

## تحسين أداء خوارزمية Viola-Jones في كشف وتحديد

### الوجوه ضمن الصور ومقاطع الفيديو الرقمية

د.م. فواز مفضي \*\*\*

د.م. طلال حمود\*\*

م. ولاء سفور\*

#### الملخص

تمّ في هذا البحث إجراء دراسة مرجعية لأهم خوارزميات كشف وتحديد الوجوه في الصور الرقمية والفيديو الرقمي، وهي خوارزمية Viola-Jones، ومن ثمّ إضافة تحسين لهذه الخوارزمية. يتمثل التحسين بزيادة سرعة تنفيذ الخوارزمية، وذلك عن طريق إضافة عملية كشف الجلد skin detection على المنطقة المحيطة من الصورة المدروسة أو الإطار المدروس من مقطع الفيديو، ومن ثمّ تطبيق خوارزمية Viola-Jones على الصورة مع إهمال المنطقة المحيطة إن كانت غير حاوية على الجلد. قمنا باختبار الخوارزمية على عدة صور وعدة مقاطع فيديو قبل وبعد التحسين، مع عرض النتائج.

**الكلمات المفتاحية:** كشف وتحديد الوجوه، خوارزمية Viola-Jones، خصائص Haar، خوارزمية Adaboost، كشف لون الجلد البشري.

\* أعد هذا البحث في سياق رسالة الدكتوراه للمهندسة ولاء سفور بإشراف الدكتور المهندس طلال حمود.

\*\* طالبة دكتوراه في قسم هندسة الإلكترونيات والاتصالات - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

\*\*\* أستاذ مساعد في قسم هندسة الإلكترونيات والاتصالات - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

\*\*\*\* دكتور مدرس في قسم هندسة الإلكترونيات والاتصالات - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

## Improving Viola-Jones algorithm's performance in face detection for digital images and videos

### Abstract

In this research, we present a reference study for the most important face detection algorithms in digital images and digital videos, which is Viola-Jones algorithm, and then we proposed an improvement to the algorithm which is increasing the speed of the algorithm's implementation by adding a skin detection process to the peripheral area of the studied image or the studied frame of video, and then applying Viola-Jones algorithm to the image while neglecting the peripheral area if it is not containing skin. We tested the algorithm on several images and videos before and after the optimization.

---

**Key words:** face detection, Viola-Jones algorithm, Haar features, AdaBoost algorithm, skin detection.

**1.مقدمة**

يُقصد بعملية كشف الوجه في صورة أو مقطع فيديو تحديد فيما إذا كانت الصورة أو المقطع يحوي وجوه أو لا، بالإضافة إلى تحديد موقع وأبعاد كل وجه، وكشف الوجه تطبيقات متعددة فهو يمثل مرحلة أولى للكثير من العمليات والتي من أهمها التعرف على الوجوه Face Recognition، التعرف على تعابير الوجه Facial Expressions Recognition ، كشف العمر والجنس وغيرها من التطبيقات. تُعتبر خوارزمية Viola-Jones من أهم خوارزميات كشف الوجه في الوقت الحالي، تم تطوير هذه الخوارزمية عام 2001 وكان ذلك بمثابة قفزة كبيرة في كشف الوجه لامتياز هذه الخوارزمية بالدقة العالية، بالإضافة إلى سرعة في التنفيذ لاعتمادها على أساليب حسابية ذات زمن تنفيذ قليل مما يجعل الخوارزمية مناسبة لكشف وملاحقة الوجوه في مقاطع الفيديو لذلك يُعتمد على خوارزمية Viola-Jones حالياً في معظم تطبيقات كشف وتحديد الوجه في الهواتف النقالة والحواسيب الشخصية.

منذ تطوير خوارزمية Viola\_Jones للمرة الأولى وحتى الآن، يعمل الباحثون على إضافة تحسينات لها، مما أدى إلى نشوء نسخ جديدة من الخوارزمية بعضها ذات سرعة أعلى وبعضها ذات دقة كشف أعلى من الخوارزمية الأساسية، ونذكر من ذلك قيام الباحثين John Gan و Adrlan Clarck في عام 2017 بزيادة سرعة الخوارزمية عن طريق استبدال خصائص Haar التي تستخرج في الخوارزمية الأساسية بخصائص الأنماط الثنائية المحلية Local Binary Patterns (LBP)، مما أعطى زيادة في سرعة الخوارزمية بمقدار الضعف، ولكن بوجود تقييد وهو التطبيق على الصور الحرارية فقط، والتي تلتقط من كاميرات خاصة [1]، أيضاً نذكر جهود الباحثين Ahmed I. Taloba، Adel A. Sewisy و Yasser A. Dawood عام 2018 في تحسين دقة خوارزمية Viola\_Jones وذلك عن طريق الخوارزميات الجينية Genetic Algorithms ويعتمد التحسين على وجود معامل يمكن من زيادة دقة الخوارزمية ولكن على حساب إنقاص سرعتها، أو العكس أي زيادة السرعة ولكن على حساب الدقة [2]، إضافةً إلى ذلك، قام الباحثون Muhammad Fachrurrozi, Kerel Afif عام 2020 بإضافة عملية كشف الجلد skin detection على

نوافذ الخوارزمية، ومن ثمّ الاستفادة من نتيجة الكشف لزيادة كل من دقة الخوارزمية وأيضاً زيادة سرعتها وقد بلغ مقدار زيادة السرعة 6.14%، إلا أنّ عملية الاختبار شملت الصور وحيدة الوجوه فقط [3].

