

## تقييم مداخل استخدام تقنيات التعلم الآلي في المراجعة الخارجية بغرض تحقيق فعالية التنبؤ بتحريفات القوائم المالية -

### دراسة تجريبية على الشركات المقيدة في البورصة المصرية

د/ سحر عبد الستار عبد الستار النقيب. مدرس بقسم المحاسبة والمراجعة كلية التجارة جامعة بور سعيد

[Sahnakeeb810@gmail.com](mailto:Sahnakeeb810@gmail.com)

#### ملخص:

**الهدف:** يهدف هذا البحث إلى استكشاف مدى فعالية مداخل استخدام تقنيات التعلم الآلي ML في مساعدة المراجع الخارجي في التنبؤ بتحريفات القوائم المالية، بالإضافة إلى فعاليتها في تحديد العوامل والخصائص المميزة للشركات المحرفة والتي تمثل علامات حمراء تمثل تحذيرات هامة من خطر وقوع التحريف. ومن ثم قياس احتمال ومخاطر التحريف، مما يجنب المراجع مخاطر التقاضي نتيجة للإخفاق في عملية المراجعة وعدم إصدار التقرير المناسب.

**التصميم والمنهجية:** قدمت الباحثة دراسة تحليلية للأدب المحاسبي والاصدارات المهنية فيما يتعلق بتقنيات التعلم الآلي ML وتطور استخدامها في مجال المراجعة ودورها في اكتشاف والتنبؤ بالتحريفات وإعادة إصدار القوائم المالية. كما صممت الباحثة دراسة تجريبية على عينة من الشركات المقيدة بالبورصة المصرية والتي تمثل عملاء لمكاتب المراجعة الخارجية؛ وذلك بهدف اختبار فروض الدراسة. فقد تم استخدام برنامج IBM® SPSS® Modeler Premium 18.3 على 33 شركة محرفة للقوائم المالية خلال الفترة من 2012 إلى 2021 (عينة الدراسة) ، وعدد 99 شركة مقابلة لهذه الشركات وتتفق معها في الحجم والقطاع الصناعي والفترة الزمنية (العينة المقابلة الضابطة) . واستخدمت الباحثة التقارير المالية خلال ثلاث سنوات متتالية تشمل سنة التحريف والسنتين السابقتين لها وذلك لكل شركات الدراسة ( محرفة وغير محرفة) بما يعادل 396 مشاهدة. ومن أجل تقييم القدرة التنبؤية لنماذج التعلم الآلي ML في التنبؤ بالشركات المحرفة وخصائصها اعتمدت الباحثة في تصميم دراستها على ثلاث مداخل إما استخدام المؤشرات المالية فقط أو المؤشرات النصية فقط، أو الجمع بين الاثنين ؛ وذلك من أجل تطبيق تقنيات التعلم الآلي ML على 70% من بيانات عيني الدراسة (شركات محرفة وغير محرفة). ثم اختبار مدى دقة تلك التقنيات في التنبؤ بالتحريفات في القوائم المالية في شركات العملاء محل المراجعة باستخدام باقي البيانات(30%).

**النتائج والتوصيات:** توصلت الباحثة من الجانب النظري إلى أن هناك العديد من المصطلحات التي تعبر عن مفهوم التحريفات في القوائم المالية في أدب المراجعة. كما أن هناك توجه كبير من قبل مهنة المراجعة نحو استخدام التقنيات التكنولوجية الحديثة ومنها تقنيات التعلم الآلي بأنواعها المختلفة سواء تخضع للإشراف أو لا تخضع وسواء كانت من نوع التعلم المعزز أو التعلم العميق. أما من الجانب التجريبي فقد أوضحت النتائج أن المدخل المالي لاستخدام تقنيات التعلم الآلي يحقق أعلى درجات دقة في الكشف عن والتنبؤ بتحريفات القوائم المالية ، يليه المدخل المختلط ثم المدخل النصي. ومن ثم يجب على المراجع عدم الاعتماد على المدخل النصي فقط في الكشف عن تحريفات القوائم المالية.

**الأصالة والإضافة:** ينفرد البحث بتأصيل إطار نظري لاستخدام تقنيات التعلم الآلي ML في المراجعة من أجل التنبؤ بالتحريفات في القوائم المالية. كما يقدم البحث دراسة تجريبية باستخدام بيانات فعلية من القوائم المالية للشركات محل المراجعة؛ مما يوضح للمراجعين الخارجيين في الواقع العملي كيفية تطبيق تقنيات التعلم الآلي ML الحديثة في الكشف عن والتنبؤ بتحريفات القوائم المالية. بالإضافة إلى تقييم المداخل التي يمكن للمراجع استخدامها وعرض دقة النماذج المستخدمة للمقارنة بينها.

**الكلمات المفتاحية:**

تقنيات التعلم الآلي وبرمجياته، فعالية التنبؤ، تحريفات القوائم المالية، مسؤولية المراجع الخارجي، الشركات المقيدة بالبورصة المصرية.

## **Evaluation of the approaches to using machine learning techniques in external auditing to achieve effectiveness of financial misstatements prediction- An experimental study on companies listed on the Egyptian Stock Exchange**

**Abstract:**

**Objective:** This research aims to explore the effectiveness of the approaches to using machine learning techniques in assisting the external auditor in predicting misstatements of the financial statements, in addition to its effectiveness in identifying the factors and characteristics of the misrepresented companies, which are red flags that represent important warnings of the risk of misrepresentation. And then measure the possibility and risks of misrepresentation, which avoids the auditor risks litigation because of failure in the audit process and failure to issue the appropriate report.

**Design and Methodology:** The researcher presented an analytical study of accounting literature and professional publications in relation to machine learning techniques, the development of their use in the field of auditing, and their role in detecting and predicting misstatements and restatements. The researcher also designed an experimental study on a sample of companies listed on the Egyptian Stock Exchange, which represent clients of external audit offices to evaluate the hypotheses of the study. The IBM SPSS Modeler Premium 18.3 program was used on 33 companies that distorted the financial statements during the period from 2012 to 2021 (the study sample), and the number of 99 companies corresponding to these companies and corresponding with them in size, industrial sector, and time (the corresponding control sample). The researcher used the financial reports during three consecutive years, including the year of distortion and the two years preceding it, for all study companies (distorted and not distorted), with an equivalent of 396 observations. To evaluate the predictive ability of machine learning models in predicting distorted companies and their characteristics, the researcher relied on designing her study on three approaches, either using financial indicators only or text indicators only, or a combination of the two; This is to apply machine learning techniques to 70% of the data of the two study samples (distorted and non-distorted companies). Then testing the accuracy of these techniques in predicting misstatements in the financial statements of the client companies under review using the rest of the data (30%).

**Findings and recommendations:** From the theoretical side, the researcher concluded that there are many terms that express the concept of misstatements in the financial statements in the auditing literature. There is also a great trend by the auditing profession towards the use of modern technological techniques, including machine learning techniques of various types, whether subject to supervision or not, and whether they are of the type of reinforcement or deep learning. On the experimental side, the results showed that the financial approach using machine learning techniques achieves the highest degree of accuracy in detecting and predicting misstatements of the financial statements, followed by the mixed approach and then the text approach. Hence, the auditor should not rely solely on the textual approach in detecting misstatements of the financial statements.

**Originality and addition:** The research is unique in rooting a theoretical framework for using machine learning techniques in auditing to predict misstatements in the financial statements. The research also presents an experimental study using actual data from the financial statements of the companies under review. Which shows the external auditors in practice how to apply modern machine learning techniques in detecting and predicting misstatements of the financial statements. In addition to evaluating the

entries that the reviewer can use and presenting the accuracy of the models used to compare them.

**Keywords: Machine learning techniques and software, effectiveness of prediction, financial misstatements, external auditor responsibility, companies listed on the Egyptian Stock Exchange.**

## 1- إطار البحث

### 1-1 المقدمة

تعد تحريفات القوائم المالية وبصفة خاصة التي ترجع إلى الغش والاحتيال مشكلة عالمية تؤثر على مختلف قطاعات منظمات الأعمال. وذلك نتيجة لما لها من تأثير سلبي شديد على الشركات وأصحاب المصلحة المعنيين. ولقد أوضحت بعض الدراسات أن الآثار المالية المترتبة على حدوث أنشطة احتيالية تقدر بنحو 5.127 تريليون دولار خلال العقد الماضي فقط . كما قدرت الخسائر المصاحبة لهذه التحريفات بنسبة 56% خلال العشر سنوات الماضية (Gee & Button, 2019). ومن المحتمل أن تكون التكاليف الفعلية للتحريفات في القوائم المالية أكبر مما هو مسجل في القضايا، خاصة إذا ما أخذ في الاعتبار التكاليف غير المباشرة ؛ بما في ذلك الضرر الذي يلحق بتشويه مصداقية الإدارة، والقائمين على الإفصاح مما يفقد ثقة المستثمرين والدائنين والعاملين وغيرهم من أصحاب المصالح. بالإضافة إلى انخفاض نشاط الشركة بسبب

الفضيحة الناتجة عن تلك التحريفات، مما قد يعرض بقائها واستمراريتها إلى الخطر، ويعرضها للإفلاس (ACFE, 2020).

ولقد تزايدت الضغوط على مهنة المراجعة الخارجية نتيجة لتزايد معدلات حدوث التحريفات في القوائم المالية سواء بقصد (غش واحتيال) أو بدون قصد (أخطاء). ولذا يلجأ الممارسون للمهنة إلى استخدام أدوات التكنولوجيا الحديثة لمساعدتهم في تخفيف هذه الضغوط، والتنبؤ بتلك التحريفات مبكراً قبل وقوعها. فالمراجعون بحاجة إلى تقنيات ترفع من كفاءتهم في التنبؤ بتحريفات القوائم المالية قبل حدوثها تجنباً للتعرض لتعديل القوائم المالية، ومن ثم انهيار أسعار الأسهم أو حدوث تعثر مالي للشركات محل المراجعة مما يضر بفئة المستثمرين وأصحاب المصالح.

إن التحريف المالي له أهمية كبيرة لدى مستخدمي القوائم المالية. وقد قدم الأدب المحاسبي دراسات عديدة ارتكز أغلبها حول دور العوامل المالية سواء أكانت مالية أو غير مالية في رفع قدرة المراجع على التنبؤ بالتحريف المالي. ولذا تحاول الباحثة من خلال هذا البحث أن تبين أهمية استخدام تقنيات التعلم الآلي ML والتعلم العميق في التنبؤ بتحريفات القوائم المالية، بهدف تحسين كفاءة وفعالية المراجعة.

## 1 - 2 مشكلة البحث :

ورد في تقرير رابطة فاحصي الاحتيال المعتمدين (ACFE) الصادر عام 2020 أن متوسط التكلفة لكل حالة من حالات الاحتيال المهني حول العالم بلغ 125000 دولار خلال فترة 14 شهر. وعلى الرغم من أن معظم حالات الاحتيال كانت اما فساد أو سرقة أصول؛ إلا أن الخسائر الناجمة عن التحريف في القوائم المالية كانت أكبر وأكثر خطورة. إذ تمثلت الخسارة الناجمة عن تحريفات القوائم المالية في 954,000 دولار أمريكي خلال فترة 24 شهراً (ACFE, 2020).

ولقد اتهم مركز جودة المراجعة<sup>1</sup> المديرين بأنهم يقومون بتحريف القوائم المالية عن عمد لعدة أسباب منها: المنفعة الشخصية، أو ضرورة لتحقيق الأهداف المالية قصيرة الأجل، والنية لإخفاء الأخبار السيئة. ويمكن التلاعب بالقوائم المالية الاحتيالية، بحيث تحمل في طياتها تشابهاً مقنعاً مع التقارير غير الاحتيالية، ويمكن أن تظهر في أنواع مختلفة ومتميزة (Huang, Tsaih, & Yu, 2014). ومن أكثر الأساليب شيوعاً في تحريف القوائم المالية هي التلاعب بصافي الدخل زيادة ونقصاناً حسب المنفعة المراد تحقيقها من ذلك. أيضاً المبالغة في الإيرادات الوهمية أو تخفيضها

<sup>1</sup> مركز جودة المراجعة Center for Audit Quality CAQ : هو منظمة سياسية غير حزبية تعبر عن صوت المراجعين الخارجيين وتهتم بتعزيز الأداء عالي الجودة بما يخدم أصحاب المصالح المستفيدين من القوائم المالية للشركات محل المراجعة.

عن الواقع، بالإضافة إلى إظهار الالتزامات بقيمة أعلى من حقيقتها أو إخفائها. كذلك تقييم الأصول بقيم غير ملائمة، والإفصاحات الكاذبة (Singleton & Singleton, 2010).

ولما كانت مسؤولية اكتشاف التحريفات في القوائم المالية تقع على عاتق المراجع، فكان لا بد من استخدام وسائل متطورة تساعده في أداء مهمته بفعالية وكفاءة، وعلى أعلى مستوى من الجودة، دون التعرض لمخاطر المسائلة والتقاضى (DYCK, MORSE, & ZINGALES, 2010). فعلى الرغم من وجود مبادئ إرشادية للمراجع تساعده في أداء مهمته في الكشف عن التحريفات أو التنبؤ بها، إلا أن الكشف عن مؤشرات الاحتيال أو التحريفات يعد أمراً صعباً. فقد أوضح تقرير عام 2020 أنه لم يتم الكشف عن حالات الغش والاحتيال التي حدثت من قبل المراجعين إلا بنسبة 4% للمراجعين الخارجيين و 15% للمراجعين الداخليين (ACFE, 2020).

ومن هنا توجهت الأنظار نحو التقنيات والأنظمة الآلية للكشف عن الاحتيال في القوائم المالية (Comission, 2019). فهذه التقنيات لها أهمية مختلفة باختلاف فئات أصحاب المصالح. فالمستثمرون يعتمدون عليها من أجل تسهيل عملية اتخاذ القرارات السليمة التي تمكنهم من تعظيم استثماراتهم في الشركات المفصحة. أما المراجعون فيلجأون لتلك التقنيات من أجل تحسين دقة عملية المراجعة للقوائم المالية في وقت زمني قياسي. أما المنظمون فيعتمدون على هذه التقنيات من أجل تركيز تحقيقاتهم نحو هدفها (Khan et al., 2022). لذلك، تم بذل جهود لتطوير أنظمة ذكية مصممة لاكتشاف الاحتيال في القوائم المالية. ولقد تناولت الدراسات السابقة مختلف العوامل المالية والعوامل النصية (شعورية وموضوعية) كمؤشرات للمخالفات المالية (E. Hunt, Hunt, 2022; Richardson, & Rosser, 2022; Jan, 2021; Khan et al., 2022).

ولذا تتمثل مشكلة البحث في عدم وضوح دور التقنيات الحديثة للتعلم الآلي، ومدى منفعتها في مساعدة المراجع الخارجي في تحقيق فعالية التنبؤ بالتحريف في القوائم المالية؛ ومن ثم تحقيق جودة المراجعة. وذلك من خلال استخدام عدة مداخل: منها مدخل التحليل المالي، ومدخل التحليل النصي، وأخيراً المدخل المختلط الذي يجمع بينهما. وينبثق عن هذه المشكلة تساؤلات البحث على النحو التالي:

1. ما هي تحريفات القوائم المالية؟ وما مدى مسؤولية المراجع الخارجي عن اكتشافها؟
2. ما هي التقنيات الحديثة للتعلم الآلي؟ وكيف يمكن استخدامها في التنبؤ بالتحريف في القوائم المالية؟

3. هل الجمع بين مدخل المقاييس المالية ومدخل المقاييس النصية يوفر محتوى إعلامي أكبر يفيد في التنبؤ بدقة بالتحريف في القوائم المالية بنوعيه؟ أم أنه يفضل استخدام كل مدخل على حدة؟

4. كيف يمكن تقييم مداخل التنبؤ بالتحريف في القوائم المالية في الشركات محل المراجعة المدرجة في البورصة المصرية؟ وما هو دور التقنيات الحديثة للتعلم الآلي في تحقيق فعالية وكفاءة المراجعة؟

### 3-1 أهداف البحث:

يهدف هذا البحث إلى تقييم مدى فعالية استخدام المراجع الخارجي للتقنيات الحديثة للتعلم الآلي ML في التنبؤ بالتحريف في القوائم المالية، بالإضافة إلى اختبار مدى فعالية تلك التقنيات في التنبؤ بالتحريفات في الشركات محل المراجعة والمدرجة في البورصة المصرية. وينقسم هذا الهدف إلى عدة أهداف فرعية كما يلي:

1. دراسة وتحليل مفهوم ومصطلحات تحريفات القوائم المالية، ومناقشة مسؤولية المراجع تجاه الكشف عنها والتنبؤ بها وفقاً للإصدارات المهنية والتنظيمية.
2. استقراء الدراسات السابقة بشأن مفهوم التعلم الآلي وتطور تقنياته في ظل الذكاء الاصطناعي.
3. استنباط مداخل استخدام المراجع الخارجي لتقنيات التعلم الآلي في الكشف عن والتنبؤ بتحريفات القوائم المالية.
4. إجراء دراسة تجريبية لقياس مدى فعالية تقنيات التعلم الآلي ML في مساعدة المراجع الخارجي بالتنبؤ بالتحريفات في القوائم المالية في الشركات المدرجة في البورصة المصرية، مع مقارنة مداخل الاستخدام المختلفة لتحديد أكثرها دقة في عملية التنبؤ.

### 1 - 4 أهمية البحث:

تتبع أهمية البحث من الناحية الأكاديمية من مصدرين :

**أولهما:** أهمية موضوع تحريفات القوائم المالية وكيفية التنبؤ بها لمساعدة المراجع الخارجي في اتخاذ قراره بشأن تقرير المراجعة، بما يمكنه من أداء مهمته لحماية المستثمرين وأصحاب المصالح الذين يعتمدون على رأيه الوارد في التقرير. فمنذ انهيار بعض الشركات الكبرى وحدث هزة في ثقة المستثمرين، أضحت من الضروري إجراء العديد من الأبحاث التي تساند المراجع في التنبؤ بالتحريفات قبل وقوعها وانهيار الشركة محل المراجعة.

**ثانيهما:** نتيجة للتحويل الرقمي وكافة مجالات الأعمال وكبر حجم المعلومات والبيانات الضخمة واستخدام تقنيات الأتمتة والذكاء الاصطناعي والتعلم الآلي ML، يساهم هذا البحث في زيادة الوعي لدى كل من المراجعين الخارجيين وأصحاب المصالح بأهمية الدور الذي تلعبه تلك التقنيات في تحقيق فعالية المراجعة ومن ثم رفع الثقة في القوائم المالية والاعتماد عليها من قبل أصحاب المصالح في اتخاذ القرارات الملائمة.

أما من **الناحية العملية** فتتمثل أهمية هذا البحث في أنه يقدم دراسة اختبارية لتقييم مدى فعالية تقنيات التعلم الآلي ML في التنبؤ بالتحريفات في القوائم المالية للشركات محل المراجعة ومقيدة بالبورصة المصرية. إذ يقارن البحث بين ثلاث مداخل لاستخدام تلك التقنيات من أجل الوصول إلى أنسبها وأدقها في التنبؤ. مما يساند في تنشيط سوق الأوراق المالية في مصر الذي يمكن حجر الأساس في الاقتصاد المصري وركن من أركان الاستقرار الاقتصادي العالمي.

### 1- 5 مجال وحدود البحث:

يتمثل مجال البحث في تقييم مدى فعالية استخدام المراجع الخارجي للتقنيات الحديثة للتعلم الآلي ML في التنبؤ بالتحريفات في القوائم المالية، بالإضافة إلى التحقق من مدى فعالية هذه التقنيات وأي المداخل أكثر دقة في التنبؤ بالتحريفات القوائم المالية للشركات محل المراجعة والمقيدة في البورصة المصرية. ولذا تتمثل حدود البحث في:

1. **الحدود النظرية:** يركز البحث على آليات المراجعة الخارجية في الكشف عن والتنبؤ بالتحريفات في القوائم المالية قبل حدوثها، ولذا يخرج عن نطاق البحث دور المراجع الداخلي في مساعدة المراجع الخارجي في ذلك.

2. يقتصر البحث على استخدام تقنيات التعلم الآلي ML في التنبؤ بتلك التحريفات وذلك من خلال الاعتماد على المدخل المالي أو النصي أو كليهما. ولذا يخرج عن نطاق البحث باقي التقنيات الحديثة مثل الأتمتة الروبوتية، والأتمتة الذكية، والتحليلات الذكية للبيانات الضخمة، وغيرها من التقنيات الحديثة والتي يمكن للمراجع الخارجي أن يعتمد عليها.

