إن لكل عصبون يحتوي على وصلة جمع تقوم بجمع الدخل المخزون مع الإزاحة لتشكيل المخرج العادي للعصبون وفي النتيجة ان مركبات مخرجات الطبقة وتحديداً طبقة العصبونات تشكل شعاع الإخراج وعاده ما تكون عبارة عن مصفوفة من عامود واحد حيث ان مركبات الشعاع الداخل الى الشبكة من خلال مصفوفة من الاوزان ممثلة بالشكل الاتي:

$$W = \begin{array}{c} \text{المدخلات} \\ \downarrow \end{array} \begin{bmatrix} W_{11} & W_{12} & \cdots & W_{1n} \\ W_{21} & W_{22} & \cdots & W_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ W_{s1} & W_{s2} & \cdots & W_{sn} \end{bmatrix} \leftarrow \text{الهـدف}$$

ان مؤشرات السطر لعناصر هذه المصفوفة تدل على العصبون الهدف أما مؤشرات العمود تدل على مركبات الدخل أو المصدر اي ان المؤشرات في العنصر وليكن العنصر (W_{12}) يدل على ان هذا الوزن يتعلق بالعصبون الاول وان مركبة الدخل كانت متجهة الى العصبون في الطبقة الثالثة.

ان الشبكة العصبونية تتكون (تتألف) من طبقة واحدة او عدة طبقات وفي هذه الحالة يكون لكل حالة مصفوفة (وزن) (W) وشعاع إزاحة يرمز له (B) وشعاع اخراج يرمز له بالرمز (A) ويلاحظ ان الشبكة متعددة الطبقات هي شبكات ذات فعالية كبيرة وخاصة الشبكات التي تظم طبقتين وهي الأكثر شيوعاً واستخداماً اذ تستطيع هذه الشبكات من حل العديد من المشاكل المعقدة ولكن يعاب عليها انها تستغرق وقت طويـــل.

شبكة المدرك الحسي

إن الشكل العام لشبكة المدرك كما يلي:

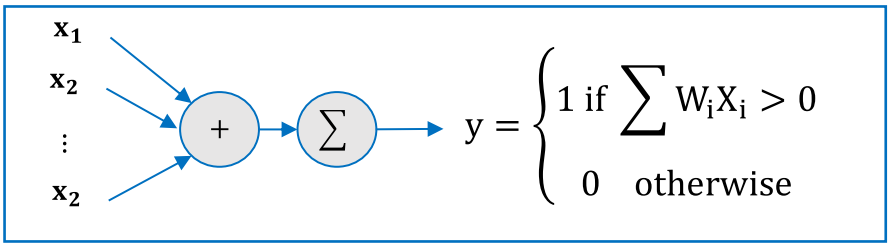

ان وحدة المدرك الحسي الممثلة في هذا التمثيل المبسط يمكنها معالجة معظم العمليات المنطقية مثل عمليات $[And\ ,or]$ في العمليات الإيجابية و $[\ NAnd\ ,\ Nor]$ في العمليات السلبية. وتتم عملية التدريب على بعض المدخلات والمخرجات المرغوبة من خلال تعديل الاوزان وحسب القاعدة التاليـــة:

$$W_i\ new = W_i\ old + \alpha(y - \hat{y})X_i$$

حيث أن (W_i) تمثل الاوزان و (y) تمثل المخرج او المخرجات و (X_i) تمثل الادخال و تمثل (α) سرعة التعلم او معدل التعلم.

مثال: إذا كان لدينا عدد من المدخلات بمقدار (2) فما هو المخرج لهذه المدخلات؟

X_1	X_2	y	W_1	W_2	$\hat{y}$	error	W_1new	W_2new
0	0	0	0	0	0	0	0	0
0	1	1	0	0	0	1		
1	0	1	0	1	1	0		
1	1	1	1	1	1	0		

وعند تدريب شبكة المدرك الحسي وفقاً للعمليات المنطقية ولتكن [او] او [or] عندها [or] يكون اختيار الاوزان عشوائياً ولتكن قيمتها مساوية الى [الصفر] في البداية وقيمة الفا (α) تساوي [الواحد] ويتم تحديث الأوزان وفقاً للقاعدة السابقة وعلى النحو الاتـــي:

$$W_1\text{new} = W_1\text{old} + \alpha(y - \hat{y})X_1$$

$$W_2\text{new} = W_2\text{old} + \alpha(y - \hat{y})X_2$$

وتستمر عملية التدريب مع تكرار تحديث الأوزان حتى تستقر الأوزان عند قيم معينة لا تغيير بعدها ويتم حساب المخرجات حسب القاعدة السابقة:

$$y = \begin{cases} 1 \text{ if } \sum W_i X_i > 0 \\ 0 \quad \text{otherwis} \end{cases}$$

يُلاحظ مما سبق أن وحدة المدرك الحسي لها قدرة كبيرة في معالجة المشاكل البسيطة التي تُعنى بالتصنيف والتجزئة وان العملية المنطقية [او (or)] تمثل وضع حد فاصل بين مجموعتين مفصولتين اصلاً. وان عملية التدريب لا تتعدى البحث على هذا الحد الفاصل من خلال اختيار اوزان الترابط.

