

Email:

[Maysoon\\_khider@yahoo.com](mailto:Maysoon_khider@yahoo.com)

Email:

[khalil\\_alsaiif@yahoo.com](mailto:khalil_alsaiif@yahoo.com)

### **Abstract**

*In this research the neural network was adopted to classified the gender of the spoken, by creating the two dimension matrix from the parameters of the spoken speech signal which normal was snigle dimension array.*

*The porpose algorithm in this research divided in two stage :-*

*In the first stage the seven moment were calculated for a set of spoken signal of 50 persons , to be followed creating database depend on the seven moments .This database will be used to find the threshold value for both genders (male/female) which will be trained by neural network to classify any input tothe network.*

*In the second stage , speech of any spoken will be selected and the same feature will be extracted , as in the first stage , to be used as input to the neural network which was traind previously for gender recognition.*

*Back propagation neural network was achieved for recognition. The result of the applied algorithm on 10 spoken passed on 8 of them and 2 of them was failed.*

( paralinguistic)

( )

(vocal tract)

%

-١

(off- Line)

)

(

.(Rotating / translating and scaling)

(Flusser,2000)

$\eta_{pq}$  [Gonzales and Wintz,1987]:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \dots\dots\dots(1)$$

$p, q = 0,1,2,\dots$

Y,X

p,q

f(x,y)

.[

. y x

y x

$$\mu_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{x})^p (y - \bar{y})^q f(x, y) dx dy \dots\dots\dots(2)$$

$$\bar{x} = \frac{m_{10}}{m_{00}}, \bar{y} = \frac{m_{01}}{m_{00}}$$

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y) \dots\dots\dots(3)$$

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^{\gamma}} \dots\dots\dots(4)$$

$$\gamma = 1/2(p + q) + 1 \dots\dots\dots (5)$$

$p + q = 2,3,\dots$

invariant moment

:

$$\phi_1 = \eta_{20} + \eta_{02}, \dots\dots\dots(6)$$

$$\phi_2 = (\eta_{20} - \eta_{02})^2 + 4 \eta_{11}^2 \dots\dots\dots(7)$$

$$\phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \dots\dots\dots(8)$$

$$\phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \dots\dots\dots(9)$$

$$\phi_5 = (\eta_{30} - 3\eta_{12}) (\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2],$$

$$+ (3\eta_{21} - \eta_{03}) (\eta_{21} + \eta_{03}) [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \dots\dots(10)$$

$$\phi_6 = (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2],$$

$$+ 4\eta_{11}(\eta_{30} + \eta_{12}) (\eta_{21} + \eta_{03}), \dots\dots\dots(11)$$

$$\phi_7 = (3\eta_{21} - \eta_{03}) (\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2 ],$$

$$+ (3\eta_{12} - \eta_{30}) (\eta_{21} + \eta_{03}) [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \dots\dots(12)$$

translation (Hu 1962 )

.[ , ] Scaling Rotation

: -

(Artificial neural networks ANN)

[Rao, V.B. and Rao,H.V. ...

,1993]

-:[Abod L.K., 1998]

#### 4- طور تدريب الشبكات العصبية الاصطناعية Artificial Neural Networks Training

التعلم طور في الشبكات العصبية عندما تتدج بيانات جديدة في الشبكة نتيجة تغير الوزن (weight). لشبكة تدرب على التطبيق المعطى أي على مجموعة الادخالات لإنتاج الإخراج المطلوب والتدريب ينجز بشكل متسلسل على متجه الإدخال عندما تتغير الأوزان للشبكة وفقاً لقوانين محددة [Lippmann R.P., 1987].  
خلال التدريب تقرب أوزان الشبكة تدريجياً من القيم المثالية ويعمل الإدخال على إظهار الإخراج المطلوب ، ويكون التدريب في الشبكات العصبية الاصطناعية بإشراف أو بدون إشراف [Rao, V.B. and Rao,H.V. ,1993].

