


example

خلية التغذية الراجعة Back propagation

مثال \\\ قم بتدريب شبكة Back propagation للتعلم على مدخلات ومخرجات بوابة OR علماً ان معامل التعلم 1 والاوزان عشوائية.

سوف ندرّب الصف الاول من البوابة

x1	x2	T
0	0	0
0	1	1
1	0	1
1	1	1

$x1=0$ $x2=0$, $T=0$, $w11=1$, $w12=0$, $w21=0$, $w22=1$, $w10=1$, $w20=1$

* لكي ندرّب الخلية المطلوبة يجب ان نعرف بعض المصطلحات التالية:

- 1- $h1$: يمثل مجموع المدخلات للخلية الاولى ضمن الطبقة الخفية .
- 2- $h2$: يمثل مجموع المدخلات للخلية الثانية ضمن الطبقة الخفية .
- 3- $h3$: يمثل مخرج الخلية الاولى من الطبقة الخفية .
- 4- $h4$: يمثل مخرج الخلية الاولى من الطبقة الخفية .
- 5- N : مجموع مدخلات خلية طبقة المخرجات .
- 6- O : يمثل المخرج الفعلي للخلية
- 7- T : المخرج المطلوب للخلية

* سوف نبدأ الحل وحسب الخوارزمية :-

1- تمرير المدخلات على الشبكة وصولاً الى طبقة المخرجات وذلك حسب القانون التالي :

$$\begin{aligned} h1 &= w11 * x1 + w21 * x2 \\ &= 1 * 0 + 0 * 0 \\ &= 0 \end{aligned}$$

$$\begin{aligned} h2 &= w12 * x1 + w22 * x2 \\ &= 0 * 0 + 1 * 0 \\ &= 0 \end{aligned}$$

$$\begin{aligned} h3 &= 1 / (1 + e^{-h1}) \\ &= 1 / (1 + e^{-0}) \\ &= 0.5 \end{aligned}$$

$$\begin{aligned} h4 &= 1 / (1 + e^{-h2}) \\ &= 1 / (1 + e^{-0}) \\ &= 0.5 \end{aligned}$$

2- الحصول على مجموع المدخلات التي تدخل طبقة المخرجات وذلك من خلال القانون التالي :-

$$N = w10 * h3 + w20 * h4$$

$$\begin{aligned} &= 1 * 0.5 + 1 * 0.5 \\ &= 1 \end{aligned}$$

3- استخراج قيمة المخرج الفعلي (الناتج) للشبكة وذلك كما يلي :

$$\begin{aligned} O &= 1 / (1 + e^{-N}) \\ &= 1 / (1 + e^{-1}) \\ &= -0.73106 \end{aligned}$$

4- مقارنة المخرج الفعلي (الناتج) مع المخرج المطلوب وعند اكتشاف خطأ بين المقارنتين ففي هذه الحالة فاننا نحتاج الى تعديل الاوزان وتحديد مقدار الخطأ وكما يلي :-

$$\begin{aligned} eo &= (T - O) * O * (1 - O) \\ &= (0 - (-0.73106)) * (-0.73106) * (1 - (-0.73106)) \\ &= -0.14373 \quad (\text{مقدار نسبة الخطأ بين المخرج المطلوب والمخرج الفعلي}) \end{aligned}$$

5- بعد اكتشاف الخطأ فانه سوف يتم تعديل الاوزان التي تربط بين طبقة المخرجات والطبقة الخفية وذلك بواسطة القوانين التالية :-

$$\begin{aligned} W10_{new} &= W10_{old} + a * eo * h3 \\ &= 1 + 1 * (-0.14373) * 0.5 \\ &= 0.92813 \end{aligned}$$

$$\begin{aligned} W20_{new} &= W20_{old} + a * eo * h4 \\ &= 1 + 1 * (-0.14373) * 0.5 \\ &= 0.92813 \end{aligned}$$

6- نستمّر على نفس الطريقة لكن هذه المرة بين الطبقة الخفية وطبقة المدخلات

$$\begin{aligned} eh1 &= h3(1-h3)*w10*eo \\ &= 0.5 (1-0.5) * 0.92813 * (-0.14373) \\ &= 0.03335 \\ eh2 &= h4(1-h4)*w20*eo \\ &= 0.5 (1-0.5) * 0.92813 * (-0.14373) \\ &= 0.03335 \end{aligned}$$

