

# 淡江大學土木工程系碩士班

當代迴歸技術與類神經網路在剛性鋪面回算之應用

Application of Modern Regression Techniques and Neural Network on Rigid Pavement Backcalculation

指導教授：李英豪

研究生：劉耀斌

## 緒論

研究背景

- 鋪面管理系統的重要性
  - 鋪面評估系統
  - 鋪面結構強度之評估
    - 破壞性檢測
    - 非破壞性檢測
- 鋪面回算的重要性
  - 傳統鋪面回算方法
  - 新的演算技術
    - 類神經網路演算法
  - 當代迴歸技術
    - 投影追逐迴歸法
    - 小區域迴歸法

## 緒論

研究目的


- 解決類神經網路演算法使用之問題
  - 純量方式進行預測模式構建
  - 耗費大量時間在網路之訓練上
  - 需要極大的資料庫
  - 僅適用於個案
- 利用新的當代迴歸技術解決回算之問題
  - 以鋪面力學為出發點、傳統統計為基礎
  - 配合因次分析之方法
  - 採用最新的統計迴歸方法「小區域迴歸」

## 緒論

研究範圍與方法

- 本研究首先對於現有之鋪面回算問題進行探討，將以往所建構之回算分析方法之使用與限制做一介紹。
- 研究中將以Visual Basic構建一自動化分析程式，並以此分析程式構建資料庫，以供後續分析與模式構建所使用。
- 研究中將先採用類神經網路以傳統之網路建構方法構建一預測模式，接著利用本研究以力學為出發點並配合統計之概念所建議之方法建立另一預測模式，將二者進行比較，以得知最適用於類神經網路建構模式之方法為何，並提出建議以改善以往類神經網路之缺點與問題。
- 研究中亦將利用新的當代迴歸技術配合本研究所建議之方法建立進行二維中央荷重無限版與有限版之預測模式構建，並且建立三維中央荷重有限版之最大撓度值預測模式，最後進行類神經網路以及小區域迴歸構建之預測模式之初步比較。
- 針對實驗驗證類神經網路預估模式與當代迴歸技術所建立之預測模式，並比較兩者之預估結果，預測模式之精度、時間效益以及未來的擴充性進行比較，以定義出最適合剛性鋪面回算預測模式構建之演算法。
- 針對『TKUBAK』之錯誤加以修正，並加以擴充。

## 研究流程



## 論文組織與架構

- 第一章：說明研究緣起、目的、範圍內容及研究流程。
- 第二章：介紹國內外預測模式以及鋪面回算面臨之問題。
- 第三章：介紹類神經網路原理，並且探討因次分析以及純量之方法於類神經網路之適用性為何。
- 第四章：介紹小區域迴歸之原理，並利用類神經網路以及路以及小區域迴歸建立其預測模式並進行比較。
- 第五章：針對實例驗證類神經網路預測模式與當代迴歸技術所建立之預測模式，並比較兩者之預估結果；針對TKUBAK程式之錯誤加以修正與功能擴充。
- 第六章：研究成果與往後研究之建議。

## 非破壞性撓度試驗簡介

- 靜力撓度試驗 (Static Deflection)
- 穩定動力撓度試驗 (Steady State Dynamic Deflection)
- 衝擊荷重撓度試驗 (Impact Load Response)
- 波傳遞試驗 (Wave Propagation)

## 鋪面回算程式之方法 傳統回算法(1)

- 迭代法  
先假設一組起始彈性模數進行正算，將其正算出之撓度值與現地之實際量測撓度值相比較。再利用重覆修正起始彈性模數之方法，反覆計算出撓度值，直至計算出之撓度值與現地之撓度值誤差在一定範圍內即可停止迭代過程。例如：BISDEF、BISAR、WESDEF、ELSDEF、CHEVDEF等程式皆採用此一方法。

## 鋪面回算程式之方法 傳統回算法(2)

- 資料庫處理法

主要是以路基反力模數搭配混凝土鋪面版之回彈模數所計算出之撓度值建立一大型資料庫，再利用比對法將量測撓度與資料庫內之撓度值做一比較，搜尋出一組可互相配之路基反力模數與混凝土版之回彈模數。例如：MODULUS、COMDEF


## 鋪面回算程式之方法 傳統回算法(3-1)

- 閉合解法


閉合解法係以實際量測之撓度值，計算 AREA 指標，再利用迴歸之方法找出 AREA 指標與相對徑度半徑之關係，加上混凝土鋪面本身之彈性模數與路基反力模數等相關參數，代入計算即可直接回算出路基反力模數與搭配混凝土鋪面版之彈性模數。例如：ILLI-BACK 即為利用此一方法所建構之回算程式。

## 鋪面回算程式之方法 傳統回算法(3-2)

- 撓度盤面積指標 AREA



$$AREA = \frac{A}{w_0} = \left( \frac{6}{w_0} \right) (w_0 + 2w_{12} + 2w_{24} + w_{36})$$



AREA 指標與相對徑度半徑關係圖

## 傳統回算法之限制

- 限定使用儀器
- 固定荷重半徑
- 撓度盤之感應器必須由四個組成，且間距為12in
- AREA指標之計算單位為因次單位 (in.)
- 不同的4個撓度值可能會計算出同樣的AREA指標而產生相同的相對徑度半徑。

## 鋪面回算程式之方法 撓度比回算法

此一回算方法先行利用ILLI-SLAB有限元素法程式與因次分析之原理來克服傳統限制，並以撓度比無因次因子的觀念作為回算方式的控制參數，再配合使用投影追逐迴歸法 (PPR) 建立一系列的撓度比預估模式。此一回算法最大的優點為只需載重盤作用處之最大撓度及其它任何徑向一點的表面撓度值，配合所建立之撓度比預估模式，即可回算出路基反力模數與鋪面版之彈性模數。該回算法克服了下列問題：

- 1、作用之載重盤半徑須固定為5.9 in.
- 2、撓度盤之撓度感應器必須由四個組成，且間距為12in.
- 3、撓度量測儀器限定為落重撓度儀 (FWD)
- 4、AREA計算單位為in.

## 鋪面回算程式之方法 撓度比回算法(2)

$$R = 0.52074 + 0.36641 \phi_1 + 0.01398 \phi_2$$
$$\phi_1 = \begin{cases} 2.270 + 2.343 A_1 + 0.537 A_1^2 + 0.049 A_1^3 & A_1 \leq -2 \\ 1.342 + 0.508 A_1 - 0.717 A_1^2 - 0.239 A_1^3 & A_1 > -2 \end{cases}$$
$$\phi_2 = \begin{cases} -0.406 + 4.261 A_2 + 5.436 A_2^2 + 13.407 A_2^3 & A_2 \leq 0.1 \\ -0.658 + 7.027 A_2 + 3.488 A_2^2 + 6.312 A_2^3 & A_2 > 0.1 \end{cases}$$
$$A_1 = 0.36634 x_1 - 0.93048 x_2$$
$$A_2 = -0.99384 x_1 + 0.11082 x_2$$
$$X = [x_1, x_2] = [a/l, r/l]$$

Statistics : N = 117, R<sup>2</sup> = 0.9998, SEE = 0.00455  
Limits : 0.05 ≤ a/l ≤ 0.30, 0.0 ≤ r/l ≤ 4.0

