


ذكاء صناعي 2

محاضرة 3

Artificial Neural Networks

د. فادي متوج

Artificial Neural Networks




- ❑ الشبكات العصبية الاصطناعية هي نماذج حسابية تهدف لمحاكاة عمل الشبكات العصبية البيولوجية في الدماغ البشري.
- ❑ تتألف الشبكات العصبية الاصطناعية من عناصر معالجة بسيطة متصلة فيما بينها تدعى **عصبونات neurons**.
- ❑ ينجز كل عصبون مهمة حسابية بسيطة لكن السلوك الكلي للشبكة يتحدد من خلال الاتصال بين مختلف هذه العناصر.

Advantages of Neural Networks

- لا تحتاج إلى البرمجة بل تتعلم من خلال الأمثلة.
- **تتميز بخاصية التعميم (Generalization)** : أي يمكن تطبيق الشبكة العصبونية على معطيات جديدة لم يتم تعلمها مسبقاً (أي على معطيات لم تستخدم خلال عملية التعلم وتدريب الشبكة العصبونية).
- **قادرة على تحمل الخطأ (fault tolerant)** : يمكن أن تنتج خرجاً صحيحاً من معطيات غير كاملة وتحتوي على ضجيج، في حين أن أجهزة الكمبيوتر التقليدية تتطلب عادة معطيات صحيحة.
- **سريعة** : حيث أن العصبونات المتصلة فيما بينها تعمل على التفرع
- عند التلف، فإنها تفشل بطريقة تدريجية، على عكس أجهزة الكمبيوتر التتابعية التي يمكن أن تفشل بشكل كارثي بعد فشل أحدها.

Disadvantages of Neural Networks

- Neural networks have *no model* of the universe in which they work.
- Whereas neural networks work well for inputs reasonably similar to their training data, they may give completely unpredictable outputs outside this region.
- Although they require no programming, a considerable effort may go into the **pre-processing and post-processing subsystems** to a neural network.
- Much of the knowledge about neural networks is empirical.



A typical neural network between a
preprocessor and a **postprocessor**.

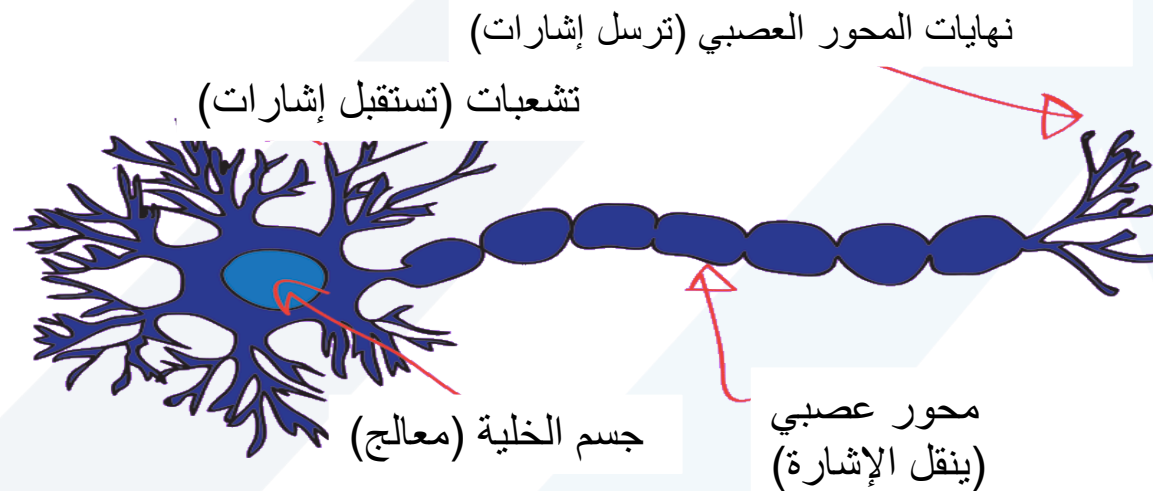
Applications of Neural Networks

- Systems which detect explosives at airport gates;
- Character recognition and document reading systems;
- Robot vision systems;
- Speech understanding systems, e.g. telephone systems which can recognize and distinguish between words such as *yes, no, one, two, three, etc.*;
- Financial investment systems.
- Control
- Functions Approximation
- Modeling

Biological and Artificial Neural Networks

- الشبكة العصبونية الاصطناعية هي محاكاة متواضعة بفعالها و شكلها و مضمونها للشبكة العصبونية الحيوية الموجودة في دماغ الإنسان
- حتى نفهم كيف تعمل شبكة عصبونية اصطناعية يجب ان نلقي نظرة على كيفية عمل الشبكة العصبونية البيولوجية.

- أدمغتنا مكونة من حوالي 100 مليار وحدة صغيرة تسمى الخلايا العصبية *neurons*.
- تتصل الخلايا العصبية مع بعضها البعض بوصلات عصبية و تتواصل مع بعضها عبر إشارات كهروكيميائية
- هذه الخلايا يثبت عددها في المراحل الأولى من عمر الإنسان لكن الذي يتغير هو عدد الوصلات العصبية إما بالزيادة أو بالنقصان مع تقدم العمر
- تتألف الخلية العصبية الطبيعية من ثلاثة مكونات رئيسية: زوائد عصبية و نواة و محور (غمد)



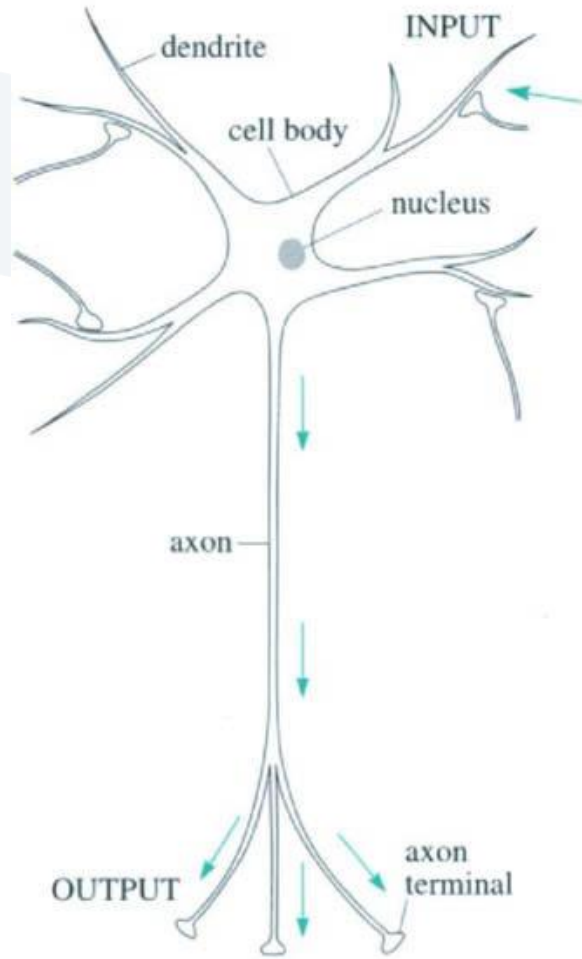
1. تشعبات (زوائد عصبية) *dendrites* :

