

أثر الذكاء الاصطناعي على التأمين المعتمد على البيانات: دراسة تطبيقية باستخدام نماذج التعلم الآلي

عمر محبوب محمد الحسين

الشؤون المالية، الحرس الأميري، دولة قطر

omarmahjoub@gmail.com

المستخلص

هدفت هذه الدراسة إلى تحليل أثر تطبيق تقنيات الذكاء الاصطناعي في قطاع التأمين، مع التركيز على قياس دقة التنبؤ بالمخاطر، وتحديد العوامل المؤثرة على عدالة تسعير الأقساط، والحد من التحيز في القرارات التأمينية، بالإضافة إلى تقييم فعالية الذكاء الاصطناعي في كشف وتقليل الاحتيال التأميني. اعتمدت الدراسة منهجية كمية شملت نماذج الانحدار الخطي، وتحليل التباين (ANOVA)، واختبارات الدلالة الإحصائية (t-tests)، وذلك باستخدام بيانات لعينة من العملاء تتضمن متغيرات تقليدية ومتغيرات معتمدة على الذكاء الاصطناعي.

أظهرت النتائج أثراً ذا دلالة إحصائية لنماذج الذكاء الاصطناعي في تحسين دقة التنبؤ بالمطالبات وتحقيق عدالة أكبر في تسعير الأقساط، فقد أسهمت المتغيرات المعتمدة على الذكاء الاصطناعي في رفع القدرة التفسيرية للنماذج وتقليل الاعتماد على المتغيرات التقليدية المعرضة للتحيز. في المقابل، لم تثبت النتائج دلالة إحصائية واضحة لتأثير الذكاء الاصطناعي على الحد من الاحتيال التأميني؛ وهو ما يعزى إلى محدودية حجم العينة وطبيعة المتغير محل الدراسة.

خلصت الدراسة إلى أن الانتقال نحو التأمين المعتمد على البيانات يمثل توجهاً واعداً، شريطة تبني أطر حوكمة وتنظيم تكفل الشفافية والعدالة في استخدام الخوارزميات.

الكلمات المفتاحية: الذكاء الاصطناعي، التأمين المعتمد على البيانات، عدالة التسعير، التحيز الخوارزمي، الاحتيال التأميني.

The Impact of Artificial Intelligence on Data-Driven Insurance Systems: An Applied Study using Machine Learning Models

Omar Mahjoub Mohammed Al-Hussain

Financial Affairs, Amiri Guard, State of Qatar
omarmahjoub@gmail.com

Abstract

This study investigates the impact of artificial intelligence (AI) applications in the insurance sector, focusing on measuring risk prediction accuracy, Identifying the factors affecting installment pricing, and reducing bias in underwriting decisions, as well as evaluating AI's effectiveness in mitigating insurance fraud. A quantitative methodology was employed, including linear regression models, analysis of variance (ANOVA), and t-tests, based on a dataset comprising insurance customers and incorporating both traditional and AI-driven variables.

The findings indicate a statistically significant effect of AI-based models on improving claim prediction accuracy and achieving fairer premium pricing. AI-related variables enhanced the explanatory power of the models and reduced reliance on traditional variables prone to bias. However, the results did not provide conclusive evidence of AI's impact on reducing insurance fraud, likely due to data limitations and the characteristics of the fraud variable.

The study concludes that transitioning toward data-driven insurance is a promising approach, provided that governance and regulatory frameworks are implemented to ensure transparency and fairness in algorithmic decision-making.

Keywords: Artificial Intelligence, Data-Driven Insurance, Pricing Fairness, Algorithmic Bias, Insurance Fraud.

1. هيكل الدراسة

1.1 المقدمة

يشهد قطاع التأمين تحولاً رقمياً مستفيداً من البيانات الضخمة، والذكاء الاصطناعي، وإنترنت الأشياء بهدف تقديم سياسات تأمين فائقة التخصيص وأسعار ديناميكية، وإدارة استباقية.

اعتمد التأمين التقليدي على فئات متنوعة لتقدير المخاطر مثل: سنة صنع السيارة، وسعة الماكينة، والموقع، لكن الآن النماذج المدارة بالذكاء الاصطناعي تحلل بيانات الاتصال عن بعد، وكذلك الأجهزة القابلة للارتداد وتطبيقات الصحة الخاصة بمستويات اللياقة البدنية، وأجهزة الاستشعار المنزلي الخاصة بالحماية من مخاطر الحرائق والسرقة، والبيانات الخاصة بعادات وأنماط حياة الأفراد؛ هذا التغيير قد أدى إلى تغيير أساليب تقييم المخاطر، وتسعير الأقساط، وكشف حالات الاحتيال، وتجارب العملاء.

لا شك أن هناك تحديات ومخاوف أخلاقية حاضرة تتعلق بالخصوصية، فيما يتعلق بكمية البيانات الشخصية التي ينبغي للشركات الوصول إليها، والتحيز الخوارزمي المتمثل في قدرة الذكاء الاصطناعي على التمييز بناءً على عوامل لا تتميز بالخطورة، كذلك الامتثال التنظيمي في مجال اللوائح العامة لحماية البيانات، والقوانين، كذلك الإفراط في التخصيص؛ ونقصد بها مواجهة الأفراد المعرضين للمخاطر الذين قد يضطرون إلى دفع أقساط عالية فوق المعتاد. قد يجعل التخصيص القائم على البيانات أقل عدالة وكفاءة على العملاء، لكن لا يزال تحقيق التوازن بين الابتكار والخصوصية، والاختراع يعد أمراً بالغ الأهمية.

إن التحول الذي يشهده قطاع التأمين سوف ينقله من حالة التقديرات للتسعير الثابتة لأقساط التأمين لكل العملاء، إلى نماذج تسعير مخصصة مدعومة بالذكاء الاصطناعي.

2.1 مشكلة الدراسة وتسائلاتها

كيف غير الذكاء الاصطناعي نماذج شركات التأمين التقليدية، التي تعتمد على قواعد تقديرات ثابتة.

مشكلة الدراسة تتمثل في السؤال الآتي:

ما مدى تأثير استخدام الذكاء الاصطناعي في تحسين كفاءة ودقة التأمين المعتمد على البيانات مقارنة بالأساليب التقليدية؟

3.1 أسئلة الدراسة

- أ. كيف يؤثر الذكاء الاصطناعي على دقة تقييم المخاطر وتسعير الأقساط؟
- ب. ما مدى قدرة وفعالية خوارزميات الذكاء الاصطناعي في كشف الاحتيال، مقارنة مع الأساليب التقليدية؟
- ت. ما الآثار الأخلاقية والتنظيمية الناتجة على الاعتماد على البيانات بصورة كبيرة في التأمين؟
- ث. كيف يتغير تعريف المخاطر الانتقائية عندما تُستخدم مصادر بيانات جديدة "بيانات الإنترنت، البيانات السلوكية"؟
- ج. هل يتفوق نموذج التعلم الآلي على طرق التسعير التقليدية؟

4.1 فرضيات الدراسة

تفترض الدراسة الآتي:

- H1: نماذج الذكاء الاصطناعي المحسنة تزيد دقة التنبؤ بمعدل المطالبات بنسبة ذات دلالة إحصائية مقارنة بالنماذج التقليدية.
- H2: التأمين المعتمد على البيانات يؤدي إلى أقساط أكثر عدلاً للعملاء منخفضي المخاطر.
- H3: اعتماد بيانات بديلة في التقدير "سلوكية-جغرافية" يؤدي إلى تحيز وبالتالي يضر ببعض فئات العملاء.
- H4: استخدام الذكاء الاصطناعي يقلل من حالات الاحتيال التأميني.

5.1 أهداف الدراسة

تهدف هذه الدراسة إلى الآتي:

- أ. قياس الدقة في تقييم المخاطر وتسعير أقساط التأمين عند استخدام الذكاء الاصطناعي.
- ب. تحديد العوامل الرئيسية التي تؤثر على قرارات التسعير.
- ت. تقييم دور الخوارزميات في كشف الاحتيال.
- ث. تحديد المخاطر الأخلاقية والتنظيمية، وعرض توصيات لضمان العدالة والشفافية.

