مجلة جامعة دمشق للعلوم الهندسية
المجلد41 العدد(2) – 2025: 290-306

Damascus University Journal for engineering sciences
Vo 41 number (2) -2025: 290-306

كشف تعابير الوجه في الفيديو الرقمي باستخدام خصائص حيزية وزمنيّة

ولاء رياض سفور *[1] طلال حمود[2] فواز مفضي[3]

*[1]. طالبة دكتوراه في قسم هندسة الإلكترونيات والاتصالات -كلية الهندسة الميكانيكية والكهربائية -جامعة دمشق. walaa.saffour@damascusuniversity.edu.sy .

[2]. أستاذ مساعد، دكتور، في قسم هندسة الإلكترونيات والاتصالات -كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق. TalaHammoud@Damascusuniversity.edu.sy.

[3]. دكتور مدرس في قسم هندسة الإلكترونيات والاتصالات -كلية الهندسة الميكانيكية والكهربائية -جامعة دمشق. FawwazMufdi@Damascusuniversity.edu.sy.

الملخص:

يُعدّ الكشف الآلي لتعابير الوجه في مقاطع الفيديو الرقمية من المواضيع البحثية الهامة في الوقت الحالي بسبب تطبيقاته المتعددة التي فرضها التطور التكنولوجي في السنوات الأخيرة، كما تُعدّ دقّة الكشف التحدّي الأكبر الذي يواجه مطوري خوارزميات الكشف عن تعابير الوجه لتحقيق أفضل أداء ممكن. يركّز هذا البحث على خوارزميات الطرائق التقليدية للكشف، حيث تمّ تحليل مقطع الفيديو في كل من المستويين الحيّزي والزمني بهدف كشف تغيّر التعبير من التعبير المحايد وحتى تعبير آخر من التعابير السبعة الأساسيّة وذلك خلال تتابع أطر المقطع، بالإضافة إلى إجراء تجارب عملية لاختبار دقة الخوارزميّة (حيث بينت التجارب الوصول إلى دقة 98.87% على قاعدة بيانات CK+) مع مقارنة الخوارزمية مع الخوارزميات المماثلة بالتصنيف.

الكلمات المفتاحية: كشف تعابير الوجه، الفيديو الرقمي، الخصائص الهندسية، مخطط التدرجات الموجهة HOG، الخصائص الزمنيّة، آلة شعاع الدعم SVM.

تاريخ الايداع: 2023/1/18
تاريخ القبول: 2023/5/22

حقوق النشر: جامعة دمشق -سورية، يحتفظ المؤلفون بحقوق النشر بموجب **CC BY-NC-SA**

Developing a Facial Expressions Recognition Algorithm for Digital Video

Walaa Read Saffour[*1] Talal Hammoud[2] Fawwaz Mufdi[3]

*[1]. PhD student in the Department of electronics and communications- Damascus University. walaa.saffour@damascusuniversity.edu.sy.

[2]. Associated Professor in the Department of electronics and communications- Damascus University. TalaHammoud@Damascusuniversity.edu.sy.

[3]. Professor in the Department of electronics and communications- Damascus University. FawwazMufdi@Damascusuniversity.edu.sy.

Received: 18/1/2023

Accepted: 22/5/2023

Copyright: Damascus University– Syria, The authors retain the copyright under a CC BY– NC–SA

Abstract:

The automatic detection of facial expressions in digital video is one of the important research topics at the present time because of its multiple applications imposed by technological development in recent years. Detection accuracy is one of the challenges facing developers of facial expression detection algorithms to achieve the best possible performance. This research focuses on the algorithms of conventional methods, we developed an algorithm based on spatial and temporal stude of video frames to recognize expression change from neutral to one of the another seven expressions, we conducted practical experiments to test its accuracy (experiments showed an accuracy of 98.87% on CK+ dataset), in addition to compare it with algorithm with the same classification.

Keywords: facial expressions recognition, digital video, appearance features, geometric features, histogram of oriented gradients, landmarks, temporal features, support vector machine.

المقدّمة:

تصنّف تعابير الوجه الأساسيّة حسب Darwin (1872) إلى ستّة تعابير هي: الفرح، الغضب، الحزن، الدهشة، الاشمئزاز والخوف، بالإضافة إلى التعبير المحايد كتعبير سابع [1]، أضاف Ekman و Heider (1988) إليها تعبير الاحتقار ليصبح عدد التعابير الأساسيّة ثمانية تعابير [2]، يبيّن الشكل (1) تعابير الوجه الثمانية المذكورة مأخوذة من قاعدة البيانات CK+.

الشكل (1) تعابير الوجه الثمانية الأساسيّة [3]

يعدّ الكشف الآلي لتعابير الوجه في الفيديو الرقمي من المواضيع التي حازت على اهتمام الباحثين في الآونة الأخيرة، وذلك لما له من أهمّيّة في تحقيق التفاعل بين الأجهزة والإنسان، والذي يمكن الاستفادة منه في تطبيقات متعدّدة، كمراقبة المرضى، السائقين والأطفال، وفي تفاعل الروبوتات مع الإنسان، بالإضافة إلى الألعاب التفاعليّة وتطبيقات الواقع الافتراضي والواقع المعزّز. تُعرّف الخوارزميّات التقليديّة في كشف التعابير على انّها الخوارزميّات التي تعتمد إمّا على دراسة شكليّة للوجه (أي دراسة بعض الخصائص الشكلية في أماكن محدّدة من صورة الوجه أو في الوجه كاملاً)، أو على دراسة هندسيّة للوجه (أي دراسة الأبعاد بين نقاط محدّدة في صورة الوجه ودراسة الزوايا التي تشكّلها الخطوط بين هذه النقاط)، أو على كل من الخصائص الشكليّة والهندسيّة وتدعى الخوارزميّة في هذه الحالة بالخوارزميّة الهجينة. تعاني الخوارزميّات التقليديّة من الدقّة المنخفضة نسبيّاً بالمقارنة مع طرائق أخرى كخوارزميّات التعلّم العميق [4]، ونقصد هنا بالدقّة مدى اقتراب نتائج الكشف للخوارزميّة من التعابير الحقيقيّة الظاهرة في مقاطع الفيديو، ومن هنا تبرز الحاجة إلى إيجاد آليات لزيادة دقّة هذه الخوارزميّات. يتضمّن البحث تطوير خوارزميّة ذات دقّة عالية نسبياً معتمدة على الطرائق التقليدية لكشف التعابير في مقاطع الفيديو، ويُقصد بذلك كشف انتقال تعبير الوجه من التعبير المحايد إلى تعبير آخر من التعبيرات السبعة.

1- الدراسات المرجعيّة السابقة:

تقترح العديد من الأبحاث العلميّة خوارزميّات تقليديّة لكشف تعابير الوجه وباستخدام خصائص شكليّة وهندسيّة مختلفة، فقد اقترح Kar وآخرون (2022) [5] خوارزميّة تستخدم خاصيّة شكليّة وهي تحليل النمط المتغيّر Variational Mode Decomposition (VMD) بالإضافة إلى مراحل أخرى تهدف إلى تقليص حجم البيانات، وقد استخدموا للتصنيف آلة التعلّم الأقصى ذات النواة kernel extreme learning machine، درست الخوارزميّة التعابير على مستوى الإطار الواحد وقد كشفت تعابير الوجه لقاعدة بيانات CK+ بدقّة 98.81%، بينما طوّر Kim وآخرون (2022) [6] خوارزميّة لكشف تعابير الوجه على مستوى تتابع أطر المقطع بدقّة 96.64% بالاعتماد على تغيّر الأبعاد بين نقاط محدّدة ترسم الوجه تدعى نقاط الاستدلال landmarks وكذلك تغيّر الزوايا بين الخطوط الواصلة بين هذه النقاط وذلك أثناء تتابع الأطر مستخدمين للتصنيف آلة شعاع الدّعم Support Vector Machine (SVM) وقد اعتمدوا على قاعدة بيانات CK+ للتدريب والاختبار، كما اقترح Haghpana وآخرون (2022) [7] دراسة مناطق محدّدة من

http://journal.damascusuniversity.edu.sy/index.pHp/index/index
ISSN (online): 2789-6854

