神經系統的數學表示法。這時的 Multilayer Perceptron 已與 2015 年以後使用的深度學習演算法沒有太大的差別。

在 1986 時由 Rumelhart et al. (1986)提出 Back-propagation 演算法¹³，這個演算法能夠重複調整神經網路中各單元中的權重，讓神經網路的輸出向量與目標向量殘差值降到最低。然而當時卻發現如果神經網路的隱藏層超過三層¹⁴，就無法訓練出好的結果。於是在 1989 年左右，多數學者認為一層的隱藏層就足夠模擬各種函數¹⁴，於是 Multilayer Perceptron 的聲量又再次下跌。

¹⁰ Bishop, C. M. 2006. *Pattern recognition and machine learning*: springer. (pp.193-194)

¹¹ 李宏毅. 2016d. ML Lecture 6: Brief Introduction of Deep Learning. YouTube.

<https://www.youtube.com/watch?v=Dr-WRIEFefw>. (4:19-10:59)

¹² Bishop, C. M. 2006. *Pattern recognition and machine learning*: springer. (pp.226)

¹³ Rumelhart, D. E., G. E. Hinton, and R. J. Williams. 1986. Learning representations by back-propagating errors. *nature* 323 (6088):533-536.

¹⁴ Nielsen, M. *CHAPTER 4 A visual proof that neural nets can compute any function* 2019 [cited]. Available from <http://neuralnetworksanddeeplearning.com/chap4>.

在 1999 年後，隨著 GPU 的發展，訓練多層以上的隱藏層成為可能，於是學者們就將 Multilayer Perceptron 重新命名為 Deep Learning，也就是現在常聽到的「深度學習」，回到眾人的面前。而在 2006 年 Hinton et al. (2006)提出使用 Restricted Boltzmann machines(RBM)來訓練深度學習的各項權重的初始值¹⁵，由於其結構複雜吸引各研究者的目光，讓 Deep Learning 重新受到重視，甚至有人認為使用 Restricted Boltzmann machines(RBM)才算是 Deep Learning，而未使用則是屬於 1980 年代的 Multilayer Perceptron。但隨著更多研究投入，便發現不需要 Restricted Boltzmann machines(RBM)也能訓練 Deep Learning 模型，於是 Deep Learning 與 Multilayer Perceptron(Neural Network)成為同一種演算法但不同名稱，換句話說「深度學習」與「神經網絡」屬於同一種演算法，兩個名稱常被交互使用，為了避免困惑先在此述明。

第二節 Activation Function

Activation function 是深度學習中最基本的單位，可以想像它是神經網路中的一個節點(node)，執行最簡單的非線性轉換。Activation function 有許多種，常見的有 Sigmoid(3.1)、Rectified Linear Unit (ReLU)(3.2)等。

$$y = \frac{1}{1 + e^{-x}} \quad (3.1)$$

$$\max(0, x) \quad (3.2)$$




Fig. 3-1 Sigmoid Function




Fig. 3-2 ReLU Function

¹⁵ Hinton, G. E., S. Osindero, and Y.-W. Teh. 2006. A fast learning algorithm for deep belief nets. *Neural computation* 18 (7):1527-1554.

Activation function 可以產生相當於邏輯運算子的效果，而且串接越多效果越強。舉一個例子，如附圖 Fig. 3-3，有四個點，分別為(0,0)、(1,0)、(0,1)、(1,1)。如果要將(0,0)與(1,1)分為一類，(1,0)與(0,1)分為另一類，會發現若單純使用線性函數會無法進行分類。但若將各點經過下面兩組 ReLU 轉換(3.3)(3.4)，就會發現利用一次函數區分成為可能¹⁶。

$$w = \max(0, x - 0.5 * y) \quad (3.3)$$

$$z = \max(0, -0.9x + y) \quad (3.4)$$

經轉換後的四個點分別為(0,0)、(0.5,0.1)、(1,0)、(0,1)，如附圖 Fig. 3-4，可以輕易的被一次函數區分。若使用多個 Activation function 則能更有效地轉換資料，幫助分類。




Fig. 3-3 轉換前的資料




Fig. 3-4 轉換後的資料

第三節 深度學習架構

深度學習的架構可以任意改變，以應對各種需求，在這篇論文中會使用最基礎的 Fully Connected Feedforward Network 架構¹⁷。深度學及模型可以想像成一個巨

¹⁶ 李宏毅. 2016g. ML Lecture 11: Why Deep? YouTube.

<https://www.youtube.com/watch?v=XsC9byQkUH8>. (36:14-39:08)

¹⁷ ————. 2016d. ML Lecture 6: Brief Introduction of Deep Learning. YouTube.

<https://www.youtube.com/watch?v=Dr-WRIEFefw>. (16:58-18:48)



型的函數，和一般的函數一樣，將一向量輸入函數後能夠轉換成另一向量。此模型由一層 Input Layer、一層 Output Layer 以及任意數量 Hidden Layer 組成。

一、 Input layer

Input layer 並不是真的「一層」，而是單純指要輸入方程式的向量¹⁷。換句話說，就是指所有要使用的自變數，在 Fully Connected Feedforward Network 的架構下，每一個自變數都會輸入到下一層的所有節點(node)中，下一層的每個節點都會使用 Input layer 中每一個自變數。

二、 Hidden layer

Hidden layer 是 Input layer 輸出的對象，可以任意決定要有多少層，每層由任意數量的 Activation function 組成，作為 Hidden layer 的節點(node)¹⁷。每一層的節點不用相同，每層使用的 Activation function 也不用相同。如第一層是五千個 Sigmoid function，第二層可以接三千個 ReLU function。從 Input layer 得到自變數後，每個節點會產出一個值，這些值會當作新的自變數輸入到下一層的 Hidden Layer 之中。如同 Input layer，在 Fully Connected Feedforward Network 的架構下，每一個節點產生的值都會輸入到下一層的所有節點中，下一層的每個節點都會使用上一層 Hidden layer 中每一個產出的數值。最後一層的 Hidden Layer 會將值輸出到 Output layer。

三、 Output layer

Output layer 是一個分類器¹⁸，就像在 Activation Function 章節提到的例子，原資料經過非線性轉換後被一次方程式分類。對比到深度學習，input layer 是未經轉換的資料，經過 hidden layer 非線性轉換後，將資料點轉換成容易被分類的型態，或可稱為找到資料的特徵(Feature)，再利用 Output layer 把資料分類成多個種類，但相較於一次方程式，Output layer 會使用能夠一次區分多種類類別的函數。常在

¹⁸ Ibid. (27:24-28:30)

分類時被使用的函數為 Softmax function(3.5)。Sigmoid function 的主要目的直覺上從 hidden layer 中的資料壓縮到 0 至 1 之間¹⁸，並算出一筆資料被分到各個類別的後驗機率(Posterior probability)¹⁹，其中擁有最大值後驗機率的類別就是該筆資料被預測出來的類別。

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.5)$$

四、 Fully Connected Feedforward Network

這是指一種最常見的連接各 Layer 的方法²⁰，每一個節點產出的資料都會輸出到下一層的所有節點中，而每一個節點也會使用上一層所有節點產出的資料，這就是 Fully Connected，如附圖 Fig. 3-5²¹。Feedforward 則是指資料從 Input Layer 傳遞到 Hidden Layer 在傳遞到 Output Layer，呈現順向的結構。Fully Connected Feedforward Network 只是最基礎的深度學習架構，還有許多別的架構如 DANN、Residual Net 等。




Fig. 3-5 Fully Connected Feedforward Network²¹

¹⁹ Bishop, C. M. 2006. *Pattern recognition and machine learning*: springer. (pp.209-210)

²⁰ 李宏毅. 2016d. ML Lecture 6: Brief Introduction of Deep Learning. YouTube.

<https://www.youtube.com/watch?v=Dr-WRIEFefw>. (12:50-18:46)

²¹ Ibid. (28:19)



第四節 Loss Function

有深度學習的模組後，還需要一個用來評價模組好壞的方法²²。此時就需要使用 Loss Function。Loss Function 依照模組預測出來的結果與真實資料互相比對後算出一個分數，這個分數(Loss)越低就代表預測的結果與真實資料越接近，代表模組較為優良，反之分數(Loss)高就代表模組並不完善。在做分類時常會使用 Cross Entropy²³當作 Loss Function²⁴。會使用 Cross Entropy 而不是常見的平方差公式主要是因為 Cross Entropy 在模組預測與真實資料相差很大時，Cross Entropy 能在被微分後擁有較大的斜率²⁵，有利於訓練，而平方差公式在同樣情況下則呈現平緩，不利於訓練，可參考 Fig. 3-6。此外 Loss Function 必須能被微分，才能夠利用 Gradient Descent 的方法找出最符合真實狀況的模組。此外依據狀況不同，也可以改用其他的 Loss Function 或打造自己的 Loss Function。

$$-\sum_{c=1}^M y_{o,c} \ln(p_{o,c}) \quad (3.6)$$

M = 類別數

y = 真實資料屬於某個 class

p = 模組輸出的數字

²² 李宏毅. 2016g. ML Lecture 11: Why Deep? YouTube.

<https://www.youtube.com/watch?v=XsC9byQkUH8>. (9:35-18:58)

²³ ML-Glossary. *Loss Functions* 2017 [cited. Available from https://ml-cheatsheet.readthedocs.io/en/latest/loss_functions.html].

²⁴ 李宏毅. 2017a. ML Lecture 5: Logistic Regression. YouTube.

<https://www.youtube.com/watch?v=hSXFuypLukA>. (3:53-14:56)

²⁵ Glorot, X., and Y. Bengio. 2010. Understanding the difficulty of training deep feedforward neural networks. Paper read at Proceedings of the thirteenth international conference on artificial intelligence and statistics.

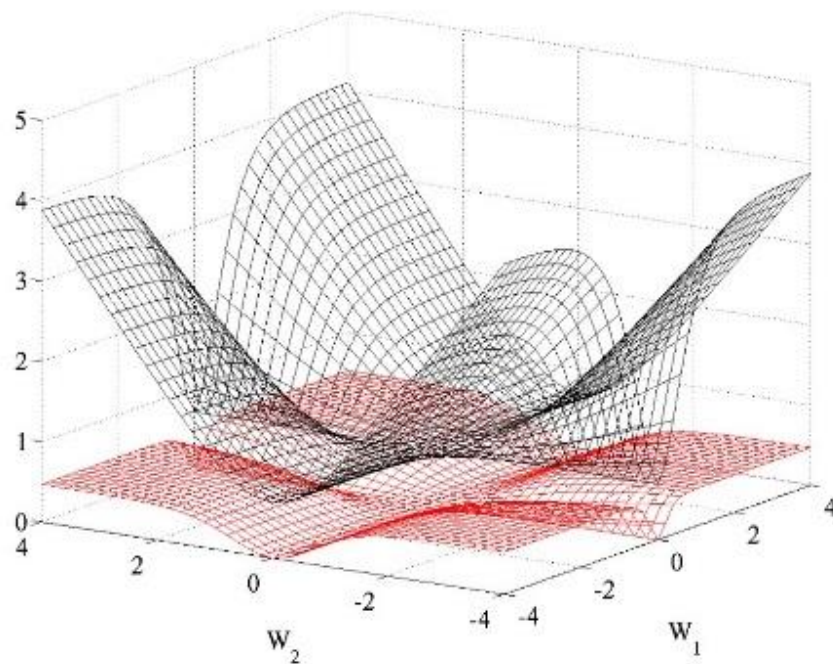


Fig. 3-6 Loss 值分布圖，上層為 Cross Entropy，下層為平方差公式²⁵

第五節 Gradient Descent

想像模型中每一個權重(weight)都代表空間中的一軸²⁶，把所有權重帶入 Loss Function 中形成一個高低起伏不斷的大空間，如 Fig. 3-6 中所描繪，波浪上的每一點都是一組權重算出來的 Loss，而最好的模組擁有最低的 Loss，也就是整個波浪中最低點的位置。若要算出全部權重組合的 Loss 會消耗過多的資源，於是使用 Gradient Descent 來找出答案。

想像在 Loss 組成的波浪中隨機抽選一個點，朝著該點斜率的反方向走一小步，再從下一點的斜率反方向再走一小步，漸漸地朝向最低點邁進，最後會抵達斜率為 0 的最低點。而要得到此斜率需要把 Loss Function 對每一個權重做偏微分，得到的值組成一個向量就叫做梯度(Gradient)，可用符號 ∇ 表示。而為了要求得最低值，需要將原本的權重減去 Gradient，才會朝最低值前進。但直接減去 Gradient 可能會離

²⁶ . 李宏毅. 2016a. ML Lecture 1: Regression - Case Study. YouTube. <https://www.youtube.com/watch?v=fegAeph9UaA>. (18:59-38:14)



原先的點差距太遠而非像最低點前進，於是在減 Gradient 時會乘上一個數來限制 Gradient 的步伐長度，這個數稱之為 Learning Rate，可用符號 η 表示。以上步驟可用公式(3.7)²⁷表示。

$$w^{(T+1)} = w^{(T)} - \eta \nabla \text{Loss}(w^{(T)}) \quad (3.7)$$

除了最基礎的 Gradient Descent 外，他還有許多變形，如一次只使用一筆資料的 Stochastic Gradient Descent²⁸、能夠處理各不同散佈的自變數的 Adagrad，結合 Adagrad 並加入動量概念的 Adam²⁹，也是本論文中所使用的方法。

第六節 Backpropagation

在 Deep Learning model 中³⁰，要完成一次的權重更新，需要幫每一個節點(node)中每一個權重都算一次偏微分，其計算量過度龐大，用普通的微分方法算 Gradient 十分困難，所以要使用 Backpropagation 來計算 Gradient。換句話說 Backpropagation 並不是指一種獨立於 Gradient Descent 外的演算法，而是指 Backpropagation 就是計算 Gradient Descent 的手段。

在開始介紹 Backpropagation 前，先定義五個式子，式子(3.8)表示資料輸入到一個節點時經過各權重加權的結果，式子(3.9)代表把加權的結果輸入到 Activation Function 之中。式子(3.10)代表 Output Layer 要使用的 Softmax Function。式子(3.11)代表要使用 Cross Entropy 來當作 Loss Function，且代表使用單一個 Training Data 所計算的 Loss。式子(3.12)代表所有 Training data 算出來的 Loss 加總的結果。

$$z = \sum_{i=1}^n w_i x_i + b \quad (3.8)$$

²⁷ Bishop, C. M. 2006. *Pattern recognition and machine learning*: springer. (pp.239-240)


²⁸ 李宏毅. 2016c. ML Lecture 3-1: Gradient Descent. YouTube.

<https://www.youtube.com/watch?v=yKKNr-QKz2Q>.

²⁹ ———. 2016f. ML Lecture 9-1: Tips for Training DNN. YouTube. (35:50-54:46)

³⁰ ———. 2016e. ML Lecture 7: Backpropagation. YouTube.

<https://www.youtube.com/watch?v=ibJpTrp5mcE>.



$$a(z) = \max(0, z) \quad (3.9)$$

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.10)$$

$$C(\sigma) = -\sum_{i=1}^M y_i \ln(\sigma(\vec{z})_i) \quad (3.11)$$

$$\text{Loss}(\sigma) = -\sum_{i=1}^S C^i(\sigma) \quad (3.12)$$

若要計算每個權重的偏微分，則需要對 Loss Function 做偏微分，於是有式子 (3.13)。

$$\frac{\partial \text{Loss}(\sigma)}{\partial w} = \frac{\partial \sum_{i=1}^S C^i(\sigma)}{\partial w} \quad (3.13)$$

於是我們可以利用分開計算各個 Training Data 的 Cross Entropy 來計算整體的 Loss，並藉由微分連鎖律，我們擁有以下的式子(3.14):

$$\frac{\partial C}{\partial w} = \frac{\partial z}{\partial w} \frac{\partial C}{\partial z} \quad (3.14)$$

w 對 z 做偏微分很容易計算，就是與該權重相乘的自變數 x(或是從上一層節點傳來的變數)。而 z 對 C 的偏微分則可以藉由微分連鎖律拆成以下式子(3.15):

$$\frac{\partial C}{\partial z} = \frac{\partial a}{\partial z} \frac{\partial C}{\partial a} \quad (3.15)$$

z 對 a 的偏微分一樣容易計算，z 對 ReLU 的微分值在小於 0 時為 0，大於等於 0 時則為 1。而 z 對 C 的偏微分利用微分連鎖律分成以下式子(3.16)³¹:

$$\frac{\partial C}{\partial a} = \sum_{i=1}^p \frac{\partial z^i}{\partial a} \frac{\partial C}{\partial z^i} \quad (3.16)$$

由於 a 對 C 的影響在於 a 會作為下一層節點的自變數而被帶入下一層的 z 進而一算到 C，所以 a 對 C 的偏微分可以看成 a 對下一層所有節點的 z 做偏微分((3.16)中

³¹ Hoskiss. 2020. [機器學習] Backpropagation with Softmax / Cross Entropy 2019 [cited December 2 2020]. Available from <https://medium.com/hoskiss-stand/backpropagation-with-softmax-cross-entropy-d60983b7b245>.

的 p 代表下一層所擁有的節點數)，乘上下一層的所有 z 對 C 做偏微分。而計算 a 對下一層所有節點的 z 的偏微分很簡單，就是節點連結到下一層所有節點的權重 w 。而 z 對 C 的偏微分則又會回到式子(3.15)，這樣不斷的連鎖後，會達到 Output Layer，而 Output Layer 的微分式如下：(3.17):

$$\frac{\partial C}{\partial z} = \frac{\partial a}{\partial z} \frac{\partial C}{\partial a} \quad (3.17)$$

以上的式子中 z 對 a 的偏微分依然是權重 w ，但 a 對 C 的微分經過 Softmax Function 簡化後會變為以下的式子(3.18) ³¹:

$$\frac{\partial C}{\partial a} = \sigma(\bar{z})_i - y_i \quad (3.18)$$

a 對 C 的偏微分精簡化後為經過 Softmax 計算後的 z 減去真實資料的分類 y 。於是 Output Layer 的 Gradient 被計算出來，依據微分連鎖率可算出上一層所有節點的 Gradient，一路算回最上層的節點。這樣從 Output Layer 向後算的動作我們稱之為 Backpropagation。

第七節 小結

這一章介紹 Deep Learning model 的組成架構，如何利用 Loss Function 評估模型的，以及如何利用 Backpropagation 實作 Gradient Descent。幸運的是以上這些方法都已經預先寫再 python 的 PyTorch 套件之中，利用 PyTorch 套件能夠直接使用以上的各項功能來架構與計算 Deep Learning model，讓訓練模型的進入門檻降低。



第五章 研究方法

本次研究是利用台灣經濟新報 TEJ+ 的資料，並訓練一組深度學習模型來預測下一年可能發生審計失敗的查核案件，本章節介紹所使用的應變數、自變數、模型架構與訓練方法。

第一節 資料整理

使用的資料皆是從台灣經濟新報 TEJ+ 中取得，使用上市加上櫃，非金電(不含 TDR)加電子產業(不含 TDR)範圍中的資料。從 TEJ 審計品質分析資料庫向下的任期及經驗、客戶重要性、產業專家以及 IFRS 以合併為主簡表(單季)-全產業向下的資產負債表、損益表、權益變動表、現金流量表中全部欄位另加上裁決應計數、會計師與會計師事務所垂直與水平傳染效果作為本次使用的自變數。並以 TEJ 審計品質分析資料庫向下的重編彙整資料庫中重編原因欄位為轉投資相關、會計估計及評價、損益期間歸屬、虛增(漏列)交易、所得稅及租賃會計、重大重分類/CPA 更新意見的資料作為應變數。期間為 2006 年至 2019 年，包含季報與年報。

一、 審計失敗

審計失敗是本次研究所要預測的目標，並使用財務報表重編來代表審計失敗。在台灣經濟新報 TEJ+ 中 TEJ 審計品質資料庫的衡量變數-重新彙整資料庫中，提供各年度所有財務報表重編的資料與其發生原因。由於審計失敗代表會計師出具不適當的查核意見而產生重編，而非因會計原則變動而產生重編，因此重編原因為會計原則變動的重編案件從應變數中剔除。所使用的重編原因如 Tabel 1 所示：

Tabel 1 審計失敗所使用的重編原因

重編大類別代碼	重編原因大類別
01	轉投資相關
02	會計估計及評價
03	損益期間歸屬
04	虛增(漏列)交易

05	所得稅及租賃會計
07	重大重分類/CPA 更新意見



二、 裁決性應計數

裁決性應計數為模型的自變數之一。Kothari et al. (2005)在其論文中提到³²
³³Dechow et al. (1995)所提出的 modified-Jones model 是最能夠詮釋裁決性應計數的
 模型，而此模型與原本的 Jones model 差別在於添加應收帳款年度變動作為盈餘操
 作的變數之一。而 Kothari et al.則在公式中加入常數項(α)與資產報酬率(ROA)，這
 是為了減少因忽略公司大小而造成的變異數不一致的問題。其公式如(4.1)

$$\frac{TA_{it}}{Asset_{it-1}} = \alpha + \beta_0 \frac{1}{Asset_{it-1}} + \beta_1 \frac{\Delta REV_{it} - \Delta AR_{it}}{Asset_{it-1}} + \beta_2 \frac{PPE_{it}}{Asset_{it-1}} + \beta_3 \frac{ROA_{it}}{Asset_{it-1}} + \varepsilon_{it}$$

(4.1)

變數如下：

1. 總應計數(TA_{it}) = (流動資產年度變動-現金與約當現金年度變動-流動負債年度變動+一年內到期長期負債年度變動-折舊-攤銷)/去年度資產總額
2. 資產($Asset_{it-1}$) = 去年度資產總額
3. 營業收入變動(ΔREV_{it}) = 今年度營業收入淨額-去年度營業收入淨額
4. 應收帳款變動(ΔAR_{it}) = 今年度應收帳款-去年度應收帳款
5. 不動產、廠房與設備(PPE_{it}) = 今年度不動產、廠房與設備
6. 資產報酬率(ROA_{it}) = 此處使用稅後息前的今年度資產報酬率
7. 常數項(α)

為了不減少訓練資料，計算公式的係數時採用當年度同產業的資料作回歸。依照資料中的報表的年、月以及台灣證券交易所 TSE 產業代碼將資料分群，並對各群中的資料分別做線性回歸並用其參數預測各筆資料應有的總應計數，再以各資

³² S.P. Kothari, Andrew J. Leone, Charles E. Wasley. (2005). Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, 39(1), 163-197.

³³ 蔡孟瑾. (2015). 審計失敗之傳染效果-以台灣為例. 臺灣大學會計學研究所學位論文, 1-48.



料真實的總預計數減去預計的總預計數得到裁決性應計數。

三、 審計失敗傳染效果

審計失敗傳染效果為模型的自變數之一。依照 Li et al. (2015)⁴ 的研究，審計失敗的傳染效果可分為垂直傳染與水平傳染，並又可區分為會計師層級與事務所層級。在訓練模型時利用虛擬變數(dummy variable)來表符合被傳染的條件。水平傳染為了要模擬真實預測時無法取得當年度審計失敗資料的狀況，而設為若前一年同會計師或事務所執行的查核案件出現審計失敗，則本年度查核案件的被傳染可能設為 1。垂直傳染則分為五年內曾經發生審計失敗與以往曾經發生審計失敗，又向下細分為是同公司的查核案件與不限同公司查核案件兩種。所有變數如 Tabel 2 所示：

Tabel 2 審計失敗傳染效果應變數

變數	定義
會計師水平傳染	若查核案件的執行會計師在去年執行的查核案件中出現審計失敗，標示為 1
事務所水平傳染	若查核案件的執行事務所在去年執行的查核案件中出現審計失敗，標示為 1
會計師垂直傳染不同公司(無年限)	若查核案件的執行會計師在過去執行的查核案件中出現審計失敗，標示為 1
會計師垂直傳染同公司(無年限)	若查核案件的執行會計師在過去執行的同公司查核案件中出現審計失敗，標示為 1
會計師垂直傳染五年內不同公司	若查核案件的執行會計師在過去五年內執行的查核案件中出現審計失敗，標示為 1
會計師垂直傳染五年內同公司	若查核案件的執行會計師在過去五年內執行的同公司查核案件中出現審計失敗，標示為 1

事務所垂直傳染不同公司(無限年)	若查核案件的執行事務所在過去執行的查核案件中出現審計失敗，標示為 1
事務所垂直傳染同公司(無限年)	若查核案件的執行事務所在過去執行的同公司查核案件中出現審計失敗，標示為 1
事務所垂直傳染五年內不同公司	若查核案件的執行事務所在過去五年內執行的查核案件中出現審計失敗，標示為 1
事務所垂直傳染五年內同公司	若查核案件的執行事務所在過去五年內執行的同公司查核案件中出現審計失敗，標示為 1

四、 整理結果

其他未經特殊處理的自變數於附錄中說明。除了當年度的資料外，每一筆查核案件都會使用前二年內所有應變數，來達到時間序列的效果。最終每筆查核案件都擁有 5,679 個自變數與 1 個審計失敗應變數。使用上市加上櫃，非金電(不含 TDR)加電子產業(不含 TDR)範圍中的資料。訓練資料年度從 2007 年至 2018 年，測試資料則為 2019 年的資料，詳細如 Tabel 3 所示：

Tabel 3 訓練資料與測試資料

	訓練資料	測試資料
資料量	67,176	6,708
年度	2007~2018	2019
資料範圍	上市+上櫃，非金電(不含 TDR)+ 電子產業(不含 TDR)	上市+上櫃，非金電(不含 TDR)+ 電子產業(不含 TDR)
自變數維度	5,679	5,679
應變數(審計失敗)維度	1	1
審計失敗為 1 的資料量	665	27

審計失敗為 0 的資料量	66,511	6,681
--------------	--------	-------



第二節 模型架構

模型的架構由三種元件組成，ReLU、Drop Out 與 Batch Normalization 組成。

1. ReLU

ReLU 如第三章所述，其公式可參考(3.2)，由一整排的 ReLU 組成的 Hidden Layer。選擇 ReLU 而非 Sigmoid 的原因在於它結構簡單微分容易，計算速度快且較不易產生梯度消失(Gradient Vanishing)的問題³⁴。

2. Dropout

Dropout 擁有減低過度擬合(Overfitting)的效果³⁵，在這次實驗中過度擬合是十分嚴重的問題。Dropout 的作法是在每次更新參數時把模型中一部份的節點拿掉，只訓練剩下的節點，讓模型變得更窄。這會使模型在訓練資料上的表現降低，但由於每次都更換模型的形狀，可想像成是訓練大量不同的模型，再將模型的結果平均，讓原本因為變異程度過大而使模型在測試資料上表現不佳，降低其變異程度而讓預測結果能夠更為精準。


3. Batch Normalization

Batch 是指在訓練時不會一次把所有資料都投入，而會將資料切成需多小組，依序投入，這能夠大幅降低訓練所需的時間。Batch Normalization 是使用 Batch 訓練時，將 Hidden Layer 執行一次標準化，這能夠有效處理 Internal Covariates Shifting 的問題，並可使用較大的 Learning Rate 來加快訓練速度。此外也能防止梯度消失(Gradient Vanishing)、防止過度擬合(Over Fitting)的效果。

本次的模型如 Fig. 4-1 所示，Input Layer 有 5,679 維度的應變數，下一層是

³⁴ 李宏毅. 2016f. ML Lecture 9-1: Tips for Training DNN. YouTube. (17:08-23:46)

³⁵ Ibid.(1:10:29-1:26:02)



2,500 個節點的 ReLU 層，訓練時會隨機 Dropout 百分之五十的節點進行訓練，並執行一次 Batch Normalization，下一層為 1,000 個節點的 ReLU 層訓練時會隨機 Dropout 百分之二十的節點進行訓練，並執行一次 Batch Normalization。下一層為兩個節點的 Linear，並將資料送入 Softmax，最後輸出預測的審計失敗結果，1 代表預測該筆查核案件會出現審計失敗，0 代表預測該筆查核案件不會出現審計失敗。

可以從模型看出此架構並不是非常深，這是因為實驗時發現若使用非常深的模型會導致過度擬合的問題，在訓練資料上可以達到非常高的正確率，但在測試資料中的正確率卻不高，因此加入 Dropout 並使用較淺的模型減低過度擬合。各隱藏層要使用的節點數並沒有硬性規定，可以依當時狀況或隨喜好更改，但最後一層 Linear Layer 需要使用與應變數要分成的類別數一樣，如審計失敗分成發生與未發生兩類，所以使用兩個節點。另外需要注意使用 Pytorch 時，Softmax Function 會包含在 Loss Function 中，在架構模型時不要加入 Softmax Function 避免重複計算，圖中僅為示意用途。

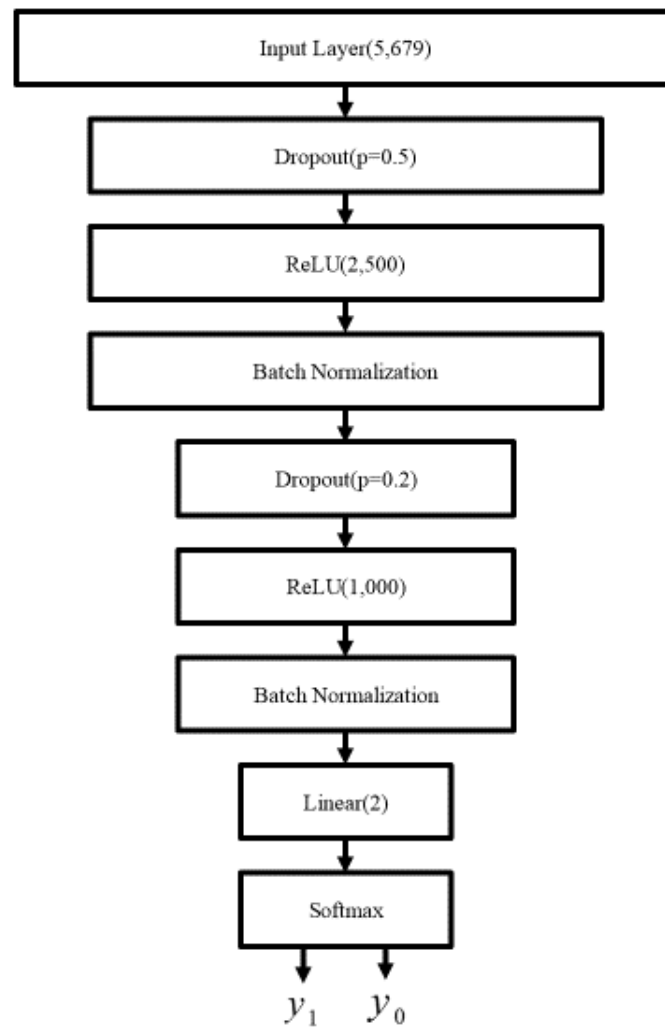



Fig. 4-1 深度模型架構

第三節 訓練模型

模型使用 Python 中的 Pytorch 套件架構，並依照第三章所述，使用 Cross Entropy 為 Loss Function，並使用 Adam 作為計算 Gradient Descent 的演算法，一次訓練 50 組模型，每組模型經過 20 個 Epoch 的訓練(使用全部訓練資料訓練一次為 1 個 Epoch)。本次實驗所使用的設備如 Tabel 4 所示：

Tabel 4 實驗設備與軟體

硬體/軟體	規格/版本
-------	-------



Python	3.6.8
Pytorch(Python 套件)	1.6.0
scikit-learn(Python 套件)	0.23.2.
作業系統	Windows10
CPU	Intel Core i5-9600K CPU @ 3.70GHz
RAM	XPG SPECTRIX D41 DDR4 3200 8G*2
GPU	NVIDIA GeForce GTX 1660
主機板	Gigabyte Z390 AORUS MASTER-CF
記憶體	ADATA SX8200PNP (SSD)

一、 資料清洗

在進行訓練前，需要將資料整理成可訓練的狀態。首先將類別類型的資料改以虛擬變數(dummy variable)表示，經處理的應變數有：簽證意見類型、繼續經營假設是否有疑慮、是否為大型事務所、會計師 1、會計師 2、事務所代碼、產業名稱。接著將非以虛擬變數表示的自變數標準化，標準化在訓練深度學習時十分重要，可以增加訓練的效率，因為標準化能讓各自變數對模型的影響拉近，當計算梯度時，參數會依 Loss Function 法線向量反向更迭，若各自變數對模型的影響相近，法線向量的反向會指向 Loss 的最低點，讓訓練更準確快速³⁶。最後將資料中所有空值都用 0 替代，這是為了要保持訓練的資料數量，且在真實預測的狀況億筆資料很難擁有所有必需的應變數，因此補 0 較直接刪除該資料更為合理。

二、 訓練資料抽選

從 Tabel 3 中可以觀察到資料集有很嚴重的資料不平等(Imbalance Dataset)的問題，出現審計失敗的查核案件在訓練資料中僅有 665 筆，僅占訓練資料 0.99%。這

³⁶ 李宏毅(2016, October 7). ML Lecture 3-1: Gradient Descent: Tips for Training DNN (36:57-42:26). Retrieved December 15, 2020, from <https://www.youtube.com/watch?v=yKKNr-QKz2Q>

樣的資料筆會使模型在訓練時僅針對非審計失敗的資料更新參數，雖然這能讓整體模型的正確率達到最高，但卻無法得到預測出審計失敗的效果，因為模型會將所有測試資料預測為非審計失敗，因此需要新的一組平衡的資料集才能更好的訓練。製造平衡資料集的方法十分直觀，將發生審計失敗的資料複製到跟非審計失敗的資料一樣多，但這會讓資料集過於龐大，訓練時間太長而難以訓練。於是我使用 ufoym (2020)所提供的 Imbalanced Dataset Sampler³⁷，這個方法能夠隨機抽選一定數量的非審計失敗的訓練資料，並複製相同數量的審計失敗資料並將兩者混合在一起，創造平衡的資料集。新的訓練資料為 15,000 筆非審計失敗與 15,000 筆審計失敗，並會隨著訓練新的模組改變其組成。

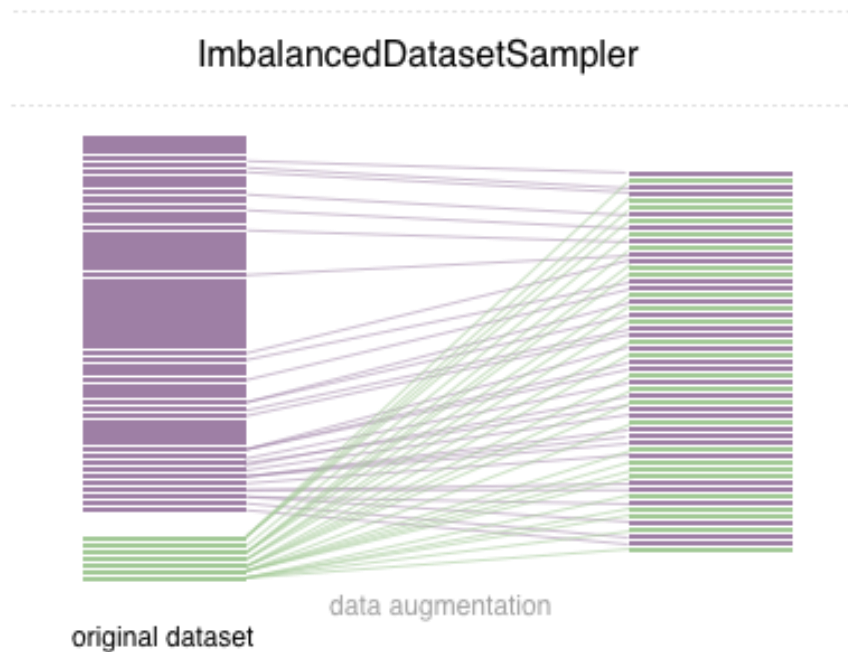


Fig. 4-2 抽選並創造平衡資料集(取自於 ufoym 的 Github, 2020)³⁷

三、 半監督式學習

如果僅依靠第三章所述之監督式學習，預測效果仍人沒有預期中的高，在測試資料的 27 筆審計失敗中，依靠監督式學習僅能預測出 23 筆審計失敗，佔總體審

³⁷ ufoym. 2020. *Imbalanced Dataset Sampler*, October 9 2020 [cited December 15 2020]. Available from <https://github.com/ufoym/imbalanced-dataset-sampler>.

