

### 第三章 模型架構與實證結果

#### 第一節 資料

本文研究資料將針對民國 85 年至 93 年間，台灣上市公司發生「違約」與否之公司，而違約之定義為該公司的股票交易是否限定為「全額交割」之公司，而「全額交割」包含：外部人違約、董監事跳票、公司跳票擠兌、破產倒閉、有繼續經營疑慮、被淘空挪用、杼困求援、重整、接管、暫停交易、董事長票跳、謠傳危機、銀行緊縮等十二項。

選出一家違約公司外，我們另外也從上市公司歸類中的相同產業中挑出三家未違約公司以作為配對，而我們將以這些公司的財務報表為樣本資料建構模型，所有財務報表資料是取自於台灣經濟新報（TEJ）資料庫內的資料。

而關於違約公司的財務報表資料的選取，選定違約公司前三年度的財務報表做為違約樣本，例如，大魯閣於 93 年度違約，而我們選取其 90 年至 92 年的年度財務報表資料，而相對應於太魯閣，我們再選出相同產業同一年度的三家公司的財務報表（新紡、新纖、年興）做為對應的樣本資料。

違約樣本總共選取 39 家上市公司，而違約的財務資料則為  $39 \times 3 = 117$ ，未違約樣本為 117 家上市公司，而違約財務資料為  $117 \times 3 = 351$ ，共 468 筆財務資料，其中違約與未違約比例為 1:3，而我們將觀察到的違約樣本定義為 1，非違約樣本定義為 0。

## 第二節 解釋變數基本統計量

我們利用逐步迴歸的方式，將所有財務變數做一篩選，最後我們留下了六個較為顯著的變數，分別為：

$$X_1 = (\text{現金與約當現金}) / \text{總資產}$$

$$X_2 = (\text{營業收入淨額}) / \text{總資產}$$

$$X_3 = (\text{利息支出}) / \text{總資產}$$

$$X_4 = (\text{稅前息前淨利}) / \text{總資產}$$

$$X_5 = (\text{融資活動淨現金流入}) / \text{總資產}$$

$$X_6 = \text{TCRI 信用評等}$$

本研究 and Z-Score 模型相較之下，共同使用了稅前息前淨利/總資產，其餘變數皆不相同，而本研究利息支出解釋變數的概念和 Zeta 中的利息保障倍數一樣，現金與約當現金解釋變數和 Z-Score 中的營運資金、Zeta 的流動比率也有相關，而融資活動淨現金流入以及 TCRI 信用評等此二項解釋變數則是另外兩個模型所沒有的。

這個六個變數中，我們預期現金及約當現金、營業收入淨額、稅前息前淨利越高越不容易倒閉，而利息支出、融資活動淨現金流入與 TCRI 信用評等越高則易倒閉，而由【表 3-1】違約下-解釋變數基本統計量、【表 3-2】未違約下-解釋變數基本統計量中也可看出，違約下的觀察值中，現金及約當現金、營業收入淨額、稅前息前淨利的平均數皆較未違約下觀察值的平均數低，而利息支出、融資活動淨現金流入以及 TCRI 信用評等皆較未違約下觀察值的平均數高。

【表 3-1】為違約下六個解釋變數基本統計量，我們可以看出財務變數中以營業收入淨額的觀察值差異性最大，而利息支出觀察值的差異性最小，非財務變數的 TCRI 信用評等因為沒有除以總資產，故表上的標準差為 1.782657，高出其他變數，但觀察值也有出現 TCRI 信用評為 2 但是該觀察值卻是違約的情形。

【表 3-2】為未違約下六個解釋變數基本統計量，其中財務變數中以營業收

入淨額的觀察值差異性最大，而利息支出觀察值的差異性最小，非財務變數的 TCRI 信用評等因為沒有除以總資產，故表上的標準差為 2.3296781.782657，高出其他變數，而 TCRI 信用評最大值為 10 但是該觀察值卻未違約。

【表 3-1】違約下-解釋變數基本統計量

變數名稱	觀察個數	平均數	標準差	最小值	最大值
違約	117	1	0	1	1
現金與約當現金 /總資產	117	0.045	0.065	0.000	0.397
營業收入淨額 /總資產	117	0.462	0.352	0.007	2.015
利息支出/總資產	117	0.021	0.011	0.000	0.065
稅前息前淨利 /總資產	117	-0.039	0.141	-0.855	0.191
融資活動淨現金流 入/總資產	117	0.050	0.270	-2.340	0.730
TCRI 信用評等	117	7.649	1.782	2	10

