

---

# 各章概要

---

## Chapter 1 開始接觸類神經網路

類神經網路是什麼東西？先來比較跟其他機器學習演算法的差異，再以圖片、簡單的數學式解說類神經網路的結構與能夠做到哪些事情。

## Chapter 2 學習正向傳播

解說構成感知器類神經網路的單純演算法是如何進行運算，舉判別圖像尺寸為例，學習從輸入值到輸出值依序計算的「正向傳播」。

## Chapter 3 學習反向傳播

說明在類神經網路上，如何求得適當的權重與偏差。使用微分更新權重與偏差，盡可能減少「誤差」，但正攻法的計算相當麻煩，因此我們會採用簡化計算的「誤差反向傳播法」。

## Chapter 4 學習卷積類神經網路

學會類神經網路的基本原理後，接著學習使用卷積類神經網路處理圖像，舉出卷積類神經網路的特有機制、運算，並說明權重、偏差的更新方法。

## Chapter 5 實作類神經網路

根據前面章節學到的類神經網路計算方法，使用 Python 編寫程式。以 Chapter 2、3 出現的基本類神經網路，實作圖像的尺寸判定；以 Chapter 4 出現的卷積類神經網路實作手寫文字辨識。

## Appendix

收錄 Chapter 1 ~ 5 未能詳細解說的數學知識、Python 程式設計的環境設置、Python 與 NumPy 的簡易說明。

總和符號 / 微分 / 偏微分 / 合成函數 / 向量與矩陣 / 指數與對數 / Python 環境設置 / Python 基礎入門 / NumPy 基礎入門

# Chapter

# 1

## 開始接觸類神經網路



你最喜歡的是起司蛋糕

對深度學習產生興趣的綾乃，  
向友人美緒請求指導。  
然而，綾乃對深度學習完全沒有概念，  
美緒只好從頭開始說明。  
在沒有困難數學式與程式的情況下，  
和美緒她們一起學習  
什麼是深度學習吧！



我也要！

Section

2

## 類神經網路的定位



首先，先畫出整體的俯瞰圖。

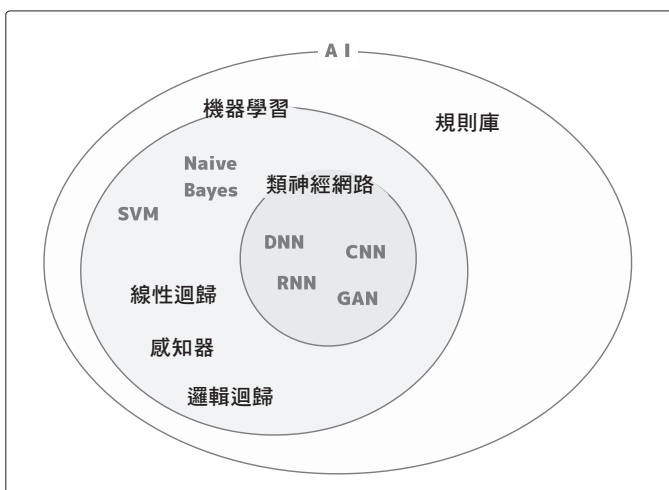


圖1-1



確認一下類神經網路在 AI 範圍中的什麼位置。



是機器學習的領域之一嘛。



妳聽過線性迴歸、感知器（perceptron）、邏輯迴歸嗎？類神經網路是這些機器學習演算法的同伴哦。



這樣啊！我還以為類神經網路是全新的東西。



類神經網路的歷史相當久遠，與其他機器學習相同，可求解迴歸、分類的問題。



因為最近很流行才誤會了，類神經網路並不是全新的技術嘛。



妳還記得迴歸和分類嗎？



回歸是處理連續值，比如，由過去的股價預測未來股價與趨勢。




圖1-2



分類是處理非連續值，比如，將郵件分為「垃圾郵件」或「非垃圾郵件」的問題。

郵件的內容	是否為垃圾郵件
工作辛苦了。下個星期天預計去的……	×
和我交個朋友嘛。這邊有我的照片哦！ <a href="http://..">http://..</a>	○
恭喜您抽中夏威夷旅行……	○