7- وبعد اكتشاف الخطأ يتم تعديل الاوزان وكما يلي:

$$\begin{aligned} W11_{new} &= W11_{old} + a * eh1 * X1 \\ &= 1 + 1 * 0.03335 * 0 \\ &= 1 \\ W12_{new} &= W12_{old} + a * eh2 * X1 \\ &= 0 + 1 * 0.03335 * 0 \\ &= 0 \end{aligned}$$

$$\begin{aligned} W21_{new} &= W21_{old} + a * eh1 * X2 \\ &= 0 + 1 * 0.03335 * 0 \\ &= 0 \\ W22_{new} &= W22_{old} + a * eh2 * X2 \\ &= 1 + 1 * 0.03335 * 0 \\ &= 1 \end{aligned}$$

ملاحظة // الاوزان الجديدة لم تتغير وذلك بسبب المدخلات الصفرية (x1 , x2) ولكن الوضع سوف يتغير مع بقية المدخلات .

* ربما تكون بعض النتائج غير مضبوطة ولكن المهم هو فهم عمل الخلية العصبية وكيفية تعاملها مع المدخلات والمخرجات .

*تتوقف عملية التدريب عندما تصبح النتيجة الناتجة من التدريب مطابقة إلى النتيجة الأصلية أي : $T=0$

امثلة:

سيتم عرض مثال مبسط عن عملية تدريب الشبكات العصبية، وادناه جدول يبين المدخلات والمخرجات المستعملة للتدريب الشبكة الانتشار العكسي.

x_1	x_2	Target (t)
0	0	0
0	1	1
1	0	1
1	1	1

الحل:

سيتم اختيار الأوزان عشوائياً ونبدأ باستعمال الصف الأول من جدول المدخلات والمخرجات وكما كوضح في الجدول الآتي:

x_1	x_2	t	W_{11}	W_{12}	W_{21}	W_{22}	W_{10}	W_{20}
0	0	0	1	0	0	1	1	1

وسنختار قيمة سرعة التعلم مساوية إلى 1 وعدد العقد في الطبقة المخفية مساوي إلى 2 وذلك لتسهيل العمليات الحسابية علماً بأن عدد العقد في طبقة المدخلات يساوي 2 وفي طبقة المخرجات يساوي 1.

تعريف مصطلحات رموز الشبكة العصبية الاصطناعية:

h_{i1} : مجموع المدخلات للعقدة أو الخلية الاولى في الطبقة المخفية.

h_{i2} : مجموع المدخلات للعقدة الثانية في الطبقة المخفية.


h_{i1} : مخرج العقدة الاولى في الطبقة المخفية.

h_{12} : مخرج العقدة الثانية في الطبقة المخفية.

S: مجموع المخلات لعقدة طبقة المخرجات

y: المخرج الفعلي للشبكة العصبية الاصطناعية

والمخطط الآتي يبين معمارية الشبكة العصبية الاصطناعية قيد الدرس.



ولحل هذه الشبكة نتبع خطوات الموضحة خوارزمية الانتشار العكسي وكذلك في غخطط التمرير الامامي والخلفي.

التمرير الامامي:

مجموع الاشارات التي تدخل لعقدة الاولى في طبقة المخفية. $h_{j1} = W_{11}X_1 + W_{21}X_2$

$$0 = 0 * 0 + 0 * 1 =$$

$$h_{j2} = W_{21}X_1 + W_{22}X_2$$

مجموع الاشارات التي تدخل لعقدة الثانية في طبقة المخفية.

$$= 1 * 0 + 0 * 0 = 0$$

$$h_{y1} = \frac{1}{1 + e^{-h_{i1}}} \\ = \frac{1}{1 + e^{-0}} = 0.5$$

مخرج العقدة الاولى في الطبقة المخفية

$$h_{y2} = \frac{1}{1 + e^{-h_{i2}}} \\ = \frac{1}{1 + e^{-0}} = 0.5$$

مخرج العقدة الثانية في الطبقة المخفية

مجموع الاشارات التي تدخل في عقدة طبقة المخرجات.

$$S = W_{10}h_{y1} + W_{20}h_{y2}$$

$$= 1 * 0.5 + 1 * 0.5 = 1$$

وبهذا يكون المخرج الفعلي للشبكة.