3. **الحدود التجريبية:** يتم تصميم التجربة باستخدام برنامج IBM® SPSS® Modeler Premium 18.3 وبالاعتماد على بيانات القوائم المالية وتقارير مجلس الإدارة للشركات المدرجة في البورصة المصرية والتي تمثل عملاء لمكاتب المراجعة المختلفة. ولذا يخرج عن نطاق البحث

— تجريب ذلك في مكاتب ومنشآت المراجعة المختلفة.



- استخدام البرمجيات والمنصات المفتوحة الأخرى لتطبيق تقنيات التعلم الآلي ML.
- استخدام البيانات النصية الأخرى بخلاف تقارير مجالس الإدارة، مثل تقرير الاستدامة والحوكمة وتعليقات العملاء على تويتر، وغيرها من وسائل التواصل الاجتماعي.
4. تقتصر الدراسة على فترة زمنية من 2012 إلى 2021 والتي تمثل الفترة التي استطاعت الباحثة أن تحصل فيها على عينة الشركات المحرفة للقوائم المالية أولاً والتي بناء عليها حددت العينة الضابطة.

## 1-6 تنظيم البحث:

في ظل هدف البحث وحدوده تقسم الباحثة ما تبقى من البحث على النحو التالي:

### 2- الدراسة النظرية واستنباط الفروض

2-1 مفهوم تحريفات القوائم المالية، ومسؤولية المراجع الخارجي بشأنها.

2-2 مفهوم التعلم الآلي ML، وتطور تقنياته في ظل الذكاء الاصطناعي AI

2-3 مداخل استخدام تقنيات التعلم الآلي ML في التنبؤ بتحريفات القوائم المالية

3- دراسة تجريبية على تقارير الشركات محل المراجعة والمقيدة بالبورصة المصرية

3-1 تصميم الدراسة التجريبية

3-2 تحليل النتائج الإحصائية والتحقق من الفروض

4- النتائج والتوصيات والتوجهات البحثية المستقبلية

4-1 النتائج التي توصلت إليها الدراسة

4-2 توصيات البحث

4-3 التوجهات البحثية المستقبلية

## 2- الدراسة النظرية واستنباط الفروض

تقدم الباحثة في هذا القسم مسحا نظريا للدراسات التي تناولت محاور الدراسة الرئيسية. ففي المحور الأول: تحريفات القوائم المالية تحلل الباحثة مفهوم تحريفات القوائم المالية والمصطلحات التي تناولها الأدب المحاسبي للتعبير عنها، ثم تستعرض ما تناولته معايير المراجعة والمنظمات المهنية فيما يخص مسؤولية المراجع نحو الكشف عن تحريفات القوائم المالية والتنبؤ بها. وتتناول الباحثة في المحور الثاني: تقنيات التعلم الآلي ML، وأنواعها في ظل الذكاء الاصطناعي. وأخيرا تحلل الباحثة المداخل المطبقة لاستخدام تقنيات التعلم الآلي ML في المراجعة الخارجية من أجل تحقيق التنبؤ بتحريفات القوائم المالية وذلك بغرض استنباط فروض الدراسة.

2-1 مفهوم تحريفات القوائم المالية، ومسؤولية المراجع الخارجي بشأنها

يمثل التحريف الجوهري في القوائم المالية مشكلة عالمية سواء الناتج عن الغش والاحتيال المحاسبي المتعمد أو الناتج عن الأخطاء المحاسبية غير المتعمدة. وإذا لم يتم الكشف عن هذا التحريف في الوقت المناسب ومنعه وبصفة خاصة المتعمد منه ( الغش / الاحتيال) فقد يسبب ضررا كبيرا لأصحاب المصلحة. إذ قدرت الخسائر الناجمة عن الغش في القوائم المالية للشركات المعروفة Enron Corp., Tyco, and WorldCom Inc بحوالي 460 بليون دولار آنذاك (Rezaee, 2005). وقد أثبتت الدراسات أن الضرر الناتج عن الغش المحاسبي لا يقتصر على أصحاب المصالح في الشركات المحرفة للقوائم المالية فقط؛ بل يتعداها ويسبب خسائر لأصحاب المصالح في الشركات المنافسة الأخرى، وهذا ما يطلق عليه بعض الكتاب عدوى الغش في القوائم المالية (Gleason, Jenkins, & Johnson, 2008; Jia & Zhao, 2020).

ولما كان من الصعب اكتشاف التحريف الجوهري في القوائم المالية الناتج عن الاحتيال المحاسبي، علاوة على أنه حتى لو تم اكتشافه، فعادة ما يكون قد حدث بالفعل ضرر جسيم. ولذا فإن استخدام النماذج الفعالة والأكثر دقة في التنبؤ بتحريفات القوائم المالية وتقدير مخاطر الاحتيال المحاسبي قبل وقوعه لها أهمية كبيرة لدى المراجعين الخارجيين لكي يؤديوا مسؤولياتهم تجاه أصحاب المصالح بأعلى جودة ممكنة (Cheng, Kao, & Lin, 2021; Lin, Chiu, Huang, & Yen, 2015).

ولكن ما هو مفهوم تحريفات القوائم المالية؟ وماهي مسؤولية المراجع الخارجي تجاه تلك التحريفات وفقا لما ورد في الإصدارات المهنية والقواعد التنظيمية والقانونية؟

## 2- 1- 1 مفهوم تحريفات القوائم المالية ومصطلحات دراستها في الأدب المحاسبي

ورد مصطلح تحريفات القوائم المالية في العديد من الدراسات والتي تناولته تحت مسميات مختلفة. ويحصر المصطلحات الواردة في الأدب المحاسبي لهذا المفهوم، تقسم الباحثة المصطلحات الدالة على تحريفات القوائم المالية كلية أو جزئيا وفقا لما هو وارد في الجدول رقم (1).

### 1. المصطلح الأول: انتهاك المبادئ المحاسبية المتعارف عليها GAAP Violation

حيث أشارت دراسة (Beneish, 1997) في عنوانها إلى " الكشف عن انتهاك المبادئ المحاسبية المتعارف عليها من خلال تقديم نموذج للكشف عن إدارة الأرباح بين الشركات المتفوقة الأداء. وعند اختيار العينة أورد الباحث مصطلح تحريفات القوائم المالية من أجل تحديد الشركات

التي قامت بإدارة الأرباح. وهذا يدل على أن الباحثين في المحاسبة والمراجعة يرون أن مفهوم تحريفات القوائم المالية هو مفهوم عام يدل على انتهاك المبادئ المحاسبية المتعارف عليها بإدارة الأرباح وفقا لهوى الإدارة وبغرض تحقيق مصلحتها. وترى الباحثة أن هدف المراجع هو التأكيد على تطبيق المبادئ المحاسبية المتعارف عليها والإطار المفاهيمي والمعايير المحاسبية عند إعداد القوائم المالية، ومن ثم فإن مفهوم انتهاك تلك المبادئ هو تعريف جزئي لتحريفات القوائم المالية المسؤول عن اكتشافها والتنبؤ بها وتقدير مخاطرها. وقد توالى الدراسات في استخدام هذا المصطلح " انتهاك المبادئ المحاسبية المتعارف عليها منها (Beneish, 1997; Thevenot, 2012).

ولقد استخدم المعنى المقصود من انتهاك المبادئ المحاسبية المتعارف عليها بطرق مختلفة مثل الأرباح غير المعتمدة على المبادئ المحاسبية Non- GAAP Earnings كما في دراسة (Shiah-Hou, 2021). واطلقت بعض الدراسات مصطلح الأصول غير المحسوبة وفقا للمبادئ المحاسبية المتعارف عليها. وفي دراسات أخرى أطلق الباحثين مصطلح إعداد التقارير غير المتوافقة مع المبادئ المحاسبية المتعارف عليها (X. Chen, Jiang, Lu, ) Non- GAAP Reporting (Yu, 2021; Kyung, Lee, & Marquardt, 2019). أيضا فيما يتعلق بانتهاك مبادئ المحاسبة كمصطلح يعبر عن التحريفات في القوائم المالية أطلق بعض الباحثين مصطلح الإفصاحات غير المتوافقة مع المبادئ المحاسبية (H.-C. Chen, ) Non- GAAP Disclosures (Lee, Lo, & Yu, 2021; Thielemann & Dinh, 2019).

## 2. المصطلح الثاني: الغش / الاحتيال المحاسبي Accounting Fraud

يعد الغش أو الاحتيال المحاسبي أكثر المصطلحات تداولاً في الأدب المحاسبي (Liao, Smith, & Liu, 2019; Papík & Papíková, 2022; Y. Wang, Ashton, & Jaafar, 2019) نظرا لما له من آثار قضائية. لأنه يفترض فيه العمد والقصد المبيت للتحريف. ولذا ورد في العديد من الدراسات المحاسبية وأدب المراجعة والمعايير الدولية للمراجعة مصطلح الغش، إذ يختلف عن الأخطاء المحاسبية العادية وانتهاك المبادئ المحاسبية المتعارف عليها بمعياري واحد هو النية أو القصد. فالغش في القوائم المالية هو فعل متعمد، وغير قانوني يتحدد بثلاث خصائص هي: الرشد والتوجه، والفرصة وأخيرا الدافع والضغط (Singh Yadav & Sora, 2021). فمنها من أطلق عليها الغش في القوائم المالية Financial Statement Fraud حيث عرفه بأنه الحالة التي تقدم فيها إدارة الشركة معلومات مزيفة في القوائم المالية تمنع من ظهورها وظيفة المراجعة الخارجية التي تضمن خلو القوائم المالية للشركة محل المراجعة من الاحتيال والزيف والغش والمعلومات الخاطئة والمحرفة. ومع كل هذا الاحتياط ترتكب التحريفات والاحتيالات المحاسبية ويظهر الغش في القوائم

المالية والذي من الصعب اكتشافه وتقدير مخاطره مسبقاً (Dilla & Raschke, 2015; شحاته, 2017; على, 2017).

وبنفس المعنى هناك مصطلحات أخرى وردت في الأدب المحاسبي لتعبر عن الاحتيال المحاسبي: منها القوائم المالية المضللة Fraudulent Financial Statements حيث استخدم هذا المصطلح في السنوات التي قبل عقد مضي (Humpherys, Moffitt, Burns, Burgoon, & Felix, 2011; Kirkos, Spathis, & Manolopoulos, 2007) ثم حل محله مصطلح الغش في القوائم المالية Financial Statements Fraud في السنوات الأخيرة (Cheng et al., 2021; Craja, Kim, & Lessmann, 2020; Shen et al., 2021) أو التقرير المالي المضلل Fraudulent Financial Reporting كما في دراسة (Zager, Malis, & Novak, 2016; Zhang, Zhang, & Yao, 2022) أو الغش المالي أو الغش فقط Financial Fraud كما في دراسة (Achakzai & Juan, 2022; Petraşcu & Tîeanu, 2014; Wu, Chang, Li, & Zhu, 2022)

### 3. المصطلح الثالث: تحريفات القوائم المالية Financial Misstatements

يمثل مصطلح تحريفات القوائم المالية المصطلح المذكور في معايير المراجعة الدولية والمحلية (IAASB, 2021b; الهيئة العامة للرقابة المالية، 2008a). ويقصد به تعديل يحدث في القوائم المالية بغرض الحصول على قوائم مالية محرفة ومضللة بغرض تحقيق مصلحة للإدارة (Kanapickiene & Grundienė, 2015).

ولقد عرف معيار المراجعة الدولي رقم 450 كلمة تحريف Misstatement على أنها "اختلاف بين مبلغ بند من بنود القوائم المالية، أو تصنيفه، أو عرضه، أو الإفصاح عنه، وما يجب أن يكون عليه مبلغ هذا البند، أو تصنيفه، أو عرضه، أو الإفصاح عنه، طبقاً لما يتطلبه إطار التقرير المالي المعمول به". ويمكن أن تنشأ التحريفات عن خطأ، أو غش. كما أوضح المعيار الدولي رقم (200) ونظيره المصري أن وجود مثل هذه التحريفات يتعارض مع حكم المراجع عن القوائم المالية بالعدالة والصدق، ولذا يجب عليه فحص وتقييم تلك التحريفات وتحديد مدى أهميتها وأثرها (IAASB, 2021b; الهيئة العامة للرقابة المالية، 2008a).

وهناك مصطلحات مماثلة تعبر عن تحريفات القوائم المالية وردت في بعض الدراسات مثل خطأ التقرير financial misreporting (N. C. Hunt, Curtis, & Rixom, 2022; Su & Karpoff, Scott Lee, ) financial misrepresentation وخطأ العرض (Alexiou, 2022)

(Dechow, GE, Larson, & Sloan, 2011) وقد استخدمت دراسة (& Martin, 2008). ومصطلح إدارة الأرباح Earnings Management كبدل للتحريفات في القوائم المالية على اعتبار أنها نفس الإجراءات التي تستخدمها الإدارة من أجل التلاعب في الأرباح، ومصطلح الأخطاء الجوهرية كما ورد في دراسة (أبو الخير, 2019).

وتخلص الباحثة إلى أن استخدام مصطلح تحريفات القوائم المالية يعد المصطلح الأكثر ملائمة لدراستها هنا؛ إذ أنه يعبر عن كافة التحريفات المسؤول عنها المراجع سواء بكشفها أو التنبؤ بمخاطر الوقوع فيها، وسواء كانت بدون عمد الإدارة / أخطاء، أو مع النية المبيتة / الغش والاحتيال. ويمكن تعريف تحريفات القوائم المالية بأنها أي انتهاك للمبادئ المحاسبية المتعارف عليها أو للقوانين والقواعد المنظمة للتقرير المالي والإفصاح. وتتفق الباحثة مع دراسة (Brown, Crowley, ) (Elliott, 2020; Dechow et al., 2011) في عدم استخدام مصطلح الغش لأنه مصطلح قانوني لا يمكن إثباته إلا بعد التقاضي من قبل مستخدمي القوائم المالية وثبات الدعوة القضائية ضد الشركة وصدور حكم ضدها واجب التنفيذ: مثل قيامها بإعادة إصدار القوائم المالية Restatement.

## 2- 1- 2- تحريفات القوائم المالية من منظور المعايير والمنظمات المهنية ومسؤولية المراجع تجاهها

أصدر مجلس معايير المراجعة الأمريكية بمعهد المحاسبين القانونيين المعتمدين (AICPA) معيار المراجعة SAS رقم 82 بعنوان "النظر في الغش عند مراجعة القوائم المالية" ليكون بمثابة حجر الزاوية في برنامج مكافحة الغش (AICPA, 2002). إذ كان يتطلب هذا المعيار من المراجع أن يقوم على وجه التحديد بتقييم مخاطر التحريف الجوهرية في القوائم المالية والتي ترجع إلى الغش في كل عملية مراجعة. وقد صنف المعيار الغش إلى نوعين هما: الغش في القوائم المالية، واختلاس الأصول. ولم يطالب المعيار المراجع بأن يقدر مخاطر الغش بمستوى معين على خلاف مخاطر الرقابة الداخلية. ولكن المطلوب من المراجع أن يبحث في العوامل التي قد تؤدي إلى الغش وإصدار قوائم مالية مضللة من ناحية والعوامل التي قد تسبب اختلاس الأصول من ناحية أخرى. ثم حل معيار المراجعة SAS رقم 99 محل المعيار 82 وذلك ليعطي للمراجع إرشادات أوسع نطاق عند تخطيط عملية المراجعة بشأن اكتشاف الغش والاختلاس. ولقد قدم المعيار الجديد 99 استراتيجية جديدة تمكن المراجع من اكتشاف الاحتيال وهي استراتيجية العصف الذهني والتي يجب استخدامها عند كل تعاقد مع عميل جديد (AICPA, 2002).

علاوة على ذلك ، كان مجلس مراقبة حسابات الشركات العامة PCAOB قلقًا أيضًا بشأن دور المراجعين في اكتشاف الاحتيال. ولذا يطلب تغيير طبيعة وتوقيت ومدى إجراءات المراجعة اللازمة للتعامل مع مخاطر التحريفات الجوهرية الناتجة عن الاحتيال. إذ يتطلب الأمر من المراجع إجراءات جديدة للحصول على أدلة أكثر موثوقية أو يمكن التحقق منها ، وقد يتطلب الوضع تعديل توقيت الاختبارات الموضوعية لتعكس مدى تقييم مخاطر التحريفات الجوهرية التي ترجع إلى الغش والاحتيال (PCAOB, 2007).

أما بالنسبة لمعايير المراجعة المصرية والتي توازي معايير المراجعة الدولية فقد صدر معيار المراجعة المصري رقم 240 بعنوان: "مسئولية المراجع بشأن الغش والتدليس عند مراجعة قوائم مالية". ويهدف هذا المعيار إلى وضع قواعد وتوفير إرشادات تتعلق بمسئولية مراقب الحسابات بشأن الغش والتدليس في مراجعة القوائم المالية كما أنه يتطرق بالتفصيل إلى كيفية تطبيق المعايير والإرشادات في معيار المراجعة المصري رقم (315) " تفهم المنشأة وبيئتها وتقييم مخاطر التحريف الهام" ومعيار المراجعة المصري رقم (330) " إجراءات المراقب لمواجهة المخاطر التي تم تقييمها" فيما يتعلق بمخاطر التحريفات الهامة والمؤثرة الناتجة عن الغش والتدليس. ويجب أن يتم دمج المعايير والإرشادات المقدمة في هذا المعيار مع إجراءات المراجعة الكلية. ويركز البحث هنا على النوع الثاني من الغش وهو التحريفات الناتجة عن إعداد تقارير مالية مزيفة. إذ يتطلب من مراقب الحسابات القيام بالإجراءات التي تمكنه من الحصول على المعلومات التي تستخدم في تحديد مخاطر التحريفات الجوهرية والمؤثرة الناتجة عن الغش والتدليس (الهيئة العامة للرقابة المالية، 2008b؛ الهيئة العامة للرقابة المالية، 2008c). ولذا يركز البحث هنا على تقييم مداخل استخدام تقنيات التعلم الآلي ML في التنبؤ بالتحريفات الجوهرية في القوائم المالية، وذلك بهدف مساعدة مراقب الحسابات في تحقيق مهمته بفعالية.

أما من ناحية مجلس الرقابة على محاسبة الشركات العامة PCAOB<sup>2</sup> فقد أصدر العديد من النشرات التي تحتوي على معايير يجب على المراجعين الالتزام بها، كان منها ما يخص تحريفات القوائم المالية. فالإصدار رقم AS2110 يعبر عن معيار خاص بعنوان "تحديد وتقدير مخاطر التحريفات الجوهرية" حيث ناقش الإجراءات التي يجب أن يتبعها المراجع في سبيل تحديد وتقدير مخاطر التحريفات الجوهرية ومنها على سبيل المثال (PCAOB, 2010) : فهم الشركة وبيئتها الداخلية والخارجية، ثم فهم أنظمة الرقابة الداخلية على عملية التقرير المالي، ومراجعة معلومات الارتباط بالعميل والتعاقدات السابقة معه، ثم أداء الإجراءات التحليلية، وإجراء مناقشة بين

PCAOB<sup>2</sup> مجلس الرقابة على محاسبة الشركات العامة: هو مؤسسة غير ربحية أسسها مجلس الشيوخ (الكونجرس) في الولايات المتحدة الأمريكية للإشراف على أعمال مراجعة الشركات العامة، ولحماية مصالح المستثمرين والجمهور؛ من خلال تعزيز الثقة في تقارير المراجعة المستقلة.

فريق عمل المراجعة حول التحريفات الجوهرية، وأخيراً عمل استفسارات من لجنة المراجعة الداخلية والإدارة حول مخاطر التحريفات الجوهرية.

كما أصدر مجلس الرقابة على محاسبة الشركات العامة PCAOB أيضاً المعيار رقم AS 2301 بعنوان "مسؤوليات المراجع تجاه مخاطر التحريفات الجوهرية" (PCAOB, 2010). إذ أوضح فيه استجابات المراجع الخارجي وردود أفعاله وتصرفاته الإلزامية نحو تحريفات القوائم المالية، حيث ناقش نوعين من الاستجابات هما: أولاً: استجابات عامة يجب تصميمها وتنفيذها مع أية مخاطر لتحريفات القوائم المالية مثل: التأكد من أن معرفة ومهارات وقدرة أعضاء فريق الارتباط الذين يتحملون مسؤوليات مهمة عن المشاركة تتناسب مع المخاطر المقدرة للتحريف الجوهري. وثانياً: استجابات خاصة بطبيعة وتوقيت ونطاق إجراءات المراجعة.

