

نقليل عدد نطاقات الصور الطيفية باستخدام خوارزمية تحليل المكونات الرئيسية وتطبيقه في التعرف على الوجوه

طالب الدراسات العليا: علي عبد الله الحسين

كلية الهندسة الميكانيكية والكهربائية - جامعة البعث

الاختصاص: الهندسة الالكترونية والاتصالات

الدكتور المشرف: نبيل دحدوح + الدكتور المشارك: عيد العبود

المخلص

في الوقت الحاضر، يتم استخدام تقنيات التصوير الطيفي على نطاق واسع. على الرغم من أن الصور الطيفية توفر معلومات كثيرة حول النطاقات، إلا أن أبعادها العالية وعددها نطاقاتها الكبير تزيد بشكل كبير من العبء الحسابي. تتمثل إحدى المهام الرئيسية في معالجة البيانات الطيفية في تقليل التكرار في المعلومات الطيفية والمكانية دون فقدان أي تفاصيل مهمة. في هذه المقالة، نقدم تقنية لتقليل عدد النطاقات الطيفية وهي خوارزمية تحليل المكونات الرئيسية (PCA) Principal Component Analysis حيث تم تخفيض عدد النطاقات الطيفية من 33 نطاق إلى 5 نطاقات واستخراج الميزات من كل نطاق باستخدام خوارزمية الرسم البياني للتدرج الموجه (HOG) Histogram of Oriented Gradients والتي تعالج العديد من التحديات المتعلقة بالتعرف على الوجوه البشرية مثل تغيرات الإضاءة وغيرها وللتحقق من المطابقة والتصنيف استخدامنا خوارزمية تصنيف الجوار الأقرب إلى K (KNN) K-Nearest Neighbor. تم تطبيق الخوارزميات وتقييم الأداء على قاعدة البيانات UWA-HSFD. تظهر النتائج التجريبية أن الخوارزمية المقترحة فعالة من حيث الدقة والزمن بالمقارنة مع الخوارزميات الأخرى.

كلمات مفتاحية: التعرف على الوجوه- التصوير الطيفي-تحليل المكونات الرئيسية- الرسم

البياني للتدرج الموجه-مصنف KNN

Reducing the number of spectral image bands using Principal Component Analysis algorithm and its-application in face recognition

Abstract

Nowadays, spectral imaging techniques are widely used. Although the spectral images provide a lot of information about the bands, their high dimensions and their large number of bands greatly increase the computational burden. One of the main tasks in spectral data processing is to reduce redundancy in spectral and spatial information without losing any important details. In this article, we present a technique to reduce the number of spectral bands which is the Principal Component Analysis algorithm (PCA) where the number of spectral bands was reduced from 33 to 5 bands and the features were extracted from each band using the Histogram of Oriented Gradient Graph (HOG) algorithm. Gradients, which address many challenges related to human face recognition such as lighting changes, etc., and to verify conformance and classification, we used the K (KNN) K-Nearest Neighbor classification algorithm. Algorithms and performance evaluation were applied to the UWA-HSFD database. The experimental results show that the proposed algorithm is efficient in terms of accuracy and time compared to other algorithms.

Keywords: Face recognition - Spectral imaging – PCA – HOG - KNN classifier

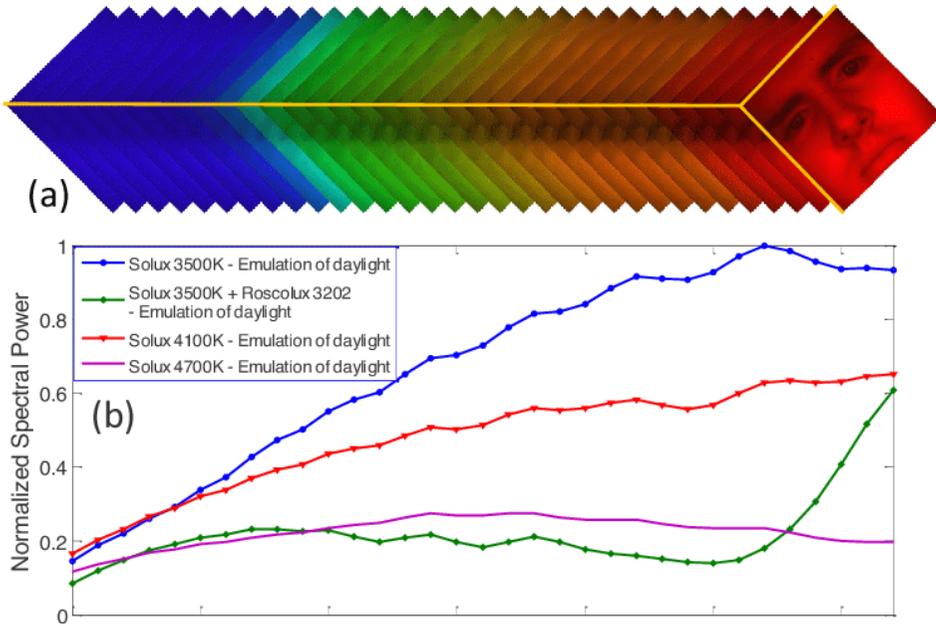
1 المقدمة

تجمع تكنولوجيا التصوير الطيفي (HSI) Hyperspectral imaging المعلومات من نطاقات طيفية مختلفة بما في ذلك السمات الهيكلية التشكيلية والكيميائية من خلال تعرف المعلومات المكانية والمعلومات الطيفية للأجسام [1]. ويمكن استخدامه في العديد من مجالات التعرف والتحقق، مثل تعرف الوجوه [2]، تقييم جودة الطعام [3]، وكشف سلامة الأغذية [4]، والعلاج الطبي مثل الكشف عن السرطان [5].

يوفر التصوير الطيفي فرصاً جديدة لتحسين دقة تعرف الوجوه. من خلال تقسيم الطيف إلى العديد من النطاقات الضيقة فإن الكاميرا الطيفية تكشف عن معلومات غير واضحة للعين البشرية أو لكاميرا RGB التقليدية كما أن إضافة البعد الطيفي يزيد من حجم قاعدة بيانات الأوجه أي يزيد عدد الصور التي يتم المقارنة بينها وهو ما يؤدي إلى تفاوت أكبر بين الأشخاص بسبب زيادة المعلومات لكل وجه من الوجوه كما أن الخصائص الطيفية لأنسجة الوجه مفيدة لزيادة التمييز بين المواد [6]. بالإضافة إلى المظهر السطحي، يمكن للقياسات الطيفية في نطاق الأشعة تحت الحمراء القريبة أيضاً أن تستشعر ميزات الأنسجة تحت السطحية التي تختلف اختلافاً كبيراً بين الشخص والآخر. يوجد ميزات أخرى عديدة للتصوير الطيفي منها تقديم اختبارات حيوية من خلال التمييز بين البصمة الطيفية للوجه البشري الحقيقي من جهة والأقنعة الاصطناعية أو الصور الفوتوغرافية من جهة أخرى.