## 2. هدف البحث

يهدف البحث إلى تقديم تحسين لخوارزمية Viola-Jones، ويتضمّن التحسين زيادة لسرعة تنفيذ الخوارزمية، ومن المعلوم أن خوارزمية Viola-Jones تعتبر من الخوارزميات ذات سرعة التنفيذ الجيدة كما ذكرنا سابقاً، لكن زيادة إضافية في سرعة التنفيذ ستكون مفيدة وفعالة في تحسين أداء الخوارزمية خصوصاً في ما يتعلّق بكشف وملاحقة الوجوه في مقاطع الفيديو بشكل عام، ومقاطع الفيديو التي تُبث مباشرةً بشكل خاص حيث تأخذ سرعة التنفيذ أهمية خاصة.


## 3. دراسة مرجعية عن كشف وتحديد الوجه باستخدام خوارزمية Viola-Jones

تقوم الفكرة الأساسية للخوارزمية على تمرير نافذة على الصورة واختبار فيما إن كانت هذه النافذة تحوي وجه ذا أبعاد موافقة لأبعاد النافذة أم لا. من أجل كشف وجوه بأبعاد مختلفة يجب تمرير نوافذ بأبعاد مختلفة، أي تمرير نافذة على كل مواضع الصورة ومن ثمّ تغيير حجم النافذة وتمرير النافذة الجديدة على مواضع الصورة وهكذا. تعتمد خوارزمية Viola-Jones في اختبار وجود الوجه في النافذة على ما يسمى خصائص Haar [4].

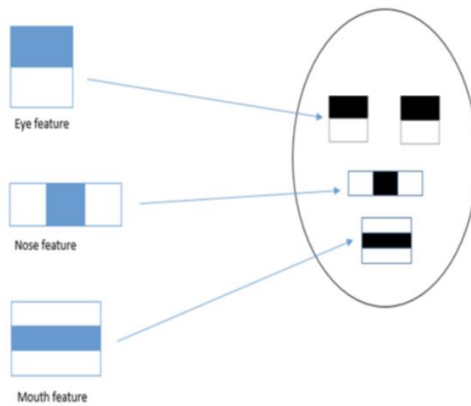


الشكل (1) مسح النافذة للصورة





الشكل (3) مثال أول عن استخدام خصائص Haar لكشف الوجه [6]



الشكل (4) مثال ثانٍ عن استخدام خصائص Haar لكشف الوجه [6]

يمكن لكل خاصية من خصائص Haar أن تعطي إما نتيجة إيجابية (استجابة عالية)، أو نتيجة سلبية (استجابة منخفضة)، أي يمكن القول أنّ كل خاصية Haar هي مصنّف يعطي نتيجة إيجابية أو سلبية عن وجود وجه في النافذة الحالية، لكنّ المصنّف المعتمد على خاصية Haar واحدة هو مصنّف ضعيف جداً أي ذو نتائج غير دقيقة فلا يمكن بالتأكيد الاقتصار عليه، وسنرى لاحقاً كيفية تشكيل مصنّف قوي لكشف الوجه عن طريق تكامل عدد كبير من خصائص Haar باستخدام خوارزمية AdaBoost [5].


### 2.3. طريقة حساب خصائص Haar في خوارزمية Viola-Jones

يتم حساب خصائص Haar عن طريق ما يعرف بالصورة التكاملية وهي طريقة للحساب السريع لمجموع القيم المحتواة ضمن مستطيل في الصورة، وتعتمد على العلاقة التالية:

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y')$$

حيث  $ii(x, y)$  هي الصورة التكاملية عند البكسل ذي الإحداثيات  $(x, y)$ ،  $i(x', y')$  هي الصورة الأصلية. يمكن الاعتماد على الصورة الجمعية من أجل حساب مجموع القيم ضمن المستطيل ABCD المبين في الشكل (5) عن طريق العلاقة التالية:

$$\sum_{(x,y) \in ABCD} i(x, y) = ii(D) + ii(A) - ii(B) - ii(C)$$



الشكل (5) حساب مجموع القيم ضمن مستطيل باستخدام الصورة التكاملية [7]

ونلاحظ أن حساب مجموع قيم بكسلات مستطيل تم بعملية حسابية على أربع قيم فقط، وبإسقاط هذا الأمر على حساب خصائص Haar، يمكن القول بأن حساب خاصية Haar للنوع الأول مثلاً تتم بعملية حسابية على ست قيم فقط، مقابل ثماني قيم لحساب النوع الثاني وتسع قيم لحساب النوع الثالث، ما يعني أن الاعتماد على الصورة التكاملية يفيد في حساب خصائص Haar بزمن قصير جداً [7].

### 3.3. التصنيف عن طريق خوارزمية AdaBoost

تهدف خوارزمية AdaBoost في بحثنا إلى تشكيل مصنّف قادر على تصنيف نافذة ما في صورة إما نافذة تحوي وجه أو نافذة لا تحوي وجه، بحيث أنّ أبعاد الوجه الذي نبحث عنه موافق لأبعاد النافذة، ويتم الاعتماد في تشكيل معادلة هذا المصنّف على خصائص Haar.

قبل شرح مبدأ عمل خوارزمية Adaboost في كشف الوجه لا بد من التطرق إلى التصنيف الثنائي.

### 1.3.3. التصنيف الثنائي

يُعرّف التصنيف classification على أنه نسب عنصر ما data object إلى فئة محددة من فئات معروفة مسبقاً، وذلك حسب خصائص هذا العنصر، وتتم عملية التصنيف عن طريق تحليل بيانات عدد من العناصر والتي عُلّم تصنيفها مسبقاً ويطلق عليها اسم عينات التدريب training data، وذلك بهدف تعلّم نموذج model أو تابع function يمكن استخدامه لاحقاً من أجل نسب عناصر غير معلومة التصنيف إلى الفئة الصحيحة. في تطبيق كشف الوجه، يوجد حالتان فقط للتصنيف هما وجود وجه وعدم وجوده، لهذا السبب نركز في الدراسة على التصنيف الذي يتضمن حالتين فقط، أو ما يعرف بالتصنيف الثنائي binary classification.