الوجه أسموها مناطق الاهتمام حيث قاموا بدراسة الأبعاد بين نقاط الاستدلال من هذه المناطق وأيضاً كشف كثافة التجاعيد ضمنها باستخدام مرشّح تمرير مرتفع مستخدمين للتصنيف الشبكة العصبونيّة، وقد حقّقت هذه الخوارزميّة دقّة 96.12% على +CK، أيضاً نذكر الخوارزميّة التي طوّرها Parra وآخرون [8](2022)، معتمدين على رسم شبكة عنكبوتيّة تخيّليّة على الوجه والتي تقسّمه إلى قطاعات ومن ثمّ حساب عدد نقاط الاستدلال ضمن كلّ قطاع، ومقارنتها مع جداول مخزّنة مسبقاً لتحديد تعبير الوجه دون الحاجة إلى التدريب، وقد كشفت هذه الخوارزميّة تعابير الوجه لقاعدة +CK بدقّة 91.5%. أيضاً اعتمد Kulkarni وآخرون (2021) [9] على نوعين من الخصائص وهما الأنماط الثنائيّة المحلّيّة Local Binary Batterns (LBP)، والأبعاد بين 19 نقطة من نقاط الاستدلال، لتطوير خوارزميّة كشف تعابير الوجه بدقّة 92% وباستخدام طريقة الجار الأقرب K-Nearest Neighbor (KNN) للتصنيف، معتمدين على قاعدة بيانات جديدة خاصّة . أخيراً، نذكر الخوارزميّة التي اقترحها Wang وآخرون (2021) [10] والتي تعتمد على إيجاد ما يسمّى إطار الذروة في مقطع الفيديو وهو الإطار الذي يكون فيه تعبير الوجه مشبعاً لأقصى درجة ممكنة، ومن ثمّ دراسة تغيّر الأبعاد والزوايا بين نقاط الاستدلال وذلك بين إطار الذروة والإطار المرجعي (الإطار الأوّل وهو إطار التعبير المحايد)، تمّ كشف التعابير باستخدام آلة شعاع الدّعم وقد أعطت الخوارزميّة دقّة 98.73% على قاعدة بيانات +CK.

2- الأساسيّات النظريّة:

2-1- طرائق كشف تعابير الوجه في مقاطع الفيديو:

تُقسم طرائق كشف تعابير الوجه في الفيديو إلى مجموعتين:

1- الطرائق المعتمدة على الدراسة على مستوى الإطار frame based، تعتمد هذه الطرائق على دراسة في المستوى الحيّزي فقط وذلك على مستوى إطار واحد مُختار من المقطع (عادةً هو الإطار الذي يكون فيه التعبير أوضح ما يمكن ويدعى إطار الذروة peak frame)، وتكون الدراسة على مستوى الصورة فقط دون دراسة التغيّرات الزمنيّة التي حدثت خلال تتابع الأطر حتى الوصول إلى الإطار المدروس.

2- الطرائق المعتمدة على الدراسة على مستوى تتابع الأطر sequense based، لا تقتصر على الدراسة في المستوى الحيّزي فقط وإنّما تدرس أيضاً التغيّرات الزمنيّة الحاصلة أثناء تتابع أطر مقطع الفيديو، وتُعدّ هذه الخوارزميّات أشمل من خوارزميّات النوع السابق [4].

2-2- الطرائق التقليديّة في كشف تعابير الوجه في المستوى الحيّزي:

تُعد دراسة أطر مقطع الفيديو في المستوى الحيّزي (مستوى الصورة) الركيزة الأساسيّة في عمليّة كشف التعابير، وتصنّف خوارزميات الطرائق التقليدية في كشف تعابير الوجه حسب نوع الخصائص الحيّزيّة المعتبرة إلى ثلاثة أصناف: الكشف باعتماد خصائص الأبعاد الهندسية، الكشف باعتماد الخصائص الشكلية، الكشف باعتماد الخصائص الهجينة.

1- الكشف باعتماد خصائص الأبعاد الهندسية: يتم في البداية إيجاد ما يسمى النقاط المرجعية أو نقاط الاستدلال (landmarks)، وهي نقاط ترسم ملامح الوجه كما يبين الشكل (2)، وتكون الخصائص المطلوب حسابها هي بعض المسافات بين هذه النقاط أو الزوايا التي تشكّلها الخطوط الواصلة بين النقاط.

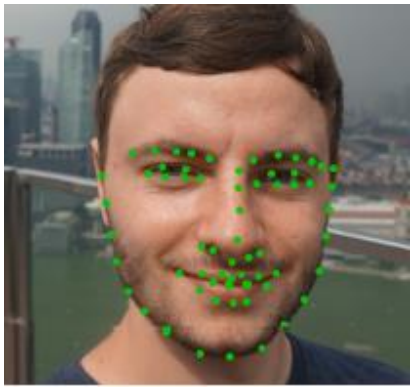

الشكل(2) نقاط الاستدلال في الوجه [11]

2- الكشف باعتماد الخصائص الشكلية: تعتمد هذه الخوارزميات على دراسة كتل (blocks) تتضمن مناطق محددة من الوجه وهي المناطق ذات التأثير في تعابير الوجه، مثل: منطقة العينين ومنطقة الأنف ومنطقة الفم، ومن ثم دراسة الشكل الموجود ضمن هذه الكتل. توجد العديد من الخصائص المعبّرة عن الشكل الموجود في صورة أو كتلة منها، مثل الأنماط الثنائية المحلية local binary patterns(LBP) ومخطط التدرجات الموجهة histogram of oriented gradients(HOG) وغيرها.

3- الكشف باعتماد الخصائص الهجينة: يتم الاعتماد على كل من النوعين السابقين أي دمج الخصائص الشكلية مع خصائص الأبعاد الهندسية بهدف الحصول على خوارزمية ذات دقة كشف عالية [1]. وتُعتبر الخوارزمية المقترحة في هذا البحث من هذا النوع.

2-3- مخطط التدرجات الموجهة Histogram of Oriented Gradients(HOG):

يشير مصطلح التدرّج في الصورة إلى الاتجاه الذي يتغير فيه السطوع ضمن الصورة بالإضافة إلى شدة تغير هذا السطوع كما يبين الشكل(3)، حيث نرى التدرّج كأشعة لكل منها مطال واتجاه، يعبّر اتجاه الشعاع عن اتجاه تغير السطوع، بينما يعبر مطال الشعاع عن شدة هذا التغير.

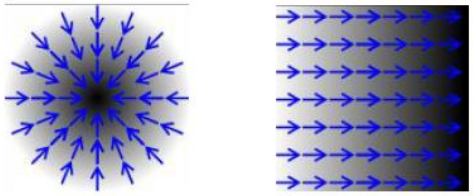

الشكل(3) التدرج ضمن الصورة [12]

أمّا مصطلح التوزع التكراري أو الهيستوغرام histogram فهو قيمة إحصائية تعبّر عن توزع عناصر محددة على مجموعة من الخانات المعلومة مسبقاً، بمعنى آخر مرّات تكرار كل قيمة من قيم هذه الخانات، بينما يعبر مصطلح مخطط التدرجات الموجهة أو هيستوغرام التدرجات الموجهة histogram of oriented gradients(HOG) عن التوزع التكراري لزوايا أشعة التدرج ضمن الصورة. يمكن القول بأنّ مخطط التدرجات الموجهة لصورة الوجه هو واحدة من الخصائص الشكلية التي يمكن لها أن تعبر عن تعبير هذا الوجه بشكل فعال [13].

بشكل عام يأخذ حساب مخطط التدرجات الموجهة في نافذة ما من صورة لوجه المرحلتين التاليتين:

المرحلة الأولى: حساب قيم التدرجات ضمن النافذة، حيث يكون لدينا قيمة للتدرج عند كل بكسل معبّر عنها كمطال وزاوية Ø ,abs تُحسب كما يلي:

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

$$G_y = I(x,y+1) - I(x,y-1) \quad (2)$$

$$abs = \sqrt{{G_x}^2 + {G_y}^2} \quad (3)$$

$$\emptyset = arc\tan(\frac{G_y}{G_x}) \quad (4)$$

المرحلة الثانية: تقسيم النافذة إلى خلايا cells (على سبيل المثال خلية مؤلفة من 8x8 بكسل)، ويؤخذ عدد من القيم للزوايا (عادةً 9 قيم)، ويحسب التوزع التكراري لهذه الزوايا من أجل كل خلية، وهكذا يصبح لدينا مقابل كل خلية مصفوفة أحادية بعد مؤلفة من 9 عناصر، وتُجمع مصفوفات الخلايا في النهاية لتشكل مصفوفة واحدة كما يبين الشكل (4) [15],[14].

