

Development of a Model to Enhance the Security of Signature Verification Systems Using Deep Learning Algorithms (MobileNetV2/LSTM)

Ahmed A.Aluadheeri*

Department of Computer science ,Libyan Academy for Postgraduate Studies

*Email (for reference researcher): master.alhodiry@gmail.com

تطوير نموذج لتحسين أمن أنظمة التوقيع الإلكتروني باستخدام خوارزميات التعلم العميق MobileNetV2 /LSTM

أحمد عبدالقادر الحضييري

قسم الحاسوب، الأكاديمية الليبية للدراسات العليا فرع المنطقة الجنوبية

Received: 30-05-2026; Accepted: 28-07-2026; Published: 05-08-2026

Abstract:

The aim of this paper was to develop a hybrid model to improve the efficiency and reliability of Offline Arabic Electronic Signature Verification by integrating MobileNetV2 for spatial feature extraction with an LSTM network for analyzing the temporal characteristics of signatures. The study seeks to determine the effectiveness of the proposed model in improving the accuracy of Arabic signature verification and its ability to reduce errors compared with traditional models.

The model was trained and evaluated on an Arabic signature dataset. The experimental results showed that the proposed MobileNetV2-LSTM-Attention-Security model achieved high performance in Arabic signature verification, with an Accuracy of 98.03%, Precision of 98.38%, Recall of 97.66%, F1-Score of 98.02%, and AUC of 0.9925. It also achieved low error rates, with FAR = 1.61%, FRR = 2.34%, and EER $\approx$ 1.90%, demonstrating its strong ability to distinguish between genuine and forged signatures.

Keywords: Electronic Signature, MobileNetV2, LSTM, Deep Learning, Signature Verification, Offline Signature..

المخلص:

هدفت هذه الورقة إلى تطوير نموذج هجين لتحسين كفاءة وموثوقية التحقق من التوقيعات الإلكترونية العربية غير المتصلة (Offline Electronic Signature Verification)، من خلال دمج خوارزمية MobileNetV2 لاستخلاص الخصائص المكانية، مع شبكة LSTM لتحليل الخصائص الزمنية للتوقيع. وتسعى الدراسة إلى الإجابة عن مدى فاعلية النموذج المقترح في تحسين دقة التحقق من التوقيعات العربية، ومدى قدرته على تقليل الأخطاء مقارنةً بالنماذج التقليدية. وقد تم تدريب النموذج واختباره على مجموعة من بيانات التوقيعات العربية، أظهرت النتائج التجريبية أن النموذج المقترح MobileNetV2-LSTM-Attention-Security حقق أداءً مرتفعاً في التحقق من التوقيعات العربية، حيث بلغت AUC = 98.03%، Accuracy = 98.38%، Precision = 97.66%، و Recall = 98.02%، F1-Score = 98.02%، مع AUC = 0.9925. كما حقق معدلات خطأ منخفضة بلغت FAR = 1.61% و FRR = 2.34% و EER $\approx$ 1.90%، مما يدل على قدرة جيدة على التمييز بين التوقيعات الأصلية والمزورة.

الكلمات المفتاحية: التوقيع الإلكتروني، MobileNetV2، LSTM، التعلم العميق، التحقق من التوقيع، التوقيع غير المتصل.

1- المقدمة

شهد العصر الرقمي متسارعا في طبيعة المعاملات اليومية، حيث أصبحت التفاعلات الإلكترونية جزءاً أساسياً من المراسلات والمعاملات المالية والقانونية الحساسة. وفي هذا السياق، تبرز أهمية أنظمة التوقيع الإلكتروني بوصفها إحدى الوسائل المستخدمة للتحقق من هوية الموقع وإثبات موافقته على محتوى المستند الإلكتروني، بما يساهم في تعزيز أصالة المعاملات الرقمية وسلامتها. ومع التوسع في استخدام التوقيعات الإلكترونية، تزداد الحاجة إلى أنظمة تحقق قادرة على التمييز بين التوقيعات الأصلية والمزورة بدرجة عالية من الدقة والكفاءة.

تعتبر اللغة العربية من أكثر اللغات تعقيداً وتميزاً، حيث تتسم خطوطها بتنوع كبير في الأشكال، وتداخل في الحروف، واختلاف في أنماط الكتابة مثل (النسخ، الرقعة، الديواني). ويمثل هذا التنوع تحدياً لأنظمة التحقق من التوقيعات الإلكترونية غير المتصلة (Offline Signatures)، التي تعتمد على تحليل الصورة الثابتة للتوقيع واستخلاص خصائصها البصرية بخلاف أنظمة التحقق المتصلة (online) التي يمكن أن تعتمد على معلومات ديناميكية (مثل سرعة القلم والضغط)، ومن ثم فإن تطوير نموذج قادر على استخلاص السمات البصرية المهمة من صور التوقيعات العربية وتحليل العلاقات بين السمات المستخرجة يمثل اتجاهاً مهماً لتحسين دقة التحقق وكفاءة النظام وفي هذا الإطار، تقترح الدراسة الحالية نموذجاً هجيناً يجمع بين LSTM، MobileNetV2 و للتحقق من التوقيعات الإلكترونية العربية غير المتصلة وكشف التزوير، مع التركيز على تحقيق توازن بين دقة التحقق والكفاءة الحاسوبية وقابلية التطبيق العملي.

2. مشكلة الدراسة

تتمثل مشكلة الدراسة في محدودية بعض النماذج الحالية للتحقق من التوقيعات الإلكترونية العربية الغير متصلة في تحقيق التوازن المناسب بين دقة التحقق والكفاءة الحاسوبية وقابلية التطبيق العملي. كما أن الاعتماد على نماذج مرتفعة التكلفة أو على تقنيات منفصلة قد لا يحقق استفادة متكاملة من الخصائص البصرية للتوقيع والعلاقات التسلسلية بين السمات المستخرجة من صورته ويزداد التحدي مع خصوصية التوقيع العربي وتنوع أشكاله وأنماط كتابته مما يستدعي تطوير نموذج قادر على تحقيق دقة مرتفعة في التحقق وكشف التزوير مع المحافظة على كفاءة حاسوبية مناسبة، قابلية النشر في البيئات محدودة الموارد.

تشير الدراسات السابقة الى تنوع الأساليب المستخدمة في التحقق من التوقيعات غير المتصلة، وبين النماذج العميقة، والنماذج الهجينة، والنماذج خفيفة الوزن إلا أن الحاجة مازال قائمة الى دراسة نموذج يجمع بين كفاءة MobileNetV2 في استخراج السمات البصرية، وقدرة LSTM على نمذجة العلاقات بين السمات المرتبة المستخرجة من صورة التوقيع، مع التركيز على التوقيعات العربية وتحقيق التوازن بين الدقة والكفاءة وقابلية التطبيق العملي.

