

فيما سبق تم التراجع من طبقة المخرجات الى الطبقة المخفية ونستمر بالتراجع الآن من الطبقة المخفية الى طبقة المدخلات لتحديد قيمة الخطأ وكما يلي:

$$\delta h_1 = hy_1 (1 - hy_1) \delta_k W_{10} \rightarrow 0.5 (1 - 0.5)(0.928)(-0.1437) = -0.03339$$

$$\delta h_2 = hy_2 (1 - hy_1) \delta_k W_{20} \rightarrow 0.5 (1 - 0.5)(0.928)(-0.1437) = -0.03339$$

والآن يتم حساب قيمة الأوزان وتقديمها بالشكل الآتي:

$$W_{11} = W_{11} + \eta \delta h_1 x_1 \rightarrow (1) + (1)(-0.03339)(0) = 1$$

$$W_{12} = W_{12} + \eta \delta h_2 x_1 \rightarrow (0) + (1)(-0.03339)(0) = 0$$

$$W_{21} = W_{21} + \eta \delta h_1 x_2 \rightarrow (0) + (1)(-0.03339)(0) = 0$$

$$W_{22} = W_{22} + \eta \delta h_2 x_2 \rightarrow (1) + (1)(-0.03339)(0) = 1$$

x_1	x_2	T	W_{11}	W_{12}	W_{21}	W_{22}	W_{10}	W_{20}
0	0	0	1	0	0	1	0.928	0.928

H. W:

$$h_{i1} = W_{11} x_1 + W_{21} x_2 \rightarrow (1 * 0) + (0 * 1) = 0$$

$$h_{i2} = W_{12} x_1 + W_{22} x_2 \rightarrow (0 * 0) + (1 * 1) = 1$$

$$hy_1 = \frac{1}{1 + e^{-h_{i1}}} \rightarrow \frac{1}{1 + e^{-0}} = 0.5$$

$$hy_2 = \frac{1}{1 + e^{-h_{i2}}} \rightarrow \frac{1}{1 + e^{-1}} = 0.73$$

$$S = W_{10} hy_1 + W_{20} hy_2 \rightarrow (1 * 0.5) + (1 * 0.73) = 0.5 + 0.73 = 1.23$$

وبما أن قيمة S لا تساوي قيمة Target (الهدف) إذًا نستخدم التمرير الخلفي لتعديل وتحديث الأوزان:

$$\delta k = E_k * y_k(1 - y_k) , E_k = t_k - y_k , t_k = 1$$

$$y_k = \frac{2}{(1 + e^S) - 1} = \frac{2}{(1 + e^{1.23}) - 1} = \frac{2}{(1 + 3.42) - 1} = \frac{2}{3.42} = 0.58$$

$$\delta k = (t_k - y_k) * y_k(1 - y_k) \rightarrow (1 - 0.58)(0.58)(1 - 0.58) = 0.1$$

$$W_{10}(\text{new}) = \eta \delta_k h_{y_1} + \alpha W_{10}(\text{old}) \rightarrow (1)(0.1)(0.5) + (1)(1) = 1.05$$

$$W_{20}(\text{new}) = \eta \delta_k h_{y_2} + \alpha W_{20}(\text{old}) \rightarrow (1)(0.1)(0.73) + (1)(1) = 1.073$$

$$\delta h_1 = hy_1 (1 - hy_1) \delta_k W_{10} \rightarrow 0.5 (1 - 0.5)(0.1)(1.05) = \mathbf{0.02625}$$

$$\delta h_2 = hy_2 (1 - hy_2) \delta_k W_{20} \rightarrow 0.73 (1 - 0.73)(0.1)(1.073) = \mathbf{0.02115}$$

$$W_{11} = W_{11} + \eta \delta h_1 x_1 \rightarrow (1) + (1)(0.02625)(0) = \mathbf{1}$$

$$W_{12} = W_{12} + \eta \delta h_2 x_1 \rightarrow (0) + (1)(0.02115)(0) = \mathbf{0}$$

$$W_{21} = W_{21} + \eta \delta h_1 x_2 \rightarrow (0) + (1)(0.02625)(1) = \mathbf{0.2625}$$

$$W_{22} = W_{22} + \eta \delta h_2 x_2 \rightarrow (1) + (1)(0.02115)(1) = \mathbf{1.2115}$$

إذاً الأوزان تكون كالآتي:

x_1	x_2	T	W_{11}	W_{12}	W_{21}	W_{22}	W_{10}	W_{20}
0	1	1	1	0	0.2625	1.2115	1.05	1.073

الشبكات العصبية الإحصائية Statistical Neural Networks

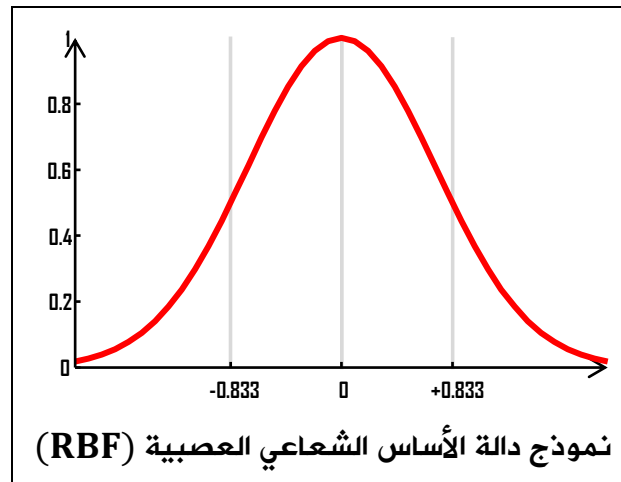
يستعمل الإحصاء في الشبكات التغذوية الامامية واحد أهم تلك الشبكات هي شبكة دالة الأساس الشعاعي. أصبحت الشبكات العصبية تنتشر بشكل متزايد بتطبيقات متنوعة وربما تكون المنافس الرئيسي لمستقبلات متعدد الطبقات.

شبكة دالة الأساس الشعاعي Radial Basis Function Networks

تُعد أساليب تصنيف الأنماط الإحصائية التقليدية الأساس أو الملهم لشبكات دالة الأساس الشعاعي والتي يرمز لها اختصاراً بـ (RBF) ، والتي تعد أساساً للحصول على زخماً جديداً لوصفها الشبكات العصبية. وتأخذ شبكة دالة الأساس الشعاعي العصبية (RBF) الصيغة الرياضية الآتية:

$$\text{radbas}(n) = e^{-n^2}$$

ويمكن تمثيلها بيانياً كما في الرسم الآتي:



وتتكون المعمارية الهندسية الأساسية لشبكات دالة الأساس الشعاعي (RBF) من ثلاث طبقات وهي:

- **طبقة المدخلات:** هي الطبقة الأولى وتمثل طبقة مدخلات الشبكة وهي لا تقوم بأي معالجة.
- **الطبقة المخفية:** هي الطبقة الثانية إذ تقوم بمعالجة العلاقات غير الخطية من فضاء المدخلات إلى فضاء أعلى الأبعاد التي تكون قابلة للفصل خطياً.
- **طبقة المخرجات:** هي الطبقة الأخيرة التي تقوم بجمع الأوزان البسيطة للمخرجات الخطية. إذا استخدمت شبكة (RBF) لتقريب دالة ما فإنها تُعطي مخرجات جيدة ، ومع ذلك إذا كان مطلوباً تصنيف نمط معين بالدالة السينية Sigmoid function ، فإن معالجة مخرجات الشبكة يكون بعبء قيمة للمخرج (0) أو (1).

وهناك عدة فوائد لشبكة دالة الأساس الشعاعي (RBF) مقارنة بمستقبلات متعدد الطبقات (MLP) ومنها:

- 1- منها أن تدريب شبكة (RBF) أسرع من تدريب شبكة (MLP).

- 2- يقدم استخدام شبكة (RBF) حد قرار أفضل من باقي الشبكات.
 - 3- إن الفائدة المتحققة من استخدام شبكة (RBF) تتمثل بأن الطبقة المخفية فيها أسهل تمثيلاً من الطبقة المخفية لـ (MLP).
 - 4- إن الطبقة المخفية في (RBF) تتمثل بدالة الكثافة الاحتمالية.
- وهناك عيوب تتجلى في ان مستقبلات متعدد الطبقات (MLP) تعطي تمثيل توزيع بشكل أفضل من شبكة دالة الأساس الشعاعي (RBF).

الشبكة العصبية الاحتمالية (PNN) Probabilistic Neural Networks

وضحنا فيها سبق بان شبكة دالة الأساس الشعاعي (RBF) طُورت من خلال أساليب تصنيف الانماط الإحصائية التقليدية وهذا يكون أكثر وقعاً لشبكات العصبية الاحتمالية والتي يرمز لها اختصاراً بـ (PNN).

طُورت الشبكة العصبية الاحتمالية (PNN) من قبل (Specht) في عام 1990.

وتعتمد الشبكة الاحتمالية شبكات التغذية الأمامية بواسطة دالة الكثافة الاحتمالية لأنماط وتستخدم في التصنيف والتنبؤ والسيطرة.

تفترض شبكة (RBF) بان دوال الكاوسين (Gaussian) تجعل التقريب أفضل لتوزيع العنقودي في نمط الفضاء.

الشبكة الاحتمالية تشابه شبكة دالة الأساس الشعاعي (RBF) وتستخدم وحدة في وسط الطبقة المخفية.

(مميرات) وتتميز الشبكة (PNN) ⁽¹⁾ بعدم وجود تدريب ، ⁽²⁾ وقيم الأوزان في الطبقة المخفية ما هي سوى بيانات بذاتها. ⁽³⁾ والأوزان في طبقة المخرجات ، تكون جميعها (1) أو نصف قطرها (σ) وتحدد من خلال عدد العينات في كل صف من مجموعة التدريب.

أما العيب الوحيد فهو ان عدد الوحدات المطلوبة يطابق حجم البيانات.

منهجية الشبكة العصبية الاحتمالية PNN

يمكن إيجاز المراحل التي تصف الشبكة العصبية الاحتمالية من خلال الخوارزمية الآتية:

- 1- لكل نموذج مدرب (U_j) نحسب احتمالية (U_j) (اذا كانت دالة كثافة الاحتمال معلومة) وبموجب الصيغة الآتية:

$$H_j = \exp \left[- (X_i - U_j)^T (X_i - U_j) / (2\sigma^2) \right]$$

- 2- حساب مجموع الاحتماليات المنتهية الموجودة أو المحتسبة لكل النماذج المدربة نجد ($\sum h_i$).
- 3- لكل مخرج (k) نجد الآتي: