

## تصميم نظام للتعرف على مسميات المخططات الزمنية باستخدام الشبكات العصبونية

الدكتور علي سليمان\*

الدكتور بلال شيجا\*\*

محمد طه كفرناوي\*\*\*

(تاريخ الإيداع 15 / 7 / 2015. قُبل للنشر في 11 / 2 / 2016)

### □ ملخص □

يقدم هذا البحث منظومة للتعرف على مسميات المخططات الزمنية، حيث يتم استخلاص المسميات من المخططات، التي هي عبارة عن صورة باستخدام التقسيم المكاني من أجل اقتطاع صور المسميات فقط. تُوجد أحجام صور المسميات باستخدام خوارزمية المتوسط لسبين؛ الأول تشكيل قاعدة البيانات التدريبية للشبكات العصبونية المستخدمة، وثانياً من أجل اجراء عملية التعرف. تم اعتماد الشبكات العصبونية للتعرف بالآيتين مختلفتين: آلية التصنيف classification باستخدام شبكة Perceptron وآلية التمييز باستخدام شبكة الانتشار العكسي، حيث تم بناء شبكة Perceptron دخلها صورة المسمى فنُعطي في خرجها الدليل التصنيفي للمسمى، ليتم معرفته بالاعتماد على جدول مسميات مخزن مسبقاً، وشبكة انتشار عكسي دخلها صورة المسمى وخرجها الترميز الحاسوبي للمسمى، كما تم تصميم شبكة الانتشار العكسي بحيث يمكن لها التعرف على كافة صور مسميات أحرف الأبجدية الانكليزية المستخدمة في المخططات الزمنية، أظهرت نتائج البحث فعالية المنظومة المصممة للتعرف على مسميات المخططات الزمنية من صورها، وذلك للآيتين التصنيفية والتمييزية، بعد تطبيق النظام على ثلاث مخططات زمنية.

**الكلمات المفتاحية:** صورة، تقسيم مكاني، شبكة عصبونية، برنامج، تدريب، مسمى.

\* أستاذ مساعد - قسم هندسة الحاسبات والتحكم - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

\*\* أستاذ مساعد - قسم هندسة الحاسبات والتحكم - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

\*\*\* طالب دراسات (دكتوراه) - قسم هندسة الحاسبات والتحكم - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

## System Design to Recognize of Time Plans Labels Using Neoural Networks

Dr. Ali Soliman\*

Dr. Bilal Chiha\*\*

Mohammad Taha Kafrnawi\*\*\*

(Received 15 / 7 / 2015. Accepted 11 / 2 / 2016)

### □ ABSTRACT □

This paper introduces a system to recognize labels of time plans, where labels are extracted from time plan. This labels are images, so spatial segmentation is used to extract images of labels only. Size of images of labels are made same using median's algorithm for two purposes. The first one is to create database training for used neural networks. The second is to recognizing's processing. Two methods of recognizing are dependent on using neural networks technic: classification using perceptron network and recognizing using back propagation network. Perceptron network is built to take image as input and to give classification index as output for label. Then label is recognize dependent on stored table of ASCII for label. Back propagation network is designed to recognize images for all letters of English alphabet that are used in time plan. Results of research appear efficiency of designed system to recognize labels of time plan from their images for both methods after system had been applied on three time plans.

**Key words:** image, spatial segmentations, neoural network, program, training, label.

---

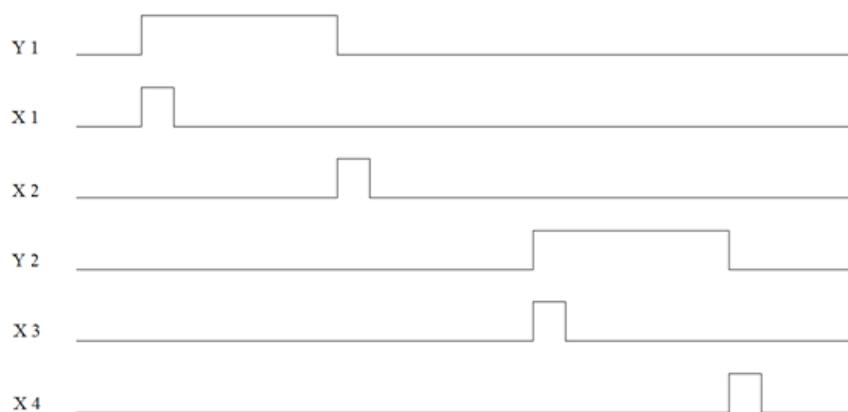
\* Associate Professor, Dept. computer & control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen university

\*\* Associate Professor, Dept. computer & control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen university

\*\*\* Postgraduate, Dept. computer & control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen university

**مقدمة:**

تعتبر المخططات الزمنية الأساس في فهم مبدأ عمل أي منظومة صناعية مؤتمتة، لذلك نجد أن جميع الشركات العالمية والمرموقة تدعم آلاتها والمنظومات الصناعية المصممة من قبلها بمخططات زمنية، تبين من خلالها آلية عمل هذه الآلات والمنظومات، يبين الشكل (1) مخطط زمني لمنظومة ما.



الشكل (1) المخطط الزمني لمنظومة مؤتمتة.

تحتوي هذه المخططات على رموز مثل  $Y1$  و  $X1$  وغيرها، وتعتبر هذه الرموز مسميات لكل منحنى بياني من المخططات الزمنية، وهي أيضاً جزء لا يتجزأ من المخطط ككل، والذي يكون على شكل صورة ورقية أو إلكترونية.

**أهمية البحث وأهدافه:**

تقوم فكرة البحث على تقديم طريقة، يستطيع الحاسوب من خلالها التعرف على مسميات المخططات الزمنية، بمعنى آخر نقوم بإعطاء الحاسب صورة المخطط الزمني فيقوم بمعرفة المسميات الموجودة في هذا المخطط، وبالتالي تمييز مخطط عن آخر ومعرفة تبعية المخطط فيما إذا كان مدخل  $X$  أم مخرج  $Y$  أم مؤقت  $T$  أو عداد  $C$  ومعرفة رقم المدخل أو المخرج أو العداد أو المؤقت في حال استخدام الآلية التصنيفية من خلال شبكة Perceptron. ومعرفة اسم كل مخطط من خلال معرفة الترميز الحاسوبي لكل مسمى في حال استخدام الآلية التمييزية من خلال شبكة الانتشار العكسي، وقد تم أخذ الآلية التمييزية كون بعض المخططات الزمنية تحوي مسميات مختلفة لا تقتصر على رموز المداخل والمخارج.

**طرائق البحث ومواده:**

إن عملية إنجاز الطريقة البرمجية من أجل التعرف على مسميات المخططات تحتاج دراسة عدة مراحل، ففي البداية درست تقنيات معالجة الصورة بغية تطبيقها على صورة المخططات الزمنية وتتضمن ترشيح صور المخططات الزمنية، واقتطاع المسميات وتجزئتها وتهيئتها، بحيث تناسب دخل الشبكة العصبونية، وذلك بإعادة تحجيمها، ثم تمت دراسة آليتي بناء شبكة عصبونية الأولى Perceptron وتدريبها لغرض تصنيف على مختلف صور المسميات، والثانية شبكة الانتشار العكسي من أجل التمييز، وذلك لبرمجة هذه المراحل بحيث نحصل على طريقة لترتيب المسمى مع رقمه بعد التعرف عليه وعلى رقمه من قبل الشبكة العصبونية المدربة بالآليتين التصنيفية والتمييزية لكل من شبكة

Perceptron وشبكة الانتشار العكسي على الترتيب، وفي النهاية تمت عملية تحصيل النتائج بعد الاختبار على عدة مخططات زمنية.