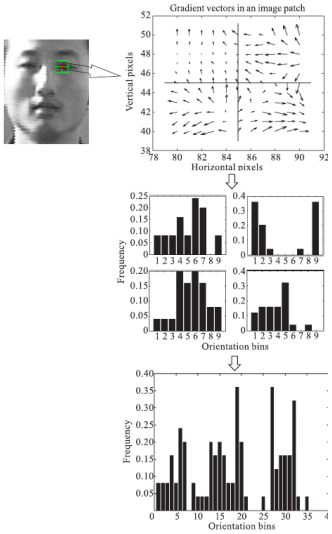

الشكل(4) مراحل إيجاد مخطط التدرجات الموجهة لنافذة من صورة [14]

2-4- آلـة شـعاع الـدعم Support Vector Machine(SVM):

آلة شعاع الدعم هي عبارة عن آلية اتخاذ قرار ذات أساس رياضـي معتمدة على التعلّم، لها العديد من الاستخدامات التي من أهمها التصنيف classification [16].

سنفترض أنّ لدينا عدد L من عينات التدريب وكلّ عينة يمكن أن تأخذ واحداً من تصنيفين class1, class2 وأنّ التصنيف يعتمد على اثنتين من الخصائص x_1,x_2 تشكلان مصفوفة الخصائص X حيث $X=[x_1,x_2]$، ويكون لدينا مصفوفة التدريب Y حيث $Y=[X_1,X_2,\dots,X_L]^T$ (اعتبرنا عدد التصنيفات والخصائص 2 لسهولة الشرح وسهولة التمثيل البياني). يمكن أن نرى في الشكل(5) مواقع عينات التدريب مع تصنيفاتها منسوبة إلى المحورين الإحداثيين و ملاحظة أنّه يمكن الفصل بين عينات التصنيفين بخط مستقيم يدعى الخط الفاصل (لذلك يطلق على هذا النوع من البيانات البيانات القابلة للفصل خطياً) نلاحظ أيضاً مستقيمين موازيين للخط الفاصل يمران بأقرب عينة من هذا المستقيم ويطلق عليهما اسم الشعاعين الداعمين support vectors. توجد عدد من المستقيمات الممكنة كاحتمالات للفصل بين العينات حيث تكون معادلة المستقيم الفاصل بين العينات:

$$w_1x_1 + w_2x_2 + b = 0 \quad (5)$$

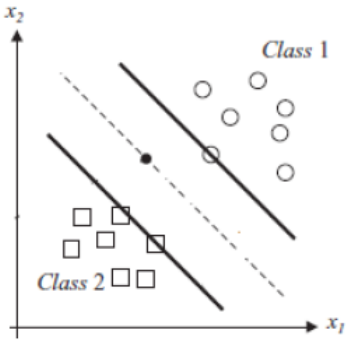

الشكل(5) المبدأ العام لآلة شعاع الدعم [17]

يتمثل الهدف في آلة الشعاع الداعم في إيجاد أفضل معادلة للمستقيم الفاصل، بالتالي يمكن معرفة تصنيف عينة جديدة حسب موقعها من هذا المستقيم، في حالة صنفين فقط كالمثال المشروح سابقاً، تتمثل عملية التدريب في إيجاد كل من $w_1,w_2,$ b، أما في الحالة العامة (عدد التصنيفات n) فتكون المعادلة:

$$d = \sum_{i=1}^{n} w_i x_i + b \quad (6)$$

وتكون مهمة التدريب إيجاد W,b حيث:

$$W= [w_1, w_2, \dots , w_n]^T \quad (7) \quad [17]$$

بعض البيانات تكون غير قابلة للفصل بشكل خطي، لذلك تستخدم توابع معينة لفصل البيانات تدعى توابع النواة kernel functions، مثل تابع الظل القطعي Hyperbolic tangent function (sigmoid) والتابع متعدد الحدود polynomial function وتابع الأساس الشعاعي الغاوسي Gaussian radial basis function(RBF). نجد في الشكل (6) أشكال بعض توابع لنواة لآلة شعاع الدعم.

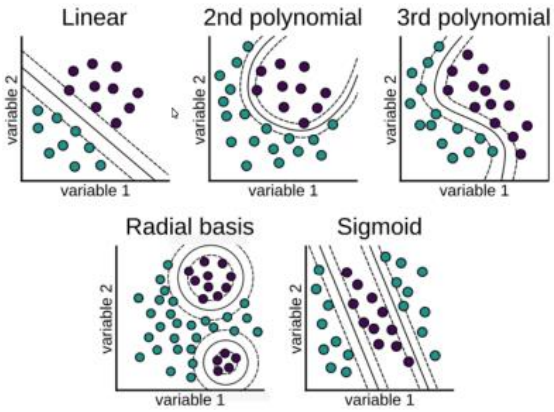

الشكل (6) أمثلة عن توابع نوى SVM [18]

يمكن توظيف آلة شعاع الدعم من أجل التصنيف متعدّد الخصائص multiple feature classification، وذلك إمّا عبر جمع الخصائص مع بعضها لتشكّل خاصّيّة واحدة بعدد أبعاد كبير، أو يمكن تدريب عدّة آلات شعاع دعم بخاصّيّة واحدة لكلّ منها كما يبيّن الشكل(7) بحيث تُعطي كل آلة نتيجة مستقلّة، ومن ثمّ تُجمع نتائج المصنّفات بطريقة ما للحصول على نتيجة واحدة وهذا يُعرف باسم آلة شعاع الدعم متعدّدة الرأي multi-view SVM، ومن طرائق جمع نتائج المصنّفات طريقة تصويت الأغلبيّة majority voting حيث يؤخذ الخرج الأكثر تكراراً لنتائج المصنّفات كخرج نهائي [19,20] .

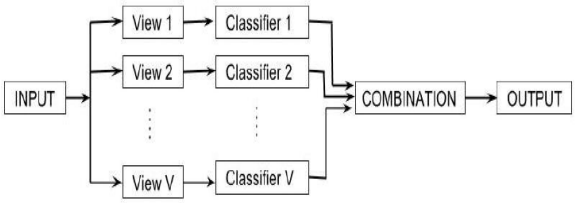

الشكل (7) استخدام مصنّفات متعدّدة [20]

3- الخوارزميّة المقترحة:

تدرس الخوارزميّة المقترحة مقطع الفيديو على مستوى تتابع الأطر، وكما هو الحال في خوارزميّات هذا الصنف يكون الهدف كشف انتقال التعبير من التعبير المحايد وحتى تعبير آخر من التعابير السبعة. تعتمد الخوارزميّة على استخراج خصائص شكليّة وخصائص هندسيّة في المستوى الحيّزي من المقطع، لذلك فهي تُصنّف من الخوارزميّات الهجينة.

اعتُمد في الخوارزميّة المقترحة على قاعدة بيانات +CK لكلّ من التدريب والاختبار، وهي قاعدة بيانات تحوي 593 مقطع فيديو ل123 شخص من أعمار وجنسيّات مختلفة، بحيث يتمّ الانتقال في كلّ مقطع من التعبير المحايد إلى واحد من التعابير السبعة الأخرى بفترة بين أجزاء من الثانية إلى ثلاث ثوان، وبمعدّل إطار 30 إطار في الثانية وتمييزيّة 640x480 بكسل. خُصّص 40% من قاعدة البيانات للتدريب و 60% منها للاختبار. قبل كلّ من عمليّتي التدريب والاختبار يجري كشف وتحديد الوجه لأطر مقطع الفيديو المخصّص للتدريب أو الاختبار وذلك باستخدام خوارزميّة Viola-Jones وتغيير أبعاد صورة الوجه لتصبح ذات أبعاد موحّدة 256×256 بالإضافة إلى إيجاد نقاط الاستدلال لجميع الأطر.

3-1- التدريب:

تعتمد مرحلة التدريب على بناء أربع آلات شعاع دعم متعدّدة الأصناف بدل آلة واحدة، بحيث أنّ كل آلة شعاع دعم تتعامل مع خاصّيّة محدّدة، وتعطي نتيجة مستقلّة، تكون آلات شعاع الدعم الثلاثة الأولى مخصّصة للدراسة في المجال الحيّزي، أمّا آلة شعاع الدعم الرابعة فهي خاصّة بالمجال الزمني.

نجد في الشكل(8) المخطط التدفقي الخاص بالتدريب على المستوى الحيّزي والذي يهدف لبناء آلات شعاع الدعم الثلاث الأولى حيث يتمّ المرور على جميع الصور ذات التعابير المشبعة ضمن مقاطع الفيديو (أي الصور التي يكون فيها تعبير الوجه ظاهراً بشكله الأقصى) ، والتي تزوّدها قاعدة البيانات +CK، وليكن عدد هذه الصور M مساوياً لعدد مقاطع الفيديو المخصّصة للتدريب، سنطلق على هذه الصور اسم صور التدريب، من كلّ صورة يتمّ اقتطاع صورتين جزئيّتين هما صورة العينين وصورة الفم كما يبيّن الشكل (9)، وهكذا يكون لدينا ثلاث صور: صورة الوجه كاملاً، صورة العينين وصورة الفم. عند كل مرور بصورة تدريب يتمّ إجراء ما يلي:

1- لتشكيل آلة شعاع الدعم الأولى: يُستخرج مخطّط التدرّجات الموجّهة HOG لصورة الوجه الكامل، نرمز لمصفوفة مخطّط التدرّجات الموجّهة للوجه $h1_n$ حيث n دليل الصورة الحاليّة، ويكون لها الأبعاد $1 \times H_1W_1$ حيث H_1 طول صورة الوجه و W_1 عرضها أي أنّ أبعاد المصفوفة السابقة هو 65536×1، تُضاف المصفوفة $h1_n$ إلى المصفوفة الكلّيّة الخاصّة بالتدريب hog_face والتي سيكون لها الأبعاد $M \times H_1W_1$ عند الخروج من الحلقة. وهي مصفوفة تضمّ كلّ عيّنات التدريب الخاصة بآلة شعاع الدعم الأولى.

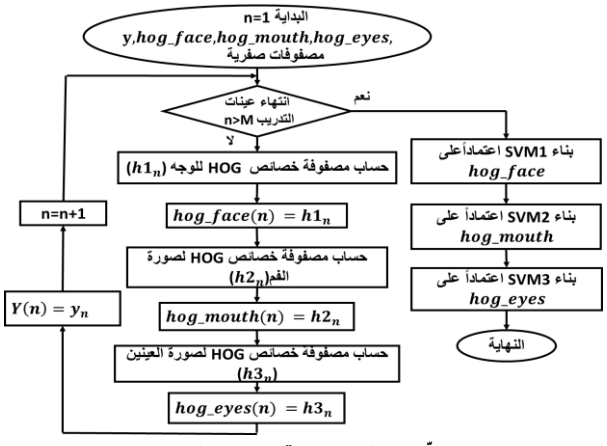

الشكل (8) المخطّط التدفقي لعمليّة التدريب في المستوى الحيّزي [الباحث]

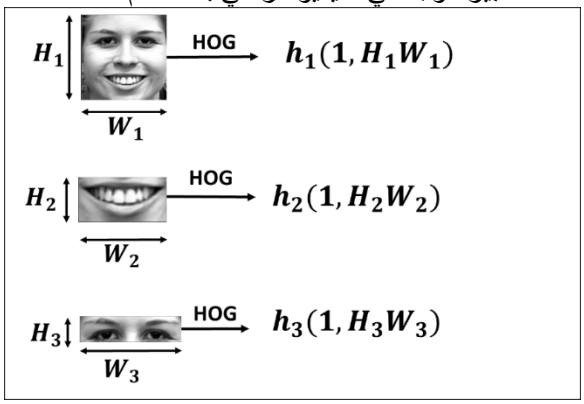

الشكل (9) استخراج خصائص آلات شعاع الدعم المخصصة للمجال الحيّزي [الباحث]

2- لتشكيل آلة شعاع الدعم الثانية: يُستخرج مخطّط التدرّجات الموجّهة HOG لصورة الفم (بعد اقتطاعها من صورة الوجه وتغيير أبعادها إلى 200×100 وذلك بهدف توحيد أبعاد صور الفم المخصصة للتدريب). نرمز لمصفوفة مخطّط التدرّجات الموجّهة للفم $h2_n$ حيث n دليل الصورة الحاليّة، ويكون لها الأبعاد $1 \times H_2W_2$ أي 1×20000 حيث H_2 طول صورة الفم و W_2 عرضها، تُضاف المصفوفة $h2_n$ إلى المصفوفة الكلّيّة الخاصّة بالتدريب hog_mouth والتي سيكون لها الأبعاد $M \times H_2W_2$ عند الخروج من الحلقة، وهي مصفوفة تضمّ كلّ عيّنات التدريب الخاصة بآلة شعاع الدعم الثانية.

3- لتشكيل آلة شعاع الدعم الثالثة: يُستخرج مخطّط التدرّجات الموجّهة HOG لصورة العينين (بعد اقتطاعها من صورة الوجه وتغيير أبعادها إلى 100×200 وذلك بهدف توحيد أبعاد صور العينين المخصصة للتدريب). نرمز لمصفوفة مخطّط التدرّجات الموجّهة للفم $h3_n$ حيث n دليل الصورة الحاليّة، ويكون لها الأبعاد $1 \times H_3W_3$ أي 1×20000 حيث H_3 طول صورة العينين و W_3 عرضها، تُضاف المصفوفة $h3_n$ إلى المصفوفة الكلّيّة الخاصّة بالتدريب hog_eyes والتي سيكون لها الأبعاد $M \times H_3W_3$ عند الخروج من الحلقة. وهي مصفوفة تضمّ كلّ عيّنات التدريب الخاصة بآلة شعاع الدعم الثالثة.

4- أخذ تعبير الوجه الخاص بكل صورة تدريب y_n والذي تزوّده قاعدة البيانات، وإضافته إلى المصفوفة الخاصّة بالتعابير Y.

تصبح مجموعات التدريب الخاصة لكل آلة شعاع دعم جاهزة بعد الخروج من الحلقة، فمن أجل آلة شعاع الدعم الأولى يكون لدينا عيّنات تدريب عددها M، نرمز للعيّنة hog_face_n حيث $i = 1,2, \dots, M$، عدد الخصائص لكل عيّنة H_1W_1. وكلّ عيّنة لها قيمة تعبير مقابل Y_n والذي يمكن أن يأخذ إحدى القيم الثمانية الأساسيّة، أي أنّ مجموعة التدريب لآلة شعاع الدعم الاولى هي $\{hog_face_n, Y_n\}$، ومن أجل آلة شعاع الدعم الثانية تكون مجموعة التدريب $\{hog_mouth_n, Y_n\}$ وعدد الخصائص لكل عيّنة H_2W_2، بينما آلة شعاع الدعم الثالثة تكون مجموعة تدريبها $\{hog_eye_n, Y_n\}$ وعدد الخصائص لكل عيّنة H_3W_3. نلاحظ أنّ آلات شعاع الدعم الثلاث السابقة مخصّصة لتقييم صورة واحدة وليس لاختبار تتابع صور (مقطع فيديو)، وستكون مهمّتها تقييم التعبير الظاهر في إطار واحد فقط من مقطع الفيديو عبر دراسته في المجال الحيّزي (إيجاد مخطّطات التدرّجات الموجّهة السابقة).