وبعد اكتشاف عدم مقدرة استعمال الخلية الواحدة لهذه القيم لذا يجب (يتم اللجوء) الى فصل عملية (او بطريقه غير خطية) وبذلك ظهرت طريقة استعمال اكثر من خلية لتكوين شبكة متكاملة من هذه الخلايا.

لذا اقترح انواع متعددة من هذه الشبكات اهمها الشبكات ذات التغذية الأمامية التي بدورها تسمح للإشارة بالانتقال الى الامام فقط من المدخلات الى المخرجات ومن ثم اضافة طبقة جديدة وهي الطبقة المخفية (تعريف) وسميت هذه الطبقة بالطبقة المخفية [كونها لا تتصل بالمحيط الخارجي ومرتبطة فقط بالطبقة التي قبلها والطبقة التي بعدها] بينما طبقتي المدخلات والمخرجات تتصل بالمحيط الخارجي وتتكون هذه الطبقات بعد من العقد او الخلايا التي يرمز لها دائما بالرسم على شكل دائرة للتبسيط.

تعريف بعض المصطلحات لشبكات العصبية الاصطناعية:

1- المدخلات: المتغيرات المستقلة او المتغيرات التوضيحية.

2- المخرجات: وتمثل القيم المتنبئ بها.

3- الأهداف: وتمثل احصائيات المتغيرات التابعة.

4- **الأخطاء**: تُمثل قيم البواقي ما بين قيمة المُخرج الحقيقي والقيمة المُتنبئ بها.

5- **التدريب**: وهو يمثل قيمه التقدير.

6- **الأنماط (النمط) أو أزواج التدريب**: وهي عادة تُمثل القيم الحقيقية للمشاهدات.

7- **أوزان المشبك**: وتُمثل إحصائياً قيم تقدير المعلمات (المعلمة).

EX1: if $X = [100 \quad 200]$ solve this vector to find the output resalt.

X_1	X_2	y	W_1	W_2	$\hat{y}$	error	W_1new	W_2new	$\hat{y}$	error
100	200	1	0	0	0	1	1	1	1	0
200	100	1	1	1	1	0	1	1		
200	200	1	1	1	1	0	1	1		
100	100	1	1	1	1	0				

1) $y = \sum X_i = X_1 + X_2 \Rightarrow (100 + 200) = 300 > 0 = 1$

$W_1 = 0 , W_2 = 0$

$\hat{y} = f \sum W_i X_i = f(W_1X_1 + W_2X_2) \Rightarrow f(0 * 100 + 0 * 200) = f(0) = 0$

$error = y - \hat{y} \Rightarrow 1 - 0 = 1$

$W_1new = W_1old + \alpha(y - \hat{y})X_1 \Rightarrow 0 + 1(1)100 = 100 > 0 = 1$

$W_2new = W_2old + \alpha(y - \hat{y})X_2 \Rightarrow 0 + 1(1)200 = 200 > 0 = 1$

$\hat{y} = f(W_1X_1 + W_2X_2) \Rightarrow f(1 * 100 + 1 * 200) = f(300) > 0 = 1$

$error = y - \hat{y} \Rightarrow 1 - 0 = 1$

2) $y = \sum X_i = X_1 + X_2 \Rightarrow (200 + 100) = 300 > 0 = 1$

$\hat{y} = f \sum W_i X_i = f(W_1X_1 + W_2X_2) \Rightarrow f(1 * 200 + 1 * 100) = f(300) > 0 = 1$

$error = y - \hat{y} \Rightarrow 1 - 1 = 0$

$W_1new = W_1old + \alpha(y - \hat{y})X_1 \Rightarrow 1 + 1(0)200 = 1$

$W_2new = W_2old + \alpha(y - \hat{y})X_2 \Rightarrow 1 + 1(0)100 = 1$

3) $y = \sum X_i = X_1 + X_2 \Rightarrow (200 + 200) = 400 > 0 = 1$

$$\hat{y} = f\sum W_i X_i = f(W_1X_1 + W_2X_2) \Longrightarrow f(1 * 200 + 1 * 200) = f(400) > 0 = 1$$

$$error = y - \hat{y} \Longrightarrow 1 - 1 = 0$$

$$W_1 new = W_1 old + \alpha(y - \hat{y})X_1 \Longrightarrow 1 + 1(0)200 = 1$$

$$W_2 new = W_2 old + \alpha(y - \hat{y})X_2 \Longrightarrow 1 + 1(0)200 = 1$$

4) $$y = \sum X_i = X_1 + X_2 \Longrightarrow (100 + 100) = 200 > 0 = 1$$

$$\hat{y} = f\sum W_i X_i = f(W_1X_1 + W_2X_2) \Longrightarrow f(1 * 100 + 1 * 100) = f(100) > 0 = 1$$

$$error = y - \hat{y} \Longrightarrow 1 - 1 = 0$$

$$W_1 new = W_1 old + \alpha(y - \hat{y})X_1 \Longrightarrow 1 + 1(0)100 = 1$$

$$W_2 new = W_2 old + \alpha(y - \hat{y})X_2 \Longrightarrow 1 + 1(0)100 = 1$$