

行政院國家科學委員會補助專題研究計畫 成果報告
 期中進度報告

免疫演算法於高性能混凝土配比設計多目標最佳化之研究

Mult-Objective Optimization of High Performance Concrete Mix
Design Using Immune Algorithms

計畫類別： 個別型計畫 整合型計畫

計畫編號：NSC-93-2211-E-216-001-

執行期間：93年8月1日至94年7月31日

計畫主持人：葉怡成

共同主持人：

計畫參與人員：連立川、劉原旭、黃冠傑

成果報告類型(依經費核定清單規定繳交)： 精簡報告 完整報告

本成果報告包括以下應繳交之附件：

- 赴國外出差或研習心得報告一份
- 赴大陸地區出差或研習心得報告一份
- 出席國際學術會議心得報告及發表之論文各一份
- 國際合作研究計畫國外研究報告書一份

處理方式：除產學合作研究計畫、提升產業技術及人才培育研究計畫、
列管計畫及下列情形者外，得立即公開查詢

涉及專利或其他智慧財產權， 一年 二年後可公開查詢

執行單位：中華大學

中華民國 94 年 10 月 10 日

致謝

本研究的完成最需感謝連立川同學的努力，沒有他一再嘗試、修改，本研究難以完成。

葉怡成 謹誌

九十四年十月

摘要

本研究旨在以基於遺傳演算法(genetic algorithm)的強化式學習(reinforced learning)解決二個實際的問題：(1)高性能混凝土(high performance concrete)強度行為建模；(2) 高性能混凝土工作度行為建模。研究結果顯示，若使用者要求的是可理解的 HPC 材料行為模型，遺傳演算法結合運算樹(genetic algorithm of operation tree)是一個準確且能夠產生自組織公式的 HPC 強度及坍度模型建構方法；若使用者對於可理解的 HPC 材料行為模型要求度不高，僅在乎最後的結果是否準確，則倒傳遞網路(back-propagation networks)是一個更準確且快速的 HPC 強度及坍度模型建構方法。

關鍵字：強化式學習(reinforced learning)、遺傳演算法(genetic algorithm)、高性能混凝土(high performance concrete)、運算樹(operation tree)、類神經網路(artificial networks)。

Abstract

This study used genetic algorithms combined with operation tree (GAOT) to produce self-organized formula for the strength of high-performance concrete (HPC), and compared its accuracy with five methods published, including back-propagation networks, regression analysis, macro-evolutionary genetic programming, grammar evolution genetic algorithms and genetic algorithms combined with regression analysis. The results showed that GAOT certainly could produce rather accurate self-organized formula, and it is more accurate than other methods only except for back-propagation networks.

Keyword : genetic algorithms (GA), operation tree, high-performance concrete (HPC), back-propagation networks (BPN).

目錄

第一章 導論.....	1
1-1 研究背景.....	1
1-2 研究目的.....	2
1-3 研究內容.....	2
第二章 文獻回顧.....	3
2-1 強化式學習.....	3
2-2 遺傳演算法.....	4
2-3 遺傳演算法在強化式學習之應用.....	8
2-3-1 遺傳演算法結合決策樹.....	8
2-3-2 遺傳演算法結合類神經網路.....	9
2-4 混凝土材料行為建模問題.....	9
第三章 高性能混凝土強度模型之應用.....	12
3-1 前言.....	12
3-1-1 資料收集.....	12
3-1-2 演算法參數設定及適應度函數.....	13
3-2 遺傳演算法結合迴歸分析產生強度模式.....	13
3-2-1 模型建構.....	13
3-2-2 運算樹預測值之迴歸修正.....	14
3-2-3 結果.....	15
3-3 運算樹遺傳演算法產生強度模式.....	16
3-3-1 模型建構.....	16
3-3-2 運算樹預測值之迴歸修正.....	17
3-3-3 結果.....	18
3-4 遺傳演算法結合類神經網路產生強度模式.....	20
3-4-1 模型建構.....	21
3-4-2 結果.....	22
3-5 結果及討論.....	24
3-5-1 結果的解釋.....	24
3-5-2 模型準確性及解釋性比較.....	30
第四章 高性能混凝土坍度模型之應用.....	38
4-1 前言.....	38
4-1-1 資料收集.....	38
4-1-2 演算法參數設定及適應度函數.....	39
4-2 運算樹遺傳演算法產生坍度模式.....	39

4-2-1 模型建構.....	39
4-2-2 運算樹預測值之迴歸修正及尺度化.....	39
4-2-3 結果.....	40
4-3 遺傳演算法結合類神經網路產生坍塌度模式.....	43
4-3-1 模型建構.....	43
4-3-2 結果.....	43
4-4 結果與討論.....	45
4-4-1 結果的解釋.....	45
4-4-2 模型準確性及解釋性比較.....	50
第五章 結論與建議.....	57
5-1 結論.....	57
5-2 建議.....	57
參考文獻.....	59
附錄一、類神經網路之權值.....	62

圖目錄

圖 2.1	強化式學習基本概念圖.....	3
圖 2.2	單點互換交配法.....	6
圖 2.3	雙點互換交配法.....	6
圖 2.4	均勻互換交配法.....	6
圖 2.5	GA 流程圖.....	7
圖 2.6	決策樹模型示意圖.....	9
圖 2.7	決策樹模型示意圖.....	9
圖 3.1	HPC 強度模型樹狀圖.....	13
圖 3.2	初始可調整強度模型.....	14
圖 3.3	GARA 產生之 HPC 強度模型.....	15
圖 3.4	GARA 訓練範例之 HPC 強度散佈圖.....	16
圖 3.5	GARA 測試範例之 HPC 強度散佈圖.....	16
圖 3.6	五層的運算樹示意圖.....	17
圖 3.7	五層八變數 GAOT 產生之運算樹.....	18
圖 3.8	五層八變數 GAOT 之訓練範例 HPC 強度散佈圖.....	19
圖 3.9	五層八變數 GAOT 之測試範例 HPC 強度散佈圖.....	19
圖 3.10	五層十二變數 GAOT 產生之運算樹.....	19
圖 3.11	五層十二變數 GAOT 之訓練範例 HPC 強度散佈圖.....	20
圖 3.12	五層十二變數 GAOT 之測試範例 HPC 強度散佈圖.....	20
圖 3.13	八個輸入變數、一個隱藏層、多個節點及一個輸出變數的神經網路模型.....	20
圖 3.14	隱藏層節點之轉換函數圖.....	22
圖 3.15	GANN(8-4-1)訓練範例之 HPC 強度散佈圖.....	23
圖 3.16	GANN(8-4-1)測試範例之 HPC 強度散佈圖.....	23
圖 3.17	GANN(8-8-1)訓練範例之 HPC 強度散佈圖.....	23
圖 3.18	GANN(8-8-1)測試範例之 HPC 強度散佈圖.....	23
圖 3.19	GANN(8-16-1)訓練範例之 HPC 強度散佈圖.....	24
圖 3.20	GANN(8-16-1)測試範例之 HPC 強度散佈圖.....	24
圖 3.21	GARA 產生強度模型各項變數的影響性.....	25
圖 3.22	GAOT 八變數產生強度模型各項變數的影響性.....	26
圖 3.23	GAOT 十二變數產生強度模型各項變數的影響性.....	27
圖 3.24	GANN(8-4-1)產生強度模型各項變數的影響性.....	28
圖 3.25	GANN(8-8-1)產生強度模型各項變數的影響性.....	28
圖 3.26	GANN(8-16-1)產生強度模型各項變數的影響性.....	29
圖 3.27	各變數於三種方法的影響性比較.....	30

圖 3.28	8 變數迴歸分析 t 統計量	31
圖 3.29	8 變數迴歸分析之訓練範例 HPC 強度散佈圖	32
圖 3.30	8 變數迴歸分析之測試範例 HPC 強度散佈圖	32
圖 3.31	12 變數迴歸分析 t 統計量	32
圖 3.32	12 變數迴歸分析之訓練範例 HPC 強度散佈圖	33
圖 3.33	12 變數迴歸分析之測試範例 HPC 強度散佈圖	33
圖 3.34	倒傳遞網路模型(8-8-1)	34
圖 3.35	倒傳遞網路 RMS 收斂圖	34
圖 3.36	BPN 之訓練範例 HPC 強度散佈圖	34
圖 3.37	BPN 之測試範例 HPC 強度散佈圖	34
圖 3.38	BPN 之各項變數影響性	35
圖 3.39	GEGA 之訓練範例 HPC 強度散佈圖	36
圖 3.40	GEGA 之測試範例 HPC 強度散佈圖	36
圖 3.41	MEGP 之訓練範例 HPC 強度散佈圖	36
圖 3.42	MEGP 之測試範例 HPC 強度散佈圖	36
圖 3.43	七種方法在預測準確度的比較	37
圖 4.1	五層七變數 GAOT 產生之運算樹	41
圖 4.2	五層七變數 GAOT 之訓練範例 HPC 坍塌度散佈圖	41
圖 4.3	五層七變數 GAOT 之測試範例 HPC 坍塌度散佈圖	41
圖 4.4	五層十一變數 GAOT 產生之運算樹	42
圖 4.5	五層十一變數 GAOT 之訓練範例 HPC 坍塌度散佈圖	42
圖 4.6	五層十一變數 GAOT 之測試範例 HPC 坍塌度散佈圖	42
圖 4.7	11-11-1 神經網路模型	43
圖 4.8	GANN(11-4-1)訓練範例之 HPC 坍塌度散佈圖	44
圖 4.9	GANN(11-4-1)測試範例之 HPC 坍塌度散佈圖	44
圖 4.10	GANN(11-8-1)訓練範例之 HPC 坍塌度散佈圖	44
圖 4.11	GANN(11-8-1)測試範例之 HPC 坍塌度散佈圖	44
圖 4.12	GANN(11-16-1)訓練範例之 HPC 坍塌度散佈圖	45
圖 4.13	GANN(11-16-1)測試範例之 HPC 坍塌度散佈圖	45
圖 4.14	GAOT 七變數產生坍塌度模型各項變數的影響性	46
圖 4.15	GAOT 十一變數產生坍塌度模型各項變數的影響性	47
圖 4.16	GANN(11-4-1)產生坍塌度模型各項變數的影響性	48
圖 4.17	GANN(11-8-1)產生坍塌度模型各項變數的影響性	49
圖 4.18	GANN(11-16-1)產生坍塌度模型各項變數的影響性	49
圖 4.19	各變數於兩種方法的影響性比較	50

圖 4.20	七變數 RA _t 統計量	51
圖 4.21	七變數 RA 之訓練範例 HPC 坍塌度散佈圖	52
圖 4.22	七變數 RA 之測試範例 HPC 坍塌度散佈圖	52
圖 4.23	十一變數 RA _t 統計量	53
圖 4.24	十一變數 RA 之訓練範例 HPC 坍塌度散佈圖	53
圖 4.25	十一變數 RA 之測試範例 HPC 坍塌度散佈圖	53
圖 4.26	11-11-1 倒傳遞網路模型	54
圖 4.27	倒傳遞網路 RMS 收斂圖	54
圖 4.28	BPN11-11-1 之訓練範例 HPC 坍塌度散佈圖	55
圖 4.29	BPN11-11-1 之測試範例 HPC 坍塌度散佈圖	55
圖 4.30	BPN 之各項變數影響性	55
圖 4.31	四種方法的準確度比較	56

表目錄

表 3.1	強度資料中各變數的值域及型態.....	12
表 3.2	運算元變數之意義.....	14
表 3.3	係數的區間限制.....	14
表 3.4	最佳化之材料係數.....	15
表 3.5	最佳化之改進模型.....	15
表 3.6	GARA 產生 HPC 強度模型之 RMS.....	16
表 3.7	運算元之基因編碼方法.....	17
表 3.8	八變數及常數之基因編碼方法.....	17
表 3.9	十二變數之基因編碼方法.....	18
表 3.10	五層八變數 GAOT 產生 HPC 強度模型之 RMS.....	18
表 3.11	五層十二變數 GAOT 產生 HPC 強度模型之 RMS.....	19
表 3.12	GANN(8-4-1)強度模型之 RMS.....	23
表 3.13	GANN(8-8-1)強度模型之 RMS.....	24
表 3.14	GANN(8-16-1)強度模型之 RMS.....	24
表 3.15	1196 筆各項變數的平均值及標準差.....	25
表 3.16	GARA 產生強度模型各項變數的影響性.....	25
表 3.17	GAOT 八變數產生強度模型各項變數的影響性.....	26
表 3.18	GAOT 十二變數產生強度模型各項變數的影響性.....	26
表 3.19	GANN8-4-1 產生強度模型各項變數的影響性.....	27
表 3.20	GANN(8-8-1)產生強度模型各項變數的影響性.....	28
表 3.21	GANN(8-16-1)產生強度模型各項變數的影響性.....	29
表 3.22	各變數於三種方法的影響性比較.....	29
表 3.23	8 變數迴歸分析 t 統計量.....	31
表 3.24	8 變數迴歸分析之強度模型 RMS.....	31
表 3.25	12 變數迴歸分析 t 統計量.....	31
表 3.26	12 變數迴歸分析之強度模型 RMS.....	33
表 3.27	倒傳遞網路 8-8-1 強度模型之 RMS.....	35
表 3.28	GEGA 之強度模型 RMS.....	36
表 3.29	MEGP 之強度模型 RMS.....	37
表 3.30	七種方法在預測準確度及模型公式自組織的比較.....	37
表 4.1	坍塌度資料中各變數的值域及型態.....	38
表 4.2	十一變數之基因編碼方法.....	39
表 4.3	七變數及常數之基因編碼方法.....	40
表 4.4	五層七變數 GAOT 產生之 HPC 坍塌度模型 RMS.....	41

表 4.5	五層十一變數 GAOT 產生之 HP 坍塌度模型 RMS	42
表 4.6	GANN(11-4-1)坍塌度模型之 RMS	44
表 4.7	GANN(11-8-1)坍塌度模型之 RMS	45
表 4.8	GANN(11-16-1)坍塌度模型之 RMS	45
表 4.9	103 筆坍塌度資料各項變數的平均值及標準差	46
表 4.10	GAOT 七變數產生坍塌度模型各項變數的影響性	46
表 4.11	GAOT 十一變數產生坍塌度模型各項變數的影響性	47
表 4.12	GANN(11-4-1)產生坍塌度模型各項變數的影響性	48
表 4.13	GANN(11-8-1)產生坍塌度模型各項變數的影響性	48
表 4.14	GANN(11-16-1)產生坍塌度模型各項變數的影響性	49
表 4.15	各變數於兩種方法的影響性比較	50
表 4.16	七變數 RA _t 統計量分析	51
表 4.17	七變數 RA 產生之 HPC 坍塌度模型 RMS	51
表 4.18	十一變數 RA _t 統計量分析	52
表 4.19	十一變數 RA 產生之 HPC 坍塌度模型 RMS	53
表 4.20	BPN 產生之 HPC 坍塌度模型 RMS	54
表 4.21	四種方法的準確度及解釋性比較	56
附錄表 1	輸入層與隱藏層節點之權值值域範圍	62
附錄表 2	隱藏層節點與輸出層之權值值域範圍	62
附錄表 3	GANN(8-4-1)強度輸入層至隱藏層節點之權值	62
附錄表 4	GANN(8-4-1)強度隱藏層節點至輸出層之權值	62
附錄表 5	GANN(8-8-1)強度輸入層至隱藏層節點之權值	63
附錄表 6	GANN(8-8-1)強度隱藏層節點至輸出層之權值	63
附錄表 7	GANN(8-16-1)強度輸入層至隱藏層節點之權值	63
附錄表 8	GANN(8-16-1)強度隱藏層節點至輸出層之權值	64
附錄表 9	GANN(11-4-1)坍塌度輸入層至隱藏層節點之權值	64
附錄表 10	GANN(11-4-1)坍塌度隱藏層節點至輸出層之權值	64
附錄表 11	GANN(11-8-1)坍塌度輸入層至隱藏層節點之權值	65
附錄表 12	GANN(11-8-1)坍塌度隱藏層節點至輸出層之權值	65
附錄表 13	GANN(11-16-1)坍塌度輸入層至隱藏層節點之權值	65
附錄表 14	GANN(11-16-1)坍塌度隱藏層節點至輸出層之權值	66

第一章 導論

1-1 研究背景

機器學習(Machine Learning)一直是電腦科學中重要的研究課題，因為人類的知識累積主要來自學習，學習可說是人類智慧的核心[1]。監督式學習(Supervised Learning, SL)及強化式學習(Reinforced Learning, RL)是兩種典型的機器學習。監督式學習是依照知識應用在範例後，然後根據範例的「對錯」來做調整。因此，對於靜態或複雜度較低的系統，只要取得足夠的觀測樣本，就能有效地運用學習演算法進行參數的調適工作。但是對於動態或互動性較高的複雜系統，足夠的樣本無法整批取得，目標系統的教導知識亦無法獲得，導致傳統的監督式學習無法勝任[2]。一個替代的方法是強化式學習。強化式學習是依照知識應用在範例後，然後去衡量範例的「好壞」來做調整，亦即強化式學習在透過學習階段後，根據發生的情況，搜尋出最適反應，並且提出一個最佳化的決策[2]。強化式學習是一種以嘗試錯誤為主的啟發式的學習策略，不必像監督式學習必須依賴足夠且精確的訓練資料[2]。

由於強化式學習在求解過程中，常因為搜尋空間過大，記憶能力必須提高，相對的演算法在計算上的負擔就更大。為了解決這個問題，許多學者提出了遺傳演算法(Genetic Algorithms, GA)結合強化式學習的方法[3, 4]。遺傳演算法是根據達爾文物競天擇中，適者生存、不適者淘汰的理論而生，因此能在搜尋空間過大的問題中，加快收斂的速度[4]。

本文旨在應用強化式學習於實際的問題，包括(1)混凝土強度行為建模問題(2) 混凝土工作度行為建模問題。

傳統混凝土是由水、水泥、粗骨材及細骨材所組成，隨著天然資源逐漸減少及環保意識日漸抬頭，傳統材料的取得及來源日益減少，因此替代性或具經濟性材料的使用成為混凝土工業的新趨勢。又隨著人口密度逐日增加，在土地有限的情況下，建築物不得不往高處發展，因此傳統的建築材料必須加以研發改良以配合此一趨勢，於是強調具耐久性、體積穩定性、有高強度、工作度的高性能混凝土(High Performance Concrete)應運而生[5, 6]，高性能混凝土除了傳統混凝土中的四種基本成份，經常加入一些填充膠結材料，例如飛灰(fly ash)、爐石(blast-furnace slag)，及其它化學攪劑，例如強塑劑(Super Plasticizer, SP)等。雖然高性能混凝土在不同的國家有不同的定義，但在本質上是強調包括高強度、高工作度、體積穩定性與耐久性等特性[7]。

然而高性能混凝土發展至今已十多年之久，雖然已經能夠準確預測其強度行為[8, 9]，並且提出建構強度模型的方法[10-12]，但這些文獻中往往是注重準確性卻忽略的模型解釋性，又或者剛好相反的注重模型構成但忽略了準確性，另外由於工作度與材料組成的關係比強度更難以捉摸，因此至今尚未有一套精確之模型公式能準確地預測其強度及工作度行為模式。

1-2 研究目的

傳統上，建立實驗資料的模型關係式是使用統計方法，例如多變數線性迴歸分析，但是在複雜的非線性系統這種方式並不可行。一個替代的方法是倒傳遞網路[13]。倒傳遞網路模式其架構乃模仿人類大腦學習能力的電腦模式。在過去的十年中，已有相當多的研究使用倒傳遞網路於材料的領域[14-16]。雖然倒傳遞網路可以建立精確的模型，但它卻不能產生一個明確的公式。為解決產生明確公式的問題，許多研究者提出了人工智慧中演化式計算的方法[10, 11]。遺傳演算法是人工智慧中演化式計算的一門分支，其依據自然演化及適者生存的觀念衍生而成[17-19]，模擬遺傳的選擇、交配、突變等機制。其強韌性以及平行處理能力，能夠在各種不同的環境裡讓效率與精確率達到平衡[19]，並且適用於解答空間大、複雜、非線性的問題。由於遺傳演算法具有解非線性離散最佳化問題的能力，因此本研究將使用遺傳演算法的演化式計算能力，企圖發展出一套能夠產生高性能混凝土強度及工作度自組織公式的方法。

1-3 研究內容

本研究與其它文獻不同處分述如下：

- 產生自組織性公式：本研究為提出與傳統迴歸分析同樣能產生公式的方法，但準確性又比傳統迴歸分析較為優異，因此研究將採用運算樹(Operation Tree)結合遺傳演算法的方法。
- 材料之敏感度分析：由於高性能混凝土的使用參數甚多，各個參數對於其強度及工作度結果的影響程度甚少人去探討，因此本研究將針對材料之敏感度分析做探討。
- 準確及解釋性比較：本研究提出兩套演算法結合的方法論，為驗證方法論的準確性及模型解釋能力，再以傳統上常見的模型建構方法來評估其優越程度。

為產生較傳統迴歸分析解釋能力優異的模型，本研究結合運算樹及遺傳演算法的方法，企圖發展不失其準確性但又能產生自組織公式的模型。為提高準確性，再以遺傳演算法結合類神經網路的方法論，產生一具備準確性的高性能混凝土強度及工作度的方法。預期未來研究者若同樣在進行材料領域的同時，能夠有模型準確性及解釋性參考之依據。

第二章 文獻回顧

2-1 強化式學習

機器學習(Machine Learning)可定義為[1]:「研究利用電腦自動獲取解決問題的知識的科學」。機器學習依其學習策略可以分成以下幾類[1]:

- 一、監督式學習(supervised learning):從一組已分類的特殊性訓練範例中,加以普遍化,導出普遍性的知識法則。
- 二、無監督式學習(unsupervised learning):從一組未分類的特殊性訓練範例中,加以普遍化,導出普遍性的知識法則。
- 三、類比式學習(learning from analogy):將一個已解決的問題之解題策略推到一個為解決的問題之解決策略上。
- 四、強化式學習(reinforced learning):一種試誤(trial-and-error)的過程,其機制在試誤過程中得到回饋(feedback)以增加經驗累積,並透過不斷的試誤,得到最佳化的反應組合[20-22]。

強化式學習基本概念如圖 2.1 所示[2]。首先系統機制先根據 action 進入環境,此時環境將根據環境的條件給定一個 result 回到系統機制中,接著系統機制再依據演算的過程給於環境一個 feedback。因此 result 與 feedback 形成一個迴路,直到系統機至達到結束規則為止。長期間之下,系統機制所得到 feedback 愈多,相對的在得到的 result 時也就能有最佳的決定,這也是使用者在利用加強式學習時所期望得到的結果。

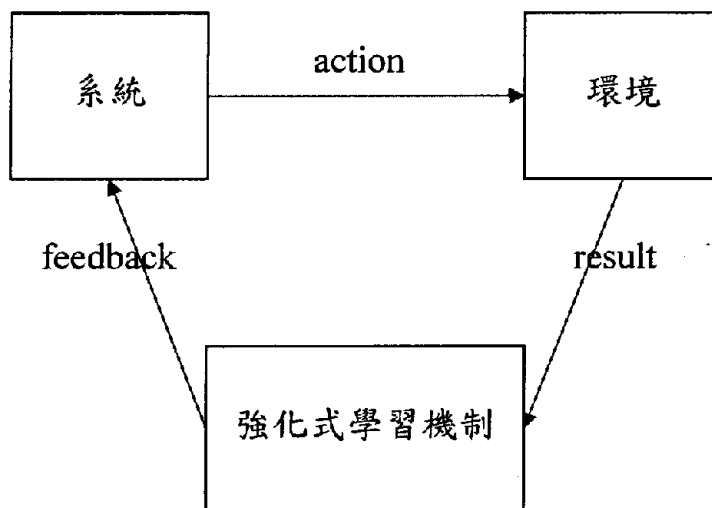


圖 2.1 強化式學習基本概念圖[2]

2-2 遺傳演算法

遺傳演算法(Genetic Algorithms, GA)，或稱基因演算法，是近年來快速發展且極具潛力的最佳化方法之一。它有獨特的搜尋技巧，能跳離局部最佳值，以趨近整體最佳值。此方法最初是由Holland於1975年發展出來，並出版Adaptation in Natural and Artificial System一書。到了1989年其弟子Goldberg又出版遺傳演算法專書Genetic Algorithms in Search, Optimization and Machine Learning，更使的學術界普遍了解到此種極為強健的最佳化技術[19]。其概念源自於達爾文「物競天擇，適者生存」的想法，仿效自然界生物生存競爭，個體結合之後，所產生的後代會繼承雙方特性，較能適應環境的個體，將獲得較高的存活機會，並繼續繁衍優秀的後代。

遺傳演算法雖是一種求解最佳化問題的工具，但如果將其應用在機器學習的知識結構問題上，即可用遺傳演算法求解。亦即先設計一種機器學習的知識結構，例如迴歸函數、決策樹、類神經網路...等，另外再以一種評價此結構匹配資料程度高低的評價函數，例如誤差均方根、誤判率...等，因此就能在以遺傳演算法優化評價函數的過程中，達成優化機器學習的知識結構問題[20-21]。

執行遺傳演算法需事先決定一些事項，例如染色體的編碼與解碼、適應度、適應函數、選擇機制、交配、突變、結束規則和儲存解答等，說明如下[19,20]：

- 染色體的編碼與解碼(encoding and decoding)：在遺傳演算法中需將問題及結果表示成可以運算的形式，即染色體編碼與解碼。例如將設計變數以"0110..."之二進制字串表示，例如9的十進制值為"9"，二進制值為"1001"。
- 適應度(fitness)：每個生物對於大自然環境都有不同的適應性，適者生存不適者淘汰。適應函數就如同大自然環境，用來衡量每個染色體對於該問題所對應的分數，此分數稱為適應值(fitness)。演化的過程，即在尋找最大或最小的適應值。
- 適應度函數(fitness function)：產生適應度的函數，適應度函數是染色體的演化環境。將染色體解碼後，代入適應函數即可求得其適應度，再依照適應度大小，來評估染色體所代表解答的好壞。適應函數即代表最佳化問題的目標函數。
- 選擇(selection)：遺傳演算法的選擇機制是模擬自然界適者生存的現象，適應度越高的染色體，存活機率較高，反之則存活機率較低。適應度較高的染色體所擁有的後代可能較多，如果某個染色體的適應值明顯高於其他染色體，就有機會藉由世代交替，逐漸成為此族群內的主體。常見的選擇方式有：輪盤法(roulette wheel selection)、期望值法(expected value)、均勻法(uniform selection)、競賽法(tournament selection)、穩態法(steady-state selection)與菁英法(elitism)。

- (1) 輪盤法：族群中每個染色體的適應值在輪盤上都有相對應的面積，相對面積越大者被選中的機會越高。此方法只能直接尋找較大值，且適應值不得小於零。若要搜尋最小值，則必須以一個常數減去原來的適應值作為新的適應值。其優點是容易使用，而且能區分出適應值之間的差異，缺點是當族群中有一

個染色體的表現特別突出時，尤其是演化初期，則在最佳解尚未出現時可能就會支配全部族群，落入局部最佳解的問題。

- (2) 期望值法：為輪盤法的改良，與輪盤法最大不同點在於，期望值法將染色體適應值的整數部分，當作一定會被複製的數目，小數部分則以輪盤法決定。例如，適應值為1.5的染色體，至少可以獲得一次複製，而0.5的部分就由轉動輪盤隨機決定。
 - (3) 均勻法：是使每個染色體被選到的機會相同，缺乏「適者生存」的精神。
 - (4) 競賽法：隨機任選兩個染色體比較，適應值較高者被選為父代，然後兩個都被放回族群中再次參加競賽，直到選出足夠數目的「種子染色體」。和輪盤法不同，競賽法亦可以反向操作，直接尋找較小值，適應值只要能夠比較大小即可，不限正負數。由於只比較的「方向」，而不考慮「距離」，因此可以避免過早收斂的情況，但相對的也忽略染色體間的差異程度。
 - (5) 穩態法：強調的是一種漸進的演化方式，在世代交替的過程中，新一代染色體不是全部由上一代演化而成。每一代的演化中，只有部份染色體被經過交配、突變運算的父代染色體所取代，其餘染色體仍然保留繼續參與演化。
 - (6) 菁英法：通常搭配其他選擇法，並強迫每一代的最佳解能保留到下一代，避免在選擇的過程中意外被淘汰。
- 交配(crossover)：將兩個個體(稱之為父個體及母個體)，做訊息的互換，以產生兩個新的子個體。目前常用的方法有三種，為單點(one point)、雙點(two points)、均勻(uniform)互換。
 - (1) 單點互換：以隨機亂數所產生的切斷點為界，以父 | 母、母 | 父的方法產生，其中「|」為切斷點，可參考圖 2.2。
 - (2) 雙點互換：以隨機亂數所產生的兩個切斷點為界，以父 | 母 | 父、母 | 父 | 母的方法產生，可參考圖 2.3。
 - (3) 均勻互換：兩個子個體各位元的來源取決於一隨機亂數的旗標值狀態，若旗標值為 1，則子個體一繼承父、子個體二繼承母，若旗標值為 0 則子個體一繼承母、子個體二繼承父，可參考圖 2.4。採用超過一個切點，其考量是避免在單點交配時，切點之前的基因總是與之後的基因分開的現象。一般研究認為，採用兩點交配即可獲得良好的效果。因為交配機制只是產生新答案，更多的切點並不保證答案變得更好，必須搭配選擇機制，才能讓較好的個體保留下來。

父個體	111 1111
母個體	000 0000
子個體 1	111 0000
子個體 2	000 1111

圖 2.2 單點互換交配法 (「|」為切斷點)

父個體	1 1111 1
母個體	0 0000 0
子個體 1	1 0000 1
子個體 2	0 1111 0

圖 2.3 雙點互換交配法

父個體	1111111
母個體	0000000
旗標狀態	0110100
子個體 1	0110100
子個體 2	1001011

圖 2.4 均勻互換交配法

- 突變(mutation)：為模仿生物基因的隨機突變而來。例如突變率 0.1%，則表示基因總數中有 0.1%的基因要進行突變。基因總數為族群大小、染色體個數、一個染色體的基因數三者之乘積。例如，0.1 % 代表 1000 個基因中才反轉一個基因，由 0 變 1 或由 1 變 0 突變的機率一般而言很小。突變運算可以幫助 GA 脫離局部最佳解。突變率也可以動態調整，當連續一段期間內族群的適應值都沒什麼改變時，可以將突變率調高，例如：Davis提出以線性的方式改變交配率以及突變率，隨著演化的進行，交配率降低，突變率增加[17]。Booker提出根據適應值的分布，動態調整交配率與突變率，當適應值進步的後增加交配率，當適應值趨近收斂的時候降低交配率，並增加突變率[20]。