يفرض التصوير الطيفي في مجال التعرف تحديات جديدة منها صعوبة الحصول على البيانات وانخفاض في نسبة الإشارة إلى الضجيج SNR وحجم البيانات الكبير. يتم التقاط الصور الطيفية بالتسلسل وطرق أخرى وبالتالي فإن حركات الأشخاص، وخاصةً رمش العينين، قد تؤدي إلى ازاحة مكانية بين النطاقات كما يؤدي اختلال نطاقات التردد إلى حدوث اختلافات بين الأشخاص يجب إلغاؤها دون المساس بزيادة المسافات بين الأشخاص التي يوفرها البعد الطيفي الإضافي. مصادر الضوء الطبيعية والاصطناعية لها كثافة منخفضة قريبة من مجموعة 400

نانومتر (الخط الأزرق) (الشكل 1 a). يؤدي هذا التأثير إلى جانب النفاذية المنخفضة وعرض النطاق الضيق لمرشحات تمرير النطاق عند هذه الأطوال الموجية (الشكل 1 b) إلى ظهور صور نطاقات ذات نسب إشارة إلى ضجيج منخفضة جداً. تزيد الأبعاد العالية للبيانات من صعوبة فصل المعلومات التمييزية المطلوبة إضافة إلى مشاكل الأبعاد الكبيرة.



الشكل (1): (a) مكعب صورة طيفية (b) طيف طبيعي لخمسة مصادر ضوئية مختلفة [7].

بدأت الأبحاث حول تعرف الوجه عن طريق الطيف في عام 2003 [6]. استخدمت لأول مرة قاعدة بيانات ذات وجه بشري طيفي للتعرف عليها ، حيث تحتوي قاعدة البيانات على 31 نطاق من 700 نانومتر إلى 1000 نانومتر. دمجت المعلومات

المكانية للصورة الطيفية للحصول على متجه أكثر تمثيلاً للتعرف على الوجه البشري، حيث تم اختيار كل عنصر صورة في الصورة المدمجة من نطاق معين في نفس الموضع. من خلال هذه الطريقة، يتم تحويل مكعب الصورة ثلاثي الأبعاد إلى صورة ثنائية الأبعاد.

أنشأت في عام 2010 قاعدة بيانات الوجه الطيفي، حيث تم اختيار النطاقات في قاعدة البيانات هذه ليكون الفاصل بين النطاقات 10 نانومتر ضمن المجال [400-720] نانومتر. خلال هذه العملية، واستناداً إلى نشاط الجلد (البشرة) البشري وخصائص الانعكاس للكرياتين والهيموغلوبين والميلانين، تم اختيار ست نطاقات طيفية كالنطاقات التجريبية التالية، وهي 530 نانومتر، 540 نانومتر، 550 نانومتر، 570 نانومتر، 580 نانومتر، و590 نانومتر. تم استخراج الميزات باستخدام خوارزمية 2D PCA. وأخيراً، تم استخدام تصنيف الجوار الأقرب إلى K للتصنيف [8].

تم اقتراح خوارزمية دمج النطاق لدمج الصور الطيفية في صورة واحدة [9]، واستخدمت خوارزمية انحدار المربعات الصغرى الجزئية (Partial Least Squares) للتحقق من دقة التعرف على الوجه وتصنيفه. في هذه الدراسة، تم تقسيم الصورة الطيفية أولاً إلى بلوكات $m \times m$ بواسطة نافذة منزلقة وحساب المساحة المغطاة بالنوافذ المنزلقة إلى قيمة من خلال سلسلة من العمليات الحسابية في كل مرة، تدمج هذه القيم في مصفوفة ثنائية الأبعاد أو الصورة النهائية المدمجة في النهاية. ثم استخدموا خوارزمية PLS لتصنيف الصورة، واختبار الخوارزمية على قواعد بيانات الصورة الوجهية المتاحة مقارنة مع عدة خوارزميات موجودة للتحقق من أدائها. أظهرت النتائج التجريبية أن خوارزمية الدمج في النطاق المقترح تؤدي أداءً أفضل من الخوارزميات المقارنة معها.

إحدى المشاكل المذكورة في تعرف الوجه هي مشكلة الأبعاد العالية curse of dimensionality [10]، مما يعني أن تقليل الأبعاد هو أحد المشكلات الحرجة

في مشكلة تصنيف صورة طيفية. إذا نظرنا لقاعدة بيانات الوجه الطيفي بدقة فسندج أن الفاصل الطيفي بين نطاقين متجاورين هو 10 نانومتر فقط، وهذا يؤدي إلى ترابط كبير بين صور النطاقات المجاورة. لذلك، يتم استخدام طرق اختيار النطاق على مجال واسع في تصنيف صورة الوجه والتي يمكن أن تحافظ على الخصائص الطيفية للوجه البشري دون أن تفقد الكثير من المعلومات [8]. ليس هناك شك في أن الخوارزمية القائمة على دمج النطاقات قد حصلت على أداء جيد، لكنها تستغرق زمناً طويلاً، وهي مشكلة كبيرة عند تطبيق هذه الخوارزمية في الواقع.

من التحديات الأخرى التي تواجه تقنيات تعرف الوجوه الطيفية هي أن الدراسات والأبحاث المتعلقة بالتعرف على الوجوه الطيفية قليلة للغاية بالإضافة إلى مشكلة قواعد البيانات القليلة في هذا المجال حيث تفتقر الجهود البحثية الحالية إلى تقييم شامل لأنها تستخدم عدداً صغيراً جداً من موضوعات الاختبار أو قواعد بيانات ذات حقوق ملكية. والأهم من ذلك، إن الدراسات الموجودة لا توفر مقارنات شاملة مع تقنيات التعرف على الوجوه الحديثة والتي لم يتم تصميمها خصيصاً للتعرف على الوجوه الطيفية ولكن يمكن تطبيقها مع بعض التعديلات. على سبيل المثال، يمكن التعامل مع كل نطاق من مكعب الصورة الطيفية كصورة منفصلة ويمكن تطبيق تقنيات التعرف على الوجوه الرمادية الموجودة.

2 هدف البحث

يهدف البحث إلى تحسين دقة تعرف الوجوه مع تخفيض التعقيد الحسابي من خلال تقليل عدد النطاقات الطيفية التي تفرضها تقنية التصوير الطيفي في أنظمة تعرف الوجوه حيث يتم اختيار النطاقات الأمثل باستخدام خوارزمية (PCA) والتي تحقق دقة تصنيف (مطابقة) مرضية مقارنة مع الدقة التي نحصل عليها باستخدام النطاقات كاملة.

3 أهمية البحث

أهمية البحث تكمن في تقليل الزمن اللازم للتصنيف والمطابقة مع الحفاظ على الدقة من خلال تقليل عدد النطاقات المطلوبة عند استخدام الخوارزميات الطيفية.

4 وطرق وأدوات البحث

طريقة البحث تجريبية وأدوات البحث هي برنامج MATLAB R2020b في مراحل تقليل النطاقات واستخراج الميزة والتصنيف وبالإستعانة ببرنامج ENVI 5.1 حصلنا على المكعب الطيفي المطلوب للمحاكاة في بيئة الـ MATLAB.

5 خوارزمية PCA

يعتمد تحليل المكون الرئيسي على حقيقة أن النطاقات المجاورة من الصور الفائقة الطيفية مترابطة بشكل كبير وغالباً ما تنقل نفس المعلومات تقريباً حول الكائن. يستخدم التحليل لتحويل البيانات الأصلية لإزالة الارتباط بين النطاقات.

