

Novel System for Human Iris Recognition Depending on Image Processing Operations and Neural Networks

Dr. Iyad Hatem*

Ali Ali**

(Received 13 / 1 / 2024. Accepted 29 / 4 / 2024)

□ ABSTRACT □

In this article, we designed an innovative method for segmenting constrained human iris images. We also presented a new system for identifying the human iris based on a number of sequential digital image processing operations based on an experimental basis starting from an analysis of the CASIA-IRIS-SYN used database. We conducted the process of calculating and evaluating the results in separate stages, using k-fold cross-validation method, morphological operations, and multi-layer artificial neural networks. Two novel approaches have been proposed in this system; The first approach is dedicated to segmenting iris images with an overall accuracy rate of (99.72%), and the second is for the feature extraction stage with an average recognition rate of (99.78%) for training patterns and (85.32%) for test patterns using the same database. We recommended the proposed method as an excellent system for human irises recognition. We also identified the weak points of this system and proposed them as subsequent modifications in order to improve performance in the future.

Keywords: Iris segmentation ; Features descriptor ; Morphological operations; Multi-layer perceptron neural networks (MLP NN).

Copyright



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

* Associate Professor, Department of Mechatronics Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen university, Lattakia, Syria.

** Post-graduate student (Master), Mechatronics Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen university, Lattakia, Syria. ali.ahmad.ali.job@gmail.com

نظام مبتكر للتعرف على القزحيات البشرية بالاعتماد على عمليات معالجة الصور الرقمية و الشبكات العصبونية

د. إياد حاتم*

علي علي**

(تاريخ الإيداع 13 / 1 / 2024. قُبِلَ للنشر في 29 / 4 / 2024)

□ ملخص □

صمنا في هذا المقال طريقة مبتكرة لتجزئة صور قزحية الإنسان المقيدة. و قدمنا أيضاً نظاماً جديداً للتعرف على قزحية الإنسان بالاعتماد على عدد من عمليات معالجة الصور الرقمية المتسلسلة و المبنية على أساس تجريبي انطلاقاً من تحليل لقاعدة البيانات CASIA-IRIS-SYN المستخدمة. أجرينا عملية حساب و تقييم النتائج على شكل مراحل منفصلة وذلك باستخدام طريقة التحقق من الصحة، والعمليات المورفولوجية والشبكات العصبونية الصناعية متعددة الطبقات. تم اقتراح نهجين جديدين في هذا النظام؛ المنهج الأول مخصص لتجزئة صور قزحية العين بمعدل دقة إجمالي قدره (99.72%) ، والثاني خاص بمرحلة استخراج الميزات بمعدل تعرف وسطي (99.78%) من أجل أنماط التدريب و (85.32%) من أجل أنماط الاختبار باستخدام نفس قاعدة البيانات. أوصينا بالطريقة المقترحة كنظام ممتاز للتعرف على القزحيات البشرية. كما حددنا نقاط ضعف هذا النظام و اقترحناها كتعديلات لاحقة وذلك لرفع الأداء مستقبلاً.

الكلمات المفتاحية: تجزئة قزحية (iris segmentation)؛ واصف الميزات / شعاع السمات (features descriptor)؛ العمليات المورفولوجية (morphological operator)؛ شبكات عصبونية متعددة الطبقات (Multi-Layer Perceptron Neural Network).



حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص

CC BY-NC-SA 04

* أستاذ مساعد - قسم هندسة الميكاترونك - كلية الهندسة الميكانيكية و الكهربائية - جامعة تشرين - اللاذقية - سورية.

** طالب ماجستير - قسم هندسة الميكاترونك - كلية الهندسة الميكانيكية و الكهربائية - جامعة تشرين - اللاذقية - سورية.

ali.ahmad.ali.job@gmail.com

مقدمة:

التعرف على قزحية العين هو طريقة مؤتمنة للتعرف على الخصائص البيولوجية للإنسان و تستخدم تقنيات التعرف على الأنماط الرياضية في صور الفيديو لإحدى قزحية العين أو كليهما ، والتي تتميز أنماطها المعقدة بأنها فريدة ومستقرة ويمكن رؤيتها من مسافة ما [1].

وُصفت قزحية العين بأنها الجزء المثالي من جسم الإنسان للتعرف على القياسات الحيوية لعدة أسباب: هي عضو داخلي محمي جيداً ضد التلف والتآكل بواسطة غشاء شديد الشفافية والحساسية (القرنية). وهذا ما يميزه عن بصمات الأصابع التي يصعب التعرف عليها بعد سنوات من أنواع معينة من العمل اليدوي. تكون القزحية مسطحة في الغالب ، ويتم التحكم في تكوينها الهندسي فقط عن طريق عضلتين مكملتين (العضلة العاصرة وحدقة العين الموسعة) التي تتحكم في قطر البؤبؤ. هذا يجعل شكل قزحية العين أكثر قابلية للتنبؤ به على سبيل المثال من شكل الوجه.

للقزحية نسيج ناعم - مثل بصمات الأصابع - يتم تحديده بشكل عشوائي أثناء فترة الحمل الجنيني. من الصعب جداً (إن لم يكن من المستحيل) إثبات أن القزحية فريدة من نوعها. ومع ذلك ، هناك العديد من العوامل التي تتطوي على تكوين هذا النسيج (القزحية وبصمة الإصبع) بحيث تكون فرصة التطابق الخاطئ لأي منهما منخفضة للغاية. حتى التوائم المتطابقين وراثياً (أيضاً العين اليسرى واليمنى لنفس الفرد) لديهم قزحية مستقلة تماماً. يشبه مسح قزحية العين النقاط صورة ويمكن إجراؤه من حوالي 10سم إلى بضعة أمتار. ليست هناك حاجة لأن يكون الشخص الذي يتم تحديد هويته على اتصال بأي جهاز لمس شخص آخر مؤخراً ، مما يقلل من فرص انتشار الأمراض مثل COVID-19 ، وكذلك القضاء على الاعتراض الذي أثير في بعض الثقافات ضد الماسحات الضوئية لبصمات الأصابع حيث يجب أن يلمس الإصبع سطحاً ، أو مسح شبكية العين ، حيث يجب تقريب العين جداً من العدسة (مثل النظر في المجهر) [2]. في حين أن هناك بعض الإجراءات الطبية والجراحية التي يمكن أن تؤثر على لون القزحية وشكلها العام، إلا أن ميزات النسيج القزحي تظل ثابتة بشكل ملحوظ على مدى عقود عديدة. نجحت بعض عمليات التعرف على قزحية العين على مدار فترة (30) عاماً تقريباً.