بالنسبة لآلة شعاع الدعم الرابعة فهدفها تقييم الإطار ضمن مقطع الفيديو في المستوى الزمني ويتمّ تدريبها عن طريق خاصّيّة تحسب من إطارين من مقطع الفيديو هما الإطار المرجعي (إطار التعبير الطبيعي) وإطار الذروة حيث تُحسَب خمس عشرة مسافة بين نقاط الاستدلال لكل من الإطارين كما يبيّن الشكل (10)، وتشكّل هذه المسافات مصفوفة نطلق عليها اسم مصفوفة المسافات:

$$\boldsymbol{d_n} = [\boldsymbol{d_{1,n}}, \boldsymbol{d_{2,n}}, \dots, \boldsymbol{d_{15,n}}].$$

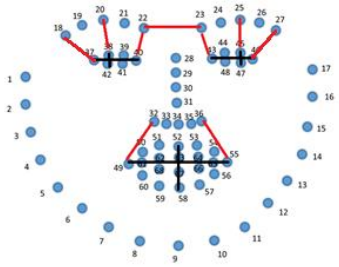

الشكل(10) المسافات المحسوبة بين نقاط الاستدلال [الباحث]

يوضّح الشكل(11) المخطّط التدفّقي لعمليّة تدريب آلة شعاع الدّعم الرابعة، والتي تتضمّن المرور على كامل عيّنات التدريب (مقاطع الفيديو المخصّصة للتدريب من قاعدة البيانات +CK)، ومن أجل كلّ عيّنة تُحسب مصفوفة الفرق D، والتي تمثّل الفرق بين مصفوفتي المسافات لكل من إطاري الذروة والإطار المرجعي لعيّنة التدريب الحاليّة:

$$D_n = d_{reference} - d_{peak}$$

ثمّ تضاف مصفوفة الفرق المحسوبة إلى المصفوفة الكليّة المخصّصة لتدريب آلة شعاع الدعم الرابعة وهي $distances$، عند الانتهاء من كل عيّنات التدريب والخروج من الحلقة سيصبح للمصفوفة distances الأبعاد $M \times 15$ حيث M عدد عيّنات التدريب بالإضافة إلى ما سبق يتمّ أخذ تعبير الوجه الظاهر في مقطع الفيديو الحالي إلى المصفوفة Yv والتي ستحوي التعابير المقابلة للخاصيّة الزمنيّة الموجودة في المصفوفة $distances$.

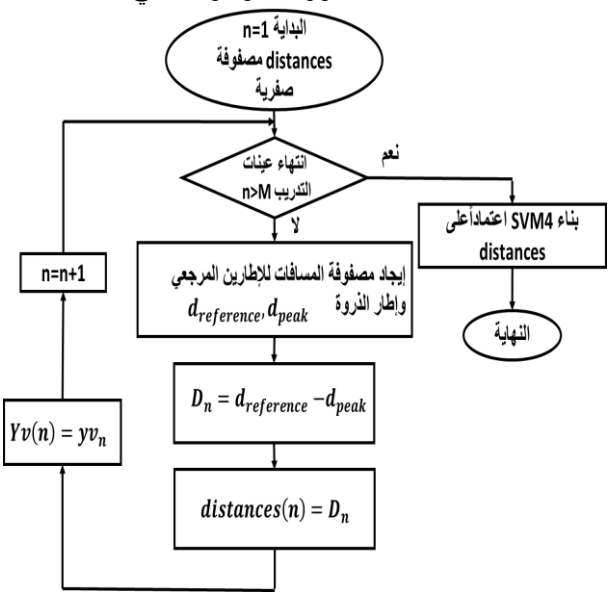

الشكل (11) المخطط التدفقي لعملية التدريب الخاصة بالمجال الزمني [الباحث]

وهكذا فإنّ مجموعة التدريب الخاصّة بآلة شعاع الدعم الرابعة هي $\{distances_n, Yv_n\}$ وعدد الخصائص لكلّ عيّنة هو 15.

3-2- الاختبار:

تقسم عمليّة الكشف باستخدام الخوارزميّة المقترحة إلى المراحل الأساسيّة التالية:

المرحلة الأولى: مرحلة تمهيديّة تتضمّن كشف وتحديد وملاحقة الوجه في مقطع الفيديو باستخدام خوارزميّة Viola-Jones، وإيجاد نقاط الاستدلال لجميع أطر المقطع.

المرحلة الثانية: تحديد إطار الذروة، وهو الإطار الأكثر اختلافاً عن الإطار المرجعي (إطار التعبير الطبيعي والذي يكون الإطار الأوّل في المقطع).

المرحلة الثالثة: دراسة إطار الذروة في المجال الحيّزي.

المرحلة الرابعة: دراسة إطار الذروة في المجال الزمني.

المرحلة الخامسة: اتخاذ قرار بشأن تعبير الوجه ضمن مقطع الفيديو بالاعتماد على نتائج الدراسة في كلّ من المجالين الحيّزي والزمني.

3-2-1-تحديد إطار الذروة:

إطار الذروة peak frame هو الإطار الأكثر اختلافاً عن إطار التعبير المحايد والذي يكون عادةً الإطار الأوّل في قواعد البيانات، نجد في الشكل (12) المخطّط التدفّقي لتحديد إطار الذروة في مقطع الفيديو، حيث يتمّ المرور على جميع الأطر في مقطع الفيديو المدروس، وحساب مصفوفة المسافات d_i لجميع الأطر ثمّ حساب المسافة الإقليديّة بين مصفوفة المسافات d_i ومصفوفة المسافات للإطار المرجعي $d_{refference}$ حسب العلاقة:

$$\boldsymbol{E = \sqrt{\sum_{j=1}^{15}(d_{i,j} - d_{refference,j})^2}}$$

فإذا كانت المسافة أكبر من القيمة العظمى max (والتي تأخذ القيمة الابتدائية 0) فعندها يتم تحديث قيمة max, $max = E$، واعتبار الإطار الحالي هو إطار الذروة وإلّا يتمّ الانتقال إلى إطار جديد، يكون إطار الذروة هو الإطار الذي تطبّق عليه كل من الدراستان الحيّزيّة والزمنيّة بهدف كشف تعبير الوجه في مقطع الفيديو.

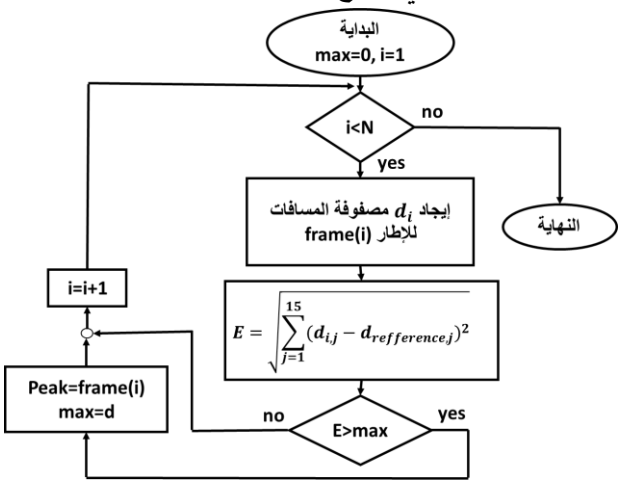

الشكل (12) المخطط التدفقي لإيجاد إطار الذروة [الباحث]

3-2-2- تحليل إطار الذروة في المجال الحيّزي:

تقسم عمليّة تحليل إطار الذروة في المجال الحيّزي إلى ما يلي:

1- دراسة الوجه كاملاً حيث تُحسب مصفوفة مخطّط التدرّجات الموجّهة لصورة الوجه $hog1$ ذات الأبعاد $1 \times H_1W_1$، وتدخل هذه المصفوفة على آلة شعاع الدعم الأولى SVM1 والمدرّبة مسبقاً، والتي ستعطي قرار مستقلّ بشان تعبير الوجه نرمز له ب y_1.

2- دراسة صورة الفم بعد اقتطاعها من صورة الوجه وتغيير أبعادها ليصبح 100×200 بهدف توحيد أبعاد صور الفم المخصّصة للاختبار، و تُحسب مصفوفة مخطّط التدرّجات الموجّهة لصورة الفم $hog2$ ذات الأبعاد $1 \times H_2W_2$، أي 1×20000 وتدخل هذه المصفوفة على آلة شعاع الدعم الثانية SVM2 والمدرّبة مسبقاً، والتي ستعطي قرار مستقلّ بشان تعبير الوجه نرمز له ب y_2.

3- دراسة صورة العينين بعد اقتطاعها من صورة الوجه وتغيير أبعادها ليصبح 100×200 بهدف توحيد أبعاد صور العينين المخصّصة للاختبار وتُحسب مصفوفة مخطّط التدرّجات الموجّهة لصورة العينين hog3 ذات الأبعاد $1 \times H_3W_3$ أي 1×20000، وتدخل هذه المصفوفة على آلة شعاع الدعم الثالثة SVM3 والمدرّبة مسبقاً، والتي ستعطي قرار مستقلّ بشان تعبير الوجه نرمز له ب y_3.

في نهاية التحليل الحيّزي أصبح لدينا ثلاثة قرارات مختلفة عن تعبير الوجه قد تتماثل وقد تختلف فيما بينها.