計失敗的 85%。為了提升預測能力而使用半監督式學習。半監督式學習的概念為，先訓練一組模型後，利用模型先預測一次測試資料的結果，並依照特定方法來評斷這次預測結果的好壞，再將結果重新修正原先的模型，讓模型在測試資料上的表現越來越好。需要注意不能直接使用測試資料的答案，以免模型直接把答案背起來。本次實驗使用 Information Entropy Loss 與 Pseudo-label 兩種方法。

(一) Information Entropy Loss

Information Entropy Loss³⁸的概念為當測試資料被預測時，模型會提供一筆查核案件是屬於審計失敗或非審計失敗的機率，而這兩個機率差距很大，代表模型對預測的結果很有把握，若機率十分接近則代表模型不能確定要將資料分成哪類。我們需要鼓勵模型產出有把握的答案而減少不確定性的答案，能夠藉由修改 Loss Function 來達到這個效果。在公式(4.2)中，若各類別的機率相差越大(k 表示有幾種類別, y_m 代表是某個類別的機率)，結果會越接近 0，而機率相近時則會大於 0。將這個結果加到原本的 Cross Entropy Loss Function ($C(y, y)$)，並乘上調整值 λ 來調整測試資料對整體 Loss 的影響，我將 λ 設為 0.05，公式如(4.3)。將 Loss Function(4.3)微分可得到 Gradient 來調整參數，在此使用 bravotty (2020)³⁹ 於 Github 所提供的微分公式。需要注意 Cross Entropy 使用訓練資料，Information Entropy Loss 則只使用測試資料。

$$E(y) = - \sum_{m=1}^k y_m \ln(y_m) \quad (4.2)$$

$$Loss = \sum_{x^r} C(y^r, y^r) + \lambda \sum_{x^t} E(y^t) \quad (4.3)$$

³⁸ 李宏毅. 2016g. ML Lecture 11: Why Deep? YouTube.

<https://www.youtube.com/watch?v=XsC9byQkUH8>. (25:52-30:41)

³⁹ bravotty. 2020. *Information-entropy-loss-pytorch*, March 31 2020 [cited December 15 2020]. Available from https://github.com/bravotty/Information-entropy-loss-pytorch/blob/master/entropy_loss_pytorch.py.



(二) Pseudo-label

Pseudo-label 是更為直覺的方法⁴⁰，使用模型預測測試資料後，將模型認為是審計失敗的測試資料與訓練資料合併後再重新抽選成新的訓練資料訓練，共執行 49 次，產生 50 組模組。這個方法能夠讓模型更熟悉測試資料而提高準確率。

Fig. 4-3 為未使用 Pseudo-label 的 0 號模型，可以看出在測試資料的 27 筆審計失敗中僅能預測出 21 筆，而此模型認為是審計失敗的查核案件共有 1,847 筆 (21+1,826)，這些資料會被併入訓練資料中訓練下一組模型。而 Fig. 4-4 則是第 50 組模型，經過 49 次合併訓練資料，可以看見在 27 筆審計失敗中已可預測出 26 筆，可抓出 96% 的審計失敗。

The Confusion Matrix of Test data			
	1 predicted	0 predicted	accuracy %
1 actual	21.000000	6.000000	77.777778
0 actual	1826.000000	4855.000000	72.668762
accuracy %	1.136978	99.856026	0.000000

Fig. 4-3 未使用 Pseudo-label 第 20 Epoch 時測試資料的混淆矩陣

The Confusion Matrix of Test data			
	1 predicted	0 predicted	accuracy %
1 actual	26.000000	1.000000	96.296296
0 actual	1527.000000	5154.000000	77.144140
accuracy %	1.674179	99.96121	0.000000

Fig. 4-4 使用 Pseudo-label 後第 49 組模組第 20 Epoch 時測試資料的混淆矩陣

四、 訓練過程

如第三章所述，在訓練時藉由 Gradient Descent 尋找 Loss 的最小值，Gradient Descent 使用 Adam 演算法，Loss Function 使用(4.3)。以 1 號模型模型為例，Fig. 4-5 中 Loss 值從第一個 Epoch 的 85.7 下降到第二十個 Epoch 的 13.1，而模型在訓練資料上的正確率從 88.8% 上升至 98.8%，表現良好，然而在測試資料上卻在

⁴⁰ 李宏毅. 2016h. ML Lecture 12: Semi-supervised. YouTube. https://www.youtube.com/watch?v=fX_guE7JNnY. (18:54-25:42)

80%~87%之間移動，正確率低於訓練資料約 15%，可以觀察出有輕微的過度擬合 (Overfitting)問題。



Fig. 4-5 1 號模型 0 至 19 Epoch 的 Loss 值、訓練資料正確率與測試資料正確率

若觀察角度改成 50 組模型在測試資料上的表現(皆為第 19 個 Epoch)，如 Fig. 4-6 0 號模型至 49 號模型在測試質量上的表現，可以觀察到模型的正確率在 80% 附近浮動，然而 Sensitivity 卻隨著模組數不斷上升，從 77.8% 上升至 96.3%，Sensitivity 亦稱為 True Positive Rate，代表有多少真正的審計失敗能夠被模型預測出來。在 0 號模組中，模型可從測試資料 27 筆審計失敗中預測出 24 筆，而到了 49 號模組，模型則可預測出 26 筆，幾乎全部都能預測出來，這是因為使用 Pseudo-label 讓模型更能夠熟悉測試資料的原因。另一方面，可從圖中觀察到模型的 Precision(positive predictive value)並不高，僅從 1.13% 上升至 1.67%，這代表在 49 號模組所預測的審計失敗(1,553 筆)中，僅有 26 筆資料是真正的審計失敗，1,527 筆資料都是誤報，也使得模型的使用價值不高。

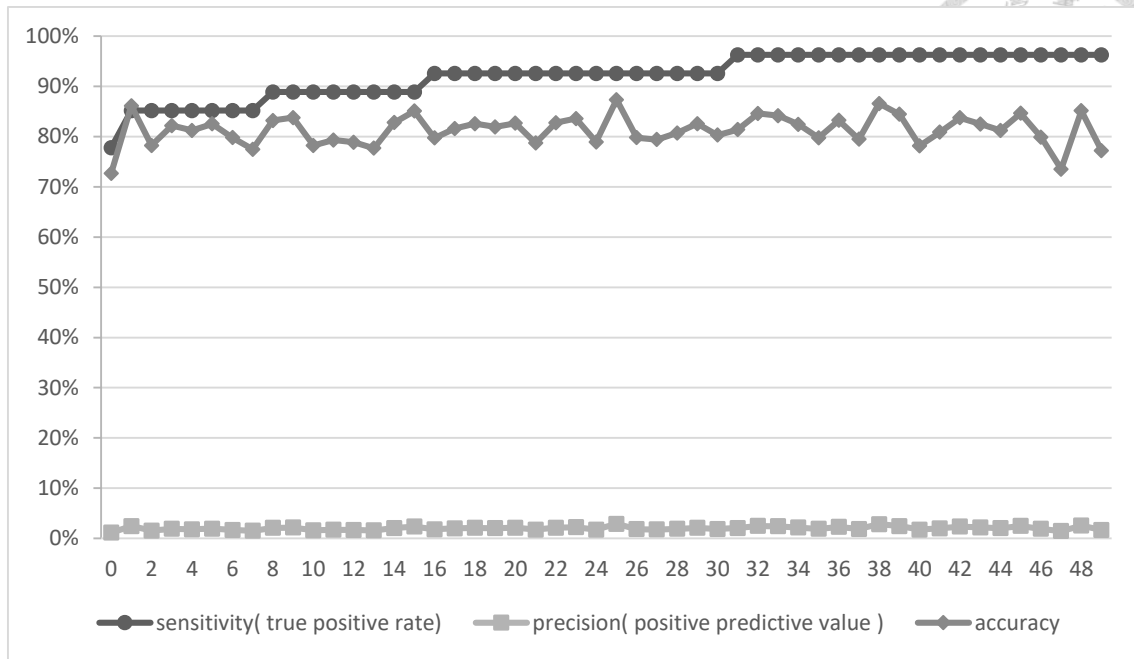


Fig. 4-6 0 號模型至 49 號模型在測試質量上的表現

五、 Voting

Precision 低落的原因為變異程度太高，使用大型模型時需要特別注意這個問題⁴¹，雖然模型能夠非常精準的找出目標值，也就是指 Bias 很小，如 27 筆審計失敗可以抓出 26 筆，但結果會非常分散，雖然能抓出目標，但也會產生大量的誤報，這時候就可以使用 Voting 的技巧⁴²。Voting 十分直觀，複數模型的情況下，將每個模型所產生的答案進行投票，看所有模型對同一筆資料的預測結果，票數較多的結果則認為是答案。舉例來說，若我將最後 24 組模型(因為 Sensitivity 較高)進行投票，設定 24 組模型中有 24 組認為意見查核案件是審計失敗的時候，才將其認定為審計失敗，結果如 Fig. 4-7。可以看見 Precision 從原先的 1.67% 提升至 20.16%，每 5 筆預測結果中就有一筆是真的審計失敗，且 Sensitivity 仍可保持在 92.59%，27 筆審計失敗能抓出其中 25 筆。Voting 的原理在於利用交叉比對，剔除變異數產

⁴¹ ——, 2016b. ML Lecture 2: Where does the error come from?. YouTube.

https://www.youtube.com/watch?v=D_S6y0Jm6dQ. (20:49-22:51)

⁴² ——, 2017b. ML Lecture 22: Ensemble. YouTube.

<https://www.youtube.com/watch?v=tH9FH1DH5n0>. (4:56-18:54)

生的誤報，而只將重複出現的審計失敗的結果保留下來，同 Fig. 4-8 25 號模型至 49 號模型經由不同投票門檻產生的預測表現中可以觀察到，若將投票的門檻從 1 票就通過調到 24 票才通過，正確率與 Precision 都逐漸提高，並指犧牲 3.7% 的 Sensitivity，表示這個模組對真實審計案件的掌握度高，只需利用重複比對來除去誤報就能提升準確度。Voting 的好處在於只要模型夠多就能夠增加 Precision，若持續訓練出更多的模組還可以達到比 20.16% 更高的數值，缺點在於十分耗費時間，50 組模型花費約 36 小時訓練，若要縮短時間則需要更好的演算法或價格更高的設備。

The Confusion Matrix of Test data

	1 predicted	0 predicted	accuracy %
1 actual	25.00000	2.00000	92.592593
0 actual	99.00000	6582.00000	98.518186
accuracy %	20.16129	99.969623	98.494335

Fig. 4-7 25 號模型至 49 號模型 Voting 結果




Fig. 4-8 25 號模型至 49 號模型經由不同投票門檻產生的預測表現

第六章 研究結果



經由第四章所陳述的訓練方法訓練出一組能預測審計失敗的模型，為了比較此模型的優劣，以 Cristina De Fuentes & Rubén Porcuna⁴³ 所提出的邏輯斯回歸作為對照組，比較兩者間在預測審計失敗時所表現的正確率、Sensitivity 與 Precision。此實驗使用資料範圍為 TEJ 資料庫中上是與上櫃公司，非金電加上電子產業並排除 TDR 的公司，2007 年至 2018 年為訓練資料，2019 年則為測試資料。

第一節 實驗組

實驗組是使用 Pytorch 架構的 Fully Connected Feedforward Network，其架構請參閱 Fig. 4-1，並使用半監督式學習與 Voting 的方式強化其預測的精準度，Fig. 5-1 為模組於 2019 年資料上的表現。模組正確率為 98.49%，Sensitivity 達到 92.59%，27 筆審計失敗中成功找出 25 筆，Precision 則為 20.16%，124 筆預測為審計失敗的案件當中僅有 25 筆為真實審計失敗。

The Confusion Matrix of Test data

	1 predicted	0 predicted	accuracy %
1 actual	25.00000	2.00000	92.592593
0 actual	99.00000	6582.00000	98.518186
accuracy %	20.16129	99.969623	98.494335

Fig. 5-1 深度學習模型實驗結果

第二節 對照組

De Fuentes and Porcuna (2019)⁴³ 依據西班牙會計與審計學會 (Instituto de Contabilidad y Auditoría de Cuentas1 ,ICAC) 所提供 2002 至 2013 年的資料，分析審計失敗發生的原因並預測其發生，以解決歐盟中有關是否應該限制會計師任期的爭議。研究中發現，當企業正經歷財務困境、會計師對正向盈餘管理過於寬容以及

⁴³ De Fuentes, C., and R. Porcuna. 2019. Predicting audit failure: evidence from auditing enforcement releases. *Spanish Journal of Finance and Accounting/Revista Española de Financiación y Contabilidad* 48 (3):274-305.

以個人身分而非事務所查核皆會增加審計失敗發生的可能性，此外若查核規模大於事務所本身的公司時，審計失敗發生的可能性降低，而會計師任期與發生可能性呈正向關係，但此現象僅存在於個人(非事務所)查核案件。其公式如(5.1)，自變數與應變數如 Tabel 5，使用 Logistic Regression，其結果如 Fig. 5-2。

$$\begin{aligned} \Pr(AF = 1) = & \alpha + \beta_1 Client_Size_{it} + \beta_2 Client_OrdLoss_{it-1} + \\ & \beta_3 Client_Zmi_{it} + \beta_4 Client_DA_{it} + \beta_5 Aud_Type_{it} + \\ & \beta_6 Tenure_3_7_{it} + \beta_7 Tenure_7_{it} + \beta_8 Aud_Op_{it} + \varepsilon_{it} \end{aligned} \quad (5.1)^{44}$$


Tabel 5 對照組使用的自變數及應變數

自變數/應變數	意義
<i>AF</i>	1 代表法定會計師於 t 年度的財報遭到懲罰，0 則相反
<i>Client_Size</i>	客戶總資產取自然對數
<i>Client_OrdLoss</i>	1 代表公司於 t-1 年度有虧損
<i>Client_Zmi</i>	利用 probit's distribution function 求出的 Zmijewski 指數 ⁴⁵
<i>Client_DA</i>	裁決性應計數，在此使用未加絕對值得應計數
<i>Aud_Type</i>	1 代表受罰的是事務所，0 代表受罰的是獨立會計師，由於會計師法規定台灣會計師都必須加入或設立事務所 ⁴⁶ ，因此這項並不使用。
<i>Tenure_3_7</i>	1 代表會計師任期介於 3 年至 7 年之間，使用主查會計師的任期
<i>Tenure_7</i>	1 代表會計師任期大於 7 年，使用主查會計師的任期
<i>Aud_Op</i>	1 代表查核意見為無保留意見，0 則為其他

⁴⁴ 使用 Tabel 6 的公式

⁴⁵ Zmijewski, M. E. 1984. Methodological issues related to the estimation of financial distress prediction models. *Journal of accounting research*:59-82.