خوارزمية التعرف على قزحية العين المنتشرة تجارياً ، كود قزحية John Daugman ، لديها معدل تطابق خاطئ غير مسبوق (أفضل من 10-11 إذا تم استخدام حد مسافة $hamming = 0.26$) ، مما يعني أن ما يصل إلى (26%) من البتات في اثنين من رموز القزحية يسمح بالاختلاف بينهما لأسباب مثل ضوضاء التصوير ، والانعكاسات ، وما إلى ذلك بينما لا يزال يعتبرهما متطابقين) [11].

يعمل التعرف على قزحية العين مع العدسات اللاصقة والنظارات الشمسية غير العاكسة. تم ترتيب المقال كما يلي: القسم الثاني مخصص للدراسات المرجعية، و القسم الثالث مخصص لهدف البحث، أما القسم الرابع فقد تم فيه ذكر طرائق البحث و موادها، النتائج، المناقشة و الاستنتاجات و إعدادات النظام و مقارنة مع بعض الدراسات المرجعية السابقة.

الدراسات المرجعية:

استخدم Ma و Wang و Tan (2002) مرشحات دائرية متناظرة لغرض التعرف على قزحية العين [4]. نفذوا البحث على (1,088) صورة مأخوذة من (109) متطوعاً تم التقاطها بواسطة جهاز استشعار بصري محلي الصنع. في هذه الدراسة ، بلغ حجم شعاع السمات (384) عنصراً. وصلت الورقة البحثية إلى معدل تعرف صحيح (99.85%).

نشر كل من H.Abiyev, Altunkaya (2008) بحثهم باستخدام قاعدة بيانات CASIA iris تحتوي على (756) صورة لـ (108) شخصاً. قاموا بتجزئة القرنية باستخدام تقنية المستطيل الأسود. استغرقت عملية التجزئة معدل زمن قدره (0.14 ثانية) ، وبلغ أداء التجزئة الصحيحة (98.63%) [5].

تم نشر دراسة: "التجزئة السريعة ووصف SURF التكميلي للتعرف على قرنية العين" في (2012) استناداً إلى قواعد بيانات UBIRIS و BATH و CASIAV3. كان وقت التقسيم لهذه الدراسة (0.396 ثانية) ، وتراوح معدل التعرف الصحيح RR من 94.27% إلى 96.85% [6].

قام كل من Mohammed, F. Al-Gailani (2019) (SCCS-) بتحرير مقالهم بعنوان: "تطوير نظام التعرف على قرنية العين بناء على التوحيد المعزز". تم استخدام قواعد بيانات CASIA iris-lamp V4 و UBIRIS V2 في هذه الدراسة. تم تحقيق الحد الأقصى لمعدلات التعرف بـ (98.5%) لقاعدة بيانات CASIA ، و (98.7%) بالنسبة لنظام UBIRIS [8].

أجريت دراسة من قبل Rana وآخرون (2019) حملت هذه الورقة عنوان: "نظام سريع للتعرف على قرنية العين من خلال الاستخراج الأمثل للميزات". تم استخدام قاعدة بيانات CASIA-Iris V4. تم الحصول على معدل تعرف صحيح 95.4% ، ومعدل قبول خاطئ (FAR) بنسبة 4% ، ومعدل رفض خاطئ (FRR) بنسبة 5% في الدراسة. بلغ متوسط زمن التنفيذ (9.1598 ثانية) على (100) عينة فقط [9].

أهمية البحث وأهدافه:

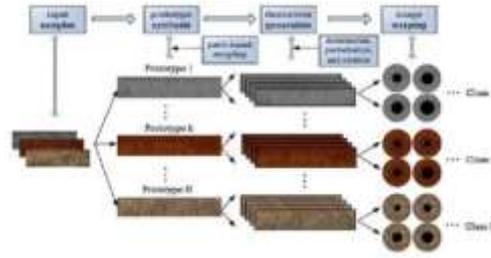
هدف البحث:

كان لهذا المقال هدف رئيس وهو إنشاء نظام تعرف على القرنيات البشرية بالاعتماد على أدوات معالجة الصور الرقمية الأساسية، يتميز بأداء جيد و يمكن استخدامه ضمن تطبيقات الزمن الحقيقي.

طرائق البحث و موادّه:

الحصول على الصورة

تم استخدام صور CASIA-Iris V4 وتحديداً قاعدة بيانات CASIA_IRIS_SYN هنا في البحث. احتوت CASIA-Iris-Syn على (10,000) صورة قرنية رمادية مستحدثة تعود لـ (1,000) شخص / نمط. كل صورة كان حجمها [640 . 480] بكسل. تم استحداث صور النموذج الأولي في مجموعة البيانات تلقائياً من مجموعة فرعية تعود لعينات بشرية حقيقية من CASIA-IrisV1 وباستخدام أسلوب أخذ العينات القائم على الرقع patches. تم تطبيق عملية توليد المشتقات (بما في ذلك عمليات التشوه والاضطراب والدوران) عليها قبل تزييف الصور، ثم تم دمج مناطق حلقة القرنية في صور القرنية الحقيقية كما هو موضح في الطريقة الموصوفة في الشكل (1)، مما جعل صور القرنية الاصطناعية أكثر واقعية. تتضمن الاختلافات داخل الفئة التي تم إدخالها في مجموعة بيانات القرنية المركبة التشوه والتشويش والدوران، مما قد يؤدي إلى تشكيل تحدي حقيقي لاستخلاص الميزات من قرنية العين ومطابقتها. وقد أظهر أن صور القرنية المركبة كانت واقعية بصرياً. والأهم من ذلك، أن نتائج الأداء التي تم اختبارها على صور القرنيات المستحدثة لها خصائص إحصائية مماثلة لقاعدة بيانات القرنية الحقيقية [15].



الشكل (1) مخطط انسيابي لطريقة تركيب نسيج القزحية لتوليد قاعدة البيانات CASIA-Iris-Syn [15]

مراحل العمل

تحليل قاعدة بيانات صور قزحية و ذلك لمعرفة المشاكل التي من المحتمل أن تواجهها صورة القزحية خلال الالتقاط أو بعده (خلال استخراج السمات منها).

تطبيق خوارزميات التجزئة II , I المبتكرتين وذلك لعزل القزحية عن باقي العناصر الموجودة في صورة الدخل.

