



企業診斷與績效評估： 平衡計分卡的運用

第五章

企業危機預警數學模式

陳澤義與陳啟斌教授著

華泰圖書文化 民國95年1月

種一種行爲，收一種習慣；種一種習慣，收一種性格；種一種性格，收一種命運。--- **George D. Boardman**

引言

企業經營一如電腦運作，企業爆發危機有如電腦當機與掛點，企業危機預警之一即組織作業效率低落，此有如電腦的執行速度緩慢。

茲有一部電腦的執行速度突然變得十分緩慢，這個「徵候」乃是電腦當機的前兆，也就是電腦危機透過執行速度遲緩來預警，今透過有系統的分析(例如案例推理法)，可知原因(病因)不外乎電腦被病毒感染而中毒；**window**作業系統損壞；某一作業軟體(例如：**office**或**powerpoint**)本身的功能受損或喪失；硬碟磁軌壞軌等因素。

至於檢修途徑則是對症下藥，即進行掃毒與解讀作業；修復、更新或重裝**window**作業系統；修復或重灌某一作業軟體；硬碟磁軌檢查測試及復原等。是以有效的預警模型，除可用來預測危機的發生，亦可用來分析問題(病因)的類型，進而可循線界定出解決方案的途徑。



企業危機預警數學模式

- 瞭解建立財務危機預警模式之理由。
- 瞭解一般化線性模式。
- 瞭解案例推理法。
- 瞭解類神經網路。
- 瞭解灰關聯分析。

建立財務危機預警模式之理由

改善財務危機預警能力，不僅有助於企業經營管理，也對投資者的投資決策及政府金融市場的管理極有參考的價值。

- 改善財務危機預警能力的優點

項目	優點
1	提供受評標的之信用風險資訊
2	降低金融機構之徵信成本
3	降低融資企業的資金成本
4	促使企業改善其本身體質
5	可提高金融管理效率
6	保障投資人的權益

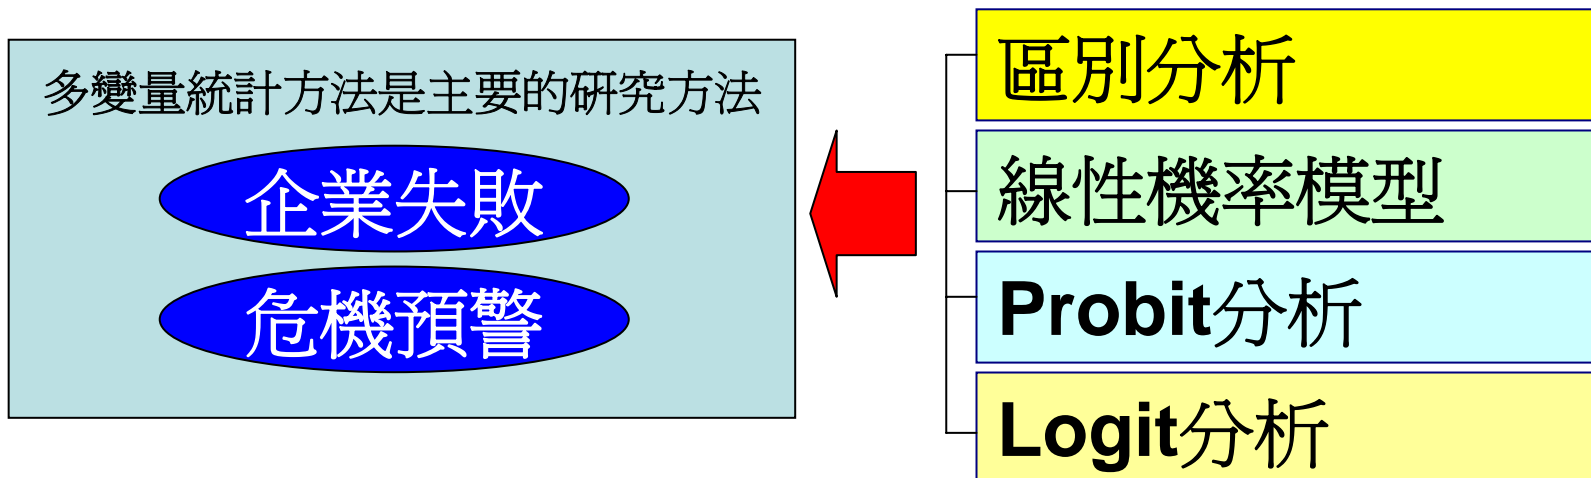
建立財務危機預警模式之理由 (續)

企業績效評價，是指對企業資本營運效益和經營者業績評估的簡稱。

- 它需要綜合運用數理統計學、經濟計量學、經濟學、會計學、財務管理學、工商管理學等多學科的理論與方法，採用市場經濟下通用的企業經營考核指標體系，參照預先測算的行業標準值，對企業一定經營期間資本營運效益和經營者業績，進行全面和科學的定性定量分析，俾進行準確的綜合評價。
- 在企業財務危機的預警方面，立面分析、概率模型、小企業模型、範式確認等為常見模式，其中又以F預警模型和Z預警模型較具有代表性。

建立財務預警之目的

- 係在於偵測企業尚未發生危機之前，即顯示出未來可能產生的經營失敗情勢。預測企業經營成敗的研究始於**1930**年，係採用單變量分析，而至**Altman (1968)**始將多變量統計技術，應用在企業失敗預測模式之領域，開始運用多變量分析方法，來發展並檢定預警模型，俾便分類與預測。





一般化線性模式 (基本迴歸分析)

一、一般迴歸分析

- 經常會發現許多事物與現象是相互聯繫，某一事物或現象的變化，會影響其他事物或現象的變化。
- 反應變數(Y)同時會受到兩個或兩個以上自變數(X_1 、 X_2 、...)的影響。
- 研究這類多變數之間的關係，常用多元線性迴歸模型分析方法，在固定 X_i 之下，隨機抽取 Y_i ， $i = 1, 2, \dots, n$ ，則機率模型便為如下所示：
- $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_{k-1} X_{i, k-1} + \varepsilon_i$
- 咸假設 ε_i 為常態分配 $N(0, \sigma^2)$ ，且彼此獨立。



一般化線性模式 (基本迴歸分析)

二、卜阿松迴歸

- 卜阿松迴歸(**Poisson regression**)模型稱爲對數線性模型(**loglinear model**)，這種線性模型使用對數連結函數(**Log link function**)。主要使用於反應變數爲間斷型資料。
- 卜瓦松迴歸的應用是根據在某一段時間內已發生的次數，而以此資訊來推估未來時間發生的行爲。
- 以銀行的信用卡客戶爲例，根據某位顧客在過去一段時間內所刷卡的比例和消費金額，用來推算該顧客未來的消費行爲和信用卡的使用機率，如此便可預估該顧客對其刷卡銀行的價值。

一般化線性模式 (單變量分析)

- 以單一的變數(如財務比率)來作為分析的指標。利用單變量分析個別財務比率，可找出最佳的取捨點，使得特定樣本其正確分類數達到極大化。採用單變數法的步驟如下：

1. 確定發生財務危機的企業群體。
2. 根據該群企業找出與之相同產業、類似規模大小的正常企業作為樣本資料。
3. 蒐集財務危機企業與正常企業的財務比率資料。
4. 利用二元分類檢定法(dichotomous classification test)，將財務比率資料依不同的年度按照大小次序排列，並從中找出一個使分類誤差百分比最小的分割點。
5. 用這些分割點做標準來對樣本外的期間做預測。



一般化線性模式 (單變量分析)

- 運用單變量分析方法的缺點：

1. 不同的財務比率可能會對同一企業有互相矛盾的預測，難以做出正確的判斷。
2. 可能會發生某一財務比率單獨考慮時區別不顯著，但和其他財務比率一併考慮時，卻發生極大解釋能力的現象。
3. 企業財務狀況極不可能以單一財務比率就可完全掌握。
4. 未考慮變數變異程度。
5. 未能獲知所有變數間的相關程度。

一般化線性模式(多變量分析)

- 企業的財務狀況經常是難以用單一變數就能全部掌握，企業經營績效應綜合多項財務指標來衡量，較具客觀性。多變量法係指同時加入多個自變數於預測模式當中，來做為預測的指標，特稱為多變量區別分析法(**multiple discriminant analysis, MDA**)。

區別分析(discriminant analysis)是早期最常使用的信用評等方法，其主要是根據樣本的特性，將樣本一一歸類於數個事前群組中的某一個群組，並依據樣本值建立區別函數，以區別函數值來對樣本進行分類，可找出各企業違約可能性之高低加以評分。

多變量法區別分析

- 採用多變量法區別分析的步驟如下：

1. 確定發生財務危機的企業群體。
2. 根據該群企業找出與之相同產業、類似規模大小的正常企業做配對樣本。
3. 以某一年度財務資料與非財務資料作為自變數。
4. 利用因素分析(**factor analysis**)或逐步(**stepwise**)的方式找出彼此之間為獨立而且具有代表性的參數作為自變數，將這些自變數納入區別函數之中。

多變量法區別分析 (續)

5. 建立一條類似迴歸方程式的區別函數，而得到一綜合性的指標，稱之為「Z分數」。將原始配對的樣本資料代入區別函數，即可得到不同企業的**Z**值，依照二分類檢定法的方式找出使分類誤差最小的**Z**值分割點。

6. 用這些分割點做標準來對樣本外的期間做預測。

區別函數的基本形式如下：

$$Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$$

其中**Z** < **Z*** 為問題企業、**Z** > **Z*** 為正常企業、**Z***為分割點。而在建立區別模式時，應該盡量使不同企業間的變異為最大，使相同企業間的變異為最小。

多變量法區別分析 (續)

- 區別分析的優點為：

- (1) 可同時考慮多項財務指標。
- (2) 較能衡量企業整體之績效。
- (3) 可找出具區別能力之財務比率。

區別分析的缺點為：

- (1) 區別分析變數需符合常態假設，而財務比率並不符合。
- (2) 分析結果，僅能做程度高低排列。
- (3) 模型無法處理非線性情況。
- (4) 不能有效處理非量化變數。
- (5) 變數須先標準化。
- (6) 變數選取無一套理論基礎，可能導致變數選擇的偏差，對分類能力會造成影響。