## 2-2 مفهوم التعلم الآلي ML، وتطور تقنياته في ظل الذكاء الاصطناعي AI

شهد العقد الأخير الكثير من النقاشات حول الذكاء الاصطناعي AI، وما يعنيه للجنس البشري، ومدى أهميته لصحة الإنسان وإنتاجه ورفاهيته. ولقد توصلت هذه النقاشات إلى أنه من غير الممكن إنكار أن تقنيات التعلم الآلي ML تدخل في مجالات عديدة وصناعات عديدة. فالتعلم الآلي ML هو الأساس في معالجة التحديات التي تواجه البشرية مثل: تحديات التغيرات المناخية، والتحديات الاقتصادية العالمية والمنافسة الشرسة التي تواجه بها المنظمات. ولقد شهدت السنوات الأخيرة تقدماً كبيراً في قدرات التعلم الآلي ML، كنتيجة لزيادة قدرة الكمبيوتر، ووجود البيانات الضخمة التي تتيح للآلة مزيداً من التعلم.

فإذا كان المجال الواسع للذكاء الاصطناعي (AI) هو علم صنع الآلات الذكية، فإن التعلم الآلي ML (Machine Learning) هو تقنية تسمح لأجهزة الكمبيوتر بأداء مهام محددة بذكاء، من خلال إعطاء الآلة نماذج وأمثلة ومشكلات محلولة حتى يمكنها التعلم منها، واتخاذ القرار في مواقف مماثلة. ومع التطور في هذه التقنيات أصبح من المتاح زيادة قدرة التعلم الآلي ML حتى وصل لما يعرف بالتعلم العميق DL الذي يستخدم لتنفيذ عمليات معقدة من خلال التعلم من البيانات، بدلاً من اتباع القواعد المبرمجة مسبقاً. كما يمكنها تنفيذ عمليات ومهام يصعب على الإنسان تنفيذها نتيجة للتقنيات التي يعتمد عليها التعلم الآلي ML.

وقبل التحدث عن تقنيات التعلم الآلي ML المستخدمة في كشف تحريفات القوائم المالية والتنبؤ بها، توضح الباحثة معنى مجال التعلم الآلي ML وعلاقته بالذكاء الاصطناعي ومراحل تطور تقنياته.

## 2-2 - 1 مفهوم التعلم الآلي ML

يعرف التعلم الآلي ML بأنه فرع من فروع علوم الحاسب، يمكن من خلاله جعل الأجهزة قادرة على التعلم دون الحاجة إلى برمجتها برمجة حرفية. إذ يمكن للآلة أن تتعلم من البيانات والأمثلة والخبرة السابقة. فهو شكل من أشكال الذكاء الاصطناعي (AI) الذي يعلم أجهزة الكمبيوتر التفكير بطريقة مماثلة لما يفعله البشر. يُعرف أيضًا بأنه تقنية تسمح لأجهزة الكمبيوتر بالتعلم مباشرة من الأمثلة والخبرة في شكل بيانات. وإجمالاً يمكن تعريف ال machine learning بتعليم الآلات لتقوم بالمهام بنفسها دون الحاجة إلى برمجتها برمجة حرفية في كل مرة لأداء مهمة معينة، وإنما برمجتها بطريقة تكون قادرة فيها على التعلم لأداء العديد من المهام المختلفة. ويدور التعلم الآلي حول استخدام الخوارزميات لتوجيه التنبؤات. الهدف من عملية التعلم الآلي هو إنشاء نموذج يعتمد على واحد أو أكثر من الخوارزميات. تم تطوير النموذج من خلال التدريب بهدف أن يوفر النموذج درجة عالية من القدرة على التنبؤ (IAASB, 2021a).

وعلى نطاق أشمل وأوسع عرف التعلم الآلي ML بأنه نهج يستخدم عمليات مؤتمتة لتحديد الأنماط والعلاقات بين المتغيرات في مجموعات البيانات مع تفاعل بشري محدود (Cecchini, Aytug, Koehler, & Pathak, 2010a). ويمكن استخدام التعلم الآلي ML من تحديد أنماط وعلاقات معقدة يصعب على البشر اكتشافها بالاعتماد على الأساليب الإحصائية التقليدية. كما عرفه آخرون بأنه مجموعة فرعية من علوم التصميم، والهدف منها هو تطوير أدوات مفيدة للمساعدة في حل المشكلات المهمة، عندما تسعى العلوم الطبيعية والاجتماعية إلى تطوير النظريات واختبارها (Kogan, Mayhew, & Vasarhelyi, 2019). تم استخدام تقنيات التعلم الآلي في نطاق البحث المحاسبي للتحقيق في الموضوعات المختلفة التي تهم باحثي المحاسبة والمراجعة، مثل الكشف عن الاحتيال والغش والتحرير في القوائم المالية (Whiting, Hansen, & McDonald, Albrecht, & Albrecht, 2012).

وعلى نحو أدق عرف (Bertomeu, Cheynel, Floyd, & Pan, 2021) التعلم الآلي ML بأنه منظومة واسعة يصمم من خلالها مجموعة من خوارزميات التعلم، لها العديد من الاستخدامات منها: قيادة السيارات، والتعرف على اللغة المنطوقة، واكتشاف الأمور المنتظمة الخفية في الأحجام المتزايدة من البيانات (البيانات الضخمة). وتعتمد الدراسات المالية السابقة على تدفق سلاسل من البيانات يمكن من خلالها تحديد خصائص الشركة، وسمات الحوكمة، وتقارير المراجعة، وبيانات السوق، ومتغيرات المحاسبة.



ويميز خوارزميات التعلم الآلي ML عن غيرها من النماذج بأن لها القدرة على التغلغل في البيانات الضخمة واستكشافها والكشف عن الأنماط المعقدة والمركبة في تلك البيانات، واختيار أفضل المتغيرات وأكثرها قوة تفسيرية لنتيجة معينة أو ظاهرة معينة. بالإضافة إلى أن التعلم الآلي ML يمكن من اكتشاف توقيعات معينة لتلك المتغيرات؛ من شأنها عمل تنبؤات دقيقة خارج نطاق العينة المستخدمة في الدراسة. وتمثل هذه الخوارزميات أداة رئيسية لفتح مصادر البيانات المالية الكبيرة والمتنامية؛ وذلك بغرض عمل تنبؤات أفضل وقرارات أكثر ذكاءً.

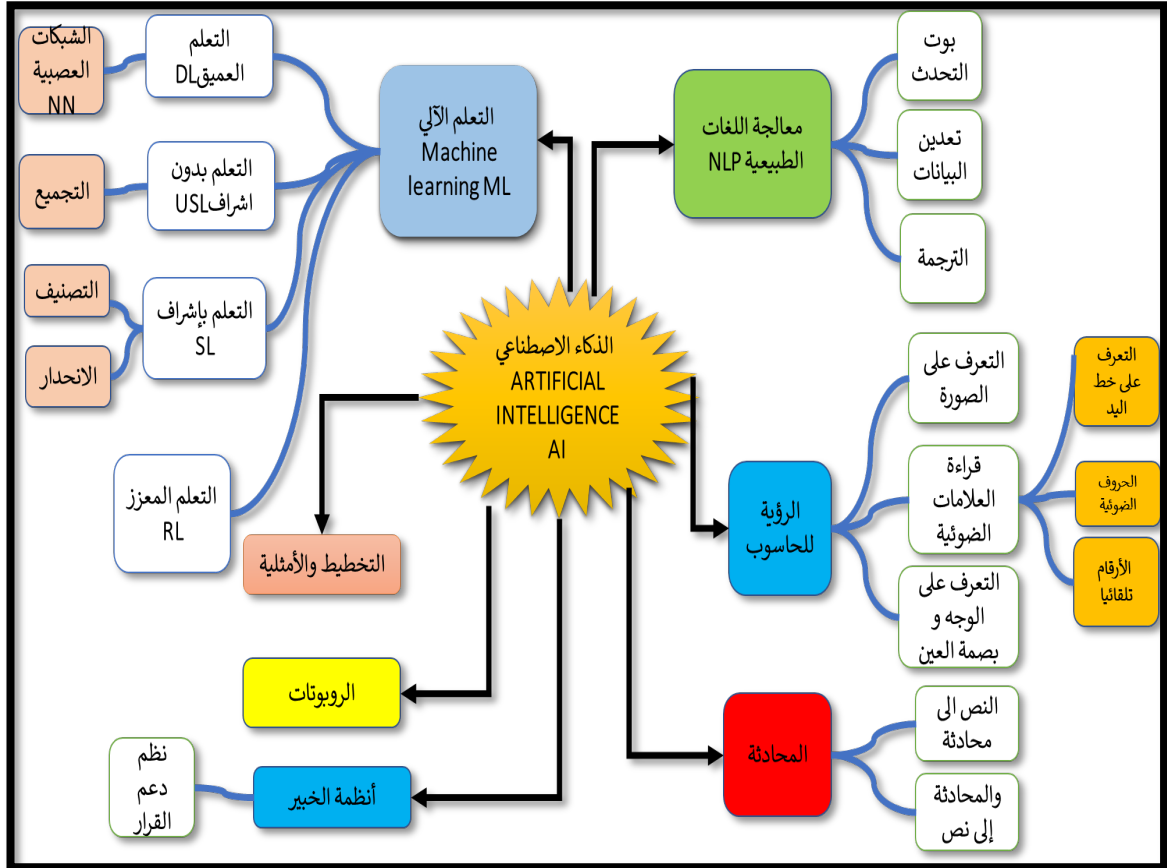
وتحاول الباحثة من خلال هذا البحث أن تبين كيفية تطبيق خوارزميات التعلم الآلي ML على بيانات الشركات من أجل التنبؤ بتحريفات القوائم المالية الجوهرية، والتي ترجع إلى أسباب عديدة كلها نتيجة للأخطاء في الأرقام المحاسبية سواء عن عمد أو عن غير قصد. إذ أنه لا تتضح العلاقة بين المتغيرات العديدة التي تمثل مدخلات نماذج الكشف عن التحريفات والتنبؤ بها وبين النواتج والمخرجات التي تمثل التحريفات. بالإضافة إلى تعدد هذه المتغيرات. ومن ثم بين الأدب السابق أن هذه الخوارزميات لها أهمية كبيرة في تحقيق الكشف عن هذه التحريفات بفعالية والتنبؤ بها بدقة بما يحقق جودة المراجعة.

## 2-2-2 علاقة التعلم الآلي ML بالذكاء الاصطناعي وأهم تقنياته

يعتمد الذكاء الاصطناعي AI على مجموعة من التقنيات الحديثة منها تقنيات التعلم الآلي ML كما هو موضح في الشكل رقم (1). حيث تنقسم تقنيات التعلم الآلي ML إلى أربعة أقسام: **(1) التعلم المعزز Reinforcement Learning** : وهو طريقة من طرق التدريب في التعلم الآلي تعتمد على مكافأة السلوكيات المرغوبة و / أو معاقبة السلوكيات غير المرغوب فيها. بشكل عام ، يكون عامل التعلم المعزز قادرًا على إدراك وتفسير بيئته ، واتخاذ الإجراءات والتعلم من خلال التجربة والخطأ (Accelerator, 2022). **(2) التعلم الخاضع للإشراف Supervised Learning** ؛ ويستخدم مجموعة البيانات المصنفة والمهيكلت والتي لها اسم أو عنوان Labeled لتدريب الخوارزميات التي تصنف البيانات أو تتوقع النتائج بدقة.

فعندما يتم إدخال بيانات الإدخال في النموذج، فإنه يعدل أوزانه حتى يتم تركيب النموذج بشكل مناسب أثناء مرحلة التدريب، ثم يتم بناء النموذج وتبدأ مرحلة الاختبار. يساعد التعلم الخاضع للإشراف المؤسسات في حل مجموعة متنوعة من مشكلات العالم الحقيقي على نطاق واسع، مثل تصنيف البريد العشوائي في مجلد منفصل عن مجلد الوارد. وتستخدم خوارزميات هذا النوع في مشكلتين: هما أولاً: مشكلة التصنيف حيث تستخدم العديد من النماذج مثل: آلات دعم

المتجه SVM، والجوار الأقرب K، وشجرة القرار DT، والغابات العشوائية RF. وثانياً: مشكلات التنبؤ باستخدام الانحدار سواء الخطي البسيط أو المتعدد أو الانحدار اللوجستي (IBM, 2020b).



الشكل رقم (1) : التعلم الآلي ML وعلاقته بالذكاء الاصطناعي \*  
\*المصدر: (IAASB, 2021a) بتصريف الباحثة

(3) **التعلم بدون إشراف Unsupervised Learning**: ويستخدم خوارزميات التعلم الآلي لتحليل مجموعات البيانات غير المسماة Unlabeled وتجميعها. ثم تكتشف هذه الخوارزميات الأنماط الخفية أو مجموعات البيانات دون الحاجة إلى تدخل بشري. إن قدرتها على اكتشاف أوجه التشابه والاختلاف في المعلومات تجعلها الحل الأمثل لتحليل البيانات الاستكشافية، واستراتيجيات البيع العابر، وتجميع وفرز العملاء، والتعرف على الصور. وتستخدم هذه الخوارزميات في مشكلتي التجميع والفرز Clustering بأنواعها المختلفة، ومشكلة الربط بين متغيرات متباعدة من خلال استنباط العلاقات Association (IBM, 2020c).

وأخيراً (4) **التعلم العميق Deep Learning**: وهو في الأساس شبكة عصبية ذات ثلاث طبقات أو أكثر. تحاول هذه الشبكات العصبية محاكاة سلوك الدماغ البشري - وإن كان بعيداً عن مطابقة قدرته - مما يسمح له "بالتعلم" من كميات كبيرة من البيانات. بينما لا يزال بإمكان الشبكة العصبية ذات الطبقة الواحدة إجراء تنبؤات تقريبية، يمكن أن تساعد الطبقات المخفية الإضافية في تحسين الدقة وتحقيق الأمثلية (IBM, 2020a).

## 2-3 مداخل استخدام تقنيات التعلم الآلي في التنبؤ بتحريفات القوائم المالية

لقد قدم الأدب المحاسبي العديد من الدراسات التي تتعلق باستخدام تقنيات التعلم الآلي ML في مجال المحاسبة والمراجعة. قدمت دراسة (Jones, 2017) نموذج لا معلمي جديد للتعلم الآلي ML يمكن من خلاله استخدام آلاف من عوامل ومتغيرات التنبؤ وترتيبها من الأدق إلى الأقل دقة. وهذا النموذج يعرف باسم نموذج تعزيز التدرج The Gradient Boosting. وهو نموذج من نماذج التعلم الآلي ML يمكن المراجع والهيئات التنظيمية من التنبؤ بإفلاس الشركة. وأوضحت دراسة (Addo, Guegan, & Hassani, 2018) أهمية استخدام تقنيات التعلم الآلي ML والتعلم العميق في التنبؤ بمخاطر الائتمان وتحليلها. واستخدمت الدراسة سبعة نماذج للتنبؤ بمخاطر الائتمان للبنوك المقرضة. فقد اعتمدت الدراسة على ثلاثة نماذج للتعلم الآلي العادي، وأربعة نماذج للتعلم العميق. إذ استخدم الكتاب نموذج الشبكة المرنة Elastic Net، ونموذج الغابات العشوائية Random Forest، وآلة تعزيز المكونات A Gradient Boosting Machine.

أما في مجال تحريفات القوائم المالية، والكشف عن الغش، والتنبؤ به فقد قدمت العديد من الدراسات حول استخدام تقنيات التعلم الآلي في ذلك. وبالبحث في هذه الدراسات أمكن للباحثة أن تستخلص ثلاثة مداخل يعتمد عليها في وضع نماذج التنبؤ بتحريفات القوائم المالية عند استخدام تقنيات التعلم الآلي: وهي المدخل المالي، و المدخل النصي، والمدخل المختلط. ويوضح الجدول رقم (1) تقنيات التعلم الآلي التي استخدمها الباحثون في ابتكار نماذج للتنبؤ بتحريفات القوائم المالية وفقاً لكل مدخل من المداخل الثلاثة.

قدم (Bertomeu et al., 2021) دراسة حول كيفية استخدام التعلم الآلي ML في الكشف عن تحريفات القوائم المالية عموماً أيما كان نوعها متعمدة أو غير متعمدة. ولقد أوضحت الدراسة أن التعلم الآلي ML يقدم طرقاً تجريبية للتقصي والبحث في مجموعات البيانات المحاسبية، والتي تعتمد على عدد كبير من المتغيرات المعرفة مسبقاً والغير معروف أولويتها بالنسبة للظاهرة المحاسبية المدروسة. وأكدت الدراسة على أن هذه الأساليب تساعد في اكتشاف وتفسير الأنماط الموجودة في التحريفات المحاسبية المستمرة. إذ أن الدراسة قد استخدمت مجموعة واسعة من المتغيرات سواء

محاسبية، أو متغيرات سوقية، أو متغيرات الحوكمة، أو المتغيرات المعتمدة على تقارير المراجعة؛ من أجل اكتشاف التحريفات الجوهرية.

## 2- 3 - 1 المدخل المالي Financial Approach للتنبؤ بتحريفات القوائم المالية

يعد المدخل المالي المعتمد على البيانات المنشورة في القوائم المالية من أكثر المداخل شيوعاً في التنبؤ بالتحريفات في القوائم المالية؛ نظراً لأن النسب المالية تمكن مستخدم القوائم المالية من الوصول إلى معلومات مفيدة بطريقة غير مباشرة ولا يمكن التوصل إليها مباشرة من البيانات الخام المعروضة في القوائم المالية. ولذا اعتمد معظم مبتكري نماذج الكشف عن التحريف في القوائم المالية وتقدير مخاطر الاحتيال المحاسبي على البيانات المالية الواردة في صورة رقمية في القوائم المالية. ومن أهم عيوب هذا المدخل أنه يعتمد على الحكم الشخصي في الكشف عن تحريفات القوائم المالية والغش المحاسبي (Hogan, Rezaee, Riley, & Velury, 2008; Kaminski, 2004). وعلى الرغم من أن هذا المدخل يعتمد في معظمه على البيانات المالية المنشورة في القوائم المالية إلا أن بعض الدراسات استخدمت بعض المؤشرات غير المالية مثل عدد العاملين. وتتناول الباحثة فيما يلي بعض النماذج المالية التي ابتكرها أصحابها لتقدير احتمال الغش والتحريف في القوائم المالية.

جدول رقم (1) مداخل استخدام تقنيات التعلم الآلي في الكشف عن والتنبؤ بتحريفات القوائم المالية		
المدخل	تقنيات التعلم الآلي (الخوارزميات) المطبقة في	المصدر
المدخل المالي	شجر القرارات DT (C4.5 <sup>3</sup> )	Kotsiantis, Koumanakos, Tzelepis, & (Tampakas, 2006)
	الشبكات العصبية الاصطناعية ANN (RBF)	
	الشبكات البيزية BN (K2 <sup>4</sup> )	
	الانحدار اللوجستي LR	
	آلة متجه الدعم SVM (SMO)	
	أقرب الجيران KNN (3NN)	
المدخل النصي	آلة المتجه الداعم SVM (WordNet)	(Cecchini, Aytug, Koehler, & Pathak, 2010b)
	الانحدار اللوجستي LR	(Humpherys et al., 2011)
	آلة متجه الدعم SVM (SMO)	
	المصنف البيزي الساذج NB	
	شجر القرارات DT (C4.5)	
التعلم المحلي المرجح LWL		
المدخل المالي + المختلط	الانحدار اللوجستي LR	(Hajek & Henriques, 2017)
	آلة المتجه الداعم SVM (SMO)	
	المجموعة بيز للتصنيف NB / )	

C4.5<sup>3</sup>: هو خوارزمية لإنشاء وتشغيل تقنية شجر القرارات في التعلم الآلي ابتكرها Ross Quinlan  
 4 K2: هي خوارزمية K2 التي اقترحها Cooper و Herskovits، حيث تستخدم طرق بحث Bayesian وطرق البحث عن تسلسل التلال لتحسين نموذج الشبكة.

	شجر القرارات DT (J48 / CART / JRip)	
	الشبكات العصبية الاصطناعية ANN (MLP)	
	مصنفات المجموعة EC (RF / Bagging)	
(Craja et al., 2020)	الأنحدار اللوجستي LR	
	الغابات العشوائية RF	
	آلة متجه الدعم SVM	
	تعزيز التدرج الشديد XGB	
	الشبكات العصبية الاصطناعية ANN	
	TF-IDF تعلم عميق (GPT-2 / HAN)	

ومن هنا تشتق الباحثة الفرض الأول للدراسة على النحو التالي:

**H1: يحقق المدخل المالي لاستخدام تقنيات التعلم الآلي ML في المراجعة الخارجية فعالية التنبؤ بتحريفات القوائم المالية**

## 2-3 - 2 المدخل النصي Text Approach للتنبؤ بتحريفات القوائم المالية

لما كانت القوائم المالية هي جزء لا يتجزأ من التقارير المالية والتي تشمل بخلاف القوائم المالية المعروفة كافة التقارير الأخرى مثل تقرير مجلس الإدارة وتقرير الحوكمة وتقرير الاستدامة وغيرها من التقارير المطلوبة في ظل اتفاقية التقارير المتكاملة. ولذا أصبح تحليل النصوص الواردة في تلك التقارير له قيمة ويحقق منفعة لمستخدمي التقارير المالية. إذ أنه تستخدم نماذج التحليل النصي من أجل التصنيف المتقدم والتنبؤ الدقيق بالغش في القوائم المالية وذلك بهدف مساعدة المراجع في الكشف عن التحريفات الجوهرية بفعالية وكفاءة (Moon, Shipman, Swanquist, & Whited, 2022).