التمرير الخلفي:

المرحلة الأخرى هي تعديل أو تحديث الأوزان من خلال تحديد قيمة مقدار الخطأ.

$$\delta_k = E_k \cdot y_k (1 - y_k)$$

↓

$1_k - y_k$ Logistic function

$$\begin{aligned}\delta_k &= (0 - 0.73106)(0.73106)(1 - 0.73106) \\ &= -0.1437\end{aligned}$$

$$\begin{aligned}W_{10}(\text{new}) &= \eta \delta_k h_{y1} + \alpha w_{10} (\text{Old}) \\ &= (1)(-0.14373)(0.5) + (1)(1) \\ &= 0.92813\end{aligned}$$

$$\begin{aligned}W_{20}(\text{new}) &= \eta \delta_k h_{y2} + \alpha w_{20} (\text{Old}) \\ &= (1)(-0.14373)(0.5) + (1)(1) \\ &= 0.92813\end{aligned}$$

فيما سبق تم التراجع من طبقة المخرجات إلى الطبقة المخفية وسنستمر بتراجع باتجاه طبقة المدخلات من خلال تحديد قيمة الخطأ.

$$\begin{aligned}\delta_{h1} &= h_{y1} (1 - h_{y1}) \delta_k w_{10} \\ &= (0.5)(1 - 0.5)(0.92813)(-0.14373) \\ &= -0.03335\end{aligned}$$

$$\begin{aligned}\delta_{h2} &= h_{y2} (1 - h_{y2}) \delta_k w_{20} \\ &= (0.5)(1 - 0.5)(0.92813)(-0.14373) \\ &= -0.03335\end{aligned}$$

ويتم تعديل الأوزان الباقية كالآتي:

$$\begin{aligned} W_{11} &= W_{11} + \eta \delta_{h_1} x_1 \\ &= 1 - (1) (-0.03335) (0) \\ &= 1 \end{aligned}$$

$$\begin{aligned} W_{12} &= W_{12} + \eta \delta_{h_1} x_2 \\ &= 0 - (1) (-0.03335) (0) \\ &= 0 \end{aligned}$$

$$\begin{aligned} W_{21} &= W_{21} + \eta \delta_{h_2} x_1 \\ &= 0 - (1) (-0.03335) (0) \\ &= 0 \end{aligned}$$

$$\begin{aligned} W_{22} &= W_{22} + \eta \delta_{h_2} x_2 \\ &= 1 - (1) (-0.03335) (0) \\ &= 1 \end{aligned}$$

نلاحظ هنا بأن الأوزان لم تتغير وهذا طبيعي لان المدخلات كلها تساوي صفر ولكن سيتغير الوضع مع المدخلات الاخرى.

نتائج المرور الأول في عملية التدريب:

x_1	x_2	t	W_{11}	W_{12}	W_{21}	W_{22}	W_{10}	W_{20}
0	0	0	1	0	0	1	0.92813	0.92813

سنأخذ الان الصف الثاني من المعطيات ونكرر تدريب الشبكة باتباع نفس الاسلوب والخطوات حيث ان البيانات المستعملة في التدريب هي:

$$X_1=0, X_2=1, t=1$$

وباستعمال هذه القيم والأوزان التي تم الحصول عليها في المرحلة السابقة تكون نتائج

التدريب كالاتي:

نتائج المرور الثاني في عملية التدريب:

x_1	x_2	t	W_{11}	W_{12}	W_{21}	W_{22}	W_{10}	W_{20}
0	1	1	1	0	0.01054	1.00838	0.9503	0.96056

وتستمر عملية التدريب بتكرار نفس الخطوات مرات عدة حتى نحصل على اقل خطأ ممكن وبعد تكرار 1000 مرة نحصل على الأوزان المثلى وتكون النتائج الفعلية قريبة جداً من النتائج المطلوبة أو المستهدفة.

جدول الأوزان النهائية «المثلى»:

W_{11}	W_{12}	W_{21}	W_{22}	W_{10}	W_{20}
-3.5402	4.0244	-3.5248	4.5814	-11.9103	4.6940

اما النتائج الفعلية والمستهدفة بعد اتمام عملية التدريب فهي كالاتي:

x_1	x_2	Target (t)	Output (y)
0	0	0	0.0264
0	1	1	0.9867
1	0	1	0.9863
1	1	1	0.9908

نلاحظ من خلال المثال السابق صعوبة التدريب لا تكمن في فهمه أو في العمليات الحسابية بل في المجهود الذي تتطلبه خصوصاً مع تكرار العمليات 1500 مرة واحياناً

Example 8.1 Find the new weights when the network illustrated in Fig. 8.3 is presented the input pattern [0.6 0.8 0] and target output is 0.9. Use learning rate $\alpha = 0.3$ and use binary sigmoid activation function.




