

## 第參章 模型建構

CPFR 流程中強調短期預測，根據少量且多元的過去與即時資料，透過買賣雙方合作協定的預測方法作短期預測，並持續不斷地模型修正，以快速反應需求，從而穩定後續生產規劃、物流配送規劃與補貨作業。然而企業在選擇使用預測模型時，偏好操作簡單的時間序列模型或易於解釋因果關係的迴歸模型，其預測誤差仍舊偏高，且無法滿足不斷調整之訂單需求。時間序列模型在短期預測上雖有不錯之績效，但僅將過去之訂單量作為未來訂單量唯一考慮因素，而不考慮在不穩定之環境下其他之訂單量影響因素；一般迴歸模型只考慮影響訂單量之因果資訊，忽略時間因子。因此，若能結合使用時間序列模型與一般迴歸模型之時間因子與因果關係之優勢，並加入最佳化演算法以求得最佳參數解，藉由近期訂單資料持續嘗試錯誤與自我學習調整，讓預測結果符合短期預測特性，將能有效提升協同訂單預測模型之預測績效。此外，本研究假設訂單預測方法不會因協同夥伴間的角色情境與合作關係的差異而有所不同。

本章依據第一章所描述的研究動機與目的，與第二章之相關理論及文獻探討為基礎，建立三階段訂單預測模型架構。首先說明本研究所建立的協同訂單預測模型整體架構，其次為模型驗證方法與績效指標。最後則分別針對協同訂單預測模型之三個階段作詳細說明，包括時間序列—指數平滑法、因果關係—多元迴歸分析與最佳化演算法—演化策略。

### 3.1 協同訂單預測模型整體架構

本研究以黃蘭禎（2004）所提出之混合預測模型為基礎，發展本研究之三階段訂單預測模型，三個階段分別為：1. 時間序列—指數平滑法；2. 因果關係—多元迴歸分析；3. 最佳化演算法—演化策略。協同訂單預測模型整體架構如圖 3-1 所示，其中預測模型之輸入變數將於本章 3.4 節詳加說明。

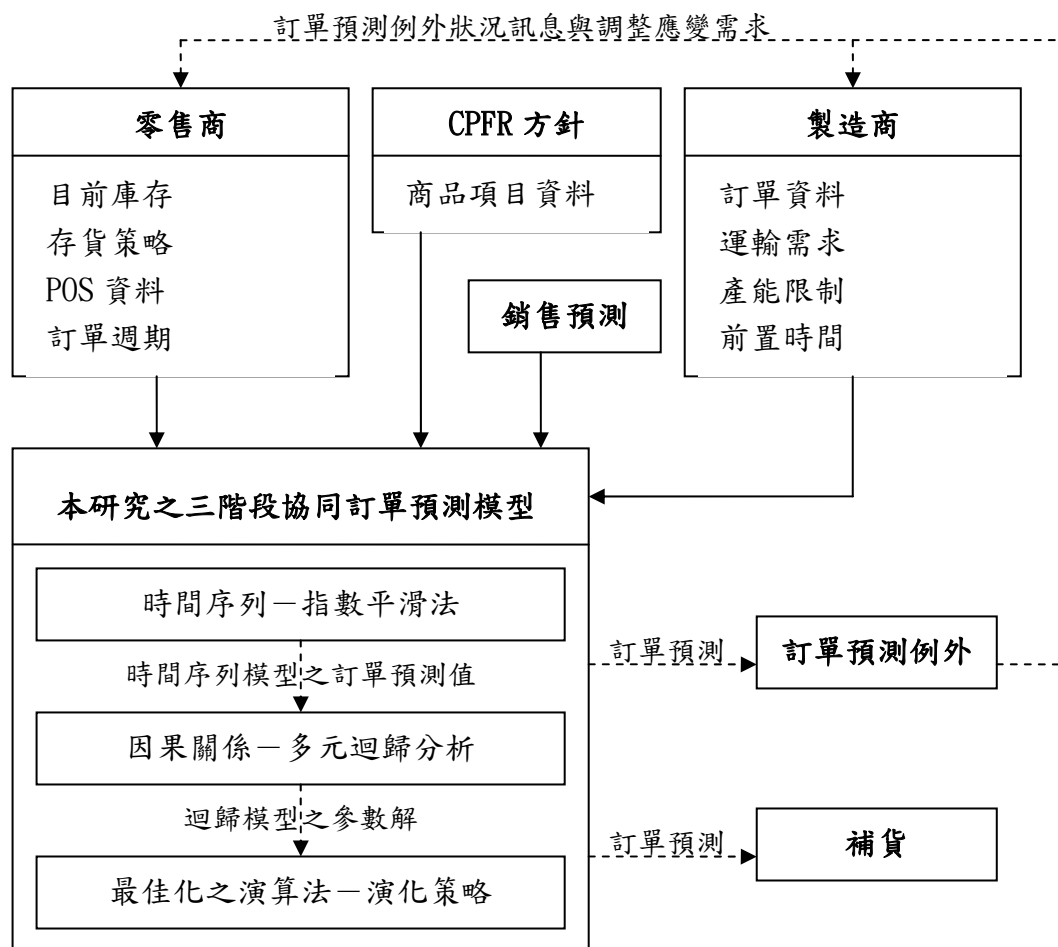


圖 3-1 協同訂單預測模型架構圖

本研究之三階段訂單預測模型說明如下：

#### 1. 時間序列—指數平滑法

時間序列係指以時間順序狀態出現之一連串觀測值集合。時間序列一般均呈隨機之現象，即對數列未來結果無法確定，以機率分配方法來表示者。簡單指數平滑法所需保留的資料少，計算方便，且預測之正確性較易獲得，其成本低之特性使得企業界多採用此法，但簡單指數平滑法無法針對季節變動進行調整，故本研究選擇使用賀特 (Holt) 提出之線性指數平滑法 (Linear Exponential-Smoothing

Method)，以改善簡單指數平滑法對趨勢變動反應遲鈍之問題，並利用敏感度分析求取最佳平滑係數值，以降低主觀判斷之誤差。此階段所求得之訂單預測值，將作為第二階段多元迴歸分析之其中一個輸入變數。

## 2. 因果關係—多元迴歸分析

因果迴歸分析屬於預測方法中的定量分析法，較常使用在解決線性方面的問題，它是一種統計分析方法，利用一組獨立變數對某一相依變數建立關係式以便作為預測的依據，它也可以作為評估獨立變數對相依變數的效用。由於第一階段之時間序列法僅把過去訂單數量做為未來訂單數量之唯一參數，並未考慮其他影響因素，其模型之預測解釋力明顯不足，故本研究透過文獻探討整理訂單資料與特性，歸納訂單預測所須具備之輸入參數，並採用多元迴歸分析將所有影響訂單預測之因素考慮進來，並將上一階段求得之時間序列模型預測值作為本模型其中一個解釋變數，讓多元迴歸模型能同時加入時間趨勢因子，此階段所求得之迴歸參數解作為第三階段最佳化演算法之起始解。

## 3. 最佳化演算法—演化策略

不同時間下各影響因素之解釋程度不同，而短期資料亦容易呈現複雜變異性。因此，第三階段便藉由最佳化演算法不斷地嘗試錯誤來自我調整，以求得符合短期訂單特性之多元迴歸分析參數最佳解。由於黃蘭禎（2004）提出之混合預測模型是採用基因演算法作為最佳化演算法，然而基因算法之編碼與流程多屬於整數解之最佳化，故本研究進一步修正，改用演化訓練流程適合實數解最佳化的演化策略法作為第三階段之模型。本階段以第二階段多元迴歸模型取得之參數解作為演化起始解，經過近期訂單資料編碼（representation）、重組（recombination）、突變（mutation）與選擇（selection）之演化訓練流程，產生最適協同訂單預測模型。

## 3.2 驗證方法與績效指標

本研究蒐集近年來國內外研究 CPFR 與訂單預測之相關文獻為基礎，歸納出協同合作下訂單需求之影響因素，作為模型的解釋變數，結合傳統時間序列與多元迴歸分析，並加上最佳化演算法，進而推導出三階段預測模型，最後採用實驗方法驗證模型績效，針對單純使用時間序列方法或統計迴歸分析的預測結果來做績效評比。本研究以 Java 與 Excel 開發三階段預測模型之演化策略法的系統雛型，進行預測結果績效比較之實驗分析，並蒐集以週為單位之產品資訊、訂單與存貨資料，檢視 10 次實驗結果四週與八週之平均績效，並與以下兩個模型之預測結果比較：

1. 時間序列模型：指數平滑法，即本研究第一階段之時間序列模型。為了降低主觀判斷之誤差，模型中兩個平滑係數事先以敏感度分析求得最佳參數值。本研究以 Java 開發線性指數平滑法之系統雛型，並自動紀錄敏感度分析過程中的實驗資料於 Excel 文件。
2. 一般迴歸模型：利用統計工具 SSPS 軟體進行迴歸分析，經過迴歸分析過程求出迴歸模型參數解，並針對模型預測區間內之訂單量作預測。與本研究模型中第二階段之迴歸模型所不同的是，一般迴歸模型並不考慮時間序列因子，即時間序列模型預測值在一般迴歸模型中不為模型解釋變數之一。

預測必定有誤差，如果要比較各種預測方法的相對準確性，就必須累計許多期的預測誤差，再運用統計方法檢定其預測正確性是否有顯著差異。不論是考慮累積或平均誤差，都必須對每一期的預測誤差取絕對值，以免正負號相抵而產生錯誤的結論。就單一期間的預測而言，可以利用預測值與實際值的差距來定義預測誤差，公式如下：

$$e_i = Y_i - F_i \quad (4-1)$$

其中， $e_i$  = 第  $i$  期的預測誤差

$Y_i$  = 第  $i$  期的實際值

$F_i$  = 第  $i$  期的預測值

公式 4-1 為衡量誤差的根本，在衡量指標部份皆是以此為出發點。本研究為避免極端值的衝擊影響而降低預測精確度的判定，選擇採用平均絕對誤差百分比 (Mean Absolute Percentage Error; MAPE) 作為預測準確度之績效衡量指標，其公式如下所示。

$$MAPE = \frac{\sum_{i=1}^n \frac{|e_i|}{Y_i}}{n} \quad (4-2)$$

另外，為提供更多績效資料以供對照，本研究輔助選用平均絕對誤差 (Mean Absolute Deviation; MAD) 與均方誤差 (Mean Square Error; MSE) 為參考比較，公式如下所示。

$$MAD = \frac{\sum_{i=1}^n |e_i|}{n} \quad (4-3)$$

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} \quad (4-4)$$

MAPE、MAD 與 MSE 皆是值愈小愈佳，值小代表預測資料與實際資料之結果愈接近，其預測績效愈佳。

### 3.3 時間序列模型

當某種產品或產品線有足夠的歷史資料可供利用，且其關係和趨勢甚為清楚和穩定時可用時間序列加以預測。時間序列預測之目的為確定可預測之因子，其預測步驟包括：

1. 步驟一：確認在時間序列中之元件，收集歷史資料，畫出資料與時間之關係，建立假設模型，以統計方法確立假設。
2. 步驟二：選擇適當的預測方法，決定輸入變數，對歷史資料進行評估。
3. 步驟三：用選定預測方法進行預測。