然而要根據問題找出最適合的調整方式，需要經過相當的反覆試驗，有學者已經實證分析出以下兩種建議值供參考[19]：

- (1) 當群體大小為100時，交配率設為0.6，突變率設為0.001。
- (2) 當群體大小為30時，交配率設為0.9，突變率設為0.01。

- 結束規則：為了讓GA演化順利進行，需預先設定結束規則，使GA依該條件終止演化循環。文獻上常見的停止規則有四種：
 - (1) 當染色體適應值已滿足預先設定的目標值。
 - (2) 當達到預先設定之最大代數，例如200代。
 - (3) 族群內各染色體的同質性已達到預先設定的水準。例如，族群內最好和最差的染色體，其適應值的差異已達到預定的範圍。
 - (4) 達到最大的失敗次數，即無法進一步找到更佳解的演化代數，例如100個世代不再進步則停止。

演化的過程為一個迴圈，因此必須設定停止執行的判斷，用以表示演化結束。停止的時機通常可以參考兩個項目，一個是時間成本，一個是收斂程度。時間成本直接受演化代數影響，若希望演算在可預期的時間內結束，可以將演化代數設為固定值。收斂程度則較為彈性，當某一代的族群，其染色體的適應值趨近一致的時候，則停止演化。兩者並沒有絕對的好壞，可根據需要而選用，亦可同時採用，即演化進行到某個代數之前，停止條件參考的是收斂程度，而最多進行到該代數為止，使得演化能在可預期的時間中結束[19]。

- 儲存最佳解答(save best)：在演化過程中，將適應度值最佳的個體加以保留至下一次演化。一個簡單的GA運作過程可參考圖 2.5。

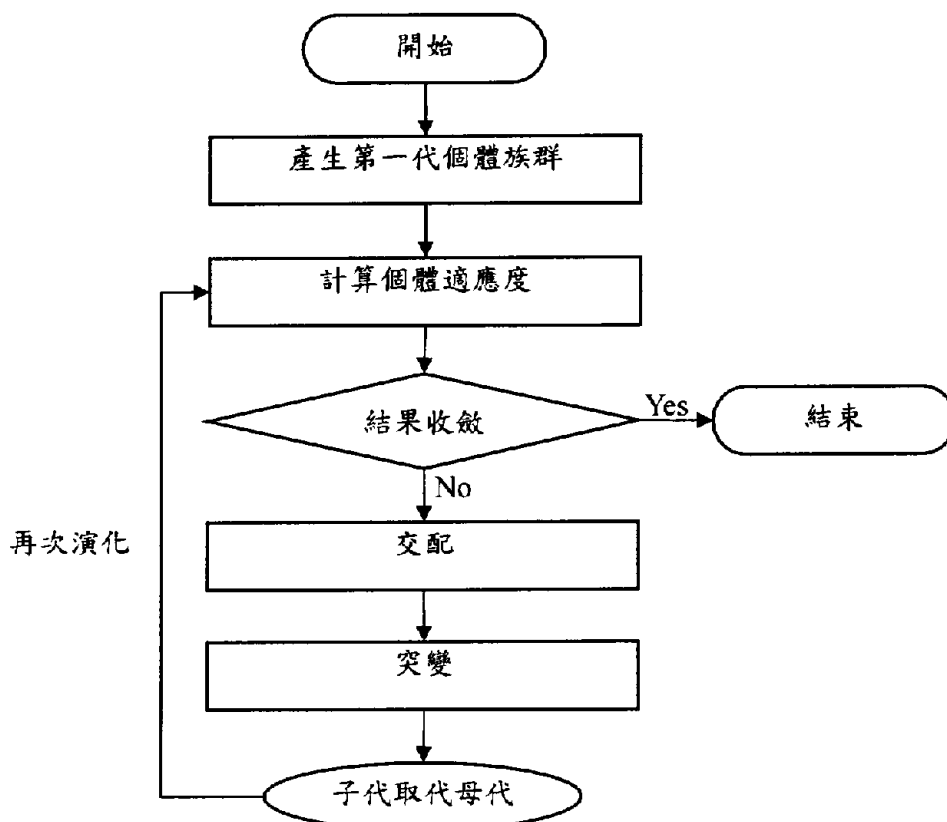


圖 2.5 GA 流程圖

2-3 遺傳演算法在強化式學習之應用

自從學者Holland提出遺傳演算法後，各學術領域開始利用遺傳演算法在其領域的研究之中，當然其中也包括強化式學習方面，本節將介紹遺傳演算法結合強化式學習的相關文獻及評論。

Mikami[4]指出，在應用強化式學習時，常遇到一些問題，即系統須具備大量的記憶空間，以儲存所需的狀態行為及反應行為，因此提出以遺傳演算法來減少所需的記憶空間，以加速學習時的收斂。

Zhao[3]認為在強化式學習上狀態與反應空間過大是一個待解決的問題，因此利用遺傳演算法克服這個問題，以遺傳演算法在強化式學習過程之初先對資料做篩選，使強化式學習的反應空間不會過大，使學習上較為準確。

Tsai[23]在代理人供應鏈模式中，利用遺傳演算法來求出供應鏈在隨機需求情況下各成員的最佳存貨政策組合。

Jellouli[24]認為供應商所面臨的環境是複雜而且變化快速的需求，所以提出以遺傳演算法來找出供應鏈中最佳的前置時間、存貨量及週轉率等，以達到供應鏈成本最佳化。

Yung[25]以代理人技術應用於供應鏈網路中倉庫位置的設計，並利用遺傳演算法來求出當倉庫位置不同時，所產生的持有成本、配送成本及再訂購成本等的一個最佳化組合。

從上述文獻中了解，遺傳演算法在學習能力方面所具有的特點，並且在供應鏈的最佳化問題方面及代理人應用上也是相當多年，因此在面對動態的供應鏈環境變化下，代理人不僅具有遺傳演算法的最佳化求解能力，並且可提升強化式學習的能力，透過以往的交易經驗，從中學習到更好的決策，進而提升整體供應鏈效益。此外，國內、外學者也常使用遺傳演算法的最佳化能力，用以輔助常見的模型架構(例如決策樹及類神經網路等...)達到最佳化目的，以下將介紹遺傳演算法在這兩種模型架構在強化式學習的概念。

2-3-1 遺傳演算法結合決策樹

決策樹具有模型構成能力[26,27]，其常見的型態如圖2.6及圖2.7所示，圖2.6是具邏輯規則的決策樹型態，其構成是由IF、OR、AND以及THEN所組成，然而橫向的架構需要哪些條件、幾個條件以及縱向的架構需要幾項構成，方達到模型最適化，此時就能夠交給遺傳演算法優化之[27]。圖2.7是一個迴歸型態的決策樹模型，其中 $X_1 \sim X_{15}$ 能夠以運算子(輸入項目或常數等...)及運算元(+、-、 \times 、 \div 、 X^y 、ln或Sin等...)所構成[27]，決定採用哪些運算子及哪些運算元也能夠交給遺傳演算法優化之，此兩種模型架構再搭配目標函數(目標最大化及誤差最小化等...)，就能夠達到模型最適化的目的。

IF (條件A₁ and 條件B₁ and 條件C₁ and...)
 OR (條件A₂ and 條件B₂ and 條件C₂ and...)
 ⋮
 AND (條件A₃ and 條件B₃ and 條件C₃ and...)
 ⋮
 THEN 結論Y

圖 2.6 決策樹模型示意圖[1]




圖 2.7 決策樹模型示意圖

2-3-2 遺傳演算法結合類神經網路

類神經網路可說是一種模型的建構工具，其模型的架構是由輸入層、隱藏層、隱藏節點數、輸出層、內部的學習速率及慣性因子所構成，而類神經網路的架構的決定是由人為所訂定，因此何者為最佳的模型架構將無法一一列舉之，然而這些架構就能夠以遺傳演算法優化求解之，遺傳演算法結合類神經網路的模式大致包含下列四種模式：

- 輸入層最佳化：以遺傳演算法排除不重要項目，並選取較具關聯性的項目，將輸入項目優化篩選之。
- 隱藏層最佳化：以遺傳演算法優化隱藏層層數及每層隱藏層之隱藏節點數。
- 權重值最佳化：以遺傳演算法優化相互連結權重值及連結偏權值。
- 參數項最佳化：以遺傳演算法優化最佳之內部學習速率與慣性因子。

2-4 混凝土材料行為建模問題

高性能混凝土本質上是強調高強度及高工作度，因此本節將針對強度及工作度做國內、外研究相關文獻的探討。

一、強度

由於高性能混凝土的組成比傳統混凝土更複雜，因而提高了混凝土抗壓強度預測的困難度，使得迴歸分析無法建立精確的預測模型。因此，國、內外學者相繼採用人工智慧中，類神經網路以及演化式計算的方法，以下是人工智慧在強度方面的相關文獻探討。

彭鈞哲[8]採用多元非線性類神經網路的方法，建立高性能混凝土強度預測模型。以水泥、飛灰、爐石、水、強塑劑、粗骨材、細骨材等七種成份的用量以及齡期為輸入變數，抗壓強度為輸出變數。結果顯示，類神經網路是建立精確高性能混凝土強度模型

的有效方法。

Chen[11]嘗試結合進化演算法(Evolutionary Algorithms, EAs)中的語法式進化(Grammatical Evolution, GE)與遺傳演算法,其目的是獲得更為理想的高性能混凝土抗壓強度預測模型。結果顯示,預測效果雖較傳統迴歸分析(Regression Analysis, RA)為佳,但是由各項評鑑指標顯示,精確度仍有待提升。

葉怡成[12]以遺傳演算法建構出高性能混凝土的強度模型。研究分成三個模式:(1)參數最佳化:從既有固定的強度模型中,使用遺傳演算法,搜尋各項影響變數的最佳係數。(2)公式結構最佳化:使用遺傳演算法,搜尋各項變數中的最佳係數,並進一步決定最佳強度模型。(3)公式結構最佳化之改進:使用遺傳演算法,搜尋最佳係數,並決定最佳強度模型後,再使用迴歸分析對混凝土強度預測值進行調節。結果顯示,第三個模式的準確度最高。

許慶安[28]以七天強度及水泥用量、拌合水用量、細骨材用量、粗骨材六分料用量、粗骨材三分料用量、附加劑用量、W/C 及 F.M.計有九項變數做為輸入變數;進行廿八天齡期抗壓強度之推估預測。結果顯示,採用類神經網路推估模式之相關係數與準確度均優於傳統的統計迴歸分析方法,其推估值與真實值之相關係數達 0.983。

陳怡成[29]以適合建構非線性模型的類神經網路取代傳統的迴歸分析,做為模型建構工具。再者,混凝土配比設計時由於使用的材料眾多,各材料價格亦會隨物價波動而變化,以往配比設計進行時通常只考慮強度與工作度,忽略經濟性,因此本研究考慮各項使用材料成本,設計出成本最低之高性能混凝土之配比。結果顯示,研究所設計之配比大致上均能滿足強度與工作度之需求,且成本低於傳統混凝土,證明本文所提之方法是高性能混凝土配比設計之一個具有潛力的新方法。

Yeh[30]指出飛灰與爐灰混凝土是一種高度複雜的材料,以致於模式化其行為變得相當地困難。因此提出一個使用類神經網路來模式化飛灰與爐灰混凝土強度的方法。強度被視為齡期與所有成份,包括水泥、飛灰、爐灰、水、強塑劑、粗骨材、細骨材的函數。並探討在具有不同的飛灰與爐灰替代百分比下,飛灰與爐灰混凝土的強度行為。結果顯示,飛灰與爐灰用量與強度的關係程度有滿意的結果。

Yeh[31]提出一個在指定的工作度與強度下,使用類神經網路與非線性規劃之高性能混凝土配比設計最佳化的方法。它包括三個步驟:(1)利用實驗數據與類神經網路建構精確的工作度與強度模型,(2)將此模型整合在一個可以評估給定配比下混凝土特定性質的軟體,(3)將此軟體與一個可以搜尋最佳配比設計的非線性規劃軟體整合,並以一個實驗計劃驗證此一方法的可用性。結果顯示,本研究是一個可行的高性能混凝土配比設計最佳化方法。

Sonbei[32]以二水準因子設計法建構包含五個獨立變數的自填充混凝土材料行為模式。這五個獨立變數包括 limestone power 比例、砂比例、強塑劑用量、viscosity agent 用量、水膠比。考慮的材料行為包括坍度、1 天及 28 天強度等。結果顯示,所產生的

模型確實能夠提供設計低抗壓強度自填充混凝土配比的有用資訊。

Abbasi[33]為了最佳化混凝土配比，建立混凝土工作度及強度模型。為了降低試驗的數量，但並不犧牲存在於因子間的交互作用，以因子設計法做為模型的建構工具，探討的因子包括水灰比、粗骨材對總骨材比、總骨材對水泥比等三個因子，並以迴歸分析建構出一個二次方程式的強度模型，及簡單的三次方程式工作度模型。

Sonbei[34]為了設計低成本中等強度自填充混凝土材，以因子設計法建構包含四個獨立變數的自填充混凝土材料行為模式。這四個獨立變數包括水泥用量、PFA 飛灰用量、水膠比、強塑劑用量。考慮的材料行為包括坍流度、7 天、28 天及 90 天抗壓強度等。結果顯示，所產生的模型確實能夠提供設計中抗壓強度自填充混凝土配比有用資訊。

二、坍度

柯泰至[35]為建立一精確的工作度預測模型，以單體形心設計做為實驗設計工具，以迴歸分析及類神經網路為模型建構工具，最後以實驗驗證，檢驗模型之可信度。結果顯示，(1)類神經網路為較理想之建構工具，(2)在工作度的影響因子中，以強塑劑之曲率作用，及水與強塑劑間之交互作用之影響最大，(3)在模型之可預測性上，以坍度及坍流度有一定程度的預測性，坍流時間沒有可預測性。

陳家偉[36]研究建構工作度之經驗模型的方法。一般建構經驗模式之主要工具為迴歸分析。然由於高性能混凝土配比材料用量與工作度之關係為複雜曲線關係，迴歸分析可能不足以建構準確之模型，因此，研究亦使用類神經網路做為工具。結果顯示，(1)建構高性能混凝土工作度模型係一可行之研究，且模型具相當之準確性；(2)以類神經網路建構高性能混凝土工作度模型遠優於以迴歸分析建構模型；(3)篩選有問題的實驗點，以獲得可靠之實驗數據，對建構精確之模型有相當大的助益。

Khayat[37]使用因子設計的方法在給定五項變數時，成功的建立水中混凝土的工作度及抗壓強度的模型。這五項變數分別是膠結料用量、水膠比、砂對總骨材比、以及兩種不同效果的添加劑用量。結果顯示，在給定這五項變數一定的區間範圍時，變數之間具有極具影響配比的交互作用。在研究中，以等高線圖探討各變數對工作度、抗壓強度的影響。在成本分析中，也成功的展現了在不同的配比需求下，經濟的配比設計。這個研究成功的建立一個有用的數學模型，提供使用者在設計水中混凝土配比設計時一個有用的設計工具。

Larrard[38]以半理論方式建構高性能混凝土的工作度模型、強度模型、勁度模型、最大理論堆積密度模型，並加以整合，發展出一套名為 BETONLAB 的高性能混凝土配比設計最佳化軟體。

第三章 高性能混凝土強度模型之應用

3-1 前言

為建構 HPC 強度行為公式，本研究以遺傳演算法為主軸並結合三種不同的模型模式化能力，達成機器學習的效果，包括：

- 遺傳演算法結合迴歸分析(Genetic Algorithms of Regression Analysis, GARA)
- 遺傳演算法結合運算樹 (Genetic Algorithms of Operation Tree, GAOT)
- 遺傳演算法結合類神經網路(Genetic Algorithms of Neuron Network, GANN)

3-1-1 資料收集

影響 HPC 強度的變數包括：水泥(C)、飛灰(FL)、爐石(SL)、水(W)、強塑劑(SP)、粗骨材(CA)，細骨材(FA)及齡期(AGE)。本研究共收集 1196 筆上述變數的高性能混凝土配比資料[8]，並以隨機的方式取樣 1000 筆資料做為模型建構的訓練範例，而剩餘的 196 筆資料做為驗證的測試範例，以評估所產生的模型是否具備普遍性，其強度資料的值域及型態如表 3.1 所示。

表 3.1 強度資料中各變數的值域及型態

變數名稱	值域	單位	型態	
C	71.00~ 897.00	Kg/m ³	連續	自變數
FL	0.00~ 200.10	Kg/m ³	連續	
SL	0.00~ 359.40	Kg/m ³	連續	
W	118.00~ 314.00	Kg/m ³	連續	
SP	0.00~ 32.20	Kg/m ³	連續	
CA	595.00~ 1820.00	Kg/m ³	連續	
FA	387.10~ 1300.00	Kg/m ³	連續	
AGE	1.00~ 365.00	day	連續	
W/C	0.24~ 2.73	比例	連續	
W/B	0.24~ 0.90	比例	連續	
W/S	0.04~ 0.13	比例	連續	
TA/B	2.18~ 9.85	比例	連續	
f _c	296.30~ 17691.00	psi	連續	

其中 $W/C=(W+SP)/(C)$ 、 $W/B=(W+SP)/(C+FL+SL)$ 、 $W/S=(W+SP)/(C+FL+SL+CA+FA)$ 、 $TA/B=(CA+FA)/(C+FL+SL)$ 。

3-1-2 演算法參數設定及適應度函數

本研究所採用之遺傳演算法參數設定為：

- 交配後產生之個體數設定為 100 個；
- 交配率設定為 0.9；
- 突變率設定為 0.001；
- 使用精英策略強迫保留目前為止所搜尋到的最佳個體；
- 設定收斂條件為連續 1000 個世代不再進步則停止程式；
- 本研究取誤差均方根(Root of Mean Square, RMS)最小化作為目標值，其 RMS 如公式 (3.1) 之公式[22]。

$$RMS = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \dots\dots\dots(3.1)$$

其中 \hat{y}_i 為第 i 筆資料的預測強度值； y_i 為第 i 筆資料的實際強度值； n 為訓練範例或測試範例之總筆數。

3-2 遺傳演算法結合迴歸分析產生強度模式

使用遺傳演算法搜尋並決定最佳 HPC 強度模型所使用材料的最佳係數，再使用單變數迴歸分析對強度模型進行調節。

3-2-1 模型建構

為了能夠使用遺傳演算法產生最佳的強度模型，本研究以樹狀圖表達強度模型，例如圖 3.1 之樹狀圖表示為公式 (3.2) 之公式。

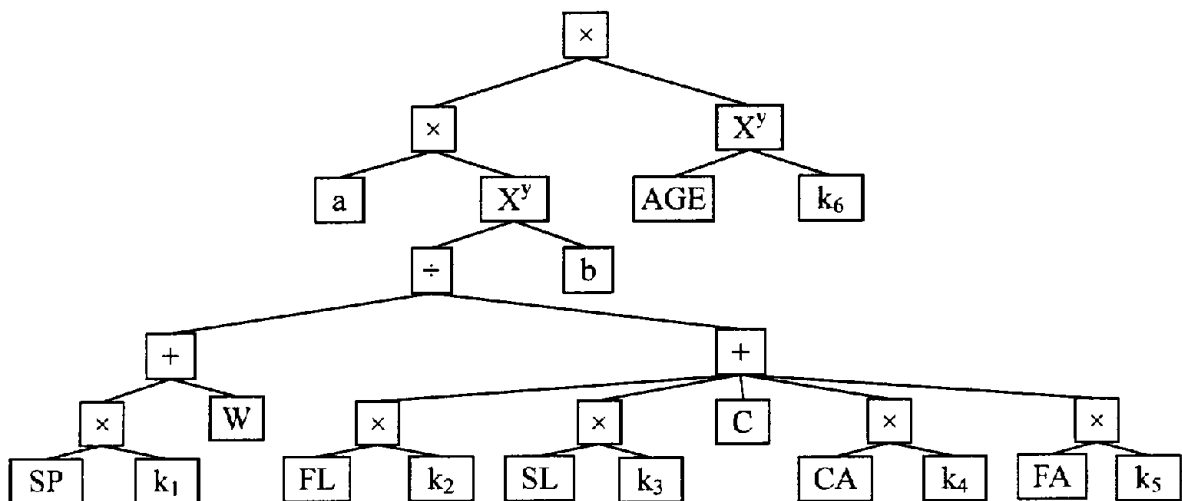


圖 3.1 HPC 強度模型樹狀圖

$$f = a \left(\frac{W + SP \times k_1}{C + FL \times k_2 + SL \times k_3 + CA \times k_4 + FA \times k_5} \right)^b \times AGE^{k_6} \dots\dots\dots(3.2)$$

本研究採用如圖 3.2 之初始可調整強度模型樹狀圖結構，其中 $y_1 \sim y_9$ 是運算元變數，可能的值有 {+、-、×、÷、 X^y 、ln}，如表 3.2 所示。a、b 及 $k_1 \sim k_6$ 是係數變數。若係數沒有給定區間限制，或區間限制給定過大，則程式在最佳化過程中可能耗時甚巨，這樣的結果將不符合時間及成本效益。因此，若本身知識背景充足，則能夠先對係數進行區間限制。其值域如表 3.3 所示。

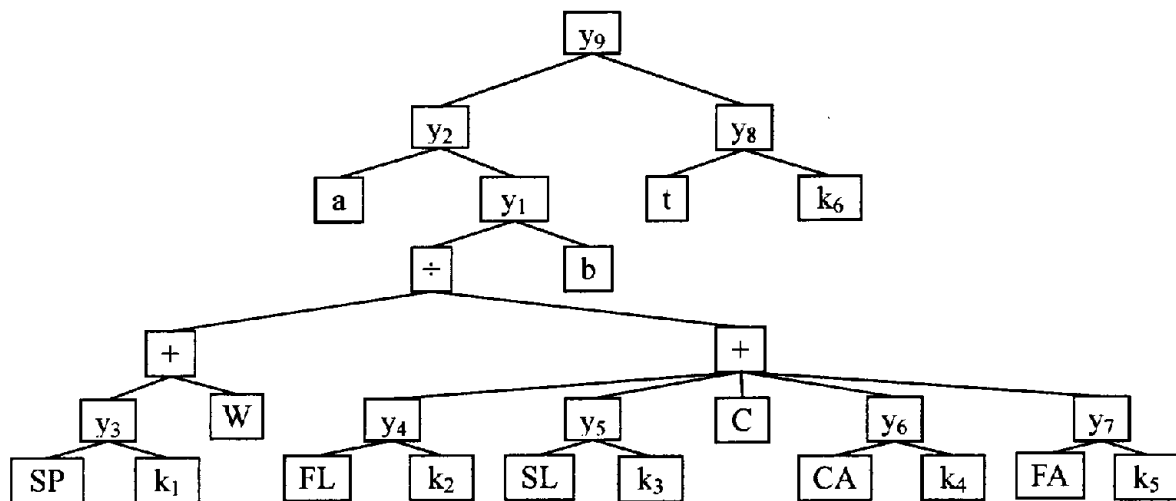


圖 3.2 初始可調整強度模型

表 3.2 運算元變數之意義

值域	1	2	3	4	5	6
運算元	+	-	×	÷	X^y	ln

表 3.3 係數的區間限制

係數	a	b	k_1	k_2	k_3	k_4	k_5	k_6
搜尋值域範圍	-5000~5000							

3-2-2 運算樹預測值之迴歸修正

預測值有時會有偏斜現象，即預測值與實際值間存在平移及旋轉關係。因此以單變數迴歸分析改進強度預測公式，如公式 (3.3) 所示。

$$y = \alpha + \beta \cdot f \dots\dots\dots(3.3)$$

表 3.6 GARA 產生 HPC 強度模型之 RMS

訓練範例	測試範例
1307.19 psi	1219.15 psi





圖 3.4 GARA 訓練範例之 HPC 強度散佈圖 圖 3.5 GARA 測試範例之 HPC 強度散佈圖

3-3 運算樹遺傳演算法產生強度模式

儘管 GARA 能夠提出一個 HPC 強度模型公式，但模型卻不夠靈活且準確度不如預期，因此本節提出了一個以運算樹遺傳演算法 (Genetic Algorithms of Operation Tree, GAOT) 的方法。

3-3-1 模型建構

本研究為產生自組織公式，採用了運算樹(Operation Tree)的公式表達方式。圖 3.6 為一個五層的運算樹示意圖，而運算樹的運算元及變數基因編碼方式如表 3.7 及表 3.8 所示。其中：

- 第一層的樹枝(X_1)限制僅能搜尋運算元編碼，因此所能搜尋的編碼為 1~6 的整數；
- 第二、三、四層樹枝($X_2 \sim X_{15}$)可搜尋的範圍完全自由，因此所能搜尋的編碼為 1~15 的整數，其中編碼 15 的 K 值限定為 -100~100 的連續數值；
- 第五層的樹枝($X_{16} \sim X_{31}$)限制僅能搜尋變數編碼，因此所能搜尋的編碼為 7~15 的整數。

此外此樹狀結構遵守下列規則：

- 當該樹枝搜尋到的運算元編碼為 \ln 時，則限制下一層僅「左」樹枝有效。
- 當該樹枝搜尋到變數編碼時，則限制該樹枝無法再成長至下一層。

第一層
第二層
第三層
第四層
第五層




圖 3.6 五層的運算樹示意圖

表 3.7 運算元之基因編碼方法

編碼	1	2	3	4	5	6
運算元	+	-	x	÷	x ^y	ln

表 3.8 八變數及常數之基因編碼方法

編碼	7	8	9	10	11	12	13	14	15
運算元	C	FL	SL	W	SP	CA	FA	AGE	K

3-3-2 運算樹預測值之迴歸修正

運算樹的預測值有時會有偏斜現象，即預測值與實際值間存在平移及旋轉關係。為修正運算樹的偏斜現象，本研究以下列單變數迴歸公式 (3.4) 改正之：

$$y = \alpha + \beta \cdot f \dots\dots\dots(3.4)$$

其中 y = 以迴歸公式改進後之運算樹預測強度值

f = 運算樹預測強度值

$$\alpha = \bar{y} - \beta \cdot \bar{f}$$

$$\beta = \frac{\sum_{i=1}^n (f_i - \bar{f}) \times (y_i - \bar{y})}{\sum_{i=1}^n (f_i - \bar{f})^2}$$

其中 \bar{y} = 所有資料的實際強度平均值

\bar{f} = 所有資料的運算樹預測強度平均值

y_i = 第i筆資料的實際強度值

f_i = 第i筆資料的運算樹預測強度值

3-3-3 結果

本研究分別展示(一)五層八變數及(二)五層十二變數的 HPC 強度模型樹狀圖，十二變數的編碼如表 3.9 所示，其目的是評估 GAOT 產生的 HPC 強度模型具備可靠性。

表 3.9 十二變數之基因編碼方法

編碼	7	8	9	10	11	12	13	14	15	16	17	18	19
運算元	C	FL	SL	W	SP	CA	FA	AGE	W/C	W/B	W/S	TA/B	K

(一)五層八變數

圖 3.7 為使用五層八變數所產生的運算樹。運算樹之修正係數 $\alpha = -2366.78$ 、 $\beta = 400.82$ 。運算樹及修正係數組成之公式如公式 (3.5) 所示，如表 3.10 所示，其訓練範例及測試範例之 RMS 分別是 1298.50 psi 及 1168.66 psi，而其散佈圖如圖 3.8 及圖 3.9 所示。




圖 3.7 五層八變數 GAOT 產生之運算樹

$$y = -2366.78 + 400.82 \times \frac{(SL + FL + C)}{2SP + W - 50.90} \times [\ln(AGE) + \ln(35.63)] \dots \dots \dots (3.5)$$

表 3.10 五層八變數 GAOT 產生 HPC 強度模型之 RMS

訓練範例	測試範例
1298.50 psi	1168.66 psi




圖 3.8 五層八變數 GAOT 之訓練範例
HPC 強度散佈圖




圖 3.9 五層八變數 GAOT 之測試範例
HPC 強度散佈圖

(二)五層十二變數

圖 3.10 為使用本方法所產生的運算樹。運算樹之修正係數 $\alpha = -2221.20$ 、 $\beta = 404.83$ 。運算樹及修正係數組成之公式如公式 (3.6) 所示，如表 3.11 所示，其訓練範例及測試範例之 RMS 分別是 1381.77psi 及 1366.77psi，而其散佈圖如圖 3.11 及圖 3.12 所示。

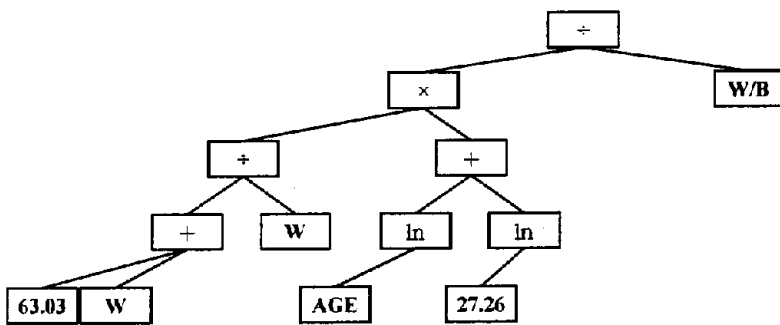


圖 3.10 五層十二變數 GAOT 產生之運算樹

$$y = -2221.20 + 404.83 \times \frac{(63.03 + W)/W}{W/B} \times [\ln(\text{AGE}) + \ln(27.26)] \dots \dots \dots (3.6)$$

表 3.11 五層十二變數 GAOT 產生 HPC 強度模型之 RMS

訓練範例之 RMS	測試範例之 RMS
1381.77 psi	1366.77 psi




圖 3.11 五層十二變數 GAOT 之訓練範例 HPC 強度散佈圖




圖 3.12 五層十二變數 GAOT 之測試範例 HPC 強度散佈圖

3-4 遺傳演算法結合類神經網路產生強度模式

由於 GARA 公式不夠靈活且準確度不如預期，此外 GAOT 雖然能夠達成公式自組織，但在準確度的能力上同樣不夠完善，因此本研究另外提出一個遺傳演算法結合類神經網路(Genetic Algorithms of Neuron Network, GANN)的方法，圖 3.13 為一個八個輸入變數、一個隱藏層、多個節點及一個輸出變數的神經網路模型，本研究是以標準的神經網路模型架構，但最佳化權值大小由最陡坡降法(Gradient Steepest Descent Method)改為以遺傳演算法求解，本章將進行多個隱藏層節點的模型建構，期望以 GANN 的方法，找出最佳的 HPC 模型。




圖 3.13 八個輸入變數、一個隱藏層、多個節點及一個輸出變數的神經網路模型

3-4-1 模型建構

本研究企圖以 GANN 的方法找出最佳的 HPC 模型，這個 GANN 的方法包括了五個部分[13]：

- 輸入層尺度轉換；
- 輸入層與隱藏層節點關係；
- 隱藏層節點函數建立；
- 隱藏層節點與輸出層關係；
- 輸出層反尺度轉換。

(一)輸入層尺度轉換

由於每種變數值域的範圍不一，為求正規化，因此進行值域-1~1 的轉換，其轉換公式如公式 (3.7) 所示。

$$x = \frac{X - X_{\min}}{X_{\max} - X_{\min}}(D_{\max} - D_{\min}) + D_{\min} \dots\dots\dots(3.7)$$

