

Arabic Fake News Detection Using Genetically Optimized Deep Learning Models

Ali. A. Elrowayati^{*1} , M. M. Shumani² ,

¹ Dept. of Electronic Engineering, College of Industrial Technology, Misurata, Libya,

² High Institute Science and Technology, Mesallata, Libya,

*Corresponding author email: elrowayati@yahoo.com

Received: 15-10-2025 | Accepted: 20-11-2025 | Available online: 03-01-2026 | DOI:10.26629/jtr.2025.**

ABSTRACT

In recent years, the proliferation of fake news across social media and digital platforms has significantly undermined public trust in traditional media outlets, raising serious challenges at the social, political, and health levels. Within the Arabic context, this problem is further exacerbated by the scarcity of effective tools for Arabic language processing. This study proposes a hybrid model that combines AraBERT for extracting deep contextual representations, Convolutional Neural Networks (CNN) for capturing local features, and a Genetic Algorithm (GA) for hyperparameter optimization. The model was evaluated on an Arabic dataset consisting of real and fake news articles, while class imbalance was addressed using class weights. Experimental results show that the GA-optimized AraBERT-CNN hybrid model outperformed both traditional (LSTM) and modern (pure AraBERT) baselines, achieving an overall accuracy more than 96% and higher F1-scores for the minority class (real news). The significance of this study lies in presenting a comprehensive framework that integrates the contextual power of transformer-based models with the adaptive optimization of evolutionary algorithms, thereby contributing to ongoing efforts to combat misinformation in Arabic and to develop more reliable intelligent news verification systems.

Keywords: Arab fake news detection, BERT, CNN, deep learning, genetic algorithm.

الكشف عن الأخبار الزائفة باللغة العربية باستخدام نماذج التعلم العميق المحسنة بالخوارزمية الجينية

علي عبدالحفيظ الروياتي¹، محمد محمود الشوماني²،

¹ قسم الهندسة الالكترونية ، كلية التقنية الصناعية، مصراتة، ليبيا

² المعهد العالي للعلوم التقنية ، مسلاتة، ليبيا

ملخص البحث

شهدت السنوات الأخيرة تزايداً كبيراً في انتشار الأخبار الكاذبة عبر وسائل التواصل الاجتماعي والمنصات الرقمية، الأمر الذي أضعف ثقة الجمهور في وسائل الإعلام التقليدية وأثار تحديات خطيرة على المستويات الاجتماعية والسياسية والصحية. في السياق العربي،

يزداد هذا التحدي تعقيداً نتيجة ندرة الأدوات الفعالة لمعالجة اللغة العربية. تهدف هذه الدراسة إلى اقتراح نموذج هجين يجمع بين نموذج المحول اللغوي العربي **AraBERT** لاستخراج التمثيلات السياقية العميقة، وطبقات الشبكات العصبية الالتفافية (**CNN**) لاستخلاص الخصائص المحلية، مع توظيف الخوارزمية الجينية **GA** لتحسين المعلمات الفائقة. تم تقييم النموذج على مجموعة بيانات عربية تتضمن مقالات إخبارية مصنفة إلى أخبار حقيقية وزائفة، مع معالجة عدم التوازن بين الفئات باستخدام أوزان الفئات. أظهرت النتائج أن النموذج الهجين المحسن بالخوارزمية الجينية تفوق على النماذج التقليدية مثل **LSTM** نموذج الذاكرة طويلة المدى، والنماذج الحديثة مثل نموذج المحول اللغوي العربي محققاً دقة كلية تجاوزت 96% ومعدل أداء متوازن **F1-score** مرتفع لفئة الأقلية (الأخبار الحقيقية). تبرز أهمية هذا البحث في كونه يقدم إطاراً متكاملًا يجمع بين قوة نماذج المحولات ومرونة الخوارزميات الجينية، مما يعزز الجهود المبذولة لمكافحة التضليل الإعلامي باللغة العربية وتطوير نظم ذكية ذات موثوقية أعلى.

الكلمات الدالة: كشف الأخبار الكاذبة، التعلم العميق، الخوارزميات الجينية، الشبكات العصبية الالتفافية، معالجة اللغة الطبيعية.

1. المقدمة

بعض الدراسات المبكرة أسهمت في تمهيد الطريق لتطبيق النماذج العصبية على النصوص العربية. فقد قدم الفقي وآخرين (2009) نموذجاً قائماً على الشبكات العصبية متعددة الطبقات (Multi Layer Perceptron – MLP) لاكتشاف الأنماط في الكلمات العربية المكتوبة يدوياً باستخدام معاملات Zernike لاستخلاص السمات، وحقق النموذج دقة تجاوزت 87% في التعرف الصحيح، مما يؤكد قدرة النماذج العصبية على التعامل مع تعقيدات اللغة العربية وتمثيلاتها المختلفة [4]. كما أظهرت دراسة السعدني وآخرين (2020) أن للغة العربية ميزات فريدة يمكن أن تدعم أداء النماذج التقليدية والشبكات العصبية الصناعية على حد سواء [5]، بينما بينت دراسة يحيى وآخرون (2021) أن نماذج التحويل (Transformers) مثل QARiB أظهرت نتائج أفضل مقارنة بالنماذج العصبية التقليدية مثل GRU [1]. مؤخرًا أدى ظهور المحول اللغوي العربي **AraBERT** في إحداث نقلة نوعية في معالجة اللغة الطبيعية العربية (**Arabic NLP**)، من خلال استخراج الميزات و توظيف التمثيلات السياقية الغنية التي يمكن استخدامها في تصنيف النصوص وكشف التضليل [6] [7].

في العقد الأخير ومع الانتشار الواسع للإعلام الرقمي الموجه انتشرت الشائعات والأخبار الزائفة وخصوصاً على مواقع التواصل الاجتماعي. وبالتالي أصبحت هذه الأخبار الزائفة **Fake News** وسيلة للتأثير السلبي على الرأي العام [1]. من هنا كان لزاماً على الباحث تطوير منهجيات وطرق لكشف هذه الأخبار وحماية المجتمع من أضرارها بدءاً من الطرق الإحصائية التقليدية مروراً بتعلم الآلة وصولاً للتعلم العميق (**Deep Learning**) والنماذج اللغوية الضخمة.

في المراحل المبكرة، ركزت الأبحاث على اللغات العالمية مثل الإنجليزية، حيث أظهرت نتائج دراسات مثل Patwa وآخرون (2021) فعالية النماذج العميقة في اكتشاف الأخبار الكاذبة المرتبطة بجائحة كوفيد-19 [2]، بينما تناول Conroy وآخرون (2015) منهجيات الكشف التلقائي باستخدام خوارزميات تعلم آلي تقليدية مثل **Naïve Bayes** و **SVM** [3].