#### 5- التدريب بدون إشراف (Unsupervised Training)

يمثل هذا التدريب الطور الأول في الشبكات العصبية ومعناه أن الشبكة تمتلك بعض المعلومات خلال التدريب أي أنها تمتلك الادخالات والأوزان فقط وليس لها معرفة عن ناتج الإخراج (بمعنى آخر لا يوجد إخراج منتخب) لأجل المقارنة [Chitra,S.P., 1993].  
اكتشف هذا التدريب من قبل العالم كوهين وآخرين تتألف مجموعة التدريب من متجه الإدخال بخوارزمية التدريب لتغيير أوزان الشبكة لإنتاج متجه الإخراج الثابت ، إذ يطبق الإدخال لإيجاد الإخراج المحدد [Rao, V.B. and Rao,H.V., 1993], [Lippmann R.P., 1987].

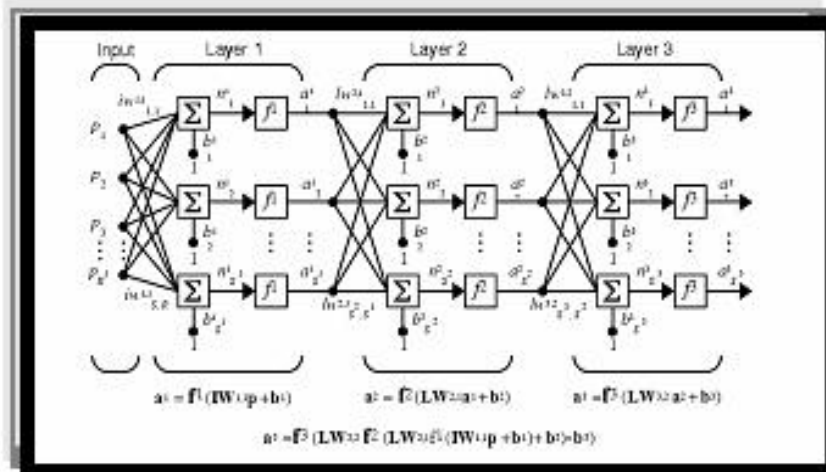
#### 6- الشبكات العصبية وتمييز الأنماط :

تستخدم الشبكات العصبية الاصطناعية في تمييز الأنماط ، ان تمييز الأنماط هي العملية التي تتم على البيانات للحصول على معلومات مرتبة لتصنيف هذه البيانات. تمييز الأنماط يستخدم لعدة تطبيقات مثل تمييز الأرقام وتمييز الحروف المكتوبة يدوياً والمطبوعة وتمييز الأصوات ومجالات لا مجال لحصرها.  
الشبكات العصبية بنوعها التي تعمل بإشراف والتي تعمل بدون إشراف طبقة واحدة أو من عدة طبقات استطاعت وبنجاح تطبيق مختلف التصنيف ومساائل التمييز [AL\_Yaseen Sh,2000].