表1-1

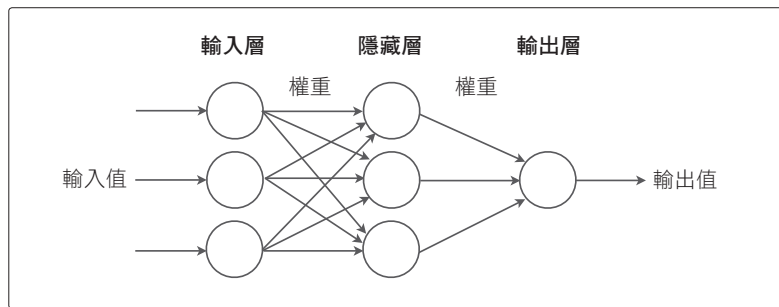


圖1-3



類神經網路形式上大多會以這樣的方式表達，圓圈表示神經元，也可稱為單元（unit）。



這種圖經常看到。從圓形部分畫出許多箭頭連結其他圓形。



這是輸入值加權後，向右進入單元層，最終輸出數值的動作示意圖。



隱約知道是從左向右前進，但輸入什麼樣的數值會輸出什麼樣的數值，過於抽象不好想像。



可以代入簡單的例子來幫助理解，比如……

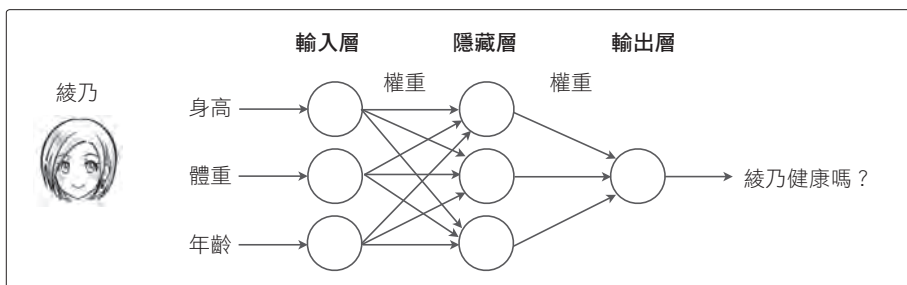


圖1-4

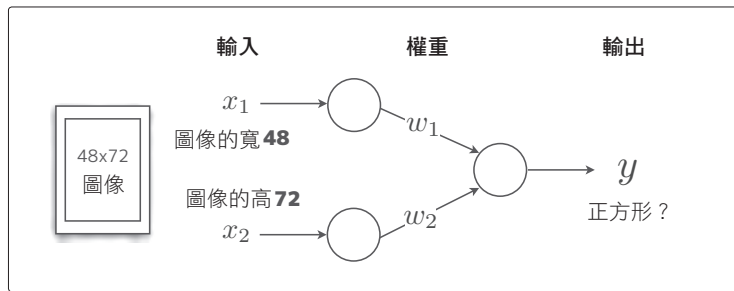


圖2-4



別忘了，與式 2-8 相同， $y$  是根據內積加上偏差的值輸出 0 或 1。

$$y = \begin{cases} 0 & (\mathbf{w} \cdot \mathbf{x} + b \leq 0) \\ 1 & (\mathbf{w} \cdot \mathbf{x} + b > 0) \end{cases} \quad (2-16)$$



跟剛才一樣計算寬和高的差值，看結果是否剛好等於 0 不就可以了嗎？



那麼，實際計算幾個例子看看吧。我想想……比如將這四個圖像輸入感知器。

$$\mathbf{x}_a = \begin{bmatrix} 45 \\ 45 \end{bmatrix}, \quad \mathbf{x}_b = \begin{bmatrix} 96 \\ 96 \end{bmatrix}, \quad \mathbf{x}_c = \begin{bmatrix} 35 \\ 100 \end{bmatrix}, \quad \mathbf{x}_d = \begin{bmatrix} 100 \\ 35 \end{bmatrix} \quad (2-17)$$



直接看數值可知： $x_a$  和  $x_b$  是「正方形」； $x_c$  和  $x_d$  是「非正方形」。



對。這是我刻意安排的。



當然，這樣就能分類，但這是知道正方形的特徵，才能列出來的式子吧？這條式子能夠用於正方形判定，但不能用於長邊判定。這樣的話，每次進行某種判定時，不就都得思考新的分類式子？