其中 X 為正規化前的變數； X_{\min} 為該變數之最小值； X_{\max} 為該變數之最大值； D_{\max} 為該技術指標正規化後值域中最大值，本研究 D_{\max} 設定為 1； D_{\min} 為該變數正規化後值域中最小值，本研究 D_{\min} 設定為 -1；x 為正規化後的變數。

(二)輸入層與隱藏層節點關係

輸入層與隱藏層節點的關係如公式 (3.8) 所示。

$$net_k = \sum_{i=1}^{N_{inp}} W_{ik} \times x_i + Bias_k \dots\dots\dots(3.8)$$

其中 net_k 是隱藏層節點的加權乘積的值； W_{ik} 是隱藏層節點與輸入層之間的權值；x 是尺度化後的輸入變數；Bias 是隱藏層的修正偏權值。

(三)隱藏層節點函數建立

本研究所使用的隱藏層節點轉換函數如公式 (3.9) 所示，其目的是將值域正規化至 -1~1 之間，其轉換函數圖，如圖 3.14 所示。

$$f(net_k) = \text{TANH}(net_k) \dots\dots\dots(3.9)$$




圖 3.14 隱藏層節點之轉換函數圖

(四)隱藏層節點與輸出層關係

神經網路的輸出值公式如公式 (3.10) 所示。

$$net_j = \sum_{k=1}^{N_{hd}} W_{kj} \times f(net_k) + Bias_j \dots \dots \dots (3.10)$$

其中 W_{kj} 是隱藏層節點與輸出層之間的權值； $Bias$ 是輸出層的修正偏權值。

(五)輸出層反尺度轉換

在輸出變數部分，再經由反尺度轉換成真實尺度，其公式如公式 (3.11) 所示。

$$y = \frac{(y_{old} + 1) \times (D_{max} - D_{min})}{2} + D_{min} \dots \dots \dots (3.11)$$

其中 y 為反尺度化後的變數； D_{max} 為該技術指標反尺度化後值域中最大值，本研究 D_{max} 設定為 17691.0； D_{min} 為該變數反尺度化後值域中最小值，本研究 D_{min} 設定為 296.3； y_{old} 為反尺度化前的變數。

3-4-2 結果

傳統類神經網路是以最陡坡降法來決定最佳權值大小，本研究是以遺傳演算法的最佳化能力來決定權值及修正偏權值的大小。本節將展示八個輸入變數，一個隱藏層，一個輸出變數，以及分別為(一)四個隱藏層節點(8-4-1)、(二)八個隱藏層節點(8-8-1)、(三)十六個隱藏層節點(8-16-1)來做 HPC 最佳模型做探討。

(一)GANN(8-4-1)

圖 3.15 及圖 3.16 分別為 GANN(8-4-1)在訓練範例及測試範例之 HPC 強度散佈圖，其 RMS 如表 3.12 所示。




圖 3.15 GANN(8-4-1)訓練範例之 HPC 強度散佈圖




圖 3.16 GANN(8-4-1)測試範例之 HPC 強度散佈圖

表 3.12 GANN(8-4-1)強度模型之 RMS

訓練範例	測試範例
1354.20 psi	1420.23 psi

(二)GANN(8-8-1)

圖 3.17 及圖 3.18 分別為 GANN(8-8-1)在訓練範例及測試範例之 HPC 強度散佈圖，其 RMS 如表 3.13 所示。




圖 3.17 GANN(8-8-1)訓練範例之 HPC 強度散佈圖




圖 3.18 GANN(8-8-1)測試範例之 HPC 強度散佈圖

表 3.13 GANN(8-8-1)強度模型之 RMS

訓練範例	測試範例
1068.87 psi	1302.46 psi

(二)GANN(8-16-1)

圖 3.19 及圖 3.20 分別為 GANN(8-16-1)在訓練範例及測試範例之 HPC 強度散佈圖，其 RMS 如表 3.14 所示。




圖 3.19 GANN(8-16-1)訓練範例之 HPC 強度散佈圖




圖 3.20 GANN(8-16-1)測試範例之 HPC 強度散佈圖

表 3.14 GANN(8-16-1)強度模型之 RMS

訓練範例	測試範例
929.25 psi	1087.94 psi

3-5 結果及討論

3-5-1 結果的解釋

為瞭解每個變數對強度之影響力，在此(1)先計算所有變數平均值及標準差，並計算其平均值加減 0.5 個標準差之值，如表 3.15 所示。(2)計算在其他變數固定為其平均值之下，某一變數改為其平均值加 0.5 個標準差之下的混凝土強度預測值，減去其平均值減 0.5 個標準差之下的強度預測值，所得之差額。其 GARA 的結果如表 3.16 及圖 3.21 所示；其 GAOT 八變數的結果如表 3.17 及圖 3.22 所示；其 GAOT 十二變數的結果如表 3.18 及圖 3.23 所示。

表 3.15 1196 筆各項變數的平均值及標準差

	\bar{x}	σ	$\bar{x}+0.5\sigma$	$\bar{x}-0.5\sigma$
C	288.5	143.9	360.5	216.5
FL	131.2	33.8	148.1	114.3
SL	146.9	63.6	178.7	115.1
W	183.8	27.1	197.3	170.2
SP	9.5	4.9	11.9	7.0
CA	960.1	133.9	1027.0	893.1
FA	806.8	110.9	862.3	751.4
AGE	56.1	79.3	95.8	16.5
W/C	0.8	0.2	0.9	0.6
W/B	0.7	0.3	0.8	0.5
W/S	0.1	0.0	0.1	0.1
TA/B	6.4	3.3	8.0	4.7

表 3.16 GARA 產生強度模型各項變數的影響性

	$\bar{f}_c - 0.5\sigma$ (KSI)	$\bar{f}_c + 0.5\sigma$ (KSI)	差值	重要性
C	7.56	10.47	2.919	+++
FL	8.67	9.36	0.685	+
SL	8.37	9.66	1.290	++
W	10.09	8.08	-2.008	---
SP	9.37	8.68	-0.685	-
CA	8.99	9.04	0.055	+
FA	8.95	9.08	0.131	+
AGE	7.23	9.79	2.556	+++

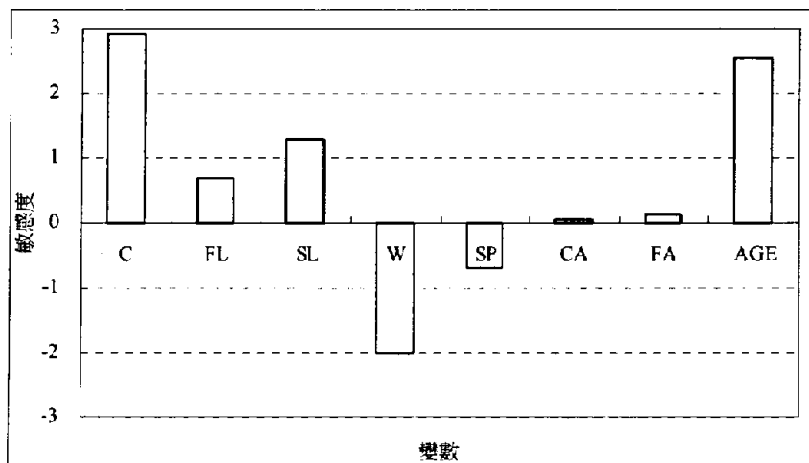


圖 3.21 GARA 產生強度模型各項變數的影響性

表 3.17 GAOT 八變數產生強度模型各項變數的影響性

	$\bar{f}_c - 0.5\sigma$ (KSI)	$\bar{f}_c + 0.5\sigma$ (KSI)	差值	重要性
C	7.56	10.45	2.889	+++
FL	8.66	9.34	0.678	+
SL	8.37	9.64	1.277	++
W	10.12	8.07	-2.049	---
SP	9.38	8.65	-0.731	-
CA	NA	NA	NA	NA
FA	NA	NA	NA	NA
AGE	7.17	9.80	2.635	+++




圖 3.22 GAOT 八變數產生強度模型各項變數的影響性

表 3.18 GAOT 十二變數產生強度模型各項變數的影響性

	$\bar{f}_c - 0.5\sigma$ (KSI)	$\bar{f}_c + 0.5\sigma$ (KSI)	差值	重要性
C	7.98	10.95	2.970	+++
FL	9.12	9.82	0.697	+
SL	8.81	10.12	1.312	++
W	10.61	8.51	-2.097	---
SP	9.62	9.32	-0.295	-
CA	NA	NA	NA	NA
FA	NA	NA	NA	NA
AGE	7.51	10.32	2.807	+++




圖 3.23 GAOT 十二變數產生強度模型各項變數的影響性

此外 GANN 以公式 (3.12) 計算各項變數的敏感性。其 GANN8-4-1、8-8-1、8-16-1 的結果分別如圖 3.24~3.26 及表 3.19~3.21 所示。表 3.22 圖 3.27 列出各項變數於三種方法的影響性比較，從表中可見影響力依序是水泥、齡期、水、爐石、強塑劑、飛灰，而粗、細骨材用量對強度並不敏感。

$$\sum f'_k \times W_{ik} \times f'_j \times W_{kj} \dots\dots\dots(3.12)$$

其中 $f'_k = (1 + \text{TANH}(\text{Bias}_k)) \times (1 - \text{TANH}(\text{Bias}_k))$; $f'_j = (1 + \text{TANH}(\text{Bias}_j)) \times (1 - \text{TANH}(\text{Bias}_j))$

表 3.19 GANN8-4-1 產生強度模型各項變數的影響性

	敏感分析	重要性
C	0.921	+++
FL	0.264	+
SL	0.324	++
W	-0.877	---
SP	-0.210	-
CA	0.073	+
FA	-0.109	-
AGE	0.234	+




圖 3.24 GANN(8-4-1)產生強度模型各項變數的影響性

表 3.20 GANN(8-8-1)產生強度模型各項變數的影響性

	敏感分析	重要性
C	0.299	+++
FL	0.137	++
SL	0.121	++
W	-0.180	--
SP	-0.026	-
CA	0.068	+
FA	-0.030	-
AGE	0.292	+++




圖 3.25 GANN(8-8-1)產生強度模型各項變數的影響性

表 3.21 GANN(8-16-1)產生強度模型各項變數的影響性

	敏感分析	重要性
C	0.535	+++
FL	0.177	+
SL	0.326	++
W	0.058	+
SP	0.073	+
CA	0.074	+
FA	0.082	+
AGE	0.066	+




圖 3.26 GANN(8-16-1)產生強度模型各項變數的影響性

表 3.22 各變數於三種方法的影響性比較

	C	FL	SL	W	SP	CA	FA	AGE
GARA	+++	+	++	---	-	+	+	+++
GAOT 八變數	+++	+	++	---	-	NA	NA	+++
GAOT 十二變數	+++	+	++	---	-	NA	NA	+++
GANN(8-4-1)	+++	+	++	---	-	+	-	+
GANN(8-8-1)	+++	++	++	--	-	+	-	+++
GANN(8-16-1)	+++	+	++	+	+	+	+	+

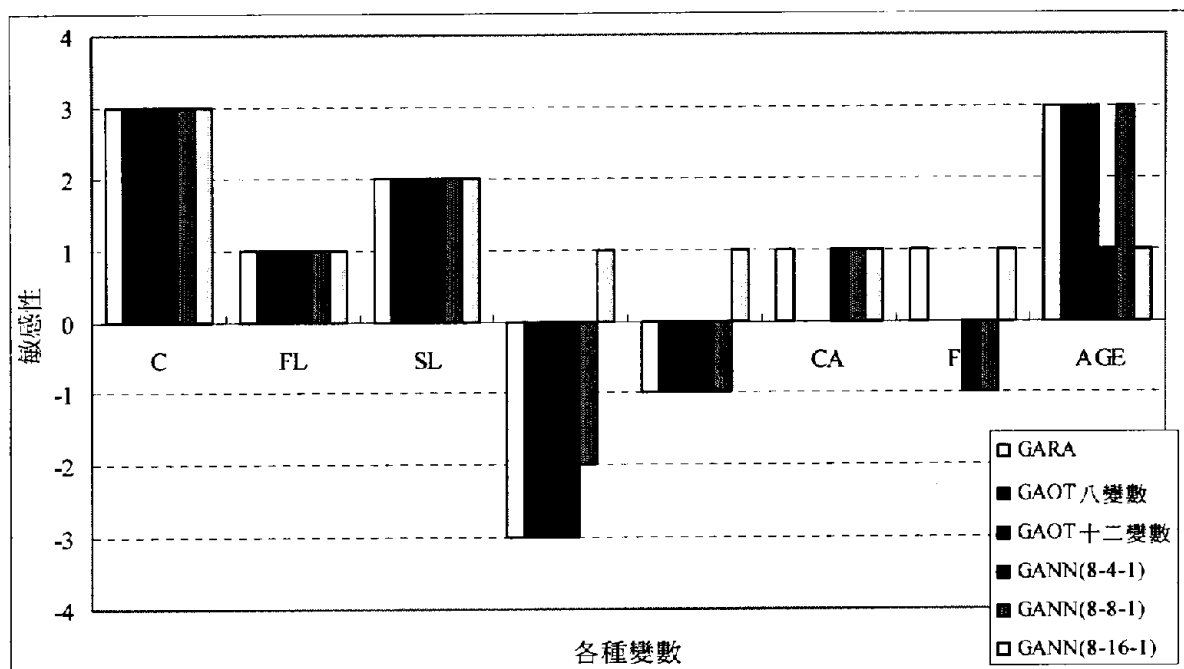


圖 3.27 各變數於三種方法的影響性比較

3-5-2 模型準確性及解釋性比較

為驗證本研究提出之方法為一可行且可靠的高性能混凝土強度模型建構方法，本研究另外以常見的迴歸分析及三種已經發表的 HPC 強度建模方法，做模型準確性及解釋性的評估：

- (一) 迴歸分析(Regression Analysis, RA)
- (二) 語法式進化遺傳演算法(Grammar Evolution Genetic Algorithms, GEGA)[11]
- (三) 巨觀進化遺傳規劃(Macro-evolutionary Algorithms Genetic Programming, MEGP)[10]
- (四) 倒傳遞網路(Back-propagation Networks, BPN)[8]

以上四種建模方法將套用本研究所使用之實驗數據，以進行強度模型準確度及解釋性的比較。

(一) 迴歸分析(Regression Analysis, RA)

公式 (3.13) 為使用八變數產生的迴歸分析強度模型，t 統計量如表 3.23 及圖 3.28 所示，其訓練範例及測試範例之 RMS 分別是 1799.73 psi 及 1823.12 psi，如表 3.24 所示，而其散佈圖如圖 3.29 及圖 3.30 所示。公式 (3.14) 為使用十二變數產生的迴歸分析強度模型，t 統計量如表 3.25 及圖 3.31 所示，其訓練範例及測試範例之 RMS 分別是 1767.50 psi 及 1811.17 psi，如表 3.26 所示，而其散佈圖如圖 3.32 及圖 3.33 所示。

$$f'_c = 12454.84 + 20.06C + 15.04FL + 14.20SL - 69.79W - 98.83SP - 0.30CA - 1.94FA + 13.64AGE \quad \dots\dots\dots(3.13)$$

表 3.23 8 變數迴歸分析 t 統計量

	係數	標準誤差	t 統計
截距	12454.84	1082.29	11.51
C	20.06	0.58	34.49
FL	15.04	1.45	10.35
SL	14.20	0.95	15.00
W	-69.79	2.75	-25.42
SP	-98.83	14.88	-6.64
CA	-0.30	0.53	-0.57
FA	-1.94	0.61	-3.16
AGE	13.64	0.75	18.09

表 3.25 12 變數迴歸分析 t 統計量

	係數	標準誤差	t 統計
截距	2330.41	2952.61	0.79
C	23.54	2.28	10.33
FL	18.11	3.04	5.95
SL	15.58	2.61	5.97
W	-139.07	15.71	-8.85
SP	-168.30	21.84	-7.71
CA	6.46	1.40	4.60
FA	5.33	1.48	3.59
AGE	13.07	0.75	17.45
W/C	400.46	284.71	1.41
W/B	7164.88	5440.99	1.32
W/S	122607.78	38324.10	3.20
TA/B	-1056.68	530.14	-1.99

表 3.24 8 變數迴歸分析之強度模型 RMS

訓練範例	測試範例
1799.73 psi	1823.12 psi




圖 3.28 8 變數迴歸分析 t 統計量




圖 3.29 8 變數迴歸分析之訓練範例 HPC 強度散佈圖




圖 3.30 8 變數迴歸分析之測試範例 HPC 強度散佈圖

$$f'_c = 2330.41 + 23.54C + 18.11FL + 15.58SL - 139.07W - 168.30SP + 6.46CA + 5.33FA + 13.07AGE + 400.46W/C + 7164.88W/B + 122607.78W/S - 1056.68TA/B \dots\dots\dots(3.14)$$




圖 3.31 12 變數迴歸分析 t 統計量




圖 3.32 12 變數迴歸分析之訓練範例 HPC 強度散佈圖




圖 3.33 12 變數迴歸分析之測試範例 HPC 強度散佈圖

表 3.26 12 變數迴歸分析之強度模型 RMS

訓練範例	測試範例
1767.50 psi	1811.17 psi

(二)倒傳遞網路(Back-propagation Networks, BPN)[8]

本研究以 8-8-1(8 輸入、8 節點、1 輸出)的倒傳遞網路來做為準確度的比較，其網路模型如圖 3.34 所示，其中網路的設定值如下所示：

- 初始權值範圍 ± 0.3
- 學習速率=1.0
- 學習速率衰減率=0.99
- 學習速率下限值=0.1
- 慣性因數初始值=0.5
- 慣性因數衰減率=0.99
- 慣性因數下限值=0.1
- 學習循環=10000，其 RMS 收斂圖如圖 3.35 所示

其訓練範例及測試範例之 RMS 分別是 798.88 psi 及 826.09 psi，如表 3.27 所示，而其散佈圖如圖 3.36 及圖 3.37 所示。此外 BPN 須以公式 (3.15) 計算各項變數的敏感性分析，其各項變數影響性如圖 3.38 所示。




圖 3.34 倒傳遞網路模型(8-8-1)




圖 3.35 倒傳遞網路 RMS 收斂圖




圖 3.36 BPN 之訓練範例 HPC 強度散佈圖




圖 3.37 BPN 之測試範例 HPC 強度散佈圖

表 3.27 倒傳遞網路 8-8-1 強度模型之 RMS

訓練範例	測試範例
798.88 psi	826.09 psi

$$\sum f'_k \times W_{ik} \times f'_j \times W_{kj} \dots\dots\dots(3.15)$$

其中 $f'_k = \frac{1}{1+e^{Bias_k}} \times (1 - \frac{1}{1+e^{Bias_k}})$; $f'_j = \frac{1}{1+e^{Bias_j}} \times (1 - \frac{1}{1+e^{Bias_j}})$




圖 3.38 BPN 之各項變數影響性

(三)語法式進化遺傳演算法(Grammar Evolution Genetic Algorithms, GEGA)[11]

公式 (3.16) 為 GEGA 的強度模型，其訓練範例及測試範例之 RMS 分別是 1521.49 psi 及 1506.05 psi，如表 3.28 所示，而其散佈圖如圖 3.39 及圖 3.40 所示。

$$f'_c = 1.033 \times AGE^{0.2} \times CA \times (W/B)^{-1.36} + 60.845 \times FA \times AGE^{-0.5} - 1771.37 \dots\dots\dots(3.16)[11]$$




圖 3.39 GEGA 之訓練範例 HPC 強度散佈圖




圖 3.40 GEGA 之測試範例 HPC 強度散佈圖

表 3.28 GEGA 之強度模型 RMS

訓練範例	測試範例
1521.49 psi	1506.05 psi

(四)巨觀進化遺傳規劃(Macro-evolutionary Genetic Programming, MEGP) [10]

公式 (3.17) 為 MEGP 的強度模型，其訓練範例及測試範例之 RMS 分別是 1872.60 psi 及 1845.30 psi，如表 3.29 所示，而其散佈圖如圖 3.41 及圖 3.42 所示。

$$f_c = 514.63 \times (W/B)^{-1.27} \times (\ln(\text{AGE}) + 0.0312) + \text{FA} \times \text{Cos}(0.216 \times \text{FA}) \dots\dots\dots(3.17)[10]$$




圖 3.41 MEGP 之訓練範例 HPC 強度散佈圖




圖 3.42 MEGP 之測試範例 HPC 強度散佈圖

表 3.29 MEGP 之強度模型 RMS

訓練範例	測試範例
1872.60 psi	1845.30 psi

表 3.30 及圖 3.43 為七種方法的比較。由表及圖中可知：

- 預測準確度：GAOT、GARA、GANN 產生之模型在測試範例的 RMS 僅高於 BPN 模型，亦即準確度優於其它三種方法產生之模型。
- 公式自組織：除 BPN 及 GANN 外，GAOT 及其它四種方法皆產生公式，具備模型可解釋能力。

因此：

- 若使用者要求是可見的 HPC 強度組合模型，則 GAOT 是一個準確且可以產生自組織公式的 HPC 強度模型建構方法。
- 若使用者對於可見的 HPC 強度組合模型要求度不高，僅在乎最後的結果是否準確，則 BPN 是一個更準確且快速的 HPC 強度模型建構方法。

表 3.30 七種方法在預測準確度及模型公式自組織的比較

方法	RMS(psi)		預測準確度	公式自組織
	訓練範例	測試範例		
GARA	1307.19	1219.15	次優	否
GAOT 八變數	1298.50	1168.65	次優	是
GANN	929.25	1087.94	次優	否
BPN	798.88	826.09	最優	否
RA 八變數	1799.73	1823.12	差	是
RA 十二變數	1767.50	1811.17	差	是
GEGA [11]	1521.49	1506.05	中	是
MEGP[10]	1872.60	1845.30	差	是




圖 3.43 七種方法在預測準確度的比較

第四章 高性能混凝土坍度模型之應用

4-1 前言

前章已知，GARA 雖然能夠產生模型，但模型是專家經由背景知識自行預設，亦即模型不夠靈活且準確度不如 GANN 及 GAOT，因此本章不再使用 GARA 的方法來建構坍度模型，僅以 GANN 及 GAOT 來這兩種方法來驗證是否的確具備準確性，解釋性及通用性。

4-1-1 資料收集

影響 HPC 工作度的可能變數包括：水泥(C)、飛灰(FL)、爐石(SL)、水(W)、強塑劑(SP)、粗骨材(CA)及細骨材(FA)。本研究共收集 103 筆上述變數的高性能混凝土配比資料[35,36]，並以隨機的方式取樣 78 筆資料做為模型建構的訓練範例，而剩餘的 25 筆資料做為驗證的測試範例，以評估所產生的模型是否具備普遍性，其坍度資料的值域及型態如表 4.1 所示。

表 4.1 坍度資料中各變數的值域及型態

變數名稱	值域		單位	型態	
C	137.0~	374.0	Kg/m ³	連續	自變數
FL	0.0~	193.0	Kg/m ³	連續	
SL	0.0~	260.0	Kg/m ³	連續	
W	160.0~	240.0	Kg/m ³	連續	
SP	4.4~	19.0	Kg/m ³	連續	
CA	708.0~	1049.9	Kg/m ³	連續	
FA	640.6~	902.0	Kg/m ³	連續	
W/C	0.5~	1.7	比例	連續	
W/B	0.3~	0.7	比例	連續	
W/S	0.1~	0.1	比例	連續	
TA/B	2.4~	5.6	比例	連續	
Slump	0.0~	29.0	cm	連續	因變數

其中 $W/C=(W+SP)/(C)$ 、 $W/B=(W+SP)/(C+FL+SL)$ 、 $W/S=(W+SP)/(C+FL+SL+CA+FA)$ 、 $TA/B=(CA+FA)/(C+FL+SL)$ 。

4-1-2 演算法參數設定及適應度函數

本研究所採用之遺傳演算法參數設定同 3-1-2 節，但部份參數改變如下：

- 交配後產生之個體數設定為 30 個；
- 本研究以訓練範例的誤差均方根為適應度函數，如公式 (4.1) 所示；

$$RMS = \sqrt{\frac{\sum_{i=1}^n (\hat{Slump}_i - Slump_i)^2}{n}} \dots\dots\dots(4.1)$$

其中 \hat{Slump} = 第 i 筆資料的運算樹預測坍度值

4-2 運算樹遺傳演算法產生坍度模式

4-2-1 模型建構

本研究為產生自組織公式，採用了運算樹(Operation Tree)的公式表達方式。圖 3.6 為一個五層的運算樹示意圖，而運算樹的運算元及變數基因編碼方式如表 3.7 及表 4.2 所示。其中：

- 第一層的樹枝(X_1)限制僅能搜尋運算元編碼，因此所能搜尋的編碼為 1~6 的整數；
- 第二、三、四層樹枝($X_2 \sim X_{15}$)可搜尋的範圍完全自由，因此所能搜尋的編碼為 1~18 的整數，其中編碼 18 的 K 值限定為 -3~3 的連續數值；
- 第五層的樹枝($X_{16} \sim X_{31}$)限制僅能搜尋變數編碼，因此所能搜尋的編碼為 7~18 的整數。

此外此樹狀結構遵守下列規則：

- 當該樹枝搜尋到的運算元編碼為 ln 時，則限制下一層僅「左」樹枝有效。
- 當該樹枝搜尋到變數編碼時，則限制該樹枝無法再成長至下一層。

表 4.2 十一變數之基因編碼方法

編碼	7	8	9	10	11	12	13	14	15	16	17	18
運算元	C	FL	SL	W	SP	CA	FA	W/C	W/B	W/S	TA/B	K

4-2-2 運算樹預測值之迴歸修正及尺度化

運算樹的預測值有時會有偏斜現象，即預測值與實際值間存在平移及旋轉關係。為修正運算樹的偏斜現象，本研究以下列單變數迴歸公式 (4.2) 改正之，此外由於坍度值域為 0~30cm 之間的數值，為避免預測出來之坍度值域不合理，因此本研究先將實際坍度值進行對數尺度化，以限制將來預測之坍度值域在合理範圍內。

$$y = \alpha + \beta \cdot f \dots\dots\dots(4.2)$$

其中 y = 雙彎曲轉換後之坍度值

f = 運算樹之函數值

$$\alpha = \bar{y} - \beta \cdot \bar{f}$$

$$\beta = \frac{\sum_{i=1}^n (f_i - \bar{f}) \times (y_i - \bar{y})}{\sum_{i=1}^n (f_i - \bar{f})^2}$$

其中 \bar{f} = 所有資料的運算樹預測坍度平均值

f_i = 第*i*筆資料的運算樹預測坍度值

\bar{y} = 尺度轉換後的所有實際坍度平均值

$$y_i = \text{LN} \left(\frac{\text{Slump}_i + 0.5}{30.5 - \text{Slump}_i} \right)$$

其中 y_i = 尺度轉換後的第*i*筆資料實際坍度值

Slump_i = 第*i*筆資料的實際坍度值

由於上述步驟的預測坍度值是進行了對數尺度化，因此需採用公式 (4.3) 進行反尺度化，將預測坍度值反尺度化成 0~30cm 之間的預測坍度值。

$$\hat{\text{Slump}} = \frac{30.5 \times e^y - 0.5}{1 + e^y} \dots\dots\dots(4.3)$$

其中 $\hat{\text{Slump}}$ = 反尺度化後的運算樹預測坍度值

4-2-3 結果

本研究分別展示(一)五層七變數的HPC坍度模型樹狀圖及(二)五層十一變數的HPC坍度模型樹狀圖，七變數的編碼如表 4.3 所示，其目的是評估 GAOT 產生的坍度模型具備可靠性。

表 4.3 七變數及常數之基因編碼方法

編碼	7	8	9	10	11	12	13	14
運算元	C	FL	SL	W	SP	CA	FA	K

(一)五層七變數

圖 4.1 為使用五層七變數所產生的運算樹。運算樹之修正係數 $\alpha=1.064$ 、 $\beta=-138000.308$ 。運算樹及修正係數組成之公式如公式 (4.4) 所示，其訓練範例及測試範例之 RMS 分別是 6.51 cm 及 6.35 cm，如表 4.4 所示，而其散佈圖如圖 4.2 及圖 4.3 所示。

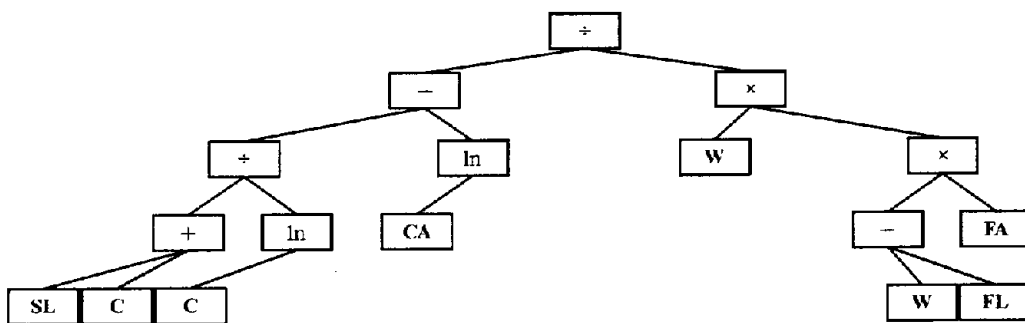


圖 4.1 五層七變數 GAOT 產生之運算樹

$$\hat{S}_{lump} = \frac{30.5 \times e^{1.064 - 138000.308 \times \left[\frac{((SL - C)/\ln(C)) - \ln(CA)}{W \times (W - FL) \times FA} \right] - 0.5}}{1 + e^{1.064 - 138000.308 \times \left[\frac{((SL + C)/\ln(C)) - \ln(CA)}{W \times (W - FL) \times FA} \right]}} \dots\dots\dots(4.4)$$

表 4.4 五層七變數 GAOT 產生之 HPC 坍度模型 RMS

訓練範例	測試範例
6.51 cm	6.35 cm




圖 4.2 五層七變數 GAOT 之訓練範例 HPC 坍度散佈圖




圖 4.3 五層七變數 GAOT 之測試範例 HPC 坍度散佈圖

(二)五層十一變數

圖 4.4 為使用五層十一變數所產生的運算樹。運算樹之修正係數 $\alpha = 0.613$ 、 $\beta = -0.000111$ 。運算樹及修正係數組成之公式如公式 (4.5) 所示，其訓練範例及測試範例之 RMS 分別是 5.92 cm 及 4.57 cm，如表 4.5 所示，而其散佈圖如圖 4.5 及圖 4.6 所示。