7- الشبكة العصبية ذات الانتشار العكسي *Back Propagation Neural Network*

:BPNN

كل شبكة عصبية قد تم تدريبها باستخدام خوارزمية الانتشار العكسي تدعى بالشبكة العصبية ذات الانتشار العكسي (الشكل 1). وتعتبر الشبكة العصبية ذات الانتشار العكسي نموذج مألوف جداً في الشبكات العصبية. وهي الأكثر استخداماً في معمارية الشبكات العصبية، والسبب الرئيسي لهذا هو : أنها سهلة التنفيذ، إذ أن الشبكات المستخدمة لخوارزمية الانتشار العكسي تتعلم المخططات المعقدة المتعددة الأبعاد بسهولة أكثر من استخدامها لخوارزميات الأخرى. والعديد من التطبيقات يمكن أن تصاغ باستخدام شبكة الانتشار العكسي حيث يكون لديها نموذج لأغلب الشبكات العصبية لمتعددة الطبقات. ومن ثم يمكننا القول إن أكثر طريقة تدريب شائعة الاستخدام في الشبكات العصبية المتعددة الطبقات هي خوارزمية الانتشار العكسي، وقد تم اختبارها بنجاح لأنواع مختلفة من المهام. وبالرغم من أن الشبكة لا تضم ارتباطات للتغذية العكسية، لكن الأخطاء تنتشر عكسياً للخلف خلال عملية التدريب. والأخطاء في طبقة الإخراج تحدد قياسات الأخطاء في الطبقة المخفية، والتي تستخدم كإحياز لتعديل أوزان الربط بين طبقة الإدخال والطبقة المخفية. كل معالجة تكرر تضم تعديل مجموعتين من الأوزان على الأقل بين زوج من الطبقات وتدوير الإخراجات، وتستمر هذه المعالجة إلى أن تقع الأخطاء تحت مستوى تفاوت مسموح به tolerance [Wassermann, P.D,1989] [ Rao,V.B. and Rao, H.V,1993].



الشكل (1) يوضح شبكة عصبية متعددة الطبقات

### 8- معمارية الشبكات العصبية ذات الانتشار العكسي BPNN :

تعتبر الشبكة العصبية ذات الانتشار العكسي هي نظام شبكة بتغذية أمامية وبصورة تدرجية، وتتألف من طبقتين أو أكثر من الطبقات لوحدات المعالجة المترابطة كلياً مع بعضها (طبقة الإدخال ليست من ضمنها). الخلايا العصبية لا ترتبط مع خلايا عصبية أخرى في نفس الطبقة (شبكة ذات ارتباط طبقي). بكلمات أخرى، كل خلية عصبية في طبقة الإدخال سوف ترسل إخراجها إلى كل خلية في الطبقة الوسطى، وكل خلية في الطبقة الوسطى سوف ترسل إخراجها إلى كل خلية في طبقة الإخراج [Wassermann, P.D,1989]. [Chitra,S.P,1993].

عدد الخلايا العصبية في الطبقة المخفية ربما يكون مختلفاً طبقاً إلى تعقيد المسألة، وحجم معلومات الإدخال. على أي حال، لعدد معطى من الإدخالات، إذا كانت الطبقة المخفية كبيرة جداً، ربما لا يكون من الممكن تطوير النمط القابل للاستخدام . من جهة أخرى، الطبقة الوسطى التي تكون صغيرة جداً سوف يكون تأثيرها قوياً في زيادة عدد التكرارات iterations المطلوبة لتدريب الشبكة [Chitra,S.P,1993].

### 9- الخوارزمية المعتمدة في البحث :

تم اقتراح خوارزمية لأجل اعتماد العزوم السبعة لمصفوفة ثنائية حاوية على عناصر إشارة الكلام بعد إجراء توافق لخزن إشارة الكلام (نو البعد الواحد) داخل مصفوفة ثنائية مربعة. حيث يتم إدخال العزوم السبعة إلى شبكة عصبية ويمكن تلخيصها بمرحلتين:

#### المرحلة الأولى:

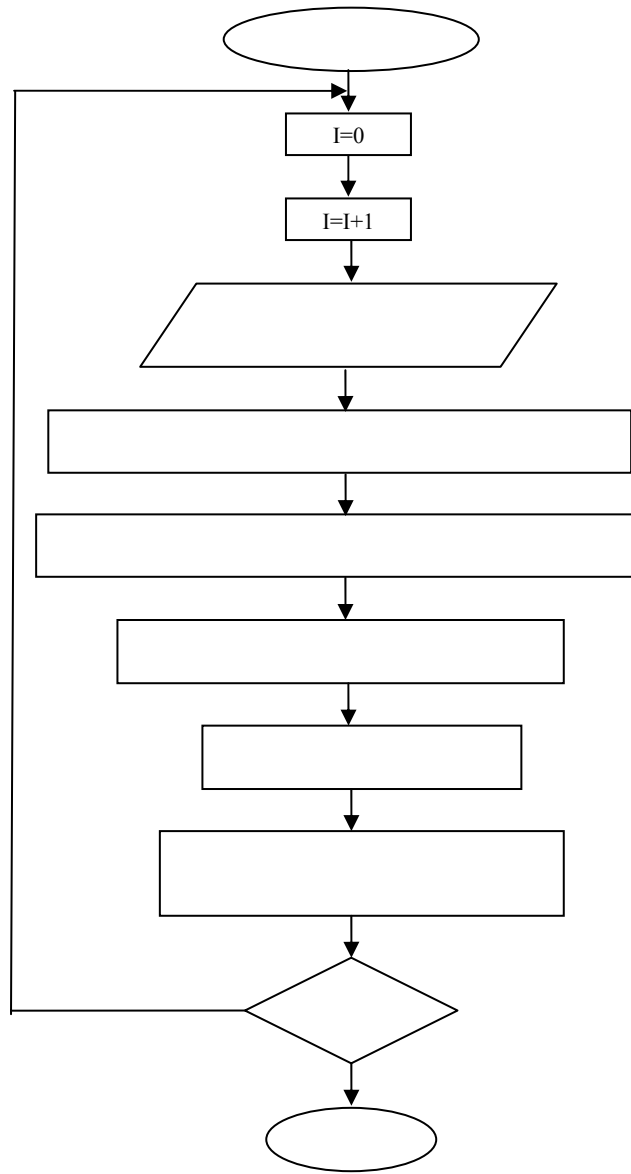
يتم العمل على تدريب شبكة عصبية لأجل التمييز بين فئتي الذكور والإناث حيث يتم اعتماد الشبكة العصبية ذات الانتشار العكسي BPNN . من خلال تهيئة مدخلات الشبكة المتضمنة العزوم السبعة للمصفوفة الثنائية الحاوية على عناصر إشارة الكلام بصيغة التردد (fourier transform).

#### المرحلة الثانية:

1. اكتساب الكلام من خلال إحدى وسائل الإدخال المتوفرة (لاقطة ، ملف صوتي مخزون سابقاً...).

١. حساب بعد المصفوفة الثنائية لأجل إدخال عناصر إشارة الكلام إليها.
  ٢. حساب تحويل فورير للمصفوفة الثنائية ومن ثم اعتماد القيمة المطلقة  
( الطيف spectrum ) .
  ٣. حساب العزوم السبعة .
  ٤. اعتماد العزوم السبعة كإدخال لشبكة الانتشار العكسي المدربة سابقا  
لأجل التمييز.
- ويوضح الشكل (2) المخطط الصندوقي لسير عمليات المرحلة الأولى للخوارزمية المقترحة:






( )

:

( )




( )

: -

.%

-:



( )

( )

:

.....

]

[ .....

[ , , , , , , , ]  
( )

: -

( / )

: -

" (word 7) " ( ) .)

2. Abod L.K.,(1998), Classification of satellite image using neural network, Ph.D. Thesis, Department of physics, college of science, university of Baghdad.
3. AL\_Yaseen Sh., 2000 Face Recognition using Neocognitron Neural Network, M.Sc. Thesis , Department of Computer Engineering , College Of Engineering , University of Mosul.
4. Chitra, S.P.(1993) Use neural networks for problem solving, Chemical engineering progress, pp. 44-52.
5. Flusser, J., 2000. On the independence of rotation moment invariant, Pattern recognition, Vol.33, pp.1405-1410.
6. Gonzales, R. C. and Wintz, 1987. Digital Image processing, Addison Wesley publishing company.
7. Lippmann R.P.,(1987), Introduction to computing with neural Nets, IEEE Assp Magazine, Vol. 4, No. 2, pp. 4-22.
8. Rao, V.B. and Rao,H.V.(1993), C++ Neural Networks and Fuzzy Logic, Henry Holt and Company, Ins., New York.
9. Wassermann, P.D.,(1989), Neural Computing theory and practic van nostrand reinhold:New York.