



الجمهورية الديمقراطية الشعبية الجزائرية

وزارة التعليم العالي والبحث العلمي

جامعة الشهيد حمه لخضر الوادي

كلية التكنولوجيا

قسم الهندسة الكهربائية

مذكرة تخرج لنيل شهادة

ماستر أكاديمي

ميدان: العلوم والتكنولوجيا

شعبة: الاتصالات

تخصص: أنظمة الاتصالات

من اعداد الطلبة:

1- بوصبيع صالح عبد الحفيظ

2- محده سعاد

الموضوع

. النظام القائم على ميزات الشبكة العصبية التلافيفية

للتحقق من القرابة

نوقشت في: 2026/06/.....

أمام لجنة المناقشة:

جامعة الوادي.

رئيسا

.....

جامعة الوادي.

مناقشا

.....

جامعة الوادي.

مشرفا

الأستاذ : حثيري مسعود

الموسم الجامعي: 2026/2025

ملخص

يُعدّ التعرّف على صلة القرابة أساسيًا لفهم العلاقات الأسرية من خلال ملامح الوجه. في هذه المذكرة، نستخدم الشبكات العصبية الالتفافية (CNN) لاستخراج الميزات. وللتحقق من صلة القرابة، نستخدم مُصنّف آلة المتجهات الداعمة (SVM). تم تقييم الدراسة على خمس قواعد بيانات صور وجوه متاحة للعموم تحتوي على أربعة أنواع من أزواج صلة القرابة.

الكلمات المفتاحية: التعرّف على صلة القرابة ، الشبكات العصبية الالتفافية (CNN) ، آلة المتجهات الداعمة (SVM) .

Abstract

Kinship recognition is fundamental to understanding family relationships through facial features. In this study, we use convolutional neural networks (CNNs) to extract features. To verify kinship, we use a support vector machine (SVM). The study was evaluated against five publicly available facial image databases containing four types of kinship pairs.

Keywords: Kinship recognition, convolutional neural networks (CNNs), support vector machine (SVM).

Résumé

La reconnaissance des liens de parenté est essentielle à la compréhension des relations familiales à travers les traits du visage. Dans cette étude, nous utilisons des réseaux de neurones convolutifs (CNN) pour extraire les caractéristiques faciales. Pour vérifier les liens de parenté, nous utilisons une machine à vecteurs de support (SVM). L'étude a été évaluée à l'aide de cinq bases de données d'images faciales publiques contenant quatre types de paires de parents.

Mots-clés : Reconnaissance des liens de parenté, réseaux de neurones convolutifs (CNN), machine à vecteurs de support (SVM).

اهـ

إلى من كان دعاؤهم سر نجاحي، وإلى من حملوا عني عناء الطريق بصبرهم و حبهم. إلى أبي الغالي، وأمي الحبيبة؛ أهديك ثمرة جهدي، وقطاف تعبتي، فأنتم الأمان الذي استندت إليه حين مالت بي السبل. أدامكم الله تاجاً فوق رأسي.

إلى كل من كان بصمة في حياتي، إلى الذين آمنوا بحلمي حينما كان مجرد فكرة. هذا الإنجاز ليس لي وحدي، بل هو إنجازٌ صنّع بفضل إيمانكم ووجودكم بجانبتي. لكل هؤلاء، أهديك نجاحي.

إلى من أضاءوا بفيض علمهم دروب المعرفة، إلى أساتذتي الأفاضل الذين لم ييخلوا عليّ بتوجيه أو نصيحة، وبذلوا جهداً في صقل فكري وتنوير بصيرتي. أهديك هذا العمل، تقديراً لجميل فضلكم وعرفاناً بمسيرتكم التعليمية النبيلة.

إلى نفسي.. التي صبرت، وثابرت، ولم تنحن أمام التحديات. إلى الشغف الذي دفعني للوصول إلى هنا، وإلى الطموح الذي لا يعرف الحدود. أهدي هذا الجهد لبداية جديدة، ولآفاق أوسع أرنو إليها بعين الأمل.

يبين دفتي هذه المذكرة، لا أضع مجرد كلمات أو أرقام، بل أضع خلاصة رحلة من البحث، والكفاح، والتعلم. أهدي هذا العمل لكل يدٍ امتدت لي بالعون، ولكل قلب نبض بالدعاء لي في الخفاء،

عبد الحفيظ بوصبيح صالح

اهــداء

إلى نبع الحنان ومن وضع الله الجنة تحت اقدامها أُمي الحبيبة، وإلى من كان سندي والقُدوة
إخوتي العزاء أهدي إليكم ثمرة جهدي ونجاحي راجيا أن ينال رضاكم.

إلى كل من كان له اثر في حياتي وساهم في تحقيق حلمي ولو بكلمة تشجيع إلى من علموني
وارشدوني اهديكم هذا العمل المتواضع.

إلى اخوتي واخواتي رفقاء الدرب وجزء من كل نجاح والى كل صديق كان لي كتفا وسندا
في لحظات التعب والياس وإلى زميلي الطالب بوصبيع صالح عبد الحفيظ الذي ساعدني كثيرا على
إنجاز هذا العمل.

سعاد محده

تشكرات

الحمد لله الذي بنعمته تتم الصالحات، والصلاة والسلام على أشرف المرسلين.
نتقدم بخالص الشكر والتقدير إلى الأستاذ المشرف مسعود حتيري، الذي تفضل بالإشراف على هذا العمل،
ولم يبخل علينا بتوجيهاته القيمة ونصائحه السديدة، فكان نعم المعلم والموجه.
كما نتوجه بالشكر والامتنان إلى كافة أساتذة جامعة الوادي : كلية التكنولوجيا قسم الهندسة الكهربائية
تخصص أنظمة الاتصالات ، الذين نلنا من علمهم طوال مسيرتنا الدراسية.
ونخص بالشكر كل من مد لنا يد العون، سواء بالنصح أو المعلومة أو التشجيع، فجزاهم الله عنا خير الجزاء.

الفهرس

1.....	ملخص
2.....	Abstract
3.....	Résumé
4.....	إهداء
6.....	تشكرات
7.....	الفهرس
11.....	قائمة الاشكال
12.....	قائمة الجداول
13.....	الاختصارات
14.....	قائمة المصطلحات
16.....	المقدمة العامة

الفصل الاول:

معلومات عامة حول التحقق من القرابة

18.....	1.1 مقدمة
18.....	2.1 معلومات عامة عن القياسات الحيوية
19.....	3.1 مهام نظام القياسات الحيوية
19.....	1.3.1 التحقق
19.....	2.3.1 تحديد الهوية
19.....	3.3.1 أنظمة تحليل صور الوجه
20.....	4.1 التحقق من القرابة

20.....	1.4.1	عموميات وتعريفات
20.....	2.4.1	بنية نظام التحقق من القرابة
21.....	3.4.1	تطبيقات نظام التحقق من القرابة
22.....	5.1	قواعد بيانات صور الوجه
22.....	1.5.1	قاعدة بيانات (Cornell Kinship (2010))
23.....	2.5.1	قاعدة بيانات (UB KinFace)
23.....	3.5.1	قاعدة بيانات (IIITD Kinship (2012))
24.....	4.5.1	قاعدة بيانات (Family101 (2013))
25.....	5.5.1	قاعدتي بيانات (KinFaceW-I و KinFaceW-II (2014))
26.....	6.1	المقارنة بين قواعد بيانات التحقق من القرابة
26.....	7.1	الخاتمة

الفصل الثاني :

الشبكات العصبية الالتفافية (CNN)

27.....	2.1	مقدمة :
27.....	2.2	المكونات الرئيسية للشبكة العصبية الالتفافية
28.....	1.2.2	طبقات الالتفاف
31.....	2.2.2	دالة التنشيط
31.....	3.2.2	طبقة التجميع
32.....	4.2.2	الطبقات المتصلة بالكامل
32.....	3.2	التدريب الزائد والتنظيم في الشبكات العصبية الالتفافية
34.....	4.2	التطبيقات العملية للشبكات العصبية الالتفافية

35.....5.2 أشهر بنى الشبكات العصبية الالتفافية

36.....6.2 الخلاصة

الفصل الثالث :

النظام القائم على الميزات والمبني على الشبكات العصبية التلافيفية

للتحقق من القرابة

37.....1.3 مقدمة

37.....2.3 بنية النظام ولمبني على الشبكات العصبية التلافيفية

38.....1.2.3 المعالجة المسبقة للوجه

39.....2.2.3 استخلاص الميزات

40.....3.2.3 توحيد وتمثيل خصائص الأزواج

41.....4.2.3 اختيار الميزات

41.....5.2.3 مصنفات الميزات

41.....6.2.3 مصنفات آلة المتجهات الداعمة (SVM)