توحيد أبعاد صورة القزحية باستخدام مبدأ Daugman's rubber sheet model.

الاعتماد على التقنيات الأساسية لمعالجة الصور الرقمية لتحسين الصورة و بناء الشعاع الواصف لقزحية الفرد بناء على المشاكل المحتمل مصادفتها في نظام التعرف على القزحيات و التي تم تحديدها بالخطوة I السابقة.

استخدام شبكات MLP في مرحلة المطابقة وذلك لبناء المصنفات بالاعتماد على مبدأ التصويت voting و مبدأ التحقق من الصحة k-fold cross validation.

تقييم النظام بالاعتماد على مقاييس محددة مثل RR, FAR, FRR.

الخطوة الأولى (تحليل قاعدة البيانات):

وجدنا أن صورة قزحية العين في قاعدة بيانات CASI_IRIS_SYN تتعرض لعدة احتمالات ممكنة من التغيير/ الضجيج هي:

التغيير المكاني للكائنات (الإزاحة على المحور X أو y من الصورة).

التغيير الدوراني (دوران الكائنات).

تغيير حجم الكائنات.

التغيير في الاتصال بين وحدات البكسل المتجاورة.

تشوه الشد للكائنات الناتج عن تمدد وتقلص البؤبؤ.

الضجيج الضبابي المحتمل بسبب حركة العين السريعة أثناء مرحلة التقاط الصورة (تأثير التمويه).

ظهور كائنات جديدة من خلال تمدد وتقلص البؤبؤ (تأثير الكائنات المخفية).

التغيير في الإضاءة.

صور قزحية غير صالحة: الصور التي تم التقاطها بشكل غير صحيح.

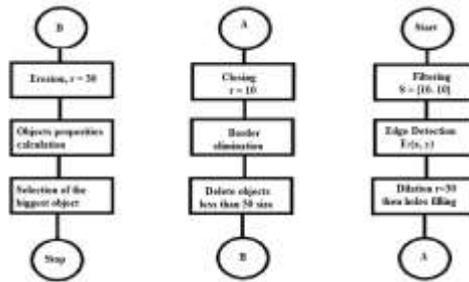
الخطوة الثانية (التجزئة):

تحتوي صورة قزحية الدخل في النظام على منطقة القزحية ومناطق أخرى مثل: البؤبؤ، والرموش، والحواجب، وما إلى ذلك.

يتمثل دور مرحلة التجزئة في فصل منطقة القرزية (ROI) عن المناطق الأخرى. للقيام بذلك ، يجب أن نعرف مكان القرزية بدقة أولاً: إنها الحلقة الملونة للعين بين البؤبؤ والصلبة. لذا فإن القرزية لها حدان. الحد الداخلي (حافة البؤبؤ)، والحد الخارجي (الحافة بين القرزية والصلبة). لاكتشاف الحدود الداخلية والخارجية، اقترحنا خوارزميتين أصيلتين تعتمدان على العمليات المورفولوجية (الخوارزمية الأولى والثانية). يوضح الشكل (2) الخطوات الكاملة للخوارزمية الأولى و التي وصفناها على النحو التالي:

أولاً ، قمنا بتعيين نواة المرشح (k) بالحجم [10 . 10] ، ثم قمنا بتهيئة أول عنصر بناء على شكل قرص بنصف القطر (se1 = 30) وعنصر البناء الثاني على شكل القرص بنصف القطر (se2 = 10). ثم قرأنا صورة قرزية الإدخال (IMG) والتي سيتم تصفيتها بواسطة المرشح. بعد ذلك تم تطبيق عملية الكشف عن الحواف في الاتجاهين (x و y) على الصورة التي تمت تصفيتها ، ثم قمنا بتمدد مورفولوجي باستخدام العنصر se1. بعد ذلك قمنا بملء الثقوب الموجودة في الصورة الممددة. تم استخدام عملية الإغلاق المورفولوجية مع العنصر se2. تم تطبيق عملية إزالة لحدود الصورة المغلقة. ثم قمنا بحذف الكائنات التي كانت مساحتها أقل من 50 بكسل. بعد ذلك تم استخدام عملية الحت مع العنصر se1. تم حساب خصائص الكائنات المتبقية (المركز ، المنطقة ، القطر). اخترنا الكائن ذا المساحة الأكبر ليمثل البؤبؤ. أخيراً قمنا بحساب مركز البؤبؤ Cp ونصف قطره Rp. حيث يمكن حساب نصف القطر Rp من المعادلة (1):

$$RP = \frac{\text{median of bigger and smaller diameter}}{2} \quad (1)$$



الشكل (2) مخطط صندوقي للخوارزمية I

يوضح الشكل (3) الخطوات الكاملة للخوارزمية II الموضحة على النحو التالي في مخطط التدفق. أولاً قمنا بتصفية الصورة (IMG) باستخدام مرشح الوسيط للحصول على صورة (MF). ثم قمنا بتطبيق تسوية للهيستوغرام على (MF) للحصول على صورة (H). تم اكتشاف الحواف الشاقولية في الصورة (H) لإنشاء صورة جديدة (VE). ثم حددنا منطقة بحث الخوارزمية و هو عبارة عن مربع مركزه Cp ونصف قطره يساوي Rp. الشكل (4) ، ثم بدأنا في حساب عدد البكسلات البيضاء (أي بكسلات الحواف) الموجودة في منطقة بحث الخوارزمية بين كل دائرة مرشحة لتمثيل حد القرزية الخارجي Ck والدائرة المرشحة السابقة Ck-1 ، حيث تراوحت قيم k بين $Rp * 1.9 = Rmin$ و $Rp * 3 = Rmax$. أخيراً، اخترنا الدائرة المرشحة Ck التي تتوافق مع العدد الأقصى لقيمة حواف البكسل لتمثيل حد القرزية الخارجي (أي اخترنا الدائرة التي حققت المعادلة التالية):

$$C p, r_i : \text{Max} \{ a \mid a \in [S p, r_i - S p, r_{i-1}] \} \quad (2)$$

حيث:

C: يمثل دائرة الحدود الخارجية المطلوبة

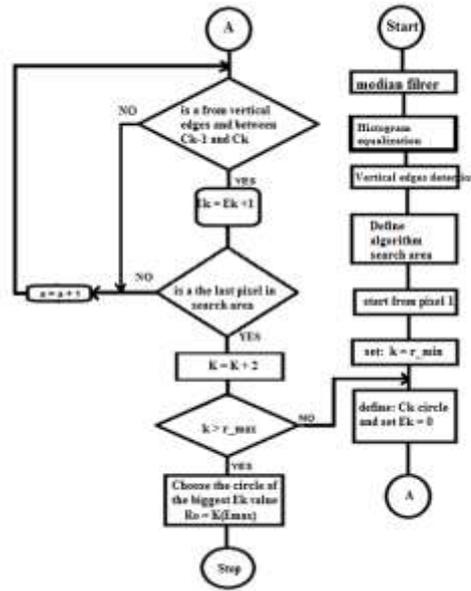
a: بكسل حافة من صورة الحواف الشاقولية VE

S: مساحة الدائرة

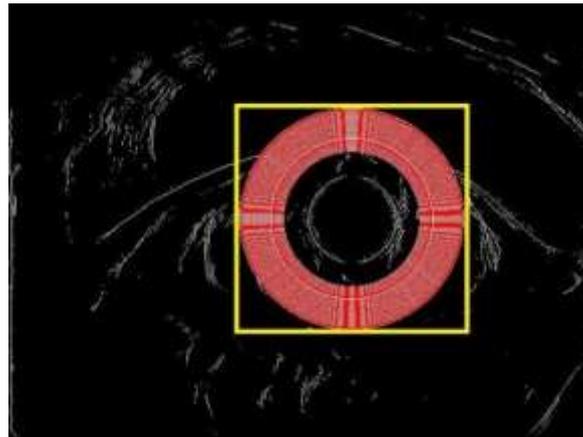
p: إحداثيات (x, y) للبوؤ

r: نصف قطر الدائرة المطلوبة

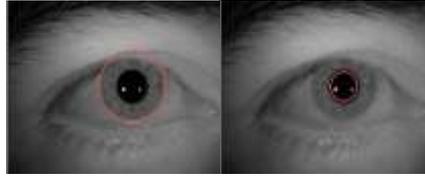
i: عداد الحلقة الثانية.



الشكل (3) مخطط صندوقي للخوارزمية II

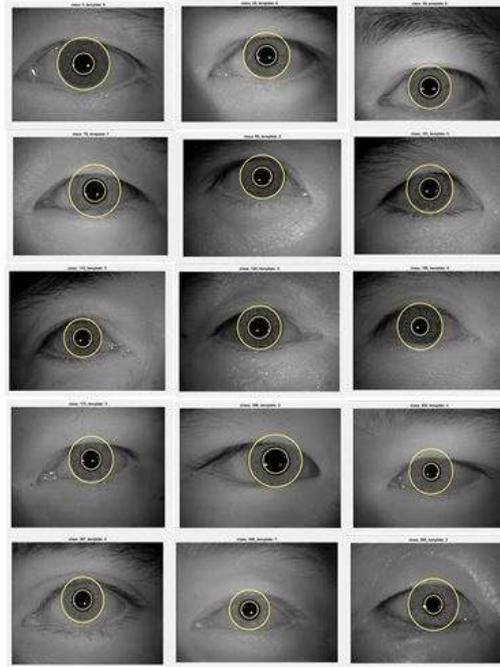


الشكل (4) منطقة بحث الخوارزمية II



الشكل (5) نتيجة الخوارزمية I (من اليسار) و الخوارزمية II (من اليمين)

طبقتنا الخوارزميتين المقترحتين (I و II) على جميع صور قاعدة البيانات Casia_iris_syn ، وحصلنا على معدل تجزئة صحيح (99.72%). يظهر الشكل (6) نتائج الخوارزميتين السابقتين على صور مختارة عشوائياً من قاعدة البيانات السابقة.



الشكل (6) نتائج التجزئة على صور مختارة عشوائياً من قاعدة البيانات

الخطوة الثالثة (توحيد أبعاد صورة القرنية):

بعد تنفيذ مرحلة التجزئة، كان علينا توحيد صورة القرنية في الدخل. نتيجة الاختلاف في مساحة حلقة القرنية من شخص لآخر وحتى من صورة إلى أخرى لنفس الشخص بسبب الاختلاف في المسافة بين العين والكاميرا، كما أن التزايد في شدة الضوء يؤدي إلى تقلص منطقة البؤبؤ وبالتالي انخفاض في نصف قطر الحد الداخلي للقرنية. لذلك ، نحتاج إلى توحيد أبعاد صورة قرنية العين المكتشفة في مرحلة التجزئة، وكذلك تحويل منطقة الاهتمام (ROI) إلى شكل مستطيل يسهل التعامل معه في المراحل القادمة من نظام مسح قرنية العين البشرية. للقيام بعملية التوحيد استخدمنا نموذج Daugman's rubber sheet [16] معبراً عنه في المعادلتين (3) و (4):

$$x = (1 - r) \cdot x_p + r \cdot x_i \quad (3)$$

$$y = (1 - r) \cdot y_p + r \cdot y_i \quad (4)$$

حيث:

$$r \in [0, 1]$$

xp: إحداثيات نقاط الحدود الداخلية للقزحية على المحور x.

yp: إحداثيات نقاط الحدود الداخلية للقزحية على المحور y.

xi: إحداثيات نقاط الحدود الخارجية للقزحية على المحور x.

yi: إحداثيات نقاط الحدود الخارجية للقزحية على المحور y.

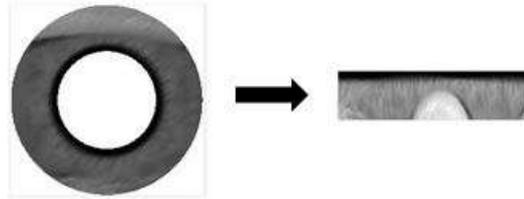
استخدمنا البارامترات التالية من أجل هذا البحث:

$$\Delta r = 0.02 \text{ قيمة الخطوة الشعاعية}$$

$$\Delta \theta = 0.005^\circ \text{ قيمة الخطوة الدورانية}$$

$$\Rightarrow s_1 = \frac{1}{\Delta r} = 50, \quad s_2 = \frac{1}{\Delta \theta} = 200$$

نتيجة لذلك ، كانت صورة قزحية العين الموحدة بحجم [200 . 50] بكسل.



الشكل (7) تحويل الشكل الحلقي لصورة القزحية إلى الشكل المستطيل الموحد

الخطوة الرابعة (تحسين الصورة و بناء الشعاع الواصف/ شعاع السمات)

بعد مرحلة التوحيد، كانت صورة قزحية العين بحاجة إلى أن تكون أكثر وضوحاً، لذلك تم تطبيق عمليات تحسين الصور على صورة قزحية العين الموحدة على النحو التالي:

حذف الصفوف العشرة الأولى من الصورة الموحدة (نظراً لعدم احتوائها على معلومات مفيدة للتعرف على القزحية، لذا أصبحت صورة القزحية الموحدة بالحجم [200 . 40].

شحن الحواف (بنسبة 500% ، نصف القطر = 5).

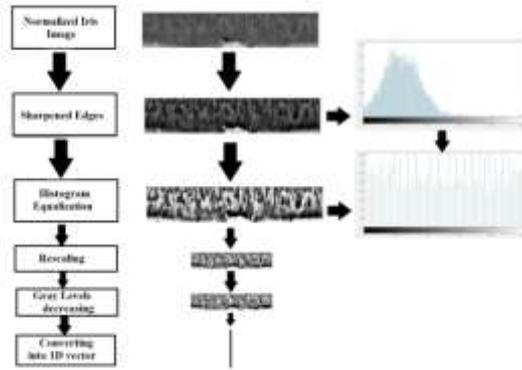
تسوية الهيستوغرام.

إعادة التحجيم من [200 . 40] إلى [50 . 10] لتقليل حجم الشعاع الواصف قبل دخوله إلى الشبكات العصبونية.

تخفيض عدد السويات الرمادية إلى 3 مستويات فقط (للقضاء على مشكلة العامل f و أيضاً لتوحيد مجال عناصر دخل الشبكة العصبونية بحيث يأخذ إحدى القيم التالية {0, 0.5, 1}).

التحويل من شكل ثنائي الأبعاد لصورة قزحية إلى متجه أحادي البعد ليكون مناسباً كمدخل للشبكة العصبونية MLP.

الاعتماد على خصائص الشبكات العصبونية (للتخلص من مشكلة المتغيرات a ، c ، e ، g ، i).



الشكل (8) بناء الشعاع الواصف لصورة القرنية

الخطوة الخامسة (المطابقة/ بناء المصنفات):

للقيام بعملية المطابقة. قمنا بتقسيم الـ 1,000 نمط الموجودين في قاعدة البيانات إلى 5 مجموعات رئيسية (A , B , C , D , E). احتوت كل مجموعة منهم على 200 نمط. ثم قمنا أيضاً بتقسيم كل مجموعة من هذه المجموعات الخمس إلى قطاعين (قطاع أول حجمه 80 % و هو مخصص لأغراض التدريب و القطاع الثاني حجمه 20% تم استخدامه لأغراض الاختبار). استخدمنا مبدأ التحقق من الصحة k-fold cross validation. خلال حساب أداء النظام الكلي؛ على سبيل المثال؛ يوضح الجدول (1) طريقة المطابقة المستخدمة مع عينات المجموعة A ، حيث احتوت المجموعة A على 200 نمط أي 2,000 صورة (حيث كل نمط ممثل بـ 10 صور/ نماذج) ، لذلك تم استخدام 1,600 صورة (80%) لأغراض التدريب وتم استخدام 400 صورة (20%) الباقية للاختبار، حيث تم اختيار عينات الاختبار من 5 مواقع متسلسلة مختلفة من عينات المجموعة A أي (5 folds) و تم تدريب عينات كل fold على 5 قيم مختلفة لعصبونات الطبقة المخفية S1 باستعمال الشكل التالي لتقسيم الأنماط (80% تدريب - 10% لأغراض التحقق - 10% لأغراض الاختبار) مع مراعاة نجاح شرط التعميم المعبر عنه بالمعادلة (5).

$$R \cdot S_1 + b_1 + S_2 \cdot S_1 + b_2 \leq Q_t \quad (5)$$

حيث:

R: حجم شعاع الميزات المستخرج (R = 500).

S1: عدد عصبونات الطبقة المخفية .

S2: عدد عصبونات طبقة الخرج.

b1: عدد الانحيازات في الطبقة المخفية

b2: عدد الانحيازات في طبقة الخرج

Qt: حجم أنماط التدريب.

$$500 \cdot S_1 + 500 + 200 \cdot S_1 + 200 \leq 500 \cdot 200 \cdot 8$$

$$S_1 \leq 113.2857 \sim = (113) \text{ neurons}$$

أي يجب ألا يتجاوز عدد عصبونات الطبقة المخفية 113 عصبون للتأكد من نجاح عملية التعميم.

اخترنا القيم التالية لعدد عصبونات الطبقة المخفية $S_1 = \{92 - 94 - 96 - 98 - 100\}$ ، بحيث يتم تدريب كل fold ضمن المجموعة الرئيسية A باستخدام 5 قيم مختلفة لـ S1. بعد ذلك قمنا بتقييم الـ (25) MLPs التابعة لنفس

المجموعة الرئيسية A باستخدام مقاييس أداء النظام، ورتبنا الشبكات العصبونية حسب الأداء من الأكبر أداء إلى الأقل أداء ، ثم قمنا بتوصيل أفضل 3 و 4 و 5 مصنفات MLPs من أجل كل fold تابع للمجموعة A بشكل متوازي معاً وذلك لإجراء عملية تحسين لنتائج التصنيف من خلال عملية التصويت الثلاثي و الرباعي و الخماسي على نفس شعاع الدخل (أي تم إجراء الاتصال المتوازي من خلال تطبيق الشعاع الواصف نفسه على جميع الشبكات الموصولة معاً ، وتحديد النتيجة النهائية التي حصلت على أكبر عدد في عملية التصويت). في حالة وجود صوت واحد مختلف لكل شبكة MLP ، اخترنا النتيجة النهائية للمصنف بحيث تتوافق مع نتيجة الشبكة ذات معدل التعرف الصحيح الأكبر %RR. تم احتساب أداء المجموعة A بأخذ المتوسط الحسابي لأداء الـ 5 folds التابعين لنفس المجموعة الرئيسية A.