一般化線性模式 (線性機率模型)

在迴歸分析法的模型中，常用的屬質因變數的模型有二元**Probit (波比)**和**Logit (羅吉斯)**模型兩種。

- 其非線性機率累積函數形式，可以解決線性機率模式其機率值，會落在 $[0, 1]$ 之外的問題，模式的係數估計採用最大概似估計法(**maximum likelihood method**)，經過重複測試達到一致性，可以處理非常態性的資料分類。
- 這兩種模型的因變數都是屬於離散性型態 (**discrete type**)，也就是說因變數為**0** (事件不發生)或**1** (事件發生)，然後在統計處理的過程中將原來的模型轉換成發生機率的模型，並且進一步求出事件發生的機率。

一般化線性模式 (線性機率模型)

- 此時為屬質因變數之特殊迴歸模型，應變數為二分類變數，設立為0與1，並以最小平方法來估計模型參數，其可解決自變數非常態之問題，且模型使用時不須資料轉換，容易使用；缺點為只能應用二分類選擇問題，且模型所產生之估計值常落於0與1之外，不符合機率理論。

• 爲了改善線性機率模型之估計值可能落於0與1之外的缺失，後續學者便假設事件發生的機率服從某種累積機率分配，使模型產生之估計值會落在0與1之間。



一般化線性模式 (線性機率模型)

- 目前最常應用的累積機率分配為**Logistic**與標準常態分配。

若事件發生的機率服從累積標準常態分配，則稱為**Probit**模式。

若事件發生的機率服從累積**Logistic**分配，則稱為**Logit**模式。

線性機率模型

一、二元Probit模型

- 為解決線性機率模型不符合機率假設之問題，**Kaplan, and Urwitz (1979)**假設事件發生的機率服從標準常態分配，且採累加機率來進行轉換，此稱為**Probit**模型，可由此模式求出企業違約之機率，給予評分。

Probit模型係在進行二元分類獨立變數 (**dichotomous dependent variable**)的統計分析時，通常必須選擇最合適的累積機率分配(**CDF**)。



線性機率模型 (續)

- 目前使用最廣泛的是**Logit**模型，如果樣本資料符合常態性分配，**Probit**模型會是比较好的選擇，**Probit** 模型如下：

$$li = \beta 1 + \beta 2 Xi$$

$$Pi = Pr(Y=1) = Pr(li^* \leq li) = F(li) = e^{-2 dt}$$

其中 Pi ：代表事件發生的機率， Pr 是機率值， Xi 為自變數， $t \sim N(0,1)$ 。

線性機率模型 (續)

- **Probit**模式優點為：
 - (1)可解決自變數非常態的問題。
 - (2)所求得之機率值落於**0**與**1**之間。
 - (3)模型可適用於非線性的情況。

Probit模式之缺點為：
模型的轉換程序較為複雜，因此過去研究多以**Logit**模型居多。

線性機率模型 (續)

二、二元Logit模型

- 二元**Logit**模型主要使用於因變數是二元性資料，例如「成功」或「失敗」。

Probit和**Logit**兩種模型的差異就在於，**Probit**模型假設事件發生的機率符合標準常態假設。

Logit模型假設事件發生的機率符合**Logistic**分配。在實證上，**Logit**模式資料處理較為容易，成本較低，故大都採用**Logit**模式進行分析。

線性機率模型 (續)

Logit 分析法主要迴歸模式爲：

- $Y_i = \beta_0 + \beta_j X_{ij} + e_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + e_i$
- 其中 X_{ij} 爲自變數， $i = 1, 2, 3, \dots, n$ ， $j = 1, 2, 3, \dots, k$ 。 β_j 爲參數、 e_i 爲干擾項， $E(e_i) = 0$ 。

• **Logit**模型的基本形式和**Probit**模型相同，差異僅在於累加機率分配函數爲**Logistic**函數，和**Probit**模式一樣是屬質因變數迴歸模型的一種，因變數均互爲分立，均可以求出企業違約之機率，來加以評分。

線性機率模型 (續)

- **Logit**模型之優點為：

可解決自變數非常態的問題、所求得之機率值落於**0**與**1**之間、模型可適用於非線性的情況，均和**Probit**模式一致，且其實證效果大都優於**Probit**模式。

Logit模型之缺點為：
須經轉換步驟才能求得機率值，重要的是切割點的決定會影響到整個模式的預測能力。

線性機率模型 (續)

•二元Logit模型

- **Logit**模型在反應變數為離散型，且分類只有兩類或少數幾類時，便成了一個最標準的分析方法。
- **Logit**模型在運用上已極為普遍，不但對於二元化的離散型資料使用率高，在**Logistic**分布之下，不但可運用在單變量迴歸模型，也可推廣至多變量迴歸模型。