- تستقبل إشارات الدخل من الخلايا الأخرى وتلك الإشارات ما هي إلا سيالة كهربائية.
- كل اتصال بين عصبون و آخر تسند له قيمة تدعى الثقل (الوزن) Weight تعبر عن مدى قوة و أهمية الارتباط بين هذين العنصرين

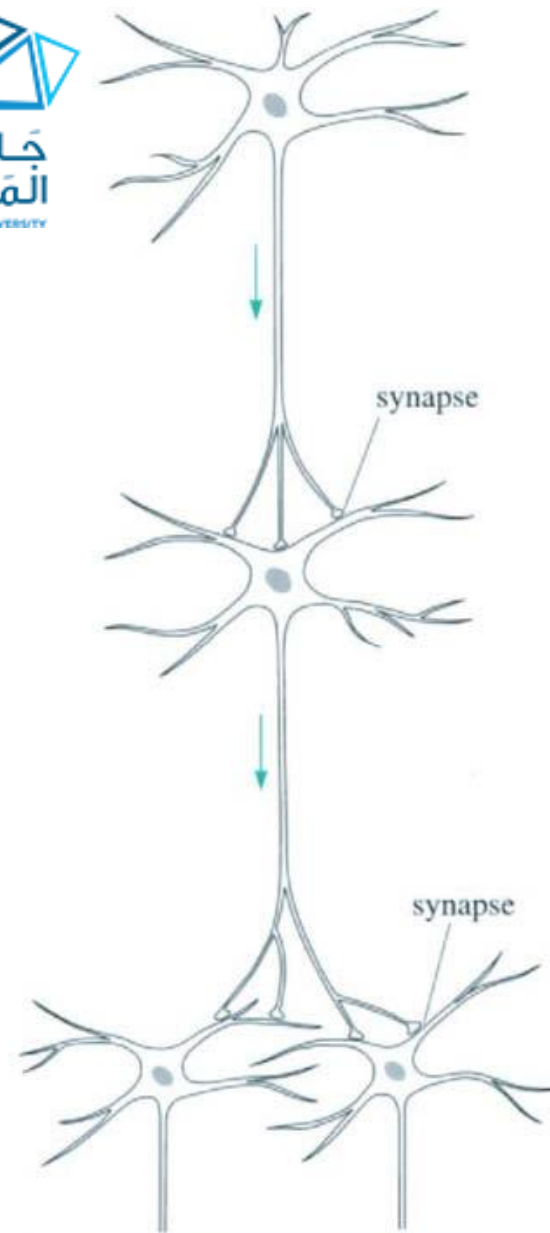
2. جسم الخلية العصبية :

- يقوم بضرب كل قيمة دخل واردة من العصبونات الأخرى بأوزان الاتصالات مع هذه العصبونات, وهذه المعالجة تعدل من قيم الإشارات الواردة
- ثم يقوم بجمع نواتج الضرب جميعا وتسمى هذه العملية بعملية الجمع المثلث (الموزون)
- إذا كان الجهد الناتج عن جمع تلك الإشارات أكبر من حد معين يسمى عتبة التفعيل عندها يتم إثارة الخلية العصبية وتعطي إشارة خرج

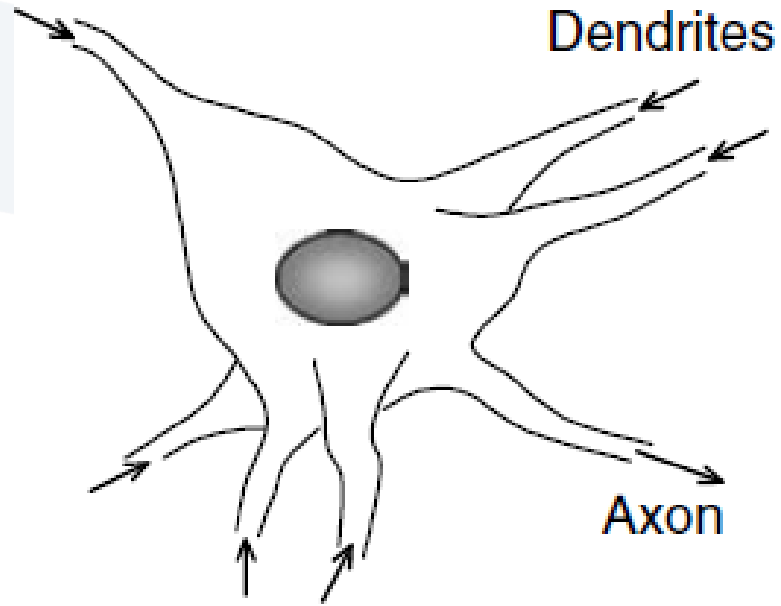
3. محور عصبي : يرسل إشارة الخرج إلى الخلايا العصبية الأخرى المتصلة معه




(a) A single neuron



(b) Neurons connected at synapses



تمثل العملية الحسابية في العصبون بالنموذج
المبين بالشكل والذي فيه الإشارات تستقبل،
تجمع (Σ) في جسم الخلية و تعالج بعد ذلك
لتنتج إشارة خرج $f(\Sigma)$





جامعة
المنارة
MANARA UNIVERSITY

Artificial Neuron

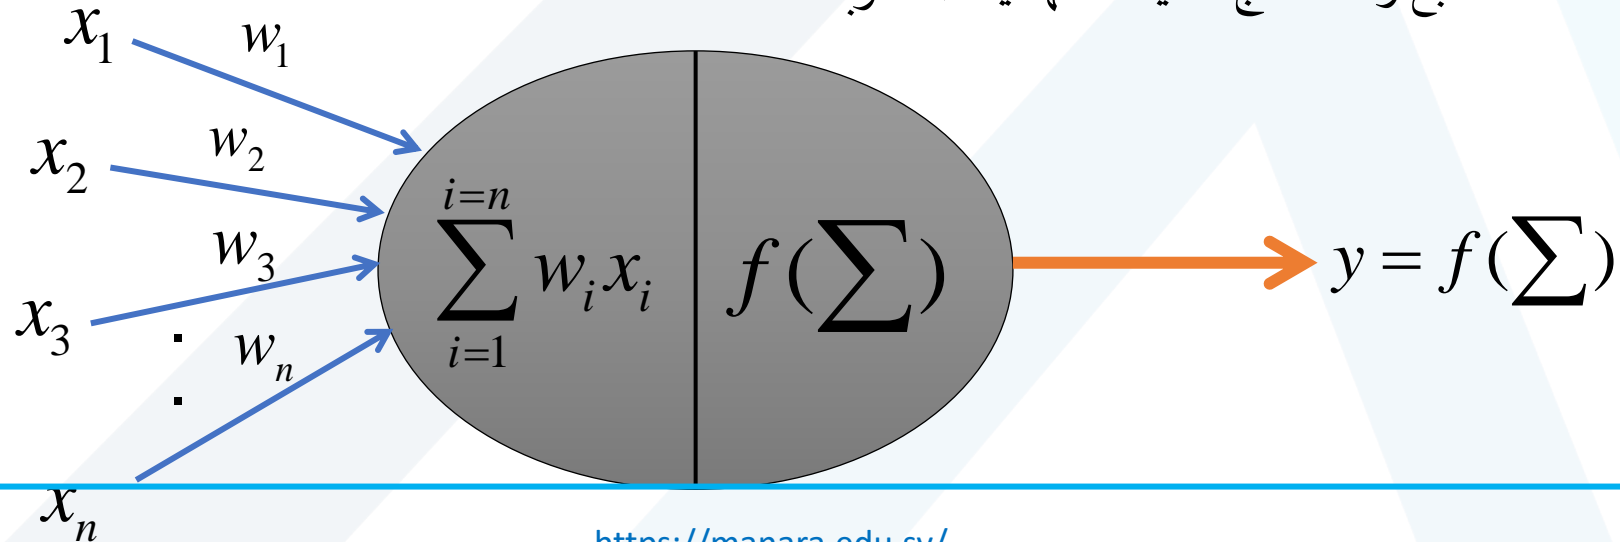
• يتكون كل عصبون اصطناعي من ثلاثة أقسام رئيسية هي :

- الدخل

- الأوزان w : وهو وزن أو عامل تثقيل لكل خلية عصبية اصطناعية وهو عبارة عن رقم حقيقي يمكن أن يكون موجب, سالب أو صفر.


- الجامع \sum : وهو عبارة عن حاصل جمع وزن كل خلية مضروبة بالدخل.

- تابع التفعيل (تابع التحويل): وهو عبارة عن تابع لمعالجة إشارة الخرج بحيث تمر هذه الإشارة من خلال هذا التابع ومنه تنتج القيمة النهائية المطلوبة.




Artificial Neuron with Bias

- لضمان عمل العصبون بشكل صحيح هناك دخل ثابت $x_0 = 1$ يطلق عليه إزاحة (offset) أو انحياز (bias)
- القيمة b تعامل معامل الأوزان حيث يتم إيجادها خلال عملية التدريب



Activation Functions


• تابع الحد الفاصل Hard-Limiting



$$y = 0 \quad \text{if} \quad x < 0$$

$$y = 1 \quad \text{if} \quad x \geq 0$$

• تابع Log sigmoid



$$y = \frac{1}{1 + e^{-x}}$$


يقع في المجال $[0,1]$

when $x = 0, y = 0.5$

when $x > 0, 1 > y > 0.5$


when $x < 0, 0.5 > y > 0$

• تابع الظل القطعي Hyperbolic tangent function



$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

يقع في المجال $[-1,1]$



$$y = x$$

• التابع الخطي

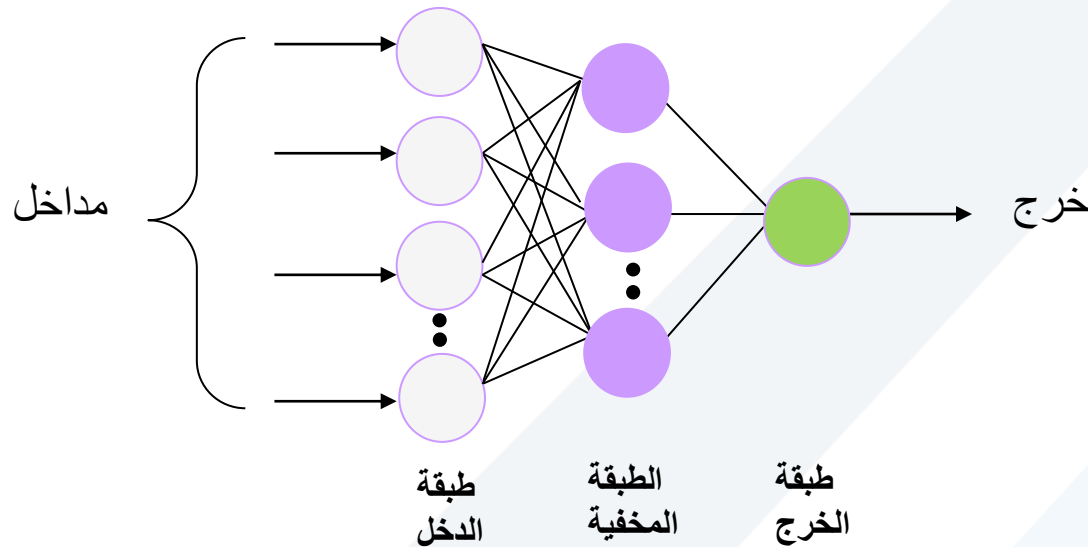
Network Topology

- طبولوجيا الشبكة هي الطريقة التي ترتبط بها العصبونات مع بعضها البعض لتشكل الشبكة.
- تتكون كل شبكة عصبية عادةً من ثلاث طبقات هي:

1. طبقة الدخل input layer

2. الطبقة المخفية hidden layer

3. طبقة الخرج output layer



- طبقة الدخل لا تقوم بأي عملية معالجة فهي ببساطة مكان تغذية الشبكة بشعاع البيانات ، تقوم طبقة الدخل بعد ذلك بتغذية (نقل المعلومات) الطبقة المخفية و من ثم تقوم الطبقة المخفية بتغذية طبقة الخرج.
- المعالجة الفعلية للبيانات Data تتم في الطبقة المخفية و طبقة الخرج.
- عندما يكون هناك عدد كاف من العصبونات في كل طبقة ، تكون الشبكة قادرة على التدريب training للقيام بأشياء مفيدة بالاستعانة بخوارزميات التدريب training algorithms

الشبكات ذات التغذية الأمامية

Feedforward Networks

- الشبكات العصبونية أمامية الانتشار هي إحدى أشهر أنواع الشبكات العصبونية، ويحدث فيها انتقال المعلومات عبر الطبقات باتجاه وحيد من طبقة الدخل إلى الطبقة المخفية إلى الطبقة النهائية.
- ترتبط العصبونات مع بعضها بحيث يرتبط كل عصبون في طبقة ما بجميع العصبونات في الطبقة التالية (لا ترتبط عصبونات نفس الطبقة مع بعضها).
- يضم هذا النوع من الشبكات العصبونية نوعين :

1. الشبكات ذات التغذية الأمامية أحادية الطبقة (Perceptron)

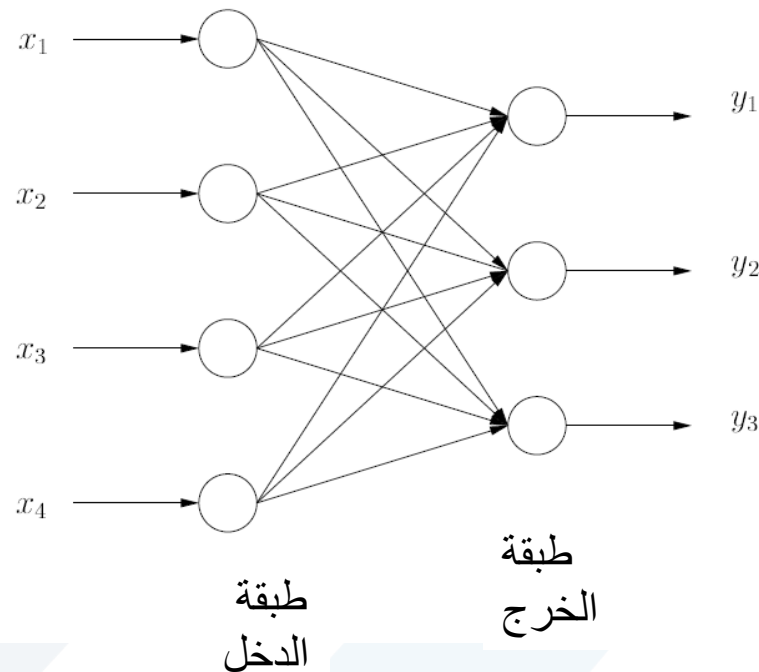
2. الشبكات ذات التغذية الأمامية متعددة الطبقات (Multi Layer Perceptron)



جامعة
المنارة
MANARA UNIVERSITY

Perceptron

- **البيروسيبترون** إحدى أبسط أنواع الشبكات العصبية أمامية التغذية حيث لا تحتوي على طبقة عصبونات مخفية بل تنتقل المعلومات المدخلة من طبقة الدخل إلى طبقة الخرج مباشرة






جامعة
المنارة
MANARA UNIVERSITY

Multi-layered perceptron (MLP)

- تتميز هذا النوع من الشبكات بوجود طبقة مخفية واحدة أو أكثر
- الشبكات الأكثر استخداماً ضمن هذه الفصيلة هي **البيرسيترون متعدد الطبقات** Multi-layered perceptron (MLP)



Neural Network Learning

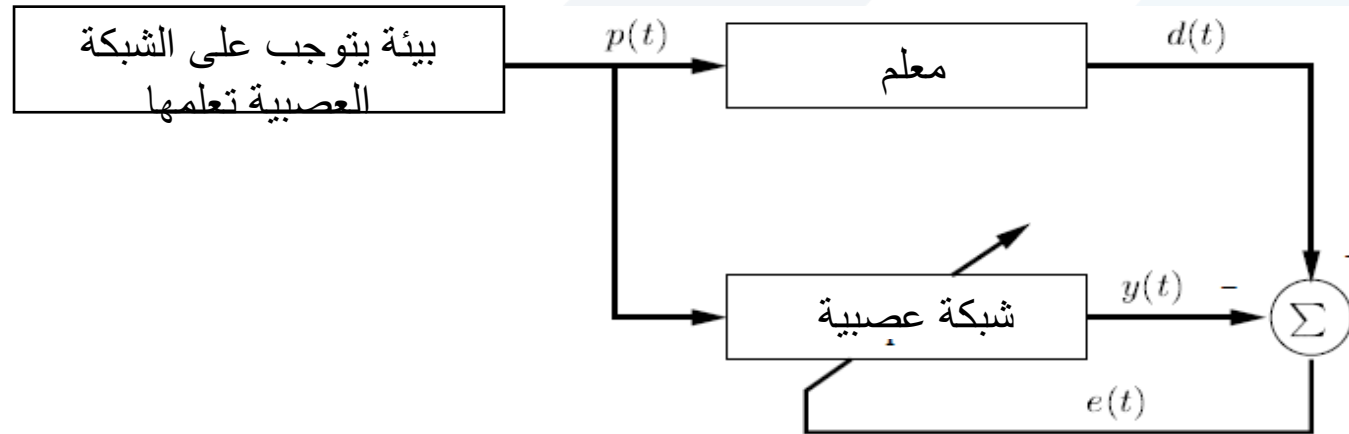
- من بين الخصائص الهامة للشبكات العصبونية هي قدرتها على تعلم بيئتها وتحسين كفاءتها من خلال عملية **التدريب**
- خلال عملية التدريب تقوم الشبكة **بتعديل مستمر** للأوزان (الأثقال w) المرتبطة بكل عصبون, حيث يشكل تعديل الأوزان محور عملية التعلم للشبكة العصبية.
- بعد كل تعديل للأوزان يقترب خرج الشبكة أكثر فأكثر من قيمة الخرج الحقيقية.
- تستمر عملية التدريب على كل المعطيات المتوفرة وتعديل الأوزان المرتبطة بكل عصبون حتى يصبح خرج الشبكة أقرب ما يمكن للواقع.
- يطلق على مجموع الخطوات المكونة لعملية التدريب **بخوارزمية التدريب learning algorithm**

طرق تعليم الشبكة العصبونية

- تتعلم الشبكة عن طريق إعطائها مجموعة من الأمثلة، التي يجب أن تكون مختارة بعناية، لأن ذلك سيساهم في سرعة تعلم الشبكة. ومجموعة الأمثلة هذه تسمى **مجموعة معطيات التدريب**.
- يمكن تمييز طريقتين رئيسيتين لتعليم شبكة عصبونية هما:
- **التعليم المراقب (بوجود معلم) Supervised Learning**
- **التعليم غير المراقب (بدون معلم) Unsupervised learning**

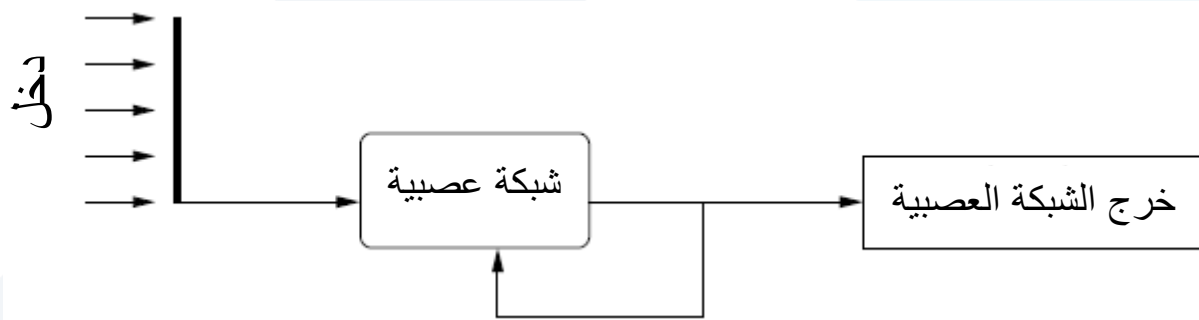
التعليم المراقب (بوجود معلم) Supervised Learning

- تقوم كل طرق التعليم أو التدريب بواسطة معلم للشبكات العصبونية الاصطناعية على فكرة عرض البيانات التدريبية أمام الشبكة على شكل مجموعة أزواج (دخول , خرج مستهدف)
- الخرج المستهدف هو الخرج المرغوب المثالي الذي يجب أن تنتجه الشبكة من أجل دخل محدد



التعليم غير المراقب (بدون معلم) Unsupervised Learning

- في هذه الطريقة تكون معطيات التدريب عبارة عن شعاع الدخل فقط دون عرض الهدف (الخرج المطلوب) على الشبكة، وتسمى هذه الطريقة التعليم الذاتي حيث تبني الشبكات العصبية الاصطناعية أساليب التعليم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من أشكال وأنساق وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض أمثلة لما يجب عليها أن تنتجه وذلك على عكس المبدأ المتبع في أسلوب التعليم بواسطة معلم



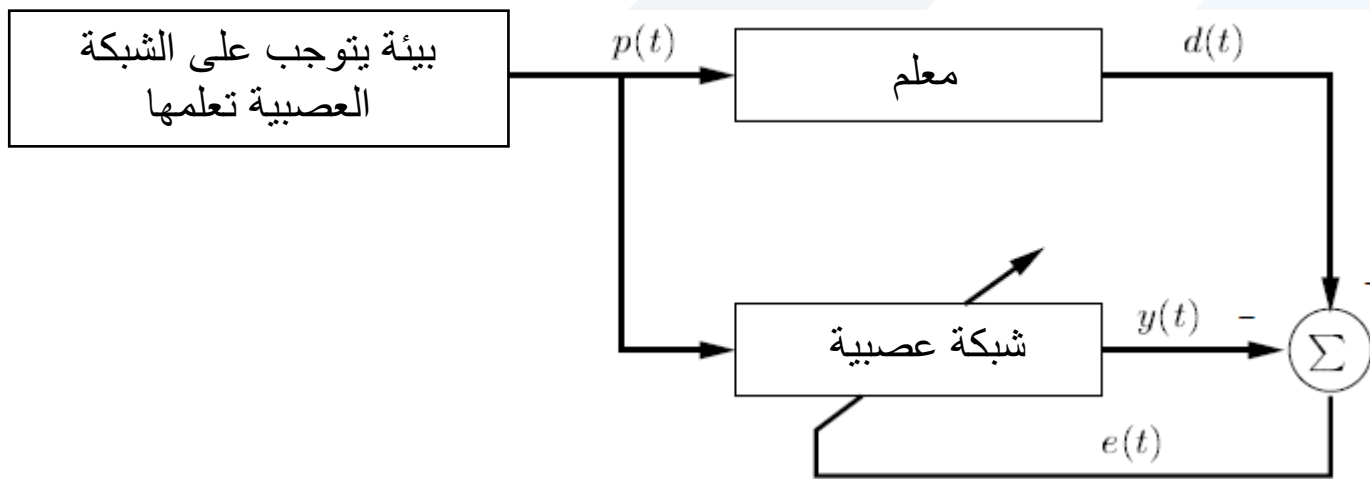
التعليم المر اقب (بوجود معلم) Supervised Learning



جامعة
المنارة
MANARA UNIVERSITY

التعليم المراقب (بوجود معلم) Supervised Learning

- سمي بالتعليم المراقب لأن الشبكة العصبية تحتاج أثناء التدريب إلى مراقب (معلم) ليبين لها الخرج المطلوب المقابل لكل دخل $p(t)$
- مع مقارنة الخرج الفعلي $y(t)$ مع الخرج المطلوب $d(t)$ تحاول الشبكة العصبية **تحديث (تعديل)** الأوزان Weights لتصل في النهاية إلى النتيجة الصحيحة و التي لا تحتاج بعدها لا إلى التدريب ولا إلى هذا الإشراف الخارجي



التعليم المراقب (بوجود معلم)

Supervised Learning

- تستعمل هذه الطريقة التدريبية مع الشبكات ذات التغذية الأمامية (Feedforward Networks)

التعليم المراقب (بوجود معلم) Supervised Learning

يمكن أن نعرف تابع يسمى **تابع الخطأ** أو **تابع الكلفة** Cost Function أو **تابع الأداء** performance Function لتحديد الفرق بين الخرج الفعلي للشبكة و الخرج المطلوب

$$E(W) = \frac{1}{2} \sum_k (d_k - y_k)^2$$

حيث :

W شعاع الأوزان

y_k خرج عصبون الخرج k

d_k الخرج المرغوب على خرج العصبون k

$$E(W) = \frac{1}{2} \sum_k (d_k - y_k)^2$$

- تم الضرب بـ $\frac{1}{2}$ فقط لتسهيل الحسابات الرياضية
- التربيع يجعل الخطأ موجب و يبرز أثر الأخطاء الكبيرة
- أهم المواصفات التي يجب أن تتوفر في هذا التابع هي أن يكون **قابلاً للاشتقاق** بالنسبة للأوزان

مبدأ خوارزميات التدريب المراقب

- التوضع في نقطة ابتدائية على سطح تابع الخطأ (اختيار قيم عشوائية للأوزان W)
- إيجاد **اتجاه** انحدار (تناقص) تابع الخطأ في فضاء المتحولات W
- **تعديل** الأوزان في هذا الاتجاه أي الانتقال خطوة واحدة في هذا الاتجاه حيث نصل لنقطة جديدة
- نكرر هذا الإجراء حتى يتحقق شرط توقف عملية التدريب
- حيث يتم تعديل الأوزان في الدور $k+1$ وفق العلاقة :

$$W_{k+1} = W_k + \eta D$$




η سرعة التعلم (معدل التعلم)

$$W_{new} = W_{old} + \Delta W_{old}$$

D اتجاه انحدار (تناقص) تابع
الخطأ التربيعي



جامعة
المنارة
MANARA UNIVERSITY



خوارزمية الإنحدار التدرجي Gradient Descent

- هي خوارزمية تقترب من القيمة الصغرى المحلية local minimum لتابع الخطأ وذلك من خلال الانتقال بخطوات متناسبة مع **الاتجاه المعاكس لتدرج تابع الخطأ**.
- أي لإنقاص تابع الخطأ يتم تعديل الأوزان بالاتجاه المعاكس للتدرج (gradient). أي بالاتجاه:

$$D = -\nabla E(W_k) = -\frac{\partial E}{\partial W}$$

- وتصبح علاقة تعديل الأوزان كما يلي:

$$W_{k+1} = W_k - \eta \nabla E(W_k)$$

∇ : التدرج

$$\Delta W_k$$

فهم التدرج Gradient

- التدرج هو معدل تغير تابع وهو عبارة عن **شعاع** يشير إلى **اتجاه الازدياد الأعظمي** للتابع
- التدرج هو مشتق تابع لأكثر من متحول
- إن التدرج لا يعطينا إحداثيات النقطة التي يجب الانتقال إليها، بل يعطينا **اتجاه** الانتقال بحيث يزداد التابع لدينا.
- التدرج هو مجرد اتجاه، حيث نتحرك قليلا في هذا الاتجاه، ومن ثم نحسب التدرج مرة أخرى
- التدرج صفر يعني أننا وصلنا إلى القيمة العظمى للتابع



جامعة
المنارة
MANARA UNIVERSITY



$$F(x, y, z) = x + y^2 + z^3$$

$$\text{grad}F(x, y, z) = \nabla F(x, y, z) = \left(\frac{dF}{dx}, \frac{dF}{dy}, \frac{dF}{dz} \right) = (1, 2y, 3z^2)$$

$$\text{direction} = (1, 2(4), 3(5)^2) = (1, 8, 75)$$

هناك طريقتان لحساب الإنحدار التدريجي :

• النظام التزايدى : Incremental Mode

يتم وفق هذه الطريقة حساب التدرج ومن ثم تعديل الأوزان بعد كل دخل يعطى للشبكة.

• نظام الدفعة الواحدة : Batch Mode

وفق هذا النمط تزود الشبكة بكل أشعة الدخل قبل القيام بعملية تحديث الأوزان حيث يتم تعديل الأوزان في هذه الطريقة بعد تزويد الشبكة بكامل مجموعة التدريب

طريقة الانتشار الخلفي للخطأ

Error Back propagation

- و تتكون هذه العملية من الخطوات التالية :
- إعطاء أوزان عشوائية للوصلات بين عصبونات الشبكة
 - تغذية الشبكة بإحدى المعطيات المعدة للتدريب
 - تطبيق عملية الانتشار الأمامي لتحديد خرج الشبكة العصبية
 - مقارنة الخرج الفعلي (خرج الشبكة) مع الخرج المطلوب و تحديد قيمة الخطأ
 - التراجع بالخطأ عبر الشبكة و تصحيح الأوزان في الاتجاه الذي يضمن تصغير قيمة الخطأ و من هنا جاءت تسمية **الانتشار الخلفي**

خوارزميات تدريب أخرى

1. خوارزمية Quasi-Newton
 2. خوارزمية التدرج المترافق Conjugate Gradient
 3. خوارزمية Levenberg-Marquardt
- هي خوارزميات محسنة عن خوارزمية الإنحدار التدريجي.
 - تختلف هذه الخوارزميات من حيث سرعة التنفيذ و مقدار خطأ التدريب وحجم الذاكرة المستخدمة لإجراء الحسابات على الحاسب
 - أفضل هذه الخوارزميات هي خوارزمية **Levenberg-Marquardt**

مرحلة اختبار الشبكة العصبونية المدربة

- اختبار الشبكة مشابه تماماً لعملية التعليم إلا أن الشبكة في هذه المرحلة لا تضبط أوزانها، وإنما فقط تقوم بعملية الجمع والتحويل ومقارنة الناتج الذي تنتجه الشبكة بالناتج الهدف.
- حيث يتم عرض **معطيات اختبار** على الشبكة وتحتوي هذه المعطيات على مجموعة من المدخلات والمخرجات المصاحبة لكل مدخل.
- ويفضل أن تكون معطيات الاختبار **مختلفة** عن معطيات التدريب.
- فإذا استطاعت الشبكة اجتياز الاختبار وإعطاء إجابات صحيحة، يكون تعليم الشبكة **ناجح**، وتصبح الشبكة جاهزة للاستخدام.

أسباب عدم تعلم الشبكة العصبونية

قد يتم تصميم الشبكة وتدريبها، ولكنها بالنهاية **تفشل!** و أسباب فشلها في الواقع متعددة منها:


- نوعية الشبكة لا تناسب التطبيق الذي تم تدريبها عليه، وهذا يستلزم اختيار شبكة أخرى.
- عدد وحدات المعالجة (العصبونات) غير مناسب.
- الأوزان التي تبدأ بها الشبكة غير مناسبة.
- معدل التعلم غير مناسب.
- معطيات التدريب لم يتم اختيارها بعناية.
- توابع التحويل غير مناسبة.