الجدول (1) تطبيق مبدأ التحقق من الصحة على عينات المجموعة A

Group information	Fold	Training samples 80%	Testing samples 20%
Group name: A	1	S2, S3, S4, S5, S6, S7, S8, S9	S0, S1
Number of classes = 200	2	S0, S1, S4, S5, S6, S7, S8, S9	S2, S3
Number of images = 2.000	3	S0, S1, S2, S3, S6, S7, S8, S9	S4, S5
Classes: from C0 to C199	4	S0, S1, S2, S3, S4, S5, S8, S9	S6, S7
Samples of each class = from S0 to S9	5	S0, S1, S2, S3, S4, S5, S6, S7	S8, S9

مقاييس تقييم أداء النظام المقترح:

Recognition Rate %: معدل التعرف الصحيح

False Acceptance Rate %: معدل القبول الخاطئ

False Rejection Rate %: معدل الرفض الخاطئ

النتائج:

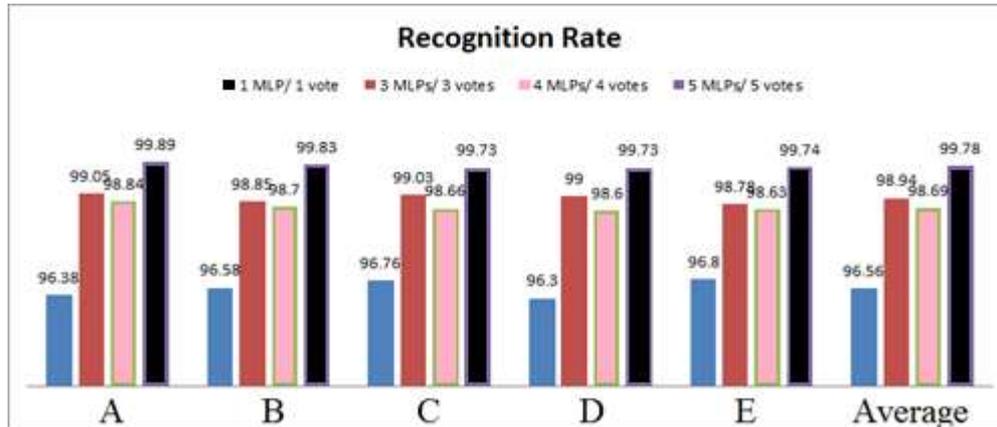
يحتوي هذا القسم على النتائج الرئيسية لهذه الدراسة. تمثل الجداول (2 و 3) والأشكال (9، 10، 11، 12، 13، 14، 15) النتائج الرئيسية لنظامنا المقترح.

الجدول (2) أداء الخوارزمية المقترحة على أنماط التدريب لقاعدة البيانات بأكملها

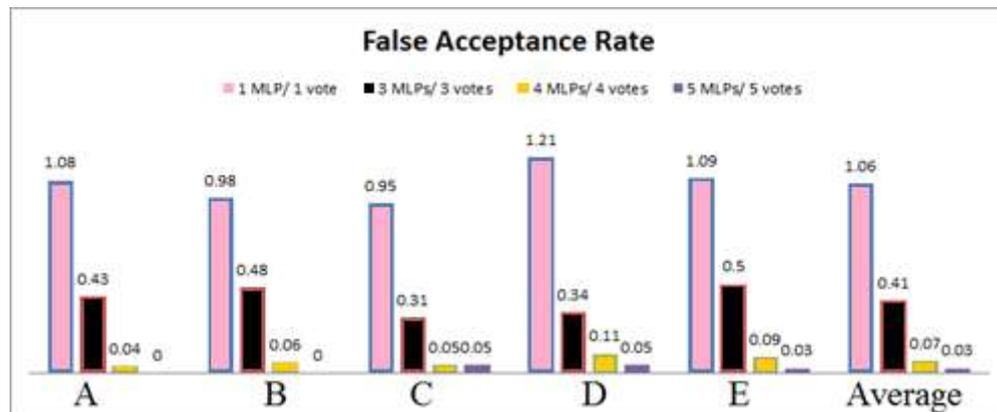
Votes number	1	3	4	5
%RR	96.56	98.94	98.69	99.78
%FAR	1.06	0.41	0.07	0.03
%FRR	2.38	0.65	1.25	0.20

الجدول (3) أداء الخوارزمية المقترحة على أنماط الاختبار لقاعدة البيانات بأكملها

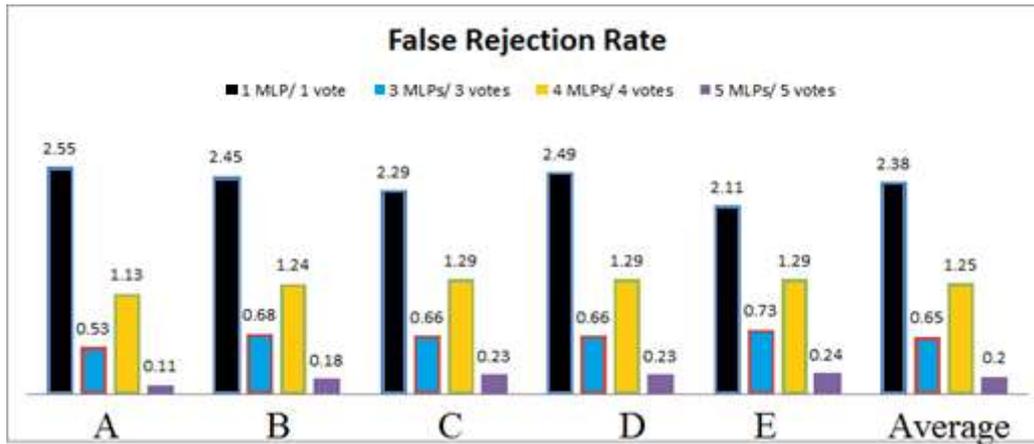
Votes number	1	3	4	5
%RR	81.98	84.15	82.14	85.32
%FAR	5.77	4.36	2.05	3.02
%FRR	12.25	11.49	15.81	11.66



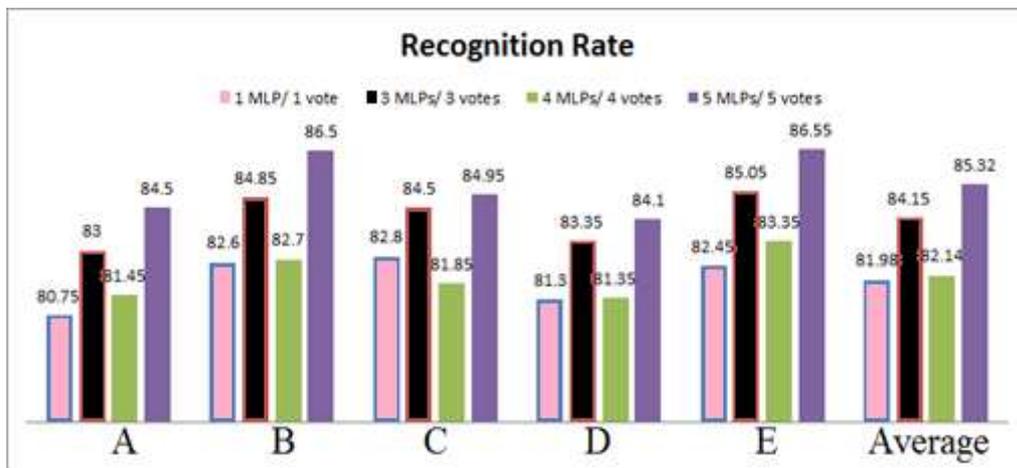
الشكل (9) معدل التعرف بالاعتماد على الطريقة المقترحة على المجموعات A و B و C و D و E باستخدام أنماط التدريب.