وكثيرا ما يستخدم التحليل النصي لفحص إفصاحات الشركات، والحصول منها على معلومات ضمنية (Craja et al., 2020). فلقد استخدمت الخصائص والميزات اللغوية في تحليل المكالمات الجماعية للشركات (Larcker & Zakolyukina, 2012)، والإفصاح عن الأرباح (Davis, Piger, & Sedor, 2012)، والتقارير الدورية (Zinovyeva, Härdle, & Lessmann, 2020) والتقارير السنوية (Tang, Li, Tan, & Shi, 2020). كما ركزت العديد من الدراسات على قسم مناقشة وتحليل الإدارة A&MD الوارد في نموذج التقارير المالية الأمريكية 10-K - والمعروف في مصر وغيرها من الدول العربية باسم تقرير الإدارة المرفق بالقوائم المالية - لفحص اللغة المستخدمة في التقارير السنوية (Cecchini et al., 2010b; Humpherys et al., 2011).

ولكن التحليل النصي ليس بهذه السهولة؛ إذ يحتاج المراجعون إلى وسائل تقنية حديثة تساعدهم في جمع المعلومات المفيدة من النصوص الواردة في التقارير المالية مثل تقنيات التعلم الآلي ML وما يتبعها من التحليل النصي الآلي (Singh Yadav & Sora, 2021). ومن خلال العديد من الأشكال للبيانات الغير مهيكلة وشبه المهيكلة يمكن استخراج معلومات مفيدة ومهيكلة باستخدام ما يعرف بالتعددين النصي Text Mining TM. وفي البداية كان التعددين النصي يدوي يعتمد على عمل جداول مقسمة إلى أعمدة يحتوي كل منها على خاصية معينة يتم البحث عنها في المحتوى الإعلامي والنصوص الواردة في التقارير المالية. ثم تطور واستخدم فيه التقنيات الحديثة من خلال برمجيات التعلم الآلي ML والبحث في البيانات الضخمة أيا كان شكلها أو نوعها (Broer Bahaweres, Trawally, Hermadi, & Imam Suroso, 2021).

ولذا يمكن اشتقاق الفرض الثاني للدراسة على النحو التالي:

**H2: يحقق المدخل النصي لاستخدام تقنيات التعلم الآلي ML في المراجعة الخارجية فعالية التنبؤ بتحريفات القوائم المالية**

### 2-3 - 3 المدخل المختلط Hybrid Approach للتنبؤ بتحريفات القوائم المالية

يعتمد المدخل المختلط على الجمع بين المدخل المالي والمدخل النصي. ولقد أوضحت قليل من الدراسات فائدة المدخل المختلط من أجل تقليل مخاطر المراجع وتحقيق أعلى جودة في تقدير مخاطر الغش والتنبؤ بتحريفات القوائم المالية. إذ يتم استخدام أي من نماذج المدخل المالي السابق ذكرها، إلى جانب استخدام أي من نماذج المدخل النصي، بهدف الوصول إلى أعلى دقة ممكنة في التنبؤ بالاحتيال في القوائم المالية.

وهناك اتجاه متزايد لتطبيق المدخل المختلط والذي يعتمد على المتغيرات المالية والمتغيرات النصية لحل مشكلات المحاسبة والتمويل. فمثلاً، تعتمد الأدبيات السابقة خوارزميات K-medians للبحث عن معيار لتقييم الأداء بالاعتماد على التحليل المالي والنصي (Ding, Peng, & Wang, 2019). بالإضافة إلى استخدام خوارزميات التعلم العميق DL لتحديد المعلومات المفيدة سواء مالية أو نصية، وذلك أثناء عملية اتخاذ قرارات في المراجعة (Hunt, Rosser, & Rowe, 2021; Sun, 2019). علاوة على ذلك، أوضح الأدب المحاسبي السابق أن هناك استخدام لنماذج التعلم الآلي ML في تحسين دقة التنبؤ بالتأخر في السداد للتصنيفات الائتمانية المختلفة اعتماداً على مجموعة من المؤشرات المالية والتحليلات النصية (Munkhdalai, Munkhdalai, Namsrai, 2019). كما استخدمت الشبكات العصبية الالتفافية كأحد تقنيات التعلم الآلي ML

في التنبؤ بكل من معدلات الصرف وأسعار الأسهم وتحريفات القوائم المالية معتمدة في ذلك على الخصائص المالية والتحليل النصي ( Parot, Michell, 2017; Galeshchuk & Mukherjee, 2019; & Kristjanpoller, 2019).

وعلى الرغم من أن الدراسات قد أكدت على الأهمية المتزايدة للتحليل النصي للتقارير المالية جنباً إلى جنب مع التحليل المالي، إلا أنه لا توجد أي منها على المستوى المصري والعربي - إلى حد علم الباحثة - يقيم أهمية الجمع بين المدخلين عند استخدام المراجع الخارجي لتقنيات التعلم الآلي ML في التنبؤ بتحريفات القوائم المالية. فهذه التقنيات تمكن المراجع من استنباط سمات نصوص تقارير مجلس الإدارة من أجل مساعدته في التنبؤ بالتحريفات في القوائم المالية، ومن ثم تقليل إعادة الإصدار. علاوة على ذلك، تركز الباحثة على دمج كل من المعلومات المالية مقاسة بالنسب المالية والمعلومات النصية مقاسة ببعض السمات الشعورية المستنبطة من استخدام تقنيات التعلم الآلي ML في التحليل النصي لتقارير مجلس الإدارة وذلك بهدف التنبؤ الذكي بالتحريف في القوائم المالية. بالإضافة إلى إمكانية تفسير تلك التنبؤات، وهو جانب مهم لدعم المراجعين.

و بناء عليه تصيغ الباحثة الفرض الثالث للدراسة على النحو التالي:

**H3: يحقق المدخل المختلط لاستخدام تقنيات التعلم الآلي ML في المراجعة الخارجية فعالية تنبؤ بتحريفات القوائم المالية أعلى من كل من المدخل المالي والمدخل النصي منفردين.**

### 3- دراسة تجريبية على تقارير الشركات محل المراجعة والمقيدة بالبورصة المصرية

تهدف الدراسة التجريبية إلى التحقق من النتائج التي قد توصلت إليها الباحثة في الدراسة النظرية السابقة، وما إذا كانت تقنيات التعلم الآلي ML تفيدي في تمكين المراجع الخارجي في الكشف عن والتنبؤ بتحريفات القوائم المالية بدرجة أدق من النماذج العادية وبفعالية وجودة أعلى لعملية المراجعة بصفة عامة. وأيضاً البحث عن أكثر المداخل ملائمة للكشف عن التحريفات في القوائم المالية في الشركات المقيدة في البورصة المصرية وتمثل عملاء مكاتب المراجعة المصرية.

#### 3-1 تصميم الدراسة التجريبية

يحتوي هذا القسم من البحث على هيكل الدراسة الاختبارية، التي أجرتها الباحثة على عينة من الشركات المقيدة بالبورصة المصرية باعتبارها عملاء مكاتب المراجعة ويقع على المراجع الخارجي مسؤولية اكتشاف والتنبؤ بتحريفات القوائم المالية لها. ولذا توضح الباحثة في هذا القسم: مجتمع وعينة الدراسة، ثم المتغيرات التي استخدمت في الدراسة، والنماذج التي طبقت عليها تقنيات

التعلم الآلي ML، و أخيرا البرمجيات التي استعانت بها الباحثة في تطبيق تلك التقنيات وفي تقييم دقة تلك النماذج.

### 3 - 1 - 1 مجتمع وعينة الدراسة ومصادر البيانات

يتكون المجتمع الذي تعتمد عليه الدراسة من جميع الشركات المقيدة ببورصة الأوراق المالية المصرية خلال فترة الدراسة من 2012 إلى 2021، والتي تمثل عملاء لمكاتب المراجعة في مصر. وللحصول على عينة الدراسة قامت الباحثة بعمل مسح لبعضها من الدراسات الرائدة والأكثر تأثيرا في مجال البحث سواء على المستوى الدولي أو على مستوى مصر. وقد أوضحت الدراسات الرائدة في بناء نماذج الكشف عن والتنبؤ بالغش أو التحريفات المالية عموما مصادر البيانات الممكن الاعتماد عليها في بناء تلك النماذج كما يوضح الجدول رقم (2)

ويتضح من الجدول رقم (2) أن الدراسات العالمية تعتمد على قواعد بيانات خاصة بها للحصول على بيانات الشركات المحرفة أو التي أعادت إصدار قوائمها المالية، مثل إصدارات القرارات الإجبارية للمحاسبة والمراجعة في أمريكا AAER. وقاعدة بيانات خدمات بيانات البحث العلمي الصيني CNRDS في الصين. أما في مصر فقد تنوعت مصادر بيانات الشركات المحرفة أو المعدلة أو التي أعادت إصدار قوائمها المالية. فمنها من اعتمد على الدعاوي القضائية والجنح المرفوعة على الشركات المقيدة أسهمها بالبورصة الصادرة في محاكم القاهرة (هلالي، 2015). ومنها من اعتمد على استخدام نماذج معينة للتنبؤ بالغش في القوائم المالية مثل Z- score أو M- score أو P- score وذلك لتحديد عينة الشركات المحرفة وغير المحرفة (شحاته، 2017؛ على، 2017).

بينما اعتمدت بعض الدراسات العينة خلال فترة زمنية معينة دون أن تذكر كيفية تحديد الشركات المعدلة أو المحرفة (أبو الخير، الميهي، وعلى، 2021؛ فرج؛ 2018). وأخيرا استخدمت إحدى الدراسات تحليل محتوى التقارير المالية للشركات المقيدة بالبورصة المصرية وذلك من خلال البحث عن مرادفات معينة مثل إعادة الإصدار، أو تنقيح، أو تعديل وضبط، أو أخطاء من أجل تحديد عينة الشركات المعدلة للقوائم المالية (هلالي، 2017).

وسوف تطبق الباحثة أسلوب دراسة (هلالي، 2017) في البحث عن الشركات المحرفة للقوائم المالية من خلال البحث في محتوى التقارير المالية للشركات المقيدة في البورصة المصرية وتقارير البورصة الدورية والمعلومات الواردة في موقع مباشر شاملة تقرير مراقب الحسابات وتقرير الإدارة عن بعض المصطلحات التي تنوه عن وجود تحريف مثل: تعديل أو معدلة أو إعادة إصدار،



أو أخطاء أو غش أو احتيال أو سوء تمثيل أو تحريفات أو بتحفظ، أو مخالفة المعايير المحاسبية وذلك خلال فترة الدراسة من 2012 إلى 2021. وقد توصلت الباحثة إلى 60 حالة تحريف خلال فترة الدراسة لعدد 42 شركة.

جدول رقم (2): مصادر البيانات المستخدمة في الدراسات الاختبارية الرائدة لبناء نماذج الكشف عن والتنبؤ بتحريفات القوائم المالية*							
م	الدراسة	شركات الدراسة	نموذج التنبؤ	آلي	الدولة	المدخل	مقاييس الأفضلية
1	(Beneish, 1999)	2332/74 من عام 1998- 1982	Probit analysis / WESML	X	أمريكا	FIN	AUC (ROC)
2	(Dechow et al., 2011)	167982 /2190 من عام 1982- 2005	LR	X	أمريكا	FIN/ NFIN	Acc /TPR /FPR/FNR/ min F-score
3	(Perols, 2011)	15,934 /51 من 1998 إلى 2005	SVM/ LR/ C4.5/ Bagging/ Stacking	✓	أمريكا	FIN	Fraud Probability and MC
4	(Czerney, Schmidt, & Thompson, 2014)	30825 شركة - سنة من عام 2000 ألي 2009	LR	✓	أمريكا	LING	Robust Z
5	(Purda & Skillicorn, ) (2015)	4708 /1407 من 1994 إلى 2006	SVM	✓	أمريكا	TXT (BOW) top 200 RF words	AUC / Fraud Probability
6	(هلالى, 2015)	38 شركة من 2008 إلى 2016	R / SLR / MLR	X	مصر	FIN/ NFIN	R / ADJ R <sup>2</sup>
7	(Kim, Baik, & Cho, ) (2016)	2156 /788 من 1992 إلى 2005	LR/ SVM / BBN	✓	أمريكا	FIN	Acc /TPR/ G-mean / Cost matrices
8	(Goel & Uzuner, 2016)	180 / 180 من 1994 إلى 2012	SVM	✓	أمريكا	LING + POS tags	Acc /TPR /FPR/ Precision/ F-score
9	(Hajek & Henriques, ) (2017)	311/ 311 من 2005 إلى 2015	BBN/ DTNB /Bag/ JRIP/ CART/ SVM/ MLP/AB/ LR/ NB	✓	أمريكا	FIN + LING	Acc /TPR /TNR / MC/ F-score / AUC (ROC)
10	(على, 2017)	الشركات المسجلة فيما عدا المالية من 2012 إلى 2015	Correlation	x	مصر	FIN/ NFIN	P value
11	(شحاته, 2017)	الشركات المسجلة فيما عدا المالية 2012	LR	x	مصر	FIN/ NFIN	Wald / P value
12	(صالح, 2019)	50 مشاهدة من 2011 إلى 2017	MLR	x	مصر	FIN/ NFIN	R / ADJ R <sup>2</sup>
13	(Brown et al., 2020)	131,528 /553 من 1994 إلى 2012	LDA dynamic time series process / LR	✓	أمريكا	FIN + TXT style	Auc / F-score
14	(أبو الخير 2021, et al., )	40 /36 من 2000 إلى 2019	MLR	x	مصر	FIN/ NFIN	R / ADJ R <sup>2</sup>
15	(Xu, Xiong, & An, ) (2022)	35,922 / 4440 من 2009 إلى 2018	RF /GBDT / RUSBoost / LR / SVM / ANN	✓	الصين	FIN/ NFIN	NDCG@k, Precision@k, and Recall@k

\* المصدر: من إعداد الباحثة بناء على المصادر المذكورة في الجدول

ولما كانت الشركات المحرفة تمثل مجموعة التجربة في الدراسة وهي عينة حكمية متحيزة. ولذا يجب أن تقابل بعينة من الشركات غير المحرفة حتى يمكن تثبيت باقي العوامل من غير

متغيرات الدراسة مثل الفترة الزمنية، والقطاع الصناعي، وحجم الشركة، من أجل الوصول إلى نماذج عالية الدقة يمكن أن يستخدمها المراجع الخارجي في التنبؤ بالتحريفات بفعالية وجودة عالية.

جدول رقم (3): توزيع شركات العينة وفقا للقطاعات الصناعية*				
النسبة	الإجمالي	الشركات غير المحرفة	الشركات المحرفة	القطاع الصناعي
3.0%	4	3	1	اتصالات و اعلام و تكنولوجيا المعلومات
13.6%	24	18	6	أغذية و مشروبات و تبغ
3.0%	4	3	1	خدمات النقل و الشحن
3.0%	4	3	1	خدمات و منتجات صناعية وسيارات
6.1%	8	6	2	رعاية صحية و ادوية
9.1%	12	9	3	سياحة و ترفيه
21.2%	28	21	7	عقارات
6.1%	8	6	2	مقاولات و إنشاءات هندسية
6.1%	8	6	2	منسوجات و سلع معمرة
9.1%	12	9	3	مواد البناء
12.1%	16	12	4	موارد أساسية
3.0%	4	3	1	ورق و مواد تعبئة و تغليف
100%	132	99	33	الإجمالي


\* المصدر من إعداد الباحثة بناء على عيني الدراسة

ويراعى مجموعة من المعايير في كل شركة غير محرفة (Tang et al., 2020; Yao, ) و (Pan, Yang, Chen, & Li, 2019) بحيث تصبح مقابلة لشركة محرفة هذه المعايير كما يلي:

- يقاس الحجم بإجمالي الأصول ( مع تفاوت بمقدار  $\pm 10\%$  )
- الفترة الزمنية نفس السنة (مع تفاوت بمقدار  $\pm$  سنتين)
- القطاع الصناعي (مع تفاوت  $\pm$  شركة واحدة في القطاع الصناعي)

ولذ تتبع الباحثة أسلوب دراسة (Jan, 2021; Kotsiantis et al., 2006; Papík & Papíková, 2022) ومن المبادئ التي ذكرتها بعض الدراسات لمقابلة مفردات عينة الدراسة بعينة رقابية من الشركات هو أن يتم مقابلة كل شركة في عينة الشركات المحرفة للقوائم المالية بثلاث شركات في نفس الفترة الزمنية وفي نفس القطاع الصناعي في عينة الرقابة أو المقابلة أي بنسبة (1شركة محرفة: 3 غير محرفة) (Papík & Papíková, 2022). ومن ثم تتكون عيني الدراسة من 132 شركة منها 33 شركة محرفة للقوائم المالية يقابلها 99 شركة غير محرفة للقوائم المالية كما يتضح من الجدول رقم (3).

وقامت الباحثة بجمع البيانات الخاصة بالشركات خلال فترة ثلاث سنوات سابقة. فعلى سبيل المثال في عام 2021 يوجد شركة واحدة محرفة داخلية في عينة الدراسة ويقابلها ثلاث شركات غير محرفة من نفس القطاع الصناعي وقريبة منها في الحجم ولذا يتم جمع بيانات التقارير المالية الخاصة بهذه الشركات الأربعة خلال العام المعلن فيه تحريف الشركة المحرفة للقوائم المالية وعامين قبله أي عام 2020 وعام 2019.



### 3 - 1 - 2 متغيرات الدراسة

على الرغم من حقيقة أن اختيار المتغيرات أمر بالغ الأهمية من أجل بناء نموذج للتنبؤ بتحريفات القوائم المالية و الكشف عنها، إلا أنه لا يوجد حتى الآن مبادئ و أدوات يمكن الاعتماد عليها في اختيار المتغيرات التفسيرية لنموذج التنبؤ (Perols, 2011). بالإضافة إلى أن فئات المتغيرات تختلف كما أوضحت الباحثة من قبل فهي كمية ونصية، وذلك بسبب عدم وجود نظرية شاملة لتوجيه الباحثين في اختيار المتغير الملائم (Kaminski, 2004). ولقد استخدمت العديد من المتغيرات في الدراسات السابقة ومنها ما ثبتت فعاليته في التنبؤ بالتحريفات، ومنها ما لم يثبتت فعاليته. وبناء على العديد من الدراسات سوف تختار الباحثة المتغيرات الأكثر فعالية .

تختبر الباحثة مدى فعالية استخدام المراجع الخارجي لتقنيات التعلم الآلي ML في الكشف عن والتنبؤ بتحريفات القوائم المالية. ولذا تطبق الباحثة ثلاثة مداخل لذلك وهي: المدخل المالي والمدخل النصي والمدخل المختلط. ونتيجة لذلك تعتمد الدراسة على نوعين من المتغيرات: هما

متغيرات كمية مالية وغير مالية، ومتغيرات نصية أو لغوية أو ترتبط بالموضوع. وبناء على العديد من الدراسات السابقة سواء التي اعتمدت على المتغيرات المالية أو تلك التي استخدمت المتغيرات النصية، أو التي اعتمدت على المدخل المختلط، اختارت الباحثة متغيرات الدراسة وفقا لما هو موضح في الجدول رقم (4)

### 3-1-2-1 المتغيرات المالية

تم حساب المتغيرات المالية الواردة في الجدول رقم (4) بناء على القوائم المالية لعينتي الدراسة سواء الشركات المحرفة للقوائم المالية أو الشركات غير المحرفة للقوائم المالية. وذلك خلال فترة الدراسة. ولقد اعتمدت الباحثة على هذه المتغيرات المالية نظرا لأنها قد استخدمت في العديد من الدراسات من أجل صياغة نموذج للتنبؤ بالتحريف في القوائم المالية. وتعد الثماني متغيرات الأولى من X1 الى X8 هي بمثابة المتغيرات الأصلية التي قدمها Beneish في نموذجه والتي استخدمها كل من (Kim et al., 2016; Papík & Papíková, 2022). أما باقي المتغيرات فهي تمثل أهم النسب المالية التي استخدمت في هذا الغرض من قبل (Jan, 2018; R. Wang, Asghari, Hsu, Lee, & Chen, 2020; Yao et al., 2019)

### 3-1-2-2 المتغيرات النصية

فيما يتعلق بالمتغيرات اللغوية أو النصية، فقد ركزت الدراسات السابقة على قسم تحليل ومناقشة الإدارة A & MD والذي يقابله في الإفصاح المصري تقرير الإدارة في التقارير السنوية؛ لأنها توفر للمستثمرين فرصة للحصول على معلومات متنوعة، ومفيدة عن أداء الشركة وآفاقها المستقبلية، من منظور إدارة الشركة (Humpherys et al., 2011; Purda & Skillicorn, 2015). ولقد أظهرت الدراسات السابقة أن المحتالين هم أكثر عرضة لاستخدام كلمات سلبية وغير مؤكدة (Bodnaruk, Loughran, & McDonald, 2013; Throckmorton, Mayew, 2015). وهذا ثابت صحته نظريا عندما يتصرف المحتال تصرفا غير لفظي (Vrij, 2008). مما يشير إلى أن المخادعين غالبًا ما تتضمن أقوالهم عبارات تشير إلى النفور أو المزاج السلبي. فالمخادعين يفتقرون إلى الاقتناع ، مما يؤدي إلى درجة أقل من اليقين في أقوالهم.