قضايا إضافية في الشبكات العصبونية


• عند التعامل مع الشبكات العصبونية يجب الانتباه إلى بعض القضايا المهمة خصوصاً عند التصميم و التدريب، وعدم الانتباه لهذه القضايا يؤدي إلى شبكات عصبونية ناقصة أو عديمة الفعالية. ومن هذه القضايا:

- التدريب المفرط Overfitting
- التدريب الناقص Underfitting
- اختيار حجم الشبكة
- معايرة البيانات Normalization
- سرعة (معدل) التعلم Learning Rate

التدريب المفرط والتدريب الناقص




تدريب ناقص



P

تدريب سليم



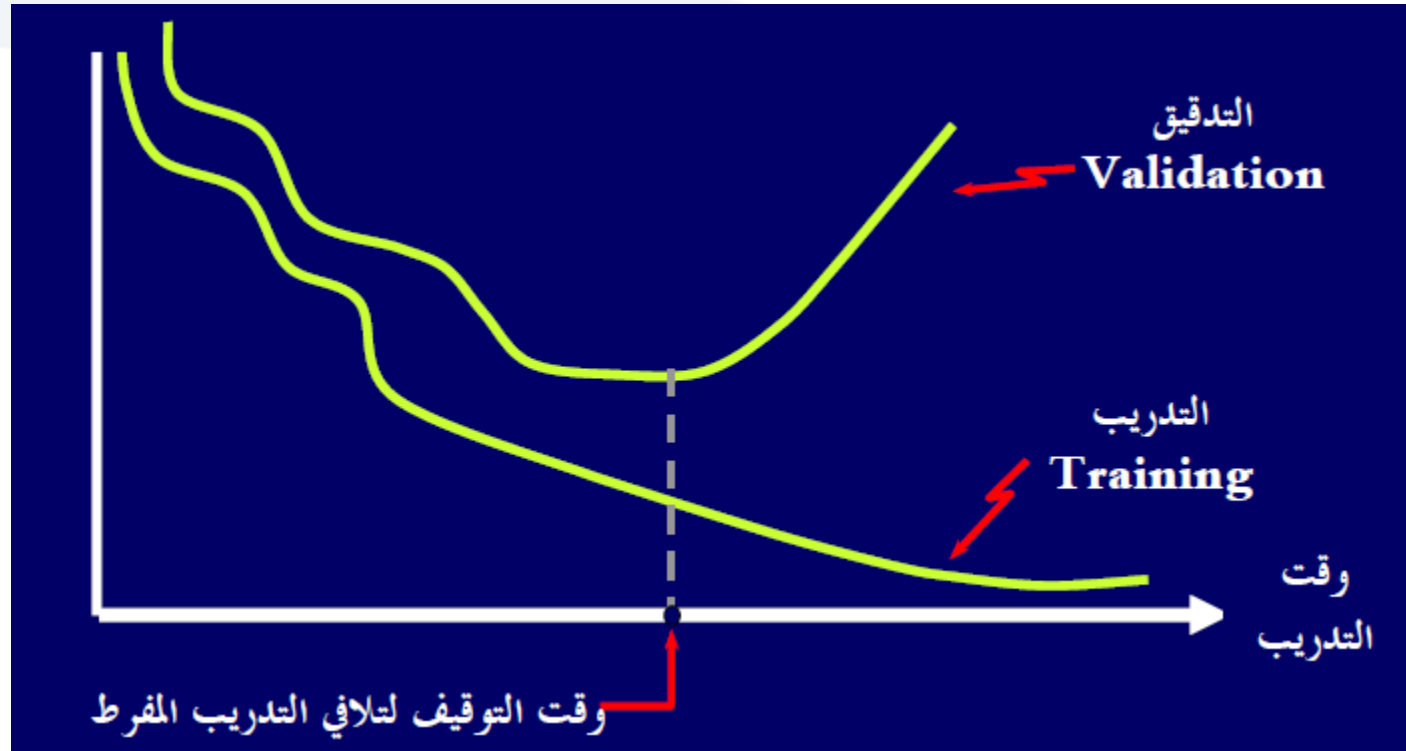
«C

تدريب مفرط

• لتلافي مشكلات التدريب المفرط هناك عدة طرق أهمها **طريقة التوقيف المبكر (Early Stopping)** للتدريب.

• وفي هذه الطريقة تقسم البيانات إلى ثلاثة أقسام:

1. ثلث للتدريب (Training Data)
2. و ثلث للتدقيق (Validation Data)
3. وثلث آخر للاختبار (Test Data)



اختيار الحجم المناسب للشبكة

- يعتبر اختيار الحجم المناسب للشبكة أصعب المشكلات على الإطلاق في تصميم الشبكات العصبونية الاصطناعية
- فبالإضافة للاختيارات الكثيرة المتوفرة لتابع التحويل (تابع التفعيل) لكل عصبون، هناك إشكالية اختيار العدد المناسب للطبقات في الشبكة و عدد العصبونات في كل من هذه الطبقات
- و كل هذه الاختيارات يجب أن تتم قبل البدء بالتدريب و بدون شك فإن الاختيار غير الموفق لحجم الشبكة يؤدي إلى نتائج غير مقبولة
- ما زالت أكثر الطرق استخداماً في اختيار حجم الشبكة هي أقدم الطرق و أسهلها و هي **طريقة المحاولة والخطأ Trial and Error**