3. أسئلة الدراسة

- 1- ما مدى فاعلية النموذج الهجين المقترح القائم على LSTM، MobileNetV2 في التحقق من التوقيعات الإلكترونية العربية غير المتصلة وكشف التزوير؟
- 2- إلى أي مدى يحقق النموذج المقترح توازناً بين دقة التحقق والكفاءة الحاسوبية؟
- 2- ما مدى ملائمة النموذج المقترح للتطبيق العملي في البيئات والأجهزة محدودة الموارد؟

4. الأهمية

- 1- الأهمية العلمية: تسهم الدراسة في تطوير التحقق من التوقيعات الإلكترونية العربية من خلال دمج MobileNetV2، LSTM في نموذج هجين.
- 2- الأهمية التطبيقية: تسعى الدراسة الى تحقيق توازن بين دقة التحقق والكفاءة الحاسوبية، بما يدعم إمكانية استخدام النموذج في البيئات محدودة الموارد.

5. الأهداف

- 1- تطوير نموذج هجين قائم على V2 MobileNet و LSTM للتحقق من التوقيعات الإلكترونية العربية غير المتصلة وكشف التزوير.
- 2- تقييم أداء النموذج المقترح باستخدام مقاييس التحقق المناسبة، وقياس قدرته على تحقيق التوازن بين الدقة ومعدلات الخطأ والكفاءة الحاسوبية.
- 3- تقييم ملائمة النموذج للتطبيق العملي من خلال تحليل حجم النموذج ومتطلبات الموارد والمؤشرات المرتبطة بالكفاءة، بما يوضح مدى ملائمة للبيئات والأجهزة محدودة الموارد.

مراجعة الأدبيات والدراسات السابقة:

الدراسات المتعلقة بالتوقيعات العربية

تظهر الأدبيات العربية اتجاهين متكاملين. الأول يعتمد على السمات المصممة واختيارها مع مصنفات أحادية الفئة أو قواعد قرار خاصة بالكاتب. تقدم Abdulhussien et al. (2023a) نموذجاً عربياً أحادي الفئة قائماً على اختيار السمات. وتطور Abdulhussien et al. (2023b) نموذج QIGA، وقد أبلغت على SID-Arabic عن FRR قدره 3.3%، و FAR للترزوير الماهر 3.2% وللترزوير البسيط 1.9%، و EER قدره 2.6% أما Abdulhussien et al. (2023c) فتقدم progressive fusion وتبلغ على SID-Arabic عن FRR قدره 6.81%، و FAR قدره 4.76% للترزوير الماهر و 4.20% للبسيط، و EER قدره 5.65% تكشف هذه السلسلة أن اختيار السمات ونمط البحث يؤثران بقوة في نظام أحادي الفئة، لكنها تظل مرتبطة بإطار سمات يدوية أكثر من تمثيل عميق. end-to-end. الاتجاه الثاني يستفيد من التعلم العميق أو نماذج هجينة. قدم CNN AIKarem et al. (2024) للتحقق اليدوي، بينما صمم Al-Zubaidi et al. (2026) نظاماً ضبابياً Offline مخصصاً للعربية مع عتبات Writer-Dependent، ووسعت Balat et al. (2026) التقييم إلى ASVAR العربية باستخدام ست CNN-Transformer hybrids ويعد ظهور ASVAR في دراسة حديثة مع MobileNetV2 نقطة تقاطع وثيقة مع موضوع الرسالة الحالية، مع ضرورة الانتباه إلى بروتوكولها Seen-Writer عند قراءة أرقام الأداء.

يتضح من الدراسات السابقة المتعلقة بالتوقعات العربية أن معظم الأساليب المبكرة اعتمدت على استخراج واختيار السمات اليدوية مع استخدام مصنفات تقليدية، في حين اتجهت الدراسات الحديثة إلى توظيف نماذج التعلم العميق والنماذج الهجينة. وعلى الرغم من تحسن الأداء، لا تزال الحاجة قائمة إلى نماذج تجمع بين كفاءة استخراج السمات البصرية وانخفاض التكلفة الحاسوبية، مع تقييم واضح لقدرتها على التمييز بين التوقعات الأصلية والمزورة ضمن بروتوكول تجريبي محدد. ومن هذا المنطلق، تركز الدراسة الحالية على تطوير نموذج هجين يجمع بين MobileNetV2 و LSTM للتحقق من التوقعات العربية غير المتصلة.

أساليب التعلم العميق للتحقق غير المتصل (Offline Deep Learning Approaches)

تُعرض الدراسات الخاصة بالتحقق المتصل (Online) للمقارنة المفاهيمية مع التحقق غير المتصل، نظراً لاختلاف طبيعة البيانات والخصائص المتاحة في كلا النوعين. ولا تُستخدم نتائج هذه الدراسات للمقارنة المباشرة مع النموذج المقترح، لأن أنظمة Online تعتمد على معلومات ديناميكية مثل السرعة والضغط ومسار القلم، وهي معلومات غير متاحة في صور التوقعات غير المتصلة.

في Offline، تتنوع بنية المشكلة بين التصنيف المباشر والتحقق الزوجي والتعلم بالمسافة. تستخدم Xiao and Wu (2025) ResT داخل ViT و Wang et al. (2026) ResNet لتحسين مواعمة السمات، بينما تجمع Li et al. (2025) CNN-CrossViT و Writer-Independent. تستخدم Mitikas et al. (2026) SPD/Riemannian على هندسة Vasilakis et al. (2025) في حين تركز CNN. هذا التنوع يؤكد أن مشكلة Offline لا تُختزل في بنية واحدة، وأن جودة التمثيل والبروتوكول لا تقل أهمية عن العمق.

تدعم نتائج النماذج الخفيفة منظور الكفاءة. Chetry and Kar (2025) أظهروا متوسط 98.98% للتزوير العشوائي و 98.07% للماهر باستخدام SqueezeNet على CEDAR ضمن بروتوكولهم، بينما استهدفت Fatihia et al. (2024) تطبيقاً محمولاً، ويعرض تحليلها اختباراً على مستخدمين محتجزين بدل الاقتصاد على صور عشوائية من المستخدمين أنفسهم. وتبين الفروق بين هذه الأعمال أن صرامة فصل المستخدمين قد تغير النتيجة أكثر مما يفعله اسم المعمارية.