## 類神經網路應用於鋪面分析之回顧與探討(1)

國內將類神經網路應用鋪面回算大多以柔性鋪面之回算為主。一般回算模式建構流程，通常先以ABAQUS有限元素法程式根據不同鋪面材料性質，並模擬國內較常使用之落重撓度儀 (FWD 8000) 所施加荷重之方式進行正算，再將正算所得距荷重中心各點 (0、20、30、45、65、90與120 cm) 撓度值建立一撓度與鋪面狀況之相關資料庫，爾後再以類神經網路根據資料庫進行回算模式之構建。

## 類神經網路應用於鋪面分析之回顧與探討(2)

- FEM-ANN
  - 採用擬動態荷重
  - 材料模擬採彈性材料
  - 鋪面厚度變數固定
  - 純量資料庫分析
- ABAQUS-ANN
  - 採用擬動態荷重
  - 材料模擬採線彈性材料
  - 鋪面厚度變數固定
  - 採用單層隱藏層結構、內含50個處理單元數
  - 純量資料庫分析
- DIPLBACK
  - 主要是用以複合鋪面之回算 (AC加鋪於PCC)
  - 首先利用到無因次參數，大多亦採純量
  - 使用25000筆撓度資料做為訓練與測試
  - 利用三個類神經網路預測模式，來進行鋪面回算

## 類神經網路應用於鋪面分析之回顧與探討(3)

- Meier et. al
  - 主要用於三層之柔性鋪面回算
  - 利用純量方式進行網路訓練
  - 9750筆訓練範例、250筆測試範例
  - 花費8小時進行網路訓練
- Haussmann et. al
  - 主要應用於剛性鋪面
  - 預測距離荷重中心垂直與水平方向應力
  - 共執行1140個ILLI-SLAB案例
  - 固定版長、版寬、版厚、混凝土版之彈性模數與路基反力模數
- DEF-SN
  - 主要應用於四層之柔性鋪面
  - 預測撓度與鋪面結構數 (Structural Number, SN)
  - 採用純量之方式進行預測模式構建
  - 厚度之選擇僅有4種不同之組合
  - 可依照氣候分為夏季、非夏季進行預測

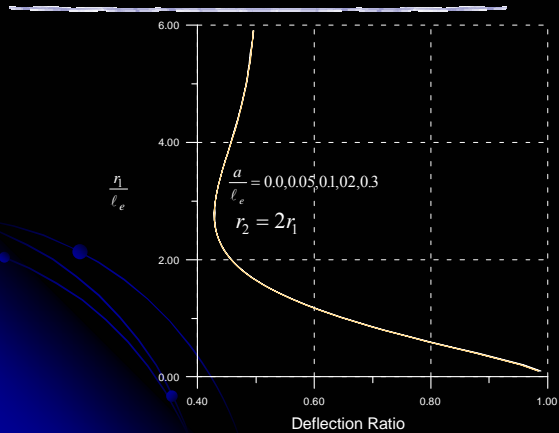
## 當代迴歸技術應用於鋪面分析之回顧與探討(1)

統計迴歸方法在鋪面分析之應用上已行之有年，由於鋪面回算所需考慮之因子眾多，且其完成迴歸分析後之預測模式亦需要有極高之精度，因此以往舊有的迴歸技術已不敷使用，而近年來發展出許多新的統計迴歸方法稱之為當代迴歸技術，例如：投影追逐迴歸法 (PPR)、小區域迴歸法 (Locally-Weight Regression, LOESS) 等，使得以往傳統統計迴歸方法不足的精度更加提高。

## 當代迴歸技術應用於鋪面分析之回顧與探討(2)

- 雙層柔性鋪面回算預測模式之應用
  - 配合因次分析之方法
  - 採用投影追逐迴歸法
  - 預測精度不佳
- TKUBAK程式
  - 單輪荷重、單版雙層混凝土鋪面
  - 採用投影追逐迴歸法
  - 適用於溫氏基礎、彈性固體基礎
  - 配合因次分析
  - 預測精度極高
  - 考慮到荷重傳遞效應
  - 可利用荷重中心與任一徑向之量測撓度進行回算

### 當代迴歸技術應用於鋪面分析之回顧與探討(3)



### 當代迴歸技術應用於鋪面分析之回顧與探討(4)

- 許瑞升 (1999)
  - 應用於雙層混凝土鋪面
  - 採用修正因子之概念
  - 配合因次分析之概念
  - 利用小區域迴歸法
  - 考量多版荷重效應
  - 考量荷重傳遞效應
  - 考量線性溫差效應

### 預測模式建構方法之探討


- 類神經網路預測模式
  - 採用純量分析
  - 建構預測模式需要龐大的資料庫
  - 需要良久的模式建構時間
  - 需耗費龐大的電腦資源
  - 僅適用於個案
  - 類神經網路參數之採用無參考之依據
- 當代迴歸方法預測模式
  - 採用因次分析概念
  - 以傳統統計學為出發點
  - 預測結果良好
  - 配合因次分析概念使其應用範圍相當廣泛

### 相關軟體之採用

- ILLI-SLAB有限元法程式之採用
  - 可分析單版、多版
  - 可分析多層混凝土版結構
  - 有多種基礎模式可選擇
  - 錯誤最少之刚性鋪面有限元程式
- 類神經網路程式之採用
  - QNET2000試用版
  - 最多可有8層隱藏層之結構
  - 擁有多種轉換函數可供選擇
  - 視窗化軟體
  - 前處理與後處理視覺化
- 當代迴歸技術程式之採用
  - S-PLUS軟體
  - LOCFIT程式



QNET2000 試用版



S-PLUS 6.1

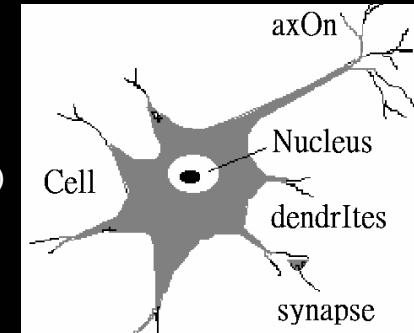
## 類神經網路發展與原理

- 發展歷史
  - 自第二次世界大戰末期至今
- 類神經網路
  - 又稱人工神經網路(Artificial Neural Network)
  - 模仿生物神經網路之資訊處理系統
  - 一種基於腦與神經系統研究，所啟發的資訊處理技術
  - 根據其適用範圍與發展背景共有11種模式
  - 經由反覆訓練達到所需之精度
- 結合生理、心理與電腦等科技

## 類神經網路原理

發展與原理(2)

- 神經核(Nucleus)
- 神經軸(axon)
- 神經樹(dendrites)
- 神經鍵(synapse)



## 類神經網路與傳統迴歸分析之比較

- 類神經網路之優點
  - 模型精確度高。
  - 良好之推廣性
  - 可接受邏輯、數列、有序分類、無序分類等不同的變數作為輸入
  - 應用廣泛。
- 類神經網路之缺點
  - 網路優化的工作相當費時
  - 耗費電腦資源
  - 需要反覆試誤才得到最佳的神經元個數
  - 容易發生過度學習 (over learning) 現象

## 倒傳遞網路


倒傳遞網路原理(1)

- 目前應用最多之類神經網路模式之一
- 採用最陡坡降法 (the steepest descent of gradient method) 之觀念
- 將資料分為兩部份：
  - 訓練範例
  - 測試範例
- 以一次一個訓練範例的方式進行稱之為逐例學習，直到學習完所有訓練範例
- 反覆學習，直到達收斂為止
- 每學習數個學習循環，即可將測試範例載入，測試網路之精度。