وفيما يتعلق بفئات المشاعر فقط أوضحت دراسة (Goel & Uzuner, 2016) أن التقارير المالية المحرفة تحتوي على ثلاث أضعاف كلمات سلبية وأربعة أضعاف كلمات إيجابية مقارنة بالتقارير المالية غير المحرفة. لذلك قامت الباحثة بقياس نسبة الكلمات الإيجابية التي تعبر عن

التفاؤل، والكلمات السلبية التي تعبر عن التشاؤم في تقارير الإدارة الواردة في التقارير السنوية للشركات الداخلة في عيني الدراسة (محرفة / غير محرفة).

كما استخدمت الباحثة متغير نسبة الكلمات المعبرة عن عدم التأكد كمقياس ينوب عن مستوى الاقناع في تقرير الإدارة وفقا لما ورد في دراسة (Hajek & Henriques, 2017). كما استخدمت الباحثة متغيرات أربعة أخرى قدمت في دراسات سابقة تخص التقارير المالية والتحليل النصي المالي فقط. أوردت دراسة كل من (Loughran & McDonald, 2011) و (Bodnaruk et al., 2013) أنه يمكن استخدام مقاييس أخرى طورت خصيصا للتقارير المالية مثل مقياس الكلمات المتنازعة، والوسائط الضعيفة، والوسائط القوية، والكلمات المقيدة، وذلك بغرض تقليل الغموض المرتبط بمختلف معاني الكلمات ونغماتها في المجالات الفردية.

جدول رقم (4) المتغيرات المالية الداخلة في الدراسة*			
الرمز	وصف المتغير	طريقة حسابه	بعض الدراسات المستخدمة للمتغير
<i>AQI</i>	مؤشر جودة الأصول <sup>أ</sup>	$\frac{TA_t - CA_t - PPE_t}{TA_{t-1} - CA_{t-1} - PPE_{t-1}}$	(Gepp, 2015; Kim et al., 2016)
<i>DEPI</i>	مؤشر الإهلاك <sup>أ</sup>	$\frac{DE_t / (DE_t + PPE_t)}{DE_{t-1} / (DE_{t-1} + PPE_{t-1})}$	(Gepp, 2015; Kim et al., 2016)
<i>GMI</i>	مؤشر مجمل الربح <sup>أ</sup>	$\frac{S_t - CGOS_t}{S_{t-1} - CGOS_{t-1}}$	(Perols, 2011)
<i>DSRI</i>	مؤشر فترة التحصيل <sup>أ</sup>	$\frac{NAC_t / S_t}{NAC_{t-1} / S_{t-1}}$	(Gepp, 2015; Kim et al., 2016)
<i>SGAI</i>	مؤشر م. البيعية والإدارية العامة <sup>أ</sup>	$\frac{GSAE_t / S_t}{GSAE_{t-1} / S_{t-1}}$	Gepp, 2015; Kim et al., 2016; Papík & Papíková, 2022
<i>SQI</i>	مؤشر نمو المبيعات <sup>أ</sup>	$\frac{S_t - S_{t-1}}{TA_t}$	(Kirkos et al., 2007)
<i>LVGI</i>	مؤشر الرفع المالي <sup>أ</sup>	$\frac{LL_t + CL_t}{TA_t}$	Gepp, 2015; Kim et al., 2016; Papík & Papíková, 2022
<i>TATA</i>	إجمالي الاستحقاقات / إجمالي الأصول	$\frac{(NOI_t - CFO_t)}{TA_t}$	Gepp, 2015; Kim et al., 2016; Papík & Papíková, 2022
<i>CR</i>	نسبة التداول	$\frac{CA_t}{CL_t}$	(F. Chen, (Dutta, Dutta, & Raahemi, 2017) Du, Lai, & Ma, 2018)
<i>DAR</i>	نسبة المديونية للأصول	$\frac{LL_t + CL_t}{TA_t}$	(R. Wang et al., 2020; Yao et al., 2019)
<i>DER</i>	نسبة المديونية لحقوق الملكية	$\frac{LL_t + CL_t}{TA_t}$	(Dutta et al., 2017)(Lin et al., 2015)
<i>FAT</i>	معدل دوران الأصول الثابتة	$\frac{NOI_t}{FA_t}$	(R. Wang et al., 2020; Yao et al., 2019)
<i>GPTA</i>	نسبة مجمل الربح لإجمالي الأصول	$\frac{GI_t}{TA_t}$	(Kirkos et al., 2007)(F. Chen et al., 2018)
<i>CAT</i>	معدل دوران الأصول المتداولة	$\frac{NOI_t}{CA_t}$	(R. Wang et al., 2020; Yao et al., 2019)
<i>NPS</i>	صافي الربح / المبيعات	$\frac{NI_t}{S_t}$	(Hajek & Henriques, 2017)
<i>ROA</i>	العائد على الأصول	$\frac{NI_t}{TA_t}$	(R. Wang et al., 2020; Yao et al., 2019)

(R. Wang et al., 2020; Yao et al., 2019)	$\frac{NI_t}{TE_t}$	العائد على حقوق الملاك	ROE
TA: إجمالي الأصول، PPE العقارات والمعدات، CA: الأصول المتداولة، LL: الخصوم طويلة الأجل، CL: الخصوم المتداولة، NI: صافي الدخل بعد الضرائب، GI: مجمل الربح، S: المبيعات، NOI: صافي دخل التشغيل، CFO: التدفقات النقدية من التشغيل، DE: الإهلاك، FA: الأصول الثابتة			
a مؤشر من مؤشرات دراسة (Beneish, 1999) واستخدم في دراسات أخرى.			
*المصدر من إعداد الباحثة بالاستعانة بالمصادر المذكورة في آخر خانة			

ونظرا لأن تقارير الإدارة في الشركات المقيدة بالبورصة المصرية معلنة باللغة العربية، وتحتاج الباحثة لوقت طويل للبحث في القواميس العربية لاستخراج قوائم بالكلمات التي تعبر عن كل متغير من المتغيرات النصية الداخلة في الدراسة. ولذا استعانت الباحثة بأداة الترجمة التي يحتوي عليها برنامج IBM SPSS Modeler والمعروفة باسم Translation Node؛ وذلك من أجل ترجمة تقارير مجلس الإدارة التي حصلت عليها لبعض مفردات عينتي الدراسة. وبالنسبة لقوائم الكلمات المعبرة عن متغيرات الدراسة من تقاؤل وسلبية وتؤكد فقد اختارت الباحثة القوائم المشهورة المعروفة باسم (L & M) وهي قوائم أعدتها دراسة (Loughran & McDonald, 2011)، واستعانت بها العديد من الدراسات اللاحقة نظرا لأنها تخص التحليل النصي الخاص بالقوائم المالية، وتحتوي على كلمات معبرة عن كل الخصائص اللغوية في القوائم المالية.

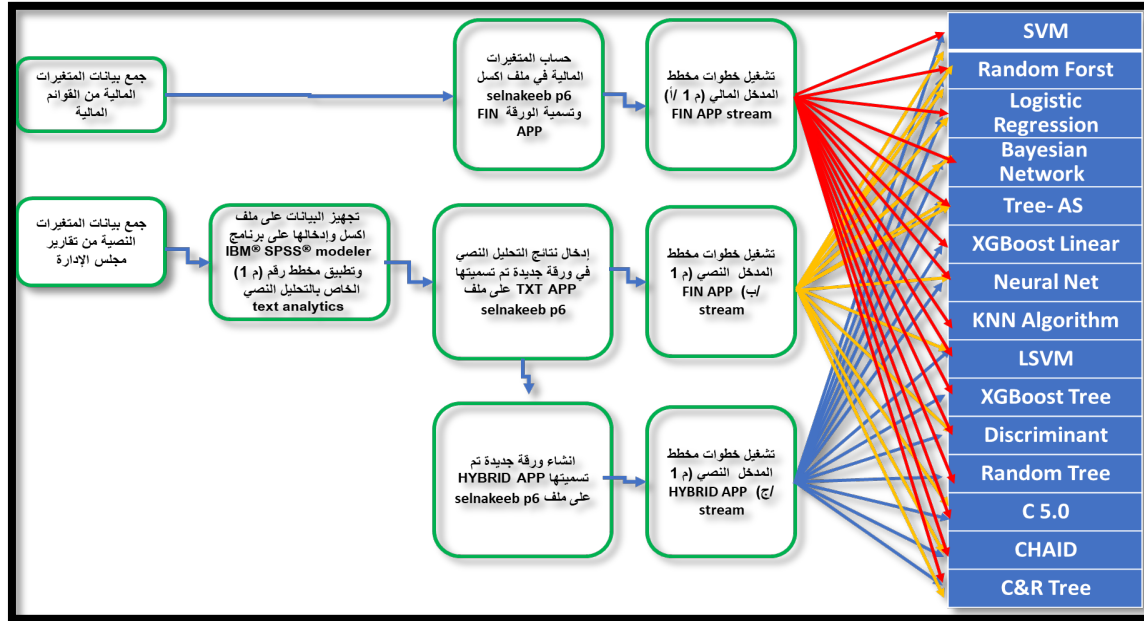
جدول رقم (5) المتغيرات النصية الداخلة في الدراسة*			
الرمز	وصف المتغير	طريقة حسابه	بعض الدراسات المستخدمة للمتغير
POS	نسبة الكلمات الإيجابية (تقاؤل)	عدد الكلمات الإيجابية/ إجمالي عدد الكلمات في التقرير	(Hajek & Henriques, 2017)
NEG	نسبة الكلمات السلبية (تشاؤم)	عدد الكلمات السلبية/ إجمالي عدد الكلمات في التقرير	(Hajek & Henriques, 2017)
TONE	النعمه الكلية للتقرير	(عدد الكلمات الإيجابية - عدد الكلمات السلبية) / (عدد الكلمات الإيجابية + عدد الكلمات السلبية)	(Hajek & Henriques, 2017)
LITIG	نسبة كلمات النزاع القضائي	عدد كلمات النزاع القضائي/ إجمالي عدد الكلمات في التقرير	(Loughran & McDonald, 2011)
WEAKM	نسبة الكلمات المساعدة الضعيفة	عدد الكلمات المساعدة الضعيفة/ إجمالي عدد الكلمات في التقرير	(Loughran & McDonald, 2011)
STRONGM	نسبة الكلمات المساعدة القوية	عدد الكلمات المساعدة القوية/ إجمالي عدد الكلمات في التقرير	(Loughran & McDonald, 2011)
CONST	نسبة كلمات القيود (الشروط)	عدد كلمات القيود/ إجمالي عدد الكلمات في التقرير	(Loughran & McDonald, 2011)

\*المصدر من إعداد الباحثة بالاستعانة بالمصادر المذكورة في آخر عمود

### 3 - 1 - 3 خطوات تنفيذ التجربة على برنامج IBM® SPSS® modeler

يوجد ثلاث خطوات لتنفيذ التجربة على البرنامج بعد قياس كافة المتغيرات النصية والمالية وإعداد ملف اكسل يحتوى على ثلاث ورقات الأولى لجميع المتغيرات والثانية للمتغيرات المالية فقط

والثالثة للمتغيرات النصية فقط. ويبين الشكل رقم (3) تخطيط عام لخطوات تنفيذ التجربة على برنامج IBM® SPSS® modeler. كما توضح الباحثة في نهاية البحث في الملحق رقم (م) / (1) التخطيطات المتتابعة لتنفيذ كل مدخل على البرنامج



الشكل رقم (3) تخطيط الدراسة التجريبية\*  
المصدر: من إعداد الباحثة

وبناء على الشكل السابق توضح الباحثة فيما يلي خطوات التجربة وفقاً لما تم على البرنامج

#### الخطوة الأولى: التجهيز الأولي للبيانات باستخدام Auto data prep node

استخدمت الباحثة عقدة Auto data prep وفيها يتم تحديد المتغير الهدف والذي يمثل المتغير التابع المعبر عنه بتحريف القوائم المالية وهو متغير وهمي يأخذ القيمة (1) في حالة تحريف القوائم المالية، والقيمة (0) في حالة عدم التحريف. ثم تحدد باقي المتغيرات على أنها تنبؤية أو مستقلة أو تفسيرية. كما قامت الباحثة باختيار تحويل المتغيرات المتصلة باستخدام درجات Z بمتوسط (0) وانحراف معياري (1) حتى لا تؤثر القيمة المتطرفة على العلاقة بين المتغير المستقل والتابع.

جدول رقم (6) القدرة التنبؤية للمتغيرات المستقلة وفقاً لإرتباطها بالمتغير التابع*			
المتغير	القدرة التنبؤية	المتغير	القدرة التنبؤية

0.17	CONST	0.50	INDUSTRY
0.17	DER	0.30	NPS
0.16	DEPI	0.26	GMI
0.14	STRONGM	0.24	CR
0.14	GPTA	0.24	CAT
0.14	FAT	0.22	ROA
0.12	YEAR	0.22	SQI
0.11	NEG	0.21	LVGI
0.10	LITIG	0.21	AQI
0.10	WEAKM	0.20	DAR
0.09	TONE	0.19	ROE
0.09	POS	0.19	DSRI
EXCLUDED	FIRM	0.18	DGAI
		0.18	TATA
* المصدر من إعداد الباحثة وفقا لمخرجات برنامج IBM® SPSS® modeler			

أما فيما يتعلق بمعالجة القيم المفقودة في بعض المتغيرات فقد طبقت الباحثة أسلوب تعويض القيم المفقودة عن طريق اختيار قيمة الوسط mean للقيمة المفقودة بالنسبة للمتغيرات المتصلة، واختيار الوسيط median للقيم المفقودة بالنسبة للمتغيرات الترتيبية، وأخيرا تم اختيار المنوال mode لتعويض القيم المتوسطة بالنسبة للمتغيرات الأسمية. وقد اتبعت الباحثة منهج إكمال القيم المفقودة على نحو العديد من الدراسات ( Beneish, 1999; Gepp, 2015; Papík & (Papíková, 2022; Yao et al., 2019).

وهناك أسلوب آخر اتبعه بعض الباحثين وهو حذف الشركات ذات القيم المفقودة تماما من الدراسة، إلا أنه تم انتقاد هذا الأسلوب في كشف التحريفات (Mao & Ye, 2022) لأن ذلك قد تسبب في فقدان المعلومات الأساسية لاكتشاف الاحتيال. قد يؤدي التضمين (استبدال القيم المفقودة أو منخفضة الجودة) إلى تحسين مستويات الدقة المحققة في الكشف عن الاحتيال. ومن ثم يجب على المراجعين في إجراءاتهم التحليلية أن يتبعوا أسلوب التضمين وليس الحذف للحصول على تنبؤات أدق بتحريفات القوائم المالية.

وأخيرا قامت الباحثة من خلال هذه الأداة بحساب القدرة التنبؤية لكل متغير وفقا لدرجة ارتباطه بالمتغير التابع من نفس الأداة كما يتضح من الجدول رقم (6)



ويتضح من الجدول أن القطاع الصناعي أظهر أعلى قدرة على التنبؤ بالتحريف يليه صافي الربح بالنسبة للمبيعات NPS وهكذا باقي المتغيرات المالية أظهرت قدرة تنبؤية معقولة. أما المتغيرات النصية فكانت الأقل في القدرة التنبؤية حيث كانت متغيرات الشروط النصية أعلاها بقدرة تنبؤية 0.17. إلا أن جميع المتغيرات كانت أعلى من 0.05 أي أنها لها قدرة تنبؤية بتحريفات القوائم المالية.

### الخطوة الثانية: تطبيق أداة اختيار المتغيرات Feature Selection

نظرا لأن هناك تجميعات عديدة يمكن أن تدخل في نماذج التنبؤ بتحريف القوائم المالية سواء بتطبيق مدخل المتغيرات المالية فقط أو المتغيرات النصية فقط أو كلاهما؛ لذا حتى يحدث توازن في نموذج التنبؤ بالتحريف وحلا لمشكلة كثرة الأبعاد يجب تطبيق أداة من أدوات اختيار الخصائص أو الميزات أو كما تسميها الباحثة المتغيرات التفسيرية. وهناك العديد من الطرق المتبعة في اختيار المتغيرات فيمكن ان يتم من خلال تطبيق قاعدة تصفية، أو من خلال تطبيق خوارزميات متنوعة فقد طبقت دراسة (Papík & Papíková, 2022) أسلوبين الأول لتجميع المتغيرات باستخدام خوارزمية Boruta والثاني عن طريق التجميع باستخدام أسلوب انحدار lasso. أما دراسة (Hajek & Henriques, 2017) فقد طبقت قاعدة التصفية بناء على القوة التنبؤية لاستبعاد المتغيرات التي ليس لها أي علاقة بالمتغير التابع ثم استخدمت خوارزمية الانتقاء الأول BestFirst من أجل تجميع مجموعات المتغيرات.

ونظرا لأن برنامج IBM® SPSS® modeler المستخدم في الدراسة الحالية يحتوي على أداة يمكن من خلالها اختيار المتغيرات التفسيرية الأهم في الوصول إلى المتغير التابع الممثل لتحريف القوائم المالية والمعروفة باسم Feature Selection فقد استخدمتها الباحثة وطبقتها في الثلاث مخططات (وفقا لثلاث مداخل: مالي، نصي، مختلط).

### الخطوة الثالثة: تطبيق أداة التصنيف التلقائي Auto Classifier

وهذه الأداة تحتوي على تبويب الخبير وفيه يتم اختيار نماذج التعلم الآلي ML المناسبة للمتغيرات والتي تحقق أعلى درجات دقة. وقد طبقتها الباحثة مرتين إحداهما على المتغيرات كلها

بدون اختيار، والمرة الثانية على المتغيرات بعد الاختيار وفقاً للخطوة السابقة، وذلك في الثلاث مخططات بهدف المقارنة بين دقة كل نموذج.

ويوضح الملحق رقم (م/1) أشكال مخططات التدفق التي صممتها ونفذتها الباحثة على برنامج IBM® SPSS® modeler من أجل الوصول إلى النتائج التالي شرحها وربطها بفروض الدراسة.

### الخطوة الرابعة: اختيار مقاييس أداء نماذج التعلم الآلي

إن قياس مدى نجاح نموذج التعلم الآلي في اكتشاف الشركات المحرفة في مرحلة التدريب (70% من البيانات) والتنبؤ بها في مرحلة الاختبار (30% من البيانات) يعد هدف الباحثة الأساسي في هذه الدراسة التجريبية، وذلك من أجل توجيه المراجعين الخارجيين إلى النماذج الأعلى دقة والأكثر ملائمة للتنبؤ بالتحريفات في القوائم المالية والتي ترفع من جودة المراجعة وتحقق فعاليتها. وقد تعددت مقاييس الأداء التي استخدمها الباحثون في قياس مدى نجاح ودقة نماذج التعلم الآلي، إلا أن معظم الدراسات التي ركزت على مشكلة التحريف في القوائم المالية استخدمت مجموعة من المقاييس تستخرج كلها من جدول مقارنة الفعلي بالمتنبأ به المعروف لأي تجربة أو اختبار باسم مصفوفة الخطأ Confusion Matrix (Hajek & Henriques, 2017; Jan, 2018; Papík & Papíková, 2022). فيها يتم مقارنة حالتي المتنبأ به (صفي تلك المصفوفة) بحالتي الفعلي (عمودي المصفوفة) في أي اختبار نتيجته ثنائية إما موجب أو سالب وهنا موجب شركة محرفة وسالب شركة غير محرفة. كما هو موضح في الجدول رقم (7).