يستخدم PCA الخصائص الإحصائية للنطاقات الطيفية لفحص تبعية النطاق أو الارتباط. قد نجد العديد من المرادفات لـ PCA، مثل تحويل Hotelling أو تحويل Karhunen-Loeve Woods 1993، فإن كل هذه المصطلحات تستند إلى نفس المبدأ الرياضي المعروف باسم تحليل القيمة المفردة (SVD) Singular Value Decomposition لمصفوفة التغاير لنطاقات الصورة الفائقة الطيفية لتحليلها [11].

5.1 آلية عمل الخوارزمية

ليكن لدينا عدد C من النطاقات الطيفية (X_1, X_2, \dots, X_C) والمعبر عنها بمكعب طيفي $cube$ في مجال التصوير الطيفي [8]، كل نطاق له الأبعاد $M \times N$ (2D).

• الخطوة الأولى:

إعادة تشكيل النطاق ثنائي البعد الى متجه أحادي البعد ID وبالتالي كل نطاق أصبح يمثل بمتجه $1 \times MN$ على شكل تتابع صفوف.

نرتب كل النطاقات للحصول على مصفوفة البيانات X أبعادها $C \times MN$. وفي هذه المصفوفة كل سطر يعبر عن نطاق طيفي.

• الخطوة الثانية:

إيجاد متوسط المصفوفة X : $m = \bar{X}$.

• الخطوة الثالثة:

طرح المتوسط m من كل سطر من المصفوفة X :

$$X_m = X - m \quad (1)$$

• الخطوة الرابعة:

إيجاد مصفوفة التغاير (covariance matrix) للمصفوفة X_m بالعلاقة (2):

$$Q = \left(\frac{X_m^T \cdot X_m}{n-1} \right) \quad (2)$$

حيث أن أبعاد المصفوفة X_m : $C \times MN$ وأبعاد المصفوفة X_m^T : $MN \times C$ وبالتالي تكون أبعاد المصفوفة Q : $MN \times MN$ كبيرة جداً جداً.

• الخطوة الخامسة:

حساب القيم الذاتية (eigenvalues) للمصفوفة Q بمعنى اخر أن نقوم بعملية الـ diagonalize للمصفوفة Q والهدف من هذه الخطوة هو جعل البيانات غير مترابطة.

يمكن الحصول على القيم الذاتية باستخدام مصفوفة التحويل P حيث:

$$P^{-1}QP = \Lambda \quad (3)$$

Λ : مصفوفة قطرية ولها الأبعاد $MN \times MN$

عندما تكون المصفوفة P المتعامدة نستطيع أن نكتب:

$$P^TQP = \Lambda \quad (4)$$

علماً أن القطر الرئيسي يحمل كل القيم الذاتية (eigen values) للمصفوفة Q .
نستطيع إيجاد مصفوفة التحويل P من خلال المتجهات الذاتية (eigen vectors) للمصفوفة Q ، يوجد MN متجه ذاتي بأبعاد $1 \times MN$ وهذه المتجهات متعامدة بالنسبة لبعضها البعض.

وعند ترتيب هذه المتجهات جنباً إلى جنب نحصل على المصفوفة P بأبعاد $MN \times MN$:

$$P = [p_1 p_2 p_3, \dots, p_{MN}] \quad (5)$$

نلاحظ أن أبعاد هذه المصفوفة كبيرة ايضاً وتسمى model matrix ويمكن أن تستخدم هذه المصفوفة P لفك ارتباط البيانات (decorrelate).

يعطى هذا التحويل بالعلاقة (6):

$$T_{c \times MN} = [X_m]_{c \times MN} \cdot [P]_{MN \times MN} = [X - m]_{c \times MN} \cdot [P]_{MN \times MN} \quad (6)$$

نلاحظ أن مجموعة البيانات المحولة بأبعاد $c \times MN$ وبالتالي لم يتم تقليل الأبعاد والسبب هو أننا أخذنا كامل المصفوفة P في عملية التحويل ونلاحظ أيضاً أن كل المتجهات الذاتية تمثل كل محاور المكونات (All principal axis) أي إلى الآن لم يتم تقليل الأبعاد.

إذاً لتقليل الأبعاد علينا اختيار بضع المتجهات للمكونات المسيطرة أو الرئيسية بمعنى آخر يجب أن نختار بضعة أعمدة فقط (eigen vectors) من المصفوفة P .

السؤال هو كيف سنختار الأعمدة القليلة هذه (eigen vectors) والإبقاء عليها فقط في المصفوفة P

والجواب، سنختار فقط العدد L من المتجهات الذاتية (أعمدة المصفوفة P) والذي يطابق العدد L من القيم الذاتية الأكبر لـ (λ) كما هو موضح في المعادلة (7):

$$T_{c \times L} = [X - m]_{c \times MN} \cdot [P_{PCA}]_{MN \times L} \quad (7)$$

العدد L سيتراوح بين [20-50] ونحن نعلم أن MN هي من رتبة الآلاف وبالتالي حصلنا على تقليل كبير جداً في أبعاد البيانات X حيث:

$$\{ [X]_{c \times MN} \square [T]_{c \times L} \} \quad (8)$$

نحن نعلم أن كل سطر بالمصفوفة $X_{c \times MN}$ يعبر عن نطاق بأبعاد $1 \times MN$ وبعد التحويل المصفوفة $T_{c \times L}$ كل نطاق أصبحت تمثل بأبعاد $1 \times L$

إذا كان لدينا صورة (نطاق) أو متجه فإن قانون PCA (من الصورة الأصلية للصورة ذات الأبعاد المنخفضة) يعطى بالعلاقة (9):

$$I_{PCA(1 \times L)} = [I - m]_{(1 \times MN)} \cdot [P_{PCA}]_{(MN \times L)} \quad (9)$$

5.2 اختيار النطاقات

نقوم باختيار النطاقات وفقاً لأعلى تباين لمعاملات النطاقات (coefficient) حسب المرجع [12] حيث تم استخدام خوارزمية تحليل المكون الرئيسي (PCA)، وهي كما ذكرنا أداة قوية في تقليل الأبعاد للبيانات شديدة الارتباط، لشرح مكعب البيانات متعدد النطاقات المحدد بواسطة عدد صغير من المتغيرات غير المرتبطة خطياً وفقاً للمعادلة (10):

$$PC_m = \sum_{i=1}^c W_i I_i \quad (10)$$

حيث:

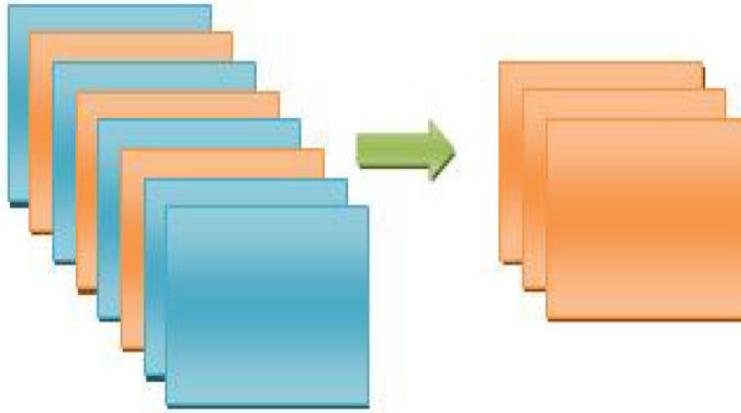
PC_m : هي صورة المكون الرئيسي m^{th} .

c : هو عدد الصور (النطاقات) في قاعدة بيانات صورة الوجه الفائقة الطيفية الأصلية.

w_i : هو معامل الوزن للصورة في النطاق الموجي i .

