

類神經

LMS Learning

授課教授：趙春棠 教授

學生：黃秉宏

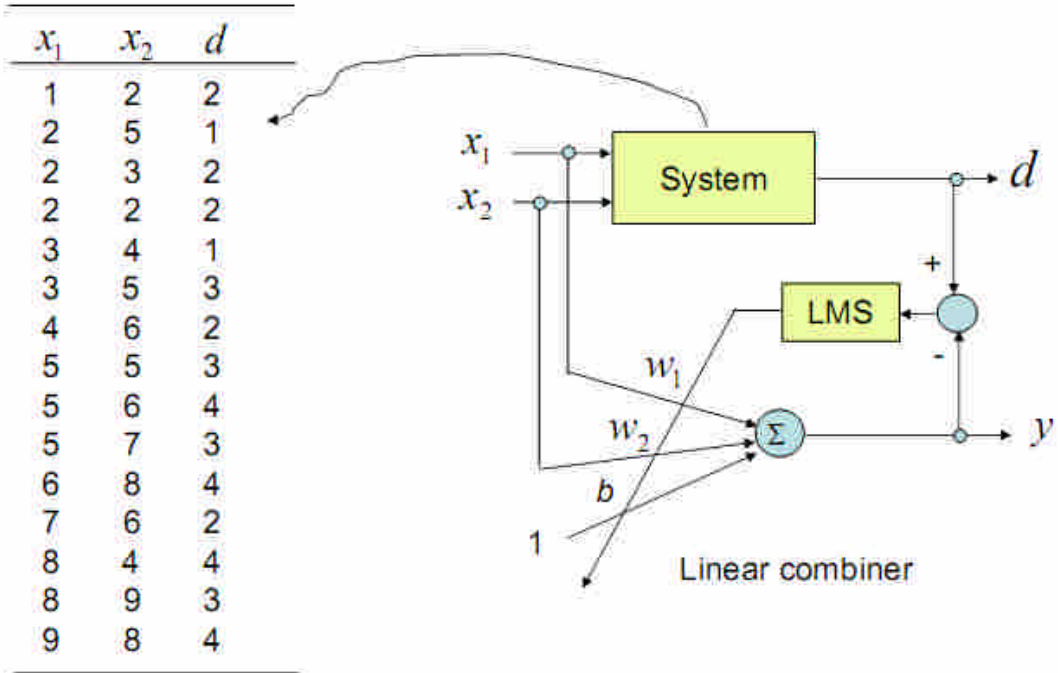
學號：49422019

班級：機電四甲

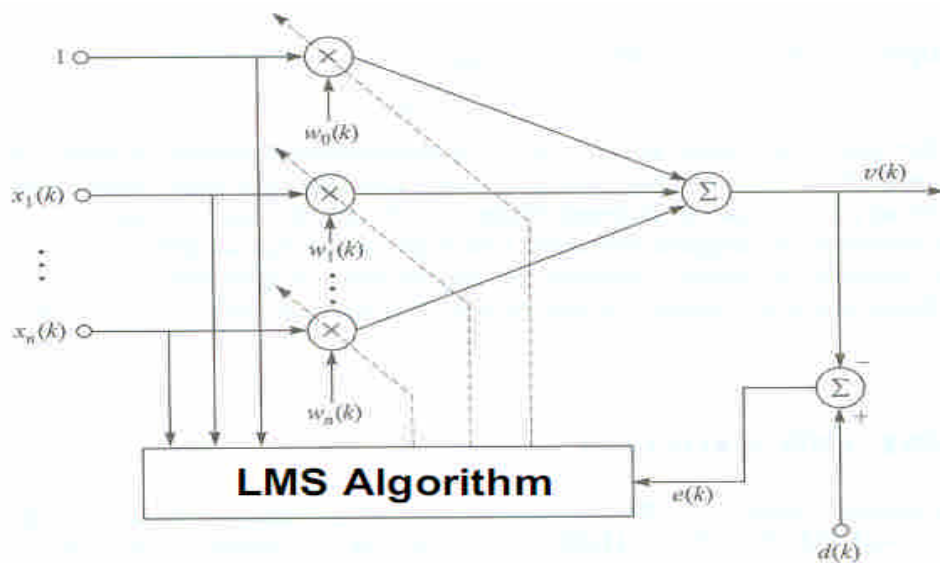
第一題題目

Problem 1

Q1: Use LMS to learn the following weights and simulate it by Matlab



(1) LMS 架構圖：



(2) 數學方程式：

$$\begin{aligned}
 \nabla_w J(w) &\approx \left. \frac{1}{2} \frac{\partial e^2(k)}{\partial w} \right|_{w=w(k)} \\
 &= \frac{1}{2} \frac{\partial}{\partial w(k)} [d^2(k) - 2d(k)x^T(k)w(k) + w^T(k)x(k)x^T(k)w(k)] \\
 &= -d(k)x(k) + x(k)x^T(k)w(k) = -d(k)x(k) + w^T(k)x(k)x(k) \\
 &= -\underbrace{[d(k) - w^T(k)x(k)]}_{e(k)} x(k) = -e(k)x(k)
 \end{aligned}$$

Therefore, the learning rule for updating the weights using the steepest-descent method as

$$w(k+1) = w(k) + \mu[-\nabla_w J(w)] = w(k) + \mu e(k)x(k)$$

Where μ is learning rate with $0 < \mu < \frac{2}{\lambda_{\max}}$ or $0 < \mu < \frac{2}{\text{trace}\{C_x\}}$

(3) 設定步驟：

Step 1. Set $k = 1$, initialize the synaptic weight vector $w(k = 1)$, and select values for μ_0 and τ .

Step 2. Compute the learning rate parameter as

$$\mu(k) = \frac{\mu_0}{1 + k/\tau} \quad \tau : \text{searching time constant}$$

100 ≤ τ ≤ 500

Step 3. Compute the error

$$e(k) = d(k) - \sum_{i=1}^n w_i(k)x_i(k)$$

Step 4. Update the synaptic weights $w_i(k+1) = w_i(k) + \mu(k)e(k)x_i(k)$, for $i = 1, 2, \dots, n$.

Step 5. If convergence is achieved, stop; else set $k \leftarrow k + 1$, then go to step 2.

(4) Matlab 程式：

```
1  clc
2  clear all
3  x=zeros(2,15);
4  d=zeros(1,15);
5  x(1,:)= [1 2 2 2 3 3 4 5 5 5 6 7 8 8 9];
6  x(2,:)= [2 5 3 2 4 5 6 5 6 7 8 6 4 9 8];
7  d=[2 1 2 2 1 3 2 3 4 3 4 2 4 3 4];
8  Cx=x*x'/15;
9  lr0=0.9/max(eig(Cx));
10 tau=200;
11 w=zeros(2,1);
12 b=zeros(1,1);
13 t=0;
14 cw=10000;
15 a=0:cw-1;
16 for j=1:cw
17     t=t+1;
18     lr(t)=lr0/(1+t/tau);
19     for i=1:15
20         y=x(1,i)*w(1)+x(2,i)*w(2)+b;
21         yo(j)=y;
22         e=d(i)-y;
23         eo(j)=e;
24         w=w+lr(t)*e*x(:,i);
25         wo(:,j)=w;
26         b=b+lr(t)*e;
27         bo(j)=b;
28     end
29 end
30 subplot(2,2,1)
31 plot(a,yo)
32 axis([-inf,inf,-7,7])
33 xlabel('次數');
34 title('實際輸出值');
35 subplot(2,2,2)
36 plot(a,eo)
37 axis([-inf,inf,-7,7])
38 xlabel('次數');
39 title('實際誤差值');
40
```