جدول رقم (7) مصفوفة الخطأ Confusion Matrix للشركات المحرفة وغير المحرفة الداخلة في الدراسة*			
الفعلي Actual وفقاً للبيانات التقارير المالية			
غير محرفة (0)	محرفة (1)		
False Positive FP	True Positive TP	محرفة (1)	المتنبأ به Predicted وفقاً لنماذج التعلم الآلي
True Negative TN	False Negative FN	غير محرفة (0)	

\* المصدر (Field, 2013; Kulkarni, Chong, & Batarseh, 2020) بتصريف الباحثة

وبناء على هذه المصفوفة يتم حساب مجموعة من مقاييس الأداء التي تقيس مدى نجاح وفعالية نماذج التعلم الآلي في الكشف عن والتنبؤ بتحريرات القوائم المالية، وتوضح الباحثة فيما يلي تلك المقاييس وكيفية حسابها:

### 1. الدقة Accuracy

ويعبر هذا المقياس عن نسبة التنبؤ الصحيح (شركات محرفة وغير محرفة) إلى إجمالي حجم العينة.

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

### 2. حساسية النموذج Sensitivity

ويقاس هذا المقياس مدى قدرة النموذج على الكشف عن الشركات المحرفة على نحو صحيح أي أنه يحدد معدل حالات الكشف الصحيح عن الشركات المحرفة نسبة إلى إجمالي الشركات المحرفة في بيانات الدراسة، كلما أعدنا الاستخدام ولذا يعرف بمقياس إعادة الاستدعاء Recall

$$Sensitivity = \frac{TP}{TP+FN} \quad (2)$$

### 3. نوعية النموذج Specificity

ويعبر هذا المقياس عن مدى جودة نموذج التعلم الآلي في تجنب التصنيف الخاطئ للشركات على أنها غير محرفة.

$$Specificity = \frac{TN}{TN+FP} \quad (3)$$

### 4. احكام النموذج Precision

ويقاس هذا المقياس عن مدى إحكام نموذج التعلم الآلي في الكشف الصحيح عن الشركات المحرفة عند تكرار استخدام نفس النموذج.

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

### 5. مقياس درجات إف F-measure

ونظراً لأن هذه الدراسة تتعامل مع بيانات غير متوازنة بين الشركات المحرفة وغير المحرفة. فنسبة المحرفة إلى غير المحرفة 1 : 3 ، لذا يفضل استخدام مقياس F ليحسب مدى الانسجام بين كل من الحساسية والإحكام للنموذج المستخدم في التنبؤ بالتحريف.

$$(5) \dots\dots\dots \text{درجات إف } F\text{-measure} \text{ لنموذج التعلم الآلي} = \frac{2 \times \text{precision} \times \text{sensitivity}}{\text{precision} + \text{sensitivity}}$$

## 6. مقياس AUC

وهو يمثل المساحة تحت منحنى ROC والذي يقيس احتمال أن النموذج يرتب الحالات المحرفة أعلى من الحالات غير المحرفة عند التصنيف اللحظي، وهو يعبر عن قوة النموذج في التنبؤ.

### 3-2 تحليل نتائج الدراسة التجريبية والتحقق من الفروض

تحقيقاً لأهداف البحث واختبار صحة فروضه صممت الباحثة تجربة على برنامج IBM SPSS modeler 18.3 with text analytics. ويوضح الشكل رقم ( 4 ) مخطط التجربة المصممة. فلقد قامت الباحثة أولاً بجمع البيانات الخاصة بالمتغيرات المالية من القوائم المالية وتنسيقها في ملف اكسل في ورقة خاصة بها. ثم قامت الباحثة بتجميع ما أتيح لها من تقارير مجلس الإدارة لشركات عينتي الدراسة ووضعتها في صورة ملف فاصلة في اكسل وبعد ترجمته على برنامج IBM® SPSS® modeler، أمكن إنشاء ورقة في نفس ملف الاكسل خاصة بالمتغيرات النصية بعد حسابها. وأخيراً على نفس الملف أنشأت الباحثة ورقة ثالثة تحتوي على جميع المتغيرات المالية والنصية معاً. وهذا هو الملف الذي أدخلته الباحثة كمصدر للبيانات في التجربة كما هو موضح في الشكل رقم (4).

يوضح الجدول (8) الإحصاء الوصفي الأساسي للعينات. ويلاحظ أن النتيجة الأكثر لفتاً للانتباه والتي تصف البيانات هي أن الشركات المحرفة للقوائم المالية أظهرت ارتفاعاً ملحوظاً في قيم المتوسطات عن الشركات غير المحرفة، وذلك في كل من مؤشر نسبة الإهلاك *DEPI*، ومؤشر نسبة مجمل الربح *GMI* ، ومؤشر نسبة المصروفات البيعية والإدارية *DSRI*، ومؤشر نمو المبيعات *SQI* ومؤشر نسبة الربح المالي *LVGI*، وأخيراً مؤشر نسبة الدين إلى الأصول *DAR* . وهذا يؤكد على أن الشركات التي تلجأ لإدارتها للتحريف في القوائم المالية هي الشركات الأكثر عرضة للأزمات المالية والإفلاس ولذا تحاول أن تغطي هذا بتحريفات في القوائم المالية.

## 3-2 - 1 تحليل النتائج الوصفية لمتغيرات الدراسة

جدول رقم (8) الإحصاءات الوصفية للمتغيرات المالية للدراسة (وسط $\pm$ الانحراف المعياري)*									
الشركات غير المحرفة		الشركات المحرفة		المتغير	الشركات غير المحرفة		الشركات المحرفة		المتغير
St.Dev.	mean	St.Dev.	mean		St.Dev.	mean	St.Dev.	mean	
40.658	54.215	39.578	68.245	DAR	1460.4	438.5	995.8	378.7	AQI
322.2	458.7	77.3	108.1	DER	0.1154	0.6587	0.8888	0.9547	DEPI
214.294	50.214	30.1247	9.2147	FAT	0.2228	0.2354	0.1245	0.4587	GMI
294.5	403.0	62.5	82.7	GPTA	0.1257	0.5621	0.0124	0.8592	DSRI
1.4214	1.546	1.3654	1.2451	CAT	0.1125	0.0215	0.2398	-0.1249	SGAI
95.3254	5.2489	163.547	9.8147	NPS	0.3214	0.2225	0.3698	0.3265	SQI
12.562	6.508	17.601	-0.0165	ROA	0.2166	0.1111	0.1289	0.214	LVGI
27.233	15.472	136.321	-17.123	ROE	0.9521	0.6548	0.7845	0.5612	TATA
					2.1456	3.2149	3.1243	2.3215	CR

\* المصدر من إعداد الباحثة بناء على مخرجات برنامج IBM SPSS Modeler 18.3

كما أظهرت النتائج الوصفية انخفاضا ملحوظا في متوسطات الشركات المحرفة عن الشركات غير المحرفة وذلك في كل من: مؤشر نسبة المديونية لحقوق الملكية DER، ومعدل دوران إجمالي الأصول (TATA)، ومعدل دوران الأصول الثابتة FAT والمتداولة CAT، بالإضافة إلى الانخفاض في متوسط نسبة العائد على الأصول ROA والعائد على حقوق الملكية ROE. مما يؤكد على حقيقة أن المركز المالي ونتائج الأعمال للشركات المحرفة دائما في غير صالح المساهمين وأصحاب المصالح مما يدفع الإدارة إلى التحريف في القوائم المالية لتجميل الصورة.

جدول رقم (9) الإحصاءات الوصفية للمتغيرات النصية للدراسة (وسط $\pm$ الانحراف المعياري)*				
الشركات غير المحرفة		الشركات المحرفة		المتغير
St.Dev.	mean	St.Dev.	mean	
0.1260	0.0931	-0.0105	0.0116	POS
0.0037	0.0018	0.2229	0.2035	NEG
0.1286	-0.4315	0.1291	-0.4926	TONE
0.0030	0.0135	0.0028	0.0132	UNCERT
0.0081	0.0149	0.0078	.00152	LITIG
0.0014	0.0041	0.0015	.00042	STRONGM

0.0019	1.0066	0.0018	.00046	<i>WEAKM</i>
0.0018	0.0068	0.0016	.00065	<i>CONST</i>
* المصدر من إعداد الباحثة بناء على مخرجات برنامج IBM SPSS Modeler 18.3				

### 2-3 - 2 تحليل نتائج نماذج التعلم الآلي

يبين الجدول رقم (10) تقييم نماذج التعلم الآلي في المدخل الأول وهو المدخل المالي، الآلة الداعم الخطي LSVM والانحدار اللوجستي LR قد حققوا أعلى مستويات دقة (97.6% ، 97.6% و 93.1% ، 86.2% على التوالي). وبتطبيق أداة اختيار المتغيرات feature selection لم تظهر هذه النماذج تحسناً في مستوى الدقة باستثناء نموذج متجه الآلة الداعم الخطي LSVM حيث ارتفع مستوى الدقة من 93.1% إلى 96.8% نظراً لأن هذا النموذج كان الأقل في مقياس المساحة تحت منحنى ROC ولذا كان هناك مجال للتحسن. ويؤكد ذلك مقياس F- SCORE حيث كان الأعلى بالنسبة لهذه النماذج عند استخدام المدخل المالي.

جدول رقم (10) مقاييس تقييم أداء نماذج التعلم الآلي وفقاً للمدخل المالي <i>Financial approach</i>				
المساحة تحت المنحنى AUC	مقياس F	الدقة Accuracy	خواريزمية التطبيق	نموذج التعلم الآلي
1.0	0.918	97.692	SVMALL	SVM
1.0	0.918	97.692	SVMFS	
0.458	0.399	65.385	RFALL	Random Forst
0.724	0.653	68.462	RFFS	
1.0	0.988	86.154	LRALL	Logistic Regression
1.0	0.988	86.154	LRFS	
0.873	0.754	49.231	BNALL	Bayesian Network
0.992	0.971	80.000	BNFS	
1.0	0.918	97.692	MLPALL	Tree- AS
1.0	0.918	97.692	MLPFS	
0.790	0.775	76.923	XGBLALL	XGBoost Linear
0.801	0.791	76.923	XGBLFS	
0.952	0.899	72.308	ANNALL	Neural Net
0.984	0.912	73.846	ANNFS	
0.896	0.874	87.692	KNNALL	KNN Algorithm
0.871	0.645	83.077	KNNFS	
0.929	0.911	93.077	LSVMALL	LSVM

1.000	0.924	96.923	LSVMFS	
0.597	0.512	76.923	XGBTALL	XGBoost Tree
0.581	0.417	76.923	XGBTFS	
0.441	0.410	62.308	DISCALL	Discriminant
0.484	0.456	64.615	DISCFS	
0.502	0.478	53.846	RTALL	Random Tree
0.426	0.402	53.846	RTFS	
0.500	0.487	76.923	C5ALL	C 5.0
0.500	0.487	76.923	C5FS	
0.500	0.487	76.923	CHAIDALL	CHAID
0.500	0.487	76.923	CHAIDFS	
0.500	0.468	76.923	CRALL	C&R Tree
0.500	0.468	76.923	CRFS	
*المصدر من إعداد الباحثة بناء على تشغيل مخطط المدخل المالي على برنامج IBM® SPSS® modeler				

أما نموذج الشبكة البيزية Bayesian Network فعلى الرغم من أنه أظهر أقل النتائج في مستوى الدقة 49.2% إلا أن التحسن كان فائق بتطبيق أداة اختيار المتغيرات، حيث ارتفعت الدقة إلى 80%. وكانت باقي النماذج على مستوى متوسط من الدقة يتراوح بين 60% و 80% وهذا يتفق مع معظم الدراسات التي طبقت المدخل المالي.

جدول رقم (11) مقاييس تقييم أداء نماذج التعلم الآلي وفقا للمدخل النصي TEXT*				
المساحة تحت المنحنى AUC	مقياس F	الدقة Accuracy	خوارزمية التطبيق	نموذج التعلم الآلي
0.489	0.4111	74.615	SVMALL	SVM
0.692	0.625	78.283	SVMFS	
0.480	0.402	75.385	RFALL	Random Forst
0.608	0.598	71.212	RFFS	
0.433	0.399	76.154	LRALL	Logistic Regression
0.587	0.561	73.737	LRFS	
0.553	0.493	21.538	BNALL	Bayesian Network
0.775	0.725	77.778	BNFS	
0.597	0.504	76.923	MLPALL	Tree- AS
0.591	0.574	73.485	MLPFS	
0.437	0.384	76.923	XGBLALL	XGBoost Linear
0.586	0.549	73.485	XGBLFS	
0.535	0.501	76.923	ANNALL	Neural Net
0.619	0.625	73.485	ANNFS	

0.430	0.401	73.077	<b>KNNALL</b>	<b>KNN Algorithm</b>
0.765	0.712	74.747	<b>KNNFS</b>	
0.451	0.325	77.692	<b>LSVMALL</b>	<b>LSVM</b>
0.597	0.531	72.980	<b>LSVMFS</b>	
0.607	0.588	76.923	<b>XGBTALL</b>	<b>XGBoost Tree</b>
0.958	0.874	73.485	<b>XGBTFS</b>	
0.531	0.504	58.462	<b>DISCALL</b>	<b>Discriminant</b>
0.598	0.546	56.313	<b>DISCFS</b>	
0.511	0.467	63.077	<b>RTALL</b>	<b>Random Tree</b>
0.608	0.597	71.212	<b>RTFS</b>	
0.518	0.494	66.154	<b>C5ALL</b>	<b>C 5.0</b>
0.500	0.435	73.485	<b>C5FS</b>	
0.527	0.457	68.462	<b>CHAIDALL</b>	<b>CHAID</b>
0.595	0.513	73.485	<b>CHAIDFS</b>	
0.500	0.426	76.923	<b>CRALL</b>	<b>C&amp;R Tree</b>
0.606	0.588	75.000	<b>CRFS</b>	

\*المصدر من إعداد الباحثة بناء على تشغيل مخطط المدخل المالي على برنامج IBM® SPSS® modeler

وتؤكد نتائج المدخل المالي تحقق صحة الفرض الأول والذي كان ينص على أنه: يحقق المدخل المالي لاستخدام تقنيات التعلم الآلي ML في المراجعة الخارجية فعالية التنبؤ بتحريفات القوائم المالية، نظراً لأن مستويات الدقة كانت في حدود المرتفع والمتوسط في نسبة 90% من نماذج التعلم الآلي. مما يساعد المراجع في أداء مهمة قياس مخاطر التحريف والتنبؤ بها بفعالية.

جدول رقم (12) مقاييس تقييم أداء نماذج التعلم الآلي وفقاً للمدخل المختلط Hybrid approach*				
المساحة تحت المنحنى AUC	مقياس F	الدقة Accuracy	خوارزمية التطبيق	نموذج التعلم الآلي
0.424	0.417	67.692	<b>SVMALL</b>	<b>SVM</b>
0.569	0.541	75.500	<b>SVMFS</b>	
0.404	0.394	66.923	<b>RFALL</b>	<b>Random Forst</b>
0.999	0.924	94.555	<b>RFFS</b>	
0.865	0.745	89.214	<b>LRALL</b>	<b>Logistic Regression</b>
0.922	0.854	90.548	<b>LRFS</b>	
0.865	0.799	81.481	<b>BNALL</b>	<b>Bayesian Network</b>
0.772	0.761	78.750	<b>BNFS</b>	
0.617	0.5	75.926	<b>MLPALL</b>	<b>Tree- AS</b>
0.584	0.592	74.250	<b>MLPFS</b>	
0.684	0.599	75.962	<b>XGBLALL</b>	<b>XGBoost Linear</b>
0.623	0.587	74.250	<b>XGBLFS</b>	
0.642	0.578	74.815	<b>ANNALL</b>	<b>Neural Net</b>
0.630	0.602	74.000	<b>ANNFS</b>	



0.763	0.754	77.407	KNNALL	KNN Algorithm
0.826	0.795	76.750	KNNFS	
0.674	0.623	75.556	LSVMALL	LSVM
0.610	0.601	74.500	LSVMFS	
0.944	0.941	75.926	XGBTALL	XGBoost Tree
0.946	0.854	74.25	XGBTFS	
0.678	0.655	63.704	DISCALL	Discriminant
0.629	0.611	60.250	DISCFS	
0.713	0.698	74.444	RTALL	Random Tree
0.613	0.605	71.000	RTFS	
0.757	0.692	82.963	C5ALL	C 5.0
0.500	0.478	74.250	C5FS	
0.617	0.578	75.926	CHAIDALL	CHAID
0.607	0.547	74.500	CHAIDFS	
0.697	0.632	77.037	CRALL	C&R Tree
0.500	0.488	74.250	CRFS	
*المصدر من إعداد الباحثة بناء على تشغيل مخطط المدخل المالي على برنامج IBM® SPSS® modeler				

كما يوضح الجدول رقم (11) نتائج استخدام المدخل النصي في الكشف عن والتنبؤ بالشركات المحرفة للقوائم المالية. ويستنتج من الجدول أن كل نماذج التعلم الآلي حققت مستوى أقل من الدقة عن استخدام المدخل المالي، وهذا يتفق مع نتائج ( Craja et al., 2020; Hajek & Henriques, 2017). فأعلى مستوى دقة حققه نموذج متجه الآلة الداعم الخطي LSVM ( 77.7%) وهو مستوى متوسط ويؤكدده كل مقياس F- Score و مقياس AUC حيث كانت أقل من النصف (0.325، 0.451 على التوالي) أي أن استخدام المراجع للمدخل النصي فقط لا يمكنه من الكشف بدقة عن الشركات المحرفة أو التنبؤ بها. كما أوضحت النتائج أن جميع النماذج انخفض فيها مستوى الدقة بتطبيق أداة اختيار أهم المتغيرات، مما يعني أن المتغيرات الهامة عددها قليل وغير كافية للتصنيف. وعلى غرار المدخل المالي فقد كانت نتائج نموذج الشبكة البيزية Bayesian Network توضح أقل مستوى الدقة 21.2% وهذا أقل مما نتج في المدخل المالي دليل على أن المتغيرات النصية وحدها لا تكفي المراجع للكشف عن التحريفات.

ولا شك أن هذه النتائج تحقق صحة الفرض الثاني للبحث والذي كان ينص على أنه: يحقق المدخل النصي لاستخدام تقنيات التعلم الآلي ML في المراجعة الخارجية فعالية التنبؤ بتحريفات القوائم المالية. إلا أن هذه الدقة كانت أقل من مثيلتها في المدخل المالي، ولذا ينصح المراجع بعدم استخدام المدخل النصي منفصل لتقدير مخاطر والتنبؤ بالتحريفات في القوائم المالية.

أما استخدام المدخل المختلط كما هو موضح في الجدول رقم (12) فقد حسن مستوى الدقة عن المدخل النصي ولكن لم يصل إلى مستويات الدقة المحققة في المدخل المالي. إلا أن تطبيق أداة اختيار المتغيرات الأهم أعطى نتائج دقة أعلى دليل على استبعاد المتغيرات النصية في معظمها لأنها كانت أقل أهمية وأقل تفسيراً للتحريف. وهذه النتائج تحقق صحة جزئية للفرض الثالث للبحث والذي كان ينص على أنه: **يحقق المدخل المختلط لاستخدام تقنيات التعلم الآلي ML في المراجعة الخارجية فعالية التنبؤ بتحريفات القوائم المالية أعلى من كل من المدخل المالي والمدخل النصي منفردان.** حيث أثبتت النتائج أن المدخل المختلط يحقق نتائج أفضل من المدخل النصي منفرد، إلا أنه يحقق نتائج أقل دقة وفعالية في التنبؤ بالتحريفات من المدخل المالي منفرد.

#### 4- النتائج والتوصيات والتوجهات البحثية المستقبلية

##### 4-1 النتائج التي توصلت إليها الدراسة

استهدف البحث تقييم مداخل التعليم الآلي التي يستخدمها المراجع الخارجي بغرض تحقيق فعالية التنبؤ بتحريفات القوائم المالية في الشركات محل المراجعة. وتحقيقاً لهذا الهدف تم إجراء دراسة نظرية تستكشف مصطلحات تحريفات القوائم المالية ومسؤولية المراجعة تجاهها، وتبين مفهوم التعلم الآلي وتقنياته ومداخل استخدامه في الكشف عن والتنبؤ بتحريفات القوائم المالية. كما أجرت الباحثة دراسة تجريبية على برنامج IBM® SPSS® Modeler Premium 18.3 استخدمت فيها متغيرات عديدة مالية ونصية تم تجميع بياناتها من تقارير الشركات المسجلة في البورصة المصرية. ويمكن بلورة النتائج والإجابة على تساؤلات البحث على النحو التالي:

1- تمثل التساؤل الأول في تحديد ماهية تحريفات القوائم المالية، ومدى مسؤولية المراجع الخارجي عن اكتشافها. وقد تم الإجابة على هذا التساؤل في القسم الأول من الدراسة النظرية وتوصلت الباحثة إلى نتائج عديدة من أهمها:

— تعدد المصطلحات المستخدمة في الدراسات السابقة والتي تعبر عن تحريفات القوائم المالية، وترى الباحثة أن مصطلح تحريف من أدق المصطلحات، وأشملها من منظور إجراءات المراجعة.

— يعد المراجع الخارجي مسؤول مسؤولية تامة عن الكشف عن تحريفات القوائم المالية، سواء بعمد ترقى إلى مستوى الغش والاحتيال أو بدون عمد وتمثل أخطاء لتطبيق معايير ومبادئ المحاسبة المالية. وذلك وفقاً لمعايير المراجعة الدولية والمصرية، ووفقاً لقواعد الهيئات التنظيمية.

2- وتركز التساؤل الثاني للبحث حول مفهوم التعلم الآلي، وتطور تقنياته في ظل الذكاء الاصطناعي. وقد تم الإجابة على هذا التساؤل من خلال القسم الثاني في الدراسة النظرية، وتوصلت الباحثة إلى النتائج التالية:

— التعليم الآلي فرع من فروع الذكاء الاصطناعي (AI) يركز على تعليم أجهزة الحاسب التفكير المنطقي بطريقة تشابه العقل البشري.

— تقنيات التعلم الآلي تطورت بدءاً من التقنيات الخاضعة للإشراف ومروراً بالتقنيات غير الخاضعة للإشراف وانتهاءً بالتعلم المتعمق والمعزز.

3- وتمحور التساؤل الثالث لهذه الدراسة حول مداخل استخدام تقنيات التعليم الآلي في الكشف عن والتنبؤ بتحريقات القوائم المالية. وتم الإجابة على هذا التساؤل في القسم الثالث من الدراسة النظرية. حيث توصلت الباحثة إلى مجموعة من النتائج أهمها:

— توجد ثلاثة مداخل استخدمها الباحثون للكشف عن تحريقات القوائم المالية والتنبؤ بها: وهي المدخل المالي، والمدخل النصي، والمدخل المختلط.

— يعتمد المدخل المالي على متغيرات ومؤشرات مالية فقط يتم استخراجها مباشرة من القوائم المالية، أو حسابها وفقاً لنوع المتغير. ويستخدم هذا المدخل بكثرة نظراً لسهولة الحصول على بياناتها وتسهيلها على المراجع عند إجراء عملية المراجعة.

— ويعتمد المدخل النصي على مجموعة من المتغيرات النصية التي يتم استخراجها من التقارير النصية التي تصدر عن الشركة مثل تقرير مجلس الإدارة وتقرير الاستدامة وتقرير الحوكمة. أو التعليقات النصية التي يكتبها العملاء أو الموردين أو المستثمرين عن الشركة في وسائل التواصل الاجتماعي. وركزت الدراسات حول تقرير مجلس الإدارة نظراً لإمكانية الحصول عليه من قبل مراجع الشركة.

— المدخل المختلط يعتمد على مجموعة من المتغيرات المالية والنصية ويمكن أن يحقق فعالية أكبر في التنبؤ بتحريقات القوائم المالية.

4- وتركز التساؤل الرابع حول كيفية إجراء دراسة تجريبية باستخدام بيانات التقارير المالية للشركات المقيدة في البورصة المصرية من أجل تقييم مداخل التنبؤ بالتحريف في القوائم المالية والتحقق من فعاليتها في أداء عملية المراجعة. ولقد تم الإجابة على هذا التساؤل في قسم الدراسة التجريبية. وفيها توصلت الباحثة إلى مجموعة من النتائج من أهمها:

— يمكن استخدام برنامج IBM® SPSS® Modeler Premium 18.3 لتطبيق تقنيات التعلم الآلي في الكشف عن تحريقات القوائم المالية.

— يعد المدخل المالي أعلى المداخل دقة لاستخدام تقنيات التعلم الآلي في الكشف عن تحريقات القوائم المالية.

- المدخل النصي يعطي دقة منخفضة ولا يمكن أن يعتمد عليه المراجع بمفرده في الكشف عن والتنبؤ بتحريفات القوائم المالية.
- المدخل المختلط هو مدخل وسط بين المدخل النصي والمدخل المالي في تحقيق فعالية الكشف عن تحريفات القوائم المالية.
- استخدام أداة اختيار المتغيرات يحقق تحسين في دقة نماذج التعلم الآلي في الكشف عن والتنبؤ بتحريفات القوائم المالية.

#### 4- 2 توصيات البحث

في ضوء ما توصلت إليه الباحثة من نتائج وتحقق للفروض توصي الباحثة بالتوصيات التالية:

1. ضرورة تطوير مكاتب المراجعة باستخدام ورش عمل وحلقات تدريبية للعاملين بها بما يمكنها من استخدام تقنيات التعلم الآلي وما يستجد منها في مرحلة تحديد مخاطر التحريفات والتنبؤ بها.
2. يجب أن يكون هناك قاعدة بيانات مصرفية للبيانات المالية والتقارير النصية للشركات المدرجة في البورصة يمكن الاعتماد عليها لإجراء مزيد من الدراسات التجريبية .
3. ضرورة قيام مكاتب المراجعة بالبحث عن البرمجيات المتطورة في تقنيات الذكاء الاصطناعي عموماً والتعلم الآلي على وجه الخصوص، من أجل تيسير تنفيذ إجراءات المراجعة بجودة عالية.
4. ضرورة تطوير مناهج المراجعة الخارجية في الجامعات المصرية على نحو يمكن الخريج من تعلم كل مستجد في الذكاء الاصطناعي وكيفية الاستفادة منه في مجال المراجعة.
5. ضرورة التعاون بين المنظمات المهنية المصرية والدولية لعقد مؤتمرات عالمية وندوات دولية تثري فكر المراجعين بأهمية التحول إلى تطبيق نماذج التعلم الآلي في التنبؤ بتحريفات القوائم المالية.

#### 4- 3 التوجهات البحثية المستقبلية

و استكمالاً لما بدأته الباحثة في هذا البحث يمكن إجراء الأبحاث والدراسات التالية في المستقبل:

- مدخل مقترح لتطبيق تقنيات التعلم العميق في تخطيط مخاطر المراجعة، دراسة اختبارية على البنوك المدرجة بالبورصة المصرية.

- قياس أثر استخدام تقنيات التعلم الآلي في المراجعة الخارجية على جودة المراجعة.
- نموذج مقترح لتطبيق تقنيات التعلم الآلي في المراجعة الداخلية بهدف تحقيق جودة الحوكمة.
- دراسة تجريبية على مكاتب المراجعة الكبرى في مصر من أجل تطبيق برمجيات التعلم الآلي، ودورها في تنفيذ المراجعة التحليلية.
- دراسة مقارنة بين جودة تطبيق تقنيات التعلم الآلي في مكاتب المراجعة المصرية والمكاتب الدولية.
- التحليل النصي لمحتويات وسائل التواصل الاجتماعي بهدف تحقيق فعالية الكشف عن الغش في القوائم المالية دراسة تجريبية على الشركات المقيدة في البورصة المصرية.
- دور نماذج التعلم الآلي في مساعدة المراجع في اتخاذ قرار بشأن مدى استمرارية المنشأة، دراسة تجريبية على الشركات الصغيرة والمتوسطة.

## المراجع

### أولاً: المراجع باللغة العربية

أبو الخير، أسامة أحمد محمد، (2019)، "دور استخدام أساليب التنقيب في البيانات لتحسين تقديرات مراقب الحسابات في مدى وجود أخطاء جوهرية بالقوائم المالية: دراسة ميدانية في بيئة الأعمال المصرية"، *مجلة الدراسات التجارية المعاصرة*، كلية التجارة، جامعة كفر الشيخ، مج (7)، ع (7)، ص ص: 305 - 357 .

الهيئة العامة للرقابة المالية، (2008a)، "معييار المراجعة المصري رقم (200) الهدف من عملية مراجعة القوائم المالية والمبادئ العامة التي تحكمها"، قرار رقم (166)، جمهورية مصر العربية، ص ص: 1- 27.

الهيئة العامة للرقابة المالية، (2008c)، "معييار المراجعة المصري رقم (315) تفهم المنشأة وبيئتها وتقييم مخاطر التحريف الهام" قرار رقم (166)، جمهورية مصر العربية، ص ص: 1- 66.

الهيئة العامة للرقابة المالية، (2008b)، "معييار المراجعة المصري رقم (240) مسئولية المراجع بشأن الغش والتدليس عند مراجعة قوائم مالية"، قرار رقم (166)، جمهورية مصر العربية، ص ص: 1- 54.

شحاته، شحاته السيد، (2017)، "مدى ملاءمة نموذجي مربع وخماسي الغش في تحديد احتمال وجود الغش بالقوائم المالية المضللة دراسة تطبيقية على الشركات المقيدة بالبورصة المصرية"، *مجلة الاسكندرية للبحوث المحاسبية*، قسم المحاسبة والمراجعة، كلية التجارة، جامعة الإسكندرية، مج (1)، ع (1)، ص ص: 49- 99.

صالح، أبو الحمد مصطفى، (2019)، "أثر إعادة إصدار القوائم المالية على قرارات منح الائتمان في البيئة المصرية"، *مجلة البحوث التجارية المعاصرة*، كلية التجارة، جامعة سوهاج، مج (33)، ع (3)، ص ص : 2 - 42.

على، عبد الوهاب نصر، (2017)، "العلاقة بين التعثر المالي ووجود الغش بالقوائم المالية - دراسة تطبيقية على الشركات المقيدة بالبورصة المصرية"، *مجلة الاسكندرية للبحوث المحاسبية*، قسم المحاسبة والمراجعة، كلية التجارة، جامعة الإسكندرية، مج (1)، ع (1)، ص ص: 1- 41.

فرج، هاني خليل، (2018)، "أثر استخدام مراقب الحسابات للنسب المالية للشركات على كفاءته في كشف الغش بالقوائم المالية المحرفة عن عمد : دراسة تطبيقية على الشركات غير المالية المقيدة بالبورصة المصرية في الفترة من 2011- 2015"، *مجلة البحوث المحاسبية*، قسم المحاسبة والمراجعة، كلية التجارة، جامعة طنطا، مج (1)، ع (5)، ص ص: 298- 348.

هلاي، أسامة أحمد جمال، (2015)، "إعادة إصدار القوائم المالية وأثرها على خطر تقاضي الشركات المقيدة بالبورصة المصرية - دراسة اختبارية"، *مجلة المحاسبة المصرية*، قسم المحاسبة والمراجعة، كلية التجارة، جامعة القاهرة، مج (10)، ص ص: 1- 51.

هلاي، أسامة أحمد جمال، (2017)، "أثر القوائم المالية المعدلة على أسعار الأسهم ومصادر التمويل وعلي تغيير مراقب الحسابات للشركات المقيدة بالبورصة المصرية : دراسة إختيارية"، *الفكر المحاسبي*، قسم المحاسبة والمراجعة، كلية التجارة، جامعة عين شمس، مج (5)، ع (21)، ص ص: 492- 552.

## ثانيا: المراجع باللغة الانجليزية

Accelerator, T. (2022), "In-depth guide to machine learning in the enterprise", available at: <https://www.techtarget.com/searchenterpriseai/In-depth-guide-to-machine-learning-in-the-enterprise> , (accessed 12/5/2022).

ACFE. (2020), "Report to the Nations 2020 Global Study on Occupational Fraud and Abuse, available at: <https://legacy.acfe.com/report-to-the-nations/2020/>, (accessed 17/ 5/ 2022).

Achakzai, M. A. K. and Juan, P. (2022), "Using machine learning Meta-Classifiers to detect financial frauds", *Finance Research Letters*, Vol. 48, pp. 102915.

- Addo, P., Guegan, D. and Hassani, B. (2018), "Credit Risk Analysis Using Machine and Deep Learning Models", *Risks*, Vol.6, No.2, 38 ; <https://doi.org/10.3390/risks6020038> .
- AICPA. (2002), " AU section 316. Statement on Auditing Standard No. 99: Consideration of Fraud in a Financial Statement Audit", available at: <https://us.aicpa.org/content/dam/aicpa/research/standards/auditattest/downloadabledocuments/au-00316.pdf>, (accessed 10/ 3/ 2022).
- Beneish, M. D. (1997), "Detecting GAAP violation: implications for assessing earnings management among firms with extreme financial performance", *Journal of Accounting and Public Policy*, Vol. 16 No. 3, pp.309-271 .
- Beneish, M. D. (1999), "The Detection of Earnings Manipulation", *Financial Analysts Journal*, Vol. 55 No. 5, pp. 24-36.
- Bertomeu, J., Cheynel, E., Floyd, E. and Pan, W. Q. (2021), "Using machine learning to detect misstatements", *Review of Accounting Studies*, Vol. 26 No. 2, pp. 468-519.
- Bodnaruk, A., Loughran, T. and McDonald, B. (2015), "Using 10-K Text to Gauge Financial Constraints", *The Journal of Financial and Quantitative Analysis*, Vol. 50, No. 4, pp. 623-646.
- Broer Bahaweres, R., Trawally, J., Hermadi, I. and Imam Suroso, A. (2021), "Forensic Audit Using Process Mining to Detect Fraud", *Journal of Physics: Conference Series*, Vol. 1779 No. 1, pp. 012013.
- Brown, N., Crowley, R. and Elliott, W. (2020), "What Are You Saying? Using topic to Detect Financial Misreporting", *Journal of Accounting Research*, Vol. 58 No. 1, pp. 237-291.
- Cecchini, M., Aytug, H., Koehler, G. J. and Pathak, P. (2010a), "Detecting Management Fraud in Public Companies", *Management Science*, Vol. 56 No. 7, pp. 1146-1160.
- Cecchini, M., Aytug, H., Koehler, G. J. and Pathak, P. (2010b), "Making words work: Using financial text as a predictor of financial events", *Decision Support Systems*, Vol. 50 No. 1, pp. 164-175.
- Chen, F., Du, X. Q., Lai, S. J. and Ma, M. (2018), "Does the use of honorific appellations in audit reports connote higher financial misstatement

- risk? Evidence from China", *Asian Review of Accounting*, Vol. 26 No. 2, pp. 154-181.
- Chen, H.-C., Lee, Y.-J., Lo, S.-Y. and Yu, Y. (2021), "Qualitative characteristics of non-GAAP disclosures and non-GAAP earnings quality", *Journal of Accounting and Economics*, Vol. 72 No. 1, pp. 101402.
- Chen, X., Jiang, X., Lu, L. Y. and Yu, Y. (2021), "Local political corruption and Firm's non-GAAP reporting", *Journal of Corporate Finance*, Vol. 70, pp. 102071.
- Cheng, C.-H., Kao, Y.-F. and Lin, H.-P. (2021), "A financial statement fraud model based on synthesized attribute selection and a dataset with missing values and imbalanced classes", *Applied Soft Computing*, Vol. 108, pp. 107487.
- US Securities and Exchange Commission, (2019 ), " *Fiscal Year 2019 Agency Financial Report*, " available at <https://www.sec.gov/reports-and-publications/annual-reports/sec-2019-agency-financial-report>, accessed in 22 /10 /2022.
- Craja, P., Kim, A. and Lessmann, S. (2020), "Deep learning for detecting financial statement fraud", *Decision Support Systems*, Vol. 139, pp. 113421.
- Czerney, K., Schmidt, J. J. and Thompson, A. M. (2014), "Does Auditor Explanatory Language in Unqualified Audit Reports Indicate Increased Financial Misstatement Risk?", *The Accounting Review*, Vol. 89 No. 6, pp. 2115-2149.
- Davis, A., Piger, J. and Sedor, L. (2012), "Beyond the Numbers: Measuring the Information Content of Earnings Press Release Language", *Contemporary Accounting Research*, Vol. 29, pp. 845-868.
- Dechow, P. M., GE, W., Larson, C. R. and Sloan, R. G. (2011), "Predicting Material Accounting Misstatements", *Contemporary Accounting Research*, Vol. 28 No. 1, pp. 17-82.
- Dilla, W. and Raschke ,R. (2015), "Data visualization for fraud detection: Practice implications and a call for future research", *International Journal of Accounting Information Systems*, Vol. 16, March pp. 1-22.



- Ding, K., Peng, X. and Wang, Y. (2019), "A Machine Learning-Based Peer Selection Method with Financial Ratios", *Accounting Horizons*, Vol. 33 No. 3, pp. 75-87.
- Dutta, I., Dutta, S. and Raahemi, B. (2017), "Detecting financial restatements using data mining techniques", *Expert Systems with Applications*, Vol. 90, pp. 374-393.
- DYCK, A ,.MORSE, A. and ZINGALES, L. (2010), "Who Blows the Whistle on Corporate Fraud?", *The Journal of Finance*, Vol. 65 No. 6, pp. 2213-2253.
- Field, A. (2017), *Discovering statistics using IBM SPSS statistics*, 5<sup>th</sup> ed., Sage Publications Ltd, UK.
- Galeshchuk, S. and Mukherjee, S. (2017), "Deep networks for predicting direction of change in foreign exchange rates", *Intelligent Systems in Accounting, Finance and Management*, Vol. 24 No. 3, pp. 1-25.
- Gee, J. and Button, M. (2019), "The financial cost of fraud 2019: The latest data from around the world." *The business Magazine*, 30<sup>th</sup> July, available at: <https://www.businessinnovationmag.co.uk/the-financial-cost-of-fraud-2019-the-latest-data-from-around-the-world/>, (accessed 28/ 2/ 2022).
- Gepp, A. (2015), "Financial statement fraud detection using supervised learning methods (Ph.D. Dissertation)", Bond Business School, available at: <https://research.bond.edu.au/en/studentTheses/financial-statement-fraud-detection-using-supervised-learning-met>, (accessed 14/1/2022).
- Gleason, C. A., Jenkins, N. T. and Johnson, W. B. (2008), "The contagion effects of accounting restatements", *The Accounting Review*, Vol. 83 No. 1, pp. 83-110.
- Goel, S. and Uzuner, O. (2016), "Do Sentiments Matter in Fraud Detection? Estimating Semantic Orientation of Annual Reports", *Intelligent Systems in Accounting, Finance and Management*, Vol. 23 No. 3, pp. 215-239.
- Hajek, P. and Henriques, R. (2017), "Mining corporate annual reports for intelligent detection of financial statement fraud – A comparative study of machine learning methods", *Knowledge-Based Systems*, Vol. 128, pp. 139-152.

- Hogan, C. E., Rezaee, Z., Riley, R. A., Jr. and Velury, U. K. (2008), "Financial Statement Fraud: Insights from the Academic Literature", *AUDITING: A Journal of Practice & Theory*, Vol. 27 No. 2, pp. 231-252.
- Huang, S.-Y., Tsaih, R.-H. and Yu, F. (2014), "Topological pattern discovery and feature extraction for fraudulent financial reporting", *Expert Systems with Applications*, Vol. 41 No. 9, pp. 4360-4372.
- Humpherys, S. L., Moffitt, K. C., Burns, M. B., Burgoon, J. K. and Felix, W. F. (2011), "Identification of fraudulent financial statements using linguistic credibility analysis", *Decision Support Systems*, Vol. 50 No. 3, pp. 585-594.
- Hunt, E., Hunt, J., Richardson, V. J. and Rosser, D. (2022), "Auditor Response to Estimated Misstatement Risk: A Machine Learning Approach", *Accounting Horizons*, Vol. 36 No. 1, pp. 111-130.
- Hunt, N. C., Curtis, M. B. and Rixom, J. M. (2022), "Financial priming, psychological distance, and recognizing financial misreporting as an ethical issue: The role of financial reporting responsibility", *Accounting, Organizations and Society*, Vol. 102 No. 16, DOI: [10.1016/j.aos.2022.101349](https://doi.org/10.1016/j.aos.2022.101349).
- Hunt, Rosser, D. M. and Rowe, S. P. (2021), "Using machine learning to predict auditor switches: How the likelihood of switching affects audit quality among non-switching clients", *Journal of Accounting and Public Policy*, Vol. 40, No. 5: DOI: [org/10.1016/j.jaccpubpol.2020.106785](https://doi.org/10.1016/j.jaccpubpol.2020.106785) .
- IAASB, (2021a), " *IAASB Digital Market Scan Artificial Intelligence —A Primer*", available at: <https://www.iaasb.org/news-events/2022-03/iaasb-digital-technology-market-scan-artificial-intelligence-primer>, (accessed 27/ 1/ 2022).
- IAASB, (2021b), "ISA 450 Evaluation of Misstatements Identified during the Audit", available at <https://www.ifac.org/system/files/downloads/a021-2010-iaasb-handbook-isa-450.pdf>, (accessed 28/12/2021).
- IBM. (2020a), "Deep Learning", available at: <https://www.ibm.com/eg-en/cloud/learn/deep-learning> , (accessed 10/12 /2021).