I_i : هو الصورة الأصلية في النطاق الموجي i .

يوضح الشكل (2) آلية عمل خوارزمية PCA في اختيار النطاقات



الشكل (2): تقنية PCA في اختيار النطاقات

6 استخراج الميزة Feature Extraction

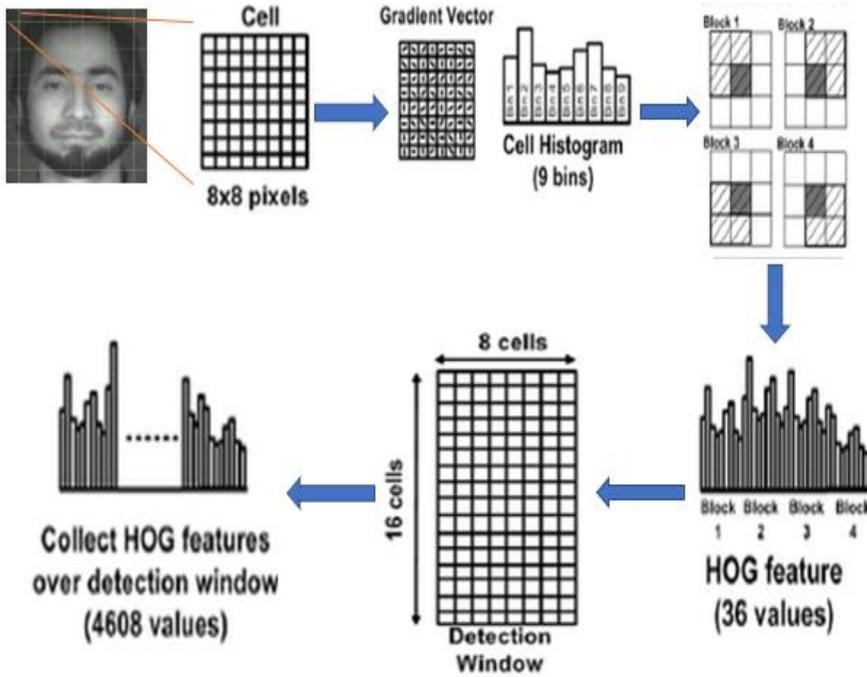
تستخدم خوارزمية الرسم البياني للتدرج الموجه (HOG) اتجاه التدرج اللوني للصورة والرسم البياني العادي لاستخراج الميزة، يتم تلخيص خطوات استخراج الميزة على النحو التالي:

بدايةً يتم تغيير حجم صورة الإدخال إلى 100×100 عنصر صورة. يتم بعد ذلك إجراء تسوية جاما Gamma على الصورة، متبوعاً بحساب حجم التدرج وزاويته لكل عنصر صورة. ثم يتم تقسيم الصورة الناتجة إلى شبكة من الخلايا cells بحجم 8×8 عنصر صورة. بعد ذلك، يتم وضع نافذة منزلة بقياس 16×16 بيكسل أعلى الشبكة وتزلق عبر الخلايا. في كل خطوة، تتداخل النافذة المنزلة مع أربع خلايا مكونةً بلوك ثم يتم تطبيع normalize الرسوم البيانية وتجميعها لتشكيل متجه ميزة 1-D.

خوارزمية HOG

الفكرة العامة لهذه الخوارزمية هي استخراج ميزة HOG باستخدام عدد انتقائي من صناديق (bins) الرسم البياني [13]. بدلاً من استخدام نفس العدد من صناديق

المرج التكراري في جميع أنحاء الصورة، تستخدم الطريقة المقترحة عدداً أكبر من صناديق الرسم البياني في مناطق الصورة التي قد تنتمي إلى الميزات الأساسية في الوجه (العينين- الأنف- الحاجبين- الخدين- الفم) بينما يكون عدد الصناديق أقل في باقي المناطق. لجعل الميزات أكثر ثباتاً في تغييرات الإضاءة في الصورة، يتم استخدام تسوية البلوكات المتعددة لتقليل حجم الميزة بشكل أكبر.



الشكل (3): ملخص خوارزمية الرسم البياني للتدرج الموجه HOG

يتم شرح تفاصيل كل خطوة من خطوات الطريقة المقترحة في الأقسام الفرعية التالية:

أ- المعالجة المسبقة للصور Image pre-processing

نقوم بتغيير قياس صورة الإدخال إلى 100×100 بيكسل لضمان استخدام حجم ثابت للصورة في استخراج الميزة. ثم يتم تحويل الصورة إلى تدرج الرمادي.

ب- حساب التدرج Gradient computation

بعد ذلك، يتم حساب التدرجات اللونية لكل بيكسل في الصورة باستخدام المعادلات (11-12):

$$dx = I(x + 1, y) - I(x, y) \quad (11)$$

$$dy = I(x, y + 1) - I(x, y) \quad (12)$$

حيث dx و dy هما التدرج الأفقي والعمودي على التوالي، $I(x, y)$ هي قيمة البيكسل في الموضع (x, y) يتم حساب اتجاه التدرج θ باستخدام المعادلة (13):

$$\theta(x, y) = \tan^{-1} \left(\frac{dy}{dx} \right) \quad (13)$$

ت- تقسيم الصورة المدخلة إلى خلايا وبلوكات

يتم تقسيم صورة التدرج الناتج إلى خلايا 8×8 بيكسل. يتم بعد ذلك تمرير نافذة منزلقة بحجم 16×16 بيكسل عبر الخلايا، حيث تغطي كل خطوة أربع خلايا مجاورة. تشكل كل مجموعة من أربع خلايا مجاورة بلوك. تتداخل البلوكات المجاورة مع بعضها البعض كما هو موضح في الشكل (3) وبهذه العملية، يتم تشكيل

إجمالي 120 بلوك على صورة 100×100 عنصر صورة (الشكل (4) يوضح أن عدد الخلايا هو 13×11 وبالتالي يكون عدد البلوكات الإجمالي 12×10).

ث- بناء الرسم البياني للتدرج الموجه باستخدام عدد انتقائي من

صناديق الرسم البياني

لكل بلوك، يتم إنشاء رسم بياني لاتجاه التدرج. يتم ذلك عن طريق اختيار زوايا الاتجاه لكل عنصر صورة في عدد محدد مسبقاً من صناديق الرسم البياني. سيؤدي استخدام عدد أكبر من الصناديق إلى استخراج معلومات توجيه أكثر تفصيلاً من الصورة ولكنه سيؤدي إلى إنشاء عدد أكبر من الميزات.

لتقليل حجم الميزة مع الاحتفاظ بالتفاصيل المهمة في الميزة، يتم استخدام عدد مختلف من صناديق الرسم البياني لمناطق مختلفة في الصورة. يتم استخدام عدد أكبر من صناديق الرسم البياني لاستخراج ميزات المناطق التي قد تنتمي إلى الميزات الأساسية بينما يتم استخدام عدد أقل من الصناديق لبقية المناطق.