ليكن لدينا عدد من عينات التدريب، حيث أنّ عينة التدريب في حالتنا (كشف الوجه) هي عبارة عن صورة إما تحوي وجه أو لا تحوي وجه، وليكن عدد هذه العينات  $m$  وكل عينة تمتلك عدداً من الخصائص التي يعتمد عليها في التصنيف. سنرمز للمجموعة المؤلفة من العينات بالرمز  $X$ ، كل عينة من العينات لها تصنيف محدد والذي له خياران إما 1 (صورة تحوي وجه) أو -1 (صورة لا تحوي وجه) ونرمز لمجموعة التصنيفات بالرمز  $Y$  حيث  $Y = \{-1, +1\}$ .

سنعرّف الآن ما يسمى بمجموعة تدريب العينة sample training set وهي المجموعة  $S$  وتحوي العينة  $x_j$  مع التصنيف المقابل لها  $y_j$  أي  $S = \{(x_j, y_j)\}$  حيث  $j = 1, 2, \dots, m$ . سنرمز لخصائص العينة المؤثرة في عملية التصنيف بالرمز  $f_t$  حيث  $t = 1, 2, \dots, T$  باعتبار  $T$  عدد الخصائص.

تعني عملية تدريب المصنف الثنائي الخطي إيجاد علاقة خطية تربط بين الخصائص ونتيجة التصنيف وفق ما يلي:


$$z = \alpha_1 f_1 + \alpha_2 f_2 + \dots + \alpha_T f_T + b$$



$$z = \alpha^T x + b$$

وبحيث أنّ العينة الحالية تنتمي للتصنيف الأول أي  $y=1$  عندما يكون  $z>0$  وبالمقابل، تنتمي العينة إلى التصنيف الثاني أي  $y=-1$  عندما  $z<0$ . يطلق على  $\alpha$  اسم شعاع الوزن وهو يعطي وزن مختلف لكل خاصية من الخصائص بحسب مدى تأثيرها بالتصنيف، ويطلق على العدد  $b$  قيمة الانحياز، ويمكن للتبسيط اعتبار  $b=0$  بشرط جعل  $a_1 = 1$  بحيث يتحقق انحياز المستقيم المعبر عن العلاقة تبعاً للقيمة  $f_1$ .  
يمكن أن نلاحظ مما سبق أنّ مهمة تدريب المصنّف الثنائي الخطي هي إيجاد شعاع الوزن  $\alpha$  أي إيجاد القيم  $\alpha_1, \alpha_2, \dots, \alpha_T$  [8,9].

### 2.3.3. مبدأ خوارزمية AdaBoost

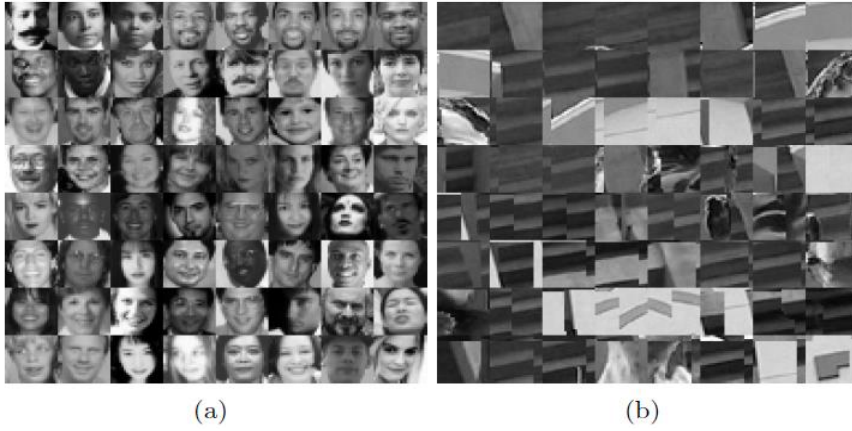


الشكل (6) المخطط الصندوقي لخوارزمية AdaBoost [10]


يقوم المبدأ الأساسي لخوارزمية AdaBoost على تكامل عمل عدد من المصنّفات الضعيفة (والتي لا تعطي نتائج دقيقة) للحصول على مصنف قوي، ويتم ذلك عن طريق التدريب بوجود عدد من عينات التدريب. في حالتنا كل مصنّف ضعيف يعتمد على واحدة من خصائص Haar أي يتخذ القرار بناءً على خاصية Haar واحدة، بينما عينات التدريب هي صور تحوي أو لا تحوي وجوه. يبين الشكل (7) بعض عينات التدريب المستخدمة في الخوارزمية، تتلخّص الخوارزمية بأنّ كل مصنّف ضعيف سيتم اختياره باستخدام جميع العينات من حيث إعطائه تصنيفاً صحيحاً أو خاطئاً، مع إعطاء أوزان لعينات التدريب بحيث تأخذ العينة وزناً عالياً إن تمّ تصنيفها بشكل خاطئ، بينما تأخذ العينة وزناً منخفضاً إن تمّ تصنيفها بشكل صحيح، وتستخدم العينات ذات الأوزان الجديدة لاختبار مصنّف جديد وهكذا حتى انتهاء المصنّفات، مع العلم أن المرور بكل مصنّف سينتج عنه وزن لهذا المصنّف

بحيث يكون الوزن أعلى كلما أعطى المصنّف نتائج أكثر دقة، وتهدف خوارزمية AdaBoost في النهاية إلى الحصول على معادلة مصنّف قوي قادر على تحديد ما إن كانت النافذة الحالية تحوي وجهاً مطابقاً لأبعادها أم لا، ويتمّ تشكيل هذه المعادلة من معادلات المصنّفات الضعيفة مع أوزانها [10].