⁴⁶ 會計師法第 8 條:領有會計師證書者，應設立或加入會計師事務所



α	常數項
ε	殘差

Dep. Variable:	AF	No. Observations:	62878
Model:	Logit	Df Residuals:	62870
Method:	MLE	Df Model:	7
Date:	Sat, 19 Dec 2020	Pseudo R-squ.:	0.01154
Time:	17:41:43	Log-Likelihood:	-3408.8
converged:	True	LL-Null:	-3448.6
Covariance Type:	nonrobust	LLR p-value:	1.668e-14

	coef	std err	z	P> z	[0.025	0.975]
Client_Size	0.0308	0.028	1.108	0.268	-0.024	0.085
Client_OrdLoss	0.3333	0.092	3.628	0.000	0.153	0.513
Client_Zmi	-0.1435	0.046	-3.121	0.002	-0.234	-0.053
Client_DA	-0.9803	0.389	-2.520	0.012	-1.743	-0.218
Tenure_3_7	-0.1778	0.082	-2.160	0.031	-0.339	-0.016
Tenure_7	-0.9477	0.582	-1.627	0.104	-2.089	0.194
Aud_Op	-0.3962	0.083	-4.802	0.000	-0.558	-0.235
constant	-4.3745	0.494	-8.850	0.000	-5.343	-3.406

Fig. 5-2 對照組 Logit Regression Result

從 Fig. 5-2 中可以發現自變數中 Client_OrdLoss、Client_Zmi、Client_DA、Tenure_3_7、Aud_Op 皆為顯著，可以觀察出以台灣的查核案件來說當企業經歷財務困境、企業信用風險、裁決性應計數、會計師的任期及查核意見皆會影響讓審計失敗出現的可能性。然而這個模型的解釋能力並不高，Pseudo R-square 僅有 0.00154，而此模型於 Receiver Operating Characteristic curve(ROC)上的表現也不佳，曲線下的面積(AUC)僅有 0.655，曲線甚至在特定區段還比未使用模型還要低。此外從 Fig. 5-3 中可見，若將深度學習模組在測試資量上的表現繪於圖上，可發現表現遠好於對照組，向畫面左上角靠近(由於深度學習模型並不是單純使用閾值進行預測，因此難以繪製 ROC curve，僅能存在一個點)。




Fig. 5-3 對照組 ROC curve

第三節 實驗組與對照組比較

比較兩組模型需要使用 Precision-Recall Plot (PR Plot)。Precision-Recall Plot 以 Precision 與 Recall 作為兩軸，Recall 就是 Sensitivity，又稱為 True Positive Rate，其計算方法為真實答案為 1 之中，成功預測為 1 的比例，如 2019 真實發生審計失敗中被模組成功預測的比例。而 Precision 又可稱為 Positive Predictive Value，代表預測為 1 的資料，真實答案為 1 的比例，如模組對 2019 年審計失敗的預測當中，真實為審計失敗的查核案件所佔的比例。當我們處理二元分類的問題，且資料分部非常不平均時 (Imbalanced Datasets)，我們能夠從 Precision-Recall Plot 中得到比 Receiver Operating Characteristic curve 更多的資訊⁴⁷。

⁴⁷ Saito, T., and M. Rehmsmeier. 2015. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS one* 10 (3):e0118432.

實驗組與對照組的 Precision-Recall Plot 如 Fig. 5-4 所示，點為深度學習模組，實線為對照組，虛線則為未使用任何模組。由於深度學習模組並不是單純依照閾值 (Threshold) 產生預測結果，因此無法畫出曲線，僅能為畫面上的一個點。於圖中能夠發現對照組表現非常差，幾乎與無模組重合，而曲線最左方也是因為 0 除以 0 造成 Precision 的極大值。此曲線代表不論使用任何閾值，雖然能讓 Recall(Sensitivity) 提高，但預測結果中夾雜大量誤報，讓模型幾乎不堪使用，與隨機分類的效果差不多。而深度學習模組在確保 Recall(Sensitivity) 為 0.93 的情況下，Precision 能保持在 0.2，代表模型預測的結果之中，五分之一為審計失敗，且囊括全年查核案件中 92.6% 的審計失敗，相較於對照組更有實用性。




Fig. 5-4 實驗組與對照組的 Precision-Recall Plot

以實際結果為例，若要維持 Recall(Sensitivity) 並有較高的 Precision，對照組可以使用 0.009 作為其閾值，預測機率大於 0.009 的查核案件被認作審計失敗，其結果為圖~，Recall(Sensitivity) 為 62.96%，27 筆審計失敗中能抓出 17 筆，Precision 僅有 0.795%，模型認為的審計失敗中誤報的案件共有 2,121 筆，過高的誤報數使得此模型難以被使用，反之深度學習模型誤報數僅有 99 筆，實用性較高。

	1 predicted	0 predicted	accuracy %
1 actual	17.000000	10.000000	62.962963
0 actual	2121.000000	4537.000000	31.856413
accuracy %	0.795136	0.219925	0.000000



Fig. 5-六-5 對照組預測結果(閾值為 0.009)

第四節 模組的優點與缺點

深度學習模組預測雖然高，但仍有一大缺點，深度學習如同一個黑盒子，很難知道模組做預測的依據，若以模組預測結果去評價會計師的查核品質，會計師可能為不服。然而這也是深度學習為何高效，它能夠處理人類無法釐清的因果關係，如影像辨識、聲音辨識等皆因使用深度學習而有重大突破，審計失敗也是同理。雖然有許多論文分析各種自變數對應審計失敗的影響，但實際用來預測審計失敗時效果不彰，無法用於實務操作，深度學習卻能藉由學習掌握各自變數與審計失敗間的因果關係，並可於實務上使用。深度學習模組的另一個特點是客製化，可以依照現有的資料以及設備隨時調整模型的架構、隱藏層層數、節點數量、Loss Function 等並重新訓練新的模型，於實務使用時，每個使用者擁有的資源都不同，高自由度讓深度學習能被更廣泛的運用。

Tabel 6 模組的優缺點

	深度學習	回歸模型
優點	準確度高 客製化容易	自變數與應變數的關係清楚，易被分析 訓練時間短 設備要求低
缺點	模組龐大，訓練時間長 設備要求高 做預測的依據難以理解，分析困難	準確度低

第七章 結論



第一節 研究結論

本次研究藉由 Pytorch 套件依照 Fully Connected Feedforward Network 架構打造一組深度學習模型用以預測審計失敗，利用台灣經濟新報 TEJ+現有資料與過去已被研究的審計失敗因子做為模型自變數，並使用半監督式學習與 Voting 的方法強化預測結果，於 2019 年測試資料上得到 98.49%正確率，Sensitivity 為 92.59%，Precision 為 20.6%，預測結果與對照組的邏輯斯回歸相比更為精準，能有效地限縮可能產生審計失敗的案件的範圍，增加抽查財務報表時能查到隱含錯誤與舞弊的財務報表的機率上升。

第二節 研究建議

礙於實驗設備與編寫程式的技巧不足，訓練模型相對消耗大量時間，僅訓練 50 組模型，此外是使用最基礎的 Fully Connected Feedforward Network 架構，建議後續研究者可以訓練更多的模組做 voting，精準會提升更多，此外也可以使用其他深度學習架構與 Activation Function，測試哪種架構最適合預測審計失敗。

這次的研究主要目的之一是測試深度學習模型在審計失敗這個問題上能不能被使用，其結果為可行，也希望機器學習能在會計領域上漸漸被廣泛使用，能有效減少人力，獲得事半功倍的效果。

參考資料



- Bishop, C. M. 2006. *Pattern recognition and machine learning*: springer.
- bravotty. 2020. *Information-entropy-loss-pytorch*, March 31 2020 [cited December 15 2020]. Available from https://github.com/bravotty/Information-entropy-loss-pytorch/blob/master/entropy_loss_pytorch.py.
- De Fuentes, C., and R. Porcuna. 2019. Predicting audit failure: evidence from auditing enforcement releases. *Spanish Journal of Finance and Accounting/Revista Española de Financiación y Contabilidad* 48 (3):274-305.
- DeAngelo, L. E. 1981. Auditor size and audit quality. *Journal of accounting and economics* 3 (3):183-199.
- Dechow, P. M., R. G. Sloan, and A. P. Sweeney. 1995. Detecting earnings management. *Accounting review*:193-225.
- Glorot, X., and Y. Bengio. 2010. Understanding the difficulty of training deep feedforward neural networks. Paper read at Proceedings of the thirteenth international conference on artificial intelligence and statistics.
- Hinton, G. E., S. Osindero, and Y.-W. Teh. 2006. A fast learning algorithm for deep belief nets. *Neural computation* 18 (7):1527-1554.
- Hoskiss. 2020. [機器學習] *Backpropagation with Softmax / Cross Entropy* 2019 [cited December 2 2020]. Available from <https://medium.com/hoskiss-stand/backpropagation-with-softmax-cross-entropy-d60983b7b245>.
- Jones, J. J. 1991. Earnings management during import relief investigations. *Journal of accounting research* 29 (2):193-228.
- Kothari, S. P., A. J. Leone, and C. E. Wasley. 2005. Performance matched discretionary accrual measures. *Journal of accounting and economics* 39 (1):163-197.
- Krishnan, G. V. 2003. Audit quality and the pricing of discretionary accruals. *Auditing: A journal of practice & theory* 22 (1):109-126.
- Li, L., B. Qi, G. Tian, and G. Zhang. 2015. The Contagion Effect of Low-Quality Audits along Individual Auditors. Available at SSRN 2478348.
- ML-Glossary. *Loss Functions* 2017 [cited. Available from https://ml-cheatsheet.readthedocs.io/en/latest/loss_functions.html].
- Nielsen, M. *CHAPTER 4 A visual proof that neural nets can compute any function* 2019 [cited. Available from <http://neuralnetworksanddeeplearning.com/chap4>].
- Rumelhart, D. E., G. E. Hinton, and R. J. Williams. 1986. Learning representations by back-propagating errors. *nature* 323 (6088):533-536.
- Saito, T., and M. Rehmsmeier. 2015. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PloS one*

- 10 (3):e0118432.
- ufoym. 2020. *Imbalanced Dataset Sampler*, October 9 2020 [cited December 15 2020]. Available from <https://github.com/ufoym/imbanced-dataset-sampler>.
- Zmijewski, M. E. 1984. Methodological issues related to the estimation of financial distress prediction models. *Journal of accounting research*:59-82.
- 吳琮璿教授. 2001. 審計學--新觀念與本土化. 台北市: 吳琮璿教授.
- 李宏毅. 2016a. ML Lecture 1: Regression - Case Study. YouTube. <https://www.youtube.com/watch?v=fegAeph9UaA>.
- . 2016b. ML Lecture 2: Where does the error come from? . YouTube. https://www.youtube.com/watch?v=D_S6y0Jm6dQ.
- . 2016c. ML Lecture 3-1: Gradient Descent. YouTube. <https://www.youtube.com/watch?v=yKKNr-QKz2Q>.
- . 2016d. ML Lecture 6: Brief Introduction of Deep Learning. YouTube. <https://www.youtube.com/watch?v=Dr-WRIEFefw>.
- . 2016e. ML Lecture 7: Backpropagation. YouTube. <https://www.youtube.com/watch?v=ibJpTrp5mcE>.
- . 2016f. ML Lecture 9-1: Tips for Training DNN. YouTube.
- . 2016g. ML Lecture 11: Why Deep? YouTube. <https://www.youtube.com/watch?v=XsC9byQkUH8>.
- . 2016h. ML Lecture 12: Semi-supervised. YouTube. https://www.youtube.com/watch?v=fX_guE7JNnY.
- . 2017a. ML Lecture 5: Logistic Regression. YouTube. <https://www.youtube.com/watch?v=hSXFuypLukA>.
- . 2017b. ML Lecture 22: Ensemble. YouTube. <https://www.youtube.com/watch?v=tH9FH1DH5n0>.
- 陳怡均. 2008. 簡介美國 PCAOB 對於公開公司會計師之監理. 金融監督管理委員會 2008 [cited October 16 2008]. Available from [https://www.fsc.gov.tw/fckdowndoc?file=%E5%AF%A6%E5%8B%99%E6%96%B0%E7%9F%A5%20\(1\).pdf&flag=doc](https://www.fsc.gov.tw/fckdowndoc?file=%E5%AF%A6%E5%8B%99%E6%96%B0%E7%9F%A5%20(1).pdf&flag=doc).
- 蔡孟瑾. 2015. 審計失敗之傳染效果-以台灣為例. 臺灣大學會計學研究所學位論文:1-48.

附錄



Confusion Matrix

Confusion Matrix 是表現二元分類的一個方法，將真實答案與模型預測結果表現在 2*2 的格子中，四個格子分別為 True Positive、False Negative、False Positive、True Negative。True Positive 與 True Negative 皆代表預測與真實狀況一致，False Negative 代表真實發生的事件並沒有被模型預測出來，為漏報。False Positive 則代表模型預測出的會發生的事件其實並沒有發生，為誤報，可參考 Tabel 7:

Tabel 7 Confusion Matrix

		Predicted Class	
		Class 1	Class 0
Actual Class	Class 1	True Positive(TP)	False Negative(FN)
	Class 0	False Positive(FP)	True Negative(TN)

有幾項計算模型的指標:

1. 正確率: 正確率為模型中預測正確占整體資料的比例。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. Sensitivity: Sensitivity 又可稱作 Recall 或 True Positive Rate，可以用以計算真實發生的案件中有多少比例成功地被模型預測。

$$Sensitivity(Recall) = \frac{TP}{TP + FN}$$



3. Precision: Precision 又可稱作為 Positive Predictive Value，可以用以計算預測會發生的案件中真實發生的比例有多少。

$$Precision = \frac{TP}{TP + FP}$$

4. Fall-out: Fall-out 又可稱為 False Positive Rate，可以檢測真實不會發生的案件中有多少比率是誤報。

$$Fallout = \frac{FP}{FP + TN}$$

Zmijewski (1984) index^{45 43}

對照組中所使用的 Zmijewski 指數從符合下列三個公式的 Probit model 得到:

$$P(B = 1) = P(B^* > 0)$$

$$B^* = \alpha_0 + a_1 ROA_{it} + a_2 FINL_{it} + a_3 LIQ_{it} + \mu_{it}$$

$$P(B^* > 0) = P(-\mu_{it} < \alpha_0 + a_1 ROA_{it} + a_2 FINL_{it} + a_3 LIQ_{it})$$

變數如下所式

$P(\cdot) = (\cdot)$ 的機率

B = 如果公司有財務困難 $B=1$ ，反之為 0

ROA_{it} = Return on Assets

$FINL_{it}$ = 財務槓桿，總負債除總資產

LIQ_{it} = 流動資產除流動負債

μ_{it} = 殘差項

此 Probit mode 需要使用 maximizing the log-likelihood 的方法使 (L^*) 最大化， L^* 如下所示:

$$L^* = \sum_{i=1}^j (B) \ln[\Phi(H)] + \sum_{i=1}^j (1-B) \ln[1 - \Phi(H)]$$

參數如下所示:



Φ = 累積常態分佈

$$H = \alpha_0 + a_1 ROA_{it} + a_2 FINL_{it} + a_1 LIQ_{it}$$

為了估計破產機率 Zmijewski 指數的各項係數由下列 Probit model 中得到:

$$G(z) = \Phi(z) \equiv \int_{-\infty}^z \Phi(v) dv$$

其中 $\Phi(z)$ 為常態機率分布，如下所示

$$\Phi(z) = (2\pi)^{-\frac{1}{2}} e^{-\frac{z^2}{2}}$$

$$z = \alpha_0 + a_1 ROA_{it} + a_2 FINL_{it} + a_1 LIQ_{it}$$

其他參數

其他在模型中使用的參數，僅列出本年度，模型中則使用本年度、上年度及前年度的所有欄位。請注意以下項目是使用虛擬變數(Dummy Variable)的方式呈現: 簽證意見類型、繼續經營假設是否有疑慮、是否為大型事務所、產業名稱、會計師 1、會計師 2。

Tabel 8 其他參數

會計科目/欄位名稱	說明(取自台灣經濟新報 TEJ+)
現金及約當現金	係庫存現金、銀行存款與零星支出之週轉金及隨時可轉換成定額現金且即將到期 而其利率變動對其價值影響甚少之短期且具高度流動性之投資約當現金係指自投資日起三個月內到期之商業本票，銀行承兌匯票等