# 倒傳遞網路

倒傳遞網路原理(2)

輸入層 隱藏層 輸出層



倒傳遞網路示意圖



傳統倒傳遞網路訓練流程圖

# 倒傳遞網路

倒傳遞網路原理(3)

- 誤差計算法則
  - 函數問題採用「誤差均方根(Root Mean Square ,RMS)」
  - 分類型問題採用「誤判率(Error Ratio)」

$$RMS = \sqrt{\frac{\sum_{p=1}^M \sum_{j=1}^N (T_{jp} - Y_{jp})^2}{M \times N}}$$

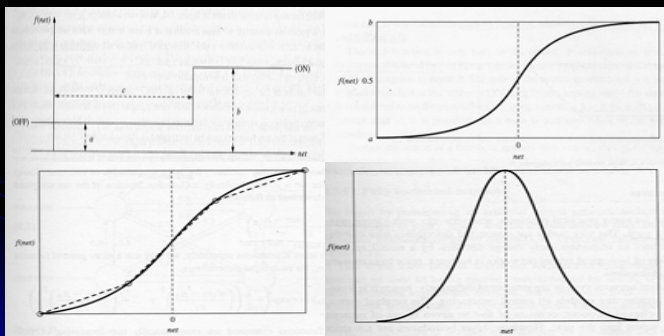
$$\text{誤判率} = \frac{\text{範例總數} - \text{正判範例數}}{\text{範例總數}}$$

# 轉換函數

轉換函數示意圖

階梯函數

雙彎曲函數、正切雙彎曲函數



線性函數

輻射型函數

# 倒傳遞網路注意事項

- 隱藏層數目
- 隱藏層處理單元數
- 學習速率(Learning Ratio)
- 範例選擇之同質性



## 因次分析方法原理

當理論分析工具無法產生封閉型解，或是在研究涉及許多數值和經驗性的一些工程問題上時，因次分析 (Dimensional Analysis) 原理的應用顯然有其必要性。因次分析方法是使用壓縮的方式將影響反應的參數數目與複雜性降低的方法White (1986) 因此，利用因次分析可減少相關參數的數目，可節省相當多的時間與成本。此法最大的優點在於其可找出真正重要的控制參數，並將其複雜的問題簡化。但是，從事該研究之人員必需謹防在將問題簡化之過程中不慎忽略了其它的重要參數，而導致實用性大減或以偏概全的情形。

## 資料庫之構建

控制參數

根據以往運用因次分析原理的研究，控制鋪面結構反應的主要參數為撓度載重盤荷重半徑與相對徑度半徑的比值( $a/l$ )、鋪面版之有限長度與相對徑度半徑的比值( $L/l$ )以及鋪面版之有限寬度與相對徑度半徑的比值( $W/l$ )，而由於本研究所探討的是鋪面撓度值的變化，在資料的取得方面是依距離載重圓盤中心點的遠近 $r$ 為依據，因此對於無因次化參數( $r/l$ )亦須加入，其公式如下所示。在以往研究中已針對無因次參數的使用正確與否進行驗證，證實其確實可使用在鋪面之分析，因此在本研究之資料庫構建上，將採用上述之無因次參數做為主要之參考依據。

$$\frac{\delta k l^2}{P} = f\left(\frac{a}{l}, \frac{r}{l}, \frac{L}{l}, \frac{W}{l}\right)$$

## 資料庫之構建

網格切割方法


就其荷重形式而言，本研究主要是討論中央荷重時之情況，其所使用之載重為9000磅、混凝土版彈性模數之範圍為2-7 Mpsi以及路基反力模數之範圍為150至650 pci。研究中根據上述之條件利用Visual Basic程式撰寫一建立ILLI-SLAB程式輔助輸入檔之建立程式，在大量的輸入檔中建立批次檔，以避免繁複的執行步驟及人為誤差的發生，在分析完成後，再利用Visual Basic程式撰寫一抓取撓度值之程式，將所需之撓度資料存成一文字格式檔，再利用Access資料庫軟體與EXCEL試算表應用程式，進行關聯性資料庫之聯結與分析並找出所需之資料。其所使用之切割方式如下：

中央荷重網格切割：2.5"x2.5"x2,10"x3，往後根據節點數平均分割荷重面積：10x10 in.

## 資料庫之構建

因次分析資料庫

- 中央荷重無限版長撓度比資料庫
  - 根據Ioannides之無限版長建議
  - $a/l$ ：0.05-0.4(step 0.01)
  - $W/l=L/l$ ：8
  - 共494筆資料
- 中央有限版長撓度比資料庫
  - $a/l$ ：0.05-0.4
  - $L/l$ ：2、3、4、5、6、7
  - $W/l$ ：2、3、4、5、6、7
  - 共2227筆資料



## 資料庫之構建

純量資料庫

- 中央荷重無限版長純量資料庫構建
  - 混凝土彈性模數：2-7 Mpsi
  - 路基反力模數：50-650 pci
  - 混凝土版厚：3-30 in.
  - 混凝土版長、版寬：8xℓin.
  - 共12329筆資料

## 小區域迴歸


緣起與簡介(1)

1931年Macaulay為了描述自變數與應變數之數學關係，並且利用該數學關係預測出更精準之應變數值，首先採用了多項式區域迴歸之方式，隨後Waston（1964）、Stone（1977）以及Cleveland（1979）陸續將小區域迴歸之技術應用在更多一般的案例。1979年Cleveland提出了小區域迴歸的明確方法；1986年Devlin擴充了小區域迴歸的方法並且為其定義了數學上的特性。

## 小區域迴歸

緣起與簡介(2)

簡單的逐級小區域迴歸之建構方法先將資料庫之變數依據權重函數區分為許多小區域，每個小區域為一獨立個體，爾後再針對每一個小區域做小區域平均（Local Smoothing）或是一次線性迴歸或是二次線性迴歸等方式迴歸，因此每一個小區域均有其迴歸曲面（線）（圖），並將每一個小區域結合而成一個模式，此模式即為此變數的迴歸值，故小區域迴歸法並不會建立一個公式，而是建立一個類似資料庫的檔案。



## 小區域迴歸

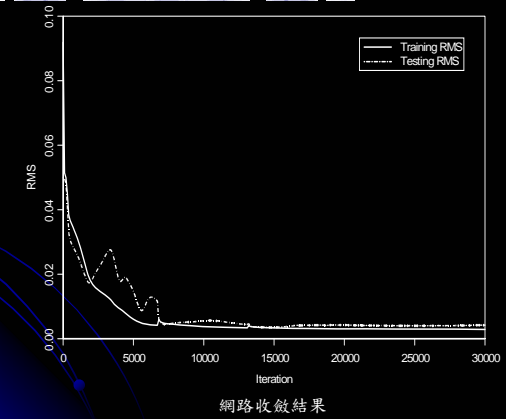
緣起與簡介(3)

- 小區域迴歸之限制
  - 雖然在少量資料下亦能進行迴歸，然而卻無法完整的逼進資料曲面。
  - 若使用者在利用已完成之預測模式進行預測時，若輸入之變數超出建構之範圍，將造成無法預測之狀況，因此一個大範圍的資料庫是非常重要的。
  - 在線性(deg=1)之迴歸狀況下，最多可採用15個變數，在非線性(deg=2)之迴歸狀況下，僅可採用4個變數。