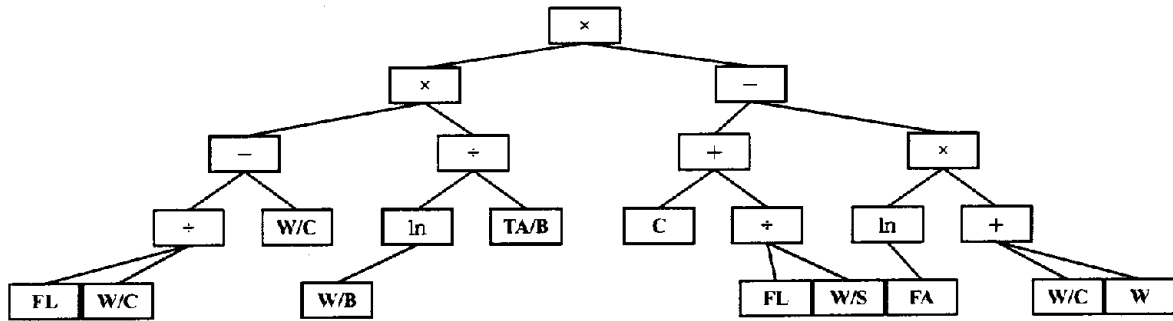


圖 4.4 五層十一變數 GAOT 產生之運算樹

$$\hat{Slump} = \frac{30.5 \times e^{0.613 - 0.000111 \times \left[\left(\frac{FL}{W/C} - W/C \right) \times \frac{\ln(W/B)}{TA/B} \right] \times \left[C + \frac{FL}{W/S} - \ln(FA) \times (W/C + W) \right]}{1 + e^{0.613 - 0.000111 \times \left[\left(\frac{FL}{W/C} - W/C \right) \times \frac{\ln(W/B)}{TA/B} \right] \times \left[C + \frac{FL}{W/S} - \ln(FA) \times (W/C + W) \right]}} - 0.5 \quad (4.5)$$

表 4.5 五層十一變數 GAOT 產生之 HP 坍度模型 RMS

訓練範例	測試範例
5.92 cm	4.57 cm




圖 4.5 五層十一變數 GAOT 之訓練範例 HPC 坍度散佈圖




圖 4.6 五層十一變數 GAOT 之測試範例 HPC 坍度散佈圖

4-3 遺傳演算法結合類神經網路產生坍塌度模式

圖 4.7 為一個，個輸入變數、一個隱藏層、多個節點及一個輸出變數的神經網路模型，本研究是以標準的神經網路模型架構，但最佳化權值大小由最陡坡降法(Gradient Steepest Descent Method)改為以遺傳演算法求解，本章將進行多個隱藏層節點的判斷，期望使用 GANN 的方法，找出最佳的 HPC 模型。




圖 4.7 11-11-1 神經網路模型

4-3-1 模型建構

本研究企圖以 GANN 的方法找出最佳的 HPC 坍塌度模型，這個 GANN 的方法與 3-4-1 節相同，同樣包括五個部分：

- 輸入層尺度轉換，如公式 (3.7) 所示；
- 輸入層與隱藏層節點關係，如公式 (3.8) 所示；
- 隱藏層節點函數建立，如公式 (3.9) 所示；
- 隱藏層節點與輸出層關係，如公式 (3.10) 所示；
- 輸出層反尺度轉換，如公式 (3.11) 所示。

4-3-2 結果

本研究將展示十一個輸入變數，一個隱藏層，一個輸出變數，以及分別為(一)四個隱藏層節點、(二)八個隱藏層節點、(三)十六個隱藏層節點來做 HPC 最佳坍塌度模型探討。

(一)GANN(11-4-1)

圖 4.8 及圖 4.9 分別為 GANN(11-4-1)在訓練範例及測試範例之 HPC 坍塌度散佈圖，其 RMS 分別是 4.65cm 及 3.87cm，如表 4.6 所示。




圖 4.8 GANN(11-4-1) 訓練範例之 HPC 坍度散佈圖




圖 4.9 GANN(11-4-1) 測試範例之 HPC 坍度散佈圖

表 4.6 GANN(11-4-1) 坍度模型之 RMS

訓練範例	測試範例
4.65 cm	3.87 cm

(二)GANN(11-8-1)

圖 4.10 及圖 4.11 分別為 GANN(11-8-1) 在訓練範例及測試範例之 HPC 坍度散佈圖，其 RMS 分別是 3.24cm 及 4.40cm，如表 4.7 所示。




圖 4.10 GANN(11-8-1) 訓練範例之 HPC 坍度散佈圖




圖 4.11 GANN(11-8-1) 測試範例之 HPC 坍度散佈圖

表 4.7 GANN(11-8-1)坍度模型之 RMS

訓練範例	測試範例
3.24 cm	4.20 cm

(二)GANN(11-16-1)

圖 4.12 及圖 4.13 分別為 GANN(11-16-1)在訓練範例及測試範例之 HPC 強度散佈圖，其 RMS 分別是 2.79cm 及 4.99cm，如表 4.8 所示。





圖 4.12 GANN(11-16-1)訓練範例之 HPC 坍度散佈圖

圖 4.13 GANN(11-16-1)測試範例之 HPC 坍度散佈圖

表 4.8 GANN(11-16-1)坍度模型之 RMS

訓練範例	測試範例
2.79 cm	4.99 cm

4-4 結果與討論

4-4-1 結果的解釋

本節與 3-5-1 節相同，同樣想瞭解每個變數對坍度之影響力，其各變數平均值及標準差如表 4.9 所示。其 GAOT 七變數的結果如表 4.10 及圖 4.14 所示；其 GAOT 十一變數的結果如表 4.11 及圖 4.15 所示。

表 4.9 103 筆坍度資料各項變數的平均值及標準差

	\bar{x}	σ	$\bar{x}+0.5\sigma$	$\bar{x}-0.5\sigma$
C	229.89	78.49	269.14	190.65
FL	105.68	45.79	128.57	82.78
SL	187.18	48.23	211.29	163.06
W	197.17	20.11	207.22	187.11
SP	8.54	2.79	9.94	7.14
CA	883.98	87.96	927.96	840.00
FA	739.60	63.03	771.12	708.09

表 4.10 GAOT 七變數產生坍度模型各項變數的影響性

	$\bar{f}_c - 0.5\sigma$ (KSI)	$\bar{f}_c + 0.5\sigma$ (KSI)	差值	重要性
C	17.98	17.24	-0.747	--
FL	18.69	15.77	-2.920	---
SL	17.96	17.27	-0.691	--
W	16.61	18.39	1.781	+++
SP	NA	NA	NA	NA
CA	17.61	17.62	0.008	+
FA	17.37	17.84	0.465	++




圖 4.14 GAOT 七變數產生坍度模型各項變數的影響性

表 4.11 GAOT 十一變數產生坍度模型各項變數的影響性

	$\bar{f}_c - 0.5\sigma$ (KSI)	$\bar{f}_c + 0.5\sigma$ (KSI)	差值	重要性
C	20.29	16.30	-3.989	--
FL	23.48	9.01	-14.476	---
SL	19.31	18.48	-0.826	-
W	14.84	21.80	6.960	+++
SP	18.71	19.15	0.442	+
CA	19.56	18.33	-1.231	-
FA	19.14	18.73	-0.409	-

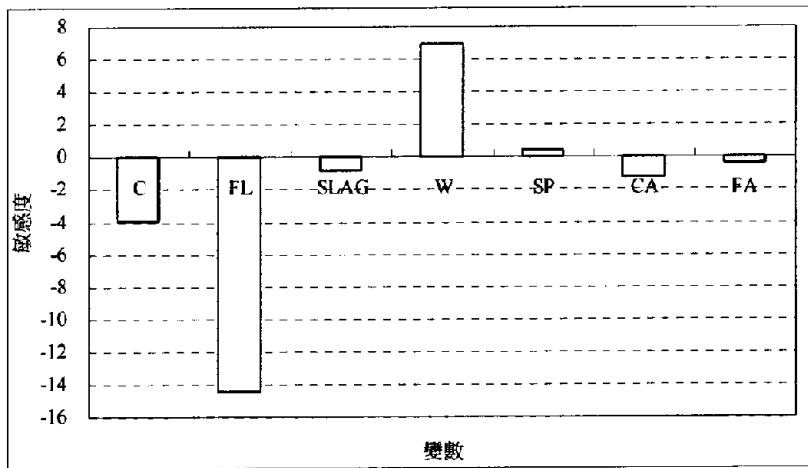


圖 4.15 GAOT 十一變數產生坍度模型各項變數的影響性

此外 GANN 以公式 (3.12) 計算各項變數的敏感性。其 GANN11-4-1、11-8-1、11-16-1 的結果分別如圖 4.16~4.18 及表 4.12~4.14 所示。表 4.15 及圖 4.19 列出各項變數於兩種方法的影響性比較，從表中可見影響力依序是水、飛灰、水泥、強塑劑、爐石、細骨材及粗骨材

表 4.12 GANN(11-4-1)產生坍度模型各項變數的影響性

	敏感分析	重要性
<i>C</i>	-0.02	-
<i>FL</i>	0.15	+
<i>SL</i>	0.26	++
<i>W</i>	0.17	+
<i>SP</i>	0.21	++
<i>CA</i>	0.60	+++
<i>FA</i>	0.55	+++
<i>W/C</i>	-0.15	-
<i>W/B</i>	0.28	++
<i>W/S</i>	0.37	++
<i>TA/B</i>	-0.74	---




圖 4.16 GANN(11-4-1)產生坍度模型各項變數的影響性

表 4.13 GANN(11-8-1)產生坍度模型各項變數的影響性

	敏感分析	重要性
<i>C</i>	0.19	-
<i>FL</i>	-1.25	---
<i>SL</i>	0.03	---
<i>W</i>	1.18	+++
<i>SP</i>	-0.47	-
<i>CA</i>	1.43	+++
<i>FA</i>	1.00	+++
<i>W/C</i>	-0.91	--
<i>W/B</i>	0.90	+++
<i>W/S</i>	0.27	+
<i>TA/B</i>	1.08	+++




圖 4.17 GANN(11-8-1)產生坍度模型各項變數的影響性

表 4.14 GANN(11-16-1)產生坍度模型各項變數的影響性

	敏感分析	重要性
<i>C</i>	-0.12	-
<i>FL</i>	-0.07	-
<i>SL</i>	-0.08	-
<i>W</i>	0.44	+++
<i>SP</i>	0.02	+
<i>CA</i>	0.50	+++
<i>FA</i>	0.29	++
<i>W/C</i>	0.07	+
<i>W/B</i>	-0.48	---
<i>W/S</i>	-0.20	-
<i>TA/B</i>	-0.24	--




圖 4.18 GANN(11-16-1)產生坍度模型各項變數的影響性

表 4.15 各變數於兩種方法的影響性比較

	C	FL	SL	W	SP	CA	FA
GAOT 七變數	--	---	--	+++	NA	+	++
GAOT 十一變數	--	---	-	+++	+	-	-
GANN(11-4-1)	-	+	++	+	++	+++	+++
GANN(11-8-1)	-	---	---	+++	-	+++	+++
GANN(11-16-1)	-	-	-	+++	+	+++	++




圖 4.19 各變數於兩種方法的影響性比較

4-4-2 模型準確性及解釋性比較

為驗證本研究提出之方法為一可行且可靠的高性能混凝土坍度模型建構方法，本研究另外以常見的迴歸分析及倒傳遞網路來做 HPC 坍度模型的準確性及解釋性評估：

- 迴歸分析(Regression Analysis, RA)
- 倒傳遞網路(Back-propagation Networks, BPN)[8]

以上兩種建模方法將套用本研究所使用之實驗數據，以進行坍度模型準確度及解釋性的比較。

(一)迴歸分析(Regression Analysis, RA)

公式 (4.6) 為進行七變數迴歸分析後的坍度模型，為求得七種變數對於坍度的敏感性，因此我們將常數項限制為零，其 t 統計量如表 4.16 及圖 4.20 所示，其訓練範例及測試範例之 RMS 分別是 7.51cm 及 6.14cm，如表 4.17 所示，而其散佈圖如圖 4.20 及圖 4.21 所示。公式 (4.7) 為進行十一變數迴歸分析後的坍度模型，其 t 統計量如表 4.18 及圖 4.23 所示，其訓練範例及測試範例之 RMS 分別是 6.58cm 及 6.63cm，如表 4.19 所示，而其散佈圖如圖 4.24 及圖 4.25 所示。

$$\hat{S}_{lump} = -0.01C - 0.05FL - 0.02SL + 0.15W - 0.18SP - 0.01CA + 0.01FA \quad \dots\dots\dots(4.6)$$

表 4.16 七變數 RA_t 統計量分析

Input variables	係數	標準誤差	t 統計
C	-0.01	0.01	-1.05
FL	-0.05	0.02	-2.57
SL	-0.02	0.01	-1.65
W	0.15	0.04	3.58
SP	-0.18	0.34	-0.54
CA	-0.01	0.01	-0.82
FA	0.01	0.01	0.47




圖 4.20 七變數 RA_t 統計量

表 4.17 七變數 RA 產生之 HPC 坍塌模型 RMS

訓練範例	測試範例
7.51 cm	6.14 cm





圖 4.21 七變數 RA 之訓練範例 HPC 坍度
散佈圖

圖 4.22 七變數 RA 之測試範例 HPC 坍度
散佈圖

$$\hat{Slump} = 97.74 - 0.27C - 0.26FL - 0.31SL + 4.02W + 3.60SP - 0.06CA - 0.05FA + 10.61W/C - 166.63W/B - 6156.71W/S - 3.22TA/B \quad \dots\dots\dots(4.7)$$

表 4.18 十一變數 RA_t 統計量分析

Input variables	係數	標準誤差	t 統計
Constant term	97.74	340.27	0.29
C	-0.27	0.15	-1.80
FL	-0.26	0.15	-1.69
SL	-0.31	0.14	-2.23
W	4.02	1.25	3.21
SP	3.60	1.29	2.78
CA	-0.06	0.15	-0.40
FA	-0.05	0.15	-0.30
W/C	10.61	14.96	0.71
W/B	-166.63	111.21	-1.50
W/S	-6156.71	2667.71	-2.31
TA/B	-3.22	12.24	-0.26




圖 4.23 十一變數 RA 統計量

表 4.19 十一變數 RA 產生之 HPC 坍度模型 RMS

訓練範例	測試範例
6.58 cm	6.63 cm




圖 4.24 十一變數 RA 之訓練範例 HPC 坍度散佈圖




圖 4.25 十一變數 RA 之測試範例 HPC 坍度散佈圖

(二)倒傳遞網路(Back-propagation Networks, BPN) [8]

本研究以 11-11-1(11 輸入、11 節點、1 輸出)的倒傳遞網路來做為準確度的比較，其網路模型如圖 4.26 所示，其中網路的設定值如下所示：

- 初始權值範圍 ± 0.3
- 學習速率=1.0

- 學習速率衰減率=0.99
- 學習速率下限值=0.1
- 慣性因子初始值=0.5
- 慣性因子衰減率=0.99
- 慣性因子下限值=0.1
- 學習循環=3000，其 RMS 收斂圖如圖 4.27 所示

其訓練範例及測試範例之 RMS 分別是 2.56cm 及 3.46cm，如表 4.20 所示，而其散佈圖如圖 4.28 及圖 4.29 所示。其各項變數影響性如圖 4.30 所示。




圖 4.26 11-11-1 倒傳遞網路模型




圖 4.27 倒傳遞網路 RMS 收斂圖

表 4.20 BPN 產生之 HPC 坍度模型 RMS

訓練範例	測試範例
2.56 cm	3.46 cm




圖 4.28 BPN11-11-1 之訓練範例 HPC 坍塌度散佈圖




圖 4.29 BPN11-11-1 之測試範例 HPC 坍塌度散佈圖




圖 4.30 BPN 之各項變數影響性

表 4.21 及圖 4.31 為四種方法在準確度及模型解釋能力的比較。由表及圖可知：

- 預測準確度：GAOT 及 GANN 產生模型之測試範例 RMS 優於傳統 RA，且略差於 BPN，顯示 GAOT 及 GANN 產生之模型具備一定的準確度。
- 公式自組織：除 BPN 及 GANN 外，GAOT 及傳統 RA 皆能夠產生公式，具備模型可解釋能力。

因此：

- 若使用者要求是可見的 HPC 坍塌度組合模型，則 GAOT 是一個準確且可以產生自組織公式的 HPC 坍塌度模型建構方法。
- 若使用者對於可見的 HPC 坍塌度組合模型要求度不高，僅在乎最後的結果是否準

確，則 BPN 是一個更準確且快速的 HPC 坍塌度模型建構方法。

表 4.21 四種方法的準確度及解釋性比較

方法	RMS(cm)		預測準確度	公式自組織
	訓練範例	測試範例		
GANN	3.24	4.20	優	否
GAOT 七變數	6.51	6.35	中	是
GAOT 十一變數	5.92	4.57	中	是
BPN	2.56	3.46	優	否
傳統 RA 七變數	7.44	6.60	差	是
傳統 RA 十一變數	6.58	6.63	中	是




圖 4.31 四種方法的準確度比較

第五章 結論與建議

5-1 結論

- (一) 由第三章的敏感度分析可知，GARA、GAOT 八變數、三種 GANN、RA 及 BPN 的方法可看出，與強度成正相關且依照關聯性強弱的排名分別是，水泥、齡期、飛灰、爐石，與強度成負相關且依照關聯性強弱排名分別是，水及強塑劑，此外，部分的方法認為粗骨材及細骨材與強度呈現正相關關係，但關聯性並不強烈，這樣的結論與實務上相符合。
- (二) 由第三章的模型準確性及解釋性比較可知，在準確度方面，GAOT、GARA、GANN 產生之模型在測試範例的 RMS 僅高於 BPN 模型，亦即準確度優於其它三種方法產生之模型。在模型的解釋性方面，除 BPN 及 GANN 外，GAOT 及其它四種方法皆產生公式，具備模型可解釋能力。
- (三) 由第四章的敏感度分析可知，GARA、GAOT 及三種 GANN、RA 及 BPN 的方法可看出，與坍度成正相關且依照關聯性強弱的排名分別是，水、強塑劑、粗骨材及細骨材，而飛灰及水泥大致與坍度成負相關，此外爐石沒有明顯正相關或負相關趨勢。由此可知，各項材料對於坍度的影響具備高複雜度。
- (四) 由第四章的模型準確性及解釋性比較可知，在準確度方面，GAOT 及 GANN 產生模型之測試範例 RMS 優於傳統 RA，且略差於 BPN，顯示 GAOT 及 GANN 產生之模型具備一定的準確度。在模型的解釋性方面，除 BPN 及 GANN 外，GAOT 及傳統 RA 皆能夠產生公式，具備模型可解釋能力。
- (五) 若使用者要求是可理解的 HPC 材料行為模型，則 GAOT 是一個準確且能夠產生自組織公式的 HPC 強度及坍度模型建構方法；若使用者對於可理解的 HPC 材料行為模型要求度不高，僅在乎最後的結果是否準確，則 BPN 是一個更準確且快速的 HPC 強度及坍度模型建構方法。

5-2 建議

一、高性能混凝土方面

領域的擴充：由於 GAOT 是一個可以產生自組織公式的模型建構方法，其在 HPC 的坍度建模有一定的成果，因此未來將應用在其它需建立模型的工程材料領域，並預期所產生之模型能夠與實務相互呼應且期望採掘尚未發現的因果關係。

二、強化學習演算法方面

- (一) 運算樹模型過度配適(Over fitting)的懲罰：本研究尚未考慮運算樹層數過大或變數使用過多造成模型過度配適的懲罰，因此未來將進行這方面的研究，期望在犧牲少許的準確度之下，卻能夠產生最簡單易懂的自組織公式模型。
- (二) 遺傳演算法的改良：遺傳演算法是一個能夠經由人工的改進，使之產生模型架構

的演算法(解釋性)，其準確能力可說是比一般常用的迴歸分析更優異(準確度)，但是卻略差於類神經網路，且收斂所需的時間花費甚高，因此重點將走向，如何改進其演算的準確度，使之更接近完美的類神經網路，但不失其模型的解釋性，且也可以很容易的達到收斂的要求。

參考文獻

- [1] 葉怡成,「機器學習在土木工程專家系統應用之研究」,博士論文,國立成功大學,台南市 (1991)。
- [2] 曾敬翔,「需求預測對 VMI 績效之影響—以加強式學習多位代理人供應鏈模式分析」,國立高雄第一科技大學,高雄市 (2002)。
- [3] Zhao, L., and Liu, Z., “A genetic algorithm for reinforcement learning,” *IEEE International Conference on Neural Networks*, Vol.2, pp.1056-1060 (1996).
- [4] Mikami, S., Wada, M. and Kakazu, Y., “Combining reinforcement learning with GA to find coordinated control rules for multi-agent system,” *Proceedings of IEEE International Conference on Evolutionary Computation*, pp.356-361 (1996).
- [5] 黃兆龍, 混凝土性質與行為, 詹氏書局, 台北市, (1999)。
- [6] 沈得縣,「含波索蘭材料高性能混凝土之配比技術及力學性質研究(I)」,國科會 HPC 研究成果推廣應用研討會, 第 107-112 頁, (1997)。
- [7] Chang, T. P., Chung, F. C. and Lin, H. C., “A mix proportioning methodology for high-performance concrete,” *Journal of the Chinese Institute of Engineers*, Vol.19, No.6, pp.645-655 (1996).
- [8] 彭鈞哲,「以倒傳遞網路在高性能混凝土抗壓強度之應用」,碩士論文,中華大學,新竹市 (1995)。
- [9] 賴鴻成,「倒傳遞網路在混凝土材料強度之應用」,碩士論文,交通大學,新竹市 (1993)。
- [10] Chen, L., “A study of applying macroevolutionary genetic programming to concrete strength estimation,” *ASCE, Journal of Computing in Civil Engineering*, Vol.17, No.4, pp.290-294 (2003).
- [11] Chen, L., Tasi, C. S., and Chen, H. M., “A study of applying grammar evolution to concrete strength estimation,” *Chung Hua Journal of Science and Engineering*, Vol.2, No.2, pp.55-62 (2004).
- [12] 葉怡成, 免疫演算法於高性能混凝土配比設計多目標最佳化之研究(1/2), 行政院國家科學委員會專題研究計畫成果報告, NSC 92-2211-E-216-015 (2004)。
- [13] 葉怡成, 應用類神經網路, 儒林圖書有限公司 (2002)。
- [14] Yeh, I-Cheng, “Modeling of strength of high performance concrete using artificial neural networks,” *Cement and Concrete Research*, Vol.28, No.12, pp.1797-1808 (1998).
- [15] Yeh, I-Cheng, “Modeling concrete strength with augment-neuron networks,” *ASCE, Journal of Materials in Civil Engineering*, Vol.10, No.4, pp.263-268 (1998).
- [16] Yeh, I-Cheng, “Design of high performance concrete mixture using neural networks,” *ASCE, Journal of Computing in Civil Engineering*, Vol.13, No.1, pp.36-42 (1999).
- [17] Davis, L., *Handbook of Genetic Algorithms*, Van Nostrand Reinhold, NY. (1991).

- [18] Holland, J. H., *Adaptation in Natural and Artificial System*, University of Michigan Press, Ann Arbor. (1975).
- [19] Goldberg, D. E., *Genetic Algorithms in Search Optimization and Machine Learning*, Addison-Wesley Publishing Company. (1989).
- [20] Booker, L. B., Goldberg, D. E., and Holland, J. H., "Classifier systems and genetic algorithms," *Artificial Intelligence*, Vol.40, pp.235-282 (1989).
- [21] Barto, A. G., Sutton, R. S. and Watkins, C. J. C. H., "Learning and sequential decision making," in Gabriel M. and Moore, J. W., *Learning and computational neuroscience: foundations of adaptive networks*, MIT Press, Cambridge, Mass, pp.539-602 (1990).
- [22] 葉怡成，資料探勘-方法應用與實作，未出版 (2005)。
- [23] Tsai, K. M., and Lian, T. Z., "Intelligent multi-agent supply chain modeling with genetic algorithms," *The 5th International symposium on logistics* (2000).
- [24] Jellouli, O. and Chatelet, E., "Monte carlo simulation and genetic algorithm for optimising supply chain management in a stochastic environment," *2001 IEEE International Conference on Systems, Man, and Cybernetics*, Vol.3, pp.1835-1839 (2001).
- [25] Yung, S. K. and Yang, C. C., "Inerlligent multi-agents for supply chain management," *IEEE International Conference on Systems, Man, and Cybernetics*, Vol.2, pp.528-533 (1999).
- [26] 連立川、葉怡成、謝明勳，「以遺傳演算法建構台灣股市買賣決策規則之研究」，2004智慧型知識經濟研討會暨第二屆演化式計算應用專題研討會，台北市 (2004)。
- [27] 連立川、葉怡成、張皓博、謝明勳，「以遺傳演算法及運算樹作高性能混凝土工作度建模」，2005營建技術暨管理研討會，斗六市 (2005)。
- [28] 許慶安，「應用類神經網路推估混凝土之抗壓強度」，碩士論文，國立成功大學，台南市 (2002)。
- [29] 陳怡成，「以倒傳遞網路作高性能混凝土配比設計之研究」，碩士論文，中華大學，新竹市 (2001)。
- [30] Yeh, I-Cheng, "Prediction of strength of fly ash and slag concrete by the use of artificial neural networks," *Journal of the Chinese Institute of Civil and Hydraulic Engineering*, Vol.15, No.4, pp.659-663 (2003).
- [31] Yeh, I-Cheng, "Design of high performance concrete mixture using neural networks," *ASCE, Journal of Computing in Civil Engineering*, Vol.13, No.1, pp.36-42 (1999).
- [32] Sonebi, M., Svermova, L., and Bartos, P. J. M., "Factorial design of cement slurries containing limestone powder for self-consolidating slurry-infiltrated fiber concrete," *ACI Materials Journal*, Vol.101, No.2, pp.136-145 (2004).
- [33] Abbasi, F., Ahmad, M. and Wasim, M., "Optimization of concrete mix proportioning using reduced factorial experimental technique," *ACI Materials Journal*, Vol.84, No.1, pp.55-63 (1987).

- [34] Sonebi, M., "Applications of statistical models in proportioning medium-strength self-consolidating concrete," *ACI Materials Journal*, Vol.101, No.5, pp.339-346 (2004).
- [35] 柯泰志,「以類神經網路建構高性能混凝土工作度模型之研究」, 碩士論文, 中華大學, 新竹市 (2001)。
- [36] 陳家偉,「以迴歸分析與類神經網路建構高性能混凝土工作度模型之比較研究」, 碩士論文, 中華大學, 新竹市 (2002)。
- [37] Khayat, K. H., Yahia, A. and Sonebi, M., "Applications of statistical models for proportioning underwater concrete," *ACI Materials Journal*, Vol.96, No.6, pp.634-640 (1999).
- [38] Larrard, F. and Sedran, T., "Optimization of ultra high performance concrete by the use of a packing model," *Cement and Concrete Research*, Vol.24, No.6, pp.997-1009 (1994).
- [39] Ward Systems Group, Inc., *GeneHunter User's Guide*, GeneHunter Release 2.4, pp.17-18 (2000).