<p>透過損益按公允價值衡量之金融資產—流動</p>	<p>1.指非屬按攤銷後成本衡量或透過其他綜合損益按公允價值衡量之金融資產。</p> <p>2.屬按攤銷後成本衡量或透過其他綜合損益按公允價值衡量之金融資產，依國際財務報導準則第九號規定可指定為透過損益按公允價值衡量之金融資產。</p> <p>配合 IFRS 9 新增科目：</p> <p>2017Q4（含）以前科目值，由以下原科目（列入停止維護）衍生值。</p> <p>〔透過損益按公允價值衡量之金融資產—流動〕</p> <p>〔以成本衡量之金融資產—流動〕</p>
<p>透過其他綜合損益按公允價值衡量之金融資產—流動</p>	<p>〔IFRS 9〕</p> <p>1.指同時符合下列條件之債務工具投資：</p> <p>(1)發行人係在以收取合約現金流量及出售為目的之經營模式下持有該金融資產。</p> <p>(2)該金融資產之合約條款產生特定日期之現金流量，完全為支付本金及流通在外本金金額之利息。</p> <p>2.指原始認列時作一不可撤銷之選擇，將公允價值變動列報於其他綜合損益之非持有供交易之權益工具投資。</p> <p>〔TW GAAP 34〕</p> <p>係非衍生性金融資產且符合下列條件之一者：</p> <p>1.被指定為備供出售。</p> <p>2.非屬下列金融資產：(1)公平價值變動列入損益之金融資產 (2) 持有至到期日金融資產 (3)以成本衡量之金融資產 (4)無活絡市場之債券投資 (5)應收款。</p> <p>備供出售金融資產應依其流動性區分為流動與非流動，非流動者應改列基金及投資項下之備供出售金融資產-非流動。</p> <p>**此科目為新增科目，係依財會準則 34 號公報將投資依持有目的分類，95 年起適用。</p> <p>配合 IFRS 9 更名科目：原科目名為〔備供出售金融資產—流動〕。</p>
<p>按攤銷後成本衡量之金融資產—流動</p>	<p>1.發行人係在以收取合約現金流量為目的之經營模式下持有該金融資產。</p> <p>2.該金融資產之合約條款產生特定日期之現金流量，完全為支付本金及流通在外本金金額之利息。</p>

	<p>配合 IFRS 9 新增科目：</p> <p>2017Q4 (含) 以前科目值，由以下原科目 (列入停止維護) 衍生值。</p> <p>[無活絡市場之債券投資一流動]</p> <p>[持有至到期日金融資產一流動]</p>
避險之金融資產一流動	<p>[IFRS 9]</p> <p>依避險會計指定且為有效避險工具之金融資產。</p> <p>[TW GAAP 34]</p> <p>目的為避險之衍生性流動金融資產，應以公平價值衡量。</p> <p>**此科目為新增科目，係依財會準則 34 號公報將投資依持有目的分類，95 年起適用。</p> <p>配合 IFRS 9 更名科目：原科目名為 [避險之衍生金融資產一流動]。</p>
合約資產一流動	<p>[IFRS 15]</p> <p>1.指企業依合約約定，已移轉商品或勞務予客戶，惟仍未具無條件收取對價之權利。</p> <p>2.合約資產備抵損失之認列及衡量，應依國際財務報導準則第九號規定辦理。</p> <p>[TWGAAP 11]</p> <p>係指當建造合約至今已發生成本加計已認列利潤並減除已認列損失超過工程進度請款全額時，該差額係列示為應收建造合約款。</p> <p>配合 IFRS15 更名科目：原科目名為 [應收建造合約款]。</p>
應收帳款及票據	<p>僅含出售商品、勞務之貨幣請求權(含關係人部份)，非營業行為者均予剔除(含關係人部份)。</p>
其他應收款	<p>為非營業活動之應收款項，如應收利息、應收租金、應收退稅款、應收保險賠償款或損害賠償金等賠償。</p>
資金貸予他人一流動	<p>對關係企業、股東、員工、同業之短期資金融通。</p>
存貨	<p>備供正常營業出售者 (2)生產中且在生產完成後將供營業出售者(3)於商品生產貨勞務提供過程中，所消耗之材料或物料。(財會公報#10 存貨定義)若為營業範圍涉及營建業，則須將營建用地、在建工程及待售屋等加入。</p> <p>= 原料及物料+半成品及在製品+商品及製成品+農產品+其他存貨-存貨備抵跌價損失+存貨—土地+存貨—在建工</p>

	程+存貨-成屋待售
待出售非流動資產	當一項非流動資產的帳面金額主要將透過出售而非持續使用而回收時，應將其歸類為待出售非流動資產。該資產必須能在目前情況下，依照一般條件和商業慣例可供立即出售；且出售必須高度很有可能。
當期所得稅資產—流動	本期及前期已支付金額超過該期間應付金額，則超過之部分應認列為當期所得稅資產—流動。
流動資產	企業因營業所產生之資產，預期將於企業之正常營業週期中變現、消耗或意圖出售者。 = 現金及約當現金 + 透過損益按公允價值衡量之金融資產-流動 + 透過其他綜合損益按公允價值衡量之金融資產—流動 + 按攤銷後成本衡量之金融資產—流動 + 避險之金融資產—流動 + 合約資產—流動 + 應收帳款及票據 + 應收建造合約款 + 其他應收款 + 資金貸予他人—流動 + 存貨 + 生物資產流動 + 預付費用及預付款 + 應收代理店款 + 待出售非流動資產 + 當期所得稅資產—流動 + 其他金融資產—流動 + 其他流動資產。
透過損益按公允價值衡量之金融資產—非流動	1.指非屬按攤銷後成本衡量或透過其他綜合損益按公允價值衡量之金融資產。 2.屬按攤銷後成本衡量或透過其他綜合損益按公允價值衡量之金融資產，依國際財務報導準則第九號規定可指定為透過損益按公允價值衡量之金融資產。 配合 IFRS 9 新增科目： 2017Q4 (含) 以前科目值，由以下原科目 (列入停止維護) 衍生值。 〔透過損益按公允價值衡量之金融資產—非流動〕 〔以成本衡量之金融資產—非流動〕
透過其他綜合損益按公允價值衡量之金融資產—非流動	〔IFRS 9〕 1.指同時符合下列條件之債務工具投資： (1)發行人係在以收取合約現金流量及出售為目的之經營模式下持有該金融資產。 (2)該金融資產之合約條款產生特定日期之現金流量，完全為支付本金及流通在外本金金額之利息。 2.指原始認列時作一不可撤銷之選擇，將公允價值變動列報於其他綜合損益之非持有供交易之權益工具投資。 〔TW GAAP 34〕

	<p>係非衍生性金融資產且符合下列條件之一者：</p> <ol style="list-style-type: none"> 1.被指定為備供出售。 2.非屬下列金融資產：(1)公平價值變動列入損益之金融資產 (2) 持有至到期日金融資產 (3)以成本衡量之金融資產 (4)無活絡市場之債券投資 (5)應收款。 <p>備供出售金融資產應依其流動性區分為流動與非流動，非流動者應改列基金及投資項下之備供出售金融資產-非流動。</p> <p>**此科目為新增科目，係依財會準則 34 號公報將投資依持有目的分類，95 年起適用。</p> <p>配合 IFRS 9 更名科目：原科目名為〔備供出售金融資產－非流動〕。</p>
按攤銷後成本衡量之金融資產－非流動	<ol style="list-style-type: none"> 1.發行人係在以收取合約現金流量為目的之經營模式下持有該金融資產。 2.該金融資產之合約條款產生特定日期之現金流量，完全為支付本金及流通在外本金金額之利息。 <p>配合 IFRS 9 新增科目：</p> <p>2017Q4（含）以前科目值，由以下原科目（列入停止維護）衍生值。</p> <p>〔無活絡市場之債券投資－非流動〕</p> <p>〔持有至到期日金融資產－非流動〕</p>
避險之金融資產－非流動	<p>〔IFRS 9〕</p> <p>依避險會計指定且為有效避險工具之金融資產。</p> <p>〔TW GAAP 34〕</p> <p>目的為避險之衍生性非流動金融資產，應以公平價值衡量。</p> <p>**此科目為新增科目，係依財會準則 34 號公報將投資依持有目的分類，95 年起適用配合 IFRS 9 更名科目：原科目名為〔避險之金融資產－非流動〕。</p>
合約資產－非流動	<ol style="list-style-type: none"> 1.指企業依合約約定，已移轉商品或勞務予客戶，惟仍未具無條件收取對價之權利。 2.合約資產備抵損失之認列及衡量，應依國際財務報導準則第九號規定辦理。 <p>配合 IFRS15 新增科目：2017Q4（含）以前科目值衍生 NA。</p>

採權益法之長期股權投資	投資公司對被投資公司有控制能力或重大影響力者。
預付投資款	係指企業因投資金融資產而產生之預付款。
不動產廠房及設備	<p>= 土地成本 + 土地改良物成本 + 房屋及建築成本 + 機器及儀器設備成本 + 模具設備成本 + 水電設備成本 + 電腦通訊設備成本 + 試驗設備成本 + 運輸設備成本 + 辦公設備成本 + 其他設備成本 + 固定資產 + 租賃資產及改良成本 + 出租資產成本 + 重估增值 + 固定資產累計折舊 + 固定資產損失準備 + 在建工程及預付款。係為供營業上使用，且使用年限在一年以上，非以出售為目的之有形資產。</p>
商譽及無形資產合計	<p>= 遞延退休金成本 + 土地使用權淨額 + 其他無形資產淨額 + 商譽淨額 + 特許權 + 發展中無形資產。</p> <p>無形資產係符合下列三項條件，而無實體形式的非貨幣性資產：</p> <p>(1) 具有可辨認性。</p> <p>(2) 可被企業控制。</p> <p>(3) 具有未來經濟效益。</p> <p>* 95/3 前含商譽、商標、權利金、營業權、土地使用權等。</p> <p>** 95/3 起將商譽拆出，不含商譽。</p>
遞延所得稅資產	如資產與負債的帳面價值與課稅基礎的差異，而於未來帳面資產回收或負債清償時，會產生未來可減除金額，稱為可減除暫時性差異，須認列為遞延所得稅資產(鄭丁旺 第九版 P414 P415)
遞延資產合計	<p>= 遞延所得稅資產 + 其他遞延資產淨額</p> <p>含長期預付款(分年攤銷者)遞延借項、租賃權益、技術合作費、開辦費、遞延所得稅等。若其將商標權利金歸入，則不另分出。</p>
使用權資產	TEJ 無解釋
投資性不動產淨額	為賺取租金或獲取長期資本增值，而由所有者或融資租賃之承租人所持有之不動產(土地或建築物之全部或一部分)，而非供正常營業短期出售所持有之不動產。此處指扣除累計減損及累計折舊之淨額。
其他非流動資產	長期借支、長期應收款、催收款、暫付款、存出保證金、閒置資產、承受擔保品等。

	= 遞延借項—非流動 + 投資性不動產淨額 + 預付設備款 + 長期預付租金 + 生物資產非流動 + 其他金融資產--非流動。
非流動資產	係指流動資產以外，具長期性質之有形、無形資產及金融資產。
資產總額	係指企業過去的交易或其他事項所形成的、由企業擁有或控制、預期會給企業帶來經濟效益的資源。 = 流動資產 + 非流動資產
短期借款	貸自金融機構、關係企業、同業、股東或員工等個人之短期資金、附買回債券。
應付商業本票 / 承兌匯票	發行商業本票或銀行承兌匯票，由貨幣市場取得之短期資金
透過損益按公允價值衡量之金融負債—流動	1. 持有供交易之金融負債： (1) 其發生主要目的為近期內再買回。 (2) 於原始認列時即屬合併管理之可辨認金融工具組合之一部分，且有證據顯示近期該組合為短期獲利之操作模式。 (3) 除財務保證合約或被指定且為有效避險工具外之衍生金融負債。 2. 指定透過損益按公允價值衡量之金融負債。 3. 透過損益按公允價值衡量之金融負債應按公允價值衡量。但指定為透過損益按公允價值衡量之金融負債，其公允價值變動金額屬信用風險所產生者，除避免會計配比不當之情形或屬放款承諾及財務保證合約須認列於損益外，應認列於其他綜合損益。 配合 IFRS 9 新增科目： 2017Q4 (含) 以前科目值，由以下原科目 (列入停止維護) 衍生值。 T1123 [透過損益按公允價值衡量之金融負債—流動] T1129 [以成本衡量之金融負債—流動]
避險之金融負債—流動	[IFRS 9] 依避險會計指定且為有效避險工具之金融負債。 [TW GAAP 34] 依避險會計指定且為有效避險工具之衍生性金融負債，應以公平價值衡量，並應依被避險項目之流動性區分為流動與非流動，非流動者應

	<p>改列長期負債項下避險之衍生性金融負債-非流動。</p> <p>**此科目係依財會準則 34 號公報設立，95 年起適用。</p> <p>配合 IFRS 9 更名科目：原科目名為〔避險之衍生金融負債—流動〕。</p>
按攤銷後成本衡量之金融負債—流動	<p>指非屬下列條件之金融負債：</p> <ol style="list-style-type: none"> 1.透過損益按公允價值衡量之金融負債。 2.因金融資產之移轉不符合除列要件或因適用持續參與法而產生之金融負債。 3.財務保證合約。 4.以低於市場之利率提供放款之承諾。 <p>配合 IFRS 9 新增科目：2017Q4（含）以前科目值衍生 NA。</p>
合約負債—流動	<p>指企業依合約約定已收取或已可自客戶收取對價而須移轉商品或勞務予客戶之義務。</p> <p>配合 IFRS15 新增科目：</p> <p>2017Q4（含）以前科目值，由以下原科目（列入停止維護）衍生值。</p> <p>〔應付建造合約款〕</p> <p>〔預收款項〕</p>
應付帳款及票據	<p>僅含賒購商品、原物料、及勞務而發生之負債(含關係人部分)，非營業行為者如借款、承兌匯票、購置設備等均予剔除。</p>
其他應付款	<p>除應付款項，應付費用，預收款項，其餘公司所需支付之金額，且在一年內或一營業週期內需支付款項；但 97 年前含應付員工紅利及應付董監事酬勞。</p>
當期所得稅負債	<p>本期及前期所產生之當期所得稅其尚未支付之金額應認列為當期所得稅負債。</p>
負債準備—流動	<p>係指不確定時間點或金額之負債。</p> <p>企業因過去事件所產生之現時義務，且該義務很有可能使企業為了履行義務而造成具有經濟效益之資源流出，及該義務之金額能可靠估計時，應予認列。</p>
與待出售非流動資產直接相關之負債	<p>係指一出售處分群組之一般條件及商業慣例，於目前狀態下，可供立即出售，且其出售必須為高度很有可能之待出售處分群組內之負債。</p>
租賃負債—流動	<p>租賃負債—流動</p>
一年內到期長期負	<p>含公司債、銀行長期借款、應付租賃款、分期付款之設備</p>

債	款、應付機器進口關稅一年到期部分。若應付票據中含長期應付票據一年內到期部分時，則須將其拆出至一年內到期長期負債。但若無長期部分，則列入短期借款中。
特別股負債－流動	具還本或付息義務且屬流動性質之特別股，如強制贖回特別股、附賣回特別股等 **此科目為新增科目，係依財會準則 36 號公報分類，自 95 年起適用。
流動負債	= 短期借款 + 應付商業本票 + 透過損益按公允價值衡量之金融負債-流動 + 避險之金融負債－流動 + 按攤銷後成本衡量之金融負債－流動 + 合約負債－流動 + 應付帳款及票據 + 其他應付款 + 當期所得稅負債 + 負債準備－流動 + 與待出售 非流資相關 + 其他金融負債－流動 + 一年內到期長期負債 + 特別股負債－流動 + 應付代理店款 + 其他流動負債。
透過損益按公允價值衡量之金融負債－非流動	1. 持有供交易之金融負債： (1) 其發生主要目的為近期內再買回。 (2) 於原始認列時即屬合併管理之可辨認金融工具組合之一部分，且有證據顯示近期該組合為短期獲利之操作模式。 (3) 除財務保證合約或被指定且為有效避險工具外之衍生金融負債。 2. 指定透過損益按公允價值衡量之金融負債。 3. 透過損益按公允價值衡量之金融負債應按公允價值衡量。但指定為透過損益按公允價值衡量之金融負債，其公允價值變動金額屬信用風險所產生者，除避免會計配比不當之情形或屬放款承諾及財務保證合約須認列於損益外，應認列於其他綜合損益。 配合 IFRS 9 新增科目： 2017Q4 (含) 以前科目值，由以下原科目 (列入停止維護) 衍生值。 〔透過損益按公允價值衡量之金融負債－非流動〕 〔以成本衡量之金融負債－非流動〕
避險之金融負債－非流動	〔IFRS 9〕 依避險會計指定且為有效避險工具之金融負債。 〔TW GAAP 34〕 依避險會計指定且為有效避險工具之衍生性金融負債，應

	<p>以公平價值衡量，並應依被避險項目之流動性區分為流動與非流動，非流動者應改列長期負債項下避險之衍生性金融負債-非流動。</p> <p>**此科目係依財會準則 34 號公報設立，95 年起適用。</p> <p>配合 IFRS 9 更名科目：原科目名為〔避險之衍生金融負債－非流動〕。</p>
按攤銷後成本衡量之金融負債－非流動	<p>指非屬下列條件之金融負債：</p> <ol style="list-style-type: none"> 1.透過損益按公允價值衡量之金融負債。 2.因金融資產之移轉不符合除列要件或因適用持續參與法而產生之金融負債。 3.財務保證合約。 4.以低於市場之利率提供放款之承諾。 <p>配合 IFRS 9 新增科目：2017Q4（含）以前科目值衍生 NA。</p>
合約負債－非流動	<p>指企業依合約約定已收取或已可自客戶收取對價而須移轉商品或勞務予客戶之義務。</p> <p>配合 IFRS15 新增科目：2017Q4（含）以前科目值衍生 NA。</p>
特別股負債－非流動	<p>發行凡具還本或付息義務且屬非流動性質之特別股屬之，如強制贖回特別股。</p>
應付公司債－非流動	<p>又稱公司債，係指企業為籌措資金，依公司法規定，向社會大眾公開舉債，約定到期還本並承諾定期付息。還本日期為一年以上，故屬於長期負債。</p>
銀行借款－非流動	<p>係指供營業週轉所需，向銀行借入還款期限為一年以上之債務。</p>
其他長期借款－非流動	<p>係指企業因營運所需，向銀行以外之其他單位借入償還期限超過一年之債務。</p>
租賃負債－非流動	<p>租賃負債－非流動</p>
負債準備－非流動	<p>外銷損失準備、營業準備、鍋爐損失準備、外幣兌換損失準備等(除應計退休金負債之外)。</p>
遞延貸項	<p>遞延收入、合併貸項、聯屬公司間未實現收益、未實現售後租回利益。</p>
應計退休金負債	<p>按員工退休辦法所提列的準備不得少於"最低退休金負債 (Minimum Liability)"即累積給付義務-退休基金資產之公平價值;但會小於"提撥狀況-Σ未認列"，即提撥狀況 (T1536)-未認列過度性淨給付義務-未認列前期服務成本-未認列退休金損益。</p>