### 1- معالجة صور المسميات

بما أن المخططات الزمنية عبارة عن صورة، فإذا كان ت صورة ملونة من نوع RGB (Red Green Blue) سيكون المخطط الزمني مكون من ثلاث مصفوفات لونية، مصفوفة قيم طيف اللون الأحمر ومصفوفة طيف اللون الأخضر ومصفوفة اللون الأزرق، وذلك لأن كل بكسل من الصورة مكون من شعاع بثلاث قيم [1]، ومنه ستكون صورة المخطط المبين بالشكل (1) مكون من ثلاث مصفوفات لونية  $N$  عمود و  $M$  سطر ، غالباً ما تكون صورة المخطط الزمني مشوشة عند ادخالها إلى الحاسب إذا كان المخطط ورقياً، لذلك لابد من ترشيحها . يمكن الحصول على صور مسميات المخطط الزمني بشكل مجزأ من الصورة الرقمية للمخطط الزمني باستخدام خوارزمية التقسيم المكاني spatial segmentations [2,3] وذلك بإجراء تقسيم عامودي وفق الإجراء التالي:

```

k = 0
for j = 1 → N
  if  $\sum_{i=1}^M IM(i, j) = M$ 
    separate
    k = k + 1
  end if
end for

```

ينتج لدينا عن التقسيم العامودي عدد من الصور الجزئية وليكن عددها  $q$  نقوم بتقسيم كل منها أفقياً وفق الإجراء التالي:

```

for i = 1 → M
  if  $\sum_{j=1}^{N_k} IM_k(i, j) = N_k$ 
    separate
  end if
end for

```

حيث  $IM_k$ : الصورة  $k$  من مجموعة الصور  $q$  الناتجة عن التقسيم العمودي،  $k$  عدد صحيح يدل على رقم الصورة الناتجة يأخذ قيم ضمن المجال  $[1, q]$ ،  $N_k$ : عدد أعمدة الصورة  $k$  أما عدد أسطرها فهو متساوٍ لجميع الصور  $q$ ، بتطبيق خوارزمية التقسيم المكاني، نكون قد قمنا بإجراء اقتطاع وتجزئة المخطط الزمني من مخطط زمني ككل إلى مكونات جزئية عبارة عن منحنيات ومسميات كلاً على حدا، *separate*: إجراء فصل الصورة إلى صور جزئية.

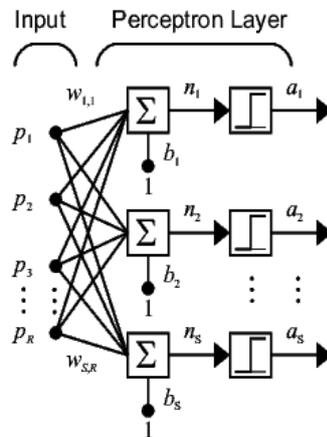
يتم تمييز صور المسميات عن صور المخططات عن طريق حجمها، إذ يكون حجم صورة المخطط أكبر من صورة المسمى، ثم تُوحد أحجام صور المسميات كافة باستخدام إعادة تحجيم الصور الجزئية الناتجة وفق قاعدة المتوسط باستخدام إطار Kernel تحدد أبعاده  $n \times m$  بناءً على حجم الصورة قبل وبعد التحجيم وفق العلاقة (1)

$$\begin{aligned} n &= N_b/N_a \\ m &= M_b/M_a \end{aligned} \quad (1)$$

حيث  $N_b$ : عدد أعمدة الصورة قبل التحجيم،  $N_a$ : عدد أعمدة الصورة بعد التحجيم،  $M_b$ : عدد أسطر الصورة قبل التحجيم،  $M_a$ : عدد أسطر الصورة بعد التحجيم.

## 2- بناء وتدريب الشبكة العصبونية التصنيفية

إن عملية تصنيف صور مسميات المخططات الزمنية تتم ببناء شبكة عصبونية مكونة من الدخل وطبقة Perceptron، كما هو مبين بالشكل (2) [4,5,6]، حيث  $p_i$ : عنصر دخل الشبكة و  $i \in [1, R]$ ، أما  $S$  عدد العصبونات،  $w_{1,1}$ : الوزن الواصل بين الدخل الأول ( $p_1$ ) والعصبون الأول،  $w_{S,R}$ : الوزن الواصل بين الدخل  $R$  والعصبون  $S$ ، أما  $n_j$  خرج عقدة التجميع ويعطى بالعلاقة (2) حيث  $j \in [1, S]$  الانحياز  $b_j$ ،  $a_j$  bias، خرج العصبون  $j$  وهو تابع التنشيط Activation Function وقد أخذ [4,5,6] Hard Limit الذي يعطى بالعلاقة (3).



الشكل (2) الشبكة العصبونية المستخدمة للتصنيف

$$n_j = \sum_{i=1}^R w_{j,i} p_i + b_j \quad (2)$$

$$a_j = \begin{cases} 0; & n_j < 0 \\ 1; & n_j \geq 0 \end{cases} \quad (3)$$

تتم عملية التدريب وفق قواعد تدريب شبكة Perceptron المعطاة بالعلاقين (4) و (5)، [5,6,7] على مجموعة من البيانات تدعى قاعدة بيانات التدريب.

$$w_{j,i}^{new} = w_{j,i}^{old} + e_j p_i \quad (4)$$

$$b_j^{new} = b_j^{old} + e_j \quad (5)$$

حيث  $e_j$  الخطأ بين خرج العصبون  $a_j$  والخرج المرغوب  $t_j$  ويعطى بالعلاقة (6)

$$e_j = t_j - a_j \quad (6)$$

## 3- بناء وتدريب الشبكة العصبونية التمييزية

يطلق على الشبكة العصبونية التي تعتمد خوارزمية الانتشار العكسي شبكة الانتشار العكسي. [7],[8],[9] تُعتبر خوارزمية الانتشار العكسي واحدة من أكثر الخوارزميات استخداماً لتدريب الشبكة العصبونية متعددة الطبقات، بسبب كفاءتها في حل العديد من المسائل والتطبيقات في مجالات التعرف والتمييز والملاءمة، أن خرج العصبون الأول من الطبقة الأولى (طبقة الدخل)  $y_{11}$  يعطى بالعلاقة (7) [8],[9],[10]،

$$y_{11} = f(w_{111}x_1 + w_{211}x_2 + \dots + w_{L1r}x_L) \quad (7)$$

حيث  $f$ : تابع التنشيط ويحدد حسب المسألة،  $L$ : عدد المداخل وهو يساوي  $N_a \times M_a$ ،  $w_{111}$ : الوزن الواصل بين الدخل الأول والعصبون الأول من الطبقة الأولى،  $w_{211}$ : الوزن الواصل بين الدخل الثاني والعصبون الأول من الطبقة الأولى،... وهكذا،  $x_1$ : الدخل الأول،  $x_2$ : الدخل الثاني،  $x_L$ : الدخل  $L$ ، تتم عملية تعديل الأوزان أثناء مرحلة التدريب وفق المعادلة (8) [8],[9]

$$w'_{ljr} = w_{ljr} + \eta e \frac{df(\delta_{jr})}{de} y_{jr} \quad (8)$$

حيث  $w'_{ljr}$ : الوزن الجديد بعد التعديل للدخل  $l$  والعصبون  $j$  والطبقة  $r$

