

類神經網路 控制系統

朱明輝 彭增榮 編著

Artificial Neural
Network
Control Systems

7P183
20103

類神經網路 控制系統

朱明輝 彭增榮 編著

Artificial Neural
Network
Control Systems

國家圖書館出版品預行編目資料

類神經網路控制系統 / 朱明輝、彭增榮編著,
-- 初版. -- 臺北縣中和市：新文京開發,
2008 (民 97)
面；公分

ISBN 978-986-150-787-3 (平裝)

1. 神經網路

312.8

97002124

類神經網路控制系統

(書號：C146)

編著者	朱明輝、彭增榮
出版者	新文京開發出版股份有限公司
地址	台北縣中和市中山路二段 362 號 8 樓 (9 樓)
電話	(02) 2244-8188 (代表號)
F A X	(02) 2244-8189
郵撥	1958730-2
初版	西元 2008 年 3 月 3 日

有著作權 不准翻印

建議售價：390 元

法律顧問：蕭雄淋律師


ISBN 978-986-150-787-3

序言 PREFACE

回顧類神經網路的主要發展歷程中，早期研究還是著重於有關學習、視覺和條件反射等一般理論，並沒有包含有關神經元工作的數學模型。20 世紀的 40 年代 McCulloch 與 Pitts 提出的神經元計量模型，是為現代對神經網路領域研究工作的開始。在 20 世紀的 50 年代後期，Frank Rosenblatt 所提出的“感知器”和“聯想學習法則”，則是最早的類神經網路模式的實際應用。時至今日，神經網路在許多領域上的廣泛應用，使其極具吸引力。同時，基於高速電腦和快速演算法，也可以用神經網路解決過去許多計算問題。

本書介紹了神經網路的基本概念、架構和學習法則，重點是對這些神經網路的數學分析、訓練方法、信號處理以及自動控制系統等工程實現的應用。本書第一章是介紹一個簡單化的神經生理學概念，從單一神經元細胞體的組成、特性、及兩個神經細胞之間的連結活動，進而建構出類神經網路系統 ANS 模型，用來描述理想化的神經網路架構。而在最後兩節以感知器做為 ANS 模型的特例，探討在它適用性上有哪些限制，和如何克服這些限制。第二章內容是回顧基本的信號處理理論，並對於濾波器的設計、功能及建立類比濾波器之數位化等量的技術做一概略的敘述。最後將重點放在 Adaline 和 Madaline 網路的探討上。

第三章分別以倒傳遞類神經網路的基本原理和類神經網路之神經鍵更新演算方式，敘述在類神經網路的學習過程中，採用批次學習訓練範例，經過週而復始的學習週期，直至收斂為止。最後舉例：應用三層誤差倒傳遞類神經網路模擬 2 輸入 OR 邏輯閘執行程式。




第四章內容為類神經網路應用在自動控制領域中，並在一般、間接及特定這三種學習架構中，做控制反應和成效比較。第五章介紹二種受控系統 Jacobian 的近似值求法：(1)線上學習類神經網路適應性控制(2)倒傳遞誤差項近似法。並進行模擬直流馬達轉速控制系統的轉速反應、類神經網路控制器之輸出量以及神經鍵於控制過程之加權值變化情形。第六章介紹直接神經網路控制器架構、系統控制、系統判別之外還具有模擬器 (Emulator) 的神經網路間接適應控制系統。

第七章探討直接類神經網路控制應用於直流馬達轉速控制，第八章探討直接類神經網路控制應用於電液伺服閥控液壓系統位置控制，第九章探討直接類神經網路控制應用於可變排量軸向型柱塞泵輸出流量控制，第十章探討比例微分與類神經網路混合控制器。最後，感謝文京出版機構全體同仁的大力支持，並將原稿編排成書，使本書得以順利出版。

編著者 謹識

目錄 CONTENTS



CHAPTER 1 類神經網路技術的介紹

- 1.1 基本神經生理學 4
- 1.2 從神經細胞到 ANS 6
- 1.3 結 論 15

CHAPTER 2 Adaline 和 Madaline

- 2.1 信號處理的回顧 20
- 2.2 Adaline 和 ALC (自適應線性組合器) 26
- 2.3 MADALINE 27

CHAPTER 3 倒傳遞類神經網路原理

- 3.1 倒傳遞類神經網路 32
- 3.2 倒傳遞類神經網路(BPN) 36
- 3.3 類神經網路之神經鍵更新演算 (激發函數為雙曲線正切函數) 36
- 3.4 類神經網路之神經鍵更新演算 (激發函數為 Sigmoid 函數) 39

