

أثر المعلومات المستمدة من تكامل سلاسل الكتل والتعلم الآلي كتقنيات للذكاء الاصطناعي في الكشف والتقرير عن الاحتيال المحاسبي مع أدلة تطبيقية وميدانية

د. حسين محمد سليمان
مدرس المحاسبة والمراجعة
كلية التجارة - جامعة قناة السويس

د. شرين عبد الله عباس
مدرس المحاسبة والمراجعة
كلية التجارة - جامعة قناة السويس

الملخص:

استهدف البحث الحالي دراسة أثر المعلومات المستمدة من تكامل سلاسل الكتل و التعلم الآلي كتقنيات للذكاء الاصطناعي في الكشف و التقرير عن الاحتيال المحاسبي ، واشتملت خطة البحث على الدراسة النظرية، والتي تناولت تحليل العلاقة بين تطبيق سلاسل الكتل و الاحتيال المحاسبي ، توضيح دور تعلم الآلة في الكشف عن الاحتيال المحاسبي ، و تحليل اثر المعلومات المستمدة من تكامل سلاسل الكتل و تعلم الآلة في ممارسات المحاسبة و المراجعة على الكشف و التقرير عن الاحتيال المحاسبي ، كما تناولت الخطة الدراسة التطبيقية التي اشتملت على جزئين :اعتمد الجزء الاول على البيانات الثانوية التي يمكن استخراجها من البيانات المحاسبية بالقوائم المالية لتحليل العلاقة بين تعلم الآلة و الاحتيال المحاسبي . اما الجزء الثاني اعتمد على البيانات الاولى التي تعتمد على قوائم الاستقصاء لتحليل اثر العلاقة التكاملية بين سلاسل الكتل و تعلم الآلة على الاحتيال المحاسبي . وتوصلت الدراسة إلى وجود علاقة ذات دلالة احصائية بين تطبيق تقنية سلاسل الكتل و الاحتيال المحاسبي ، وجود علاقة ذات دلالة احصائية بين تطبيق تقنية تعلم الآلة و الاحتيال المحاسبي ، وجود علاقة ذات دلالة احصائية بين دور المعلومات المستمدة من تكامل سلاسل الكتل و تعلم الآلة في الكشف عن الاحتيال المحاسبي . و اوصى الباحثان بإجراء تحديثات منتظمة لنماذج التعلم الآلي داخل النظام البيئي للـ Blockchain ، بما يضمن الحفاظ على سلامة النموذج مع إبقاء مجتمع المستخدمين على اطلاع جيد.

الكلمات المفتاحية: سلاسل الكتل ، التعلم الآلي ، الذكاء الاصطناعي ، الاحتيال المحاسبي.

Abstract:

The current research aimed to study the impact of information derived from the integration of blockchains and machine learning as artificial intelligence techniques in detecting and reporting on accounting fraud. The research plan included a theoretical study that dealt with analyzing the relationship between the application of blockchains and accounting fraud, clarifying the role of machine learning in detecting Accounting fraud, and analyzing the impact of information derived from the integration of blockchains and machine learning into accounting and auditing practices on detecting and reporting accounting fraud. The plan also addressed the applied study, which included two sections: The first section relied on secondary data that can be extracted from accounting data. With financial statements to analyze the relationship between machine learning and accounting fraud. The second section relied on primary data based on survey lists to analyze the impact of the complementary relationship between blockchains and machine learning on accounting fraud. The study found that there is a statistically significant relationship between the application of blockchain technology and accounting fraud, the existence of a statistically significant relationship between the application of machine learning technology and accounting fraud, the existence of a statistically significant relationship between the application of blockchain technology and machine learning technology, the existence of a significant relationship Statistics

between the role of information derived from the integration of blockchains and machine learning in detecting accounting fraud. The researchers recommended regular updates to machine learning models within the blockchain ecosystem, ensuring that the integrity of the model is maintained while keeping the user community well informed.

Key words: blockchains, machine learning, artificial intelligence, accounting fraud.

الاطار العام للبحث

أولا : مقدمة وفكرة البحث

تعتبر التكنولوجيا المحرك الأساسي لتطوير مختلف المجالات، فهي أصبحت مفتاح الحياة ومحرك لقوي التطوير ولقد ادي التطور الهائل في التكنولوجيا الى اتجاه معظم الدول المتقدمة والنامية علي حد سواء الي اللجوء الي التحول الرقمي، وانعكس ذلك علي علم المحاسبة استجابة للتقدم التكنولوجي في المعلومات الناتجة من التقارير والقوائم المالية ، من خلال استبدال الممارسات المحاسبية التقليدية بالحلول الرقمية و المعتمدة علي التكنولوجيا مثل الحوسبة السحابية، والذكاء الاصطناعي، و سلاسل الكتل والتعلم الآلي .

وأكدت دراسة (Roszkowska.,2021) ان تقنيات سلاسل الكتل وانترنت الأشياء والعقود الذكية وتقنيات الذكاء الاصطناعي والتعلم الآلي هي حلول تقنية ولها وظائف مختلفة تساهم بشكل فعال في معالجة المشاكل المتعلقة بالمحاسبة والمراجعة بما تتمتع به من إمكانيات قوية تجعلها قادرة علي تعزيز موثوقية البيانات المالية والحد من الاحتيال المحاسبي في التقارير المالية.

كما أوضحت دراسة (Idehen & Mayor.,2021) مدي إمكانية الاعتماد علي تقنية سلاسل الكتل لما تتمتع به من خصائص متمثلة في اللامركزية، والسجلات غير القابلة للتغيير والثبات وعدم الكشف عن الهوية والامن والقابلية للتدقيق والشفافية والثقة وإمكانية التحقق ومشاركة المعلومات يجعلها هي التكنولوجيا الأكثر مصداقية وقيمة في وقف الاحتيال في منظمات الاعمال، وفي ذات السياق اشارت دراسة (Septiawan & Fartika.,2022) ان من أهم خصائص سلاسل الكتل اعتمادها علي محاسبة القيد الثلاثي والذي يعد حلا لمشاكل الشفافية والاحتيال ويوفر مزايا تتبع لكل بيانات المعاملات والتحقق من صحتها .

واشارت دراسة (Rakshit.,2022) ان من خلال استخدام دفتر الأستاذ الرقمي المشترك في تقنية سلاسل الكتل يمكن زياده وضوح المعاملات وشفافيتها، وبالتالي تساهم في الحد من جرائم الاحتيال المحاسبي ، وأكدت ذلك دراسة (Pedreno,et al.,2021) ان تقنية سلاسل الكتل لها دور بارز وملمس في منع الاحتيال لان البيانات لا يتم ارسفتها فحسب بل يتم تسويتها وترتيبها ديناميكيا كما ان التسجيل التلقائي للمعاملات يجعل من الممكن تجنب التلاعب بالبيانات وحماية افضل للمعاملات من الاحتيال .

وتري دراسة (Tyagi, et al., 2020) انه يكاد يكون من المستحيل اختراق سلاسل الكتل ، الا انه قد تكون تطبيقاتها والطبقات الإضافية لها عرضة للخطر و ليست امنه، وتضيف الدراسة أنه يمكن أن تساعد التعلم الآلي في اكتشاف انتهاكات الشبكة و ضمان التنفيذ الآمن للتطبيقات . وفي العصر الرقمي و مع تطور التكنولوجيا تتطور أيضا الاساليب التي يستخدمها المحتالون مما يجعل من الضروري تطوير تقنيات فعالة للكشف و الوقاية . و لمكافحة المشهد المتطور باستمرار للاحتيال المالي الرقمي افسحت تقنيات الكشف عن الاحتيال التقليدية المجال امام التقنيات المتقدمة (Isuru.,2023)

كما يبدو ان صناعة الكشف عن الاحتيال و الوقاية منه واعدة مع الزيادة في تطبيق التقنيات المتقدمة مثل الذكاء الاصطناعي و التعلم الالى و البلوكتشين و التنقيب عن البيانات و النمذجة التنبؤية و غيرها ، و بشكل عام تؤدي التقنيات الناشئة في العصر الرقمي و لاسيما اذا ما تم التكامل بينهم الى حلول مفيدة لمنع أنشطة الاحتيال في كافة المجالات و التهديدات المعقدة. (Baul.,2023)

حيث يلعب التعلم الآلي دوراً مهماً في مجال المحاسبة المالية ولقد ثبت أن التعلم الآلي ضروري لتقنية سلاسل الكتل والذكاء الاصطناعي. لقد تمت أتمتة العديد من الواجبات التي قام بها المحاسبون تاريخياً في المؤسسات بواسطة تعلم الآلة. كما تستخدم خوارزميات تعلم الآلة لتحليل البيانات المالية والانحرافات التي يمكن أن تشير إلى احتمال حدوث معاملات احتيالية أو غير صحيحة، وذلك لان من خصائص التعلم الالى أنه يعمل علي تحسين العمليات المالية، تعزيز عملية صنع القرار، تقليل الاحتيال وتسهيل إكمال المهام المحاسبية المتكررة، ويعتبر التعلم الالى أحد التطبيقات الهامة المستخدمة في استخراج المعلومات من فواتير المدفوعات والمحاسبة خاصة عندما يكون للفواتير تنسيق محدد مسبقاً ويمكن استخراجها بواسطة برنامج تم تدريبه للقيام بذلك، فلقد أصبح إعداد البيانات المالية والوثائق، وكذلك تدقيق الحسابات المالية، أمراً بسيطاً (Kanaparthi., 2024).

و تري دراسة (Ramzan & Lokanan.,2024) ان الأنظمة القائمة علي القواعد وأشجار القرارات والشبكات العصبية وألات ناقل الدعم تعتبر فعالة في التنبؤ بالاحتيال ، حيث وجدت بعض الدراسات انها تستطيع تحقيق مستويات عالية من الأداء ،ولكن ضمان دقة أي خوارزمية بنسبة 100 % وان فعالية أي خوارزمية ستختلف اعتماداً علي مجموعة البيانات المحددة وحالة الاحتيال موضوع الفحص ، ومن خلال فحص البيانات المنظمة وغير المنظمة يمكن لخوارزميات تعلم الآلة تمييز الأنماط وتقديم تقييمات شاملة للمخاطر من خلال النظر للمتغيرات المختلفة مما يؤدي الى تحسن في فعالية عملية المراجعة . وفي ضوء ما سبق تتبلور فكرة البحث في دراسة أثر المعلومات

المستمدة من تكامل سلاسل الكتل والتعلم الآلي كتقنيات للذكاء الاصطناعي في الكشف والتقرير عن الاحتيال المحاسبي مع أدلة تطبيقية وميدانية.

ثانياً: أهمية البحث

تنقسم أهمية البحث الى قسمين :

1. الأهمية العلمية . وتتمثل في ندرة الادبيات المحاسبية التي تناولت العلاقة التكاملية بين تقنية سلاسل الكتل والتعلم الآلي في توفير المعلومات التي تسهم في الكشف والتقرير عن الاحتيال المحاسبي ، بما يؤدي الى تقليل الآثار السلبية للاحتيال المالي و المحاسبي .
2. الأهمية العملية : تتركز في الكشف الفعال عن الاحتيال المحاسبي في العصر الرقمي و الذي يمثل تحدياً لمهنة المحاسبة حيث تقدر خسائر الاحتيال المحاسبي 4 تريليون دولار امريكي وفقاً للتقرير الصادر عن جمعية مدققي الاحتيال المعتمدين في (ACFE., 2018) ،بالإضافة الى محدودية قدرة المراجعين في الكشف عن الاحتيال بنسبة 4% فقط من عملية الاحتيال المهني وفقاً لدراسة (Malekolkalami, et al.,2023) الامر الذي يضيف مزيداً من الأهمية حول موضوع البحث ، ويوضح الدور المرتقب في الكشف والتقرير عن الاحتيال المحاسبي لمختلف المؤسسات باستخدام تقنيات الذكاء الاصطناعي .

ثالثاً: أهداف البحث

1. تأصيل نظري للعلاقة التكاملية بين تطبيق تقنية سلاسل الكتل والاحتيال المحاسبي .
2. توضيح دور تعلم الآلة كأحد تقنيات الذكاء الاصطناعي في الكشف و التقرير عن الاحتيال المحاسبي.

3. عرض نموذج تطبيقي للعلاقة التكاملية بين المعلومات المستمدة من تكامل تقنيتي سلاسل الكتل والتعلم الآلي في الكشف والتقرير عن الاحتيال المحاسبي.

رابعاً: فروض البحث

1. لا توجد علاقة ذات دلالة إحصائية بين تطبيق تقنية سلاسل الكتل والاحتيال المحاسبي.
2. لا توجد علاقة ذات دلالة إحصائية بين تطبيق تقنية تعلم الآلة والاحتيال المحاسبي .
3. لا توجد علاقة ذات دلالة إحصائية بين تقنية سلاسل الكتل و تقنية تعلم الآلة.
4. لا توجد علاقة ذات دلالة إحصائية بين المعلومات المستمدة من تكامل سلاسل الكتل وتعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي.

خامساً : خطة البحث

في ضوء فكرة البحث وأهميته وتحقيقاً لأهدافه واختباراً لفروضه . يتم تقسيم البحث إلى أربعة أقسام علي النحو التالي .

القسم الأول تحليل العلاقة بين سلاسل الكتل و الاحتيال المحاسبي.

القسم الثاني دور تعلم الآلي فى الكشف عن الاحتيال المحاسبي.

القسم الثالث المعلومات المستمدة من تكامل تقنية سلاسل الكتل وتعلم الآلة للكشف و التقرير عن الاحتيال المحاسبي.

القسم الرابع أدلة تطبيقية و ميدانية

القسم الأول : تحليل العلاقة بين سلاسل الكتل والاحتيال المحاسبي

باستخدام تقنية البلوكتشين يمكن التحقق بشكل آمن من هوية الافراد و المؤسسات و انشاء سجل آمن و مقاوم للعبث بهوية المستخدمين ، مما يمكن أن يساعد

في منع الاحتيال المتعلق بالهويات المزيفة والتلاعب بالمستندات، كما تعمل تقنية البلوكتشين على إنشاء سلسلة توريد شفافة وقابلة للتتبع ويمكنها اكتشاف الأنشطة الاحتيالية، و تعد تقنية دفتر الأستاذ غير القابل للتغيير الخاصة بـ Blockchain اتجاهًا ناشئًا يستخدم لإنشاء مسار تدقيق آمن وشفاف للمعاملات المالية مما يجعل اكتشاف الأنشطة الاحتيالية ومنعها أسهل (Baul.,2023). و تعد تقنية البلوكتشين خيارا مثاليا لاكتشاف الاحتيال المحاسبي للعديد من الاسباب منها (Bhaskaran, et al., 2021) : البلوكتشين دفتر استاذ رقمي مشترك موزع يحتوى على بيانات مشتركة بين اجهزة الكمبيوتر و يتم تسويتها بشكل منتظم مع ادارة شفافة و ترخيص بحيث لا يوجد فرصة لارتكاب الاحتيال ، و الاجماع على التحقق من صحة البيانات و العمليات من قبل المشاركين قبل تشكيل الكتلة و اضافتها الى السلسلة ، كما ان المعاملات غير قابلة للتغيير حيث يتم التحقق من صحة كل كتلة مع الطابع الزمني و لا يمكن تغييرها ، و يساهم البلوكتشين القائم على الاذن او الخاص فى منع الأنشطة الاحتيالية عن طريق تقييدها الوصول الى النظام ، و الجمع بين التوقيع الرقمي و تقنيات التشفير يمكن ان يوفر خصوصية متصلة فى التصميم .

و تستخدم تقنيات التنقيب عن البيانات DM للكشف عن الاحتيال المحاسبي و هى تتمثل فى تقنيات من تخصصات مختلفة مثل الاحصاء ، التعلم الآلى ، الشبكات العصبية، الحوسبة و العديد من المجالات الاخرى . و ذلك لاستخراج و تحديد المعلومات المفيدة و المعرفة اللاحقة من قواعد البيانات الكبيرة لمنع الحالات الشاذة و اكتشافها . و يستخدم DM نهجين لكشف الاحتيال : النهج الاستباقي و النهج التفاعلي، و يحدد النهج الاستباقي من و ماذا يمكن اجراء مجموعة محددة من المعاملات او الاجراءات التى تميز الاحتيال قبل حدوثه ، بينما يكتشف النهج التفاعلي الحالات الشاذة التى تحدث فى مجموعة من المعاملات (Sinha.,2020) . و تتعدد طرق و اساليب التنقيب عن البيانات للكشف عن الاحتيال المحاسبي منها (الشبكات العصبية ، الانحدار اللوجستي ، تحليل النصوص ،تقنية تحليل بيانات المجموعات ، شبكة بايزي، شجرة القرار ، منهجية مستوى الاستجابة و غيرهم) و هناك معايير مختلفة لتحديد

اداء و كفاءة تقنيات الكشف السابقة و التى عادة ما تكون ثلاث خصائص مشتركة :
الدقة ، الحساسية ، قوة الكشف (Malekolkalami, et al., 2023)

و يمكن تعريف البلوكتشين ببساطة على انه دفتر الاستاذ الرقعى الموزع الذى يسمح بالنقاط المعاملات التى تتم بين عدة أطراف فى الوقت الفعلى و يعمل كقاعدة بيانات لا مركزية ، حيث يحتفظ كل مشارك بنسخة متطابقة من دفتر الاستاذ ، ليست هناك حاجة الى وسطاء لتسوية المعاملات و يتم اجراء التحقق من قبل عدة مستخدمين ، بمجرد قبول الشبكة للمعاملة يتم تحديث جميع نسخ دفتر الاستاذ . (Bonyuet .,2020)

و البلوكتشين ليست تقنية جديدة و لكنها تتكون من سلسلة من التقنيات الحالية
هى : 1 (تقنية دفتر الاستاذ المزع غير القابل للتغيير على شبكة النظير الى النظير ، فكل نظير فى الشبكة هو خادم و عميل سواء فى توفير الموارد او استهلاكها ، يتيح ذلك تسهيل دفتر الاستاذ الموزع بدون وجود طرف ثالث مركزى . 2) تقنيات الامان ، و تتضمن خوارزميات التشفير و التجزئة لضمان امان و خصوصية المعاملات و التحقق من الهوية الرقمية . 3) اليات الاجماع ، وهى الية رياضية للتحقق الجماعى من المعاملات على البلوكتشين و لانشاء علاقة ثقة بين جميع الاطراف فى شبكة تضم عقد متعددة و غير موثوقة . 4) العقد الذكى ، يتضمن مجموعة من الاتفاقيات التى يمكن للمشاركين فى العقد من خلالها تنفيذ هذه الالتزامات ، و ذلك دون مشاركة طرف ثالث .
(Yontar.,2023 ; Wenhua, et al., 2023 ; Deloitte., 2019)

و اشار معهد المحاسبين القانونيين فى انجلترا و ويلز (ICAEW 2018) بان البلوكتشين ليست تقنية واحدة بل هى بروتوكول – طريقة للقيام بالاشياء – لتسجيل المعاملات . على عكس الانترنت الذى يتم من خلاله مشاركة البيانات ، يمكن فى تقنية البلوكتشين نقل الملكية من طرف الى اخر ، يعد البلوكتشين نموذج مرغوب فيه لعدة أسباب : على سبيل المثال:- فى سوق يضم يضم العديد من الاطراف المتعاملة يمكن ان يلغى الحاجة الى التوفيق بين دفاتر الاستاذ المختلفة ، كما ان التوزيع بين جميع المستخدمين يلغى أيضا حالات الانقطاع و يزيل تكلفة الاضطرار الى دفع سلطة مركزية

للحفاظ على دقة دفتر الأستاذ ، و يمكن لاي مشارك فى دفتر الأستاذ تتبع جميع المعاملات السابقة مما يسمح بزيادة الشفافية و التدقيق الذاتى .

ويشير معهد المحاسبين القانونيين فى انجلترا و ويلز الى البلوكتشين كتقنية محاسبية لنقل ملكية الاصول و كتابة دفتر الأستاذ للمعلومات المالية الدقيقة،حيث ينشأ دفتر الأستاذ من الثقة فى النظام الذى يقود عملية حفظ السجلات (Han, et al., 2023)

ويتكون دفتر الأستاذ الموزع هذا من سلسلة متزايدة باستمرار من الكتل ، حيث تحتوى كل كتلة على قائمة بالمعاملات ، و ترتبط هذه الكتل معا باستخدام تجزئات التشفير ، مما يؤدي الى انشاء سجل غير قابل للتغيير و شفاف لجميع المعاملات (Thakker & Japee.,2023) . فعند حدوث معاملة يتم تسجيلها فى كل نسخة من دفتر الأستاذ من خلال انشاء الكتلة و ذلك بعد الموافقة على المعاملة من قبل غالبية أجهزة الكمبيوتر " العقد المشاركة فى النظام " باستخدام الية التوافق و الاجماع (Gudelci .,2022) . و فى كل مرة تحدث معاملة جديدة فى البلوكتشين تتم اضافة سجل لتلك المعاملة الى دفتر الأستاذ لكل مشارك ، و بمجرد انشائها لا يمكن محو المعلومات ابدًا ، و تتكون كل كتلة من تجزئة تشفير للكتلة السابقة و ختم زمنى و بيانات المعاملة (Idehen & Mayor., 2021) . من خلال "الختم الزمني"، يمكن للنظام تسجيل وقت كل إدخال تلقائياً، يتيح ذلك للشبكة إنشاء ترتيب زمني للأحداث المتعلقة بأى أصل. (Leavins & Ramaswamy .,2023)

و يمكن تصنيف انواع البلوكتشين فى فئتين: بلوكتشين العام (بدون اذن / غير مصرح به /مفتوح) و هو يسمح لاي شخص لديه الانترنت الانضمام الى الشبكة و الكتابة عليها و قراءة ملف المعاملات و لا يوجد جهة مركزية لهذه الانظمة كما يمكن لجميع المستخدمين المشاركة فى عملية التصديق على المعاملات و من امثلة الانظمة التى تستخدم البلوكتشين العام البيتكوين و الايثريوم، و النوع الثانى هو البلوكتشين الخاص (بأذن / مصرح به)فهو يتيح لمستخدمين محددين فقط من قبل سلطة معينة الدخول للشبكة و الاطلاع على البيانات و الكتابة و التصديق على المعاملات ، و غالبا

تعمل تلك الانظمة داخل الكيان حيث لا تكون الكيانات الخارجية قادرة على المشاركة .
(Bonyuet ,2020; Siddiqui , et al., 2020)

و هناك العديد من التطبيقات لـ Blockchain في المحاسبة والمراجعة
والمساءلة كما اوضحتها دراسة (Huang., 2023):

1. حفظ السجلات الرقمية، يمكن لـ Blockchain تخزين وإدارة السجلات الرقمية للمعاملات، توفر العقود والفواتير نظاماً آمناً وغير قابل للتغيير لحفظ السجلات، مما يزيد من دقة مسك الدفاتر ويقلل من احتمالية الاحتيال والخطأ

2. كشف الاحتيال، يمكن لتقنية Blockchain اكتشاف الاحتيال من خلال تقييم ما إذا كانت المعاملة تستوفي الشروط أم لا. لا يمكن تسجيل المعاملات غير القانونية في الكتلة. يمكن لـ Blockchain إنشاء سجلات غير قابلة للتغيير وشفافة للمساعدة في اكتشاف الاحتيال. نظراً لأن Blockchain يسجل كل معاملة في الوقت الفعلي، فإنه سيزيد من كفاءة وفعالية اكتشاف الاحتيال. علاوة على ذلك، من خلال تحليل الكثير من بيانات المعاملات الهيكلية، يمكن لخوارزمية التعلم الآلي تحديد الأنماط والانحرافات في البيانات التي ستشير إلى الأنشطة التي قد تحتوي على احتيال أو خطأ .

3. التدقيق المالي، يمكن أن يوفر تسجيلاً آمناً وغير قابل للتغيير للمعاملات ويساعد في ذلك أتمتة عملية التدقيق، بتكلفة أقل ودقة أكبر. علاوة على ذلك، يمكن لـ Blockchain تمكين المدققين من الوصول إلى البيانات المالية من مصادر متعددة في الوقت الفعلي ومن ثم تحسين قدرتهم على مراقبة الأنشطة المالية واكتشاف الاحتيال وتحسين جودة أعمال التدقيق والتقارير

4. المعاملات المالية العامة، و تتمثل في إنشاء نظام شفاف وآمن وغير قابل للتغيير للمعاملات المالية الحكومية، وتوفير المزيد من المساءلة والحد من مخاطر الاحتيال، التطبيق الآخر المحتمل هو توزيع المنافع العامة والإعانات باستخدام تقنية Blockchain ، و يمكن للحكومات إنشاء نظام آمن وشفاف لتوزيع الأموال

على الأشخاص المستهدفين، يمكنهم الحد من الاحتيال والاختلاس والتأكد من إمكانية توزيع الأموال على الأشخاص المؤهلين

5.تدقيق سلسلة التوريد ، إنشاء سجل ثابت للمعاملات داخل سلسلة التوريد ،توفر مساراً دقيقاً للمعاملات المختلفة، المساعدة في زيادة المساءلة وتقليل مخاطر الاحتيال في سلسلة التوريد

6. الهوية الرقمية القائمة على تقنيةBlockchain ، إنشاء هوية رقمية آمنة ولا مركزية قادرة على ذلك يمكن استخدامها للتحقق من الأفراد والمنظمات المشاركة في المعاملات، مما يقلل من مخاطر الاحتيال

7. الدفع عبر الحدود، تسهيل المدفوعات عبر الحدود، وتقليل الحاجة إليها الوسطاء، وزيادة السرعة والأمن (نظرا لعدم وجود وسطاء) لهذه المعاملات.

و يتفق الباحثان مع دراسة (Kanaparthi., 2024) فى تجميع تطبيقات تقنية ال Blockchain فى المحاسبة المالية من خلال الجدول التالى :

جدول (1-1): تطبيقات تقنية سلاسل الكتل للحد من الاحتيال المحاسبي

استخدام	توضيح
تتبع الأصول	يتم استخدام Blockchain لتتبع ملكية ونقل الأصول مثل العقارات والأسهم والسندات باستخدام نظام دفتر الأستاذ الموزع
مسارات التدقيق	جميع البيانات الموجودة على Blockchain مقاومة للتلاعب ويمكن إرجاعها إلى مصدرها، مما يسهل اكتشاف ومنع النشاط الاحتيالي.
العقود الذكية	تستخدم العقود الذكية لأتمتة المعاملات المالية المعقدة
التحقق من الهوية	توفر تقنية Blockchain طريقة لامركزية آمنة للتحقق من هويات الأشخاص، والتي يمكن استخدامها للامتنال لمبادئ اعرف عميل (KYC) ومكافحة غسيل الأموال (AML) في المحاسبة المالية

معالجة الدفع	توفر تقنية Blockchain معالجة دفع أسرع وأرخص وأكثر أماناً من خلال القضاء على الوسطاء وتقليل تكاليف المعاملات. كما أنه يسهل المدفوعات عبر الحدود عن طريق تقليل الحاجة إلى تحويلات العملة.
ادارة سلسلة التوريد	تم استخدام Blockchain لتتبع حركة البضائع والمواد عبر سلسلة التوريد وبالتالي زيادة الشفافية وتقليل الاحتيال وتحسين الكفاءة
الامتثال التنظيمي	ساعد تقنية Blockchain على ضمان الامتثال للوائح المالية المختلفة، مثل قوانين خصوصية البيانات، واللوائح الضريبية، والأوراق المالية. من خلال توفير سجل للمعاملات مقاوم للتلاعب وقابل للتدقيق، تعمل تقنية Blockchain على تسهيل الامتثال للمتطلبات التنظيمية.

المصدر: Kanaparthi., 2024

و يقسم الباحثان القسم الأول إلى ما يلي :-

أولاً: دور المعلومات المستمدة من تقنية سلاسل الكتل في الكشف والتقرير عن الاحتيال المحاسبي

بدأت البلوكتشين في الواقع كسجل معاملات إلكتروني أي قاعده بيانات إلكترونية ذات ميزات فريدة مصممه لإنشاء سجلات آمنه ودقيقه ومفتوحه وقابله للاستخدام (AlSaq,et al.,2020) كما اكدت دراسه (Fullana & Ruiz .,2020) على ما سبق حيث اشارت الى ان الاحتيال يمكن منعه باستخدام تقنيه البلوكتشين بسبب الكتل التي يتم انشائها والتي تحتاج الى موافقه قبل الدخول الى المرحله التاليه، فتتظيم البيانات في كتل متسلسله اجراء فوري للكشف عن اي محاوله للتلاعب وحتى اذا كان هناك شخص ما قادرا على الوصول الى نظام الكمبيوتر واجراء اي نشاط احتيالي فان النظام يجعل من المستحيل على المحتال التستر على اثره.