時間序列法之原理為，所有的預測都是當歷史資料可用時，預測人員將過去資料之態勢投射或引申到未來。簡單的說，時間序列法是利用過去歷史資料的趨勢來做為未來的依據，以預測出未知的值。一般時間序列方法有天真預測法、簡單移動平均法與指數平滑法，簡介如下：

1. 天真預測法：最簡單的預測技巧莫過於天真預測法。任何一期之天真預測值為前期的真實值。天真預測法看起來雖然可能顯得太簡單，卻不失為正常的預測工作，適用於多產品之預測，其優點為不需任何成本，預測簡單迅速、使用者容易瞭解。此方法最主要的缺點為不能提供高度精確的預測值，須有大量之歷史資料。天真預測法通常是更複雜的預測法之起點。
2. 移動平均法：此法係以過去資料為依據，將最近  $n$  期資料之算術平均或加權平均值作為下一期之預測值。此法適用於少量產品之預測，使用極為簡單與易於系統化，且可消除季節變動，不規則變動或兩者之影響，但對於資料的變動調整緩慢。其公式如下：

$$F_t = \frac{\sum_{i=1}^n Y_i}{n} \quad (4-5)$$

其中， $i$  = 資料之期間 ( $i = 1, 2, 3, \dots, n$ )

$n$  = 移動平均之期數

$Y_i$  = 第  $i$  期的實際值

$F_t$  = 第  $t$  期的預測值 ( $t = n + 1$ )

3. 指數平滑法 (Brown, 1959)：指數平滑法為 Brown 所命名，他認為指數平滑法為特殊總類的加權移動平均法，其理論基礎為過去，尤其是最近過去的需求型態，在某種程度上會持續到最近的未來；所需要的條件是數列型態需具有穩定性或規則性。此法與移動平均法相似，唯一的不同點是指數平滑法決定數值時最近的資料所佔的比重較大，指數平滑法之種類很多，這裡所提的為簡單指數平滑法。此法適用於短期預測、生產和存貨控制、財務資料預測，所需保留的資料少，計算方便，且預測之正確性較易獲得，為最便宜應用廣泛的一種短期預測方法，缺點為加權值不易設定。其公式(新預測值 = 舊預測值 +  $\alpha$ (實際值 - 舊預測值))，公式如下：

$$F_t = F_{t-1} + \alpha (Y_{t-1} - F_{t-1}) \quad (4-6)$$

其中， $F_t$  = 第  $t$  期的預測值

$F_{t-1}$  = 第  $t-1$  期的預測值

$\alpha$  = 平滑係數

$Y_{t-1}$  = 第  $t-1$  期的實際值

$\alpha$  稱為平滑係數，當  $\alpha$  接近 0 時，即對過去的觀測值作最大加權。反之，當  $\alpha$  接近 1 時，即對近期的觀測值作最大加權。通常，當需求穩定時，觀測值的變動僅受偶然變動的影響，則取小的  $\alpha$  值以期使用之前的歷史值來抵消偶然變動。如果需求不穩定，觀測值的變動還受到偶然變動以外的變動（趨勢變動、季節變動、週期變動）影響，則取較大的  $\alpha$  值以期預測值可以快速的反應這些變動。由於指數平滑法是由本期的預測值和本期實際值之差來調整下期的預測值，所以對變動的反應遲鈍，但卻能將偶然的變動予以平滑化，如果存在偶然變動以外的變動，則產生的預測值對趨勢變動反應遲鈍。由於在時間數列資料有增加趨勢時，會得出偏低的需求預測，所以在實際應用指數平滑法時，需要採用一些方法消除它對趨勢變動反應遲鈍的問題。此外，這種指數平滑法不能用於處理季節變動。如果時間數列資料的季節變動不明顯時，問題還不大；但當季節變動明顯時，對季節變動的平滑作用就很差。

對於訂單數量穩定或沒有季節性變動的產品，用簡單的指數模型就可以完全滿足預測的要求，然而許多產品訂單量具有明顯的趨勢變化，還有不少產品屬於強烈季節型。簡單指數平滑法對趨勢變動反應有遲鈍的問題，為了能計算長期趨勢和季節性，有必要擴展現有的簡單指數平滑模型，賀特（Holt）提出之線性指數平滑法（Linear Exponential-Smoothing Method）便改善簡單指數平滑法所面臨的問題。線性指數平滑法適用於具有線性趨勢的預測，因此故本研究選擇採用線性指數平滑法以忽略季節性因子，其公式如下：

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (4-7)$$

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta) T_{t-1} \quad (4-8)$$

$$\hat{Y}_t(k) = L_t + kT_t \quad (4-9)$$

其中， $\alpha$  = 平滑係數（針對等級）

$\beta$  = 平滑係數（針對趨勢）



$L_t$  = 時間  $t$  之估計值

$T_t$  = 時間  $t$  之趨勢估計值

$Y_t$  = 時間  $t$  之觀察值

$\hat{Y}_t(k)$  = 到時間  $t$  為止之預測值

為了降低主觀判斷之誤差，最佳平滑係數值則是透過敏感度分析來決定，以該預測之 MAPE 值最小者為佳。本研究之線性指數平滑模型預測步驟說明如下：

1. 將時間序列資料分為訓練資料集與驗證資料集。
2. 選擇適當指數平滑法—賀特之線性指數平滑法。
3. 對訓練資料集設定初始參數。
4. 對驗證資料集作預測並求出預測誤差。
5. 修正初始參數並尋求最適化。

時間序列模型僅將過去銷售量作為未來銷售量之輸入變數，並未考慮其他訂單影響因素。本研究模型下一個階段將探討其他訂單影響因素，並透過多元迴歸分析把這些影響因素納入考量，而此階段所求得之時間序列訂單預測值，將作為第二階段多元迴歸模型其中一個輸入變數。

### 3.4 多元迴歸模型

由於第一階段之時間序列法僅把過去訂單數量做為未來訂單數量之唯一變數，並未考慮其他影響因素，故本研究透過文獻探討歸納訂單預測之輸入變數，並採用多元迴歸分析試圖將所有影響訂單預測之因素考慮進來。這些影響因素將作為迴歸模型中的解釋變數，而求得之迴歸模型參數解乃第三階段最佳化演算法之起始解。本研究多元迴歸模型變數與定義說明如下：

1. 銷售預測 (VICS 網站; Armingier, 2002): 在 CPFR 流程下, 銷售預測是訂單預測一個重要的輸入變數, 銷售預測作為訂單預測的前一個階段, 根據歷史銷售資料、行銷事件與客戶需求進行未來消費者需求量的預測, 因此銷售預測是訂單預測中相當重要的決定因素。
2. 時間序列模型預測 (黃蘭楨, 2004): 時間序列模型以過去訂單量作為未來訂單量預測的基準, 其優點為資料取得容易, 對於短期預測能提供一個較佳的結果。透過時間序列模型預測, 可以有效解釋訂單量的時間變化趨勢, 故本研究加入該期時間序列預測為迴歸模型之解釋變數。
3. 供應商庫存持有成本 (Matt Johnson, 1999; Armingier, 2002): 供應商儲存和保管存貨的費用為持有成本, 其中包括存貨佔用資金的利息、倉庫設備的折舊費和維修費、倉儲費、通風照明費、運雜費、存貨變質損耗費等。某項庫存物品一定時期內的儲存成本, 即該物品存放在這時期內的全部費用。儲存成本與庫存量有直接關係, 供應商必須保留部分庫存來滿足零售商平時或緊急訂單之需求, 避免缺貨帶來的損失, 相對來說就替零售商承擔相當的存貨成本, 故供應商庫存持有成本可能會影響訂單量。
4. 前置時間 (Luhtala, 1994; Frank Chen, 2000): 前置時間定義為產品從原料採購、製造、入庫、成品配送至顧客所需時間, 主要分為資訊傳遞前置時間、生產前置時間、運送前置時間及等待閒置時間。Luhtala(1994)提到一般製造業資訊傳遞及設置前置時間佔 2%、生產前置時間佔 20%、運送前置時間佔 24%, 而其餘 54% 則為等待閒置時間。Frank Chen(2000)將前置時間的影響獨立列出, 由於前置時間的拉長, 訂單變異會增加。不穩定之前置時間常會影響所需的訂單量, 當前置時間愈長, 供貨的穩定性與銷售預測的準確性就會相對降低, 因而增加生產的變動或訂單的變動。

5. 零售商安全庫存 (Frank Chen, 1998): 零售商安全庫存是為了應付超出預期的顧客需求與供應能力變化而保存的額外庫存。由於供應鏈間之實體流通, 須考慮其可服務水準, 往往會因此在各供應鏈階層間設有安全存量, 相對的供應鏈階層數越多增設安全存貨越多。平均來說, 為了避免顧客需求或供應能力突然變化導致缺貨情況的發生, 庫存水準總是保持在安全庫存之上。Frank Chen (1998) 指出零售商不同的安全存貨水準, 會促使訂單量的顯著改變。因此, 安全庫存是零售商向供應商採購商品數量之重要依據之一。
6. 訂單週期 (VICS; Fred Baumann, 2002): 即零售商距離上一次向供應商發出訂單之間隔時間。因訂單週期的落差, 造成供應商所面對需求情況與實際的市場需求存在時間落差, 訂單量跟著會有劇烈的變化。故訂單週期在不固定之情況下, 會顯著影響訂單數量。
7. 零售商在手庫存量 (VICS; Fred Baumann, 2002; Armingier, 2002): 即零售商目前擁有的存貨數量, 又稱在手量。
8. 零售商已訂購庫存量 (VICS; Fred Baumann, 2002; Armingier, 2002): 即零售商已經下達的採購單、但尚未收到或未收完的數量被稱為已訂購庫存量, 又可稱作在途量。在運送過程中可能發生貨物丟失等存貨資料不同步之情形, 故已訂購庫存量具有相當的不確定性存在。
9. 存貨策略 (VICS; Fred Baumann, 2002; Armingier, 2002): 一般常見的存貨策略有四種, 各為 $(s, Q)$ 存貨策略、 $(s, S)$ 存貨策略、 $(R, S)$ 存貨策略、 $(R, s, S)$ 存貨策略, 說明如下。

(1)  $(s, Q)$ 存貨策略: $(s, Q)$ 系統為連續型庫存監控系統。當庫存達到或低於 $s$ 時即訂購固定 $Q$ 單位之存貨。應用 $(s, Q)$ 系統的優點在於簡單易用, 可減少錯誤的發生, 供應商較易於預測需求。