لتحديد المناطق التي قد تنتمي إلى الميزات الأساسية، يتم إنشاء صورة متوسطة من عدد من عينات تدريب إيجابية. ثم يتم وضع إطار يوضح موضع البلوكات على متوسط الصورة كما هو موضح في الشكل 4 (الشكل الأيسر). من هذه الصورة، يتم تحديد البلوكات التي قد تحتوي على الميزات الأساسية. تظهر هذه البلوكات في الشكل 4 (الشكل الأيمن).

يتم استخدام عدد أكبر من صناديق الرسم البياني لاستخراج ميزات للبلوكات المظلمة بينما يتم استخدام عدد أقل من صناديق الرسم البياني لبقية البلوكات. يتم تحديد القيم المثلى للعدد المرتفع والمنخفض من الصناديق المراد استخدامها تجريبياً.



1	2	3	4	5	6	7
8	9	10	11	12	13	14
15	16	17	18	19	20	21
22	23	24	25	26	27	28
29	30	31	32	33	34	35
36	37	38	39	40	41	42
43	44	45	46	47	48	49
50	51	52	53	54	55	56
57	58	59	60	61	62	63
64	65	66	67	68	69	70
71	72	73	74	75	76	77
78	79	80	81	82	83	84
85	86	87	88	89	90	91
92	93	94	95	96	97	98
99	100	101	102	103	104	105

الشكل (4): الشكل الأيسر يوضح شبكة لإظهار موضع البلوكات المغطاة على الصورة المتوسطة الناتجة، الشكل الأيمن يوضح البلوكات المحددة التي تغطي الميزات الأهم في صورة الوجه

ج- تطبيع البلوك Block normalization

يتم استخدام مخطط تطبيع L2 لتطبيع قيم الرسم البياني لجعل الميزات أكثر ثباتاً مع التغييرات في الإضاءة.

استناداً إلى التجارب التي أجراها [16]، أظهرنا أن L2-المعياري هو أفضل مخططات التطبيع لاستخراج ميزة HOG وبالتالي يتم استخدامه في الطريقة المقترحة. يتم تعريف مخطط تسوية L2 باستخدام المعادلة (14):

$$v_n = v / \sqrt{\|v\|_2^2 + \epsilon^2} \quad (14)$$

حيث v هو متجه الميزة غير المطبوعة non-normalize، وهو متجه الخاصية الطبيعية، $\|v\|_2$ هي قيمة L2 المعيارية L2-norm و ϵ هو ثابت التطبيع الصغير لتجنب القسمة على الصفر. يتم حساب قيمة L2-norm من خلال المعادلة (15):

$$\|v\|_2 = \sqrt{\sum_{i=1}^n v_i^2} \quad (15)$$

يتم تنفيذ التطبيع متعدد البلوكات من خلال تجميع عدة بلوكات متجاورة وفقاً لعدد صناديق التوجيه المستخدمة في إنشاء المدرج التكراري. تم تشكيل حوالي الـ 30 مجموعة كما هو موضح في الشكل (5).

1		2		3
4		5		6
7	8	9	10	
12	13	14	15	16
17	18	19	20	21
22		23		24
25		26		27
28		29		30

الشكل (5): تجميع البلوكات لإنجاز خطوة التطبيع normalization

ثم يتم استخدام مخطط التطبيع L-2 لتطبيع جميع قيم المدرج التكراري في كل مجموعة. يتم أخيراً ربط الرسوم البيانية المطبوعة من جميع المجموعات لتشكيل متجه الميزة المقترح.

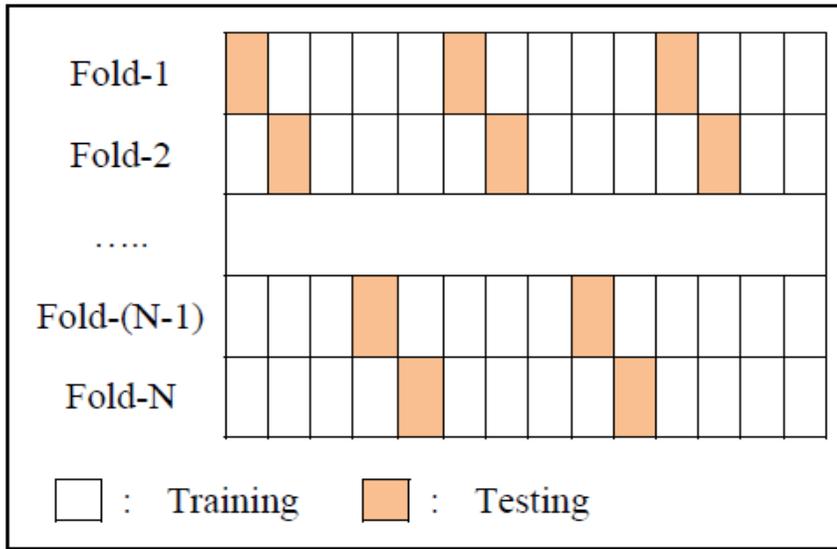
7 التصنيف

خوارزمية تصنيف الجوار الأقرب إلى K (K-Nearest Neighbor (KNN) هي طريقة تصنيف البيانات التي يمكن استخدامها كطريقة للتعرف على الوجوه [14]. يمثل كل بيكسل في الوجه معلومات فريدة. نقوم بالتعرف على الوجه بناءً على تصنيف كل بيكسل. تم تحديد الوجه بواسطة معظم الفئات مما أدى إلى تصنيف كل بيكسل. في آلية التعرف يجب إعادة تشكيل مصفوفة البيكسل لصورة الوجه إلى متجه قبل التصنيف. يتم وصف خوارزمية التعرف على الوجوه KNN المقترحة على النحو التالي:

1. تعديل أبعاد مصفوفة الوجه M-row و N-column (M x N) في متجه تبديل الوجه (MN x 1).
2. ترتيب كل متجه وجه في شكل مصفوفة (K x MN) باستخدام K هو عدد صور وجوه التدريب. يمثل كل صف صورة واحدة ويمثل كل عمود موضع البيكسل نفسه في كل صورة وجه.
3. تعديل مصفوفة اختبار الصورة في متجه تبديل الوجه بنفس طريقة صور تدريب (MN x 1).
4. حساب المسافة الإقليدية (d) بين كل عمود (i) في صورة الاختبار (x) وكل عمود (i) في صورة التدريب (y) وتوضح المعادلة (16) طريقة حساب المسافة الإقليدية:

$$d_E(x, y) = \sum_{i=1}^N \sqrt{x_i^2 - y_i^2} \quad (16)$$

5. تحديد التصنيف بناءً على أقصر مسافة للعمود بأكمله في كل صف.
6. تحديد التعرف على الوجوه على أساس أقرب الجار k.



الشكل (6) : N-Fold Cross Validation

8 الاختبارات والنتائج

8.1 قاعدة البيانات

من أجل تجاربنا، قامت جامعة غرب أستراليا بتطوير قاعدة بيانات الوجه الطيفي [9]، وهي معروفة باسم UWA-HSFD. قاعدة البيانات هذه تحمل اسم TIP 2013 & BMVC 2015. وهي عبارة عن مجموعة مكونة من 120 مكعب صورة من 70 شخصاً موزعة على عدة جلسات في كل جلسة يتم التقاط الصور الطيفية بحالة مختلفة عن الجلسة الأخرى (مع ذقن- بدون ذقن.... الخ) مع كل مكعب مصور يتكون من 33 نطاقاً وراء نطاق الطيفي من 400 إلى 720 نانومتر على خطوات من 10 نانومتر.