و اتفقت دراسه (Pereira, et al., 2019) على انه يمكن لعملية التحقق واليه الاجماع على البلوكتشين منع الفشل والاحتيال دون الحاجه الى منظم مركزي او حتى طرف ثالث موثوق به ، نظرا لانه يتم نسخ دفتر الاستاذ الموزع عبر جميع عقد

الشبكة كما ان التحقق من الصحة يتم من خلال الاجماع فان تزوير المعاملات او الانفاق المزدوج صعب ويتم بسهوله رصد التزوير وتصحيحه تلقائيا.

و اشتملت دراستي كلا من (Wang & Garanina, et al., 2022) و Kogan., 2018) على انه في Blockchain لا تتم إدارة عملية التحقق من المعاملة مركزياً ، بل إنها تشمل جميع أجهزة الكمبيوتر الموجودة في الشبكة، لذلك لا تعاني تقنية Blockchain من أحداث نقطة الفشل، ولايجوز للأفراد التواطؤ لتجاوز الضوابط أو تغيير أو حذف السجلات المحاسبية الرسمية بشكل غير مشروع، وبالتالي، فإن الشركات التي تدمج تقنية Blockchain في أنظمتها المحاسبية قد تقلل من مخاطر الاحتيال.

واوضحت دراسه (Oladejo & Jack.,2020) ان لدى البلوكتشين القدره على منع بعض الانشطة الاحتياليه لانها تستخدم خاصيه التشفير وشبكة النظير للنظير واتفقت معها دراسه (Mahtani., 2022) في ان استخدام تقنيه البلوكتشين في منع الاحتيال المحاسبي هي ميزه تتحقق من خلال خاصيه التشفير وعدم قابليه تغيير بيانات المعاملات والتي يتم توزيعها عبر اجهزه الكمبيوتر ، كما تمتاز تقنيه البلوكتشين بانها توفر طريقه للتفاعل من خلال شبكه النظير الى النظير بدون سلطه مركزيه ، فكل قاعده بيانات البلوكتشين تحمل نفس السجلات مما يجعل التلاعب والاحتيال امرا صعبا حيث تحتاج جميع اجهزه الكمبيوتر الى التحديث في وقت واحد وهذا ما يجعلها اكثر اماناً مقارنة بقاعده البيانات التقليديه على خادم مركزي .

وايدت دراسه (Roszkowska.,2021) ما اوضحته شركه (Deloitte., 2016) في ان نظام المحاسبه القائم على البلوكتشين يمتاز بان جميع الادخالات موزعه الكتروننيه ومختومه بالتشفير وذلك على غرار المعاملات التي تم التحقق منها بواسطه كاتب عدل ، ولكن في هذه الحاله بواسطه "كاتب عدل الكتروني " ، وبالتالي فان تزويرها او اتلافها لاختفاء النشاط الاحتيالي امر مستحيل عمليا لانها مشفره ومختومه وموزعة . وقدمت دراسة (Thakker & Japee.,2023) العديد من

المميزات التي تجعل البلوكتشين ذات قيمة في تقليل الاحتيال وضمان المسائله في مختلف الصناعات ، أولا: توفر الشفافية ،حيث يمكن لجميع المشاركين الوصول الى نفس الاصدار من دفتر الاستاذ. ثانيا: يعزز الامان من خلال استخدام تقنيات التشفير لتأمين المعاملات ومنع التلاعب او التعديلات غير المصرح بها . ثالثا: يتيح امكانيه التتبع حيث يتم تسجيل كل معامله وختمها بالوقت مما يؤدي الى انشاء مسار للاحداث قابل للتدقيق.

وفي نفس السياق اكدت دراسة (Iskamto & Juariyah.,2023) ان التفرد الرئيسي لتقنيه البلوكتشين يكمن في (امانها وشفافيتها) مما يقلل من مخاطر الاحتيال فتوفر تقنيه البلوكتشين ، اولا : مستوى عالي من الامان من خلال استخدام خوارزميات تشفير قوية البيانات المخزنه في البلوكتشين مشفرة ولا يمكن الوصول اليها الا من قبل الاطراف المصرح لها . ثانيا : توفر تقنيه البلوكتشين شفافية البيانات وموثوقيتها فيتم تسجيل كل معامله او تغيير في البيانات ويمكن لجميع الاطراف المعنيه رؤيتها مما يقلل من مخاطر التلاعب بالبيانات وتزويرها .

وفى هذا الصدد اكدت دراسة (Sirapanji .,2023) أن Blockchain كدفتر أستاذ لامركزي موزع يميزه خاصية توزيع شبكة الند للند (شبكة نظير إلى نظير) (شبكة P2P) كنظام برمجي موزع يتكون من عقد (أجهزة كمبيوتر فردية).و هذا يجعلها واحدة من التطورات التكنولوجية التي يمكن استخدامها في مختلف المجالات وخاصة في مجال منع الاحتيال المحاسبي، ويمكن استخدام Blockchain كمفهوم لتنفيذ منع الاحتيال المحاسبي من قبل الشركات داخليا بوضع عقدة على كل قسم يعد النظام الموزع على Blockchain ميزة يمكن للشركات الاستفادة منها بحيث يمكن لكل قسم المشاركة في مراقبة دخل ومصاريف الأقسام الأخرى دون أي قيود ، والغرض من هذا زيادة وعي الموظفين و المديرين بعدم ارتكاب الاحتيال المحاسبي بسبب مراقبة الأقسام الأخرى باستخدام دفتر الأستاذ الموزع على Blockchain بحيث يمكن لكل قسم معرفة دخل ومصاريف الأقسام الأخرى. كما يمكن أيضاً استخدام Blockchain من قبل الشركات خارجياً بإقامة

علاقات لمكافحة الاحتيال المحاسبي بين إدارة الشركة والأطراف الخارجية والأطراف المعنية مثل المستثمرين والمالكين و المراجعين الخارجيين .

و ذكرت دراسة (Huang., 2023) أنه في ظل Blockchain ، فإن الطريقة اللامركزية لتخزين البيانات، لديها القدرة على استبدال نظام المحاسبة النموذجي لتخطيط موارد المؤسسات (ERP) حيث سيتم توزيع الحق في التحقق من المعاملات وبيانات التخزين والتنظيم على كل عقدة ،كل مشارك أو كمبيوتر يطلق عليه اسم "العقدة" في نظام Blockchain، مما قد يقلل من خطر الاحتيال أو الخطأ الذي تتعرض له عقدة واحدة و عادةً ما يُنظر إلى نظام تخطيط موارد المؤسسات (ERP) التقليدي على أنه نظام آمن ، نظراً لأن نظام تخطيط موارد المؤسسات (ERP) الحديث يمكنه منع الهجوم من خارج المؤسسة، ولكن في هذه الحالة، تكون مشكلة الاحتيال من الداخل، أي المديرين، ولا يستطيع نظام تخطيط موارد المؤسسات (ERP) التقليدي التحكم في المدير نظراً لأنهم يتمتعون بأعلى وصول إلى النظام . تعد Blockchain أيضاً الأداة المثالية لتشكيل منصة يمكن للشركات مشاركة المعلومات عليها طوعاً، سيؤدي ذلك إلى تقليل احتمالات الخطأ أو الاحتيال في المعلومات المحاسبية وتحسين جودة المعلومات المحاسبية.

و باستخدام العقود الذكية واللامركزية اضافت دراسة (Tianhao .,2022) خاصية ثالثة ،وهي اللاحاق الخطي لبيانات المعامله ، واستخدمت الخواص الثلاثة للبلوكتشين في كسر اضلاع مثلث الاحتيال (الدافع ، الفرصه ، التبرير) وذلك كما يلي: اولا ستؤدي اللامركزية (بدلا من التفويض المركزي) الى زياده تكلفه الاحتيال بشكل كبير مما يؤدي الى احباط السلوك الاحتيالي في التقارير الماليه فلتعديل البيانات على البلوكتشين سيحتاج المديرون اكثر من 50% من العقد للتعاون معهم والموافقه وبالتالي بموازنه المنفعه مقابل التكلفه سيتم كسر "دافع" الاحتيال. ثانيا اللاحاق الخطي فقط لبيانات المعامله (بدلا من قاعده البيانات التقليديه) اي ادخال البيانات على التوالي ، مما يساعد على تحسين تتبع الاصول المرمزه مثل المخزون ،ويضمن ان جميع الفواتير يتم ترقيمها على التوالي وبالتالي سيتم القضاء على ضلع "الفرصه"

في مثلث الاحتيال. ثالثا من الممكن الجمع بين تقنية Blockchain مع تقنيات أخرى مثل الذكاء الاصطناعي والبيانات الضخمة وما إلى ذلك، لبناء نظام محاسبة آلي يعتمد بشكل أقل على الأشخاص، وبموجب العقد الذكي الذي يعتمد على Blockchain والتشفير، تعتمد عملية المحاسبة بشكل أقل على الأشخاص، " ، تستخدم العقود الذكية كعناصر تحكم تلقائية مما يزيل العامل البشري وبالتالي يعزز بيئه التحكم والرقابه وهذا يزيل العذر عن المحاسبين لتبرير العمل الاحتيالي.

واوضحت دراسة (Idehen & Mayor., 2021) ان تقنيه البلوكتشين يمكن ان تساعد في الكشف عن الاحتيال لانها تتيح خاصيه مشاركته المعلومات في الوقت الفعلي ويتمتع جميع المشاركين في البلوكتشين بإمكانية رؤيه المعاملات، لذلك يتم احباط الاخطاء ومنع البيانات الزائفة ولا يمكن ادخال البيانات الاحتياليه في البلوكتشين . وهذا ما اكدت عليه ايضا دراسة (Rakshit., 2022) حيث اشار الى ان احدى الخصائص الرئيسيه التي تحدد قيمه البلوكتشين هي قدرتها على مشاركته البيانات بسرعه وبشكل آمن من دون الاعتماد على مؤسسه واحده لتولي المسؤوليه عن امان البيانات ، فزياده الامان المقدمه من تقنيه البلوكتشين تعد احد مزاياها وترجع الى الطريقه التي تعمل بها التكنولوجيا باستخدام التشفير التام تولد سجل للمعاملات غير قابل للتغيير مما يمنع الاحتيال والنشاط غير المصرح به.

و على ذات السياق أيضا اشارت دراسة (Han, et al., 2023) أن من شأن المحاسبة في الوقت الفعلي التي تدعمها تقنية Blockchain أن تقلل بشكل كبير من السلوكيات الإدارية الانتهازية للانخراط في الحيل المحاسبية وإجراءات تدمير القيمة للتلاعب بالأرباح المبلغ عنها. وذلك لأن مثل هذه المحاسبة يمكن أن تسمح للمشاركين على الفور باكتشاف عمليات نقل الأصول المشبوهة والمعاملات الأخرى التي تنطوي على خطر تضارب المصالح.

علاوه على ما سبق اكدت دراسته (Oladejo., 2023) على انه بالرغم من ان تكنولوجيا البلوكتشين تحتوي على بعض الالات الوقائيه مثل التشفير والاجماع

الموزع لشبكه النظير الى النظير، الا انه من الملاحظ ان هذه التقنيه ليست محصنه بنسبه 100% ضد الادخالات الاحتياليه والهجمات الخبيثه على قواعد البيانات وغيرها من الانشطه الاحتياليه.

وفي ذات الاتجاه اشارت دراسة (Nickerson ., 2019) الى ان الاخطاء البشريه والعوامل التقنيه في تقنيه البلوكتشين تؤثر على نظام منع الاحتيال والكشف عنه ، حيث لا زال بإمكان الافراد الذين لديهم (الفرصه والضغط والتبرير) تجاوز التكنولوجيا ، وسيظل العنصر البشري الحلقة الاضعف في اي اعداد وهذا يعني ان مستندات المصدر عرضه للخطر، ولأن الادخال يحدد الاخراج وفي هذا الوضع لا يمكن للبلوكتشين ضمان حقيقه وصدق مستندات المصدر وهذا يعني ان الاخراج ايضا لا يكون موثوقا به.

و ذكرت دراسة (Bhaskaran, et al., 2021) ان خاصيه اللامركزيه التي تمتاز بها شبكات البلوكتشين تجعل البنيه التحتيه مفتوحه للتلاعب والوصول غير المصرح به لذلك من المهم للشركات استخدام بلوكتشين مصمم للعمل على بنيه تحتيه مناسبه ومع الخدمات الصحيحه.

ويتفق الباحثان مع (Wang & Kogan., 2018) على انه بالرغم من ان البلوكتشين ربما لا تستطيع القضاء على الاحتيال تماما الا انها قد تساعد في تحديد الاحتيال في الوقت الفعلي .

فعلى الرغم من ان تقنيه البلوكتشين تمنع السلوكيات الاحتياليه الا انها لا تستطيع الاكتشاف الاحتيال من تلقاء نفسها فلا يمكن للبلوكتشين الحمايه بشكل مباشر من اشياء مثل الاستيلاء على الحساب او سرقة الهويه (Ngo.,2020). و لا تزال معاملات البلوكتشين عرضه لمختلف الهجمات الخبيثه وتحتاج مؤسسات الاعمال الى معالجه قضايا الامن والاحتيال فكما توجد انواع احتيال يمكن ان تمنعها البلوكتشين توجد ايضا هجمات تظل البلوكتشين عرضه له وقد يجد المخالفون طرقا غير متوقعه لسرقة الاموال وارتكاب الاحتيال (Bhaskaran, et al., 2021)

ثانيا : تقنية سلاسل الكتل والاحتيال المحاسبي: التحديات والمخاطر

أكدت دراسة (Lu, et al., 2019) على انه على الرغم من ان تقنية البلوكتشين لها العديد من المزايا الا ان نظام التشغيل الحالي لا يزال غير مثالي وبه العديد من المخاطر : يمكن تقسيمها الى :- (مخاطر تشغيلية ، مخاطر سيبرانية ، مخاطر قانونية) . المخاطر التشغيلية : وهي المشاكل التقنية والاجتماعية التي تنعكس في فقدان البيانات والهوية ، ارتفاع تكاليف معاملات البلوكتشين العام ، قلة المتلقين والمستخدمين ، عدم وجود خبره طويله الامد، المشاكل الفنية، عدم وجود طريقه موحده للتشغيل. اما المخاطر الالكترونية(السيبرانية) و التي تشير الى السلوك السيء مثل الاحتيال بسبب الامن غير الكافي او عيوب التصميم، وتنعكس في وجود احتيال في الربط بين العالم الحقيقي وعالم البلوكتشين ، و قد يتعرض التبادل لهجوم الهاكرز واختراق كلمه مرور المستخدمين وتحويل الاموال ، واخيرا المخاطر القانونية و التي تشير الى الاعمال غير القانونيه و التي قد تحدث في سلاسل الكتل وتنعكس على التهرب الضريبي و الاستخدام غير القانوني للمعلومات و كذلك استخدام البلوكتشين في المعاملات غير المشروعه

وعرضت دراسه (Maffei, et al., 2021) مخاطر وتهديدات تقنية البلوكتشين في فئتين:- اولا مخاطر الحمايه : وتتمثل في المخاطر المتعلقة بخصوصية البيانات وسريتها ، مخاطر فقدان المفتاح الخاص، المخاطر الناشئه عن ضعف التشفير، مخاطر انخفاضات مستوى الامان المقدم للحساب. ثانيا مخاطر التشغيل : وتتمثل في مخاطر الحوكمه والتوافق ، مخاطر الاندماج من نقص التكامل مع الانظمه الحاليه ، مخاطر القابليه للتوسع والتوزيع الجغرافي وقوة المعالجه بالنظر الى الحجم الكبير للمعاملات ، مخاطر تشغيل تكنولوجيا المعلومات والاختفاقات المرتبطه بالافراد والاجراءات الداخليه، المخاطر التنظيميه المتعلقه بعدم تدوين العقود الذكيه واختبارها للامتثال.

وتناولت دراسه (Siddiqui , et al., 2020) تحديات ومخاطر البلوكتشين فيما يلي :- (1) مخاطر الخصوصية و التي تتمثل في خصوصيه بيانات المعامله والسريه لا تزال تمثل تحديا في شبكه البلوكتشين يمكن لكل عقده في شبكه البلوكتشين الوصول الى بيانات المعاملات الخاصه بالعقد الاخرى ، يمكن للفرد الذي يلقي نظره على البلوكتشين ايضا رؤيه سجل المعلومات ، وبالتالي لا توجد خصوصيه للبيانات المخزنه في البلوكتشين. (2) مخاطر طبيعه البلوكتشين اللامركزيه : على الرغم من ان اللامركزيه في نظام البلوكتشين تحمي مستخدمي النظام من التعرض للهجوم ففي نفس الوقت قد تتعطل شبكه البلوكتشين من قبل مطور البرنامج الذي يكون على درايه كامله بتخطيط الشبكه وخاصه عندما يكون تطوير البرنامج وظيفه داخليه. (3) مخاطر ضعف البرامج و هي عبارة عن الاخطاء الموجوده في كود البرنامج وبعضها موجود في البرامج سيئه التصميم عاده ما يكون هذا النوع من البرامج عرضه للاختراق . (4) مخاطر التكرار: واجهت البلوكتشين تحديات التكرار في الشبكه توجد نسخ من كل معامله في عقد شبكه البلوكتشين مما يخلق تحديات كبيره امام تنفيذ البلوكتشين من حيث انها معقده وتستغرق وقت طويل من الناحيه الحسابيه.

بالاضافه الى ما سبق فان خطر الاختراق المحتمل لمجموعه البيانات، يعد احد محددات استخدام تقنيه البلوكتشين وقد حددت عدة دراسات (Islam, et al., 2021; Wenhua, et al., 2023; Radanliev., 2023) التحديات والهجمات لامن بيانات البلوكتشين فيما يلي :

- 1- هجوم 51% : هو الخطر الاكبر في صناعه البلوكتشين لانه ينطوي على امكانيه تعديل البلوكتشين بالكامل والذي من المرجح ان يحدث في وقت مبكر من البلوكتشين عندما يكون هناك عدد قليل جدا من المعدنين في السلسله.
- 2- هجمات سيبييل : ينشئ المتسللون عقدا مزيفه للشبكه ويغمررون الشبكه المستهدفه بعدد هائل من الهويات المزيفه مما يؤدي الى تعطل النظام وتعطيل معاملات السلسله.

3- هجمات التصيد: في هجومات التصيد الاحتيالي يكون هدف المتسلل هو الحصول على اعتمادات المستخدم، لديهم القدرة على ارسال رسائل بريد الكتروني تبدو شرعيه الى مالك مفتاح المحفظه، اثناء قيام المستخدم بادخال بيانات تسجيل الدخول من خلال ارتباط تشعبي زائف مرتبط يحصل على جميع البيانات .

4- هجمات التوجيه: هي مخاطر الامان والخصوصيه يمكن للقراصنه الاستفادة من اخفاء هويه الحساب لاعتراض البيانات المرسله الى مزودي خدمه الانترنت .

5- هجمات امان المفتاح الخاص: تعتمد تقنيه البلوكتشين على تشفير المفتاح العام يمكن ان يؤدي التنفيذ والمعالجه غير الصحيحه لتشفير المفتاح العام الى مشكلات امان خطيره في البلوكتشين ، قد يتمكن المهاجم من الحصول على مفتاحك الخاص من المفتاح العام اذا تم تنفيذ توقيع مفتاح البلوكتشين بشكل سيء، يؤدي التحكم في مفتاحك الخاص امتلاك جميع بياناتك في البلوكتشين .

كما تناول تقرير (Deloitte., 2019) المشكلات التي يمكن ان تنتج عندما يكون هناك اليه اجماع غير مناسبه وتتضمن:- 1- شوكه صلبه للبلوكتشين : يعرف بانه حدث يتم بموجبه انشاء نسختين من البلوكتشين، يحدث عاده نتيجة الخلاف بين المشاركين في الشبكة حول القواعد التي تحكم البلوكتشين. 2- الانفاق المزدوج : يعد الانفاق المزدوج مشكله اساسيه في العملات المشفره حيث يمكن نقل الاصول الرقمية نفسها الى كيانات متعدده. 3- سيطره 51% : يتم تعريفها على انها مشكله في المقام الاول في عالم التشفير غير المسموح به حيث يتحكم كيان واحد في اكثر من 51% من قوه معالجه الشبكة ونتيجة لذلك فان الكيان لديه القدره التقنيه على التصرف بشكل ضار. 4- الأداء السيء : آليات الاجماع هي المفاضله بين مستوى عدم الثقة بين المشاركين والسرعه التي يجب ان يتحقق بها توافق الاراء.

ويتضح مما سبق للباحثان ان هجمات مثل سرقة الهويه واختراق النظام و الهجمات الالكترونيه و غيرها لا تزال ممكنه ويصعب اكتشافها باستخدام البلوكتشين ،

فالبلوكتشين يكتشف بشكل فعال الاحتيال الموضوعي وليس الاحتيال الذاتي ، فعلى الرغم من ان خوارزميات الاجماع للبلوكتشين مثل اثبات العمل او اثبات الحصة يمكنها التحقق من صحة المعاملة الا انها لا تتحقق من طبيعته المستخدمين المشاركين في المعاملات او الذين يتحققون من المعاملات وهذا يجعل شبكه البلوكتشين لا تزال عرضة للانشطة الاحتياليه ولتخفيف الضغط وللقضاء على الاحتيال احدى الطرق هي استخدام تقنيات التعلم الآلي (Bhowmik,et al., 2021) . فعلى الرغم من ان مطوري البلوكتشين يعززون تقنياتهم الا ان التقنيات والاساليب المبتكرة مطلوبه لاكتشاف الهجمات ، فالتقنيات التي تستخدم خوارزميات التعلم الآلي والتتقيب عن البيانات قد تجد تطبيقات جديده في اكتشاف الاحتيال والاقتحام والتطفل في المعاملات القائمه على البلوكتشين من خلال تحديد الانماط السلوكيه ومراقبتها واكتشافها استنادا الى تاريخ معاملات الاشخاص ، قد تساعد مناهج التعلم الآلي الخاضعه و غير الخاضعة للإشراف مثل الشبكات العصبية للتعلم العميق ، آلة المتجهات الداعمة ، شبكات المعتقدات البايزية ، الانحدار اللوجستي ، شجرة القرار ، و مصنف الغابات العشوائيه وغيرها في اكتشاف السلوكيات الخارجه (Xu ,2016) .

وفي عصر تقنية Blockchain، يعمل الذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي على تعزيز تحليل البيانات من خلال التدقيق في المعاملات المعقدة واللامركزية. يمكن لخوارزميات الكشف عن الحالات الشاذة تحديد الأنماط أو التناقضات غير العادية في معاملات Blockchain، مما يوفر للمدققين أداة قوية لضمان سلامة وشفافية السجلات المالية. وبعيداً عن الفضائح المالية، أثبت الذكاء الاصطناعي فعاليته في اكتشاف عمليات الاحتيال في بطاقات الائتمان. تقوم خوارزميات التعلم الآلي بتحليل أنماط المعاملات وسلوك المستخدم ونقاط البيانات الأخرى لتحديد الأنشطة الشاذة التي قد تشير إلى معاملات احتيالية، مما يمنع الخسائر المالية للأفراد والشركات (Odeyemi , et al., 2024).

القسم الثاني : دور التعلم الآلي في الكشف عن الاحتيال المحاسبي

و يقسم الباحثان هذا القسم إلى ما يلي :-

أولاً: التعلم الآلي كأحد تقنيات الذكاء الاصطناعي

تتمتع تقنيات الذكاء الاصطناعي و التعلم الآلي بالقدرة على تحليل كمية هائلة من البيانات لتحديد الحالات الشاذة التي قد تشير الى نشاط احتيالي ،و يشير الذكاء الاصطناعي الى محاكاة الذكاء البشري في الآلات المبرمجة لاداء المهام التي تتطلب عادة الادراك البشري ،و يشمل الذكاء الاصطناعي على عدة تقنيات مكونة له بما في ذلك ، التعلم الآلي ، معالجة اللغة الطبيعية، الشبكات العصبية ، الانظمة الخبيرة ، الروبوتات ، و التعلم العميق (Thakker & Japee.,2023) . و يتم استخدام تقنيات الذكاء الاصطناعي و التعلم الآلي لمراقبة المعاملات في الوقت الفعلي لتحديد الأنشطة المشبوهة على الفور و تحديد درجة احتيال لكل معاملة او مستخدم ، مما يسمح باكتشاف و منع الاحتيال بكفاءة اكبر ، و بالتالي اصبح استخدام التعلم الآلي و الذكاء الاصطناعي في الكشف عن الاحتيال و منعه أداة مهمة للمؤسسات لمكافحة الاحتيال المحاسبي و تحديد الانماط و الشذوذ في البيانات المالية لاكتشاف الأنشطة الاحتمالية المحتملة من خلال تحليل بيانات المعاملات التاريخية و اكتشاف الانماط غير العادية ، و يمكن لانظمة الذكاء الاصطناعي توفير اشارات تحذير مبكرة للسلوك الاحتيالي و مساعدة المؤسسات على تخفيف المخاطر المالية . (Baul .,2023) .

و تتمتع تقنيات التعلم الآلي بالقدرة على تحسين اكتشاف الاحتيال والوقاية منه في مجال المحاسبة الجنائية بشكل كبير. من خلال استخدام هذه التقنيات ، يمكن للمحققين تطوير نماذج تنبؤية يمكنها تحديد المعاملات المشبوهة في الوقت الفعلي ومنع الأنشطة الاحتمالية قبل حدوثه (Hossain., 2023).

كما تساعد تقنيات التحليلات المتقدمة للبيانات بتحليل كميات هائلة من البيانات واكتشاف الأنماط والحالات الشاذة، ومؤشرات الاحتيال المحتملة.و تحديد شبكات الاحتيال المعقدة بتحليل البيانات الحالية والتاريخية وتقييم احتمالية حدوث شيء ما ،

مما يتيح اتخاذ تدابير استباقية للتخفيف من المخاطر (Isuru.,2023)، وتتضمن تحليلات البيانات، التحليل الإحصائي والتعلم الآلي والتقنيات المتقدمة الأخرى لتحديد الأنماط والشذوذ والأعلام الحمراء في مجموعات البيانات الكبيرة التي قد تشير إلى أنشطة احتيالية محتملة، يمكن لتقنيات تحليل البيانات مثل التنقيب عن البيانات والتعلم الآلي أن تعزز كفاءة ودقة الكشف عن الاحتيال (Hossain.,2023). فيمكن استخدام تقنيات النماذج الإحصائية مثل (نماذج السلاسل الزمنية، قانون بنفورد، Z score، لالتمان، M score، ليبينش) لاكتشاف الشذوذ.

كما تم اعتماد أساليب بديلة وأكثر تقدماً من أجل اكتشاف الاحتيال المحاسبي منها الشبكات العصبية، وآلات ناقل الدعم، والشبكات البايزية، والبرمجة الجينية، والأساليب الهجينة. وهذه النماذج المذكورة أعلاه تم استخدامها لفترة طويلة، مما سمح بإظهار بعض القصور فيها وللتغلب على أوجه القصور في هذه النماذج، يلزم المزيد من الأبحاث لبناء نماذج جديدة للتنبؤ بالاحتيال المحاسبي باستخدام أساليب التعلم الآلي (بينما لا يوجد نموذج أو أساليب مستخدمة على نطاق واسع حتى الآن) (Ustinova .,2022)، ومن النماذج التي تم تطويرها للتنبؤ بالاحتيال المحاسبي استخدام XGBoost، وهو نهج قوي للتعلم الآلي الجماعي (Sun& Zeng., 2021)

أوضحت دراسة (jebamikyous,et al.,2023) ان التعلم الآلي هو خوارزمية حاسوبية يمكنها انجاز المهام دون أن تتم برمجتها حرفياً لأداء مهمة معينة بشكل صريح، وانما يتم برمجتها بطريقة قادرة على التعلم لأداء العديد من المهام المختلفة. حيث تتعلم الآلة العلاقات داخل البيانات نفسها وتتنبأ بالنتائج دون الاعتماد على افتراضات إحصائية صريحة.

وقامت دراسات عديدة في نطاق الكشف عن الاحتيال المحاسبي (Ashtiani & Baahemi., 2021 ; Schneider & Bruhl.,2023; Bao, et al .,2022) بالأخذ في الاعتبار القضايا المهمة للتنبؤ والتي تركز على تحديد أو تعريف للاحتيال المحاسبي، والمتغيرات التي تتنبأ بهذه النتائج من وجود احتيال من عدمه التي تتمثل

فى البيانات المالية وتشمل النسب المالية أو البيانات الأولية، والتي تكون فى شكل بيانات منظمة يمكن العثور عليها من قواعد البيانات والبيانات غير المالية سواء نصية أو صوتية كبيانات غير منظمة يتم الحصول عليها من تقارير الادارة قسم MD&A ونصوص مكالمات الارباح ومؤتمرات المديرين التنفيذيين واستكشاف التقنيات الناشئة لتحويل المحتويات النصية الى ناقلات للميزات مثل خوارزميات (Vec2Word, Vec2DOC, Bert) ، و كذلك تحديد أفضل نماذج التنبؤ من حيث الدقة النسبية .

و من حيث تقنيات التعلم الآلى أشارت العديد من الدراسات الى انه يمكن تقسيمها الى اربعة انواع تتمثل فى : التعلم الخاضع للإشراف ، والتعلم غير الخاضع للإشراف ، والتعلم شبه الخاضع للإشراف (التعلم المعزز) ، التعلم العميق .وقد يشير التعلم الخاضع للإشراف الى أنه تقنية تتطلب توفر بيانات مصنفة تاريخيا .ويتم استخدام المصنف لأول مرة لتدريب النموذج على هذه البيانات التاريخية من أجل التعرف على الأنماط الموجود والتي يمكن استخدامها بعد ذلك للتنبؤ بالحالات الشاذة فى مجموعة البيانات المستقبلية ;(kureljusic & Kareger.,2023) (jebamikyous,et al .,2023 ; Bhattacharya & Lindgreen.,2020) ، وتتكون خوارزميات التعلم الآلى الخاضع للإشراف من نوعين متميزين وهما التصنيف والانحدار اعتمادا على نوع بيانات الاهداف فإذا كان الهدف المتوقع متغير فئوى فيتم استخدام خوارزمية التصنيف وإذا كان الهدف متغير كمى يتم استخدام خوارزمية الانحدار (Fieberg,et al.,2022).

وفى دراسة (Nielsen.,2022) أوضحت أن الهدف من التعلم غير الخاضع للإشراف هو نمذجة البنية الأساسية أو التوزيع فى البيانات لمعرفة المزيد عن بنية البيانات وكيف يمكن استخدامها وتعمل الخوارزميات لاكتشاف وتقديم البنية المثيرة للاهتمام فى البيانات . وفى ظل التعلم غير الخاضع للإشراف قد يواجه نظام الذكاء الاصطناعى مشكلة وعليه أن يتعلم سلوكا معيناً لحله ويتم تعلم هذا السلوك من خلال تفاعلات التجربة والخطأ مع البيئة التى يعد الوكيل (نظام الذكاء الاصطناعى جزءاً منها)

. وبهذا تصبح انظمة الذكاء الاصطناعي معلمة خاصة بها ولا تحتاج الى بيانات او توجهات او معرفة يقدمها العنصر البشرى (kureljusic & Kareger.,2023).

ويتطلب لبناء نموذج مختلط دمج تقنيات متعددة تمر بثلاث مراحل حيث تعتمد المرحلة الأولى على تحليل البيانات الاستكشافية وتعتمد المرحلة الثانية على تقنيات التجميع أو التصنيف والتي يمكن استخدامها لمعالجة البيانات مسبقا، وتعتمد المرحلة الثالثة على عدد من الخوارزميات الخاضعة للإشراف (Nielsen.,2022) ، وقد يجمع التعلم شبه الخاضع للإشراف أو التعلم المعزز بين كلا النوعين وغالبا ما يتم استخدامه عندما تتكون البيانات بأكملها من جزئين جزء مسمى وجزء غير مسمى نظرا لأنه من الصعب الحصول على تسميات في مجموعة بيانات كبيرة ولكن البيانات غير المسماه قد تكون بيانات ضخمة وفي ظل التعلم شبه الخاضع للإشراف يتم تدريب كلا من هياكل النماذج الخاضعة للإشراف وغير الخاضعة للإشراف في وقت واحد وذلك من خلال استخدام نموذج غير خاضع للإشراف ومدرب على البيانات غير المسماه لتحديد الملاحظات ذات الاحتمالية العالية لكونها بيانات شاذة أو مخالفة ووضع تسمية مستعارة لها على أنها تسمية حقيقية . ومن ثم تطوير نموذج خاضع للإشراف لتحليل البيانات الضخمة بناء على التسميات المستعارة. وظهرت هذه التقنية إمكانية كبيرة لتحسين نتائج التنبؤ (Bhattacharya & Lindgreen.,2020).

وفيما يلي ملخص شامل للعديد من التطبيقات البارزة. لا غنى عن الذكاء الاصطناعي والتعلم الآلي في تمييز أنماط المعاملات، خاصة في الكشف عن الأنشطة الاحتيالية وعمليات الاحتيال المحتملة داخل الشركة. (Kanaparathi., 2024)

جدول (1-2): التطبيقات المختلفة لتقنية التعلم الآلي في الكشف عن الاحتيال

وظيفة	توضيح
أتمتة إدخال البيانات	يتم استخدام ML لأتمتة مهام إدخال البيانات من خلال التعرف على المعلومات واستخراجها من الفواتير والإيصالات والمستندات المالية الأخرى وهذا يمكن أن يقلل من الأخطاء ويوفر الوقت.
الكشف عن الغش	يعد تعلم الآلة مهماً في تحديد الأنماط والانحرافات في البيانات المالية التي قد تشير إلى الاحتيال أو المخالفات الأخرى.
النمذجة التنبؤية	يتم استخدام التعلم الآلي لبناء نماذج تنبؤية تحلل البيانات المالية للمساعدة في التنبؤ بالاتجاهات والنتائج المستقبلية
إدارة المخاطر	يحدد ML ويقيم المخاطر المرتبطة بالاستثمارات والقروض والمعاملات المالية الأخرى
مراقبة الامتثال	يتم استخدام ML لمراقبة المعاملات المالية من أجل الامتثال للوائح والسياسات.

المصدر: Kanaparthi., 2024

ثانياً: التعلم الآلي والاحتيال المحاسبي : الفرص والتحديات

أوضحت دراسة (Bao, et al., 2022) أن بناء أي نموذج للتنبؤ بالاحتيال يتطلب اتخاذ قرارات مهمة بشأن المكونات الثلاثة التالية: (1) مدخلات البيانات (المتنبئات) ومخرجات البيانات (تسميات الاحتيال) التي ينبغي استخدامها للنموذج (2) تحديد خوارزميات التعلم الآلي اللازمة للتنبؤ بالاحتيال المحاسبي (3) معايير التقييم التي ينبغي استخدامها للحكم على أداء نموذج التنبؤ بالاحتيال.

حيث أوضحت دراسة (Chukwuma, et al., 2023) هذه المنهجية للكشف عن الاحتيال . وحيث أن مكونات النموذج تبدأ بمدخلات البيانات (عناصر التنبؤ) للنموذج فقد اختلفت الدراسات في متغيرات الإدخال . وأوضحت الدراسات الأولى في نماذج كشف الاحتيال النسب المالية التي حددها الخبراء وثبت تجريبي أنها مرتبطة بالاحتيال المحاسبي أو الأخطاء المادية ومن هذه الدراسات دراسة (Cecchini,et al.,2010; Dechow, et al.,2011; Hamal &Senvar.,2021;Jofre & Gerlach., 2018) ،وأوضحت

نتائج هذه الدراسات أن النسب المالية المرتبطة بالحسابات التي تم التلاعب بها سوف تنحرف عن السلوك الطبيعي لها وستظهر علامات الاحتيال المحاسبي ومن ثم تم استخدامها على نطاق واسع كمؤشرات لخطر الاحتيال .

وفي اتجاه اخر للدراسات أوضحت ضرورة اضافة البيانات غير المالية الى البيانات المالية وذلك للكشف عن الاحتيال حيث أشارت دراسة (Bertomeu.,2020) (Campbell & Shang .,2022)؛ أن البيانات المالية تعكس جزئيا فقط الاعمال الداخلية للشركة بما في ذلك الأنماط والقيم السلوكية والتي من المحتمل أن ترتبط بسوء السلوك . وعرضت دراسة (Rahman & Zhu.,2023) أهمية المتغيرات المالية في الكشف عن خصائص الشركة المميزة المتعلقة بالتقارير المالية الخاطئة وأن المتغيرات غير المالية تساعد في تقييم مخاطر الاحتيال لأنها لحد ما تسيطر على أنشطة الشركة الحقيقية .

وقامت دراسات عديدة باستخدام البيانات المالية والبيانات غير المالية مثل دراسة (Riskiyadi., 2023) استخدمت الروابط السياسية وجودة المراجعة ، ودراسة (Achakzai & Peng.,2023) اضافت النسب المالية الى المتغيرات الأولية ومتغيرات التحليل النصي وتلك المتغيرات المرتبطة بالمراجعة وتمويل الشركات . وفي دراسات أخرى تم الارتكاز على البيانات النصية فقط مثل دراسة Cecchini,et al.,2010 ; Purda & skillicorn.,2015) وبسبب أن الاختيار الأولي لمتغيرات المدخلات يعد خطوة حاسمة في بناء نماذج فعالة لكشف الاحتيال ، ولا يوجد اطار نظري موحد وثابت للاختيار (Gepp,et al.,2023)

ومن جانب اخر اتجهت دراسة (Xu , et al.,2023) بتوجيه اختيار المتغيرات في نماذج التعلم الآلي بناء على اطار عمل Gone استنادا الى عناصر مثلث الاحتيال من الجشع والفرصة والحاجة والتعرض وذلك للتنبؤ بالاحتيال في الشركات ، ومع ذلك فإن هذا الإطار لا يستفيد من حقيقة أن متغيرات المدخلات يتم اختيارها في أغلب الاحيان بناء على نتائج الدراسات السابقة ومثلث الاحتيال

(Shahana,et al ., 2023) ، وعلى الرغم من أن مثلث الاحتيال هو الأساس في توفير التوجيه النظري لاختيار المتغيرات ولكنه قاصر بسبب أنه يركز على الظروف الأولية التي تدفع السلوك للاحتيال بدلا من المؤشرات القابلة للتشغيل للكشف عن الاحتيال ومن ثم قامت دراسة (Gepp,et al.,2023) بتطوير مثلث الاحتيال بإضافة عنصر رابع الى الفرصة والحافز أو الضغط والمبرر يتمثل في عنصر المعلومات المشبوهة (النتائج الجانبية للبيانات) التي تحدث نتيجة الاحتيال.

و وفقا لدراسة (Sadgali,et al., 2019) تم تصنيف التقنيات الخاصة بالكشف عن الاحتيال الى تقنيات وصفية وتقنيات تنبؤية . وتركز التنبؤات الوصفية على البنية الجوهرية والعلاقات والترابط ، وتقنيات تنبؤية مثل الانحدار اللوجستي ، شجرة القرار ، الشبكات العصبية ، شبكات معتقدات بايز ، آلة دعم المتجهات ، أقرب جار ، ونماذج بايز نايف Naive Bayesian قد تكون نماذج مستقلة ولها خوارزميات مختلفة ولكل نموذج مزايا وعيوب . تشمل نماذج المجموعة الغالبة العشوائية ، Bagging ، Adaboost ، Boosted trees ، نموذج التعزيز التدريجي ، تقنيات الذكاء الاصطناعي والحاسوبي والتي تمثل مجموعة من المنهجيات والأساليب الحسابية لمعالجة مشاكل العالم الحقيقي التي تعتمد على النمذجة الرياضية مثل الخوارزمية الجينية ، الشبكات العصبية الاصطناعية ، الشبكات العصبية متعددة الطبقات (Sadgali, et al.,2019) .

تم إنشاء خوارزميات التجميع للتغلب على أوجه القصور لكل نموذج (Riskiyadi.,2023)، وتم استخدام تقنيات التعلم الآلي المدمجة والتي تفوقت على المصنفات الفردية حيث تدمج مصنفات المجموعة تنبؤات النماذج المتعددة . وأن دمج العديد من النماذج يؤدي الى دقة التنبؤ وعلاوة على ذلك يساعد على تخفيض التباين (Sadgali, et al., 2019). وفي دراسة (Nielsen.,2022) أوضح أن التقنيات الهجينة للتعلم الآلي أظهرت تفوقها على التقنيات الفردية .

وفى دراسة (Bochkay,et al.,2023) أوضح أن اختيار النموذج من بين النماذج المختلفة يتطلب الأخذ بخمسة عوامل وهم الوظيفة، البساطة، الألفة، أداء النموذج، تكاليف الحوسبة. وتشير الوظيفة الى ماذا كان النموذج يخدم الهدف المقصود، والبساطة تشير الى اختيار ابسط النماذج اذا تعددت النماذج التي تخدم الغرض، وتشير الألفة الى المعرفة بأساليب التعلم الآلي التقليدية والتي سبق استخدامها في سياقات مختلفة على سبيل المثال اكتشاف الاحتيال، التنبؤ بالافلاس، قياس المشاعر والتي أثبتت فعاليتها للتطبيق بالإضافة الى المعرفة بتطور نماذج التعلم الآلي التقليدي و ستؤدي الألفة إلى تقليل الجهد، والمساعدة في التشخيص، وتسهيل التنفيذ.

فيما يتعلق بأداء النموذج يعد التعلم العميق جيداً للبدء لثلاثة أسباب. أولاً:- أنه يمثل مجموعة من الاختلافات تركز على نفس بنية النموذج المركزي وبالتالي يسهل فهمها ككل، في حين أن التعلم الآلي التقليدي عبارة عن العديد من هياكل النماذج المتباينة. ثانياً:- عادةً ما يكون أداء التعلم العميق أفضل من التعلم الآلي التقليدي فيما يتعلق بالبيانات النصية وأن نماذج تعزيز التدرج Gradient Boosting تعد أفضل في حالة البيانات الجدولية، وكذلك تعد نماذج Lasso & Rf خيارات جيدة لنمذجة العلاقات الخطية وغير الخطية. وثالثاً:- على الرغم من وجود مكتبات مدربة مسبقاً من التعلم الآلي التقليدي في حالات خاصة، مثل TextBlob و VADER، إلا أن النماذج المدربة مسبقاً موجودة لجميع أساليب التعلم العميق، وذلك بفضل بنية النموذج والتي تساعد على نقل التعلم. كذلك لا بد من الأخذ في الاعتبار تكاليف الحوسبة في حالة اختيار النموذج.

و يعد اختيار مقاييس تقييم الأداء المناسبة لمجموعات البيانات غير المتوازنة (الحالات غير الاحتمالية تفوق الحالات الاحتمالية) أمراً حيوياً. وقد تتعدد مقاييس التقييم بين مقياس الدقة، الحساسية، التخصيص (specificity)، المنطقة تحت المنحنى (the Area under the curve)، الدقة المتوازنة (Balanced Accuracy) ويعد مقياس الدقة من المقاييس الأكثر شيوعاً في الاستخدام.

و اتفقت عديد من الدراسات (Ucoglu., 2020 ; Hossain.,2023) على دور التعلم الآلى فى زيادة الكفاءة والدقة والفعالية فى اكتشاف الاحتيال وتحديد الانماط والشذوذ وتوفير الرقابة فى الوقت الفعلى كذلك يمكن استخدامه لاجراء تحليل تنبؤى لاكتشاف الاحتيال قبل حدوثه . ويتم تحديث النماذج باستمرار بجهد أقل بسبب التغيرات المستمرة فى انماط الاحتيال .

و عن التحديات التى تواجه نماذج التعلم الآلى للكشف عن الاحتيال فقد أشارت العديد من الدراسات الى التحديات التى تواجه التعلم الآلى فى كشف الاحتيال المحاسبى حيث اتجهت الدراسات الى تقسيم التحديات الى تحديات ناتجة عن طبيعة الاحتيال والخصائص المميزة له ، وتحديات اخرى تخص نماذج التعلم الآلى والبيانات المطلوبة لهذه النماذج (Bao, et al .,2022 ; Fieberg,et al., 2022)

وقد أشارت دراسة (Perols.,2011) الى وجود مجموعة من الخصائص المميزة للاحتيال تتمثل فى 1- نسبة الشركات الاحتيالية الى الشركات غير الاحتيالية صغيرة (مشكلة عدم التوازن للفئة) 2- خطأ التصنيف قد يكون أكثر تكلفة عند تصنيف الشركات الاحتيالية كشركات غير احتيالية مقارنة بتصنيف الشركات غير احتيالية كشركات احتيالية (عدم توازن التكلفة) 3- السمات المستخدمة لكشف الاحتيال تكون صاخبة نسبيا حيث يمكن أن تشير قيم السمات المشابهة الى انشطة احتيالية وغير احتيالية 4- يحاول المحتالون إخفاء الاحتيال بشكل فعال مما يجعل قيم سمات شركات الاحتيال تبدو مشابهة لقيم سمات الشركات غير احتيالية .

وأشارت دراسة (Kafi & Adanan., 2020) الى التحديات المواجهة للتعلم الآلى والتى تتمثل فى جودة البيانات وتكاملها والاعتبارات الأخلاقية والفجوة المعرفية والمهارات ، وقابلية نماذج التعلم الآلى للتفسير والتوضيح حيث تعد الشفافية وفهم النتائج المالية أمرا بالغ الأهمية .

بينما رأت دراسة (Hassanniakalager, et al.,2022) أن هناك وجود ثلاثة من التحديات الهامة عند تطبيق تقنيات التعلم الآلى والتى قد تنشأ عنها تحيز وقد

تؤدي الى نتائج غير صحيحة والتي تتمثل في المتغيرات العديدة في نماذج التعلم الآلي ، الاحتيال التسلسلي والذي قد يكون مضلل عند استخدام أساليب تعلم الآلة ، وتقسيم العينة بتسلسل زمني يعد حل غير كفء لهيكل البيانات المحاسبية حيث يتجاهل الارتباطات داخل الشركة والتي تؤدي الى التقرير غير الصحيح عن أداء النموذج في عينة التحقق.

وفي ضوء تحليل الدراسات السابقة يرى الباحثان أنه يمكن تقسيم التحديات التي تواجه نماذج التعلم الآلي للكشف عن الاحتيال الى اربعة تحديات أساسية:- 1- اختيار المتغيرات وتحديد الخوارزميات 2- مشكلة عدم التوازن في الفئة 3- مشكلة عدم التوازن في التكلفة 4- الاحتيال التسلسلي

و فيما يلي يتناول الباحثان التحديات السابقة كالآتي :

1-اختيار المتغيرات وتحديد الخوارزميات

يعد أحد القيود الرئيسية لاكتشاف الاحتيال ومنعه هي جودة البيانات فقد أشارت دراسة (Kafi & Adanan., 2020) أن أحد التحديات المواجهة عند استخدام البيانات الضخمة في المحاسبة هو التأكيد على جودة البيانات وتكاملها ونظرا لأن مصادر البيانات الهامة قد تتضمن مجموعات من البيانات متنوعة ومعقدة من أنظمة مختلفة مما قد يؤدي الى وجود مشاكل في دقة البيانات واتساقها وتوافقها . وأشار (Bao, et al., 2020) أن جودة البيانات وسلامتها وشموليتها من الأمور الهامة لنماذج التعلم الآلي للتنبؤ بالاحتيال وتقاس جودة البيانات الضخمة من خلال أربعة ابعاد تشمل الحجم والسرعة والتنوع والمصادقية وأن الثلاثة أبعاد الأولى قد تعرقل مصداقية البيانات. وقد اوضحت دراسة (Hossain.,2023) أن عدم توافر السمات التي تشير لجودة البيانات من الدقة واكتمالها واتساقها وحسن توقيتها قد تؤدي لنتائج غير صحيحة ويقلل من فعالية تقنيات تحليلات البيانات. وكذلك الحاجة الى مجموعة بيانات كاملة ومتوازنة وكبيرة لضمان التنبؤ (Ucoglu.,2020).

2- مشكلة عدم التوازن في الفئة

تؤدي الندرة النسبية لحالات الاحتيال مقارنة بحالات عدم الاحتيال الى تفاوت النسبة بينهم في أية مجموعة بيانات وهذا قد يشير لمشكلة عدم التوازن (Fieberg,et al.,2022). ونظرا لعدم اتخاذ اجراءات صارمة بشأن الشركات الاحتيالية باستثناء عدد محدود منها مما قد يؤدي الى وجود عينة غير متوازنة (Liu, et al.,2023) وحيث أن عدم التوازن بين كلا من الشركات الاحتيالية والشركات غير الاحتيالية أدى الى استخدام عينات متطابقة بين شركات الاحتيالية وغير احتيالية في دراسات التعلم الآلي مما نتج عن استخدام هذه العينات في الواقع الفعلي نتائج متحيزة ومن ثم فإن استخدام نماذج الكشف عن الاحتيال غير عملي (Achakzai & Peng.,2023) وبسبب المشاكل الشائعة الناتجة عن عدم التوازن في الفئة للشركات الاحتيالية وغير احتيالية فإن النماذج التقليدية للمجموعة يجب ان تقترن مع تقنيات أخذ العينات مثل الافراط في أخذ العينات (Oversampling) أو الاختزال في العينات (Undersampling) وذلك من أجل تحقيق التوازن في الفئة (Ali, et al .,2023).

وفي دراسة (Liu,et al.,2023) تم استخدام خوارزمية جديدة للتعلم الآلي (Light GBM) للتنبؤ بمخاطر الاحتيال المحاسبي والتي ارتكزت على أسلوب الاختزال في أخذ العينة لموازنة عينة التدريب . وقد استخدمت دراسة (Rahman & Zhu.,2023) نماذج المجموعة غير متوازنة (CusBoost , RusBoost) وذلك لتحقيق الدقة خارج العينة والتغلب على مشكلة عدم التوازن في البيانات . وأشارت دراسة (Ali, et al .,2023) الى طرق أخذ العينة كتقنية الافراط في أخذ العينات الاقلية الاصطناعية أو الاختزال في العينة ، ووضحت أن إحدى تقنيات الافراط في أخذ العينات لانتاج أمثلة جديدة وهو (Smote) ويمكن تنفيذها بشكل مستقل عن المصنف المستخدم وتعالج تقنية (Smote) تحدى التجهيز الزائد الناتج عن الافراط العشوائي في أخذ العينات والتي قد تعتمد على مساحة الميزات لانشاء أمثلة جديدة لمساعدة الاستكمال الداخلي بين الحالات الايجابية التي تقع معا . ومن جانب اخر فقد أشارت دراسة (Huang, et al .,2022) الى بديل آخر عن مداخل أخذ العينة وهو

التعلم ذات الحساسية للتكلفة حيث يوجه المصنف تجاه فئة الاقلية بافتراض ارتفاع تكاليف التصنيف الخاطئ لفئة الأقلية .

3- مشكلة عدم التوازن في التكلفة

يعد التصنيف الخاطئ للشركات الاحتمالية أكثر تكلفة من التصنيف الخاطئ للشركات غير احتمالية (Fieberg,et al.,2022) . ويتم النظر الى تكلف التصنيف على أنها مشكلة ثنائية فقد تكون النتيجة إما سلبية كاذبة وذلك بتصنيف شركات الاحتيال بشكل غير صحيح على انها شركات غير احتمالية أو تكون النتيجة ايجابية كاذبة بتصنيف الشركات غير احتمالية على أنها شركات احتمالية . وتؤثر نسب هذه التكاليف على كلا من التدريب والتقييم .

4- مشكلة الاحتيال التسلسلي

يشير الاحتيال التسلسلي الى أنه عملية احتيال قد تمتد لأكثر من عام واحد ، وتتميز نماذج التعلم الجماعي بأنها أكثر قوة ومرونة عن نماذج التعلم الفردية ، وقد يؤدي الاحتيال التسلسلي الى احتواء فترة التدريب وفترة الاختبار على نفس الشركات الاحتمالية ومن ثم أداء مبالغ فيه للنماذج (Nguyen,et al.,2022). كذلك تمتد العديد من حالات الاحتيال لعدة فترات محاسبية ، مما قد يؤدي الى التعقيد في تطوير نموذج الكشف عن الاحتيال (Hassanniakalager, et al .,2022) .

وقد يؤدي التجاهل للاحتيال التسلسلي الى التحيز وتكون النتائج مضللة وأوضحت دراسة (Bao,et al.,2020; Hassanniakalager,et al .,2022) أن أداء تقنيات التعلم الآلي قد يتضخم بمقدار ثلاثة اضعاف عند عدم الضبط بسبب الاحتيال التسلسلي وأن مقاييس التقييم من الدقة والحساسية ثلاثة اضعاف بالزيادة لخوارزمية Rusboost .

و في سياق مماثل لاحظت الدراسة التالية (Tyagi, et al., 2020) أن كلا التقنيتين Blockchain و ML تكملان بعضهما البعض لأنهما قادران على حل

التحديات القائمة في مجالات كل منهما. و يتطلب التعلم الآلي كميات هائلة من البيانات لكي تصبح قابلة للتطبيق على تقنيات / استخدامات العصر الحالي هذه هي النقطة الدقيقة التي تتألق فيها تقنية Blockchain ولديها القدرة على الاندماج مع التعلم الآلي / الذكاء الاصطناعي. وبالتالي، يمكن أن تكون تقنية Blockchain ذات قيمة تقنية (مكون / أداة) لعلماء التعلم الآلي لجمع البيانات (بما في ذلك الحفاظ على أمان هذه البيانات في كل موقع / عميل / خادم / في الشبكة). على سبيل المثال ، يمكن نشر شبكة عصبية أعلى شبكة Blockchain، أي توزيعها على نطاق واسع من أجل جمع كميات كبيرة من البيانات. و لا فائدة من جمع المعلومات لأغراض التخزين فقط . تعد معالجة التعلم الآلي بمثابة استثمارية منطقية لاستخدام قاعدة بيانات Blockchain، يمكننا جمع البيانات وتخزينها على نظام لامركزي (طريقة) ، وستقوم خوارزميات التعلم الآلي بمعالجتها / تحليلها باستخدام العديد من التقنيات الفعالة. ونتيجة لذلك ، فإن النظام المحدث (بعد التحليل) سوف يتعلم باستمرار ويغذي بالمعلومات التي تم الحصول عليها

القسم الثالث : المعلومات المستمدة من تكامل تقنية سلاسل الكتل وتعلم الآلة للكشف والتقرير عن الاحتيال المحاسبي

لقد مهد ظهور تقنية Blockchain والذكاء الاصطناعي (AI) الطريق للتقدم الثوري في مختلف المجالات، بما في ذلك المحاسبة والمراجعة . يجمع نظام التدقيق المدعوم بخوارزميات الذكاء الاصطناعي على Blockchain بين الطبيعة اللامركزية وغير القابلة للتغيير لـ Blockchain مع القدرات التحليلية للذكاء الاصطناعي و التعلم الآلي لتعزيز كفاءة ودقة وشفافية عمليات التدقيق . يحمل هذا التكامل القدرة على إعادة تشكيل ممارسات المحاسبة و التدقيق التقليدية، وتخفيف الاحتيال، وتحسين تقييم المخاطر، وتوفير رؤى حقيقية للبيانات المالية. (Baâtout & Boussetta., 2024)

و يتناول الباحثان هذا القسم كما يلي :

أولا : العلاقة التأثيرية بين سلاسل الكتل والتعلم الآلي كمرتكز لتقنيات الذكاء الاصطناعي

يتمتع الجمع بين كل من التعلم الآلي وتقنية Blockchain بالكثير من الفوائد من حيث تعزيز الأمان و الشفافية وإمكانية التتبع و تعزيز خصوصية البيانات و الأتمتة والكفاءة و التدقيق والامتثال المعززان . على الرغم من كون كل منهما ثورية كما هي بالفعل ، فإن Blockchain و MI لديها القدرة على أن تكون أكثر ثورية عند الجمع بينهما. يمكن لكل منهما زيادة قدرات بعضهما البعض وكذلك تحسين مستويات الشفافية والثقة والخصوصية (Tyagi, et al., 2020)

و فيما يلي بعض الفوائد الرئيسية من علاقة التكامل بين تقنية البلوكتشين و التعلم الآلي في مجال المحاسبة و المراجعة:

1- تحسين أمان البيانات : يوفر دمج Blockchain والتعلم الآلي أمانًا معززًا من خلال التشفير واللامركزية. إن الميزة المتأصلة في Blockchain المتمثلة في تخزين البيانات في كتل آمنة ذات تجزئة تشفير تجعل من المستحيل تقريبًا تغيير المعلومات بمجرد تسجيلها. ويضمن هذا، جنبًا إلى جنب مع آليات الإجماع، أن تكون نماذج التعلم الآلي على Blockchain آمنة، ومضادة للتلاعب، وجديرة بالثقة، و يمكن أن يؤدي دمج التعلم الآلي في تطبيقات البلوكتشين إلى تعزيز التدابير الأمنية (Katala.,2023) ، و ان السمة المميزة لـ Blockchain هي أنها آمنة للغاية لأنه يتم تخزين البيانات في كتل ثم يتم إغلاقها باستخدام خوارزميات التشفير، مما يجعل التلاعب بالبيانات شبه مستحيل. و لا عجب أن تعتبر تقنية Blockchain مثالية لتخزين البيانات الحساسة للغاية. ومن ناحية أخرى، كما يساعد التعلم الآلي في نشر تطبيقات Blockchain والتنبؤ بإمكانيات انتهاكات النظام. ويعملون معاً على تعزيز الأمن . عززت أساليب التعلم الآلي بشكل كبير من كفاءة مهام الكشف عن الاحتيال في أنظمة المحاسبة التي نشرت

تقنية Blockchain والذكاء الاصطناعي ، وبالتالي فإن استخدام أساليب التعلم الآلي يعد ميزة للأغراض الأمنية لغرض تحديد الانحرافات والهجمات في أنظمة المحاسبة . (Alsulami, et al ., 2023)

2- الشفافية وإمكانية التتبع: تعمل تقنية Blockchain بطبيعتها على تعزيز الشفافية وإمكانية التتبع بسبب دفتر الأستاذ الثابت الخاص بها. ويتم تسجيل كل تغيير أو تحديث أو تغيير يتم إجراؤه على نماذج التعلم الآلي على Blockchain ، مما يؤدي إلى إنشاء تاريخ يمكن تتبعه لتطور النموذج. وتعتبر هذه الميزة مفيدة في الحفاظ على سلامة نماذج تعلم الآلة، وتعزيز الثقة بين المستخدمين، وتسهيل عمليات التدقيق والتحقق من الامتثال. علاوة على ذلك، فإن استخدام تقنية Blockchain لتتبع التحسينات في نماذج التعلم الآلي يعزز المساءلة ويعالج المخاوف بشأن الطبيعة الغامضة للخوارزميات المعقدة (Katala.,2023). و تحتاج ممارسات المحاسبة والمراجعة إلى التخفيف من عدم تناسق المعلومات لصالح الشفافية والمساءلة. لذلك فإن استخدام Blockchain و MI يمكن أن يوفر وسيلة تكنولوجية جديدة للتحكم في المعلومات المحاسبية ومراقبتها لتقليل عدم تناسق المعلومات ومشاكل الوكالة . ويحدث هذا لأن Blockchain يتيح البيانات المشتركة والتحقق منها والمتفق عليها والذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي الذي يكتشف الحالات الشاذة (Han,et al., 2023) .

3- تعزيز خصوصية البيانات: تعد خصوصية البيانات من الاهتمامات الرئيسية في المشهد الرقمي اليوم. من خلال الاستفادة من خوارزميات التعلم الآلي ، يمكن لأنظمة Blockchain تعزيز خصوصية البيانات عن طريق تشفير المعلومات الهامة وتمكين الوصول إلى الكيانات المصرح بها فقط . يمكن أيضاً استخدام التعلم الآلي لاكتشاف الانحرافات والانتهاكات الأمنية المحتملة ، مما يسمح باتخاذ التدابير الوقائية في الوقت المناسب (Odin.,2023) . يعمل كل من Blockchain والذكاء الاصطناعي بشكل مختلف تماماً، تعمل تقنية Blockchain كمخزن آمن وهي لا مركزية ومضادة للتلاعب وشفافة. و من

ناحية أخرى، يقوم الذكاء الاصطناعي و التعلم الآلي بمعالجة كميات هائلة من البيانات وعادة ما يكون مركزياً وسريع التطور وغير شفاف. فبينما تعاني تقنية Blockchain من قابلية التوسع والكفاءة، فإن الذكاء الاصطناعي يعاني من الشفافية والخصوصية، مما يجعل التقنيتين متطابقتين تماماً لأن كل واحدة منهما يمكنها معالجة نقاط الضعف لدى الأخرى. توفر تقنية Blockchain الثقة والخصوصية والمساءلة للذكاء الاصطناعي، بينما يوفر الذكاء الاصطناعي قابلية التوسع والكفاءة والأمان للBlockchain (Yang., 2022)

4- التدقيق والامثال المعززان: يدعم تكامل Blockchain والتعلم الآلي عمليات تدقيق أكثر كفاءة وفعالية، يضمن Blockchain سلامة البيانات والشفافية وإمكانية التتبع، بينما تساعد التحليلات المدعومة بالذكاء الاصطناعي المدققين في تحديد الحالات الشاذة وتقييم المخاطر وإجراء عمليات تدقيق أكثر شمولاً، ومراقبة الامثال (Thakker & Japee., 2023). ويمكن للمراجعين استخدام تقنيات الذكاء الاصطناعي لمراجعة دفاتر الأستاذ العامة والامثال الضريبي وأوراق عمل التدقيق وتحليلات البيانات واكتشاف الاحتيال واتخاذ القرار. توفر تقنية Blockchain الثقة في العمليات القائمة على الذكاء الاصطناعي من خلال إثراء الثقة في بياناتها ونماذجها وتحليلاتها، وتمكين نموذج تدقيق أكثر مرونة ودقة يعمل على أتمتة الضمان وبالتالي يقوي المراجعة. يمكن أن تستفيد مهنة التدقيق من تقنية الذكاء الاصطناعي من خلال مقارنة إدخلات المحاسبة المقابلة في سلاسل الكتل المسجلة من قبل كل طرف من الأطراف التجارية. هذا الإجراء سهل نسبياً لأن بيانات Blockchain قابلة للتتبع وقابلة للمراجعة. (Han, et al., 2023).

5- الأتمتة والكفاءة: يتيح تكامل Blockchain والتعلم الآلي أتمتة المهام المتكررة مما يقلل الجهد اليدوي ويزيد الكفاءة التشغيلية (Thakker & Japee., 2023).. لوحظ أن التطبيق المتكامل للذكاء الاصطناعي و Blockchain يمكن أن يحسن العمليات في الصناعة. يمكن أن يؤدي استخدام

تقنيات المعلومات إلى أتمتة القرارات المحاسبية إلى حد كبير وتحويل العمل اليومي للمحاسبين (Kumar, et al., 2023).

و مما سبق يتضح للباحثان ان من خلال دمج هذه التقنيتين ، تستطيع المؤسسات تعزيز دقة وكفاءة وحماية عمليات المحاسبة المالية الخاصة بها. إن التأثير المحتمل لهذا الدمج على المحاسبة المالية عميق. ومع ذلك، فإن تحقيق إمكاناتها الكاملة يتطلب التغلب على بعض العقبات. تشمل هذه التحديات وضع مبادئ توجيهية محددة لتطبيق هذه التقنيات في المحاسبة المالية، ومعالجة قابلية التوسع في شبكات Blockchain، ودمج أنظمة الذكاء الاصطناعي بسلاسة مع بروتوكولات وأنظمة المحاسبة الحالية. ومع تقدم البحث والتطوير المستمر في مجال Blockchain والذكاء الاصطناعي، فإن حل هذه العقبات سيمهد الطريق لعصر جديد في المحاسبة المالية، مدفوعة بالتكنولوجيا المتطورة (Kanaparathi., 2024) .

ثانيا : تطويع إمكانية الاستفادة من المعلومات المستمدة من تقنية سلاسل الكتل والتعلم الآلي في الكشف والتقرير عن الاحتيال المحاسبي .

توفر تقنية Blockchain ، المعروفة بنظام دفتر الأستاذ الآمن والمقاوم للتلاعب، منصة موثوقة لتسجيل المعاملات المالية والتحقق منها. تتم تجزئة كل معاملة بشكل مشفر والتحقق من صحتها بواسطة عقد متعددة في الشبكة، مما يضمن الشفافية والثقة. عند تطبيقها على التدقيق، تضمن تقنية Blockchain عدم قابلية تغيير السجلات المالية، وبالتالي تقليل مخاطر التلاعب بالبيانات والتعديلات غير المصرح بها. بالإضافة إلى ذلك، فإن الطبيعة اللامركزية لـ Blockchain تلغي الحاجة إلى سلطة مركزية، مما يعزز نظاماً أكثر شفافية وفعالية ببيئة المراجعة. (Baâtout & Boussetta., 2024)

يضيف دمج الذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي في عملية التدقيق طبقة من التطور والأتمتة. يمكن للخوارزميات التي تعمل بالذكاء الاصطناعي تحليل كميات هائلة من البيانات المالية، وتحديد الأنماط، والحالات الشاذة، والمخاطر

المحتملة، وتزويد المدققين برؤى قابلة للتنفيذ و يمكن لهذه الخوارزميات مراقبة المعاملات والسجلات المالية بشكل مستمر في الوقت الفعلي، مما يسمح للمدققين باكتشاف المخالفات على الفور ومعالجة المشكلات المحتملة، و من خلال التعلم من البيانات التاريخية، تعمل أنظمة التعلم الآلي على تحسين دقتها وكفاءتها بمرور الوقت، وتبسيط عملية التدقيق وتقليل الاعتماد على الإجراءات اليدوية. علاوة على ذلك، فإن استخدام العقود الذكية، وهي عقود ذاتية التنفيذ بقواعد محددة مسبقاً، يمكن أن يؤدي إلى أتمتة عمليات التدقيق المختلفة، مما يقلل من احتمالات التلاعب الإداري والسلوك الانتهازي و تقليص دور الإنسان في مهنة التدقيق والمحاسبة مما يقلل من مخاطر الخطأ البشري . تضمن العقود الذكية استيفاء الشروط المحددة مسبقاً قبل تنفيذ المعاملات، مما يعزز دقة وموثوقية إجراءات التدقيق إن قدرة Blockchain على إنشاء دفتر أستاذ غير قابل للتغيير وغير مركزي، إلى جانب براعة الذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي في تحليل البيانات، تمهد الطريق لعمليات المحاسبة والتدقيق الآلية في الوقت الحقيقي (Al- Baâtout & Boussetta., 2024 ; Habashneh &Hamdan., 2023). و فيما يلي يوضح الباحثان مجالات التكامل بين Blockchain والتعلم الآلي من منظور مهني و التي يستمد منها المعلومات بغرض القضاء على ممارسات الاحتيال المحاسبى :

1. تعزيز إدارة المخاطر وكشف الاحتيال : قد أدى دمج تقنية Blockchain والذكاء الاصطناعي في العمليات إلى تعزيز قدرات إدارة المخاطر واكتشاف الاحتيال بشكل كبير و يمكن للخوارزميات التي تعمل بالذكاء الاصطناعي، والقادرة على تحليل كميات كبيرة من بيانات المعاملات في الوقت الفعلي، تحديد الأنماط غير العادية التي تشير إلى نشاط احتيالي و بفضل طبيعتها التكيفية، تعمل نماذج التعلم الآلي على تحسين أنظمة اكتشاف الاحتيال بشكل مستمر من خلال التعلم من مدخلات البيانات الجديدة و تقوم خوارزميات الذكاء الاصطناعي أيضاً بتقييم عوامل الخطر المرتبطة بمطالبات التأمين وطلبات القروض والمحافظ الاستثمارية، مما يسهل التخفيف الاستباقي للمخاطر وتعزيز عملية صنع

القرار حيث تعمل تقنية Blockchain على تعزيز الذكاء الاصطناعي في إدارة المخاطر واكتشاف الاحتيال من خلال توفير إطار عمل شفاف وآمن لتسجيل المعاملات والتحقق منها. من خلال الاستفادة من تقنية دفتر الأستاذ اللامركزي الخاصة بـBlockchain ، يمكن للمؤسسات تقليل مخاطر التلاعب بالبيانات، مما يعزز قابلية التدقيق وسلامة سجلات المعاملات (Addula,et al., 2024) .

فخوارزميات التعلم الآلي تتفوق في تحليل كميات كبيرة من البيانات لاكتشاف الأنماط والشذوذ و من خلال دمج التعلم الآلي مع Blockchain ، يمكن للمؤسسات تعزيز آليات الكشف عن الاحتيال والوقاية منه. تضمن ثبات Blockchain أنه بمجرد تسجيل البيانات ، لا يمكن تغييرها ، مما يجعلها منصة مثالية لتخزين بيانات المعاملات التي تستخدمها نماذج التعلم الآلي لتحديد الأنشطة الاحتيالية (Odin.,2023) وعلاوة على ذلك، يمكن للعقود الذكية على Blockchain فرض القواعد والشروط المحددة مسبقاً بشكل مستقل وإجراء فحوصات الامتثال، وتبسيط عمليات الكشف عن الاحتيال وإدارة المخاطر(Addula, et al., 2024).

إن دمج نظام التدقيق المدعوم بالذكاء الاصطناعي في Blockchain يحمل إمكانات هائلة لتحويل مجال التدقيق. من خلال الجمع بين شفافية Blockchain وثباته واللامركزية مع القدرات التحليلية والأتمتة للذكاء الاصطناعي، يمكن للمدققين تعزيز عملية صنع القرار وتحسين تقييم المخاطر وتحقيق عمليات تدقيق أكثر كفاءة وشفافية. يمثل هذا التكامل خطوة مهمة نحو مستقبل التدقيق، حيث تساهم الحلول المعتمدة على التكنولوجيا في موثوقية وفعالية التقارير المالية وممارسات التدقيق لاكتشاف الاحتيال (Baâtout & Boussetta., 2024) . يقدم الذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي حلاً استباقياً لكشف ومنع الأنشطة الاحتيالية لمعاملات ال Blockchain. فيمكن لخوارزميات التعلم الآلي أن تتعلم من البيانات التاريخية، مما يجعلها دقيقة بشكل متزايد بمرور الوقت في تحسين تحليلات Blockchain بعدة طرق كما يلي : (Bron., 2023)

أ- تحديد المعاملات المشبوهة

يمكن لخوارزميات الذكاء الاصطناعي تحليل بيانات المعاملات لتحديد الأنماط والانحرافات التي قد تشير إلى نشاط احتيالي و يمكن لنظام الذكاء الاصطناعي وضع علامة على معاملة مشبوهة إذا كانت تنطوي على مبلغ كبير من المال، وتحدث بين حسابين لم يتفاعلا من قبل مطلقاً، ويتم إجراؤها في وقت غير معتاد. ومن خلال القيام بذلك، يمكن للذكاء الاصطناعي تحديد الأنشطة الاحتيالية بسرعة وبشكل استباقي.

ب - مراقبة المخاطر

يمكن استخدام الذكاء الاصطناعي لتقييم المخاطر المرتبطة بالمعاملات والحسابات الفردية. يمكن لنظام الذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي تعيين درجة مخاطرة لكل معاملة أو حساب من خلال تحليل عوامل مثل تاريخ المعاملة وعمر الحساب والموقع و يمكن بعد ذلك وضع علامة على المعاملات أو الحسابات ذات الدرجات العالية المخاطر لإجراء مزيد من التحقيق و من خلال مراقبة المخاطر، يمكن للذكاء الاصطناعي منع الأنشطة الاحتيالية وغسل الأموال قبل حدوثها.

ج- تحسين التحقق من الهوية

يمكن للذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي تعزيز عمليات التحقق من الهوية من خلال تحليل البيانات البيومترية للمستخدم مثل التعرف على الوجه أو مسح بصمات الأصابع و من خلال التأكد من أن كل مستخدم هو ما يدعيه، يمكن للذكاء الاصطناعي منع سرقة الهوية والتأكد من أن المستخدمين الشرعيين فقط هم الذين يمكنهم الوصول إلى شبكة Blockchain من خلال تعزيز التحقق من الهوية، يمكن للذكاء الاصطناعي تحسين أمان شبكة Blockchain .

د- تعزيز كشف الاحتيال

يمكن للذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي تعزيز اكتشاف الاحتيال من خلال تحليل البيانات التاريخية وتحديد أنماط النشاط الاحتيالي و إذا اكتشف نظام الذكاء الاصطناعي سلسلة من المعاملات المشابهة لتلك المرتبطة بحالات الاحتيال السابقة، فقد يقوم بوضع علامة عليها لإجراء مزيد من التحقيق ومن خلال القيام بذلك، يمكن للذكاء الاصطناعي منع الأنشطة الاحتيالية وغسل الأموال في المستقبل.

2. تعزيز العقود الذكية والأتمتة في المحاسبة و المراجعة : العقود الذكية المشفرة على Blockchain هي عقود ذاتية التنفيذ بقواعد محددة مسبقاً، ويتم تنفيذها عند استيفاء شروط محددة مسبقاً، وتستخدم عموماً لتنفيذ اتفاقية دون الحاجة إلى وسيط. وبرزت العقود الذكية كواحدة من أكثر حلول إدارة البيانات كفاءة وفعالية (Yang., 2022) . يمكن أن تؤدي العقود الذكية إلى أتمتة عمليات التدقيق المختلفة، مما يقلل من احتمالات التلاعب الإداري والسلوك الانتهازي و تضمن العقود الذكية استيفاء الشروط المحددة مسبقاً قبل تنفيذ المعاملات، مما يعزز دقة وموثوقية إجراءات التدقيق (Baâtout & Boussetta., 2024) . يمكن لخوارزميات التعلم الآلي أن تعزز تنفيذ العقود الذكية من خلال تحليل البيانات ، والتنبيه بنتائج المعاملات، وتحديث معلومات العقد ديناميكياً في الوقت الفعلي (Addula , et al., 2024) .

يعد التعلم الآلي أداة قوية تعتمد على كميات كبيرة من البيانات لإنشاء النماذج والتنبيه الدقيق. يتم قضاء الكثير من الوقت في جمع وترتيب ومراجعة هذه المعلومات للتأكد من دقتها. هذا هو المكان الذي تلعب فيه Blockchain حيث يمكن لتقنية Blockchain أن تقلل بشكل كبير من الوقت المستغرق و يمكن تبادل البيانات بشكل مباشر وآمن من خلال استخدام العقود الذكية في هذه الحالة . يمكن للعقود الذكية أن تعزز العملية برمتها إلى حد كبير باستخدام التوقيعات الرقمية و يمكن تصميم العقود

الذكاء لنقل البيانات مباشرة إلى علماء البيانات الذين سيستخدمون البيانات لتطوير نماذج التعلم الآلي من أجل ضمان سرية البيانات التي تم الحصول عليها باستخدام تقنيات Blockchain هذا يعني أنه مثل العديد من التقنيات الأخرى ، فإن هذا التكامل بين التعلم الآلي وتكنولوجيا Blockchain يمكن أن يغير قواعد اللعبة ، حيث سيستمر في إنشاء منصة لعلوم البيانات. وبالمثل ، فإن هذا الدمج يدعم قطاعات مثل التمويل والتأمين ، حيث يمكن استخدامها في تطوير أدوات للكشف عن الاحتيال ومنعه. (Tyagi, et al., 2020)

و أكد (Kanaparthi., 2024) على ان الاستخدام المهم لتقنية Blockchain في المحاسبة المالية هو العقود الذكية. عند استيفاء المتطلبات المحددة مسبقاً، تقوم هذه العقود ذاتية التنفيذ تلقائياً بتنفيذ الشروط و شروط الصفقة. يتم إكمال المعاملات المالية بسرعة وكفاءة أكبر بفضل هذه الطريقة، مما يقلل أيضاً من تكاليف المعاملات ويلغي الحاجة إلى الوسطاء. ويمكن من أتمتة دفع الفواتير وتقارير النفقات وأخذ العينات والتدقيق والامتثال باستخدام العقود الذكية التي تدعم Blockchain ، تسهيل هذه التقنية على المؤسسات التحكم في المعلومات المحاسبية ومراقبتها. وبالتالي سيكون من الصعب إخفاء الاحتيال المالي عند استخدامها مع الذكاء الاصطناعي للكشف عن الحالات الشاذة (Han, et al., 2023).

و تأكيداً على ما سبق ناقش (Roszkowska., 2021) عمليات الاحتيال المحاسبية في الشركات (إنرون مع آرثر أندرسن) و الناجمة عن فشل المدقق في اكتشاف عمليات الاحتيال هذه وناقش كيف تقدم FinTech حلاً فعالاً لمثل هذه المشكلات، حيث يمكن للتنفيذ المشترك لـ Blockchain والعقود الذكية وحلول الذكاء الاصطناعي المتقدمة التغلب على أوجه القصور في إعداد التقارير المالية والتدقيق و ذلك كما يلي : (Roszkowska., 2021)

ا- تزوير السجلات وتبادل المعلومات ، حيث يأتي التحسن الكبير في هذا المجال من تقنية Blockchain التي تجعل جميع المعلومات الموجودة في نظام إعداد

التقارير قد تم التحقق منها مسبقاً بالفعل ومن المستحيل تغييرها أو حذفها. تعمل إنترنت الأشياء والعقود الذكية على أتمتة أنواع مختلفة من الإدخالات (مثل المخزون والتعرف على الإيرادات) وتسجيلها في النظام المحاسبي دون الحاجة إلى تدخل بشري (غالباً ما يكون متحيزاً أو خاطئاً). ويقدمون معاً بيانات صحيحة في الوقت الفعلي ومتاحة للتدقيق المستمر.

ب- توزيع المسؤولية ، حيث تتمتع التقنيات الناشئة بالقدرة على منع المزيد من الانتهاكات في عالم الشركات من خلال نسبة جميع الإجراءات إلى "أصحابها". هنا، تتيح تقنية Blockchain تتبع كل معاملة حتى بدايتها. يمكن استخدام العقود الذكية لبرمجة الإدخالات أو المعاملات وأيضاً لتشفير المسؤول عن كل عملية. ومن ناحية التدقيق، فإن الحلول المستندة إلى تعلم الآلة والشبكات العصبية لديها القدرة على مساعدة المدقق على ربط نتائج التقارير مع منشئها إما لإزالة الخطأ أو الكشف عن السلوك الاحتيالي والإبلاغ عنه.

ج- أولوية إيرادات المدقق على أهداف التدقيق الجوهرية، تؤدي أتمتة الإدخال (إنترنت الأشياء، والعقود الذكية) والتحقق المسبق من المعلومات وثباتها (سلسلة الكتل) إلى تقليل الوقت المخصص لعملية تدقيق عالية الجودة. تعمل الحلول المستندة إلى التعلم الآلي على تعزيز عملية التدقيق من خلال التحديد الفعال للأعلام الحمراء في الأرقام المبلغ عنها والتي لا تتماشى مع المعايير والممارسات المحاسبية. وبهذه الطريقة تصبح الخدمة أرخص وأكثر موضوعية، مما يلغي العديد من الحوافز لضبط نتائج التدقيق بما يتوافق مع توقعات العميل من أجل الحفاظ على الإيرادات.

د- اعتماد المراجع. تجعل تقنية Blockchain وإنترنت الأشياء والعقود الذكية من المستحيل التلاعب بمعظم البيانات المحاسبية من قبل الشركة ويصعب "تغطيتها" بتقرير مدقق حسابات مناسب. يمكن برمجة أدوات التدقيق المستندة إلى التعلم الآلي لتحديد العلامات الحمراء والإبلاغ عنها بشكل موضوعي. إن الحد

الأدنى من نماذج الإفصاح المطبقة أعلى Blockchain يمنح أدونات محددة للنظر في بيانات الشركة: يمكن للمدققين (وليس فقط المتعاقدين والمحاسبين الشرعيين) الحصول على حق الوصول الكامل، في حين يمكن للمجتمع المالي الأوسع أن يكون لديه وصول محدود إلى سجلات الشركة لحمايه ميزتها التنافسية.

3- تعزيز المحاسبة و إعداد التقارير المالية في الوقت الفعلي

اشارت دراسة (Kanaparthi., 2024) الى ان التكامل بين Blockchain والتعلم الآلي يحقق ما يلي :

توفر التقارير المالية في الوقت الفعلي حيث تحقق ميزة مزدوجة: لأنها تشمل تقليل تكاليف المحاسبة المالية مع زيادة الدقة. تعمل تقنية Blockchain على تسهيل جمع البيانات المالية وتحديثها في الوقت الفعلي، في حين تسفر خوارزميات تعلم الآلة المطبقة على هذه البيانات عن نتائج تحليلية يتم نشرها على أصحاب المصلحة المعنيين. حيث لا يقتصر دور إعداد التقارير في الوقت الفعلي على إنقاذ السعي الشاق للحصول على السجلات الفردية، ولكنه يضمن أيضاً الالتزام بالمعايير المحاسبية. مع تثبيت الطوابع الزمنية المضمنة في المعاملات أنها لا تقدر بثمن لتتبع الوثائق والتحقق من صحتها. في جوهرها، تعمل تقنية Blockchain بمثابة دفتر أستاذ غير قابل للفساد، حيث يحتوي على سجل شامل لجميع معاملات الشركات. ويضمن تنفيذه سجلاً دقيقاً للمعاملات، مرتبطاً بشكل فريد بمستخدمي النظام، القضاء بشكل فعال على احتمالات الاحتيال أو الأخطاء الكامنة في تسجيل البيانات المالية يدوياً أو تخزين قاعدة البيانات المركزية.

تعمل أتمتة التحقق من البيانات والتحقق من صحتها من خلال Blockchain على تقليل الأخطاء بشكل كبير مما يعزز دقة التقارير المالية، و غرس الثقة في المؤسسات فيما يتعلق بأمن أصولها من خلال القضاء على الممارسات الاحتيالية، و تركز جهود الباحثين على تطوير تقنية Blockchain والتعلم الآلي لتحسين عمليات التدقيق التنظيمي. حيث يروا إن نظام دفتر الأستاذ الشفاف والقابل للتحقق

والموثوق الذي توفره Blockchain يمكن المدققين بشكل كبير من التأكد من موثوقية البيانات المالية واكتشاف التناقضات المحتملة داخل البيانات المالية. يتطلب تأسيس ضوابط داخلية قوية وجود أدلة لمقارنة البيانات، وفي هذا الجانب، فإن طبيعة Blockchain الثابتة تجعلها جديرة بالثقة بشكل استثنائي. علاوة على ذلك فإن تكامل الذكاء الاصطناعي وتعلم الآلة يتيح أتمتة عمليات محاسبية محددة، وتبسيط العمليات داخل المجال المالي.

كما يمكن لتقنية Blockchain وتعلم الآلة إحداث تحول في ممارسات المحاسبة المالية و تقليل النفقات المحاسبية بشكل فعال وزيادة الدقة، وتمكين إعداد التقارير المالية في الوقت الفعلي، وتسريع عملية التدقيق. من خلال أتمتة مهام المحاسبة المالية المتكررة، يساعد الذكاء الاصطناعي المؤسسات في تجنب النفقات الإضافية المرتبطة بتعيين المزيد من الموظفين للأغراض المحاسبية. ولذلك، يجب بأن تعتمد المؤسسات هذه التقنيات لزيادة كفاءة إطار المحاسبة المالية الخاص بها. (Kanaparathi., 2024)

4- تعزيز التدقيق المستمر المدعوم بالذكاء الاصطناعي على Blockchain

عندما تجمع بين التعلم الآلي وتقنية Blockchain ، فلن تحصل على أقل من ثورة تكنولوجية. من الممكن تصور عالم يتم فيه المحاسبة والتدقيق في الوقت الفعلي، مع إعلام جميع الأطراف ذات الصلة في كل خطوة على الطريق- تدقيق مستمر حقيقي. بدلاً من إجراء عمليات التدقيق على فترات منتظمة، توفر تقنية Blockchain والتعلم الآلي إمكانية إجراء تدقيق مستمر حقيقي. (2018) , (Vetter

و يمكن بسهولة التحقق من سلامة المعاملات التجارية من خلال الجمع بين تقنية Blockchain والذكاء الاصطناعي. وسيقوم الكمبيوتر بمعظم العمل، ولا يترك سوى التحليل النهائي للمدقق. في هذه الحالة، ستكون المسؤولية الرئيسية للمدققين هي قضاء معظم وقتهم في تصميم ومراجعة والتحقق من كيفية تدفق المعلومات بين

الأنظمة. تقلل هذه المواءمة بين التعلم الآلي وتقنية Blockchain من الحاجة إلى إجراء عمليات تدقيق منتظمة على فترات زمنية محددة وتخلق إمكانية إجراء تدقيق مستمر. ومن خلال القيام بذلك، يتم إخطار المدققين أو الإدارة تلقائياً عندما يكتشف النظام مشكلة محتملة. لا يمكن تحقيق هذا النوع من المراقبة المستمرة إلا بمساعدة التعلم الآلي حيث سيكون من المستحيل تقريباً على البشر التحقق بشكل فعال من كل معاملة على أساس مستمر. ومن خلال التدقيق المستمر، يمكن تحديد الاتجاهات والبيانات المفقودة في وقت أبكر بكثير، مما يسمح بمعالجة المشكلات بشكل استباقي، بدلاً من الإبلاغ عنها بشكل تفاعلي. (Fallatah.,2021)

و علاوة على ذلك، تتيح أدوات تعلم الآلة إمكانية نشر تنبيهات تلقائية في الوقت الفعلي تقريباً للأطراف المعنية ذات الصلة بشأن أنشطة الشركة غير العادية. يمكن إخطار السلطات الضريبية على الفور إذا كان هناك حدث تهرب ضريبي، والمستثمرين - إذا كانت الشركة تسيء استخدام مواردها، والبنوك - إذا كانت الشركة تستخدم الأموال المقترضة بشكل لا يتوافق مع اتفاقية القرض. يمكن أن يكون هذا ممكناً من خلال التنفيذ المشترك للتعلم الآلي وتقنية Blockchain في النظام المحاسبي للشركة (Roszkowska., 2021)

ومن منظور نظرية الوكالة ستزيد تقنية Blockchain من صعوبة تلاعب المديرين لبيانات المحاسبة لأنها توفر عقوداً ذكية وتسجيل البيانات بدقة و يتم التحقق من صحة البيانات المسجلة على Blockchain من خلال إجماع متعدد الأطراف. هذا يجعل من الصعب التلاعب بالبيانات و بالإضافة إلى ذلك ، يمكن أتمتة العديد من العمليات. على سبيل المثال ، يعمل دفتر أستاذ Blockchain المشترك في محاسبة الإدخال الثلاثي على أتمتة التسوية. يمكن أتمتة دفع الفواتير وتقارير النفقات وأخذ العينات والتدقيق والامتنال باستخدام العقود الذكية التي تدعم Blockchain ستسهل هذه التقنية على المؤسسات التحكم في المعلومات المحاسبية ومراقبتها. وبالتالي سيكون من الصعب إخفاء الاحتيال المالي عند استخدامه مع الذكاء الاصطناعي للكشف عن الحالات الشاذة. من الناحية النظرية ، يمكن أيضاً اكتشاف التحويلات المالية المشبوهة

في الوقت الفعلي ومع ذلك ، هذا لا يعني أن استخدام Blockchain والذكاء الاصطناعي في المحاسبة يمكن أن يقضي على الاحتيال. يفترض هذا التأكيد على تخفيف مشاكل الوكالة عن طريق الحد من عدم تناسق المعلومات أن الناس لا يتلاعبون بالمصدر أو البيانات الأولية في سلاسل الكتل. تجدر الإشارة إلى أنه لا تزال هناك حوافز للشركات للغش من خلال تزوير بيانات المصدر إذا كانت الفوائد المحتملة كبيرة بما يكفي. إذا حصل المديرون على 51٪ من قوة الحوسبة ، فسيكونون قادرين على معالجة دفتر الأستاذ Blockchain عن طريق إضافة معلومات خاطئة أو حذف / تعديل البيانات التاريخية. (Han, et al., 2023)

5- تعزيز إمكانية الوصول إلى نماذج التعلم الآلي باستخدام Blockchain

باستخدام بنية البيانات اللامركزية لـ Blockchain، يمكن لنماذج التعلم الآلي الوصول إلى البيانات المخزنة على شبكة Blockchain للتنبؤات وتحليل البيانات، ويؤدي تخزين البيانات على Blockchain إلى التخلص من مشكلات مثل القيم المفقودة والتكرارات والضوضاء، والتي تعد مصادر شائعة للأخطاء في نماذج التعلم الآلي ، و تعمل هذه البيانات النظيفة والموثوقة على تعزيز دقة وموثوقية تنبؤات وتحليلات التعلم الآلي ، و يضمن دفتر الأستاذ الموزع لـ Blockchain أن تظل البيانات مقاومة للتلاعب من مرحلة التسجيل إلى التدقيق، وهو أمر بالغ الأهمية لبناء ثقة الجمهور في تقنيات الذكاء الاصطناعي و التعلم الآلي و يتضمن تعزيز الوصول إلى نماذج التعلم الآلي من خلال Blockchain عملية استراتيجية تضمن ما يلي : (Katala.,2023)

1-اختيار منصة Blockchain المناسبة

الخطوة الأولى الحاسمة في تسخير قوة Blockchain لنماذج التعلم الآلي هي اختيار منصة Blockchain مناسبة، يعد هذا القرار بمثابة الأساس للتكامل السلس. ويتضمن تقييم الأنظمة الأساسية المختلفة بناءً على معايير أساسية مثل قابلية التوسع والأمان والتوافق مع سير عمل التعلم الآلي ، ومن خلال استكشاف السمات

المميزة للمنصات الشائعة، يمكنك اتخاذ قرار مستنير يعمل على موازنة التكنولوجيا بشكل فعال.

ب- تطوير العقود الذكية

أحد الجوانب المحورية لهذا التكامل هو تنفيذ العقود الذكية، وهي عقود ذاتية التنفيذ بشروط مشفرة مباشرة في التعليمات البرمجية وتعتبر هذه العقود أساسية في أتمتة وتنفيذ الشروط المتفق عليها، وتعزيز الثقة والشفافية داخل النظام، ولإنشاء نظام قوي وموثوق من الضروري تطوير واختبار ونشر العقود الذكية على منصة Blockchain المختارة.

ج- التدريب النموذجي والتسلسل

قبل أن يتم دمج نماذج التعلم الآلي بسلاسة في Blockchain، يجب أن تخضع لمرحلة تحضيرية حاسمة، والتي تتضمن التدريب على النماذج والتسلسل. تستلزم هذه العملية عدة خطوات رئيسية، مثل إعداد البيانات، والتدريب على النموذج باستخدام الخوارزميات المناسبة، وتحويل النموذج إلى تنسيق مناسب للتحميل على Blockchain، ويضمن التسلسل أن يحافظ النموذج على هيكله ومعلوماته المستفادة مما يجعله قابلاً للنشر والاستخدام بسهولة داخل بيئة ويعمل التسلسل على تحويل نموذج التعلم الآلي المدرب إلى تنسيق يسهل تخزينه أو توصيله أو تحميله لاستخدامه لاحقاً، إن تغليف بنية النموذج ومعلوماته وأوزانه في ملف أو ذاكرة يجعل من الممكن إعادة تحميل النموذج واستخدامه دون تدريب مكرر.

د- تحميل النماذج إلى Blockchain

مع تسلسل نماذج التعلم الآلي، فإن الخطوة الحاسمة التالية هي تحميلها على Blockchain. تتطلب هذه العملية التحقق والتحقق الدقيقين لضمان سلامة النموذج ووظيفته. إن تحميل النماذج إلى Blockchain يوفر لهم بيئة آمنة وشفافة، مما يسهل الطريق لتحسين إمكانية الوصول.

هـ تنفيذ تحديثات النموذج

يتطلب ضمان الدقة والأهمية المستمرة لنماذج التعلم الآلي إجراء تحديثات منتظمة. يعد تنفيذ هذه التحديثات داخل النظام البيئي Blockchain أمراً بالغ الأهمية ويجب تنفيذه بدقة. وهذا يضمن الحفاظ على سلامة النموذج مع إبقاء مجتمع المستخدمين على اطلاع جيد ومشارك.

القسم الرابع: أدلة تطبيقية و ميدانية

تهدف الدراسة الحالية الى تحليل أثر التكامل بين تقنيتي سلاسل الكتل وتعلم الآلة في ممارسات المحاسبة والمراجعة على الحد من ممارسات الاحتيال المحاسبي، ونظراً لأن التقنيات الرقمية الخاصة بسلاسل الكتل وتعلم الآلة حديثة العهد بالبيئة المحاسبية، فانه يمكن للباحثان محاولة الدمج بين البيانات الثانوية والبيانات الأولية في الحصول على مصادر البيانات بغرض تحليل البيانات والوصول الى النتائج.

ففي هذا الشأن، يمكن للباحثان تقسيم الدراسة التطبيقية الى جزئين رئيسيين، يعتمد الجزء الأول على البيانات الثانوية التي يمكن استخراجها من البيانات المحاسبية بالقوائم المالية، بينما يعتمد الجزء الثاني على البيانات الأولية التي تعتمد على قوائم الاستقصاء من مصادرها المختلفة في المنظمات والشركات المختلفة. وذلك على النحو التالي:

1-4: الدراسة الأولى (بيانات ثانوية):

تهدف الدراسة المعتمدة على البيانات الثانوية الى تحليل العلاقة بين تعلم الآلة والاحتيال المحاسبي بالقوائم المالية، حيث ان الاحتيال المحاسبي يعتمد على مجموعة من الممارسات المحاسبية التي تستند الى الفجوات بالخيارات المحاسبية المختلفة بالمعايير المحاسبية. ولذلك، يمكن للباحثان استخدام متنبآت تعلم الآلة في تقدير فجوة الخيارات المحاسبية في اطار تحديد العينة من الشركات المقيدة في سوق الأوراق المالية المصري وبياناتها، وذلك على النحو التالي:

4-1-1: مجتمع وعينة الدراسة:

يمثل مجتمع الدراسة كافة المفردات التي تتوافر فيها خاصية واحدة يمكن إخضاعها للاختبار بغرض اكتشاف العلاقات الرئيسية بين المتغيرات، ولذلك يتمثل مجتمع الدراسة الحالية في كافة الشركات المقيدة في سوق الأوراق المالية المصري، والتي يمكن استخراج البيانات المحاسبية من قوائمها المالية للكشف عن مستوى الاحتيال المحاسبي المتعلق بالتقديرات والخيارات المحاسبية بالمعايير الحالية.

ولغرض تعميم النتائج تتضح أهمية اللجوء الى أساليب المعاينة الاحصائية حيث يتعذر حصر بيانات المجتمع كافة وإخضاعها للاختبارات الاحصائية والتأكد على العلاقة بين متغيرات الدراسة، ونظراً لارتباط الظاهرة محل الدراسة بالبيانات المحاسبية في القوائم المالية والتي تتأثر بالعديد من المحددات الزمانية وقطاعية فانه يمكن للباحثان اللجوء الى استخدام العينة الاتحكمية العمدية التي تخضع الى الشروط التالية:

- أن تكون من الشركات المدرجة في مؤشر التداول المصري EGX100 على اعتبار أن الظاهرة محل الدراسة تتعلق بالاحتيال المحاسبي وهو ما قد يؤثر على صنع القرارات الاستثمارية في سوق الأوراق المالية، ولذلك ستعتمد الدراسة الحالية على اختيار الشركات الأكثر تداولاً لضمان عدم تحيز العينة نحو الشركات المحتملة.
- استبعاد الشركات العاملة في مجال البنوك والخدمات المالية غير المصرفية باعتبارها شركات ومؤسسات لها طبيعة خاصة تختلف في التشغيل عن بقية الشركات العاملة في سوق الأوراق المالية المصري.
- أن تكون الفترة الزمنية للدراسة الحالية من الفترة الزمنية 2017 الى 2022 باعتبار أن هذه السلسلة الزمنية هي أكثر الفترات استقراراً في سوق الأوراق المالية المصري لاستبعاد أثر التقلبات الاقتصادية العنيفة على مخرجات القوائم المالية.

واستناداً الى الشروط السابقة، وباجراء التحليل اليدوي تبين للباحثان وجود 76 شركة تتوافق مع الشروط الواردة أعلاه لتسجل 456 مشاهدة (76 شركة $\times$ 6 سنوات)، وباستبعاد 42 مشاهدة ذات قيم مفقودة، وعدد 33 مشاهدة ذات قيم شاذة ومتطرفة تصبح العينة النهائية للدراسة 381 مشاهدة. ويمكن للباحثان تلخيص اجراءات اختيار العينة من خلال الجدول التالي:

جدول رقم (1-4): اجراءات تحديد عينة الدراسة

الاجراء	عدد الشركات	عدد المشاهدات
العينة الأولية للدراسة	100	600
(-) البنوك والشركات المالية غير المصرفية	24	144
(-) مشاهدات ذات قيم مفقودة	--	42
(-) مشاهدات ذات قيم شاذة ومتطرفة	--	33
صافي العينة	76	381

وفيما يتعلق بتوزيع عينة الدراسة على قطاعات وسنوات الدراسة المختلفة فإنه يمكن للباحثان عرض تلك المشاهدات من خلال الجدول التالي:

جدول رقم (2-4): توزيع عينة الدراسة من البيانات الثانوية

2022	2021	2020	2019	2018	2017	الشركات	القطاع
3	3	3	2	2	3	3	اتصالات واعلام وتكنولوجيا المعلومات
11	10	9	7	8	8	11	أغذية ومشروبات وتبغ
2	2	2	2	2	2	2	خدمات النقل والشحن
1	1	1	1	1	1	1	خدمات تعليمية
9	5	6	5	6	6	9	خدمات ومنتجات صناعية وسيارات
6	6	5	5	5	5	6	رعاية صحية وأدوية
4	4	4	3	3	3	4	سياحة وترفيه
4	4	4	4	4	4	4	طاقة وخدمات مساندة
17	17	20	18	16	15	20	عقارات
2	2	2	1	1	2	2	مقاولات وإنشاءات هندسية
3	3	2	2	2	3	3	مواد البناء
11	10	9	7	7	8	11	موارد أساسية
73	67	67	57	57	60	76	الاجمالي

4-1-2: قياس متغيرات الدراسة وتحديد معلمات التنبؤ:

ترتبط الدراسة المتعلقة بالبيانات الثانوية بتحليل العلاقة بين تعلم الآلة وممارسات الاحتيال المحاسبي في القوائم المالية، ولذلك سيتم قياس أثر تعلم الآلة على ممارسات الاحتيال المحاسبي من خلال التعرف على مستوى تحسن القدرة التنبؤية بالاحتيال المحاسبي من خلال تحليل الفروق الجوهرية بين نتائج الاحتيال المحاسبي باستخدام تعلم الآلة ونتائج الاحتيال المحاسبي باستخدام الأساليب الإحصائية التقليدية، ومن ثم يمكن تحديد متغيرات الدراسة الحالية على الوضع التالي:

أولاً: المتغير المستقل للدراسة (تعلم الآلة):

في هذا السياق، باعتبار تعلم الآلة هو المتغير المستقل للدراسة فإن عملية القياس ستختلف عما هو متعارف عليه في الدراسات التطبيقية المختلفة في مجال المحاسبة والمراجعة، حيث أنه سيتم الاعتماد على التقنيات الرقمية وتغذيتها بالبيانات المحاسبية المختلفة بالقوائم المالية لغرض التنبؤ بمستوى الاحتيال المحاسبي بالقوائم المالية.

ولذلك تسمى هذه البيانات المحاسبية التي يتم تغذيتها على التقنيات الرقمية بمعلمات القرار أو معلمات التنبؤ، وتعبر عن كافة المتغيرات التي يمكن استخدامها للتنبؤ بمستوى الاحتيال المحاسبي في القوائم المالية لعينة الدراسة، ومن ثم فإنه يمكن للباحثان بناء متنبآت تعلم الآلة للإحتيال المحاسبي كما بالجدول رقم (4-3) التالي:

جدول رقم (4-3): متنبآت تعلم الآلة للاحتيال المحاسبي

المتنبأ	الرمز	التفسير
التغير الجوهري في نسب النقدية	X1	مؤشر وهمي يأخذ القيمة 1 في حالة التغير في نسبة النقدية أكبر من 20%.
مؤشر التكلفة البيعية والعمومية	X2	نسبة التغير التكلفة البيعية والعمومية والإدارية إلى الإيرادات، حيث أن عدم ثبات النسبة بين السنوات دليل على التلاعب بالسياسات المحاسبية.
مؤشر تكلفة البضاعة المباعة	X3	نسبة التغير تكلفة البضاعة المباعة إلى الإيرادات، حيث أن عدم ثبات النسبة بين السنوات دليل على التلاعب بالسياسات المحاسبية.
فجوة الاستحقاقات المحاسبية	X4	وهي قيمة الاستحقاقات المحاسبية للفرق بين إجمالي الإيرادات وصافي التدفقات النقدية من الأنشطة التشغيلية.
التغيير في قيم الاهلاك	X5	مؤشر وهمي يأخذ القيمة 1 في حالة التغير في نسبة قيم الاهلاك أكبر من 20%.
التغير في السياسات المحاسبية	X6	مؤشر وهمي يأخذ القيمة 1 في حالة وجود تغيير في السياسات المحاسبية والقيمة صفر فيما عدا ذلك.
رأي المراجع الخارجي	X7	مؤشر وهمي يأخذ القيمة 1 في حالة وجود رأي مراجع خارجي بخلاف الرأي النظيف والقيمة صفر فيما عدا ذلك.
نسبة مصروفات البحث والتطوير	X8	مؤشر وهمي يأخذ القيمة 1 في حالة توافق نسبة ما تم رسملته من مصروفات للبحث والتطوير إلى إجمالي مصروفات البحث والتطوير في نفس السنة مع الشروط المحددة بالمعايير والقيمة صفر فيما عدا ذلك.

ثانياً: المتغير التابع للدراسة (الاحتيال المحاسبي):

يعبر الاحتيال المحاسبي عن قدرة الشركة على استغلال أصولها المختلفة وما بها من موارد في تضليل وخداع المستخدم الخارجي للقوائم المالية بنتائج الأعمال، ولذلك تكون أكثر الأمور استخداماً في هذا الصدد أحد طريقتين: أولهما يعتمد على استخدام فجوة الخيارات المحاسبية بشكل عام ولا سيما تلك التي تعبر عن الفجة بين التدفقات النقدية التشغيلية والأرباح المحاسبية المحققة بقائمة الدخل. أما الثانية فتتعلق بإدارة الأرباح الحقيقية والتي تتعلق بالتلاعب في تقديرات قيم التكلفة للبضاعة المباعة

وما يترتب عليها من قيم المخزون بغرض تعظيم نواتج الأعمال بشكل عام. وبالتالي، يمكن للباحثان تقسيم أدوات قياس المتغير التابع على النحو التالي:

- الاحتيايل المحاسبي من خلال فجوة الاستحقاقات:

يتمثل المتغير التابع بالدراسة الحالية في الاحتيايل المحاسبي والذي يتمثل في فجوة الخيارات المحاسبية، ولغرض قياس فجوة الخيارات المحاسبية يمكن للباحثان الاعتماد على قيمة الاستحقاقات المحاسبية في القوائم المالية من خلال الفرق بين صافي الربح المحاسبي المحقق بقائمة الدخل وصافي التدفقات النقدية التشغيلية بقائمة التدفقات النقدية.

- الاحتيايل المحاسبي من خلال الادارة الحقيقية للأرباح:

تركز على الجانب الخاص بحساب مجمل الربح ولا سيما استغلال السياسات الادارية المختلفة التي تسهم في زيادة حجم تكلفة البضاعة المباعة مما يؤدي الى انخفاض مستوى مجمل الربح المحقق مثل انخفاض حجم مستويات المخزون مما يؤدي الى زيادة التكلفة الثابتة المحملة على المنتجات فتتخفض الأرباح، بالإضافة الى ذلك امكانية التلاعب بالمصروفات البيعية والعمومية والادارية مما يسهم أيضاً في تدنية صافي الربح. ويمكن التعبير عن مستوى الادارة الحقيقية للأرباح من خلال الفرق بين الأرباح الجوهرية المتوقعة والأرباح الجوهرية غير المتوقعة (الأرباح الجوهرية الفعلية – الأرباح الجوهرية المتنبأ بها) ويمكن تمثيل هذا الفرق من خلال النموذجين التاليين (Zang, 2012):

$$\text{PRODt/At-1} = \beta_0 + \beta_1 (1/\text{At-1}) + \beta_2 (\text{St/At-1}) + \beta_3 (\Delta\text{St/At-1}) + \beta_3 (\Delta\text{St-1/At-1}) + \varepsilon \dots \dots \dots (1)$$

$$\text{DISXt/At-1} = \beta_0 + \beta_1 (1/\text{At-1}) + \beta_2 (\text{St-1/At-1}) + \varepsilon \dots \dots \dots (2)$$

حيث أن:

$PROD_t$ = مجموع تكلفة البضاعة المباعة للسنة t والتغير في المخزون من السنة- t
1 إلى السنة- t ؛

$DISX_t$ = المصروفات الاختيارية (مجموع مصروفات البحوث والتطوير والدعاية
والمصروفات البيعية والعمومية والإدارية)؛

A_{t-1} = إجمالي الأصول للسنة- $t-1$ ؛

S_t = صافي المبيعات في السنة- t ؛

ΔS_t = التغير في صافي المبيعات من السنة- $t-1$ إلى السنة- t .

على أن يكون مجموع بواقي النموذج الأول الثاني هي قيمة الإدارة الحقيقية
للأرباح والتي استغلتها الإدارة لتحقيق الاحتيال المحاسبي على المستخدم الخارجي
للقوائم المالية.

4-3-1: نتائج تشغيل تقنيات تعلم الآلة للتنبؤ بالاحتيال المحاسبي:

استقرت العديد من الدراسات المحاسبية على أن أهم تقنيات تعلم الآلة الجاري
استخدامها في مجال المحاسبة والمراجعة تتمثل في: استخدام تقنية تعلم الآلة الإشرافي
(SVM)، وأسلوب شجرة القرارات (Decision Tree)، والشبكات
العصبية (Neural Network)، وأسلوب الشبكة البيزية (Bayesian Network)،
وتقنية الجار الأقرب (K-Nearest Neighbour).

وفي هذا الشأن، سيقوم الباحثان بتحليل نتائج استخدام تعلم الآلة على ثلاثة مراحل
متتالية، تتمثل الأولى منها في اختبارات تحليل المكونات الأساسية للمؤشرات والمعلومات
المختلفة للتنبؤ، ثانياً تحليل نتائج دقة وصلاحية نماذج تعلم الآلة في متنبات الدراسة الحالية،
ثالثاً دراسة نتائج مصفوفة مؤشرات التعارض، وذلك على النحو التالي:

- نتائج تحليل المكونات الأساسية:

يهدف هذا الجزء من اجزاء تحليل المكونات الأساسية الذي يهدف الى تقسيم
البيانات الى مجموعات كل مجموعة منها تختص بخاصية معينة، وتستند جودة تقسيم

البيانات الى مجموعات فرعية على الخصائص التي تم تحديدها في مجموعة البيانات، حيث يعد تحليل المكونات الرئيسية طريقة احصائية متعارف عليها تهدف الى اختزال العوامل بين المجموعات المختلفة على أن تكون كل مجموعة مستقلة في حد ذاتها تشكل نموذج يمكن من خلاله التنبؤ. وبتشغيل طريقة المكونات الأساسية للوصول الى المجموعات الفرعية لنماذج التنبؤ تم التوصل الى مصفوفة العوامل المدورة التالية في الجدول رقم (4-4) التالي:

جدول رقم (4-4): معاملات التحميل بمكونات التحليل الأساسي لمصفوفة العوامل المدورة

Variables	PC1	PC2	PC3	PC4	PC5
X1	0.037	0.101	0.070	0.084	0.535
X2	0.056	0.096	0.585	0.607	0.062
X3	0.551	0.100	0.067	0.039	0.088
X4	0.052	0.597	0.596	0.039	0.090
X5	0.546	0.032	0.087	0.566	0.037
X6	0.104	0.047	0.542	0.051	0.113
X7	0.033	0.586	0.054	0.076	0.592
X8	0.528	0.106	0.596	0.032	0.035
Eigenvalue	2.898	2.522	2.216	1.987	1.114
Variance explained (%)	0.165	0.155	0.145	0.141	0.132
Cum. variance explained (%)	0.165	0.320	0.465	0.606	0.738

يتضح من النتائج المبينة بالجدول السابق أن النموذج الحالي للدراسة انقسم الى خمسة نماذج فرعية من PC1 الى PC5 وكل نموذج من هذه النماذج يضم مجموعة من المتغيرات الرئيسية التي تؤثر على مستوى الاحتيال المحاسبي فمثلاً المكون PC1 يحتوى على المتغيرات X8 & X5 & X3 بينما يحتوى المكون PC2 على المتغيرات X7 & X4 وهكذا.....

- نتائج الدقة وصلاحية نماذج تعلم الآلة:

يهدف الباحثان في هذه الخطوة الى تشغيل نماذج تعلم الآلة بغرض التنبؤ بقيم الاحتيال المحاسبي وفقاً لفجوة الاستحقاقات والادارة الحقيقية للأرباح ولغرض التحقق من أن القيم التي تم التنبؤ بها دقيقة وتتسم بصلاحية المقارنة مع النتائج التقليدية للنماذج أصبح من الأهمية بمكان استخراج مستوى الجودة والدقة لتلك النماذج بعد التشغيل، وذلك من خلال الجدول رقم (5-4) التالي:

جدول رقم (5-4): نتائج دقة وصلاحية نماذج تشغيل تعلم الآلة

Models Accuracy							
Model	Dependent Variable	Training Dataset	Validation Dataset	Test Dataset	Average	Type I Error	Type II Error
Support Vector Machine (SVM)	Accounting Fraud	97.80%	88.30%	87.90%	91.33%	2.20%	2.46%
Decision Tree (DT)		97.90%	88.50%	88.70%	91.70%	2.10%	2.35%
Neural Networks (NN)		92.90%	90.60%	89.50%	91.00%	7.10%	7.95%
Bayesian Network (BN)		93.80%	90.70%	88.60%	91.03%	6.20%	6.94%
K-Nearest Neighbour (KNN)		93.20%	89.20%	88.70%	90.37%	6.80%	7.62%

يتضح لدى الباحثان من خلال النتائج المبينة بالجدول السابق أن مستوى معدلات الدقة لكلٍ من Training Dataset، Validation Dataset تبلغ 97.8%، 88.3% على التوالي في إطار استخدام نظام تعلم الآلة الإشرافي، أما بالنسبة لنتائج الدقة للبيانات التي تم اختبارها فتبلغ 87.90%، وبالتالي فإن النموذج يصبح مستقراً للتنبؤ بمستويات الاحتيال المحاسبي. وفيما يتعلق بالخطأ فكان الخطأ من النوع الأول يبلغ 2.20%، ومن النوع الثاني 2.46% (حيث يشير الخطأ من النوع الأول الى احتمالية وجود احتيال محاسبي مصنف تحت فجوة الاستحقاقات إلا أنه ينبغي تصنيفه تحت ادارة الأرباح الحقيقية، بينما يشير الخطأ من النوع الثاني الى احتمالية وجود احتيال محاسبي مصنف تحت ادارة الأرباح الحقيقية إلا أنه ينبغي تصنيفه تحت فجوة الاستحقاقات).

وفيما يتعلق بمقاييس جودة استخدام شجرة القرارات فقد تبين أن معدلات الدقة لكلٍ من Training Dataset، Validation Dataset تبلغ 97.9%، 88.5% على التوالي، أما بالنسبة لنتائج الدقة للبيانات التي تم اختبارها فتبلغ 87.70%، وبالتالي فإن النموذج يصبح مستقراً للتنبؤ بمستويات الاحتيال المحاسبي. وفيما يتعلق بالخطأ فكان الخطأ من النوع الأول يبلغ 2.10%، ومن النوع الثاني 2.35% (حيث يشير الخطأ من النوع الأول الى احتمالية وجود احتيال محاسبي مصنف تحت فجوة الاستحقاقات إلا أنه ينبغي تصنيفه تحت ادارة الأرباح الحقيقية، بينما يشير الخطأ من النوع الثاني الى احتمالية وجود احتيال محاسبي مصنف تحت ادارة الأرباح الحقيقية إلا أنه ينبغي تصنيفه تحت فجوة الاستحقاقات).

وبالنسبة لمقاييس جودة استخدام الشبكات العصبية فقد تبين أن معدلات الدقة لكلٍ من Training Dataset، Validation Dataset تبلغ 92.9%، 90.6% على التوالي، أما بالنسبة لنتائج الدقة للبيانات التي تم اختبارها فتبلغ 89.50%، وبالتالي فإن النموذج يصبح مستقراً للتنبؤ بمستويات الاحتيال المحاسبي. وفيما يتعلق بالخطأ فكان الخطأ من النوع الأول يبلغ 7.10%، ومن النوع الثاني 7.95% (حيث يشير الخطأ من النوع الأول الى احتمالية وجود احتيال محاسبي مصنف تحت فجوة

الاستحقاقات إلا أنه ينبغي تصنيفه تحت ادارة الأرباح الحقيقية، بينما يشير الخطأ من النوع الثاني الى احتمالية وجود احتيال محاسبي مصنف تحت ادارة الأرباح الحقيقية إلا أنه ينبغي تصنيفه تحت فجوة الاستحقاقات).

وبالنسبة لمقاييس جودة استخدام الشبكات البيزية فقد تبين أن معدلات الدقة لكل من Training Dataset، Validation Dataset تبلغ 93.8%، 90.7% على التوالي، أما بالنسبة لنتائج الدقة للبيانات التي تم اختبارها فتبلغ 88.60%، وبالتالي فإن النموذج يصبح مستقراً للتنبؤ بمستويات الاحتيال المحاسبي. وفيما يتعلق بالخطأ فكان الخطأ من النوع الأول يبلغ 6.20%، ومن النوع الثاني 6.94% (حيث يشير الخطأ من النوع الأول الى احتمالية وجود احتيال محاسبي مصنف تحت فجوة الاستحقاقات إلا أنه ينبغي تصنيفه تحت ادارة الأرباح الحقيقية، بينما يشير الخطأ من النوع الثاني الى احتمالية وجود احتيال محاسبي مصنف تحت ادارة الأرباح الحقيقية إلا أنه ينبغي تصنيفه تحت فجوة الاستحقاقات).

وبالنسبة لمقاييس جودة استخدام تقنية الجار الأقرب فقد تبين أن معدلات الدقة لكل من Training Dataset، Validation Dataset تبلغ 93.2%، 89.20% على التوالي، أما بالنسبة لنتائج الدقة للبيانات التي تم اختبارها فتبلغ 88.70%، وبالتالي فإن النموذج يصبح مستقراً للتنبؤ بمستويات الاحتيال المحاسبي. وفيما يتعلق بالخطأ فكان الخطأ من النوع الأول يبلغ 6.80%، ومن النوع الثاني 7.62% (حيث يشير الخطأ من النوع الأول الى احتمالية وجود احتيال محاسبي مصنف تحت فجوة الاستحقاقات إلا أنه ينبغي تصنيفه تحت ادارة الأرباح الحقيقية، بينما يشير الخطأ من النوع الثاني الى احتمالية وجود احتيال محاسبي مصنف تحت ادارة الأرباح الحقيقية إلا أنه ينبغي تصنيفه تحت فجوة الاستحقاقات).

- نتائج مؤشرات مصفوفة عدم التوافق:

تشير مصفوفة عدم التوافق الى مدى التطابق بين ما تم توقعه وكانت نتائجه صحيحة، وبين ما تم توقعه وتبين أن نتائجه خاطئة. وفي هذا الشأن، قد تم اعداد مصفوفة عدم التوافق لكافة الأساليب الخمسة من أساليب تعلم الآلة للتحقق من مستوى التوافق أو عدم التوافق بين التوقعات والنتائج الفعلية، وقد أسفرت نتائج التحليل الاحصائي عن الجدول رقم (4-6) التالي:

جدول رقم (4-6): نتائج مؤشرات مصفوفة عدم التوافق

Confusion Matrix Indicators							
Model	Dependent Variable	Accuracy	Precision	Sensitivity (Recall)	Specificity	F1 Score	Training Time
Support Vector Machine (SVM)	Accounting Fraud	90.90%	87.00%	86.90%	94.20%	86.95%	500 μ s
Decision Tree (DT)		91.10%	85.50%	86.90%	94.20%	86.19%	500 μ s
Neural Networks (NN)		92.50%	84.90%	86.40%	94.20%	85.64%	500 μ s
Bayesian Network (BN)		91.10%	87.40%	86.10%	94.20%	86.75%	500 μ s
K-Nearest Neighbour (KNN)		92.00%	86.20%	85.70%	96.18%	85.95%	500 μ s

أوضحت النتائج المبينة بالجدول السابق، أن مؤشرات التوافق لنموذج تعلم الآلة الاشرافي المتمثلة في: (Accuracy=90.90%, Precision=87%, Sensitivity(Recall)=86.90%, Specificity = 94.20% & F1 Score = 86.95%)، وهو ما يشير الى ارتفاع مستوى التوافق بالنموذج وانخفاض مستوى

التعارض بين النتائج المتوقعة والنتائج الفعلية، وهو ما يشير الى ارتفاع مستوى الاعتمادية بنتائج التنبؤ المستخرجة من النموذج.

وفيما يتعلق بنتائج شجرة القرارات المتمثلة في: (Accuracy = 91.10%, Precision=85.5%, Sensitivity(Recall)=86.90%, Specificity=94.20% & F1 Score = 86.19%)، وهو ما يشير الى ارتفاع مستوى التوافق بالنموذج وانخفاض مستوى التعارض بين النتائج المتوقعة والنتائج الفعلية، وهو ما يشير الى ارتفاع مستوى الاعتمادية بنتائج التنبؤ المستخرجة من النموذج.

وبالنسبة لنتائج الشبكات العصبية المتمثلة في: (Accuracy = 92.50%, Precision=84.9%, Sensitivity(Recall)=86.40%, Specificity=94.20% & F1 Score = 85.64%)، وهو ما يشير الى ارتفاع مستوى التوافق بالنموذج وانخفاض مستوى التعارض بين النتائج المتوقعة والنتائج الفعلية، وهو ما يشير الى ارتفاع مستوى الاعتمادية بنتائج التنبؤ المستخرجة من النموذج.

وبالنسبة لنتائج الشبكات البيزية المتمثلة في: (Accuracy = 91.10%, Precision=87.4%, Sensitivity(Recall)=86.10%, Specificity=94.20% & F1 Score = 86.75%)، وهو ما يشير الى ارتفاع مستوى التوافق بالنموذج وانخفاض مستوى التعارض بين النتائج المتوقعة والنتائج الفعلية، وهو ما يشير الى ارتفاع مستوى الاعتمادية بنتائج التنبؤ المستخرجة من النموذج.

وأخيراً توضح نتائج تقنية الجار الأقرب المتمثلة في: (Accuracy = 92.00%, Precision=86.2%, Sensitivity(Recall)=85.70%, Specificity=96.18% & F1 Score = 85.95%)، وهو ما يشير الى ارتفاع مستوى التوافق بالنموذج وانخفاض مستوى التعارض بين النتائج المتوقعة والنتائج الفعلية، وهو ما يشير الى ارتفاع مستوى الاعتمادية بنتائج التنبؤ المستخرجة من النموذج.

4-1-4: نتائج تشغيل الأساليب الإحصائية التقليدية في التنبؤ:

يهدف الباحثان في هذا الجزء من الدراسة الى استخدام الأساليب التقليدية للتنبؤ بمستوى الاحتيال المحاسبي من خلال تشغيل نماذج الانحدار المتعدد للإدارة الحقيقية للأرباح للتنبؤ بالبوافي واعتبارها مستوى الاحتيال المحاسبي في القوائم المالية، وسيتم تشغيل النموذج والحصول منهما على تنبؤات بمستوى الاحتيال المحاسبي توازي التنبؤات المستخرجة من أساليب تعلم الآلة، حتى يمكن مقارنتها بمستويات الاحتيال المحاسبي المستخرجة من نماذج تعلم الآلة السابق عرضها وقد أسفرت نتائج التحليل الإحصائي عن النتائج التالية:

جدول رقم (7-4): نتائج تحليل الانحدار المتعدد للتنبؤ بمستوى الاحتيال المحاسبي

Panel (A)				Panel (B)		
Variables	β	T-Stat.	P-Value	β	T-Stat.	P-Value
Cons.	0.055	1.206	0.115	0.063	1.179	0.095
(1/At-1)	0.137	2.636	0.035	0.168	2.293	0.034
(St/At-1)	0.173	2.192	0.028	0.182	2.548	0.035
(Δ St/At-1)	0.103	3.177	0.038	0.166	2.170	0.028
(Δ St-1/At-1)	0.191	3.035	0.030	0.084	2.910	0.014
N	381			381		
F-Value	15.381***			17.921***		
Adj. R2	53.40%			59.30%		

يتبين للباحثان من خلال النتائج المبينة بالجدول السابق ارتفاع القوة التفسيرية للنموذجين حيث تبلغ 53.4%، 59.30% على التوالي، لكل من المصروفات الانتاجية والمصروفات الاختيارية على التوالي، كما يتضح من الجدول ارتفاع قيم F ومعنويتها حيث تبلغ 15.381، 17.921 على التوالي. بالإضافة الى ذلك يتبين معنوية كاة المتغيرات المستقلة المدرجة بنموذج التنبؤ بمستوى الاحتيال المحاسبي، وهو ما يشير الى ارتفاع القدرة التنبؤية للنموذج بمستوى الاحتيال المحاسبي.

4-5: نتائج اختبارات الفروق الجوهرية لتحليل أثر تعلم الآلة على الاحتيال المحاسبي:

يهدف الباحثان في هذه الخطوة الى اتباع أسلوب المقارنات الاحصائية للتنبؤ بمستوى الفروق الجوهرية بين مستوى الاحتيال المحاسبي الذي تم التنبؤ به، ومستوى الاحتيال المحاسبي الفعلي المستخرج من البيانات المحاسبية الموجودة بالقوائم المالية والمستندة الى النماذج التقليدية للانحدار، وقد أسفرت نتائج التحليل الاحصائي عن الجدول رقم (4-8) التالي:

جدول رقم (4-8): نتائج اختبارات الفروق الجوهرية للتنبؤ بمستوى الاحتيال المحاسبي

	Variables	Mean	T	Sig. (2-tailed)
Pair (1)	Predicted Accounting Fraud by Support Vector Machine (SVM)	0.644	4.569	0.000
	Actual Accounting Fraud by regression	0.203		
Pair (1)	Predicted Accounting Fraud by Decision Tree (DT)	0.592	4.095	0.000
	Actual Accounting Fraud by regression	0.184		
Pair (1)	Predicted Accounting Fraud by Neural Networks (NN)	0.601	4.312	0.000
	Actual Accounting Fraud by regression	0.152		
Pair (1)	Predicted Accounting Fraud by Bayesian Network (BN)	0.625	4.515	0.000
	Actual Accounting Fraud by regression	0.163		
Pair (1)	Predicted Accounting Fraud by K-Nearest Neighbour	0.656	4.957	0.000
	Actual Accounting Fraud by regression	0.182		

يتنبأ الفرض الاحصائي الرئيسي للدراسة التطبيقية المستندة الى البيانات الثانوية بأثر استخدام تقنيات تعلم الآلة على مستوى الاحتيال المحاسبي ويتبين من نتائج الجدول السابق وجود فروق جوهرية ومعنوية بين مستوى الاحتيال المحاسبي وفقاً لأساليب تعلم الآلة ومستوى الاحتيال المحاسبي باستخدام النماذج التقليدية، حيث تبين أن قيمة T تبلغ 4.569، 4.095، 4.312، 4.515، 4.957 على التوالي لكلٍ من نظم تعلم الآلة الاشرافي، وشجرة القرارات، والشبكات العصبية، والشبكات البيزية، وتقنية الجار الأقرب على التوالي، وجميعها معنوية وموجبة لصالح تقنيات التعلم

الآلي، وهو ما يشير الى تحقق جودة تقنيات تعلم الآلة في التنبؤ بمستوى الاحتيال المحاسبي عن النماذج التقليدية المتمثلة في الانحدار، وتأسيساً على ذلك يمكن للباحثان استنتاج أن تقنيات تعلم الآلة لها تأثير معنوي ايجابي على تحسين عملية التنبؤ بمستوى الاحتيال المحاسبي لصالح المستخدم الخارجي للقوائم المالية. وبالتالي، يمكن للباحثان قبول الفرض الاحصائي الأول للدراسة على الشكل البديل التالي: يوجد تأثير طردي معنوي لتقنيات تعلم الآلة على التنبؤ بمستوى الاحتيال المحاسبي.

4-2: الدراسة الثانية (بيانات أولية):

تهدف الدراسة المعتمدة على البيانات الأولية الى تحليل أثر العلاقة التكاملية بين سلاسل الكتل وتقنيات تعلم الآلة على الاحتيال المحاسبي من خلال البيانات الأولية، حيث لم يكن باستطاعة الباحثان الحصول على بيانات تلك المتغيرات من القوائم المالية المنشورة للشركات المدرجة في سوق الأوراق المالية المصري، وذلك على النحو التالي:

4-2-1: مجتمع وعينة الدراسة:

يتمثل مجتمع الدراسة الميدانية في كافة الأفراد العاملين بمجال المحاسبة والمراجعة في الشركات المدرجة في سوق الأوراق المالية المصري فضلاً عن الأكاديمين والمستثمرين من الأطراف الخارجية ذوي المصلحة والأكثر ارتباطاً بمتغيرات الدراسة وعددهم يتجاوز 10,000 مفردة فضلاً عن انتشارهم الجغرافي بين المحافظات المختلفة لجمهورية مصر العربية، وتأسيساً على ذلك يصبح الحد الأدنى لعينة الدراسة عند مستوى معنوية 5% باستخدام محدد حجم العينة Sample Size Calculator هو 384 مفردة.

وتأسيساً على ذلك، قام الباحثان باعداد استبيان ورفعته على رابط جوجل فورم Google Form ونشره على كافة المواقع ذات الصلة والتواصل مع المبحوثين، وذلك بما يطابق الشروط المطبقة لدراسة (Saunders, et al., 2009).

حيث أنه لتطبيق الاستقصاء عبر الإنترنت لابد أن تكون مفردات مجتمع البحث قادرة على التعامل مع الإنترنت، ويجب أن تكون الاسئلة الخاصة بالاستقصاء مغلقة وقصيرة قدر الإمكان، كما أنه من الأفضل نشر الاستقصاء عبر الإنترنت من أسبوعين إلى ستة أسابيع، حيث تم وضع الاستبيان من 2024/04/01 الى 2024/04/30 وكانت الاستجابة بواقع 395 قائمة صالحة للتحليل.
4-2-2: مقاييس متغيرات الدراسة:

اعتمد الباحثان على قائمة استقصاء مصممة لغرض جمع البيانات من عينة الدراسة على أن يتم تصميم قائمة الاستقصاء من قسمين رئيسيين يتمثلان في:

- **القسم الأول من قائمة الاستقصاء:** ويهدف الى التأكد من قيام المستقضي منهم بابداء الرأي بشأن أبعاد البحث، وذلك من خلال التعرف على رأي العاملين بمجال المحاسبة والمراجعة الأكاديميين ذوي الصلة بمتغيرات من خلال وضع 12 عبارة لقياس مستوى الموافقة على دور سلاسل الكتل في كشف الاحتيال لمحاسبي، و13 عبارة لقياس دور تقنية التعلم الآلي في الكشف عن والتقرير عن الاحتيال المحاسبي، و8 عبارات لقياس امكانية التكامل بين سلاسل الكتل وتقنية تعلم الآلة، وأخيراً 11 عبارة لقياس دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي.
- **القسم الثاني من قائمة الاستقصاء:** ويتعلق بسؤال عينة الدراسة عن بعض المتغيرات الديموغرافية مثل (الوظيفة والخبرة والمستوى التعليمي).

4-2-3: نتائج اختبارات الصدق والثبات:

ويستخدم هذا الاختبار لمعرفة مدى إمكانية الاعتماد على قائمة الاستقصاء في جمع بيانات تتسم بالثبات، ويقصد به إمكانية الحصول على نفس البيانات عند إعادة الدراسة في نفس الظروف باستخدام نفس الأداة ونفس الأفراد (Adams, et al.,

(2007). ومعامل الثبات ألفا كرونباخ هي الطريقة التي استخدمها الباحثان لحساب ثبات المقاييس وذلك باستخدام برنامج SPSS (V. 26) ، وفي معظم الحالات يمكن اعتبار ألفا كرونباخ مؤشراً ملائماً وممتازاً لقياس ثبات المقياس ويعتبر من المعاملات التي من خلالها يمكن قياس مدى ثبات المقياس من خلال الاتساق الداخلي، حيث يرى (Hair, et al. (2014 أن قيم ألفا المقبولة هي التي تتراوح من 0.6 الى 0.7 في حين أن القيم أكبر من 0.7 تشير إلى درجة عالية من الاعتمادية على المقاييس المستخدمة. بينما يستخدم اختبار الصدق الذاتي لبيان مدى صدق عبارات قائمة الاستقصاء في قياس ما صُممت من أجله وهو الجذر التربيعي لقيمة معامل ألفا، والتأكيد على أن عبارات القائمة تعطي للمستقصي منه نفس المعنى والمفهوم الذي يقصده الباحث (Adams, et al., 2007). وبالتالي، قام الباحثان باختبار الصدق والثبات لقائمة الاستقصاء باستخدام عينة الدراسة المكونة من 395 مفردة، وأظهرت نتائج التحليل الجدول التالي رقم (4-9):

جدول رقم (4-9): نتائج قيم معاملات الثبات والصدق الذاتي للاستبيان

المتغير	عدد العبارات	معامل ألفا كرونباخ	معامل الصدق
دور سلاسل الكتل في كشف الاحتيال المحاسبي	12	0.841	0.917
دور تقنية التعلم الآلي في الكشف عن والتقرير عن الاحتيال المحاسبي	13	0.891	0.944
التكامل بين سلاسل الكتل وتقنية تعلم الآلة	8	0.788	0.888
دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي	11	0.851	0.922
اجمالي القائمة	44	0.848	0.921

المصدر: من إعداد الباحثان من نتائج التحليل الإحصائي لبرنامج SPSS

ويتضح من الجدول رقم (4-9) ما يلي:

- فيما يخص مقياس دور سلاسل الكتل في كشف الاحتيال المحاسبي فقد تخطت قيم معامل ألفا كرونباخ للمحور 0.60. وهي القيمة الأدنى لقبول واعتماد ثبات المقياس، حيث كانت قيمة معامل ألفا كرونباخ للمحور 0.841.
- فيما يخص مقياس دور تقنية التعلم الآلي في الكشف عن والتقرير عن الاحتيال المحاسبي فقد تخطت قيم معامل ألفا كرونباخ للمحور 0.60. وهي القيمة الأدنى لقبول واعتماد ثبات المقياس، حيث كانت قيمة معامل ألفا كرونباخ للمحور 0.891.
- فيما يخص مقياس التكامل بين سلاسل الكتل وتقنية تعلم الآلة فقد تخطت قيم معامل ألفا كرونباخ للمحور 0.60. وهي القيمة الأدنى لقبول واعتماد ثبات المقياس، حيث كانت قيمة معامل ألفا كرونباخ للمحور 0.788.
- فيما يخص مقياس دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي فقد تخطت قيم معامل ألفا كرونباخ للمحور 0.60. وهي القيمة الأدنى لقبول واعتماد ثبات المقياس، حيث كانت قيمة معامل ألفا كرونباخ للمحور 0.851.
- وفي ضوء ذلك، يتضح أن جميع المقاييس المستخدمة لقياس متغيرات البحث تحظى بصدق وثبات مرتفع.

4-2-4: نتائج الاحصاءات الوصفية:

يهدف الباحثان من عرض الاحصاءات الوصفية الى بيان طبيعة عينة الدراسة وكذلك اتجاهات الموافقة على متغيرات الدراسة ومحاورها الرئيسية بغرض التمهيد لاختبار الفروض الاحصائية من خلال الاحصاء الاستدلالي، وذلك من خلال مرحلتين على النحو التالي:

أولاً: توصيف عينة الدراسة:

من خلال استخدام الاحصاء الوصفي يمكن وصف خصائص عينة الدراسة وذلك على النحو التالي كما هو موضح بالجدول رقم (4-10) على النحو التالي:
جدول رقم (4-10): الخصائص الديموغرافية لعينة الدراسة

النسبة	عدد المفردات	الخصائص الديموغرافية	
38.23%	151	محاسب	الوظيفة
17.47%	69	مدير مالي	
16.46%	65	مراجع خارجي	
27.85%	110	أكاديمي	
#####	395	الاجمالي	
16.46%	65	من 5 سنوات لأقل من 10 سنوات	مستوى الخبرة
34.43%	136	من 10 سنوات لأقل من 15 سنة	
39.75%	157	من 15 سنة لأقل من 20 سنة	
9.37%	37	من 20 سنة فأكثر	
#####	395	الاجمالي	
47.34%	187	بكالوريوس	مستوى التعليم
24.56%	97	دبلوم دراسات عليا	
15.70%	62	ماجستير	
12.41%	49	دكتورة	
#####	395	الاجمالي	

المصدر: اعداد الباحثان اعتماداً على نتائج التحليل الاحصائي

ويتضح لدى الباحثان من الجدول السابق مجموعة من الملاحظات التي يمكن بيانها فيما يلي:

- فيما يتعلق بالوظيفة، كانت فئة المحاسبين هي الفئة الأكثر شيوعاً بواقع 151 مفردة بنسبة 38.23%، ويليهما فئة الأكاديمين بواقع 110 مفردة بنسبة 27.85%، ويليهما فئة المدير المالي بواقع 69 مفردة بنسبة 17.47%، وأخيراً فئة المراجع الخارجي بواقع 65 مفردة بنسبة 16.46%.
- أما على مستوى الخبرة، فكانت فئة من 15 سنة لأقل من 20 سنة هي الفئة الأكثر شيوعاً بواقع 157 مفردة بنسبة 39.75%، ويليهما فئة من 10 سنوات لأقل من 15 سنة بواقع 136 مفردة بنسبة 34.43%، ويليهما فئة من 5 سنوات لأقل من 10 سنوات بواقع 65 مفردة بنسبة 16.46%، وأخيراً فئة من 20 سنة فأكثر بواقع 37 مفردة بنسبة 9.37%.
- أما على المستوى التعليمي فكانت فئة البكالوريوس هي الفئة الأكثر شيوعاً بواقع 187 مفردة بنسبة 47.34%، ويليهما فئة دبلوم الدراسات العليا بواقع 97 مفردة بنسبة 24.56%، ويليهما فئة الحاصلين على درجة الماجستير بواقع 62 مفردة بنسبة 15.70%، وأخيراً فئة الحاصلين على درجة الدكتوراة بواقع 49 مفردة بنسبة 12.41%.

ثانياً: الإحصاءات الوصفية لمتغيرات الدراسة:

يحتوي البحث على أربعة محاور أساسية وهم دور سلاسل الكتل في كشف الاحتيال المحاسبي، دور تقنية التعلم الآلي في الكشف والتقرير عن الاحتيال المحاسبي، التكامل بين سلاسل الكتل وتقنية تعلم الآلة، ودور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي، ويمكن عرض نتائج التحليل الوصفي لهذه المتغيرات كما في الجدول رقم (4-11) وذلك كما يلي:

جدول رقم (4-11): التحليل الوصفي لمتغيرات وأبعاد البحث (ن = 395)

المحور	الوسط الحسابي	الانحراف المعياري	معامل الالتواء	معامل التفرطح
دور سلاسل الكتل في كشف الاحتيال المحاسبي	3.84	0.63	0.48	0.91
دور تقنية التعلم الآلي في الكشف عن والتقرير عن الاحتيال المحاسبي	3.95	0.62	0.49	0.94
التكامل بين سلاسل الكتل وتقنية تعلم الآلة	3.88	0.50	0.54	0.46
دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي	3.96	0.45	0.49	1.10

ويتضح من الجدول (4-11) ما يلي:

- بلغ الوسط الحسابي للمحور الأول الخاص بدور سلاسل الكتل في كشف الاحتيال المحاسبي 3.84، وهو ما يشير الى ارتفاع درجة الموافقة على المحور الأول.
- بلغ الوسط الحسابي للمحور الثاني الخاص بدور تقنية التعلم الآلي في الكشف عن والتقرير عن الاحتيال المحاسبي 3.95، وهو ما يشير الى ارتفاع درجة الموافقة على المحور الثاني.
- بلغ الوسط الحسابي للمحور الثالث الخاص بالتكامل بين سلاسل الكتل وتقنية تعلم الآلة 3.88، وهو ما يشير الى ارتفاع درجة الموافقة على المحور الثالث.
- بلغ الوسط الحسابي للمحور الرابع الخاص بدور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي 3.96، وهو ما يشير الى ارتفاع درجة الموافقة على المحور الرابع.
- كما يتبين من نتائج الجدول السابق أن جميع عبارات المقياس تميل الى التوزيع الطبيعي حيث تراوحت قيم معامل الالتواء ما بين (± 3) ، كما كانت قيم معامل التفرطح تتراوح ما بين (± 10) .

4-5: نتائج الاحصاء الاستدلالي:

يهدف الباحثان في هذه الخطوة الى اجراء اختبارات الفروض الاحصائية بعد اجراء التحليل العاملي الاستكشافي والاستدلالي لمحاوَر الدراسة في اطار متوسطات العبارات كل محور، ثم الوصول الى النتائج النهائية لاختبارات الفروض الاحصائية للدراسة وذلك على النحو التالي:

أولاً: اتجاه المتوسط العام للعبارات والتحليل العاملي:

يستخدم التحليل العاملي الاستكشافي ويتم تطبيق نهجه الاحصائي على نطاق واسع في العديد من التخصصات مثل أنظمة المعلومات والعلوم الاجتماعية والعلوم التربوية والنفسية، ويهدف الى اختزال عدد العوامل، وتقييم خطي متعدد العوامل التي يوجد بينها ارتباط، وتقييم وفحص النماذج الأحادية، وتقييم الصدق البنائي في قائمة الاستقصاء، وكذلك دراسة علاقة العوامل أو فحص نموذج الدراسة، بالإضافة الى تطوير المفاهيم النظرية، واثبات النظرية المقترحة (Taherdoost, et al., 2014). وبالتالي، يتم استخدام التحليل العاملي الاستكشافي لتقليل عدد العوامل التي تبني النموذج ولتجميع العوامل التي لها نفس الخصائص معاً من أجل تحديد العوامل التي لها أكبر الأثر وتبقى في النموذج، وأي العوامل لها تأثير ضئيل أو ليس لها تأثير، وبالتالي يتم استبعادها من النموذج، ومن ثم الحصول على نموذج للعوامل الأكثر فعالية (Henson and Roberts, 2006).

وقد تم استخدام التحليل العاملي الاستكشافي في اطار الدراسة الحالية في ظل متوسطات العبارات لتحديد العوامل الرئيسية التي حددت متغيرات الدراسة والتباين الذي تفسره العوامل المحددة، وذلك بالاعتماد على تحليل المكونات الأساسية والذي يعتمد على بناء نموذج تستند فيه العوامل الى التباين الكلي ومقياس Kaiser- KMO Meyer-Olkin والذي يسعى الى قياس كفاية العينة وملاءمتها، وحتى تكون البيانات صالحة للاستخدام يجب ألا تقل قيمته عن 0.5 وباستخدام التحليل العاملي الاستكشافي ببرنامج SPSS V.26 لعينة قوامها (395 مفردة، 44 عبارة)، وكانت نتائج التحليل العاملي على النحو التالي:

- المحور الأول: دور سلاسل الكتل في كشف الاحتيال المحاسبي:

باجراء تحليل المتوسطات والتحليل العاملي الاستكشافي والتوكيدي للمحور الأول أسفرت نتائج التحليل الاحصائي عن الجدول رقم (4-12) التالي:
جدول رقم (4-12): تحليل المتوسطات والتحليل العاملي للعبارات (ن = 395)

Bartlett's Test		معامل KMO	معامل التحميل	الوسط الحسابي	العبرة	المحور
مستوى المعنوية	مربع كاي					
0.000	351.411	0.687	0.709	4.152	Q1	دور سلاسل الكتل في كشف الاحتيال المحاسبي
			0.764	3.710	Q2	
			0.622	3.825	Q3	
			0.806	4.138	Q4	
			0.696	4.127	Q5	
			0.666	4.112	Q6	
			0.680	3.828	Q7	
			0.788	3.795	Q8	
			0.748	4.167	Q9	
			0.626	4.159	Q10	
			0.721	3.840	Q11	
			0.763	3.777	Q12	

يتضح للباحثان من خلال النتائج المبينة بالجدول السابق ما يلي:

- ارتفاع قيم المتوسطات الحسابية للعبارات الخاصة بالمحور الأول حيث تراوحت ما بين 3.710 الى 4.167 مما يشير الى ارتفاع مستويات الموافقة على دور سلاسل الكتل في كشف الاحتيال المحاسبي.
- ارتفاع قيم معاملات التحميل للعبارات المختلفة الخاصة بالمحور الأول دور سلاسل الكتل في كشف الاحتيال المحاسبي حيث أنها جميعاً أكبر من 0.5 وهو ما يشير الى أن العبارات قادرة على تفسير التباين أكثر من 50%.
- فيما يتعلق بمعاملات KMO يتبين أنها أيضاً أكبر من 0.5 مما يشير الى صلاحية المحور ككل للاختبار، ويؤكد ذلك معنوية اختبار Bartlett's Test

- المحور الثاني: دور سلاسل الكتل في كشف الاحتيال المحاسبي:

باجراء تحليل المتوسطات والتحليل العاملي الاستكشافي والتوكيدي للمحور الثاني أسفرت نتائج التحليل الاحصائي عن الجدول رقم (4-13) التالي:

جدول رقم (4-13): تحليل المتوسطات والتحليل العاملي للعبارات (ن = 395)

Bartlett's Test		معامل KMO	معامل التحميل	الوسط الحسابي	العبرة	المحور
مستوى المعنوية	مربع كاي					
0.000	486.511	0.751	0.769	4.222	Q13	دور تقنية التعلم الآلي في في الكشف عن التقرير عن الاحتيال المحاسبي
			0.794	3.686	Q14	
			0.766	3.897	Q15	
			0.763	3.777	Q16	
			0.723	4.186	Q17	
			0.742	3.970	Q18	
			0.719	3.693	Q19	
			0.775	3.700	Q20	

			0.748	4.134	Q21	
			0.625	4.052	Q22	
			0.623	4.121	Q23	
			0.680	3.757	Q24	
			0.691	3.866	Q25	

يتضح للباحثان من خلال النتائج المبينة بالجدول السابق ما يلي:

- ارتفاع قيم المتوسطات الحسابية للعبارات الخاصة بالمحور الثاني حيث تراوحت ما بين 3.686 الى 4.22 مما يشير الى ارتفاع مستويات الموافقة على دور تقنية التعلم الآلي في الكشف عن والتقرير عن الاحتيال المحاسبي.
- ارتفاع قيم معاملات التحميل للعبارات المختلفة الخاصة بالمحور الثاني دور تقنية التعلم الآلي في الكشف عن والتقرير عن الاحتيال المحاسبي حيث أنها جميعاً أكبر من 0.5 وهو ما يشير الى أن العبارات قادرة على تفسير التباين أكثر من 50%.
- فيما يتعلق بمعاملات KMO يتبين أنها أيضاً أكبر من 0.5 مما يشير الى صلاحية المحور ككل للاختبار، ويؤكد ذلك معنوية اختبار

Bartlett's Test

- المحور الثالث: التكامل بين سلاسل الكتل وتقنية تعلم الآلة:

باجراء تحليل المتوسطات والتحليل العاملي الاستكشافي والتوكيدي للمحور الثاني أسفرت نتائج التحليل الاحصائي عن الجدول رقم (4-14) التالي:

جدول رقم (4-14): تحليل المتوسطات والتحليل العاملي للعبارات (ن = 395)

Bartlett's Test		معامل KMO	معامل التحميل	الوسط الحسابي	العبرة	المحور
مستوى المعنوية	مربع كاي					
0.000	396.578	0.689	0.725	4.201	Q26	التكامل بين سلاسل الكتل وتقنية تعلم الآلة
			0.814	4.194	Q27	
			0.808	4.212	Q28	
			0.746	4.227	Q29	
			0.630	3.919	Q30	
			0.671	4.067	Q31	
			0.691	3.872	Q32	
			0.720	4.020	Q33	

يتضح للباحثان من خلال النتائج المبينة بالجدول السابق ما يلي:

- ارتفاع قيم المتوسطات الحسابية للعبارات الخاصة بالمحور الثالث حيث تراوحت ما بين 3.872 الى 4.227 مما يشير الى ارتفاع مستويات الموافقة على التكامل بين سلاسل الكتل وتقنية تعلم الآلة.
- ارتفاع قيم معاملات التحميل للعبارات المختلفة الخاصة بالمحور الثالث التكامل بين سلاسل الكتل وتقنية تعلم الآلة حيث أنها جميعاً أكبر من 0.5 وهو ما يشير الى أن العبارات قادرة على تفسير التباين أكثر من 50%.
- فيما يتعلق بمعاملات KMO يتبين أنها أيضاً أكبر من 0.5 مما يشير الى صلاحية المحور ككل للاختبار، ويؤكد ذلك معنوية اختبار Bartlett's Test

- المحور الرابع: دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي:

باجراء تحليل المتوسطات والتحليل العاملي الاستكشافي والتوكيدي للمحور الثاني أسفرت نتائج التحليل الاحصائي عن الجدول رقم (4-15) التالي:
جدول رقم (4-15): تحليل المتوسطات والتحليل العاملي للعبارات (ن = 395)

Bartlett's Test		معامل KMO	معامل التحميل	الوسط الحسابي	العبارة	المحور
مستوى المعنوية	مربع كاي					
0.000	479.115	0.779	0.660	3.741	Q34	دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي
			0.810	3.939	Q35	
			0.635	3.848	Q36	
			0.705	3.874	Q37	
			0.739	4.204	Q38	
			0.768	3.903	Q39	
			0.720	4.189	Q40	
			0.685	3.732	Q41	
			0.625	4.067	Q42	
			0.788	3.849	Q43	
			0.791	4.179	Q44	

يتضح للباحثان من خلال النتائج المبينة بالجدول السابق ما يلي:

- ارتفاع قيم المتوسطات الحسابية للعبارات الخاصة بالمحور الرابع حيث تراوحت ما بين 3.732 الى 4.204 مما يشير الى ارتفاع مستويات الموافقة على دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي.
- ارتفاع قيم معاملات التحميل للعبارات المختلفة الخاصة بالمحور الرابع دور المعلومات المستمدة من التكامل بين تقنيتي سلاسل الكتل وتقنية تعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي حيث أنها جميعاً أكبر من 0.5 وهو ما يشير الى أن العبارات قادرة على تفسير التباين أكثر من 50%.
- فيما يتعلق بمعاملات KMO يتبين أنها أيضاً أكبر من 0.5 مما يشير الى صلاحية المحور ككل للاختبار، ويؤكد ذلك معنوية اختبار

Bartlett's Test

ثانياً: نتائج اختبارات الفروض الاحصائية للدراسة:

- نتيجة اختبار الفرض الاحصائي الأول للدراسة:

ينص الفرض الاحصائي الأول للدراسة على " لا توجد علاقة ذات دلالة إحصائية بين تطبيق تقنية سلاسل الكتل والاحتيال المحاسبي " ولغرض اختبار هذا الفرض الاحصائي فقد هدف الباحثان الى التعرف على مستوى الاتفاق بين المفردات المختلفة بعينة الدراسة بشأن عبارات المحور الأول والتي تهدف الى التأكد من مساهمة سلاسل الكتل في كشف الاحتيال المحاسبي بما يحقق التأثير المعنوي، ولذلك تم الاعتماد على الدمج بين الاختبارات المعلمية واللامعلمية تتمثل في اختبار ANOVA واختبار كروسكال والس للمتغيرات الديموغرافية متعددة الأوجه مثل الوظيفة، ومستوى الخبرة، والمستوى التعليمي، وقد أسفرت نتائج التحليل الاحصائي عن الجدول التالي:

جدول رقم (4-16): مستوى الفروق الجوهرية بالمحور الأول: دور سلاسل الكتل في كشف الاحتيال المحاسبي

ANOVA			Kruskal – Walls			المتغير
Result	Sig.	F	Result	Sig.	Chi-Square	
NS	0.179	2.034	NS	0.308	1.282	الوظيفة
NS	0.231	1.306	NS	0.181	1.296	مستوى الخبرة
NS	0.202	1.405	NS	0.199	1.187	المستوى التعليمي

يتضح للباحثان من خلال الجدول رقم (4-16) أن قيمة χ^2 الناتجة من اختبار كروسكال والس غير معنوية، فضلاً عن عدم معنوية قيمة F الناتجة من اختبار ANOVA، للمحور الأول الخاص بدور سلاسل الكتل في كشف الاحتيال المحاسبي حيث أنهما أكبر من 5% مما يشير الى عدم وجود أي فروق معنوية تتعلق باختلاف الخصائص الديموغرافية المتمثلة في الوظيفة أو المستوى التعليمي أو مستوى الخبرة تؤثر على آراء عينة الدراسة بشأن دور سلاسل الكتل في كشف الاحتيال المحاسبي، وبالتالي يمكن للباحثان الإشارة الى وجود الاتفاق بين مفردات عينة الدراسة (باختلاف خصائصها الديموغرافية) على دور سلاسل الكتل في كشف الاحتيال المحاسبي. ومن ثم قبول الفرض الاحصائي الأول للدراسة على الشكل البديل التالي: **توجد علاقة ذات دلالة إحصائية بين تطبيق تقنية سلاسل الكتل والاحتيال المحاسبي.**

• نتيجة اختبار الفرض الاحصائي الثاني للدراسة:

ينص الفرض الاحصائي الثاني للدراسة على " لا توجد علاقة ذات دلالة إحصائية بين تطبيق تقنية تعلم الآلة والاحتيال المحاسبي " ولغرض اختبار هذا الفرض الاحصائي فقد هدف الباحثان الى التعرف على مستوى الاتفاق بين المفردات المختلفة بعينة الدراسة بشأن عبارات المحور الثاني والتي تهدف الى التأكد من مساهمة تقنية تعلم الآلة في كشف الاحتيال المحاسبي بما يحقق التأثير المعنوي، ولذلك تم الاعتماد على الدمج بين الاختبارات المعلمية واللامعلمية تتمثل في اختبار

ANOVA واختبار كروسيكال والس للمتغيرات الديموغرافية متعددة الأوجه مثل الوظيفة، ومستوى الخبرة، والمستوى التعليمي، وقد أسفرت نتائج التحليل الاحصائي عن الجدول التالي:

جدول رقم (4-17): مستوى الفروق الجوهرية بالمحور الثاني: دور تقنية التعلم الآلي في الكشف عن التقرير عن الاحتيال المحاسبي

ANOVA			Kruskal – Walls			المتغير
Result	Sig.	F	Result	Sig.	Chi-Square	
NS	0.294	1.936	NS	0.315	1.467	الوظيفة
NS	0.22	1.736	NS	0.128	1.252	مستوى الخبرة
NS	0.198	1.498	NS	0.154	0.97	المستوى التعليمي

يتضح للباحثان من خلال الجدول رقم (4-17) أن قيمة χ^2 الناتجة من اختبار كروسيكال والس غير معنوية، فضلاً عن عدم معنوية قيمة F الناتجة من اختبار ANOVA، للمحور الثاني الخاص بدور تقنية التعلم الآلي في الكشف عن التقرير عن الاحتيال المحاسبي حيث أنهما أكبر من 5% مما يشير الى عدم وجود أي فروق معنوية تتعلق باختلاف الخصائص الديموغرافية المتمثلة في الوظيفة أو المستوى التعليمي أو مستوى الخبرة تؤثر على آراء عينة الدراسة بشأن دور تقنية التعلم الآلي في الكشف عن التقرير عن الاحتيال المحاسبي، وبالتالي يمكن للباحثان الإشارة الى وجود الاتفاق بين مفردات عينة الدراسة (باختلاف خصائصها الديموغرافية) على دور تقنية التعلم الآلي في الكشف عن التقرير عن الاحتيال المحاسبي. ومن ثم قبول الفرض الاحصائي الثاني للدراسة على الشكل البديل التالي: **توجد علاقة ذات دلالة إحصائية بين تطبيق تقنية تعلم الآلة والاحتيال المحاسبي.**

• **نتيجة اختبار الفرض الاحصائي الثالث للدراسة:**

ينص الفرض الاحصائي الثالث للدراسة على " لا توجد علاقة ذات دلالة إحصائية بين سلاسل الكتل وتقنية تعلم الآلة" ولغرض اختبار هذا الفرض الاحصائي

فقد هدف الباحثان الى التعرف على مستوى الاتفاق بين المفردات المختلفة بعينة الدراسة بشأن عبارات المحور الثالث والتي تهدف الى التأكد من وجود العلاقة بين تقنية سلاسل الكتل وتقنية تعلم الآلة بما يحقق التأثير المعنوي، ولذلك تم الاعتماد على الدمج بين الاختبارات المعلمية واللامعلمية تتمثل في اختبار ANOVA واختبار كروسكال والس للمتغيرات الديموغرافية متعددة الأوجه مثل الوظيفة، ومستوى الخبرة، والمستوى التعليمي، وقد أسفرت نتائج التحليل الاحصائي عن الجدول التالي:

جدول رقم (4-18): مستوى الفروق الجوهرية بالمحور الثالث: العلاقة بين سلاسل الكتل وتقنية تعلم الآلة

ANOVA			Kruskal – Walls			المتغير
Result	Sig.	F	Result	Sig.	Chi-Square	
NS	0.285	1.314	NS	0.167	1.506	الوظيفة
NS	0.18	1.161	NS	0.242	1.039	مستوى الخبرة
NS	0.24	1.915	NS	0.314	1.309	المستوى التعليمي

يتضح للباحثان من خلال الجدول رقم (4-18) أن قيمة كا² الناتجة من اختبار كروسكال والس غير معنوية، فضلاً عن عدم معنوية قيمة F الناتجة من اختبار ANOVA، للمحور الثالث الخاص بالعلاقة بين سلاسل الكتل وتقنية تعلم الآلة حيث أنهما أكبر من 5% مما يشير الى عدم وجود أي فروق معنوية تتعلق باختلاف الخصائص الديموغرافية المتمثلة في الوظيفة أو المستوى التعليمي أو مستوى الخبرة تؤثر على آراء عينة الدراسة بشأن العلاقة بين سلاسل الكتل وتقنية تعلم الآلة، وبالتالي يمكن للباحثان الإشارة الى وجود الاتفاق بين مفردات عينة الدراسة (باختلاف خصائصها الديموغرافية) على العلاق بين سلاسل الكتل وتقنية تعلم الآلة. ومن ثم قبول الفرض الاحصائي الثالث للدراسة على الشكل البديل التالي:
توجد علاقة ذات دلالة إحصائية بين تطبيق تقنية سلاسل الكتل وتقنية تعلم الآلة.

• نتيجة اختبار الفرض الاحصائي الرابع للدراسة:

ينص الفرض الاحصائي الرابع للدراسة على " لا توجد علاقة ذات دلالة إحصائية بين دور المعلومات المستمدة من تكامل سلاسل الكتل وتعلم الآلة في الكشف والتقرير عن الاحتيال المحاسبي" ولغرض اختبار هذا الفرض الاحصائي فقد هدف الباحثان الى التعرف على مستوى الاتفاق بين المفردات المختلفة بعينة الدراسة بشأن عبارات المحور الرابع والتي تهدف الى التأكد من مساهمة دور المعلومات المستخدمة من تكامل سلاسل الكتل وتعلم الآلة في الكشف عن الاحتيال المحاسبي بما يحقق التأثير المعنوي، ولذلك تم الاعتماد على الدمج بين الاختبارات المعلمية واللامعلمية تتمثل في اختبار ANOVA واختبار كروسيكال والس للمتغيرات الديموغرافية متعددة الأوجه مثل الوظيفة، ومستوى الخبرة، والمستوى التعليمي، وقد أسفرت نتائج التحليل الاحصائي عن الجدول التالي:

جدول رقم (4-19): مستوى الفروق الجوهرية بالمحور الرابع: دور المعلومات المستخدمة من تكامل سلاسل الكتل وتعلم الآلة في الكشف عن الاحتيال المحاسبي

ANOVA			Kruskal – Walls			المتغير
Result	Sig.	F	Result	Sig.	Chi-Square	
NS	0.144	0.94	NS	0.277	1.487	الوظيفة
NS	0.33	2.118	NS	0.269	1.338	مستوى الخبرة
NS	0.268	1.591	NS	0.289	1.232	المستوى التعليمي

يتضح للباحثان من خلال الجدول رقم (4-19) أن قيمة χ^2 الناتجة من اختبار كروسيكال والس غير معنوية، فضلاً عن عدم معنوية قيمة F الناتجة من اختبار ANOVA، للمحور الرابع الخاص بدور المعلومات المستخدمة من تكامل سلاسل الكتل وتعلم الآلة في الكشف عن الاحتيال المحاسبي حيث أنهما أكبر من 5% مما يشير الى عدم وجود أي فروق معنوية تتعلق باختلاف الخصائص الديموغرافية المتمثلة في الوظيفة أو المستوى التعليمي أو مستوى الخبرة تؤثر على آراء عينة الدراسة بشأن دور المعلومات المستخدمة من تكامل سلاسل الكتل وتعلم الآلة في

الكشف عن الاحتيال المحاسبي، وبالتالي يمكن للباحثان الإشارة الى وجود الاتفاق بين مفردات عينة الدراسة (باختلاف خصائصها الديموغرافية) على دور المعلومات المستخدمة من تكامل سلاسل الكتل وتعلم الآلة في الكشف عن الاحتيال المحاسبي. ومن ثم قبول الفرض الاحصائي الرابع للدراسة على الشكل البديل التالي: **توجد علاقة ذات دلالة إحصائية بين دور المعلومات المستخدمة من تكامل سلاسل الكتل وتعلم الآلة في الكشف عن الاحتيال المحاسبي.**

النتائج والتوصيات والأبحاث المستقبلية

في ضوء ما توصلت إليه الدراسة النظرية والعملية يوضح الباحثان أهم النتائج والتوصيات و الأبحاث المستقبلية على النحو التالي:

أولاً: النتائج

1- تعد ابرز خصائص تقنية البلوكتشين و التي تجعلها خيار مثاليا لكسر مثلث الاحتيال و منع الاحتيال المحاسبي ما يلي : لامركزية تعتمد على شبكة النظير الى النظير ، استخدام تقنية دفتر الاستاذ الموزع المشترك ، المصادقة القوية باستخدام الية الاجماع دون الحاجة الى وسيط ، استخدام تقنيات التشفير لضمان الامان ، الثبات فالمعاملات ثابتة غير قابلة للتغيير لضمان مقاومة العبث ، استخدام العقود الذكية لامتة المعاملات ، الشفافية و التدقيق الذاتي.

2- تقلل المحاسبة في الوقت الفعلي التي تدعمها تقنية Blockchain بشكل كبير من السلوكيات الإدارية الانتهازية للانخراط في الحيل المحاسبية وإجراءات تدمير القيمة للتلاعب بالأرباح المبلغ عنها.

3- تؤثر الاخطاء البشريه والعوامل التقنيه في تقنيه البلوكتشين على نظام منع الاحتيال والكشف عنه ، حيث لا زال بإمكان الافراد الذين لديهم (الفرصه والضغط والتبرير) تجاوز التكنولوجيا ، وسيظل العنصر البشري الحلقة الاضعف في اي اعداد وهذا يعني ان مستندات المصدر عرضه للخطر.

4- على الرغم من أن تقنية البلوكتشين تمنع السلوكيات الاحتيالية ، إلا أنها لا تستطيع الاكتشاف الاحتيال من تلقاء نفسها فلا يمكن للبلوكتشين الحماية بشكل مباشر من أشياء مثل الاستيلاء على الحساب أو سرقة الهوية.

5- على الرغم من أن تقنية البلوكتشين لها العديد من المزايا إلا أن نظام التشغيل الحالي لا يزال غير مثالي وبه العديد من المخاطر و يمكن تقسيمها الى : مخاطر تشغيلية ، مخاطر سيبرانية ، مخاطر قانونية .

6- في عصر تقنية Blockchain، يعمل الذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي على تعزيز تحليل البيانات من خلال التدقيق في المعاملات المعقدة واللامركزية. يمكن لخوارزميات الكشف عن الحالات الشاذة تحديد الأنماط أو التناقضات غير العادية في معاملات Blockchain، مما يوفر للمدققين أداة قوية لضمان سلامة وشفافية السجلات المالية.

7- يتطلب بناء أي نموذج للتنبؤ بالاحتيال اتخاذ قرارات مهمة بشأن المكونات الثلاثة التالية: أولاً: مدخلات البيانات (المتنبئات) ومخرجات البيانات (تسميات الاحتيال) التي ينبغي استخدامها للنموذج . ثانياً: تحديد خوارزميات التعلم الآلي اللازمة للتنبؤ بالاحتيال المحاسبي . ثالثاً: معايير التقييم التي ينبغي استخدامها للحكم على أداء نموذج التنبؤ بالاحتيال

8- يمكن تقسيم التحديات التي تواجه نماذج التعلم الآلي للكشف عن الاحتيال الى اربعة تحديات أساسية :- اختيار المتغيرات وتحديد الخوارزميات ، مشكلة عدم التوازن في الفئة ، مشكلة عدم التوازن في التكلفة ، و الاحتيال التسلسلي .

9- يتمتع الجمع بين كل من التعلم الآلي وتقنية Blockchain بالكثير من الفوائد من حيث تعزيز الأمان و الشفافية وإمكانية التتبع و تعزيز خصوصية البيانات و الأتمتة والكفاءة و التدقيق والامثال المعززان . على الرغم من كون كل منهما ثورية كما هي بالفعل ، فإن Blockchain و MI لديها القدرة على أن تكون أكثر ثورية عند الجمع

بينهما. فيمكن ل كليهما زيادة قدرات بعضهما البعض وكذلك تحسين مستويات الشفافية والثقة والخصوصية.

10- يقدم الذكاء الاصطناعي باستخدام خوارزميات التعلم الآلي حلاً استباقياً لكشف ومنع الأنشطة الاحتيالية لمعاملات الـ Blockchain. فيمكن لخوارزميات التعلم الآلي أن تتعلم من البيانات التاريخية، مما يجعلها دقيقة بشكل متزايد بمرور الوقت في تحسين تحليلات Blockchain .

11- توفر تقنية Blockchain والتعلم الآلي إمكانية إجراء تدقيق مستمر حقيقي. ومن خلال التدقيق المستمر، يمكن تحديد الاتجاهات والبيانات المفقودة في وقت أبكر بكثير، مما يسمح بمعالجة المشكلات بشكل استباقي، بدلاً من الإبلاغ عنها بشكل تفاعلي .

12- يؤدي تخزين البيانات على Blockchain إلى التخلص من مشكلات مثل القيم المفقودة والتكرارات والضوضاء، والتي تعد مصادر شائعة للأخطاء في نماذج التعلم الآلي.

13- توضح نتائج التحليل الإحصائي : وجود علاقة ذات دلالة احصائية بين تطبيق تقنية سلاسل الكتل والاحتيال المحاسبي ، وجود علاقة ذات دلالة احصائية بين تطبيق تقنية تعلم الآلة والاحتيال المحاسبي ، وجود علاقة ذات دلالة احصائية بين دور تقنية سلاسل الكتل وتقنية تعلم الآلة، وجود علاقة ذات دلالة احصائية بين دور المعلومات المستمدة من تكامل سلاسل الكتل و تعلم الآلة في الكشف عن الاحتيال المحاسبي .

ثانياً: التوصيات

1- يوصى الباحثان بإجراء تحديثات منتظمة لنماذج التعلم الآلي داخل النظام البيئي للـ Blockchain ، فيعد تنفيذ هذه التحديثات امراً بالغ الأهمية ويجب تنفيذه بدقة. وهذا يضمن الحفاظ على سلامة النموذج مع إبقاء مجتمع المستخدمين على اطلاع جيد ومشارك.

2- لضمان التكامل الآمن للتقنيات الجديدة في أنظمة المحاسبة، يوصى الباحثان بضرورة وضع خطة أمنية شاملة تتضمن المراقبة المستمرة وعمليات التدقيق الأمني المتكررة والحفاظ على التدابير الأمنية المستمرة للحماية من التهديدات الضارة ، و نشر بروتوكولات تفسير قوية وضوابط الوصول وتقنيات إخفاء هوية البيانات التي تحمي البيانات الحساسة وتضمن الامتثال التنظيمي . علاوة على ذلك، يمكن للحوسبة الموزعة والحوسبة السحابية وتطورات تسريع الأجهزة أن تعزز قابلية التوسع لأنظمة الذكاء الاصطناعي وخوارزميات التعلم الآلي و تقنية Blockchain . وهذا يسمح بمعالجة مجموعات البيانات الضخمة والحسابات الصعبة في الوقت الحقيقي.

3- ضرورة استخدام المعلومات المستمدة من تكامل تقنيات سلاسل الكتل والتعلم الآلي في مهنة المراجعة لضمان تطوير كفاءة و فعالية إجراءات عملية المراجعة في الكشف عن الاحتيال المحاسبي .

4- الالتزام بتطبيق اليات الرقابة الداخلية و أطر حوكمة تكنولوجيا المعلومات لمواجهة كلا من : المخاطر المرتبطة بـ Blockchain ومنها،نقاط الضعف في العقود الذكية وإجراءات الإجماع، بالإضافة إلى احتمال تعرض استقرار الشبكة للخطر بنسبة 51٪ نظراً لاعتمادها على مجموعات كبيرة من البيانات، وكذلك التحديات الأمنية في مجال الذكاء الاصطناعي و التعلم الآلي بسبب الهجمات العدائية والتحيز النموذجي.

5- يجب اصدار معيار محاسبي يلزم مراقبي الحسابات بتبنى ادوات التكنولوجيا المالية الجديدة مثل سلاسل الكتل و العقود الذكية و التعلم الآلي و الذكاء الاصطناعي و انترنت الاشياء و تحليل البيانات الضخمة في ممارسات المحاسبة و المراجعة .

ثالثاً: الأبحاث المستقبلية

- 1- أثر اعتماد مراقب الحسابات على التعلم الآلي على دقة حكمه على التحريفات الجوهرية بالقوائم المالية مع دليل ميداني و تطبيقي من الشركات المقيدة بالبورصة المصرية .
- 2- دراسة و اختبار مدى ملائمة خوارزميات التعلم العميق للتنبؤ برأى مراقب الحسابات بشأن الاستمرارية مع دليل تطبيقي .
- 3- أثر مستوى الإفصاح عن المعلومات المستمدة من البلوكتشين على جودة المعلومات المحاسبية مع دليل من شركات الأغذية و المشروبات المقيدة بالبورصة المصرية .

قائمة المراجع

1. ACFE,(2018), ACFE Report to the Nations on Occupational Fraud and Abuse Association of Certified Fraud Examiners, 1-80 . available at: <https://www.iasplus.com/en-ca/news/regulations/2018/2018-report-to-the-nations-on-occupational-fraud-and-abuse>
2. Achakzai, M. A. K., & Peng, J. (2023). Detecting financial statement fraud using dynamic ensemble machine learning. *International Review of Financial Analysis*, 89, 102827.
3. Addula, S. R., Meduri, K., Nadella, G. S., & Gonaygunta, H. AI and Blockchain in Finance: Opportunities and Challenges for the Banking Sector., *International Journal of Advanced Research in Computer and Communication Engineering*, 13, (2), 184-190.
4. Al-Habashneh, A., & Hamdan, S. (2023). Benefits and Challenges of Artificial Intelligence and Blockchain Adoption in Auditing Process: a Research Agenda, ", Easy Chair Preprint № 9604, 1-19.

5. Ali, A. A., Khedr, A. M., El-Bannany, M., & Kanakkayil, S. (2023). A Powerful Predicting Model for Financial Statement Fraud Based on Optimized XGBoost Ensemble Learning Technique. *Applied Sciences*, 13(4), 2272,1-16.
6. ALSaqa, Z. H., Hussein, A. I., & Mahmood, S. M. (2019). The impact of Blockchain on accounting information systems. *Journal of Information Technology Management*, 11(3), 62-80.
7. Alsulami, R., Albalawi, R., Albalawi, M., Alsugair, H., Alblowi, K. A., & Alharbi, A. R. (2023). Review the Recent Fraud Detection Systems for Accounting Area using Blockchain Technology. *International journal of computer science and network security: IJCSNS*, 23(5), 109-120.
8. Ashtiani, M. N., & Raahemi, B. (2021). Intelligent fraud detection in financial statements using machine learning and data mining: a systematic literature review. *Ieee Access*, 10, 72504-72525.
9. Baâtout,E, Boussetta,J,(2024)," Does the Integration of Blockchain Technology andArtificial Intelligence Enhance the Efficiency and Reliability of Accounting and Auditing Practices?", International Journal of Novel Research and Development ,ISSN: 2456-4184 9(2), 479-520.
10. Bao, Y., Hilary, G., & Ke, B. (2022). Artificial intelligence and fraud detection. *Innovative Technology at the Interface of Finance and Operations: Volume I*, 223-247.
11. Baul,k,(2023) ,"Top 5 Trends in Fraud Detection and Prevention", available at: <https://www.linkedin.com/pulse/top-5-fraud-trends-2023>
12. Bertomeu, J. (2020). Machine learning improves accounting: discussion, implementation and research opportunities. *Review of Accounting Studies*, 25(3), 1135-1155.

13. Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W. (2021). Using machine learning to detect misstatements. *Review of Accounting Studies*, 26, 468-519.
14. Bhaskaran,A., Varghese,J, Thomas,S.A., & Vinod,S,(2021)," Fraud Detection In Blockchain Systems", International Conference On Cyber Security And Ethical Hacking In Blockchain Technology, 91-93.
15. Bhattacharya, I., & Lindgreen, E. R. (2020, June). A Semi-Supervised Machine Learning Approach to Detect Anomalies in Big Accounting Data. In *ECIS*,1-15.
16. Bhowmik, M., Chandana, T. S. S., & Rudra, B. (2021, April). Comparative study of machine learning algorithms for fraud detection in Blockchain. In *2021 5th international conference on computing methodologies and communication (ICCMC)* (pp. 539-541). IEEE.
17. Bhowmik, M., Chandana, T. S. S., & Rudra, B. (2021, April). Comparative study of machine learning algorithms for fraud detection in Blockchain. In *2021 5th international conference on computing methodologies and communication (ICCMC)* (pp. 539-541). IEEE.
18. Bochkay, K., Brown, S. V., Leone, A. J., & Tucker, J. W. (2023). Textual analysis in accounting: What's next?. *Contemporary accounting research*, 40(2), 765-805.
19. Bonyuet, D. (2020). Overview and impact of Blockchain on auditing. *International Journal of Digital Accounting Research*, 20, 31-43.
20. Bron,D, (2023) ," The Use of AI in Blockchain Analytics: Improving the Detection and Prevention of Fraud and Money Laundering" ,(1-7) , available at: <https://www.linkedin.com/pulse/use-ai-Blockchain-analytics-improving-detection-prevention-bron>
21. Campbell, D. W., & Shang, R. (2022). Tone at the bottom: Measuring corporate misconduct risk from the text of employee reviews. *Management Science*, 68(9), 7034-7053.

22. Cecchini, M., Aytug, H., Koehler, G. J., & Pathak, P. (2010). Detecting management fraud in public companies. *Management Science*, 56(7), 1146-1160.
23. Chen, T. (2022, April). Blockchain and accounting fraud prevention: A case study on Luckin coffee. In *2022 7th International Conference on Social Sciences and Economic Development (ICSSSED 2022)* (pp. 44-49). Atlantis Press.
24. Chukwuma, O. V., Okolie, P. I., Eneh, N. A., & Ejike, S. I. (2023). Using data analytics techniques for the detection of accounting fraud in financial statements, *International Journal of Multidisciplinary Research and Growth Evaluation* . ISSN (online): 2582-7138 ,212-214.
25. Dechow, P. M., Ge, W., Larson, C. R., & Sloan, R. G. (2011). Predicting material accounting misstatements. *Contemporary accounting research*, 28(1), 17-82.
26. Deloitte (2019) , "An internal auditor's guide to Blockchain: Blurring the line between physical and digital -Part one: Introduction to Blockchain", Available at: <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/risk/us-risk-Blockchain-for-internal-auditors.pdf>.
27. Deloitte.,(2016), "Blockchain Technology A game-changer in accounting?", Available at: https://www2.deloitte.com/content/dam/Deloitte/de/Documents/Innovation/Blockchain_A game-changer in accounting.pdf (Accessed: 7 July 2020).
28. Fallatah,R,(2021)," Literature review – machine learning in accounting and assurance",Academy of Accounting and Financial Studies Journal, 25(6) 1-14.
29. Fieberg, C., Hesse, M., Loy, T., & Metko, D. (2022). Machine learning in accounting research. In *Diginomics research perspectives: The role of digitalization in business and society* (pp. 105-124). Cham: Springer International Publishing.

30. Fullana, O., & Ruiz, J. Accounting Information Systems in the Blockchain Era. 2020. <https://ssrn.com/abstract,35,17142>,1-35.
31. Garanina, T., Ranta, M., & Dumay, J. (2022). Blockchain in accounting research: current trends and emerging topics. *Accounting, Auditing & Accountability Journal*, 35(7), 1507-1533.
32. Gepp, A., Kumar, K., & Bhattacharya, S. (2023). Taking the hunch out of the crunch: A framework to improve variable selection in models to detect financial statement fraud. *Accounting & Finance*,1-20.
33. GÜDELÇİ, E. N. (2022). New era in Blockchain technology and better accounting information. *Journal of Accounting and Taxation Studies*, 15(2), 437-461.
34. Hamal, S., & Senvar, Ö. (2021). Comparing performances and effectiveness of machine learning classifiers in detecting financial accounting fraud for Turkish SMEs. *Int. J. Comput. Intell. Syst.*, 14(1), 769-782.
35. Han, H., Shiwakoti, R. K., Jarvis, R., Mordi, C., & Botchie, D. (2023). Accounting and auditing with Blockchain technology and artificial Intelligence: A literature review. *International Journal of Accounting Information Systems*, 48, 100598,1-16.
36. Hassanniakalager, A., Ji, X., Perotti, P., & Tsoligkas, F. (2022). A Machine Learning Approach to Detect Accounting Frauds. *Available at SSRN 4117764*. 1-42.
37. Hossain, M. Z. (2023). Emerging Trends in Forensic Accounting: Data Analytics, Cyber Forensic Accounting, Cryptocurrencies, and Blockchain Technology for Fraud Investigation and Prevention. *Cyber Forensic Accounting, Cryptocurrencies, and Blockchain Technology for Fraud Investigation and Prevention (May 16, 2023)*. DOI: 10.2139/ssrn.4450488,1-30.
38. Hossain, M. Z. (2023). Emerging Trends in Forensic Accounting: Data Analytics, Cyber Forensic Accounting, Cryptocurrencies, and

- Blockchain Technology for Fraud Investigation and Prevention. *Cyber Forensic Accounting, Cryptocurrencies, and Blockchain Technology for Fraud Investigation and Prevention* (May 16, 2023). DOI: 10.2139/ssrn.4450488,1-30.
39. Huang, L., Abrahams, A., & Ractham, P. (2022). Enhanced financial fraud detection using cost-sensitive cascade forest with missing value imputation. *Intelligent Systems in Accounting, Finance and Management*, 29(3), 133-155
40. ICAEW (2018), "Blockchain and the future of accountancy", (1-16), available at: <https://www.icaew.com/-/media/corporate/files/technical/technology/thought-leadership/Blockchain-and-the-future-of-accountancy.ashx>
41. Idehen, A. V., & Mayor, E. (2021). Examining the role of Blockchain technology against fraud in SMEs. *International Journal of Research in Business and Social Science* (2147-4478), 10(5), 245-252.
42. Iskanto, D., & Juariyah, L. (2023). Blockchain Technology Challenge in the Future:: Data Security and Efficiency. *International Journal of Law, Policy, and Governance*, 2(2), 65-76.
43. Islam, M. R., Rahman, M. M., Mahmud, M., Rahman, M. A., & Mohamad, M. H. S. (2021, August). A review on Blockchain security issues and challenges. In *2021 IEEE 12th control and system graduate research colloquium (ICSGRC)* (pp. 227-232). IEEE.
44. Isuru,s,(2023)," Financial Fraud in the Digital Age: Detection and Prevention Strategies", available at: <https://www.linkedin.com/pulse/financial-fraud-digital-age-detection-prevention-strategies-isuru/>
45. Jebamikyous, H., Li, M., Suhas, Y., & Kashef, R. (2023). Leveraging machine learning and Blockchain in E-commerce and beyond: benefits, models, and application. *Discover Artificial Intelligence*, 3(1), 3.1-16.

46. Jebamikyous, H., Li, M., Suhas, Y., & Kashef, R. (2023). Leveraging machine learning and Blockchain in E-commerce and beyond: benefits, models, and application. *Discover Artificial Intelligence*, 3(1), 3, 1-16.
47. Jofre, M., & Gerlach, R. (2018). Fighting accounting fraud through forensic data analytics. *arXiv preprint arXiv:1805.02840*.. 1-39.
48. Kafi, M. A., & Adnan, T. (2020). Machine Learning in Accounting Research: A Computational Power to Wipe Out the Challenges of Big Data. *Asian Accounting and Auditing Advancement*, 11(1), 55-70.
49. Kanaparthi, V. (2024). Exploring the Impact of Blockchain, AI, and ML on Financial Accounting Efficiency and Transformation. *arXiv preprint arXiv:2401.15715*,1-18.
50. Katala,J,(2023) ," Blockchain IMPROVING MACHINE LEARNING MODELS ACCESSIBILITY", (1-15), available at: <https://www.cryptopolitan.com/Blockchain-access-machine-learning-models>
51. Kumar, S., Lim, W. M., Sivarajah, U., & Kaur, J. (2023). Artificial intelligence and Blockchain integration in business: trends from a bibliometric-content analysis. *Information Systems Frontiers*, 25(2), 871-896.
52. Kureljusic, M., & Karger, E. (2023). Forecasting in financial accounting with artificial intelligence—A systematic literature review and future research agenda. *Journal of Applied Accounting Research*, (ahead-of-print),81.104.
53. Leavins,J,R., Ramaswamy,V.,(2023)," Improving Internal Control Over Fixed Assets With Blockchain ", *International Journal of Business & Management Studies* ,4(6),1-4.
54. Liu, Y., Wu, B., & Zhang, M. (2023). Can independent directors identify the company's risk of financial fraud: Evidence from

- predicting financial fraud based on machine learning. *China Journal of Accounting Studies*, 11(3), 465-492.
55. Lu, H., Huang, K., Azimi, M., & Guo, L. (2019). Blockchain technology in the oil and gas industry: A review of applications, opportunities, challenges, and risks. *Ieee Access*, 7, 41426-41444.
56. Maffei, M., Casciello, R., & Meucci, F. (2021). Blockchain technology: uninvestigated issues emerging from an integrated view within accounting and auditing practices. *Journal of Organizational Change Management*, 34(2), 462-476.
57. Mahtani, U. (2022). Fraudulent practices and Blockchain accounting systems. *Journal of Accounting, Ethics and Public Policy*, 23(1), 97-148.
58. Malekolkalami, T., Khodabakhshi Parijani, K., & Alifari, M. (2023). Application of data mining to detect accounting fraud in information systems. *International Journal of Knowledge Processing Studies*, 3(4), 60-72.
59. Ngo,D.,(2020) ," How Blockchain Technology Can Enhance Fraud Detection, Interview with Feedzai's CTO", Available at: <https://coinjournal.net/news/how-Blockchain-technology-can-enhance-fraud-detection-interview-with-feedzais-cto/>
60. Nguyen, M., Nguyen Hoang To, L., & Nguyen Viet, H. (2022). A model for detecting accounting frauds by using machine learning.1552-1560.
61. Nickerson, M. A. (2019). Fraud in a world of advanced technologies: The possibilities are (unfortunately) endless. *The CPA Journal*, 89(6), 28-34.
62. Nielsen, S. (2022). Management accounting and the concepts of exploratory data analysis and unsupervised machine learning: a literature study and future directions. *Journal of Accounting & Organizational Change*, 18(5), 811-853.

63. Odeyemi, O., Awonuga, K. F., Mhlongo, N. Z., Ndubuisi, N. L., Olatoye, F. O., & Daraojimb, A. I. (2024). The role of AI in transforming auditing practices: A global perspective review. *World Journal of Advanced Research and Reviews*, 21(2), 359-370.
64. Oladejo, M. T. (2023). *Blockchain technology: Disruptor or enhancer to the accounting and auditing profession* (Doctoral dissertation, The University of Waikato), 1-492.
65. Oladejo, M. T., & Jack, L. (2020). Fraud prevention and detection in a Blockchain technology environment: challenges posed to forensic accountants. *International Journal of Economics and Accounting*, 9(4), 315-335.
66. Pascual Pedreño, E., Gelashvili, V., & Pascual Nebreda, L. (2021). Blockchain and its application to accounting. *Intangible Capital*, 17(1), 1-16.
67. Pereira, J., Tavalaei, M. M., & Ozalp, H. (2019). Blockchain-based platforms: Decentralized infrastructures and its boundary conditions. *Technological Forecasting and Social Change*, 146, 94-102.
68. Pereira, J., Tavalaei, M. M., & Ozalp, H. (2019). Blockchain-based platforms: Decentralized infrastructures and its boundary conditions. *Technological Forecasting and Social Change*, 146, 94-102.
69. Perols, J. (2011). Financial statement fraud detection: An analysis of statistical and machine learning algorithms. *Auditing: A Journal of Practice & Theory*, 30(2), 19-50.
70. Purda, L., & Skillicorn, D. (2015). Accounting variables, deception, and a bag of words: Assessing the tools of fraud detection. *Contemporary Accounting Research*, 32(3), 1193-1223.
71. Radanliev, P. (2023). Review and comparison of US, EU, and UK regulations on cyber risk/security of the current Blockchain

- technologies: Viewpoint from 2023. *The Review of Socionetwork Strategies*, 17(2), 105-129.
72. Rahman, M. J., & Zhu, H. (2023). Predicting accounting fraud using imbalanced ensemble learning classifiers—evidence from China. *Accounting & Finance*, 63(3), 3455-3486.
73. Rakshit, A., Kumar, Sh & Ramanathan, L , (2022), " Fraud Detection: A Review on Blockchain", *International Research Journal of Engineering and Technology (IRJET)* , 9 (1) , 1040-1050.
74. Ramzan, S., & Lokanan, M. (2024). The application of machine learning to study fraud in the accounting literature. *Journal of Accounting Literature*, 1-27.
75. Riskiyadi, M. (2023). Detecting future financial statement fraud using a machine learning model in Indonesia: a comparative study. *Asian Review of Accounting*, 1-29 .
76. Roszkowska, P. (2021). Fintech in financial reporting and audit for fraud prevention and safeguarding equity investments. *Journal of Accounting & Organizational Change*, 17(2), 164-196.
77. Sadgali, I., Sael, N., & Benabbou, F. (2019). Performance of machine learning techniques in the detection of financial frauds. *Procedia computer science*, 148, 45-54.
78. Schneider, M., & Brühl, R. (2023). Disentangling the black box around CEO and financial information-based accounting fraud detection: machine learning-based evidence from publicly listed US firms. *Journal of Business Economics*, 93(9), 1591-1628.
79. Septiawan, B., & Fartika, W. (2022). APPLICATION OF TRIPLE-ENTRY BOOKKEEPING WITH BLOCKCHAIN TECHNOLOGY AS AN EFFORT TO PREVENT ACCOUNTING FRAUD. *Akuntansi Dewantara*, 6(2), 42-47

80. Shahana, T., Lavanya, V., & Bhat, A. R. (2023). State of the art in financial statement fraud detection: A systematic review. *Technological Forecasting and Social Change*, 192, 122527.
81. Siddiqui, S. T., Ahmad, R., Shuaib, M., & Alam, S. (2020). Blockchain security threats, attacks and countermeasures. In *Ambient Communications and Computer Systems: RACCCS 2019* (pp. 51-62). Springer Singapore.
82. Sinha, D. (2020)," Use Data Analytics for Fraud Prevention and Detection", Available at: <https://www.techaheadcorp.com/blog/data-analytics-fraud-prevention>.
83. Sirapanji, J. (2023). Analysis of Blockchain Application in the Context of Prevention Accounting Fraud. *Available at SSRN 4517928*,1-8.
84. Thakker, P., & Japee, G. (2023). Emerging technologies in accountancy and finance: A comprehensive review. *European Economic Letters (EEL)*, 13(3), 993-1011.
85. Tyagi, A. K., Aswathy, S. U., & Abraham, A. (2020). Integrating Blockchain technology and artificial intelligence: Synergies perspectives challenges and research directions. *Journal of Information Assurance and Security*, 15(5), ISSN 1554-1010,178-193.
86. Ucoglu, D. (2020). Current machine learning applications in accounting and auditing. *PressAcademia Procedia*, 12(1), 1-7.
87. Vetter, A. (2018). Blockchain, machine learning, and a future accounting. *Retrieved May, 28, 2019*,1-3.
88. Wang, Y. (2018). *Designing continuous audit analytics and fraud prevention systems using emerging technologies* (Doctoral dissertation, Rutgers University-Graduate School-Newark),1-149.
89. Wenhua, Z., Qamar, F., Abdali, T. A. N., Hassan, R., Jafri, S. T. A., & Nguyen, Q. N. (2023). Blockchain technology: security issues, healthcare applications, challenges and future trends. *Electronics*, 12(3), 546,1-28.

90. Xu, J. J. (2016). Are Blockchains immune to all malicious attacks? *Financial Innovation*, 2 (1), 25,1-9.
91. Xu, X., Xiong, F., & An, Z. (2023). Using machine learning to predict corporate fraud: evidence based on the gone framework. *Journal of Business Ethics*, 186(1), 137-158.
92. Yang, Sh, (2022) ," Blockchain + AI In Finance : How Opposites Attract ", DATA SCIENCE AND AI , (1-6) available at : <https://insight.factset.com/Blockchain-ai-in-finance-how-opposites-attract>.
93. Yontar, E. (2023). Challenges, threats and advantages of using Blockchain technology in the framework of sustainability of the logistics sector. *Turkish Journal of Engineering*, 7(3), 186-195.



جامعة قناة السويس

كلية التجارة

قسم المحاسبة والمراجعة

قائمة استقصاء

السادة الأفاضل /

تحية طيبة وبعد

يتشرف الباحثان د/ حسين محمد سليمان & د/ شرين عبد الله عباس بإجراء
بحث بعنوان:

"أثر المعلومات المستمدة من تكامل سلاسل الكتل والتعلم الآلي كتقنيات للذكاء
الاصطناعي في الكشف والتقرير عن الاحتيال المحاسبي مع دراسة تطبيقية"

ويهدف البحث الى تحليل اثر العلاقة التكاملية بين سلاسل الكتل وتعلم الالة على
الاحتيال المحاسبي، لذا فإن البيانات التي يتم الحصول عليها ستكون مفيدة جداً
للدراسة، مع العلم بأنها لن تستخدم إلا لأغراض البحث العلمي فقط، ولمراعاة
الموضوعية والسرية فإن ذكر الاسم غير ملزم على الإطلاق.

ونشكركم مقدماً على حسن تعاونكم ...

الباحثان

البيانات الديموغرافية

1- طبيعة الشركة التي تعمل فيها :

2- الوظيفة

- | | |
|----------------------|-------------------|
| <input type="text"/> | أ- محاسب |
| <input type="text"/> | ب- مدير مالي |
| <input type="text"/> | ج - مراجع خارجي |
| <input type="text"/> | د- عضو هيئة تدريس |

3- مستوي الخبرة :

- | | |
|----------------------|-------------------------------|
| <input type="text"/> | أ- من 5 الي 10 سنوات |
| <input type="text"/> | ب- من 10 سنوات الى اقل 15 سنة |
| <input type="text"/> | ج - من 15 سنة الي 20 سنة |
| <input type="text"/> | د- 20 سنة فأكثر |

4- مستوي التعليم

- | | |
|----------------------|----------------------|
| <input type="text"/> | أ- بكالوريوس |
| <input type="text"/> | ب- دبلوم دراسات عليا |
| <input type="text"/> | ج - ماجستير |
| <input type="text"/> | د- دكتوراه |

حدد درجة موافقتك على العبارات التالية:

السؤال الأول: تساهم تقنية البلوك تشين في الكشف والتقرير عن الاحتيال المحاسبي من خلال الخصائص التالية :

لا أوافق تماماً	لا أوافق	محايد	موافق	موافق تماماً	العبارة
					Q1 انها دفتر أستاذ موزع تتيح النقاط المعاملات التي تتم من عدة افراد في الوقت الفعلي .
					Q2 انها دفتر أستاذ رقمي غير قابل للتغيير .
					Q3 قدرتها علي انشاء عقود ذكية لأتمتة المعاملات والتحكم المزدوج من قبل مختلف اطراف الصفقة.
					Q4 تمتعها بالبيات اجماع بما يتيح تحقق جماعي وينشئ الثقة بين جميع الأطراف في شبكة تضم عقد متعددة .
					Q5 تستخدم تقنيات التشفير لتأمين المعاملات حيث تحتوي كل كتلة علي طوابع زمنية مختومة بالوقت.
					Q6 تعزيز إمكانية التتبع بسبب الكتل التي يتم انشاؤها مما يؤدي الى انشاء مسار للأحداث قابلة للتدقيق.
					Q7 توفر الشفافية لجميع المشاركين من خلال الوصول الى نفس الإصدار من دفتر الأستاذ الرقمي .
					Q8 تعتبر طريقة أمنه للتحقق من هويات الأشخاص .
					Q9 معاملات الدفع التي تتم عن طريقها تعتبر معاملات اسرع واكثر أمانا .
					Q10 تنظم البيانات في شكل كتل متسلسلة و لا يتم انشاء كتلة جديدة الا بموافقة قبل الدخول ومن ثم يتخذ اجراء فوري لمنع الاحتيال
					Q11 تعتبر أداة مثالية لتشكيل منصة يتم من خلالها مشاركة المعلومات طوعا وهذا يساهم في الحد من التلاعب والاحتيال .
					Q12 استخدامها للطريقة الامركزية في تخزين البيانات يساهم في توفير فرص متساوية لجميع الأطراف في التحقق من المعاملات وبيانات التخزين والتنظيم وبالتالي الحد من الاحتيال

أثر المعلومات المستمدة من تكامل سلاسل الكتل والتعلم الآلي كتقنيات للذكاء الاصطناعي في الكشف والتقرير ...
د/ حسين محمد سليمان & د/ شرين عبد الله عباس

السؤال الثاني: تساهم تقنية التعلم الآلي في الكشف والتقرير عن الاحتيال المحاسبي من خلال الخصائص التالية :

العبرة	موافق تماماً	موافق	محايد	لا أوافق	لا أوافق تماماً
Q13 قدرته علي تحليل كمية هائلة من البيانات لتحديد الحالات الشاذة التي تشير الى النشاط الاحتيالي .					
Q14 مراقبة المعاملات في الوقت الفعلي لتحديد الأنشطة المشبوهة علي الفور					
Q15 توفير إشارات تحذير مبكرة للسلوك الاحتيالي .					
Q16 تمتعها بفترة تدريب وفترة اختبار يتيح لها تحليل البيانات الحالية والتاريخية وتقييم احتمالية حدوث شيء ما ومن ثم اتخاذ تدابير استباقية للتخفيف من المخاطر .					
Q17 يساهم في زيادة الكفاءة والفعالية في الكشف عن الاحتيال وتحديد الأنماط والشذوذ في البيانات.					
Q18 قدرتها علي إضافة البيانات المنظمة وغير المنظمة سواء مالية او غير مالية - نصية او صوتية مما يتيح استخدام افضل نماذج التنبؤ للكشف والتقرير عن الاحتيال.					
Q19 استخدام التعلم الآلي يؤدي الى تقليل عدد اختبارات الفروض وذلك لانه يعتمد علي بيانات الإدخال الأولية فقط بما يجعلها اكثر دقة من الأساليب الإحصائية التقليدية					
Q20 تحسين دقة القياس نتيجة اعتمادها علي تنبؤات أكثر والتعامل بفاعلية مع المشكلات غير الخطية .					
Q21 تنمية قدرات المدققين والمنظمين في تحديد الشركات التي قد يحتمل أن تكون احتيالية .					
Q22 اعتمادها علي العديد من نماذج التنبؤ الوصفية والكمية يمكنها من الكشف والتقرير عن الاحتيال بشكل افضل من أساليب الذكاء الاصطناعي الأخرى .					
Q23 استخدام تقنيات التعلم الآلي المجموعة يمكن من التغلب علي اوجه القصور لكل نموذج وثم يحقق دقة اعلي في الكشف والتقرير عن الاحتيال المحاسبي .					
Q24 يساعد في الامتثال الى اللوائح والسياسات من خلال مراقبة المعاملات المالية					
Q25 استخدام التعلم الآلي يعد ميزة للأغراض الأمنية لغرض تحديد الانحرافات والهجمات في أنظمة المحاسبة					

السؤال الثالث: يمكن ان يتحقق التكامل بين تقنية البلوك تشين وتقنية التعلم الآلي من خلال:

العبارة	موافق تماماً	موافق	محايد	لا أوافق	لا أوافق تماماً
Q26 توفر تقنية البلوك تشين الثقة والخصوصية والمساءلة للتعلم الآلي					
Q27 يوفر التعلم الآلي قابلية التوسع والكفاءة والأمان للبلوك تشين .					
Q28 تعزيز امان البيانات الناتج عن التشفير واللامركزية حيث ان من خصائص البلوك تشين المتمثلة في تخزين البيانات في كتل امه ذات تجزئة تشفير تجعل من المستحيل تغيير المعلومات بمجرد تسجيلها ويضمن ان يكون نماذج التعلم الآلي امه .					
Q29 البلوك تشين يجعل من التلاعب بالبيانات شبه مستحيل.					
Q30 يساعد التعلم الآلي في نشر تطبيقات البلوك تشين والتنبؤ بإمكانية انتهاكات النظام.					
Q31 من خلال خاصيتي الشفافية وامكانية التتبع للبلوك تشين يمكن من انشاء تاريخ يمكن تتبعه لتطور نموذج التعلم الآلي بما يضمن سلامة النموذج وزيادة قدراته .					
Q32 تعزيز خصوصية البيانات عن طريق تشفير المعلومات الهامة وتمكين الوصول للكيانات المعتمدة المصرح بها فقط .					
Q33 يعد التعلم الآلي اداة قوية تعتمد علي كميات كبيرة من البيانات لانشاء النماذج وللقيام بالتنبؤ بدقة يحتاج الى وقت كبير وتتغلب تقنية البلوك تشين علي هذا في خفض الوقت المستغرق.					

أثر المعلومات المستمدة من تكامل سلاسل الكتل والتعلم الآلي كتقنيات للذكاء الاصطناعي في الكشف والتقرير ...
د/ حسين محمد سليمان & د/ شرين عبد الله عباس

السؤال الرابع: تساعد المعلومات المستمدة من التكامل بين تقنية البلوك تشين وتقنية التعلم الآلي في الكشف والتقرير عن الاحتيال المحاسبي من خلال:

العجارة	موافق تماماً	موافق	محايد	لا أوافق	لا أوافق تماماً
Q34 تعزيز قدرات إدارة المخاطر واكتشاف الاحتيال بشكل كبير					
Q35 دمج نظام التدقيق المدعوم بالتعلم الآلي في البلوك تشين يحمل إمكانات هائلة لتحويل مجال التدقيق من خلال الجمع بين شفافية البلوك تشين وثباتها واللامركزية مع القدرات التحليلية واثمة للتعلم الآلي .					
Q36 تعزيز امان البيانات الناتج عن التشفير واللامركزية حيث ان من خصائص البلوك تشين المتمثلة في تخزين البيانات في كتل امته ذات تجزئة تشفير تجعل من المستحيل تغيير المعلومات بمجرد تسجيلها ويضمن ان يكون نماذج التعلم الآلي امته .					
Q37 تتيح تقنية البلوك تشين تتبع كل معاملة حتى بدايتها ويتيح ولتعلم الآلي القدرة علي مساعدة المدقق علي ربط نتائج التقارير مع منشئها أنا لإزالة الخطأ او الكشف عن السلوك الاحتيالي والابلاغ عنه .					
Q38 يساعد التكامل في تقليل الوقت المخصص لعملية التدقيق عالية الجودة من خلال الحلول المستندة الى التعلم الآلي حيث تعتمد علي التحديد الفعال للاعلام الحمراء في الأرقام والابلاغ عنها بشكل موضوعي .					
Q39 توفير وسيلة تكنولوجية جديدة للتحكم في المعلومات المحاسبية ومراقبتها لتقليل عدم تناسق المعلومات.					
Q40 يمكن من معالجة التحديات التي تواجه ممارسات المحاسبة الحالية من تسجيل البيانات وتحديثها والتحقق من صحتها ومشاركتها بما يضمن تدقيق معزز للبيانات.					
Q41 يساعد التكامل في تحقيق ميزة مزدوجة حيث تقليل تكاليف المحاسبة وزيادة الدقة حيث تعمل تقنية البلوك تشين علي تسهيل جميع البيانات المالية وتحديثها في الوقت الفعلي.					
Q42 يدعم التكامل عمليات تدقيق أكثر كفاءة و وفعالية .					
Q43 يتيح التكامل اتمة المهام المتكررة مما يقلل من الجهد اليدوي ويزيد من الكفاءة التشغيلية .					
Q44 يؤدي تخزين البيانات علي البلوك تشين الى التخلص من مشكلات القيم المفقودة والتكرارات والوضوءاء والتي تعد مصادر شائعة للأخطاء في نماذج التعلم الآلي بما يضمن تعزيز دقة وموثقيه تنبؤات وتحليلات التعلم الآلي					