$w_{ljr}$ : الوزن القديم للدخل  $l$  والعصبون  $j$  والطبقة  $r$

$\eta$ : معدل التدريب

$e$ : الفرق بين الخرج الحالي والخرج المرغوب للشبكة

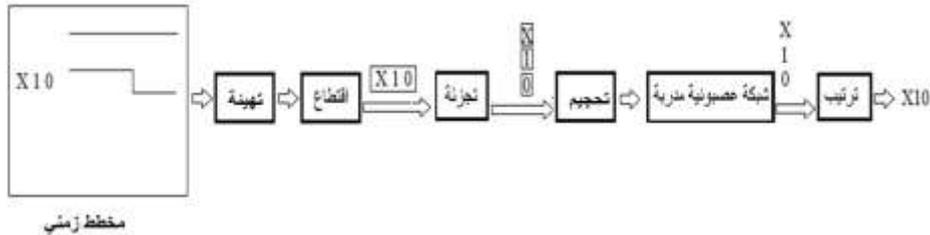
$y_{jr}$ : خرج العصبون  $j$  من الطبقة  $r$

$\delta_{jr}$ : أما فهو دخل تابع التنشيط ويعطى بالعلاقة (9) [7-9]

$$\delta_{jr} = \sum_{l=1}^L w_{ljr} x_l \quad (9)$$

## النتائج والمناقشة:

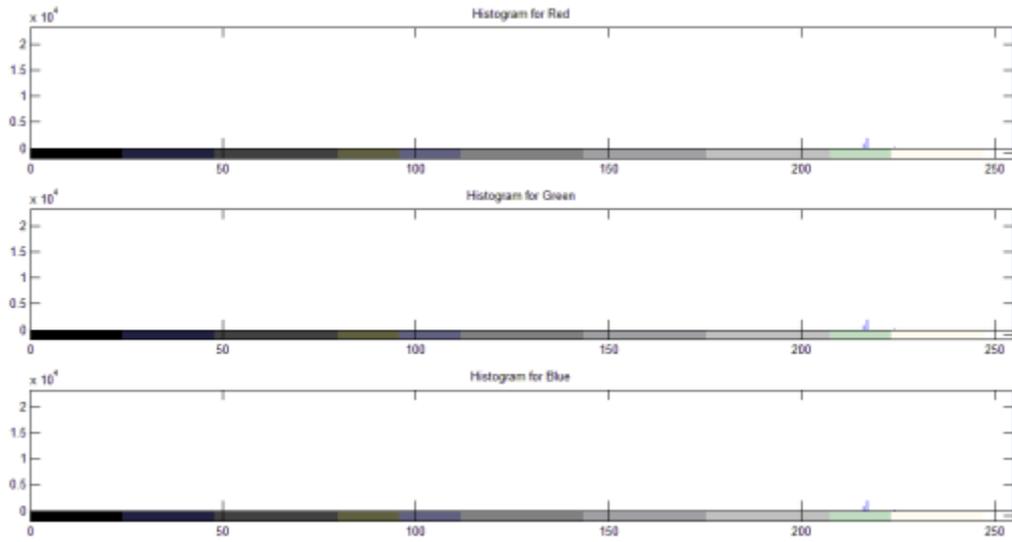
ي بين الشكل (3) المخطط الصندوقي المقترح لعمل المنظومة البرمجية المصممة ، حيث يتم إدخال صورة المخطط وتهيئته وتجزئة المسميات وتميرها للشبكة العصبونية المناسبة من أجل التعرف عليها ثم إعادة ترتيبها بالشكل الصحيح لنحصل على المسميات مع تعريفها.



الشكل(3) المخطط الصندوقي لعملية التعرف على صورة مسمى

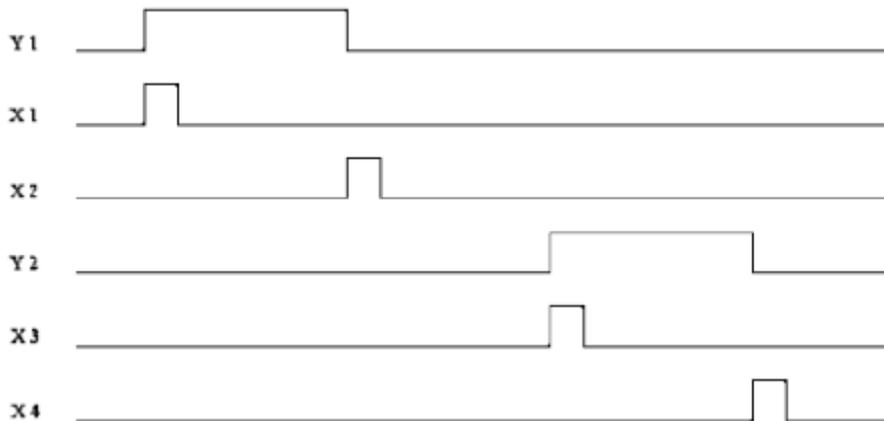
برسم المخطط البياني Histogram للأطياف اللونية الثلاثة لصورة المخطط الملونة كما في الشكل (4) نجد أن قيم الأطياف اللونية تتركز بعد القيمة الحدية 200، لذلك تم تحويل صورة المخطط الزمني من الشكل اللوني RGB إلى الشكل الرقمي Binary، بالاعتماد على المقارنة اللونية مع العتبة الحدية threshold التي أخذت عند 200، كما هو مبين بالعلاقة (10) المقترحة، حيث  $P_b$ : الصورة الثنائية binary image الناتجة عن ترشيح الصورة اللونية  $P_{RGB}$ ، وبسبب تماثل قيم الأطياف اللونية نجد أن مخططات Histogram للأطياف اللونية الثلاثة متماثلة عيّن الشكل (4) صورة المخطط الزمني بعد تحويله إلى الشكل الرقمي.

$$P_b = \begin{cases} 1; & P_{RGB} > threshold \\ 0; & P_{RGB} < threshold \end{cases} \quad (10)$$



الشكل (4) مخطط Histogram لصورة المخطط الزمني

بتطبيق العلاقة (10) على صورة المخطط الزمني العيّن بالشكل (1) من أجل ترشيحه نحصل على الصورة الرقمية الموافقة له والمبينة بالشكل (5)



الشكل (5) الصورة الرقمية للمخطط الزمني الناتج عن الترشيح

نحصل على صور مسميات المخطط الزمني بشكل مجزأ من الصورة الرقمية للمخطط الزمني باستخدام خوارزمية التقسيم المكاني كما هو مبين بالشكل (6)

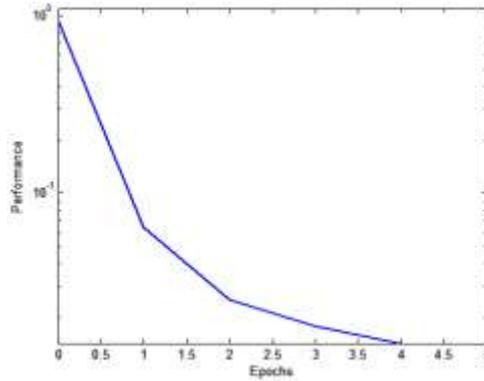
Y X X Y X X  
1 1 2 2 3 4

الشكل (6) صور مسميات المخطط الزمني

يتم إعادة تحجيم صور المسميات بتحديد  $N_a = 10$  و  $M_a = 10$  بناءً على عدد مداخل الشبكة العصبونية حيث يكون جدائهما مساوٍ إلى عدد مداخل الشبكة العصبونية التصنيفية  $R = N_a \times M_a = 100$  و عدد عصبونات الشبكة التصنيفية  $S = 14$ ، إذ تم تخصيص عصبون لكل صورة رقم (0,1,2,3,...,9)، وعصبون لصورة المسمى X، وآخر للمسمى Y، وكذلك الأمر للمسميين T و C، أُخِذَتْ ستون عينة تدريبية والمبينة بالشكل (7) لتدريب الشبكة التي تم بناؤها، وفق قواعد تدريب شبكة Perceptron المعطاة بالعلاقتين (5) و (6)، نبين بالشكل (8) منحنى التدريب الموافق لعملية تدريب.