【表 3-2】未違約下-解釋變數基本統計量

變數名稱	觀察個數	平均數	標準差	最小值	最大值
未違約	351	0	0	0	0
現金與約當現金 /總資產	351	0.059	0.071	0.000	0.474
營業收入淨額 /總資產	351	0.680	0.506	0.033	3.654
利息支出/總資產	351	0.010	0.009	0.000	0.046
稅前息前淨利 /總資產	351	0.046	0.076	-0.472	0.274
融資活動淨現金 流入/總資產	351	0.039	0.123	-0.385	0.459
TCRI 信用評等	351	5.299	2.329	1	10

【圖 3-1】到【圖 3-6】為各解釋變數在違約與不違約下的直方圖來，我們可觀察直方圖來了解各解釋變數的觀察值的分佈情形；在【圖 3-1】（現金與約當現金/總資產）直方圖中，可明顯看出不管是違約或者未違約的觀察樣本中，分配皆出現右偏的情形，但是未違約的現金與約當現金解釋變數的樣本平均數相較於違約樣本平均數高。



【圖 3-2】（營業收入/總資產）的直方圖中，違約與未違約樣本皆有集中趨勢的現象，但是違約樣本的眾數在 0.25，而未違約樣本在 0.45，未違約樣本的平均數高於違約樣本。

【圖 3-3】（利息支出/總資產）直方圖中可明顯看出，在違約樣本中利息支出佔總資產的比例的平均數高於未違約樣本，在違約樣本中利息支出佔總資產的比例絕大部分超過 0.0005，而未違約樣本中小於等於 0.0005 的樣本數為其眾數。



【圖 3-4】（稅前息前淨利/總資產）直方圖中，未違約樣本的稅前息前淨利明顯高於違約樣本，且都有集中趨勢的現象。

【圖 3-5】為（融資活動淨現金流入/總資產）直方圖，而就未違約樣本的平均數低於違約樣本的平均數。【圖 3-6】為 TCRI 信用評等指標，該指標最大為 10，最小為 1，指標越大越容易違約，指標越小則越不容易違約，同樣違約樣本的分佈較集中於右邊，而未違約樣本則略往左邊集中。



【圖 3-1】違約與未違約下(現金與約當現金/總資產) 直方圖





【圖 3-2】違約與未違約下(營業收入/總資產) 直方圖



【圖 3-3】違約與未違約下(利息支出/總資產) 直方圖





【圖 3-4】違約與未違約下(稅前息前淨利/總資產) 直方圖

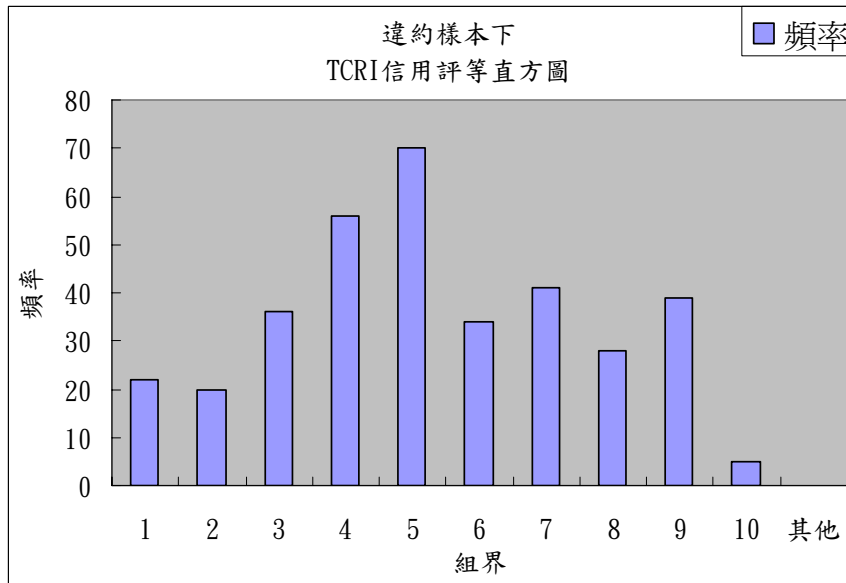





【圖 3-5】違約與未違約下(融資活動淨現金流入/總資產)直方圖



【圖 3-6】違約與未違約下(TCRI 信用評等/總資產) 直方圖



### 第三節 Logit 模型實證估計結果

本研究利用上述六個變數建構 Logit 模型，而實證結果如【表 3-3】Logit 實證結果，我們發現此六項解釋變數皆低於或相當於顯著水準 0.05 的標準，其中符號方向的判定上，營業收入淨額與稅前息前淨利的估計係數的正負符號和我們一開始預期的結果相同，即是營業收入越高或稅前息前淨利越高則該公司將越不容易違約，而利息支出、融資活動淨現金流入、TCRI 信用評等此三項解釋變數的估計係數的正負號也和我們一開始預期相同，即利息支出越高、融資活動淨現金流入越高、TCRI 信用評等指標越高、則該公司越容易違約。

而現金與約當現金此項解釋變數的估計係數之正負號卻與我們一開始預估相反，我們以為此解釋變數越高，則該公司的還款能力越佳，則違約風險越低，但是實證結果顯示該解釋變數越高則該公司越有可能違約，而這其中的原因是因為該公司未將資金妥善運用，或有其他因素，需要再多做探討。

【表 3-3】Logit 實證結果

變數名稱	估計係數	標準差	T 值
常數項	-4.216	0.708	-5.950
$\frac{\text{現金與約當現金}}{\text{總資產}}$	6.354	2.293	2.770
$\frac{\text{營業收入淨額}}{\text{總資產}}$	-0.828	0.424	-1.948
$\frac{\text{利息支出}}{\text{總資產}}$	70.420	14.330	4.914
$\frac{\text{稅前息前淨利}}{\text{總資產}}$	-3.688	1.745	-2.113
$\frac{\text{融資活動淨現金流入}}{\text{總資產}}$	1.968	0.726	2.710
TCRI 信用評等	0.316	0.085	3.689

#### 第四節 Binary Regression Quantiles 估計結果

再建構 Logit 模型之後，我們利用相同的六項變數，現金與約當現金/總資產、營業收入/總資產、利息支出/總資產、稅前息前淨利/總資產、融資活動淨現金流入/總資產以及 TCRI 信用評等等六項變數，來建構 Binary Regression Quantiles 模型，我們將模型設定成九個分量，分別為百分之十、百分之二十、百分之三十、百分之四十，一直到百分之九十。而各個解釋變數在不同分量的顯著性不同，【表 3-4】為各個解釋變數在不同分量的係數值與標準差，係數中下方括號內為標準差。

【表 3-4】各個不同分量下解釋變數的係數值與標準差


分量	截距項	現金與約當現金	營業收入	利息支出	稅前息前淨利	融資活動淨現金流入	TCRI 信用評等
0.1	-0.497 (0.562)	1.894 (0.232)	1.582 (0.389)	-0.153 (0.902)	-0.988 (0.368)	1.966 (0.470)	0.182 (0.046)
0.2	1.580 (0.192)	1.972 (0.735)	0.917 (0.445)	-0.893 (1.104)	-0.955 (0.235)	1.963 (0.685)	-0.049 (0.063)
0.3	1.160 (0.630)	0.794 (0.550)	0.107 (0.666)	-0.771 (1.003)	-0.877 (0.694)	1.994 (0.708)	0.094 (0.068)
0.4	1.007 (0.779)	0.320 (0.891)	0.157 (0.763)	0.079 (0.812)	0.358 (0.704)	1.466 (0.872)	0.136 (0.132)
0.5	1.537 (0.937)	0.932 (0.688)	-0.013 (0.777)	0.039 (0.733)	-0.865 (0.833)	1.726 (0.706)	0.048 (0.197)
0.6	-0.264 (0.411)	0.714 (0.771)	-0.313 (0.712)	0.807 (1.054)	-0.002 (0.989)	1.708 (0.765)	0.742 (0.102)
0.7	-0.869 (0.307)	-0.987 (1.009)	-0.999 (0.582)	-0.726 (0.910)	-0.593 (0.841)	1.886 (0.862)	1.143 (0.236)

0.8	-0.978 (0.123)	-0.729 (0.933)	-0.995 (0.145)	1.461 (0.799)	-0.973 (0.282)	-0.329 (0.956)	1.583 (0.118)
0.9	-0.958 (0.079)	-0.979 (0.774)	-0.464 (0.361)	-0.011 (0.835)	-0.672 (0.141)	1.768 (1.149)	1.536 (0.061)


