

تحليل النماذج في الصور والتعرف عليها باستخدام الشبكات العصبونية

سهى عراج*

(تاريخ الإيداع 28 / 12 / 2014. قُبل للنشر في 23 / 2 / 2015)

□ ملخص □

يقدم البحث طريقة مطورة لكشف مكان نموذج الوجه في الصورة، وذلك بجمع أكثر من تقنية لتحقيق أفضل نسبة كشف. يبنى نموذج لون بشرة باستخدام الفضاء اللوني (RGB) Red, Green, Blue، لكشف مناطق البشرة وينتج المناطق المرشحة لتكون الوجه في الصورة. ومن خلال تقنية الشبكة العصبونية يتم تدريب مجموعة من صور الوجوه وصور لغير الوجوه (الخلفية)، بعد إسقاطها على حيز جزئي بواسطة تقنية تحليل المعاملات الأولية بهدف تقليل أبعاد صور التدريب وتقليل الزمن الحسابي. يوجد تعديلين للاستخدام التقليدي للشبكة العصبونية وهما: أولاً، تختبر الشبكة العصبونية مناطق الصورة المرشحة لتكون وجوه فقط، بالنتيجة يتم تقليل حيز البحث. ثانياً، يتم تكيف نافذة مسح الشبكة العصبونية لصورة الدخل، بحيث تعتمد على حجم المنطقة المرشحة لتكون وجه مما يمكن نظام الكشف من كشف الوجوه بحجوم متعددة.

الكلمات المفتاحية: كشف نموذج الوجه، شبكات عصبونية، تحليل المعاملات الأولية، كشف لون البشرة.

* قانم بالأعمال - قسم هندسة الاتصالات والالكترونيات - الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية

Pattern Analysis and detection in images using neural networks

Suha Arraj*

(Received 28 / 12 / 2014. Accepted 23 / 2 / 2015)

□ ABSTRACT □

A new face detection system is presented. The system combines several techniques for face detection to achieve better detection rates, a skin color model based on RGB color space is built and used to detect skin regions. The detected skin regions are the face candidate regions. Neural network is used and trained with training set of faces and non-faces that projected into subspace by principal component analysis technique. we have added two modifications for the classical use of neural networks in face detection. First, the neural network tests only the face candidate regions for faces, so the search space is reduced. Second, the window size used by the neural network in scanning the input image is adaptive and depends on the size of the face candidate region. This enables the face detection system to detect faces with any size.

Key words: face pattern detection, neural networks, principal component analysis, skin color.

*Academic Assistant, Faculty Of Communication And Electronic Engineering; University of Tishreen, Lattakia, Syria.

مقدمة:

الحاسب من أجل معالجة صور الوجوه بهدف عمليات الكشف والتعرف على الأشخاص. قد جذب تمييز نموذج الوجه وتعاييره الانتباه، وتمت دراسته لأكثر من 20 سنة من قبل علماء النفس والأعصاب و المهندسين والباحثين. أوائل المستخدمين لبرامج التعرف على الوجوه هم أجهزة الأمن للتخلص من الاحتيال والنصب واعتقال المشبوهين بواسطة سجلات (فيش) تتضمن صورالسارقين والمجرمين. ثم تعدد استخدام هذه البرامج لأغراض مختلفة كثيرة، من أهمها استخدام برنامج نظام التعرف على الوجوه في منح وتسليم تأشيرة الدخول للأشخاص[1].

أهمية البحث وأهدافه:

الخطوة الأولى لأي نظام تعرف على الوجوه هي كشف المواقع التي يمكن أن تتواجد فيها الوجوه في الصورة ، ومن أهم الصعوبات التي ترافق عملية الكشف[2]:

- تعدد حجوم الوجوه في الصورة.
- الحجب من قبل ساتر أو صورة وجه آخر.
- تعبيرات الوجه.
- اتجاه الوجه (زاوية الوجه بالنسبة لكاميرا التصوير).
- وجود مواصفات متغيرة كاللحية والشارب التي تغطي مساحات من الملامح.
- الإضاءة غير المناسبة.
- تدني مواصفات كاميرا التصوير.

يتلخص هدف البحث في اقتراح تقنية لتحسين كفاءة نظام كشف مكان نموذج الوجه في الصورة، عن طريق دمج أكثر من تقنية من التقنيات المعروفة باستخدام تجهيزات ذات تكاليف منخفضة وتطويرها برمجياً. يعد البحث أول مرحلة من مراحل تطوير نظام تعرف وتحديد هوية الشخص في الصورة، حيث تتعدد الجهات التي يمكن أن تستفيد من نظام التعرف. على اعتبار أن أية شركة أو مؤسسة حكومية أو تجارية تستطيع أن تراقب مداخلها ومخارجها اعتماداً على أشكال وجوه الموظفين التي يتم تخزينها في قاعدة البيانات، كما يمكن للمصارف أن تخزن بيانات صورة المودعين لتكون وسيلة حماية عند قيامهم بسحب النقود من المصرف أو الكباثن البعيدة عن مقر المصرف.

طرائق البحث ومواده:

تم في هذا البحث دراسة النقاط التالية:

1. دراسة مرجعية لتقنيات كشف مكان نموذج الوجه في الصورة.
2. تطبيق عملي برمجي لعدد من هذه التقنيات.
3. مناقشة نتائج الدراسة وصياغة الاستنتاجات.

3- تقنيات كشف مكان نموذج الوجه في الصورة

هناك طرائق عديدة لكشف مكان الوجه في الصور الساكنة والمتحركة (صور الفيديو)، تعتمد هذه الطرائق على تحليل المعلومات الموجودة في الصورة لتصنيف مناطق الصورة باعتماد خوارزميات كشف مناسبة . من أشهر هذه الطرائق [2] :

-طرائق تعتمد قاعدة المعارف (الذكاء الصناعي) [3].

-طرائق تعتمد السمات الوجهية والمسافات بينها، وتشمل: كشف لون البشرة وكشف موقع العين والأنف والفم والأذن وخطوط الوجه [4,2].

_ طرائق تعتمد مطابقة القالب [5].

_ طرائق تعتمد مظهر نموذج الوجه العام وتشمل: الشبكات العصبونية، تقنية الوجوه المميزة، تقنيات التوزيع، تقنية Support Vector Machine (SVM)، التعليم الاستقرائي، مصنفات (Naive Bayes) [8,7,6].

اعتمدنا في هذا البحث على التقنيات المعتمدة على السمات الوجهية والتقنيات المعتمدة على المظهر العام للصورة، وذلك باعتبار معياري سرعة الكشف ونسبة الكشف لهذه التقنيات والتكامل بينها. حيث:

سرعة الكشف: هي الزمن اللازم للتعرف على مكان وجود الوجه في الصورة.

نسبة الكشف: عدد عينات صور الوجوه المكتشفة بشكل صحيح بواسطة الحاسب بالنسبة للعدد الكلي للوجوه الموجودة في الصورة المدخلة.

• التقنيات المعتمدة على السمات الوجهية: تقوم بتطبيق عمليات الاشتقاق والتحليل للحصول على المعلومة المطلوبة عن الوجه، وهذه السمات هي لون البشرة في الوجه وشكل الوجه و الملامح الوجهية (عيون، أنف، فم، المسافات بين هذه الملامح، إلخ . . .).

• التقنيات المعتمدة على المظهر العام للصورة: حيث تتعامل مع كشف الوجه كمسألة تمييز نموذج عام، وتستخدم خوارزميات تدريب لتصنيف مناطق الصورة إلى نماذج وجوه ونماذج غير الوجوه (faces ,nonfaces) . من هذه التقنيات، الشبكات العصبونية وتقنية الوجوه المميزة.

يبين الجدول (1) ميزات هذه التقنيات:

الجدول (1) يبين ميزات التقنيات المستخدمة

التقنية المستخدمة	سرعة الكشف	نسبة الكشف
السمات الوجهية [2]	عالية (عدة ثوان)	متوسطة (75_86)%
المظهر العام [6]	متوسطة (11_25) ثانية	عالية (تتجاوز 90%)

1 - تقنية كشف لون البشرة في الصورة

تعتبر تقنية كشف لون البشرة في الصورة من التقنيات المعتمدة على السمات الوجهية، وهي إجراء لإيجاد بيكسلات لون البشرة في الصورة أو الفيديو، ويستخدم لعدة أهداف:

- كشف الأشخاص.

- كشف الوجوه، وتعقب حركة الوجه.

- تعقب حركة اليد في تمييز الإشارة.

1- ميزات الطرق المعتمدة على لون البشرة

- فعالة عند تغيرات الدقة أو درجة الإيضاح (resolution) للصورة.

- تسمح بمعالجة سريعة.

- فعالة تحت ظروف حجب جزئية [4].

2- أطوار العمل:

تتضمن عملية كشف بيكسلات لون البشرة في الصورة طورين أساسيين وهما طور التدريب و طور الكشف.

• **طور التدريب:** يتم تدريب كاشف البشرة (skin detector) ويتطلب:

- جمع قاعدة بيانات لبقع البشرة من صور مختلفة لأناس مختلفين تحت حالات إضاءة مناسبة.

- اختيار فضاء لوني مناسب.

- تعليم مصنف البشرة لتعريف حد قرار لصنف لون البشرة.

• **طور الكشف:** يتم تحديد هوية بيكسلات البشرة في الصورة، ويتضمن:

- تحويل الصورة إلى نفس الفضاء اللوني الذي استخدم في طور التدريب.

- تصنيف كل بكسل باستخدام مصنف البشرة إما بشرة أو غير بشرة.

- يتطلب معالجة لاحقة بتطبيق عمليات هندسة شكلية للتأكيد على التجانس الفراغي للمناطق المكتشفة [4].

3- استخلاص السمات

▪ **السمات:** هي معاملات يتم حسابها واستنتاجها من الصورة باستخدام المعادلات الرياضية أو الإحصائية أو

إجراء بعض التحويلات اللازمة للصورة .

▪ **استخلاص السمات:** هي عملية الحصول على سمات مناسبة من الصورة وقادرة على تمييز هذه الصورة عن

غيرها وذلك حسب الغرض المطلوب [9].

إن استخلاص السمات من أهم مراحل نظام التعرف لأن نجاحها يؤدي إلى نجاح نظام التعرف ويجب أن تمثل

هذه السمات الأنماط بأقل حجم ممكن، أي يجب تقادي زيادة عدد السمات المستخدمة للإسراع في إنجاز اختبار

التعرف، والسمات التي يتم اختيارها هي المعطيات الناتجة عن التعلم، وتتحدد من خلال أكبر عدد ممكن من عينات

النماذج المعروفة في المسألة [10].

▪ **استخلاص السمات في المجال الترددي:** يتم استخلاص السمات في المجال الترددي (يتميز بالسرعة) [9]

من مصفوفة المعاملات الناتجة عن تحويل صورة التمثيل بإحدى التحويلات ثنائية البعد المعروفة:

• التحويل التجميعي المتقطع Discrete Cosine Transform (DCT).

• تحويل فورييه المتقطع ثنائي البعد Discrete Fourier Transform (2-D DFT) Two-

Dimensional.

• تحويل Gabor Transform.

• التحويل المويجي المتقطع ثنائي البعد Discrete Wavelet Transform (Two - (2-D DWT)

Dimensional)

• تحويل هوتيلينغ (تحليل المعاملات الأولية PCA) وهو التحويل الذي سننعمد عليه في دراستنا وذلك لأن مسألة بحثنا ذات طبيعة إحصائية ويعتبر هذا التحويل ملائم لمثل هذه المسائل.

4- تحليل المعاملات الأولية

وهي تقنية إحصائية، وجدت تطبيقات في مجالات متعددة، مثل تمييز الوجه وضغط الصور واستخلاص السمات والتصنيف.

كما أنها تقنية شائعة لإيجاد النماذج في بيانات عالية الأبعاد، وذلك بإسقاط هذه البيانات إلى حيز أخفض نسبياً مع الاحتفاظ بنسبة كبيرة من المعلومات التي تحملها تلك البيانات .

تستخدم هذه التقنية عدة مفاهيم رياضية كالمتوسط والانحراف المعياري والتباعد والأشعة المميزة والقيم المميزة حيث وصفت من قبل Turk and Pentland [7]:

وذلك بافتراض أشعة تمثل وجوه في مجموعة التدريب، حيث يمثل كل وجه بشعاع ذو s بعد، تعمل Pca على إيجاد حيز جزئي ذو t بعد، تكون الأشعة المميزة له متطابقة مع اتجاه التغير الأعظمي في حيز الصورة الأصلي وأبعاده هذا الحيز الجديد أخفض بكثير من أبعاد الحيز الأصلي للصورة ($t \ll s$). يتم إسقاط صور مجموعة التدريب على هذا الحيز الجزئي والحصول على مجموعة من الأوزان تصف مساهمة كل صورة. تعرف الأشعة المميزة بواسطة المصفوفة W_{pca} :

$$W_{pca} = \sum_{i=1}^m (X_i - M)(X_i - M)^T \quad (1)$$

$$M = \frac{1}{m} \sum_{i=1}^m X_i \quad (2)$$

m : عدد صور وجوه التدريب.

M : الوجه المتوسط لمجموعة صور وجوه التدريب.

X_i : الصورة ذات الترتيب i مع أعمدها المتسلسلة بشعاع. للمصفوفة (W_{pca})، شعاع مميز بالتوازي مع t قيمة مميزة الأكبر، بتشكيل مصفوفة الأشعة المميزة هذه نحصل على شعاع السمة (Feature vector).

$$\text{Feature vector} = (\text{eig1 eig2 eig3} \dots \text{eig } t)$$

نحصل على مصفوفة الصور الجديدة بأخذ منقول شعاع السمة وضربه مع مصفوفة W_{pca} :

$$W_{pca} \times \text{New Data} = \text{Feature vector}^T$$

وبذلك تقل أبعاد صور التدريب بالتوازي مع عدد الأشعة المميزة الموجودة ضمن شعاع السمة. حيث يتم تقليل الأبعاد عند حذف جزء من المعاملات التي تكون نسبة التشنت لها قليلة جداً، فعدد الأشعة المميزة يساوي تماماً عدد السمات ولكن بفضل القيم المميزة التي تحدد نسبة التشنت من أجل كل شعاع مميز يمكن معرفة ما هي المركبات التي يمكن حذفها .

وبعد إجراء الدراسة المرجعية وتوضيح القاعدة النظرية والرياضية لموضوع عملنا، نبين التطبيق العملي من خلال الخطوات الموجودة ضمن الفقرة التالية.

النتائج العملية

استخدمنا قاعدة بيانات معروفة باسم CBCL

<http://www.ai.mit.edu/projects/cbcl>

نستعرض بعض الأعمال التي تمت على قاعدة البيانات هذه في الجدول (1):

الجدول (1) يبين عدة أبحاث لكشف موقع نموذج الوجه في الصورة تمت على قاعدة البيانات CBCL

Year (عام النشر)	INSTITUTION (موقع البحث)	TITLE (عنوان البحث)	AUTHOR (الباحث)
2007	Center for Biological and Computational Learning, MIT	An Empirical Comparison of SNoW and SVMs for Face Detection	M. Alvira and R. Rifkin
2012	IEEE Transactions on Pattern Analysis and Machine Intelligence	Neural Network-Based Face Detection	H. A. Rowley and S. Baluja and T. Kanade
2004	Center for Biological and Computational Learning, MIT	Face Detection in Still Gray Images	B. Heisele and T. Poggio and M. Pontil

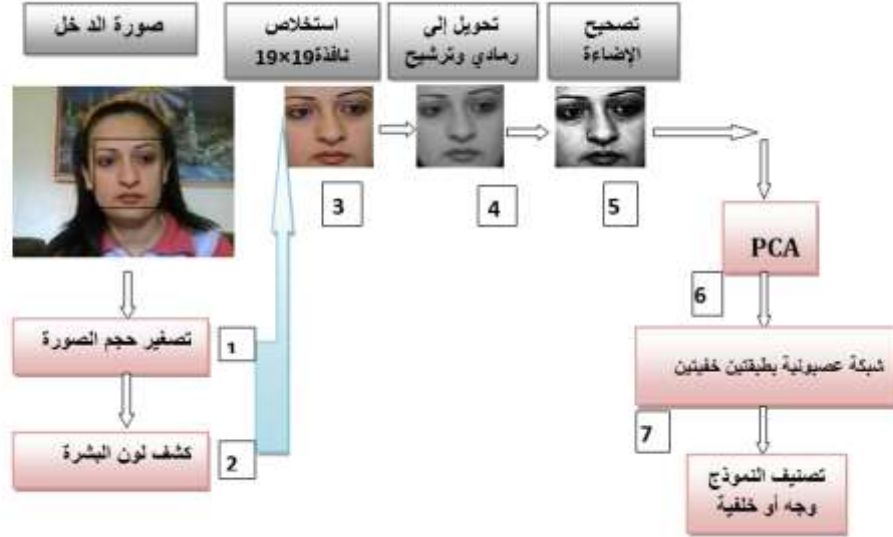
تضم قاعدة البيانات CBCL 30000 عينة (تدريب واختبار) وهي صور بحجم (19×19) تمت معالجتها مبدئياً وجاهزة للاستخدام، كما قمنا بإضافة بعض الصور لجعل الدراسة أكثر واقعية. ومرحلة المعالجة المبدئية المطبقة على قاعدة البيانات:

- تحويل الصورة الملونة إلى رمادي.
- ترشيح الصورة بواسطة المرشح الغوسي وحذف ضجيج الترددات العالية.
- ضبط تباين الصورة (تسوية الهستوغرام) وتقليل تأثيرات الإضاءة.

مراحل العمل المقترحة

- 1- تصغير حجم الصورة (480 × 640) بيكسل إلى حجم معين (60×80) بيكسل لتقليل حيز البحث، وترشيح الصورة لحذف ضجيج الترددات العالية.
- 2- كشف مناطق تواجد البشرة في الصورة (skin)، لتخفيض أخطاء الكشف وتسريع العمل. وإجراء عملية ضرب منطقي للصورة الثنائية الناتجة مع الصورة الملونة الأصلية.
- 1- بناء هرم الصورة بعدة حجوم من صورة (60×80) وذلك لكشف الوجوه ذات الأحجام المختلفة.
- 2- إجراء مسح المستطيلات بحجم (19×19) بيكسل على هرم الصورة في مجال البحث فقط، بعد تسوية الهيستوغرام لها وتحويلها إلى رمادي (لتسريع المعالجة).
- 3- إسقاط المستطيلات إلى PCA لإتقاق البعدية (19×19=361) لشعاع الصورة.
- 6- تصنيف المستطيلات المسقطة التي تم تخفيض أبعادها بواسطة مصنف شبكة عصبونية صناعية (ANN).
- 7- تقدير خرج الشبكة العصبونية على هرم الصورة وكشف وجوه متعددة.

يبين الشكل (1) مخططاً صندوقياً لكافة مراحل العمل المقترحة.

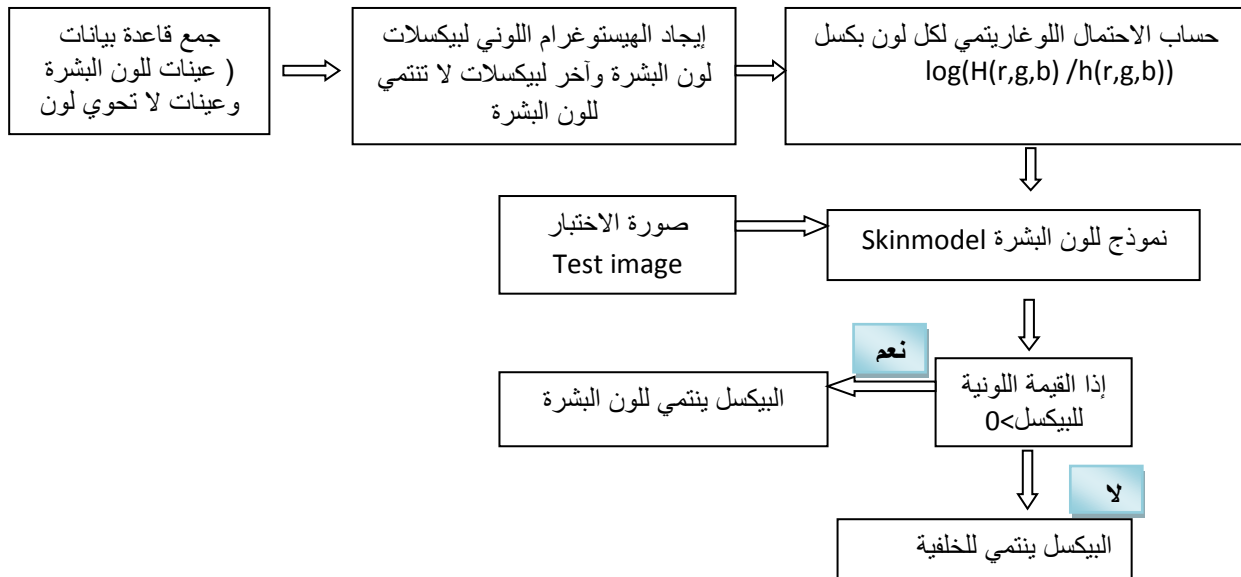


الشكل (1) يبين المخطط الصندوقي لمراحل العمل المقترحة

خوارزمية كشف لون البشرة

تتبع الخوارزمية الخطوات التالية:

- جمع عينات لون بشرة (Skin samples) متنوعة من أشخاص مختلفين ومن جنسيات مختلفة، وعينات أخرى لا تحوي بيكسلات لون بشرة (Nonskin samples).
- إيجاد الهستوغرام اللوني (RGB histogram) لأجل بيكسلات لون البشرة $H(r,g,b)$ وآخر لأجل بيكسلات لا تنتمي للون البشرة $h(r,g,b)$.
- حساب الاحتمال اللوغاريتمي $\log(H(r,g,b) / h(r,g,b))$ لأجل كل قيمة لونية (لون بيكسل) لاختبار انتمائه للون البشرة.
- النتيجة هي مصفوفة بقيم موجبة وسالبة، تدل القيم الموجبة على بيكسلات البشرة والقيم السالبة على بيكسلات غير البشرة وبذلك يتم الحصول على نموذج لون بشرة (Skin model).
- مقارنة نموذج لون بشرة مع بيكسلات صورة الاختبار وتعتيب النتيجة (قيمة العتبة=0) لتحديد انتماء البيكسل إلى لون البشرة أولاً، والصورة الناتجة هي صورة ثنائية (أبيض وأسود). المخطط التالي في الشكل (2) يوضح هذه الخطوات:




الشكل (2) يمثل المخطط الصندوقي لخوارزمية كشف لون البشرة في الصور

- تطبيق الكود البرمجي على مجموعة من الصور الملونة تحوي أشخاص من جنسيات متنوعة والحصول على النتائج التالية التي تظهر بيكسلات لون البشرة باللون الأبيض والخلفية باللون الأسود والصورة الناتجة هي صورة ثنائية (أبيض وأسود) كما هو مبين بالشكل (3):



الشكل (3) يبين نتائج كشف البشرة في الصور الملونة (Image1, Image2)

- إجراء عمليات هندسة شكلية، مثل عمليات تآكل وتوسيع متتالية (erotion, dilation) على الصورة الثنائية الناتجة للتأكيد على التجانس الفراغي للصورة كما هو موضح (c, d) في الشكل (4).
- إجراء عملية ضرب منطقي للصورة الثنائية (d) مع الصورة الملونة الأصلية (a) كما هو مبين في الصورة الناتجة (e) الشكل (4)، ويتم بذلك إلغاء أجزاء من الخلفية، وبالتالي تقليل حيز البحث وإنقاص أخطاء الكشف.



الشكل(4) يبين تطبيق عمليات شكلية على الصور الثنائية

باستخدام برنامج Matlab7.10.0 أدخلنا مجموعة متنوعة من الصور الملونة وأجرينا تحليل FPR,DR حيث:
 العدد الكلي لبكسلات البشرة / عدد بكسلات البشرة المصنفة بشكل صحيح = DR
 DR (Detection Rate): نسبة الكشف الصحيح.
 العدد الكلي لبكسلات البشرة / عدد بكسلات غير لون البشرة المصنفة كلون البشرة = FPR
 FPR (False Positive Rate): نسبة الخطأ الإيجابي. والشكل(5) يبين الصور الثنائية الناتجة:



الشكل(5) يبين الصور الثنائية الناتجة (Image 3 , mage 4)

توجد بعض الحالات تنتج فيها مناطق كبيرة من الخلفية على أنها لون بشرة (بيضاء) بسبب وجود مواد في الطبيعة لها نفس الدرجة اللونية للبشرة (طلاء، قماش، تراب . .) والصور التالية توضح هذه الحالات: , Image2
 Image5 (من الشكل (3) مكررة).



الشكل (6) يبين نتائج كشف البشرة في الصورة مع وجود مناطق خلفية لها نفس الدرجة اللونية للبشرة (Image2, Image5)

نبين نسب DR, FPR التي حصلنا عليها للصور الثنائية الموجودة في الأشكال السابقة ضمن الجدول (2):
الجدول (2) يبين نتائج FPR , DR لمجموعة صور ثنائية
الجدول (3) يبين مقارنة أداء مجموعة أبحاث لكشف البشرة

Method	DR (%)	FPR (%)
Our Work	98	15
Pixel based skin color detection technique[11]	94.17	17.3
Bayes SPM in RGB [12]	93.4	19.8
Maximum Entropy Model in RGB [13]	80	18
Gaussian Mixture Model in RGB [14]	80	9.5
Elliptical Boundary[15] Model	90	20.9

Image	DR (%)	FPR (%)
Image-1	98.64	5.43
Image-2	98.10	29.66
Image-3	97.45	1.88
Image-4	98.01	4.31
Image-5	85.23	36.24

نلاحظ من الجدول (2) أن الصور Image-2, Image-5 لها نسبة خطأ إيجابي عالية ولذلك يفضل إتباع العمل بتقنية تصنيف أخرى (مثل الشبكة العصبونية) [6].
بمقارنة أداء الخوارزمية التي اتبعناها لكشف البشرة في الصور مع أعمال أخرى في هذا المجال والمبينة في الجدول (3) نجد أننا حصلنا على نسبة كشف صحيح مرتفعة 98% مع نسبة خطأ منخفضة 15% مما يؤكد لنا فعالية هذه الطريقة لمتابعة عملنا.

خوارزمية تحليل المعاملات الأولية على الصور

يمكن باتباع إجرائية PCA تمثيل صور الوجوه بإسقاطها على عدد صغير من الصور المميزة التي تشتق بإيجاد الأشعة المميزة الأكثر أهمية لمصفوفة التباعد لصور التدريب وفق الخطوات التالية:

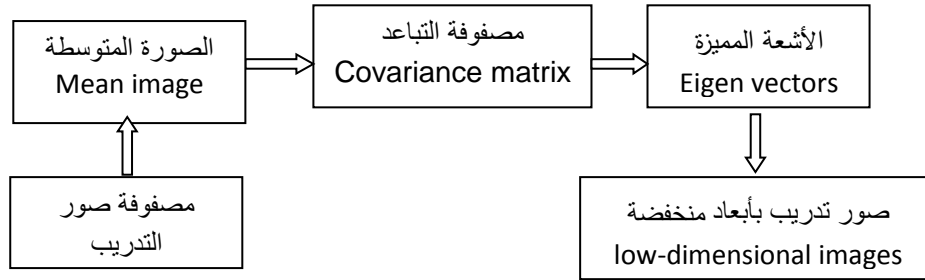
- قراءة صور التدريب ذات أبعاد (19 x 19) وجعل كل صورة بشكل شعاع عمود ووضعها في مصفوفة كبيرة.

- الحصول على الصورة المتوسطة لمجموعة صور التدريب.

- طرح المتوسط من كل صورة (عمود) في المصفوفة الناتجة في الخطوة الأولى وإيجاد مصفوفة التباعد (covariance) لصور التدريب .

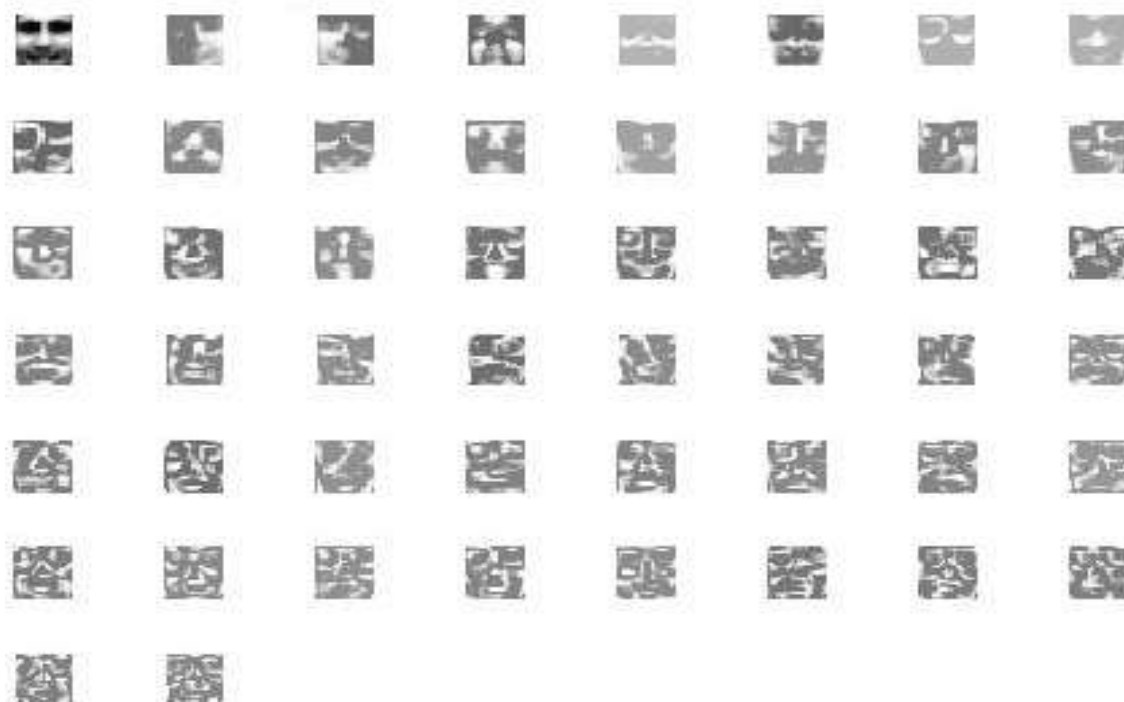
- الحصول على الأشعة المميزة من مصفوفة التباعد لصور التدريب وترتيبها حسب القيم المميزة المرتبطة بها (الأكبر أو الأكثر أهمية) واشتقاق الوجوه المميزة الممثلة لها.

- إسقاط مصفوفة صور التدريب على المعاملات الأساسية التي تم اختيارها والحصول على صور تدريب جديدة بأبعاد منخفضة (تساوي عدد الأشعة المميزة الأكثر أهمية التي احتفظنا بها). والمخطط الصندوقي التالي في الشكل (7) يمثل هذه الخطوات:



الشكل (7) يمثل المخطط الصندوقي لإجرائية تحليل المعاملات الأولية

بتطبيق هذه الخوارزمية ينتج لدينا في البداية 361 قيمة مميزة مرتبطة مع 361 شعاع مميز، نستخدم القيم المميزة التي تتراوح بين (5.4119_0.0087 X 1.0e+004) ونهمل القيم الصغيرة وبالتالي ينتج لدينا خمسين شعاع مميز (مرتبطة مع القيم المميزة الأكبر) وبذلك نحتفظ بنسبة 98% من معلومات الصورة [9]. لبناء الحيز الجزئي وإسقاط عينات الصور ضمن هذا الحيز، يتم تمثيل كل عينة بعدد من المعاملات (السمات)=50 لتكون مداخل إلى الشبكة العصبونية. والشكل (8) يظهر الوجوه المميزة (تظهر عادة بشكل وجوه غير واضحة المعالم):



الشكل (8) يبين الوجوه المميزة الناتجة عن PCA

الشبكات العصبونية (شبكة الانتشار العكسي)

يتضمن تدريب الشبكة بطريقة الانتشار الخلفي ثلاثة مراحل:

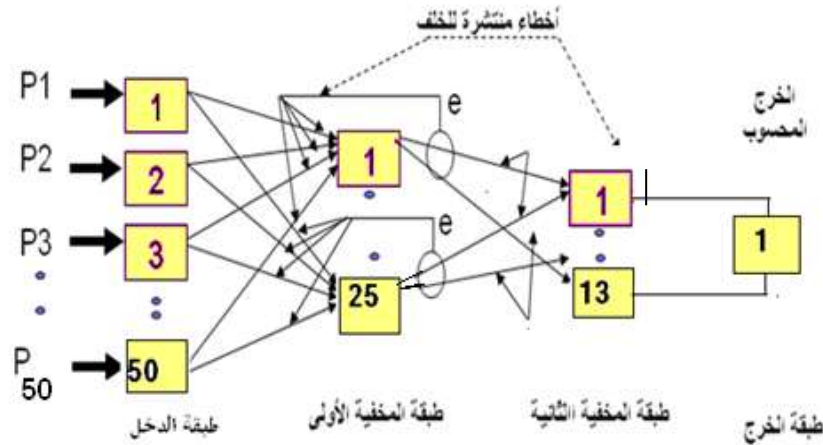
1. مرحلة التغذية الأمامية لعينات تدريب الدخل.
2. مرحلة الحساب والانتشار الخلفي للخطأ المتعلق بالخرج.
3. مرحلة توليف الأوزان.

وتبدأ مرحلة الاختبار بعد انتهاء مرحلة التدريب والتي تتضمن مرحلة واحدة فقط وهي طور الانتشار الأمامي، وحتى إذا كان التعليم بطيئاً فإن الشبكة المتدربة يمكنها أن تنتج إشارة خرجها بشكل سريع جداً. لقد تم تطوير طريقة الانتشار الخلفي لتحسين سرعة العملية التدريبية [16].

تصميم الشبكة العصبونية

بعد إجراء العديد من الاختبارات التجريبية، تم اختيار عدد السمات = 50 لكل عينة من الصور لتكون مداخل للشبكة العصبونية.

عدد العصبونات في كل من الطبقات الخفية، تم اختيارها بشكل تجريبي [2، 8] حيث كانت النتائج الأفضل عند (13 _ 25). وعصبون واحد لطبقة الخرج ونحدد له قيمة الخرج المطلوب (عادةً لعينات الوجوه 0.99 ، لعينات غير الوجوه 0.01). والشكل (9) يظهر بنية الشبكة العصبونية المستخدمة.



الشكل (9) يبين مخطط تصميم الشبكة العصبونية المستخدمة

تدريب الشبكة العصبونية

بالاعتماد على برنامج الماتلاب نستعمل التابع newff لتكوين الشبكة وله أربع محددات:

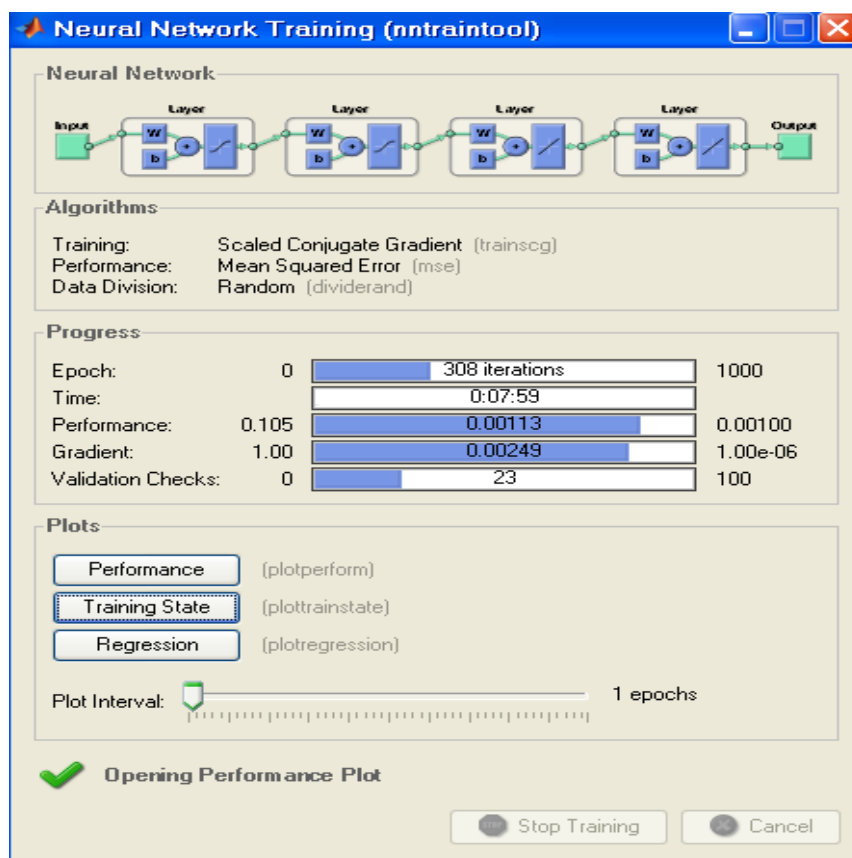
$$\text{net}=\text{newff}(P,T, [s1\ s2] ,\{TF1\ TF2 \} , BTF)$$

BTF: اسم تابع التدريب المستخدم وهو trainscg حيث يعتبر من التوابع الأسرع في عملية التدريب [12]

بارامترات تابع التدريب:

عند التدريب تظهر نافذة للتابع (nntraintool) ضمن الماتلاب تحتوي على عدد الطبقات، وشكل تابع التفعيل

في كل طبقة، وتغييرات بارامترات التدريب خلال عملية التدريب، وعلامة تبويب تدل على تابع أداء الشبكة performance ، كما يظهر لدينا في الشكل (10).




الشكل (10) يبين نافذة تدريب الشبكة مع الخصائص والبارامترات المتعلقة بها

عند الضغط في مربع الحوار ntraintool على علامة التبويب performance تابع الأداء، الذي يدل على تقليص الفرق بين الخرج المحسوب والمنشود، والذي نعلم منه فيما إذا تدرت الشبكة بحيث تصبح قادرة على إعطاء نتائج صحيحة من أجل عينات تدريب جديدة، تظهر لدينا النافذة التالية لتبين أداء الشبكة وتوقف عملية التدريب عند التكرار 308 عند الوصول إلى أصغر خطأ لمجموعات (التدريب، التصحيح، الاختبار). كما هو مبين في الشكل (11). ونبين أيضاً أداء مجموعة التصحيح validation التي تراقب عملية التدريب وتوقفها عند النقطة التي يبدأ عندها خطأ التدريب بالازدياد وتبين القيمة المتوقعة لخطأ النظام بشكل عام كما في الشكل (12).

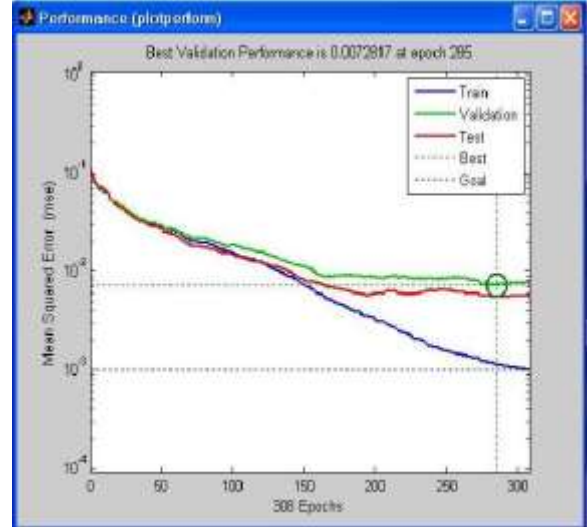
تستخدم عادة قاعدة دلنا لتعديل أوزان الترابطات بين وحدات الشبكة العصبية بحيث نحصل على قيمة خطأ كلي أصغري للفرق بين دخل وخرج وحدة الخرج للشبكة. أي بين y_{in} و t من أجل جميع عينات التدريب ويعطى مربع الخطأ بالعلاقة: (3) $SE = \sum_{i=1}^m (t - y_{in})^2$ حيث m : عدد عينات الدخل.

إن إيجاد قيمة دنيا لخطأ التدريب سوف يقلل القيمة المتوقعة (المتوسط) للخطأ (MSE) للتوزيع الاحتمالي

$$MSE = \sum_{i=1}^m (t - y_{in})^2 / m \quad (4) \text{ وتعطى بالعلاقة:}$$



الشكل (12) يبين أفضل أداء لمجموعة التصحيح (أقل قيمة متوقعة



الشكل (11) يعبر عن انخفاض قيمة تربيع الخطأ لمجموعات للخطأ (التدريب، التصحيح، الاختبار). العام عند التكرار 295

اختبار الشبكة (عدد السمات=50):

تم اختبار الشبكة باستخدام التعليمة $y = \text{sim}(\text{net}, \text{test.p})$

عدد عينات الاختبار = 6690

الأخطاء السلبية : عينات الوجوه المكتشفة بشكل خاطئ.

الأخطاء الإيجابية: عينات غير الوجوه (الخلفية) المكتشفة بشكل خاطئ.

نوضح نتائج الاختبار في هذه الحالة في الجدول (2):

الجدول (4) يبين نتائج الاختبار (عدد السمات=50)

شعاع السمات	زمن التدريب	دقة التصنيف	الأخطاء السلبية	الأخطاء الإيجابية
50	7.59 دقيقة	%99.2	%0.4	%0.4

نتائج الشبكة (عدد السمات=28):

نوضح النتائج العملية عند تقليل عدد السمات إلى العدد 28 من خلال الجدول (5):

الجدول (5) يبين نتائج الاختبار (عدد السمات=28)

شعاع السمات	زمن التدريب	دقة التصنيف	الأخطاء السلبية	الأخطاء الإيجابية
28	5.14 دقيقة	%98.14	%0.59	%1.27

الاستنتاجات والتوصيات:

بعد الاطلاع على العديد من الأبحاث الحديثة التي اعتمدت دمج أكثر من تقنية لتحسين أداء طرق كشف نموذج الوجه في الصور، نبين نسب وأخطاء الكشف لهذه الأبحاث (كما وردت ضمن المقال) بالإضافة إلى نتائج هذا البحث باستخدام قواعد بيانات مختلفة في الجدول (6):

الجدول (6) يبين نتائج الكشف لمجموعة من الأبحاث

الأعمال السابقة- العمل المقترح	نسب الكشف	الأخطاء الإيجابية
robust real time face detection [17] كشف وجه فعال في الزمن الحقيقي	%94.70	%2.94
integration of segmentation and template matching in face detection [5] تكامل التقطيع ومطابقة القالب في كشف الوجه	%91.49	%3.78
face detection using combination of classifiers [18] كشف الوجه باستخدام مجموعة مصنفات	%95.13	%2.50
face recognition using radial basis function neural network [19] تمييز الوجه باستخدام شبكة عصبونية ذات تابع أساس شعاعي	%98.9	% 0.7
Face Detection Based on Skin Color Using Neural Networks [6] كشف الوجه باستخدام لون البشرة والشبكات العصبونية	%91.43	%3.9
using of voroni diagram for face segmentation [20] استخدام مخطط voroni لتقطيع الوجه	%95.16	%2.43
تحليل النماذج في الصور والتعرف عليها باستخدام الشبكات العصبونية (العمل المقترح)	%99.2	% 0.4

من خلال الجدول (6) نجد تقنيات كشف لها نسب كشف جيدة كانت أعلاها %98.9 مع نسبة أخطاء إيجابية 0.7%.

الاستنتاجات:

مناقشة النتائج التي تم الحصول عليها، وذلك على النحو الآتي:

1- من أجل شعاع السمات (feature vector) مكوّن من 50 عنصر:

في هذه الحالة حصلنا على نسبة تصنيف جيدة جداً 99.2% بالمقارنة مع النسب التي تم الحصول عليها من التقنيات السابقة الموضحة في الجدول (6) وانخفضت أخطاء الكشف أيضاً بنسبة 0.4%.

2- من أجل شعاع السمات (feature vector) مكوّن من 28 عنصر:

وفي هذه الحالة انخفضت نسبة التصنيف من 99.2% إلى 98.14% بمقابل الحصول على نظام كشف أسرع. نلاحظ أنه تم تخفيض عدد المداخل إلى النصف تقريباً مع انخفاض قليل في نسبة التصنيف وزيادة في أخطاء الكشف.

التوصيات:

- تقليل عدد السمات المستخلصة من عينات صور التدريب للحصول على نظام أسرع ما يمكن مع (الحفاظ على النسب نفسها) .
- تطوير النظام الموجود في هذا البحث لكشف الوجوه غير الأمامية (تصنع زاوية مع كاميرا التصوير).
- دراسة إمكانية كشف الوجوه تحت ظروف إضاءة مختلفة.
- العمل على إيجاد نظام كشف وجوه يعمل ضمن الزمن الحقيقي (real time).

المراجع:

- 1- CHELLAPPA, R. ; AMIT, K. R. and SHAOHUA, K. Z."Recognition of Humans and Their Activities Using Video".United States of America,First Edition, 2012.
- 2- YANG,M.H. ; KRIEGMAN, J. D and AHUJA,N." Detecting Faces in Images: A Survey". IEEE 3-Transactions on Pattern Analysis and Intelligence,Vol.24,No.1,2004,34-58.
- 3- YANG,G. ; HUANG,T.S. "Human Face Detection in Complex Background." Pattern Recognition, Vol. 27, No. 1,2007, 53-63.
- 4- AHMED, E. ; CRYSTAL,M. and DUNXU, H."Skin Detection - a Short Tutorial". Piscataway, NJ, 08902, USA,2011.15.
- 5- XIE, G. ; GUPTA,A. "integration of segmentation and template matching in face detection", IEEE Trans. Pattern Analysis and Machine Intelligence,2009,14 .
- 6- MOSTAFA,L. ; ABD AL AZEEM,S."Face detection based on skin color using neural networks", GVIP conference, cairo,Egypt,2005.
- 7- TURK, M. ; PENTLAND,A. "Eigenfaces for Recognition". J. Cognitive Neuroscience, vol. 3, no. 1, 1991, 71-86 .
- 8- ROWLEY, H. ; BALUJA,S. and KANADE,T. "Neural Network-Based Face Detection." IEEE Trans. Pattern Analysis and Machine Intelligence,2003. vol. 20, no. 1,Jan,1998, 23-38 .
- 9- El-Bakry,M. H." a New Implementation of PCA for Fast Face Detection" International Journal of Intelligent Systems and Technologies ,2009.

10- KIRBY, M. ; SIROVICH, L. "Application of the Karhunen-Loe`ve Procedure for the Characterization of Human Faces". IEEE Trans.Pattern Analysis and Machine Intelligence, vol. 12, no. 1,1996, 103-108.

11- Roziati, Z ;Ihab, Z."Pixel – Based Skin Color Detection". Pattern Analysis and Machine Intelligence,2005.

12- JONES, M. J., AND REHG J. M." Bayes SPM in RGB ".In Proceedings of the CVPR '99, vol. 1, 274–280.2006.

13- JEDYNAK, B., ZHENG, H., DAOUDI,. "Maximum entropy models for skin detection", Technical Report XIII, Universite des Sciences et Technologies de-Lille, France. 2004.

14- AHMED, E. ; CRYSTAL,M. and DUNXU, H." Gaussian Mixture Model in RGB. Piscataway", NJ, 08902, USA, 15. 2009.

15- LEE, J. Y., YOO, S. I. "An elliptical boundary model for skin color detection". In Proceedings of the International Conference on Imaging Science, Systems, and Technology,2006.

16- المهندس علام زكي عيسى، الشبكات العصبونية البنية الهندسية، الخوارزميات، دار النشر و العلوم ،

الطبعة الأولى، 2000

17- VIOLA, P. ; JONES. M.J." Robust Real-Time Face Detection". International Journal of Computer,Vol. 57,No.2,2004,137–154.

18- RAMIRES,G.A.; FUENTES,G."face detection using combination of classifiers".In Proceeding of the 2nd canadian conference,May, 2005,610-615.

19- BALASUBER,M.; PALANIVEL,S ."real time face recognition using radial basis function neural networkl".Expert Systems with applications ,2009.

20- CHEDDED, et. al."ExPloiting voronoi diagram for face segmentation and feature extaction" . Elsevier Ltd, vol. 41, 2008,3842-3859.