أما فيما يتعلق بتوظيف تقنيات التعلم الآلي والتعلم العميق في معالجة اللغة العربية، فلا يزال هذا المجال حديثاً نسبياً مقارنة باللغات الطبيعية الأخرى، إلا أن

بناء النماذج المقترحة لاكتشاف الأخبار الزائفة باللغة العربية، وذلك لبيان الأسس العلمية التي تستند إليها مراحل المنهجية المستخدمة. تشمل هذه التقنيات التعلم العميق (Deep Learning)، الشبكات العصبية الالتفافية (CNN)، نماذج المحولات (Transformers)، والخوارزميات الجينية (Genetic Algorithms).

1.2 التعلم العميق

يعتبر التعلم العميق Deep Learning من أهم مجالات الذكاء الاصطناعي، إذ يهدف إلى محاكاة آلية التعلم البشري لاكتساب المعرفة. يُستخدم كوسيلة فعالة لأتمتة التحليلات التنبؤية من خلال الشبكات العصبية متعددة الطبقات (Multilayer Neural Networks) التي تتعلم الأنماط والعلاقات المعقدة التي تربط البيانات ببعضها البعض. تتميز خوارزميات التعلم العميق بقدرتها على استخراج الخصائص تلقائيًا من النصوص دون تدخل المبرمج أو استخدام خوارزميات أخرى كما هو الحال في تقنيات تعلم الآلة، مما يجعلها مناسبة لتطبيقات مثل تحليل اللغة الطبيعية والرؤية الحاسوبية والترجمة الآلية [10].

2.2 آلية عمل التعلم العميق

تتكون الشبكات العصبية الاصطناعية من عدة طبقات وكل طبقة بها عدد من العقد (Neurons) التي تحاكي آلية معالجة الدماغ البشري. يتم تحديث وضبط الأوزان بين هذه الطبقات باستخدام خوارزمية الانتشار العكسي (Backpropagation) لتقليل الخطأ وتحسين دقة النموذج. وتعتبر هذه الشبكات القلب المحرك للنماذج اللغوية الكبيرة التي تستكشف العلاقة بين الكلمات والجمل وسبق الكلام لتمثلها بشكل فريد وقابل للتصنيف، وهو ما يشكل الأساس في النماذج المقترحة [10].

2.3 الشبكات العصبية الالتفافية

ومع كل ذلك، فإن أغلب الأبحاث والدراسات التي اهتمت بالأخبار الزائفة المنشورة باللغة العربية اعتمدت على بناء نماذج أحادية أو هجينة محدودة دون تحسين شامل للمعلومات الفائقة أو تقديم معالجة فعالة لمشكلة عدم اتزان البيانات المستخدمة في تدريب واختبار هذه النماذج [8].

كما أن هذه الأبحاث لم توظف قوة التمثيل العميق للسياق في المحولات كنموذج المحول اللغوي العربي وامكانيات الشبكات العصبية الالتفافية على استخراج الأنماط والميزات، ثم توظيف تقنيات التحسين الجيني مثل الخوارزمية الجينية في ضبط المعلمات وتحسين أداء النماذج.

تقدم هذه الورقة إطارًا جديدًا للكشف عن الأخبار الزائفة باللغة العربية، يعتمد على دمج التمثيلات السياقية من نموذج المحول اللغوي العربي AraBERT مع قدرات الاستخلاص المكاني للشبكات العصبية الالتفافية CNN، مع تطبيق الخوارزمية الجينية (GA) لتحسين المعلمات الفائقة.

تسهم هذه الدراسة في تطوير نموذج تعلم عميق هجين محسن وراثيًا يُعد من أوائل النماذج العربية التي تدمج بين تمثيلات نموذج المحول اللغوي العربي وآليات الشبكات الاصطناعية الالتفافية مع التحسين بالخوارزمية الجينية، مما يفتح آفاقًا جديدة لتطبيقات معالجة اللغة الطبيعية العربية في مجالات الكشف الآلي عن التضليل الإعلامي.

تنقسم هذه الورقة إلى أربعة أقسام رئيسية: يتناول القسم الثاني المنهجية المقترحة بما في ذلك مراحل المعالجة المسبقة، النماذج المستخدمة، وآلية التقييم. أما القسم الثالث فيستعرض النتائج ومناقشتها مع مقارنة النموذج المقترح بالدراسات السابقة. ويختتم القسم الرابع من الورقة بأبرز الاستنتاجات والتوصيات المستقبلية.

1. الإطار النظري للتقنيات المستخدمة

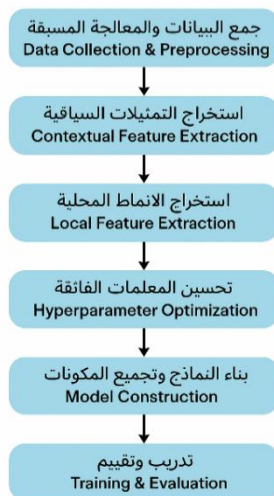
يتناول هذا الجزء من الورقة البحثية الخلفية النظرية العلمية لأهم التقنيات التي اعتمدت عليها هذه الورقة في

تُعتبر الخوارزمية الجينية إحدى الآليات البرمجية المستوحاة من سلوك الكائنات الحية، وكيف يفكر الإنسان في خلق الله سبحانه وتعالى ويوظفه مثل مراحل نمو الإنسان، أو سلوك اسراب الطيور المهاجرة، وحياة النحل، وقطعان الذئاب وغيرها.

تبدأ عملية اختيار أفضل مسار أو حل بإنتاج مجموعة من الكروموسومات (الحلول) الابتدائية العشوائية، ثم تقييمها باستخدام دالة الملاءمة (Fitness Function) بعد ذلك تُختار الكروموسومات الأفضل لتخضع لعملية المراجعة والعبور (Crossover) والتطوير للطفرة الجينية (Mutation) لتحسين الحلول عبر الأجيال المتعاقبة. وقد استُخدمت هذه الخوارزمية في النماذج المقترحة لضبط المعلمات الفائقة (Hyperparameters) كمعدل التعلم، حجم الدفعة، وأوزان الفئات، مما ساهم في تحسين دقة النماذج واستقرارها [12].

2. منهجية الدراسة

اعتمدت هذه الورقة إطار عمل متكامل للكشف عن الأخبار الزائفة باللغة العربية مستخدمة تقنيات التعلم العميق والخوارزميات الجينية. يُوضّح الشكل (2) التسلسل العام لمراحل المنهجية بدءاً من المعالجة المسبقة للبيانات وانتهاءً بمرحلة تقييم النماذج.




شكل 2. المنهجية العامة للدراسة

تعتبر الشبكات العصبية الالتفافية Convolution Neural Network من أهم أنواع التعلم العميق وأكثرها شيوعاً وخاصة مجال معالجة الملتيميديا صوتاً وصوراً ونصوصاً. وهي تصنف من طرق التعلم الآلي الخاضع للإشراف. تتكون هذه الشبكة من عدة طبقات رئيسية كما في الشكل (1)، تشمل:

- طبقة اللي (Convolution) وتستخدم لاستخراج الميزات المحلية بواسطة مرشحات خاصة.
- طبقة التجميع (Pooling): وتستخدم لتقليل حجم الميزات مع الحفاظ على أهمها.
- طبقة التنشيط (ReLU/SoftMax): تستخدم هذه الطبقة لضبط المخرجات وتحسين أداء النموذج.
- الطبقة المتصلة بالكامل

Fully Connected Layer: تستخدم لجمع كل المخرجات من العقد في الطبقة التي تسبقها لاتخاذ القرار النهائي [11].