說明：

$$Cx = x * x' / 15;$$


$x * x'$ 是求出共變異矩陣，而除以15則是要算出平均值，此項計算便於下個步驟求出eigen value所做的矩陣計算

$$lr0 = 0.9 / \max(\text{eig}(Cx));$$

$lr0$ 做的計算則是初始學習速率， $\text{eig}(Cx)$ 則是將共變異矩陣求出eigen value，再利用max函數求得最大之eigen value。 $lr0$ 所計算出來之數值為下列公式之 u_0 。

$$u(k) = \frac{u_0}{1 + k/\bar{\tau}}$$

(5) 模擬結果：

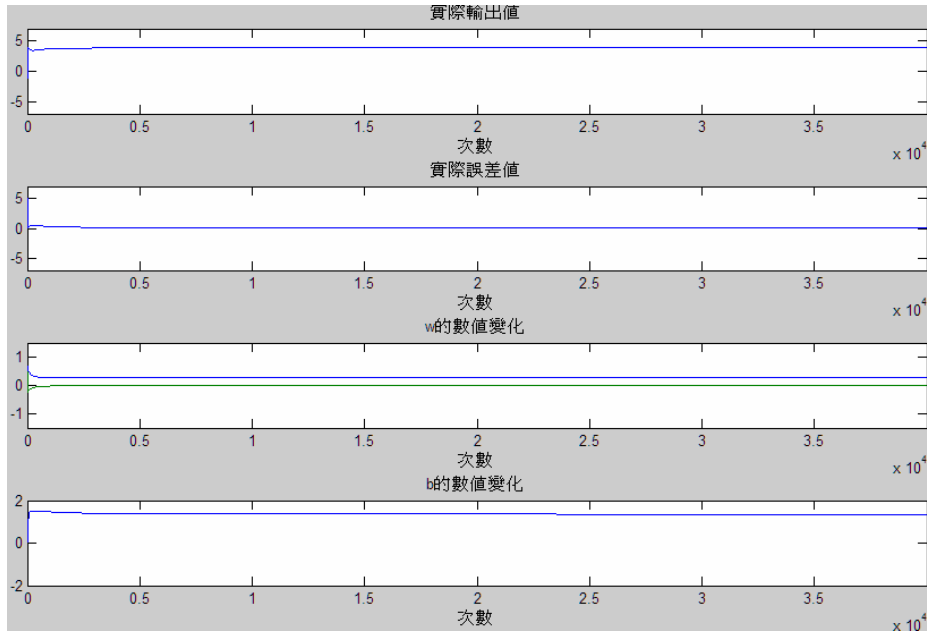


```
Command Window
>> w
w =
    0.2839
   -0.0052
>> b
b =
    1.3688
>> e
e =
    0.1236
>> y
y =
    3.8764
>> |
```

(6) 討論：

1. 學習次數對輸出結果之影響(上述測試以 10000 次學習討論)

學習次數調整為 40000 次之結果



Command Window

```
>> w  
  
w =  
  
    0.2856  
   -0.0044  
  
>> b  
  
b =  
  
    1.3573  
  
>> e  
  
e =  
  
    0.1091  
  
>> y  
  
y =  
  
    3.8909  
  
>> |
```