遞延所得稅	跨期間所得稅分攤，因會計所得和課稅所得不同所產生之遞延認列之所得稅費用
非流動負債	'係指償還期限在一年或一年以上之負債。 = 透過損益按公允價值衡量之金融負債-非流動 + 避險之衍生性金融負債—非流動 + 按攤銷後成本衡量之金融負債—非流動 + 合約負債—非流動 + 特別股負債—非流動 + 應付公司債—非流動 + 銀行借款—非流動 + 其他長期借款—非流動 + 負債準備—非流動 + 遞延貸項 + 應計退休金負債 + 遞延所得稅 + 其他非流動負債。
負債總額	= 流動負債 + 非流動負債
普通股股本	已發行之普通股資本。
特別股股本	優先於普通股分配之股本。
預收股款	現金增資時，所收到的認股款，含面額及溢價金額。
待分配股票股利	無償配股時的待轉股本，均按面額轉列、待分配股票股利、可轉換公司債換股權利書。
換股權利證書	持有人(員工)有權利但無義務於特定期間按固定或可決定的金額認購企業股票的 合約 (鄭丁旺 第九版 P265)
股本	又稱法定資本，係股東對發行人所投入之資本，並向公司登記主管機關申請登記者。為維持法定資本之完整性，非經減資手續不得加以減少或消除。
資本公積合計	係指發行人發行金融商品之權益組成要素及發行人與股東間之股本交易所產生之溢價。股東權益項下，歸屬於資本公積之部分，來源包括:含溢價發行新股的溢價金額、固定資產重估增值金額、出售固定資產利益、受領捐贈等。
法定盈餘公積	依法提列稅後淨利 10%之公積。
特別盈餘公積	依公司章程提列之特別公積。
未分配盈餘	皆指分配前之未分配盈餘。
保留盈餘	係指公司歷年累積之純益，未以現金或其他資產方式分配給股東、轉為資本或資本或資本公積者。 = 法定盈餘公積 + 特別盈餘公積 + 未分配盈餘。
其他權益	凡屬上述所指之其他權益調整項目。 = 國外營運機構財務報表換算之兌換差額 + 透過其他綜合損益按公允價值衡量之金融資產未實現損益 + 指定按公允價值衡量之金融負債信用風險變動影響數 + 確定福利計畫再衡量數 + 避險工具損益 + 不動產重估增值 + 與待出

	售非流動資產直接相關之權益 + 股東權益其他調整項。
庫藏股票帳面值	89/12 之前，公司不得買庫藏股票，故該科目僅合併報告會提供。 89/12 之後(含 89/12)公司得在一定範圍內買庫藏股；財會準則第 30 號"庫藏股票會計處理"自 90/12 起適用，除公司自己買回之庫藏股外，子公司持有母公司股票亦視同庫藏股處理。
母公司股東權益合計	係指合併股東權益中非屬少數股權之金額，其主要組成項目為股本、資本公積、保留盈餘（或累積虧損）及股東權益其他項目項目之金額減去庫藏股票面值。
共同控制下前手權益	同一控制下企業合併發生後，最終控制者所持有被併方之股權份額。
合併前非屬共同控制股權	同一控制下企業合併發生前之各時點，外部人所持有被併方之股權份額。
非控制權益	為合併報告方有之科目，係子公司之股東權益非屬母公司直接或間接持有者。
股東權益總額	為總資產減去總負債後之餘額，即為股東在企業所擁有之權益。= 母公司股東權益合計+非控制權益。
負債及股東權益總額	= 負債總額 + 股東權益總額
營業收入淨額	= 營業收入毛額 + 營收—租金收入 + 營收—利息收入 + 營收—處分投資收入 + 營收—投資收益 + 營收—處分土地收入 - 退回及折讓。
營業成本	銷貨時該出售商品的成本即是= 銷貨成本 + 租金成本 + 出售土地成本 + 利息支出成本 + 處分投資成本 + 投資損失。
營業毛利	= 營收淨額 - 營業成本
聯屬公司已（未）實現銷貨利益	屬於聯屬公司之已(未)實現銷售毛利
已實現銷貨毛利	= 銷貨毛利 + 聯屬公司已(未)實現銷貨毛利
營業費用	= 推銷費用 + 管理費用 + 研發費用 + 其他費用 + 預期信用減損（損失）利益 - 營業費用
研究發展費	依其費用性質細分為研究發展,建議在衡量此科目時，應當考慮公司所屬產業
預期信用減損（損	依國際財務報導準則第九號認列之預期信用損失或迴轉金

失) 利益－營業費用	額，且歸屬於營業費用範圍者屬之。 配合 IFRS 9 新增科目：2017Q4 (含) 以前科目值衍生 NA。
其他收益及費損淨額	係指原須歸屬於營業外收及支出，但基於個別企業營業交易之性質，將其歸屬於營業內之收益及費損。
營業利益	= 營業毛利 + 聯屬公司已(未)實現銷貨利益 - 營業費用 + 其他收益及費損淨額
利息收入	送存金融機構或貸放他人款項所收到之利息。此為企業主要營運活動外之收入
其他收入	86/9 起不含存貨跌價損失回轉。 = 利息收入 + 租金收入 + 權利金收入 + 股利收入 + 廉價購買收益 + 違約金收入 + 預期信用減損利益 + 沖銷逾期應付款利益 + 其他收入-其他。
其他利益及損失	= T3440 + T3434 + T3460 + T34BD + T34BG + T34BN + T34AY + T3436 + T3447 + T3498 + T34BE - T3599 - T358E - T359A - T3540 - T3534 - T3560 - T359U - T35BG - T35BN - T359T - T3536 - T3547 - T35BD + T359V
財務成本	= 利息支出 + 負債性特別股股息 + 財務成本-其他。
採權益法之關聯企業及合資損益之份額	採權益法之關聯企業及合資損益之份額
預期信用減損 (損失) 利益	依國際財務報導準則第九號認列之預期信用損失或迴轉金額，且歸屬於營業外收支範圍者屬之。 配合 IFRS 9 新增科目：2017Q4 (含) 以前科目值衍生 NA。
除列按攤銷後成本衡量金融資產淨損益	係指企業自帳上除列原已認列之按攤銷後成本衡量之金融資產所產生之淨損益。 配合 IFRS 9 新增科目：2017Q4 (含) 以前科目值衍生 NA。
金融資產重分類淨損益	係指依國際財務報導準則第九號規定，符合下列條件之一者： 1. 自按攤銷後成本衡量重分類至透過損益按公允價值衡量所產生之淨利益 (損失)。 2. 自透過其他綜合損益按公允價值衡量重分類至透過損益按公允價值衡量所產生之累計淨利益 (損失)。

	配合 IFRS 9 新增科目：2017Q4 (含) 以前科目值衍生 NA。
營業外收入及支出—其他	此科目尚未適用。
營業外收入及支出	= 其他收入 + 其他利益及損失 - 財務成本 + 採權益法之關聯企業及合資損益 + 營業外收入及支出 - 其他。
稅前淨利	= 營業利益 + 營業外收入及支出。
所得稅費用	含當期及遞延所得稅費用或利益，但不含停業部門。
繼續營業單位損益	繼續營業單位損益
停業單位損益	含停業前營業損失和處分停業部門之損益(已減除相關之所得稅利益費用後之淨額)。
合併前非屬共同控制股權損益	同一控制下企業合併發生前之各時點，外部人所持有被併方所屬的股權損益。
其他損益調整項—非常項目及累計影響數	包含： 1. 非常項目：指性質特殊且不常發生之事項，如：地震災害(已減除相關之所得稅利益費用後之淨額)。 2. 累計影響數：指會計原則變動所產生之累積影響數(已減除相關之所得稅利益費用後之淨額)。
合併總損益	= 本期稅後淨利〈歸屬母公司股東〉 + 非控制權益淨利。
不重分類至損益之項目—OCI	凡扣除相關所得稅影響數前之確定福利計畫之再衡量數、不動產重估增值等不重分類至損益之其他綜合損益項目，與不重分類至損益之其他綜合損益項目相關之所得稅之合計數屬之。= 確定福利計畫之再衡量數—不重分類—OCI + 不動產重估價之利益(損失)—不重分類—OCI + 指定按公允價值衡量金融負債信用風險變動影響—不重分—OCI + 待售待分業主非流資(處分群組)直接相關權益—不重分—OCI + 透過 FVOCI 衡量權益工具投資未實現評價損益—不重分類—OCI + 避險工具之損益—不重分類—OCI + 採權益法認列關聯企業及合資其他綜合損益份額—不重分—OCI + 其他綜合損益—其他—不重分類—OCI + 與其他綜合損益組成部分相關之所得稅—不重分類—OCI
後續可能重分類至損益之項目—OCI	凡扣除相關所得稅影響數前之國外營運機構財務報表換算之兌換差額、現金流量避險中屬有效避險部分之避險工具損益等後續可能重分類至損益之其他綜合損益項目，與後續可能重分類至損益之其他綜合損益項目相關之所得稅之

	合計數屬之。= 國外營運機構財務報表換算之兌換差額-可重分類-OCI+待售待分業主非流資（處分群組）直接相關權益-可重分-OCI+透 FVOCI 衡量債務工具投資未實現評價損益-可重分類-OCI+避險工具之損益-可重分類-OCI+採權益法認列關聯企業及合資其他綜合損益份額-可重分-OCI+其他綜合損益-其他-可重分類-OCI+ 與其他綜合損益組成部分相關之所得稅-可重分類-OCI
合併前非屬共同控制股權綜合損益淨額-OCI	同一控制下企業合併發生前之各時點，外部人所持有被併方之股權所屬綜合損益淨額。
其他綜合損益-OCI	屬共同控制股權綜合損益淨額-OCI
本期綜合損益總額	= 合併總損益 +其他綜合損益-OCI。
歸屬母公司淨利（損）	合併報表方之科目，指母公司股東所擁有之普通股東權益應分配之合併總損益
歸屬非控制權益淨利（損）	合併報表方之科目，指少數股東所擁有之普通股東權益應分配之合併總損益。
歸屬共同控制下前手權益淨利（損）	同一控制下企業合併發生後，最終控制者所持有被併方之普通股東權益應分配之合併總損益。
綜合損益歸屬母公司	合併報表方之科目，指母公司股東所擁有之普通股東權益應分配之綜合總損益
綜合損益歸屬非控制權益	合併報表方之科目，指少數股東所擁有之普通股東權益應分配之綜合總損益。
綜合損益歸屬共同控制下前手權益	同一控制下企業合併發生後，最終控制者所持有被併方之普通股東權益應分配之綜合總損益。
每股盈餘	每股盈餘(Earnings Per Share ;EPS)按當期之加權平均股數計算，而不採用追溯調整後之股數。 **依財會準則第 30 號公報，子公司持有母公司之股票應視為庫藏股票處理，故自 91 年起每股盈餘係已扣除子公司持有母公司股票影響後之數字。
加權平均股數	流通在外股數若因無償配股，紅利，股票分割及減資彌補虧損而造成變動時，應予以追溯調整計算加權平均股數。
發放特別股股息	係發放於特別股股東的股利
稀釋稅後淨利	為了計算稀釋後每股盈餘所調整之淨利。加減具稀釋作用之潛在支出。

每股盈餘－完全稀釋	係指假設將所有具有稀釋效果之證券及或有發行股份等，均予轉換、行使或發行普通股，所計算之每股盈餘。若公司無約當普通股，則稀釋後每股盈餘 = 每股盈餘
加權平均股數－稀釋	加權平均股數加上具潛在稀釋作用之認股權、可轉換公司債、可轉換特別股及股權認購證。
稅前息前淨利	= 稅前淨利 + 財務成本
稅前息前折舊前淨利	= 稅前淨利 + 財務成本 + 折舊 + 攤提
常續性稅後淨利	<p>= 繼續營業部門純益-子公司董監酬勞-非常續淨利</p> <p>**非常續(Nonrecurring)淨利係指一次式(處分)損益，如處分資產損益、處分投資損益、金融商品減損損失及迴轉及資產減損損失及迴轉</p> <p>**NOI(非常續淨利)=(廉價購買收益 + 處分不動產、廠房及設備利益 - 處分不動產、廠房及設備損失 + 處分投資利益 - 處分投資損失 + 透過損益按公允價值衡量之金融資產(負債)利益 - 透過損益按公允價值衡量之金融資產(負債)損失 + 資產評價利益 - 資產評價損失 + 金融資產減損迴轉利益 - 金融資產減損損失 + 資產減損迴轉利益 - 資產減損損失 + 按攤銷後成本衡量之金融負債利益 - 按攤銷後成本衡量之金融負債損失 + 避險工具之利益 - 避險工具之損失 + 除列按攤銷後成本衡量金融資產淨損益 + 金融資產重分類淨損益)</p>
期中普通股－現金股利	期中發放於普通股股東的現金股利。
期中普通股－股票股利	期中發放於普通股股東的股票股利。
期中特別股－現金股利	期中發放於特別股股東的現金股利。
期中特別股－股票股利	期中發放於特別股股東的股票股利。
期末普通股－現金股利	發放於普通股股東的現金股利
期末普通股－股票股利	發放於普通股股東的股票股利
期末特別股－現金股利	發放於特別股股東的現金股利

期末特別股—股票股利	發放於特別股股東的股票股利
普通股每股現金股利（盈餘及公積）	係每股普通股股東所能分配到的現金股利。
普通股每股現金股利—盈餘	每股普通股股東所能分配到的現金股利來自盈餘之部分。
普通股每股現金股利—公積	每股普通股股東所能分配到的現金股利來自公積之部分。
普通股每股股票股利—盈餘	含增資準備轉股本、特別公積轉股本、盈餘轉增資。
普通股每股股票股利—公積	公司配發的每股股利來源係為資本公積,而非盈餘的配發
資本公積—現金股利	現金股利的配發來源為資本公積。
資本公積轉增資—股票股利	股票股利的配發來源為資本公積。
稅前淨利—CFO	用間接法計算現金流量表所用的稅前淨利。
折舊—CFO	各種折舊性資產之成本分攤屬之。
攤提—CFO	各種無形資產遞延資產攤銷費用屬之。
來自營運之現金流量	78 年以後(含 78 年)才有的科目。係指企業在透過平時的營運活動中所產生的現金流出與流入。
新增投資—CFI	購買長期投資。包括權益證券、債券、土地及其他。
出售投資—CFI	出售長期投資。包括權益證券、債券、土地及其他。
購置不動產廠房設備（含預付）—CFI	含購置其他閒置用之固定資產；購置其他閒置用之固定資產，主係部分公司會購置農地而將其帳列其他資產或閒置資產中。
處分不動產廠房設備（含預付）—CFI	含處分閒置資產價款。
投資活動之現金流量	78 年以後(含 78 年)才有的科目。係指企業在透過平時的營運活動中所產生的現金流入與流出。
現金增（減）資—CFF	含溢價部份、預收股款、預收股款退回、第一年之設立股本，及發行 GDR，若為負數，係公司減資退還股款。
支付現金股利—CFF	86/06 年以前含支付董監酬勞及員工紅利。
籌資活動之現金流	78 年以後(含 78 年)才有的科目。係指企業在透過平時的

量	營運活動中所產生的現金 流入與流出。
匯率影響數	凡外幣現金餘額按期末結帳匯率換算成新台幣,大於按外 幣收付當時匯率或當期 加權平均匯率換算成新台幣之收支差額者
本期產生現金流量	= 來自營運之現金流量 +投資活動之現金流量 +融資活 動之現金流量 +匯率影 響數。
期初現金及約當現 金	期初現金及約當現金
期末現金及約當現 金	= 期初現金及約當現金 +本期產生現金流量
簽證意見類型	查核意見型態 A：無保留意見； B：保留意見； C：無法表示意見； D：否定意見； E：修正式無保留意見
繼續經營假設是否 有疑慮	會計師是否對公司之繼續經營假設存有疑慮；Y(有)/N(無)
是否為大型事務所	是否為大型之會計師事務所
產業名稱	受查公司所屬產業名稱，依 TEJ 產業分類
會計師 1	CPA1 名稱(左右簽字，取左者；上下簽字，取上者)
會計師 2	CPA2 名稱(左右簽字，取右者；上下簽字，取下者)(自 1983/7 起，公開發行公司之財務報告，應由會計師二人以 上簽證)
本期產生現金流量	本期產生現金流量
期初現金及約當現 金	期初現金及約當現金
期末現金及約當現 金	期末現金及約當現金
Total_accural/去年 Asset	依照裁決性應計數計算出的 Total_accural/去年 Asset
1/去年 Asset	依照裁決性應計數計算出的 1/去年 Asset
銷售額變動	依照裁決性應計數計算出的銷售額變動
應收帳款變動	依照裁決性應計數計算出的應收帳款變動