為了更清楚地看出解釋變數的在不同分量下的訊息，我們將係數與信賴區間製作成圖形。【圖 3-7】為現金與約當現金/總資產分量係數圖、【圖 3-8】為營業收入/總資產分量係數圖、【圖 3-9】為利息支出/總資產分量係數圖、【圖 3-10】為稅前息前盈餘/總資產分量係數圖、【圖 3-11】為融資活動淨現金流入/總資產分量係數圖、【圖 3-12】為 TCRI 信用評等指標分量係數圖、【圖 3-13】為截距項係數在各分量的值。其中橫軸代表 0.1 至 0.9 各個不同分量，縱軸代表係數值，而圖中實現的部分為係數的在各個不同分量時的連結，而以上及以下的虛線是以百分之九十的信賴水準所建構出來的區間。

其中，現金與約當現金解釋變數中，在 0.1 至 0.3 以及 0.5 分量時為顯著的，營業收入解釋變數在 0.1、0.2 分量以及 0.7 至 0.9 分量為顯著的，利息支出解釋變數只有在 0.8 分量時為顯著，稅前息前淨利解釋變數在 0.1 至 0.3 分量以及 0.8、0.9 分量為顯著的，融資活動淨現金流入解釋變數除了在 0.8 分量不顯著外，其餘分量都是顯著的，而 TCRI 信用評等指標在 0.3 分量以及 0.6 分量之後皆為顯著，截距項的部分除了 0.1 以及 0.6 分量外，其餘分量下皆是顯著的。


【圖 3-7】現金與約當現金分量係數圖




【圖 3-8】營業收入分量係數圖




【圖 3-9】利息支出分量係數圖



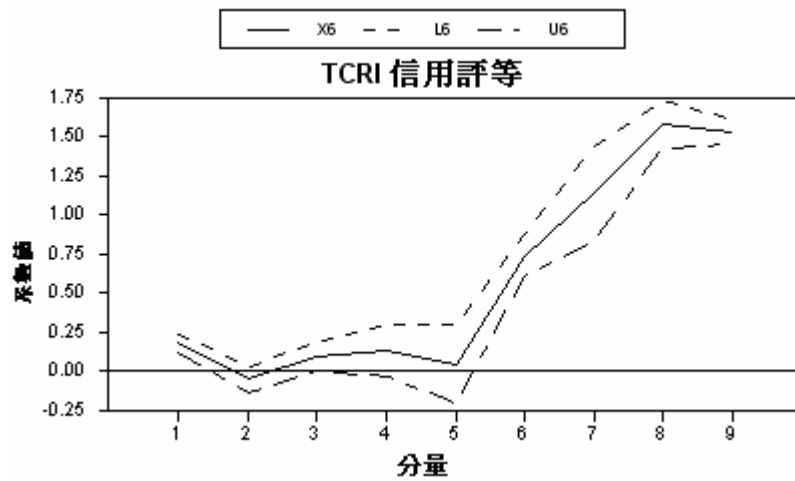
【圖 3-10】稅前息前淨利分量係數圖




【圖 3-11】融資活動淨現金流入分量係數圖



【圖 3-12】TCRI 信用評等指標分量係數圖



【圖 3-13】截距項 分量圖





## 第五節 預測效力比較

我們試圖利用第二章第二節第四點所介紹的 ROC 以及 CAP 曲線作為比較的方法，將 Logit 模型和 Binary Regression Quantiles 模型的預測解釋做一比較。而我們將以兩個方式對兩種模型做比較：

1. 將 Binary Regression Quantiles 中所計算出每一分量的係數和 Logit 模型單獨比較。
2. 我們將使用美國學者 Kordas (2004) 的方法，關於如何將 Binary Regression Quantiles 模型中所計算出的係數應用在解釋預測上的方法和 Logit 做一比較。

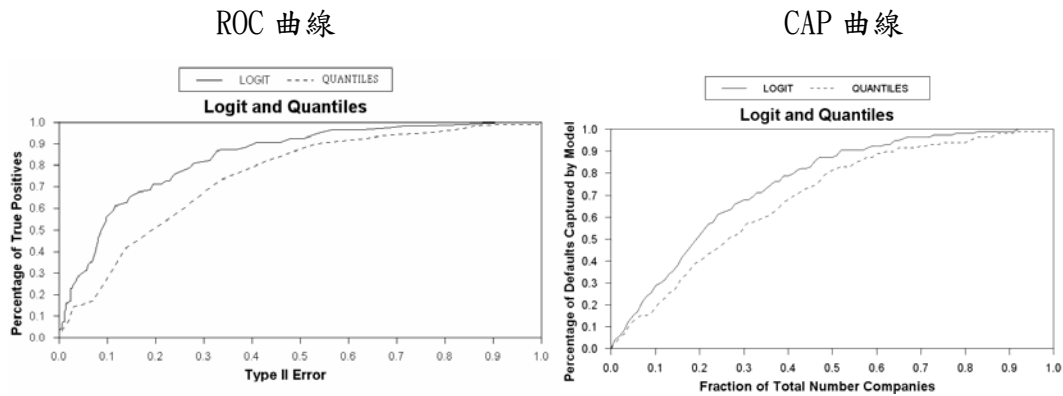
首先，我們針對不同分量的係數和 Logit 模型做 ROC 以及 CAP 曲線的比較：