3-2-3- تحليل إطار الذروة في المجال الزمني:

يتضمّن هذا التحليل دراسة كل من الإطارين المرجعي وإطار الذروة، حيث يُحسب كلّ من مصفوفتي المسافات لهما:

$$d_{reference} = [d_{r,1},\ d_{r,2},\ \dots, d_{r,15}]$$
$$d_{peak} = [d_{p,1},\ d_{p,2},\ \dots, d_{p,15}]$$

ثمّ تحسب مصفوفة الفرق:

$$D = d_{peak} - d_{reference}$$

يوضّح الشكل (13) عمليّة إيجاد مصفوفة الفرق لمقطع فيديو.

تُدخل مصفوفة الفرق إلى آلة شعاع الدعم SVM4 المدرّبة مسبقاً والتي تُعطي في خرجها قراراً مستقلّاً عن تعبير الوجه الذي قد يتماثل أو يختلف عن التعابير التي أعطتها آلات شعاع الدعم الثلاث السابقة.

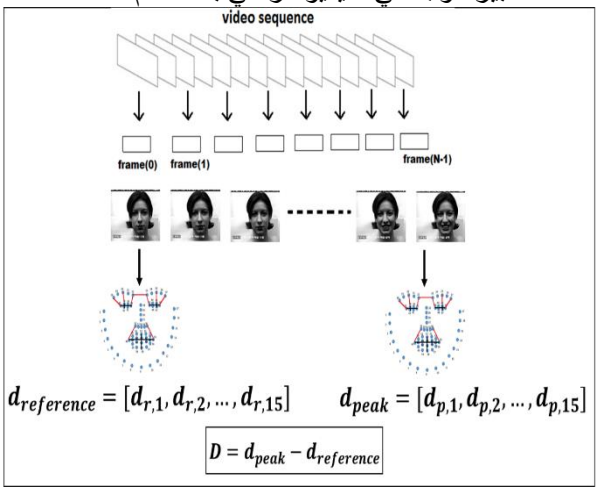

الشكل (13) إيجاد مصفوفة الفرق لمقطع فيديو [الباحث]

نتيجة كل من التحليلين الحيّزي والزمني لإطار الذروة يكون لدينا أربعة تعابير وجه للفيديو، كل تعبير ناتج عن آلة شعاع دعم. يبيّن الشكل (14) المخطّط الوظيفي لعمليّة تحليل إطار الذروة حيّزيّاً وزمنيّاً.

3-2-4-اتخاذ القرار:

يكمن سبب استخدام عدّة آلات شعاع دعم في الاحتمال الضعيف لإعطائها مجتمعةً نفس النتيجة الخاطئة، بالتالي زيادة دقّة الخوارزميّة. تعتمد عمليّة اتخاذ القرار على التصويت بالأغلبيّة majority voting على نتائج آلات شعاع الدعم الأربع، حيث يجري البحث عن التعبير الأكثر تكراراً كخرج كما يبيّن المخطط التدفقي في الشكل (15)، ونلاحظ في البداية قيم مميّزة للتعابير لكل منها القيمة 0، يتمّ المرور على آلات شعاع الدعم الأربع الواحدة تلو الأخرى، وعند كل آلة منها يتمّ المرور على التعابير الثمانية وفحص شرط مساواة خرج آلة شعاع الدعم لكلّ تعبير، فإذا كان التساوي محقّق عندها نزيد القيمة المميّزة e للتعبير الحالي وننتقل إلى آلة شعاع الدعم التالية وإلّا نفحص التعبير التالي. بعد الانتهاء من المرور على كلّ آلات شعاع الدعم ستكون القيم المميّزة للتعابير قد تغيّرت، وتبقى الخطوة الأخيرة هي معرفة القيمة المميّزة الأكبر منها، واعتبار التعبير الموافق لها هو تعبير الوجه الظاهر في مقطع الفيديو.

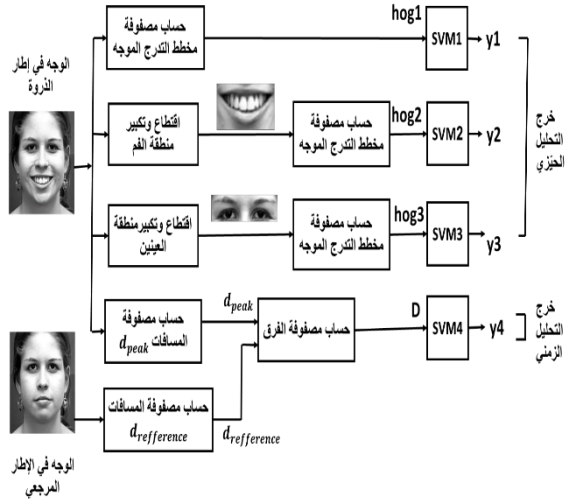

الشكل (14) المخطط الوظيفي لتحليل إطار الذروة [الباحث]

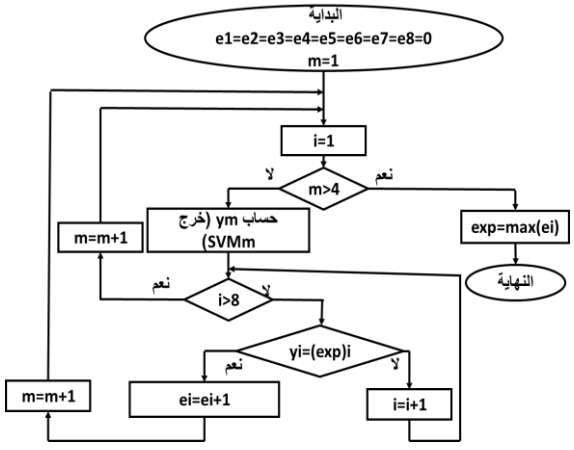

الشكل (15) المخطط التدفقي لعمليّة اتخاذ القرار النهائي [الباحث]

باعتبار أنّه تمّ تحديد كل من الوجوه ونقاط الاستدلال يتمّ إيجاد إطار الذروة لكلّ مقطع وتحليله حيّزيّاً وزمنيّا واتخاذ قرار بشان تعبير الوجه، إذا كان القرار المتّخذ صحيحاً عندها تزيد قيمة T بمقدار 1 وهي تمثّل عند الخروج من الحلقة العدد الكلّي لمقاطع الفيديو التي كُشف التعبير فيها بشكل صحيح، وتُحسب دقّة الخوارزميّة من العلاقة $Acc = (T/L) \times 100$.

3-3- النتائج:

نُفِّذت الخوارزميّة واختُبِرت بلغة بايثون نسخة 3.6، باستخدام حاسب نوع dell بمعالج Intel core i3, 2.53 GHz، وذاكرة وصول عشوائي GB4، وعلى قاعدة البيانات CK+ كما ذُكر مسبقاً. يبيّن الشكل (16) نتيجة التنفيذ على إطار الذروة لسبعة مقاطع من قاعدة البيانات.

الشكل (16) نتيجة التنفيذ على أطر من قاعدة البيانات CK+

3-3-1- دقّة الخوارزميّة والتعقيد الزمني للتصنيف:

أعطت الخوارزميّة دقّة 98.87% وذلك بأخذ حجم كتلة مخطّط التدرّجات الموجّهة 7x7، واستخدام تابع الأساس الشعاعي الغاوسي كتابع نواة لل SVM، ونجد في الجدول (1) مصفوفة الارتباك في هذه الحالة والتي توضّح الدقّة لكلّ تعبير من التعابير السبعة التي تمّ الانتقال إليها بدءاً من التعبير المحايد، بالإضافة إلى التعابير الخاطئة كنسبة مئويّة، تعبّر الرموز في الجدول عن التعابير كما يلي:

الدهشة: SU، الخوف: FE، الفرح: HA، الحزن: SA، الاشمئزاز: DI، الغضب: AN، الاحتقار: CO.