CHAPTER 4 類神經網路控制

- 4.1 類神經網路控制器發展 54
- 4.2 直接類神經網路控制 57
- 4.3 關於隱藏層數目及隱藏層神經元數目的考量 62
- 4.4 收斂性分析 62

CHAPTER 5 特定學習架構直接適應控制

- 5.1 線上學習類神經網路適應性控制 78
- 5.2 倒傳遞誤差項近似法 79

CHAPTER 6 特定學習架構間接適應控制

- 6.1 系統判別 96
- 6.2 間接適應控制 110

CHAPTER 7 直接類神經網路控制應用於直流馬達控制

- 7.1 直接類神經網路控制應用於直流馬達轉速控制 120
- 7.2 直接類神經網路控制應用於直流馬達轉角控制 129
- 7.3 直接類神經網路控制應用於直流馬達轉角控制實驗結果 134

CHAPTER 8 直接類神經網路控制應用於電液伺服閥控液壓系統位置控制

- 8.1 直接類神經網路適應控制電液伺服閥控液壓系統描述 142
- 8.2 類神經網路控制器 144
- 8.3 動態模擬結果 144

CHAPTER 9 直接類神經網路控制應用於可變排量軸向型柱塞泵輸出流量控制

- 9.1 控制系統描述 160
- 9.2 類神經網路控制器 165
- 9.3 動態模擬 166
- 9.4 實驗結果 168

CHAPTER 10 比例微分與類神經網路混合控制器

- 10.1 混合控制器發展 172
- 10.2 控制系統描述 172
- 10.3 控制系統模擬 176
- 10.4 DANN 控制系統實驗結果 181

類神經網路技術的介紹

現今一般電腦系統的能力不足，無法建造一個能思考的電腦，無法期待機器能夠理解出虛擬影像中的形狀所代表的意義，無法讓相同的機器從經驗中相互學習，只能藉由人類的程式設計師，重複不斷地下達明確性的指令集。這些都是電腦設計者、工程師和程式設計師所面臨的問題。他們都在努力的開發更多的“智慧型”電腦系統，針對現今一般的電腦系統的能力不足，進行改善。然而，不表示這些機器完全不適用，許多工作適合藉由一般性的電腦來解決：科學上和數學上的問題求解；資料庫的開發、操控和維護、電子通訊、文字處理、繪圖和平台的設立等；甚至對於那些加了智慧型裝置，而使我們家庭上的工具和器具俱備簡單控制功能，都被現今的電腦非常有效地掌控。相對地在許多的應用上，我們都喜歡自動化帶來的便利，但卻無法做到完全自動化的原因是因為可程式化的電腦採用過度複雜化的方法去解決關聯性問題，大範圍的關聯性問題是無法被解決，在計算機發展歷史中，我們發現使用序列性程序的電腦系統難以解決關聯性問題。

若我們唯一的工具是序列性的演算法，那將導致我們必須盡很大的努力去做複雜化的演算法發展，去解決關聯性問題，甚至找不到一個可以被接受的解決方式。



近年來許多平行式處理架構，提供我們多樣化應用的新工具。有了這些工具，我們將可以更容易地解決更多近期難以解決的問題。當然眾所熟悉的現有工具仍然持續在發展中，但必須具有能夠完成平行處理的完整工具，才具備有效的開發“智慧型”電腦系統的能力。

近年來類神經網路蓬勃發展，我們藉由定義一個神經網路的架構，作為一個平行處理器相連接的收集區，應用於圖形處理及文字辨識可以有效改善其效能。建構這種網路架構，有助於平行處理問題的解決，我們以圖示方式定義一個處理單元（或單位），在網路上被當做是一個節點，並藉由弧線來代表單元之間的連結；我們在網路上運用了箭頭的連結來表示資訊流的方向。為簡化所舉的例子，我們將限制神經網路的字元數目，必須辨識十進位字元 0、1、...、9，而不使用整個的 ASCII 字元集。我們採用了此種限制，只是要讓舉例更清楚明白，並沒有特別的理由。