Fig. 8.3 A Backpropagation Net

Solution The solution to the problem is as follows:

Step 1: Initialize the weight and bias

$$W = [-1 \ 1 \ 2], W_0 = [-1]$$

$$v = \begin{bmatrix} 2 & 1 & 0 \\ 1 & 2 & 2 \\ 0 & 3 & 1 \end{bmatrix} V_0 = [0 \ 0 \ -1]$$

Step 3: For each training pair

$$X = [0.6 \ 0.8 \ 0]$$

$$t = [0.9]$$

Feed Forward Stage

Step 4:

$$Z_{-in j} = v_{oj} + \sum_{i=1}^n x_i v_{ij}$$

$$\Rightarrow Z_{-in1} = v_{o1} + \sum_{i=1}^3 x_i v_{i1}$$

$$\Rightarrow v_{o1} + x_1 v_{11} + x_2 v_{21} + x_3 v_{31}$$

$$\Rightarrow 0 + 0.6 \times 2 + 0.8 \times 1 + 0 \times 0$$

$$\Rightarrow 1.2 + 0.8 = 2$$

$$Z_{-in2} = v_{o2} + \sum_{i=1}^3 x_i v_{i2}$$

$$\Rightarrow v_{o2} + x_1 v_{12} + x_2 v_{22} + x_3 v_{32}$$

$$\Rightarrow 0 + 0.6 + 0.8 \times 2 + 0 \times 3$$

$$\Rightarrow 2.2$$

$$\begin{aligned}
 Z_{-in3} &= v_{o3} + \sum_{i=1}^3 x_i v_{i3} \\
 &\Rightarrow v_{o3} + x_1 v_{13} + x_2 v_{23} + x_3 v_{33} \\
 &\Rightarrow -1 + 0.6 \times 0 + 0.8 \times 2 + 0 \times 1 \\
 &\Rightarrow -1 + 1.6 = 0.6 \\
 z_1 &= f(z_{-in1}) = \frac{1}{1 + e^{-2}} = 0.8808 \\
 z_2 &= f(z_{-in2}) = \frac{1}{1 + e^{-2.2}} = 0.9002 \\
 z_3 &= f(z_{-in3}) = \frac{1}{1 + e^{-0.6}} = 0.646
 \end{aligned}$$

Step 5: Calculate Y_{-ink}

$$\begin{aligned}
 y_{-ink} &= w_{ok} + \sum_{j=1}^p z_j w_{jk} \\
 y_{-in1} &= w_{o1} + \sum_{j=1}^3 z_j w_{j1} \\
 &= w_{o1} + z_1 w_{11} + z_2 w_{21} + z_3 w_{31} \\
 &\Rightarrow -1 + 0.8808 \times -1 + 0.9002 \times 1 + 0.646 \times 2 \\
 &\Rightarrow -1 - 0.8808 + 0.9002 + 1.292 \\
 y_{-in1} &= [0.3114]
 \end{aligned}$$

Calculate the output signal

$$y_1 = f[y_{-in1}] = \frac{1}{1 + e^{-0.3114}} = 0.5772$$

Back Propagation of Error

Step 6: Calculate error information term δ_k .

$$\delta_k = (t_k - y_k) f^l(y_{-ink})$$

$$\delta_1 = (t_1 - y_1) f^l(y_{-in1})$$

we know that for binary sigmoid function

$$f^l(x) = f(x)(1 - f(x))$$

$$f^l(y_{-in1}) = f(y_{-in1})(1 - f(y_{-in1}))$$

$$= 0.5772 (1 - 0.5772)$$

$$= 0.2440$$

$$\delta_1 = (t_1 - y_1) f^l(y_{-in1})$$

$$\Rightarrow (0.9 - 0.5772)(0.2440)$$

$$= 0.0708$$

Step 7: Back propagation to be first hidden layer ($i = 1,2,3$) we have

To calculate δ_{-in1}

$$\delta_{-inj} = \sum_{k=1}^m \delta_k w_{jk}$$

$$\delta_{-inj} = \sum_{k=1} \delta_k w_{jk}$$

$$\delta_{-in1} \Rightarrow \delta_1 w_{11} \Rightarrow 0.0788 \times -1 = -0.0788$$