الجدول (1) مصفوفة الارتباك للخوارزميّة [الباحث]

	SU	FE	HA	SA	DI	AN	CO
SU	99	0	0.8	0	0	0.2	0
FE	0	98	1	0	1	0	0
HA	0.7	1	98	0	0	0	0.3
SA	0	0	0	98	1	0.3	0.7
DI	0	0.8	0.2	0	99	0	0
AN	0.5	1.4	1.2	0.3	1.2	95	0.4
CO	0	0	1.3	0	0.7	0	98

نجد في الجدول (2) دقّة نتائج كل آلة شعاع دعم، بالإضافة إلى الدقّة النهائيّة للخوارزميّة وذلك لعدّة نوى لآلات شعاع الدعم، ويمكن ملاحظة ما يلي:

1- يعطي الجمع بين نتائج آلات أشعّة الدعم حسب آليّة اتخاذ القرار السابقة دقّة أعلى من دقّة كل آلة شعاع دعم.

2- التابع الأمثل للنواة هو تابع الأساس الشعاعي الغاوسي حيث أعطى اعلى دقّة ممكنة لآلات شعاع الدعم وللدقّة النهائيّة.

الجدول (2) دقّة الخوارزميّة لعدّة توابع نوى لأشعة الدعم [الباحث]

التابع	دقة SVM1	دقة SVM2	دقة SVM3	دقة SVM4	الدقة النهائية

التابع الخطي	.1%39	.1%39	.2%19	5.8%8	.5%59
تابع الأساس الشعاعي الغاوسي	.5%59	.2%59	.3%39	7.3%8	%87.89
التابع متعدد الحدود	.2%39	.4%59	.2%29	4.5%8	.4%69
تابع الظل	%19	.2%29	.2%80	5%5	.8%19

باعتبار أنّ تابع النواة لل SVM هو RBF، يكون التعقيد الزمني لآلة شعاع الدعم هو $O(dk)$، حيث k عدد أشعة الدعم و d هو عدد أبعاد الدخل [6]، لذلك سيكون التعقيد الزمني للتصنيف باستخدام آلات أشعة الدعم الأربع هو $O(kd_1 + kd_2 + kd_3 + kd_4)$، أمّا التعقيد الزمني لعمليّة اتخاذ القرار المبيّنة في الشكل (15) فهي $O(1)$.

3-3-2- تأثير حجم كتلة مخطّط التدرّجات الموجّهة على الدقّة وزمن التنفيذ:

بتجربة تغيير حجم كتلة HOG للصور المدروسة (صورة الوجه، العينين، الفم)، لوحظ تغيّر دقّة الخوارزميّة، حيث زادت الدقّة بإنقاص حجم الكتلة، ولكن على حساب زمن التنفيذ حيث تستغرق الخوارزميّة زمناً أكبر من أجل حجم كتلة أصغر. يوضّح الشكل (17) العلاقة بين الدقّة وبعد الكتلة لمخطّط التدرّجات الموجّهة، بينما يعبّر الشكل (18) عن العلاقة بين متوسّط زمن التنفيذ (الذي حسب للمقاطع المخصّصة للاختبار) وبعد الكتلة.

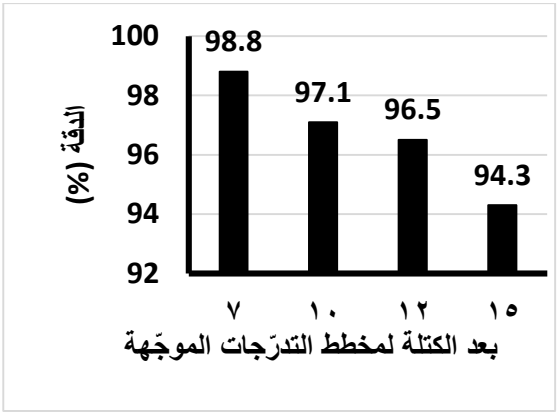

الشكل (17) تأثير تغيير بعد كتلة HOG على الدقّة [الباحث]

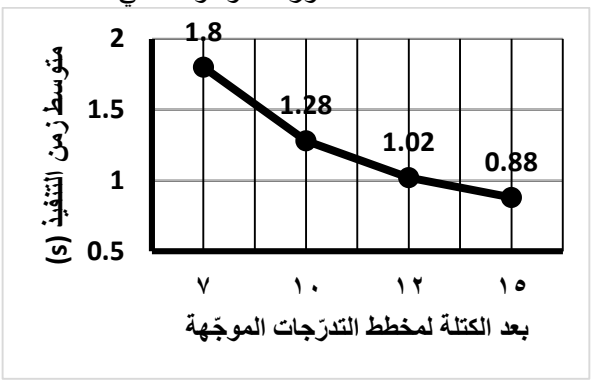

الشكل (18) تأثير تغيير بعد كتلة HOG على زمن التنفيذ [الباحث]

3-3-3- تأثير استخدام آلات شعاع دعم متعددة على أداء الخوارزميّة:

من أجل معرفة تأثير استخدام أربع آلات شعاع دعم مع تصويت الأغلبيّة بدلاً من آلة واحدة، جرى اختبار تشكيل شعاع واحد للخصائص (يحوي الخصائص كاملةً أي مخطط التدرجات الموجهة لصور الوجه والعينين والفم وفرق المسافات) وإدخالها إلى آلة شعاع دعم واحدة ومن ثمّ حساب كل من الدقة ومتوسّط زمن التنفيذ بعد الاختبار على نفس قاعدة البيانات وبأخذ أبعاد الكتلة 7x7. يبيّن الجدول (3) مقارنة بين الحالتين (استخدام آلة واحدة أو عدة آلات) ويمكن ملاحظة زيادة زمن التنفيذ باستخدام آلات شعاع دعم متعددة لكن مع تحقيق زيادة واضحة في الدقة.

الجدول (3) مقارنة بين نتائج استخدام آلة شعاع دعم واحدة أو عدة آلات [الباحث]

	SVM واحدة	SVM متعددة
دقة الخوارزميّة	81.1%	98.87%
متوسط زمن التنفيذ	0.967s	1.18 s

3-3-4- مقارنة الخوارزميّة المقترحة مع بعض خوارزميّات الطرائق التقليديّة:

نجد في الجدول (4) مقارنة بين الخوارزميّة المقترحة وبعض خوارزميّات الطرائق التقليديّة من حيث الخصائص المستخدمة ودقّة الكشف، بينما نجد في الجدول (5) المقارنة من حيث الإيجابيات والسلبيّات، مع العلم انّ جميع الخوارزميّات اختُبرت على قاعدة البيانات CK+ ما عدا الخوارزميّة الخامسة التي اختُبرت على قاعدة بيانات جديدة أنشأها الباحثون.

نلاحظ من الجدول (5) أنّ التحليل في الخوارزميّات ذات الأرقام (5-4-3-1) هو على المستوى الحيّزي فقط، بينما تتفوّق الخوارزميّة المقترحة مع الخوارزميّات ذات الأرقام (2-6) بكون الدراسة في كل من المستويين الزمني والحيّزي، بمعنى أنّها قادرة على كشف الانتقال من التعبير المحايد إلى تعبير آخر وليس فقط كشف وجود تعبير ما في إطار محدّد، كما يمكن أن نلاحظ من الجدولين تجاوز دقّة الخوارزميّة المقترحة دقّة الخوارزميّتين (6-2)، بالإضافة إلى كشف التعابير السبعة كاملةً، خلافاً للخوارزميّة السادسة التي كشفت الانتقال إلى ستة تعابير فقط.

يبيّن الجدول (6) مقارنة بين التعقيد الزمني للتصنيف للخوارزميّات المرجعية التي تستخدم آلة شعاع دعم واحدة (الخوارزميّتان 2 و6) والتعقيد الزمني للطريقة المتبعة، (يرتبط التعقيد بنواة SVM فيكون $O(k)$ للتابع الخطي و $O(kd)$ لتابع الأساس الشعاعي الغاوسي حيث k عدد أشعة الدعم و d أبعاد الدخل [21])، ويمكن أن نلاحظ زيادة التعقيد الزمني في الطريقة المقترحة بسبب استخدام عدة آلات شعاع دعم، ولكن مع الحصول على زيادة في الدقة.