缺點在於因訂購量為固定  $Q$ ，難以有效率的應付單次大量的交易。例如，訂  $s$  為 5， $Q$  為 10，需求為 15，當庫存為 4 時即使及時補貨亦無法滿足需求。

(2)  $(s, S)$  存貨策略： $(s, S)$  系統亦為連續型庫存監控系統。當庫存達到或低於  $s$  時即訂足夠的量至  $S$  為止。該存貨策略的優點在於包含補貨成本、缺貨成本、隨機需求之動態庫存下， $(s, S)$  系統為擁有最小總成本之最佳存貨策略。缺點為若欲求得最佳之  $s$  與  $S$  參數，常需解決較為複雜的非線性規劃問題，有可能得到區域最佳解而非全域最佳解，不似  $(s, Q)$  系統般簡易。

(3)  $(R, S)$  存貨策略： $(R, S)$  為定期庫存監控系統，每隔  $R$  單位時間就訂足夠的量至  $S$  為止。 $(R, S)$  存貨策略的優點在易於整合運送相關物品，例如當定期從海外訂購時，為了節省運送成本必會盡量填滿貨櫃空間以節省成本。此外  $(R, S)$  系統也可視需要定期的調整最大庫存，以符合市場的需求。該系統的缺點為存貨持有成本會高於連續監控系統。

(4)  $(R, s, S)$  存貨策略： $(R, s, S)$  系統為  $(s, S)$  與  $(R, S)$  的結合。即每  $R$  單位時間檢查其庫存水準，若到達或低於  $s$  及訂足夠的貨至  $S$  為止，若高於  $s$  則該週期不予補貨直至下一週期(再  $R$  個單位時間)再檢視其庫存水準。

針對不同季節或不同之策略需求，零售商所採行的存貨策略可能有所不同，訂單量自然會受影響。

上述為本研究多元迴歸模型所考慮之訂單預測解釋變數，結合黃蘭楨(2004)所發表之文獻，對 CPFR 流程下銷售預測與訂單預測影響因素之差異整理如表 3-1。

表 3-1 CPFR 流程下銷售預測與訂單預測影響因素之差異

銷售預測	訂單預測
1. 產品售價	1. 銷售預測
2. 價格差率	2. 供應商庫存持有成本
3. 商店與產品關鍵促銷活動之有無	3. 前置時間
4. 個別產品之促銷活動數	4. 零售商安全庫存
5. 零售商店之整體促銷活動數	5. 訂單週期
6. 該期所屬月之尖峰類別	6. 零售商在手庫存量與已訂購庫存量
7. 產品所處之生命週期	7. 存貨策略
8. 該期是否有同類別之新產品導入	

在採用的因果關係模型部分，黃蘭楨（2004）指出一般因果預測函數中，依其複雜性有一般線性迴歸與非線性迴歸。為方便操作，非線性迴歸須轉換為線性，轉換後以半對數（semi-log）線性迴歸和雙對數（double-log）線性迴歸較為常見，這些線性迴歸模型定義如下：

$$1. \text{ 一般多元迴歸線性模型： } Y = \beta_0 + \sum \beta_i * X_i \quad (4-10)$$

$$2. \text{ 半對數線性迴歸模型： } \log Y = \beta_0 + \sum \beta_i * X_i \quad (4-11)$$

$$3. \text{ 雙對數線性迴歸模型： } \log Y = \beta_0 + \sum \beta_i * X_i + \sum \beta_j * \log X_j \quad (4-12)$$

一般而言，非線性迴歸模型較線性迴歸模型更能解釋因果關係與變化趨勢。本研究之訂單迴歸模型中一般變數與虛擬變數同時存在，各解釋變數數值差異甚大，若使用一般多元迴歸線性模型（公式 4-10）或半對數線性迴歸模型（公式 4-11），容易使影響因素之效果被高估或低估，故採用雙對數線性迴歸模型（公式 4-12）。本研究訂單預測方法之第二階段多元迴歸模型如下所示。

$$\begin{aligned} \log Y(t) = & \beta_0 + \beta_1 \log \text{SaleForc}(t) + \beta_2 \log \text{TsEst}(t) + \beta_3 \log \text{SuppInv}(t) + \\ & \beta_4 \text{LeadTime}(t) + \beta_5 \log \text{SafeStoc}(t) + \beta_6 \text{OrderCyc}(t) + \\ & \beta_7 \log \text{OnHand}(t) + \beta_8 \log \text{OnOrder}(t) + \beta_9 \text{InvStraDV}(t) + \varepsilon_t \quad (4-13) \end{aligned}$$

其中， $\log Y(t)$  = 第  $t$  期訂單量之對數值

$\log \text{SaleForc}$  = 銷售預測之對數值

$\log \text{TsEst}$  = 時間序列模型預測之對數值

$\log \text{SuppInv}$  = 供應商庫存持有成本之對數值

$\text{LeadTime}$  = 前置時間（單位為週）

$\log \text{SafeStoc}$  = 零售商安全庫存之對數值

$\text{OrderCyc}$  = 訂單週期（單位為週）

$\log \text{OnHand}$  = 零售商在手庫存量（Inventory On Hand）之對數值

$\log \text{OnOrder}$  = 零售商已訂購庫存量（Inventory On Order）之對數值

$\text{InvStraDV}$  = 零售商的存貨策略，分為四種：1 表(s, Q)連續盤點制；

2 表(s, S) 連續盤點制；3 表(R, S)定期盤點制；4 表

(R, s, S)定期盤點制。

本研究利用 SSPS 統計軟體分析訂單資料，並針對模型解釋度、顯著性與解釋變數間共線性作分析，以求出合適的多元迴歸模型。

### 3.5 演化策略模型

在不同時間下各影響因素之解釋程度不同，且短期資料亦容易呈現複雜變異性。因此，第三階段便藉由最佳化演算法不斷地嘗試錯誤來自我調整，以求得多元迴歸參數之最佳解。由於黃蘭禎（2004）在此階段所採用之基因演算法屬於整