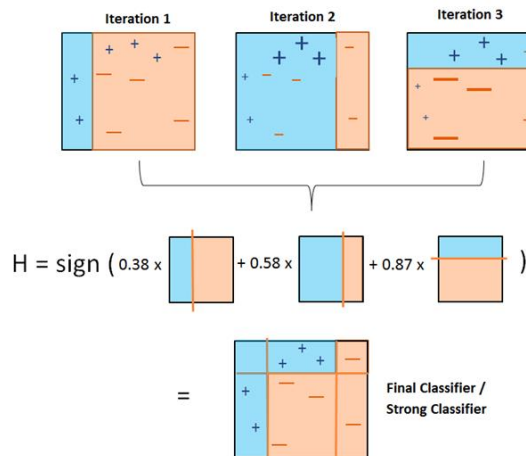
يوضح الشكل (8) المخطط التدفقي للخوارزمية بينما نرى في الشكل (9) مثلاً على الانتقال من مصنف إلى آخر مع عملية تغيير أوزان العينات.



الشكل (7) بعض عينات التدريب المرجعية بتدرجات الرمادي وبحجم 24x24، الشكل a يحوي عينات إيجابية والشكل b يحوي عينات سلبية [11]



الشكل (8) المخطط التدفقي لتدريب خوارزمية AdaBoost



الشكل (9) تغيير أوزان العينات مع الانتقال من مصنف إلى آخر وتشكيل المصنف النهائي [12]

من أجل الشرح التفصيلي للمخطط التدفقي لخوارزمية AdaBoost سنعتبر في البداية أن لدينا عدد من عينات التدريب (صور تحوي أو لا تحوي وجوه)، يتم إعطاء أوزان لهذه العينات، ونرمز لوزن العينة بالرمز  $D_{t,j}$  حيث  $j$  ترتيب العينة الحالية،  $t$  ترتيب المصنّف الحالي الذي سيُختبر باستخدام العينة الحالية. تكون الأوزان في بداية العمل متساوية ومساوية ل  $1/m$  حيث  $m$  عدد العينات، بعد ذلك، ندخل في حلقة هدفها المرور على المصنّفات الضعيفة الواحد تلو الآخر، شرط استمرار الحلقة هو عدم انتهاء المصنّفات أي  $t < T$  حيث  $t$  هي دليل المصنّف الحالي، في كل دورة للحلقة ستتقدّم الخطوات التالية:

1- اختيار أفضل مصنّف، أي المصنّف الذي يعطي خطأ تصنيف أقل ما يمكن، بحيث تعطى معادلة الخطأ:

$$E_t = \sum_{j=1}^n |h_t(x_j) - y_j|$$

2- حساب وزن المصنّف الحالي  $\alpha_j$  (في حالتنا هو وزن إحدى خصائص Haar) كما يلي:

$$\alpha_t = \log \frac{1 - E_t}{E_t}$$

3- الدخول في حلقة ثانية هدفها المرور على كل عينات التدريب وإعطاؤها أوزان، شرط استمرار الحلقة هو  $j < m$  حيث  $j$  دليل العينة الحالية،  $m$  عدد العينات الكلي. في كل دورة للحلقة يتم فحص العينة هل تمّ تصنيفها بشكل صحيح من قبل المصنّف الحالي أم لا، وبناءً عليه فإن العينة الحالية تعطى وزن عالي إن صنّفت بشكل خاطئ، وتُعطى وزن قليل إن صنّفت بشكل صحيح.

عند الانتهاء من تحديث أوزان عينات التدريب ننتقل إلى مصنّف جديد بمعادلة  $h_t(x)$ ، يقوم بدوره بتصنيف العينات بناءً على أوزانها الجديدة وتعاد الخطوات نفسها.

بعد الانتهاء من جميع المصنّفات يمكن الحصول على معادلة المصنّف النهائي  $H(x)$  حيث:

$$H(x) = \text{sign}\left(\sum_{t=1}^T a_t h_t(x)\right)$$

والذي يمكن له التحديد بدقة ما إن كانت النافذة تحوي وجه متناسب مع أبعادها أم لا [10].

### 4.3. تتالي المصنّفات Cascade of Classifiers

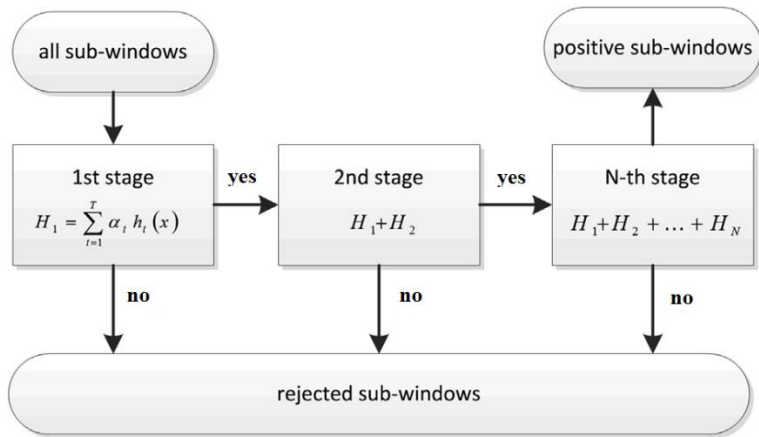
تعتمد خوارزمية Viola-Jones على عدة مصنّفات قوية، بحيث أنّ كل مصنّف قوي قد تمّ تشكيله من عدة مصنّفات ضعيفة معتمدة على خصائص Haar وذلك عن طريق خوارزمية AdaBoost. لتسريع عملية كشف الوجه يتمّ تشكيل عدة مراحل stages من المصنّفات القوية السابقة، بحيث تكون المرحلة الأولى قد تمّ تشكيل مصنّفها القوي من مصنّفات ضعيفة معتمدة على خصائص Haar الأكثر تأثيراً ودقّةً في الكشف، ونقل أهمية خصائص Haar المشكّلة للمصنّفات كلما تقدّمتنا في المراحل. تكمن الميزة الأساسية لخوارزمية Viola-Jones في سرعتها، وهذا الأمر تمّ تحقيقه عن طريق تتالي المصنّفات cascade of classifier وفق ما يلي:

- إذا أعطى المصنّف الخاص بالمرحلة الأولى (المعتمدة على الخصائص الأكثر تأثيراً) نتيجة سلبية هنا يمكن القول أنه لا يوجد وجه مقابل للنافذة الحالية، ولا داعي لاختبار المراحل التالية، وتمّ في هذه الحالة رفض النافذة الحالية بسرعة دون إضاعة وقت في اختبار باقي المصنّفات للنافذة.

- أمّا إذا أعطى المصنّف الخاص بالمرحلة الأولى نتيجة إيجابية فهنا توجد احتمالية لوجود وجه، ويتمّ التحقق من ذلك عن طريق مصنّف المرحلة الثانية، فإذا أعطى المصنّف الثاني بدوره نتيجة سلبية فهذا يعني عدم وجود وجه ويتمّ رفض النافذة دون المرور بالمراحل التالية، أمّا إذا أعطى المصنّف الثاني نتيجة إيجابية فهنا يتمّ

الانتقال إلى مصنّف المرحلة الثالثة وهكذا. يوضح الشكل (10) مبدأ تتالي المصنّفات.

بناءً على ما سبق، يتلخص عمل خوارزمية Viola-Jones بمسح الصورة بنوافذ متعددة الحجم، وعند كل تموضع للنافذة يتم اتخاذ قرار إما بوجود وجه ذي أبعاد متوافقة مع أبعاد النافذة أو بعدم وجوده، وذلك عن طريق تتالي مصنّفات قوية مشكّلة من خصائص Haar ومدربة سابقاً اعتماداً على خوارزمية AdaBoost [13].



الشكل (10) تتالي المصنّفات [13]

#### 4. تحسين خوارزمية Viola-Jones

يعتمد تحسين الخوارزمية على الاستفادة من فكرة أنّ الاحتمال الأكبر لوجود الوجوه في معظم التطبيقات لا يكون في المنطقة المحيطة للصورة، أي أنّ هذه المنطقة تملأ على الأغلب من الوجوه، فإذا تمكنا من التحقق من هذا الأمر بالنسبة إلى الصورة المدروسة أمكن حذف هذه المنطقة من المساحة التي تمسحها النوافذ في الخوارزمية، واقتصار مرور النوافذ ودراسة احتمالية وجود الوجوه على المنطقة المتبقية من الصورة، مما يعني التقليل من الزمن اللازم لتنفيذ الخوارزمية على الصورة. وعلى الرغم من أنّ خوارزمية Viola-Jones تعتبر من الخوارزميات السريعة نسبياً، لكن يبقى الحصول على سرعة إضافية في التنفيذ أمراً مرغوباً

ومثراً خصوصاً إذا كان تطبيق الخوارزمية على عدة صورة متلاحقة وليس هلى صورة واحدة ثابتة (حالة كشف وملاحقة الوجوه في مقاطع الفيديو).

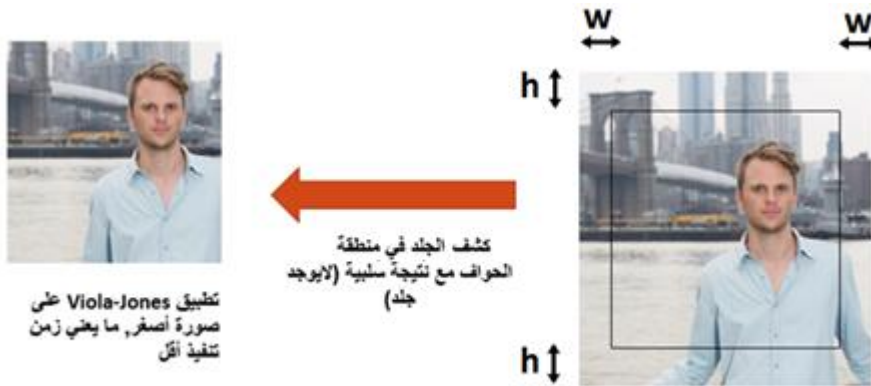
في البداية، يتم اختيار سماكة محددة للمنطقة المحيطة من الصورة، ولتكن على الشكل التالي مع أخذ قيمة مناسبة لN:

$$h = \frac{height}{N}$$

$$w = \frac{width}{N}$$

بعدها يجري اختبار وجود لون الجلد في المنطقة المحيطة المذكورة، وهنا يكون لدينا حالتان:

- النتيجة إيجابية أي المنطقة تحوي جلد وهنا يتم تطبيق خوارزمية Viola-Jones على الصورة كاملةً دون تغيير.
- النتيجة سلبية أي المنطقة لا تحوي جلد (وهو الاحتمال الأرجح)، هنا تُحذف المنطقة المحيطة المذكورة من الصورة وتقتصر حركة النافذة في خوارزمية Viola-Jones على المنطقة المتبقية من الصورة كما يبين الشكل (11).