瞭解數據的特徵、規則，也就代表不需要機器學習。感知器的作業到底是在規則不明瞭的情況下，機器執行根據內積加上偏差的正負號決定結果。



對哦……就這個意義來說，正方形判定、長邊判定本來就是不使用感知器等機器學習的思維，也能夠求解的問題嘛。



沒錯。現在只是為了練習，舉簡單的問題來求解而已。



但是，沒辦法用感知器求解正方形的判定，只是因為權重  $w$  和偏差  $b$  的數值不好嘛？經過學習求得正確的數值後，應該就能夠正確分類吧？



很遺憾，感知器是解不開的哦！

## Section

# 6

## 感知器的缺點



光由數學式沒辦法看出來，這邊畫出關係圖來幫助理解吧。




圖2-5



是的。這個問題無法只用一條直線分類哦。



果然沒辦法用一條來分類……



感知器不能解這種無法只用一條直線分類的問題。



無論怎麼改動權重  $w$  和偏差  $b$  都解不開？



解不開。



這、這樣啊……



變更權重、偏差的操作，實際上等同於變更圖中的直線。所以，一開始就無法以直線分類的問題，無論怎麼改動權重、偏差，結果還是無法分類哦。



對感知器來說，能不能用直線分類很重要的意思？



是的。可用直線分類的問題稱為**線性可分離**；無法用直線分類的問題稱為**線性不可分離**，這要好好記住哦！




圖2-9





嗯。剛剛是分別計算 3 個感知器，得到判斷結果。



嗯。但是，我們通常不會這麼麻煩地一個個計算。還記得妳前面提到：「類神經網路感覺好像數學的函數」嗎？



$f(x) = y$  的函數嘛，將輸入值  $x$  代入類神經網路  $f$  得到結果  $y$ 。



妳不想從數學的角度，更詳細瞭解類神經網路  $f$  的內部嗎？



嗚……是想啊……但一聽到數學就會感到排斥。



呵呵。多複習幾次就行了，慢慢來理解吧。



美緒也一起的話，我就努力……看看。



後面的說明中，也會直接使用與剛才圖 2-12 相同的類神經網路。這邊將圖稍微畫得簡潔一些。

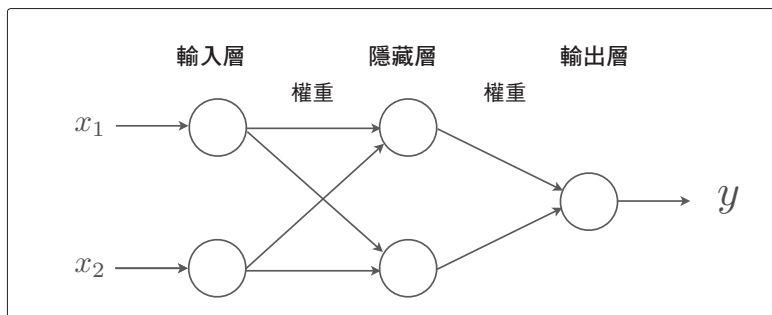


圖2-15



嗯，雖然重新畫過，但結構本身沒有改變嘛。



在類神經網路，存在單層感知器沒有的思維——「階層」。



就是輸入層、隱藏層、輸出層嘛。



是的。這邊會導入編號來識別階層，也就是令輸入層為 0，後面各層依序編號。比如，剛才的類神經網路會是：

- 假設輸入層為第 0 層；
- 假設隱藏層為第 1 層，其連接的權重為第 1 層的權重；
- 假設輸出層為第 2 層，其連接的權重為第 2 層的權重。



示意圖如下：

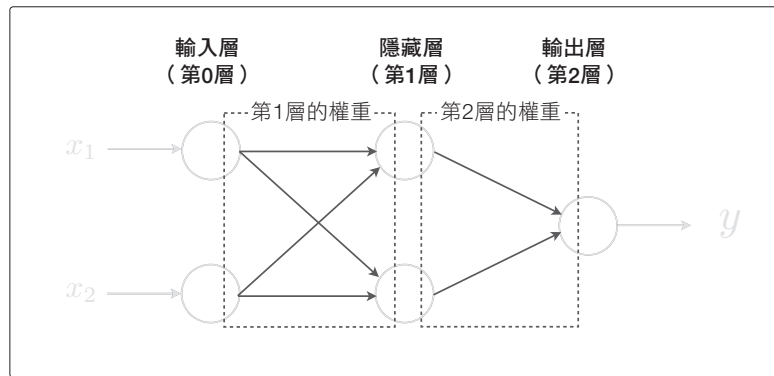


圖2-16



順便一提，類神經網路的階層結構，與權重、偏差數的關係為：

- 權重數 = 連結階層間單元的線數；
- 偏差數 = 該階層的單元數。



這跟美緒在式 2-23 做的計算相同嘛。最後會是權重和輸入值的內積加上偏差。

$$\mathbf{W}^{(1)}\mathbf{x}^{(0)} + \mathbf{b}^{(1)} = \begin{bmatrix} w_{11}^{(1)}x_1 + w_{21}^{(1)}x_2 + b_1^{(1)} \\ w_{12}^{(1)}x_1 + w_{22}^{(1)}x_2 + b_2^{(1)} \end{bmatrix} \quad (2-43)$$



沒錯。然後，套用第 1 層的激活函數：

$$\mathbf{a}^{(1)}(\mathbf{W}^{(1)}\mathbf{x}^{(0)} + \mathbf{b}^{(1)}) \quad (2-44)$$



傳到隱藏層的值，也就是式 2-34，可想成通過激活函數從隱藏層輸出哦。

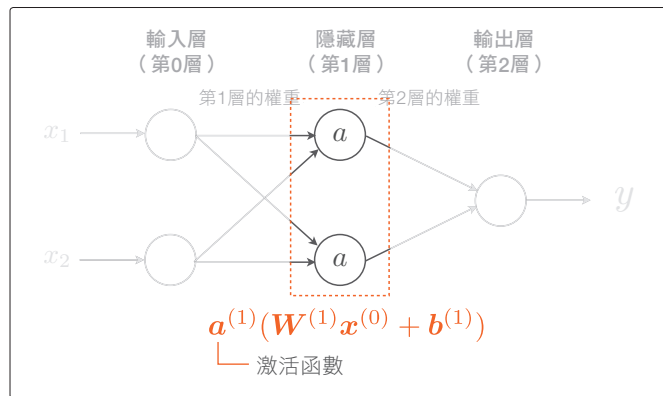


圖2-25



就是將第 1 層的激活函數  $a^{(1)}$  套用到各元素嘛。

$$\mathbf{a}^{(1)}(\mathbf{W}^{(1)}\mathbf{x}^{(0)} + \mathbf{b}^{(1)}) = \begin{bmatrix} a^{(1)}(w_{11}^{(1)}x_1 + w_{12}^{(1)}x_2 + b_1^{(1)}) \\ a^{(1)}(w_{21}^{(1)}x_1 + w_{22}^{(1)}x_2 + b_2^{(1)}) \end{bmatrix} \quad (2-45)$$



沒錯。然後，取從第 1 層到第 2 層輸入值的意思，以文字記為  $\mathbf{x}^{(1)}$ 。這也可視為第 1 層的輸出值。

$$\mathbf{x}^{(1)} = \mathbf{a}^{(1)}(\mathbf{W}^{(1)}\mathbf{x}^{(0)} + \mathbf{b}^{(1)}) \quad (2-46)$$

## 為什麼必要？



我嘗試了不使用激活函數會發生什麼事。



喔！原來如此，不錯的嘗試。



對吧。比如，假設一個像這樣單純的類神經網路：

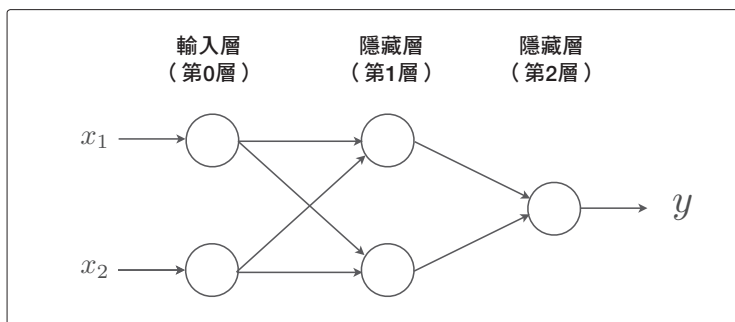


圖2-c-1



這個類神經網路是由輸入  $\mathbf{x}$  和兩個權重矩陣  $\mathbf{W}^{(1)}$ 、 $\mathbf{W}^{(2)}$  所構成。

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}, \mathbf{W}^{(1)} = \begin{bmatrix} w_{11}^{(1)} & w_{12}^{(1)} \\ w_{21}^{(1)} & w_{22}^{(1)} \end{bmatrix}, \mathbf{W}^{(2)} = \begin{bmatrix} w_{11}^{(2)} & w_{12}^{(2)} \end{bmatrix} \quad (2-c-1)$$



順便一提，偏差對這個嘗試來說可有可無，姑且先忽視它。



這樣的話，類神經網路的正向傳播計算，能夠用這個式子描述：