## 類神經網路預測模式構建 純量資料庫(1)

類神經網路使用參數表		
網路型態	倒傳遞神經網路	
使用訓練函數	Sigmoid Function	
隱藏層數	2	
隱藏層處理單元數	第一層：12 第二層：12	
輸入參數	E、K、h、r	
輸出參數	徑向距離之撓度	
使用範例	訓練範例	11329
	測試範例	1000
學習週期	30000	
學習速率	0.5	
收斂結果	訓練範例	0.00290
	測試範例	0.00420
花費時間	6小時43分鐘	
判定係數	0.999	

## 類神經網路預測模式構建 純量資料庫(2)



## 類神經網路預測模式構建 純量資料庫(3)




## 無限版長撓度比預測模式之構建 類神經網路(1)

- 學習速率
  - 研究中採0.1
- 轉換函數之採用
  - 雙彎曲函數、正切雙彎曲函數以及輻射函數進行比較
- 隱藏層層數
  - 問題之複雜度不高，因此採用單層即可
- 隱藏層處理單元數
  - 不同的處理單元數進行測試，找出最佳之處理單元數
- 資料庫之採用
  - 輸入參數： $a/l$ 、 $r/l$ ，輸出參數：撓度比( $w/w_0$ )
  - 訓練範例：394，測試範例：100


## 無限版長撓度比預測模式之構建 類神經網路(2)

函數名稱	雙彎曲函數	正切雙彎曲函數	輻射函數
訓練範例	0.00416	0.00405	無法收斂
測試範例	0.00384	0.00411	無法收斂
判定係數	0.9999	0.9999	無法收斂
時間	35''	60''	無法收斂



## 無限版長撓度比預測模式之構建 類神經網路(3)


處理單元數	5	6	7	8	9	10
訓練之RMS	0.00416	0.00377	0.00524	0.00569	0.00554	0.00520
測試之RMS	0.00384	0.00360	0.00492	0.00529	0.00520	0.00490
判定係數	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
花費時間	35''	42''	52''	60''	67''	82''



## 無限版長撓度比預測模式之構建 類神經網路(4)

類神經網路使用參數表		
網路型態	倒傳遞神經網路	
使用訓練函數	Sigmoid Function	
隱藏層數	1	
隱藏層處理單元數	6	
輸入參數	a/l, r/l	
輸出參數	撓度比(w/w <sub>0</sub> )	
使用範例	訓練範例	394
	測試範例	100
學習週期	10000	
學習速率	0.1	
收斂結果	訓練範例	0.00377
	測試範例	0.00360
判定係數	0.9999	

## 中央無限版撓度比預測模式測試結果



## 純量與因次分析方法之比較

- 純量資料庫於類神經網路之應用
  - 資料量大
  - 訓練時間久
  - 輸入參數多
  - 耗費龐大的電腦資源
  - 僅適用於個案
- 因次分析資料庫於類神經網路之應用
  - 資料量小
  - 訓練時間少
  - 輸入參數少
  - 適用範圍廣

## 無限版長撓度比預測模式之構建 小區域迴歸(1)

- 模式應用
  - Deg=2(非線性)
  - Cell=0.1
  - Span=0.1
- 資料庫應用
  - 輸入參數： $a/l$ 、 $r/l$
  - 輸出參數：撓度比( $w/w_0$ )
  - 資料數量：494

## 無限版長撓度比預測模式之構建 小區域迴歸(2)

\*\*\* Local Regression Model \*\*\*

Call:

loess(formula = def ~ aol + rol, span = 0.1, cell = 0.1)

Number of Observations: 494

Equivalent Number of Parameters: 61.7

Residual Standard Error: 0.001281

Multiple R-squared: 1


Residuals:

	min	1st Q	median	3rd Q	max
	-0.007247	-0.0004731	-0.000109	0.0002131	0.005799

統計量:

樣本數: 494; 等值參數: 61.7; 殘餘標準誤: 0.001281; 判定係數: 1  
使用限制:  $0.05 < a/l < 0.4$ ;  $W/l$ 、 $L/l \geq 8$

## 無限版長撓度比預測模式之構建 小區域迴歸(3)



小區域迴歸結果圖


小區域迴歸測試結果圖

## 有限版長撓度比預測模式構建 類神經網路(1)

- 學習速率
  - 研究中採0.01
- 轉換函數之採用
  - 雙彎曲函數、正切雙彎曲函數以及輻射函數進行比較
- 隱藏層層數
  - 單層、雙層
- 隱藏層處理單元數
  - 以不同的處理單元數進行測試，以找出最佳之處理單元數
- 資料庫之採用
  - 輸入參數： $a/l$ 、 $r/l$ 、 $L/l$ 、 $W/l$
  - 輸出參數：撓度比( $w/w_0$ )
  - 訓練範例：2027，測試範例：200

## 有限版長撓度比預測模式構建 類神經網路(2)


函數名稱	雙彎曲函數	正切雙彎曲函數	輻射函數
範例RMS	0.01037	0.00966	無法收斂
測試RMS	0.01007	0.00899	無法收斂
判定係數	0.9988	0.9992	無法收斂
時間	11分21秒	20分26秒	無法收斂




## 有限版長撓度比預測模式構建 類神經網路(3)

單隱藏層處理單元數測試結果表

處理單元數	8	9	10	11	12	13
訓練之RMS	0.01037	0.00965	0.00974	0.00782	0.00887	0.00925
測試之RMS	0.01007	0.00966	0.01046	0.00785	0.00923	0.01011
判定係數	0.9988	0.9989	0.9989	0.9993	0.9991	0.9989
花費時間	11分	12分	13分	15分	16分	17分



## 有限版長撓度比預測模式構建 類神經網路(4-1)



第一層隱藏層處理單元數為8時之收斂結果

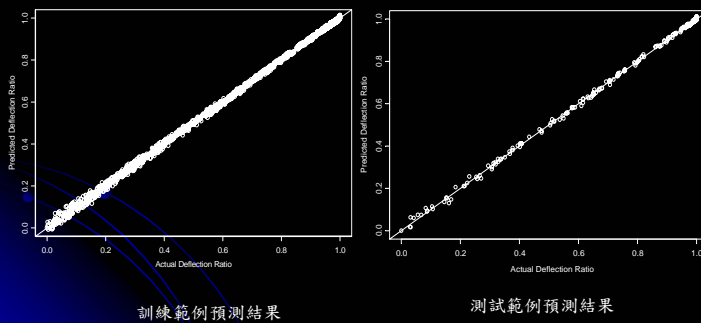
## 有限版長撓度比預測模式構建 類神經網路(4-2)

第一層處理單元		第二層處理單元					
		8	9	10	11	12	13
1	訓練之RMS	0.00552	0.00550	0.00562	0.00553	0.00602	0.00539
	測試之RMS	0.00565	0.00594	0.00518	0.00513	0.00562	0.00568
	判定係數	0.9997	0.9997	0.9996	0.9997	0.9997	0.9997
	時間	11分	12分	13分	16分	17分	21分
2	訓練之RMS	0.00714	0.00620	0.00563	0.00668	0.01102	0.00589
	測試之RMS	0.00711	0.00604	0.00581	0.00613	0.01028	0.00713
	判定係數	0.9994	0.9996	0.9994	0.9995	0.9988	0.9995
	時間	13分	13分	15分	18分	19分	22分
3	訓練之RMS	0.00599	0.00751	0.00581	0.00817	0.00981	0.01008
	測試之RMS	0.00549	0.00831	0.00588	0.00864	0.00904	0.01061
	判定係數	0.9997	0.9988	0.9991	0.9988	0.9979	0.9978
	時間	15分	16分	17分	19分	21分	24分
4	訓練之RMS	0.00570	0.00748	0.00558	0.01005	0.00673	0.00671
	測試之RMS	0.00569	0.00803	0.00559	0.01074	0.00656	0.00726
	判定係數	0.9993	0.9988	0.9994	0.9978	0.9978	0.9991
	時間	18分	18分	19分	22分	24分	25分