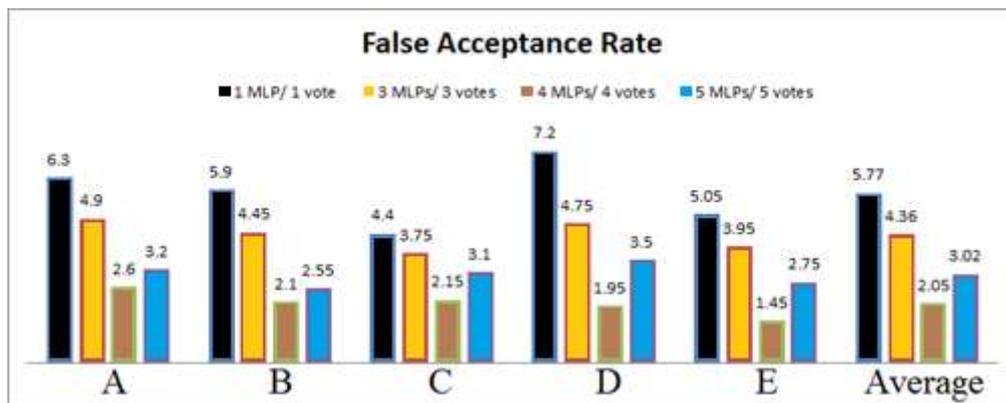
الشكل (10) معدل القبول الخاطئ للطريقة المقترحة على المجموعات A و B و C و D و E باستخدام أنماط التدريب.



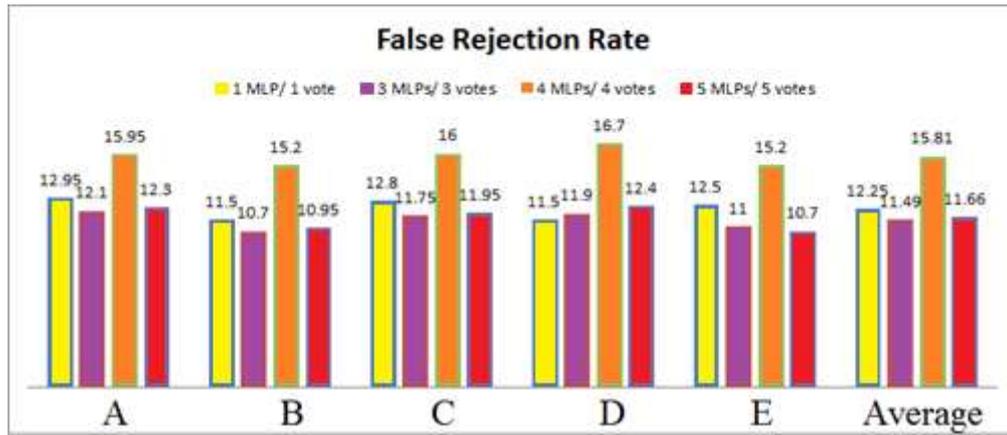
الشكل (11) معدل الرفض الخاطئ للطريقة المقترحة على المجموعات A و B و C و D و E باستخدام أنماط التدريب.



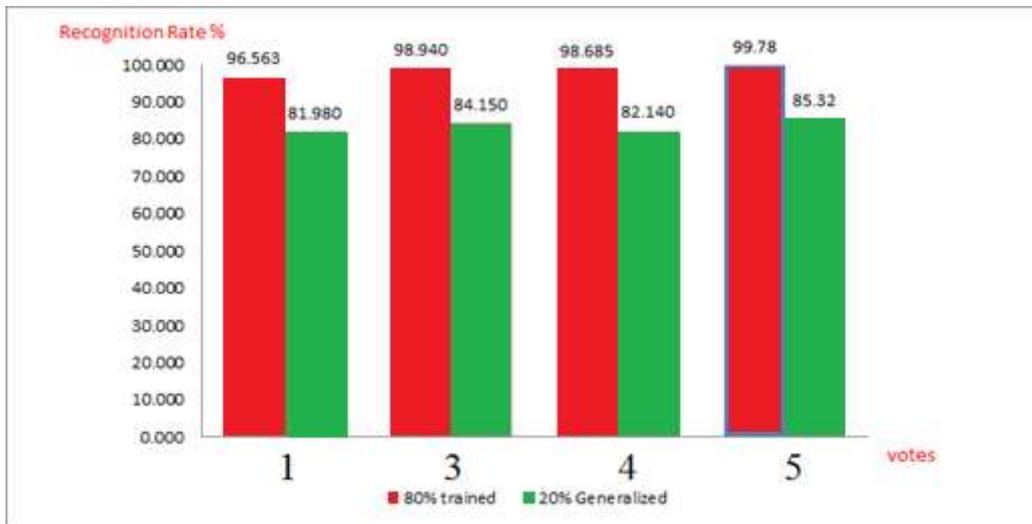
الشكل (12) معدل التعرف بالاعتماد على الطريقة المقترحة على المجموعات A و B و C و D و E باستخدام أنماط الاختبار.



الشكل (13) معدل القبول الخاطئ للطريقة المقترحة على المجموعات A و B و C و D و E باستخدام أنماط الاختبار.



الشكل (14) معدل الرفض الخاطئ للطريقة المقترحة على المجموعات A و B و C و D و E باستخدام أنماط الاختبار.



الشكل (15) معدل التعرف الصحيح على قزحية العين باستخدام الطريقة المقترحة في قاعدة بيانات casia-iris-syn بأكملها.

مناقشات النتائج:

مناقشة نتائج مرحلة التجزئة:

يمكن للخوارزميات التي اقترحها هذا البحث في مرحلة التجزئة أن تتعامل بشكل مثالي مع صور قزحية العين المقيدة (الدوران حول المحور γ يساوي درجة الصفر ، مسافة (10 - 70) سم من الكاميرا، والصور الرمادية).

