

استخدام الذكاء الاصطناعي في قياس كفاية وملاءمة ادلة الاثبات الالكترونية في عمليات التدقيق (الشبكات العصبية التلافيفية نموذج)

The use of artificial intelligence in measuring the adequacy and appropriateness of electronic evidence in auditing processes (convolutional neural networks as a model).

بوخالفي مسعود

جامعة غرداية - الجزائر

Boukhalfi.messaoud@univ-ghardaia.dz

تاريخ النشر: 2024/06/27

ورقلي وليد*

مخبر التنمية الإدارية للارتقاء بالمؤسسات الاقتصادية

جامعة غرداية - الجزائر

ouargli.walid@univ-ghardaia.dz

تاريخ الاستلام: 2023/11/25

تاريخ القبول للنشر: 2024/03/28

ملخص:

تعتبر الرقمنة أمراً حيوياً في الزمان الحالي، خاصة مع انتشار تطبيقات الذكاء الاصطناعي بشكل واسع، وهذا ما أدى إلى دفع الجميع نحو اعتماد هذه التقنيات في ظل الظروف الجديدة التي فرضتها الواقعية المعاصرة.. تهدف هذه الورقة البحثية إلى تحليل استخدام الذكاء الاصطناعي في قياس كفاية وملاءمة ادلة الاثبات، وتأثيره على أعمال التدقيق، سواء من حيث توفير المعلومات الدقيقة أو إمكانية الاعتماد عليها في اتخاذ القرارات الرشيدة في مجملها. وذلك من خلال بناء نموذج ذكاء اصطناعي قائم على خوارزمية *TEXT CNN* لقياس كفاية وملاءمة أدلة الاثبات، توصلت الورقة البحثية إلى ان الذكاء اصطناعي فعال في تحسين جودة أعمال التدقيق، وهو ما يسمح بإجراء تقييم أكثر دقة لكفاية وملاءمة البيانات المالية. الكلمات المفتاحية: أدلة الاثبات الالكترونية، الذكاء الاصطناعي، الشبكات العصبية التلافيفية، التدقيق. تصنيفات JEL: M42، O32.

Abstract:

Digitization is vital in the present time, especially with the huge spread of artificial intelligence applications. In this context, it has become very critical for everyone to adopt these technologies so as to keep up with the temporary circumstances. This research paper aims to analyze the use of artificial intelligence in measuring adequacy and appropriateness of evidence as well as its impact on audit practice, whether in terms of providing accurate information or in terms of the possibility of relying on it in making rational decisions through the construction of an artificial intelligence model that utilizes the *TEXT CNN* algorithm to measure the sufficiency and appropriateness of the evidence.

The paper concluded that artificial intelligence is effective in improving the quality of audit practice, leading to more precise valuations of the adequacy and relevance of financial statements.

Keywords: electronic evidence; artificial intelligence; Convolutional Neural Networks; Audit.

Jel Classification Codes: M42, O32.

* المؤلف المراسل.

استخدام الذكاء الاصطناعي في قياس كفاية وملائمة ادلة الاثبات الالكترونية في عمليات التدقيق (الشبكات العصبية التلافيفية نموذج)

1. مقدمة:

في الماضي القريب انتشرت بالولايات المتحدة الامريكية مجموعة من الفضائح المتعلقة بالمحاسبة والتدقيق، بدأت مع شركة Enron وانتشرت على نطاق واسع. حيث كان لمجموعة من العوامل المختلفة دورا مهيما في تشكيل تلك الفضائح بما في ذلك على سبيل المثال لا الحصر الممارسات الاحتمالية المرتبطة ببعض وظائف الأعمال الأساسية (التقارير المالية المحاسبة التدقيق، والرقابة الداخلية، التمويل، الإشراف، وحوكمة الشركات)، دون نسيان الضرر الناتج عن انتهاك المبادئ الأخلاقية مثل الدقة، الأمانة، الشفافية، الاستقلالية والمساءلة التي كانت واضحة أيضا، علاوة على ذلك هناك عملية تغير واضحة الأطر والمعالم حدثت في جميع أنحاء العالم فيما يتعلق بتكنولوجيا المعلومات والتحول الرقمي، أدت الى انفجار هائل في حجم البيانات وظهور ما يعرف بالبيانات الضخمة، التي اعتمد في تحليلها على الأنظمة الخبيرة والأجهزة الحاسوبية التي لديها القدرة العالية في معالجة الكم الكبير من العمليات خاصة في مجال المحاسبة والتدقيق.

ترتب على هذا التغير ولوج بيئة التشغيل الالكتروني التي اتسمت بتغيرات جوهرية في المستندات والبيانات التي يستخدمها المدقق في تنفيذ عملية التدقيق إذ أصبحت اغلب ادلة الاثبات إلكترونية في طبيعتها واصبح التعامل معها بالطرق التقليدية صعبا جدا خاصة في قياس كفايتها ودرجة ملائمتها، ونتيجة لهذا واجه المدققون وشركات التدقيق تحديات جديدة من أجل أداء تدقيق أكثر فعالية، واستجابة لهذا بدأت شركات التدقيق الاستثمار بشكل متزايد في تقنيات الذكاء الاصطناعي من اجل البحث عن افضل الطرق الممكنة التي تمكنها من قياس كفاية وملائمة ادلة الاثبات الالكترونية بفعالية وسرعة كبيرة.

1.1. مشكلة البحث:

انطلاقا مما سبق ذكره تتبلور معالم التساؤل الرئيسي لهذه الدراسة والذي يمكن صياغته كما يلي: ما فعالية استخدام الذكاء الاصطناعي في قياس كفاية وملائمة أدلة الاثبات الالكترونية في أعمال التدقيق؟

وللتعمق في هذه الدراسة والوصول إلى إجابة للإشكالية المطروحة قمنا بطرح الأسئلة الفرعية التالية:

- ما المقصود بأدلة الاثبات، وما آلية عمل والشبكات العصبية التلافيفية CNN؟
- ما هي توقعات تأثير الذكاء الاصطناعي على أعمال التدقيق؟
- هل الذكاء الاصطناعي قادر على توفير معلومات دقيقة وممكن الاعتماد عليها في اتخاذ القرارات الرشيدة؟

2.1. فرضيات الدراسة:

تستند هذه الدراسة إلى الفرضية التالية:

- تساهم خوارزمية الشبكات العصبية في تحديد الاختلاف (إن وجد) المسجل بشكل أكثر كفاءة وفاعلية؛
- يمكن لخوارزمية الشبكات العصبية ان تقضي على مشكل اختيار العينة؛
- تعد أساليب الذكاء الاصطناعي من الأدوات المنهجية المناسبة لتقييم موثوقية ادلة الاثبات.

3.1. أهداف الدراسة:

تصبو هذه الدراسة لتحقيق مجموعة من المقاصد أهمها:

- الوصول الي ادلة اثبات أكثر كفاية وملائمة؛

- الاسهام في ولوج بيئة التدقيق الذكي الذي يعتمد على تقنيات الذكاء الاصطناعي؛
- التقليل من مخاطر التدقيق فيما يتعلق باختيار العينة؛
- الوصول الى ادلة اثبات أكثر موثوقية يستند عليها المدقق في ابداء رايه الفني.

4.1. أهمية الدراسة

تتجلى أهمية الدراسة في تسليطها الضوء على استخدام اهم التقنيات الحديثة في مهنة التدقيق الذكي لمواجهة تحديات التحول الرقمي الذي طرأ على كل المجالات بدون استثناء، حيث تعتبر تكنولوجيا المعلومات أحد أهم الموارد التي تمتلكها الشركات اليوم وهي بمثابة الذهب الأسود في هذا القرن ولا يمكن لمهنة التدقيق تجاهل استخدامها، لهذا فقد بدأت الدراسات والأبحاث الكبرى في مجال التدقيق الى السعي وراء استخدام تقنيات ذكية تعتمد على الذكاء الاصطناعي وفروعه لتحليل المستندات والادلة للاستفادة منها ودعم التدقيق الذكي "Audit AI" لزيادة كفاءة أعمالها وتطوير المهنة والبقاء في مستوى تطورات العملاء وتحقيق ميزة تنافسية.

5.1. منهج الدراسة والأدوات المستخدمة

إن تحقيق البحث العلمي للإضافة العلمية التي يصبو اليها يعتمد بدرجة كبيرة على منهجية سليمة وواضحة، لذلك سنحاول من خلال هذه الدراسة الاعتماد على منهجية تأسيس النظرية (grounded theory reseach) في تقديم الادبيات النظرية التعاريف والمفاهيم المتعلقة بالموضوع كمفهوم ادلة الاثبات، الشبكات العصبية التلافيفية (CNN)،... وغيرها من المفاهيم التي تساعد على فهم الموضوع بصورة أفضل، ومنهجية البحث الاجرائي لبناء نموذج متكامل لقياس كفاية وملاءمة ادلة الاثبات الالكترونية باستخدام الشبكات العصبية (CNN)، أما فيما يخص الأدوات المستخدمة فقد تم الإطلاع على مجموعة من الكتب، والمجلات، إلى جانب البرامج المستخدمة في البرمجة مثل لغة بايثون، وبيئة جوبتير لإعداد نموذج لتعلم العميق يمكن تدريبه من اجل اكتشاف الأخطاء الأساسية المتعلقة بالموضوع وإيجاد بعض الحلول لإشكالية الدراسة.

2. الخلفية والادبيات ذات الصلة

لا يزال تدقيق المستندات الالكترونية وتحديد الثغرات التي يحتمل أن تزيد من محاولات الاحتيال فيها، قضية رئيسية في البيئة المحاسبية اليوم. وبالتالي لا يزال الكشف المسبق عن التجاوزات والوقاية منه يجذب اهتماما كبيرا من الباحثين من مختلف المجالات البحثية. تم تطوير المناهج البحثية والدراسات الأكاديمية وسن لوائح قانونية متنوعة ووضعها موضع التنفيذ من قبل السلطات لمراقبتها. وعلى الرغم من كل تلك الجهود المشتركة لا يزال فحص ادلة الاثبات الالكترونية لا يرقى للمستوى المطلوب. يهدف هذا المحور إلى تقديم تلخيص للخلفية والأدبيات المتعلقة بأدلة الاثبات الالكترونية والشبكات العصبية التلافيفية CNN لإعطاء الفكرة.

1.2. ادلة الاثبات

في الوقت الحاضر، تعد البيانات الضخمة واحدة من المفاهيم الشائعة والمستخدمه على نطاق واسع في نموذج تكنولوجيا المعلومات. حيث يقوم العديد من المستثمرين الآن بدمج هذه البيانات الضخمة مع مناهج تحليلية جديدة ومعقدة لتوليد الذكاء لاتخاذ القرار (Appelbaum et al., 2017, p. 1). يمكن لهذا السيناريو أن يغير بشكل أساسي عملية إعداد التقارير المالية من تقليدية الي الكترونية مغيرا معه في نفس الوقت الطريقة التي يتم بها إجراء عمليات التدقيق لهذه البيانات المالية الى ما يعرف بالتدقيق الذكي، وكذلك يؤدي إلى ظهور مجموعة من المخاوف الجديدة لدى مجتمع التدقيق هذه المخاوف تتمثل في عدم القدرة على جمع أدلة الاثبات لعملية التدقيق باعتبار ان البيئة الكترونية (Yoon et al., 2015).

2.1.1. تعريف أدلة الإثبات

إرتأينا قبل تحديد مفهوم أدلة الإثبات أن نعرج بداية على تقديم مفهوم الإثبات، والذي يقصد به في اللغة هو إقامة الحجة الدامغة وتأكيد الحق بالدليل على حقيقة امر مدعى به أو تأكيد الحق بالبينه. اما الإثبات في التدقيق هو عملية إقامة الدليل على صحة أو فساد البيانات التي تحويها القوائم المالية الختامية. وإقامة الدليل في المستندات الإلكترونية يعد تحديا كبيرا لأن المستخدمين يخفون المواقع المادية للبيانات عن العميل بمعنى الوصول المحدود للحقائق، ولا حقيقة بغير دليل. لذلك يكون الإثبات بالدليل ضرورة لا غنى عنها، وإلا يفقد خصائصه الأساسية ويتحول الى معتقدات إذا لم يصاحبه الدليل، او قد يتحول الى مجرد انطباع.

ويقصد بأدلة الإثبات حسب معيار التدقيق الدولي رقم "500" «المعلومات التي يستخدمها المراجع في التوصل الى الاستنتاجات التي يبني رايه على أساسها، وتتضمن كلا من المعلومات الواردة في السجلات المحاسبية التي تستند اليها القوائم المالية والمعلومات المتحصل عليها من مصادر أخرى» (الهيئة السعودية للمحاسبين القانونيين، 2020، ص 315). وتعرف بأنها كل « ما من شأنه ان يؤثر على حكم وتقدير المدقق فيما يتعلق بمطابقة ما عرض من معلومات مالية (عباس م يونس أكبر، 2019، ص 225). كما عرفت بأنها «كافة الحقائق والانطباعات التي يحصل عليها المدققون والتي تساعدهم في تكوين رأي معين عن حقيقة القوائم المالية محل الفحص» (لقويرة، 2019، ص 79).

في حين تم تعريف أدلة الأثبات الإلكترونية على أنها عبارة عن بيانات يتم إنشاؤها أو معالجتها من خلال أحد تطبيقات تكنولوجيا المعلومات أو حوسبة المستخدم (على سبيل المثال، Excel ، وأدوات مستودع البيانات مثل SQL) يعتمد عليها المدقق في دعم الرأي الذي يتوصل إليه في تقريره (Josiah & Izedonmi, 2013, p. 2).

2.1.2. مميزات أدلة الإثبات الإلكترونية:

حتى تحظى أدلة الإثبات الإلكترونية بالقبول يجب ان تتميز بمجموعة من الصفات نذكر منها:

❖ **الصدق والامانة:** يستند الى فكرة أساسية وهي المطابقة بين المعتقد والواقع، ويمكن الحصول عليه من ثبوت "القضية التركيبية" وفقا للمنطق الفلسفي المبني على دالة الصدق التي تحتوي على ثابت الوصل وثابت الفصل، فالصدق الذي تحققه الأدلة الإلكترونية بعدم التعارض مع الواقع هو (ثابت الوصل)، والاتساق مع المعلومات السابقة هو (ثابت الفصل)، وهو يتدرج بين الصدق الاحتمالي والصدق اليقيني وهما حدود الصدق الذي يهدف اليه المدقق من الإثبات. أما الأمانة فهي اكتمال المعلومات ودقتها وضممان أنه قد تم التحقق منها ولم يتم تغييرها أو إتلافها عن قصد أو عن طريق الخطأ عندما تم إنشاؤها أو معالجتها أو نقلها أو صيانتها أو تحقيقها (Josiah & Izedonmi, 2013, p. 4).

❖ **تأثيرها على العقل البشري:** تأثر أدلة إثبات الإلكترونية على العقل البشري وفق عاملين أساسيين هما:

— **العامل الأول:** ان بعض الإثباتات قوية اليقين وحيوية تلزم العقل البشري بقبولها كحقيقة حتمية، والتي يمكن قياسها بشكل موضوعي من خلال أدوات القياس، فضلا على ان الإثباتات الاقل حيوية وقوة ويمكن للعقل البشري ان يستقبلها ويتعلل بها وأن يأخذها بحسب تأثيرها بقبول او رفض القضية التي تعززها الإثباتات المقدمة او التي تم الحصول عليها. لذلك هناك اختلافات بين الإثباتات نفسها من حيث تأثيرها على عقل صانع الحكم. (Markina et al., 2021, p. 2390) سواء بالإقناع الكامل (المطلق)، الاقناع الإيجابي، أو الاقناع الحيادي الذي لا يقود الى الشك، ومما تجدر الإشارة اليه هنا ان الاقناع الكامل نادر في التدقيق.

– اما العامل الثاني: الذي يؤخذ في الحسابان من ناحية اختلاف التأثر على الحكم فهو درجة المهارة والتمرس لدى الشخص الذي يستخدم الاثباتات، فالمبتدئ في اي مجال يمكن ان يتلاعب به بسهولة، اما المتمرس صاحب النظرة فانه يصعب اقناعه فهو ينظر للإثباتات مع شكوكية صحية، فهو يرى أكثر مما تراه العين (التركيز مضاف). تعني عبارة "رؤية أكثر مما تراه العين" تشغيل عقل المرء المتسائل بشكل كامل لتحديد ما إذا كانت هناك أية تصريحات خاطئة أو تناقضات أو المخالفات المخفية في البيانات المالية والدفاتر والسجلات المحاسبية. بعبارة أخرى، يقوم المدقق بإجراء "اختبار الرائحة" للعثور على برهان لأي تضارب أو عدم انتظام بين أدلة المراجعة.

وبخصوص البرهان في التدقيق فان بيان مفاهيم التدقيق الاساسية تقوم على فكرة ان البرهان في التدقيق جوهريا هو استقرائي. وقد علق Toba على ذلك بالقول ان البرهان يتطلب التكوين المسبق للفرضيات الاولية موضوع البرهنة لغرض برهنة الفرضية النهائية التي توضح المعرفة الممكنة التي يمكن تحقيقها فعلا من قبل المدققين. وهذا يمكننا من فهم ان البرهان هو ايضا عبارة عن عملية التعلم او الحصول على المعرفة عن الفرضية النهائية. أما الاثبات فهو عملية الاقناع التي يحصل عليها المدقق من المعرفة المكونة عن الفرضية النهائية وان الاستنتاج الذي توصل اليه Toba من ذلك هو "ان الفشل في التمييز بين البرهان والاقناع يجعل من الصعب فهم طبيعة ممارسات التدقيق الفعلية" (Toba, 2011, p. 98.99).

❖ المصادقة: المصادقة في مجال أمن تكنولوجيا المعلومات هي نموذجاً للتحكم في الوصول وعملية إثبات ملكية الموضوع أو السيطرة على هوية معينة، عادة ما يتم ذلك استناداً إلى اسم المستخدم وكلمة المرور التي تمنح الأفراد إمكانية الوصول إلى كائنات النظام بناء على هويتهم بهدف الحفاظ على سرية البيانات وعدم الإنكار الأطراف الأفعال التي يقومون بها. إذا تم إنشاء المصادقة والتفويض والمحاسبة بشكل صحيح، فلا يمكن لأي شخص أن ينكر أفعاله، لأن خرق السرية قد يؤثر على المركز المالي للكيان (Josiah & Izedonmi, 2013).

يمكن أن تتضمن المصادقة العديد من الأشياء كما في حالة الشهادات الرقمية والسماح البيومترية من أجل منح سلطة الوصول الي البيانات فمثلا. المصادقة على أساس السمات البيومترية للمستخدم هي طريقة تحدد الأشخاص وتتعرف عليهم بناء على تميز سماتهم الحيوية مثل الصوت أو سمة جسدية مثل بصمة الإصبع أو التعرف على الوجوه أو التعرف على قرنية العين أو مسح شبكية العين.

❖ الصلاحية وسلطة الاعتماد: هو التأكد من أن المعلومات يتم إعدادها ومعالجتها وتعديلها وتصحيحها وإرسالها واستلامها والوصول إليها يتم عن طريق أشخاص مخولين ومسؤولين عن ذلك العمل.

❖ عدم التنصل والإنصاف: لا يمكن لأي طرف أو شخص أو كيان أرسل أو تلقى معلومات أن ينكر مشاركته في التبادل وأن ينكر محتوى المعلومات. استناداً على ما إذا كان هناك دليل قاطع لا يمكن دحضه على منشأ المعلومات الإلكترونية أو استلامها أو محتواها، فإنه يجب الاعتراف بمنشأ تلك المعلومات أو استلامها أو محتواها (Josiah & Izedonmi, 2013, p. 5).

2.3.1 طرق جمع أدلة الاثبات

تنقسم طريقة جمع الأدلة إلى نوعين أساسيين: الجمع النشط والجمع السلبي وفقاً لأغراض مختلفة، لكن من أجل أغراض التدقيق يجب الجمع بين الطريقتين النشطة والسلبية لتحقيق جمع كامل للأدلة القوية والأدلة الضعيفة في النظام، بما في ذلك معلومات الإنذار ومعلومات ملفات التسجيل ومعلومات حركة المرور (Yuan et al., 2019, pp 648, 649).

استخدام الذكاء الاصطناعي في قياس كفاية وملائمة ادلة الاثبات الالكترونية في عمليات التدقيق (الشبكات العصبية التلافيفية نموذج).

- ❖ **الجمع النشط:** الجمع النشط يعني أن البيانات الالكترونية يتم إرسالها إلى مركز تجميع البيانات أو مسؤول النظام بواسطة نظام المراقبة. يشير هذا النوع بشكل أساسي إلى جميع أنواع البيانات الالكترونية القوية، التي يتم إرسالها بصفة آلية إلى مسؤول خلية التدقيق عن طريق البريد، أو إرساله إلى نظام المصعب من خلال بروتوكول الإرسال.
- ❖ **الجمع السلبي:** ما يسمى بالجمع السلبي يعني أن وجهة نقل البيانات ليس بطريقة مباشرة، وإنما يتم الحصول عليها بطريقة غير محددة مسبقا. كأن يتم جمع البيانات الالكترونية في الملف على القرص ثم نقله إلى مركز تجميع البيانات أو مسؤول النظام، في هذا النمط يحتاج الجامع إلى معرفة ما إذا تم إنشاء بيانات جديدة في نهاية اليوم لتحديد ما إذا كانت البيانات الجديدة محينه فينظام المصعب ام لا.

2.2 الشبكات العصبية التلافيفية

ترتب على ظهور الكميات الهائلة من البيانات التي تتطلب التحليل والمعالجة في الوقت القياسي، استكشاف خوارزميات سريعة للتعامل مع أحجام البيانات الكبيرة جدا، مثل خوارزميات الشبكات العصبية التلافيفية Convolutional Neural Network (CNN) التي تملك ارتباط وثيق و دور فعال في الكثير من تطبيقات الذكاء الاصطناعي المتنوعة، والتي يمكنها القيام بمعالجة البيانات الغير مهيكلة مثل الصور والنصوص بأسلوب محاكاة العقل البشري. وهو ما ركز عليه الباحثين في مجال البرمجة لتحسين أداء نماذج التعلم العميق في ظل تحولات القائمة. هدفنا في هذا القسم هو توضيح هذه الفجوة الأدبية مع التركيز بشكل خاص على text CNN.

1.2.2. تعريف الشبكات العصبية التلافيفية

عندما نسمع للوهلة الأولى عبارة الشبكات العصبية التلافيفية يتبادر إلى أذهاننا مزيج بين علم الأحياء والرياضيات مع القليل من علوم الحاسب، ولكن في واقع الأمر هي بنية شبكة عصبية عميقة مستوحاة من القشرة البصرية للدماغ البشري والتي يمكنها تعلم الميزات الثابتة من مصفوفة الإدخال، بحيث تتفاعل مع كائنات العالم الحقيقي بنفس الطريقة التي يتفاعل بها النظام العصبي الطبيعي (البيولوجي) مع العالم الحقيقي، تم تطويرها في الأصل لمهام التعرف على الأنماط المرئية مثل الصور.

كما تم تعريفها من قبل فوكوشيما « على أنها سلسلة من طبقات الالتفاف وطبقات التجميع التي يتم فيها استخراج الميزات المهمة في الصورة باستخدام طوبولوجيا الصورة، أي الانزلاق فوق الصورة مكانيا » (Aswathy et al., 2021, P 4).

2.2.2. سمات الشبكات العصبية التلافيفية:

تتميز بثلاث سمات أساسية مقارنة بالشبكات العصبية الأخرى:

- ❖ **المجالات المحلية للاستقبال:** تتصل الخلية العصبية في الطبقة المخفية فقط بمجموعة فرعية من الخلايا العصبية في الطبقة التي تسبقها، بسبب هذا الاتصال المتناثر، فإن كاشف الميزة الذي يشار إليه عادة بالنواة أو الفلتر قادر على تعلم الميزات ضمنيا، أي يمكن له تصور مجموعة الحواف أو النقاط الملونة ضمن الامتداد المكاني الذي نتج عن التوصيل المتناثر والذي يطلق عليه المجال الاستقبالي (Aloysius & Geetha, 2018, P 588).
- ❖ **التشارك في المعاملات (الاوزان):** معلمات الطبقة هي مجموعة من الفلترات أو النواة القابلة للتعلم. يتم تجميع هذه الفلترات مع خرائط الميزة لإنتاج خريطة تنشيط منفصلة ثنائية الأبعاد والتي عند تكديسها معا على طول بعد العمق

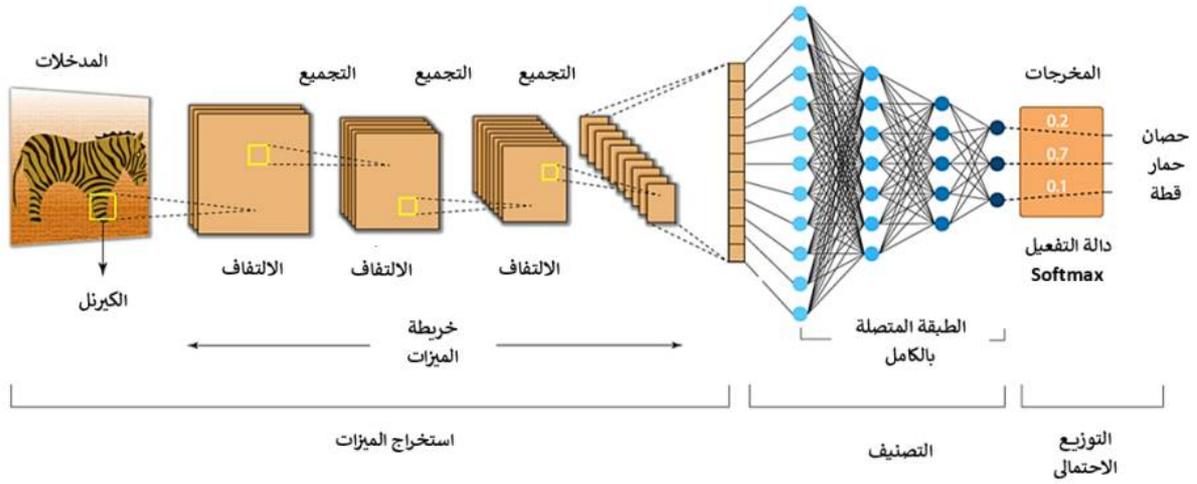
تنتج حجم الإخراج. تشترك الخلايا العصبية الموجودة في نفس خريطة الميزة في الوزن (مشاركة المعاملات) وبالتالي تقلل من تعقيد الشبكة عن طريق الحفاظ على عدد المعلمات منخفضاً (Vazan, 2022, P 121)

❖ التجميع: تقلل طبقة التجميع هذه الأبعاد المكانية للسّمات المستخرجة بواسطة طبقة الالتواء، تتمثل الأهمية الرئيسية لطبقة التجميع في أنها تقلل من الأبعاد دون فقدان المعلومات. يساعد التجميع أيضاً في التعميم وتقليل مشكلة فرط البيانات. يؤدي هذا إلى تقليل تعقيد الشبكة (Feddewar et al., 2022, P 150).

3.2.2. بنية الشبكات العصبية التلافيفية

هي واحدة من أكثر البنى استخداماً في استخراج الميزات الموجودة في الصور الرقمية، تتكون من طبقة إدخال مهمتها التعرف على ميزات معينة من خلال بكسلات الموجودة في الصورة وطبقة إخراج وظيفتها التصنيف بناءً على الخصائص المستخرجة في الخطوات السابقة (López et al., 2022, p. 2)، يمكن رؤية معماريتها العامة في الشكل رقم (01)

الشكل رقم (01) نظرة عامة عن هيكل الشبكة العصبية التلافيفية



❖ طبقة الالتفاف (الالتواء): تأتي بعد طبقة الإدخال وأهم لبنة في بناء شبكة عصبية تلافيفية تضم مجموعة من عوامل الالتفاف مهمتها استخراج الميزات الموجودة في المناطق المحلية لصورة الإدخال. الالتفاف هو وظيفة محورية لاستخراج الميزة، يحتوي على مزيج من الفلاتر يطلق عليها اسم الكيرنل (kernel) أو كاشفات السمات (المعالم)، الذي هو في الأساس يمثل مصفوفة صغيرة تنزلق على بيانات الإدخال ثنائية الأبعاد (الصورة)، وتقسّمها إلى أجزاء أصغر من الصور، يرتبط كل منها بجزء صغير يسمى هذا الجزء الضئيل مجال استقبالي، على سبيل المثال، إذا كان الإدخال إلى الشبكة عبارة عن صورة بحجم $(3 \times 64 \times 64)$ صورة ملونة RGB بأبعاد 64×64 (وقمنا بتعيين حجم الحقل الاستقبالي على 6×6 سيكون لدينا إجمالي من أوزان بقيمة 108 على كل خلية عصبية داخل الطبقة التلافيفية).

الطبقات التلافيفية قادرة أيضاً على تقليل تعقيد النموذج بشكل كبير من خلال توضيب مخرجاته باستخدام المعاملات الفائقة "العمق، الخطوة وضبط الحشوة الصفرية"، كما يمكننا أن نحدد الخطوة التي يتم فيها الانزلاق حول الأبعاد المكانية للمدخلات من أجل وضع المجال الاستقبالي. على سبيل المثال، إذا أردنا أن نحدد خطوة على أنها 1 فنسحصل على مجال استقبالي متداخل بشدة ينتج عنه عمليات تنشيط كبيرة للغاية. بدلا من ذلك، سيؤدي تعيين الخطوة وفق رقم أكبر إلى تقليل مقدار التداخل وإنتاج مخرجات ذات أبعاد مكانية أقل. ومع ذلك، عند إعداد نواة التفاف (الكيرنل) بحجم

استخدام الذكاء الاصطناعي في قياس كفاية وملائمة ادلة الاثبات الالكترونية في عمليات التدقيق
(الشبكات العصبية التلافيفية نموذج).

معين سنفقد المعلومات على الحواف ومن ثم، يتم إدخال الحشو (padding) لتكبير المدخلات بقيمة صفرية، وهي طريقة فعالة لإعطاء مزيد من التحكم في أبعاد أحجام الإخراج وعدم فقدان المعلومات على الحواشي. التمدد او العمق يتيح لطبقة الالتفاف أن يكون لها مجال استقبال أكثر كفاءة من الادخال مع الحفاظ على حجم النواة ثابتا، يتم الحصول على ذلك عن طريق إدخال المسافة D بين كل خلية من الكرينل. من المهم أن نستوعب أنه من خلال استخدام هذه التقنيات، سنقوم بتغيير الأبعاد المكانية لخرائط الميزات. لحساب هذا، يمكنك الاستفادة من الصيغة التالية:

$$(V - R) + 2Z$$

$$S + 1$$

حيث يمثل V حجم الإدخال (الارتفاع × العرض × العمق)؛

ويمثل R حجم الحقل المستقبلي؛

ويمثل Z مقدار مجموعة الحشو الصفرية؛

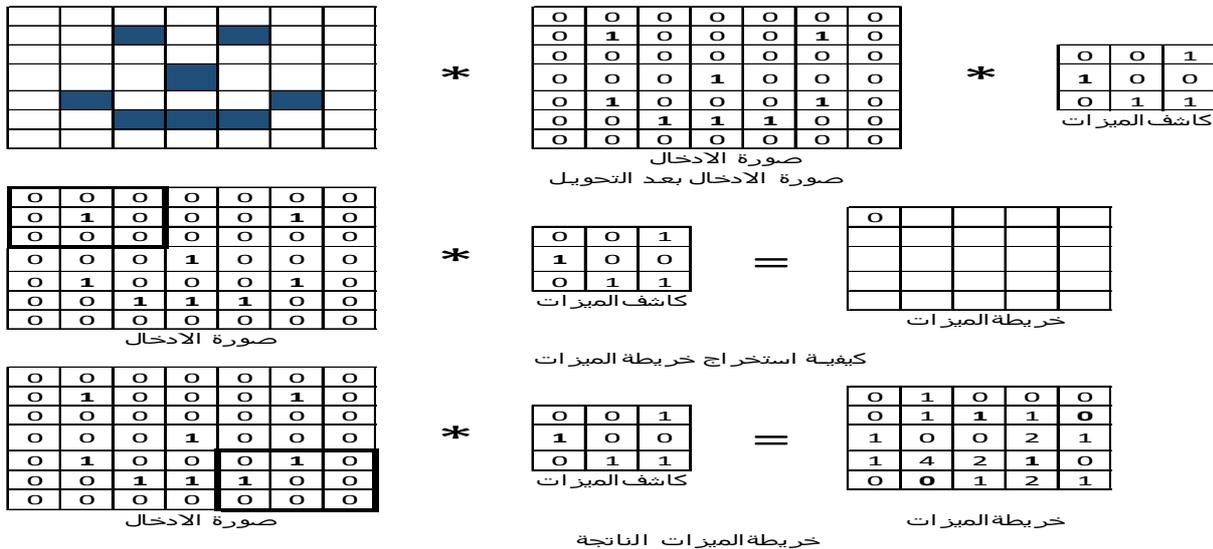
ويشير S إلى الخطوة.

إذا كانت النتيجة المحسوبة من هذه المعادلة لا تساوي عددا صحيحا كاملا، فسيتم تعيين الخطوة بشكل خاطئ،

حيث لن تتمكن الخلايا العصبية من التوافق بدقة عبر الإدخال المحد كما هو موضح الشكل رقم 02 (O'Shea & Nash,

2015, P 07)

الشكل رقم 02 عملية الالتفاف



المصدر: (Vazan, 2022)

❖ طبقة الدمج (التجميع): تقلل طبقة التجميع البعد المكاني لخرائط التنشيط (دون فقدان المعلومات) وعدد المعلمات في الشبكة وبالتالي تقليل التعقيد الحسابي الكلي. هذه العملية تساعد على التحكم في مشكلة فرط التجهيز وتسهل إستخراج الميزات المهمة والعالية المستوى للمدخلات من خريطة المعالم. توجد العديد من أنواع التجميع الشائعة أبرزها

التجميع الأقصى، والتجميع المتوسط، والتجميع العشوائي، والتجميع الطيفي، والتجميع الهرمي المكاني والتجميع غير المنظم متعدد المقاييس. (Aloysius & Geetha, 2018, P 581)

❖ طبقة المتصلة بالكامل: ترتبط الخلايا العصبية ذات الطبقة المتصلة بالكامل في هذه الطبقة بشكل كامل بجميع الخلايا العصبية في الطبقة السابقة، كما هو الحال في الشبكة العصبية العادية. يتم هنا تفكيك عالي المستوى. لا يتم ترتيب الخلايا العصبية مكانيا (بعد واحد) لذلك لا يمكن أن تكون هناك طبقة تحويل بعد طبقة متصلة بالكامل (O'Shea & Nash, 2015, P8) والتي يمكن أن تضبط الحجم بشكل غير مباشر، بمعنى آخر منع فقدان المعلومات في الحواشي .

3. بناء نموذج قياس كفاية وملاءمة المستندات المالية على أساس التدريب المسبق وTextCNN

من أجل مساعدة المدققين في الحصول على معلومات فعالة بخصوص كفاية وملاءمة أدلة الاثبات من كمية البيانات المالية الكبيرة في أسرع وقت ممكن، تم اقتراح نموذج للكشف عن صحة الشيكات المحررة عن طريق وسائط النظم المالية يعتمد على الشبكات العصبية، تم بناءه باستخدام التعلم العميق لإثراء المعلومات الموجود فوق الشيك.

1.3. تهيئة البيئة البرمجية ومعالجة البيانات

1.1.3. بيئة العمل

على الرغم من أن إعداد البيئة ليس عنصرا في أي لغة برمجة، إلا أنه الخطوة الأولى التي يجب توفرها قبل كتابة أي برنامج، عندما نقول إعداد البيئة، فهذا يعني ببساطة أننا نحتاج إلى تثبيت بيئة تطوير متكاملة على جهاز الكمبيوتر الخاص بنا يمكننا من خلالها القيام ببرمجتنا.

في ورقتنا هذه تم استعمال بيئة التطوير المتكاملة (anaconda) وهي برنامج لإدارة الحزم البرمجية يوفر أكثر من 250 حزمة مثبتة بشكل تلقائي ضمنه ويدعم تثبيت أكثر من 7500 حزمة أخرى مفتوحة المصدر، بالإضافة إلى حزمة conda وكذلك مدير البيئة الافتراضية (environment manager). ضمن هذه البيئة تم استعمال دفتر Jupyter الأداة مفتوحة المصدر القائمة على المستعرض التي تعمل كمفكرة افتراضية للمختبر لدعم سير العمل، والتعليمات البرمجية، مما يسهل التشغيل البيئي والتواصل الأكاديمي (Randles et al., 2017, p. 1).

لبناء TextCNN تم انتقاء Python 3.9 كلغة تطوير إذ تعتبر اللغة الأكثر شيوعا في التعلم العميق بسبب تركيبها البسيط ومكتبتها القوية. إلى جانب ذلك، تم تنفيذ النموذج بالاعتماد على TensorFlow 2.8.0 الذي يحتوي على مكتبة keras ضمنه، والتي تعتبر من أهم المكتبات في التعلم العميق Deep Learning، وقد صممت لتعطي مرونة وسهولة في تصميم الشبكات العصبية حيث يعرف المستخدم عدد الطبقات ونوعها وعدده متغيرات بكل يسر وسهولة ويبني معمارية الشبكة ويتنبأ، وتدعم المكتبة عدة أنواع من خوارزميات التعلم العميق منها الشبكات العصبية العميقة والانتقافية convolutional.

2.1.3 معالجة البيانات

في هذه الورقة البحثية، تم استخدام مجموعة بيانات تتألف من شيكات تم تحريرها باستخدام وسائط التكنولوجيا المالية وتم تخزينها في شكل ملفات PDF، بإتباع أسلوب يحاكي الواقع العملي الفعلي، (لم يتم استخدام شيكات حقيقية بسبب حساسية المعلومات التي تحتويها). في هذا السياق تم في الأول تحرير 250 شيك قسمت الي فئتين، الأولى تحتوي على 200 شيك محرر بطريقة صحيحة و50 محررة بصفة خاطئة عمدا للتدريب النموذج، بعد اجراء تجربة أولية تبين ان حجم

استخدام الذكاء الاصطناعي في قياس كفاية وملائمة ادلة الاثبات الالكترونية في عمليات التدقيق (الشبكات العصبية التلافيفية نموذج).

البيانات وشكلها غير صالح لاعطاء نتائج جيدة إذا قدم النموذج نسبة دقة قدرة بـ 73% وهامش خطأ 0.315، وهي نسب ضعيف جدا لا يمكن ان ترتقي لاعتماد النموذج.

استنادا لما سبق تجدر الإشارة إلى أن شكل وحجم البيانات المستعملة لأغراض البحث والتطوير في مجال المالية وتكنولوجيا المعلومات مهمة جدا. إذ يتطلب تطوير النماذج الحديثة في مجال المالية استخدام بيانات واقعية تشبه السيناريوهات الحقيقية لعمليات المالية، في هذا الصدد المعالجة المسبقة للنص خطوة لا غنى عنها لتحقيق التدريب، ولهذا ارتأينا القيام بالتحسينات التالية على البيانات:

- كأول خطوة كان يجب علينا اعتمادها هي مضاعفة حجم البيانات إلى 21000 نسخة الشيء الذي يسمح لنا بتحقيق نتيجة مرضية، ولهذا الغرض تم استخدام واحدة من أهم الأدوات المستخدمة في تحسين أداء نماذج التعلم العميق وهي دالة تحسين البيانات أو ما يعرف بـ "Augmentation Data" التي تستخدم لتعزيز وتوسيع مجموعة البيانات التدريبية المتاحة للنموذج، بدون الحاجة إلى جمع مزيد من البيانات الجديدة. تتمثل فكرة العمل في إجراء تعديلات صغيرة ومتنوعة على البيانات الأصلية لتوليد مجموعة جديدة من البيانات التي يمكن استخدامها لإنشاء نماذج تعلم أفضل وأكثر قدرة على التعميم generalize.
- بعد مضاعفة البيانات تم استخدام دالة extract_text_from_pdf ضمن مكتبة fitz لفتح ملف PDF واستخراج النصوص منه وتجميعها في فئات محددة ضمن جدول بتنسيق منظم عن طريق دالة create_table_from_folder، من أجل التمكن من معالجتها.
- كخطوة ثانية هي تحويل النص إلى سلسلة كلمات نظيفة مناسبة للتدريب والتأكد، تشمل المعالجة المسبقة للمحتويات تجزئة الكلمات وتطبيعها في توكنات صغيرة باستعمال دالة nltk.word_tokenize(). ثم تنظيفها بإزالة المسافات واستبدال الفاصلة، '!' عن طريق دالة str.replace، وغيرها من الكلمات المشوهة التي لا تحتوي على أي معلومات، وليس لها معنى عملي.
- كخطوة ثالثة تم استخدام دالة text_similarity(text1, text2) التي تستخدم لحساب نسبة التشابه بين نصين من مكتبة difflib والدالة SequenceMatcher().ratio() لحساب نسبة التشابه بين النصوص المعالجة في عمود "montantenlettre_processed" و "montantenmots_processed" وتخزينها في عمود "target" الذي يحتوي على قيمة "1" إذا كان هناك تشابه والقيمة "0" في حالة عدم التشابه، نتائج المعالجة تظهر في الشكل رقم (3).
- كخطوة أخيرة في هذا الجزء هي استخدام مكتبة scikit-learn لتقسيم البيانات إلى جزء تدريب وجزء للتأكد.

الشكل رقم (03): البيانات المستخلصة ومعالجتها

Jupyter checks validity prediction model Dernière Sauvegarde : vendredi dernier à 00:04 (auto-sauvegardé) Python 3 (ipykernel)

File Edit View Insert Cell Kernel Help Non fiable Python 3 (ipykernel)

Entrée [7]:

```
print(df_train_csv.shape)
print(df_test_csv.shape)
df_test_csv.head(4000)
```

(10531, 10)
(2633, 10)

Out[7]:

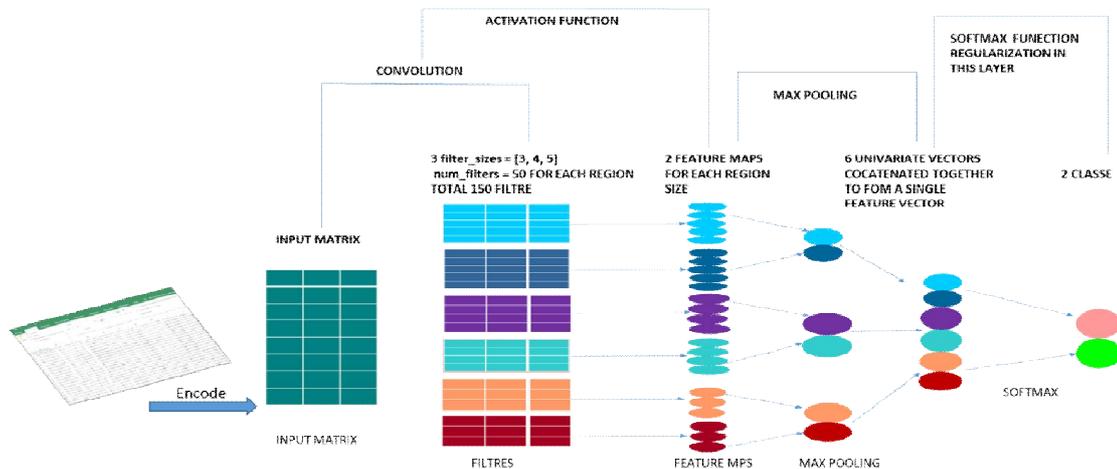
	date de cheque	fournisseur	lieu	montant de cheque	montant en lettre	numero de cheque	montant en mots	montant en lettre_processed	montant en mots_processed	target
0	14/04/2023	SPA EPE DIDO	ALGER	451216.20	quatre cent cinquante et un mille deux cent se...	2523516	quatre cent cinquante et un mille deux cent se...	['quatre', 'cent', 'cinquante', 'et', 'un', 'mille', 'deux', 'cent', 'se...']	['quatre', 'cent', 'cinquante', 'et', 'un', 'mille', 'deux', 'cent', 'se...']	1
1	19/05/2023	EURL SIDIBO	ALGER	45784.60	Quarante Cinq Mille Sept Cent Quatre Vingt Qua...	2523627	quarante cinq mille sept cent quatre vingt qua...	['quarante', 'cinq', 'mille', 'sept', 'cent', 'quatre', 'vingt', 'qua...']	['quarante', 'cinq', 'mille', 'sept', 'cent', 'quatre', 'vingt', 'qua...']	0
2	23/03/2023	EURL DIDO	ALGER	4584500.26	Quatre Millions Cinq Cent Quatre Vingt Quatre ...	2523570	quatre millions cinq cent quatre vingt quatre ...	['quatre', 'millions', 'cinq', 'cent', 'quatre', 'vingt', 'quatre', 'mille', 'deux', 'cent', 'se...']	['quatre', 'millions', 'cinq', 'cent', 'quatre', 'vingt', 'quatre', 'mille', 'deux', 'cent', 'se...']	0
3	28/04/2023	EURL DIDO	ALGER	9512036.00	Neuf Millions Cinq Cent Douze Mille Trente Six...	2523606	neuf millions cinq cent douze mille trente six...	['neuf', 'millions', 'cinq', 'cent', 'douze', 'mille', 'trente', 'six', 'cent', 'se...']	['neuf', 'millions', 'cinq', 'cent', 'douze', 'mille', 'trente', 'six', 'cent', 'se...']	1
4	13/03/2023	EURL TIANO	ALGER	256030.00	Deux Cent Cinquante Six Mille Dinar Algerien	2523710	deux cent cinquante six mille trente Dinar Alg...	['deux', 'cent', 'cinquante', 'six', 'mille', 'trente', 'dinar', 'algerien', 'deux', 'cent', 'se...']	['deux', 'cent', 'cinquante', 'six', 'mille', 'trente', 'dinar', 'algerien', 'deux', 'cent', 'se...']	0
...

المصدر: مخرجات النموذج المقترح.

2.3. هيكل النموذج

في هذا النموذج، تم استخدام TextCNN باعتبارها خوارزمية فعالة لمهام تصنيف النص القصير، ولأدائها الواعد TextCNN خوارزمية تتمتع بإمكانيات الحوسبة الموازية لـ CNN من سرعة في التدريب وقدرة عالية في الحفاظ على خصائص CNN الأصلية، علاوة على هذا فهي تستخدم الإلتواء الأحادي البعد للحصول على العلاقات الدلالية بين الكلمات، آلية الانتباه الذاتي في النموذج قادرة على استخراج ميزات النص الضحل، مما يحسن قدرة النموذج على تفسير والتنبؤ. بالمقارنة مع شبكة CNN التقليدية للصورة، معمارية textCNN تم توضيح إطار منهجيتها في الشكل رقم (4).

الشكل رقم (4): معمارية text CNN المعتمدة في النموذج.



المصدر: مخرجات النموذج المقترح.

1.2.3.1. الطبقة الأولى: طبقة الإدخال (Input Layer)

هي الطبقة الأولى في النموذج، تم استخدامها لتلقي البيانات المدخلة. يمكن إعتبارها واجهة النموذج التي تسمح للبيانات التي تم استخراجها وتجهيزها مسبقا بالتدفق من ملف csv إلى النموذج لمعالجتها بنزع الفراغات واستبدال الفواصل. بعد ذلك تأتي مرحلة التجزئة إلى كلمات (Tokenization) وهي الخطوة التي تقوم فيها طبقة الإدخال باستلام النصوص وتحويلها إلى تمثيل رقمي (يتم تمثيل كل جملة أو كلمة برقم محدد وفقا لفهرس الكلمات (Word Index) المستخدم من قبل المحول) باستخدام المحول (Tokenizer) في النموذج.

2.2.3. طبقة التضمين (Embedding Layer)

هذه الطبقة مسؤولة عن تحويل الكلمات في النصوص إلى تمثيلات رقمية (متجهات حقيقية) منخفضة الأبعاد، (لأنه عندما تكون المفردات كبيرة يمكن أن تكون مصفوفات الوزن المقابلة هائلة مما يحول دون نشرها في بيئة محدودة الموارد...)، وتستخدم هذه التمثيلات لتعلم النموذج عن السياق والعلاقات بين الكلمات. يتم تحديد حجم الأبعاد المطلوب للتمثيل بواسطة المتغير `Embedding_dim` في هذا النموذج، سيتم تمثيل الكلمات باستخدام تضمين بحجم 100، وهو يساعد النموذج على التعامل مع الكلمات بشكل جيد واستخلاص معانيها..

3.2.3. طبقات الالتواء (الالتفاف) (Conv1D Layers)

تستخدم هذه الطبقات لاكتشاف الأنماط والميزات في النصوص باستخدام العمليات التحويلية ثنائية الأبعاد. يتم تحديد حجم النواة (kernel size) باستخدام قائمة `filter_sizes` التي سيتم استخدامها في طبقات التصفية في النموذج. هنا، يتم استخدام أحجام التصفية [3, 4, 5]، مما يعني أن النموذج سيكون قادرا على اكتشاف الأنماط المكونة من 3 كلمات، و4 كلمات، و5 كلمات في النص. وتحديد عدد النوى (number of filters) التي تم استخدامها لاكتشاف الملامح والأنماط المميزة في النص باستخدام المتغير `num_filters` المقدر بـ 50 فلترا. في النموذج تم استخدام كذلك 14 طبقة الالتفاف لزيادة قدرة النموذج على استخراج المزيد من الميزات من النصوص.

4.2.3. طبقة التجميع القصوى (Global MaxPooling1D Layer)

بعد طبقات التصفية، يتم استخدام هذه الطبقة لتقليل الأبعاد من النتائج. تستخدم هذه العملية لاختيار القيمة القصوى في كل قناة (كلمة) من نتائج طبقات التصفية. هذا يساعد في تقليل حجم البيانات وتركيز الميزات الهامة فقط. ميزة أخرى لهذا هي أننا إذا لم نضع الجملة من قبل، فإن طول الجملة يكون مختلفا، كما أن أبعاد متجه العمود التي تم الحصول عليها بعد الالتواء مختلفة أيضا. يمكن استخدام التجميع لإزالة الاختلاف في الطول بين الجمل.

5.2.3. طبقة التساقط (Dropout Layer)

تم استخدام طبقة التساقط لتجنب التحفظ الزائد وتحسين عمومية النموذج. تعمل طبقة التساقط عند التدريب على إيقاف تشغيل بعض وحدات النموذج بشكل عشوائي، مما يساهم في تقليل التعلم المبالغ فيه وزيادة قدرة العمومية.

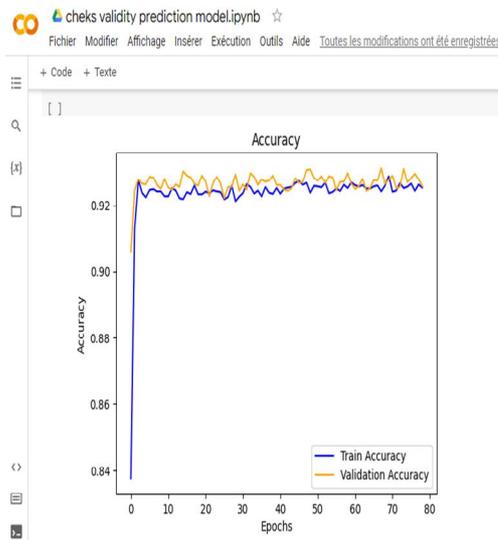
6.2.3. طبقة متصلة بالكامل (Fully-Connected Layer)

هذه الطبقة تحتوي على الوحدات النهائية التي تقوم بتصنيف النصوص النهائي. يتم تحديد عدد الوحدات في هذه الطبقة بواسطة المتغير `num_classes` في النموذج. كما تستخدم الدالة (Sigmoid) كدالة تنشيط للحصول على نتائج تصنيفية للفئتين.

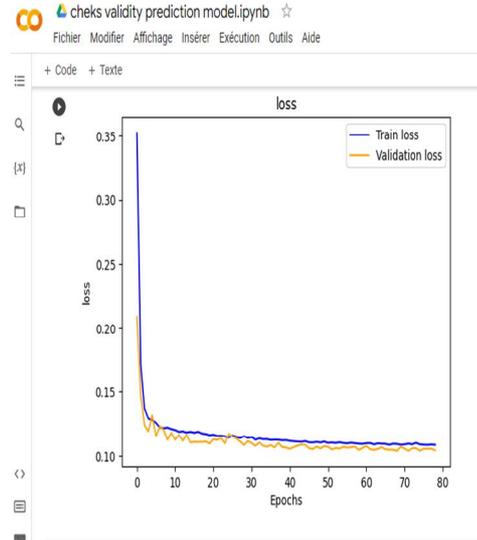
3.3. التقييم والملاحظات نتائج التدريب

من أجل العثور على أفضل نموذج يمكن اعتماده للتنبؤ بمدى كفاية وملاءمة ادلة الاثبات (يمكن اعتماده لقياس صلاحية الشيكات من عدمه)، أجرينا العديد من التجارب وقمنا بانتقاء افضل نموذج text CNN استنادا لافضل معدل دقة ونسبة خطأ كما يظهر في الشكل رقم (05).

الشكل رقم (05): نتائج التدريب والتحقق.



val Accuracy: 0.9274592



val Loss: 0.10888

المصدر: مخرجات النموذج المقترح.

بعد تنفيذ التدريب والتحقق من النموذج TextCNN على مجموعة من البيانات المقسمة إلى 80% تدريب و 20% إختبار وحجم دفعة 32 ومعدل تعلم 0.001 وفقا للقيمة الافتراضية الواردة ضمن حيد من آدم، حصلنا على نتائج مذهلة. تم تحقيق دقة (Accuracy) بنسبة 92.74% وهامش خطأ على مجموعة البيانات الاختبارية. هذه الدقة المرتفعة تدل على قدرة النموذج على التعامل مع التحديات المتعلقة بتصنيف الشيكات وتحليلها بدقة عالية. علاوة على ذلك تم تحقيق قيمة جيدة للـ Loss قدرة بـ 0.10888.

1.3.3. تقييم الأداء

بمجرد الانتهاء من بناء النموذج الخاص بنا، فإن السؤال الأكثر أهمية الذي يطرح نفسه هو ما مدى جودة النموذج الخاص بنا؟ لذا، فإن تقييم النموذج الخاص بنا هو أهم مهمة في الورقة البحثية من "مدى جودة تنبؤاتك" ❖ مقاييس التقييم: بعد تقديم جميع الملفات الجديدة (التي لم يسبق له وان رآها) لنموذج لتنبؤ بصحتها من عدمها، نتحقق من الدقة والأداء بناء على بعض المعلمات مثل الدقة والاستدعاء ودرجات F-1 ومصفوفة الارتباك (accuracy, precision, recall, and F-1 scores, confusion matrix).