## 有限版長撓度比預測模式構建 類神經網路(5)

類神經網路使用參數表		
網路型態	倒傳遞神經網路	
轉換函數	Sigmoid Function	
隱藏層數目	2	
隱藏層神經元素	第一層：8	第二層：1
輸入參數	a/l、r/l、L/l、W/l	
輸出參數	撓度比(w/w <sub>0</sub> )	
使用範例	訓練範例	2027
	測試範例	200
學習週期	30000	
學習速率	0.01	
誤差均方根	測試範例	0.00552
	訓練範例	0.00565
判定係數	0.9997	

## 有限版長撓度比預測模式測試結果



## 有限版長撓度比預測模式構建 小區域迴歸(1)

- 模式應用
  - Deg=2(非線性)
  - Cell=0.1
  - Span=0.1
- 資料庫應用
  - 輸入參數：a/l、r/l、L/l、W/l
  - 輸出參數：撓度比(w/w<sub>0</sub>)
  - 資料數量：2227

## 有限版長撓度比預測模式構建 小區域迴歸(2)

\*\*\* Local Regression Model \*\*\*

Call:

loess(formula = defratio ~ aol + lol + wol + rol, span = 0.1, cell = 0.1)

Number of Observations: 2227

Equivalent Number of Parameters: 31.9

Residual Standard Error: 0.006376

Multiple R-squared: 1

Residuals:

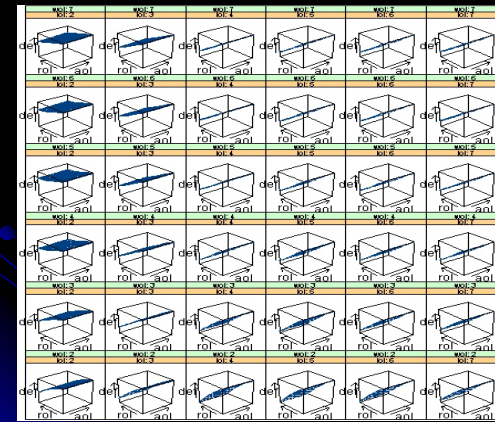
min 1st Q median 3rd Q max  
-0.05171 -0.002484 5.115e-006 0.003133 0.02274

統計量:


樣本數: 2227; 等值參數: 31.9; 殘餘標準誤: 0.006376; 判定係數: 1

使用限制:  $0.05 \leq a/l \leq 0.4$   $2 \leq L/l, W/l \leq 7$

## 有限版撓度比預測模式小區域迴歸結果

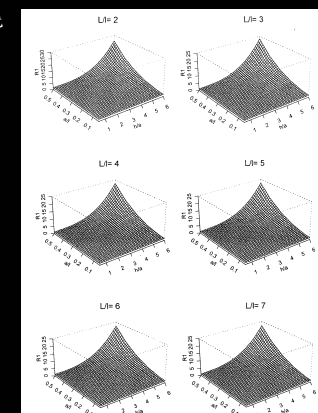


## 有限版撓度比預測模式小區域迴歸測試結果



## 三維撓度修正因子預測模式構建 資料庫採用

- 採用吳炳達(2002)三維中央荷重最大撓度資料庫
- 假設混凝土版為正方形版(L=W)
- 資料範圍:
  - $a/l$ : 0.05 - 0.5
  - $L/l$ : 2-7(step 1)
  - $h/a$ : 0.5 - 6 (step 0.5)





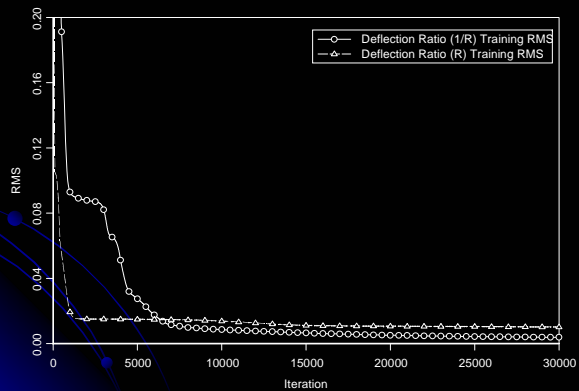
### 三維撓度修正因子預測模式構建 類神經網路(1)

- 學習速率
  - 研究中採0.02
- 轉換函數之採用
  - 雙彎曲函數
- 隱藏層層數
  - 雙層
- 隱藏層處理單元數
  - 以不同的處理單元數進行測試，以找出最佳之處理單元數
- 資料庫之採用
  - 輸入參數： $a/l$ 、 $L/l$ 、 $h/a$
  - 輸出參數：NET1：撓度修正因子(R1)  
NET2：撓度修正因子倒數(1/R1)
  - 訓練範例：404，測試範例：100


### 三維撓度修正因子預測模式構建 類神經網路(2)

網路型態	倒傳遞神經網路		
轉換函數	Sigmoid Function		
隱藏層數目	2		
隱藏層神經元素	第一層：10;第二層：4		
輸入參數	$a/l$ 、 $L/l$ 、 $h/a$		
輸出參數	NET1：撓度修正因子(R1) NET2：撓度修正因子之倒數(1/R1)		
使用範例	訓練範例	404	
	測試範例	100	
學習週期	30000		
學習速率	0.02		
誤差均方根	NET1	測試範例	0.01019
		訓練範例	0.00989
	NET2	測試範例	0.00478
		訓練範例	0.00539
判定係數	NET1	0.9988	
	NET2	0.9999	

### 三維撓度修正因子預測模式構建 類神經網路(3)



### 三維撓度修正因子預測模式構建 類神經網路(4)



測試範例預測結果

訓練範例預測結果

### 三維撓度修正因子預測模式構建 小區域迴歸(1)

- 模式應用

- Deg=2(非線性)
- Cell=0.1
- Span=0.1

- 資料庫應用

- 輸入參數： $a/l$ 、 $L/l$ 、 $h/a$
- 輸出參數：撓度修正因子倒數(1/R1)
- 資料數量：504

### 三維撓度修正因子預測模式構建 小區域迴歸(2)

\*\*\* Local Regression Model \*\*\*

Call:

loess(formula = 1/R ~ aol + Lol + hoa, span = 0.1, cell = 0.1)

Number of Observations: 504  
 Equivalent Number of Parameters: 56.6  
 Residual Standard Error: 0.004784  
 Multiple R-squared: 1

Residuals:


	min	1st Q	median	3rd Q	max
	-0.01829	-0.001788	-0.0002162	0.001796	0.02074

統計量:


樣本數: 504; 等值參數: 56.6; 殘餘標準誤: 0.004789; 判定係數: 1

使用限制:  $0.05 \leq a/l \leq 0.5$   $2 \leq L/l \leq 8$   $0.5 \leq h/a \leq 6$

### 三維撓度修正因子預測模式構建 小區域迴歸(3)

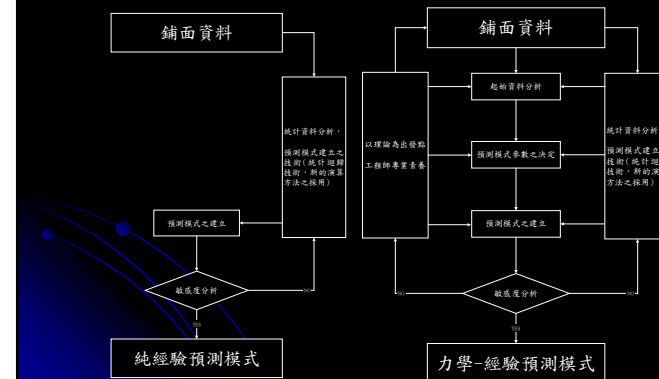


小區域迴歸預測模式結果



預測模式測試結果


### 預測模式建構流程之建議



# 多維度最大撓度預測模式

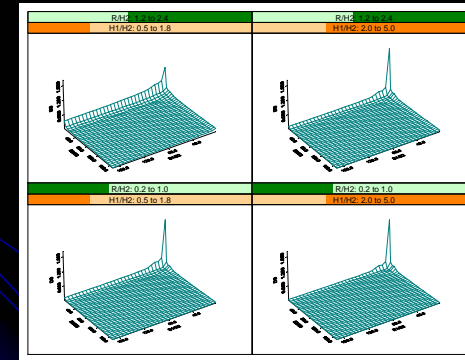
● 資料庫

- 適用於柔性鋪面
- 正算軟體BISAR
- $R/H_2$  : 0.2,0.4,0.8,1.2,1.8,2.4
- $H_1/H_2$  : 0.5,1.0,1.5,2.0,4.0,5.0
- $E_2/E_3, E_1/E_2$ : 0.5,1.0,2.0,5.0,10,30,50,90,140,170
- 模式建構用資料: 3600
- 驗證用資料: 1728



# 多維度最大撓度預測模式


資料分析(1)



原始資料分佈狀況


# 多維度最大撓度預測模式

資料分析(2)



# 多維度最大撓度預測模式


資料分析(3)



輸出參數處理(Log $D_0$ )後之資料分佈

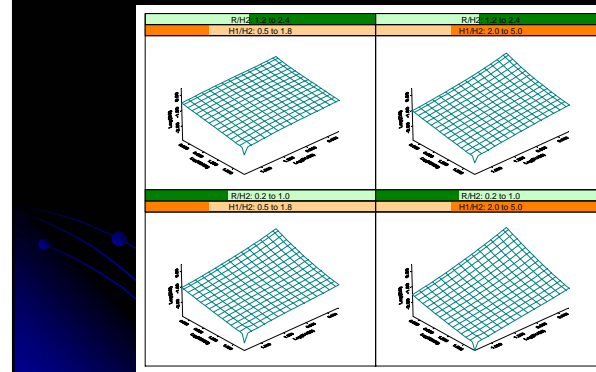
## 多維度最大撓度預測模式

資料分析(4)



## 多維度最大撓度預測模式

資料分析(5)



## 多維度最大撓度預測模式

類神經網路(1)

- NET1
  - 輸入參數： $R/H_2, H_1/H_2, E_2/E_3, E_1/E_2$
  - 輸出參數： $D_0$
- NET2
  - 輸入參數： $R/H_2, H_1/H_2, E_2/E_3, E_1/E_2$
  - 輸出參數： $\text{Log}(D_0)$
- NET3
  - 輸入參數： $R/H_2, H_1/H_2, \text{Log}(E_2/E_3), \text{Log}(E_1/E_2)$
  - 輸出參數： $\text{Log}(D_0)$


## 多維度最大撓度預測模式

類神經網路(2)

- NET1
  - 網路無法收斂
- NET2
  - 轉換函數：正切雙彎曲函數
  - 共採用三層隱藏層
    - ▶ 第一層：15
    - ▶ 第二層：10
    - ▶ 第三層：5
  - 20萬個學習循環
  - 使用10小時之網路訓練時間

## 多維度最大撓度預測模式


類神經網路(3)



NET2收斂結果

## 多維度最大撓度預測模式

類神經網路(4)



最大撓度測試結果 (Log)

最大撓度測試結果 (實際)

## 多維度最大撓度預測模式


類神經網路(5)

### ● NET3

- 轉換函數：正切雙彎曲函數
- 使用2層隱藏層
  - 第一層：12
  - 第二層：6
- 2萬7千個學習循環
- 使用26分鐘進行網路訓練

## 多維度最大撓度預測模式


類神經網路(6)



NET3收斂結果

## 多維度最大撓度預測模式

類神經網路(7)



最大撓度測試結果 (Log)

最大撓度測試結果 (實際)

## 多維度最大撓度預測模式

小區域迴歸(1)

### ● 模式之應用

- Span = 0.1
- Cell = 0.1
- Deg = 2

### ● 資料之採用

- 輸入參數：R/H<sub>2</sub>、H<sub>1</sub>/H<sub>2</sub>、Log(E<sub>2</sub>/E<sub>3</sub>)、Log(E<sub>1</sub>/E<sub>2</sub>)
- 輸出參數：Log(D<sub>0</sub>)
- 建構預測模式之資料：3600
- 測試資料庫：1728

## 多維度最大撓度預測模式

小區域迴歸(2)

\*\*\* Local Regression Model \*\*\*

Call:

loess(formula = log(do) ~ log(K1) + log(K2) + h + a, span = 0.1, cell = 0.1)

Number of Observations: 3600

Equivalent Number of Parameters: 31.9

Residual Standard Error: 0.02792

Multiple R-squared: 1

Residuals:

min 1st Q median 3rd Q max  
-0.1262 -0.0187 -0.00271 0.01085 0.1618

表中：K1：E<sub>1</sub>/E<sub>2</sub>，K2：E<sub>2</sub>/E<sub>3</sub>，h：H<sub>1</sub>/H<sub>2</sub>，a：R/H<sub>2</sub>

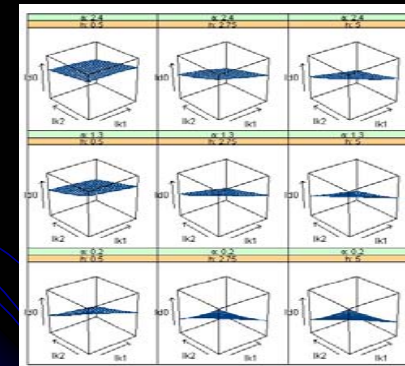
統計量：

樣本數：3600；等值參數：31.9；殘餘標準誤：0.02792；判定係數：1

使用限制： $0.5 \leq K1 \left(\frac{E_1}{E_2}\right) \leq 170$ ， $K2 \left(\frac{E_2}{E_3}\right) \leq 170$ ， $0.5 \leq h \left(\frac{H_1}{H_2}\right) \leq 5$ ， $0.2 \leq a \left(\frac{R}{H_2}\right) \leq 2.4$


## 多維度最大撓度預測模式

小區域迴歸(3)