(銷售變動-應收變動)/去年 Asset	依照裁決性應計數計算出的(銷售變動-應收變動)/去年 Asset
PPE/去年 Asset	依照裁決性應計數計算出的 PPE/去年 Asset
ROA/去年 Asset	依照裁決性應計數計算出的 ROA/去年 Asset
預測的 Total_accural	依照裁決性應計數計算出的預測的 Total_accural
裁決性應計數	裁決性應計數
1/asset 參數	計算裁決性應計數時自變數 1/asset 的係數
sale-ar 參數	計算裁決性應計數時自變數 sale-應收帳款的係數
ppe 參數	計算裁決性應計數時 ppe 的係數
roa 參數	計算裁決性應計數時 roa 的係數
intercept 參數	計算裁決性應計數時 intercept 的係數
成立年數	受查公司設立年數，公式=目前年度-公司設立年度+1。 (*)-一般而言，成立年數應為正數，但有特例，因海外回台掛牌公司，通常於第三地成立控股公司後再回台上市，但因須公告前三年財報，故常會編製控股公司成立前之擬制性財報，導致成立年數為負數的特殊情況。
上市年數	受查公司上市櫃掛牌年數
事務所任期_自 1983 起(年)	會計師事務所查核公司年數_自 1983 年起算 任期中斷後，若以後又再查核，會從 1 起算
事務所任期_上市櫃起(年)	會計師事務所查核公司年數_自公司上市櫃起算
事務所任期_公開發 起(年)	會計師事務所查核公司年數_自公司公開發行起算
CPA1 任期_自 1983 起(年)	CPA1 查核公司年數_自 1983 年起算 任期中斷後，若再次查核，任期不從新起算，會接續前次 任期繼續起算
CPA1 任期_上市櫃 起(年)	CPA1 查核公司年數_自公司上市櫃起算
CPA1 任期_公開發 行起(年)	CPA1 查核公司年數_自公司公開發行起算
CPA2 任期_自 1983 起(年)	CPA2 查核公司年數_自 1983 年起算
CPA2 任期_上市櫃 起(年)	CPA2 查核公司年數_自公司上市櫃起算

CPA2 任期_公開發行起(年)	CPA2 查核公司年數_自公司公開發行起算
CPA1 應輪調	CPA1 是否應輪調；0=否、1=是 2003 年，兩位會計師均連續簽證 5 年為 1； 2004 年至 2007 年，任一會計師連續簽證 5 年為 1； 2008 年起，任一會計師連續簽證 7 年為 1。
CPA2 應輪調	CPA2 是否應輪調；0=否、1=是 2003 年，兩位會計師均連續簽證 5 年為 1； 2004 年至 2007 年，任一會計師連續簽證 5 年為 1； 2008 年起，任一會計師連續簽證 7 年為 1。
CPA1 連續查核任期	CPA1 連續查核任期
CPA2 連續查核任期	CPA2 連續查核任期
更換會計師人數	簽證會計師實際異動人數
更換會計師事務所	是否更換會計師事務所；0=否、1=是，包含事務所因合併而導致法律個體改變者
更換會計師事務所 A	TEJ 無解釋
CPA1 經驗_自 1983 起(年)	CPA1 查核公司之經驗_自 1983 年起算(年數)
CPA1 經驗_上市櫃(年)	CPA1 查核上市櫃公司之經驗(年數)
CPA1 經驗_公開發行(年)	CPA1 查核公開發行公司之經驗(年數)
CPA1 經驗_產業(年)	CPA1 查核受查公司所屬產業之經驗(年數)
CPA2 經驗_自 1983 起(年)	CPA2 核公司之經驗_自 1983 年起算(年數)
CPA2 經驗_上市櫃(年)	CPA2 核上市櫃公司之經驗(年數)
CPA2 經驗_公開發行(年)	CPA2 查核公開發行公司之經驗(年數)
CPA2 經驗_產業(年)	CPA2 查核受查公司所屬產業之經驗(年數)

CPA1_ √ 營收 / √ 上市櫃客戶營收 %	受查客戶營收佔 CPA1 全部上市櫃客戶營收之比重；公式 =受查公司營收/CPA 全部上市客戶營收，營收開根號
CPA1_ √ 營收 / √ 公發客戶營收 %	受查客戶營收佔 CPA1 全部公開發行以上客戶營收之比 重；公式=受查公司營收/CPA1 全部公開發行以上客戶營 收，營收開根號
CPA1_ √ 資產 / √ 上市櫃客戶資產 %	受查客戶資產佔 CPA1 全部上市櫃客戶資產之比重；公式 =受查公司資產/CPA1 全部上市客戶資產，資產開根號
CPA1_ √ 資產 / √ 公發客戶資產 %	受查客戶資產佔 CPA1 全部公開發行以上客戶資產之比 重；公式=受查公司資產/CPA1 全部公開發行以上客戶資 產，資產取 log
CPA1_log 營收 / log 上市櫃客戶營收 %	受查客戶營收佔 CPA1 全部上市櫃客戶營收之比重；公式 =受查公司營收/CPA1 全部上市客戶營收，營收取 log
CPA1_log 營收 / log 公發客戶營收 %	受查客戶營收佔 CPA1 全部公開發行以上客戶營收之比 重；公式=受查公司營收/CPA1 全部公開發行以上客戶營 收，營收取 log
CPA1_log 資產 / log 上市櫃客戶資產 %	受查客戶資產佔 CPA1 全部上市櫃客戶資產之比重；公式 =受查公司資產/CPA1 全部上市客戶資產，資產取 log
CPA1_log 資產 / log 公發客戶資產 %	受查客戶資產佔 CPA1 全部公開發行以上客戶資產之比 重；公式=受查公司資產/CPA1 全部公開發行以上客戶資 產，資產取 log
CPA1_上市櫃客戶 家數 %	受查客戶佔 CPA1 全部上市櫃客戶家數之比重；公式 =1/CPA1 全部上市客戶家數
CPA1_上市櫃客戶 總家數	CPA1 上市櫃客戶家數
CPA1_上市櫃客戶 總營收(千元)	CPA1 上市櫃客戶總營收
CPA1_上市櫃客戶 總資產(千元)	CPA1 上市櫃客戶總資產
CPA1_公開發行客 戶數 %	受查客戶佔 CPA1 全部公開發行客戶家數之比重；公式 =1/CPA1 全部上市客戶家數
CPA1_公開發行客 戶總家數	CPA1 公開發行(含上市櫃)客戶家數

CPA1_公開發行客戶總營收(千元)	CPA1 公開發行(含上市櫃)客戶總營收
CPA1_公開發行客戶總資產(千元)	CPA1 上市櫃客戶總資產
CPA1_營收/上市櫃客戶營收 %	受查客戶營收佔 CPA1 全部上市櫃客戶營收之比重；公式 = 受查公司營收/CPA1 全部上市客戶營收
CPA1_營收/公開發行客戶營收 %	受查客戶營收佔 CPA1 全部公開發行以上客戶營收之比重；公式 = 受查公司營收/CPA1 全部公開發行以上客戶營收
CPA1_資產/上市櫃客戶資產 %	受查客戶資產佔 CPA1 全部上市櫃客戶資產之比重；公式 = 受查公司資產/CPA1 全部上市客戶資產
CPA1_資產/公發客戶資產 %	受查客戶資產佔 CPA1 全部公開發行以上客戶資產之比重；公式 = 受查公司資產/CPA1 全部公開發行以上客戶資產
CPA2_ √ 營收/√ 上市櫃客戶營收 %	受查客戶營收佔 CPA2 全部上市櫃客戶營收之比重；公式 = 受查公司營收/CPA 全部上市客戶營收，營收開根號
CPA2_ √ 營收/√ 公發客戶營收 %	受查客戶營收佔 CPA2 全部公開發行以上客戶營收之比重；公式 = 受查公司營收/CPA2 全部公開發行以上客戶營收，營收開根號
CPA2_ √ 資產/√ 上市櫃客戶資產 %	受查客戶資產佔 CPA2 全部上市櫃客戶資產之比重；公式 = 受查公司資產/CPA2 全部上市客戶資產，資產開根號
CPA2_ √ 資產/√ 公發客戶資產 %	受查客戶資產佔 CPA2 全部公開發行以上客戶資產之比重；公式 = 受查公司資產/CPA2 全部公開發行以上客戶資產，資產取 log
CPA2_log 營收/log 上市櫃客戶營收 %	受查客戶營收佔 CPA2 全部上市櫃客戶營收之比重；公式 = 受查公司營收/CPA2 全部上市客戶營收，營收取 log
CPA2_log 營收/log 公發客戶營收 %	受查客戶營收佔 CPA2 全部公開發行以上客戶營收之比重；公式 = 受查公司營收/CPA2 全部公開發行以上客戶營收，營收取 log
CPA2_log 資產/log 上市櫃客戶資產 %	受查客戶資產佔 CPA2 全部上市櫃客戶資產之比重；公式 = 受查公司資產/CPA2 全部上市客戶資產，資產取 log

CPA2_log 資產／ log 公發客戶資產 %	受查客戶資產佔 CPA2 全部公開發行以上客戶資產之比 重；公式=受查公司資產/CPA2 全部公開發行以上客戶資 產，資產取 log
CPA2_上市櫃客戶 家數 %	受查客戶佔 CPA2 全部上市櫃客戶家數之比重；公式 =1/CPA2 全部上市客戶家數
CPA2_上市櫃客戶 總家數	CPA2 上市櫃客戶家數
CPA2_上市櫃客戶 總營收(千元)	CPA2 上市櫃客戶總營收
CPA2_上市櫃客戶 總資產(千元)	CPA2 上市櫃客戶總資產
CPA2_公開發行客 戶數 %	受查客戶佔 CPA2 全部公開發行客戶家數之比重；公式 =1/CPA2 全部上市客戶家數
CPA2_公開發行客 戶總家數	CPA2 公開發行(含上市櫃)客戶家數
CPA2_公開發行客 戶總營收(千元)	CPA2 公開發行(含上市櫃)客戶總營收
CPA2_公開發行客 戶總資產(千元)	CPA2 上市櫃客戶總資產
CPA2_營收／上市 櫃客戶營收 %	受查客戶營收佔 CPA2 全部上市櫃客戶營收之比重；公式 =受查公司營收/CPA2 全部上市客戶營收
CPA2_營收／公開 發行客戶營收 %	受查客戶營收佔 CPA2 全部公開發行以上客戶營收之比 重；公式=受查公司營收/CPA2 全部公開發行以上客戶營 收
CPA2_資產／上市 櫃客戶資產 %	受查客戶資產佔 CPA2 全部上市櫃客戶資產之比重；公式 =受查公司資產/CPA2 全部上市客戶資產
CPA2_資產／公發 客戶資產 %	受查客戶資產佔 CPA2 全部公開發行以上客戶資產之比 重；公式=受查公司資產/CPA2 全部公開發行以上客戶資 產
事務所_ √ 營收／ √ 上市櫃客戶營收 %	受查客戶營收佔會計師事務所全部上市櫃客戶營收之比 重；公式=受查公司營收/CPA 全部上市客戶營收，營收 開根號
事務所_ √ 營收／ √ 公發客戶營收 %	受查客戶營收佔會計師事務所全部公開發行以上客戶營收 之比重；公式=受查公司營收/會計師事務所全部公開發行 以上客戶營收，營收開根號

事務所_ $\sqrt{\text{資產}} / \sqrt{\text{上市櫃客戶資產}} \%$	受查客戶資產佔會計師事務所全部上市櫃客戶資產之比重；公式=受查公司資產/會計師事務所全部上市客戶資產，資產開根號
事務所_ $\sqrt{\text{資產}} / \sqrt{\text{公發客戶資產}} \%$	受查客戶資產佔會計師事務所全部公開發行以上客戶資產之比重；公式=受查公司資產/會計師事務所全部公開發行以上客戶資產，資產取 log
事務所_log 營收 / log 上市櫃客戶營收 %	受查客戶營收佔會計師事務所全部上市櫃客戶營收之比重；公式=受查公司營收/會計師事務所全部上市客戶營收，營收取 log
事務所_log 營收 / log 公發客戶營收 %	受查客戶營收佔會計師事務所全部公開發行以上客戶營收之比重；公式=受查公司營收/會計師事務所全部公開發行以上客戶營收，營收取 log
事務所_log 資產 / log 上市櫃客戶資產 %	受查客戶資產佔會計師事務所全部上市櫃客戶資產之比重；公式=受查公司資產/會計師事務所全部上市客戶資產，資產取 log
事務所_log 資產 / log 公發客戶資產 %	受查客戶資產佔會計師事務所全部公開發行以上客戶資產之比重；公式=受查公司資產/會計師事務所全部公開發行以上客戶資產，資產取 log
事務所_上市櫃客戶家數 %	受查客戶佔會計師事務所全部上市櫃客戶家數之比重；公式=1/會計師事務所全部上市客戶家數
事務所_上市櫃客戶總家數	會計師事務所上市櫃客戶家數
事務所_上市櫃客戶總營收(千元)	會計師事務所上市櫃客戶總營收
事務所_上市櫃客戶總資產(千元)	會計師事務所上市櫃客戶總資產
事務所_公開發行客戶家數 %	受查客戶佔會計師事務所全部公開發行客戶家數之比重；公式=1/會計師事務所全部上市客戶家數
事務所_公開發行客戶總家數	會計師事務所公開發行(含上市櫃)客戶家數
事務所_公開發行客戶總營收(千元)	會計師事務所公開發行(含上市櫃)客戶總營收
事務所_公開發行客戶總資產(千元)	會計師事務所上市櫃客戶總資產

事務所_營收/上市櫃客戶營收 %	受查客戶營收佔會計師事務所全部上市櫃客戶營收之比重；公式=受查公司營收/會計師事務所全部上市客戶營收
事務所_營收/公開發行客戶營收 %	受查客戶營收佔會計師事務所全部公開發行以上客戶營收之比重；公式=受查公司營收/會計師事務所全部公開發行以上客戶營收
事務所_資產/上市櫃客戶資產 %	受查客戶資產佔會計師事務所全部上市櫃客戶資產之比重；公式=受查公司資產/會計師事務所全部上市客戶資產
事務所_資產/公開發行客戶資產 %	受查客戶資產佔會計師事務所全部公開發行以上客戶資產之比重；公式=受查公司資產/會計師事務所全部公開發行以上客戶資產
受查客戶營收(千元)	受查公司營收
受查客戶資產(千元)	受查公司資產
CPA1_上市櫃客戶_家數	CPA1 查核受查公司所屬產業的上市櫃客戶家數
CPA1_上市櫃客戶_查核產業數	CPA1_上市櫃客戶_查核產業數
CPA1_上市櫃客戶_營收	CPA1 查核受查公司所屬產業的上市櫃客戶總營收
CPA1_上市櫃客戶_資產	CPA1 查核受查公司所屬產業的上市櫃客戶總資產
CPA1_公開發行客戶_家數	CPA1 查核受查公司所屬產業的公開發行客戶家數
CPA1_公開發行客戶_查核產業數	CPA1_公開發行客戶_查核產業數
CPA1_公開發行客戶_營收	CPA1 查核受查公司所屬產業的公開發行客戶總營收
CPA1_公開發行客戶_資產	CPA1 查核受查公司所屬產業的公開發行客戶總資產
CPA1_產業客戶_家數(上市櫃)	CPA1 查核上市櫃客戶家數
CPA1_產業客戶_家數(公發)	CPA1 查核公開發行客戶家數

CPA1_產業客戶_營收(上市櫃)	CPA1 查核上市櫃客戶總營收
CPA1_產業客戶_營收(公發)	CPA1 查核公開發行客戶總營收
CPA1_產業客戶_資產(上市櫃)	CPA1 查核上市櫃客戶總資產
CPA1_產業客戶_資產(公發)	CPA1 查核公開發行客戶總資產
CPA1_產業市佔率_家數/上市櫃家數 %	CPA1 產業簽證市佔率－上市櫃公司家數；公式=CPA1 查核該產業上市公司客戶家數/該產業上市公司家數
CPA1_產業市佔率_家數/公發家數 %	CPA1 產業簽證市佔率－公開發行公司家數；公式=CPA1 查核該產業公開發行公司客戶家數/該產業公開發行公司家數
CPA1_產業市佔率_營收/上市櫃營收 %	CPA1 產業簽證市佔率－上市櫃公司營收；公式=CPA1 查核產業上市櫃客戶之營收總和/該產業所有上市公司營收總和
CPA1_產業市佔率_營收/公發營收 %	CPA1 產業簽證市佔率－公開發行公司營收；公式=CPA1 查核產業公開發行客戶之營收總和/該產業所有公開發行公司營收總和
CPA1_產業市佔率_資產/上市櫃資產 %	CPA1 產業簽證市佔率－上市櫃公司資產；公式=CPA1 查核產業上市櫃客戶之資產總和/該產業所有上市公司資產總和
CPA1_產業市佔率_資產/公發資產 %	CPA1 產業簽證市佔率－公開發行公司資產；公式=CPA1 查核產業公開發行客戶之資產總和/該產業所有公開發行公司資產總和
CPA1_產業市佔率_排名_家數(上市櫃)	CPA1 查核產業上市公司排名_家數
CPA1_產業市佔率_排名_家數(公發)	CPA1 查核產業公開發行公司排名_家數
CPA1_產業市佔率_排名_營收(上市櫃)	CPA1 查核產業上市公司排名_營收
CPA1_產業市佔率_排名_營收(公發)	CPA1 查核產業公開發行公司排名_營收
CPA1_產業市佔率_排名_資產(上市櫃)	CPA1 查核產業上市公司排名_資產