الجدول (4) مقارنة مع بعض الخوارزميّات التقليديّة من حيث الخصائص والدقّة [الباحث]

	الخوارزمية	الخصائص وآليّة التصنيف	الدقة
1	Kar, N., K babu and S Bakshi (2022) [5]	–تحليل النمط المتغير VDM KELM –	98.81%
2	Kim, J. et al. (2022) [6]	–تغير الأبعاد والزوايا بين نقاط الاستدلال SVM –	96.64%
3	Haghpana, M. et al. (2022) [7]	–الأبعاد بين نقاط الاستدلال من مناطق الاهتمام، كشف الحواف ضمن مناطق الاهتمام – شبكة عصبونيّة	96.12%
4	Parra, B. et al. (2022) [8]	–نموذج الشكل الشبكي WSM – مقارنة مع جداول	91.5%
5	Kulkarni, P. and TM, R. (2021) [9]	–الأبعاد بين نقاط الاستدلال، الأنماط الثنائية المحلية LBP. KNN –	92%
6	Wang, Y. et al. (2021) [10]	–تغير الأبعاد والزوايا بين نقاط الاستدلال SVM –	98.37%
	الخوارزمية المقترحة	–تغير الأبعاد بين 15 من نقاط الاستدلال، مخطط التدرجات الموجهة HOG. SVM–	98.87%

الجدول (5) مقارنة مع بعض الخوارزميّات التقليديّة من حيث الإيجابيّات والسلبيّات [الباحث]

	الإيجابيات	السلبيات
1	دقة عالية نسبياً	التحليل على مستوى الإطار
2	التحليل على مستوى تتابع الأطر	
3	تم الاختبار على الزمن الحقيقي	التحليل على مستوى الإطار

التحليل على مستوى الإطار	لا يوجد حاجة إلى التدريب	4
التحليل على مستوى الإطار	الاختبار على قاعدة بيانات تقسم كل تعبير إلى ثلاثة مستويات	5
عددالتعابير 6 فقط	التحليل على مستوى تتابع الأطر	6
	– التحليل على مستوى تتابع الأطر – عدد التعابير 7	7

الجدول (6) مقارنة بين التعقيد الزمني للتصنيف وفق الطريقة المقترحة مع تعقيد التصنيف الخاص بالخوارزميتين المعتمدتين على SVM [الباحث]

الدقة	عدد التعابير	التعقيد الزمني لعملية التصنيف	نواة SVM	
96.64% (الاختبار على مستوى الإطار الواحد)	7	$O(kd)$	RBF	2
%98.37 (الاختبار على مستوى تتابع الأطر)	6	$O(d)$	linear	6
%98.87 (الاختبار على مستوى تتابع الأطر)	7	$O(kd_1 + kd_2 + kd_3 + kd_4)$	RBF	المقترحة

4- الاستنتاجات:

يمكن تلخيص استنتاجات البحث بالبنود التالية:

1- تمّ تطوير خوارزميّة جديدة لكشف تعابير الوجه في الفيديو الرقمي بالاعتماد على دراسة حيّزيّة وزمنيّة لإطار الذروة في المقطع، تتميّز الخوارزميّة المقترحة عن الخوارزميّات السابقة بأنها تجمع ما يلي:

a) تدرس مقطع الفيديو على مستوى تتابع الأطر وليس فقط على المستوى الحيّزي.

b) تكشف الانتقال إلى التعابير السبعة المشمولة في قاعدة البيانات كاملةً.

c) أعطت نتائج ذات دقّة عالية نسبياً بالمقارنة مع باقي الخوارزميّات بما فيها التي تدرس المقطع على مستوى تتابع الأطر.

2- استُخدم لكشف التعابير في الفيديو بدقّة عالية نسبيّاً نوعان من الخصائص:

a. خاصيّة حيّزيّة شكليّة وهي مخطّط التدرّجات الموجّهة لثلاث صور مأخوذة من إطار الذروة.

b. خاصّيّة حيّزيّة هندسيّة وفي نفس الوقت خاصيّة زمنيّة وهي تغيّر الأبعاد بين نقاط استدلال محدّدة بين الإطارين المرجعي وإطار الذروة.

2- يؤدّي تخصيص آلة شعاع دعم لكلّ خاصيّة سواءً حيّزيّة أو زمنيّة في مقطع الفيديو ومن ثمّ تنفيذ آليّة اتّخاذ قرار حسب التصويت بالأغلبية إلى إعطاء دقّة أعلى من حالة الاعتماد على آلة واحدة مع شعاع وحيد للخصائص ولكن مع زيادة التعقيد الحسابي.

3- التابع الأمثل لنواة آلات شعاع الدعم لكشف التعابير باستخدام الخصائص السابقة لمقطع الفيديو (مخطّط التدرّجات الموجّهة وتغيّر الأبعاد بين نقاط الاستدلال) هو تابع الأساس الشعاعي الغاوسي.

4- يؤدّي إنقاص حجم كتلة مخطّط التدرّجات الموجّهة إلى زيادة دقّة الكشف النهائيّة للمقطع ولكن على حساب سرعة التنفيذ.

التمويل: هذا البحث ممول من جامعة دمشق وفق رقم التمويل(501100020595).

References:

[1] Darwin, C. (1873). The Expression of the Emotions in Man and Animals. New York, D. APPLETION AND COMPANY.

[2] Ekman, P., Heider, K. (1988) The universality of a contempt expression: A replication. Motiv Emot 12,303-308.

[3] Lucey, P., Cohn, J., et al. (2010) The Extended Cohn-Kanade Dataset (CK+): A complete dataset for action unit. Disney Research, 4615 Forbes

Ave, Pittsburgh, PA 15213. and emotion-specified expression.

[4] Ko, B. (2018). A Brief Review of Facial Emotion Recognition Basedon Visual Information. sensors 18,401.

[5] Kar, N., babu ,K. & Bakshi, S. (2022). Facial expression recognition system based on variational mode decomposition and whale optimized KELM. Image and Vision Computing.

[6] Kim, J.,Kim, M. & Suh, H.(2022). Hybrid Approach for Facial Expression Recognition Using Convolutional Neural Networks and SVM. applied sciences. https://creativecommons.org/licenses/by/4.0/.

[7] Haghpana, M., Saeedizade, E., Masouleh, M., & Kalhor, A. (2022). Real-Time Facial Expression Recognition using Facial Landmarks and Neural Networks. International Conference on Machine Vision and Image Processing (MVIP),1-7. https:/10.1109/MVIP53647.2022.9738754.

[8] Barra, P., Maio, L.D., Barra, S. (2021). Emotion recognition by web-shaped model. Multimed Tools Appl . https://doi.org/10.1007/s11042-022-13361-6.

[9] Kulkarni, P. & M, R. (2021). Video Based Sub-Categorized Facial Emotion Detection Using LBP and Edge Computing. International Information and Engineering Technology Association, 35(3), 55-61. http://iieta.org/journals/ria.

[10] Wang, Y., Miao, S., Gu, X., Zhou, Y. & Zhang, B. (2021). Dynamic Facial Expressions Recognition based on Fusion of handcraft features. IAENG International Journal of Computer Science, 48(3).

[11] Kopp, P., Bradlie, D. (2019) Analysis and Improvement of Facial Landmark Detection. Swiss Federal Institute of Technology Zurich.

[12] Hamdi, S. (2018) OBJECT DETECTION USING HISTOGRAM OF GRADIENTS. SCHOOL OF SCIENCE & ENGINEERING – AL AKHAWAYN UNIVERSITY.

[13] Carcagnì, P., Coco, M. (2015) Facial expression recognition and histograms of oriented gradients: a comprehensive study. SpringerPlus.

[14] Chang, S., Xiaoqing, D., Ch,i F. (2011) Histogram of the Oriented Gradient for Face Recognitio., TSINGHUA SCIENCE AND TECHNOLOGY, Volume 16, Number 2.

[15] Greche, L., ES-Sbai, N. (2016). Automatic System for Facial Expression Recognition Based Histogram of Oriented Gradient and Normalized Cross Correlation. IEEE.

[16] Awad, M., Khanna, R. (2015). Support Vector Machines for Classification.

[17] Kecman, V. (2005). Support Vector Machines – An Introduction. The University of Auckland, School of Engineering, Auckland, New Zealand.

[18] Rhys, H. (2020) Machine Learning with R, the tidyverse, and mlr.

[19] Sun, B., Lee, M. (2006). SUPPORT VECTOR MACHINE FOR MULTIPLE FEATURE CLASSIFCATION. The Chinese University of Hong Kong, Shatin, Hong Kong.

[20] Goial, A. (2018). Learning a Multiview Weighted Majority Vote Classifier: Using PAC Bayesian Theory and Boosting.

[21] Maji, S., Berg, A. & Malik, J. (2012). Efficient Classification for Additive Kernel SVMs. IEEE TRANSACTION ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE.