

اكتشاف الإشاعات والأخبار الكاذبة باستخدام تقنيات الذكاء الصناعي

د. جعفر سلمان *

م. لين سلامه **

تاريخ الإيداع ٢٠٢٣/٥/٢٨ . قُبل للنشر في ٢٠٢٣/١٠/٥

□ ملخص □

إنّ عملية كشف الأخبار الكاذبة وغير المؤكدة يمثل تحدياً كبيراً يجب معالجته بأسرع وقت. يقدم هذا البحث منهجية ذكية لإنشاء نموذج قادر على تصنيف الأخبار المنتشرة على وسائل التواصل الاجتماعي والتحقق من صحتها وتحديد إذا كانت صحيحة أو كاذبة، وذلك من خلال إجراء عملية معالجة مسبقة لمجموعة بيانات نصية باستخدام تقنية معالجة اللغات الطبيعية NLP وتحويل TF-IDF ومن ثم اختيار مجموعة الميزات المناسبة لعملية التصنيف واخيراً تطبيق خوارزميات التعلم الآلي الخاضعة للإشراف على مجموعة البيانات الناتجة حيث تم استخدام ثلاث خوارزميات رئيسية هي خوارزمية شجرة القرار، خوارزمية الغابة العشوائية، خوارزمية الانحدار اللوجستي، حيث تم اختيار هذه الخوارزميات كونها أثبتت جدارتها في العديد من الأبحاث [3]، [5]، [4] والتي أظهرت نتائج تصنيف جيدة مع تحقيق قيم دقة عالية كان أفضلها مع استخدام خوارزمية الغابة العشوائية Random Forest حيث وصلت إلى 97.01% ، تم في هذه الدراسة اعتماد data set تحوي مجموعة من الأخبار الصحيحة و الكاذبة المصنفة يدوياً [2] .

الكلمات المفتاحية: أخبار كاذبة -ذكاء صناعي - تعلم آلي - إشاعات - تصنيف

** مدرس في قسم هندسة تكنولوجيا المعلومات - كلية هندسة تكنولوجيا المعلومات والاتصالات - جامعة طرطوس - سوريا
*** طالب ماجستير في قسم هندسة تكنولوجيا المعلومات - كلية هندسة تكنولوجيا المعلومات والاتصالات - جامعة طرطوس - سوريا.

Rumors and fake news detection using artificial intelligence technology

*Dr . jaafar slman

**Eng.leen slamah

(Received 28/5/2023 . Accepted 5/10/2023)

□ ABSTRACT □

The process of exposing false and unconfirmed news is a major challenge that must be addressed as soon as possible. This research presents an intelligent methodology to create a model capable of classifying and verifying the news spread on social media and determining if it is true or false, by pre-processing a text data set using NLP natural language processing technology and TF-IDF conversion, and then choosing the appropriate set of features for the classification process, and finally applying supervised machine learning algorithms to the resulting data set, where three main algorithms were used: the decision tree algorithm, the random forest algorithm, and the logistic regression algorithm, where these algorithms were chosen As it has proven its worth in many researches [3], [5], [4], which showed good classification results with achieving high accuracy values, the best of which was with the use of the Random Forest algorithm, which reached 97.01%.

Keywords: fake news-Rumors- artificial intelligence - Machine Learning – classification-

*Teacher, Information Technology Engineering Department, Information and communication Technology Engineering, Tartous University, Syria

**Master Student- Information Technology Engineering Department, Information and communication Technology Engineering, Tartous University, Syria

١ - المقدمة:

مع التقدم التكنولوجي الكبير وظهور الصحافة الحديثة المعتمدة على الأنترنت بكافة أشكالها ونظراً للنمو الهائل للمعلومات عبر الأنترنت أصبحت عملية الحصول على الأخبار عن طريق وسائل التواصل الاجتماعي سلاح ذو حدين فمن ناحية أولى أصبحت عملية الوصول إلى الأخبار واستخدامها ونقلها أسرع وأسهل، لكن من ناحية أخرى أصبحت هذه الأخبار أكثر عرضة للتلاعب، حيث شكلت هذه المواقع بيئة خصبة لانتشار الأخبار الكاذبة والمزيفة على نطاق واسع والتي تعد مصدر قلق بالغ الأهمية نظراً لقدرتها على إلحاق الكثير من الأضرار بالفرد والمجتمع. وأصبح الأنترنت في وقتنا الحاضر جزء لا يتجزأ من أسلوب الحياة اليومي، حيث سجلت شبكات التواصل الاجتماعي مثل Twitter و Facebook ارتفاعاً هائلاً في شعبيتها مقابل تراجع ملحوظ لمصادر المعلومات والقنوات الإعلامية التقليدية مثل الصحف والمجلات والتلفاز والإذاعة.

يستخدم الكثير من الأشخاص منصات ووسائل التواصل الاجتماعي لجمع المعلومات والأخبار المتنوعة من جميع أنحاء العالم ولما توفره من تنوع في الأخبار والمصادر بالإضافة للمرونة والسرعة في الوصول إليها. [1] كان هذا التطور مصاحباً لانتشار كبير للأخبار الكاذبة والمزيفة، حيث أصبح لدينا كم هائل من المعلومات على الأنترنت والتي من المستحيل اختبار مدى صحتها من عدمه وبالتالي التأثير السلبي الخطير لذلك على الفرد والمجتمع. [2]

٢ - هدف البحث:

الهدف من هذا البحث هو تصميم مصنف ذكي يعمل على تصنيف الاخبار الكاذبة والاشاعات المزيفة التي تعمل البرمجيات الخبيثة على انشاءها ونشرها على منصات ووسائل التواصل الاجتماعي المختلفة بالاعتماد على أساليب وتقنيات الذكاء الصناعي والتعلم الآلي، وذلك بهدف التقليل من هذه الظاهرة والحد من الآثار السلبية الخطيرة الناتجة عنها.

٣ - مواد وطرق البحث:

تم في هذا البحث الاعتماد على العديد من الدراسات المرجعية:

٣-١ الدراسات المرجعية:

الدراسة الأولى

"Fake news Identification on Twitter with combination of CNN and RNN models,"

حيث اقترح فيها الباحثون نموذجاً لتحديد التغريدات الإخبارية الكاذبة المنتشرة على موقع تويتر بدون إدخال العنوان (title) في قاعدة البيانات من أجل عملية التصنيف وتم الاعتماد على مزيج من الشبكات العصبونية CNN و RNN، وتم تطبيق النموذج الناتج على مجموعة بيانات مؤلفة من ٥٨٠٠ تغريدة تتمحور حول خمس قضايا وإشاعات ذات شعبية عالية على المنصة الإلكترونية.

أما في هذا البحث يتم بزيادة حجم قاعدة البيانات من خلال استخدام أخبار من أكثر من موقع تواصل اجتماعي ولا يقتصر على تويتر، بالإضافة الى إدخال العنوان بعملية التصنيف و ذلك لأنه يساهم في زيادة نسبة كشف الأخبار الكاذبة و قد تمت عملية التصنيف باستخدام خوارزميات التعلم الآلي. وذلك بالاعتماد على لغة البايثون البرمجية (Python) لما تقدمه هذه اللغة من مكتبات رياضية ومكتبات تعلم آلي أثبتت جدارتها في هذا المجال[4].

الدراسة الثانية

A SYSTEM USING DEEP LEARNING AND FUZZY LOGIC TO DETECT FAKE YELP REVIEWS Jun Bai, M.S.(2018)

قدمت هذه الأطروحة طريقة محسنة لاكتشاف المراجعات الزائفة باستخدام تقنيات تعلم الآلة، استخدمت هذه الدراسة بيانات مرجعية من جامعة اوهايو كليفلاند وهي بيانات YELP استخدمت مزيج من شبكات CNN +RNN ووصلت دقة التصنيف فيها إلى نسبة ٧٢% ولكن عانت هذه الدراسة أولاً من ضعف دقة التصنيف وثانياً من مشكلة استهلاك الزمن بشكل كبير[6].

الدراسة الثالثة

Effective Fake News Detection with Deep Diffusive Neural Network , Bowen Dong, Philip S. Yu(٢٠١٩)

كان الهدف من هذا البحث تحديد مصداقية الأخبار وصحتها عن طريق تصنيف الأخبار إلى موثوقة وغير موثوقة، تم جمع البيانات من موقع تويتر لحساب PolitiFact الإخباري تم في هذا البحث استخدام خوارزمية SVM Support Vector Machine هذه الدراسة تمكنت من تصنيف ١٥٠٠ مقال إلى ٩٦٠ كاذب و ٥٤٠ مقال صحيح وبنسبة دقة في التصنيف وصلت إلى ٨٦%، اختصت هذه الدراسة بمقالات عن الانتخابات الأمريكية سنة ٢٠١٦ ولم تنطرق إلى مواضيع مقالات أخرى[9].

الدراسة الرابعة

Detecting Misleading Information on COVID-19/KIN FUN LI (2020)

كان الهدف من هذه الدراسة الكشف عن الأخبار الغير صحيحة عن كوفيد ١٩ ، نهدف إلى تقديم نظام يساعد المنظمات إلى تصنيف معلومات عن الكورونا مثل منظمة الصحة العالمية وغيرها، تم جمع مجموعة من الأخبار عن تويتر التي تحوي على كلمة COVID، تم استخدام عدة خوارزميات وتمت المقارنة بينها أفضل الخوارزميات أداء أعطت دقة تصنيف بنسبة ٩٣%، كانت الصعوبة في اختيار الميزات حيث موضوع البحث جديد و لحد الان لم يتم اكتشاف الاعراض الأساسية لهذا المرض و اكتشاف الأعراض من شخص لأخر[9].

الدراسة الخامسة

Language-Independent Fake News Detection :English, Portuguese, and Spanish Mutual Features (Gabriel Marques Tavares - 2020)

قام الباحث باستخراج الخصائص المشتركة من اللغات الإنجليزية والبرتغالية والاسبانية وقام بتحديد الميزات / الخصائص المشتركة بين تلك اللغات استخدم تقنيات lexical analysis, fuzzy logic. وصلت الدقة إلى 88% [10].

الدراسة السادسة

Fake news detection: a survey of evaluation datasets (Maria Chiara Caschera - 2021)

تم استخدام ٦ مجموعات من البيانات بمجموع مليون نص من البيانات المصنفة أو ما تعرف ب labeled data تمت مقارنة النصوص عن طريق حزمة Fuzzy Wuzzy سرعت من الأداء ولكن دون تحديد نسبة دقة الأداء التي تم الوصول إليها [11].

٣-٢ توصيف البيانات Data characterization:

تم في هذه الدراسة اعتماد data set تحوي مجموعة من الأخبار الصحيحة و الكاذبة المصنفة يدوياً و مكونة من ٤٤٨٩٨ سجل و ٤ واصفات و التي تم الحصول عليها من البحث [2] وتم إضافة ما يقارب ١٠ آلاف خبر على البيانات من أجل تحسين الأداء و زيادة دقة النتائج و يوضح الشكل (١) عينة تم التقاطها للبيانات أثناء التنفيذ.

	target	subject	text	title
0	true	worldnews	LISBON (Reuters) - Former Portuguese prime min...	Portuguese ex-PM Socrates indicted on corrupti...
1	fake	Middle-east	Tune in to the Alternate Current Radio Network...	Boiler Room EP #113 - 'CNN is ISIS'
2	fake	left-news	Hillary shouldn't be on FOX News giving interv...	HILLARY GOT DESTROYED By Chris Wallace On FOX ...
3	true	politicsNews	WASHINGTON (Reuters) - President Donald Trump ...	Trump recommits to U.S. allies but says they m...
4	true	worldnews	TEGUCIGALPA (Reuters) - Observers cannot be ce...	OAS says Honduran vote results in doubt due to...

الشكل (١): مجموعة البيانات المستخدمة في بناء المصنف تم التقاطها من البرنامج أثناء التنفيذ

١. title: ويمثل عنوان الخبر المنتشر على مواقع التواصل الاجتماعي.
٢. text: يمثل المحتوى النصي المطلوب تصنيفه باللغة الإنكليزية وتحديد هل هو مزيف أم حقيقي.
٣. subject: يشير إلى الموضوع الذي يندرج تحته هذا النوع من النصوص حيث تم الأخذ بعين الاعتبار ستة (٦) أنواع من الأخبار:

الجدول (١) التعداد الكلي لأنواع الاخبار	
Government News	١٥٧٠
Middle-east News	٧٧٨
Literary News	٧٨٣
Economic News	٤٤٥٩
Politics News	١١٢٧٢
Social News	١٠١٤٥

٤. target: فئة التصنيف النهائية لهذه النصوص الممثلة باستخدام قيم منفصل وهي [4]:
 - a. Fake
 - b. True

٣-٣ تقنية معالجة اللغات الطبيعية (NLP) Natural Language Processing:

معالجة اللغات الطبيعية (NLP) هي حقل فرعي لعلوم الكمبيوتر والذكاء الاصطناعي الذي يحدد آلية التفاعل بين أجهزة الكمبيوتر واللغات البشرية. الهدف الأساسي ل (NLP) هو تمكين أجهزة الكمبيوتر من فهم وتفسير وتوليد اللغة الطبيعية بالطريقة التي يقوم بها البشر [5]، هناك مرحلتان رئيسيتان لمعالجة اللغة الطبيعية:

٣-٣-١ المعالجة المسبقة للنصوص Process Documents:

لاستخدام التنقيب في النصوص (Text Mining) نحتاج إلى إعداد البيانات لتكون جاهزة لتطبيق تقنيات التنقيب، و ذلك بهدف تحويل المستندات النصية إلى نموذج مناسب لخوارزميات استخراج بيانات التصنيف، حيث أن المعالجة المسبقة تتكون من الخطوات التالية :

- التقطيع Tokenization: هو عملية تقسيم الجمل إلى مجموعة كلمات token بالاعتماد على الفراغات بين الكلمات وعلامات الترقيم.
- إزالة كلمات التوقف Stop word removal: في هذه الخطوة تتم إزالة الكلمات غير الهامة التي لا يؤثر حذفها على عملية التصنيف مثل الضمائر (هو، هي، هم، هؤلاء،...) وكلمات الاستفهام (ماذا، لماذا،...) وكلمات غير هامة (بغض النظر، بالإضافة، بالرغم، بالنسبة،...).
- التجذير Stemming: هنا يتم استنتاج جذر الكلمات أي ردها على أصلها (إزالة البادئات و اللواحق) [6].

٣-٣-٢ الخوارزمية Algorithm:

بمجرد انتهاء مرحلة المعالجة المسبقة للبيانات تنتقل إلى المرحلة التالية وهي بناء خوارزمية تصنيف البيانات، هناك العديد من خوارزميات معالجة اللغة الطبيعية المختلفة، والتي يتم الاعتماد من خلالها على نظامين أساسيين هما: [8]

- النظام القائم على القواعد Rules-based system: يستخدم هذا النظام قواعد لغوية مصممة بعناية، وكان مستخدم بشكل أساسي خلال المراحل الأولى لتطوير معالجة اللغة الطبيعية.
- النظام القائم على التعلم الآلي Machine learning-based system: تستخدم خوارزميات التعلم الآلي الأساليب الإحصائية، حيث تتعلم أداء المهام بناءً على بيانات التدريب التي يتم تغذيتها بها، ومن ثم ضبط أساليب هذه الخوارزميات مع معالجة المزيد من البيانات. وهو النظام الذي تم الاعتماد عليه ضمن هذا البحث [7] و تم اعتماد هذا النوع لقابليته على التطوير بسهولة دون الحاجة إلى إعادة صياغة قواعد جديدة على عكس النوع السابق.

٣-٤ تواتر المصطلحات وتواتر المستندات العكسي Term Frequency – Inverse Document

:(tf-idf) Frequency

هو مقياس رقمي يُستخدم لتسجيل أهمية كلمة ما في مستند بناءً على عدد مرات ظهورها في ذلك المستند ومجموعة معينة من المستندات، وذلك لاستخدامه في عملية معالجة اللغة الطبيعية (NLP) حيث يجب تحويل النص إلى تمثيل رقمي لتطبيق تقنيات التعلم الآلي في معالجة النص حيث تم صياغة مجموعة من المعادلات من أجل حساب المقياس الذي يعبر عن أهمية الكلمة [9].

يعتمد هذا المقياس على فرضية: " إذا ظهرت كلمة بشكل متكرر في مستند، فيجب أن تكون مهمة ويجب أن نعطي هذه الكلمة درجة عالية. ولكن إذا ظهرت إحدى الكلمات في العديد من المستندات الأخرى، فمن المحتمل ألا تكون معرّفًا فريدًا، لذلك يجب علينا تعيين درجة أقل لتلك الكلمة ". يتكون TF-IDF من مصطلحين أساسيين هما [5]:

Term Frequency (TF) مصطلح التردد:

إحدى طرق تحويل الكلمات (في مستند) إلى أرقام عن طريق حساب عدد مرات ظهور مصطلح (t) في المستند (D) ، فهو يعطي مقياساً للكلمات المهمة في مستند واحد. وفق المعادلة التالية:

$$TF(t) = (\text{count}(t) \text{ in } D / \text{Total words in } D) \quad (1)$$

لكن تكمن مشكلة TF في أنه يأخذ في الاعتبار جميع الكلمات بنفس القدر من المساواة، مع العلم أن هناك كلمات مثل "a , the" وغيرها تظهر بشكل أكبر في أي مستند ولكنها ليست مهمة. لحل هذه المشكلة تم استخدام تردد المستند العكسي (IDF) .

تردد المستند العكسي (IDF) :

قبل الدخول في شرح هذا المصطلح يجب معرفة مفهوم DF.

تردد المستند (DF) :

يوضح عدد المستندات في مجموعة من المستندات التي تحتوي على مصطلح معين والذي بدوره سيقدر مدى أهمية كلمة ما وفائدتها، فإذا كان المصطلح "t" موجوداً في جميع مستندات المجموعة، تقل فرص أن تكون الكلمة مفيدة.

يمكننا القول أن أهمية المصطلح تتناسب عكساً مع تردد المستند (DF) ، وهذا هو سبب أهمية تردد المستند العكسي (IDF) .

والذي يتم تعريفه كالتالي:

$$IDF(w) = \log (\text{Total no. of Docs} / \text{No. of docs containing the term 't'}) \quad (2)$$

TF-IDF :

هي الترددات الموزونة على أساس التردد. نستخدم الآن كل من TF و IDF لإنشاء تمثيل رقمي ذو

معنى للنص:

$$TF-IDF = TF (t) * IDF (t) \quad (3)$$

حيث:

- t: تشير إلى المصطلحات.
- d: تشير إلى كل مستند أو وثيقة.
- D: تشير إلى جميع المستندات.

وبالتالي سيكون قيمة TF-IDF مرتفعة إذا كان كل من TF و IDF مرتفعاً، "t" الذي يتكرر عدة مرات في مستند، على سبيل المثال D1 ويحدث فقط في عدد قليل من المستندات في المجموعة سيكون له قيمة TF-IDF عالية لـ D1.

٣-٤ مرحلة التصنيف:

بعد القيام بعملية المعالجة المسبقة للبيانات بحيث أصبحت جاهزة لتشكيل دخل للمرحلة التالية وهي تطبيق خوارزميات التعلم الآلي لتصنيف مجموعات البيانات إلى أخبار مزيفة أو حقيقية، حيث تم استخدام ثلاث خوارزميات تتقرب لهذه الغاية وهي [10] :

١- خوارزمية شجرة القرار Decision tree.

٢- خوارزمية الغابة العشوائية Random forest.

٣- خوارزمية الانحدار Logistic Regression

٣-٤-١ معايير تقييم أداء الخوارزمية:

لتقييم أداء خوارزميات الكشف عن الأخبار المزيفة، تم استخدام مجموعة من مقاييس التقييم المختلفة التي ترتبط بعملية التصنيف بالفئة المستهدفة هل هي فئة أخبار كاذبة أم صحيحة؟ وهي:

١. مصفوفة الارتباك:

هي عبارة عن مصفوفة بسطرين وعمودين (يرتبط حجمها بعدد فئات التصنيف الناتجة) تتكون في هذه الحالة من قيم محددة تمكننا من معرفة عدد العينات التي تم تصنيفها بشكل خاطئ وعدد العينات التي تم تصنيفها بشكل صحيح بسرعة كما يوضح الجدول التالي (٢).

الجدول (2): مصفوفة الارتباك

		التصنيف الحقيقي	
		Class - 1	Class - 0
التنبؤات	Class - 1	TP	FP
	Class - 0	FN	TN

تتكون مصفوفة الارتباك من القيم التالية:

- **TP (True Positive)**: تمثل القيم الإيجابية والتي تم تصنيفها من قبل الخوارزمية على أنها إيجابية.
- **FP (False Positive)**: تمثل القيم السلبية ولكن تم تصنيفها من قبل الخوارزمية على أنها إيجابية.
- **TN (True Negative)**: تمثل القيم السلبية والتي تم تصنيفها من قبل الخوارزمية على أنها سلبية.
- **FN (False Negative)**: تمثل القيم الإيجابية ولكن تم تصنيفها من قبل الخوارزمية على أنها سلبية.

وبناءً على القيم السابقة يمكن حساب المقاييس التالية [12]:

٢. Precision:

تعبر عن جزء التصنيفات الإيجابية المتوقعة بشكل صحيح True Positive من بين إجمالي البيانات

الإيجابية وفق الصيغة التالية:

$$Precision = \frac{|TP|}{|TP| + |FP|} \quad (4)$$

٣. Recall:

جميع من بين True Positive صحيح بشكل المتوقعة الإيجابية التصنيفات جزء عن يعبر
التالية الرياضية وفق العلاقة quality الجودة مقياس يمثل وهو للخوارزمية Positive الإيجابية التصنيفات

$$Recall = \frac{|TP|}{|TP| + |FN|} \quad (5)$$

٤. F-Measure:

الآتية بالعلاقة ويعطى Recall و Precision بين التوافق متوسط عن تعبر

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (5)$$

٥. Accuracy:

وهي تمثل قدرة نموذج التصنيف على توقع الفئة المستهدفة بشكل صحيح وتقاس بالنسبة المئوية وفق المعادلة:

$$Accuracy = \frac{|TP| + |TN|}{|TP| + |TN| + |FP| + |FN|} \quad (6)$$

٣-٥ الأدوات و البرمجيات المستخدمة: [6]

لغة البرمجة python:

هي لغة برمجة عالية المستوى وذات أهداف عامة وديناميكية وعالية المستوى تدعم نهج البرمجة غرضية التوجه لتطوير التطبيقات مثل تصميم النظم الذكية والخبرة وتصميم المواقع. تتمتع بالبساطة وسهولة التعلم كما توفر الكثير من هياكل البيانات عالية المستوى لذلك يتم استخدامها بالمرتبة الأولى في مجال الذكاء الاصطناعي والتعلم الآلي. تمتاز أيضاً بأن مصادرها متاحة مجاناً والتحديثات الخاصة بها متاحة ويمكنك الحصول عليها بسهولة، بالإضافة الى قابليتها للتكيف مع لغات البرمجة الأخرى.

Jupyter Notebook:

هي عبارة عن بيئة تفاعلية مفتوحة المصدر قائمة على الويب لتطوير وعرض مشاريع علوم البيانات بشكل تفاعلي حيث تسمح بإنشاء ومشاركة المستندات التي تجمع بين التعليمات البرمجية والنصوص والصور ومقاطع الفيديو والمعادلات الرياضية و المخططات والخرائط وواجهة المستخدم الرسومية وعناصر واجهة المستخدم في مستند واحد، ويأتي الاسم "Jupyter"، من لغات البرمجة الأساسية التي يدعمها وهي: Julia و Python و R.

مكتبة Scikit-learn (Sklearn):

هي إحدى مكتبات Python الخاصة بالتعلم الآلي تحتوي على الكثير من الأدوات الفعالة للتعلم والنمذجة الإحصائية بما في ذلك التصنيف والانحدار حيث تستخدم في بناء نموذج التعلم الآلي بالاعتماد على مجموعة من المكونات المميزة والتي تجعلها رائدة في هذا المجال نذكر منها:

• خوارزميات التعلم الخاضع للإشراف مثل Linear Regression, SVM, Decision Trees
• Bayesian methods .

• خوارزميات التعلم غير الخاضع للإشراف مثل clustering, factor analysis.

• Cross-validation: للتحقق من دقة النماذج الخاضعة للإشراف على البيانات غير المرئية

• استخراج الميزات Feature extraction من الصور والنص.

Natural Language Toolkit (NLTK):

مجموعة أدوات اللغة الطبيعية (NLTK) هي عبارة عن منصة تستخدم لبناء برامج بايثون التي تعمل مع بيانات اللغة البشرية للتطبيق في معالجة اللغة الطبيعية الإحصائية (NLP).

يحتوي على مكنبات معالجة نصوص للترميز، والتحليل، والتصنيف، والاشتقاق، والعلامات، والتفكير الدلالي. يتضمن أيضاً عروض توضيحية رسومية ومجموعات بيانات نموذجية بالإضافة إلى كتاب يشرح المبادئ الكامنة وراء مهام معالجة اللغة الأساسية التي يدعمها NLTK. هي مكتبة مفتوحة المصدر للغة بايثون تمت كتابتها في الأصل لاستخدامها في التطوير والتعليم.

٤ - النتائج والمناقشة:

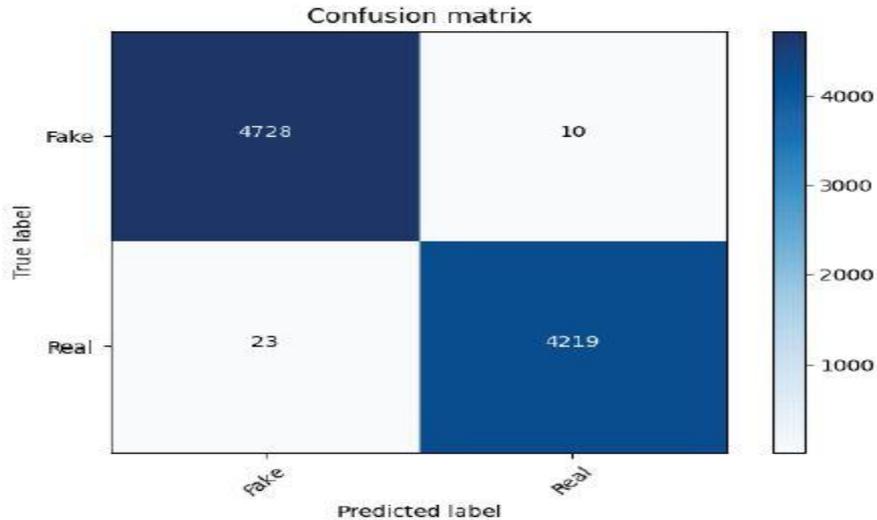
٤-١ مرحلة التدريب:

بعد الانتهاء من مرحلة معالجة البيانات ننقل إلى مرحلة التدريب و قبل البدء بتدريب الخوارزميات سيتم تقسيم مجموعة البيانات إلى مجموعتين رئيسيتين:

- Training Dataset: مجموعة التدريب تمثل 80% من حجم البيانات الكلي أي 35918 سجل.
- Testing Dataset: مجموعة بيانات الاختبار تمثل 20% من حجم البيانات الكلي أي 8980 سجل.

٤-٢ تطبيق خوارزمية شجرة القرار:

بعد تطبيق نموذج التصنيف الخاص بشجرة القرار على مجموعة بيانات التدريب تم قياس صحة و دقة الأداء باستخدام بيانات الاختبار و بالنتيجة حصلنا على مصفوفة الارتباك التالية:



الشكل (٣): مصفوفة الارتباك الناتجة عن تطبيق خوارزمية Decision Tree

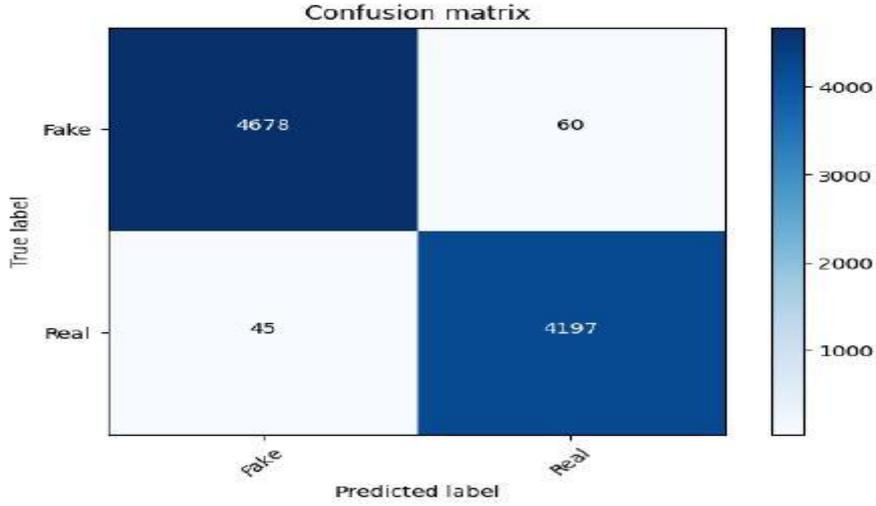
و يوضح الجدول (3) مقاييس الأداء للخوارزمية Decision Tree :

الجدول (٣): قيم معايير التقييم لنتائج خوارزمية Decision Tree

	TP	FP	TN	FN	Accuracy	Recall	Precision
Evaluation Values	4728	10	4219	23	90.64%	89.51%	88.78%

٤-٣ تطبيق خوارزمية Logistic Regression:

بعد تطبيق نموذج التصنيف الخاص بخوارزمية الانحدار على مجموعة بيانات التدريب تم قياس صحة و دقة الأداء باستخدام بيانات الاختبار و بالنتيجة حصلنا على مصفوفة الارتباك التالية:



الشكل (٤): مصفوفة الارتباك الناتجة عن تطبيق خوارزمية Logistic Regression

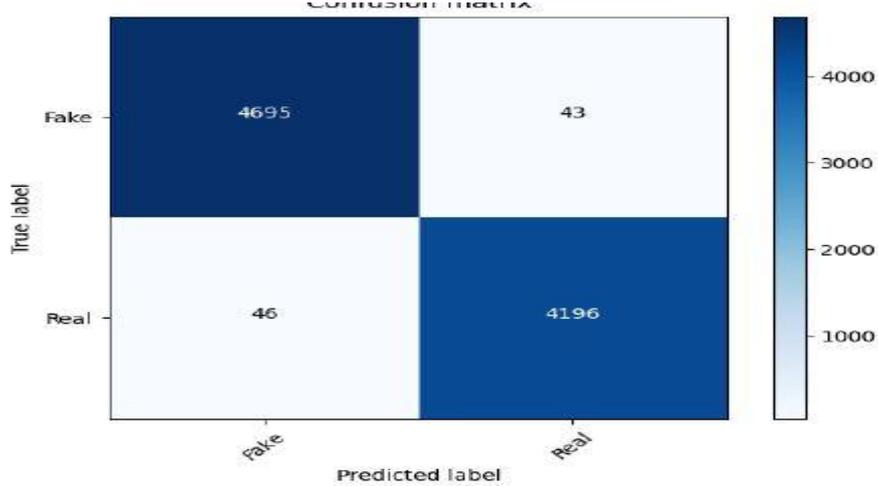
والتي نستنتج منها قيم التقييم التالية:

الجدول (٤): قيم معايير التقييم لنتائج خوارزمية Logistic Regression

	TP	FP	TN	FN	Accuracy	Recall	Precision
Evaluation Values	4678	60	4197	45	٨٥.83%	٨٥.04%	٨٤.73%

٤-٤ تطبيق خوارزمية الغابة العشوائية:

قمنا باختبار نموذج التصنيف الناتج عن تطبيق خوارزمية الغابة العشوائية على مجموعة بيانات الاختبار لنحصل على قيم التصنيف ممثلة ضمن مصفوفة الارتباك الناتجة التالية:



الشكل (٥): مصفوفة الارتباك الناتجة عن تطبيق خوارزمية Random Forest

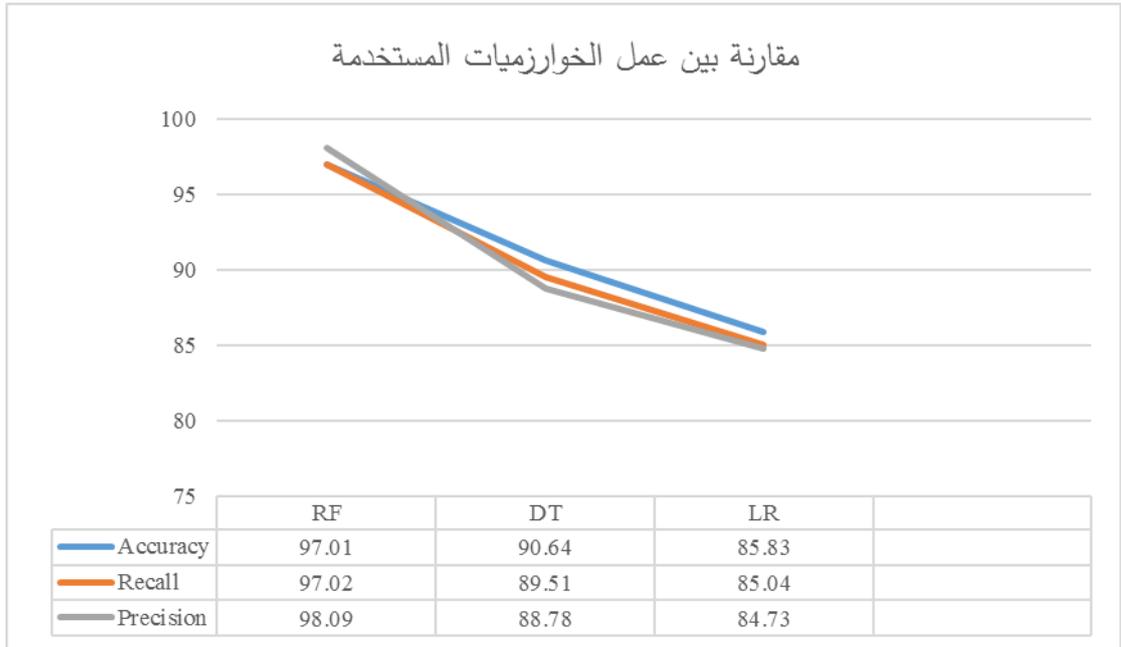
وبدراسة قيم مصفوفة الارتباك نستنتج قيم مقاييس التقييم الموضحة في الجدول التالي:

الجدول (٥): قيم معايير التقييم لنتائج خوارزمية Random Forest

	TP	FP	TN	FN	Accuracy	Recall	Precision
Evaluation Values	4695	43	4196	46	97.01%	97.02%	98.09%

نلاحظ من القيم في الجدول بأن الخوارزميات الثلاث حققت نسب دقة تصنيف مختلفة ووصل لأعلى قيمة لها عند دقة التصنيف لمصنف خوارزمية Random Forest بنسبة مرتفعة جداً وصلت إلى 97.01% .
ويمكننا أن نرى بشكل واضح بأن خوارزمية Random Forest قد حققت أعلى النتائج وذلك بفضل قدرة الخوارزمية على التعامل مع البيانات ذات العدد الكبير وقدرتها على الموازنة ضمن البيانات بشكل تلقائي وأيضاً تكمن قوة هذه الخوارزمية عن طريق تطبيق N شجرة قرار (تختلف كل شجرة عن الأخرى) وانتخاب التصنيف النهائي تبعاً لشجرات القرار.

ونلاحظ أيضاً بانخفاض كبير في خوارزمية Logistic Regression والسبب وراء هذا الضعف في الأداء بأن الخوارزمية السابقة تفترض تلقائياً وجود علاقة خطية بين متغيرات الدخل و متغير الخرج(الهدف) وهذا لا يوجد في مجموعة البيانات الخاصة بهذا البحث كونها مجموعة بيانات نصية.



الشكل (٦): مقارنة بين عمل الخوارزميات المستخدمة

٤- الخاتمة:

يسلط هذا البحث الضوء على المفاهيم والمبادئ الأساسية للأخبار المزيفة في وسائل التواصل الاجتماعي وعملية تحديد وكشف وتمييز المزيفة منها بالاعتماد على تقنيات ومبادئ الذكاء الصناعي والتعلم الآلي وبالأخص خوارزميات التنقيب في النصوص وتقنيات معالجة اللغات الطبيعية بغرض تحقيق نتائج تصنيف ممتازة من حيث دقة وجودة عملية التصنيف المنجزة ،حيث تم خلال هذا البحث التركيز على الأخبار النصية دون غيرها من أنواع الوسائط المنشرة على المنصات الالكترونية ووسائل التواصل الاجتماعي من مقاطع صوتية أو فيديو بالإضافة إلى النصوص، كما اقتصر الميزات على المرتبطة منها بخصائص النص.

سيكون نظام التصنيف الذكي المصمم خلال هذا البحث عامل فعال جداً في مرحلة ضبط والحد من الانتشار الواسع للأخبار المزيفة والشائعات على وسائل التواصل الاجتماعي والمنصات الالكترونية بكافة أنواعها، وبالتالي التقليل من الاثار السلبية الكبيرة المترتبة على عمليات التزوير والتضليل الالكتروني.

٥-التوصيات:

تم خلال هذا البحث التركيز على الأخبار النصية دون غيرها من أنواع الوسائط المنشرة على المنصات الالكترونية ووسائل التواصل الاجتماعي من مقاطع صوتية أو فيديو بالإضافة إلى النصوص، كما اقتصرتم الميزات على المرتبطة منها بخصائص النص.

من الأعمال المستقبلية الممكن القيام بها لتطوير هذا البحث توسيع حدوده لإدراج الأنواع الأخرى من الوسائط ضمن قاعدة البيانات وبالتالي زيادة عدد الميزات المدروسة لهذه البيانات. كما يمكننا تطبيق خوارزميات التعلم الآلي الاخرى واجراء عمليات تصنيف هذه البيانات إلى مزيفة أو حقيقية مع إجراء عمليات المقارنة المطلوبة.

٦ - المراجع:

- [1] Kumar, S., Kumar, S., Yadav, P., & Bagri, M. (2021, March). A survey on analysis of fake news detection techniques. In 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS) (pp. 894-899). IEEE.
- [2] Zubiaga, A., Aker, A., Bontcheva, K., Liakata, M., & Procter, R. (2018). Detection and resolution of rumours in social media: A survey. *ACM Computing Surveys (CSUR)*, 51(2), 1-36.
- [3] Shifath, S. M., Khan, M. F., & Islam, M. (2021). A transformer based approach for fighting COVID-19 fake news. *arXiv preprint arXiv:2101.12027*.
- [4] Burkart, N., & Huber, M. F. (2021). A survey on the explainability of supervised machine learning. *Journal of Artificial Intelligence Research*, 70, 245-317.
- [5] Helm, J. M., Swiergosz, A. M., Haeberle, H. S., Karnuta, J. M., Schaffer, J. L., Krebs, V. E., ... & Ramkumar, P. N. (2020). Machine learning and artificial intelligence: definitions, applications, and future directions. *Current reviews in musculoskeletal medicine*, 13(1), 69-76.
- [6] Kang, Y., Cai, Z., Tan, C. W., Huang, Q., & Liu, H. (2020). Natural language processing (NLP) in management research: A literature review. *Journal of Management Analytics*, 7(2), 139-172.
- [7] Sun, S., Luo, C., & Chen, J. (2017). A review of natural language processing techniques for opinion mining systems. *Information fusion*, 36, 10-25.
- [8] Kao, A., & Poteet, S. R. (Eds.). (2007). *Natural language processing and text mining*. Springer Science & Business Media.
- [9] Luo Xin, Xia De-lin, Yan Pu-liu. Feature selection based on word frequency difference and improved TF-DF formula [J]. *Computer Applications* ,2005,25(9):2031-2033.
- [10] Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M. (2019). Artificial neural networks-based machine learning for wireless networks: A tutorial. *IEEE Communications Surveys & Tutorials*, 21(4), 3039-3071.
- [11] Chowdhary, K. (2020). Natural language processing. *Fundamentals of artificial intelligence*, 603-649.
- [12] A.Botchkarev," Performance Metrics (Error Measures) in Machine Learning Regression, Forecasting and prognostics: Properties and Typology," *arXiv preprint arXiv: 1809.03006*, 2018-arxiv.org.