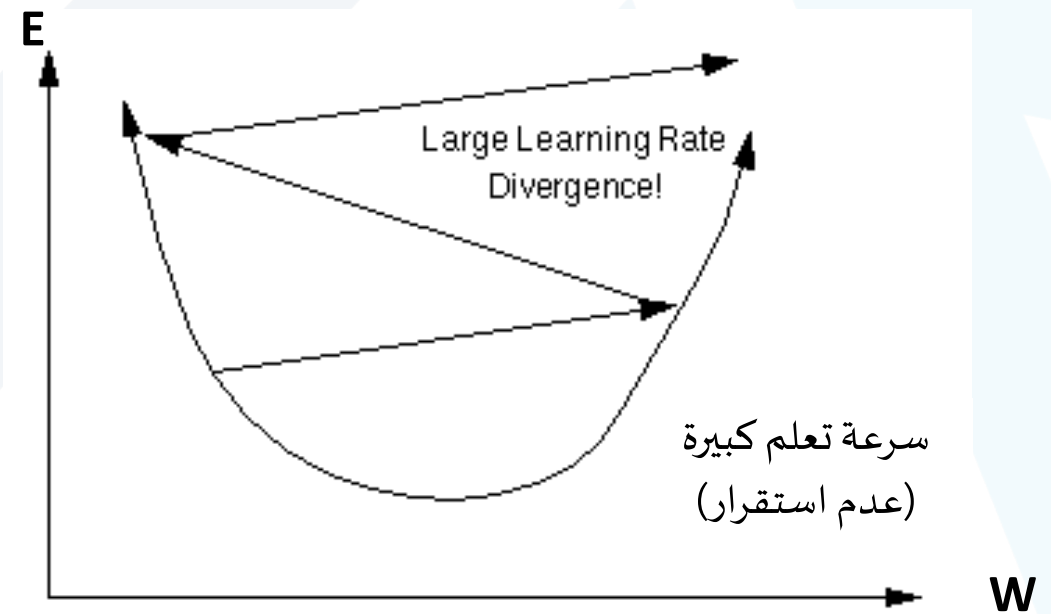
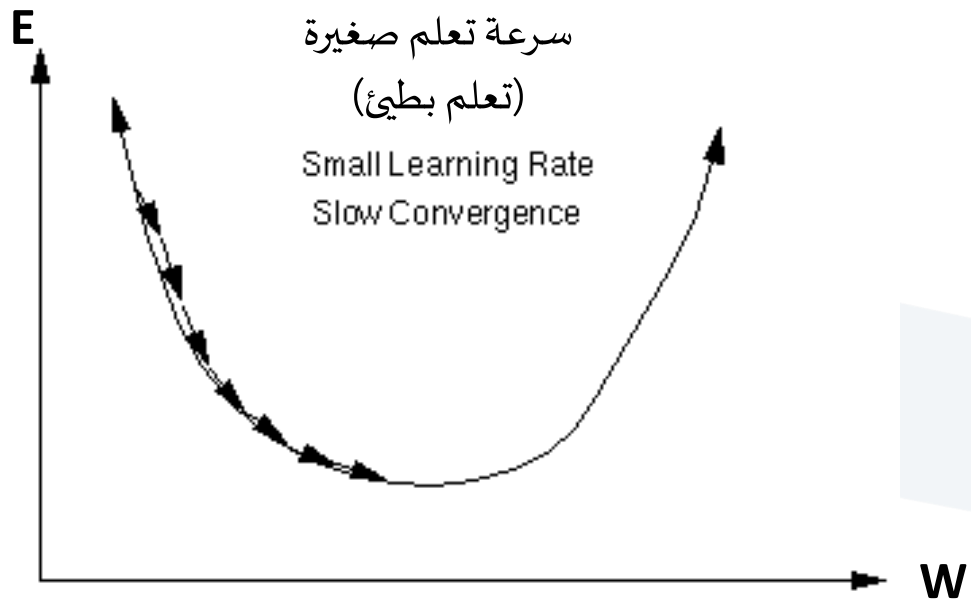
- على المصمم أن يجرب عدداً من الشبكات و يختار أحسنها على أن يكون هذا التجريب منهجياً نوعاً ما حتى لا يستغرق وقتاً طويلاً
- بإمكان المصمم أن يبدأ بشبكة بسيطة و يزيد في حجمها شيئاً فشيئاً بإضافة عصبونات أو طبقات إلى أن يصل إلى نتائج مقبولة
- قد يتبادر للذهن أن هذه الطريقة تستغرق وقتاً طويلاً، لكن في معظم الأحيان وبتوفر البرمجيات الكثيرة كبرنامج الـ **MATLAB** يمكن الوصول إلى نتائج ممتازة في وقت معقول

معايرة البيانات Normalization

- في حالات كثيرة تكون بيانات الدخل المعدة لتدريب الشبكة العصبية غير متقاربة فيما بينها من حيث القيمة، وبالتالي فخلال عملية التدريب تغطي المداخل ذات القيم الكبيرة على تلك ذات القيم الأصغر. وكذلك الحال بالنسبة لقيم الخرج. لذلك ينصح بمعايرة بيانات الدخل والخرج للشبكة
- ولهذه المعايرة فوائد كثيرة أهمها:
 - **أولاً:** أن كل المداخل تكون قيمها متقاربة و بالتالي لا يغطي مدخل على آخر
 - **ثانياً:** أن القيم المعيرة (مثلاً بين 1 و -1 أو بين 0 و 1) تجعل التدريب سريعاً
- و للقيام بمعايرة البيانات يمكن أن تقسم بيانات متغير ما على أكبر قيمة له وبالتالي تصبح القيمة القصوى بعد المعايرة مساوية للواحد
- يستخدم تابع الماتلاب *premnmx* من أجل المعايرة

معدل التعلم (سرعة التعلم) Learning rate(speed of learning)

- من الاختيارات التي يجب على المصمم تحديدها أثناء التدريب سرعة التعلم Learning Rate وهذا المتغير هو الذي يحدد سرعة تحديث الأوزان و الوصول للأوزان النهائية
- إذا كان هذا المتغير صغيراً يكون التحديث بطيئاً و بالتالي تستغرق عملية التدريب وقتاً طويلاً
- لكن إذا كان هذا المتغير كبيراً قد تتذبذب الأوزان و تبتعد عن الأوزان المطلوبة شيئاً فشيئاً و تصل عملية التدريب إلى حالة عدم استقرار



صندوق ادوات الشبكات العصبية في MATLAB Neural Network Toolbox

إنشاء الشبكة العصبية

newff

تدريب الشبكة العصبية

train

اختبار كفاءة الشبكة العصبية

sim

إنشاء الشبكة العصبية

- إن أول خطوة في تدريب الشبكة هو إنشاء الشبكة وذلك باستخدام عدة توابع . فمثلاً لإنشاء شبكة ذات تغذية أمامية سوف نستعمل التابع **newff** الذي يحتاج إلى أربعة محددات دخل وهي :
 1. مصفوفة تحتوي على القيم الصغرى والعظمى لكل عنصر من عناصر شعاع الدخل ويمكن أن يستعاض عنها بـ $\min\max(p)$ الذي يقوم بتحديد أصغر وأكبر قيمة في مجال الدخل.
 2. مصفوفة تحتوي على عدد العصبونات في كل طبقة من طبقات الشبكة .
 3. مصفوفة تحتوي على أسماء توابع التفعيل لكل طبقة .
 4. اسم تابع التدريب المستخدم .

إنشاء الشبكة العصبية

• مثال :

```
net=newff( [0 5],[10,6,2],{'tansig' 'logsig' 'purlin'}, traingd )
```

إن هذه التعليلة تقوم بإنشاء شبكة ذات تغذية أمامية، حيث يقع مجال الدخل بين القيمتين 0 و 5 ، وتتألف هذه الشبكة من طبقتين خفيتين وطبقة خرج ، الطبقة الخفية الأولى تحوي عشرة عصبونات بينما الطبقة الخفية الثانية تحوي ستة عصبونات ، أما طبقة الخرج فتتألف من عصبوني خرج ، وتوابع التفعيل لهذه الطبقات هي tansig للطبقة الخفية الأولى ، و logsig للثانية ، و purlin لطبقة الخرج ، أما تابع التدريب المستخدم في هذه الشبكة هو traingd