

جدوى الاستثمار في أدوات كشف الاحتيال المحاسبي المعتمدة على

الذكاء الاصطناعي: مدخل لقياس التكلفة والعائد

ورقة بحثية | أكتوبر 2026

أحمد هشام المحلاوي

ملخص

شراء أداة ذكية لكشف الاحتيال استثمار يُحكم عليه بميزان التكلفة والعائد، لا بقوة التقنية وحدها. تقترح الورقة مدخلًا بسيطًا لهذا القياس: تقدير الخسارة السنوية المتوقعة، وتحديد التكلفة الكاملة للأداة، ثم حساب العائد في ثلاثة سيناريوهات لنسبة تخفيض الخسارة وفحص نقطة التعادل. وفي مثال افتراضي تتعادل الأداة عند تخفيض 20% من الخسارة فقط، ويرتفع العائد أو ينخفض بحسب حجم الخسارة المتوقعة وعدد التنبيهات الكاذبة. وتظهر مراجعة الدراسات العربية أنها تقيس جودة الكشف والمراجعة ولا تحسب العائد النقدي، وهي فجوة تحاول الورقة الإسهام في سدها. وأرقام العائد في الورقة افتراضية لتوضيح الطريقة، وبيانات ACFE ارتباطية وخاصة بالرقابة الاستباقية على البيانات عمومًا لا بالذكاء الاصطناعي وحده.

المقدمة ومشكلة الورقة

الاحتيال مشكلة مكلفة فعلاً، والسؤال الذي يهم صاحب القرار هو: هل يغطي عائد أدوات الكشف الذكي تكلفتها؟ فقد سجل تقرير جمعية فاحصي الاحتيال المعتمدين (ACFE, 2026) نتائج 2,402 حالة احتيال وظيفي في 143 دولة، بلغ وسيط الخسارة فيها 104,000 دولار ومتوسطها 1,457,000 دولار، وتجاوزت الخسارة مليون دولار في نحو 20% من الحالات. غير أن الأداة الذكية ليست مجانية ولا مضمونة النتيجة، ولذلك يُحكم عليها بميزان التكلفة والفائدة كأى استثمار آخر.

وتتركز مشكلة الورقة في أن الدراسات العربية المتاحة تناولت فاعلية هذه الأدوات في تحسين الكشف والمراجعة أكثر مما تناولت جدواها الاقتصادية.

أسئلة الورقة

- ما عناصر تكلفة الاستثمار في أدوات كشف الاحتيال الذكية، وما مصادر العائد منها؟
- كيف تقدّر المنشأة العائد على هذا الاستثمار بطريقة منهجية قبل الشراء؟
- كيف تؤثر الافتراضات الأساسية، مثل نسبة تخفيض الخسارة وعدد التنبيهات الكاذبة، على جدوى الاستثمار؟

الهدف والمنهج

تهدف الورقة إلى اقتراح مدخل لقياس التكلفة والعائد وتوضيحه بمثال افتراضي، دون ادعاء اختبار فرضيات على بيانات فعلية. وتعتمد على منهج وصفي تحليلي يستند إلى تقرير ACFE وإلى دراسات منشورة عربية وأجنبية.

ما المقصود بأدوات الكشف الذكية؟

الأداة الذكية برنامج يتعلم من بيانات عمليات سابقة، بعضها معروف أنه احتيال وبعضها سليم، فيكتشف الأنماط التي تميز الاحتيال. ثم يفحص العمليات الجديدة ويعطي كل عملية درجة شك، وإذا ارتفعت الدرجة أرسل تنبيهًا لمحقق بشري يراجعها. وبهذا يفحص البرنامج آلاف العمليات التي لا يستطيع المراجع فحصها يدويًا، ويترك للإنسان الحالات المشتبها فيها فقط.

مثال توضيحي افتراضي: عميل تحويلاته المعتادة صغيرة ونهارية داخل مصر، ثم ظهر تحويل كبير في الثالثة فجرًا إلى دولة لم يتعامل معها من قبل. تعطي الأداة هذه العملية درجة شك عالية فتنبه المحقق، بينما تمر العمليات المعتادة دون تدخل.

وأشهر الأساليب التي تقوم عليها هذه الأدوات، كما رصدتها دراسة Ngai وآخرين (2011) في مراجعتها لتسعة وأربعين بحثًا منشورًا بين 1997 و2008، أربعة:

- **النماذج اللوجستية:** تحسب احتمال أن تكون العملية احتياليًا.
 - **الأشجار القرارية:** سلسلة أسئلة متتابعة تنتهي بقرار.
 - **الشبكات العصبية:** تتعلم أنماطًا معقدة من البيانات.
 - **شبكات بايز:** تحسب الاحتمالات بناءً على ما يُعرف عن العملية.
- ولاحظت الدراسة قلة الأبحاث عن احتيال الرهن العقاري وغسل الأموال.