الشكل(11) الاستفادة من كشف الجلد في المنطقة المحيطة

#### 1.4. كشف الجلد في الصورة Skin Detection

يمكن كشف الجلد البشري في صورة بالاعتماد على معرفتنا المسبقة بالمجال اللوني الذي يمكن أن يحتله الجلد، وتوجد عدة طرائق لتحديد هذا المجال بحيث تعتمد كل طريقة على واحد من الفضاءات اللونية  $YCbCr$ ,  $HSV$ ,  $RGB$ .. إلخ. يُعتبر فضاء  $HSV$  الأفضل والأدق من حيث كشف العناصر بالاعتماد على اللون، لذلك تمّ الاعتماد على هذا الفضاء اللوني في البحث.

يعبر فضاء  $HSV$  عن اللون باستخدام ثلاث مركبات: المركبة الأولى  $Hue$  وهو يمثل تغير اللون بحد ذاته بدءاً من اللون الأحمر وانتهاءً بالأخضر، ويأخذ قيم بين 0، 360. المركبة الثانية هي التشبع  $Saturation$  وهو يحدد هل اللون فاتح أم قاتم فعلى سبيل المثال وبالنسبة لقيمة  $Hue$  المساوية للصففر والمقابلة للون الأحمر، يعطي التشبع عدة تدرجات للأحمر تنتهي باللون الوردي الفاتح  $pink$ . المركبة الثالثة هي القيمة  $Value$  وهي تحدد الكثافة اللونية أي انتقال اللون من الأسود إلى الأبيض، ويُعبّر عن كل من التشبع والقيمة عادةً بنسبة بين 0،1.

يمكن الحصول على دقة جيدة عند استخدام فضاء  $HSV$  في كشف لون الجلد وذلك باعتبار أن الألوان المتعددة للجلد البشري تنحصر في المجالات التالية لمركبات الفضاء:

$$0 \leq H \leq 25$$

$$0.2 \leq S \leq 0.6$$

$$v \geq 0.4$$

فإذا كانت قيم البكسل ضمن المجالات السابقة للمركبات الثلاث يمكن القول بأنّ لون البكسل هو لون للجلد البشري، والعكس بالعكس [14].



## 5. النتائج ومناقشتها

## 1.5. نتائج تطبيق التحسين على الصور الثابتة

اختبرنا خوارزمية Viola-Jones قبل وبعد التحسين باستخدام لغة PYTHON نسخة 3.6 وبالاستعانة ببعض المكتبات مثل numpy,time، بالإضافة إلى الاعتماد بشكل أساسي على مكتبة openCV، وهي مكتبة خاصة بمعالجة الصور والفيديو. ما يميز هذه المكتبة في تطبيقنا هو أنها تمكّن من بناء تتالي مصنّفات بحيث يكون كل مصنّف مبنياً اعتماداً على خصائص Haar، بالإضافة إلى ذلك تؤمن مكتبة openCV مرونة في الانتقال بين الفضاءات اللونية المختلفة للصور، وبالتالي الانتقال إلى فضاء HSV من أجل كشف لون الجلد. الحاسب المستخدم هو بمعالج intel core i3 بسرعة 2.53GHZ. شمل الاختبار صوراً من إحدى قواعد البيانات الخاصة بتقييم خوارزميات كشف وتحديد الوجوه في الصور وهي قاعد بيانات (Face Detection Data Set and Benchmark). FDDB. تحوي قاعدة البيانات المذكورة على 2845 صورة فيها 5171 وجه، مع تعدد كبير من حيث ألوان الوجوه ووضعياتها، وكذلك دقة الصور والخلفيات [15].

تمّ الاختبار بأخذ قيم متعددة ل N، مع تقسيم النتائج إلى نتائج إيجابية (زيادة السرعة بعد التحسين) ونتائج سلبية (نقصان السرعة بعد التحسين)، قمنا بحساب النسبة المئوية للزيادة والنقصان. يبين الجدول (1) النتائج السابقة، ويبين الشكل (12) أمثلة على نتائج التنفيذ مع نقصان زمن التنفيذ بأخذ N=10، بينما يعبر الشكل (13) عن نتيجتين مع زيادة زمن التنفيذ بأخذ N=10.

N=14	N=12	N=10	N=8	N=6		
------	------	------	-----	-----	--	--

تحسين أداء خوارزمية Viola-Jones في كشف وتحديد الوجوه ضمن الصور ومقاطع الفيديو الرقمية

70.3%	66.3%	58.5%	54.4%	49.1%	النسبة المئوية لعدد النتائج الإيجابية	النتائج الإيجابية
78ms	113ms	141ms	172ms	200ms	متوسط نقصان زمن التنفيذ	
19.8%	23%	25.6%	30.2%	34.6%	متوسط النسبة المئوية لزيادة السرعة	
11.7%	15.7%	23.5%	27.6%	32.9%	النسبة المئوية لعدد النتائج السلبية	النتائج السلبية
20ms	20ms	22ms	22ms	23ms	متوسط زيادة زمن التنفيذ	
3.8%	3.8%	4%	3.9%	4.1%	متوسط النسبة المئوية لنقصان السرعة	
18%	18%	18%	18%	18%	النسبة المئوية لعدد النتائج الخاطئة	النتائج الخاطئة

الجدول (1) نتائج تطبيق تحسين الخوارزمية على قاعدة بيانات FDDB



الشكل (12) أمثلة على صور ذات نتائج إيجابية من قاعدة بيانات FDDDB باعتبار  $N=10$



الشكل (13) مثالان على صور ذات نتيجتين سلبيتين من قاعدة بيانات FDDDB باعتبار  $N=10$

نستنتج من الجدول السابق ما يلي:

1- كلما زاد المعامل  $N$  كلما زاد عدد النتائج الإيجابية أي أنه بزيادة  $N$  من أجل صورة ما يكون لدينا احتمالية أكبر لتحقيق تنفيذ الخوارزمية بسرعة أعلى.

2- مع زيادة المعامل  $N$  نحصل على زيادة أقل في سرعة التنفيذ، وهذا أمر متوقع لأن مساحة المنطقة المحذوفة والتي لن تمسحها نافذة الخوارزمية ستكون أقل بأخذ  $N$  أعلى.

3- هناك نتائج سلبية نقصت فيها سرعة التنفيذ، وهي تخص الصور التي تحوي الجلد في المناطق المحيطية، مثل الصورتين في الشكل (13)، حيث نلاحظ وجود الجلد في المنطقة السفلى لكل من الصورتين، وسبب هذه الزيادة في زمن التنفيذ هو أنّ عملية كشف الجلد في المنطقة المحيطية استغرقت زمناً، دون أن يقابلها تقليل في المساحة التي مسحتها نافذة الخوارزمية.


4- حسب الجدول (1) نرى أن متوسط زيادة زمن التنفيذ في الحالات السلبية (والمذكورة في البند 3) يقارب 20ms وهو رقم قليل بالمقارنة مع نقصان الزمن الذي نحصل عليه فيما لو كانت الصورة لا تحوي الجلد في المناطق المحيطية (حالة النتائج الإيجابية)، والذي قد يتجاوز 100ms، أي أنّ الفائدة المتحققة فيما لو كانت النتيجة إيجابية تفوق الضرر المتحقق عند النتيجة السلبية، مع الأخذ بعين الاعتبار أنّ معظم النتائج إيجابية خصوصاً عند أخذ  $N$  مساوية لـ 10 فما فوق كما هو مبين في الجدول.

4- نعلم أنّ جميع الخوارزميات الخاصة بكشف وتحديد الوجوه لها نسبة خطأ حيث تقشل الخوارزمية بكشف الوجه، فلا توجد خوارزمية تعطي نتائج صحيحة بنسبة 100% عند اختبارها بقاعدة بيانات ما، ونلاحظ من الجدول أن نسبة الخطأ للخوارزمية المدروسة بقيت عند القيمة المتعارف عليها للخوارزمية وهي 18% أي لم تتغير قبل وبعد إضافة كشف الجلد عليها، أي لا تتأثر نسبة الخطأ بإضافة التحسين.

## 2.5. نتائج تطبيق التحسين على مقطع فيديو

يمكن تطبيق خوارزمية Viola-Jones على مقاطع الفيديو ويعني ذلك تطبيق الخوارزمية على كل إطار frame من أطر المقطع، مما يفيد في كشف وملاحقة الوجوه ضمن الفيديو. يبين الشكل (14) المخطط التدفقي لتنفيذ تحسين خوارزمية Viola-Jones على مقطع فيديو.

قمنا باختبار خوارزمية Viola-Jones قبل وبعد التحسين على 20 مقطع فيديو وبأخذ الحالة الأكثر احتمالية لتحسين السرعة وهي حالة  $N=14$ ، وقد أخذ بعين الاعتبار تنوع محتوى هذه المقاطع حيث حوت نصف المقاطع على أشخاص متحركين بشكل عشوائي في شوارع وأسواق (من أجل دراسة تأثير وجود الجلد في حواف أطر الفيديو عند عدة لحظات زمنية) كالأمتلة في الشكل(14)، بينما حوى النصف الآخر أشخاص بموضع ثابت في منتصف أطر مقطع الفيديو كمقدم برنامج تلفزيوني مثلاً، كما نرى في المثالين المبينين في الشكل (15) حيث لا تحوي الحواف الجلد وذلك خلال كامل أطر المقطع.



الشكل (14) المخطط التدفقي لتنفيذ تحسين خوارزمية Viola-Jones على مقطع فيديو [الباحث]



الشكل (15) عينات لحظية من ثلاثة مقاطع فيديو بحركة عشوائية للأشخاص



الشكل (16) عينتان لحظيتان من مقطعي فيديو يحويان أشخاص ثابتين في منتصف الأطر

قمنا بحساب الزمن اللزم للتنفيذ قبل وبعد التحسين بالنسبة للمقاطع السابقة مع حساب نسبة تغير السرعة لمقاطع الحركة العشوائية ومقاطع الوجوه الثابتة ولاحظنا بالمقارنة ما يلي:

1- بالنسبة لمقاطع الحركة العشوائية للأشخاص، وبحساب متوسط تغير زمن التنفيذ بعد تطبيق التحسين وجدنا أنه مساوٍ ل  $0.002+$  ثانية للدقيقة الواحدة، أي يمكن القول أنه لا يوجد تأثير يذكر على سرعة التنفيذ بالنسبة لمقاطع الحركة العشوائية حيث أخذ التنفيذ بعد التحسين زمناً يساوي تقريباً الزمن قبل التحسين، وهذا الأمر متوقع بسبب وجود الجلد في حواف نسبة لا بأس بها من الأطر نتيجة للحركة العشوائية للأشخاص ما يعني تأثيراً سلبياً

على السرعة، ويعاكس هذا التأثير الأطر الأخرى التي لا تحوي الجلد في حوافها والتي تزيد فيها سرعة التنفيذ بالنسبة للإطار الواحد.