結論：學習次數越高，可讓 w 和 b 值學習更精準。但對收斂速度無幫助。

2. 學習率、tau 值的關係：

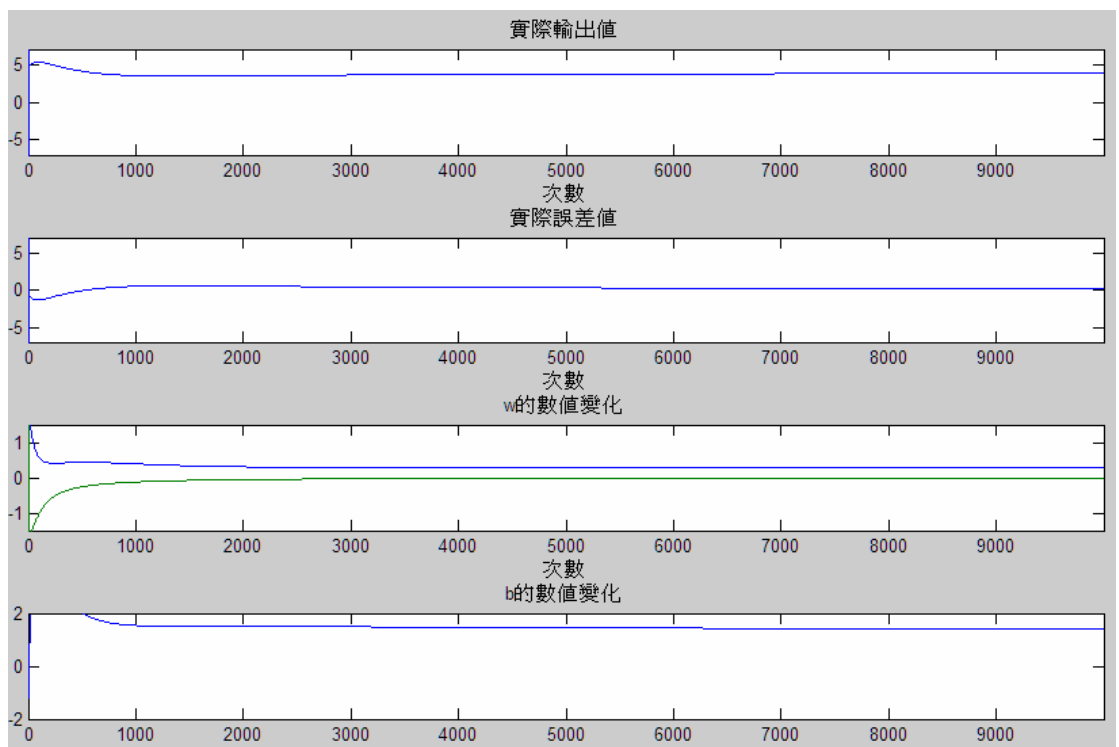
$$\mu(k) = \frac{\mu_0}{1 + k/\tau}$$

Where μ is learning rate with $0 < \mu < \frac{2}{\lambda_{\max}}$ or $0 < \mu < \frac{2}{\text{trace}\{C_x\}}$

$$w(k+1) = w(k) + \mu[-\nabla_w J(w)] = w(k) + \mu e(k)x(k)$$

所求得之 lr_0 為 μ_0 ，w 每次更新為前一次數值+學習率*誤差值*輸入值，但因學習率會受到 k 的執行次數影響，而降低學習率，因此 w 所更新的值也越來越小，而 tau 也會直接影響至學習率，tau 越大，學習率越大，學習率越大，w 的更新值越大，也較難收斂。

下列數值以 tau=500， lr_0 設為 $\text{lr}_0 = 1.5/\max(\text{eig}(C_x))$



由此圖可看出， τ 及 $\ln 0$ 越大，學習率較大，需較長時間才能收斂。至於學習率為何會定義右邊公式原因：

$$0 < \mu \leq \frac{2}{\lambda_{\max}}$$

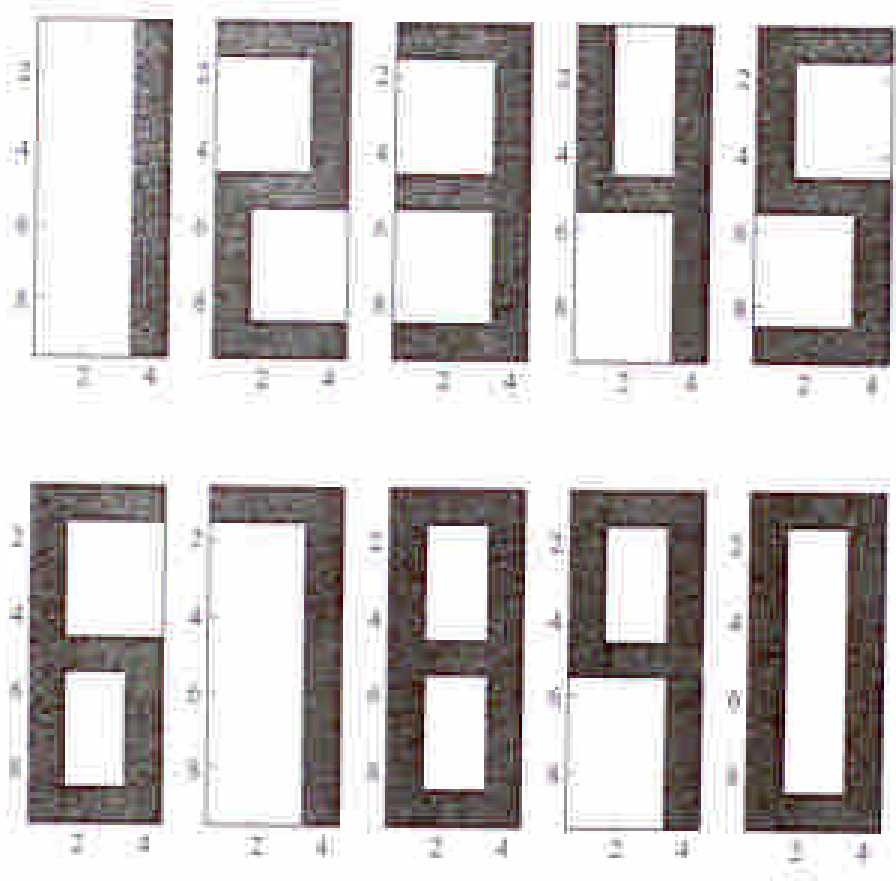
U 的大小會決定權重更新步伐，如果 u 太小則

權重改變量也較小，太大則是造成目標發生振盪，因此Haykin建議 u

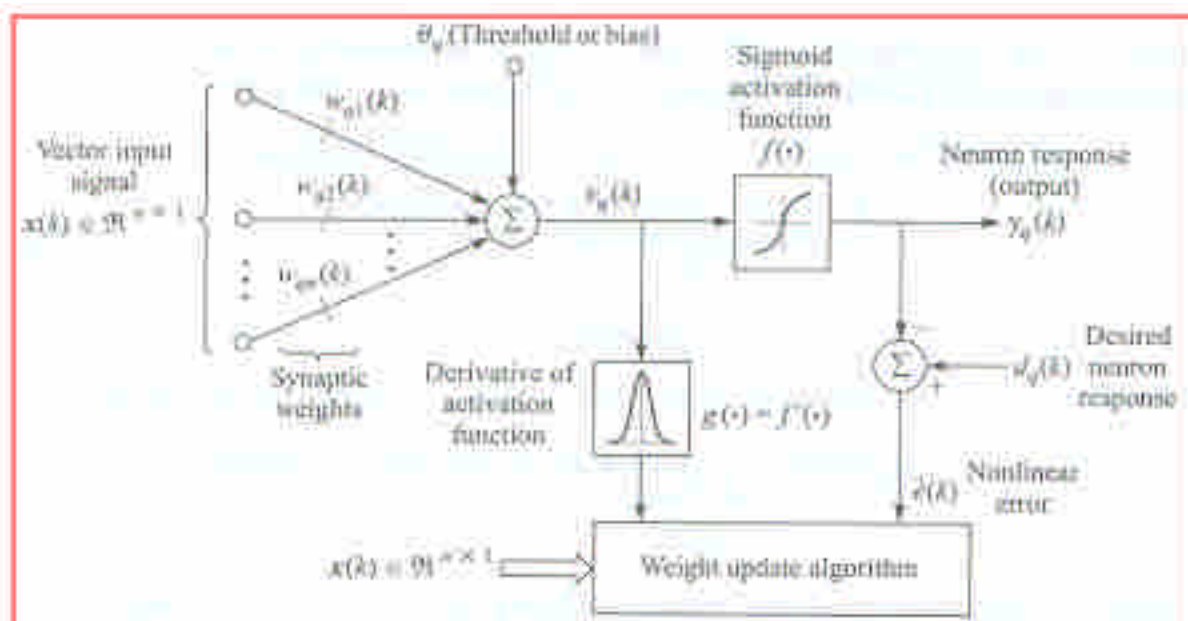
在右上之範圍為最好。

Problem 2

Q2: Use the simple perception with the sigmoid function to learn the digital 0~9 shown in right figure. (Use one neuron)



(1) 架構圖：



(2) 數學方程式：

Step 1. feed forward computation

$$\bar{e}_q(k) = d_q(k) - y_q(k)$$

$$y_q(k) = f[v_q(k)]$$

$$= f\left[\sum_{j=1}^n x_j(k)w_{qj}(k) + \theta_q\right]$$

Step 2. feedback learning

$$w_{qj}(k+1) = w_{qj}(k) + \mu\alpha\bar{e}_q(k)[1 - y_q^2(k)]x_j(k)$$


or

$$w_{qj}(k+1) = w_{qj}(k) + \mu\alpha\bar{e}_q(k)[1 - y_q^2(k)]x_j(k)$$

where $j = 1, 2, \dots, n$.

學習率，學習次數為 10000 次。運算式採用 Binary sigmoid function 方式計算。

(4) 模擬結果：



實際誤差圖

```

Command Window
163kB
>> d

d =

Columns 1 through 8

    0.9000    0.8000    0.7000    0.6000    0.5000    0.4000    0.3000    0.2000

Columns 9 through 10

    0.1000         0

>> yt

yt =

Columns 1 through 8

    0.9000    0.7999    0.7040    0.6000    0.4972    0.4025    0.2978    0.1949

Columns 9 through 10

    0.1020    0.0028

>>

```

d 為期望值、yt 為記錄最後輸出值

80	9990	9991	9992	9993	9994	9995	9996	9997	9998	9999	10000
1	-0.0028428	-0.0028425	-0.0028422	-0.0028419	-0.0028416	-0.0028413	-0.002841	-0.0028407	-0.0028403	-0.00284	-0.002835
2											
3											
4											

誤差值在接近 10000 次運算時的數值

(5) 討論：

Binary sigmoid function

$$y_q = f_{bs}(v_q) = \frac{1}{1 + e^{-\alpha v_q}}$$

Where α is the slope parameter

The function is continuous and differentiable

Binary sigmoid function

Step 1. feed forward computation

$$\tilde{e}_q(k) = d_q(k) - y_q(k)$$

$$y_q(k) = f[v_q(k)] \\ = f\left[\sum_{j=1}^n x_j(k)w_{qj}(k) + \theta_q\right]$$

Step 2. feedback learning

$$w_{qj}(k+1) = w_{qj}(k) + \mu\alpha\tilde{e}_q(k)[1 - y_q^2(k)]x_j(k)$$

or

$$w_{qj}(k+1) = w_{qj}(k) + \mu\alpha\tilde{e}_q(k)[1 - y_q^2(k)]x_j(k)$$

where $j = 1, 2, \dots, n$.

1. afa 值的影響：

由Binary sigmoid function看出afa越小，則 $\exp(-a*v)$ 越小，但輸出值y會越大。afa越小則會影響到w的更新權值。

2. sita q 的影響：

sita q 越小，vq 也會變小，而vq 變小後，經過 Binary sigmoid function 運算後，進而影響至輸出值y 會變大。

3. u 的影響：

u 越小則會影響到w的更新權值。

實驗：

將 α 設為0.1、 σ 設為0.05、 u 設為0.01，可從下圖看出收斂速度明顯慢了好幾倍。