•由於**Logit**迴歸和迴歸分析中最大的差別，在於反應變數形態的不同，故**Logit**迴歸在運用上也須符合傳統迴歸分析的一般假設，也就是避免解釋變數之間共線性的問題，及符合常態分配和避免殘差存在自我相關等的統計基本假設。

各種財務危機預警模式常用之統計方法比較

方法	假設條件	優點	缺點
單變量分析 (二分類檢定)	無	計算簡易。 所求得的數值易於解釋。	以試誤法尋求最佳財務指標，無共同的區別理論架構。 單一區別指標，無法涵蓋企業整體面。
多變量分析 (區別分析)	須符合常態假設。 每一變數都不是其他變數的線性組合。 每一群體的共變數矩陣必須假設相等。	同時考慮多項指標，對整體績效衡量較二分類檢定為客觀。 可瞭解那些財務比率最具區別能力。	財務資料較難以符合其常態假設。 對虛擬變數無法有效處理。 當樣本選擇偏差，對模式分類能力影響很大。 模型使用前，資料須標準化。
Logit模型	殘差項須為韋伯分配，自變數間無共線性存在。 樣本數必須大於迴歸參數個數。	可解決區別分析自變數非常態問題。 機率值介於0與1之間 模式適用於非線性狀況。	模式使用前須經由資料轉換。 計算程序較複雜。
Probit模型	殘差項須常態分配。 殘差項變異性齊一。 自變數間無共線性。 樣本數必須大於迴歸參數個數。	可解決區別分析中自變數非常態的問題。 模式不須經資料轉換，較容易使用。	只能應用於二分類選擇模式。 其機率常落於0與1之外，不符合機率假設之前提。

國外財務危機預警模型內容大要的彙整

研究者 (年度)	研究主題	研究樣本	研究變數	研究方法預測	正確率(%)
Beaver (1966)	企業失敗預測	失敗、非失敗企業各79家	14個財務比率	單變量分析	---
Altman (1968)	企業破產預測	破產及正常企業各33家	22個財務比率	區別分析	72-95
Deakin (1972)	企業破產預測	失敗及成功企業各32家	14個財務比率	二次式區別分析	82-90
Blum (1974)	企業失敗預測	失敗及正常企業各115家	12個財務比率及趨勢	二次式區別分析	70-94
Altman and Loris (1976)	經紀商財務預警制度	失敗經紀商40家、正常經紀商113家	6個財務比率	二次式區別分析	86.2~90
Altman, Haldeman and Narayanan (1977)	驗證企業破產風險之新模型	破產企業53家，正常企業58家	27個財務比率	線性區別分析 二次式區別分析	76.8~92.8 69.7~92.8
Ohlson (1980)	企業破產機率之預測	破產企業105家，非破產企業2058家	9個財務比率	Logit	92.84~96.12
Dambolena, and Khoury (1980)	企業失敗預測	失敗及正常企業各23家	財務比率 穩定性	區別分析	82~96
Zmijewski (1984)	企業破產預測模式檢視	破產企業76家 未破產企業3880家	選擇基礎 偏差 樣本選擇 偏差	加權及未加權 Probit 單變量及雙變量 Probit	76.3~99.7

國外財務危機預警模型內容大要的彙整

Frydman, Altman and Kao (1985)	迴覆分割與分類結果之關係	200 家企業	20 個財務比率	反覆分割演算法	85~94
Lo (1986)	企業破產預測	破產38 家 正常38 家	財務比率	區別分析 Logit	---
Zavgren (1985)	企業破產預測	破產及正常各45 家	7 個財務比率	Logit	69~83
Gentry, Newbold, and Whitfold (1985)	企業破產預測	失敗及非失敗企業各33 家	資金流量	Logit	71.71~83.33
Keasey and McGuinness (1990)	企業失敗預測	失敗及非失敗各58家	產業相對比率、 財務比率	Logit Entropy	70~86
Platt and Platt (1990)	企業失敗預測	(1)114家 (2)68家 (3)182家	產業相對比率、 財務比率	Logit	78~90
Odom and Sharda (1990)	企業破產預測	65家失敗企業，64家 正常企業	5個 財務比率	類神經網路 區別分析	100 86.64
Tam and Kiang (1992)	企業失敗預測	59家失敗銀行，59家 正常銀行	19個 財務比率	線性區別模式 Logit、決策樹 類神經網路	---

案例推理法

- 案例推理法(**case-based reasoning**)主要是依據人類的實際推理「上一次當、學一次乖」方式。
- 一般在思考推理的過程上，當遇到問題時，會嘗試從以前的經驗中找出最相似的方法，而藉由過去類似的情況來判斷可能發生的問題；所以是依循經驗來推理的方法，以過去發生的案例(**cases**)為主要的經驗依據。
- 當決策者擁有很多不同案例，而且能夠在合理時間內找出相似的案例，則以案例為基礎的判斷過程對決策者是很有效的方法。

案例推理法之推理流程

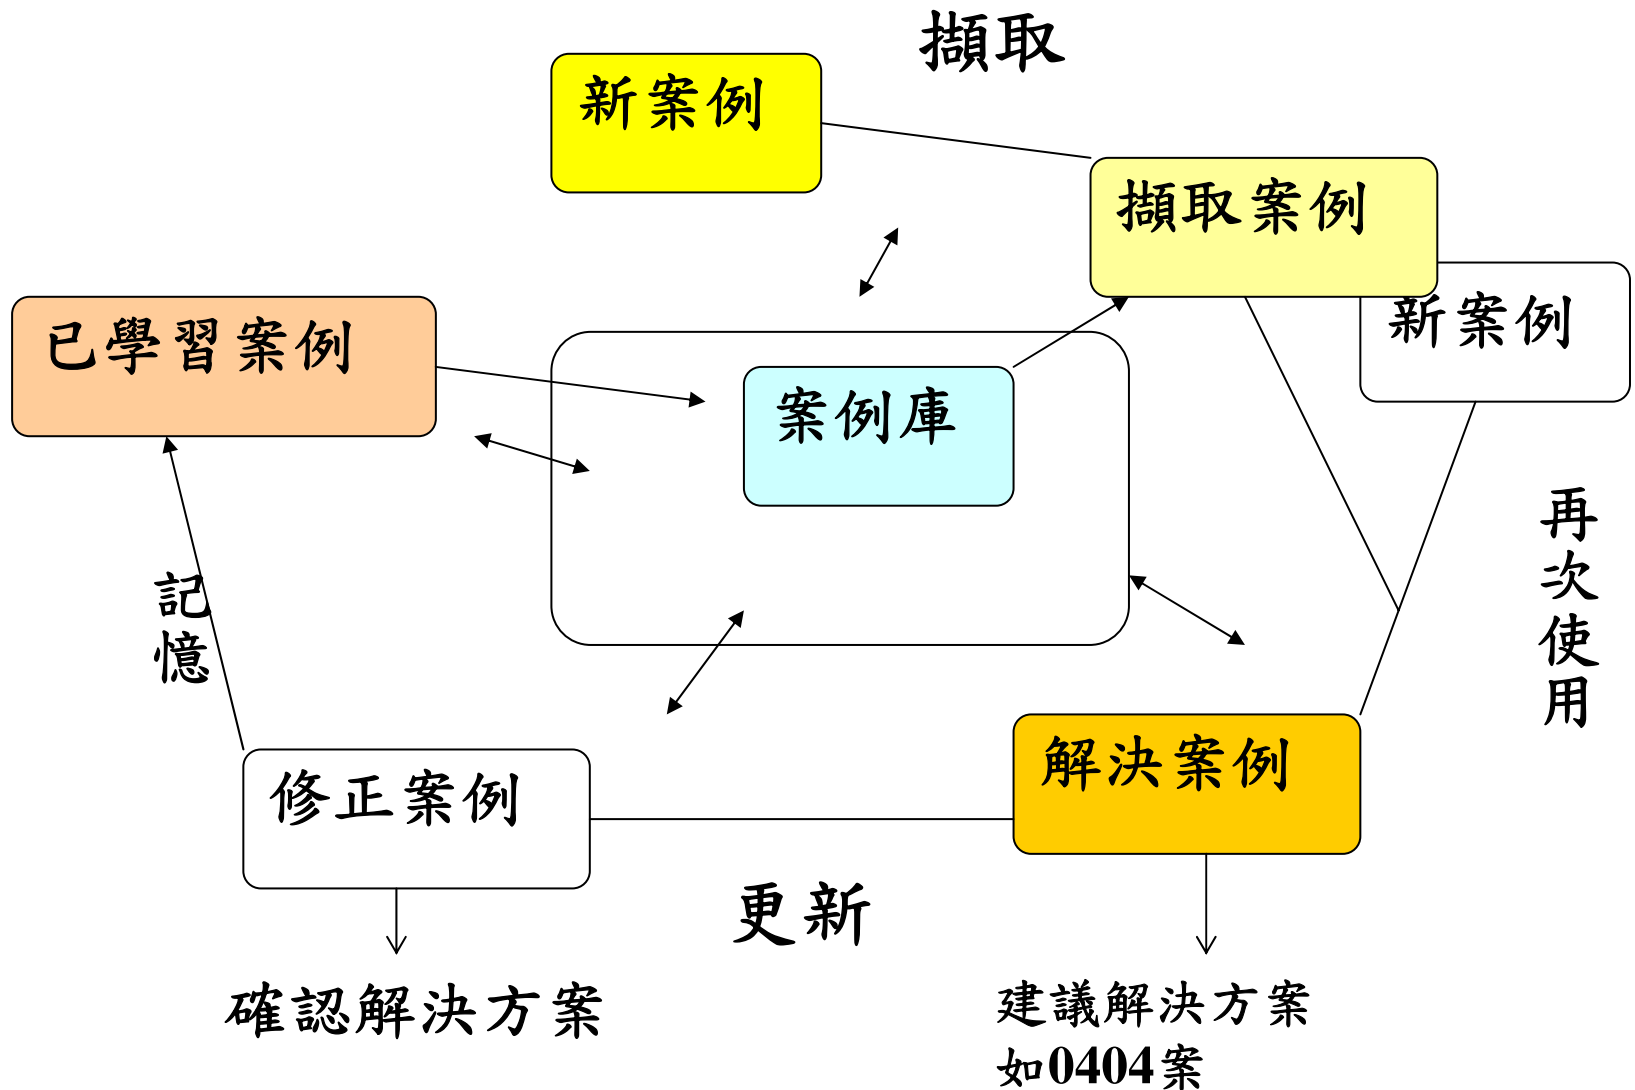
- 案例推理法為機器學習領域，是屬於記憶庫中的認知模式，以過去類似的經驗來指導解決新的問題，將以往解決舊問題的答案加以蒐集整理，而用來解決未來可能要發生的問題，其問題包含曾經發生與不曾發生的案例。

若輸入一個新的問題到案例推理法系統，會再從現有的案例庫中搜尋相似的案例，搜尋解決問題的方法或修正選取的案例，使其能符合新案例所需。使用案例推理法，也可以用來偵測公司的經營成效，以判斷是否有財務危機。這基本的方式就是以過去的類似經驗來指導解決新的問題。

案例推理過程的週期循環

- 當管理者面對某一問題時，即可視其為一新案例(new case)，此時管理者即從其腦海記憶中，找出已學習案例(learned case)，並經由案例庫中來擷取若干適用的案例，將之與新案例並列、比對，再一次使用以建立起一個解決案例(solved case)，據以形成建議或解決方案，進而更新案例庫的資訊成修正案例(repaired case)，最後再納入管理者的記憶中以形成已學習案例。

案例推理過程的週期循環



案例推理法之優點

- 案例推理法係從記憶中案例，尋找以往所解決過的問題與現在要解決的問題相同或相類似者，分數愈高的表示相似的程度愈高，此分數有助於使用者選取相似的案例，並將其以相似的優先順序表列出來。優點如下：

重複利用過去相關推理成功案例，有效解決所面臨的新問題。由於過去成功的案例能夠指引經理人避免重蹈覆轍，並找到成功的替代方案，使得能夠改良解決問題的品質。由於蒐集過去成功與失敗的案例相當容易，簡化知識的擷取。較不會因太多未知因素的存在，而像傳統評估模式一樣繁複。分析上不受限一般統計理論要求常態分配、大樣本數等要求。

案例推理法演算流程

- 案例推理法主要包含以下幾個步驟：

1. 先對新的案例做分析，分析完後再決定變數的篩選法則（***T-test***或逐步迴歸法）。

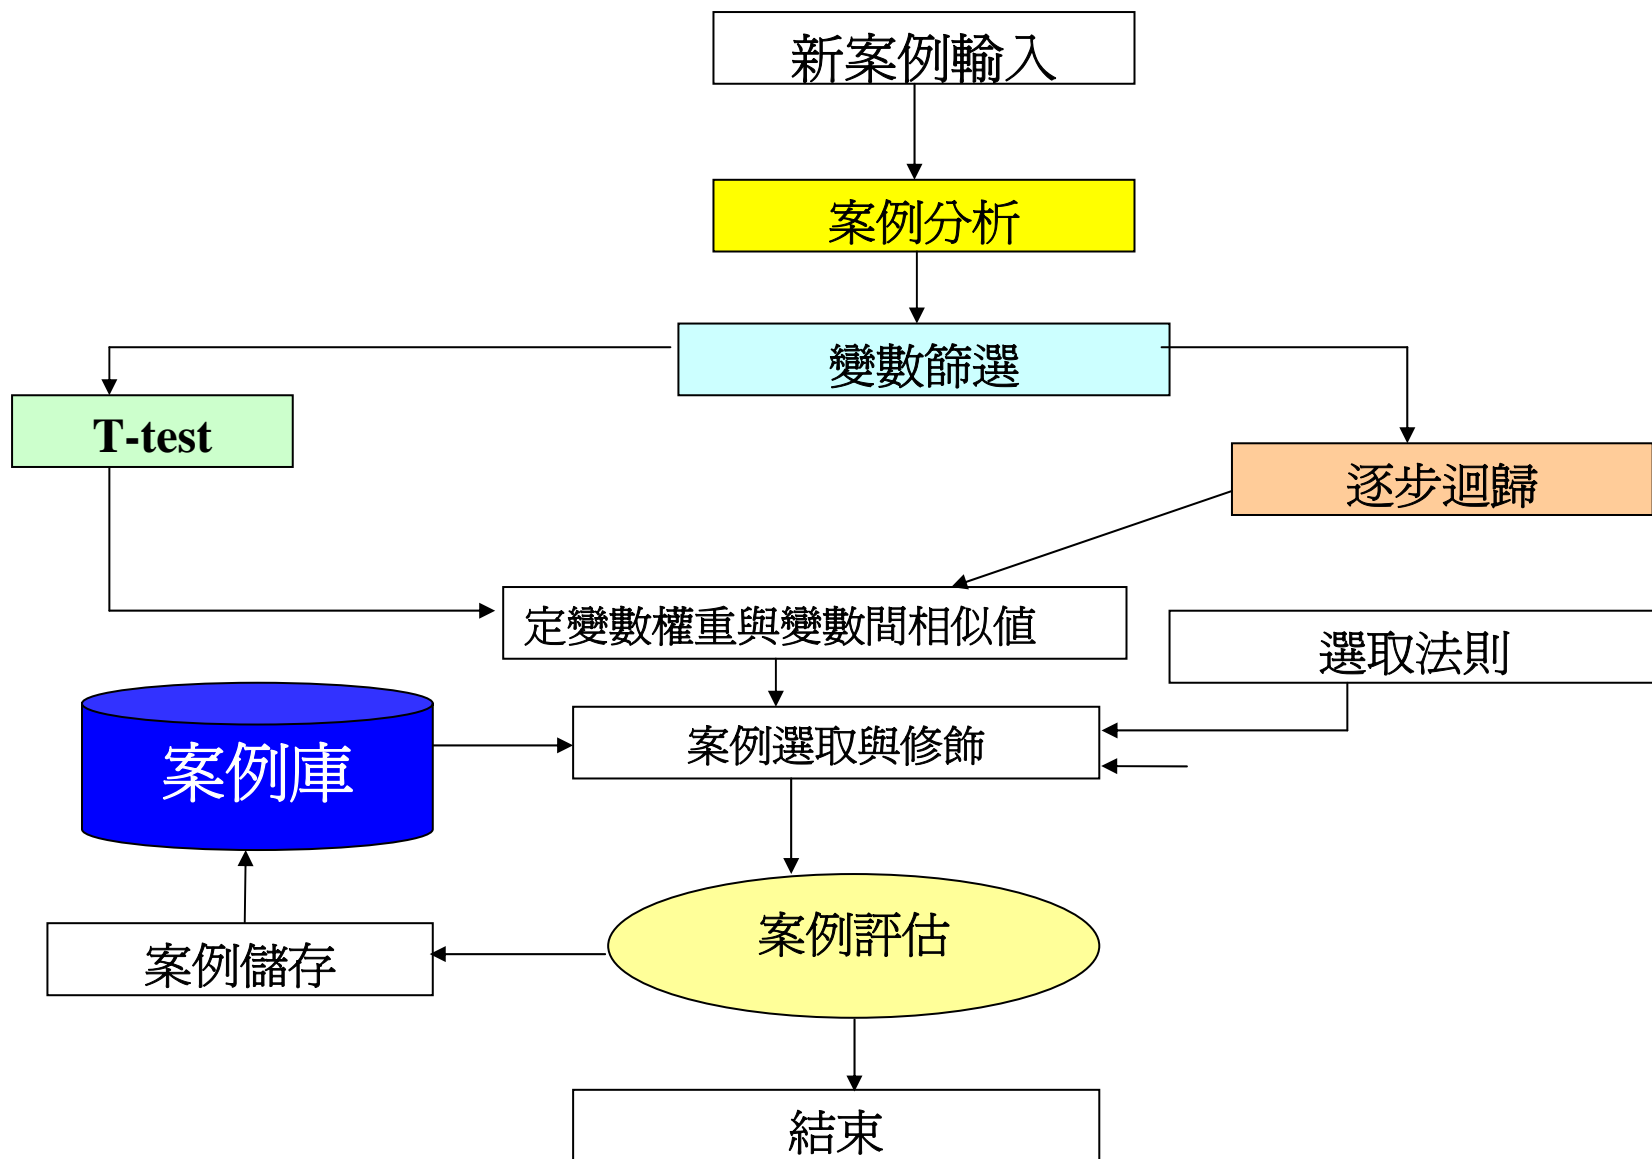
2. 根據上一步驟決定之變數篩選法則所篩選之自變數，決定所篩選之自變數權重。

3. 根據相似性演算法則，算出案例間之距離，再轉變為案例間之相似度，由相似度 (**similarity**) 選取最相近之案例。

案例推理法演算流程

- **a, b**兩個案例之相似度(**Sab**)計算公式為：
- **Sab = e**，其中
$$dab = [Wj] |Xaj - Wbj|^r \quad 1/r$$
- **dab**為案例**a**與案例**b**之距離，**Wj**為屬性**j**之權重，**Xaj**與**Xbj**分別為案例**a**與案例**b**中，屬性的衡量值，**r**則代表距離空間尺度，一般可令**r=2**。
- 對所選出之案例做案例評估。
- 如果所選出之案例結果正確則結束案例推理法，如果不正確，則將新案例重新存回案例庫(**base case**)。

案例推理法演算流程圖



類神經網路

- 類神經網路(neural network)，其模型是模擬人類大腦思考的方式建構出來的人工智慧系統，它是藉由學習訓練範例的過程，來找出輸入變數與輸出變數間之關係，並建構出預測模型，類神經網路並不受限於樣本為常態分配的假設，也無變數是否具共線性的問題，其結果會介於**0**與**1**之間。

類神經網路 (續)

- 類神經網路之優點為：

模型無嚴格的假設限制且具有處理非線性問題之能力，可接受虛擬變數(**dummy variable**)

類神經網路之缺點為：
模型運作時是黑箱作業，無法得知其運作方式內容，沒有統計理論與基礎。

類神經網路 (續)

- 類神經網路的學習方法分爲監督式學習 (supervised learning)、非監督式學習 (unsupervised learning)，以及聯想式學習 (associate learning)。
- 監督式學習是從訓練範例上，學習輸入和目標輸出值的內在對應規則。

• 在學習的過程中，當輸入一筆資料後，網路會以目前的權重計算出相對應的推論值，以及推論值和目標輸出值的誤差，而這誤差值再回饋到網路中，以調整網路的權重。經由不斷的輸入訓練範例以及重複的訓練範例後，網路會漸漸修正內部的權重，而使得網路推論值漸漸逼近目標輸出值，當目標輸出值和推論值接近到某一範圍內時，則停止學習而不再改變權重，此表示網路已經從訓練範例中學到範例資料之間的規則。

類神經網路建構步驟

- 建構類神經網路的過程包括：發展模式之軟硬體選擇、網路架構如隱藏層和處理單元的決定、學習參數和轉換公式的選擇，以及學習次數和收斂範圍的決定，而這些因素對網路的學習速度和預測結果有很大的影響。

類神經網路開發軟硬、體之選擇：

類神經網路的軟體開發工具可以利用程式語言如C語言來發展，最主要的好處是彈性大、可立即修改程式以符合研究的需求，對往後若發展成爲預測資訊系統時，可以很容易的和其他程式或資料庫連接，而唯一的不便就是需要花時間寫碼及測試。



類神經網路建構步驟(續)

- 隱藏層層數的決定：

類神經網路的後向增生網路 (**back propagation network, BPN**)，它的可貴之處在於隱藏層，如果沒有隱藏層就是只有輸入跟輸出的組合，功能和一般的線性迴歸分析差不多。目前對於隱藏層的層數沒有一定的方法可循，全視問題的複雜程度來決定。



類神經網路建構步驟(續)

- 各層處理單元(**process elements; PE**)的決定：

—輸入層處理
單元數：與輸
入一樣。

輸出層處理單元數：
只有一個輸出處理單
元（有無危機）。

—隱藏層處理單元數：決定隱藏層**PE**值的方法不勝枚舉，但是爲了不讓隱藏層的**PE**值過多以致造成網路的記憶效應(**memorization**)，而缺乏歸納(**generalization**)的能力。因此，選擇適合的**PE**值非常重要，目前大都同時考慮數種不同的隱藏層處理單元的網路架構，以取得最佳的預測值；或以分析權重的敏感度以決定增刪處理單元。

類神經網路建構步驟(續)

- 學習參數的設定：

學習速率：其大小會影響網路學習的收斂速度，學習速率愈大學習愈快，但也可能使網路在收斂過程中產生振盪；如果學習速率太小，則收斂太慢且容易陷入局部最小值。

慣性項：可以改善收斂過程的振盪現象，並加速收斂。



類神經網路建構步驟(續)

- 轉換公式和學習法則的設定：

轉換函數一般有雙曲線正切函數(hyperbolic tangent function)和雙彎曲函數(sigmoid function)兩種。

疊代值(epoch)設定：

經過先前的測試發現，當疊代值小於學習樣本數時，網路無法收斂且誤差值上下振盪。因此，將疊代值設定和學習樣本數一樣大，類神經網路將學習完全部的樣本數後才改變權重一次。

類神經網路建構步驟(續)

- 學習樣本與測試樣本的決定：

網路的運作過程可分為學習以及測試兩階段，學習是網路從成對的輸入與輸出學習樣本中學得輸入、輸出資料間的規則，而測試過程只輸入測試樣本的輸入值，並由網路推論出相對的輸出值，並將此輸出值和測試樣本原先的輸出值相比較，以求出誤差值，進而瞭解網路的學習成效。



類神經網路建構步驟(續)

- 學習次數的決定：

決定網路的學習程度方法有兩種，一是決定學習次數，學習到一定的次數後停止學習，但不能保證此時的網路是否會收斂，因為若學習次數不足則網路不會收斂；另一個方法是決定誤差的範圍，等到網路的誤差小於原先訂定的誤差值後停止學習，這可以求最小誤差，可能會導致過度訓練(**over-training**)的問題。

類神經網路建構步驟(續)

- 預測準確度的評估標準：
通常評估準確性的標準有平均方根誤差(mean square error, **MSE**)、平均絕對誤差(mean absolute deviation, **MAD**)及均方根誤差(root mean square error, **RMSE**)，公式如下：

$$MSE = \frac{\sum_{i=1}^n (A_i - F_i)^2}{n}$$

$$MAD = \frac{\sum_{i=1}^n |A_i - F_i|}{n}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - F_i)^2}{n}}$$

其中 **A_i** 為實際值， **F_i** 為預測值， **$i=1, 2, \dots, n$** ， **n** 為樣本數。



上帝的心意就是要你們成爲聖潔，遠避淫行。---
《聖經·帖薩羅尼迦前書》4：3

私慾懷了胎，就生出罪來，罪既長成，就生出死
來。---《聖經·雅各書》1：15