$$\delta_{-in2} = \delta_1 w_{21} = 0.0788 \times 1 = 0.0788$$

$$\delta_{-in3} = \delta_1 w_{31} \Rightarrow 0.0788 \times 2 = 0.01576$$

To calculate error term in hidden layer,

$$\Delta = \delta_{-inj} f^1(z_{-inj})$$

$$f^1(z_{-in1}) = f(z_{-in1}) (1 - f_{-in1})$$

$$\Rightarrow (0.8808)(1 - 0.8808)$$

$$= 0.1049$$

$$\Delta_1 = \delta_{-in1} f(z_{-in1}) (1 - f_{-in1})$$

$$\Rightarrow (-0.0788)(0.1049)$$

$$= -0.0083$$

$$\Delta_2 = \delta_{-in2} f^1(z_{-in2})$$

$$f^1(z_{-in2}) = f(z_{-in2})(1 - f_{zin2})$$

$$\Rightarrow (0.9002)(1 - 0.9002)$$

$$= 0.09$$

$$\Delta_2 = 0.0788 \times 0.09 \Rightarrow 0.0071$$

$$\Delta_3 = \delta_{-in3} f^1(z_{-in3})$$

$$f^1(z_{-in3}) = f(z_{-in3})(1 - f(z_{-in3}))$$

$$\Rightarrow (0.646)(1 - 0.646)$$

$$\Rightarrow 0.2286$$

$$\Delta_3 = 0.1576 \times 0.2286$$

$$= 0.0361$$

Step 8: Weight Updation

$$\Delta v_{ij} = \alpha \Delta_j x_i$$

$$x = [0.6 \ 0.8 \ 0]$$

$$\Delta = [-0.0083 \ 0.0071 \ 0.0361]$$

$$\alpha = 0.3$$

$$\Delta v_{11} = \alpha \Delta_1 x_1 = 0.3 \times -0.0083 \times 0.6 = -0.0015$$

$$\Delta v_{12} = \alpha \Delta_2 x_1 = 0.3 \times 0.0071 \times 0.6 = 0.0013$$

$$\Delta v_{21} = \alpha \Delta_1 x_2 = 0.3 \times -0.0083 \times 0.8 = -0.002$$

$$\Delta v_{22} = \alpha \Delta_2 x_2 = 0.3 \times 0.0071 \times 0.8 = 0.0017$$

$$\Delta v_{13} = \alpha \Delta_3 x_1 = 0.3 \times 0.0361 \times 0.6 = 0.0065$$

$$\Delta v_{23} = \alpha \Delta_3 x_2 = 0.0087$$

$$\Delta v_{31} = \Delta_{32} = \Delta v_{33} = 0$$

$$\Delta v_{01} = \alpha \Delta_1; \quad \Delta v_{02} = \alpha \Delta_2; \quad \Delta v_{03} = \alpha \Delta_3$$

$$\Delta v_0 = 0.3 \times -0.0023 \Rightarrow -0.0025$$

$$\Delta v_{02} = 0.3 \times 0.0071 \Rightarrow 0.0021$$

$$\Delta v_{03} = 0.3 \times 0.0361 \Rightarrow 0.0108$$

$$v_{\text{new}} = v_{\text{old}} + \Delta v_1$$

$$v_{11}(\text{new}) = v_{11}(\text{old}) + \Delta v_{11} = 2 - 0.0015 = 1.9985$$

$$v_{12}(\text{new}) = v_{12}(\text{old}) + \Delta v_{13} = 9 + 0.0013 = 1.0013$$

$$v_{13}(\text{new}) = v_{13}(\text{old}) + \Delta v_{13} = 0.1 + 0.065 = 0.065$$

$$v_{21}(\text{new}) = v_{21}(\text{old}) + \Delta v_{21} = 1 - 0.002 = 0.998$$

$$v_{22}(\text{new}) = v_{22}(\text{old}) + \Delta v_{22} = 2 + 0.0017 = 2.0017$$

$$v_{23}(\text{new}) = v_{23}(\text{old}) + \Delta_{23} = 2 + 0.0067 = 2.0087$$

$$v_{31}(\text{new}) = v_{31}(\text{old}) + \Delta_{31} = 0 + 0 = 0$$

$$v_{32}(\text{new}) = v_{32}(\text{old}) + \Delta_{32} = 3 + 0 = 3$$

$$v_{33}(\text{new}) = v_{32}(\text{old}) + \Delta_{33} = 1 + 0 = 1$$

$$\therefore v = \begin{bmatrix} 1.9985 & 1.0013 & 0.085 \\ 0.998 & 2.0017 & 2.0087 \\ 0 & 3 & 1 \end{bmatrix}$$