كما توسع Rathore et al. (2026) خارج التعلم العميق بإطار SignGuard الذي يجمع Gray Wolf Optimization و Principal Orientation Alignment و ووصفات CS-LBP/OC-CSLBP و مصنفات SVM/XGBoost. وبلغت الدقة المبلغ عنها 98.77% و 97.46% للواصفين الرئيسيين. وجود نتيجة قوية من إطار ML حديث يؤكد أن المقارنة العلمية يجب أن تشمل جودة المعالجة والسمات والبروتوكول، لا أن تقتصر تفوق التعلم العميق لمجرد زيادة التعقيد.

التحقق من التوقيع المتصل أو الديناميكي (Online/Dynamic Signature Verification)

تستخدم أنظمة Online معلومات لا تتوافر في صورة Offline، ولهذا تُراجع هنا لأغراض المقارنة المفاهيمية لا لدمج خصائصها في نطاق الرسالة. تلخص Nsaif et al. (2025) نظم التعرف المتصل وأساليبها، وتدرس Roszczewska and Niewiadomska-Szynkiewicz (2024) التوقيع على الأجهزة المحمولة، بينما يقترح Luan et al. (2024) مصفوفة موضع نسبي ودمجاً متعدد المقاييس للتحقق. Writer-Independent Online كما قدم Zheng et al. (2024) DWSCNN مع خفض أبعاد CAE-MV، وقدم Zhang et al. (2023) 1-D CNN ضمن Federated Learning للحفاظ على الخصوصية.

نتجه أعمال أحدث إلى تمثيلات أكثر ثراءً. Huang, Ruan, Li, Xu, et al. (2026) استخدموا لحظات إحصائية زمنية/ترددية مع UMAP، بينما اقترح Huang, Ruan, and Li (2026) في دراسة منفصلة تحققاً Few-Shot عبر دمج ثنائي الاتجاه وانتباه واعٍ بالحشو على SVC2004 وبيانات خاصة. أما Diaz et al. (2025) فاستخرجوا سمات ديناميكية مرتبطة بصياغة Lagrange ونماذج روبوتية ثنائية وثلاثية الأبعاد. وتوضح Salturk et al. (2026) مساراً Contactless باستخدام توقعات في الهواء و Siamese BiLSTM، بمتوسط Accuracy و F1 يقارب 85% و Recall 91% تحت Leave-Two-Sample-Out متعدد الانقسامات.

تتناول Faundez-Zanuy (2025) و Faundez-Zanuy et al. (2026) جانب سلامة الإشارة من خلال watermarking، بينما يربط Huang et al. (2023) بين تمثيلات Online و Offline للتوقيع الإلكتروني البيومتري. هذه الأعمال مفيدة لإبراز أن ديناميكيات القلم والضغط ليست متاحة تلقائياً في Offline؛ بل هي قياسات أصلية لنمط مختلف من الاستحواذ، ولذلك لا يجوز نقل خصائصها إلى نموذج قائم على الصور.

تشير الدراسات السابقة إلى أن استخدام الشبكات العصبية الالتقافية والتعلم بالنقل يوفر قدرة جيدة على استخراج السمات البصرية من صور التوقعات، خاصة في ظل محدودية حجم بعض قواعد البيانات. كما أظهرت النماذج خفيفة الوزن إمكانية تحقيق أداء مناسب مع تقليل المتطلبات الحاسوبية. إلا أن معظم هذه الدراسات ركزت على استخراج السمات والتصنيف، في حين تركز الدراسة الحالية على توظيف MobileNetV2 لاستخراج تمثيل بصري خفيف، ثم إعادة تنظيم هذا التمثيل في صورة تسلسل لمعالجته بواسطة LSTM، بهدف الاستفادة من العلاقات بين السمات المستخرجة.

أساليب CNN والتعلم بالنقل (CNN and Transfer Learning Approaches)

يعكس مسار CNN انتقالاً من الشبكات المدربة مباشرة إلى استغلال backbones مسبقاً التدريب. AlKarem et al. (2024) يمثل نموذج CNN مباشراً، وAbdirahma et al. (2024) يقدم دراسة عميقة عالية الدقة ضمن بروتوكوله، بينما تستهدف Fatihia et al. (2024) النشر المحمول. من ناحية التعلم بالنقل، يعتمد Pathak et al. (2026) على VGG19 مع مصنفات محسنة في SignalLearn ويبلغ عن 83.703% على BHSig260 و 87.983% على UTSig و 100% على CEDAR تحت تقسيم 9:1 كما ورد في الدراسة؛ لكن هذه الأرقام لا تُرتب قواعد البيانات لأن تركيبها وصعوبتها مختلفان.

تستخدم ShuffleNet (2026) Tamizharasi and Priyadarsini خفيفة مع attention وتعلم بالنقل، وتبلغ 97.2% في إعدادات training 90% المبلغ عنه. كما تبحث Chang and Wu (2024) مشكلة قلة العينات، بينما يعالج Tehsin et al. (2024) التحقق باستخدام Triplet Siamese Similarity Networks في المستندات الرقمية. ويظهر من هذه الدراسات أن نقل التعلم و metric learning أداتان مكملتان للتعامل مع نقص البيانات، لكن قوة الدليل تعتمد على كيفية فصل الكتاب وتكوين الأزواج ونوع التزوير.

أساليب LSTM والانتباه والمحولات (LSTM, Attention and Transformer Approaches)

في LSTM، تقدم Alsuhiimat and Mohamad (2023b) دمج HOG مع LSTM في Offline؛ ويبلغ الملخص 92.4% على UTSig و 87.7% على CEDAR، مع وجود اختلافات داخلية في بعض القيم المعروضة بأقسام أخرى من الورقة، لذلك نُقرأ النتائج بحذر ولا تُعامل كمرجع رقمي وحيد. أما Transformers فقد توسعت من 2C2S لـ Ren et al. (2023) إلى TransOSV لـ Li et al. (2024) و Hybrid ViT لـ Ishfaq et al. (2024) ثم CNN-CrossViT لـ Li et al. (2025). et al. (2025) وجمع Wang et al. (2026) بين ResNet و Transformer، فيما تستخدم Balat et al. (2026) CNN backbones بالتوازي مع مسارات ViT/DeiT ثم دمج السمات.

في المجال Online، يقدم OSVConTramer Vorugunti et al. (2023) بوصفه هجين CNN-Transformer، بينما تستخدم attention Huang, Ruan, and Li (2026) واعياً بالحشو ضمن Few-Shot. كما يستفيد Sánchez Nielsen and Martín-Herrera (2025) من Transformer في نظام OCR لإثبات مفهوم التحقق من التوقيع في عرائض تشريعية، وهو سياق يختلف عن التحقق البيومتري الثنائي التقليدي لكنه يوضح انتشار البنية في تحليل التوقيعات المكتوبة.

وتكشف نتائج Ren et al. (2023) اختلافاً كبيراً عبر قواعد البيانات: 93.25% على SUES-Sig، و 90.68% على CEDAR، و 100% على BHSig-Bengali، و 72.22% على BHSig-Hindi وفق التقرير المنشور. هذا التباين داخل النموذج نفسه دليل مباشر على أن Dataset و Protocol يحددان صعوبة المهمة بدرجة لا تقل عن المعمارية، ولذلك لا يجوز نقل رقم من قاعدة إلى أخرى أو تعميمه على التوقعات العربية.

وبناءً على ما سبق، فإن توظيف LSTM في الدراسة الحالية لا يُقصد به نمذجة الزمن الحقيقي للتوقيع، وإنما تحليل تسلسل منظم من السمات المستخرجة من الصورة بواسطة MobileNetV2. وعليه، فإن قيمة LSTM في النموذج المقترح ترتبط بقدرتها على نمذجة العلاقات بين عناصر هذا التسلسل، وليس باستخلاص خصائص ديناميكية غير متاحة في بيانات Offline.

الأساليب خفيفة الوزن والموجهة للأجهزة المحمولة (Lightweight and Mobile Approaches)

توجد حاجة واضحة لتقليل الكلفة عند نقل التحقق من المختبر إلى أجهزة محدودة الموارد. استهدفت Fatihia et al. (2024) تطبيقاً محمولاً، واستخدم SqueezeNet Chetry and Kar (2025)، بينما تبنت Tamizharasi and Priyadarsini ShuffleNet (2026) خفيفة. وفي SignatureGuard يظهر MobileNetV2 كأخف Backbone بين المقارنة الثلاثية، مع 3.4M معلمة و 0.30 GFLOPs في الجسم الأساسي مقابل كلف أعلى بكثير لـ ResNet50 و EfficientNetB7 (Balat et al., 2026).

غير أن صفة Lightweight لا ينبغي أن تُستنتج من اسم المعمارية وحده؛ فالرأس المضاف، وحجم المدخل، والكمية الفعلية للمعاملات القابلة للتدريب، وطريقة الحفظ والكمية، كلها تحدد الحجم والزمن النهائيين. وعند غياب Model Size أو زمن الاستدلال في الدراسة الأصلية تبقى هذه القيم غير مبلغة (Not reported)، ولا يمكن استنتاجها من عدد طبقات backbone وحده، لذلك تعتمد المقارنة في الدراسة الحالية على مؤشرات قابلة للقياس، تشمل حجم النموذج وعدد المعاملات والتكلفة الحسابية، إلى جانب مؤشرات الأداء مثل Accuracy و FAR و EER و FRR، بدل الاعتماد على تصنيف المعمارية بأنها خفيفة أو ثقيلة بصورة وصفية فقط.

على الرغم من تنوع أساليب التحقق من التوقعات غير المتصلة، ما تزال الحاجة قائمة إلى نموذج خفيف وفعال يجمع بين كفاءة MobileNetV2 في استخراج السمات وقدر LSTM على تحليل العلاقات بين السمات المستخرجة، مع التركيز على التوقعات العربية غير المتصلة.

التقنيات المستخدمة


الشبكات العصبية الالتفافية

الشبكات العصبية الالتفافية (Convolutional Neural Networks – CNNs) هي نماذج من التعلم العميق تُستخدم لاستخراج الخصائص المكانية من الصور من خلال تطبيق مرشحات على مناطق محلية، مما يساعد على اكتشاف الأنماط البصرية مثل الحواف والانحناءات وتفاصيل التوقيع. (Alsuhiimat و Mohamad، 2023)

التعلم بالنقل (Transfer Learning):

هو أسلوب يستفيد من أوزان نموذج مدرب مسبقاً على قاعدة بيانات كبيرة مثل ImageNet ، ثم يُعاد تكييفه لمهمة جديدة مثل التحقق من التوقعات.

MobileNetV2 والنماذج خفيفة الوزن



الخفيفة MobileNetV2 شكل 1: المكونات المفاهيمية لمعمارية

المصدر: Balat et al., 2026; Alreshidi, 2026; Tamizharasi & Priyadarsini, 2026.

1- الالتفاف القابل للفصل عمقياً (Depthwise Separable Convolution)

MobileNetV2 هي معمارية التلافية خفيفة الوزن صُممت لتقليل عدد العمليات الحسابية والمعاملات مع الحفاظ على كفاءة استخراج الخصائص. وتعتمد على كتل **Inverted Residuals** و **Depthwise Convolution** و **Linear Bottlenecks**، مما يجعلها مناسبة للتطبيقات التي تتطلب توازناً بين أداء النموذج والكفاءة الحاسوبية. وفي هذه الدراسة تُستخدم MobileNetV2 لاستخراج الخصائص البصرية من صور التوقعات قبل تمريرها إلى الجزء التسلسلي من النموذج. (Balat وآخرون، 2024)

2- كتل المتبقي المعكوس (Inverted Residual Blocks)

تستخدم MobileNetV2 كتل المتبقي المعكوس (Inverted Residual Blocks) تبدأ الكتلة عادة بتوسيع تمثيل منخفض الأبعاد عبر 1×1 ، ثم تطبيق **depthwise convolution**، ثم إسقاط خطي إلى فضاء أضيق. وعند توافق الأبعاد يمكن إضافة مسار متبقي، وهو ما يحسن تدفق المعلومات والتدرج مع إبقاء التمثيل الضيق على طرفي الكتلة. ويكتسب هذا التصميم أهميته في تطبيقات التوقيع عندما يكون الهدف استخلاص سمات قوية بكلفة أقل من **backbones** الثقيلة.

3- الاختناقات الخطية (Linear Bottlenecks)

يشير الاختناق الخطي (Linear Bottleneck) إلى عدم استخدام لخطية قوية بعد إسقاط الميزة إلى الفضاء منخفض الأبعاد، لأن تطبيق لخطية في فضاء ضيق قد يدمر معلومات لا يمكن استعادتها. وبهذا تحافظ الكتلة على تمثيل أكثر ثراءً قبل الانتقال إلى كتلة أخرى. في سياق الرسالة لا يُفهم **Linear Bottleneck** كطبقة أمنية بحد ذاته، بل كقرار معماري داخل MobileNetV2 يوازن بين حفظ المعلومات وتقليل الحساب.


الشبكات العصبية المتكررة (Recurrent Neural Networks – RNNs)

صُممت الشبكات العصبية المتكررة (Recurrent Neural Networks – RNNs) لمعالجة متتابعات يكون ترتيب عناصرها ذا معنى. (Alsuhiat and Mohamad (2023b).

LSTM

هي بنية متقدمة من الشبكات العصبية المتكررة (RNN) صُممت لمعالجة المتتابعات من خلال آليات بوابية تساعد على الاحتفاظ بالمعلومات المهمة والتخلص من المعلومات غير الضرورية. (Baihan وآخرون، 2024). وفي هذه الدراسة لا تُستخدم LSTM لمعالجة الزمن الحقيقي للتوقيع، وإنما لتحليل التسلسل المنظم للخصائص المستخرجة من صورة التوقيع بواسطة MobileNetV2 ، بهدف نمذجة العلاقات بين هذه الخصائص.

1- بوابات LSTM




ويوآباتها الرئيسية LSTM شكل (2) : البنية المفاهيمية لخلية

المصدر: إعداد الباحث بالاعتماد على. Alsuhimat & Mohamad, 2023b; Nsaif et al., 2025.

2- الذاكرة طويلة قصيرة المدى ثنائية الاتجاه (Bidirectional LSTM – BiLSTM)

تجمع BiLSTM بين مسار يقرأ المتتابعة في الاتجاه الأمامي ومسار يقرأها في الاتجاه العكسي، ثم تدمج المخرجات للحصول على سياق من الجانبين. ويمكن التعبير عن الدمج بالاقتران:



شكل (3) : المفهوم العام لبنية BiLSTM ثنائية الاتجاه

المصدر: إعداد الباحث بالاعتماد على. Alsuhimat & Mohamad, 2023b; Salturk et al., 2026.

3- استخدام LSTM في التحقق غير المتصل والمتصل (LSTM in Offline and Online Signature Verification)

في Online تكون LSTM طبيعية لأنها تستقبل تسلسلاً زمنياً يضم إحداثيات أو ضغطاً أو سرعة حسب الجهاز، وقد عرضت مراجعة (Nsaif et al., 2025) طيفاً واسعاً من هذه التطبيقات. وفي Offline تكون الصورة ثابتة؛ لذلك لا يجوز القول إن LSTM تستعيد ضغط القلم أو الزمن الحقيقي. الاستخدام الصحيح هو تحويل تمثيل الصورة إلى متتابعة منظمة، ثم تعلم الاعتماد بين عناصرها. قدم (Alsuhimat and Mohamad (2023b) مثالاً يجمع HOG و LSTM في تحقق Offline، بينما تظهر بنى متكررة أيضاً في أعمال هجينة أخرى.


تُعد هذه النقطة منهجية أساسية لهذه الدراسة: قدرة LSTM في النموذج المقترح -عند عرضها لاحقاً في فصل المنهجية- تُفسر باعتبارها نمذجة للعلاقات بين السمات المرتبة المستخرجة من الصورة، لا باعتبارها معالجة لديناميكيات قلم غير موجودة في قاعدة البيانات. Offline ويحافظ هذا التفسير على الاتساق العلمي بين طبيعة المدخلات ووظيفة الخوارزمية.

آليات الانتباه والمحولات (Attention Mechanisms and Transformers) 1- آلية (Attention Mechanism)

آلية الانتباه (Attention Mechanism) هي آلية تسمح للنموذج بإعطاء أوزان مختلفة لعناصر التمثيل وفقاً لأهميتها في عملية التصنيف. وفي هذه الدراسة تُستخدم لتركيك النموذج على الخصائص الأكثر تمييزاً بين التوقعات الأصلية والمزورة

$$e_t = v^T \tanh(W_h h_t + b_h) \quad (1)$$

تمثل e_t درجة الأهمية غير المطبوعة للتمثيل h_t ، بينما تمثل W_h و b_h معاملات قابلة للتعليم.



المبدأ العام لآلية الانتباه وترجيح التمثيلات شكل (4)


المصدر: إعداد الباحث بالاعتماد على Li et al., 2024; Huang, Ruan, & Li, 2026; Tamizharasi & Priyadarsini, 2026.

3- الانتباه الذاتي (Self-Attention)

في الانتباه الذاتي (Self-Attention) تُشتق الاستعلامات والمفاتيح والقيم من التسلسل نفسه، وبذلك يستطيع كل عنصر حساب علاقته بالعناصر الأخرى. هذه الآلية مناسبة لاكتشاف الاعتماد بعيد المدى في التوقيع.

8. المنهجية و بناء النموذج :

تتبع الدراسة منهجاً تجريبياً لتطوير وتقييم نموذج هجين للتحقق من التوقعات العربية غير المتصلة. اعتمدت المنهجية على استخدام قاعدة بيانات عامة للتوقعات العربية ثم اجراء المعالجة الأولية للصور، و تقسيم البيانات الى مجموعات التدريب والتحقق والاختبار ، وتطوير النموذج المقترح وتدريبه، ثم تقييم أدائه باستخدام مجموعة من مؤشرات الأداء والكفاءة الحاسوبية ومقارنته بنماذج مرجعية. يتم توضيح المنهجية بالكامل في الشكل ، حيث يتم شرح كل مرحلة بالتفصيل في الأقسام التالية.




الشكل (5) : منهجية الدراسة و تدفق البيانات

قاعدة البيانات : اعتمدت الدراسة على قاعدة بيانات عامة للتوقعات العربية منشورة على منصة ASVAR وقد تم تحميل قاعدة البيانات ومعالجتها محلياً ضمن بيئة المشروع ، حيث تضمنت النسخة الأصلية المحملة 3,471 صورة توقيع

عربي، منها 1,712 توقيعاً أصلياً و1,759 توقيعاً مزوراً. ونظراً لوجود فرق بسيط بين عدد العينات في الفئتين، تم تطبيق أسلوب الموازنة بالاختزال العشوائي (Under sampling) للوصول إلى 3,424 صورة موزعة بالتساوي بين الفئتين، بواقع 1,712 توقيعاً أصلياً و1,712 توقيعاً مزوراً. وبعد ذلك، تم تطبيق تعزيز البيانات (Data Augmentation) بعامل تضخيم مقداره 2، ليصبح إجمالي الصور المستخدمة في التجارب 6,848 صورة، موزعة بالتساوي إلى 3,424 توقيعاً أصلياً و3,424 توقيعاً مزوراً.

تكتسب ASVAR أهمية خاصة لأنها قاعدة عربية Offline استُخدمت مباشرة في الدراسة المرجعية SignatureGuard. وفق (Balat et al. (2026)، ويمكن الوصول إليه من منصة Kaggle عن طريق الرابط

<https://www.kaggle.com/datasets/ahmedemadeldeen/arabic-signature-data>



الشكل (7) : عينة من قاعدة البيانات

معالجة البيانات الأولية

تتضمن هذه المرحلة عدة خطوات أساسية:

1- المعالجة الأولية للصور:

تضمنت المعالجة الأولية توحيد أبعاد صور التوقيعات وتحويلها إلى صيغة RGB بما يتوافق مع متطلبات نموذج MobileNetV2، تم تغيير حجم الصور إلى 224*224 بكسل مع اجراء التطبيع العددي لقيم البكسلات وفق متطلبات النموذج المستخدم. كما تم تطبيق التحويلات اللازمة على صور التدريب بهدف تحسين قدرة النموذج على التعميم والتعامل مع اختلافات صور التوقيعات.

2- تعزيز البيانات: (Data Augmentation)

تم استخدام تقنيات تعزيز البيانات بهدف زيادة تنوع عينات التدريب وتقليل احتمالية فرط التعلم، حيث طُبقت تحويلات محدودة شملت الدوران والإزاحة والتكبير أو التصغير وتغيير التباين، مع الحفاظ على الخصائص الأساسية للتوقيع. وتم استخدام عامل تضخيم قدره 2، لزيادة البيانات من 3,424 إلى 6,848 صورة.

3- تطبيع البيانات:

تم تطبيع قيم الصور حسب متطلبات المسبقة لنموذج MobileNetV2 والتعلم بالنقل، باستخدام دالة المعالجة المسبقة المناسبة للنموذج، مثل دالة preprocess_input أو ما يعادلها من حيث التطبيع العددي.

تطوير النموذج

تتمثل هذه المرحلة في بناء النموذج الهجين MobileNetV2-LSTM الذي يجمع بين:

1- طبقة استخراج الميزات (MobileNetV2):

تم استخدام MobileNetV2 المُدرّبة مسبقاً على قاعدة بيانات ImageNet لاستخراج الخصائص البصرية من صور التوقيعات، واعتمدت الدراسة على تقنية التعلم بالنقل Transfer Learning و Fine-Tuning للطبقات العليا من النموذج بهدف تكييف الخصائص المستخرجة مع طبيعة التوقيعات العربية، وبعد تطبيق global average pooling، تم الحصول على متجه خصائص بطول 1280 يمثل التمثيل البصري لصورة التوقيع.

2- طبقة التحليل التسلسلي: (LSTM):

تم تمرير التسلسل الناتج عن إعادة تشكيل الخصائص إلى طبقة Bidirectional LSTM لتحليل العلاقات بين أجزاء التسلسل في الاتجاهين الأمامي والعكسي ثلثها طبقة LSTM إضافية لتعزيز تمثيل العلاقات بين الخصائص المستخرجة. واستخدم LSTM في هذا السياق لا يمثل معالجة للزمن الحقيقي للتوقيع، وإنما يهدف إلى نمذجة العلاقات بين الخصائص المرتبة المستخرجة من الصورة الثابتة.

3- طبقات التصنيف:

بعد استخراج الميزات من MobileNetV2، يتم تطبيق Global Average Pooling للحصول على متجه ميزات بطول 1280. ثم تُستخدم طبقة Dense بـ 512 وحدة مع Batch Normalization و Dropout لضغط الميزات وتحسين التعميم. بعد ذلك، يُعاد تشكيل المتجه إلى تسلسل بأبعاد 32×16 لتمريره إلى طبقات LSTM يتكون جزء التحليل التسلسلي من طبقة Bidirectional LSTM يليها LSTM إضافية، ثم آلية انتباه Attention لاختيار الأجزاء الأكثر تمييزاً. بعد ذلك تمر الميزات عبر طبقة Security Layer، ثم ثلاث طبقات تصنيف Dense بأحجام 128 و 64 و 32، وتنتهي بطبقة إخراج Sigmoid للتصنيف الثنائي بين توقيع أصلي وتوقيع مزور. يوضح الشكل 2.1 تدفق البيانات الكامل عبر معمارية MobileNetV2-LSTM-Attention-Security. أظهرت النتائج التجريبية الأولية تحقيق دقة مرتفعة بلغت 98.03%، مع حجم نموذج مضغوط يبلغ حوالي 45 ميجابايت، الأمر الذي يجعله مناسباً للتطبيقات العملية التي تتطلب توازناً بين الدقة والكفاءة وقابلية النشر.

التدريب والتحسين

أولاً: تقسيم البيانات

(Test Set) للاختبار 20% ، (Validation Set) للتحقق 10% ، (Training Set) للتدريب 70%

ثانياً: إعدادات التدريب

بمعدل تعلم أولي 0.0001 ، حجم الدفعة: 32 Adam Optimizer ، المحسن: Binary Crossentropy دالة الخسارة:

Smith ، (Learning Rate Scheduling) ، استخدام (Early Stopping مع عينة ، عدد الحقب: حتى مائة حقبه

Step Decay أو Cosine Annealing (2017) باستخدام

ثالثاً: تقنيات التحسين:

- Early Stopping مع patience عشر حقب.
- Model Checkpointing لحفظ أفضل نموذج.
- استخدام Batch Normalization و Dropout لتحسين قدرة النموذج على التعميم.
- استخدام Mixed Precision Training لتسريع التدريب وتقليل استهلاك الذاكرة.

مقاييس التقييم والاختبار كما هو موضح في الجدول :

جدول رقم (1) معادلات القياس


المعدلة	مقاييس التقييم و الاختبار	رقم المعادلة
$confusion\ matrix = \begin{bmatrix} TP & FN \\ FP & TN \end{bmatrix}$	Confusion Matrix	(2)
$Accuracy = (TP + TN) / (TP + TN + FP + FN)$	Accuracy	(3)
$Precision = TP / (TP + FP)$	Precision	(4)
$Recall = TP / (TP + FN)$	Recall	(5)
$F1 = 2 * (Precision * Recall) / (Precision + Recall)$	F1-Score	(6)
$AUC = \int_0^1 TPR(FPR) d(FPR)$	AUC-ROC	(7)
$FAR = FP / (FP + TN)$	FAR	(8)
$FRR = FN / (FN + TP)$	FRR	(9)
$EER \approx (FPR_i + FNR_i) / 2, ati = argmin FPR_i - FNR_i $	EER	(10)

مقاييس الكفاءة :

- استهلاك الذاكرة أثناء التشغيل .
- حجم النموذج النهائي .
- عدد العمليات الحسابية (FLOPs) .

المقارنة مع النماذج الأخرى

يتم مقارنة النموذج المقترح (MobileNetV2-LSTM) مع النماذج التقليدية (ResNet50-LSTM)، VGG16-، LSTM ، (CNN-only baseline) والنماذج الخفيفة (MobileNetV1-LSTM) ، EfficientNet-B0-LSTM، ShuffleNetV2-LSTM من حيث الدقة والسرعة ، وحجم النموذج واستهلاك الموارد ، وقابلية النشر.



الشكل (7) المعمارية الكاملة للنموذج


نتائج النموذج :

أظهرت النتائج التجريبية أن النموذج المقترح MobileNetV2-LSTM-Attention-Security حقق أداءً مرتفعاً في التحقق من التوقعات العربية، حيث بلغت $\text{Accuracy} = 98.03\%$ ، $\text{Precision} = 98.38\%$ ، و $\text{Recall} = 97.66\%$ ، و $\text{F1-Score} = 98.02\%$ ، مع $\text{AUC} = 0.9925$. كما حقق معدلات خطأ منخفضة بلغت $\text{FRR} = 3.07\%$ و $\text{FAR} = 1.61\%$ و $\text{EER} \approx 1.90\%$ ، مما يدل على قدرة جيدة على التمييز بين التوقعات الأصلية والمزورة.

جدول رقم (2) نتائج مقاييس الدقة والأمان والكفاءة

المعيار	الهدف	المُحقق	التحسين	المعيار	الهدف	المُحقق	التحسين
مقاييس الدقة				مقاييس الأمان			
Accuracy	>96%	98.03%	+2.03%	FAR	<2.5%	1.61%	-36%
Precision	>95%	98.38%	+3.38%	FRR	<3.5%	2.34%	-33%
AUC	>0.95	0.9925	+4.47%	EER	<3.0%	~1.90%	-37%
الكفاءة							
حجم النموذج	<50 MB	45 MB	-10%				
FLOPs	<500M	300M	-40%				
زمن CPU	<100 ms	60-180 ms					
الذاكرة	<1 GB	750-900 MB	10-25%				

كما أظهر منحنى ROC قدرة مرتفعة للنموذج على التمييز بين التوقعات الأصلية والمزورة، حيث بلغت قيمة ROC AUC 0.9925.



الشكل (8) المنحى بين النتائج المتحصل عليها

مقارنة النموذج مع النماذج الأخرى :

أظهرت المقارنة مع النماذج البديلة أن النموذج المقترح يجمع بين الدقة المرتفعة والكفاءة الحاسوبية، مع حجم نموذج يبلغ نحو 45 mb و زمن استدلال منخفض ، مما يدعم قابليته للتطبيق العملي .
جدول رقم (3) مقارنة النموذج مع النماذج الأخرى

النموذج	Accuracy	Precision	Recall	F1	AUC	FAR	FRR	حجم (MB)	FLOPs (M)	Inference (ms)
MobileNetV2-LSTM-Att-Sec المقترح	98.03%	98.38%	97.66%	98.02%	0.9925	1.61%	2.34%	45	300	60
ResNet50-LSTM	94.82%	93.71%	95.93%	94.81%	0.948	3.12%	2.89%	125	4,100	180
VGG16-LSTM	93.50%	92.10%	94.30%	93.19%	0.935	4.20%	3.50%	550+	15,300	320+
InceptionV3-LSTM	95.48%	94.52%	96.44%	95.47%	0.968	2.68%	2.44%	98	2,800	150
EfficientNet-B0-LSTM	96.20%	95.89%	96.51%	96.20%	0.979	2.15%	2.25%	52	390	95
MobileNetV2-Dense بدون LSTM	92.26%	91.83%	92.69%	92.26%	0.941	4.51%	3.81%	35	300	45

دراسة الاستئصال Ablation Study

أوضحت دراسة الاستئصال أهمية مكونات النموذج ؛ إذ انخفضت الدقة من 98.03 % إلى 97.52% عند إزالة آلية، وإلى 92.26% عند إزالة ، مما يؤكد مساهمة هذه المكونات في تحسين أداء النموذج .

جدول رقم (4) نتائج دراسة الاستئصال

النموذج	Accuracy	FAR
النموذج الكامل	98.03%	1.61%
بدون Attention	97.52%	2.77%
بدون LSTM	92.26%	7.74%
بدون Security	97.95%	2.11%

مناقشة النتائج

تؤكد النتائج التجريبية أن النموذج الهجين MobileNetV2 /LSTM يمثل حلاً متقدماً وفعالاً لمشكلة التحقق من التوقعات الإلكترونية العربية غير المتصلة.

حيث أظهرت أن النموذج المقترح حقق أداءً مرتفعاً في التحقق من التوقعات العربية، حيث بلغت الدقة 98.03% مع انخفاض معدلات القبول والرفض الخاطئ إلى 1.61% و 2.34% على التوالي، مما يعكس توازناً جيداً بين الدقة والأمان. كما أكدت قيمة $AUC = 0.9925$ قدرة النموذج على التمييز بين التوقعات الأصلية والمزورة .

وتشير دراسة الاستئصال إلى أن مكونات النموذج أسهمت بوضوح في تحسين الأداء، خاصة LSTM وآلية Attention وطبقة Security ؛ فعند إزالة LSTM انخفضت الدقة إلى 92.26% وارتفع FAR إلى 7.74%، مما يؤكد أهمية التكامل بين مكونات النموذج .

تؤكد النتائج أن النموذج المقترح يجمع بين دقة مرتفعة، ومعدلات خطأ منخفضة، وكفاءة مناسبة للتطبيق العملي: الخلاصة

- القيود والتحديات ، على الرغم من الأداء الممتاز، واجهت الدراسة بعض القيود التي يجب معالجتها في الأبحاث المستقبلية نذكر منها :

- التزوير الماهر: لا يزال كشف التزوير الماهر يمثل تحدياً، حيث بلغ معدل الرفض الخاطئ (FN) حوالي 2.34%، مما يتطلب مزيداً من التحسين في قدرة النموذج على التمييز بين التوقعات الأصلية والمزورة بمهارة عالية.

التوصيات المستقبلية

بناءً على القيود والنتائج، نوصي بالآتي للعمل المستقبلي:

- دمج البيانات الديناميكية: توسيع النموذج ليشمل التحقق من التوقعات الديناميكية (Online Signatures) من خلال دمج بيانات السرعة والضغط، مما سيعزز بشكل كبير قدرة النموذج على كشف التزوير الماهر.

- **توسيع مجموعة البيانات:** زيادة حجم مجموعة البيانات العربية وتنوعها لتشمل أنماط خطوط وكتابات أكثر، مما يحسن من قابلية تعميم النموذج.
- **استكشاف آليات الانتباه (Attention Mechanisms):** دمج آليات الانتباه في بنية CNN-LSTM لتوجيه تركيز النموذج نحو الأجزاء الأكثر أهمية وحساسية في التوقيع، مما قد يقلل من معدل القبول الخاطئ للتزوير الماهر.
- **تحسين المعالجة المسبقة:** تطوير خوارزميات معالجة مسبقة أكثر تطوراً للتعامل مع صور التوقيعات منخفضة الجودة (DPI) منخفض لضمان أداء ثابت للنموذج في جميع الظروف.

References

1. Abdulhussien, A. A., Nasrudin, M. F., Darwish, S. M., & Alyasseri, Z. A. (2023a). A genetic algorithm based one-class support vector machine model for Arabic skilled forgery signature verification. *Journal of Imaging*, 9(4), 79. <https://doi.org/10.3390/jimaging9040079>
2. AlKarem, W. Y. A., Khalid, E. T., & Ali, K. H. (2024). Handwritten signature verification method using convolutional neural network. *Iraqi Journal for Electrical and Electronic Engineering*, 20(2), 77–84. <https://doi.org/10.37917/ijeee.20.2.7>
3. Alreshidi, E. (2026). A unified benchmarking framework for offline handwritten signature verification using deep learning architectures. *International Journal of Advanced Computer Science and Applications*, 17(2).
4. Alsubhat, F. M., & Mohamad, F. S. (2023a). A hybrid method of feature extraction for signatures verification using CNN and HOG: A multi-classification approach. *IEEE Access*, 11, 21873–21882. <https://doi.org/10.1109/ACCESS.2023.3252022>
5. Al-Zubaidi, Z. F. H., Hadi-Vencheh, A., Al-Sarray, A.-S. H., & Jamshidi, A. (2026). A fuzzy approach for the automatic off-line Arabic signature verification problem. *International Journal of Mathematical Modelling & Computations*, 16(3), 231–241. <https://doi.org/10.57647/ijm2c.2026.1603.19>
6. Balat, M., Mamdouh, E., Awaad, R., Elhoseny, M., & Anter, A. M. (2026). SignatureGuard: Hybrid CNN–transformer model for signature verification and identification across Arabic and English datasets. *Scientific Reports*, 16, 23549. <https://doi.org/10.1038/s41598-026-62860-1>
7. Bird, J. J., Naser, A., & Lotfi, A. (2023). Writer-independent signature verification; evaluation of robotic and generative adversarial attacks. *Information Sciences*, 633, 170–181. <https://doi.org/10.1016/j.ins.2023.03.029>
8. Chetry, B. P., & Kar, B. (2025). Offline signature verification using pre-trained deep convolution neural network: SqueezeNet. *International Journal of Electronics and Communication Engineering*, 12(7), 315–326. <https://doi.org/10.14445/23488549/IJECE-V12I7P125>
9. Diaz, M., Ferrer, M. A., & Vessio, G. (2024). Explainable offline automatic signature verifier to support forensic handwriting examiners. *Neural Computing and Applications*, 36, 2411–2427.
10. Diaz, M., Ferrer, M. A., Gil, J. M., Rodriguez, R., Zhang, P., & Jin, L. (2025). Online signature verification based on the Lagrange formulation with 2D and 3D robotic models. *Pattern Recognition*, 164, 111581.
11. Fatihia, W. M., Fariza, A., & Karlita, T. (2024). Convolutional neural network enhancement for mobile application of offline handwritten signature verification. *TELKOMNIKA*, 22(4), 931–940. <https://doi.org/10.12928/TELKOMNIKA.v22i4.25849>
12. Faundez-Zanuy, M. (2025). Online signature watermarking in the transform domain. *Cognitive Computation*, 17, 79. <https://doi.org/10.1007/s12559-025-10436-y>
13. Faundez-Zanuy, M., Diaz, M., & Ferrer, M. A. (2026). Fragile watermarking in the pressure signal of online signatures for integrity checking. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2026.3684266>
14. Mitikas, E., Chorianopoulos, C., & Zois, E. N. (2026). Embedding Riemannian collective background knowledge for offline signature verification. *Machine Learning and Knowledge Extraction*, 8(7), 208. <https://doi.org/10.3390/make8070208>
15. Nsaif, I. G., Ahmad, S. M. S., Mashohor, S., & Hanafi, M. (2025). A review of online signature recognition system. *Fusion: Practice and Applications*, 18(1), 130–144. <https://doi.org/10.54216/FPA.180111>
16. Pathak, H. K., Chaurasia, U., Upadhyay, R. R., Singh, K. K., & Kaplan, A. (2026). Transfer learning based approach for reliable handwritten signature verification with SignaLearn. *Discover Artificial Intelligence*, 6, 226. <https://doi.org/10.1007/s44163-026-00929-6>
17. Rathore, N. C., Juneja, A., Kumar, N., Kumar, V., & Dhaka, A. (2026). A hybrid machine learning framework for offline signature verification using gray wolf optimization. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-36163-4>

18. Ren, J.-X., Xiong, Y.-J., Zhan, H., & Huang, B. (2023). 2C2S: A two-channel and two-stream transformer based framework for offline signature verification. *Engineering Applications of Artificial Intelligence*, 118, 105639. <https://doi.org/10.1016/j.engappai.2022.105639>
19. Roszczewska, K., & Niewiadomska-Szynkiewicz, E. (2024). Online signature biometrics for mobile devices. *Sensors*, 24(11), 3524. <https://doi.org/10.3390/s24113524>
20. Salturk, S., Pamukcu, T. E., & Kahraman, N. (2026). Contactless biometric verification from in-air signatures using deep Siamese networks. *Scientific Reports*. <https://doi.org/10.1038/s41598-025-29100-4>
21. Sánchez-Nielsen, E., & Martín-Herrera, I. (2025). Transformer-based OCR system for handwritten signature verification in lawmaking petitions: A proof of concept. *IEEE Access*, 13, 177573–177594. <https://doi.org/10.1109/ACCESS.2025.3620686>
22. Tamizharasi, R., & Priyadarsini, M. J. P. (2026). DeepSign: A lightweight ShuffleNet with transfer learning for signature verification. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-57396-3>
23. Tehsin, S., Hassan, A., Riaz, F., Nasir, I. M., Fitriyani, N. L., & Syafrudin, M. (2024). Enhancing signature verification using triplet Siamese similarity networks in digital documents. *Mathematics*, 12(17), 2757. <https://doi.org/10.3390/math12172757>
24. Vasilakis, N., Chorianopoulos, C., & Zois, E. N. (2025). A Riemannian dichotomizer approach on symmetric positive definite manifolds for offline, writer-independent signature verification. *Applied Sciences*, 15(13), 7015. <https://doi.org/10.3390/app15137015>
25. Vorugunti, C. S., Gautam, A., & Pulabaigari, V. (2023). OSVConTramer: A hybrid CNN and Transformer based online signature verification. 2023 IEEE International Joint Conference on Biometrics (IJCB).
26. Xiao, W., & Wu, H. (2025). Learning features for offline handwritten signature verification using spatial transformer network. *Scientific Reports*, 15, 9453. <https://doi.org/10.1038/s41598-025-92704-3>

Disclaimer/Publisher's Note: The statements, opinions, and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of LOUJAS and/or the editor(s). LOUJAS and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions, or products referred to in the content.