- IBM. (2020b), "Supervised Learning", available at: <https://www.ibm.com/cloud/learn/supervised-learning>, (accessed 13/9/2021).
- IBM. (2020c), "Unsupervised Learning", available at: <https://www.ibm.com/cloud/learn/unsupervised-learning>, (accessed 6/12/2021).
- Jan, C.-l. (2018), "An Effective Financial Statements Fraud Detection Model for the Sustainable Development of Financial Markets: Evidence from Taiwan", *Sustainability*, Vol. 10, no. 2, [DOI:org/10.3390/su10020513](https://doi.org/10.3390/su10020513) .
- Jan, C.-L. (2021), "Detection of Financial Statement Fraud Using Deep Learning for Sustainable Development of Capital Markets under Information Asymmetry", *Sustainability*, Vol. 13 No. 17, [DOI:org/10.3390/su13179879](https://doi.org/10.3390/su13179879) .
- Jia, W. and Zhao, J. (2020), "Does the market punish the many for the sins of the few? The contagion effect of accounting restatements for foreign firms listed in the United States", *Journal of Accounting, Auditing*, Vol. 35 No. 1, pp. 196-228.
- Jones, S. (2017), "Corporate bankruptcy prediction: a high dimensional analysis", *Review of Accounting Studies*, Vol. 22 No. 3, pp. 1366-1422.
- Kaminski, K. A., Sterling Wetzel, T., & Guan, L. . (2004), " Can financial ratios detect fraudulent financial reporting? ", *Managerial Auditing Journal*, Vol19 . No. 1, pp., 15-28.
- Kanapickiene, R. and Grundienė, Ž. (2015), "The Model of Fraud Detection in Financial Statements by Means of Financial Ratios", *Procedia - Social and Behavioral Sciences*, Vol. 213, pp. 321-327.
- Karpoff, J. M., Scott Lee, D. and Martin, G. S. (2008), "The consequences to managers for financial misrepresentation", *Journal of Financial Economics*, Vol. 88 No. 2, pp. 193-215.
- Khan, A. T., Cao, X., Li, S., Katsikis, V. N., Brajevic, I. and Stanimirovic, P. S. (2022), "Fraud detection in publicly traded U.S firms using Beetle Antennae Search: A machine learning approach", *Expert Systems with Applications*, Vol. 191, pp. 116148.

- Kim, Y. J., Baik, B. and Cho, S. (2016), "Detecting financial misstatements with fraud intention using multi-class cost-sensitive learning", *Expert Systems with Applications*, Vol. 62, pp. 32-43.
- Kirkos, E., Spathis, C. and Manolopoulos, Y. (2007), "Data Mining techniques for the detection of fraudulent financial statements", *Expert Systems with Applications*, Vol. 32 No. 4, pp. 995-1003.
- Kogan, A., Mayhew, B. W. and Vasarhelyi, M. A. (2019), "Audit Data Analytics Research—An Application of Design Science Methodology", *Accounting Horizons*, Vol. 33 No. 3, pp. 69-73.
- Kotsiantis, S., Koumanakos, E., Tzelepis, D. and Tampakas, V. (2006), "Forecasting fraudulent financial statements using data mining", *International Journal of Computational Intelligence*, Vol. 3 No. 2, pp. 104-110.
- Kulkarni, A., Chong, D. and Batarseh, F. A. (2020), "5 - Foundations of data imbalance and solutions for a data democracy", in Batarseh, F. A. and Yang, R. (Eds.), *Data Democracy*. Academic Press, pp. 83-106.
- Kyung, H., Lee, H. and Marquardt, C. (2019), "The effect of voluntary clawback adoption on non-GAAP reporting", *Journal of Accounting and Economics*, Vol. 67 No. 1, pp. 175-201.
- Larcker, D. and Zakolyukina, A. (2012), "Detecting Deceptive Discussion in Conference Calls", *Journal of Accounting Research*, Vol. 50 No. 2, pp. 495-540.
- Liao, J., Smith, D. and Liu, X. (2019), "Female CFOs and accounting fraud: Evidence from China", *Pacific-Basin Finance Journal*, Vol. 53, pp. 449-463.
- Lin, C.-C., Chiu, A., Huang, S. Y. and Yen, D. (2015), "Detecting the financial statement fraud: The analysis of the differences between data mining techniques and experts' judgments", *Knowledge-Based Systems*, Vol. 89.
- Loughran, T. and McDonald, B. (2011), "When Is a Liability NOT a Liability? Textual Analysis, Dictionaries, and 10-Ks", *The Journal of Finance*, Vol. 66, pp. 35-65.

- Mao, J. and Ye, Z. (2022), "Internal control material weakness disclosure and misstatement duration", *Journal of Business Finance & Accounting*, Vol. n/a No. n/a, pp. 1-34.
- Moon, J. R., Shipman, J. E., Swanquist, Q. T. and Whited, R. L. (2022), "On Controlling for Misstatement Risk", *Auditing-a Journal of Practice & Theory*, Vol. 41 No. 2, pp. 191-210.
- Munkhdalai, L., Munkhdalai, T., Namsrai, O.-E., Lee, J. and Ryu, K. (2019), "An Empirical Comparison of Machine-Learning Methods on Bank Client Credit Assessments", *Sustainability*, Vol. 11 No. 3, DOI : [org/10.3390/su11030699](https://doi.org/10.3390/su11030699).
- Papík, M. and Papíková, L. (2022), "Detecting accounting fraud in companies reporting under US GAAP through data mining", *International Journal of Accounting Information Systems*, Vol. 45, June, DOI: [10.1016/j.accinf.2022.100559](https://doi.org/10.1016/j.accinf.2022.100559).
- Parot, A., Michell, K. and Kristjanpoller, W. (2019), "Using Artificial Neural Networks to forecast Exchange Rate, including VAR-VECM residual analysis and prediction linear combination", *Intelligent Systems in Accounting, Finance and Management*, Vol. 26 No. 2, DOI: [10.1002/isaf.1440](https://doi.org/10.1002/isaf.1440)
- PCAOB. (2007), " Observations on auditors' implementation of PCAOB standards relating to auditors' responsibilities with respect to fraud", *PCAOB Release 2007-001*, available at: [https://pcaobus.org/Inspections/Documents/2007\\_01-22\\_Release\\_2007-001.pdf](https://pcaobus.org/Inspections/Documents/2007_01-22_Release_2007-001.pdf), (accessed 22/7/2021).
- PCAOB. (2010), "AS 2301: The Auditor's Responses to the Risks of Material Misstatement", *PCAOB Release No. 2010-004*, available at: <https://pcaobus.org/oversight/standards/auditing-standards/details/AS2301>, (accessed 24/12/2021).
- Perols, J. (2011), "Financial Statement Fraud Detection: An Analysis of Statistical and Machine Learning Algorithms", *AUDITING: A Journal of Practice & Theory*, Vol. 30 No. 2, pp. 19-50.
- Petraşcu, D. and Tieanu, A. (2014), "The Role of Internal Audit in Fraud Prevention and Detection", *Procedia Economics and Finance*, Vol. 16, pp. 489-497.

- Purda, L. and Skillicorn, D. (2015), "Accounting Variables, Deception, and a Bag of Words: Assessing the Tools of Fraud Detection", *Contemporary Accounting Research*, Vol. 32 No. 3, pp. 1193-1223.
- Rezaee, Z. (2005), "Causes, consequences, and deterrence of financial statement fraud", *Critical Perspectives on Accounting*, Vol. 16 No. 3, pp. 277-298.
- Shen, Y., Guo, C., Li, H., Chen, J., Guo, Y. and Qiu, X. (2021), "Financial Feature Embedding with Knowledge Representation Learning for Financial Statement Fraud Detection", *Procedia Computer Science*, Vol. 187, pp. 420-425.
- Shiah-Hou, S.-R. (2021), "The relation between non-GAAP earnings and accounting restatements: Evidence after regulation G", *Advances in Accounting*, Vol. 55, pp. 100567.
- Singh Yadav, A. K. and Sora, M. (2021), "Fraud Detection in Financial Statements using Text Mining Methods: A Review", *IOP Conference Series: Materials Science and Engineering*, Vol. 1020 No. 1, DOI:[10.1088/1757-899X/1020/1/012012](https://doi.org/10.1088/1757-899X/1020/1/012012).
- Singleton, T. W. and Singleton, A. J. (2010), *Fraud auditing and forensic accounting*, John Wiley & Sons.
- Su, Z. and Alexiou, (2022), "The impact of anti-corruption measures and risk effects on equity incentives and financial misreporting in China", *China Journal of Accounting Research*, Vol. 15 No. 1, DOI: [10.1016/j.cjar.2021.100218](https://doi.org/10.1016/j.cjar.2021.100218).
- Sun, T. (2019), "Applying Deep Learning to Audit Procedures: An Illustrative Framework", *Accounting horizons*, Vol. 33 No. 3, pp. 89-109.
- Tang, X., Li, S., Tan, M. and Shi, W. (2020), "Incorporating textual and management factors into financial distress prediction: A comparative study of machine learning methods", *Journal of Forecasting*, Vol. 39 No. 5, pp. 769-787.
- Thevenot, M. (2012), "The factors affecting illegal insider trading in firms with violations of GAAP", *Journal of Accounting and Economics*, Vol. 53 No. 1, pp. 375-390.

- Thielemann, F. and Dinh, T. (2019), "Non-GAAP earnings disclosures around regulation G – The case of “implicit non-GAAP reporting”, *Advances in Accounting*, Vol. 46 September, DOI: [org/10.1016/j.adiac.2019.100432](https://doi.org/10.1016/j.adiac.2019.100432).
- Throckmorton, C., Mayew, W., Venkatachalam, M. and Collins, L. (2015), "Financial Fraud Detection Using Vocal, Linguistic and Financial Cues", *Decision Support Systems*, Vol. 74. June , pp. 78-87.
- Vrij, A. (2008), *Detecting lies and deceit: Pitfalls and opportunities*, John Wiley & Sons.
- Wang, R., Asghari, V., Hsu, S.-C., Lee, C.-J. and Chen, J.-H. (2020), "Detecting corporate misconduct through random forest in China's construction industry", *Journal of Cleaner Production*, Vol. 268 September, DOI: [/10.1016/j.jclepro.2020.122266](https://doi.org/10.1016/j.jclepro.2020.122266) .
- Wang, Y., Ashton, J. K. and Jaafar, A. (2019), "Money shouts! How effective are punishments for accounting fraud?", *The British Accounting Review*, Vol. 51 No. 5, DOI: [10.1016/j.bar.2019.02.006](https://doi.org/10.1016/j.bar.2019.02.006).
- Whiting, D. G., Hansen, J. V., McDonald, J. B., Albrecht, C. and Albrecht, W. S. (2012), "MACHINE LEARNING METHODS FOR DETECTING PATTERNS OF MANAGEMENT FRAUD", *Computational Intelligence*, Vol. 28 No. 4, pp. 505-527.
- Wu, H., Chang, Y., Li, J. and Zhu, X., (2022), “Financial fraud risk analysis based on audit information knowledge graph”, *Procedia Computer Science*, Vol. 199, pp. 780-787.
- Xu, X., Xiong, F. and An, Z. (2022), “Using Machine Learning to Predict Corporate Fraud: Evidence Based on the GONE Framework”, *Journal of Business Ethics*, April, DOI: [10.1007/s10551-022-05120-2](https://doi.org/10.1007/s10551-022-05120-2).
- Yao, J., Pan, Y., Yang, S., Chen, Y. and Li, Y. (2019), "Detecting Fraudulent Financial Statements for the Sustainable Development of the Socio-Economy in China: A Multi-Analytic Approach", *Sustainability*, Vol. 11 No. 6.
- Zager, L., Malis, S. S. and Novak, A. (2016), "The Role and Responsibility of Auditors in Prevention and Detection of Fraudulent Financial Reporting", *Procedia Economics and Finance*, Vol. 39, pp. 693-700.

Zhang, Y., Zhang, Y. and Yao, T" ,(2022) .Fraudulent financial reporting in China: Evidence from corporate renaming", *Journal of Contemporary Accounting & Economics*, Vol. 18 No. 1, pp. 100283.

Zinovyeva, E., Härdle, W. K. and Lessmann, S. (2020), "Antisocial online behavior detection using deep learning", *Decision Support Systems*, Vol. 138, pp. 113362.

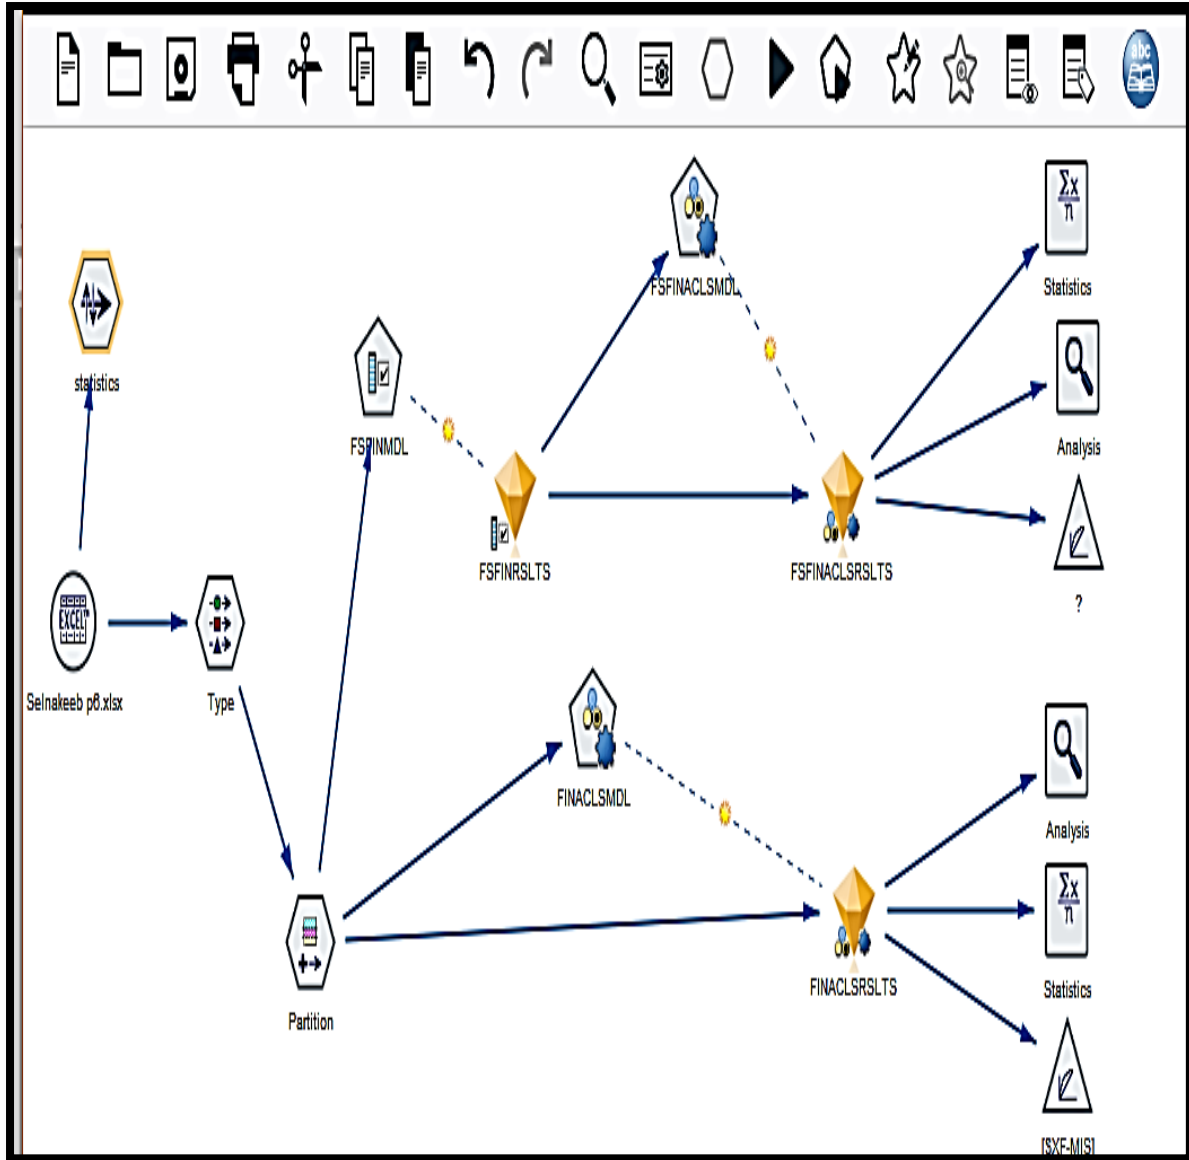
أبو الخير، مدثر طه السيد؛ الميهي، عادل عبد الفتاح مصطفى و على، تقى أحمد عبد الحي (2021) ، “Determinants of restatement of Egyptian Companies` Financial Statements and the Market Reactions: An Empirical Study” مج (8) ,جامعة طنطا ,كلية التجارة ,قسم المحاسبة والمراجعة ,مجلة البحوث المحاسبية , ص ص: 1- 44 ,ع (2)

## الملاحق




ملحق رقم (م / 1) التخطيط التتابعية Streams لمداخل استخدام نماذج التعلم الآلي في كشف تحريفات القوائم المالية على برنامج IBM® SPSS® modeler

ملحق رقم (م / 1 / 1) التخطيط التتابعي للمدخل المالي في كشف تحريفات القوائم المالية




الشكل رقم (م / 1 / 1) التخطيط التتابعي للمدخل الكمي لاستخدام نماذج التعلم الآلي\*  
\*المصدر: من تصميم الباحثة على برنامج IBM® SPSS® modeler

ملحق رقم (م / 1 / 2) التخطيط التتابعي للمدخل النصي في كشف تحريفات القوائم المالية



ملحق رقم (م / 1 / 3) التخطيط التتابعي للمدخل المختلط في كشف تحريفات القوائم المالية





## ملحق رقم (2) اختصارات البحث

جدول رقم (م / 1) اختصارات البحث		
الاختصار	مفرداته	مفهومه
PCAOB	Public Company Accounting Oversight Board	مجلس مراقبة حسابات الشركات العامة
AICPA	American Institute of Certified Public Accountants	المعهد الأمريكي للمحاسبين المعتمدين
GBML	Gradient Boosting for Machine Learning	نموذج تعزيز المكونات للتعلم الآلي ML
RVI	Relative Variable Importance	الأهمية النسبية للمتغير
AUC	Area under the ROC Curve	المساحة تحت منحنى روك لقياس أداء النموذج ككل
ROC	The Receiver Operator Characteristic	منحنى روك لقياس احتمالية القيم الثنائية (الصحيحة والخاطئة)
GBRT	Gradient Boosted Regression Tree	شجرة الانحدار المعزز للمكونات
CNN	Convolutional Neural Networks	الشبكات العصبية التلافيفية
RNN	Recurrent Neural Networks	الشبكات العصبية المتكررة
RvNNs	Recursive Neural Networks	الشبكات العصبية العودية
SDNN	Standard Deep Neural Networks	الشبكات العصبية العميقة
AAER	Accounting and Auditing Enforcement Releases	إصدارات انفاذ المحاسبة والمراجعة
ACFE	Association of Certified Fraud Examiners	رابطة فاحصي الاحتيال المعتمدين
CAQ	Center for Audit Quality	مركز جودة المراجعة
SEC	Security and Exchange Commission	هيئة الأوراق المالية والبورصات الأمريكية
ANN	Artificial Neural Networks	الشبكات العصبية الاصطناعية
DT	Decision Trees	شجر القرارات
RBF	Radial Basis Function Networks	شبكات دالة الأساس الشعاعي 19
SMO	Sequential Minimal Optimization	الأمثلية التتابعية الأقل
SVM	Sequential Minimal Optimization	آلة المتجه الداعم
kNN	K-Nearest Neighbor	تقنية أقرب الجيران كي
DTNP	Decision Table/Naïve Bayes	جدول قرار/ وفقا لخواريزمية بيز
XGB	Extreme Gradient Boosting	تعزيز التدرج الشديد
LWL	Local Weighted Learning	التعلم المحلي المرجح
LDA	Linear Discriminant Analysis	تحليل التمييز الخطي