基於這些考量，我們現在已經知道這個網路應包括 10 個二進位單元做為輸出架構。同樣地，我們必須決定如何針對這個網路去設計符合的輸入。要建立這種類型的輸入，我們從影像世界和像素的特性上。設定像素影像尺寸大小為 10×8 陣列，以 1 表示像素是 ON，以 0 表示像素是 OFF。針對這點，所有處理單元之間的連結一樣要設定大小，而且必須在內部被用來做為輸入和輸出單元之間的連結，而這些處理單元也已經被以加權值連結來定義，並且運用了已知的資料配對，來訓練這個網路。

由於這類的網路被充分地訓練後能辨識人們寫下的數字影像，雖然能夠辨識出人們寫下數字的影像，但是對於能辨識誰寫的卻沒有這類網路的訓練。假設訓練已經足夠，資訊就會傳播到網路上，並在單一的單元上產生一個二進位為 1 的輸出值，並且對應到所寫下數字的其中一個。圖 1.1(a) 為充分訓練後網路能辨識的字元，當然會有些無法辨識的字元如圖 1.1(b)。




圖 1.1 (a)能辨識的字元 (b)無法辨識的字元

我們注意到對於問題的解答訓練類神經網路的過程，可以應用為一種對資訊做簡單加密的手段，而且在訓練完成之後，類神經網路可以具有資訊加密或編碼的功能。顯示神經網路的能力涉及複雜的模型辨識問題，且不會在科技應用上受到限制。目前類神經網路系統(artificial neural system, ANS)只能得到一個表面化而類似於生物學上機能的吻合物。目前 ANS 模型可以有效發揮在關於學習上、辨識上的行為，以及有效應用在建立真實世界中的物體和物體型態之間的適用關係。ANS 模型未來發展將重視人工和自然系統之間的差異。期望未來 ANS 模型能提供擁有整個全新的工具組合，讓我們能夠解決機器智慧(Machine intelligent)的問題。



1.1 基本神經生理學

Artificial Neural Network Control Systems

本教科書從神經生物學上屬於一種特別的類神經網路架構中，引用到它的特殊結構。關於這點，我們首先針對單一的神經元，探討其功能及建立其數學模型，接著再針對神經元細胞之間的神經元連結點，討論 McCulloch-Pitts 的神經計量模型，並且討論它和我們的神經網路模型之間的特殊關係。接下來討論一個簡單化的神經生理學概觀；事實上，實際的神經生理學主題是遠遠複雜於我們所描繪的簡單化的神經生理學概觀。


1.1.1 單一神經細胞生理學

中樞神經系統中的典型神經細胞體的主要組成，如圖 1.2(a)所示，它包括：


- 一、神經核 (soma)：神經細胞中呈核狀的處理機構。
- 二、軸突 (神經軸) (axon)：神經細胞中呈軸索狀的輸送機構。
- 三、樹突 (神經樹) (dendrites)：神經細胞中呈樹枝狀的輸出入機構。
- 四、突觸 (神經節) (synapse)：神經樹上呈點狀的連結機構。

當一個神經元被輸入的訊號所激發時，神經元會產生一串脈衝列 (pulse) 沿著軸索傳遞，若是激發是在興奮突觸 (excitatory synapse)，則會增加脈衝列的速率 (pulse rate)；若是激發是在抑制突觸 (inhibitory synapse)，則會減少脈衝列的速率。因此，脈衝列的速率是同時取決於輸入脈衝列的速率，以及神經節的強度 (strength)。而神經節的強度可視為神經網路儲存資訊之所在，神經網路的學習即在調整神經節的強度。

在神經元的薄膜介於空隙的液態外部與細胞體內部的細胞質之間，細胞膜可透過帶離子的特性，使得在內部的細胞液態質和外部細胞液態質之間維持著電位差。最初完成這項工作是藉由一種以納-鉀幫浦的運作。這種機械結構的輸送方式，是納離子離開細胞體，而鉀離子則是進入細胞體如圖 1.2(b)所示。其他出現的離子性的元素，有氯離子和帶負電荷的有機離子。



(a) 神經細胞示意圖



(b) 細胞膜的鈉-鉀幫浦運作

圖 1.2 神經細胞生物模式

所有的離子性元素都能游離穿透細胞膜，而除了有機離子之外，因為它實在太大了；由於有機離子無法從細胞體游離出來，他們的網路組織充滿著負電荷，使得氯離子不正常的游離進入細胞體。也就是說，會有較高的氯離子濃度游離出細胞體，這個鈉-鉀幫浦迫使較高的鉀離子濃度在細胞體內部，而較高的鈉離子濃度在細胞體外部。