數解之最佳化，本研究進一步修正，改用適合於實數解最佳化方法的演化策略法作為第三階段模型。大多數的最佳化技術其求解方式多以目前所求的解為出發點進行鄰近解的搜尋。它們的搜尋空間皆侷限於區域性範圍，求得的解是區域最佳解（Local Optimal Solution）而非全域最佳解（Global Optimal Solution）。雖然有些最佳化技術可以克服此種陷阱，但隨著問題本身維度的增加，求解時間快速增大，因此降低了實用性。於是面臨欲求取全域最佳解時，普遍採用隨機搜尋（Rndom Search）法。演化策略法本身是一種隨機搜尋方法，利用求解過程中累積的資訊，來對搜尋空間作修正並產生較佳的解。以下分述本研究演化策略之重要機制，包括編碼型式（representation）、適應函數（fitness function）、重組（recombination）、突變（mutation）與選擇（selection），最後則說明演化策略模型之整個流程。

### 3.5.1 編碼型式

本研究將多元迴歸模型中的  $n$  個變數編碼成為變數向量  $\vec{x}$ ，為針對最佳化問題所設定的  $n$  維目標變數向量。演化策略的基本單元為個體（individual），一個個體除了目標變數向量  $\vec{x}$  外，還包括策略參數（strategy parameter） $\vec{\sigma}$ ，表示標準差的變數向量，是子代目標變數向量之變異量調整依據。本研究多元迴歸模型包含常數下總計有 10 個目標變數，若針對一個具有 10 個目標變數的多元迴歸模型來進行最佳化問題設計，要將 10 個變數編碼成為目標向量  $\vec{x} = (x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10})$ ，策略參數之個數亦為 3，則可以設定個體為  $(\vec{x}, \vec{\sigma}) = (x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}, \sigma_1, \sigma_2, \sigma_3, \sigma_4, \sigma_5, \sigma_6, \sigma_7, \sigma_8, \sigma_9, \sigma_{10})$ 。

### 3.5.2 適應函數

適應函數是演化策略法的評估個體優劣的指標，其設計好壞會影響演化結果。本研究適應函數共分為兩個部分，包括當期的預測誤差率與當期之前所有誤差率的平均值，公式如下：

$$(1) \text{ 當期的預測誤差率： } \frac{|Y_t - y_t|}{Y_t} \quad (4-14)$$

$$(2) \text{ 當期之前所有誤差率的平均值： } \frac{\sum_{i=1}^{t-1} \frac{|Y_i - y_i|}{Y_i}}{t-1} \quad (4-15)$$

本研究預測之績效指標為 MAPE，演化策略模型便以 MAPE 為基礎發展適應函數，為使預測結果更符合短期訂單特性，故以權重植加總當期的預測誤差率與之前所有誤差率的平均值，其目的乃希望該期最佳解能反映近期特性，愈接近預測當期，其誤差值之權重愈大，而適應函數值愈小者愈佳。適應函數完整公式如下所示：

$$a * \frac{|Y_t - y_t|}{Y_t} + b * \frac{\sum_{i=1}^{t-1} \frac{|Y_i - y_i|}{Y_i}}{t-1} \quad (4-16)$$

其中， $a, b =$  權重值 ( $a + b = 1$ )

$Y_t =$  第  $t$  期的實際值

$y_t =$  第  $t$  期的預測值

### 3.5.3 重組

本研究設定父代族群個數為 100，是為族群式的演化策略，意指在父代解集合數量大於 1 的情況下，即可設一定數量之父代進行重組運算。(Schwefel, 1995)



指出在自我調適的演化過程中，策略參數之重組運算佔有相當重要的地位。故本研究除了目標變數會執行重組運算外，策略參數也會加入參與重組運算。演化策略有許多種重組方式，一般可分為離散型 (discrete) 與中間產物型 (intermediate)，其運算方法如下：

$$(1) \text{ 離散型: } q_i = p_{1,i} | p_{2,i} \quad (4-17)$$

$$(2) \text{ 中間產物型: } q_i = \varepsilon_i \cdot p_{1,i} + (1 - \varepsilon_i) \cdot p_{2,i} \quad (4-18)$$

其中， $q_i$  = 子代第  $i$  個變數

$\varepsilon_i$  = 0 到 1 之間的任意實數

$p_{1,i}, p_{2,i}$  = 父代第  $i$  個變數

舉例來說，從父代族群中選取兩個父代個體  $p_1$  與  $p_2$  進行重組運算。離散型重組運算選定的父代變數組合為  $\{1, 2, 1\}$ ，意指每個變數選取對應於父代解的對象，即從兩個父代個體  $p_1$  與  $p_2$  中擇一取之；中間產物型重組運算的  $\varepsilon_i$  分別為  $\{0.6, 0.5, 0.4\}$ 。離散型重組運算子代  $q_1$  與中間產物型重組運算子代  $q_2$  之運算結果如圖 3-2 與圖 3-3 所示。