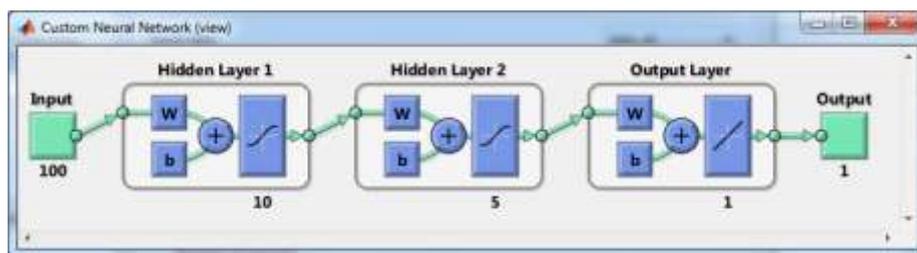
Y X X Y X 9 5 1 2 2  
1 T 7 C 3 0 6 1 8 4  
Y X 7 C 6 1 8 4 7 C  
1 1 8 4 3 0 X 9 5 T  
Y X 1 2 X 9 5 T X Y  
1 X Y 2 3 0 6 1 2 2

الشكل (7) قاعدة البيانات التدريبية للشبكة التصنيفية



الشكل (8) منحنى التدريب

وقد تم بناء شبكة عصبونية تمييزية مكونة من ثلاث طبقات، كما هو موضح بالشكل (9)، الطبقة الأولى تحتوي عشرة عصبونات والثانية خمسة عصبونات والثالثة عصبون واحد، تقوم هذه الشبكة بتمييز صور أحرف الأبجدية الإنكليزية، وتعطي على خرجها شفرة ASCII الموافقة لصورة الحرف المدخل للشبكة، أي دخلها عبارة عن صورة لمعرف ما وخرجها شفرة ASCII له.



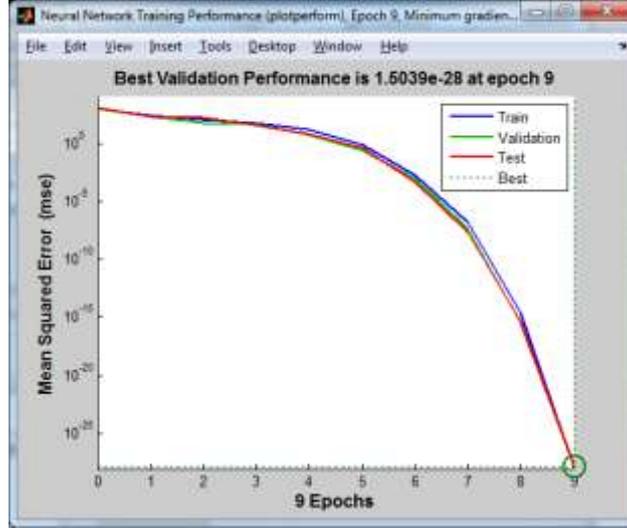
الشكل (9) الشبكة التمييزية

دُرِّبَت الشبكة على قاعدة بيانات - المبينة بالشكل (10) - تحتوي صور كافة الأحرف الأبجدية، وذلك لحالتي الأحرف، بشكلها الكبير والصغير . يبين الشكل (11) منحنى التدريب الخاص بهذه الشبكة، حيث بلغ متوسط مربع الخطأ لكافة البيانات (التدريب والتحقق والاختبار) قيمة أقل من  $10^{-25}$  عند عهد (epoch) التدريب التاسع، أي إن نسبة التمييز ستكون 100%، وهذا ما تؤكد نسبة موافقة البيانات كما هو مبين بالشكل (12)، حيث كانت نسبة الموافقة  $R = 100\% = 1$  لكافة البيانات التدريبية والاختبارية والتحقق، وبالتالي يمكن لهذه الشبكة تمييز كافة صور الحروف الأبجدية الانكليزية، ومنه التعرف على كافة صور مسميات المخططات الزمنية.

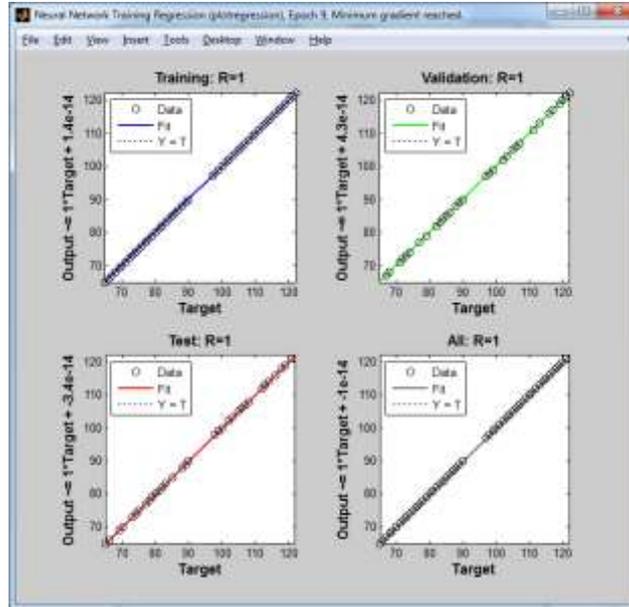
تأخذ أحرف الأبجدية الانكليزية قيم ضمن المجال [65,90] للأحرف بشكلها A,B,...,Z وضمن المجال [97,122] للأحرف بشكلها a,b,...,z، وبما أنه تم أخذ كافة الأحرف كبيانات تدريبية، لذلك تتوزع البيانات Data ضمن هذين المجالين كما هو مبين بالشكل (12)، مما يفسر وجود انقطاع بين القيمتين {91,96}، في حين يتم انتقاء بعض الأحرف لا على التعيين كبيانات التحقق Validation وبعضها الآخر كبيانات اختبار Test ويبين الشكل (12) أن منحنى الملائمة Fit يمر من كافة البيانات سواء التدريبية أو بيانات التحقق أو الاختبار كلاً على حدا، وبالتالي البيانات الكلية All، مما يفسر تطابق منحنيات الشكل (12).



الشكل (10) قاعدة البيانات التدريبية للشبكة التمييزية

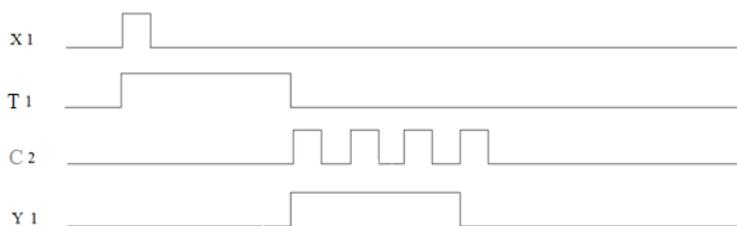


الشكل (11) منحني تدريبي الشبكة التمييزية



الشكل (12) معدل الموائمة لمختلف بيانات الشبكة (تدريب والتحقق والاختبار والكل)

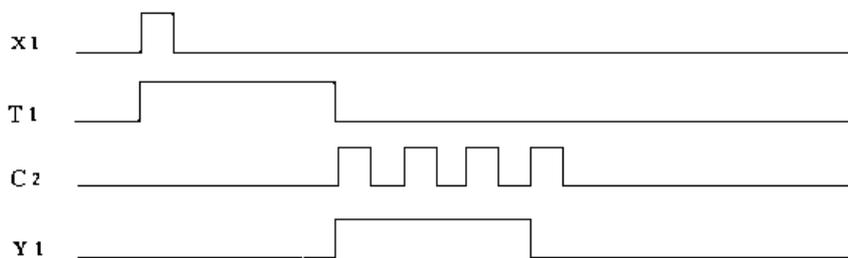
إن عملية التعرف على صور مسميات المخططات الزمنية عملية مهمة لتمييز المخطط الواحد عن الآخر حاسوبياً، أي جعل الحاسوب قادر على تمييز مسمى المخطط ذاتياً، وتبرز أهمية هذه العملية في عمليات البرمجة الآلية، تم اختبار المنظومة المصممة لهذا الغرض على نظام مؤتمت والمبين بالشكل (13)، حيث عند إعطاء إشارة على المدخل  $X_1$ ، يتم تفعيل خرج  $Y_1$  وتشغيل عداد  $C_2$  بعد فترة زمنية يحددها المؤقت  $T_1$ ، عند العدة الرابعة يتم إلغاء تفعيل الخرج  $Y_1$ ، فإنه يمكن إجراء عملية التعرف على مسميات المخطط الزمني من خلال ما يلي:



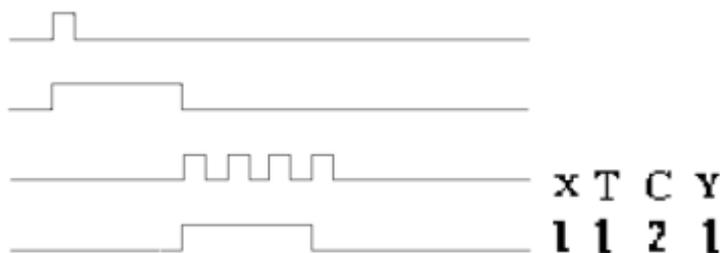
الشكل (13) صورة مخطط تشغيل لنظام مؤتمت

1- يتم تحويل صورة المخطط من الفضاء اللوني RGB إلى الشكل الرقمي بالعلاقة (1) كما هو مبين بالشكل (14).

2- تتم عملية التجزئة والاقطاع، كما هو مبين بالشكل (15)، بالاعتماد على خوارزمية التقسيم المكاني وفق إجرائي التقسيم العامودي والأفقي.



الشكل (14) صورة مخطط زمني لنظام مؤتمت بالشكل الرقمي



الشكل (15) تجزئة واقتطاع صورة مخطط زمني لنظام مؤتمت عن مسمياته

3- تتم عملية التعرف وفق آلية تصنيف المسميات من خلال إدخال كل جزء من المسمى على حدة إلى شبكة Perceptron مدربة لهذه الغرض، يكون خرج الشبكة موافقاً للجزء المُدخل للشبكة، كما هو موضح بالجدول (1)، يعطي شعاع خرج الشبكة دليل تصنيفي للصورة، يربطه مع جدول بيانات المقارنة المرجعية- الموضحة بالجدول (2)- يتم معرفة جزء المسمى، والتعرف على مسميات المخطط الزمني بإعادة ترتيب أجزاء المسمى صوراً وأسماءً وتمييز أجزاءه عن بعضها، نبين ذلك بالشكل (16).

الجدول (1) خرج الشبكة العصبونية الموافق للجزء المُدخل للشبكة

الجزء المُدخل للشبكة كصورة	خرج الشبكة الموافق
0	[1 0 0 0 0 0 0 0 0 0 0 0 0 0]
1	[0 1 0 0 0 0 0 0 0 0 0 0 0 0]
2	[0 0 1 0 0 0 0 0 0 0 0 0 0 0]

[0 0 0 1 0 0 0 0 0 0 0 0 0]	3
[0 0 0 0 1 0 0 0 0 0 0 0 0]	4
[0 0 0 0 0 1 0 0 0 0 0 0 0]	5
[0 0 0 0 0 0 1 0 0 0 0 0 0]	6
[0 0 0 0 0 0 0 1 0 0 0 0 0]	7
[0 0 0 0 0 0 0 0 1 0 0 0 0]	8
[0 0 0 0 0 0 0 0 0 1 0 0 0]	9
[0 0 0 0 0 0 0 0 0 0 1 0 0]	X
[0 0 0 0 0 0 0 0 0 0 0 1 0]	Y
[0 0 0 0 0 0 0 0 0 0 0 0 1]	C
[0 0 0 0 0 0 0 0 0 0 0 0 0 1]	T

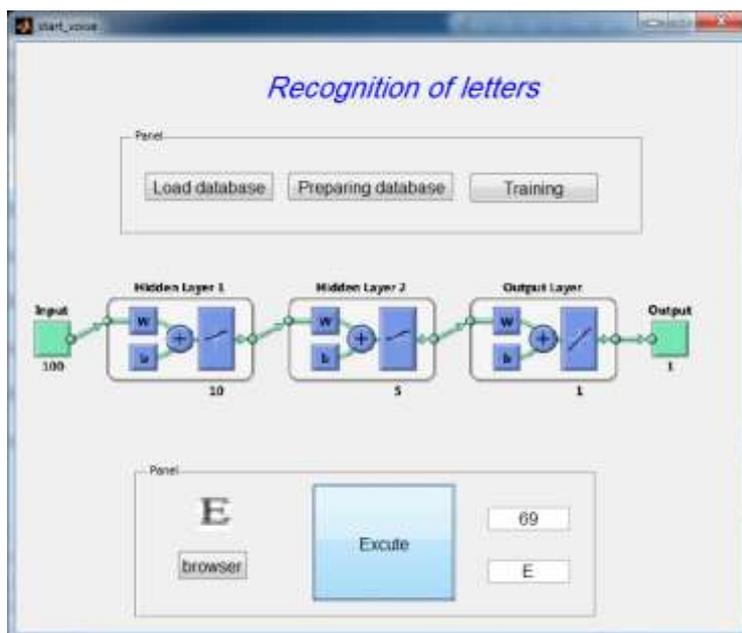
تقتصر فعالية الشبكة التصنيفية على المسميات المكونة من حرف واحد يليه رقم فقط، وهي مسميات محددة بالجدول (1) عددها (14) مع الأرقام وبدون الأرقام عددها (4)، و هي المسميات الأكثر استخداماً في المخططات الزمنية للمنظومات الصناعية، كما يتم تحجيم الصور قبل إدخالها إلى الشبكة، لأن الشبكة المصممة تُربت على عدد محدد من المداخل يتعلق بحجم الصورة وهو 100 دخل، وبالتالي يجب الالتزام بنفس الحجم اثناء وضع الشبكة قيد العمل.

الجدول(2)جدول بيانات المقارنة المرجعية

'0'	'1'	'2'	'3'	'4'	'5'	'6'	'7'	'8'	'9'	'X'	'Y'	'C'	'T'
		X1		T1		C2		Y1					
		X1		T1		C2		Y1					

الشكل(16) التعرف على مسميات مخطط تشغيل لنظام مؤتمت

4- تم تصميم برنامج خاص وبناءه باستخدام شبكة الانتشار العكسي لتمييز الأحرف من خلال التعرف عليها من صورها، كما هو مبين بالشكل (17)، حيث يحتوي على جزأين. جزء خاص بتحميل بيانات التدريب ثم تهيئتها وإجراء تدريب الشبكة يمكننا هذا الجزء من تدريب الشبكة على بيانات جديدة غير مدربة عليها سابقاً، وذلك لتفادي مشكلة تغيير نوع الخط المستخدم في صورة المخططات الزمنية. الجزء الثاني خاص بإجراء عملية تمييز وتعرف على المحرف من صورته، حيث بعد تحميل الصورة يتم تمريرها إلى الشبكة المدربة فتعطي شيفرة ASCII لصورة المحرف المُمر رقماً وكتابة، كما هو مبين بالشكل (17)، حيث أخذنا صورة المحرف E على سبيل المثال لا الحصر.



الشكل (17) تصميم وبناء شبكة تمييز محارف من صورها

4- تم اختبار المنظومة المصممة للتعرف على مسميات مخطط الزمني على مخططين زمنيين. الأول يمثل

عملية تشغيل وإطفاء، والثاني يمثل عملية تعبئة قوارير زجاجية.

5- يتم استيراد المخطط الزمني الأول وتحويله إلى صورة ثنائية، كما هو مبين بالشكل (18)، وإجراء تقسيم

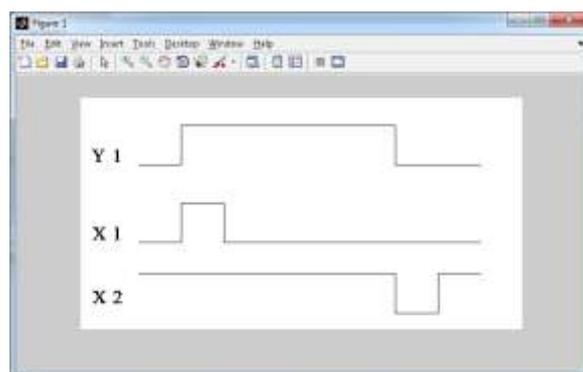
عامودي عليه فنتج ثلاث صور جزئية أي  $q = 3$  كما هو موضح بالشكل (19)، بإجراء تقسيم أفقي على هذه الصور

نحصل على صور المخططات والمسميات كلاً على حدا، نقوم بتمييز المسميات عن المخططات من خلال حجم

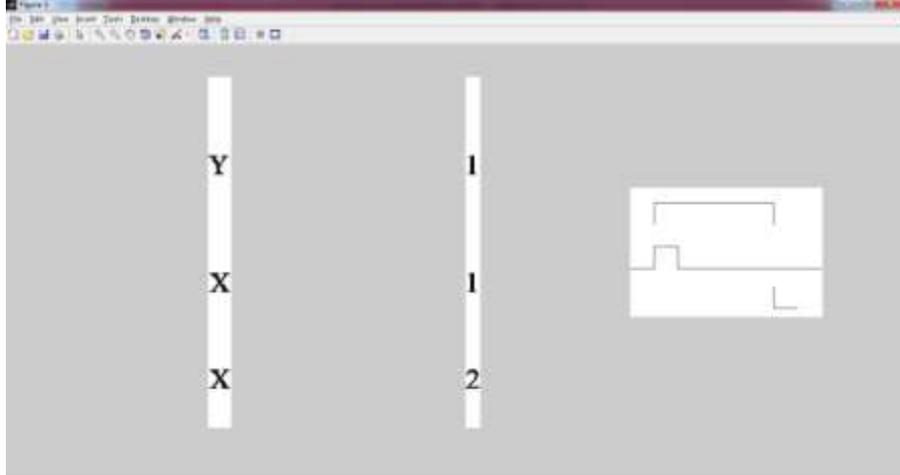
الصور الناتجة، حيث تكون صور المخططات ذات حجم أكبر، كما هو مبين بالشكلين (20) و (21)، بإدخال الصور

الجزئية على شبكة عصبونية نحصل على شيفرة ASCII لها، يتم إعادة ترتيبها وإظهارها مع صورها كما هو مبين

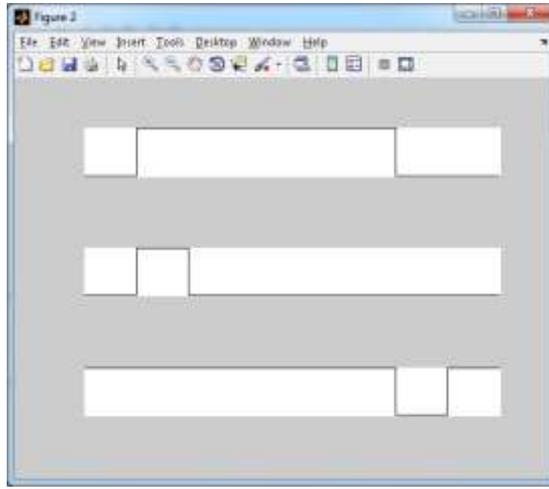
بالشكل (22).



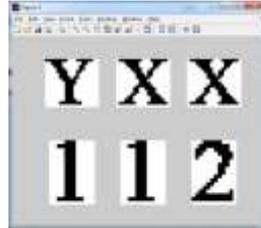
الشكل (18) المخطط الزمني لنظام تشغيل وإطفاء



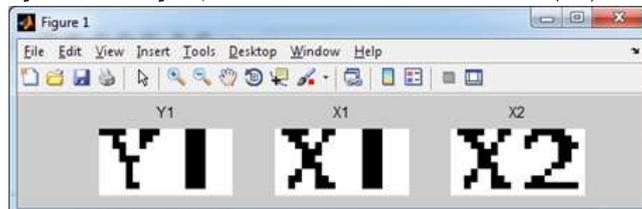
الشكل (19) الصور الناتجة بعد إجراء تقسيم عامودي للمخطط الزمني



الشكل (20) صور المخططات الناتجة بعد إجراء تقسيم الأفقي للمخطط الزمني

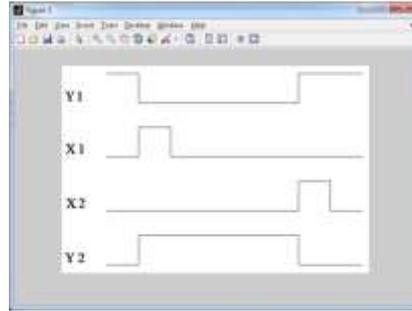


الشكل (21) صور المسميات الناتجة بعد إجراء تقسيم أفقي للمخطط الزمني

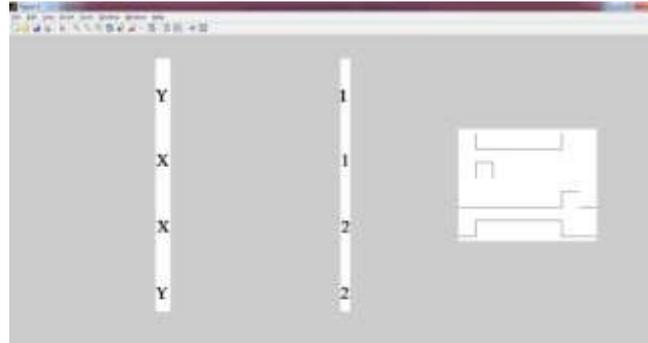


الشكل (22) التعرف على مسميات المخططات الزمنية لنظام إطفاء وتشغيل

5- تم اختبار منظومة على مخطط زمني لعملية إملء قوارير زجاجية، إذ يُحول إلى صورة ثنائية كما هو موضح بالشكل (23)، ويقسم عامودياً وأفقياً بالأشكال ( 24 ) و( 25 ) و( 26)، وتُدخل صور المسميات إلى شبكة العصبونية بعد إعادة تحجيمها.



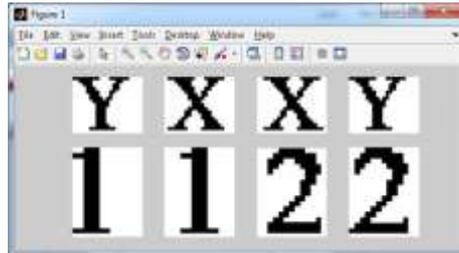
الشكل (23) مخطط الزمني لنظام إملء قوارير زجاجية.



الشكل (24) تقسيم المخطط الزمني عامودياً

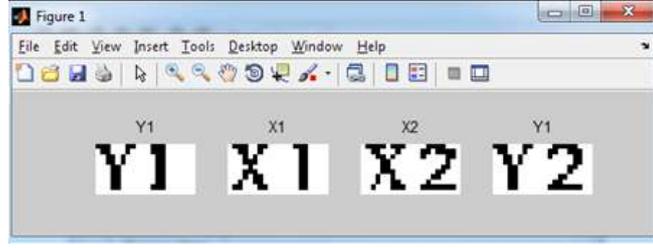


الشكل (25) تقسيم المخطط الزمني أفقياً (صور المخططات)



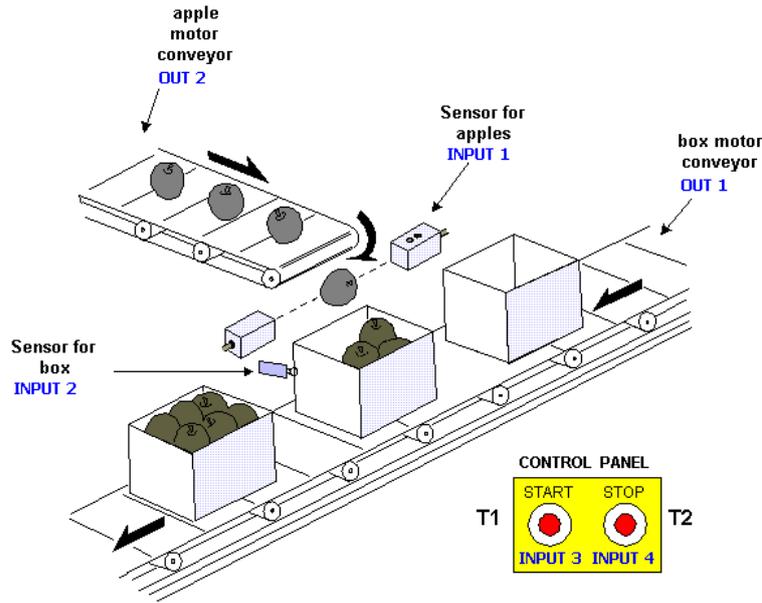
الشكل (26) تقسيم المخطط الزمني أفقياً (صور المسميات)

تتعرف الشبكة على الصورة وتعطي محارف، يعاد ترتيب المحارف المتعرف عليها وتظهر مع صورها كما هو مبين بالشكل (27)، وبالتالي تحقيق عملية التعرف على صور مسميات المخطط الزمني.



الشكل (27) التعرف على مسميات المخططات الزمنية لنظام إملء قواريير

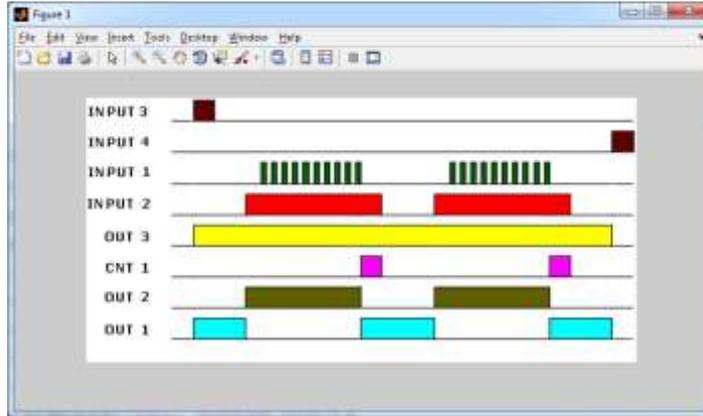
6- تم اختبار النظام المصمم على منظومة مؤتمتة لتعبئة علب تفاح المبينة بالشكل (28)، والمكونة من المداخل؛ INOUT1 حساس من أجل التفاح، INPUT2 حساس وجود صندوق التفاح، INPUT3 زر البدء، INPUT4 زر التوقف، ومن المخرجات؛ OUT1 محرك سير الناقل للصناديق، OUT2 محرك سير الناقل للتفاح.



الشكل (28) منظومة صناعية مؤتمتة لتعبئة علب تفاح

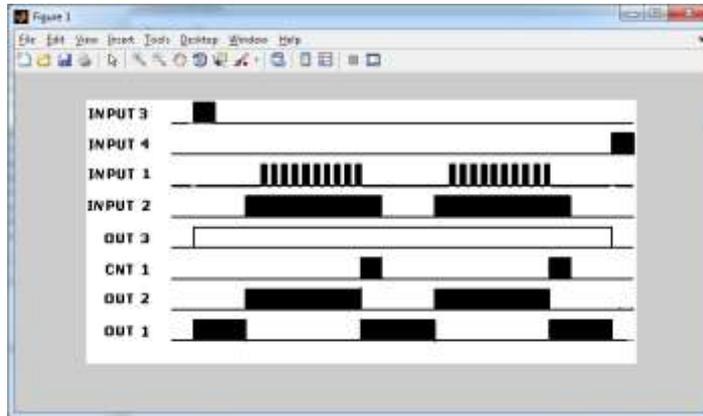
الشكل

تعمل منظومة تعبئة علب تفاح المبينة بالشكل (28) وفق المخططات الزمنية المبينة بالشكل (29)، حيث عند الضغط على زر البدء INPUT3 يبدأ محرك سير الناقل للصناديق OUT1 بالحركة حتى يصل صندوق إلى مكان توضع عند حساس وجود صندوق INPUT2، فيتوقف محرك سير الصندوق، ويبدأ محرك سير التفاح OUT2 بالحركة، فيعطي حساس التفاح INPUT1 نبضة عند مرور كل تفاحة، وعند النبضة العاشرة (بعد امتلاء صندوق التفاح بعشر تفاحات) يعطي العداد CNT1 نبضة فيعمل محرك سير الناقل للصناديق من جديد، الذي بدوره يجلب صندوق، ينقل الصندوق الممتلئ ليصل صندوق فارغ وتستمر دورة عمل المنظومة الصناعية المؤتمتة حتى الضغط على زر التوقف الموصول للمدخل INPUT4 فتتوقف المنظومة.

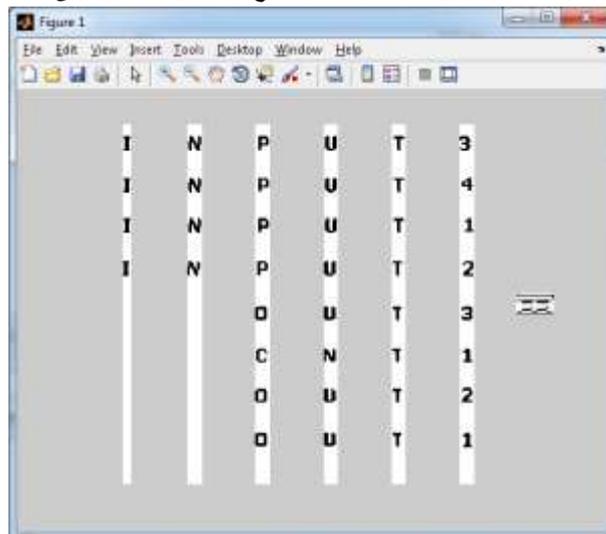


الشكل (29) المخطط الزمني لمنظومة صناعية مؤتمتة لتعبئة علب تفاح

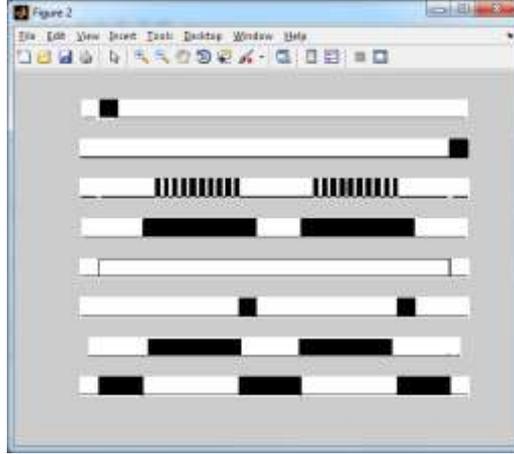
يتم تحويل صورة المخطط إلى الشكل الثنائي (الأبيض والأسود) وفق المعادلة (1) فنتج الصورة المبينة بالشكل (30) ويقسم المخطط الناتج عامودياً وأفقياً فنتج الأشكال (31) و(32) و(32) و(32)، وتُدخل صور المسميات إلى الشبكة العصبونية التمييزية بعد إعادة تحجيمها المبينة بالشكل (33) فيتم التعرف على كل محرف من صورته.



الشكل (30) المخطط الزمني لمنظومة صناعية مؤتمتة لتعبئة علب تفاح بعد إجراء التحويل إلى الشكل الثنائي (الأبيض والأسود)



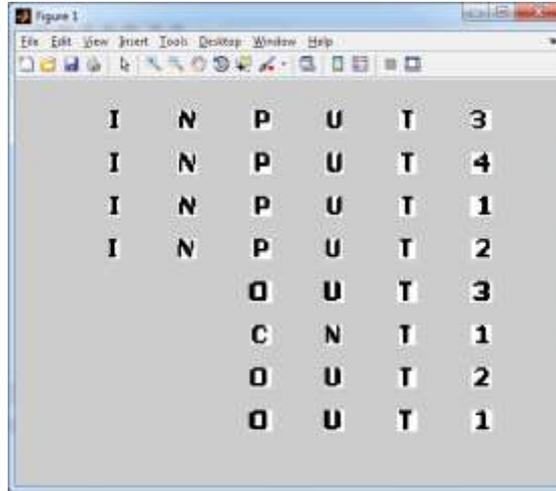
الشكل (31) الصور الناتجة بعد إجراء تقسيم عامودي للمخطط الزمني لمنظومة صناعية مؤتمتة لتعبئة علب تفاح



الشكل (32) تقسيم المخطط الزمني لمنظومة صناعية مؤتمتة لتعبئة علب تفاح أفقياً (صور المخططات)

ترتيب محارف المخطط الواحد مع تعريفاتها كما هو مبين في الشكل (34) الذي يوضح ويبين تعرف الحاسب

على صورة المخططات لمنظومة صناعية مؤتمتة آلياً.



الشكل (33) تقسيم المخطط الزمني لمنظومة صناعية مؤتمتة لتعبئة علب تفاح أفقياً (صور المسميات)



الشكل (34) التعرف على مسميات المخططات الزمنية لمنظومة صناعية مؤتمتة لتعبئة علب تفاح

## الاستنتاجات والتوصيات:

تم في هذا البحث تصميم منظومة للتعرف على مسميات المخططات الزمنية من صورها وتمييز كل منها عن حدا، إذ يتم إدخال صورة المخطط الزمني فيتعرف الحاسوب آلياً على المسميات ويعطي صورة كل مسمى مع اسمه الموافق كما هو مبين بالشكل (35)، أعطت نتائج بدقة 100% لأن العينات المطلوب التعرف عليها عددها 14 عينة فقط من أجل الطريقة التصنيفية باستخدام شبكة Perceptron، وذلك من أجل المسميات الأكثر شيوعاً في المخططات الزمنية الصناعية، في حين تم تدارك هذا الأمر والتعرف على كافة محارف الأبجدية الإنكليزية من بلطريقة التمييزية باستخدام شبكة الانتشار العكسي ، وقد طبقت الطريقة التمييزية على ثلاث مخططات زمنية لمنظومات صناعية مختلفة.



الشكل(35) التعرف على مسميات المخطط الزمني المبين بالشكل (1)

يختص هذا البحث بالتعرف على مسميات المخططات الزمنية من صورها، في حين توجد العديد من الأبحاث تهتم بالتعرف على صور المحارف فقط، حيث نجد أحد الباحثين [11] قد توصل إلى نسبة تعرف 99.99% من أجل المحارف (0~9) ونسبة 98% من أجل المحارف (A~Z) ونسبة أكثر من 94% للمحارف (a~z) ويرجع سبب عدم وصول الباحث لنسبة 100% كونه أخذ الأحرف بأحجام وألوان مختلفة كما هو موضح في الشكل (36) ولاختلاف البنية الطوبولوجية للشبكة المستخدمة، بينما في هذا البحث تم تحويل الصورة إلى الأبيض والأسود وتوحيد أحجام صور المحارف المقطعة من صورة المخطط الكلي.



الشكل(36) صور عينات المحارف بأحجام وألوان مختلفة [11]

## المراجع:

- [1] HARALICK;ROBERT M.; and LINDA G. Shapiro, *Computer and Robot Vision*, Volume I, Addison-Wesley, 1992, 28-48.
- [2] JAIME S. Cardoso;PEDROCarvalho;LUÍS F. Teixeira; Luís Corte-Real,*Partition-distance methods for assessing spatial segmentations of images and videos*, Computer Vision and Image Understanding, Volume 113, Issue 7, July 2009.
- [3]CHAOBO Min;JUNJU Zhang; Benkang Chang;BIN Sun; Yingjie Li,*Spatio-temporal segmentation of moving objects using edge features in infrared videos*; Optik - International Journal for Light and Electron Optics, Volume 125, Issue 7, April 2014.
- [4] ROSENBLATT, F., *Principles of Neurodynamics*, Washington D.C.: Spartan Press, 1961. [Rose61]
- [5] BROWN, M.; AN. P.;HARRIS. C.; WANGH.,*How Biased is your Multi-Layer Perceptron*. In: *World. Congress on Neural Networks*, Rome, 507 511(1993).
- [6] ROSENBLATT F., *1962- Principles of Neurodynamics*. Spartan Books, New York.
- [7] SRIDEVI, K.;SIVARAMAN, E.;MULLAI, P.;*Back propagation neural network modelling of biodegradation and fermentativebiohydrogen production using distillery wastewater in a hybrid upflow anaerobic sludge blanket reactor*, Bioresource Technology, In Press, Corrected Proof, 2014,Available online 27 March

- [8] FISZELEW, A.; BRITOS, P.; Perichisky, G.; GARCÍA-MARTÍNEZ, R., *Automatic Generation of Neural Networks based on Genetic Algorithms* Revista Eletrônica de Sistemas de Informação, 2003, 2(1), 1-7.[19]
- [9] JEREMY, Kun., *Neural Networks and the Backpropagation Algorithm*, Math  $\cap$  Programming Posted on December 9, 2012
- [10] CORBAL, L.; OSELLA MASSA G.; RUSSO, C.; LANZARINI, L.; DE GIUSTI, A., *Image Recovery Using a New Nonlinear Adaptive Filter Based on Neural Networks*, Journal of Computing and Information Technology - CIT 14, 2006, 4, 315–320 doi:10.2498 /cit.2006.04.07
- [11] Fazlul Kader, Md; Kaushik, Deb., *NEURAL NETWORK-BASED ENGLISH ALPHANUMERIC CHARACTER RECOGNITION*, International Journal of Computer Science, Engineering and Applications (IJCSEA) Vol.2, No.4, August 2012