附錄一、類神經網路之權值

以一個八個輸入變數，一個隱藏層八個節點及一個輸出變數來說明，附錄表 1 為輸入層與隱藏層節點之權值的值域範圍，附錄表 2 為隱藏層節點與輸出層之權值的值域範圍。

附錄表 1 輸入層與隱藏層節點之權值 附錄表 2 隱藏層節點與輸出層之權值
值域範圍 值域範圍

Input	輸入層與隱藏層節點之權值及 Bias	Node
X ₁	W _{ji} 為-1~1 之間的連續數值	N ₁
X ₂		N ₂
X ₃		N ₃
X ₄		N ₄
X ₅		N ₅
X ₆		N ₆
X ₇		N ₇
X ₈		N ₈

Node	隱藏層節點與輸出層之權值及 Bias	Output
N ₁	H _{ij} 為-1~1 之間的連續數值	Y
N ₂		
N ₃		
N ₄		
N ₅		
N ₆		
N ₇		
N ₈		

附錄表 3 為 GANN(8-4-1)強度輸入層至隱藏層節點之 GA 求解權值，附錄表 4 為 GANN(8-4-1)強度隱藏層節點至輸出層之 GA 求解權值。

附錄表 3 GANN(8-4-1)強度輸入層至 附錄表 4 GANN(8-4-1)強度隱藏層節
隱藏層節點之權值 點至輸出層之權值

輸入層與隱藏層節點之權值及 Bias						
X ₁	x1	N ₁	N ₂	N ₃	N ₄	
X ₂	x2	-0.16	0.99	0.25	-0.22	N ₁
X ₃	x3	-1.00	0.20	0.99	-0.01	
X ₄	x4	-0.18	0.48	0.36	0.00	N ₂
X ₅	x5	1.00	0.00	0.02	0.06	
X ₆	x6	0.00	-0.39	-0.17	0.00	N ₃
X ₇	x7	-0.97	-0.43	0.58	0.00	
X ₈	x8	-0.09	-0.83	-0.71	0.00	N ₄
	Bias	0.08	0.76	-1.00	1.00	
		-0.59	1.00	0.00	0.00	

隱藏層節點與輸出層之權值及 Bias		
Node	N ₁	Y
N ₁	N ₁	-1.00
N ₂	N ₂	1.00
N ₃	N ₃	-1.00
N ₄	N ₄	-0.76
	Bias	-0.86

附錄表 5 為 GANN(8-8-1)強度輸入層至隱藏層節點之 GA 求解權值，附錄表 6 為 GANN(8-8-1)強度隱藏層節點至輸出層之 GA 求解權值。

附錄表 5 GANN(8-8-1)強度輸入層至
隱藏層節點之權值

輸入層與隱藏層節點之權值及 Bias										
		N ₁	N ₂	N ₃	N ₄	N ₅	N ₆	N ₇	N ₈	
X ₁										N ₁
X ₂	x1	-0.50	0.29	-0.66	-0.24	-0.18	0.59	0.22	0.54	N ₂
	x2	-0.59	-0.22	0.00	0.44	0.00	-0.48	0.58	-0.38	N ₃
X ₃	x3	0.00	-0.06	0.27	0.00	-0.16	0.59	0.14	0.20	N ₄
X ₄	x4	-1.00	0.00	1.00	1.00	0.04	0.19	-1.00	-0.36	N ₅
X ₅	x5	-0.31	0.03	0.76	-0.39	-0.84	0.02	-0.23	-0.48	N ₆
X ₆	x6	0.60	-0.26	-0.58	0.39	0.00	-0.98	1.00	0.38	N ₇
	x7	0.04	-0.73	0.00	-0.55	0.25	1.00	0.00	0.00	N ₈
X ₇	x8	-0.13	1.00	0.32	0.30	1.00	0.41	0.51	-1.00	
X ₈	Bias	-0.59	1.00	0.38	0.75	0.69	-0.91	0.51	-0.45	

附錄表 6 GANN(8-8-1)強度隱藏層節
點至輸出層之權值

隱藏層節點與輸出層之權值及 Bias		
		Y
N ₁		
N ₂	N ₁	-0.93
N ₃	N ₂	1.00
N ₄	N ₃	0.77
N ₅	N ₄	-1.00
N ₆	N ₅	0.81
N ₇	N ₆	-0.37
	N ₇	1.00
	N ₈	1.00
N ₈	Bias	-0.85

附錄表 7 為 GANN(8-16-1)強度輸入層至隱藏層節點之 GA 求解權值，附錄表 8 為 GANN(8-16-1)強度隱藏層節點至輸出層之 GA 求解權值。

附錄表 7 GANN(8-16-1)強度輸入層至隱藏層節點之權值

輸入層與隱藏層節點之權值及 Bias																			
		N ₁	N ₂	N ₃	N ₄	N ₅	N ₆	N ₇	N ₈	N ₉	N ₁₀	N ₁₁	N ₁₂	N ₁₃	N ₁₄	N ₁₅	N ₁₆		
x1																	N ₁		
	x2																N ₂		
	x3	x1	0.54	0.00	-0.50	-0.08	0.00	0.35	-0.91	-0.12	0.37	-0.92	-0.23	0.00	0.34	0.00	-0.62	-0.40	N ₃
		x2	-0.56	-1.00	0.21	0.49	-0.68	-0.05	0.26	0.49	-0.43	0.40	0.22	-0.12	0.94	0.24	-0.68	-0.18	N ₄
	X ₃	x3	0.23	-0.29	-0.05	0.00	-0.21	0.31	0.07	0.00	0.00	0.30	0.00	0.56	0.55	-0.23	0.00	0.60	N ₅
		x4	-1.00	0.37	0.93	-1.00	0.18	-0.47	1.00	0.00	1.00	0.04	-0.62	-1.00	-1.00	0.18	-1.00	0.98	N ₆
	X ₄	x5	0.51	-0.56	0.32	0.00	0.30	-0.25	0.69	-0.71	0.18	-0.31	0.00	-0.42	-0.71	0.28	-0.28	0.00	N ₇
		x6	1.00	0.74	-1.00	1.00	-0.67	-0.40	-1.00	-0.42	-0.63	-0.06	0.00	0.75	0.65	0.00	0.00	0.88	N ₈
	X ₅	x7	0.31	-0.75	0.30	-0.19	1.00	0.00	0.24	0.01	0.44	0.82	-0.03	0.03	0.34	0.70	0.62	0.03	N ₉
		x8	0.00	0.00	-0.22	0.72	1.00	-1.00	-0.31	1.00	0.44	-0.60	-1.00	0.37	0.00	-1.00	0.75	0.53	N ₁₀
	X ₆	Bias	0.06	-0.08	0.78	0.91	0.99	-0.52	0.00	1.00	-0.36	-1.00	-0.58	0.00	-0.24	-0.89	0.38	0.37	N ₁₁
	X ₇																		N ₁₂
	X ₈																		N ₁₃
																			N ₁₄
																			N ₁₅
																			N ₁₆

附錄表 8 GANN(8-16-1)強度隱藏層節點至輸出層之權值

隱藏層節點與輸出層之權值及 Bias		
N ₁		y
N ₂	N ₁	0.66
N ₃	N ₂	0.28
N ₄	N ₃	-0.71
N ₅	N ₄	0.73
N ₆	N ₅	1.00
N ₇	N ₆	0.95
N ₈	N ₇	0.66
N ₉	N ₈	0.91
N ₁₀	N ₉	0.64
N ₁₁	N ₁₀	-0.70
N ₁₂	N ₁₁	0.83
N ₁₃	N ₁₂	-1.00
N ₁₄	N ₁₃	0.96
N ₁₅	N ₁₄	-0.94
N ₁₆	N ₁₅	-0.41
	N ₁₆	0.50
	Bias	-0.68

附錄表 9 為 GANN(11-4-1)坍塌度輸入層至隱藏層節點之 GA 求解權值大小，
附錄表 10 為 GANN(11-4-1)坍塌度隱藏層節點至輸出層之 GA 求解權值大小。

附錄表 9 GANN(11-4-1)坍塌度輸入層至 附錄表 10 GANN(11-4-1)坍塌度隱藏層
隱藏層節點之權值 節點至輸出層之權值

輸入層與隱藏層節點之權值及 Bias						
X ₁		N ₁	N ₂	N ₃	N ₄	N ₁
X ₂	x1	-0.05	0.00	0.00	-0.15	
X ₃	x2	-1.00	-1.00	-0.01	0.09	N ₂
X ₄	x3	-0.52	-0.06	0.21	-0.06	
X ₅	x4	0.79	0.77	0.34	0.62	N ₃
X ₆	x5	0.00	0.00	-0.17	0.68	
X ₇	x6	0.00	0.73	0.62	0.59	N ₄
	x7	-0.30	0.27	-0.34	0.99	
	Bias	-0.14	0.20	0.00	-0.88	

隱藏層節點與輸出層之權值及 Bias		
N ₁		y
N ₂	N ₁	-0.60
N ₃	N ₂	1.00
N ₄	N ₃	0.38
	N ₄	0.52
	Bias	0.21

附錄表 11 為 GANN(11-8-1)坍塌度輸入層至隱藏層節點之 GA 求解權值大小，
附錄表 12 為 GANN(11-8-1)坍塌度隱藏層節點至輸出層之 GA 求解權值大小。

附錄表 11 GANN(11-8-1)坍塌度輸入層

至隱藏層節點之權值

輸入層與隱藏層節點之權值及 Bias										
		N ₁	N ₂	N ₃	N ₄	N ₅	N ₆	N ₇	N ₈	
X ₁	x1	-0.18	0.55	0.00	-0.51	-0.06	-0.28	0.89	-0.25	N ₁
X ₂	x2	1.00	-0.08	-0.42	0.92	-0.31	0.00	-1.00	0.67	N ₂
X ₃	x3	0.59	0.33	0.11	-0.80	0.37	-0.55	0.51	0.40	N ₃
X ₄	x4	-0.16	0.25	0.42	-1.00	-0.27	-0.49	0.00	0.31	N ₄
X ₅	x5	0.94	-0.45	-0.92	-0.71	-1.00	0.88	-0.26	1.00	N ₅
X ₆	x6	-1.00	0.29	0.85	-0.73	0.41	-0.40	0.99	-1.00	N ₆
X ₇	x7	-0.34	-0.19	-1.00	-0.51	-0.75	-0.26	0.25	-0.56	N ₇
	Bias	-0.46	1.00	-0.48	-0.20	1.00	-0.29	0.32	0.50	N ₈

附錄表 12 GANN(11-8-1)坍塌度隱藏層

節點至輸出層之權值

隱藏層節點與輸出層之權值及 Bias		
		Y
N ₁		
N ₂	N ₁	-0.80
N ₃	N ₂	-0.80
N ₄	N ₃	0.44
N ₅	N ₄	-1.00
N ₆	N ₅	-0.95
N ₇	N ₆	-0.74
	N ₇	-0.39
	N ₈	0.58
	Bias	-0.80

附錄表 13 為 GANN(11-16-1)坍塌度輸入層至隱藏層節點之 GA 求解權值大小，附錄表 14 為 GANN(11-16-1)坍塌度隱藏層節點至輸出層之 GA 求解權值大小。

附錄表 13 GANN(11-16-1)坍塌度輸入層至隱藏層節點之權值

輸入層與隱藏層節點之權值及 Bias																		
		N ₁	N ₂	N ₃	N ₄	N ₅	N ₆	N ₇	N ₈	N ₉	N ₁₀	N ₁₁	N ₁₂	N ₁₃	N ₁₄	N ₁₅	N ₁₆	
x1																	N ₁	
x2	x1	-0.52	-0.15	-0.75	0.39	0.18	-0.42	0.54	0.86	0.00	-0.65	-0.46	-0.77	-0.85	0.04	1.00	-0.73	N ₂
x3	x2	-0.46	-0.92	-0.23	-1.00	0.12	-1.00	-0.82	0.39	-0.53	-0.54	0.54	-0.84	0.00	-0.04	-0.53	0.31	N ₃
x4	x3	-0.33	-0.60	0.00	-0.41	0.94	0.39	-0.52	-0.31	0.00	-0.39	0.14	-0.71	-0.72	-0.31	0.60	-0.93	N ₄
x5	x4	0.00	-0.76	0.87	0.61	0.90	0.57	0.63	0.99	-0.47	0.77	0.44	0.31	0.97	0.55	-1.00	0.01	N ₅
x6	x5	-0.95	-0.64	0.00	0.39	0.10	0.77	-0.20	0.00	-0.93	-0.27	0.50	-0.65	0.34	0.13	-1.00	0.01	N ₆
x7	x6	0.00	0.62	0.38	0.63	0.40	-0.06	0.45	0.58	0.44	-0.91	-0.97	0.46	-1.00	0.98	0.10	0.24	N ₇
	x7	0.77	-0.41	0.79	-0.79	0.56	0.24	-0.62	0.34	-0.17	0.31	-1.00	-0.78	0.41	-1.00	0.85	-0.31	N ₈
	Bias	0.97	0.35	-0.43	0.98	-0.49	-0.94	0.93	-0.86	-0.66	0.00	-0.36	-0.41	-0.58	-0.42	0.28	-0.96	N ₉
																		N ₁₀
																		N ₁₁
																		N ₁₂
																		N ₁₃
																		N ₁₄
																		N ₁₅
																		N ₁₆

附錄表 14 GANN(11-16-1)坍塌隱藏層節點至輸出層之權值

隱藏層節點與輸出層之權值及 Bias		
N ₁		y
N ₂	N ₁	0.62
N ₃	N ₂	-0.56
N ₄	N ₃	0.48
N ₅	N ₄	-0.52
N ₆	N ₅	0.17
N ₇	N ₆	0.90
N ₈	N ₇	0.84
N ₉	N ₈	0.45
N ₁₀	N ₉	-0.78
N ₁₁	N ₁₀	-0.34
N ₁₂	N ₁₁	-0.38
N ₁₃	N ₁₂	0.60
N ₁₄	N ₁₃	-0.64
N ₁₅	N ₁₄	-0.31
N ₁₆	N ₁₅	-0.43
	N ₁₆	0.38
	Bias	-0.80

Y

本研究計畫已發表之研究論文

國際期刊論文

1. Yeh, I-Cheng (2005), "Exploring concrete slump model using artificial neural networks," *J. of Computing in Civil Engineering*, ASCE (accepted). (EI, SCI)
2. Yeh, I-Cheng (2005), "Analysis of strength of concrete using design of experiments and neural networks," *Journal of Materials in Civil Engineering*, ASCE (accepted). (SCI, EI)

國內期刊論文

3. 葉怡成、陳家偉(2005),「以實驗計劃法與類神經網路建構混凝土的坍流度模型」,技術學刊(已接受)。
4. 葉怡成、陳家偉(2005),「以二階迴歸分析建構混凝土的坍度模型」,中華理工學刊(已接受)。

國內研討會論文

5. 葉怡成、連立川、張皓博、謝明勳(2005),「以遺傳演算法及運算樹作高性能混凝土工作度建模」,2005 營建技術暨管理研討會,斗六市。

本研究計畫已投稿之研究論文

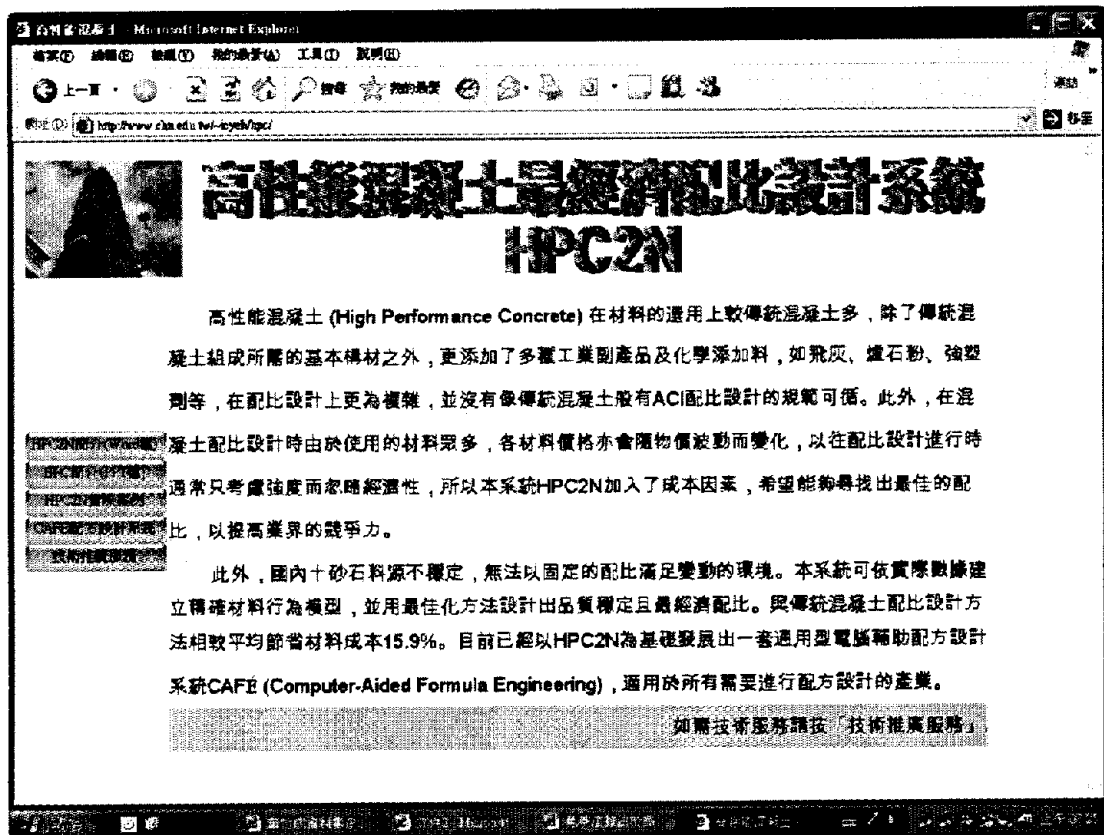
1. Yeh, I-Cheng (2005), "Modeling workability of concrete using second-order regressions and artificial neural networks," *Cement and Concrete Research* (submitted). (SCI, EI)
2. 葉怡成、彭釗哲、連立川(2005),「類神經網路與經驗公式在高性能混凝土抗壓強度預測之比較」,技術學刊。
3. Yeh, I-Cheng (2005), "Generalization of strength versus water-cementitious ratio relationship to age," *ACI Materials Journal* (submitted).(SCI, EI)
4. Yeh, I-Cheng (2005), "Computer-aided design for optimum concrete mixture," *Canadian Journal of Civil Engineering*. (SCI, EI)
5. Yeh, I-Cheng (2005), "Optimization of concrete mix proportioning using flatted simplex-centroid mixture design and neural network," *ACI Materials Journal* (submitted). (SCI, EI)
6. Yeh, I-Cheng (2005), "Prediction of workability of concrete using design of experiments for mixtures," *工業工程學刊*. (EI)
7. Yeh, I-Cheng, "Modeling Interactions of fly ash and superplasticizer on workability of concrete," *Magazine of Concrete Research* (submitted).(SCI, EI) (2005)
8. Yeh, I-Cheng (2005), "Computational simulation of concrete slump using artificial neural networks," *Cement and Concrete Research*.(SCI, EI)
9. Yeh, I-Cheng (2005), "Neural networks for evaluating workability of

- high-performance concrete,” *Cement & Concrete Composites* (submitted).(SCLEI)
10. 連立川、葉怡成、鄭明淵(2005),「以遺傳演算法及運算樹作高性能混凝土強度建模」,技術學刊,審稿中。

本研究計畫發表之學位論文

1. 黃冠傑(2004),類神經網路視窗軟體之設計,碩士論文,中華大學土木工程學系。
2. 劉原旭(2005),高性能混凝土配比設計最佳化之研究,碩士論文,中華大學土木工程學系。
3. 連立川(2005),遺傳演算法在強化式學習之應用,碩士論文,中華大學土木工程學系。

本研究計畫的專屬推廣網頁(www.chu.edu.tw/~icyeh/hpc/)



高性能混凝土最經濟配比設計系統 HPC2N

高性能混凝土 (High Performance Concrete) 在材料的運用上較傳統混凝土多,除了傳統混凝土組成所需的基本構材之外,更添加了多項工業副產品及化學添加料,如飛灰、爐石粉、強塑劑等,在配比設計上更為複雜,並沒有像傳統混凝土般有ACI配比設計的規範可循。此外,在混凝土配比設計時由於使用的材料眾多,各材料價格亦會隨物價波動而變化,以往配比設計進行時通常只考慮強度而忽略經濟性,所以本系統HPC2N加入了成本因素,希望能夠尋找出最佳的配比,以提高業界的競爭力。

此外,國內十砂石料源不穩定,無法以固定的配比滿足變動的環境。本系統可依實際數據建立精確材料行為模型,並用最佳化方法設計出品質穩定且最經濟配比。與傳統混凝土配比設計方法相較平均節省材料成本15.9%。目前已經以HPC2N為基礎發展出一套通用型電腦輔助配方設計系統CAFÉ (Computer-Aided Formula Engineering),適用於所有需要進行配方設計的產業。

如需技術服務請按「技術推廣服務」

Exploring Concrete Slump Model Using Artificial Neural Networks

By I-Cheng Yeh¹

Abstract: Fly ash and slag concrete (FSC) is a highly complex material so that modeling its behavior is a difficult task. In this paper, a method of modeling slump of FSC using artificial neural networks is described. The slump is a function of the content of all concrete ingredients, including cement, fly ash, blast furnace slag, water, superplasticizer, coarse aggregate, and fine aggregate. The model built was examined with response trace plots to explore the slump behavior of FSC. This study led to the conclusion that response trace plots can be used to explore the complex nonlinear relationship between concrete components and concrete slump.

CE Database Subject Headings: concrete, models, mixtures, neural networks.

INTRODUCTION

Workability is one of the key properties that must be satisfied for producing concrete with high quality. It should be apparent that workability is a composite property, with at least two main components: (1) Consistency describes the ease of flow. (2) Cohesiveness describes the tendency to bleed or segregate. The slump test is not suitable for measuring the consistency of very wet or very dry concrete. Although it is not a good measure for workability, it is a fairly good measure of the consistency or flow characteristic of a concrete mixture.

A basic concrete is made of 4 components (cement, water, coarse aggregate, and fine aggregate). Therefore, modeling such a concrete is a four-parameter modeling problem. Adding two mineral admixtures (fly ash and blast furnace slag) and one chemical admixture (superplasticizer), makes the problem become a seven-parameter modeling problem and much more difficult.

¹ Prof., Department of Civil Engineering, Chung-Hua University, 30 Tung Shiang, Hsin Chu, Taiwan 30067, R.O.C.

Artificial neural network (ANN) is a powerful tool for modeling complex nonlinear systems. A neural network model is a computer model whose architecture essentially imitates a human brain's learning capabilities. Most applications of neural networks are based on the back-propagation paradigm that utilizes the gradient-descent method to minimize the error function. A thorough treatment of back-propagation networks is beyond the scope of this paper. The basic algorithms of back-propagation have been covered widely (Welstead 1994).

In the area of material modeling, Ghaboussi et al. (1991) modeled the behavior of concrete in the state of plane stress under monotonic biaxial loading and compressive uniaxial cycle loading with a back-propagation neural network. Kasperkiewicz et al. (1995) demonstrated that the fuzzy-ARTMAP neural network could model strength properties of HPC mixes and optimize the concrete mixes. Yeh proposed modified neural network architecture for modeling the strength of concrete (1998a, 1998b) and optimize the mix proportions (1999, 2003).

In this paper, a method of modeling the slump of fly ash and slag concrete (FSC) using artificial neural network is described. The slump is a function of the content of all concrete ingredients, including cement, fly ash, blast furnace slag, water, superplasticizer, coarse aggregate, and fine aggregate. Besides, the effects of each component to slump were also examined by response trace plots in this study.

EXPERIMENTAL PROGRAM TO COLLECT DATA

Because superplasticizer is the essential material to workability while its chemical composition is various, the data for modeling workability were collected from the same lab by author. Mixing was carried out in a laboratory pan mixer. The superplasticizer was premixed with water to ensure consistency of action throughout the test program. The fresh concrete was assessed by the slump test.

To collect training and testing data systematically, mix proportions were performed using the design of mixture experiment, which is a special type of design of experiments (DOE) in which the factors are the ingredients or components of a mixture, and the response is a function of the proportions of each ingredient. These proportionate amounts of each ingredient are typically measured by weight, by volume, and so forth (Myers and Montgomery 1995). In this study, the experiments were designed according to a simplex-centroid design (SCD). A thorough treatment of simplex-centroid design is beyond the scope of this paper. The basic algorithms of SCD have been covered widely (Myers and Montgomery 1995). Basically, a q-component SCD consists of 2^q-1 distinct design points; therefore, there were 127 design points in this study. However, certain extreme design points are not possible

and must be omitted. For example, low water content in combination with low superplasticizer content may give too-dry mixes, and higher water content in combination with higher superplasticizer content may give too-wet mixes. In both cases, unreliable experimental data would be obtained. Therefore, such combinations have to be ignored. Consequently, instead of conducting a SCD that consists of 127 design points, only seventy-eight various mix proportions were performed to collect data. These data were used to build the workability model.

MODELING CONCRETE SLUMP USING NEURAL NETWORKS System Model

Although the components are described using only a single term for each, they actually mean a variety of forms. For example, the superplasticizer can be of various chemical compositions. However, the properties of concrete are mainly influenced by the mix proportions. Therefore, in this approach, slump of concrete is a function of the following seven input features: (1) Cement (kg/m^3) (2) Fly ash (kg/m^3) (3) Blast furnace slag (kg/m^3) (4) Water (kg/m^3) (5) Superplasticizer (kg/m^3) (6) Coarse aggregate (kg/m^3) (7) Fine aggregate (kg/m^3).

Data Sets

The database of 78 records, each containing seven components of the input vector, and one output value, slump (from 0 to 30 cm), was split in such a way that all the records were simply shuffled using a random sampling, dividing them into four groups, i.e., A, B, C, and D data group. Four models (Model A, Model B, Model C, and Model D) were developed based on these groups. For example, in Model A, data group A was assigned as the testing set, and the other three data groups (B, C, and D) were assigned as the training set.

Training Results

The values of network parameters considered in this approach are as follows: number of hidden layers = 0, 1, and 2; number of hidden units = 3, 5, 7, 10, and 14; learning rate = 0.1, 0.3, 1.0, and 3.0; momentum factor = 0.0, 0.25, 0.5, and 0.75; and learning cycles = 500, 1000, 2000, 5000, 10000, and 20000 (each cycle covers the entire database available for training). Based on the error of testing set, the best network parameters are as follows: number of hidden layers = 1; number of hidden units = 7; learning rate = 1.0; momentum factor = 0.5; and learning cycles = 2000.

It appears that the root of mean squared error (RMSE) is 4.18, 5.00, 4.15, and 2.78 cm for Model A, B, C, and D, respectively, and 4.03 cm for the integral model, which included the testing examples of Model A, B, C, and D.

To examine the influence of network and training parameters, the training results based on various numbers of hidden neurons and learning rates are shown in Fig. 1. It

is shown that although the parameters have some effects on the training results, the accuracy is rather stable through various network and training parameters.

Comparative Studies

To compare the neural network approach with the conventional material modeling approach, the non-linear regression approach was employed and the same variables and data were employed to build the regression formulas. The types of second-order regression formulas adopted were as follows:

$$y = \sum_{i=1}^q \beta_i x_i + \sum_{i < j} \beta_{ij} x_i x_j \quad (1)$$

where x_i = the i th component content; β_i, β_{ij} = regression coefficients.

It appears that the root of mean squared error (RMSE) is 8.12, 7.13, 13.86, and 5.25 cm for Model A, B, C, and D, respectively, and 9.29 cm for the integral model, which included the testing examples of Model A, B, C, and D.

The comparison shows that the neural network models (RMSE=4.03 cm) are supported better by experimental data than the regression analysis (RMSE=9.29 cm). In a study done by ASTM, it was determined that measured differences in slump of greater than 2 inches (5.08 cm) from the same batch are considered excessive. Less than 2 inch (5.08 cm) differences are considered to be typical for sampling, testing and material variation (American Concrete Pavement Association, 2005). Therefore, the error of the neural network model is relatively small and acceptable.

RESPONSE TRACE PLOTS OF THE SLUMP MODELS

The response trace is a plot of the estimated response values as we move away from the “reference mixture” and along the component axes. The trace plot can be used to find those components that most affect the response. Consider the i th component and suppose we move away from the reference mixture by changing the proportion of this component by an amount Δ_i (note that we could make Δ_i either positive or negative). Along the i th axis as the value of x_i either increases or decreases, the values of other component proportions $x_j, j \neq i$, either decrease or increase, but the relative proportions for these other components remain the same (Myers and Montgomery 1995).

We may give a general equation for these results. If x_i is changed by an amount Δ_i from the reference mixture, to keep the volume to be one cubic meter, that is

$$\sum_{i=1}^q x_i = 1 \quad (2)$$

then new proportions are

$$x_i = r_i + \Delta_i \quad (3)$$

$$x_j = r_j - \frac{r_j}{1 - r_i} \Delta_i, i \neq j \quad (4)$$

where r_i = the value of component i of the reference mixture.

To construct a response trace plot, we would choose some number of blends along the component axis; obtain the predicted response values of these blends by the fitted model; then these predicted response values are plotted against the component axis.

If one or more of the response traces is a horizontal line, this indicates that these components have little effect on the response; that is, we have discovered ingredients that are inactive. On the other hand, if one or more of the response traces is a steep slope line or a curve, this indicates that these components have a large effect on the response.

Figures 2 to 8 are the response trace plots for the slump model built. The vertical axis is the predicted slump, and the horizontal axis is the content of each component. The reference mixture is the overall center of the data set.

The following conclusions can be drawn (results should not be extrapolated outside the experimental domain or other combinations of materials):

1. The slump increases very slightly and then decreases sharply as the cement content increases at the level of 260 kg/m³ and above (refer to Fig. 2).
2. The slump increases and then decreases very sharply as the fly ash content increases at the level of 95 kg/m³ and above (refer to Fig. 3).
3. The plot of slag is very similar to that of cement. The slump increases very slightly and then decreases sharply as the slag content increases at the level of 115 kg/m³ and above (refer to Fig. 4).
4. The slump increases very sharply and then decreases very slightly as the water content increases at the level of 195 kg/m³ and above (refer to Fig. 5).
5. The plot of superplasticizer is very similar to that of water. The slump increases very sharply and then decreases very slightly as the superplasticizer content increases at the level of 10 kg/m³ and above (refer to Fig. 6).
6. The slump remains constant and then decreases as the coarse aggregate content increases at the level of 900 kg/m³ and above (refer to Fig. 7).
7. The slump remains constant as the fine aggregate content increases (refer to Fig. 8).

In conclusion, the slump is very sensitive to changes in fly ash, water, and superplasticizer. The conclusion is consistent with the current knowledge about the factors controlling the slump.

CONCLUSIONS

Fly ash and slag concrete is a highly complex material so that modeling its behavior is a difficult task. This paper is aimed at demonstrating the possibilities of adapting

neural networks to predict the slump of concrete. This study led to the following conclusions:

1. The slump model based on artificial neural networks (RMSE=4.03 cm) is much more accurate than the model based on non-linear regression analysis (RMSE=9.29 cm).
2. The response trace plot can be used to explore the complex nonlinear relationship between concrete components and concrete slump.

The slump can be calculated by those models built with this methodology. It becomes convenient and easy to use those models to predict any mix proportions as long as their types of admixtures, in particular, superplasticizer, are similar. Although the similarity of admixtures is the constraint to use the model, every empirical model based on experimental data is also confined by the constraint. Moreover, each local plant, at least in Taiwan, is always used to taking some specific admixtures; therefore, the constraint may be not a serious flaw to use the methodology.

Important future developments of the approach are listed as follows:

1. A set of comprehensive numerical experiments to explore the interactive effects between components on the mix proportions should be conducted using the response trace plots approach.
2. The system should be trained using a much larger database in a straightforward way. More reliable predictions would be possible.

Acknowledgments

This work was supported by the National Science Council, ROC, under Grant NSC-92- 2211-E-216-015.

APPENDIX. REFERENCES

- American Concrete Pavement Association (2005). "What is the meaning of slump and what does it tell me about my concrete?" <<http://www.pavement.com/PavTech/Tech/FATQ/fatq-slump.html>> (May 1, 2005)
- Ghaboussi, J., Garrett, J. H., and Wu, X. (1991). "Knowledge-based modeling of material behavior with neural networks." *J. Engrg. Mech.*, ASCE, 117(1), 129-134.
- Kasperkiewicz, J., Racz, J., and Dubrawski, A. (1995). "HPC strength prediction using artificial neural network." *J. Comp. in Civ. Engrg.*, ASCE, 9(4), 279-284.
- Myers, R. H., and Montgomery, D. C. (1995). *Response Surface Methodology*. John Wiley & Sons, Inc., New York.
- Welstead, S. T. (1994). *Neural Network and Fuzzy Logic Applications in C/C++*. John Wiley & Sons, New York.
- Yeh, I-Cheng (1998a). "Modeling concrete strength with augment-neuron networks."

J. Materials in Civ. Engrg., ASCE, 10(4), 263-268.

Yeh, I-Cheng (1998b). "Modeling of strength of high performance concrete using artificial neural networks." *Cement and Concrete Research*, 28(12), 1797-1808.

Yeh, I-Cheng (1999). "Design of high performance concrete mixture using neural networks." *J. Comp. in Civ. Engrg.*, ASCE, 13(1), 36-42.

Yeh, I-Cheng (2003). "A mix proportioning methodology for fly ash and slag concrete using artificial neural networks." *Chung Hua Journal of Science and Engineering*, 1(1), 77-84.




FIG. 1. The influence of network and training parameters.




FIG. 2. Response trace plot of slump along the component axis of cement.




FIG. 3. Response trace plot of slump along the component axis of fly ash.




FIG. 4. Response trace plot of slump along the component axis of slag.




FIG. 5. Response trace plot of slump along the component axis of water.




FIG. 6. Response trace plot of slump along the component axis of superplasticizer.




FIG. 7. Response trace plot of slump along the component axis of coarse aggregate.




FIG. 8. Response trace plot of slump along the component axis of fine aggregate.