شكل 1. التركيبة الأساسية للشبكة العصبية الالتفافية

وفي هذه الورقة، استخدم نظام هجين من الشبكات العصبية الاصطناعية الالتفافية مع نموذج المحول اللغوي العربي لاستخلاص الأنماط اللغوية المحلية من الخصائص العميقة والمعقدة للنصوص العربية.

2.4 الخوارزمية الجينية

3.1 جمع البيانات والمعالجة المسبقة

تم استخدام مجموعة قاعدة بيانات التي تحتوي على (12790) عينة من الأخبار المصنفة إلى فئتين (حقيقية وزائفة) [13]. تم مراجعة جودة البيانات وتوحيد صيغة الحقول النصية بما يضمن التوافق في التحليل اللغوي. حيث تضمنت المعالجة المسبقة الخطوات التالية:

1. الخطوة الأولى: إزالة الرموز الزائدة والتشكيل وعلامات الترقيم والفراغات والرموز غير العربية
2. الخطوة الثانية إزالة الكلمات عديمة المعنى (Stopwords).

3. الخطوة الثالثة: معالجة عدم اتزان بيانات قاعدة البيانات لتخلص من مشكلة الانحياز لكون البيانات الحقيقية أكثر من المزيفة في قاعدة البيانات المستخدمة، لحل الاشكال تم تطبيق خوارزمية أوزان الفئات (Class Weights) لضبط الأوزان.

3.2 استخراج التمثيلات السياقية

يستخدم المحول اللغوي العربي AraBERT المدرب مسبقاً (الإصدار الثاني) [7] لاستخلاص التمثيلات السياقية للنصوص العربية. هذا النموذج يعتمد المعمارية التحويلية (Transformer Architecture) القائمة على آلية التنبيه الذاتي متعددة الرؤوس (Multi-Head Self-Attention)، والتي يتم من خلالها فهم العلاقات طويلة المدى بين الكلمات ضمن الجملة الواحدة. قبل تمرير النصوص إلى النموذج يتم تجزئة وترميز النصوص (Tokenization) باستخدام دوال المحول اللغوي العربي والخاصة بمعالجة اللغة العربية، حيث نُحوّل النصوص إلى تسلسل من الرموز الرقمية يمثل كل منها كلمة أو جزءاً منها.

فعلى سبيل المثال، عند معالجة الجملة "الديناصورات تعود للظهور"، يتم تقسيمها إلى وحدات لغوية فرعية ("الديناصورات"، "تعود"، "للظهور")، ثم تحويلها إلى رموز رقمية مثل 5231، 1742، و3312 على التوالي،

لتصبح الجملة في النهاية تمثيلاً عددياً يمكن للنموذج التعامل معه مباشرة.

ينتج عن هذه العملية تمثيلات مضمنة (Embeddings) لكل رمز لغوي، بحيث تعبر عن المعاني الدقيقة والعلاقات الدلالية ضمن السياق الكامل للنص. تم ضبط طول التسلسل الأقصى (Max Sequence Length) عند 256 رمزاً لغوياً، مع تطبيق تقنيات الإضافة والقطع Padding و Truncation للحفاظ على اتساق المدخلات وتقليل العمليات الحسابية [6].

التمثيلات السياقية تعتبر حجر الأساس للنموذج المقترح، إذ تزود طبقات الشبكة العصبية الالتفافية بما تحتاجه من مدخلات غنية عن المعنى والسياق، مما يعزز قدرة النظام على التمييز بين الأخبار الحقيقية والزائفة.

3.3 استخراج الأنماط المحلية

بعد الحصول على التمثيلات السياقية من نموذج المحول اللغوي العربي، تم تمرير هذه التمثيلات إلى الشبكة العصبية الالتفافية لاستخراج الأنماط المحلية المميزة في النصوص. تُعدّ الشبكات الاصطناعية الالتفافية من النماذج الفعالة في معالجة التسلسلات النصية، حيث تعمل المرشحات على النقاط السمات النحوية والدلالية الجزئية مثل تراكيب الجمل وتتابع الكلمات ذات الصلة الوثيقة بالمعنى.

تم تصميم النموذج ليحتوي على طبقة لي واحدة Conv1D تليها طبقة تجميع GlobalMaxPooling1D لاختيار أكثر الميزات تفرداً من كل خريطة الميزات (Feature Map)، مما يقلل الأبعاد ويحافظ على المعلومات الأكثر دلالة. بعد ذلك، تُمرر النواتج إلى طبقات Dense (متصلة بالكامل) لتحسين تمثيل الأنماط المستخلصة قبل عملية التصنيف النهائية.


يساهم هذا الدمج بين نموذج المحول اللغوي العربي والشبكات العصبية الالتفافية في الجمع بين الفهم العميق للسياق الذي توفره نماذج المحولات، والقدرة على اكتشاف الأنماط الدقيقة التي تتميز بها الشبكات الالتفافية، وهو

تحقق أعلى دقة وأفضل توازن بين فئتي الأخبار الحقيقية والزائفة.

لقد ساعدت هذه الآلية في تحسين النموذج الهجين AraBERT-CNN بصورة ملحوظة، ورفع الأداء العام بالمقارنة مع النماذج غير المحسنة يدوياً، مما يؤكد فعالية استخدام الخوارزميات الجينية في ضبط المعلمات الفائقة للنماذج ذات التعلم العميق.

3.5 بناء النماذج المقترحة

تم استخدام خمسة نماذج رئيسية كما هو موضح في الشكل (3)، حيث يجمع كل منها بين مكونات مختلفة من تقنيات التعلم العميق والتحسين الجيني بهدف الوصول إلى أداء أمثل في مهمة تصنيف الأخبار الزائفة باللغة العربية. تختلف النماذج في مستوى التعقيد وطريقة التمثيل ومعالجة الأنماط النصية، كما يلي:



شكل 3. النماذج المقترحة

1. نموذج الذاكرة طويلة المدى - Long Short Term Memory (LSTM)

هو إصدار محسن من الشبكة العصبية التكرارية المصممة من قبل Hochreiter & Schmidhuber. مناسب تماماً لمهام توقع السلسلة ويتفوق في النقاط التبعيات طويلة المدى. تمتد تطبيقاته إلى المهام التي تشمل سلاسل الزمن والتسلسلات. تكمن قوة نموذج الذاكرة طويلة المدى في قدرته على فهم التبعية الترتيبية الحاسمة لحل المشاكل المعقدة. تتحكم الخلية الذاكرة بواسطة ثلاثة أبواب: بوابة الإدخال، وبوابة النسيان، وبوابة الإخراج. تقرر هذه الأبواب ما إذا كان سيتم إضافة

ما أظهر فعالية عالية في الدراسات الحديثة مثل دراسة عثمان وآخرون (2024) [7] التي أثبتت أن الجمع بين النموذجين يؤدي إلى تحسين مقاييس درجة الأداء المتوازن (F1-score) بنسبة ملحوظة مقارنة باستخدام أيٍ منهما بمفرده.

3.4 تحسين المعلمات الفائقة

تعتبر عملية تحسين وضبط المعلمات الفائقة (Hyperparameter Optimization) ركيزة محورية في بناء نماذج التعلم العميق، إذ تؤثر عملية ضبط كل من معدل التعلم (Learning Rate)، وعدد المرشحات في طبقات الشبكة العصبية الالتفافية، وحجم الدفعة (Batch Size)، وعدد الطبقات المخفية (Hidden Layers) بشكل مباشر على أداء النموذج ودقته.

في هذا الورقة، تم استخدام الخوارزمية الجينية كأداة ذكية وفعالة للبحث وتحديد مجموعة المعلمات الفائقة المثلى. تعمل الخوارزمية الجينية على تمثيل كل مجموعة من المعلمات كـ "كروموسوم"، ثم تقييم مدى "ملاءمته" وفقاً لدقة النموذج على مجموعة التحقق (Validation Set). تبدأ العملية بإنشاء تعداد أولي (Initial Population) من الحلول المرشحة (مجموعة من الكروموسومات)، ثم يُختار الأفراد الأفضل أداءً باستخدام دالة الملاءمة (Fitness Function). بعد ذلك، تُطبق عمليات التمرير (Crossover) والطفرة (Mutation) لتوليد جيل جديد من الأفراد الذين يمثلون مجموعات معلمات محسنة. تستمر هذه العملية عبر عدة أجيال (Generations) حتى الوصول إلى مجموعة مستقرة من القيم المثلى.

عملياً، تم تحديد عدد الأفراد في كل جيل بـ (6) كروموسومات، وعدد الأجيال بخمسة (5). وتمت استكشاف مساحة البحث لتشمل معدلات تعلم [0.001، 0.0001] وأحجام دفعات مختلفة [16، 32، 64]. أدت هذه الخطوات العملية إلى تحسين الأداء الكلي للنموذج، حيث ساهمت الخوارزمية الجينية في تحديد القيم التي

لاستخراج الأنماط المحلية (Local Features) مع استخدام خوارزمية أوزان الفئات أثناء التدريب لتحسين التوازن.

5. نموذج AraBERT-CNN-GA الهجين:

النموذج المقترح الرئيسي في هذه الدراسة، ويجمع بين:

- نموذج المحول اللغوي العربي المدرب مسبقاً لاستخراج الميزات السياقية.
- الشبكات العصبية الالتفافية لاستخراج الأنماط المحلية.
- الخوارزمية الجينية لتحسين المعلمات الفائقة وأوزان الفئات.

يبين الجدول (1) أهم المعلمات المستخدمة في تدريب النماذج. تم اختيار هذه القيم بعد تجارب متعددة واختبارات ضبط دقيقة بمساعدة الخوارزمية الجينية

معلومات إلى الخلية الذاكرة، أو إزالتها منها، أو إخراجها منها. تتحكم بوابة الإدخال في المعلومات التي يتم إضافتها إلى الخلية الذاكرة. تتحكم بوابة النسيان في المعلومات التي يتم إزالتها من الخلية الذاكرة. وتتحكم بوابة الإخراج في المعلومات التي يتم إخراجها من الخلية الذاكرة [14].

2. نموذج الذاكرة طويلة المدى المحسن جينياً: يستخدم الشبكة العصبية التكرارية لاستخراج الأنماط الزمنية في النصوص، مع تطبيق الخوارزمية الجينية. لتحسين المعلمات الفائقة (عدد الوحدات، معدل التعلم، حجم الدفعة).

3. نموذج المحول اللغوي العربي المدرب الأساسي:

يعتمد على AraBERT v0.2 المدرب مسبقاً كتمثيل لغوي عميق للنصوص العربية، ويتم تدريبه على طبقة تصنيف نهائية ثنائية (حقيقي/زائف) [7].

4. نموذج AraBERT-CNN مع وزن الفئات:

يتم دمج تمثيلات AraBERT مع طبقات CNN

جدول 1. إعدادات ومعلمات النماذج المقترحة

المعيار / النموذج	AraBERT-CNN	AraBERT	LSTM (GA)	AraBERT-CNN-GA مقترح الدراسة
عدد الطبقات	12 Transformer + 2 CNN layers	12 Transformer layers	LSTM طبقات 2 + طبقة كثيفة	12 Transformer + 2 CNN layers
(Units) عدد الوحدات	128	-	(GA محددة بـ) 128	(GA محسنة بـ) 128
Dropout	0.2	0.1	0.3	0.2
معدل التعلم (Learning Rate)	2e-5	2e-5	(GA optimized) 2e-5	1.8e-5 (GA optimized)
Optimizer	Adam	Adam	Adam	Adam
Batch Size	16	32	32	16 (GA optimized)
Epochs عدد التكرار	10	10	10	12

3.6 تدريب النماذج وتقييمها

تم تنفيذ عملية التدريب باستخدام مكتبة TensorFlow مع خوارزمية الأمثل لآدم Adam Optimizer، وتم تقسيم البيانات إلى 80% للتدريب، و20% للاختبار. تم استخدام بعض المقاييس لتقدير دقة النماذج المقترحة ومقارنتها، للتأكد من موثوقية النتائج.

• الدقة (Accuracy): لقياس النسبة بين

عدد الصور التي تم تصنيفها بشكل صحيح وإجمالي عدد الصور. يمكنك قياس الدقة على مقياس من 0 إلى 1 أو كنسبة مئوية. فكلما زادت الدقة، كلما كان ذلك أفضل. وبشكل عام الدقة تشير إلى مدى قرب التنبؤات من القيم الحقيقية، وهي مقياس

الإيجابية. يتم استخدام هذا المقياس عندما نريد أن نركز على تقليل الأخطاء السلبية الكاذبة. على سبيل المثال، في نموذج تشخيص امراض الزيتون، قد نريد التأكد من أن النموذج لا يفوت أي شجرة مصابة بمرض معين. ويمكن التعبير عنها كما بالمعادلة (3)[10]:

$$Recall = \frac{TP}{TP + FN} * 100 \quad (3)$$

• **المقياس الأداء المتوازن (F1-score):**
يعتبر مقياساً توافقي يجمع بين الضبط والاستدعاء (Precision) و (Recall) في مقياس واحد. وتتراوح قيمته بين 0 و 1، حيث تمثل القيمة 1 أفضل أداء للنموذج. ويمكن التعبير عنها كما بالمعادلة (4)[10]:

$$F1 - Score = \frac{2 * (Precision * Recall)}{(Precision + Recall) * 100} \quad (4)$$

• **مصفوفة الثقة أو الارتباك (Confusion Matrix):** هي جدول يستخدم في تعلم الآلة لتصنيف البيانات كما هو موضح بالشكل (4). تُظهر هذه المصفوفة بشكل واضح كيف قام نموذج التصنيف بتصنيف البيانات، سواء بشكل صحيح أو خاطئ. بمعنى آخر، فهي تُقارن بين التنبؤات التي قام بها النموذج والقيم الفعلية للبيانات. القطر الرئيسي: يمثل العناصر التي تم تصنيفها بشكل صحيح. العناصر خارج القطر الرئيسي: تمثل الأخطاء التي ارتكبها النموذج. كل خلية: تمثل عدد العينات التي تقع في تلك الفئة [10].

شامل لأداء النموذج [10]. ويمكن التعبير عنها كما بالمعادلة رقم (1):

$$Accuracy = \frac{(TN + TP)}{(TP + FP + TN + FN)} * 100 \quad (1)$$

حيث:

True Positive (TP) : هذه هي القيم الصحيحة المتوقعة بشكل صحيح، وهذا يعني أن الفئة الفعلية كانت صحيحة، كما أن توقع النموذج صحيح أيضاً.

True Negative (TN) : هذه هي القيم التي تكون فيها الفئة الفعلية خاطئة، ولكن الفئة المتوقعة تكون صحيحة.

False Positive (FP) : هذه هي القيم التي تكون فئتها الفعلية خاطئة، لكن الفئة المتوقعة تكون صحيحة.

False Negative (FN) : هذه هي القيم التي تكون فيها الفئة الفعلية صحيحة، ولكن الفئة المتوقعة تكون خاطئة.

• **الضبط (Precision):** يستخدم لتقييم انضباط النتائج الإيجابية المتوقعة من نموذج التصنيف. بمعنى آخر، عندما يقول النموذج أن شيئاً ما إيجابي، ما هي احتمالية أن يكون هذا التنبؤ صحيحاً [10]؟ ويمكن التعبير عنها كما بالمعادلة (2):

$$Precision = \frac{TP}{TP + FP} * 100 \quad (2)$$

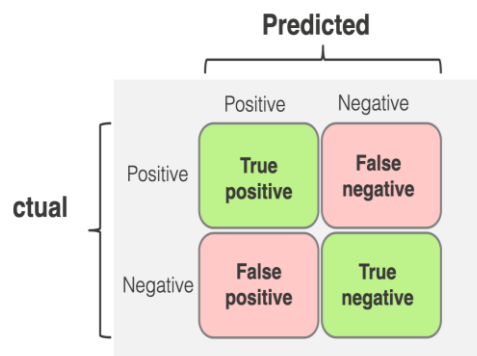
• **الاستدعاء (Recall):** يستخدم لحساب نسبة النتائج الإيجابية التي تم تصنيفها بشكل صحيح من إجمالي عدد النتائج الإيجابية. الاستدعاء يقيس مدى قدرة النموذج على تحديد جميع الحالات

مما سبق نستنتج أن الجمع بين التمثيلات السياقية العميقة باستخدام نموذج المحول اللغوي العربي وآليات استخلاص الأنماط المحلية باستخدام الشبكات العصبية الالتفافية، إلى جانب استخدام الخوارزميات الجينية يؤدي إلى أداء أكثر استقراراً وتوازناً في تصنيف الأخبار الحقيقية والزائفة على حد سواء.

الجدول (2) يوضح الفروقات في الأداء بين النماذج الأساسية والمُحسنة، مع تبيان مدى التحسن الناتج عن استخدام الخوارزمية الجينية ودمج بنى الشبكات المختلفة. من هذا الجدول يتبين أن التحول من نموذج الذاكرة الطويلة القصيرة الأساسي إلى المحسن جينياً أدى إلى تقليل كلٍ من الأخطاء من النوعين الإيجابي الكاذب (False Positive) والسلب الكاذب (False Negative)، مما يعكس فاعلية التحسين الجيني في تعزيز دقة النموذج من خلال الضبط التلقائي للمعاملات الفائقة.

بالإضافة إلى ذلك فإن دمج نموذج المحول اللغوي العربي مع الشبكات العصبية، مع تطبيق معالجة متقدمة لعدم توازن الفئات (Class Imbalance Handling)، أعطى النموذج الهجين تفوق في الأداء وجعله أكثر توازناً بين الفئتين Real وFake، وأدى إلى تحسين متوسط الدقة النوعية والاسترجاع في آنٍ واحد.

أخيراً، تجدر الإشارة إلى أن القيم المدرجة في الجدول (2) تمثل أداء النماذج على مجموعة اختبار مكونة من 2558 عينة، مما يضفي موثوقية على دقة النتائج واستقرارها التجريبي.



شكل 4. مفهوم مصفوفة الارتباك

4. النتائج والمناقشة

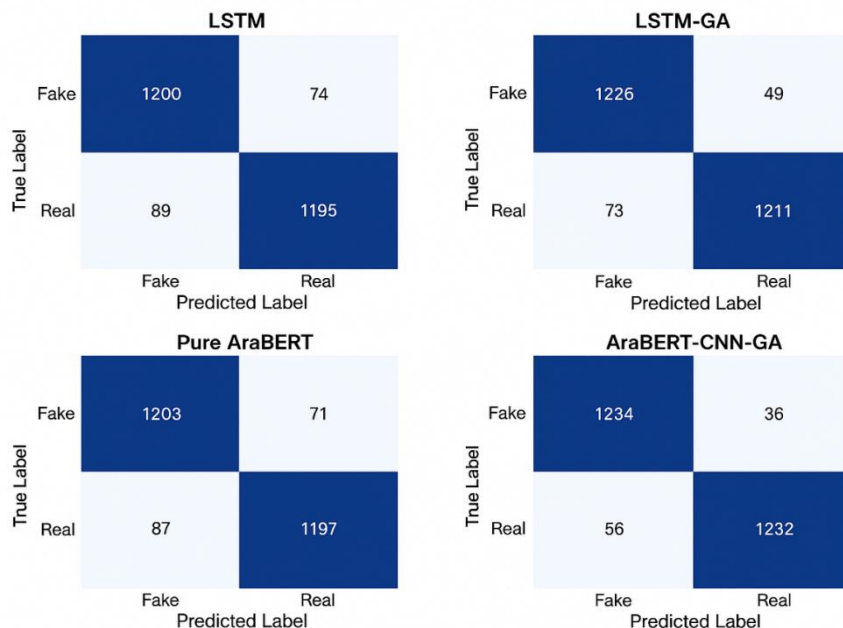
في هذا القسم من الورقة نقدم تحليلاً شاملاً لأداء النماذج التي تم توظيفها لتصنيف الأخبار الزائفة باللغة العربية، حيث تم تدريب واختبار هذه النماذج على مجموعة بيانات مخصصة لهذه المهمة. شملت عملية التقييم النماذج الخمسة المشار إليها في قسم المنهجية.

تم تقييم أداء النماذج المقترحة باستخدام مجموعة شاملة من المقاييس الإحصائية التي تشمل: الدقة والضبط والاستدعاء ومقياس الأداء المتوازن لكل فئة (حقيقية وزائفة)، لضمان تقييم متوازن وشامل للنموذج. كما هو موضح في الجدول (2)، أظهرت النتائج أن النموذج الهجين المقترح الثلاثي AraBERT-CNN-GA حقق أفضل أداء إجمالي بين جميع النماذج المستخدمة، إذ بلغت دقته 0.967 والأداء المتوسط المتوازن F1-score 0.97، متقدماً على النماذج الأخرى.

وبالرجوع إلى نموذج الذاكرة طويلة المدى المحسن جينياً فقد أظهر تحسناً كبيراً في أدائه مقارنة بنسخته الأساسية LSTM من حيث متوسط F1 الكلي (0.94 مقابل 0.92)، مما يؤكد على فعالية توظيف الخوارزمية الجينية في تحسين المعلمات الفائقة للنموذج.

جدول 2. مقارنة أداء النماذج المختلفة

النموذج	الدقة الشاملة	الضبط الحقيقي (Real)	الاستدعاء الحقيقي (Real)	متوسط الأداء المتوازن الحقيقي F1 (Real)	الاستدعاء للأخبار المزيفة (Fake)	الضبط للأخبار المزيفة (Fake)	متوسط الأداء المتوازن F1 (Fake)	Macro Avg F1	Weighted Avg F1
LSTM	0.9610	0.86	0.91	0.88	0.97	0.98	0.97	0.92	0.96
LSTM-GA	0.9664	0.89	0.93	0.91	0.97	0.98	0.98	0.94	0.97
Pure AraBERT	0.9616	0.86	0.91	0.88	0.97	0.98	0.97	0.92	0.96
AraBERT-CNN-GA النموذج المقترح	0.9668	0.90	0.91	0.90	0.97	0.98	0.98	0.94	0.97



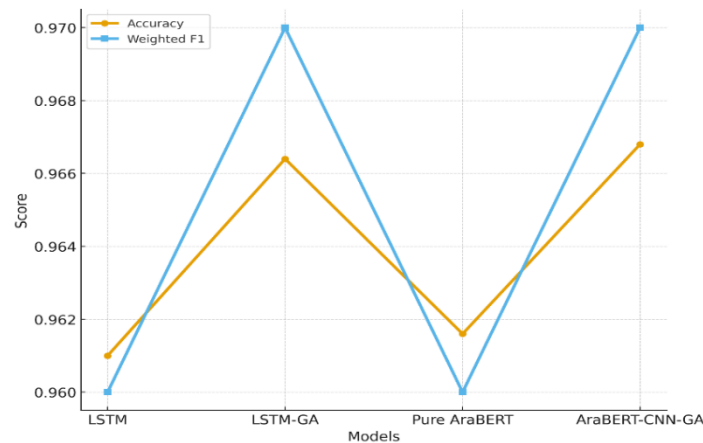
شكل 5. مصفوفات الارتباك لكل نموذج

ببقية النماذج المدروسة، حيث حقق أعلى عدد من التنبؤات الصحيحة وأدنى معدلات الخطأ في التصنيف، مما يعكس دقته العالية واستقراره في مهمة كشف الأخبار المضللة. فقد سجل النموذج 1232 حالة تصنيف

وضح الشكل (5) مصفوفات الارتباك الخاصة بكل نموذج، بما يبين توزيع التنبؤات الصحيحة والخاطئة بين فئتي الأخبار الحقيقية والأخبار الزائفة. وتُظهر النتائج تفوق النموذج الهجين AraBERT-CNN-GA مقارنة

لنموذج AraBERT وآلية استخلاص الأنماط المحلية في CNN، إلى جانب تحسين المعلمات باستخدام الخوارزمية الجينية (GA)، كان له الأثر الكبير في التقاط الفروق الدقيقة في النصوص العربية التي غالبًا ما تكون السبب في التباس التصنيف بين الفئتين.

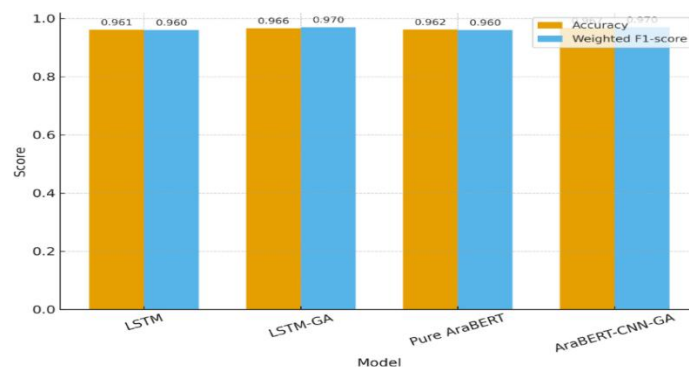
صحيحة للأخبار الحقيقية و1234 حالة تصنيف صحيحة للأخبار الزائفة، في حين انخفض عدد الأخطاء إلى 56 حالة من نوع الأخبار الحقيقية المصنفة كزائفة و36 حالة من نوع الأخبار الزائفة المصنفة كحقيقية. مما سبق نستنتج أن الجمع بين التمثيلات السياقية العميقة



شكل 6. مقارنة شاملة بين النماذج الأربعة من حيث كل من الدقة (Accuracy) ومتوسط F1 الموزون

هذا التكامل لا يظهر فقط في مقاييس الأداء الكمي مثل الدقة ومقياس الأداء المتوازن، بل يُظهر أيضا من خلال الاستقرار عبر الفئات، ما يجعله نموذجًا أكثر ملاءمة للتطبيقات الواقعية التي تتعامل مع بيانات متعددة الأنماط وغير متوازن.

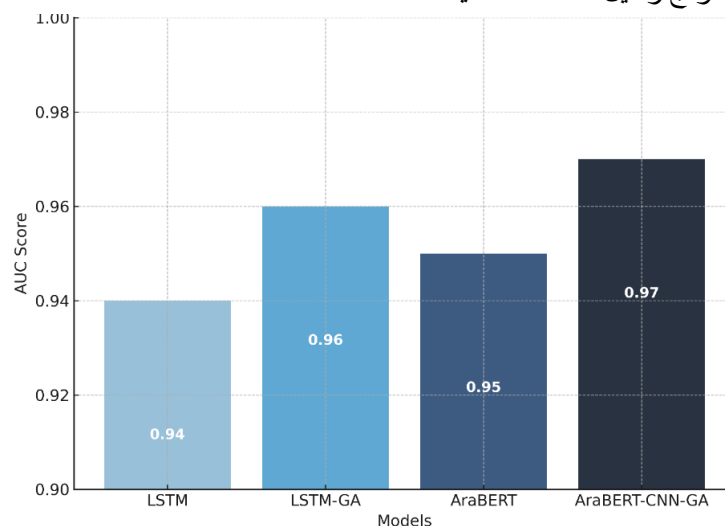
من خلال النظر في الشكل (6)، نلاحظ أن النماذج الرئيسية الأربعة نموذج المحول اللغوي العربي والنماذج المستندة إلى الأنماط المحلية المستخرجة من الشبكات العصبية الالتفافية مع التحسين الجيني أعطت نتائج ذات أداء عالي للكشف الدقيق عن الأخبار الزائفة باللغة العربية. وظهرت أهمية التكامل بينها.