細胞膜在滲透性的選擇上，比起鈉離子較有機會滲透到鉀離子上。這種對於鉀元素在化學上的升降率，產生了鉀離子游離出細胞體，但在有機離子的強大引力之下，使得鉀離子保持在細胞體內部。這種反向力量的結果，會達到了一種平衡狀態，那就表示有較多的鈉離子和氯離子在細胞體外部，並且有較多的鉀離子和有機離子在細胞體內部。此外，當脫離電位差而穿透細胞膜所產生的恆等式，其電壓值大約介於 70 到 100 毫伏(mV)之間，在內部細胞的液態質有較多的負電荷。這個電位，稱為細胞體的“**休止電位**”。



1.1.2 神經元的接合

讓我們來觀察，在處於活化狀態下所發生的兩個神經細胞之間的連結，稱為“**神經元的接合**”或“**神經節**”。在兩個神經細胞之間所發生的活動聯繫，就像是經由某些物質的前端神經元細胞體，又被稱為“**神經細胞發送器**”所釋放出來，並且在這些物質的後端神經元細胞體產生後續性吸收的結果，當動作電位到達了前端神經元細胞膜，而改變了細胞膜的滲透性，以致產生碳離子的聚集。這些離子產生了小囊胞，並包圍了神經細胞發送器，而與前端神經元細胞膜融合，而且釋放出這些神經細胞發送器進入到神經元的裂縫口。

神經細胞發送器游離穿透過接合點，並在某個接收器工作站上加入了後端神經元細胞膜中。這個在接收器工作站上的化學性反應，其結果改變了後端神經元細胞膜到某個離子性元素上的滲透性。當一個帶正電荷元素進入到細胞體的匯合點，就會產生一種去極化的休止電位；此種效應就稱為激化。若帶負電荷離子進入，則會產生一種超雙極化的效應；這種效應就稱為抑制化。這兩種效應是本身的效應，它會在細胞本體上擴散很短的距離，並且在神經軸突丘處加總。假如加總量大於某個臨界值，則會產生一個動作電位。



1.2 從神經細胞到 ANS

Artificial Neural Network Control Systems

在本節中，我們會從神經生物學的概念蒐集，轉換到以多數化的 ANS 模式為基礎，來描述理想化的架構。首先我們來描述一個人工神經細胞，它是依據生物神經元細胞的特徵，以人工建立的神經元模型，見神經元的特殊模式，來做為未來的討論。在後續的章節中，我們會介紹一個 ANS 的特別例子，稱為感知器(perceptron)。感知器是早期為了要完成複雜性的工作，所發明用來模擬神經細胞計量化的結果。我們對其做特別性的檢視，探討它在這項研究上有哪些限制，和如何克服這些限制。



1.2.1 一般性的處理單元(PE)

本書採用的個別性的計量單元，大部份是由人工神經系統模型所組成，少數被稱為人工神經細胞；多數被視為節點、單位或處理單元(PE)。本書中的這些項目名稱都是對生物神經網路與人工神經網路模型共通的且可互用的名稱。

另外，在神經網路中的處理單元，不符合我們所想像的，如同真實的生物學上的神經細胞那種一對一的關係。有時最好能將其想像成一群神經細胞集體的活化性，並具有代表性的單一處理單元。如此闡述不僅能幫助我們避免掉入一個陷阱裏，以為我們的系統是真實的大腦模型的說法，而且當我們嘗試去做一些生物學上的結構的模型化行為時，所產生的問題會更容易處理。

圖 1.3 為一般性的 PE 模型。每個 PE 都被編號，在圖中第 i 個是其中之一。舉例，像真實的神經細胞，PE 有許多的輸入，但只有一個輸出，而且在網路上能擴展出許多其他的 PE。第 i 個輸入是從第 j 個 PE 取得，被稱為 x_j （注意：這個值也是第 j 個節點的輸出，正如同是由第 i 個節點所產生的輸出一樣，標示為 x_i ）。