【圖 3-14】為 Binary Regression Quantiles 在 0.1 分量時和 Logit 模型做的比較，其中實線部分為 Logit 模型所畫出之 ROC 及 CAP 曲線，需線部分為 Binary Regression Quantiles 所畫出之 ROC 及 CAP 曲線，而在 ROC 及 CAP 曲線的比較中越往左上方則代表此模型在不同的截斷點下的預測力越佳，我們也可以整個圖形面積為分母，而曲線所包含的面積為分子，如此計算出的數值越接近 1 則代表此曲線越佳，而在 ROC 曲線的部分 Logit 模型為 0.83941，Binary Regression Quantiles 為 **0.57637**，CAP 曲線的部分 Logit 模型為 0.75373，Binary Regression Quantiles 為 **0.55746**。Binary Regression Quantiles 在 0.1 分量下的預測解釋能力不如 Logit 模型佳。



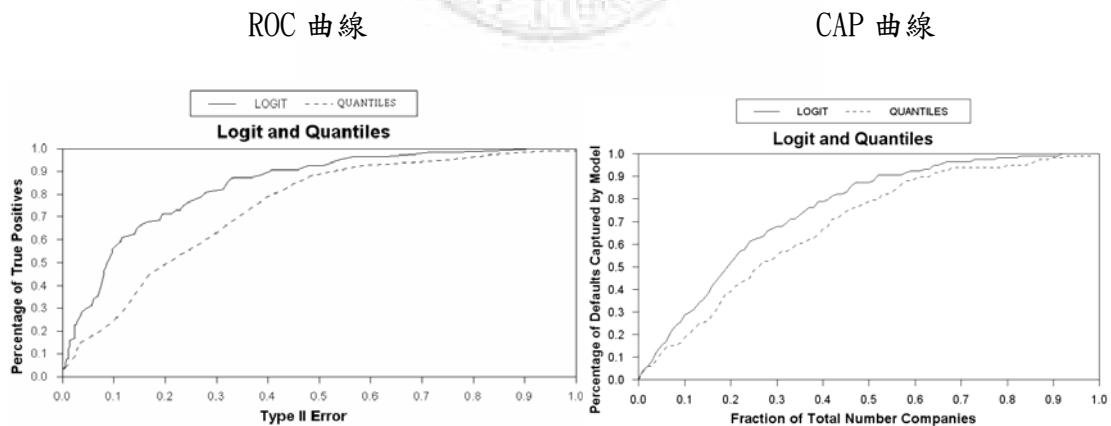
能力。

【圖 3-16】 Binary Regression Quantiles 在 0.3 分量下與 Logit 的比較



【圖 3-17】 ROC 與 CAP 曲線在 Binary Regression Quantiles 為 0.4 分量時與 Logit 的比較，其中在 ROC 曲線中 Logit 包含的面積比例為 0.83941，Binary Regression Quantiles 為 **0.74081**，CAP 曲線中 Logit 包含的面積比例為 0.75373，Binary Regression Quantiles 為 **0.68508**，Binary Regression Quantiles 在 0.4 分量下的預測解釋能力接近了 Logit 模型。