$$\Delta W_{ok} = \alpha \delta_k z_j$$

$$\Delta W_{11} = \alpha \delta_1 z_1 = 0.3 \times 0.0788 \times 0.8808 = 0.0208$$

$$\Delta W_{12} = \alpha \delta_1 z_2 = 0.3 \times 0.0788 \times 0.9002 = 0.0212$$

$$\Delta W_{13} = \alpha \delta_1 z_3 = 0.3 \times 0.0788 \times 0.646 = 0.0153$$

$$\Delta W_{11}(\text{new}) = w_{11}(\text{old}) + \Delta w_{11} = -1 + 0.0208 = 0.9792$$

$$\Delta W_{12}(\text{new}) = w_{12}(\text{old}) + \Delta w_{12} = 1 + 0.0212 = 1.0212$$

$$\Delta W_{13}(\text{new}) = w_{13}(\text{old}) + \Delta w_{13} = 2 + 0.0153 = 2.0153$$

$$\Delta W_0 = \alpha s_1 = 0.3 \times 0.0788 = 0.02364$$

$$w = [0.9792 \quad 1.0212 \quad 2.0153]$$

Thus the weights are calculated. The process can be continued upto any specified stopping condition.

H.W.

(4)

X_1	X_2	X_3	$Y = \text{target}$
5	4	9	1
0	2	1	0
5	3	7	1
1	3	1	0

$W = [1 \ 0 \ 1]$

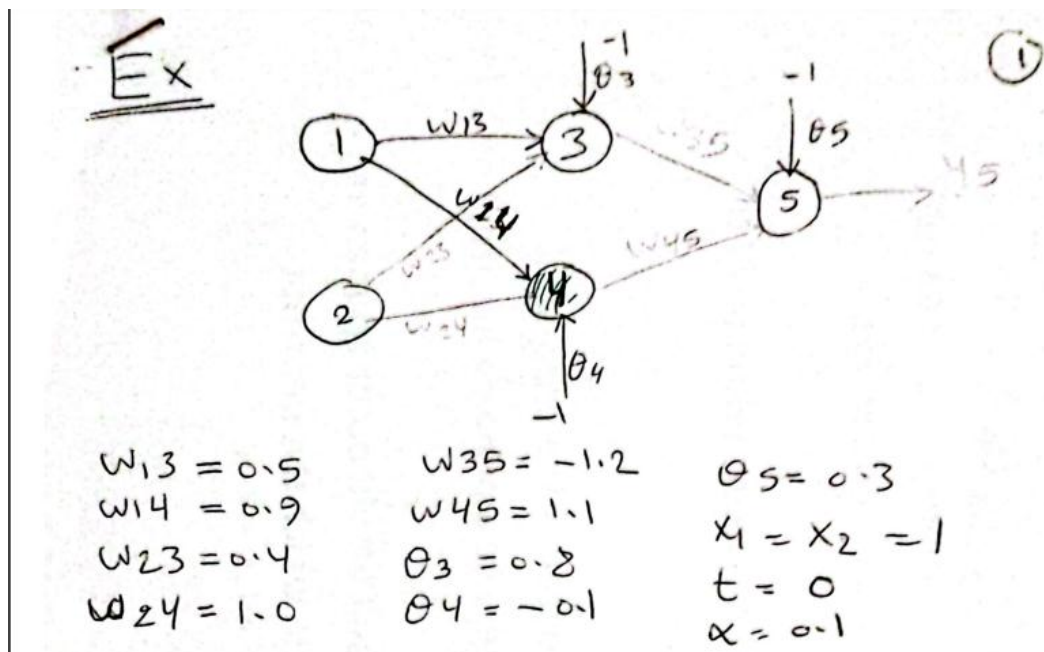
$b = 0$ غير ممكنة

$\alpha = 0.1$

$g = \begin{cases} 1 & , X > 0 \\ 0 & , X \leq 0 \end{cases}$

Solution: لا فرق إذا α لم يقرب بالوالمعنى $1 = 1$

H.W.



تقنيات ذكائية

د. عمر سالم

المرحلة الرابعة