علاقتها بالمحاسبة القضائية

تمثل الأداة دور الذكاء الاصطناعي في كشف الاحتيال، وهي تعمل بتحليل كميات كبيرة من العمليات (تحليلات البيانات المتقدمة)، ويمكن توجيهها إلى بيانات القوائم المالية لرصد مؤشرات التلاعب. وفي الدراسات العربية مثال على الأخيرة، إذ وجد أبو المعاطي (2023) في الشركات الصناعية المصرية المقيدة بالبورصة (125 مشاهدة بين 2019 و2022) أن تهديد الدخل المبني على تقديرات تنبأت بها خوارزميات التعلم الآلي يختلف معنويًا عن التمهيد المبني على التقديرات التقليدية.

تكلفة الأداة

لا تقتصر التكلفة على ثمن الترخيص، بل تشمل أربعة بنود:

- **الافتتاء والتشغيل:** الترخيص أو التطوير الداخلي، وربط الأداة بنظام المحاسبة وقواعد البيانات القائمة.
- **الكفاءات البشرية:** تدريب المحاسبين والمراجعين وتوظيف من يفهم تحليل البيانات. وقد أظهرت دراسة عبد الرضا (2026) أن نقص المهارات الفنية وضعف البنية التحتية من أهم عوائق التطبيق في شركات اتصالات عراقية، وهما بندان يُترجمان مباشرة إلى تكلفة.
- **معالجة التنبيهات الكاذبة:** كل تنبيه لا يكون احتياليًا يستهلك وقت محقق لفحصه. ويرى Psychoula وآخرون (2021) أن ارتفاع معدل التنبيهات الكاذبة مشكلة شائعة في نماذج كشف الاحتيال، وأن تفسير قرار النموذج بأساليب مثل LIME و SHAP يساعد المحللين على ترتيب أولويات الفحص.

- **تكلفة الخطأ نفسه:** لا يكلف الخطأ دائمًا بالقدر نفسه؛ فتقويت عملية احتيال كبيرة أعلى بكثير من فحص عملية سليمة، ولذلك اقترح Bahnsen وآخرون (2015) نماذج تراعي تكلفة كل خطأ عند التدريب بدل الاكتفاء بنسبة الأخطاء.

الفائدة المتوقعة

تأتي الفائدة الأساسية من اكتشاف الاحتيال مبكرًا فتقلل الخسارة. وتوضح بيانات (ACFE, 2026) الفرق بين المنشآت التي لديها رقابة استباقية على البيانات، وهي نحو 49% من المنشآت التي وقع فيها الاحتيال، وغيرها:

الجدول (1): الخسارة ومدة الاحتيال بحسب وجود رقابة استباقية على البيانات (ACFE, 2026)

المؤشر	منشآت لديها رقابة استباقية على البيانات	منشآت بدونها
وسيط الخسارة	70,000 دولار	150,000 دولار
وسيط مدة الاحتيال قبل كشفه	9 أشهر	16 شهرًا

أي أن الخسارة أقل بنحو 53% (فرق 80,000 دولار للحالة الوسيطة) والمدة أقصر بنحو 44%. وللفادة مصدر ثانٍ غير مباشر هو الردع: فإذا علم العاملون أن البيانات تُراقب بشكل مستمر قلَّ احتمال الإقدام على الاحتيال، لكن هذا الأثر يصعب قياسه نقدًا ولذلك لا يظهر عادةً في حسابات العائد.

تحفظان مهمان

1. هذه علاقة ارتباط وليست سببًا مؤكدًا، فقد تكون المنشآت التي تراقب بياناتها أكثر انضباطًا في الأصل.
 2. الأرقام تخص الرقابة الاستباقية على البيانات عمومًا وليست أدوات الذكاء الاصطناعي تحديدًا، ولم يظهر في تقرير ACFE ما يخصها، فلا يصح نسبتها إلى الذكاء الاصطناعي وحده.
- كما يبين التقرير أن وسائل الكشف التقليدية ما زالت الأهم: الإطلاعات أولاً بنسبة 43%، ثم المراجعة الداخلية 15%، ثم المراجعة الإدارية 13%. أي أن الأداة الذكية تُضاف إلى منظومة الكشف ولا تحل محلها.

الدراسات السابقة والفجوة البحثية

الدراسات العربية تقيس أثر الأدوات الذكية على جودة الكشف والمراجعة ولا تحسب التكلفة والعائد بالنقود. وتلخص الأسطر التالية أربع دراسات حديثة أُطلع على ملخصاتها المنشورة لا على نصوصها الكاملة:

- **مصر:** وجد القاضي (2025) في دراسة على 145 مشاهدة من الشركات المقيدة بالبورصة المصرية، استغرق جمع بياناتها نحو سبعة أشهر، أن تقنيات التعلم الآلي تحسّن كشف الاحتيال المحاسبي، وأن لها علاقة إيجابية دالة إحصائيًا بمراحل المراجعة الخارجية الأربع: قبول التكليف، والتخطيط، وجمع الأدلة، وإعداد التقرير. وتناولت الدراسة أيضًا مخاطر هذه التقنيات ومعوقات تطبيقها.
- **مصر (أتمتة العمليات):** توصل الموفي وآخرون (2025) في دراسة تجريبية على مراجعين في مكاتب مراجعة مصرية إلى أن أتمتة العمليات الروبوتية (RPA) تقلل الأعباء المتكررة والخطأ البشري وتزيد كفاءة الكشف عن الغش في القوائم المالية وتوفر الوقت والجهد.

- **العراق:** بيّنت دراسة عبد الرضا (2026) على 50 مراجعاً ومحاسباً في إدارات التدقيق الداخلي بأكبر ثلاث شركات اتصالات عراقية أن أدوات الذكاء الاصطناعي، وبخاصة تحليل البيانات الضخمة والتعلم الآلي، تحسّن جودة التدقيق وتقلل الخطأ البشري في تقييم المخاطر، وأن أهم العوائق نقص المهارات وضعف البنية التحتية.
 - **الجزائر:** تناولت بن علو وواضح (2025) دور الذكاء الاصطناعي في محاربة الغش المالي، وشددت على المخاطر الأخلاقية المتعلقة بالشفافية والتحيز في القرارات والتعامل مع البيانات المالية، ودعت إلى إطار تشريعي يوازن بين الفعالية والحماية القانونية.
- ويلخص الجدول التالي هذه الدراسات للمقارنة:

الجدول (2): مقارنة بين الدراسات العربية

الدراسة	البيئة والعينة	الأداة	أبرز ما توصلت إليه
القاضي (2025)	مصر، 145 مشاهدة من شركات مقيدة بالبورصة	التعلم الآلي	تحسّن كشف الاحتيال، وعلاقة إيجابية دالة بمراحل المراجعة
الموافي وآخرون (2025)	مصر، تجربة على مراجعين	أتمتة العمليات الروبوتية	تقليل الخطأ البشري وزيادة كفاءة الكشف
عبد الرضا (2026)	العراق، 50 مراجعاً ومحاسباً	تحليل البيانات الضخمة والتعلم الآلي	تحسّن جودة التدقيق، والعائق نقص المهارات والبنية التحتية
بن علو وواضح (2025)	الجزائر، دراسة نظرية	الذكاء الاصطناعي عمومًا	فعالية في الكشف مع مخاطر الشفافية والتحيز

ويجمع هذه الدراسات اتجاه واحد: الأدوات الذكية تحسّن الكشف، وتواجهها عوائق في المهارات والبنية التحتية ومخاطر في الشفافية والتحيز. والملاحظ، فيما اطلعنا عليه من ملخصاتها، أنها تقيس الأثر على جودة الكشف والمراجعة ولا تحسب التكلفة والعائد بالنقود، ومن هنا تأتي الزاوية التي تتناولها هذه الورقة.

مدخل القياس: معادلة العائد ومثال افتراضي

يُقاس العائد على الاستثمار بالمعادلة التالية:

$$\text{العائد على الاستثمار} = (\text{الفائدة} - \text{التكلفة}) \div \text{التكلفة}$$

والأرقام التالية افتراضية بالكامل، وضعت لتوضيح طريقة الحساب فقط، ولا تعبر عن شركة حقيقية ولا عن أداة بعينها:

الجدول (3): مثال افتراضي لحساب العائد على الاستثمار


البند (افتراضي)	القيمة بالجنيه
الخسارة السنوية المتوقعة من الاحتيال دون الأداة	2,000,000
التكلفة السنوية للأداة (ترخيص 150,000 + ربط 100,000 + تدريب 50,000 + معالجة التنبيهات 100,000)	400,000

البند (افتراضي)	القيمة بالجنيه
الفائدة عند نسبة تخفيض مفترضة 30%	600,000
العائد على الاستثمار $400,000 \div (400,000 - 600,000) =$	50%

حساسية النتيجة لنسبة التخفيض

المتغير الأهم في الحساب هو نسبة ما تخفضه الأداة فعلاً من الخسارة، وهي غير معروفة مسبقاً. ويبين الشكل التالي كيف يتغير العائد بتغيرها، مع ما يقابل نسبة ACFE من الفرق في وسيط الخسارة (53%)، وهي ارتباط وليست أثراً مؤكداً.

العائد يتحول من خسارة إلى ربح عند تخفيض 20% من الخسارة
الخسارة المتوقعة 2,000,000 جنيه، والتكلفة السنوية 400,000 جنيه (أرقام افتراضية)
أحمر: العائد سالب، أخضر: العائد موجب



الشكل (1): العائد على الاستثمار بحسب نسبة تخفيض الخسارة (أرقام افتراضية)

تتعادل الأداة عند تخفيض 20% فقط $(2,000,000 \div 400,000)$ ، ولا يمكن افتراض بلوغ نسبة ACFE نفسها. ويتوقف القرار كذلك على حجم الخسارة المتوقعة: فلو كانت الخسارة 800,000 جنيه بدل مليونين وبقي التخفيض 30%، لبلغت الفائدة 240,000 جنيه فقط والعائد -40%. ولا تتعادل الأداة عند تخفيض 30% إلا إذا بلغت الخسارة المتوقعة نحو 1,333,333 جنيه $(0.30 \div 400,000)$.

أثر التنبيهات الكاذبة على التكلفة

نفترض أن الأداة تنتج 4,000 تنبيه سنوياً وأن فحص التنبيه الواحد يكلف 25 جنيهاً، فيكون البند 100,000 جنيه في الجدول الأول. وتتغير تكلفة العثور على حالة احتيال حقيقية بحسب دقة الأداة (أرقام افتراضية):

الجدول (4): تكلفة الفحص لكل تنبيه صحيح بحسب دقة الأداة (افتراضي)

دقة الأداة	التنبيهات الصحيحة من 4,000	تكلفة الفحص لكل تنبيه صحيح
5%	200	500 جنيه
10%	400	250 جنيه
25%	1,000	100 جنيه

فكلما ارتفعت الدقة انخفضت تكلفة الوصول إلى الحالة الحقيقية. ونسبة 5% قريبة من الدقة التي ظهرت في الدراسة المنتقدة في القسم التالي، وهي مثال على أن الأداة قد تعمل بدقة ضعيفة دون أن يعني ذلك أنها عديمة القيمة، فالمهم هو مقارنة تكلفة فحص بقيمة الخسارة التي يمنعها كل اكتشاف.

شروط العائد والمخاطر

- العائد لا يتحدد بنوع الأداة وحدها، بل بعدة شروط، وهي تحليل من إعداد الباحث وليست نتيجة دراسة بعينها:
- **حجم الخسارة المتوقعة:** كلما ارتفع احتمال الاحتيال وحجمه، ارتفع العائد المحتمل من منعه مبكرًا.
 - **جودة البيانات:** الأداة تتعلم من بيانات المنشأة، فإن كانت ناقصة أو غير منتظمة ضعف الكشف.
 - **قدرة الفريق على التعامل مع التنبيهات:** مع نقص المهارات (كما في دراسة عبد الرضا 2026) قد تتراكم التنبيهات دون فحص.
 - **تفسير نتائج الأداة:** كلما أمكن تفسير القرار سهل على المحقق ترتيب أولوياته (Psychoula et al., 2021).
 - **الاستمرار في الوسائل التقليدية:** فالإبلاغات والمراجعة تظل أهم وسائل الكشف (ACFE, 2026).

مخاطر وحدود الأداة

- **ندرة الاحتيال تضعف الدقة.** في نقد (Walker 2021) لدراسة Bao وآخرين (2020) قُدرت نسبة الاحتيال بنحو 0.7% من سنوات الشركات، وبلغت دقة النموذج 4.5% (ونحو 2.5% بعد إعادة تشغيل الشيفرة بمعرفات الحالات الأصلية)، مقابل 2.63% لنموذج انحدار لوجستي بسيط، أي أن أغلب التنبيهات كانت كاذبة. وقد ردّ مؤلفو الدراسة الأصلية على هذا النقد (Bao et al., 2021)، فالمسألة محل جدل علمي.
- **الاعتماد على الإنسان باقٍ.** تظل الإبلاغات أول وسيلة للكشف، والأداة لا تغني عن ثقافة التبليغ والمراجعة.
- **المخاطر الأخلاقية والقانونية.** الشفافية والتحيز في القرارات وحماية البيانات المالية (بن علو وواضح، 2025).
- **حدود الأدلة المتاحة.** دراسة Ngai وآخرين (2011) سابقة على الأدوات الحالية، والدراسات العربية تعتمد على استبانات وعينات محدودة وتقيس الأثر المدرك أو جودة الكشف لا الأثر المالي، وأرقام العائد التي تنشرها شركات الأدوات دعائية ولا يُعتمد عليها هنا.