❖ مصفوفة الارتباك confusion matrix: هي مصفوفة لتقييم أداء نموذج التنبؤ، تعتمد على مقدار التخمينات الصحيحة والغير الصحيحة التي يتم تلخيصها باستخدام قيم العد وحسب كل فئة. على الرغم من أنه من السهل فهم المعلمة المستخدمة، إلا أنها محيرة (Tasnim et al., 2022, p. 10). فيما يلي مصفوفة الارتباك:

استخدام الذكاء الاصطناعي في قياس كفاية وملائمة ادلة الاثبات الالكترونية في عمليات التدقيق (الشبكات العصبية التلافيفية نموذج).

الشكل رقم (06): مصفوفة الارتباك.

		Predicted class	
		Class = Yes	Class = No
Actual Class	Class = Yes	True Positive	False Negative
	Class = No	False Positive	True Negative

TP (موجب حقيقي) يعني التنبؤ بالعينات الإيجابية على أنها إيجابية، ويعني TN (سليبي حقيقي) التنبؤ بالعينات السلبية على أنها سلبية، ويعني FP (إيجابي كاذب) التنبؤ بالعينات السلبية على أنها إيجابية، ويعني FN (سليبي كاذب) التنبؤ بالعينات الإيجابية على أنها سلبية.

❖ مقاييس الدقة (Precision): تخبرنا عن عدد الحالات التي تم التنبؤ بها بشكل صحيح والتي تبين أنها إيجابية. تحدد هذه المقاييس ما إذا كان النموذج موثوقا أم لا، تحسب وفق الصيغة التالية:

$$\text{Precision} = \frac{TP}{TP + FP}$$

❖ مقاييس الاسترجاع (Recall): تظهر عدد الحالات الإيجابية حقا التي يمكن توقعها بشكل صحيح باستخدام النموذج وتحسب وفق الصيغة التالية:

$$\text{Recall} = \frac{TP}{TP + FN}$$

❖ درجة F1 (F1-score): تعطينا F1 فكرة مجمعة حول الدقة ومقاييس الاسترجاع. هذا يعني أنه عندما نحاول ترقية قيمة الدقة Recall تنخفض والعكس صحيح وتحسب وفق الصيغة التالية:

$$F1 \text{ score} = \frac{1}{N} \sum 2 \frac{PRECISION * RECALL}{PRECISION + RECALL}$$

❖ الدقة (Accuracy): الدقة هي جزء التنبؤات الصحيحة والتنبؤات الإجمالية التي يقوم بها المصنفون وتحسب وفق الصيغة التالية:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

2.3.3. النتائج:

استندت قويمنا بالكامل على 8 شيكات قدمت للنموذج للتنبؤ بدرجة كفايتها وملائمتها، حيث كانت النتائج كما هو

موضح أدناه:

الشكل رقم (06) نتائج التنبؤ المختلفة.

```

jupyter checks validity prediction model Dernière Sauvegarde : 14/07/2023 (auto-sauvegardé)
File Edit View Insert Cell Kernel Help Non fiable Python 3 (ipykernel)
[link_data] Package punkt is already up-to-date

Updated table with target column saved to: C:/Users/comptabilite dps/Desktop/target2.csv
'numero de cheque': 2523500
Extracted Text - Montant en Lettre:
Cent Vingt Cinq Mille Six Cent Trente Six Dinar Algerien Trente Centime
Extracted Text - Montant de Cheque:
125636.3

Prediction:
شيك صحيح

'numero de cheque': 2523510
Extracted Text - Montant en Lettre:
Six Millions Cinq Cent Trente Neuf Mille Deux Cent Trente Et Un Dinar Algerien Vingt Centime
Extracted Text - Montant de Cheque:
6539231.2

Prediction:
شيك صحيح

'numero de cheque': 2523510
Extracted Text - Montant en Lettre:
Six Dinar Algerien Vingt Centime
Extracted Text - Montant de Cheque:
9128001.2

Prediction:
شيك خاطئ

'numero de cheque': Zhjkhkj
Extracted Text - Montant en Lettre:
quatre millions sept cents mille dinar algerien
Extracted Text - Montant de Cheque:
4700000.0

Prediction:
شيك خاطئ

'numero de cheque': 2784986
Extracted Text - Montant en Lettre:
quatre cent cinquante mille dinar algerien
Extracted Text - Montant de Cheque:
59000.0

Prediction:
شيك خاطئ

'numero de cheque': 2926536
Extracted Text - Montant en Lettre:
cinq cent soixante huit mille quatre cents dinar algerien
Extracted Text - Montant de Cheque:
568400.0

Prediction:
شيك صحيح

'numero de cheque': 2968789
Extracted Text - Montant en Lettre:
Cinq Millions Quatre Cent Quatre Vingt Six Mille Deux Cent Cinquante Trois Dinar Algerien
Extracted Text - Montant de Cheque:
5486253.0

Prediction:
شيك صحيح

'numero de cheque': 2784596
Extracted Text - Montant en Lettre:
trois cent vingt cinq mille dinar algerien
Extracted Text - Montant de Cheque:
195200.0

Prediction:
شيك خاطئ

```

المصدر: مخرجات النموذج المقترح.

استخدام الذكاء الاصطناعي في قياس كفاية وملائمة ادلة الاثبات الالكترونية في عمليات التدقيق
(الشبكات العصبية التلافيفية نموذج).

وفقا لنتائج الظاهرة أعلاه تم جدول مصفوفة الارتباك المحددة أدناه في الشكل 7:

confusion matrix								
NUM OF SHIKS	ChN° 2523500	ChN° 2523510	ChN° 2523510	ChN° 2hjkhkj	ChN° 2784986	ChN° 2926536	ChN° 2968789	ChN° 2784596
PREDACTED	TRUE	TRUE	FALSE	FALSE	FALSE	TRUE	TRUE	FALSE
CLASS- PRED	TP	TP	TN	TN	TN	TP	TP	TN

المصدر: مخرجات النموذج المقترح.

الجدير بذكر ان نموذج التنبؤ المقترح الخاص بنا يحقق أفضل أداء حيث كانت نتائجه على النحو التالي = accuracy = 100%، precision = 100%، Recall = 100%، F-1 scores = 100% من النتائج، يمكننا أن نرى أن التنبؤات بصحة الشبكات من عدمها تصل إلى 100%؛ وهذا راجع لدمج التلايف أحادية البعد لشبكة CNN التي تعزز التركيز المحلي للميزات وتحسن تماسك الميزات المجمعة لجزء من النص وهو ما يؤدي إلى تمثيل دلالي أكثر فعالية وقدرات عالية على التنبؤ.

4. المناقشة:

في بداية البحث قمنا بطرح مجموعة من الفرضيات بالبحثية والتي كانت كالتالي :

- تساهم خوارزمية الشبكات العصبية في تحديد الاختلاف (إن وجد) المسجل بشكل أكثر كفاءة وفاعلية؛
- تعد أساليب الذكاء الاصطناعي من الأدوات المنهجية المناسبة لتقييم موثوقية ادلة الاثبات.

بناء على النموذج الذي تم بنائه، فإن استخدام الذكاء الاصطناعي فعال في تحسين جودة أعمال التدقيق. بالنظر إلى حجم البيانات الكبيرة، يمكن لذكاء الاصطناعي تحليل حجم هائل من البيانات لمساعدة المدقق على تحديد الخطأ والغموض وكذلك اتخاذ القرار الصائب، علاوة على ذلك يمكن لذكاء الاصطناعي أداء الأعمال المتكررة والمستهلكة للوقت في ظرف قياسي مما يسهل عمل المدقق ويرفع من كفاءته. ويقلل الجهد اليدوي المبذول في تحليل دفتر الأستاذ أو المستندات المالية بالإضافة لتكلفة المراجعة، في نفس السياق يتوقع المدققون الأصغر سنا في المناصب الدنيا أن يكون للذكاء الاصطناعي تأثير أكبر على عملهم من المدققين الأكبر سنا في المناصب العليا. هذا أمر منطقي بالنظر إلى سرعة تطور الذكاء الاصطناعي والمدة التي يمكن أن يتوقعها الموظفون الأصغر سنا للبقاء في سوق العمل، الخوف من فقدان الوظيفة هو أيضا أحد الأسباب التي يهابها المدققين الأكبر سنا؛ لأن بعض المهام البشرية سيتم تنفيذها بواسطة الذكاء الاصطناعي مستقبلا. رغم ذلك، يجب اعتبارها فرصة وليست تهديدا لانهلا يمكننا الاعتماد فقط على التكنولوجيا القائمة على الذكاء الاصطناعي دون القوة البشرية لأن النظام الذي لا يحتوي على صيانة أو إشراف سيتعرض لاختلال وظيفي يؤدي بدوره إلى خسائر كبيرة. لذلك لزيادة جودة أعمال التدقيق يمكن أن يكون استخدام خبير بالإضافة إلى الذكاء الاصطناعي مفيدا.

أما فيما يخص السؤال الثاني فإن جمع الأدلة وإثبات البيانات المالية أثناء مرحلة التدقيق فإن النموذج يقدم مزايا جد هائلة في دقة التنبؤ والتقييمات الدقيقة، لا سيما في تقييم الأهمية النسبية. وهو ما يسمح بإجراء تقييم أكثر دقة واستمرارا لأهمية البنود في البيانات المالية. بالإضافة لهذا فإن الشبكات العصبية كأداة لتقييم المخاطر تعتبر أكثر منهجية وثباتا، ويمكن أيضا تطبيقها على اكتشاف الأخطاء والاحتيال، إذ يمكن تدريب الشبكات العصبية لاكتشاف الانحرافات

والأنماط التي تشير إلى أنشطة احتيالية محتملة في البيانات المالية. من خلال التعلم من حالات الاحتيال التاريخية والمعاملات غير الاحتيالية، يمكن لـ CNN تحديد المعاملات المشبوهة أو السلوكيات غير العادية أو الأنماط غير المنتظمة التي قد تتطلب مزيداً من التحقيق، علاوة على هذا يمكن استخدامها للتنبؤ بالضائقة المالية والتنبؤ بالإفلاس بناء على البيانات التاريخية والمتغيرات ذات الصلة. يمكنهم التعلم من الأنماط والعلاقات في البيانات المالية لإنشاء توقعات للمقاييس المالية الرئيسية مثل الإيرادات والمصروفات والربحية. يمكن أن يساعد ذلك في الميزانية والتخطيط المالي وعمليات صنع القرار وتشكيل آراء تدقيق مستمرة. من المهم ملاحظة أنه قد تتطلب المخرجات خبرة في المجال لضمان الفهم المناسب واتخاذ القرار.

باختصار، تظهر نتائجنا أن استخدام الذكاء الاصطناعي في التدقيق يمكن من:

- أتمتة عملية تقييم الرقابة، بما في ذلك جانب صنع القرار من خلال تنفيذ الأتمتة يمكن تبسيط تقييم الضوابط وجعله أكثر كفاءة، مما يقلل العبء على المراجعين البشريين.
- تضمين تقييم الضوابط كجزء لا يتجزأ من تصميم النموذج سيمكن هذا التكامل من المراقبة في الوقت الحقيقي وتقييم الضوابط، وتعزيز فعالية واستجابة النموذج.
- يمكن للتكنولوجيا القائمة على تطبيق الذكاء الاصطناعي أن تحلل سجلات المحاسبة بدقة، وإنشاء عناصرها الأساسية في تقرير خاص مثل تاريخ الإصدار، وتاريخ الاستلام، وتاريخ الترحيل، والمبلغ الإجمالي، والشروط الخاصة، والسلف والعقوبات...إلخ.
- استخلاص استنتاجات ونتائج أولية في تحديد المخالفات في السجلات المحاسبية، مثل الفجوات الكبيرة أو التطرف أو المبالغ المتشابهة جداً.

5. الخاتمة:

مع إنتشار الثورة الرقمية. من المعتقد أن مهنة التدقيق يجب أن تتطور من أجل البقاء وتلبية احتياجات بيئة الأعمال المتغيرة، قد تكون أتمتة إجراءات التدقيق هي الأنسب. خاصة إذا تم استعمال تقنية الذكاء الاصطناعي في التدقيق وتطبيقها في تحليل الكميات الكبيرة من البيانات واستخلاص استنتاجات أولية مبنية على معايير محددة. هذه الطريقة في استخلاص النتائج الأولية، من خلال تطبيق تقنية الذكاء الاصطناعي تقلل من مستوى الذاتية في حكم المدقق وتزيد من موثوقية نتائج التدقيق وتخفف من أخطاء التدقيق أو تقضي عليها بشكل كبير. يمكن للتكنولوجيا القائمة على تطبيق الذكاء الاصطناعي استخراج المعلومات النصية الأساسية وذات الصلة من المستندات الإلكترونية الكبيرة والمعقدة. على سبيل المثال، في عقود العمل المكونة من عدة مئات من الصفحات، في وقت قصير جداً يمكن للتكنولوجيا القائمة على تطبيق الذكاء الاصطناعي أن تولد عناصر مهمة من العقد في تقرير منفصل مثل إجمالي مبلغ العقد، والفترة، والشروط الخاصة، والعقوبات وما شابه ذلك. في بعض الحالات، عندما يكون ذلك ممكناً، يمكن لهذه الأدوات مقارنة المعلومات المستمدة من المعلومات المستمدة من العقد مع بعض المعايير المحددة مسبقاً واستخلاص بعض الاستنتاجات الأولية الملموسة والموضوعية بناء عليها، بمستوى عالٍ من الموثوقية. بهذه الطريقة، يمكن للأشخاص المشاركين في تنفيذ عملية المراجعة الحصول على درجة عالية من كفاية وملاءمة ادلة الثبات في وقت قصير، والتي لولا ذلك سيكون عليهم قضاء المزيد من الوقت في البحث عن ادلة الاثبات الكافية لدعم رأيهم الفني.

6. قائمة المراجع:

1. Appelbaum, D., Kogan, A., & Vasarhelyi, M. A. (2017). Big data and analytics in the modern audit engagement: Research needs. In *Auditing A Journal of Practice & Theory* (Vol. 36, Numéro 4, p. 1 - 27). American Accounting Association.
<https://doi.org/10.2308/ajpt-51684>.
2. Aswathy, S. U., Ajesh, F., Shamsudheen, S., & Jarin, T. (2021). Computer-Aided Diagnosis of Liver Fibrosis in Hepatitis Patients Using Convolutional Neural Network. In *Computational Analysis and Deep Learning for Medical Care* (Vol. 1999, Numéro December, p. 217 - 236). <https://doi.org/10.1002/9781119785750.ch9>.
3. Josiah, M., & Izedonmi, P. F. (2013). CRITICAL ISSUES IN INTERNATIONAL AND ELECTRONIC AUDIT EVIDENCE. *International Journal of Management Sciences and Business Research*, 2(3), 1 - 14.
4. Feddewar, P., Deshmukh, B., Science, C., & Colledge, P. (2022). Convolution Neural Processing : A Survey Network (CNN) for Video. *International Journal for Modern Trends in Science and Technology*, 8(01), 147 - 152.
<https://doi.org/10.46501/IJMTST0801025>.
5. O'Shea, K., & Nash, R. (2022). An Introduction to Convolutional Neural Networks. *International Journal for Research in Applied Science and Engineering Technology*, 10(12), 943 - 947. <https://doi.org/10.22214/ijraset.2022.47789>.
6. Randles, B. M., Pasquetto, I. V, Golshan, M. S., & Borgman, C. L. (2017). Using the Jupyter Notebook as a Tool for Open Science: An Empirical Study. *Proceedings of the ACM/IEEE Joint Conference on Digital Libraries*.
<https://doi.org/10.1109/JCDL.2017.7991618>.
7. Tasnim, A., Saiduzzaman, M., Rahman, M. A., Akhter, J., & Rahaman, A. S. M. M. (2022). Performance Evaluation of Multiple Classifiers for Predicting Fake News. *Journal of Computer and Communications*, 10(09), 1 - 21.
<https://doi.org/10.4236/jcc.2022.109001>.
8. Vazan, M. (2022). Deep Learning: From Basics to Building Deep Neural Networks with Python.
<https://doi.org/https://doi.org/10.48550/arXiv.2205.01069>.
9. Yoon, K., Hoogduin, L., & Zhang, L. (2015). Big data as complementary audit evidence. *Accounting Horizons*, 29(2), 431 - 438.
<https://doi.org/10.2308/acch-51076>.
10. Yuan, Z., Li, H., & Li, X. (2019). Evidence collection agent model design for big data forensic analysis. *Lecture Notes in Electrical Engineering*, 518, 647 - 653. https://doi.org/10.1007/978-981-13-1328-8_83.
11. الهيئة السعودية للمحاسبين القانونيين. (2020). المعايير الدولية للمراجعة والفحص والتأكدات الأخرى والخدمات ذات العلاقة المعتمدة في المملكة العربية السعودية.
12. عباس م يونس أكبر. (2019). اثر كفاية وحجية أدلة الإثبات في مخاطر التدقيق. مجلة دراسات محاسبية ومالية، 10(31)، 221-251 .
<https://doi.org/10.34093/jafs.v10i31.380>
13. لقويرة، س. (2019). مساهمة معايير أدلة إثبات في تحسين جودة التدقيق الخارجي "دراسة ميدانية آراء عينة من المدققين الخارجيين في الشرق الجزائري. جامعة باتنة1.
14. Aloysius, N., & Geetha, M. (2018). A review on deep convolutional neural networks. *Proceedings of the 2017 IEEE International Conference on Communication and Signal Processing, ICCSP 2017, 2018-Janua*, 588 - 592.
<https://doi.org/10.1109/ICCSP.2017.8286426>.
15. Markina, M. S., Voevodin, V. A., Markin, P. V., & Burenok, D. S. (2021). Methodology for Quantifying the Materiality of Audit Evidence Using Expert Assessments and Their Ranking. *2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*, 2390 - 2393. <https://doi.org/10.1109/ElConRus51938.2021.9396263>.
16. López, F. D., Martínez-Fernández, S., Felderer, M., & Franch, X. (2022). Guiding the retraining of convolutional neural networks against adversarial inputs. *Proceedings of ACM Conference (Conference'17)*, 1(1).
17. Randles, B. M., Pasquetto, I. V, Golshan, M. S., & Borgman, C. L. (2017). Using the Jupyter Notebook as a Tool for Open Science: An Empirical Study. *Proceedings of the ACM/IEEE Joint Conference on Digital Libraries*.
<https://doi.org/10.1109/JCDL.2017.7991618>.
18. Toba, Y. (2011). Toward a Conceptual Framework of Professional Skepticism in Auditing. *WASEDA Business & Economic Studies*.
https://dSPACE.wul.waseda.ac.jp/dSPACE/bitstream/2065/35707/1/WasedaBusiness%26EconomicStudies_47_Toba.pdf