2- بالنسبة للمقاطع التي حوت وجوهاً ثابتة في المنتصف حصلنا على زيادة واضحة في سرعة التنفيذ وبحساب متوسط نقصان زمن التنفيذ وُجد أنه مساوٍ 4.3 ثانية للدقيقة الواحدة، أي يمكن القول أن التحسين يكون ذا فائدة في الحالة الثانية من مقاطع الفيديو (عدم وجود حركة تؤدي إلى ظهور الجلد في المناطق المحيطة من الأطر).

في الجدول (2) مقارنة بين أداء التحسين المدروس في هذا البحث مع بعض التحسينات الأخرى لخوارزمية Viola-jones والتي عُيّنت بزيادة سرعة الخوارزمية والمذكورة سابقاً في المقدمة.

تحسين الخوارزمية	تحسين الخوارزمية	تحسين الخوارزمية	تحسين الخوارزمية	طريقة التحسين	خاصية التحسين
تحسين الخوارزمية بإضافة كشف الجلد على المناطق المحيطة من الصورة (التحسين المدروس في البحث)	تحسين الخوارزمية بإضافة كشف الجلد على كل نافذة من نوافذ الخوارزمية (2020) [3]	تحسين الخوارزمية باستخدام الخوارزميات الجينية (2018) [2]	تحسين الخوارزمية باستخدام خصائص LBP بدل خصائص Haar (2017) [1]		
زيادة سرعة الخوارزمية دون التأثير على الدقة	زيادة سرعة ودقة الخوارزمية	الاختبار بين زيادة سرعة الخوارزمية أو زيادة دقتها	زيادة سرعة ودقة الخوارزمية		فائدة التحسين
لا يوجد قيود	لا يوجد قيود	لا يوجد قيود	الصور الحرارية فقط		وجود قيود
يتراوح بين 4.1% - و 34.6% حسب محتوى الصورة والمعامل N	6.14%	يتعلق بمقدار إنقاص الدقة ويُتحكم به باستخدام معامل خاص	50%		النسبة المئوية لزيادة السرعة

الجدول (2) مقارنة بين التحسين المدروس وبعض التحسينات الأخرى لخوارزمية Viola-Jones

## 6. الاستنتاجات

يفيد التحسين المشروح في هذا البحث والمعتمد على كشف الجلد في المناطق المحيطة من الصور في زيادة سرعة تنفيذ خوارزمية Viola-Jones سواءً للصور الثابتة أو لمقاطع الفيديو وذلك في الحالات التي تقل فيها احتمالية وجود الجلد في حواف الصورة أو الأطر، ويمكن القول أن التحسين المذكور مفيد في العديد من التطبيقات، مثل تطبيقات مكالمات الفيديو حيث يكون الوجه بشكل تلقائي في المنطقة الوسطى من الصورة، بينما لا يكون التحسين مفيداً في تطبيقات أخرى كأن تكون الحركة عشوائية في مجال تصوير الكاميرا مثل صور ومقاطع الفيديو لكاميرات المراقبة حيث تتوزع الوجوه على كامل مناطق الصور.



## 7. المراجع

- [1] Gan J, Clarck A, (2017) – **Accuracy Enhancement of the Viola–Jones Algorithm for Thermal Face Detection**, University of Essex.
- [2] Taloba A, Sewisy A, Dawood Y, (2018) – **Accuracy Enhancement Scaling Factor of Viola–Jones Using Genetic Algorithms**, Assiut University.
- [3] Fachrurrozi M, Afif K, (2020) –**Face Detection Using the Viola–Jones Method with Segmentation of Skin Color on Face Images**, Informatics Engineering Department, Faculty of Computer science, Universitas Sriwijaya, Vol.15,No.4(2020)2149 – 21621
- [4] Monali C, Shanta S, Gauresh V,(2015)– **A review on Face Detection and study of Viola Jones method**, International Journal of Computer Trends and Technology(IJCTT), volume 25 Number 1
- [5] Oualla M, Sadiq A, Mbarki S, (2015)– **COMPARATIVE STUDY OF THE METHODS USING HAAR LIKE FEATURES**, International Journal of Engineering Sciences & Research Technology.
- [6] Akash A, Mollah A,MAH A, (2016)– **Improvement of Haar Features Based Face Detection in OpenCV Incorporating Human Skin Color Characteristic**, Journal of Computer Science Applications and Information Technology.

- [7] Stefanos Z, Cha Z, Zhengyou Z,(2015)– **A Survey on Face Detection in the wild: past, present and future.**
- [8] Aijun A, **Classification Methods**, York University, Canada.
- [8] Grosse R, **Linear Classification.**
- [10] Meynet J, (2003)– **Fast Face Detection Using AdaBoost.**
- [11] Viola P,Jones M,(2001)– **Rapid Object Detection using a Boosted Cascade of Simple Features.**
- [12] Dangeti P,Yu A, Petrou T, (2018)– **Numerical Computing with Python.**
- [13] Riha K, Masek J, Burget R, (2013)– **NOVEL METHOD FOR LOCALIZATION OF COMMON CAROTID ARTERY TRANSVERSE SECTION IN ULTRASOUND IMAGES USING MODIFIED VIOLA–JONES DETECTOR**, World Federation for Ultrasound in Medicine & Biology, Vol. 39, No. 10, pp. 1887–1902.
- [14] Rahman M, Purnama I, Purnomo M, (2014)– **Simple Method of Human Skin Detection using HSV and YCbCr Color Spaces**, International Conference on Intelligent Autonomous Agents, Networks and Systems.
- [15] Jain V and Miller E, FDDB: **A Benchmark for Face Detection in Unconstrained Settings**, University of Massachusetts Amherst.