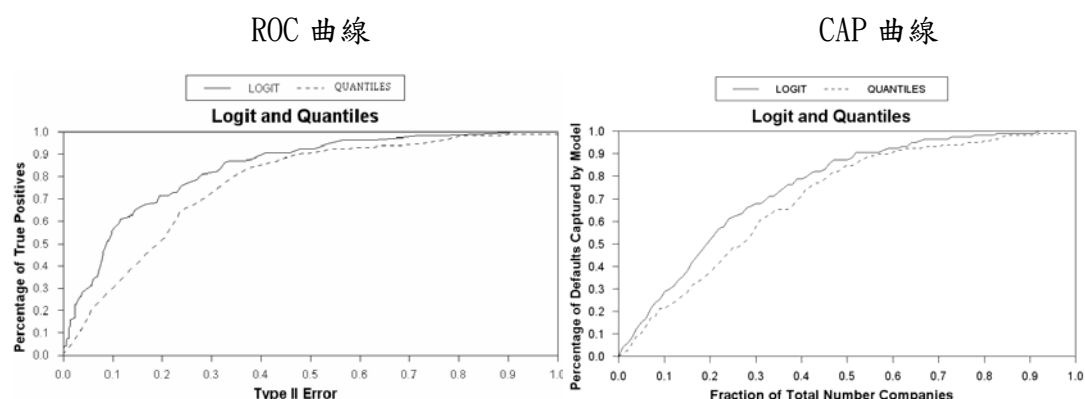
【圖 3-17】 Binary Regression Quantiles 在 0.4 分量下與 Logit 的比較



【圖 3-18】 ROC 與 CAP 曲線在 Binary Regression Quantiles 為 0.5 分量時與 Logit 的比較，其中在 ROC 曲線中 Logit 包含的面積比例為 0.83941，Binary Regression Quantiles 為 **0.76951**，CAP 曲線中 Logit 包含的面積比例為 0.75373，Binary Regression Quantiles 為 **0.70237**，Binary Regression

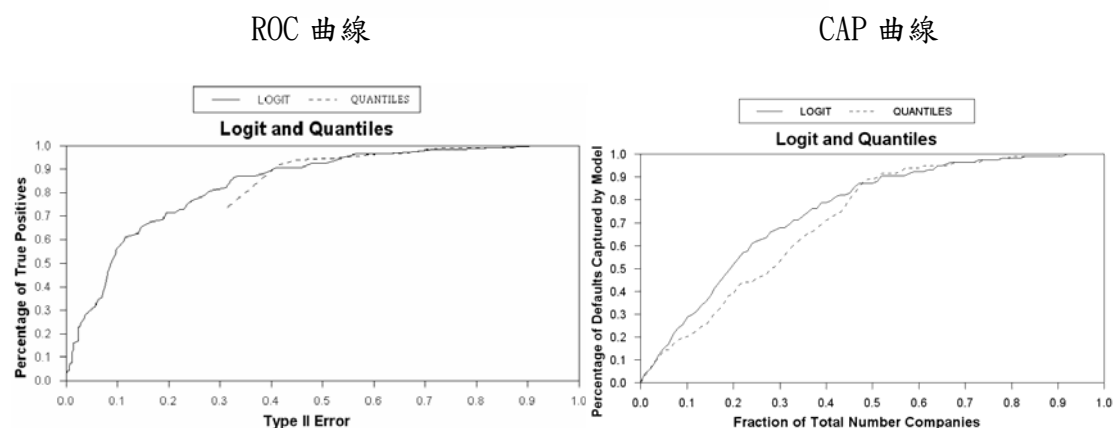
Quantiles 在 0.5 分量下的預測解釋能力和 Logit 模型相差了大約 0.06。

【圖 3-18】 Binary Regression Quantiles 在 0.5 分量下與 Logit 的比較



【圖 3-19】 ROC 與 CAP 曲線在 Binary Regression Quantiles 為 0.6 分量時與 Logit 的比較，其中在 ROC 曲線中 Logit 包含的面積比例為 0.83941，Binary Regression Quantiles 為 **0.65282**，CAP 曲線中 Logit 包含的面積比例為 0.75373，Binary Regression Quantiles 為 **0.71483**，Binary Regression Quantiles 在 0.6 分量下的預測解釋能力中 ROC 曲線比 0.5 還要差，CAP 曲線更接近了 Logit 水準。


【圖 3-19】 Binary Regression Quantiles 在 0.6 分量下與 Logit 的比較



【圖 3-20】 ROC 與 CAP 曲線在 Binary Regression Quantiles 為 0.7 分量時與 Logit 的比較，其中在 ROC 曲線中 Logit 包含的面積比例為 0.83941，Binary