CPA1_產業市佔率 排名_資產(公發)	CPA1 查核產業公開發行公司排名_資產
CPA1_產業集中度_ 家數/客戶家數 %(上市櫃)	CPA1 查核受查公司所屬產業之上市櫃公司家數，佔其所有上市櫃客戶比重；公式=CPA1 查核該公司所屬產業上市櫃公司家數/CPA1 之全部上市櫃客戶家數
CPA1_產業集中度_ 家數/客戶家數 %(公發)	CPA1 查核受查公司所屬產業之公開發行以上公司家數，佔其所有上市櫃客戶比重；公式=CPA1 查核該公司所屬產業公開發行以上公司家數/CPA1 之全部公開發行以上客戶家數
CPA1_產業集中度_ 營收/客戶營收 %(上市櫃)	CPA1 查核受查公司所屬產業之上市櫃公司營收總和，佔其所有上市櫃客戶營收比重；公式=CPA1 查核該公司所屬產業上市櫃公司營收總和/CPA1 全部上市櫃客戶營收總和
CPA1_產業集中度_ 營收/客戶營收 %(公發)	CPA1 查核受查公司所屬產業之公開發行以上公司營收總和，佔其所有公開發行以上客戶營收比重；公式=CPA1 查核該公司所屬產業公開發行以上公司營收總和/CPA1 全部公開發行以上客戶營收總和
CPA1_產業集中度_ 資產/客戶資產 %(公發)	CPA1 查核受查公司所屬產業之公開發行以上公司資產總和，佔其所有公開發行以上客戶資產比重；公式=CPA1 查核該公司所屬產業公開發行以上公司資產總和/CPA1 全部公開發行以上客戶資產總和
CPA1_產業集中度_ 資產/客戶資產%_ 上市櫃	CPA1 查核受查公司所屬產業之上市櫃公司資產總和，佔其所有上市櫃客戶資產比重；公式=CPA1 查核該公司所屬產業上市櫃公司資產總和/CPA1 全部上市櫃客戶資產總和
CPA1_產業集中度 排名_家數(上市櫃)	CPA1 查核該公司所屬產業之上市櫃公司之所內排名_家數
CPA1_產業集中度 排名_家數(公發)	CPA1 查核該公司所屬產業之公開發行以上公司之所內排名_家數
CPA1_產業集中度 排名_營收(上市櫃)	CPA1 查核該公司所屬產業之上市櫃公司之所內排名_營收
CPA1_產業集中度 排名_營收(公發)	CPA1 查核該公司所屬產業之公開發行以上公司之所內排名_營收
CPA1_產業集中度 排名_資產(上市櫃)	CPA1 查核該公司所屬產業之上市櫃公司之所內排名_資產

CPA1_產業集中度 排名_資產(公發)	CPA1 查核該公司所屬產業之公開發行以上公司之所內排名_資產
CPA2_上市櫃客戶_家數	CPA2 查核受查公司所屬產業的上市櫃客戶家數
CPA2_上市櫃客戶_查核產業數	CPA2_上市櫃客戶_查核產業數
CPA2_上市櫃客戶_營收	CPA2 查核受查公司所屬產業的上市櫃客戶總營收
CPA2_上市櫃客戶_資產	CPA2 查核受查公司所屬產業的上市櫃客戶總資產
CPA2_公開發行客戶_家數	CPA2 查核受查公司所屬產業的公開發行客戶家數
CPA2_公開發行客戶_查核產業數	CPA2_公開發行客戶_查核產業數
CPA2_公開發行客戶_營收	CPA2 查核受查公司所屬產業的公開發行客戶總營收
CPA2_公開發行客戶_資產	CPA2 查核受查公司所屬產業的公開發行客戶總資產
CPA2_產業客戶_家數(上市櫃)	CPA2 查核上市櫃客戶家數
CPA2_產業客戶_家數(公發)	CPA2 查核公開發行客戶家數
CPA2_產業客戶_營收(上市櫃)	CPA2 查核上市櫃客戶總營收
CPA2_產業客戶_營收(公發)	CPA2 查核公開發行客戶總營收
CPA2_產業客戶_資產(上市櫃)	CPA2 查核上市櫃客戶總資產
CPA2_產業客戶_資產(公發)	CPA2 查核公開發行客戶總資產
CPA2_產業市佔率_家數/上市櫃家數 %	CPA2 產業簽證市佔率—上市櫃公司家數；公式=CPA2 查核該產業上市公司客戶家數/該產業上市公司家數
CPA2_產業市佔率_家數/公發家數 %	CPA2 產業簽證市佔率—公開發行公司家數；公式=CPA2 查核該產業公開發行公司客戶家數/該產業公開發行公司家數

CPA2_產業市佔率_ 營收／上市櫃營收 %	CPA2 產業簽證市佔率－上市櫃公司營收；公式=CPA2 查核產業上市櫃客戶之營收總和／該產業所有上市公司營收總和
CPA2_產業市佔率_ 營收／公發營收 %	CPA2 產業簽證市佔率－公開發行公司營收；公式=CPA2 查核產業公開發行客戶之營收總和／該產業所有公開發行公司營收總和
CPA2_產業市佔率_ 資產／上市櫃資產 %	CPA2 產業簽證市佔率－上市櫃公司資產；公式=CPA2 查核產業上市櫃客戶之資產總和／該產業所有上市公司資產總和
CPA2_產業市佔率_ 資產／公發資產 %	CPA2 產業簽證市佔率－公開發行公司資產；公式=CPA2 查核產業公開發行客戶之資產總和／該產業所有公開發行公司資產總和
CPA2_產業市佔率 排名_家數(上市櫃)	CPA2 查核產業上市公司排名_家數
CPA2_產業市佔率 排名_家數(公發)	CPA2 查核產業公開發行公司排名_家數
CPA2_產業市佔率 排名_營收(上市櫃)	CPA2 查核產業上市公司排名_營收
CPA2_產業市佔率 排名_營收(公發)	CPA2 查核產業公開發行公司排名_營收
CPA2_產業市佔率 排名_資產(上市櫃)	CPA2 查核產業上市公司排名_資產
CPA2_產業市佔率 排名_資產(公發)	CPA2 查核產業公開發行公司排名_資產
CPA2_產業集中度_ 家數／客戶家數 %(上市櫃)	CPA2 查核受查公司所屬產業之上市櫃公司家數，佔其所有上市櫃客戶比重；公式=CPA2 查核該公司所屬產業上市櫃公司家數／CPA2 之全部上市櫃客戶家數
CPA2_產業集中度_ 家數／客戶家數 %(公發)	CPA2 查核受查公司所屬產業之公開發行以上公司家數，佔其所有公開發行以上客戶比重；公式=CPA2 查核該公司所屬產業公開發行以上公司家數／CPA2 之全部公開發行以上客戶家數
CPA2_產業集中度_ 營收／客戶營收 %(上市櫃)	CPA2 查核受查公司所屬產業之上市櫃公司家數，佔其所有上市櫃客戶比重；公式=CPA2 查核該公司所屬產業上市櫃公司家數／CPA2 之全部上市櫃客戶家數

CPA2_產業集中度_營收／客戶營收 %(公發)	CPA2 查核受查公司所屬產業之公開發行以上公司營收總和，佔其所有公開發行以上客戶營收比重；公式=CPA2 查核該公司所屬產業公開發行以上公司營收總和／CPA2 全部公開發行以上客戶營收總和
CPA2_產業集中度_資產／客戶資產 %(上市櫃)	CPA2 查核受查公司所屬產業之上市櫃公司家數，佔其所有上市櫃客戶比重；公式=CPA2 查核該公司所屬產業上市櫃公司家數(#112)／CPA2 之全部上市櫃客戶家數(#118)
CPA2_產業集中度_資產／客戶資產 %(公發)	CPA2 查核受查公司所屬產業之公開發行以上公司資產總和，佔其所有公開發行以上客戶資產比重；公式=CPA2 查核該公司所屬產業公開發行以上公司資產總和(#117)／CPA2 全部公開發行以上客戶資產總和(#123)
CPA2_產業集中度 排名_家數(上市櫃)	CPA2 查核該公司所屬產業之上市櫃公司之所內排名_家數
CPA2_產業集中度 排名_家數(公發)	CPA2 查核該公司所屬產業之公開發行以上公司之所內排名_家數
CPA2_產業集中度 排名_營收(上市櫃)	CPA2 查核該公司所屬產業之上市櫃公司之所內排名_營收
CPA2_產業集中度 排名_營收(公發)	CPA2 查核該公司所屬產業之公開發行以上公司之所內排名_營收
CPA2_產業集中度 排名_資產(上市櫃)	CPA2 查核該公司所屬產業之上市櫃公司之所內排名_資產
CPA2_產業集中度 排名_資產(公發)	CPA2 查核該公司所屬產業之公開發行以上公司之所內排名_資產
事務所_上市櫃客戶 _家數	事務所查核受查公司所屬產業的上市櫃客戶家數
事務所_上市櫃客戶 _查核產業數	事務所_上市櫃客戶_查核產業數
事務所_上市櫃客戶 _營收	事務所查核受查公司所屬產業的上市櫃客戶總營收
事務所_上市櫃客戶 _資產	事務所查核受查公司所屬產業的上市櫃客戶總資產
事務所_公開發行客 戶_家數	事務所查核受查公司所屬產業的公開發行客戶家數
事務所_公開發行客 戶_查核產業數	事務所_公開發行客戶_查核產業數

事務所_公開發行客戶_營收	事務所查核受查公司所屬產業的公開發行客戶總營收
事務所_公開發行客戶_資產	事務所查核受查公司所屬產業的公開發行客戶總資產
事務所_產業客戶_家數(上市櫃)	事務所查核上市櫃客戶家數
事務所_產業客戶_家數(公發)	事務所查核公開發行客戶家數
事務所_產業客戶_營收(上市櫃)	事務所查核上市櫃客戶總營收
事務所_產業客戶_營收(公發)	事務所查核公開發行客戶總營收
事務所_產業客戶_資產(上市櫃)	事務所查核上市櫃客戶總資產
事務所_產業客戶_資產(公發)	事務所查核公開發行客戶總資產
事務所_產業市佔率_家數/上市櫃家數%	會計師事務所產業簽證市佔率—上市櫃公司家數；公式=會計師事務所查核該產業上市公司客戶家數/該產業上市公司家數
事務所_產業市佔率_家數/公發家數%	會計師事務所產業簽證市佔率—公開發行公司家數；公式=會計師事務所查核該產業上市公司客戶家數/該產業公開發行公司家數
事務所_產業市佔率_營收/上市櫃營收%	會計師事務所產業簽證市佔率—上市櫃公司營收；公式=會計師事務所查核產業上市櫃客戶之營收總和/該產業所有上市公司營收總和
事務所_產業市佔率_營收/公發營收%	會計師事務所產業簽證市佔率—公開發行公司營收；公式=會計師事務所查核產業公開發行客戶之營收總和/該產業所有公開發行公司營收總和
事務所_產業市佔率_資產/上市櫃資產%	會計師事務所產業簽證市佔率—上市櫃公司資產；公式=會計師事務所查核產業上市櫃客戶之資產總和/該產業所有上市公司資產總和
事務所_產業市佔率_資產/公發資產%	會計師事務所產業簽證市佔率—公開發行公司資產；公式=會計師事務所查核產業公開發行客戶之資產總和/該產業所有公開發行公司資產總和
事務所_產業市佔率_排名_家數(上市櫃)	會計師事務所查核產業上市公司排名_家數

事務所_產業市佔率 排名_家數(公發)	會計師事務所查核產業公開發行公司排名_家數
事務所_產業市佔率 排名_營收(上市櫃)	會計師事務所查核產業上市公司排名_營收
事務所_產業市佔率 排名_營收(公發)	會計師事務所查核產業公開發行公司排名_營收
事務所_產業市佔率 排名_資產(上市櫃)	會計師事務所查核產業上市公司排名_資產
事務所_產業市佔率 排名_資產(公發)	會計師事務所查核產業公開發行公司排名_資產
事務所_產業集中度 _家數/客戶家數 %(上市櫃)	會計師事務所查核受查公司所屬產業之上市櫃公司家數， 佔其所有上市櫃客戶比重；公式=會計師事務所查核該公 司所屬產業上市櫃公司家數/會計師事務所全部上市櫃客 戶家數 EX.2009/12 台泥的簽證會計師事務所為勤業眾信，該事 務所共查核水泥業上市櫃公司 5 家，而其所有上市櫃客戶 數為 507 家。故其上市櫃水泥業客戶數佔其所有上市櫃客 戶數之比重(集中度)=5/507=0.99%。
事務所_產業集中度 _家數/客戶家數 %(公發)	會計師事務所查核受查公司所屬產業之公開發行以上公司 營收總和，佔其所有公開發行以上客戶營收比重；公式= 會計師事務所查核該公司所屬產業公開發行以上公司營收 總和/會計師事務所全部公開發行以上客戶營收總和計算 方法同上市櫃公司
事務所_產業集中度 _營收/客戶營收 %(上市櫃)	會計師事務所查核受查公司所屬產業之上市櫃公司營收總 和，佔其所有上市櫃客戶營收比重；公式=會計師事務所 查核該公司所屬產業上市櫃公司營收總和/會計師事務所 全部上市櫃客戶營收總和 EX.2009/12 台泥的簽證會計師事務所為勤業眾信，該事 務所共查核水泥業上市櫃公司之營收總和為 1,473 億，而 其所有上市櫃客戶營收總和為 59,454 億。故其上市櫃水 泥業客戶佔其所有上市櫃客戶營收之比重(集 中)=1,473/59,454=2.48%。
事務所_產業集中度 _營收/客戶營收 %(公發)	會計師事務所查核受查公司所屬產業之公開發行以上公司 營收總和，佔其所有公開發行以上客戶營收比重；公式= 會計師事務所查核該公司所屬產業公開發行以上公司營收 總和/會計師事務所全部公開發行以上客戶營收總和計算 方法同上市櫃公司

事務所_產業集中度_資產/客戶資產%(上市櫃)	會計師事務所查核受查公司所屬產業之上市櫃公司資產總和，佔其所有上市櫃客戶資產比重；公式=會計師事務所查核該公司所屬產業上市櫃公司資產總和/會計師事務所全部上市櫃客戶資產總和 EX.2009/12 台泥的簽證會計師事務所為勤業眾信，該事務所共查核水泥業上市櫃公司之資產總和為 4,130 億，而其所有上市櫃客戶資產總和為 226,789 億。故其上市櫃水泥業客戶佔其所有上市櫃客戶營收之比重(集中)=4,130/226,789=1.82%
事務所_產業集中度_資產/客戶資產%(公發)	會計師事務所查核受查公司所屬產業之公開發行以上公司資產總和，佔其所有公開發行以上客戶資產比重；公式=會計師事務所查核該公司所屬產業公開發行以上公司資產總和/會計師事務所全部公開發行以上客戶資產總和計算方法同上市櫃公司
事務所_產業集中度排名_家數(上市櫃)	會計師事務所查核該公司所屬產業之上市櫃公司家數之所內產業集中度排名 EX.2009/12 台泥的簽證會計師事務所為勤業眾信，該事務所上市櫃水泥業客戶數佔其所有上市櫃客戶數之比重(集中度)為 0.99%。於其所內產業排名為第 22 名。
事務所_產業集中度排名_家數(公發)	會計師事務所查核該公司所屬產業之公開發行以上公司之所內排名_家數
事務所_產業集中度排名_營收(上市櫃)	會計師事務所查核該公司所屬產業之上市櫃公司之所內排名_營收
事務所_產業集中度排名_營收(公發)	會計師事務所查核該公司所屬產業之公開發行以上公司之所內排名_營收
事務所_產業集中度排名_資產(上市櫃)	會計師事務所查核該公司所屬產業之上市櫃公司之所內排名_資產
事務所_產業集中度排名_資產(公發)	會計師事務所查核該公司所屬產業之公開發行以上公司之所內排名_資產
產業上市櫃公司總家數	受查公司所屬產業所有上市櫃公司家數
產業上市櫃公司總營收	受查公司所屬產業所有上市櫃公司總營收
產業上市櫃公司總資產	受查公司所屬產業所有上市櫃公司總資產
產業公開發行公司總家數	受查公司所屬產業所有公開發行公司家數

產業公開發行公司 總營收	查公司所屬產業所有公開發行公司總營收
產業公開發行公司 總資產	受查公司所屬產業所有公開發行公司總資產