8.2 بارامترات البحث

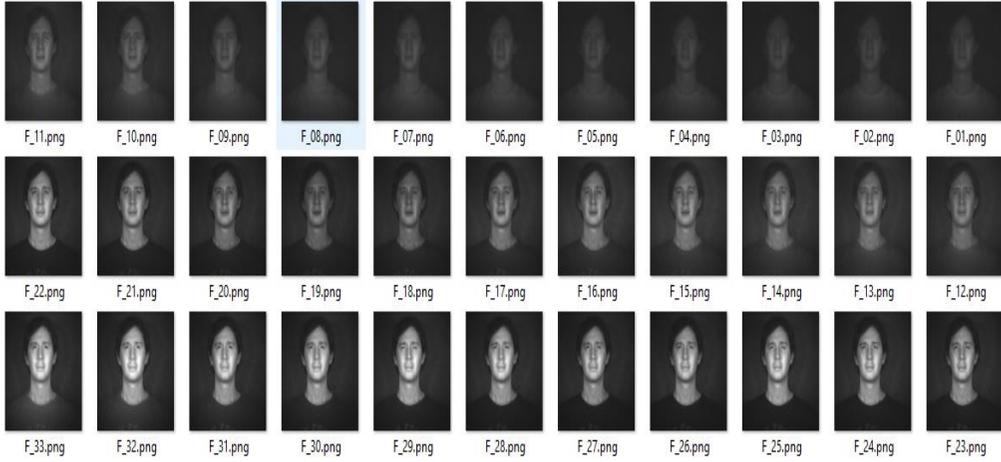
قمنا باختيار 17 مجلد كل واحد منها يحتوي على صور طيفية من 33 نطاق، بداية قمنا بقص هذه الصور لاحتواء الوجه ثم إعادة تعيين قياسها الى 100×100

باستخدام برنامج MATLAB وباستخدام برنامج ENVI 5.1 قمنا بإنشاء مكعب طيفي لكل مجلد.

بالنسبة لجميع التجارب على مجموعة بيانات UWA قمنا باختيار 17 مكعب طيفي من هذه المجموعة من أجل الحصول على نتائج دقيقة حيث أن هذه المكعبات الـ 17 مشتركة بين الجلسات الثلاث الأولى وبالتالي يتيح لنا حرية اختيار العينات العشوائية لتشمل كل الحالات (مع ذقن أو بدون، اختلاف ظروف الإضاءة والمحاذاة لكل شخص) وتم إجراء الاختبارات على 10 مجلدات واخترنا 60 عينة للتدريب و40 عينة للاختبار، في مستخرج الميزة HOG تم تعيين البارامتر غاما إلى 0.5، عندما حصلنا على ميزات HOG. وتم تعيين نسبة الحفاظ على الطاقة إلى 0.7، كما تم تطبيق خوارزميات تقليل الأبعاد واستخراج الميزة والتصنيف على المكعبات الطيفية الناتجة وتحليل النتائج باستخدام برنامج MATLAB R2020b.

يوضح الشكل (7) قاعدة البيانات المستخدمة حيث تشير أسماء الصور إلى ترتيب النطاقات (مثلاً الصورة F_01 تشير إلى أول نطاق 400 نانومتر وهكذا...) واللاحقة تشير إلى الصيغة المعتمدة في قاعدة البيانات المذكورة وهي png.

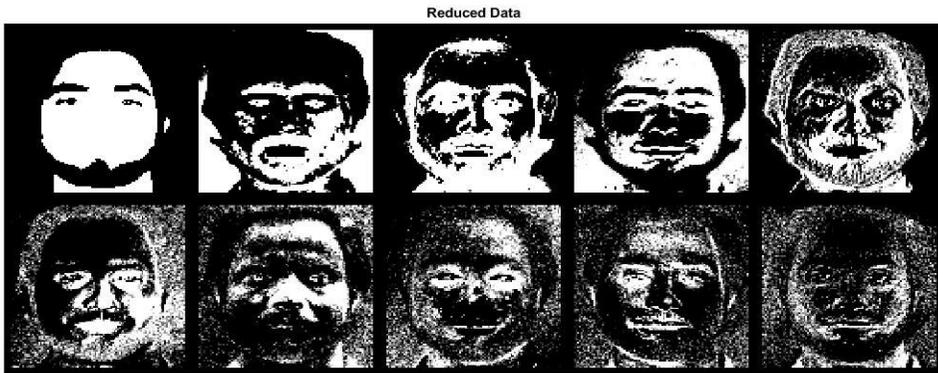




الشكل (7): مكعب وجه طيفيين من قاعدة البيانات UWA-HSFD.

8.3 نتائج البحث ومناقشتها

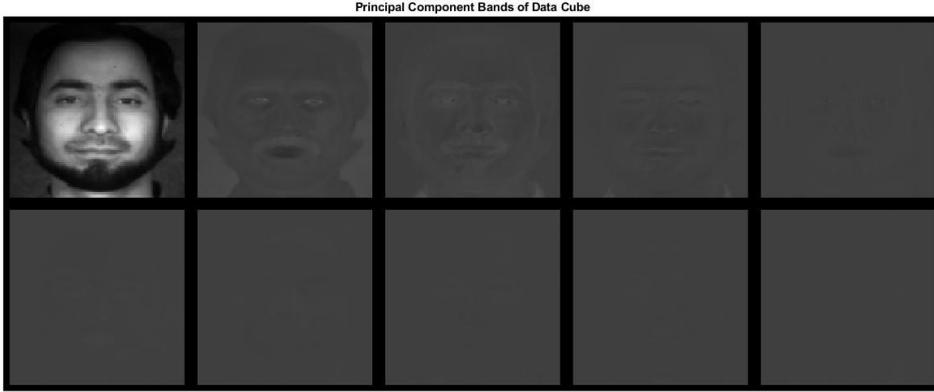
لداية نقوم بقراءة البيانات الطيفية (المكعب الطيفي) ثم نحسب نطاقات المكونات الرئيسية لمكعب البيانات الطيفية. حدد عدد المكونات الأساسية المراد استخلاصها $k = 10$ بشكل افتراضي، تستخدم الوظيفة طريقة تحليل القيمة المفردة (SVD)



لاستخراج المكونات الأساسية فنحصل على الشكل (8).

الشكل (8): المكونات العشرة الرئيسية الأولى للمكعب الطيفي

لتوضيح الصور نقوم بإعادة قياس (rescaling) قيم المكونات الأساسية لتقع في النطاق [0، 1]. ونعرض جميع نطاقات المكونات الرئيسية المستخرجة من مكعب



البيانات كما في الشكل (9).

الشكل (9): المكونات العشرة الرئيسية الأولى للمكعب الطيفي بعد عملية (rescaling)

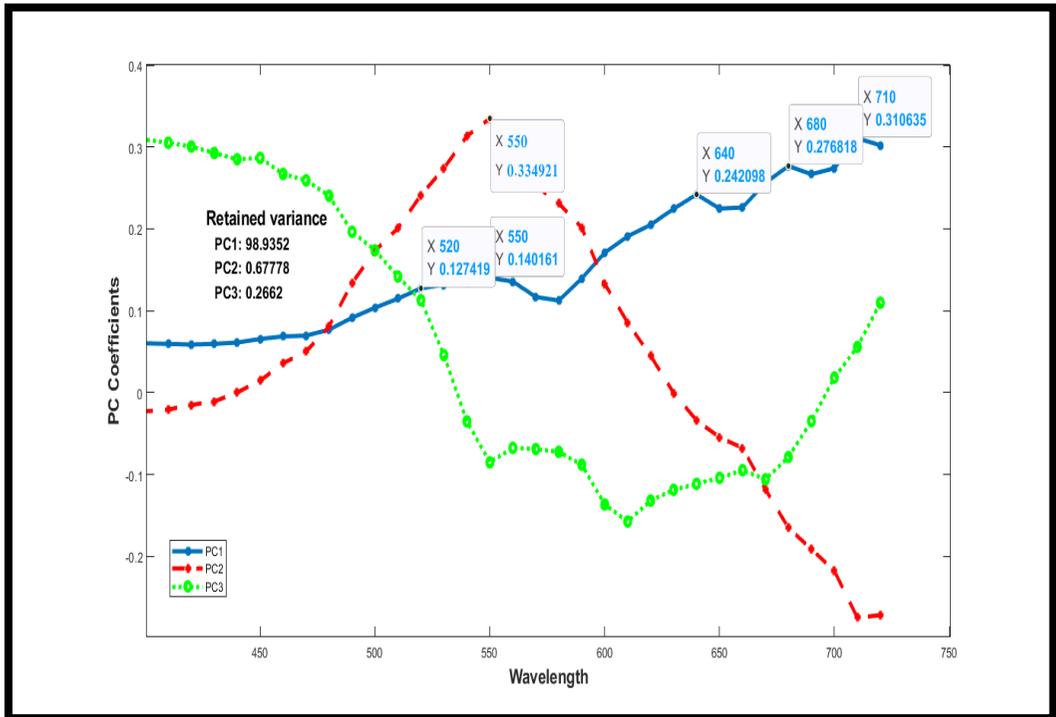
نقوم برسم معاملات المكون الرئيسي (coefficients) وعرض النسبة المئوية للتباين التي يحتفظ بها كل مكون رئيسي. يشير مجموع قيم التباين المستخرجة إلى أن ما يقرب من (99.8778%) من المعلومات في بيانات المدخلات الفائقة الطيفية يتم التقاطها بواسطة المكونات الرئيسية الثلاثة حيث في تجاربنا لاحظنا أن المكون الأول PC1 يحتوي على 98.9352% من المعلومات الطيفية بينما المكون الثاني PC2 يحتوي على 0.67778% من المعلومات وبينما المكون الثالث PC3 يحتوي فقط على 0.2662% من المعلومات كما هو موضح في الشكلين (10) - (11) ، كما يوضح الرسم البياني في الشكل (12) العلاقة بين القيم الذاتية للنطاقات المقابلة في مجموعة صور الوجه الطيفية

Principal Component Bands of Data Cube

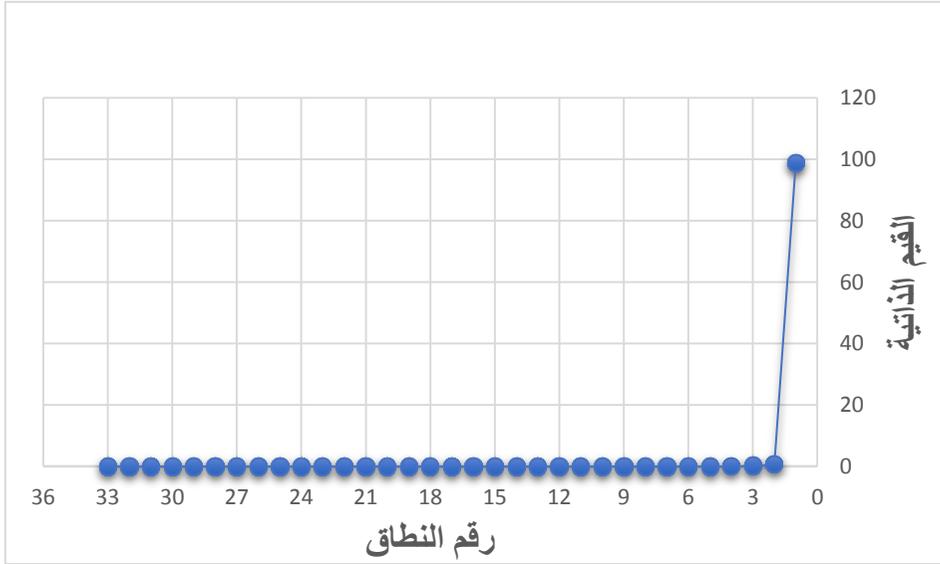


الشكل (10): المكونات الثلاثة الرئيسية الأولى للمكعب الطيفي

بالاعتماد على الشكل (11) الذي حصلنا عليه من المحاكاة نلاحظ وجود قمم لكل مكون تعبر عن قيمة المعامل العالية لكل نطاق بالنسبة للنطاقات المجاورة له.



الشكل (11): المكونات الثلاثة الرئيسية الأولى كعلاقة بين طول الموجة ومعاملات التباين (coefficients)



الشكل (12): رسم القيم الذاتية للنطاقات المقابلة في مجموعة صور الوجه الطيفية

نقوم بتحديد هذه القيم كما في الشكل (11) لنحصل بذلك على النطاقات المطلوبة وتكون النطاقات هي {520,550,640,680,710} وبعد ذلك نقوم بتطبيق خوارزمية HOG على النطاقات الناتجة ثم ندخلها الى المصنف KNN للحصول على الدقة ومقارنتها مع الخوارزميات الأخرى.

ومن أجل مقارنة النتائج قمنا باختيار نطاقات عشوائية من المكعبات الطيفية وحصلنا على دقة التصنيف المذكورة في الجدول (1) أي أننا قارنا بين اختيار 5 نطاقات باستخدام الخوارزمية المقترحة (PCA) و5 نطاقات عشوائية وهذا يثبت فعالية خوارزمتنا في أن النطاقات التي تم اختيارها هي الأفضل من أجل أهداف دقة التصنيف وبالتالي دقة التعرف على الوجوه، ويمكن الحصول على دقة التصنيف من

خلال تقسيم عدد الصور المطابقة على العدد الإجمالي لصور الاختبار وللحصول على النسبة المئوية نضرب الناتج بـ 100.

قمنا أيضاً باختبارات التصنيف على النطاقات بالكامل وحصلنا على دقة تصنيف 98.154% ولكن بزمن يساوي ستة أضعاف الزمن المطلوب لحساب الدقة لـ 5 نطاقات فقط كما هو موضح في الجدول (1).

الجدول (1): متوسط دقة التصنيف للخوارزمية المقترحة

عدد النطاقات	الدقة	الزمن
5 نطاقات عشوائية	95 %	7.998 s
5 نطاقات	98 %	8.167 s
كل النطاقات (33 نطاق)	98.154%	47.312 s

تتم مقارنة الخوارزمية المقترحة بـ 18 خوارزمية للتعرف على الوجوه فوق الطيفية الموجودة والممتدة مقسمة إلى ثلاث فئات؛ خمس خوارزميات للتعرف على الوجوه الفائقة الطيفية وسبع خوارزميات تصنيف الصور وستة خوارزميات للتعرف على الوجوه الرمادية / RGB.

بالنسبة للخوارزميات الخمسة المستخدمة سابقاً للتعرف على الوجوه الطيفية وتشمل مطابقة التوقيع الطيفي Spectral Signature وقياس الزاوية الطيفية Spectral Angle والطيف الترددي Spectral Eigenface و 2D PCA والتعرف على الوجوه الطيفي باستخدام 3D Gabor Wavelets، قام المرجع [9] بتطبيق هذه الخوارزميات وتحسين البارامترات وفقاً لما أوصى به المؤلفون الأصليون علماً أننا قمنا باستخدام نفس بيئة البرمجة التي

استخدمنا المرجع [9] وهي الـ MATLAB ونفس قاعدة البيانات واتبعنا نفس الأسلوب في تحديد عدد صور التدريب وعدد صور الاختبار كما أننا استخدمنا نفس مواصفات الحاسب المذكور في هذا المرجع (3.4 GHz CPU & 8GB RAM).

ويوضح الجدول (2) مقارنة شاملة بين الخوارزميات المذكورة وخوارزمتنا المقترحة من حيث الدقة وذلك من أجل قاعدة البيانات UWA-HSFD.

الجدول (2): مقارنة بين متوسط معدلات دقة التصنيف لـ 18 خوارزمية مع الخوارزمية المقترحة

الدقة (%)	الخوارزمية	الدقة (%)	الخوارزمية	الدقة (%)	الخوارزمية
Grayscale and RGB		Image set classification		Hyperspectral	
80.5	Eigenfaces	91.5	DCC	40.5	Spectral Signature
96.0	Fisherfaces	82.8	MMD	37.9	Spectral Angle
96.2	LBP	91.0	MDA	91.5	Spectral Eigenface
96.2	SRC	92.5	AHISD	83.8	2D PCA
96.2	CRC	92.5	CHISD	91.5	3D Gabor Wavelets
97.0	LCVBP+RLDA	92.5	SANP		
		93.1	CDL		

الدقة (%)	الخوارزمية المقترحة
98.154	PCA+HOG+KNN

9 الخاتمة والتوصيات

قدمنا خوارزمية تعرف على الوجه الطيفي استناداً إلى المعلومات الطيفية والمكانية وقمنا بتقليل عدد النطاقات باستخدام PCA من 33 إلى 5 نطاقات تحتوي على معظم المعلومات الطيفية الهامة واللازمة للتصنيف دون تدهور كبير في الدقة وبرهنا على أهمية الخوارزمية من حيث الزمن اللازم للتصنيف من خلال مقارنة الزمن المطلوب للحصول على دقة تصنيف لـ 5 مع زمن تصنيف 33 نطاق حيث أدى ذلك إلى تقليل الزمن من (47.312 s إلى 8.167 s) أي ست مرات تقريباً وهي نتيجة منطقية لأنه يتم معالجة عدد صور أقل ولكن ما نريد الإشارة إليه أن الدقة لم تتدهور حيث أنها انخفضت بمقدار 0.154% فقط مما يشير إلى أن عملية تقليل النطاقات هي منهجية واعدة في التعرف على الوجوه الفائقة الطيفية. وتم اختبار الخوارزمية المقترحة على قاعدة بيانات قياسية ومقارنتها بـ 18 خوارزمية حالية من أحدث التقنيات، بما في ذلك سبع خوارزميات، وست درجات رمادية / RGB وخمس خوارزميات للتعرف على الوجوه الطيفية. تفوقت خوارزمتنا على أحدث ما توصلت إليه قاعدة البيانات المذكورة من حيث الدقة ولم يتح لنا المقارنة من حيث الزمن وذلك لأن الدراسات السابقة قامت باستعراض نتائجها من حيث الدقة فقط.

نوصي مستقبلاً باستخدام أنظمة الحوسبة عالية الأداء لتسريع العمليات الحسابية، مثل برمجة CUDA وطريقة الحوسبة المتوازية مثل واجهة تمرير الرسائل (MPI). بالإضافة إلى ذلك استخدام خوارزميات التعلم الآلي الأكثر تقدماً وربما نماذج التعلم العميقة للتعرف على الوجه والتي ستؤدي بمجملها

تقليل عدد نطاقات الصور الطيفية باستخدام خوارزمية تحليل المكونات الرئيسية وتطبيقه في التعرف على الوجوه

إلى تحسين دقة التعرف على الوجوه وتسريع العمليات الحسابية وبالتالي تقليل الزمن.

10 المراجع

- [1] Zhu J, Tian T. Max-margin Majority Voting for Learning from Crowds[C]// International Conference on Neural Information Processing Systems. MIT Press, 2015.
- [2] Chen, Qidong, et al. "Hierarchical clustering-based band selection algorithm for hyperspectral face recognition." *IEEE Access* 7: 24333-24342,2019.
- [3] Liu Y, Pu H, Sun D W. Hyperspectral imaging technique for evaluating food quality and safety during various processes: A review of recent applications[J]. *Trends in Food Science & Technology*, 2017.
- [4] Qu J H, Wei Q, Sun D W. Carbon Dots: Principles and their Applications in Food Quality and Safety Detection[J]. *Critical Reviews in Food Science and Nutrition*, 2018.
- [5] Mooradian G, Weiderhold M, Dabiri A E, et al. Hyperspectral imaging methods and apparatus for non-invasive diagnosis of tissue for cancer: US, US 5782770 A[P]. 1998.
- [6] Z. Pan, G. Healey, M. Prasad, and B. J. Tromberg, "Face recognition in hyperspectral images," *IEEE Trans. on Pattern Anal. and Machine Intel.*, vol. 25, no. 12, pp. 1552–1560, 2003.
- [7] K. Barnard, L. Martin, A. Coath, and B. Funt, "A comparison of computational color constancy algorithms. ii. experiments with image data," *IEEE Transactions on Image Processing*, vol. 11, no. 9, pp. 985–996, 2002.
- [8] Di W, Zhang L, Zhang D, et al. Studies on Hyperspectral Face Recognition in Visible Spectrum with Feature Band Selection[J]. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 40(6):1354-1361.2010.

- [9] M. Uzair, A. Mahmood and Ajmal Mian, "Hyperspectral face recognition with spatio-spectral information fusion and PLS regression", *IEEE Trans. on Image Processing*, vol 24(3), 1127--1137, 2015.
- [10] Keogh E, Mueen A. Curse of Dimensionality[J]. *Ind.eng.chem*, 29(1):48-53.2009.
- [11] Karamizadeh, Sasan, et al. "An overview of principal component analysis." *Journal of Signal and Information Processing* 4.3B: 173,2013.
- [12] Xu, Yi, et al. "A novel hyperspectral microscopic imaging system for evaluating fresh degree of pork." *Korean journal for food science of animal resources* 38.2:362, 2018.
- [13] Chi Qin, L. A. I., and T. E. O. H. Soo Siang. "An efficient method of HOG feature extraction using selective histogram bin and PCA feature reduction." *Advances in Electrical and Computer Engineering* 16.4:101-108,2016.
- [14] Setiawan, Eko, and Adharul Muttaqin. "Implementation of K-Nearest Neighbors face recognition on low-power processor." *Telkomnika* 13.3: 949,2015.