مناقشة نتائج الطريقة المقترحة:

كان أهم عيوب هذه الطريقة هو عدم قدرتها على تغطية مشكلة المعامل b خاصة في 3 fold.

كانت مشكلة 3 fold بسبب الدوران المطبق على صور القزحية مما أدى إلى تناقص نتائج %RR الخاص بأنماط الاختبار بمقدار متوسط يساوي (15%) بالمقارنة مع نتائج %RR لأنماط التدريب. لذلك نوصي بأن تحتوي أنماط التدريب على عينات دورانية للحصول على أعلى قيمة لـ RR .

ومن الإضافات الأخرى المقترحة لهذا البحث اختبار قاعدة بيانات Casia_iris_syn المستحدثة والمقدمة من المختبر الوطني للتعرف على الأنماط ، ومعهد الأتمتة، والأكاديمية الصينية للعلوم.

الاستنتاجات والتوصيات:

تم اقتراح نهجين جديدين في نظام التعرف على قزحية العين: النهج الأول خاص بتجزئة صورة القزحية بمعدل دقة إجمالي (99.72%) لـ (10,000) صورة قزحية مأخوذة من قاعدة بيانات casia-iris-syn.

والنهج الثاني مصمم لمرحلة استخراج الميزات بمتوسط معدل التعرف (99.78%) مع أنماط التدريب و (85.32%) مع أنماط الاختبار)، وهذا هو السبب في أننا وضعنا نتيجتين في خلية RR % في الجدول (4). يستعرض الجدول (4) مقارنة بين دراستنا وخمس دراسات علمية سابقة، حيث يمكننا ملاحظة أن دراستنا تفوقت على الأعمال ذات الصلة الموصوفة سابقاً في عدد الأنماط المستخدمة (والتي كانت 1,000 في بحثنا) ، وبمعدل دقة التجزئة والذي كان يعادل (99.72%) وسطياً وجاءت دراستنا في المرتبة الثانية بمتوسط معدل التعرف على أنماط التدريب وحجم الشعاع الواسف بعد الدراسة الأولى مباشرة بفارق (0.07%) و(116) عنصراً عنها على التوالي. كما احتلت المرتبة الثانية في متوسط زمن التجزئة بعد الدراسة الثانية بفارق (0.097) ثانية عنها. إعدادات النظام:

(Intel® Core™ 2 Duo CPU T6500 @ 2.10 GHZ – RAM 4GB – Windows 64 bits) ،
Matlab إصدار (R2016a) .

الجدول (4) مقارنة بين بحثنا المقترح مع بعض الدراسات المرجعية في نفس المجال

Study #	n. of classes	n. of images	Recognition Rate [%]	Segmentation time [s]	Segmentation accuracy [%]	Vector size
Study [4]	109	1,088	99.85	-	-	384
Study [5]	108	756	99.25	0.14	98.62	-
Study [6]	50-800	11,101-22,051	94.27-98.24	0.396	96.56-99.55	-
Study [8]	261-411	-	98.5-98.7	-	98.5-98.7	5,200
Study [9]	100	200	95.4	-	-	4,500
Proposed system	1,000	10,000	85.32-99.78	0.237	99.72	500

References :

- https://en.wikipedia.org/wiki/Iris_recognition. Accessed on 31 August 2022
- Martin, Zach (2011-03-23). "Biometric Trends: Will emerging modalities and mobile applications bring mass adoption?". SecureIDNews. Retrieved 2013-07-14.
- Probing the uniqueness and randomness of IrisCodes: Results from 200 billion iris pair comparisons." Proceedings of the IEEE, vol. 94 (11), 2006, pp. 1927-1935.
- Li Ma, Yunhong Wang, Tieniu Tan. "Iris Recognition Using Circular Symmetric Filters". National Laboratory of Pattern Recognition, Institute of Automation, Chinese Academy of Sciences, P.O. Box 2728, Beijing, 100080, P.R. China. IEEE, 2002.
- Rahib H.Abiyev, Koray Altunkaya. "Personal Iris Recognition Using Neural Network". International Journal of Security and its Applications · May 2008.
- H. Mehrotra, et al., Fast segmentation and adaptive SURF descriptor for iris recognition, Mathematical and Computer Modelling (2012), doi:10.1016/j.mcm.2012.06.034
- Alceu Ferraz Costa, Gabriel Humpire-Mamani, Agma Juci Machado Traina, An Efficient Algorithm for Fractal Analysis of Textures, 2012 25th SIBGRAPI Conference on Graphics, Patterns and Images, IEEE.
- Aumama Mohammed, Mohammed F. Al-Gailani , Developing Iris Recognition System Based on Enhanced Normalization, Scientific Conference of Computer Sciences (SCCS), University of Technology - Iraq, 2019.
- Rana HK, Azam MS, Akhtar MR, Quinn JMW, Moni MA. 2019. A fast iris recognition system through optimum feature extraction. PeerJ Comput. Sci. 5:e184 <http://doi.org/10.7717/peerj-cs.184>
- R. M. Rangayyan and T. M. Nguyen, "Fractal analysis of contours of breast masses in mammograms," Journal of Digital Imaging, vol. 20, no. 3, pp. 223–37, Sep. 2007.
- G. R. Balan, A. J. M. Traina, C. Traina Jr., and P. M. A. Marques, "Fractal analysis of image textures for indexing and retrieval by content," in 18th IEEE Symposium on Computer-Based Medical Systems (CBMS'05), 2005, pp. 581–586.
- M. Schroeder, Fractals, Chaos, Power Laws: Minutes from an Infinite Paradise. New York, NY, USA: W. H. Freeman, 1992.
- <https://datascience.stackexchange.com/a/24051>. Accessed on 31 August 2022
- <https://towardsdatascience.com/multi-class-metrics-made-simple-part-ii-the-f1-score-ebe8b2c2ca1>. Accessed on 31 August 2022
- <http://biometrics.idealtest.org>. Accessed on 31 August 2022
- J. Daugman, High confidence visual recognition of persons by a test of statistical independence, IEEE Transactions on Pattern Analysis and Machine Intelligence 15 (11) (1993) 1148–1161 .
- Martin T. Hagan Oklahoma State University, Stillwater, Oklahoma Howard B. Demuth University of Colorado Boulder, Colorado. Neural Network Design, 2nd Edition. Hayden, Idaho Orlando De Jesús Consultant Frisco, Texas. Mark Hudson Beale MHB , INC