خطوات عملية لتقدير العائد قبل الشراء

هذه الخطوات مقترحة لتطبيق الفكرة عمليًا:

1. تقدير الخسارة السنوية المتوقعة من واقع حالات الاحتيال السابقة في المنشأة أو في قطاعها.
2. تحديد التكلفة الكاملة للأداة: الاقتناء والربط والتدريب ومعالجة التنبيهات.
3. تجربة الأداة على بيانات سابقة، ومعرفة نسبة ما كانت ستكتشفه من حالات معروفة وعدد التنبيهات الكاذبة التي تولدها.
4. حساب العائد بثلاثة سيناريوهات (متشائم ومتوسط ومتفائل) لنسبة التخفيض، وفحص موقع نقطة التعادل منها.
5. اتخاذ القرار ثم مراجعته سنويًا بالأرقام الفعلية: كم حالة اكتُشفت، وبأي مدة، وبأي تكلفة فحص.

الخلاصة

العائد على الاستثمار في أدوات كشف الاحتيال الذكية ليس مضموناً؛ فهو يرتفع حين تكون الخسائر المتوقعة كبيرة والبيانات منظمة وفريق الفحص قادراً على استيعاب التنبيهات، وينخفض حين تكثر التنبيهات الكاذبة أو تشتري الأداة دون استعداد. والدراسات العربية تؤيد فائدة الأدوات في تحسين الكشف لكنها لا تقدم حساباً نقدياً للعائد، وهذه فجوة يمكن للمحاسب القضائي أن يسدها بتقدير التكلفة والفائدة قبل اختيار الأداة، لا بالانبهار بالتقنية.

المراجع

المراجع العربية

أبو المعاطي، أحمد عيد محمد (2023). التنبؤ بالتقديرات المحاسبية باستخدام تقنيات تعلم الآلة وأثره على مستوى تمهيد الدخل: بالتطبيق على البيئة المصرية. المجلة المصرية للدراسات التجارية، 47(4)، 963-1004. DOI: alat.2023.330335/10.21608

بن علو، حورية، وواضح، حورية (2025). دور الذكاء الاصطناعي في محاربة الغش المالي. مجلة الإستراتيجية والتنمية، 15(2)، 322-342.

عبد الرضا، أحمد عقيل (2026). استعمال تقنيات الذكاء الاصطناعي في تدقيق الحسابات: إطار نظري وتطبيق عملي في شركات الاتصالات. مجلة الكوت للعلوم الاقتصادية والإدارية، 18(62)، 1115-1131.

القاضي، كريم محمد حافظ توفيق (2025). أثر تطبيق تقنيات التعلم الآلي على مراحل عملية المراجعة الخارجية للكشف عن الاحتيال المحاسبي: دليل عملي من الشركات المقيدة بالبورصة المصرية. المجلة العلمية للدراسات والبحوث المالية والإدارية، 17(1)، 83-149. DOI: 10.21608/masf.2025.416696

الموافي، إسراء إبراهيم الدسوقي، وسمرة، ياسر محمد عبد العزيز، وأبو جاد الله، حنان حسن (2025). أثر استخدام تقنية أتمتة العمليات الروبوتية في الكشف عن الغش بالقوائم المالية: دراسة تجريبية في البيئة المصرية. المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة جامعة دمياط، 6(2) الجزء 2، 1257-1294.

المراجع الأجنبية

Association of Certified Fraud Examiners (2026). Occupational Fraud 2026: A Report to the Nations. ACFE

Bahnsen, A. C., Aouada, D., & Ottersten, B. (2015). Example-dependent cost-sensitive decision trees. Expert Systems with Applications, 42(19), 6609-6619

Bao, Y., Ke, B., Li, B., Yu, Y. J., & Zhang, J. (2021). A response to «Critique of an article on machine learning in the detection of accounting fraud». Econ Journal Watch, 18(1), 71-78

Ngai, E. W. T., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. Decision Support Systems, 50(3), 559-569. DOI: 10.1016/j.dss.2010.08.006

Psychoula, I., Gutmann, A., Mainali, P., Lee, S. H., Dunphy, P., & Petitcolas, F. A. P. (2021). Explainable machine learning for fraud detection. arXiv:2105.06314

Walker, S. (2021). Critique of an article on machine learning in the detection of accounting fraud. Econ Journal Watch, 18(1), 61-70