圖 3-2 離散型重組運算結果




圖 3-3 中間產物型重組運算結果

本研究根據經驗法則，針對目標變數與策略參數使用不同之重組方式，決策變數採用離散型重組運算，而策略參數則採用中間產物型重組運算。

### 3.5.4 突變

突變機制意指針對子代族群進行突變運算，其中  $\tau$  和  $\tau'$  為常數，分別代表全域學習率 (global learning rate) 和區域學習率 (local learning rate)。當其應用於一特定個體時，策略參數  $\sigma_s$  必須先經過突變應算，然後再應用於目標變數。 $\sigma_s$  突變公式如下：

$$\sigma'_s = \sigma_s \cdot \exp\left(\tau' \cdot N(0,1) + \tau \cdot N(0,1)\right), s = 1, 2, \dots, n_\sigma \quad (4-19)$$

其中， $\tau' \propto (\sqrt{2n})^{-1}$  ( $n$  為目標變數的個數)

$$\tau \propto (\sqrt{2\sqrt{n}})^{-1}$$

$\sigma_s$  = 父代的第  $s$  個策略參數

$\sigma'_s$  = 子代的第  $s$  個策略參數

$N(0,1)$  = 標準常態分配隨機變數 (期望值為 0；標準差為 1)

若將標準差變數個數設定為 1，則可以將公式 4-19 簡化為：

$$\sigma'_s = \sigma \cdot \exp(\tau' \cdot N(0,1) + \tau \cdot N(0,1)) \quad (4-20)$$

決策變數  $x_i$  是利用  $\sigma'_s$  進行突變運算， $\sigma'_s$  即為常態分配隨機變數中的標準差。  $x_i$  突變公式如下：

$$x'_i = x_i + N(0, \sigma'_s), i = 1, 2, \dots, n \quad (4-21)$$

### 3.5.5 選擇

選擇機制在演化策略中可以分為  $(\mu, \lambda)$  及  $(\mu + \lambda)$ ，主要分別在於  $\mu$  個父代個體在經過突變及重組運算之後會產生新的  $\lambda$  個子代個體， $(\mu + \lambda)$  會將父代及子代族群一併進行評估；而  $(\mu, \lambda)$  會忽略父代資訊只考慮子代族群進行評估，再將考慮的集合中所有個體適應函數評估值進行排序，經由選取機制，選出下一代設定的父代族群數量，挑選集合中較佳之  $\mu$  個解成為新的父代族群，進入下一代演化程序。一般來說  $(\mu, \lambda)$  是較好的，因為它允許暫時跳脫母體的最佳解集合，將可能解決區域最佳化的問題以避免演化結果太早收斂；然而， $(\mu + \lambda)$  卻經常可以較快找到最佳解。在兼顧預測績效與時間效率之考量下，本研究選擇採用  $(\mu + \lambda)$  演化方式。

### 3.5.6 演化流程

綜合上述編碼型式、適應函數、重組、突變與選擇機制，本研究模型演化策略步驟說明如下：

1. 步驟一：初始化全域學習率  $\tau$ 、區域學習率  $\tau'$ 、第一代策略參數與終

止條件設定，並取得多元迴歸模型參數解作為初始解。

2. 步驟二：取得初始解，並隨機產生第一代母體族群。
3. 步驟三：由前一代演化族群中，隨機選取兩個父代個體，以進行重組運算，目標變數與策略參數一同加入重組運算。目標變數採用離散型重組方式；策略參數則使用中間產物型重組方式。
4. 步驟四：進行突變機制運算產生子代，其公式如下所示：

$$x_i^{g+1} = x_i^g + N(0, \sigma_i^g), i = 1, 2, \dots, n$$

$$\sigma_i^{g+1} = \sigma_i^g \cdot \exp(\tau' \cdot N(0,1) + \tau \cdot N(0,1)), i = 1, 2, \dots, n_\sigma \quad (4-22)$$

其中， $x_i^g$  = 父代的第 i 個目標變數

$x_i^{g+1}$  = 子代的第 i 個目標變數

$\sigma_i^g$  = 父代的第 i 個策略參數

$\sigma_i^{g+1}$  = 子代的第 i 個策略參數

$N(0,1)$  = 標準常態分配隨機變數

5. 步驟五：進行選擇機制運算，計算子代適應函數評估值，採用 $(\mu + \lambda)$ 演化法，將父代與子代族群中所有個體之適應函數評估值排序，挑選族群中最佳解集合成為第 t 期第 g 代的父代族群。
6. 步驟六：判斷第 t 期之所有代數是否演化完畢。若演化完畢，則繼續步驟七；否則跳至步驟三進行下一代演化。
7. 步驟七：判斷所有期數是否演化完畢。若演化完畢，則繼續步驟八；否則將第 t 期之最佳解設為初始解，並跳至步驟二進行下一期演化。

## 8. 步驟八：產生最佳預測模型。

本研究演化策略模型之虛擬碼如圖 3-4，演化流程圖則如圖 3-5 所示。

```
begin
  initialize the individual  $x$  = regressive solution
  for  $t = 1$  to the final period do
    generate initial population of  $\mu$  individuals based on individual  $x$ 
    evaluate all initial individuals according to the fitness function
    for  $g = 1$  to the final generation do
      for  $i = 1$  to  $\lambda$  do
        select two individuals for mating with equal probability:
          discrete recombine decision variables
          intermediate recombine strategy parameters
        mutate the new individual under certain probability
      end for  $i$ 
      evaluate  $\lambda$  new individuals
      select  $\mu$  best individuals from set of parents and children as new
      generation (assuming  $(\mu + \lambda)$ -selection)
    end for  $g$ 
    set individual  $x$  = the best individual in this period
  end for  $t$ 
end
```

圖 3-4 本研究演化策略模型虛擬碼

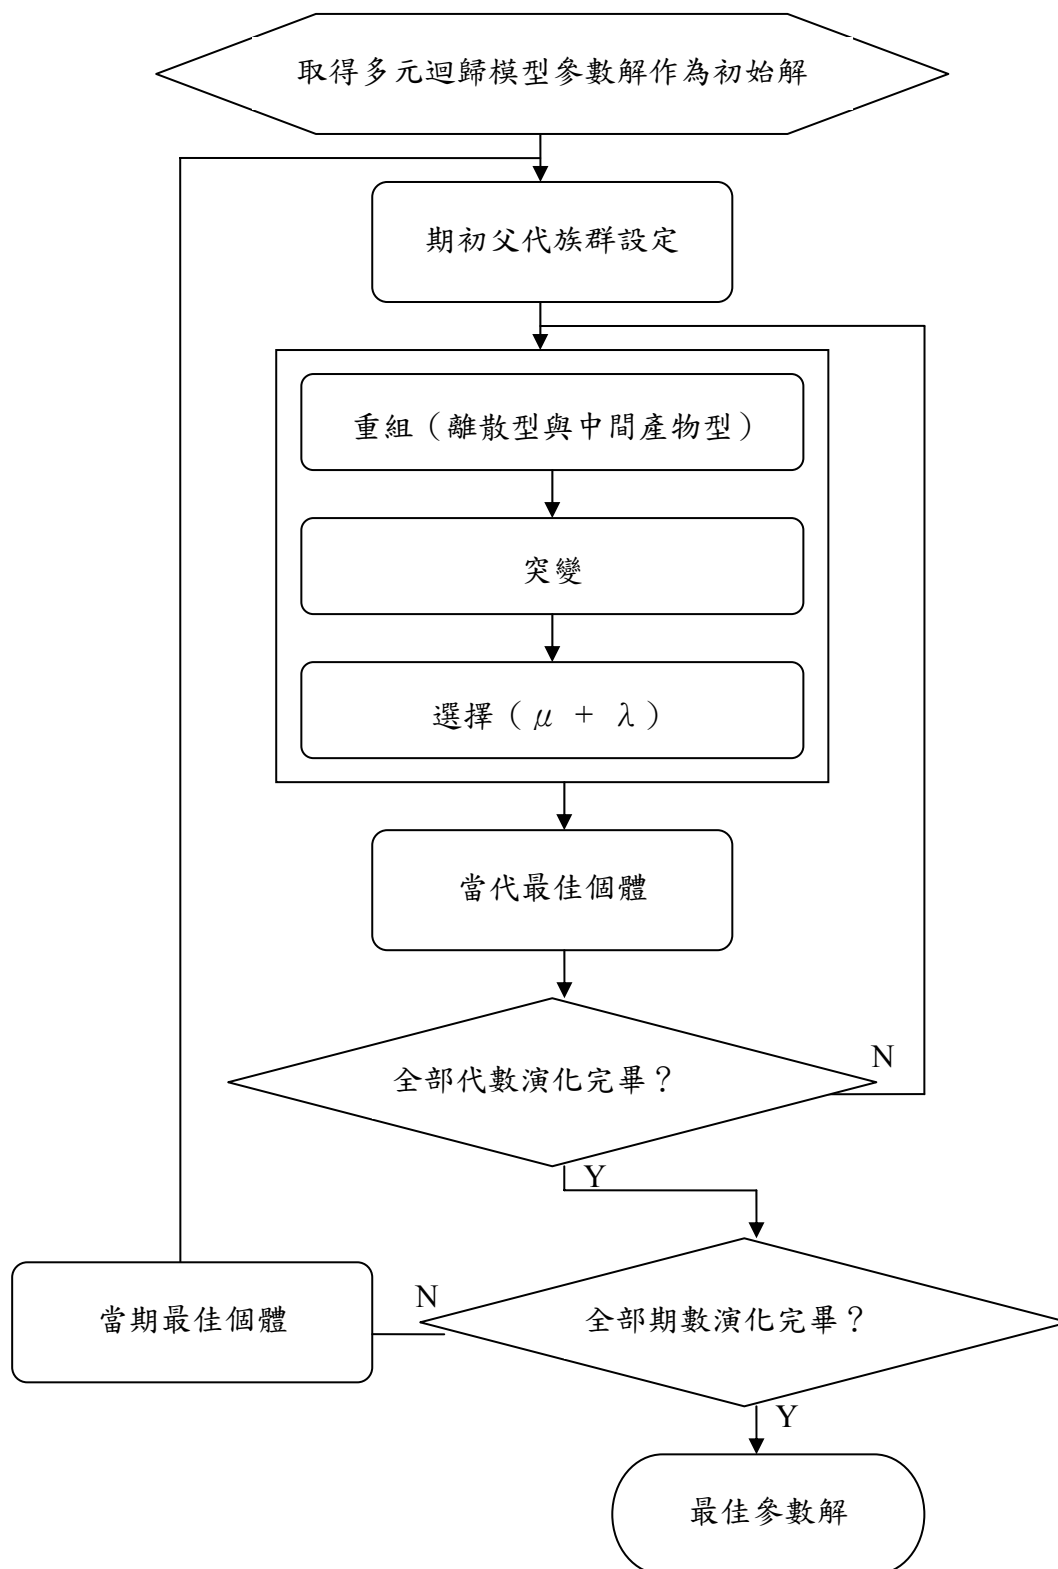


圖 3-5 本研究演化策略模型流程圖