Analysis of Strength of Concrete Using Design of Experiments and Neural Networks

By I-Cheng Yeh¹

Abstract: This paper investigates the potential of using design of experiments (DOE) and neural networks to determine the effect of fly ash replacements, from 0 to 50%, on the early and late compressive strength, from 3- to 56-day, of low- and high-strength concrete, at water-cementitious material ratio in the range of 0.3 to 0.7. Research reported in this paper shows the following conclusions. (1) Using a simplex-centroid mixture experiment design, a much smaller number of experiments need be performed to obtain meaningful data. (2) High correlations between the compressive strength and the component composition of concrete can be developed using the generalization capabilities of the neural networks. (3) Analyses of variance to test the effects of the variables and their interactions on concrete strength can be performed. (4) The strength ratio, which means the percentage of strength of concrete containing fly ash to strength of concrete without fly ash (pure cement concrete) based on the same w/b and the same age, is significantly reduced as the fly ash replacement increases, somewhat reduced as the water-binder ratio decreases, and much significantly reduced as the age decreases. (5) The higher fly ash content mixes yielded lower strength ratios throughout, the difference being greater at early age and low water-binder ratio.

CE Database Subject Headings: concrete, fly ash, strength, neural networks.

¹ Prof., Civ. Engrg. Dept., Chung-Hua Univ., Hsin Chu, Taiwan 30067, R.O.C. Email: icyeh@chu.edu.tw

Introduction

Fly ash is the primary waste material from coal-burning power plants. Production of the supplementary cementitious materials will increase as its relevant industries continue to develop. In most cases there is the economic benefit of the price differential between cement and fly ash. At the moment, there are few specific mix proportioning methods designed for fly ash concrete. The material is used as a direct replacement of cement by weight, at proportions of 10 to 25 percent by mass of the total cementitious content, and then current proportioning techniques for concrete made with portland cement are followed. Generally, the compressive strength of concrete containing fly ash is lower than that of a control concrete without fly ash, particularly at early age and at replacement levels of 25 percent and above. At low water-to-binder ratios of about 0.35, 28-day cube compressive strengths of 35 to 50 MPa have been obtained for such cements without much difficulty (Swamy and Bouikni 1990).

Over the last few decades, a considerable volume of research has been directed toward generating the strength-w/b relations for concrete in compression, the importance of which needs no elaboration. In plain portland cement concrete, it is usually assumed that as long as the portland cement itself is satisfactory, the quality of the cement paste produced is primarily an inverse function of the water-cement ratio (w/c). In other words, the strength of concrete is a function of the total void content of the material (Aitcin and Neville 1993). The addition of fly ash to the mix introduces a variable that influences paste quality and, consequently, the overall quality of the concrete. Many studies have shown that when the water-binder ratio (w/b) (water-cementitious material ratio) is used instead of water-cement ratio as the basis for mix designing, strength prediction becomes more accurate. However, the quality of the resulting fly ash portland cement paste may vary with the level of replacement. Thus, it is practically known that concretes with the same w/b value may have different compressive strength. Therefore, experimental determination of the relations has become more difficult because the composition of concrete has become more diverse (Wee et al. 1996).

This paper aims to present the experimental results of the effect of fly ash replacements on the early and late compressive strength of low- and high-strength concrete. One traditional experimental program methodology of studying the effects of various components is to vary one component at a time and keep all others constant. Response readings are then taken for different levels of this component. This process is repeated by varying other components one by one until all the components have been treated. This approach may not be satisfactory because of interactions between

components. Therefore, the methodology does not seem appropriate to build the model of concrete strength since the interactions between factors of strength are usually very large. To overcome this difficulty, recourse is made to design of experiments (DOE).

Industrial researchers typically turn to two-level factorials as their first attempt at DOE. These designs consist of all combinations of each factor at its high and low levels. With large numbers of factors, only a fraction of the runs need to be completed to produce estimates of main effects and simple interactions. However, when the response depends upon proportions of ingredients, such as in chemical or material formulations, factorial designs may not make sense.

For example, for a normal concrete consisting of cement, water, fine aggregate, and coarse aggregate, assuming that the cement and water are controllable factors with two levels, 360 and 440 kg, and 180 and 220 kg, respectively; fine aggregates and coarse aggregate are uncontrollable factors with a fixed level of 800 and 1000 kg; then, the two-level factorials are shown in Table 1. Run 1 (both factors low) and Run 4 (both factors high) have the same strength. However, it makes more sense to look at strength as a function of the proportion of water to cement, not the amount.

There are many industrial problems where the response variables of interest in the product are a function of the proportions of the different ingredients used in its formulation. This is a special type of response surface problem called a mixture problem. Design of experiments for mixture accounts for the dependence of response on proportionality of ingredient (Myers and Montgomery 1995).

Using polynomial regressions, the DOE approach permits the calculation of the response surfaces for the parameters under study over the experimental domain. However, because of high complexity of the relation between compressive strength and component composition of concrete, conventional regression analysis could be not sufficient to build an accurate model. Artificial neural networks (ANN) are essentially information modeling systems that mimic the biologic system of the brain. The neural network modeling approach is simpler and more direct in comparison with traditional statistical methods, particularly when modeling nonlinear multivariate interrelationships. Some recent applications of neural networks in civil engineering materials include those references, Ghaboussi et al. (1991), Oh et al. (1999), Basma et al. (1999), Yeh (1998a, 1998b, 1999), Yeh et al. (2002), Haj-Ali et al. (2001), Nehdi et al. (2001a, 2001b); Peng et al. (2002), El-Chabib et al. (2003), Kim et al. (2004), and Stegemann and Buenfeld (2004). However, little research has been done on modeling strength of concrete containing large amount of fly ash and superplasticizer using neural networks associated with DOE.

This paper investigates the potential of using DOE and neural networks to

determine the effects of fly ash replacements, from 0 to 50%, on the early and late compressive strength, from 3- to 56-day, of low- and high-strength concrete, at water-cementitious material ratio in the range of 0.3 to 0.7.

Introduction of Design of Experiments for Mixture

In general, suppose that the mixture consists of q ingredients or components, and let x_i represent the proportion of the i th ingredient in the mixture. In light of the above discussion the mixture problem becomes

$$x_i \geq 0, \quad i = 1, 2, \dots, q \quad (1)$$

and

$$\sum_{i=1}^q x_i = x_1 + x_2 + \dots + x_q = 1 \quad (2)$$

The constraint in Equation (2) makes the levels of the components x_i dependent, and this makes mixture experiments different from the factorial experiments. The primary differences between a factorial experiment and a mixture experiment are that (1) a special type of design must be used and (2) the form of the mixture polynomial is slightly different from the standard polynomials used in factorial design (Myers and Montgomery 1995).

In this study, a mixture design called simplex-centroid design was adopted. A q -component simplex-centroid design consists of $2^q - 1$ distinct design points. These design points are the q permutations of $(1, 0, 0, \dots, 0)$ or single-component blends, the $\binom{q}{2}$ permutations of $(1/2, 1/2, 0, \dots, 0)$ or all binary mixtures, the $\binom{q}{3}$ permutations of $(1/3, 1/3, 1/3, 0, \dots, 0)$, and so forth, and the overall centroid $(1/q, 1/q, \dots, 1/q)$. Because the mixture space is a simplex, all design points must be at the vertices, on the edges or faces, or in the interior of a simplex.

To illustrate how to apply mixture design, a simplex-centroid mixture design that involves three components is listed in Table 2. The design keeps the total of the components at one unit. Figure 1 shows the location of the points of the design in the mixture space. In this triangular layout, the apexes represent the use of only a single, specific component. Binary blends, which provide estimates of second-order effects, occur at the midpoints of the sides on the triangle. The points in the interior represent three-part blends. The centroid point contains equal amounts of all three ingredients. The individual proportions go from zero to one from base to apex in each of the three axes (Myers and Montgomery 1995).

Constraints on individual components may be introduced. The constrained mixture

problem becomes

$$L_i \leq x_i \leq U_i, \quad i = 1, 2, \dots, q \quad (3)$$

where L_i and U_i is the lower bound and upper bound of the i th component;

and Equation (2). However, this adds complications that go beyond the scope of this article. The reference of Myers and Montgomery (1995) is an excellent and very complete reference on the subject.

The design points in the simplex-centroid design will support q th-order mixture polynomial

$$E(y) = \sum_{i=1}^q \beta_i x_i + \sum_{i < j} \sum_{j}^q \beta_{ij} x_i x_j + \sum_{i < j < k} \sum_{k}^q \beta_{ijk} x_i x_j x_k + \dots + \beta_{12\dots q} x_1 x_2 \dots x_q \quad (4)$$

where x_i is the proportion of the i th ingredient in the mixture; β_i , β_{ij} , β_{ijk} , \dots ,

$\beta_{12\dots q}$ are the regression coefficients.

For $q = 3$ components, this model is

$$E(y) = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{12} x_1 x_2 + \beta_{13} x_1 x_3 + \beta_{23} x_2 x_3 + \beta_{123} x_1 x_2 x_3 \quad (5)$$

which is the special cubic polynomial from Equation (4). For $q=4$ components, the model is

$$E(y) = \sum_{i=1}^4 \beta_i x_i + \sum_{i < j} \sum_{j}^4 \beta_{ij} x_i x_j + \sum_{i < j < k} \sum_{k}^4 \beta_{ijk} x_i x_j x_k + \beta_{1234} x_1 x_2 x_3 x_4 \quad (6)$$

or the special cubic model with an additional quartic term. Because relatively efficient designs for fitting the special cubic model, simplex-centroid designs are often used when the experimenter thinks that some cubic terms may be necessary in the final model (Myers and Montgomery 1995).

Design of Experiments for Concrete Mixture

The lower and upper bound of each component is listed in Table 3. In a mixture experiment, the response is observed at all mixture design points and the effects of component and interactions between components are investigated simultaneously.

However, in concrete mixture design, certain mixture design points are not possible and must be omitted. Such a deliberate omission of some design points creates some experimental and analysis problems, both theoretical and numerical. Therefore, a flattened simplex-centroid mixture experiment design was adopted. Thus, instead of

using a total of $2^9 - 1 = 2^7 - 1 = 127$ mixture design points, 78 design points that covered a whole range of values likely to be encountered in practice were selected. The sequence in which the mixture design points were investigated was randomized to avoid any statistical significance of a blocking effect.

All compressive strengths were measured on 150 mm cylinders. These were fully compacted on a vibrating table, moist-cured for 24 hours, demolded, and then cured in water at 20°C until testing at 3, 7, 14, 28, and 56 days. Therefore, there are $78 \times 5 = 390$ training data. Each quoted strength value is the average of strengths from three cylinders.

Besides, to evaluate the accuracy of model built with the mixture design, 10 concrete mixtures and their test results at 3, 14, 28, 56, and 90 day collected from literature (Yeh 1999) were used. Therefore, there are $10 \times 5 = 50$ testing data. Although there are only 10 mixtures in the literature, they covered five different levels of strength about 25, 32.5, 40, 47.5, and 55 MPa, and five different levels of workability about 5, 10, 15, 20, 25 cm in slump. It may be sure that these will form a fairly representative group covering all the ranges of practical use for concrete mixtures and present rather complete and independent information required for such an evaluation.

The results of the compressive strength tests were subjected to polynomial regression using a computer program. Various polynomials were tried to represent the measured compressive strength data for seven component contents at a specific age. The best fit for the compressive strength was obtained with Root-Mean-Square (RMS) error of 3.96 MPa ($R^2 = 0.890$) and RMS error of 8.82 MPa ($R^2 = 0.791$) for training data and testing data, respectively. Predictions of the strength for concrete using regressions for training data and testing data are shown in Fig. 2 and Fig. 3, respectively. It can be seen that although the RMS error for training data is rather low, the RMS error for testing data is so high as to provide inaccurate predictions. In other words, the model lacks for generalization.

Introduction of Neural Networks

A neural network is a computer model whose architecture essentially mimics the knowledge-acquisition of the human brain. It consists of a number of interconnected processing elements, commonly referred to as neurons. The neurons are logically arranged into two or more layers and interact with each other via weighted connections. These scalar weights determine the nature and strength of the influence between the interconnected neurons. Each neuron is connected to all the neurons in the next layer. There is an input layer where data are presented to the neural network and an output layer that holds the response of the network to the input. It is the

intermediate layers, also known as hidden layers, which enable these networks to represent and compute complicated associations between patterns (Goh 1995). Each hidden and output neuron processes its inputs by multiplying each input by its weight, summing the product, and then passing the sum through a nonlinear transfer function to produce a result. The S-shaped sigmoid curve is commonly used as a transfer function.

The neural network “learns” by modifying the weights of the neurons in response to the errors between the actual output values and the target output values. The neural network paradigm adopted in this study utilizes the back propagation learning algorithm. In back propagation neural networks, the mathematical relationships between the various variables are not specified. Instead, they learn from the examples fed to them. In addition, they can generalize correct responses that only broadly resemble the data in the learning phase (Goh 1995). The details of the algorithm will not be discussed here. It has been thoroughly described by Lippmann (1987). Numerous implementations of back propagation are commercially available. In short, for the first cycle of training, random weights were assigned to the connections between the units. Training was carried out until the average sum squared error over all the training patterns was minimized. During training the network performance is monitored by RMS error to achieve a better understanding of the network performance.

Once trained, the values for the input parameters for the project are presented to the network. Then the network calculates the node outputs using the existing weight values and thresholds developed in the training process. The neural network will produce almost instantaneous results of the output for the practical inputs provided. Such a trained neural network not only would be able to reproduce the experiment results it was trained on, but through its generalization capability it should be able to approximate the results of other experiments. The degree of accuracy in this generalization depends on how comprehensive the training set is (Ghaboussi 1991). The predictions should be reliable, provided the input values are within the range used in the training set (Goh 1995).

Neural Networks for Modeling Strength Behavior

To efficiently generate response surfaces of compressive strength of concrete, instead of commercially available neural network software, the program adopted in this study was written in C language and essentially followed the formulations of Lippmann (1987).

The neural network developed in the investigation has eight units represented as

cement, fly ash, slag, water, SP, coarse aggregate, fine aggregate, and age, in the input layer and one unit represented as compressive strength in the output layer. After a number of trials, the best network architecture and parameters which minimize the RMS error of testing data were selected as follows:

- number of hidden layer=1
- number of hidden unit=4
- learning rate=1.0
- learning cycle=3000

Training time on a personal computer was less than 30 seconds. The RMS error is 3.01 MPa ($R^2=0.940$) and 4.32 MPa ($R^2=0.929$) for training data and testing data, respectively. Predictions of the strength for concrete using the network for training data and testing data are shown in Fig. 4 and Fig. 5, respectively. Comparing Fig. 5 and Fig.3, it may be seen that the model obtained by neural networks more accurately predicts the experimental results for the testing data in the range of concrete strength in this study.

Response Surfaces of Compressive Strength

When the neural network model for compressive strength had been built, the predicted compressive strength can be regarded as a function of all the input variables. Although there are eight input variables in the model, it is more meaningful to investigate the response surface and relations between the compressive strength and age and two ratios of components, water-binder ratio and fly ash-binder ratio. The binder means cementitious material, that is, cement plus fly ash and slag. The range of each variable is listed as follows:

1. The water-binder ratio (w/b) was varied with 0.3, 0.4, 0.5, 0.6, and 0.7.
2. The fly ash-binder ratio (fa/b), the amount of fly ash by weight of binder, was varied with 0, 10, 20, 30, 40, and 50%.
3. The age of concrete was varied with 3, 7, 14, 28, and 56 days.

Besides, all other components or their ratios were kept constant: the slag, water, and SP content was kept constant 0, 175, and $5 \text{ kg} / \text{m}^3$, respectively; the coarse aggregate to fine aggregate was kept constant 1.0; the total volume of concrete was 1.000 m^3 .

From the w/b-strength ratio curves generated using the trained neural network developed in this study with the above combinations, five sets of curves have been shown in Figs. 6 to 10 to explore the effects of fa/b and w/b at 3, 7, 14, 28, and 56 days. The strength ratio means the percentage of strength of concrete containing fly ash to strength of concrete without fly ash (pure cement concrete) based on the same w/b and the same age. Besides, five response surfaces have been shown in Figs. 11 to

15 to explore the interactions between f_a/b and w/b at 3, 7, 14, 28, and 56 days. Some conclusions were gotten as follows.

The effects of f_a/b

At the same age and w/b , the reduction of strength ratio with fly ash content in the cement paste is proportional. For example, at 28-day age, as can be seen in Fig. 9, $w/b=0.5$, the effect of relatively small replacements (10%) is to slightly decrease 2% of strength ratio; however, the effect of relatively large replacements (50%) is to significantly decrease 18% of strength ratio.

The effects of w/b

At high fly ash replacement, the greatest proportional strength ratio decreases were at the low water-cementitious material ratios. For instance, at 28-day age, the strength of concrete containing 50% of fly ash at $w/b=0.3$ and 0.7 is 72% and 82% of that of concrete without fly ash. However, at low fly ash replacement, the reduction of strength ratio produced by replacing cement with fly ash in concrete mixes prepared at a lower w/b was about the same as those prepared at a higher w/b . This phenomenon is illustrated in Figs. 6, 8, and 10 for concrete at 3-day, 14-day, and 56-day, respectively. At 3-day, the 30% fly ash mix at $w/b=0.3$ and 0.7 achieved 73% and 67% of the compressive strength of the reference pure cement mix; at 14-day, 83% and 83%, and at 56-day, 95% and 95%.

The effects of age

Higher volumes of fly ash replacement resulted in significantly lower strength ratio at the early ages, while resulted in slightly lower strength ratio at the late ages. For example, at $w/b=0.5$, the strengths of concrete containing 50% fly ash at 3-day (Fig. 6) and 56-day (Fig. 10) are 51% and 91% of that of concrete without fly ash.

The interactions of f_a/b and w/b

- (1) Lower volume of fly ash replacement resulted in about the same reduction of strength ratio at low w/b and at high w/b . For example, at 28-day age, as can be seen in Fig. 9 and Fig. 14, the strengths of concrete containing 10% fly ash at $w/b=0.3$ and 0.7 are 99% and 97% of that of concrete without fly ash, respectively.
- (2) Higher volume of fly ash replacement resulted in significantly lower strength ratio at low w/b , while resulted in slightly lower strength ratio at high w/b . For example, at 28-day age, the strengths of concrete containing 50% fly ash at $w/b=0.3$ and 0.7 are 72% and 82% of that of concrete without fly ash, respectively.

The interactions of f_a/b and age

- (1) At the early ages, fly ash contributed little to strength. For example, at 3 days, as shown in Fig. 6 and Fig. 11, at water-binder ratio of 0.5, compared to the concrete without fly ashes, the strength ratio was reduced by 7% for a 10% fly ash

replacement, and by 49% for a 50% fly ash replacement.

- (2) At medium ages, fly ash contributed a little to strength. For instance, at 28 days, as can be seen in Fig. 9 and Fig. 14, at water-binder ratio of 0.5, the strength of the 10% fly ash mixes was only slightly lower (2%) than the pure cement mixes, although 50% fly ash replacement still resulted in a 18% reduction of strength ratio.
- (3) At the later ages, the contribution of fly ash to compressive strength became greater. For example, at 56 days, as can be seen in Fig. 10 and Fig. 15, at water-binder ratio of 0.5, the strength of the 10% fly ash mixes was the same as that of the pure cement mixes, and 50% fly ash replacement only resulted in a 9% reduction of strength ratio.

The interactions of w/b and age

- (1) At the early ages, there is the optimum w/b for minimizing the reduction of strength ratio. For example, at 3 days, as shown in Figure 6, the strength ratio of concrete containing 50% fly ash at w/b=0.3 and 0.7 is 41% and 42%, respectively; however, at w/b=0.45 is 51%, a significant greater percentage.
- (2) At the later ages, the higher the w/b, the higher the strength ratio. For example, at 56 days, as shown in Figure 10, the strength ratio of concrete containing 50% fly ash at w/b=0.3, 0.5, and 0.7 are 83%, 90%, and 90%, respectively.

Conclusions

Research reported in this paper shows the following conclusions:

1. For concrete compressive strength, using a simplex-centroid mixture experiment design, a much smaller number of experiments need be performed to obtain meaningful data. Such data can be satisfactorily used for building neural network model. A q-component simplex-centroid design consists of $2^q - 1$ distinct design points. Therefore, because there are seven components in this study, there are $2^7 - 1 = 127$ mixtures. Considering that if there are five levels for each component, the complete combinations are therefore $5^7 = 78125$ mixtures. Therefore, the simplex-centroid mixture experiment design is much more economical.
2. Based on the data obtained from the DOE for mixture, high correlations between the compressive strength and the component composition of concrete can be developed using the generalization capabilities of the neural networks. Such model can be efficiently used for simulating the compressive strength behavior.
3. Based on simulating compressive strength with the model built using neural networks, analyses of variance to test the effects of the variables and their interactions on concrete strength can be performed. Such information can be

employed to induce some interesting discoveries of effects and interactions of factors.

4. The strength ratio, which means the percentage of strength of concrete containing fly ash to strength of concrete without fly ash (pure cement concrete) based on the same w/b and the same age, is significantly reduced as the fly ash replacement increases, somewhat reduced as the water-binder ratio decreases, and much significantly reduced as the age decreases.
5. The higher fly ash content mixes yielded lower strength ratios throughout, the reduction being greater at early age and low water-binder ratio.
6. At high fly ash replacement, the strength ratio is somewhat reduced as the water-binder ratio decreases; however, at low fly ash replacement, the reduction of strength ratio produced by replacing cement with fly ash in concrete mixes prepared at a lower w/b was about the same as those prepared at a higher w/b.
7. The strength ratio is much significantly reduced as the age decreases, the reduction being greater at high fly ash replacement and low water-binder ratio.

Acknowledgments

This work was supported by the National Science Council, ROC, under Grant NSC-92-2211-E-216-015.

References

- Aitcin, P. C. and Neville, A. (1993) "High-performance concrete demystified." *Concrete International*, Jan. 1993, 21-26.
- Basma, A. A., Barakat, S., and Al-Oraimi, S. (1999) "Prediction of cement degree of hydration using artificial neural networks." *ACI Mater. J.*, 96(2), 167-172.
- El-Chabib, H., Nehdi, M., and Sonebi, M. (2003) "Artificial intelligence model for flowable concrete mixtures used in underwater construction and repair." *ACI Mater. J.*, 100(2), 165-173.
- Ghaboussi, J., Garrett, J. H., and Wu, X. (1991) "Knowledge-based modeling of material behavior with neural networks." *Journal of Engineering Mechanics*, 117(1), 132-153.
- Goh, A. T. C. (1995) "Neural networks for evaluating CPT calibration chamber test data." *Microcomputers in Civil Engineering*, Vol.10, 147-151.
- Haj-Ali, R. M., Kurtis, K. E., and Akshay, R. (2001) "Neural network modeling of concrete expansion during long-term sulfate exposure." *ACI Mater. J.*, 98(1), 36-43.
- Kim, J. I., Kim, D. K., Feng, M. Q., and Yazdani, F. (2004) "Application of neural networks for estimation of concrete strength." *J. Mater. Civ. Eng.*, 16(3), 257-264.

- Lippmann, R. P. (1987) "An introduction to computing with neural nets." *IEEE ASSP Magazine*, 4(2), 4-22.
- Myers, R. H., and Montgomery, D. C. (1995) *Response Surface Methodology*. John Wiley & Sons, Inc., New York.
- Nehdi, M., El Chabib, H., and El Naggar, M. H. (2001) "Predicting performance of self-compacting concrete mixtures using artificial neural networks." *ACI Mater. J.*, 98(5), 394-401.
- Nehdi, M., Djebbar, Y. and Khan, A. (2001) "Neural network model for preformed-foam cellular concrete." *ACI Mater. J.*, 98(5), 402-409.
- Oh, J.-W., Lee, I.-W., Kim, J.-T., and Lee, G.-W. (1999) "Application of neural networks for proportioning of concrete mixes." *ACI Mater. J.*, 96(1), 61-67.
- Peng, J., Li, Z. and Ma, B. (2002) "Neural network analysis of chloride diffusion in concrete." *J. Mater. Civ. Eng.*, 14(4), 327-333.
- Stegemann, J. A. and Buenfeld, N. R. (2004) "Mining of existing data for cement-solidified wastes using neural networks." *Journal of Environmental Engineering*, 130(5), 508-515.
- Swamy, R. N. and Bouikni, A. (1990) "Some engineering properties of slag concrete as influenced by mix proportioning and curing." *ACI Mater. J.*, 87(3), 210-220.
- Wee, T. H., Chin, M. S., and Mansur, M. A. (1996) "Stress-strain relationship of high-strength concrete in compression." *J. Mater. Civ. Eng.*, 18(2), 70-76.
- Yeh, I-Cheng (1998a) "Modeling concrete strength with augment-neuron networks." *J. Mater. Civ. Eng.*, 10(4), 263-268.
- Yeh, I-Cheng (1998b) "Modeling of strength of high performance concrete using artificial neural networks." *Cement and Concrete Research*, 28(12), 1797-1808.
- Yeh, I-Cheng (1999) "Design of high-performance concrete mixture using neural networks and nonlinear programming." *J. Comput. Civ. Eng.*, 13(1), 36-42.
- Yeh, I-Cheng, Chen, I-Cheng, Ko, Tai-Zi, Peng, Chao-Che, Gan, Chun-Cheng, and Chen, J. W. (2002). Optimum mixture design of high performance concrete using artificial neural networks. *Journal of Technology*, 17(4): 583-591.




Fig. 1 Simplex-centroid mixture design that involves three components




Fig. 2 The measured and predicted compressive strength of regression for training data




Fig. 3 The measured and predicted compressive strength of regression for testing data




Fig. 4 The measured and predicted compressive strength of ANN for training data

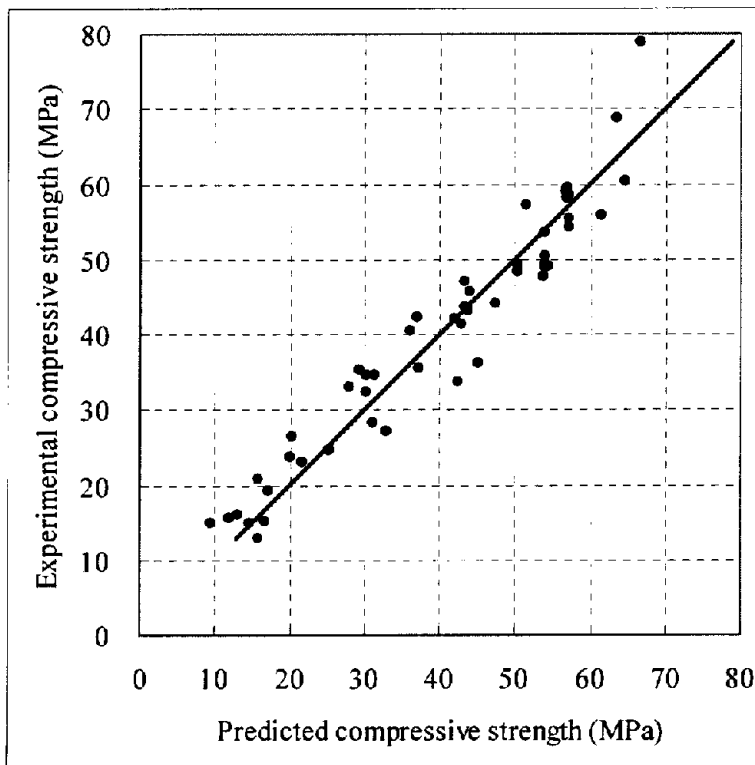


Fig. 5 The measured and predicted compressive strength of ANN for testing data




Fig. 6 The w/b-strength ratio curves at 3-day




Fig. 7 The w/b- strength ratio curves at 7-day




Fig. 8 The w/b- strength ratio curves at 14-day




Fig. 9 The w/b- strength ratio curves at 28-day




Fig. 10 The w/b- strength ratio curves at 56-day




Fig. 11 The response surface of compressive strength at 3-day




Fig. 12 The response surface of compressive strength at 7-day




Fig. 13 The response surface of compressive strength at 14-day




Fig. 14 The response surface of compressive strength at 28-day




Fig. 15 The response surface of compressive strength at 56-day

Table 1. Two-level factorial design of two controllable factors

Run No.	Cement (kg)	Water (kg)	Compressive Strength (MPa)
Run 1	360	180	34
Run 2	360	220	28
Run 3	440	180	45
Run 4	440	220	34

Table 2. Simplex-centroid design of three components

Run No.	Component 1 x_1	Component 2 x_2	Component 3 x_3
Run 1	1	0	0
Run 2	0	1	0
Run 3	0	0	1
Run 4	1/2	1/2	0
Run 5	1/2	0	1/2
Run 6	0	1/2	1/2
Run 7	1/3	1/3	1/3

Table 3. The lower and upper bound of each component

Component	Lower bound (kg/m^3)	Upper bound (kg/m^3)
Cement	150	350
Fly ash	0	200
Slag	0	260
Water	125	240
SP	3.5	12
Coarse Aggre.	850	1160
Fine Aggre.	675	980

以實驗計劃法與類神經網路建構混凝土的坍流度模型

葉怡成 陳家偉

中華大學土木系

摘要

在混凝土科技中，工作度的重要性是明顯的。在規範與標準中，用以估計工作度的經驗圖表是基於未添加強塑劑與礦物摻料(如飛灰與爐灰)等材料的混凝土。對添加這些材料的混凝土，這些關係之妥當性應該要加以研究。由於這些關係的高度複雜性，傳統的迴歸分析可能不足以建構精確的模型。類神經網路是建構非線性模型的有效工具。因此，本研究以實驗計劃法與類神經網路建構一個坍流度模型。在這個模型中，坍流度是混凝土所有成份用量的函數，包括水泥、飛灰、爐灰、水、強塑劑、粗骨材，與細骨材。本研究導出下列結論：(1) 利用雛形模式找出可疑的實驗數據，並予以重新實驗，對建構精確之模型有非常顯著的助益。(2) 類神經網路可以建構一個比二階多項式迴歸分析更精確的坍流度模型。

關鍵字：混凝土，坍流度，實驗設計，模式化，類神經網路。

MODELING WORKABILITY OF CONCRETE USING DESIGN OF EXPERIMENTS AND ARTIFICIAL NEURAL NETWORKS

I-Cheng Yeh Jia-Wei Chen

Department of Civil Engineering

Chung-Hua University

Hsin Chu, Taiwan 30067, R.O.C.

Key Words: *concrete, slump, design of experiment, modeling, artificial neural networks.*

ABSTRACT

The significance of workability in concrete technology is obvious. The current empirical diagrams and tables presented in codes and standards for estimating workability are based on tests of concrete without supplementary cementitious materials (fly ash, blast furnace slag, etc.). The validity of these relations for concrete with supplementary cementitious materials should be investigated. Because of the high complexity of these relations, conventional regression analysis is not sufficient to build an accurate model. The artificial neural network (ANN) is a powerful tool for modeling complex nonlinear models. Therefore, in this study, a slump flow model has been built using design of experiments (DOE) and ANN. In this model, the slump flow is a function of the content of all concrete ingredients, including cement, fly ash, blast furnace slag, water, superplasticizer, coarse aggregate, and fine aggregate. This study led to the following conclusions: (1) Discovering doubtful experimental data produced by using the prototype model and repeating these experiments is very significantly beneficial for building a reliable model. (2) ANN can build a more accurate slump flow model than a 2-order polynomial regression can.