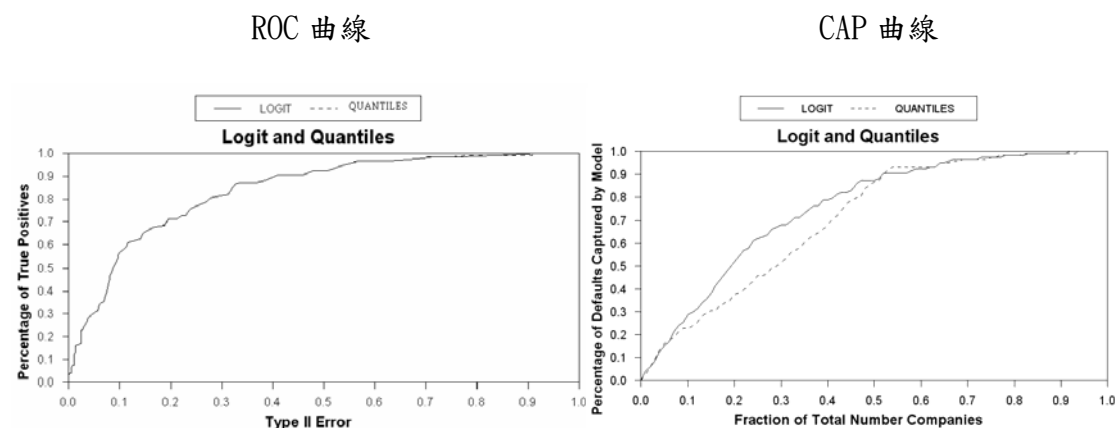
Regression Quantiles 為 **0.64573**，CAP 曲線中 Logit 包含的面積比例為 0.75373，Binary Regression Quantiles 為 **0.71585**，Binary Regression Quantiles 在 0.7 分量下的預測解釋能力中 ROC 曲線比 0.6 還要差，CAP 曲線更接近了 Logit 水準。

【圖 3-20】Binary Regression Quantiles 在 0.7 分量下與 Logit 的比較



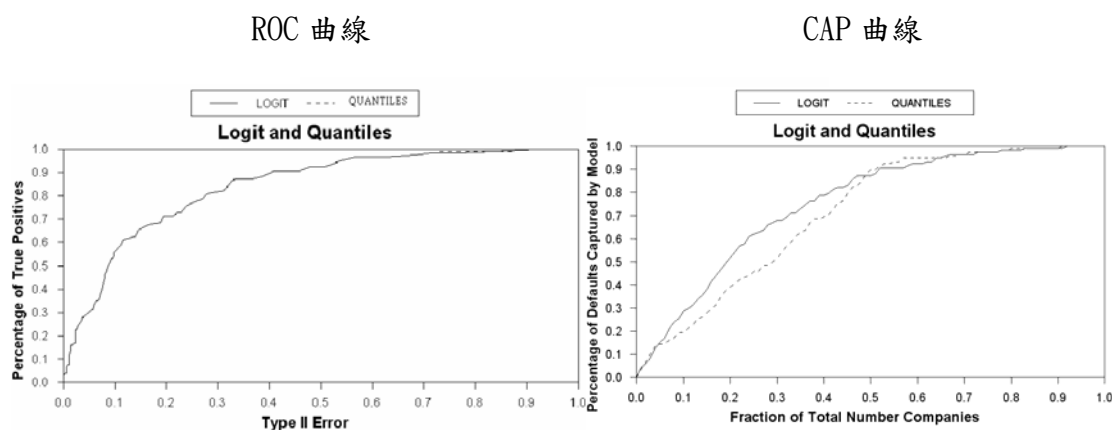
【圖 3-21】ROC 與 CAP 曲線在 Binary Regression Quantiles 為 0.8 分量時與 Logit 的比較，其中在 ROC 曲線中 Logit 包含的面積比例為 0.83941，Binary Regression Quantiles 為 **0.29571**，CAP 曲線中 Logit 包含的面積比例為 0.75373，Binary Regression Quantiles 為 **0.71585**，Binary Regression Quantiles 在 0.8 分量下的預測解釋能力在 ROC 曲線中十分低，CAP 曲線仍維持 0.7 的水準。

【圖 3-21】Binary Regression Quantiles 在 0.8 分量下與 Logit 的比較



【圖 3-22】ROC 與 CAP 曲線在 Binary Regression Quantiles 為 0.9 分量時與 Logit 的比較，其中在 ROC 曲線中 Logit 包含的面積比例為 0.83941，Binary Regression Quantiles 為 **0.26810**，CAP 曲線中 Logit 包含的面積比例為 0.75373，Binary Regression Quantiles 為 **0.71297**，Binary Regression Quantiles 在 0.9 分量下的預測解釋能力在 ROC 曲線中甚至較 0.8 分量時還低，CAP 曲線仍維持 0.7 的水準。