42.....7.2.3 تدريب الشبكة العصبية التلافيفية (CNN) للانحدار

42.....3.3 التجارب والإعدادات

42.....1.3.3 إعدادات قواعد البيانات

42.....2.3.3 النتائج التجريبية

43.....3.3.3 المقارنة مع المناهج الأخرى

44.....5.3 الخلاصة

45.....الخلاصة العامة

46.....المراجع

قائمة الاشكال

- الشكل 1.1: الخصائص البيومترية الرئيسية 18
- الشكل 2.1: البنية العامة لنظام التحقق من القرابة باستخدام صور الوجه 21
- الشكل 3.1: أمثلة على صور من قاعدة بيانات "Cornell Kinship" 22
- الشكل 4.1: أمثلة على صور من قاعدة بيانات "UB KinFace" 23
- الشكل 5.1: أمثلة على صور من قاعدة بيانات "IIITD Kinship" 24
- الشكل 6.1: أمثلة على الصور من قاعدة بيانات "Family101" 24
- الشكل 7.1: أمثلة على الصور من قاعدة بيانات "KinFaceW-I" 25
- الشكل 8.1: أمثلة على الصور من قاعدة بيانات "KinFaceW-II" 25
- شكل 1.2: بنية الشبكات العصبية التلافيفية المطبقة على التعرف على الأرقام 28
- شكل 2.2: توضيح للصورة المدخلة وتمثيلها بالبكسل 29
- شكل 3.2: تطبيق مهمة الالتفاف باستخدام خطوة مقدارها 1 مع نواة 3×3 30
- شكل 4.2: تطبيق التجميع الأقصى بخطوة 2 باستخدام مرشح 2 31
- شكل 5.2: سيع استراتيجيات للحد من فرط التخصيص في الشبكات العصبية التلافيفية 33
- شكل 6.2: بعض التطبيقات العملية للشبكات العصبية الالتفافية 34
- الشكل 1.3: التصميم العام للنظام 38
- الشكل 2.3: المعالجة المسبقة للوجه 39
- الشكل 3.3: وصف نموذج الشبكة العصبية التلافيفية 39
- الشكل 4.3: البنية العامة لشبكة ResNet CNN 40

قائمة الجداول

- الجدول 1.1: ملخص قواعد بيانات التحقق من القرابة.....26
- الجدول 1.3: دقة النتائج (%) لقواعد البيانات المستخدمة.....43
- الجدول 2.3: مقارنات بين النظام المدروس في هذه المذكرة والأساليب الأخرى الموجودة.....44

قائمة المختصرات

المختصر	المعنى
CNN	Convolutional Neural Networks
conv	convolution
ReLU	Rectified Linear Unit
ResNet	Residual network
RBF	Radial basis function
SVM	Support Vector Machine

قائمة المصطلحات

العربية	الانجليزية
التطبيع الدفعي	batch normalization
المصفوفة الملتفة	convoluted matrix
علامة الالتفاف	convolution sign
الشبكات العصبية الالتفافية	Convolutional neural networks
الالتفاف	convolution
طبقات الالتفاف	Convolutional layers
تضخيم البيانات	data augmentation
التسرب	dropout
التوقف المبكر	early stopping
التعرف على الوجوه	Facial recognition
العائلة 101	Family101
الأب	father
مرشح	Filter
شبكة عصبية متصلة بالكامل	Fully connected neural network
طبقات متصلة بالكامل	Fully connected layers
تصنيف الصور	image classification
صورة الإدخال	input image
قراية	Kinship
وجه قريب	KinFace
تمثيل البكسل	pixel representation
طبقات التجميع	pooling layers

مصفوفة التجميع	pooling matrix
أقصى تجميع	max pooling
الأم	mother
حقن الضوضاء	Noise injection
اكتشاف الأجسام	object detection
الإفراط في التخصيص أو التجاوز	Overfitting
دالة الأساس الشعاعي	Radial basis function
الشبكة المتبقية	Residual network
وحدة التنشيط الخطي المعدل	Rectified Linear Unit
خطوة	stride

المقدمة العامة

يُعدّ تحليل صور الوجه عنصراً أساسياً في مجال معالجة الصور، إذ يُوفّر معلومات قيّمة من بيانات الوجه. وإلى جانب التحقق من الهوية والتعرّف عليها بالطرق التقليدية، اتجهت الأبحاث بشكل متزايد نحو مجال التحقق من صلة القرابة.

التحقق من صلة القرابة هو تقنية بيومترية تهدف إلى تحديد العلاقات الأسرية بين الأفراد باستخدام صور وجوههم. تعتمد هذه العملية على تحليل ملامح الوجه لتحديد أوجه التشابه الوراثية. في السنوات الأخيرة، ساهمت التطورات الكبيرة في مجال رؤية الحاسوب وتقنية التعرّف على الوجوه في دفع المزيد من الأبحاث، مما حسّن من دقة وأداء هذه التقنية.

تُصنّف دراسات التحقق من صلة القرابة المعاصرة العلاقات الأسرية عادةً إلى ثلاث مجموعات جيلية: الجدّ والحفيد، والوالد والطفل، والأشقاء. ومن بين هذه المجموعات، تحظى علاقات الوالدين والأبناء بأكبر قدر من الاهتمام نظراً لأهميتها العملية، وتشمل العلاقات الشائعة علاقة الأم والابن، وعلاقة الأم والابنة، وعلاقة الأب والابن، وعلاقة الأب والابنة. يشير التحقق من القرابة إلى عملية تحليل صور وجهي شخصين لتحديد ما إذا كانت تربطهما صلة قرابة.

يُعدّ التعرف على صلة القرابة أساسياً لفهم العلاقات الأسرية من خلال ملامح الوجه، ولا يزال مهمةً أكثر تعقيداً وتحدياً من التعرف التقليدي على الوجوه. في هذه المذكرة، استخدمنا الشبكات العصبية الالتفافية (CNNs) نظراً لمتانتها في مهام رؤية الحاسوب، وتحديدًا الشبكة المتبقية (ResNet)، لاستخراج الميزات. وللتحقق من صلة القرابة، استخدمنا مصنف آلة المتجهات الداعمة (SVM). تم تقييم الدراسة على خمس قواعد بيانات صور وجوه متاحة للعموم تحتوي على أربعة أنواع من أزواج القرابة.

خصصنا الفصل الأول لدراسة أنظمة التحقق من صلة القرابة باستخدام صور الوجه. حيث قدمنا معلومات عامة حول القياسات الحيوية والتقنيات المختلفة المستخدمة في هذا المجال. ثم شرحنا المفاهيم اللازمة لفهم نظام تحليل الوجه. بعد ذلك، تناولنا البنية العامة والأهداف الرئيسية وتطبيقات نظام التحقق التلقائي من صلة القرابة. وفي نهاية هذا الفصل، قدمنا قواعد البيانات المختلفة المستخدمة.

قدمنا في الفصل الثاني نظرة شاملة على مفهوم الشبكات العصبية التلافيفية في التعلم العميق، ودورها المحوري في مهام التعرف على الصور وتصنيفها.

في الفصل الثالث و الأخير، عرضنا منهجًا لتحديد صلة القرابة يعتمد على الشبكة العصبية التلافيفية، حيث طبقناه على خمس مجموعات بيانات: KinFace W-I ، و KinFace W-II، و Family 101، و Cornell، و UB KinFace .

و قد ختمنا مذكرتنا بخلاصة عامة و الآفاق المستقبلية لهذا المنهج المعروض.

الفصل الاول:


معلومات عامة حول التحقق من القرابة

1.1 مقدمة :

يُخصّص هذا الفصل لدراسة أنظمة التحقق من صلة القرابة باستخدام صور الوجه. نبدأ بتقديم معلومات عامة حول القياسات الحيوية والتقنيات المختلفة المستخدمة في هذا المجال. ثم نشرح المفاهيم اللازمة لفهم نظام تحليل الوجه. بعد ذلك، نتناول البنية العامة والأهداف الرئيسية وتطبيقات لنظام التحقق التلقائي من صلة القرابة. وفي نهاية هذا الفصل، نُقدّم قواعد البيانات المختلفة المستخدمة.

2.1 معلومات عامة عن القياسات الحيوية

القياسات الحيوية هي العلم الذي يُعنى بتحليل الخصائص الجسدية أو السلوكية الخاصة بكل فرد، مما يُتيح التعرف على الشخص أو التحقق من هويته. يُصنف القياس الحيوي إلى فئتين: القياسات الفيزيولوجية، مثل بصمات الأصابع وملامح الوجه وشبكية العين وقزحية العين والصوت، والقياسات السلوكية، مثل المشية وديناميكية التوقيع وإيماءات اليد [10] (انظر الشكل 1.1).



الشكل 1.1: الخصائص البيومترية الرئيسية :

(أ) بصمة الإصبع، (ب) الوجه، (ج) قزحية العين، (د) شبكية العين، (هـ) شكل الأذن، (و) راحة اليد، (ز) هندسة اليد، (ح) زوج العينين، (ط) الأوعية الدموية في الملتحمة، (ي) ديناميكيات الكتابة، (ك) القياسات البشرية، (ل) التوقيع، (م) صورة حرارية للوجه، (ن) الكلام، (س) المشية.

من الناحية الأمنية، تُعد تقنيات القياسات الحيوية من بين الأقوى. فعلى عكس كلمات المرور أو أرقام التعريف الشخصية (PIN)، التي يسهل نسيانها أو استخدامها بشكل احتيالي، أو المفاتيح أو البطاقات الممغنطة التي يجب على الفرد حملها والتي يسهل سرقتها أو نسخها أو فقدانها، فإن الخصائص الحيوية فريدة لكل فرد، ومن النادر أن يمتلكها أفراد آخرون [11].

3.1 مهام نظام القياسات الحيوية

بحسب سياق التطبيق، يمكن أن يكون نظام القياسات الحيوية نظام تحقق أو نظام تعريف [12].

1.3.1 التحقق

يتحقق النظام من هوية الشخص بمقارنة خصائصه البيومترية المسجلة مع نموذج الهوية المدّعى بها والمخزن في النظام. في هذا النظام، يُدخل المستخدم بيانات هويته وخصائصه البيومترية، ما يؤدي إلى مقارنة البيانات المسجلة مع البيانات المخزنة. وتكون النتيجة إما رفضاً ("الشخص ليس هو من يدّعي أنه") أو قبولاً ("الشخص هو بالفعل من يدّعي أنه").

2.3.1 تحديد الهوية

يُحدد النظام هوية الفرد بالبحث في توافيق (نماذج) جميع المستخدمين في قاعدة البيانات. ولذلك، يُجري النظام مقارنات متعددة لتحديد هوية الفرد (أو يفشل إذا لم تكن المعلومات مسجلة في قاعدة بيانات النظام) دون أن يُطلب من المستخدم تأكيد هويته.

3.3.1 أنظمة تحليل صور الوجه

تُعد أنظمة تحليل صور الوجه من أكثر أنظمة القياسات الحيوية استخداماً. ويُعتبر تحليل صور الوجه مجالاً بحثياً شائعاً جداً، إذ يُتيح تحقيق أهداف مُحددة (مثل تحديد هوية الشخص أو التحقق منها، أو الكشف عن صلة القرابة، وما إلى ذلك) من خلال معالجة صور الوجه بشكل مناسب. تكمن أهمية هذا المجال البحثي في أن وجه الإنسان يحمل خصائص عالمية، كالجنس والعمر والانفعالات؛ وبالتالي، يُمكن استخدام صور الوجه بسهولة في العديد من التطبيقات [13].

يعتمد تحليل صور الوجه على تقنية كشف الوجوه، والتي تتضمن ببساطة تحديد الوجوه داخل الصورة. بعبارة أخرى، يهدف هذا التحليل إلى تحديد منطقة اهتمام، تُسمى "المربع المحيط"، تحتوي على الوجه. تُستخدم هذه التقنية على نطاق واسع في العديد من التطبيقات، لا سيما تلك التي تُركز على التحقق من القرابة من صور الوجه (الأباء، الأبناء).

4.1 التحقق من القرابة

1.4.1 عموميات وتعريفات

درس العديد من العلماء قدرة المُقيِّمين البشريين على إدراك القرابة والتعرف عليها من خلال صور الوجوه البشرية. وقد صنّفوا علاقات القرابة تصنيفاتٍ مختلفة. وتشمل استنتاجات الدراسات التعريفات التالية:

- أ. القرابة (التشابه، الألفة) مصطلح يُستخدم للتعرف على العلاقات بين أفراد الأسرة [21].
- ب. القرابة هي درجة القرابة الجينية بين فردين من أفراد الأسرة [22].
- ج. القرابة هي حالة الارتباط بالولادة، أو النسب المشترك، أو الزواج، أو التبني. وتشمل القرابة تقييم العلاقات بين الأطفال وأبائهم بناءً على الخصائص الجسدية والتشابه [23].
- د. القرابة نظام يُؤسس العلاقات بين الأفراد والجماعات على غرار نموذج العلاقات البيولوجية بين الآباء والأبناء، وبين الأشقاء، وبين الزوجين [24].

2.4.1 بنية نظام التحقق من القرابة

يستخدم نظام التحقق من القرابة صور وجوه شخصين لتحديد ما إذا كانت تربطهما صلة قرابة. يتكون نظام التحقق من القرابة عمومًا من خمس خطوات:

- أ. التقاط الصور
- ب. كشف الوجوه أو المعالجة المسبقة
- ت. استخراج الميزات
- ج. تمثيل الميزات،
- د. التصنيف أو التحقق من القرابة.


أ. **التقاط الصور:** يمكن أن تكون عملية التقاط الصور ثابتة (باستخدام كاميرا أو ماسح ضوئي، إلخ)، مما ينتج عنه صورة، أو ديناميكية (باستخدام كاميرا أو كاميرا ويب)، مما ينتج عنه مقطع فيديو.

ب. **المعالجة المسبقة للوجوه:** تُخصص هذه الخطوة لكشف وتحديد مواقع الوجوه البشرية في الصورة المدخلة.

ج. استخلاص الميزات: تُعد خطوة استخلاص الميزات خطوة بالغة الأهمية؛ تم تصميمه لاستخراج الميزات من صور الوجه (الآباء والأطفال) باستخدام واصفات مختلفة لتحويل الصور إلى أشعة تمثيلية وإيجاد العلاقة بينها (الآباء والأطفال).

د. تمثيل الميزات: في هذه الخطوة، يجب دمج شعاعي الميزات (الفرعي، الأصل) في شعاع ميزات واحد باستخدام المعادلات المطبقة بين الشعاعين (بيئاً بيئاً). يتيح لنا هذا الوصول المباشر إلى المصنف (الخطوة التالية).

هـ. التصنيف: المرحلة الأخيرة من النظام هي مرحلة التصنيف، حيث يُتخذ قرار التحقق من القرابة باستخدام مصنفات تعتمد على أشعة تمثيلية مُدرّبة ومُخَبَّرَة للوصول إلى القرار النهائي. يوضح الشكل 2.1 مثلاً على البنية العامة لنظام التحقق من العلاقة باستخدام صور الوجه.



الشكل 2.1: البنية العامة لنظام التحقق من القرابة باستخدام صور الوجه.

3.4.1 تطبيقات نظام التحقق من القرابة

للتحقق من صلة القرابة آثار بالغة الأهمية على التطبيقات العملية في العديد من المجالات. نلخص فيما يلي مجالات التطبيق المحتملة:

- تنظيم ألبومات العائلة باستخدام صور وجوه أفراد العائلة أنفسهم.
- إنشاء شجرة عائلة تلقائياً من مجموعات الصور عند التعرف على العلاقات بين الأشخاص على مواقع التواصل الاجتماعي.
- البحث عن الأشخاص في قواعد البيانات العامة بناءً على أحد أفراد العائلة.

د. إثراء قواعد البيانات بالعائلات الجديدة المضافة أو المكتشفة عبر الإنترنت لتعزيز فعالية نظام التحقق من القرابة.

هـ. البحث عن المفقودين (الأطفال، كبار السن، ضحايا الحوادث، إلخ) بناءً على أحد أفراد العائلة.

و. تحديد المطلوبين (الهاربين، المجرمين، إلخ) بناءً على أحد أفراد العائلة.

5.1 قواعد بيانات صور الوجه

أنشئت قواعد بيانات اختبارات إثبات القرابة منذ عام 2010. في البداية، اعتمدت هذه القواعد على صور المشاهير التي التُقطت بشكل عفوي، ثم البحث عن صورة الأب أو الابن المقابل.

1.5.1 قاعدة بيانات (Cornell Kinship (2010)

تم تجميع قاعدة البيانات صور وجوه الآباء والأبناء من خلال بحث عبر الإنترنت عن صور لشخصيات عامة ومشاهير وآبائهم أو أبنائهم.

تشمل قاعدة البيانات هذه ما يقارب 50% من القوقازيين، و40% من الآسيويين، و7% من الأمريكيين من أصل أفريقي، و3% من أعراق أخرى؛ 40% من الصور الـ 150 هي لأزواج من الآباء والأبناء، و22% لأزواج من الآباء والبنات، و13% لأزواج من الأمهات والأبناء، و26% لأزواج من الأمهات والبنات.

وبالتالي، فهي تُظهر توزيعًا واسعًا لملامح الوجه يعتمد على العرق والجنس والعمر والمهنة، وما إلى ذلك [28]. يوضح الشكل 3.1 أمثلة (إيجابية وسلبية) لأزواج الصور لعلاقات القرابة المختلفة لقاعدة بيانات القرابة (Cornell Kinship) .

	أم-ابنة	أم-ابن	أب-ابنة	أب-ابن
إيجابية				
سلبية				

الشكل 3.1: أمثلة على صور من قاعدة بيانات "Cornell Kinship"

2.5.1 قاعدة بيانات (UB KinFace)

تنقسم بشكل أساسي إلى قسمين حسب العرق، وهما: الآسيويون وغير الآسيويين، ويتألف كل قسم من 100 مجموعة، و200 شخص، و300 صورة. عادةً ما توجد أربع علاقات قرابة، وهي: "الابن-الأب"، و"الابن-الأم"، و"الابنة-الأب"، و"الابنة-الأم".

يهيمن المشاهير الذكور، من الآسيويين وغير الآسيويين، سواء كانوا أبناءً أو آباءً، على قاعدة بيانات (UB KinFace). عند النظر في علاقات القرابة الأربع المحتملة، يصبح دور "الآباء" هو الدور المهيمن، بنسبة 46.5% و38.5% في جميع المجموعات في علاقتي "الابن-الأب" و"الابنة-الأب" على التوالي.

يعرض الشكل 4.1 أمثلة (إيجابية وسلبية) لأزواج الصور لعلاقات القرابة المختلفة لقاعدة بيانات "UB KinFace".

	أب-ابن	أب-ابنة	أم-ابن	أم-ابنة
إيجابية				
سلبية				

الشكل 4.1: أمثلة على صور من قاعدة بيانات "UB KinFace"

3.5.1 قاعدة بيانات (IIITD Kinship (2012))

تضم قاعدة بيانات القرابة (IIITD) 544 صورة لـ 272 زوجاً في بيئة غير مقيدة. تتكون قاعدة البيانات من صور لمشاهير تم تحميلها من الإنترنت. قسمت الصور إلى أربع مجموعات عرقية: أمريكيون من أصل أفريقي، أمريكيون، أمريكيون أصليون، وآسيويون (باستثناء الأمريكيين الأصليين). صُنفت علاقة القرابة إلى سبع علاقات: أخ-أخ، أخ-أخت، أب-ابنة، أب-ابن، أم-ابنة، أم-ابن، وأخت-أخت.

يعرض الشكل 5.1 أمثلة على أزواج الصور لعلاقات القرابة المختلفة لقاعدة بيانات IIITD "Kinship".

أم-ابنة	أم-ابن	أب-ابنة	أب-ابن
			
أخت-أخت	أخت-أخ	أخت-أخ	أخ-أخ
			

الشكل 5.1: أمثلة على صور من قاعدة بيانات "IITD Kinship"

4.5.1 قاعدة بيانات (Family101 (2013))

تحتوي قاعدة بيانات (Family101) على 101 شجرة عائلة مختلفة، تضم 206 عائلات، و607 أفراد، و14816 صورة. تتكون مجموعة البيانات النهائية من حوالي 72% من القوقازيين، و23% من الآسيويين، و5% من الأمريكيين من أصل أفريقي، لضمان توزيع واسع لملامح الوجه التي تختلف باختلاف العرق والجنس والعمر. يوجد في قاعدة البيانات هذه: 213 علاقة أب-ابن، و147 علاقة أب-ابنة، و184 علاقة أم-ابن، و148 علاقة أم-ابنة. يوضح الشكل 6.1 أمثلة (إيجابية وسلبية) لأزواج الصور لعلاقات القرابة المختلفة في قاعدة بيانات (Family101) [50]

	أم-ابنة	أم-ابن	أب-ابنة	أب-ابن
إيجابية				
سلبية				

الشكل 6.1: أمثلة على الصور من قاعدة بيانات "Family101"

5.5.1 قاعدتي بيانات (KinFaceW-I و KinFaceW-II (2014))

تتضمن قاعدتي بيانات (KinFaceW-I و KinFaceW-II) أربع علاقات قرابة : الأب والابن (F-S)، والأب والابنة (F-D)، والأم والابن (M-S)، والأم والابنة (M-D). تحتوي مجموعة بيانات (KinFaceW-I) على 156، و134، و116، و127 زوجًا من صور القرابة لهذه العلاقات الأربع على التوالي. أما مجموعة بيانات (KinFaceW-II)، فتحتوي كل علاقة على 250 زوجًا من صور القرابة.

ويمكن الفرق بين (KinFaceW-I و KinFaceW-II) في أن كل زوج من صور وجوه القرابة في (KinFaceW-I) تم الحصول عليه من صور مختلفة، بينما في (KinFaceW-II)، تم الحصول على كل زوج من نفس الصورة. يُبين الشكل 7.1 أمثلة (إيجابية وسلبية) لصور مُقترنة لعلاقات قرابة مختلفة في قاعدة بيانات (KinFaceW-I).

	أب-ابن	أب-ابنة	أم-ابن	أم-ابنة
إيجابية				
سلبية				

الشكل 7.1: أمثلة على الصور من قاعدة بيانات "KinFaceW-I"

يعرض الشكل 8.1 أمثلة (إيجابية وسلبية) لربط الصور لعلاقات القرابة المختلفة لقاعدة بيانات "KinFaceW-II".

	أب-ابن	أب-ابنة	أم-ابن	أم-ابنة
إيجابية				
سلبية				

الشكل 8.1: أمثلة على الصور من قاعدة بيانات "KinFaceW-II"

6.1 المقارنة بين قواعد بيانات التحقق من القرابة

يقدم الجدول 1.1 ملخصاً لقواعد بيانات التحقق من القرابة :

السنة	قاعدة البيانات	عدد الأزواج	عدد الصور	عدد العلاقات
2010	Cornell KinFace	150	300	4
2011	UB KinFace	200	600	4
2012	IIITD Kinship	272	544	7
2013	Family101	206	14 816	4
2014	KinFaceW-I	533	1066	4
	KinFaceW-II	1000	2000	4

الجدول 1.1: ملخص قواعد بيانات التحقق من القرابة

7.1 الخاتمة

يُعد تحليل صور الوجه من أهم المواضيع البحثية في معالجة الصور، وذلك لما يُمكن استخلاصه من معلومات قيّمة من صورة الوجه. على مدى العقود القليلة الماضية، لم يقتصر البحث في تحليل الوجه على المجالات التقليدية كالتحقق من الوجوه والتعرف على الأشخاص، بل توسّع ليشمل مجالاً بحثياً جديداً قائماً على تحليل صور الوجه، ألا وهو التحقق من صلة القرابة.

الفصل الثاني :

الشبكات العصبية الالتفافية (CNN)

2.1 مقدمة :

تُشغّل الشبكات العصبية الالتفافية بعضًا من أكثر قدرات الذكاء الاصطناعي إثارةً للإعجاب اليوم، بدءًا من التعرف على الوجوه في الهواتف الذكية وصولًا إلى الكشف عن الأورام في التصوير الطبي. في هذا الفصل، سنشرح ماهية الشبكات العصبية الالتفافية، وكيفية عملها، ومكوناتها الأساسية، واستراتيجيات مكافحة التجاوز، وأشهر أطر العمل لبنائها.


2.2 المكونات الرئيسية للشبكة العصبية الالتفافية

تتكون الشبكة العصبية الالتفافية من أربعة أجزاء رئيسية:

- طبقات الالتفاف (Convolutional layers)
- وحدة التنشيط الخطي المعدل (Rectified Linear Unit)
- طبقات التجميع (Pooling layers)
- طبقات متصلة بالكامل (Fully connected layers)

تساعد هذه الأجزاء الشبكات العصبية الالتفافية على محاكاة طريقة عمل الدماغ البشري للتعرف على الأنماط والخصائص في الصور.

سنقوم بتعريف كل مكون من هذه المكونات من خلال المثال التالي لتصنيف رقم مكتوب بخط اليد:



شكل 1.2 بنية الشبكات العصبية التلافيفية المطبقة على التعرف على الأرقام

1.2.2 طبقات الالتفاف


طبقات الالتفاف هي اللبنة الأساسية الأولى في الشبكة العصبية الالتفافية (CNN). وهي تطبيق دالة نافذة منزلة على مصفوفة من البكسلات التي تمثل صورة المدخل. تُسمى دالة النافذة المنزلقة المُطبقة على المصفوفة بالنواة أو المرشح،

في طبقة الالتفاف، تُطبق عدة مرشحات متساوية الحجم، ويُستخدم كل مرشح للتعرف على نمط مُحدد من خصائص الصورة، مثل انحناء الأرقام، أو الحواف، أو الشكل العام للأرقام، وغير ذلك.

ببساطة، في طبقة الالتفاف، نستخدم شبكات صغيرة (تُسمى مرشحات أو نوى) تتحرك فوق الصورة. تُشبه كل شبكة صغيرة عدسة مكبرة صغيرة تبحث عن أنماط مُحددة في الصورة، مثل الخطوط، أو المنحنيات، أو الأشكال. أثناء تحركها عبر الصورة، تُنشئ شبكة جديدة تُحدد أماكن وجود هذه الأنماط.

على سبيل المثال، قد يكون أحد المرشحات فعالاً في العثور على الخطوط المستقيمة، بينما قد يكون مرشح آخر فعالاً في العثور على المنحنيات، وهكذا. باستخدام عدة مرشحات مختلفة، تستطيع الشبكة العصبية الالتفافية (CNN) تكوين فكرة جيدة عن جميع الأنماط المختلفة التي تُشكل الصورة.

لننظر إلى هذه الصورة الرمادية بحجم 32×32 لرقم مكتوب بخط اليد. القيم في المصفوفة مُوضحة لأغراض التوضيح فقط.



شكل 2.2 توضيح للصورة المدخلة وتمثيلها بالبكسل

في (الشكل 3.2)، النواة المستخدمة في عملية الالتفاف هي مصفوفة بأبعاد 3×3 . تُحدد أوزان النواة أثناء عملية تدريب الشبكة العصبية. باستخدام هذه المصفوفة، يمكن إجراء عملية الالتفاف بتطبيق الضرب النقطي، وذلك باتباع الخطوات التالية:

أ- تطبيق مصفوفة النواة من الزاوية العلوية اليسرى إلى اليمين.

ب- إجراء عملية الضرب عنصراً بعنصر.


ت- جمع قيم نواتج الضرب.

ث- القيمة الناتجة تُطابق القيمة الأولى (الزاوية العلوية اليسرى) في المصفوفة الملتفة.

ج- تحريك النواة لأسفل بما يتناسب مع حجم النافذة المنزلقة.

ح- تكرار الخطوات من أ إلى ج حتى يتم تغطية مصفوفة الصورة بالكامل.

يعتمد بُعد المصفوفة الملتفة على حجم النافذة المنزلقة. فكلما زاد حجم النافذة المنزلقة، قلّ البُعد.



شكل 3.2 تطبيق مهمة الالتفاف باستخدام خطوة مقدارها 1 مع نواة 3×3

يُطلق على النواة اسم "كاشف الميزات" أيضاً، نظراً لإمكانية ضبط الأوزان بدقة لاكتشاف ميزات محددة في الصورة المدخلة، على سبيل المثال:

- ✓ يمكن استخدام نواة حساب متوسط البكسلات المتجاورة لتشويش الصورة المدخلة.
- ✓ تُستخدم نواة طرح البكسلات المتجاورة لكشف الحواف.

ملاحظة: كلما زاد عدد طبقات الالتفاف في الشبكة، تحسّنت قدرة الطبقة على اكتشاف الميزات الأكثر تجريداً.

2.2.2 دالة التنشيط


تُطبّق دالة التنشيط ReLU بعد كل عملية التفاف. تُساعد هذه الدالة الشبكة على تعلّم العلاقات غير الخطية بين الميزات في الصورة، مما يجعلها أكثر قوة في تحديد الأنماط المختلفة. كما تُساعد في التخفيف من مشكلة تلاشي التدرج.

3.2.2 طبقة التجميع

تهدف طبقة التجميع إلى استخلاص أهم الميزات من المصفوفة الملتفة. ويتم ذلك بتطبيق بعض عمليات التجميع التي تُقلّل من أبعاد خريطة الميزات (المصفوفة الملتفة)، وبالتالي تُقلّل من الذاكرة المستخدمة أثناء تدريب الشبكة. يُعد التجميع مهماً أيضاً للتخفيف من مشكلة التجاوز. من أكثر دوال التجميع شيوعاً:

- ✓ التجميع الأقصى، وهو القيمة القصوى لخريطة الميزات.
- ✓ تجميع المجموع، وهو مجموع جميع قيم خريطة الميزات.
- ✓ التجميع المتوسط، وهو متوسط جميع القيم.

فيما يلي توضيح لمثال عن التجميع الأقصى:



شكل 4.2 تطبيق التجميع الأقصى بخطوة 2 باستخدام مرشح 2 x 2

كما يقل بُعد خريطة الميزات مع تطبيق دالة التجميع ، تقوم طبقة التجميع الأخيرة بتسطيح خريطة الميزات لتسهيل معالجتها بواسطة الطبقة المتصلة بالكامل.

4.2.2 الطبقات المتصلة بالكامل

تقع هذه الطبقات في الطبقة الأخيرة من الشبكة العصبية الالتفافية، وتتوافق مدخلاتها مع المصفوفة أحادية البعد المُسطّحة الناتجة عن طبقة التجميع الأخيرة. تُطبّق عليها دوال التنشيط ReLU لضمان اللاخطية.

أخيرًا، تُستخدم طبقة تنبؤ softmax لتوليد قيم احتمالية لكل تصنيف من تصنيفات الإخراج المحتملة، ويتم التنبؤ بالتصنيف النهائي بناءً على أعلى قيمة احتمالية.

3.2 التدريب الزائد والتنظيم في الشبكات العصبية الالتفافية

يُعدّ التدريب الزائد تحديًا شائعًا في نماذج التعلّم الآلي ومشاريع التعلّم العميق باستخدام الشبكات العصبية الالتفافية. يحدث ذلك عندما يتعلّم النموذج بيانات التدريب بشكل مفرط ("التعلّم عن ظهر قلب")، بما في ذلك التشويش والقيم الشاذة. يؤدي هذا النوع من التعلّم إلى نموذج يحقق أداءً جيدًا على بيانات التدريب، ولكنه يعاني من ضعف الأداء على البيانات الجديدة غير المرئية.

يُمكن ملاحظة ذلك عندما يحقق النموذج دقة أعلى بكثير على بيانات التدريب مقارنةً ببيانات التحقق أو الاختبار، ويوضح الرسم البياني أدناه ذلك.



شكل 5.2 سبع استراتيجيات للحد من فرط التخصيص في الشبكات العصبية الالتفافية

- أ- **التسرب:** يتضمن هذا الأسلوب حذف بعض الخلايا العصبية عشوائيًا أثناء عملية التدريب، مما يجبر الخلايا المتبقية على تعلم خصائص جديدة من بيانات الإدخال.
- ب- **التطبيع الدفعي:** يتم تقليل فرط التخصيص إلى حد ما عن طريق تطبيع طبقة الإدخال من خلال ضبط وتوسيع نطاق التنشيطات. يُستخدم هذا الأسلوب أيضًا لتسريع عملية التدريب وتحسين استقرارها.
- ت- **طبقات التجميع:** يمكن استخدامها لتقليل الأبعاد المكانية لصورة الإدخال لتزويد النموذج بنموذج تمثيل مجرد، وبالتالي تقليل احتمالية فرط التخصيص.
- ث- **الإيقاف المبكر:** يتضمن هذا الأسلوب مراقبة أداء النموذج باستمرار على بيانات التحقق أثناء عملية التدريب، وإيقاف التدريب عندما لا يتحسن خطأ التحقق.

- ج- **حقن الضجيج**: تتضمن هذه العملية إضافة ضوضاء إلى مدخلات أو مخرجات الطبقات المخفية أثناء التدريب لجعل النموذج أكثر قوة ومنعه من التعميم الضعيف.
- ح- **التنظيم L1 و L2**: يُستخدم كل من L1 و L2 لإضافة عقوبة إلى دالة الخسارة بناءً على حجم الأوزان. وبشكل أدق، يُشجع L1 على أن تكون الأوزان متفرقة، مما يؤدي إلى اختيار أفضل للميزات. من ناحية أخرى، يُشجع L2 (المعروف أيضاً باسم اضمحلال الوزن) على أن تكون الأوزان صغيرة، مما يمنعها من التأثير بشكل كبير على التنبؤات.
- خ- **تضخيم البيانات**: هي عملية زيادة حجم وتنوع مجموعة بيانات التدريب بشكل مصطنع من خلال تطبيق تحويلات عشوائية مثل التدوير، وتغيير الحجم، والقلب، أو القص على الصور المدخلة.

4.2 التطبيقات العملية للشبكات العصبية الالتفافية:

أحدثت الشبكات العصبية الالتفافية ثورة في مجال رؤية الحاسوب، مما أدى إلى تطورات كبيرة في العديد من التطبيقات العملية. فيما يلي بعض الأمثلة على كيفية تطبيقها.



تصنيف الصور



اكتشاف الأجسام



التعرف على الوجوه

شكل 6.2 بعض التطبيقات العملية للشبكات العصبية الالتفافية

- ✓ **تصنيف الصور:** تُستخدم الشبكات العصبية الالتفافية لتصنيف الصور، حيث تُصنف الصور ضمن فئات محددة مسبقًا. ومن تطبيقات هذا النوع من الشبكات تنظيم الصور تلقائيًا على منصات التواصل الاجتماعي.
- ✓ **اكتشاف الأجسام:** تتميز الشبكات العصبية الالتفافية بقدرتها على تحديد مواقع عدة أجسام داخل الصورة. وتُعد هذه الميزة بالغة الأهمية في العديد من تطبيقات مسح رفوف المتاجر لتحديد المنتجات غير المتوفرة.
- ✓ **التعرف على الوجوه:** يُعد هذا أيضًا أحد المجالات الرئيسية لتطبيقات الشبكات العصبية الالتفافية. فعلى سبيل المثال، يمكن دمج هذه التقنية في أنظمة الأمان للتحكم الفعال في الوصول للأشخاص بناءً على ملامح الوجه.

5.2 أشهر بنى الشبكات العصبية الالتفافية

- على مر السنين، طور الباحثون بنى شبكات عصبية التفافية أكثر قوة. وفيما يلي بعض من أبرزها:
- ✓ **LeNet-5 (1998):** إحدى أوائل الشبكات العصبية الالتفافية، صُممت للتعرف على الأرقام المكتوبة بخط اليد.
- ✓ **AlexNet (2012):** ساهم في انتشار الشبكات العصبية التلافيفية العميقة باستخدام التدريب على وحدات معالجة الرسومات.
- ✓ **VGGNet(2014):** أثبت أن الشبكات الأعمق ذات المرشحات الصغيرة بحجم 3x3 تُحسّن الدقة.
- ✓ **ResNet (2015):** قدّم وصلات التخطي، مما مكّن من تدريب الشبكات التي تحتوي على أكثر من 100 طبقة.
- ✓ **EfficientNet (2019):** استخدم التحجيم المركب لتحقيق التوازن بين عمق الشبكة وعرضها ودقتها.
- ✓ **ConvNeXt (2022):** تصميم مُحدّث للشبكات العصبية التلافيفية يُنافس مُحولات الرؤية.

على الرغم من بروز مُحولات الرؤية كبديل قوية منذ عام 2020، لا تزال الشبكات العصبية التلافيفية شائعة الاستخدام نظرًا لكفاءتها، وانخفاض متطلبات البيانات.

6.2 الخلاصة

قدمنا في هذا الفصل نظرة شاملة على مفهوم الشبكات العصبية الالتفافية (CNN) في التعلم العميق، ودورها المحوري في مهام التعرف على الصور وتصنيفها.

تعتبر مشكلة التجاوز (Overfitting) تحديًا كبيرًا لقدرة الشبكات العصبية الالتفافية على التعميم. وللتخفيف من هذه المشكلة، تم استعراض مجموعة متنوعة من الاستراتيجيات الفعّالة للحد من التجاوز وتحسين الأداء العام للشبكات العصبية الالتفافية.

الفصل الثالث :

النظام القائم على الميزات والمبني على الشبكات العصبية التلافيفية للتحقق من القرابة

1.3 مقدمة

في هذه الفصل، نعرض منهجاً لتحديد صلة القرابة مفصلاً كما يلي: تبدأ العملية بالحصول على أزواج من صور الوجه (الأب/الإبن). بعد ذلك، تُستخرج السمات العميقة باستخدام نموذج لشبكة عصبية تلافيفية (CNN)، والذي يلتقط الخصائص المميزة لكل زوج من الوجوه. أخيراً، يُستخدم مُصنّف آلة المتجهات الداعمة (SVM) لاتخاذ القرار النهائي بشأن صلة القرابة (قريب أو غير قريب). تم تحليل وتقييم هذا النظام على خمس مجموعات بيانات: Cornell KinFace ، KinFace W-II ، KinFace W-I ، Family 101 و UB KinFace .

2.3 بنية النظام المبني على الشبكات العصبية التلافيفية

يشير التحقق من القرابة إلى عملية تحليل صور وجهي شخصين لتحديد ما إذا كانت تربطهما صلة قرابة. تتضمن المنهجية المقترحة خمس مراحل رئيسية:

(أ) - المعالجة المسبقة للوجه،


(ب) - استخراج الميزات القائمة على الشبكات العصبية التلافيفية.

(ج) - تمثيل وتطبيع الميزات المزدوجة،

(د) - اختيار الميزات،

(هـ) - التحقق من القرابة.

يوضح الشكل "1.3 بنية هذا النظام:



الشكل 1.3: التصميم العام للنظام

1.2.3 المعالجة المسبقة للوجه

يتم تحديد معالم الوجه خلال مرحلة المعالجة المسبقة [9]. وباستخدام نفس المعايير المذكورة في [10، 11]، قمنا بمحاذاة وضعية الوجه بناءً على هذه المعالم وإحداثيات مركزي العينين. يوضح الشكل 2.3 خطوات هذه المرحلة.



الشكل 2.3: المعالجة المسبقة للوجه

2.2.3 استخلاص الميزات

يُعد استخلاص الميزات خطوة أساسية. فإننا نستخدم الشبكات العصبية الالتفافية (CNNs)، وتحديدًا بنية ResNet، لاستخلاص ميزات الوجه المميزة.


في السنوات القليلة الماضية، أظهرت التطورات في الشبكات العصبية والتعلم العميق أساليب فعّالة للغاية لمعالجة مختلف التحديات في تحليل الصور، يستلهم التعلم العميق مبادئه من كيفية حدوث التعلم في الدماغ البشري. تعود أصوله إلى الشبكات العصبية التي طُوّرت في أربعينيات القرن العشرين؛ إلا أن التعلم العميق اكتسب شعبية واسعة النطاق حوالي عام 2006 [12، 13]. ومن بين التصميمات المختلفة لنماذج التعلم العميق، حظيت الشبكات العصبية الالتفافية (CNNs) بمكانة بارزة.



الشكل 3.3: وصف نموذج الشبكة العصبية التلافيفية

يتكون هيكل الشبكة العصبية الالتفافية (CNN) من طبقة إخراج، وطبقة إدخال، وعدة طبقات وسيطة. تتضمن هذه الطبقات عادةً عمليات الالتفاف، والتجميع، والتطبيع، والربط الكامل. وقد أظهرت العديد من بنى الشبكات العصبية الالتفافية أداءً استثنائيًا في مختلف مهام التعلم الآلي. في هذا العمل، تم

استخدام ResNet كواصف لميزات الوجه [15]. يتم توليد الميزات العميقة من الطبقة المتصلة بالكامل "f1000" في بنية ResNet، مما ينتج عنه 1000 قيمة مميزة. يوضح الشكل 4.3 نماذج ResNet : ResNet-50، ResNet-18، و ResNet-101 (شبكات عصبية التلافيفية مدربة مسبقاً)، بالإضافة إلى مكوناتها الهيكلية وعدد الطبقات المكسدة المشار إليه بين قوسين. يتم إجراء عملية تقليل حجم العينة في الطبقات conv3، conv4، و conv5 باستخدام خطوة مقدارها 2. على الرغم من أن البنية العامة لنماذج ResNet متسقة، إلا أنها تختلف في عدد طبقات الالتفاف 3×3. تم اختيار طبقة f1000 لأن الطبقات الأعمق تلتقط ميزات أكثر تجريداً وثراءً دلاليًا من الطبقات السابقة.



الشكل 4.3: البنية العامة لشبكة CNN (ResNet).

3.2.3 توحيد وتمثيل خصائص الأزواج

بعد استخراج الخصائص، يتم توحيد الخصائص المقابلة لكل زوج من الأب والابن باستخدام الصيغة الموضحة في المعادلة (1.3):

$$F_{norm} = \frac{F}{\sqrt{\sum_{j=1}^N F^2(j)}} \quad (1.3)$$

حيث: F_{Norm} هو متجه الخصائص المعياري، F هو متجه الخصائص، و F_j هو عنصر متجه ذو دليل j .

بعد ذلك، يتم دمج متجهي الميزات (الأب و الابن) في متجه ميزات واحد باستخدام الصيغة المقترحة في المعادلة (2. 3):

$$F_{Proposed} = \frac{F_{child} + F_{parent}}{|F_{child} - F_{parent}|} \quad (2. 3)$$

حيث أن متجه الميزات النهائي هو $F_{proposed}$ ، و F_{parent} و F_{child} هي متجهات الميزات الخاصة بالوالد و الابن على التوالي.

4.2.3 اختيار الميزات

نقترح اختيار الميزات باستخدام ميزات الترتيب (TTest) للتعامل مع العدد الكبير من الخصائص المستخلصة من تمثيلات الوجه المختلفة. يُستخدم (TTest) كطريقة لاختيار الميزات، حيث يعتمد ترجيحه لعينتين للقيم المطلقة باستخدام تقدير التباين المُجمَع [16]. يُحسب الوزن وفقاً للمعادلة (3.3):

$$W_{ttest}(i) = \left| \frac{(m_k - m_n)}{\sqrt{\frac{\sigma_k^2}{N_k} + \frac{\sigma_n^2}{N_n}}} \right| \quad (3.3)$$

حيث N_x هو عدد العينات في فئة القرابة ($k \rightarrow$ قريب / $n \rightarrow$ غير قريب)، و W_i هو وزن الخاصية i ، m_x و σ_x^2 هو المتوسط والتباين على الترتيب لفئة القرابة في الخاصية المستهدفة. يتم ترتيب الخصائص حسب الوزن.

5.2.3 مصنفات الميزات

تمثل هذه الخطوة المرحلة الأخيرة ، حيث يحدد النظام ما إذا كانت المخرجات تُشير إلى صلة قرابة أو عدم صلة قرابة. تم اعتماد استراتيجية التحقق المتقاطع الخماسي لتقييم فعالية النموذج. تضمنت عملية التقييم مرحلتين أساسيتين. في المرحلة الأولى، تم تدريب نموذج التصنيف على 80% من أزواج الصور المخصصة للتدريب، بينما تم تخصيص الـ 20% المتبقية للتحقق. أُجريت هذه التجربة خمس مرات، باستخدام مجموعة فرعية مختلفة من أزواج التحقق في كل مرة، وتم حساب الدقة الإجمالية كمتوسط الأداء عبر جميع المراحل.

6.2.3 مصنفات آلة المتجهات الداعمة (SVM)

يمكن التعبير عن عملية التحقق من صلة القرابة كمهمة تصنيف ثنائية، حيث تُستخدم آلة المتجهات الداعمة (SVM) كنموذج لاتخاذ القرار. يتمثل المفهوم الأساسي لآلة المتجهات الداعمة في تحديد مستوى فاصل مثالي يوفر أكبر هامش ممكن بين تمثيلات ميزات صلة القرابة وعدم صلة القرابة. في هذا العمل، تم دمج نواة غاوس، والتي يُشار إليها غالبًا بنواة دالة الأساس الشعاعي (RBF)، في إطار عمل آلة المتجهات الداعمة (SVM) لمعالجة العلاقات غير الخطية في فضاء الميزات بكفاءة [17].

7.2.3 تدريب الشبكة العصبية التلافيفية (CNN) للانحدار

تُبين هذه الدراسة التجريبية كيفية تطبيق نموذج الانحدار باستخدام الشبكة العصبية التلافيفية (CNN) لتحليل بيانات الصور وتصنيف أزواج الصور. صُممت بنية الشبكة العصبية التلافيفية من خلال بناء طبقات متعددة بشكل متسلسل، وإضافة طبقة انحدار في نهاية الشبكة لإجراء تنبؤ مستمر بالقيم ودعم عملية التصنيف.

تُحدد الطبقة الأولى من الشبكة حجم ونوع بيانات الإدخال، مما يضمن تطابق أبعاد صور الإدخال مع أبعاد صور التدريب. تُشكل الطبقات الوسطى جوهر بنية الشبكة، حيث تُجرى معظم العمليات الحسابية وتعلم الميزات. تُحدد الطبقات الأخيرة بنية ونوع بيانات الإخراج. في حالة مهام الانحدار، تُوضع طبقة متصلة بالكامل مباشرة قبل طبقة الانحدار في نهاية الشبكة. تُدمج جميع الطبقات بشكل متسلسل في مصفوفة طبقات لتشكيل النموذج الكامل.

لأغراض التدريب، تم ضبط الشبكة للعمل لمدة 30 دورة تدريبية، بدءًا بمعدل تعلم قدره 0.001، ثم تم تخفيضه بعد 20 دورة تدريبية لتمكين ضبط دقيق أكثر. خلال عملية التدريب، يقوم برنامج المحاكاة بتدريب النموذج باستخدام مجموعة بيانات التدريب، مع تقييم دقته دوريًا على مجموعة بيانات التحقق. تُستخدم بيانات التحقق حصريًا لمراقبة الأداء، ولا تُستخدم في تحديث أوزان الشبكة. تم تفعيل مخطط تقدم التدريب لعرض عملية تعلم النموذج، بينما تم تعطيل إخراج نافذة الأوامر لتبسيط التنفيذ.

يتم اختبار أداء الشبكة بتقييم دقتها على مجموعة بيانات الاختبار، وفي هذه الحالة، تم ضبط عتبة التنبؤ على 0.5، ثم يتم تحديد الدقة بحساب النسبة المئوية لقيم التنبؤات التي تساوي أو تزيد عن هذه العتبة [18].

3.3 التجارب والإعدادات

1.3.3 إعدادات قواعد البيانات

استُخدمت خمس قواعد بيانات مرجعية مفتوحة المصدر - Cornell KinFace، وFamily 101، وUB KinFace، وKinFaceW-I، وKinFaceW-II - لتقييم أداء هذا النظام للتحقق من القرابة.

2.3.3 النتائج التجريبية

استُخرجت ملامح الوجه في هذه الدراسة باستخدام نماذج ResNet مُدرّبة مسبقًا. نتائج هذه التجارب على قواعد البيانات الخمس موضحة في الجدول 1.3.

قاعدة البيانات	أب- ابن	أب- ابنة	أم- ابن	أم- ابنة	القيمة المتوسطة
KinFace W-I	95.9	98.72	98.03	98.71	97.84
KinFace W-II	93.80	98.20	96.80	97.60	96.60
Cornell KinFace	99.63	98.72	98.03	98.71	98.77
Family 101	99.00	98.60	96.20	99.00	98.20
UB KinFace	99.20	98.20	96.80	97.60	97.95

الجدول 1.3: دقة النتائج (%) لقواعد البيانات المستخدمة

يُلاحظ أن أسهل العلاقات تحديدًا هي تلك التي تربط أفرادًا من الجنس نفسه، مثل علاقة الأب والابن التي يسهل تصنيفها مقارنةً بعلاقة الأب والابنة، أو علاقة الأم والابنة التي يسهل تصنيفها مقارنةً بعلاقة الأم والابن .

3.3.3 المقارنة مع المناهج الأخرى

يُظهر تقييم الأداء على قواعد بيانات مرجعية متعددة متاحة للعموم أن المنهج المدروس في هذه المذكرة، يتفوق على الطرق الأخرى. يوضح (الجدول 2.3) نتائج طريقة التحقق من القرابة المدروسة في هذه المذكرة إلى جانب العديد من المناهج الأخرى. حقق النهج المقترح في تجربتنا دقة بلغت 96.60%، و97.84%، و97.95%، و98.20%، و98.77% على قواعد بيانات KinFaceW- ، KinFaceW-II ، Cornell KinFace ، Family 101 ، UB KinFace ، I ، و KinFaceW-III .

قواعد البيانات					الطريقة	السنة
KinFace W-I	KinFace W- II	Family 101	UB KinFace	Cornell KinFace		
85.70%	75.57%	-	75.50%	81.40%	KML [22]	2019
76.89%	79.76%	82.07%	83.68%	87.16%	ResNet [23]	
80.12%	81.69%	78.16%	82.89%	84.74%	Fusion [24]	
89.9%	79.6%	-	-	-	VGG-Face [25]	2020
73.5%	68.6%	-	-	-	HOG [26]	2021
79.51%	81.27%	85.74%	86.32%	89.36%	WLD-SVM [8]	2022
90.65%	79.54%	-	-	-	Fusion [27]	2023
-	-	-	-	89.61%	Hist-2D-DWT [28]	2024
97.84%	98.71%	98.2%	97.95%	98.77%	النظام المدروس في هذه المذكرة	2026

الجدول 2.3: مقارنات بين النظام المدروس في هذه المذكرة والأساليب الأخرى الموجودة.