一、前言

高性能混凝土[1,2]發展至今已十多年之久，卻尚未有一套精確之配比設計方法，供設計者能準確地控制其所需之性質，尤其是工作度，因強劑與礦物摻料之添加，其性質更是難以捉摸。故大部分高性能混凝土配比需在配比設計完成後，進行試拌，再予以調整。本研究目的之一，即是試圖建構工作度之經驗模型。一般建構經驗模式之主要工具為迴歸分析。然由於高性能混凝土配比一般有七種材料，加上材料用量與工作度之關係十分複雜，迴歸分析可能不足以建構準確之模型，因而本研究使用為類神經網路建構高性能混凝土工作度模型。

類神經網路常應用於預測、決策與診斷問題[3]。發展至今已具有相當之研究應用於混凝土，然其重點多著重於強度預測模型[4-9]，很少工作度預測模型之研究。先前之研究指出，以類神經網路建構工作度預測模型，優於迴歸分析所建構之模型[10]。惟所建構模型誤差仍相當大，尚有可改進之空間。故本研究之另一目的即改進實驗設計方法，導入篩選問題實驗之方法，以得更精確之實驗數據，建構更精準之預測模型。

本研究與先前研究[10]主要相異之處為本研究導入篩選問題實驗之方法，針對問題實驗進行重複實驗，其後更進行第二次篩選，以決定需進行第二次重複實驗之配比。

本研究之研究過程主要分五個階段：

- (一) 以實驗設計取得實驗數據：本研究採用之實驗設計方法為單體形心設計，輔以軸向合擴充設計[11-13]，另依規範及經驗公式訂定設計限制，共有二項詳列如下：(1) 各成份上下限限制，(2) 各成份間比例限制。經由上述之限制，可使設計出之各材料使用量較為合理、可行，同時能建構較為精準之模型。又為了排除氣溫、濕度等不可控制因子之影響，將實驗順序予以隨機化。實驗實施之過程係依照實驗設計所得之配比進行拌合實驗，試驗方法則參考 CNS 1176 混凝土坍度試驗法施行之。坍流度為混凝土坍流範圍的平均直徑。
- (二) 以初始實驗數據建構模型：待實驗全數完成後，隨之將第一次試驗結果以類神經網路建構模型雛形。模型以各材料用量為輸入變數，共有七項，分別是水泥、飛灰、爐石、水、強劑、粗骨材、細骨材及強劑之用量；輸出變數則為坍流度試驗結果。
- (三) 以初始模型診斷實驗數據：以初始模型對所有實驗配比進行坍流度預測後，篩選出誤差偏大的可疑實驗數據，並進行重複實驗，確認實驗數值，以使實驗數據更為可靠。

(四) 以修正實驗數據建構模型：用經過重複實驗確認與修正後之實驗數據以類神經網路建構模型。

(五) 比較初始模型與修正模型：比較以初始實驗數據及修正實驗數據為基礎的這二種方式對模型殘差評估的影響。

本文第二節為文獻回顧；第三節以實驗設計取得實驗數據；第四節以初始實驗數據建構模型；第五節以初始模型診斷實驗數據；第六節以修正實驗數據建構模型，並比較初始模型與修正模型；第八節為驗證實驗，以及第九節為結論與建議。

二、文獻回顧

1. 實驗設計

傳統品質管理強調品質管制，然此僅為揚湯止沸，並不能有效改善品質且較浪費成本。故現今之品質管理乃強調品質設計之觀念，亦即品質係可經由設計獲得而非篩選，品質設計係以追求品質更高、成本更低及開發更快為目標，因此品質設計係產業界競爭之重要技術。

實驗設計即為品質設計中重要之過程，由於實驗係有成本考量，故如何以最少量之實驗，獲得最大量有用之品質特性資訊，即是實驗設計問題。有系統地選擇獨立變數組合，進行實驗並記錄反應值，以收集建立系統模型所需數據之程序即為實驗設計。故實驗設計之目的係以最少之實驗次數及適當之分析技術，獲得最多有用之系統資訊[11-13]。

由於高性能混凝土之各品質因子水準間具有總和限制，體積總和必須為 1 立方公尺，故其為配比設計，因此並不適用直角座標系來表達其設計空間，一般常用單體座標系來表達之，如圖 1 所示 [11]。

配比設計問題雖然也是採用反應曲面法的設計理念，但因各品質因子之水準間有總和限制，故其實驗設計、模型建構與參數優化等三個程序之技術均與一般的品質設計問題有所不同 [11]。

配比設計常用之實驗設計方法有單體格子設計(simplex lattice design)與單體形心設計(simplex centroid design)[11]。本研究採用單體形心設計，故以下簡略介紹單體形心設計過程。

在一個 q 種成份的單體形心設計中，共有 $2^q - 1$ 個實驗點，包括

- 一元混合：(1,0,0,...,0)，(0,1,0,...,0)，...，(0,0,0,...,1)等設計。
- 二元混合：(1/2,1/2,0,0,...,0)，(1/2,0,1/2,0,...,0)等由 1/2 與 0 組成的設計。
- 三元混合：(1/3,1/3,1/3,0,0,...,0)，(1/3,1/3,0,1/3,0,...,0)等由 1/3 與 0 組成的設計。

- q元混合：(1/q, 1/q, ..., 1/q)之中心點設計。
一個三成份的單體形心設計其實驗點在單體座標系的分佈如圖 2 所示。




圖 1 單體座標系示意圖




圖 2 單體形心設計(q=3)

單體形心設計所對應的多項式函數通式如下：

$$E(y) = \sum_{i=1}^q \beta_i x_i + \sum_{i<j}^q \sum \beta_{ij} x_i x_j + \sum_{i<j<k}^q \sum \sum \beta_{ijk} x_i x_j x_k + \dots + \beta_{12\dots q} x_1 x_2 \dots x_q \quad (1)$$

例如當 q=3 時，上式簡化為

$$E(y) = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{12} x_1 x_2 + \beta_{13} x_1 x_3 + \beta_{23} x_2 x_3 + \beta_{123} x_1 x_2 x_3 \quad (2)$$

當 q=4 時，上式簡化為

$$E(y) = \sum_{i=1}^4 \beta_i x_i + \sum_{i<j}^4 \sum \beta_{ij} x_i x_j + \sum_{i<j<k}^4 \sum \sum \beta_{ijk} x_i x_j x_k + \beta_{1234} x_1 x_2 x_3 x_4 \quad (3)$$

由於上述的單體設計大多數之實驗點都是在邊界上，因此這些實驗點最多只包含了 q-1 種成份。一般都希望以增加內部點(用到全部的 q 種成份)來擴大「單體格子設計」或「單體形心設計」，以能更精確地估計完全混合配比之性質，因此應在單體設計中增加內部點的數目。一般而言，內部點的選擇可放置於形心點與頂點的中間 [11]，而這也就是軸回合擴充設計。

2. 類神經網路

類神經網路是「一種基於腦與神經系統研究所啟發的資訊處理技術」，利用大量簡單且相連的人工神經元(artificial neuron)來模仿生物神經網路之能力[3]。其可以利用一組範例(即系統輸入與輸出所組成之資料)建立系統模型(輸入與輸出間之關係)，而可用於預測、決策與診斷問題。

一個類神經網路係由多個人工神經元所組成，人工神經元又可稱為處理單元，每一個處理單元之輸出以扇狀送出，成為其他處理單元之輸入；而介於處理單元間之訊號傳遞路徑則稱為連結，每一個連結上有一個數值的加權值 W_{ij} ，表示第 i 個處理單元對第 j 個處理單元之影響強度。

類神經網路之網路架構可分為：前向式架構與回饋式架構。其中以前向網路應用最為普遍。一個前向網路包含許多層，每一層包含若干個處理單元，輸入層處理單元用以輸入外在環境之訊息，輸出層處理單元用以輸出訊息給外在環境。此外，一個層狀類神經網路經常包含若干層隱藏層，其功能係提供類神經網路表現處理單元間之交互作用，與問題內在結構之能力。

類神經網路運作的主要方式為學習(Learning)與回想(Recalling)。學習乃利用經由訓練範例調整網路之連結加權值，使得網路推論輸出值趨近於目標輸出值。回想是利用學習後之網路連結加權值與網路輸入值來推論網路輸出值。當學習策略為自問題領域中取得訓練範例，學習輸入變數與輸出變數的內在對應規則，以應用於只有輸入值而需推論輸出值的新案例時，此種學習稱為監督式學習(Supervised Learning)。監督式學習適合分類(診斷、決策)、預測(函數合成)方面之應用，監督式學習中應用最廣且最具代表性首推倒傳遞網路[3]，本研究即採用此種網路。

倒傳遞類神經網路係現今應用最普遍且最具代表性之類神經網路學習模式，已發表之相關應用

為數數千個以上。其基本觀念係運用最陡坡降法之觀念，將誤差函數最小化[3]。其網路架構如圖 3 所示。

應用類神經網路於混凝土強度預測的文獻已相當豐富，例如文獻[4-9]，這些文獻均顯示，以類神經網路建構強度模型係一可行之研究，且模型具相當之準確性。但應用在工作度預測的文獻卻相當稀少，例如文獻[10]。




圖 3 倒傳遞網路之網路架構

三、以實驗設計取得實驗數據

混凝土拌合試驗甚是勞心、勞力且耗時，倘若一組配比僅作工作度試驗，尚須 30 分鐘才可完成。故假設有 100 組配比需進行試驗，則需 3000 分鐘，也就是 50 個小時方可完成，然這也需試驗人員有充沛之體力，此則突顯了實驗設計之重要性。

本研究之實驗設計過程主要可分為三個步驟：初步設計、配比調整、配比篩選，以上三個步驟分述如下各節。

1. 配比初步設計

於實驗設計前，本研究以文獻配比为基礎，訂出各材料用量之下限限制值，作為配比設計之參考。又混凝土配比設計具有各材料體積總和為 1 立方公尺，即 1000 公升之限制，因此實驗配比的體積總和必須滿足下式：

$$V_C + V_F + V_S + V_W + V_{SP} + V_{CA} + V_{FA} = 1000 \quad (4)$$

其中 $V_C, V_F, V_S, V_W, V_{SP}, V_{CA}, V_{FA}$ 依序為水泥、飛灰、爐石粉、水、強塑劑、粗骨材、細骨材之體積。

故以後之配比設計則以體積單位進行設計，待體積設計結果出來，再轉換成重量：

$$W_i = G_i \cdot V_i \quad (5)$$

其中 V_i, W_i, G_i 分別表各材料之體積、重量與比重。

最後並將各材料之重量與體積下限值整理如表一所示，這些下限的決定是基於一千多筆在文獻上找到的配比統計的結果[6,7]。

表一 各成份之下限限制值

材料名稱	重量 (公斤)	比重 (公斤/公升)	體積 (公升)
水泥	150	3.15	47.62
飛灰	0	2.22	0
爐粉	0	2.85	0
水	125	1	125
強塑劑	3.5	1.2	2.92
粗骨材	850	2.645	321.36
細骨材	675	2.66	253.76

完成上述之前處理工作後，接著應用單體形心設計與軸回合擴充設計進行配比設計，其單體座標系之示意圖如圖 4 所示。

設計結果共得 127 個實驗點，其結果如表二所示。




圖 4 初步設計之實驗設計的單體座標系示意圖

表二 以虛擬變數作配比設計之結果

	水泥	飛灰	爐石	水	強塑劑	粗骨材	細骨材
一元混合	1	0	0	0	0	0	0
	0	1	0	0	0	0	0
	0	0	1	0	0	0	0
	0	0	0	1	0	0	0
	0	0	0	0	1	0	0
	0	0	0	0	0	1	0
	0	0	0	0	0	0	1
:	:	:	:	:	:	:	:
七元混合	1/7	1/7	1/7	1/7	1/7	1/7	1/7

表中所顯示數字係虛擬變數之值，可藉由「反尺度化」之動作獲得真值，而真值與虛擬變數之轉換公式如下式所示：

$$V_i = V_i^{\min} + (1000 - \sum V_i^{\min}) \times X_i \quad (6)$$

其中 V_i ：表各項材料之體積；

V_{\min} ：表各項材料之體積下限值；

X_i ：表各項材料之虛擬變數，值域為 $1 \geq X_i \geq 0$ ，且 $\sum X_i = 1$ 。

由公式可知，當某一材料之虛擬變數為 0 時，其體積為該材料之體積下限值；而當其虛擬變數為 1 時，則其體積為最大值。虛擬變數轉換回真值之結果如表三所示。

表三 虛擬變數轉換為體積變數之配比設計之結果

序號	各成份之體積 (公升)							體積總和
	水泥	飛灰	爐粉	水	強塑劑	粗骨材	細骨材	
1	296.96	0.00	0.00	125.00	2.92	321.36	253.76	1000
2	47.62	249.34	0.00	125.00	2.92	321.36	253.76	1000
3	47.62	0.00	249.34	125.00	2.92	321.36	253.76	1000
4	47.62	0.00	0.00	374.34	2.92	321.36	253.76	1000
5	47.62	0.00	0.00	125.00	252.26	321.36	253.76	1000
:	:	:	:	:	:	:	:	:
127	83.25	35.63	35.63	160.63	38.55	356.99	289.39	1000

然混凝土之標準配比乃是以每一立方公尺多少公斤用量來表示，故需以公式 5 做轉換，轉換之結果整理如表四所示。

表四 體積變數轉換為重量變數之配比設計之結果

序號	各成份之重量 (公斤)						
	水泥	飛灰	爐粉	水	強塑劑	粗骨材	細骨材
1	935	0	0	125	3.5	850	675
2	150	554	0	125	3.5	850	675
3	150	0	711	125	3.5	850	675
4	150	0	0	374	3.5	850	675
5	150	0	0	125	302.7	850	675
:	:	:	:	:	:	:	:
127	262	79	102	161	46	944	770

2. 配比調整設計

待配比設計完成後，隨之進行配比調整之動作。此乃因在單體形心設計中，強塑劑用量有八種：3.5、46.3、53.4、63.4、78.3、103.3、153.2、

302.8 kg/m³，除了 3.5 kg/m³ 以外均超過一般常規使用量甚多，極不合理。因此需進行配比調整步驟，使其不超過合理範圍。

調整之方法係將原設計配比之最大值 302.7kg/m³ 映射為強塑劑上限用量 15.5kg/m³，此值是基於一千多筆在文獻上找到的配比統計的結果而訂[6,7]，最小值則維持不變為 3.5kg/m³，餘以內插法求得。惟如此調整後，將使原設計配比之總體積和不足 1 m³，故需將其他材料做一放大計算，以使總體積和維持為 1 m³。計算方法如下：

(一) 計算調整強塑劑用量減少之體積，公式如下：

$$\Delta V = (W_{sp} - W'_{sp}) \div G_{sp} \quad (7)$$

其中 ΔV ：強塑劑減少之體積(公升)； W_{sp} ：原設計強塑劑重量； W'_{sp} ：調整後強塑劑重量； G_{sp} = 強塑劑之比重。

(二) 計算其他材料體積放大係數，公式如下：

$$\alpha = 1 + \frac{\Delta V}{V - V_{sp}} \quad (8)$$

其中 α ：放大係數； V ：原設計總體積(即 1000 公升)； V_{sp} ：原設計 SP 之體積(公升)。

(三) 調整其他材料之用量，公式如下：

$$W'_i = W_i \times \alpha \quad (9)$$

其中 W'_i = 第 i 成份調整後用量； W_i = 第 i 成份原設計用量。

(四) 檢合調整後體積是否符合體積總和限制，若否檢查是否計算有誤或再進行調整。其調整後單體形心座標系示意圖如圖 5 所示。




圖 5 調整後之實驗設計的單體形心座標系示意圖

調整結果整理如表五所示。

表五 配比調整後之配比設計之結果

序號	減少體積數	放大倍數	調整後各成份之用量 (公斤)						
			水泥	飛灰	爐粉	水	強塑劑	粗骨材	細骨材
1	0.0	1.00	935	0	0	125	3.5	850	675
2	0.0	1.00	150	553	0	125	3.5	850	675
3	0.0	1.00	150	0	711	125	3.5	850	675
4	0.0	1.00	150	0	0	374	3.5	850	675
5	239.31	31.32	198	0	0	165	15.5	1122	891
:	:	:	:	:	:	:	:	:	:
127	32.8	1.03	271	82	105	166	6.9	976	796

3. 配比篩選設計

由於配比調整之過程僅針對強塑劑施行，惟尚有其他不合理之配比，如水泥用量 935 kg/m³ 等，為能剔除不合理之配比，本研究以整理文獻所得之材料用量上限限制及材料比例限制進行篩選之動作。其中上限限制整理如表六所示[6,7]。

表六 材料用量之上限限制值

主要成份	用量上限(公斤)
水泥	350
飛灰	200
爐粉	260
水	240
強塑劑	12
粗骨材	1160
細骨材	980

比例限制則是對水灰比、水膠比...等 9 種比例作上下限之限制，公式如下：

$$\text{水灰比} = (W_W + W_{SP}) / W_C \quad (10)$$

$$\text{水膠比} = (W_W + W_{SP}) / (W_C + W_F + W_S) \quad (11)$$

$$\text{水固比} = (W_W + W_{SP}) / (W_C + W_F + W_S + W_{CA} + W_{FA}) \quad (12)$$

$$\text{強塑劑與膠結料之比例} = W_{SP} / (W_C + W_F + W_S) \quad (13)$$

$$\text{飛灰佔膠結料之比例} = W_F / (W_C + W_F + W_S) \quad (14)$$

$$\text{爐石粉佔膠結料之比例} = W_S / (W_C + W_F + W_S) \quad (15)$$

$$\text{飛灰與爐石粉總量佔膠結料之比例} = (W_F + W_S) / (W_C + W_F + W_S) \quad (16)$$

$$\text{粗骨材之總量對膠結料之比例} =$$

$$= (W_{CA} + W_{FA}) / (W_C + W_F + W_S) \quad (17)$$

$$\text{細骨材佔粗骨材總量之比例} = W_{FA} / (W_{CA} + W_{FA}) \quad (18)$$

比例之上下限限制值整理如表七所示，這些上下限的決定是基於一千多筆在文獻上找到的配比統計的結果[6,7]。

表七 材料用量之比例限制值

材料比例	比例下限	比例上限
水灰比	0.37	1.46
水膠比	0.25	0.70
水固比	0.07	0.12
強塑劑對膠結料之比例	0.01	0.03
飛灰對膠結料之比例	0	0.55
爐粉對膠結料之比例	0	0.61
飛灰爐粉對膠結料之比例	0	0.68
骨材對膠結料之比例	2.72	6.86
細骨材對骨材總量之比例	0.39	0.51

篩選後單體座標系示意圖如圖 6 所示，配比設計最後結果之單體座標系示意圖則如圖 7 所示。

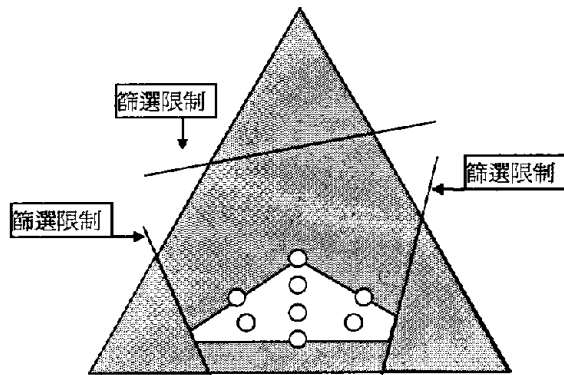


圖 6. 篩選後之實驗設計的單體座標系示意圖

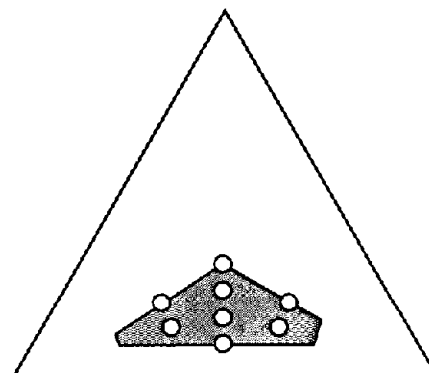


圖 7. 配比設計結果之單體座標系示意圖

配比篩選完成後，則對剩餘之實驗點進行重複與隨機化，重複乃是針對中心點（七元混合）取重複實驗，其用途為求得實驗誤差及獲得更精確之實驗數據；隨機化則是將原本之序號重新以亂數排列，其目的係減少如溫濕度等不可控制因子之影響，並確保觀測值或誤差為隨機變數 [11]。

4. 初始實驗數據之取得

本研究之工作度試驗目的在求得坍度、坍流度及坍流時間三項數據，試驗方法則參考 CNS 1176 混凝土坍度試驗法施行，其步驟簡述如下：先潤濕模具後，分三層填入搗實，每層搗實 25 下，後以 5 ± 2 秒等速提起模具 300mm，待混凝土停止流動後，記錄坍度、流度及坍流時間。其中坍度(mm)=300mm - 試體坍下後之高度，坍流度係量測試樣之平均直徑，坍流時間則係試樣停止流動之時間。

實驗過程如下：

- (一) 本研究屬七元配比設計，採用單體形心設計與軸回合擴充設計，因此在初步設計時獲得 127 個實驗點，並針對強塑劑進行配比調整，接著針對材料用量上限限制及材料比例限制進行篩選之動作。
- (二) 篩選後之實驗設計共有 57 筆，然於進行拌合實驗時。
- (三) 拌合實驗時，發現部分分配比無法膠結，故對該部分分配比進行配比調整，如增加用水量或強塑劑用量等，使其能膠結。最後結果共得 109 筆實驗數據。
- (四) 整理上述 109 筆實驗數據，經刪除拌合實驗時無法拌合之配比，包括用水量不足致使無法膠結之配比，以及嚴重泌水致使無法量測工作度等之配比，得可用之數據共 78 筆，此即為本研究用以建構工作度模型雛形之初始實驗數據。

四、以初始實驗數據建構模型

本研究於模型建構前，先將全部 78 筆初始實驗數據隨機均分為 A、B、C、D 四組。其中前三組各有 20 筆數據，最後一組有 18 筆數據。其中以 B、C、D 三組為訓練範例，A 組為測試範例所建構之模型即為模型 A；若以 A、C、D 三組為訓練範例，B 組為測試範例所建構之模型即為模型 B，餘以此類推得 C、D 模型。待完成此分組動作後，即可進行模型建構。

本研究之工作度模型係以七項材料水泥、飛灰、爐石、水、強塑劑、碎石及砂之用量為輸入變數 $x_1 \sim x_7$ ，以坍流度為輸出變數 y 而建構之。

本研究使用 CAFÉ[8]程式建構類神經網路模

型，各步驟之說明及結果分述如下：

- (一) 變數統計：此步驟係統計各變數之最小值、最大值及平均值等統計數據，以便尺度化之執行。
- (二) 尺度化：此步驟係將原本之實驗數據（實際值）映射為 -1 至 1 之值，其中 -1 代表最小值，1 代表最大值，其餘則內插。
- (三) 網路參數設定：此步驟係輸入網路訓練之參數，如輸入層、隱藏層、輸出層、訓練循環、測試週期、訓練範例數及測試範例數等。網路參數之詳細資料整理如表八所示。
- (四) 網路訓練：此步驟係根據設定之網路參數，進行類神經網路之訓練與測試。
- (五) 反尺度化：此步驟係將尺度化之預測值轉變回為實際尺度預測值，同時求得模型訓練範例與測試範例之判定係數與誤差均方根。初始模型之結果整理如表九所示。此外並將此四個模型所得之預測值集合起來，稱之為綜合模型結果，並計算其判定係數與誤差均方根，如表十所示。

由表九可知，初始模型建構結果尚非良好，誤差仍相當大。接著，將 A、B、C、D 四個模型之散佈圖整理於同一圖中，訓練範例及測試範例之結果，分別如圖 8 及圖 9 所示。由圖可知，初始模型之預測點分佈分散而不密集，顯示初始模型之準確性尚非十分良好。

表八 初始模型之網路參數

網路參數	模型 A	模型 B	模型 C	模型 D
隱藏單元數	7	6	6	8
訓練循環數	2200	2500	2000	1500
學習速率	2.0	1.0	1.0	2.0
慣性因子	0.5	0.5	0.5	0.5

表九 初始模型之建構結果

模型	訓練範例		測試範例	
	判定係數	誤差均方根(公分)	判定係數	誤差均方根(公分)
模型 A	0.5435	11.47	0.3988	19.09
模型 B	0.6546	10.20	0.2670	19.09
模型 C	0.6574	10.55	0.3641	14.59
模型 D	0.6061	11.31	0.2151	14.78

表十 初始模型之綜合結果

	測試範例	
	判定係數	誤差均方根(公分)
坍流度	0.3067	16.89




圖 8. 坍流度初始模型之訓練範例散佈圖 (單位:公分)




圖 9. 坍流度初始模型之測試範例散佈圖 (單位:公分)

五、以初始模型診斷實驗數據

1. 問題實驗篩選方法

重複實驗是尋求更精準實驗數據之方法，然若對全部實驗進行重複實驗，勢必不符合經濟效益原則，因此如何篩選出有進行重複實驗之需要的配比係一重要之課題。由文獻 [11-13]知，當某數據之標準化殘差偏離 0 特別大時，例如大於 3 或小於-3，則屬可疑的數據，可考慮檢查或刪除該數據，或者重作該筆實驗。故本研究參考上述方法，建立問題實驗之篩選方法。篩選之標準為坍流度之標準化殘差，當某筆實驗數據的標準化殘差之絕對值大於 2 時，則視為問題實驗，需進行重複實驗。詳細步驟如下：

- (一) 將各配比依上述工作度模型雛形計算得坍流度預測值。
- (二) 計算各配比之坍流度的標準化殘差。
- (三) 將坍流度標準化殘差大於 2 之配比篩選出來，進行重複實驗。

待第一階段重複實驗之配比試驗完成後，因重複實驗結果可能與原本實驗結果有所差距，倘若差距不大，表該實驗非問題實驗，人為誤差影響不大，可直接取兩者之平均值為最後實驗結果。然當差距大時，表其中之一為問題實驗，為求得較準確之實驗數據，故需挑選出以進行第二階段重複實驗，此過程即為本研究之第二階段問題實驗篩選方法。詳細步驟如下：(1) 計算重複實驗與初步實驗之坍流度差異絕對值。(2) 如果坍流度差異值小於等於 10cm，則以二次實驗之值作為實驗值；如果大於 10cm 則再進行一次重複實驗確認之。

2. 修正實驗數據之取得

本研究之實驗結果共獲得 78 筆為具有工作性之可行配比。經以類神經網路建構模型雛形獲得預測值，進而求得標準化殘差。將標準化殘差之絕對值大於 2 之 18 筆配比進行重複實驗。第一階段重複實驗完成後，進行數據比較，發現共有 7 筆配比其第一階段重複實驗與初始實驗之坍流度差值大於 10 cm，故需進行第二階段重複實驗。第二階段重複實驗完成後，因 7 筆配比之第二階段重複實驗值與第一階段重複實驗值相較之差值均小於 10 cm，故無需第三階段重複實驗，而以各實驗之較接近的二次實驗值之平均值為各實驗之採用值。

六、以修正實驗數據建構模型

修正模型之建構過程同初始模型之建構過程。其中最佳之網路參數整理如表十一所示。反尺度化後得模型建構結果，整理如表十二所示。亦整合四個模型之預測值為綜合模型，並計算其判定係數與誤差均方根，如表十三所示。由表十二可知，單就訓練範例來看，每一模型皆有相當良好之成果；若就測試範例比較，以模型 A 之成果較差。此外，將 A、B、C、D 四個模型之散佈圖整理於同一圖中，訓練範例及測試範例之結果，分別如圖 10 及圖 11 所示。由圖 10 可知，訓練範例之模型預測值與實際值相差不大；由圖 11 可知，測試範例之模型預測值與實際值相較之誤差略大於訓練範例者。

比較初始模型及修正模型之項目為兩者之綜合模型測試範例之判定係數(R2)及均方根(RMS)，整理如表十四所示。由表可知，修正模型與初始模型相較之下，不論是判定係數，還是均方根皆有大幅之改進。就判定係數來看，修正模型較初始模型多解釋了 42%($0.7240-0.3067=0.4173=42\%$)的變異。就誤差均方根來看，修正模型較初始模型減少 50% ((初始模型之誤差均方根-修正模型之誤差均方根)/ 初始模型之誤差均方根)之誤差。推斷其因

可能為，有問題之實驗點使模型被扭曲，因而導致預測值與實際值相差甚大。一旦有問題之實驗點被消除，則使模型不再被扭曲，準確性便大幅提升。由此可知，本研究提出之篩選問題實驗點之方法，對消除問題實驗點，提升模型準確性，確實有其助益。

表十一 修正模型之網路參數

網路參數	模型 A	模型 B	模型 C	模型 D
隱藏單元數	8	5	7	7
訓練循環數	2300	2000	2600	2000
學習速率	1.0	2.0	1.0	1.0
慣性因子	0.5	0.5	0.5	0.5

表十二 修正模型之建構結果

模型	訓練範例		測試範例	
	判定係數	誤差均方根(公分)	判定係數	誤差均方根(公分)
模型 A	0.8976	5.47	0.4960	9.93
模型 B	0.8266	6.53	0.8127	9.10
模型 C	0.8606	6.16	0.7751	7.51
模型 D	0.8055	6.82	0.8032	8.14

表十三 修正模型之綜合結果

	測試範例	
	判定係數	誤差均方根(公分)
坍塌度	0.7240	8.51

表十四 初始模型與修正模型之比較

模型	判定係數	誤差均方根(公分)
初始模型	0.3067	16.89
修正模型	0.7240	8.51




圖 10. 類神經網路之坍塌度修正模型之訓練範例散佈圖 (單位: 公分)




圖 11. 類神經網路之坍塌度修正模型之測試範例散佈圖 (單位: 公分)

七、類神經網路與二階迴歸分析之比較

為比較類神經網路與第二節之二階多項式迴歸分析的精確度，本研究將完全相同的實驗數據以二階多項式迴歸分析建模，其測試範例的結果如圖 12 所示，其誤差如表十五所示。由表可知，類神經網路比二階多項式迴歸分析多解釋了 40% $(0.7240-0.3230=0.401=40\%)$ 左右之變異，並減少 45% $((15.57-8.51)/15.57)$ 左右之誤差。顯見類神經網路遠比二階多項式迴歸分析精確。

表十五 類神經網路與二階多項式迴歸分析之比較

方法	判定係數	誤差均方根
類神經網路	0.7240	8.51(公分)
二階多項式迴歸分析	0.3230	15.57(公分)




圖 12. 二階多項式迴歸分析之坍塌度修正模型之測試範例散佈圖

八、驗證實驗

為確認類神經網路模型之預測能力，在建構模型後，額外進行 25 次不同配方的坍流度實驗，其結果如圖 13 所示。由圖可知實際值與預測值之間的判定係數高達 0.84，但由圖中的迴歸公式可知，坍流度的預測值比實驗值大約低 10.7 公分。原因可能是此批實驗的執行時間與原先用來建構模型的實驗的執行時間約晚了一年，因此實驗的材料、機具、人員均不相同，因此造成結果略有差異。但考量實際值與預測值之間相當高的判定係數，此一模型仍然十分具有預測能力。




圖 13. 坍流度驗證實驗之散佈圖

九、結論

本研究導出下列結論：

- (一) 利用雛形模式找出可疑的實驗數據，並予以重新實驗，對建構精確之模型有非常顯著的助益。
- (二) 類神經網路可以建構一個比二階多項式迴歸分析更精確的坍流度模型。
- (三) 由驗證實驗可知基於類神經網路的坍流度模型具有預測能力。

誌謝

本研究承國科會 NSC-92-2211-E-216-015 經費補助完成，特表感謝。

參考文獻

1. 陳振川，「高性能混凝土之定義與特性」，結構工程，第九卷，第一期，第 5-6 頁 (1994)。
2. 黃兆龍，混凝土性質與行為，詹氏書局，台北 (1999)。
3. 葉怡成，應用類神經網路，儒林圖書公司，台北 (2001)。

4. Kasperkiewicz, J., Racz, J. and Dubrawski, A., "HPC Strength Prediction Using Artificial Neural Network," Journal of Computing in Civil Engineering, ASCE, Vol.9, No.4, pp.279-284 (1995).
5. Yeh, I-Cheng, "Modeling Concrete Strength with Augment-Neuron Networks," Journal of Materials in Civil Engineering, ASCE, Vol.10, No.4, pp.263-268 (1998a).
6. Yeh, I-Cheng, "Modeling of Strength of High Performance Concrete Using Artificial Neural Networks," Cement and Concrete Research, Vol.28, No.12, pp.1797-1808 (1998b).
7. Yeh, I-Cheng, "Design of High Performance Concrete Mixture Using Neural Networks," Journal of Computing in Civil Engineering, ASCE, Vol.13, No.1, pp.36-42 (1999).
8. 葉怡成，陳怡成，柯泰至，彭鈞哲，柑俊晟，陳家偉，「以類神經網路作高性能混凝土最佳配比設計之研究」，技術學刊，第十七卷，第四期，第 583-591 頁 (2002)。
9. Yeh, I-Cheng, "A Mix Proportioning Methodology for Fly Ash and Slag Concrete Using Artificial Neural Networks," Chung Hua Journal of Science and Engineering, Vol.1, No.1, pp.77-84 (2003).
10. 柯泰至，「以類神經網路建構高性能混凝土工作度模型之研究」，碩士論文，中華大學土木工程研究所，新竹 (2001)。
11. 葉怡成，實驗計畫法-製成與產品最佳化，五南圖書公司，台北 (2001)。
12. Montgomery, D. C. *Design and Analysis of Experiments*, Jone Wiley & Sons Inc., New York, pp.12-14 (1997).
13. Myers, R. H., and Montgomery, D. C., *Response Surface Methodology*, John Wiley & Sons, Inc., New York (1995).

以二階迴歸分析建構混凝土的坍度模型

葉怡成 陳家偉

中華大學土木工程學系

TEL: (03)5374281-6730 FAX: (03)5372188 E-mail: icyeh@chu.edu.tw

關鍵詞: 二階迴歸分析, 建模, 混凝土, 坍度。

摘要

高性能混凝土是一種相當複雜的材料,使得模式化其行為變成相當困難的工作。許多研究顯示高性能混凝土的工作度不只是由用水量與最大粗骨材粒徑所決定,其它混凝土成份的用量也有影響。本文描述以二階迴歸分析建構高性能混凝土工作度模型的方法。研究結果得到下列結論:(1)當數據集不區分為樣本內與樣本外二集合時,基於二階迴歸分析的模型遠比基于一階迴歸分析者來得精確。(2)雖然在本研究中二階迴歸模型有很多殘差自由度,當數據集區分為樣本內與樣本外二集合時,以樣本內數據建構並以樣本外數據測試的模型變得遠比以不區分為二集合的數據建構並測試的模型來得不精確。因此,在使用二階迴歸分析做為模型建構工具時,應將實驗數據區分為樣本內與樣本外二集合。

MODELING WORKABILITY OF CONCRETE USING SECOND-ORDER REGRESSIONS

I-Cheng Yeh Jia-Wei Chen

Department of Civil Engineering, Chung-Hua University

Key Words: second-order regression, modeling, concrete, slump.

ABSTRACT

High-performance concrete (HPC) is a highly complex material, which makes modeling its behavior a very difficult task. Several studies have independently shown that the workability of HPC is not only determined by the water content and maximum size of coarse aggregate, but that is also influenced by the contents of other concrete ingredients. In this paper, the method for modeling workability of HPC using second-order regression is described. This study led to the following conclusions: (1) When experimental data set is not divided into in-samples set and out-of-samples set, the slump flow model based on second-order regression is much more accurate than that based on linear regression analysis. (2) Although there are many freedoms of error in the second-order regression model in this study, when data set is divided into in-samples set and out-of-samples set, the slump flow model built with in-samples and tested with out-of-samples becomes much more inaccurate than that built and tested with the data set not divided into two sets. Therefore, when second-order regression is used as a modeling tool, experimental data set should be divided into in-samples set and out-of-samples set.

一. 前言

1.1 研究目的

混凝土為最常使用的建材之一，然傳統混凝土因品質要求益增而不敷使用，故有高性能混凝土之推展。高性能混凝土具有耐久性、體積穩定性及高強度、工作度之優點，且更具品質一致性及穩定性。

然而高性能混凝土發展至今已十多年之久，卻尚未有一套精確之模型能準確地預測其各種材料行為。雖然在強度方面的研究成果較為豐富 [1-4]，但在工作度方面，因強塑劑與礦物攪料之添加，其性質更是難以捉摸，因此這方面的研究就較為稀少 [5]。故大部分高性能混凝土配比需在配比設計完成後，進行試拌，再予以調整。一般建構經驗模式之主要工具為線性之一階迴歸分析。然由於高性能混凝土配比一般有七種材料，加上材料用量與工作度之關係十分複雜，線性迴歸分析可能不足以建構準確之模型，因而本研究使用非線性之二階迴歸分析建構混凝土工作度模型。

傳統之迴歸分析均假設在變異分析中有充份的殘差自由度可以評估殘差，因而未將實驗數據區分為樣本內與樣本外二集合。然而這種做法是否適用於二階迴歸分析是一個值得探討的課題。本文旨在探討區分與不區分這二種方式對模型殘差評估的影響。

1.2 研究方法

本研究之研究過程主要分四個階段：實驗設計、實驗施行、模型建構及模型比較。以下將依序分別加以介紹。

一、實驗設計：本研究採用之實驗設計方法為單體形心設計，輔以軸回合擴充設計[6-8]，另依規範及經驗公式訂定設計限制，共有二項詳列如下：(1) 各成份上下限限制，(2) 各成份間比例限制。經由上述之限制，可使設計出之各材料使用量較為合理、可行，同時能建

構較為精準之模型。又為了排除氣溫、濕度等不可控制因子之影響，將實驗順序予以隨機化。

二、實驗實施：實驗實施之過程係依照實驗設計所得之配比進行拌合實驗，然因本研究之目的僅在建構工作度模型，故僅施行坍度試驗，試驗方法則參考 CNS 1176 混凝土坍度試驗法施行之。待實驗全數完成後，隨之將第一次試驗結果以二階迴歸分析建構模型雛形，進行預測後，篩選出誤差偏大的可疑實驗數據，並進行重複實驗，確認實驗數值，以使實驗數據更為可靠。

三、模型建構：此步驟係以最後實驗結果之數據以二階迴歸分析建構模型。模型以各材料用量為輸入變數，共有七項，分別是水泥、飛灰、爐石、水、強塑劑、粗骨材、細骨材及強塑劑之用量；輸出變數則為坍度試驗結果。建構模型時使用之實驗數據分群方式則有 (1) 不區分為樣本內與樣本外二集合，(2) 區分為樣本內與樣本外二集合。

四、模型比較：比較區分與不區分實驗數據為樣本內與樣本外這二種方式對模型殘差評估的影響。

1.3 研究內容

本研究之內容除第一章前言外，尚有五個章節。其中第二章係文獻回顧；第三章係高性能混凝土模型之實驗，內容係描述本研究之實驗設計、實驗方法及實驗結果；第四章為不分樣本內樣本外下之建模；第五章為區分樣本內樣本外下之建模；第六章為建模結果比較，以及結論與建議。

二. 文獻回顧

2.1 高性能混凝土的坍度

混凝土係台灣現今最常使用建材之一，傳統混凝土主要由四種材料，水泥、水、碎石及砂所組成，然在環保意識抬頭及更高品質要求下，傳統混凝土已不敷使用，故有高性能混凝土之發展。

高性能混凝土係於 1990 年 5 月，美國國家標準與技術研究院(NIST)及美國混凝土學會(ACI)在美國馬里蘭州之蓋茲堡城的研討會上首次提出 [9]。另中華民國結構工程學會高性能混凝土委員會則定義為，「需要具較一般混凝土品質為高之免搗實混凝土高流動性混凝土，此混凝土並可能具有高強度、高體積穩定性、高耐磨性、高水密性及其他特殊性能要求」[10]。

雖然工作度有多種指標，坍度只能表達工作度中流動性的部份概念，但由於坍度實驗簡單易行，因此一直是衡量工作度的最重要的指標 [11]。

高性能混凝土之組成材料與傳統混凝土不同，可有 4~10 種材料，然主要有 7 種，分別是水泥、飛灰、爐石、水、強塑劑、碎石及砂。其中飛灰、爐石係卜作嵐材料，飛灰及爐石之使用，除可減少水泥用量，提升高性能混凝土之經濟性外，亦能使混凝土保有骨材不析離性及材料均勻性，並可使拌合溫度降低、增加水密性及耐久性，然對混凝土之早期強度有不良之影響。強塑劑係化學摻料，其功能為減水效能高於 12% 之減水劑，而不同型號之強塑劑對混凝土有不同之影響。對因較高強度要求而水膠比較低之高性能混凝土而言，強塑劑之使用可使其具有相當之工作性，故有不容忽視之重要性。然使用強塑劑過量，對混凝土有造成緩凝、泌水析離等不良影響。

2.2 一階與二階迴歸分析

配比設計問題是指一個品質設計問題之各品質因子的水準間有總和限制者。例如傳統

的混凝土之配比成分主要為水泥、水、砂、碎石等四種，現代高性能混凝土常加強塑劑、飛灰、爐石或其他成份，以提高混凝土之品質(混凝土強度與工作度)及降低生產成本。無論四種或七種成份，其設計問題均為尋求正好組成 1 立方公尺混凝土(因為混凝土是論體積計價)之各成份的使用重量(因為原料是論重量計價)。

配比設計問題的特性是各成份 x_i 具有下列限制：

$$x_i \geq 0, \quad i=1, 2, \dots, q \quad (1)$$

$$\sum_{i=1}^q x_i = x_1 + x_2 + \dots + x_q = 1 \quad (2)$$

由於有上述公式的限制，其反應的期望值 $E(y)$ 的迴歸分析模式與傳統的迴歸分析略有差異 [6-8]：

一階迴歸分析模型：線性多項式函數

$$E(y) = \sum_{i=1}^q \beta_i x_i \quad (3)$$

二階迴歸分析模型：二次(Quadratic)多項式函數

$$E(y) = \sum_{i=1}^q \beta_i x_i + \sum_{i < j} \beta_{ij} x_i x_j \quad (4)$$

三. 實驗數據

為能獲得足以建構完整模型之實驗數據，必須依靠良好之實驗設計，才能使實驗點之分佈能夠完整表達模型。故本研究採用單體形心設計，加上軸回合擴充設計來進行實驗設計，並且考慮配比限制，以幫助淘汰不合理之配比，減少實驗數目，而達到以最少之實驗次數及適當之分析技術，獲得最多有用系統資訊之目的。

由於本研究之目的僅在建構工作度模型，故於實驗施行上僅施行坍度試驗，試驗方法則參考 CNS 1176 混凝土坍度試驗法施行之。待實驗全數完成後，隨之將第一次試驗結

果以二階迴歸分析建構模型雛形，並進行預測。再將預測值與實際值相差甚大之配比，進行重複實驗。最後所得即為本研究建構比較模型之依據。

本研究之實驗結果共獲得 109 筆配比之數據，其中有 78 筆為具有工作性之可行配比。經以二階迴歸分析建構模型雛形獲得預測值，進而求得標準化殘差。將標準化殘差之絕對值大於 2 之 18 筆配比進行重複實驗。第一階段重複實驗完成後，進行數據比較，發現共有 7 筆配比其第一階段重複實驗與初始實驗之坍度差值大於 5 cm，故需進行第二階段重複實驗。第二階段重複實驗完成後，因 7 筆配比之坍度差值均小於 5 cm，故無第三階段重複實驗。

由本研究之實驗結果可發現高性能混凝土工作度，在實驗設備、材料性質及實驗人員皆相同之情況下，實驗之誤差可獲得有效之控制。以本研究結果來說，在可行之 78 筆配比中有 18 筆配比为問題實驗點，需進行重複實驗，約佔全部實驗的 5 分之一。然就重複實驗之結果來看，高性能混凝土之工作度實驗具有一定之重現性。惟卻也發現在相同之材料、實驗設備及同一試驗人員之情況下，仍有三分之一強（7 筆）的重複實驗配比結果與原實驗配比差異甚大。推斷其因，除人為誤差、材料控管失誤外，可能尚有環境因素（如氣溫、濕度等），或強塑劑之品質穩定性不佳等因素之影響所造成。由此可知，欲獲得更精準之工作度數據，強塑劑品質之控制亦是一重要之因素。

總言之，若欲降低高性能混凝土工作度實驗數據之誤差，需注意下列三點：

1. 實驗人員工作分派宜採專人制度，
2. 拌合材料宜相同且需予以管制，
3. 使用固定之實驗設備及器具。

四. 不分樣本內樣本外下之建模

因為混凝土的性質取決於各成份的比例，而非其絕對值，例如將配比中的每種成份都放大二倍或縮小一半，其性質並不會改變。因此，必須使各成份的總和為一常數。對混凝土配比而言，材料之重量並沒有總和限制，僅材料之體積方有體積總和為 1 立方公尺，也就是 1000 公升之總和限制。故本研究於以迴歸分析建構坍度模型時，係採用材料體積為輸入變數，以滿足其限制。

接著在不區分為樣本內與樣本外二集合的方式下，以一階、二階迴歸分析作變異分析，結果如表 1 與表 2 所示。由表 1 與表 2 可知，對坍度模型而言，不論是顯著性、標準誤差或判定係數，二階模型均優於一階模型。應注意其中二階模型仍然擁有高達 50 的殘差自由度。二階模型的散佈圖如圖 1 所示。

分析上述坍度模型之殘差發現，殘差呈隨機常態分佈，無時序性及與各材料用量無相關性，符合迴歸模型之殘差變異獨立、殘差變異常數及殘差變異常態之假設。

五. 區分樣本內樣本外下之建模

本節將在區分為樣本內與樣本外二集合的方式下，以二階迴歸分析作變異分析。即將實驗數據分成樣本內與樣本外二組，以樣本內數據建構迴歸模型，再以樣本外數據進行模型測試，求得測試結果之判定係數及標準誤差，並繪製散佈圖。為了與前節(不區分為樣本內與樣本外二集合的方式)作比較，必需對所有的實驗數據均進行樣本外的評估。詳細過程敘述如下所示(參考圖 2):

1. 將實驗數據隨機均分成 A、B、C、D 四組。

2. 每次以三組為樣本內數據(訓練範例)，用以建構迴歸模型，再以此模型測試剩餘之一組數據(樣本外數據，又稱測試範例)。其中以 B、C、D 組為樣本內數據，A

組為樣本外數據所建構之模型稱為模型 A，其餘依此類推得模型 B、C、D。

模型建構結果如表 3 所示。由表可知，四個模型中以模型 D 之測試結果最佳，其中模型 A 之關係係數及判定係數最低，而模型 C 之均方差則明顯較其他模型高出甚多。

此外，將此四個模型所得之樣本外數據之預測值集合起來，稱之為綜合模型結果，並計算其判定係數與標準誤差，如表 3 所示，以及繪製散佈圖，如圖 3 所示。由表 3 可知，將實驗數據分成二群，以測試迴歸分析的真實預測能力，所得之結果遠遜於不分群之結果（表 2）。由於樣本外數據所反應的是標本外之預測能力，係真正可靠之預測能力。可見傳統之二階迴歸分析，未將資料分成樣本內數據與樣本外數據，將高估模型之預測能力，其結果應不可靠。

由圖 3 可知，模型 C 之預測值有特異點存在。在坍度預測方面，四個模型當坍度 $<10\text{cm}$ 時，不論是樣本內數據或樣本外數據，其預測值皆為高估。

六. 結論

總結本文之研究，可得以下之結論：

一. 不區分為樣本內與樣本外二集合的方式

由表 1 與表 2 的變異分析可知，二階迴歸分析遠優於一階迴歸分析。

二. 區分為樣本內與樣本外二集合的方式

比較表 3 與表 2 可知，若將實驗數據分成二群，以測試迴歸分析之真實預測能力時，所得之殘差遠高於表 2 的不分群之結果。然樣本外數據所反應的殘差才是真正可靠的殘差評估值。應注意表 2 中的二階模型擁有高達 50 的殘差自由度，但與表 3 相較可知，表 2 的殘差顯然被低估了。可見即使在有高度的殘差自由度下，傳統之二階迴歸分析未將資料

分成樣本內數據與樣本外數據，將高估模型之預測能力，其結果應不可靠。故以二階迴歸分析建構迴歸分析模型時，應將數據分為樣本內數據與樣本外數據二群為宜。

由於坍度實驗的誤差甚大，是造成判定係數偏低的原因之一，因此建議未來可採重複實驗的方式，將每種配比均重複實驗五次，取其平均值，再據以建立模型。

參考文獻

1. 彭釗哲，「以類神經網路在高性能混凝土抗壓強度之應用」，碩士論文，中華大學，新竹市(1995)。
2. Yeh, I-Cheng, "Modeling concrete strength with augment-neuron networks," *Journal of Materials in Civil Engineering*, ASCE, Vol.10, No.4, pp.263-268 (1998a).
3. Yeh, I-Cheng, "Modeling of strength of high performance concrete using artificial neural networks," *Cement and Concrete Research*, Vol.28, No.12, pp.1797-1808 (1998b).
4. Yeh, I-Cheng, "Design of high performance concrete mixture using neural networks," *Journal of Computing in Civil Engineering*, ASCE, Vol.13, No.1, pp.36-42 (1999).
5. 柯泰至，「以類神經網路建構高性能混凝土工作度模型之研究」，碩士論文，中華大學，新竹市(2001)。
6. 葉怡成，實驗計畫法-製成與產品最佳化，五南圖書公司，台北市(2001)。
7. Montgomery, D. C., *Design and Analysis of Experiments*, John Wiley & Sons Inc., New York, pp.12-14 (1997).
8. Myers, R. H., and Montgomery, D. C., *Response Surface Methodology*, John Wiley & Sons, Inc., New York (1995).
9. Kasperkiewicz, J., Racz, J., and Dubrawski, A. "HPC strength prediction using artificial neural network," *Journal of Computing in Civil Engineering*, ASCE, Vol.9, No.4, pp.279-284 (1995).
10. 陳振川，「高性能混凝土之定義與特性」，*結構工程*，第九卷，第一期，第 5-6 頁 (1994)。
11. 黃兆龍，*混凝土性質與行為*，詹氏書局，台北市(1999)。

表 1. 在不區分為樣本內與樣本外二集合的方式下迴歸分析結果：一階模型

	自由度	方差和	均方差	F 值	顯著值	標準誤差	判定係數 R ²	R ² _{adj}
模型	6	1000.03	166.67	2.906	0.0136	7.57	0.1972	0.1293
殘差	71	4071.45	57.34					

表 2. 在不區分為樣本內與樣本外二集合的方式下迴歸分析結果：二階模型

	自由度	方差和	均方差	F 值	顯著值	標準誤差	判定係數 R ²	R ² _{adj}
模型	27	3375.39	125.01	3.685	<0.0001	5.82	0.6656	0.4850
殘差	50	1696.09	33.92					

表 3. 在區分為樣本內與樣本外二集合的方式下迴歸分析結果：二階模型

模型	樣本內數據		樣本外數據	
	標準誤差	判定係數 R ²	標準誤差	判定係數 R ²
模型 A	6.08	0.7469	8.12	0.1448
模型 B	6.16	0.6663	7.13	0.2376
模型 C	4.78	0.8159	13.86	0.2831
模型 D	6.59	0.6164	5.25	0.4466
綜合模型			9.29	0.2023




圖 1. 不區分樣本內與樣本外下之散佈圖 (單位: 公分)

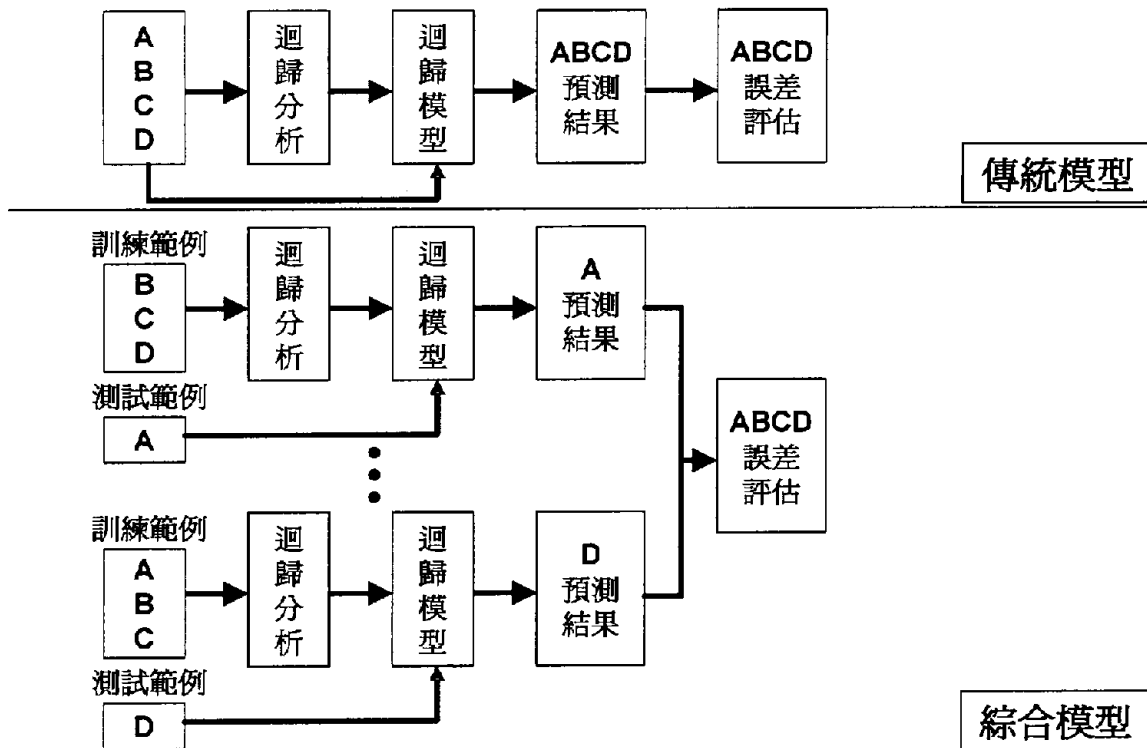


圖 2. 不區分與區分樣本內與樣本外二集合的方式




圖 3. 區分樣本內與樣本外下之散佈圖 (單位: 公分)

計畫成果自評

高性能混凝土配比設計可視為一個多目標最佳化問題，它必須同時滿足強度、工作度以及經濟性的要求。本研究提出一個新的高性能混凝土配比設計方法論，其兩大理論支柱是類神經網路 (artificial neural networks) 及遺傳演算法 (genetic algorithms)。類神經網路不需假設模型之型態，具有建立精確的多元非線性模型之能力。遺傳演算法是一個以類似於生物演化機制方式進行學習的適應性系統。這個方法論基本上包含二個階段：

- (1) 模式化(Modeling)：利用實驗資料以遺傳演算法與類神經網路建構材料行為模型，包括工作度模型以及強度模型。
- (2) 最佳化(Optimizing)：利用材料行為模型以最佳化技術優化配比設計。此配比設計滿足使用者的需求，包括工作度需求以及強度需求，並使材料成本最小化。

本研究已完成上述二個目標，並已發表五篇研究論文：

1. Yeh, I-Cheng (2005), "Exploring concrete slump model using artificial neural networks," *J. of Computing in Civil Engineering*, ASCE (accepted). (EI, SCI)
2. Yeh, I-Cheng (2005), "Analysis of strength of concrete using design of experiments and neural networks," *Journal of Materials in Civil Engineering*, ASCE (accepted). (SCI, EI)
3. 葉怡成、陳家偉(2005)，「以實驗計劃法與類神經網路建構混凝土的坍流度模型」，技術學刊(已接受)。
4. 葉怡成、陳家偉(2005)，「以二階迴歸分析建構混凝土的坍度模型」，中華理工學刊(已接受)。
5. 葉怡成、連立川、張皓博、謝明勳(2005)，「以遺傳演算法及運算樹作高性能混凝土工作度建模」，2005 營建技術暨管理研討會，斗六市。

以及十篇投稿論文

1. Yeh, I-Cheng (2005), "Modeling workability of concrete using second-order regressions and artificial neural networks," *Cement and Concrete Research* (submitted). (SCI, EI)
2. 葉怡成、彭釗哲、連立川(2005)，「類神經網路與經驗公式在高性能混凝土抗壓強度預測之比較」，技術學刊。
3. Yeh, I-Cheng (2005), "Generalization of strength versus water-cementitious ratio relationship to age," *ACI Materials Journal* (submitted).(SCI, EI)
4. Yeh, I-Cheng (2005), "Computer-aided design for optimum concrete mixture," *Canadian Journal of Civil Engineering*. (SCI, EI)
5. Yeh, I-Cheng (2005), "Optimization of concrete mix proportioning using flatted simplex-centroid mixture design and neural network," *ACI Materials Journal* (submitted). (SCI, EI)

6. Yeh, I-Cheng (2005), "Prediction of workability of concrete using design of experiments for mixtures," *工業工程學刊*. (EI)
7. Yeh, I-Cheng, "Modeling Interactions of fly ash and superplasticizer on workability of concrete," *Magazine of Concrete Research* (submitted).(SCI, EI) (2005)
8. Yeh, I-Cheng (2005), "Computational simulation of concrete slump using artificial neural networks," *Cement and Concrete Research*.(SCI, EI)
9. Yeh, I-Cheng (2005), "Neural networks for evaluating workability of high-performance concrete," *Cement & Concrete Composites* (submitted).(SCI,EI)
10. 連立川、葉怡成、鄭明淵(2005),「以遺傳演算法及運算樹作高性能混凝土強度建模」, 技術學刊, 審稿中。

以及三篇學位論文

1. 黃冠傑(2004), 類神經網路視窗軟體之設計, 碩士論文, 中華大學土木工程學系。
2. 劉原旭(2005), 高性能混凝土配比設計最佳化之研究, 碩士論文, 中華大學土木工程學系。
3. 連立川(2005), 遺傳演算法在強化式學習之應用, 碩士論文, 中華大學土木工程學系。

研究結果顯示

- 免疫演算法與遺傳演算法極為相似, 最大的不同點在於前者傾向演化出多樣化的解答。但此一特性可藉由修改遺傳演算法中的適應度函數得到相同的效果, 因此本研究中所謂的「遺傳演算法」已具備與「免疫演算法」相同的性能。
- 若使用者要求的是可理解的 HPC 材料行為模型, 遺傳演算法結合運算樹(genetic algorithm of operation tree)是一個準確且能夠產生自組織公式的 HPC 強度及坍度模型建構方法; 若使用者對於可理解的 HPC 材料行為模型要求度不高, 僅在乎最後的結果是否準確, 則倒傳遞網路(back-propagation networks)是一個更準確且快速的 HPC 強度及坍度模型建構方法。

在應用價值上, 這些技術可用來預測不同成份配比組成下材料的行為。因此可利用之產業及可開發之產品包括:

- 混凝土拌合廠: 開發最經濟混凝土配比
- 其它需要配方設計的產業: 開發最經濟產品配比

(本研究計畫的專屬推廣網頁: www.chu.edu.tw/~icyeh/hpc)

可供推廣之研發成果資料表

 可申請專利

 可技術移轉

日期：94年10月10日

國科會補助計畫	計畫名稱：免疫演算法於高性能混凝土配比設計多目標最佳化之研究 計畫主持人：葉怡成 計畫編號：NSC-93-2211-E-216-001 學門領域：土木材料
技術/創作名稱	混凝土材料行為建模技術
發明人/創作人	葉怡成
技術說明	中文： 本研究以遺傳演算法(Genetic Algorithms)結合運算樹(Operation Tree)，發展出一套能產生高性能混凝土強度(high-performance concrete, HPC)自組織公式的技術。從預測的準確度可知，遺傳演算法結合運算樹的方法確實是一個可以產生自組織公式的方法，且模型的準確度僅低於倒傳遞網路。 英文： This study used genetic algorithms combined with operation tree (GAOT) to produce self-organized formula for the strength of high-performance concrete (HPC). The results showed that GAOT certainly could produce rather accurate self-organized formula, and it is more accurate than other methods only except for back-propagation networks.
可利用之產業及可開發之產品	<ul style="list-style-type: none"> ● 混凝土拌合廠：開發最經濟混凝土配比 ● 其它需要配方設計的產業：開發最經濟產品配比
技術特點	本技術與其它技術不同處分述如下： <ul style="list-style-type: none"> ● 產生自組織性公式：本技術提出與傳統迴歸分析同樣能產生公式的方法，但準確性又比傳統迴歸分析較為優異。 ● 材料之敏感度分析：由於高性能混凝土的使用參數甚多，各個參數對於其強度及工作度結果的影響程度甚少人去探討，因此本技術提出材料敏感度分析方法。
推廣及運用的價值	為產生較傳統迴歸分析解釋能力優異的模型，本研究結合運算樹及遺傳演算法的方法，企圖發展不失其準確性但又能產生自組織公式的模型。為提高準確性，再以遺傳演算法結合類神經網路的方法論，產生一具備準確性的高性能混凝土強度及工作度的方法。這些技術可用來預測不同成份配比組成下材料的行為。 本研究計畫的專屬推廣網頁(www.chu.edu.tw/~icyeh/hpc)