小區域迴歸結果

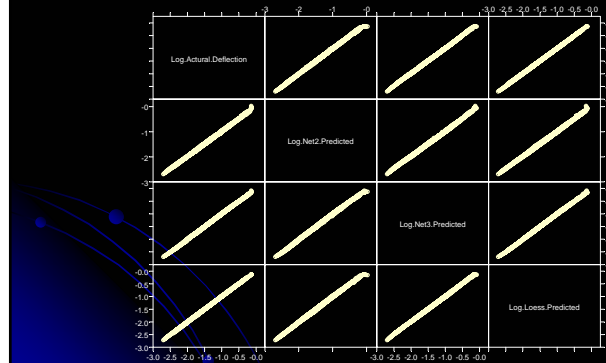
## 多維度最大撓度預測模式 小區域迴歸(4)



最大撓度測試結果 (Log)

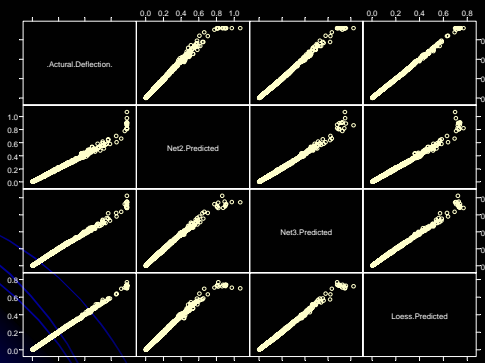
最大撓度測試結果 (實際)

## 多維度最大撓度預測模式 結果比較(1)



各預測模式預測結果比較圖(Log)

## 多維度最大撓度預測模式 結果比較(2)




各預測模式預測結果比較圖(實際)

## 無限版撓度比預測模式驗證(1)

### ● 驗證案例

- 根據Ioannides無限版長假設之建議
- 載重盤半徑 $a=5.9(\text{in.})$
- 路基反力模數 $k=300、400 \text{ pci}$
- 混凝土版回彈模數 $E=2.5、3.5 \times 10^6 \text{ psi}$
- 混凝土版寬 $W=8x \ell (\text{in.})$ ，混凝土版長 $L=8x \ell (\text{in.})$
- 混凝土版厚 $h=12、15(\text{in.})$
- 混凝土版柏松比 $\mu=0.15$
- 單位胎壓 $p=100 \text{ psi}$

## 無限版撓度比預測模式驗證(2)

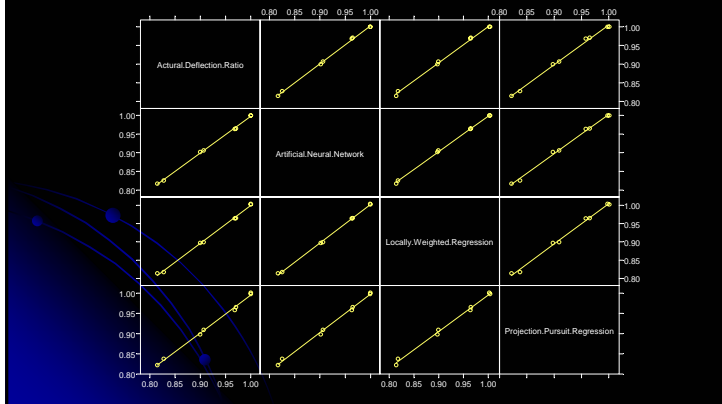


## 有限版長撓度比預測模式驗證(2)

### ● 驗證案例

- 載重盤半徑  $a=5.9(\text{in.})$
- 路基反力模數  $k=300 \text{ pci}$
- 混凝土版回彈模數  $E = 5 \times 10^6 \text{ psi}$
- 混凝土版寬  $W=4 \times l$ 、 $7 \times l(\text{in.})$
- 混凝土版長  $L=5 \times l$ 、 $6 \times l(\text{in.})$
- 混凝土版厚  $h=20(\text{in.})$
- 混凝土版柏松比  $\mu=0.15$
- 單位胎壓  $p=100 \text{ psi}$

## 有限版長撓度比預測模式驗證(2)



## 三維撓度修正因子預測模式之驗證(1)

### ● 驗證案例

- 載重半徑  $a = 5.642 (\text{in.})$
- 混凝土版回彈模數  $E=0.174 \times 10^6 \text{ psi}$
- 路基反力模數  $k=700 \text{ pci}$
- 混凝土版長  $5 \times l$ 、 $6 \times l$ 、 $5 \times l (\text{in.})$
- 混凝土版寬  $5 \times l$ 、 $6 \times l$ 、 $6 \times l (\text{in.})$
- 混凝土版厚度  $h = 28.21 (\text{in.})$
- 單位胎壓  $p = 90 \text{ psi}$



## 三維撓度修正因子預測模式之驗證(2)

類神經網路預測模式								
三維最大撓度	L/l	W/l	E/10 <sup>6</sup> (psi)	k (pci)	H (in.)	l (in.)	預測最大撓度	誤差百分比
7.022E-3	5	5	0.174	700	31.0	28.21	7.273E-3	-3.57
6.953E-3	6	6	0.174	700	31.0	28.21	7.204E-3	-3.61
6.9887E-3	5	6	0.174	700	31.0	28.21	7.273E-3	-4.06

小區域迴歸								
三維最大撓度	L/l	W/l	E/10 <sup>6</sup> (psi)	k (pci)	H (in.)	l (in.)	預測最大撓度	誤差百分比
7.022E-3	5	5	0.174	700	31.0	28.21	7.014E-3	0.11
6.953E-3	6	6	0.174	700	31.0	28.21	6.853E-3	1.44
6.989E-3	5	6	0.174	700	31.0	28.21	7.014E-3	-0.36

投影遞迴迴歸法								
三維最大撓度	L/l	W/l	E/10 <sup>6</sup> (psi)	k (pci)	H (in.)	l (in.)	預測最大撓度	誤差百分比
7.022E-3	5	5	0.174	700	31.0	28.21	6.177E-3	12.03
6.953E-3	6	6	0.174	700	31.0	28.21	6.137E-3	11.74
6.989E-3	5	6	0.174	700	31.0	28.21	6.177E-3	11.62

## 回算流程之建議

- 將半徑a(in.)荷重盤作用於混凝土版中央位置上。
- 利用NDT現地量測出距離載重中心0in與各徑向距離r(in.)之撓度w<sub>0</sub>與w，並求出各徑向距離之撓度比w/w<sub>0</sub>。
- 根據公式5-1求出一啟始之相對撓度半徑(l<sub>start</sub>)。
- 利用研究中所建立之撓度比預測模式求出撓度比。
- 反覆修正啟始之相對撓度半徑(l<sub>start</sub>)將其代入研究中所建構之撓度比預測模式，使預測模式之撓度比等於現地撓度比，如此即可得到一符合現地之相對撓度半徑(l<sub>adj</sub>)。
- 利用已知之中央荷重最大撓度w<sub>0</sub>以及所求得之相對撓度半徑(l<sub>adj</sub>)，將其代入Westergaard中央荷重撓度公式即可求得路基反力模數(k)。
- 最後利用求解相對撓度半徑之公式即可回算出混凝土版彈性模式(E)。
- 結束回算流程

## 回算流程之驗證

小區域迴歸								
撓度 (in.)	實際撓度比	實際l (in.)	h (in.)	r (in.)	預測l (in.)	k (pci)	E/10 <sup>6</sup> (psi)	誤差百分比
0.004122	1.0000	33.29	12	0	--	--	--	--
0.003799	0.9216			12	33.41	293	2.47	-0.4
0.003179	0.7712			24	33.20	296	2.44	0.27
0.002512	0.6094			36	33.12	298	2.43	0.51
0.002168	1.0000	39.83	15	0	--	--	--	--
0.002039	0.9405			12	39.94	391	3.48	-0.28
0.001780	0.8210			24	39.78	394	3.43	0.13
0.001488	0.6863			36	39.80	393	3.44	0.08