圖 1.3 一般性的 PE 模型



每個連結到第 i 個的 PE 都付予一個關聯值，稱為“加權值”或“連結強度”。從第 j 個節點到第 i 個節點的連結加權值，寫為 x_{ij} 。

這些所有的數值，在標準化的神經細胞模型中，有代表的類似體：PE 的輸出相當於神經細胞的觸發頻率，而且加權值相當於在神經細胞之間神經元連結的強度。在我們的模型中，這些數值都代表著實際的數目。

須注意的是，從輸入到 PE 會被分離成不同的類型。這種具有特殊性輸入連結的分離性知識，也許會在一些效果中產生。在輸入的連結中，或許是激化或抑制。舉例，在我們的模型中，激化性的連結加權值為正，而抑制性的連結加權值則為負，也有可能是其他類型。這類項目的增益、壓抑和非特別性的激化描述，特殊目的的連結，這些其他類型的連結特性，在本書的後面章節將會做敘述。激化和抑制作用的連結通常被認定為一起發生的，而且是構成輸入到 PE 最常見的型式。

在整個輸入連結的基礎上，一個 PE 決定一個網路輸入值，在沒有特殊的連結情形下，我們象徵性的計算出網路的輸入，由輸入值的加總乘上對應的加權值。換句話說，網路輸入到第 i 個單元可以寫成

$$net_i = \sum_j x_j w_{ij} \quad (1-1)$$

當索引值 j ，超出了所有的連結到 PE，激化和抑制都會經由加權值的符號而自動地計算，這種“積之和”的計算，在網路的模擬上產生很重要的規則，在本書後面會談到。由於在網路中，通常都有很大數目的交互連結產生，所以在完成這種計算的速度上，就取決於任何所付予網路中模擬性的效率。

自從網路的輸入被計算出之後，對 PE 而言，會轉換為“活化值”，或簡稱為“活化”，可以將這項活化值寫成

$$a_i(t) = F_i(a_i(t-1), net_i(t)) \quad (1-2)$$



表示活化值在網路輸入中是個明確的函數。須注意的是，新的活化值是依據前一個活化值 $a(t-1)^2$ 而定，在大多數的情況下，活化和網路的輸入是相同的，項式是可以互換的。有時候活化和網路的輸入不盡相同，我們更須注意到它們的不同之處。然而，大部份的時候可用活化來表示網路的輸入和替代性。

自從 PE 的活化被計算出之後，我們能夠運用輸出函數：

$$x_i = f_i(a_i) \quad (1-3)$$

來決定輸出值。通常 $a_i = net_i$ ，上式可寫成

$$x_i = f_i(net_i) \quad (1-4)$$

對於活化 VS. 網路輸入說法的其中一個理由，就是“活化函數”的項式，有時也參考使用到函數 f_i ，在轉換網路輸入值 net_i 到節點的輸出值 x_i 。當我們對於網路模型做數學基礎上的描述時，通常都會聯想到網路如同一個動態的系統，也就是說，像一個系統過度的進化一樣。要描述此類的網路，我們應該寫出另外一種不同的等式，針對各個不同 PE 的輸出，來描述所改變的時間比率。例如： $\dot{x}_i = g_i(x_i, net_i)$ ，是針對第 i 個 PE 的輸出，代表一個一般性不同的等式。在 x 字母上方的點，代表著時間關聯性的不同。因此， net_i 是隨著許多其他不同的單元而定，我們確信一個系統會有一對不同的等式。

舉個例，等式 $\dot{x}_i = -x_i + f_i(net_i)$ ，表示第 i 個處理單元的輸出，我們代入某些輸入值到 PE，使得 $net_i > 0$ 。若輸入仍然維持著一段充份的長時間，則輸出值會達到一個平衡狀態值，當 $\dot{x}_i = 0$ ，則導出 $x_i = f_i(net_i)$ ，與式子 (1.4) 是相同的等式，我們通常都假設在平衡狀態達到之前，都維持著輸入值。

一旦單元有一個非零的輸出值，移除輸入將使輸出回歸到零，若 $net_i = 0$ ，則 $\dot{x}_i = -x_i$ ，代表 $x \rightarrow 0$ 。這也非常有助於觀察在一個動態的系統中做加權值的蒐集。回想先前單元的描述，我們主張在神經細胞之間的神經元連結的強度所修正的結果，被認定是一種學習行為。在 ANS 模型中，學習行為通常會伴隨著加權值的修正期而發生。我們能寫出一個系統加權值