شكل 7. مقارنة الأداء العام بين النماذج الأربعة

فيما يخص نموذج AraBERT الأساسي قَدَم أداءً منافسًا بفضل قدرته على تمثيل السياقات اللغوية بدقة. ولكن في المقابل، النموذج الثلاثي الهجين المقترح AraBERT-CNN-GA حقق أعلى أداء في كل من الدقة و F1، مما يبرز فعالية الدمج بين قوة AraBERT في فهم السياق العميق وقدرة CNN على التقاط الأنماط المحلية في النصوص، مع التحسين الإضافي عبر الخوارزمية الجينية.

خلصت هذه النتائج إلى أن التهجين عبر دمج التقنيات يحقق توازنًا أفضل بين الدقة والاسترجاع، ويعزز قدرة النظام على التمييز بين الأخبار الحقيقية والمزيفة حتى في حالة البيانات غير المتوازنة.



شكل 8. الأداء التنبئي للنماذج الأربعة بناءً على مقياس AUC (Area Under Curve)

النموذج ذي الذاكرة الطويلة القصيرة المحسن جينياً حقق زيادة ملحوظة في قيمة AUC (0.96) مقارنة بالتقليدي (0.94)، مما يدل على أن الخوارزمية الجينية ساهمت في تحسين ضبط المعاملات الفائقة وتقليل الأخطاء الناتجة عن التنبؤات الخاطئة. أما النموذج المحول اللغوي العربي فقد سجل قيمة (0.95)، وهو ما يؤكد فعالية النماذج المعتمدة على التمثيلات السياقية العميقة في اللغة العربية. في المقابل، أظهر النموذج الهجين الثلاثي نموذج

يُوضح الشكل (7) مقارنة الأداء العام بين النماذج الأربعة المستخدمة في هذه الدراسة، وهي LSTM، LSTM-GA، Pure AraBERT، و AraBERT-CNN-GA. يُعرض في الرسم عمودان لكل نموذج يمثلان مؤشر الدقة (Accuracy) ومتوسط F1 الموزون (Weighted F1) (score)، وهما معياران أساسيان لتقييم أداء أنظمة التصنيف في مهام الكشف عن الأخبار الزائفة.

يظهر من الشكل أن كلا المؤشرين يرتفعان بشكل تدريجي مع الانتقال من النماذج التقليدية إلى النماذج المحسنة وراثيًا. نموذج LSTM سجل أقل أداءً نسبيًا، مما يعكس محدودية قدرته على التقاط الأنماط اللغوية العميقة في النصوص العربية. بينما أظهر نموذج LSTM-GA تحسنًا ملحوظًا، حيث ساعدت الخوارزمية الجينية في تحسين المعلمات الفائقة للنموذج وتقليل أخطاء التصنيف.

الشكل (8) يبين شكل الأداء التنبئي للنماذج الأربعة بناءً على مقياس AUC (Area Under Curve)، والذي يُعد من أهم المؤشرات المستخدمة لتقييم جودة النموذج في التمييز بين الفئات الكاذب والحقيقي. تشير النتائج إلى أن جميع النماذج المحللة تمتلك AUC أعلى من 0.94، ما يعكس قدرة عالية على التمييز بين الأخبار الزائفة والحقيقية، غير أن الفروقات الدقيقة بين القيم توضح أثر آليات التحسين المطبقة في الدراسة.

بناءً على ذلك، تمثل النتائج التي تم الحصول عليها تطوراً نوعياً في مسار الأبحاث العربية الخاصة بكشف الأخبار الكاذبة، وتؤسس لمرحلة جديدة من النماذج الهجينة الذكية التي توظف التحليل السياقي، والاستخلاص العميق، والتحسين الجيني في إطار واحد متكامل.

5. الخاتمة

5.1 الخلاصة

تناولت هذه الدراسة مشكلة الكشف الآلي عن الأخبار الزائفة باللغة العربية، وهي من القضايا ذات الأهمية المتزايدة في ظل الانتشار السريع للمحتوى الرقمي على شبكات التواصل الاجتماعي. اقترحت الورقة نموذجاً هجيناً متكاملًا يجمع بين التمثيلات السياقية القوية لنموذج AraBERT-CNN-GA المحول اللغوي العربي وقدرات الشبكات العصبية الالتفافية على استخراج الأنماط المحلية من النصوص، مع توظيف الخوارزمية الجينية لتحسين المعلمات الفائقة وأوزان الفئات لمعالجة مشكلة عدم توازن البيانات. أظهرت النتائج التجريبية أن النموذج الثلاثي المقترح AraBERT-CNN-GA تفوق على النماذج الأخرى، مما يدل على فعالية الجمع بين التعلم العميق والتحسين الجيني في مهام تصنيف النصوص المعقدة. كما ساهم إدخال أوزان الفئات في تحسين أداء النموذج تجاه الفئة الأقل تمثيلاً، مما عزز من العدالة في التصنيف ودقة التنبؤ.

5.2 الاستنتاجات

من خلال نتائج التجارب والتحليل المقارن مع الدراسات السابقة، يمكن استخلاص النقاط التالية:

1. النماذج الهجينة المحسنة (Hybrid Optimized Models) تقدم أداءً أفضل من النماذج الأحادية، خصوصاً عند دمج تمثيلات نموذج المحول اللغوي العربي مع وحدات الشبكات العصبية الالتفافية لتحسين فهم السياق المحلي.

المحول اللغوي العربي مع الشبكات العصبية الالتفافية المحسنة جينياً أعلى أداءً بين جميع النماذج ($AUC = 0.97$)، وهو ما يعكس التكامل الإيجابي بين مكوناته، مما يؤكد دور الخوارزمية الجينية في ضبط المعلمات الفائقة وتجنب الإفراط في التكيف (Overfitting). فيما يتعلق بدرجات الأداء المتوازن عبر الفئات، فإن النموذج الهجين الثلاثي المقترح AraBERT-CNN-GA حقق أعلى القيم لكلا الفئتين "Fake" و "Real"، مما يدل على قدرة هذا النموذج على تحقيق توازن دقيق بين تقليل الأخطاء الإيجابية الكاذبة والسلبية الكاذبة، وهي خاصية حاسمة في أنظمة كشف الأخبار الكاذبة. تُظهر هذه النتائج مجتمعة أن استخدام تمثيلات المحولات العميقة (AraBERT) مع آليات الاستخلاص المكانية (CNN) والتحسين التطوري (GA) يقدم إطاراً متفوقاً من حيث الدقة والاستقرار في تصنيف الأخبار العربية.

هذا التفوق لا يقتصر على المقارنة الداخلية بين النماذج، بل يمتد ليضع النموذج المقترح في موقع تنافسي مقارنةً بالدراسات السابقة التي تناولت كشف الأخبار الكاذبة باللغة العربية.

فبينما أظهرت دراسات مثل Saadany وآخرون (2020) [15] و Al-Yahya وآخرون (2021) [1] كفاءة النماذج العصبية والمحولات على نحو فردي، فإن النموذج الحالي يقدم دمجاً متكاملًا بين تمثيلات AraBERT العميقة وآلية استخلاص الأنماط في CNN، إلى جانب تحسين المعلمات عبر الخوارزمية الجينية (GA)، مما مكّنه من تحقيق أداء أكثر استقراراً وتوازناً بين الفئتين "Fake" و "Real". كما يتفوق النموذج المقترح على الدراسات الحديثة مثل Othman وآخرون (2024) [7] و Wotaifi و Dhannoon (2023) [9] من حيث شمولية إطار العمل، إذ أدرجت هذه الورقة كذلك معالجة عدم توازن البيانات (Class Imbalance) وعمليات المعالجة المسبقة والترميز، وهي عناصر ثبت أنها تؤثر بشكل جوهري في تحسين جودة التصنيف.

5. استخدام خوارزميات تحسين أخرى مثل PSO (Particle Swarm Optimization) أو Bayesian Optimization للمقارنة مع أداء الخوارزمية الجينية في ضبط النماذج.

خلاصة القول: قدمت هذه الدراسة إطاراً متكاملاً يجمع بين التمثيل العميق والتحسين الجيني لمعالجة واحدة من أكثر التحديات المعاصرة في تحليل النصوص العربية — وهو الكشف الدقيق والذكي عن الأخبار الزائفة — مما يمهّد الطريق أمام تطوير حلول أكثر شمولية وذكاءً في المستقبل.

المراجع

- [1] Al-Yahya M, Al-Khalifa H, Al-Baity H, Alsaeed D, Essam A. Arabic Fake News Detection: Comparative Study of Neural Networks and Transformer-Based Approaches. Complexity. 2021;2021:5516945. doi:10.1155/2021/5516945.
- [2] Patwa P, Bhardwaj M, Guptha V, Kumari G, Sharma S, Pykl S, et al. Overview of constraint 2021 shared tasks: Detecting english covid-19 fake news and hindi hostile posts. In: Proceedings of the International Workshop on Combating Online Hostile Posts in Regional Languages. 2021. p. 42-53. doi:10.1007/978-3-030-73696-5_5.
- [3] Conroy NJ, Rubin VL, Chen Y. Automatic deception detection: Methods for finding fake news. Proceedings of the Association for Information Science and Technology. 2015;52(1):1-4. doi:10.1002/pr2.2015.145052010082.
- [4] El-Fegh I, Zubi Z, Elrowayati AA. Handwritten Arabic words recognition using multi layer perceptron and Zernik moments. 2009.
- [5] Saadany H, Mohamed E, Orasan C. Fake or Real? A Study of Arabic Satirical Fake News [Internet]. 2020 [cited 2025 Oct 15]. Available from: <http://arxiv.org/abs/2011.00452>
- [6] Antoun W, Baly F, Hajj H. AraBERT: Transformer-based Model for Arabic Language Understanding [Internet]. 2021 Mar [cited 2025 Oct 15]. Available from: <https://arxiv.org/pdf/2003.00104>

2. الخوارزمية الجينية (GA) أظهرت كفاءة عالية في اختيار المعلمات الفائقة المثلى، مما قلل من الحاجة إلى التجارب اليدوية الطويلة في ضبط النماذج.

3. معالجة عدم توازن البيانات باستخدام أوزان الفئات حسّنت من أداء النموذج في الفئات الأقل شيوعاً، وهو جانب غالباً ما تم تجاهله في الدراسات السابقة.

4. المقارنة مع الدراسات السابقة تُظهر أن إضافة مرحلة التحسين الجيني والوزن التفاضلي للفئات رفعت دقة النموذج بنسبة تتراوح بين 2-4% عن أقرب النماذج السابقة أداءً.

5.3 التوصيات للعمل المستقبلي

لتحقيق مزيد من التطور في هذا المجال، توصي الدراسة بما يلي:

1. توسيع حجم وتنوع البيانات عبر تجميع مجموعات بيانات متعددة من منصات مختلفة (Twitter)، Facebook، الأخبار الإلكترونية (لضمان تعميم النموذج على مختلف أنواع النصوص).
2. الاستفادة من النماذج متعددة الوسائط (Multimodal Models) بدمج النصوص مع الصور أو الفيديوهات لزيادة دقة الكشف في الأخبار التي تتضمن وسائط بصرية.
3. تحسين التفسيرية (Explainability) من خلال تطبيق تقنيات مثل LIME و SHAP لفهم سبب تصنيف النموذج للخبر بأنه زائف أو حقيقي.
4. تطبيق النظام في بيئة حقيقية من خلال تطوير واجهات برمجية أو أنظمة إنذار مبكر لمراقبة المحتوى المضلل باللغة العربية.

- [7] Abdelhakim Othman N, Elzanfaly DS, Elhawary MMM. Arabic Fake News Detection Using Deep Learning. IEEE Access. 2024;12:122363-76. doi:10.1109/ACCESS.2024.3451128.
- [8] Albalawi RM, Jamal A, Khadidos AO, Alhothali AM. Multimodal Arabic rumors detection. IEEE Access. 2023 [cited 2025 Oct 15];11:[page numbers]. Available from: <https://ieeexplore.ieee.org/abstract/document/10026837/>
- [9] Wotaifi TA, Dhannoon BN. An effective hybrid deep neural network for Arabic fake news detection. Baghdad Science Journal. 2023;20(4):[page numbers]. [cited 2025 Oct 15]. Available from: <https://bsj.uobaghdad.edu.iq/home/vol20/iss4/20/>
- [10] Elrowayati A, Swayeb Y, Badi M. Detecting and Classifying Olive Leaf Pests and Diseases Using Optimal Deep Learning Techniques. Journal of Pure & Applied Sciences. 2024 [cited 2025 Oct 15];[volume]:[page numbers]. Available from: <https://sebhaui.edu.ly/journal/jopas/article/view/3441>
- [11] Sakib S, Jawad A, Ahmed H. An overview of convolutional neural network: Its architecture and applications [Preprint]. 2019. doi:10.20944/preprints201811.0546.v4.
- [12] Alghamdi A, Saeed A, Kamran M, Majeed K. Vehicle classification using deep feature fusion and genetic algorithms. Electronics. 2023;12(2):280. [cited 2025 Oct 15]. Available from: <https://www.mdpi.com/2079-9292/12/2/280>
- [13] Kaggle. Arabic Fake and Real News Articles [Internet]. [cited 2025 Sep 8]. Available from: <https://www.kaggle.com/datasets/shyakanobledavid/david-ozil>
- [14] Samantaray S, Kumar A. Bi-directional long short-term memory network for fake news detection from social media. In: Proceedings of International Conference on Intelligent and Cloud Computing. Singapore: Springer; 2022. p. 463-70. doi:10.1007/978-981-16-9873-6_42