【圖 3-22】Binary Regression Quantiles 在 0.9 分量下與 Logit 的比較



由以上九個分量，在個別以 0.1 至 0.9 分量係數下所做的預測，0.5 分量的係數是所有分量係數中，以 ROC 以及 CAP 的信用風險模型驗證最有效率的。

接著我們運用 Grigorios Kordas(2004)的方法，來計算 Binary Regression Quantiles 所預測的違約機率，以及該方法在 ROC 以及 CAP 的信用風險模型驗證。我們假設在一個可觀察的二元出象的變數為  $y$ ，例如違約與不違約的二元結果，而  $y$  是假設由可觀察到的一個隨機向量  $x$  所決定，而假設  $x \in R^k$ ，除了  $x$  的影響外， $y$  也受到無法觀測的分配  $u$  所影響，假設  $u \in R^1$ ，而一組  $(x, u)$  透過線性方程式影響  $y$ ，該方程式設定如下：

$$y^* = x' \beta + u \quad (1)$$

(1)式中， $\beta$  為一  $k \times 1$  的參數向量。而我們再設定以下方程式：

$$y = 1\{x' \beta + u \geq 0\} \quad (2)$$

(2)式中， $1\{A\}$ 為一 A 事件發生與否的指示函數，如果指示函數等於 1 代表 A 發生，如果指示函數等於 0，則代表 A 事件沒有發生。

在經濟的應用上， $y$  是個人兩個選擇下  $\{1, 0\}$  可觀察到的效用極大函數，(1)式中的  $y^*$  是個人選擇 1 或選擇 0 的效用函數相減的結果， $y^* = V^1 - V^0$ 。即  $y^* \geq 0$  則代表  $y=1$ ，相反  $y^* \leq 0$  則代表  $y=0$ 。

對於每個  $x \in X$ ， $\{y=1\}$  該事件的機率為  $P_{1|x} \equiv \Pr(y=1|x)$ ，即

$$P_{1|x} = \int 1\{\beta x + u \geq 0\} dF_{u|x} \quad (3)$$

(3)式中， $F_{u|x}$  為在已知  $x$  的條件下， $u$  的分配函數。而這也是我們有興趣的機率值，假設  $\tau$  代表不同分量，我們將(3)式改寫為：

$$P_{1|x} = \int_0^1 1\{x' \beta(\tau) \geq 0\} d\tau \quad (4)$$

在不影響正負號下，我們將各分量的係數標準化，將  $\beta(\tau)$  以  $\beta(\tau) / \|\beta(\tau)\|$  取代，(4)式可寫為：

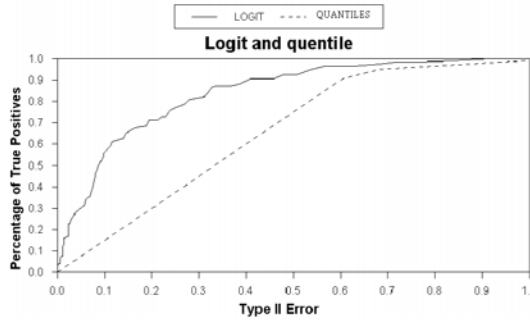
$$\hat{P}_{1|x} = M^{-1} \sum_{m=1}^M 1\{x' b_N(\tau_m) / \|b_N(\tau_m)\| \geq 0\} \quad (5)$$

(5)式中的  $b_N(\tau_m) / \|b_N(\tau_m)\|$  為標準化的 Binary Regression Quantiles 係數估計值，而總共有  $m$  個分量。我們將使用(5)式做為違約估計值的計算，將〈表 3.3〉各分量係數的估計結果代入(5)式，且計算出各個觀察值的違約機率，我們將此結果製作 ROC 以及 CAP 曲線圖，並與 Logit 方法作一比較。

【圖 3-23】ROC 與 CAP 曲線中需線的部分為利用 Grigorios Kordas(2004)的方法，也就是(5)式中所計算的違約預測值下所畫出的，與 Logit 實線的部分做一比較。其中在 ROC 曲線中 Logit 包含的面積比例為 **0.83941**，Binary Regression Quantiles 為 **0.65475**，CAP 曲線中 Logit 包含的面積比例為 **0.75373**，Binary Regression Quantiles 為 **0.52212**，Binary Regression Quantiles 在(5)式計算出違約機率的預測值，在 ROC 以及 CAP 的驗證下明顯不如傳統 Logit 來的佳。

【圖 3-23】 Binary Regression Quantiles 之 ROC 以及 CAP 曲線圖

ROC 曲線



CAP 曲線