5.3 الخلاصة

في هذا الفصل، عرضنا التحقق من صلة القرابة باستخدام نماذج التعلم العميق (ResNet) لاستخلاص الميزات. استُخدمنا مُصنّف (SVM) مبدئياً لتدريب النموذج والتنبؤ بأزواج صور القرابة. تُظهر النتائج التجريبية أن هذا النهج يُحسّن الأداء ويحقق دقة أعلى، متفوقاً على الطرق السابقة في التحقق من صلة القرابة.

الخلاصة العامة

في هذه المذكرة، عرضنا منهجاً حديثاً لتحديد صلة القرابة ، مُقسّماً إلى خمس مراحل: تبدأ العملية بالحصول على أزواج من صور الوجه (الأب/الابن). بعد ذلك، تُستخرج السمات العميقة باستخدام نموذج شبكة عصبية تلافيفية (CNN)، والذي يلتقط الخصائص المميزة لكل زوج من الوجوه. ثم تُمثّل هذه الخصائص من خلال مخطط تمثيل معين، ويُحسّن لاحقاً من خلال خطوة اختيار الخصائص للاحتفاظ بالخصائص الأكثر تمييزاً. أخيراً، يُستخدم مُصنّف آلة المتجهات الداعمة (SVM) لاتخاذ القرار النهائي بشأن صلة القرابة (قريب أو غير قريب).

تم تحليل وتقييم العمل على خمس مجموعات بيانات متاحة للعموم: KinFace، و KinFace W-I، و KinFace W-II، و Cornell، و Family 101، و UB KinFace. تُظهر النتائج التجريبية أن هذا المنهج يُحسّن الأداء ويحقق دقة أعلى، متفوقاً على الطرق السابقة في التحقق من صلة القرابة.

من خلال الجمع التآزري بين استخراج الميزات العميقة وأساليب التصنيف القوية، يضع إطار عملنا أساساً جديداً قوياً ويفتح آفاقاً واعدة للبحوث المستقبلية في مجال العدالة والكفاءة واستكشاف نطاق أوسع من العلاقات الأسرية.

المراجع

- [1] R. Fang, K D. Tang, N. Snavely, T. Chen , “Towards computational models of kinship verification”, In *Proceedings of the International Conference on Image Processing*, ICIP 2010, Hong Kong, China, pp. 1577-1580.
- [2] S. Xia, M. Shao, and Y. Fu, “Kinship verification through transfer learning,” in *IJCAI, 2011*, pp. 2539–2544.
- [3] H. Yan, J. Lu, and X. Zhou, “Prototype-based discriminative feature learning for kinship verification,” *IEEE Transactions on cybernetics*, vol. 45, no. 11, pp. 2535–2545, 2015.
- [4] X. Zhou, Y. Shang, H. Yan, and G. Guo, “Ensemble similarity learning for kinship verification from facial images in the wild,” *Information Fusion*, vol. 32, pp. 40–48, 2016.
- [5] M. Wang, Z. Li, X. Shu, J. Tang et al., “Deep kinship verification,” In *Multimedia Signal Processing (MMSP), 2015 IEEE 17th International Workshop on. IEEE*, 2015, pp.1–6.
- [6] A. Chergui, S. Ouchtati, J. Sequeira, SE. Bekhouche, and H.Telli, “Robust kinship verification using local descriptors”, In *Proceeding of Third International Conference On Advanced Technologies And Electrical Engineering ICTAEE18*, Dec 2018.
- [7] Chergui, A., Ouchtati, S., Sequeira, J., Bekhouche, S.E., Bougourzi, F., Telli, H. (2019). Deep features for kinship verification from facial images. In *2019 International Conference on Advanced Systems and Emergent Technologies (IC_ASET)*, pp. 64-67. <https://doi.org/10.1109/ASET.2019.8871011>
- [8] NH. Bouakal, M. Hettiri, A. Chergui, A. Ouafi, A. Benlamoudi and SE. Bekhouche, “Kinship Verification System based on the Color Spaces Analysis”, *7th International Conference on Image and Signal Processing and their Applications (ISPA)*, Mostaganem, Algeria, 2022, pp.1-6, <https://doi:10.1109/ISPA54004.2022.9786280>
- [9] V. Kazemi and J. Sullivan, “One millisecond face alignment with an ensemble of regression trees,” In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 1867–1874.
- [10] S. E. Bekhouche, A. Ouafi, F. Dornaika, A. Taleb-Ahmed, and A. Hadid, “Pyramid multi-level features for facial demographic estimation,” *Expert Systems with Applications*, vol. 80, pp. 297–310, 2017.
- [11] S. E. Bekhouche, “Facial soft biometrics: Extracting demographic traits,” *Ph.D. dissertation, Faculté des sciences et technologies*, 2017.
- [12] G. E. Hinton, “To recognize shapes, first learn to generate images,” *Progress in brain research*, vol. 165, pp. 535–547, 2007.
- [13] Y. Bengio, Y. LeCun et al., “Scaling learning algorithms towards ai, larg,” *Scale Kernel Mach*, vol. 34, no. 5, 2007.
- [14] Y. LeCun et al., “Lenet-5, convolutional neural networks,” URL: <http://yann.lecun.com/exdb/lenet> 2015.
- [15] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [16] R O.Duda, P E.Hart, and D G. Stork., “Pattern classification”, *second edition john wiley & sons*. New York, 58:16, 2001.
- [17] M. Arumugam,, P. Thangaraj, P. Sivakumar,, P. Pradeepkumar, Implementation of two class classifiers for hybrid intrusion detection. In *2010 International Conference on Communication and Computational Intelligence (INCOCCI)*, ISBN: 978-81- 8371-369-6, pp. 486-490.
- [18] The MathWorks, Inc. Train Convolutional Neural Network for Regression MATLAB documentation, 2023.
- [19] M.Shao, S.Xia, and F.Yun , “Genealogical face recognition based on UB kinface database”. In *Computer Vision and Pattern Recognition Workshops (CVPRW), 2011 IEEE Computer Society Conference*, pp.60–65. IEEE, 2011.

- [20] R. Fang, A C. Gallagher, T. Chen, and A. Loui, “Kinship classification by modeling facial feature heredity”, In *Image Processing (ICIP), 20th IEEE International Conference on*, pp.2983–2987, 2013.
- [21] J. Lu, X. Zhou, YP. Tan, Y. Shang, and J. Zhou, “Neighborhood repulsed metric learning for kinship verification”, *IEEE Transactions on Wireless Communications*, vol. 36, no. 2, pp. 331-345, 2014.
- [22] K. Gurney, “An introduction to neural networks”, *University College London*, UK, 2004.
- [23] A. Chergui, S. Ouchtati, S. Mavromatis, S E. Bekhouche, and J. Sequeira, “Investigating deep cnns models applied in kinship verification through facial images”, In *5th International Conference on Frontiers of Signal Processing (ICFSP)*, pp. 82–87, 2019.
- [24] A. Chergui, S. Ouchtati, S. Mavromatis, S E Bekhouche, J. Sequeira, and H. Zerrari, “Kinship verification using mixed descriptors and multi block face representation. ”, In *International Conference on Networking and Advanced Systems (ICNAS)*, pp.1–6, 2019.
- [25] L. Zhang, Q. Duan., D. Zhang., W. Jia, and X. Wang., “ Advkin: adversarial convolutional network for kinship verification”, *IEEE Transactions on Cybernetics*, vol.51, no.12,pp. 883–5896.
- [26] N. Nermeen , A. Abd EL-Ghani, Fatma, El-Sappagh, Shaker , Kwak, Kyung , Elmogy and Mohammed., “Kinship verification and recognition based on handcrafted and deep learning feature-based techniques”, *PeerJ Computer Science*. 7. 10.7717/peerj-cs.735.
- [27] N. Nader; F. EL-Gamal, and M.Elmogy, “Enhanced kinship verification analysis based on color and texture handcrafted techniques”, *The Visual Computer* (2024) 40:2325–2346 <https://doi.org/10.1007/s00371-023-02919-6>
- [28] B. El Ouanas; M. Khammari , G. A Abderraouf, B M R Aymene ,and Ch Ammar, “Wavelet Transform-Based Feature Extraction for Face Kinship Verification”, v1. <https://doi.org/10.20944/preprints202411.0264>

Sites d’Internet

<https://www.datacamp.com/tutorial/introduction-to-convolutional-neural-networks-cnns>

https://fr.wikipedia.org/wiki/R%C3%A9seau_neuronal_convolutif

<https://www.nexa.fr/blog/convolutional-neural-network>

<https://www.ibm.com/think/topics/convolutional-neural-networks>

<https://www.data-bird.co/blog/cnn>

<https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks/>

<https://www.geeksforgeeks.org/machine-learning/introduction-convolution-neural-network/>

<https://fr.mathworks.com/discovery/convolutional-neural-network.html>

<https://liora.io/convolutional-neural-network>