投影遞迴迴歸法								
撓度 (in.)	實際撓度比	實際l (in.)	h (in.)	r (in.)	預測l (in.)	k (pci)	E/10 <sup>6</sup> (psi)	誤差百分比
0.004122	1.0000	33.29	12	0	--	--	--	--
0.003799	0.9216			12	33.65	288	2.51	-1.08
0.003179	0.7712			24	33.01	299	2.41	0.84
0.002512	0.6094			36	33.07	298	2.42	0.66
0.002168	1.0000	39.83	15	0	--	--	--	--
0.002039	0.9405			12	41.52	362	3.74	-4.24
0.001780	0.8210			24	39.72	395	3.42	0.28
0.001488	0.6863			36	39.35	402	3.35	1.21

## 結論

(1)

- 在文獻中發現，以往類神經網路之預測模式構建並未使用因次分析之概念，**皆以純量資料庫之方式來進行預測模式之構建**，然而利用純量方式會造成輸入參數增多、資料庫過大以及需要大量的時間來進行網路的訓練，並且無法兼顧到完整的鋪面狀況，僅適用於個案等等缺點。由於上述之問題本研究首先以力學為基礎配合因次分析之概念，將其運用到類神經網路的預測模式構建上。**在研究中發現，使用因次分析之資料庫不僅大量減少輸入參數、大量的縮減了資料之數量並且可快速的達到網路所需之精度**，因次分析之方法應用在類神經網路上將可增加其訓練之效率，並且增加其精度。

## 結論

(2)

- 本研究利用純量的方式來建構類神經網路預測模式，在將其與因次分析所建立之預測模式相比較後，可發現純量之預測模式的網路訓練時間長達6小時，其為因次分析預測模式建構之數百倍的時間，並且就網路訓練之資料筆數而言，純量預測模式需要上萬筆之資料如此才有辦法進行預測模式建構，反之因次分析之預測模式僅需上百筆資料即可達到相當良好之精度。

## 結論

(3)

- 在研究過程中發現，在類神經網路預測模式之建構過程中，轉換函數的選擇、隱藏層的層數以及各隱藏層之處理單元數，對網路的收斂速度以及精度有很大的影響，一個正確的轉換函數可以加快網路的收斂速度，並且可增加網路之精度，然而錯選轉換函數可能會導致網路無法收斂之狀況。而隱藏層的層數與各層的處理單元數也影響類神經網路訓練的時間以及精度。在研究過程中發現，當網路收斂到一定程度後，再增加隱藏層以及處理單元數，對精度並不會有太大之影響，多增加隱藏層及處理單元數僅會浪費多餘的時間在網路的訓練上，並且容易造成過度學習的現象。

## 結論

(4)

- 在隱藏層的層數以及其處理單元數量的決定上，一般而言僅需一層隱藏層即可達到所需之精度，而研究過程中發現，當網路為單層之隱藏層之結構時，可先由(輸入參數+輸出參數)之兩倍測試起，若無法達到所需之精度可將其處理單元數以個處理單元數為範圍再測試之，如此應可達到所需之精度，反之若還是無法達到所需之精度，即可考慮使用雙層隱藏層之網路結構。當使用雙層隱藏層之網路結構時，其處理單元數之測試第一層之個數可為先前測試單層收斂結果最好之處理單元數為起始，第二層之處理單元數可由前一隱藏層的一半進行測試，若無法達到所需精度時，則利用減少或增加第二層之處理單元數之方法，反覆試誤直至達到所需精度為止，而第二層的處理單元數以不超過第一層之處理單元數目為原則。

## 結論

(5)

- 小區域迴歸為一最新的當代迴歸技術，此一迴歸方法擁有極高的精度，可充分的反應自變數與變數間的關係，在研究中發現使用小區域迴歸配合因次分析之概念建構之撓度比預測模式，可得到非常良好的精度，若資料本身之可信度高且資料量夠多時，在建構預測模式中可藉由調整網格切割大小 (cell)，以及調整平滑參數 (span) 等方法來快速的達到預測模式所需之精度，雖然其在非線性 ( $deg = 2$ ) 的狀況下，僅可使用4個變數，然而此點將限制小區域迴歸的使用性，然而卻可由工程師本身的專業知識或是應用因次分析的方法，來解決此一問題。

## 結論

(6)

- 在預測模式的建構過程中，資料的判讀以及前處理是非常重要的，在研究中發現，在使用類神經網路建構三維中央荷重撓度最大修正因子預測模式的過程中，若未對輸出參數（撓度修正因子）取倒數來縮小資料範圍之後才進行網路訓練的話，將無法達到研究所需之精度要求，反之若取其倒數進行網路訓練，不僅精度大幅增加，亦可加快網路收斂的速度，因此不論是使用類神經網路、小區域迴歸或是投影追逐迴歸法進行預測模式構建時，資料的處理與分析將為一非常重要的環節，在預測模式構建之前，必須先經由工程師本身的專業知識來決定是否先行對資料進行處理與轉換，如此將可確保預測模式之精度，並且可減少預測模式構建之時間。

## 結論

(7)

- 就精度而言，類神經網路、小區域迴歸與投影追逐迴歸法所構建之中央無限版撓度比預測模式、中央有限版撓度比預測模式並無太大的差別，其精度範圍誤差皆在2%以內，然而在三維中央荷重撓度修正因子預測模式構建時，小區域迴歸所建立之預測模式所預測之結果最佳，類神經網路次之，投影追逐迴歸法所建立之模式最差，最後根據預測精度、模式構建時間，以及未來擴充性而言，小區域迴歸可得到最好的結果，因此本研究在預測模式構建方法的選擇上，經由時間效益、精度以及未來擴充性等方面考量，小區域迴歸將為最好之選擇。

## 建議

(1)

- 本研究礙於時間之關係，僅針對中央荷重無限版長與有限版長之撓度比預測模式於溫氏基礎下之狀態進行模式構建，在未來可利用小區域迴歸再針對不同荷重位置（邊緣、角隅）以及不同的基礎模式進行其餘預測模式之構建，並且在未來可利用三維有限元素法分析各不同荷重位置之反應，再利用所得之結果建立三維之剛性鋪面回算模式，以更切合現地鋪面之狀況。
- 在經由驗證後發現，小區域迴歸配合因次分析之概念，確實可利用在剛性鋪面之回算上，然而礙於時間因素，研究中並未將溫差、骨材互鎖效應、多版、荷重傳遞效應等等納入考量，因此在未來可利用因次分析之方法配合小區域迴歸構建相關之預測模式。

## 建議

(2)

- 經由模式構建與驗證過程中發現，類神經網路亦可運用在鋪面回算之工作上，在研究中得知，因次分析之方法所構建之預測模式確實優於純量之方法，因此本研究建議未來類神經網路在模式構建時應採用因次分析之方法，捨棄純量之方式。
- 類神經網路尚擁有許多之網路模式，研究中僅利用最常為研究學者所採用之倒傳遞網路進行預測模式構建，在未來可利用因次分析方法配合其餘不同之網路模式進行構建。

簡報結束

敬請指教