6.1 أهمية الدراسة

تتمثل أهمية الدراسة في أن الذكاء الاصطناعي يفترض أن يزيد من كفاءة التسعير وتقليل الخسائر، لكنه يثير قضايا عدالة الوصول، والتمييز الخفي، والخصوصية. فهم هذا الأثر مهم لصانعي القرار داخل شركات التأمين، والمشرعين.

7.1 منهج الدراسة وأدواتها

تعتمد هذه الدراسة على المنهج التحليلي التطبيقي عن طريق تحليل الأدبيات، بناء نموذج تطبيقي باستخدام بيانات تخيلية للعملاء، ثم تقييم أثر الذكاء الاصطناعي عبر مؤشرات كمية. أما في الجانب التطبيقي سوف يتم تطبيق نموذج تعلم آلي: مثل (Random Forest) أو (XG Boost) باستخدام عدة متغيرات، ثم مقارنة نتائج النموذج مع الأقساط الثابتة التقليدية.

8.1 حدود الدراسة

الحدود الموضوعية: بيانات تجريبية وليست فعلية، باستثناء أقساط التأمين الثابتة المحسوبة حسب سعة محرك السيارة.

2. الدراسات السابقة

استعرضنا في الدراسات السابقة مجموعة من البحوث التي تناولت موضوع الدراسة من زوايا متعددة.

1.2 دراسة (Fedorovych, Rykhalsky, & Poltavskiy, 2025)

هدفت هذه الدراسة إلى تحليل آفاق ومشاكل دمج الذكاء الاصطناعي في خدمات التأمين، كما هدفت إلى تحديد الاتجاهات الرئيسية لتطبيق تقنيات الذكاء الاصطناعي في إدارة المخاطر، وتحسين منتجات التأمين، ودراسة الجوانب القانونية والأخلاقية والتقنية لهذا التحول.

توصلت الدراسة إلى عدة استنتاجات: منها أن الذكاء الاصطناعي أداة رئيسية لتحسين أنشطة التأمين التي تشمل الاكتتاب، وتقييم المخاطر، ومعالجة المطالبات وخدمة العملاء بصورة شخصية؛ كذلك النمو المتوقع لسوق الذكاء الاصطناعي في قطاع التأمين يشير إلى زيادة مطردة في الاستثمار في هذا المجال، كما أن هناك تحديات عدة من ناحية حدوث أخطاء في معالجة البيانات، والحاجة إلى إنشاء آليات جديدة لمراقبة

امتثال للتقنيات للقوانين.

أوصت الدراسة بضرورة إحداث طرق منهجية لمواجهة التحديات، مما يعزز إمكانيات الذكاء الاصطناعي في قطاع التأمين وضمان استدامة تطوره، كذلك أشارت الدراسة إلى أن تطوير البنية التحتية، وتدريب الموظفين، والدعم التنظيمي تعد أموراً مهمة لضمان الاستخدام الفعال والعاقل للذكاء الاصطناعي في هذا القطاع.

تختلف هذه الدراسة عن دراسة الباحث في أنها قدمت تحليلاً لآفاق ومشاكل دمج الذكاء الاصطناعي في خدمات التأمين، ولكنها لم تتطرق إلى أثر الذكاء الاصطناعي على التأمين من ناحية دقة التنبؤ، وعدالة الأقساط، والتحيز والاحتيايل.

2.2 دراسة (Durant, McClure, Karunakaran, & Anderson, 2022)

هدف هذا البحث إلى تقييم كيفية إعادة تشكيل الذكاء الاصطناعي (AI) لصناعة التأمين من خلال تعزيز كفاءة الاكتتاب وتجربة العملاء ومعالجة التحديات الأخلاقية.

خلص البحث إلى مجموعة من الاستنتاجات منها أن الذكاء الاصطناعي يقلل بشكل كبير من وقت الاكتتاب، وأن الاعتبارات الأخلاقية، مثل خصوصية البيانات والتحيز الخوارزمي، ظهرت كتحديات ملحوظة، كذلك أكدت الاستنتاجات أن الذكاء الاصطناعي، لا يبسط العمليات فحسب، بل يعزز أيضاً تفاعلات العملاء الأكثر تخصيصاً وكفاءة.

خرج البحث بعدة توصيات: منها ضرورة تعزيز الشفافية ومراقبة التحيز، وثقيف العملاء بشأن الخدمات التي تعتمد على الذكاء الاصطناعي، والاستفادة من الذكاء الاصطناعي في الكشف عن الاحتيال والوقاية منه، والاستثمار في تقنيات التخصيص المعتمدة على الذكاء الاصطناعي.

يختلف هذا البحث عن دراسة الباحث في أنها قدمت تقييماً لكيفية إعادة تشكيل الذكاء الاصطناعي (AI) لصناعة التأمين من خلال تعزيز كفاءة الاكتتاب وتجربة العملاء ومعالجة التحديات الأخلاقية. ولكنها لم تتطرق إلى أثر الذكاء الاصطناعي على التأمين من ناحية دقة التنبؤ، عدالة الأقساط، التحيز والاحتيايل.

3.2 دراسة (Holland, 2022)

هدفت هذه الدراسة إلى تقديم تحليلات وتقييمات مفاهيمية مُفصلة لتكنولوجيا الذكاء الاصطناعي التي تضعها في سياق استراتيجي، وتدرس كيفية تكامل تطبيقات الذكاء الاصطناعي المختلفة وتكوين صورة

متماسكة، كذلك قدمت الدراسة حالة مُفصّلة لمجموعة شركة (BGL) باعتبارها شركة تأمين أوروبية رائدة، واستخدمت نموذجًا عامًا لعمليات وأعمال شركات التأمين لتنظيم التحليل، كما حددت الدراسة التوجه المُستقبلي المُحتمل للذكاء الاصطناعي في قطاع التأمين.

استخلصت الدراسة بعض الاستنتاجات العامة: منها أن النموذج الذي قدمته الدراسة لتدفق البيانات المُفصّل يعتبر طريقة تحليلية فعّالة، إذ يُوضح كيفية ارتباط أنظمة الذكاء الاصطناعي الفردية ببعضها البعض، ومدى ملاءمتها للعلاقة بين شركة التأمين والعميل، كذلك يُعدّ هذا السياق أساسيًا لاستكشاف ظواهر مهمة على مستوى أعلى: مثل التنفيذ، وخلق القيمة، والدور الحاسم للبيانات في جميع مراحل نموذج الأعمال. كما خلصت الدراسة إلى أن الذكاء الاصطناعي قد أحدث تحولاً جذرياً في قطاع التأمين، كذلك هناك ندرة في التحليلات والتقييمات المفاهيمية المُفصّلة لتكنولوجيا الذكاء الاصطناعي، وأن تبني شركة (BGL) الجانب الرقمي والتجريبي يؤدي إلى دورة اتخاذ قرارات سريعة لاعتماد الفكرة وتوسيع نطاقها أو رفضها، كما يتم تحديث البنية التحتية الرقمية باستمرار، مما يوفر مرونةً لأساليب العمل الجديدة والتقنيات الحديثة من خلال تجنب مشاكل الأنظمة القديمة والضخمة.

تختلف هذه الدراسة عن دراسة الباحث في أنها قدمت تحليلات وتقييمات مفاهيمية مُفصّلة لتكنولوجيا الذكاء الاصطناعي التي تضعها في سياق استراتيجي، ودرست كيفية تكامل تطبيقات الذكاء الاصطناعي. ولكنها لم تتطرق إلى أثر الذكاء الاصطناعي على التأمين من ناحية دقة التنبؤ، وعدالة الأقساط، والتحيز والاحتيال.

3. الإطار النظري

1.3 مفهوم الذكاء الاصطناعي:

يشمل الذكاء الاصطناعي مجموعة واسعة من التقنيات والأنظمة ذاتية التعلم والقابلة للتكيف. وتتميز هذه التقنية بقدرتها على محاكاة الإنسان، وتستخدم الخوارزميات لتحليل البيانات وإنشاء نماذج لوصفها (أو تسجيلها) للاستفادة منها بطرق متعددة.

يستخدم مصطلح الذكاء الاصطناعي للإشارة إلى مشروع تطوير أنظمة تحاكي القدرات العقلية للبشر، مثل التفكير المنطقي، وفهم المعنى، والتعلم من التجارب. منذ الأربعينيات بُرّجت الحواسيب الرقمية لأداء مهام معقّدة (مثل إثبات النظريات الرياضية أو لعب الشطرنج). رغم التقدّم في الحوسبة؛ لكن لا توجد برامج تضاهي مرونة العقل البشري بالكامل، إلا أن بعض البرامج قد بلغت مستوى أداء الخبراء البشريين في مهام

محددة، مثل التشخيص الطبي، والبحث الرقمي، والتعرف على الصوت أو الكتابة اليدوية، وبرامج المحادثة الآلية والترجمة.

عرفت الموسوعة البريطانية (Encyclopedia Britannica) الذكاء الاصطناعي (AI) بأنه "هو قدرة الحاسوب الرقمي أو الروبوت-المُتحكَّم به حاسوبياً- أداء مهام تُرتبط عادةً بالكائنات الذكية" (Copeland, 2025).

2.3 أنواع الذكاء الاصطناعي:

شهدت قدرات الذكاء الاصطناعي تطورًا متسارعًا منذ الاختراق العلمي الذي حققته الشبكات العصبية الاصطناعية في عام 2012م، ذلك الاختراق الذي أتاح للآلات القدرة على التعلم المعزز، ومحاكاة أسلوب معالجة عقل الإنسان للمعلومات. تطورت قدرات الذكاء الاصطناعي لتظهر عدة أنواع من الذكاء الاصطناعي بناءً على القدرات، وهناك ثلاثة أنواع من الذكاء الاصطناعي بناءً على القدرات وهي:

1.2.3 الذكاء الاصطناعي الضيق:

يُعرف الذكاء الاصطناعي الضيق (Artificial Narrow AI) أيضًا يطلق عليه الذكاء الاصطناعي الضعيف (Weak AI)، وهو النوع الوحيد من الذكاء الاصطناعي الموجود حاليًا من أنماط الذكاء الاصطناعي. ويصمم هذا النوع ليؤدي مهمة واحدة محددة أو مجموعة ضيقة من المهام، وغالبًا ما يتفوق في أدائها على القدرات البشرية من حيث السرعة والدقة. مع ذلك فإن قدراته تبقى محصورة داخل نطاق الوظائف التي تمت برمجته أو تدريبه عليها؛ فلا يستطيع التعلُّم أو الأداء خارج هذا الإطار المحدد. فهو يستهدف مجالًا معرفيًا واحدًا ويتقدم فيه دون امتلاك القدرة على التفكير الشامل أو الوعي أو الفهم الحقيقي.

من أبرز أمثلة الذكاء الاصطناعي الضيق Siri و Alexa من Amazon و IBM Watson، كذلك يعد ChatGPT من OpenAI يعد شكلاً من أشكال الذكاء الاصطناعي الضيق لأنه يقتصر على مهمة واحدة، وهي الدردشة النصية. ومع ذلك، لا يمكنه العمل خارج نطاق مهمته المحددة. بدلاً من ذلك، يستهدف مجموعة فرعية واحدة من القدرات المعرفية، ويتقدم في هذا النطاق.

2.2.3 الذكاء الاصطناعي العام:

يُعرف الذكاء الاصطناعي العام (AGI)، أيضًا بالذكاء الاصطناعي القوي، اليوم ليس أكثر من مفهوم نظري. يمكن للذكاء الاصطناعي العام استخدام المعارف والمهارات السابقة لإنجاز مهام جديدة في سياق مختلف

دون الحاجة إلى تدريب بشري للنماذج الأساسية. تُمكن هذه القدرة الذكاء الاصطناعي العام من التعلّم وأداء أية مهمة فكرية يستطيع الإنسان القيام بها.

3.2.3 الذكاء الاصطناعي الفائق:

يُشار إلى الذكاء الاصطناعي الفائق (ASI) عادةً باسم الذكاء الاصطناعي الفائق، وهو مثل الذكاء الاصطناعي العام، لكنه لا يزال مفهوماً نظرياً. وإذا ما تحقق ذلك، فسيفكر ويُعقل ويتعلم ويُصدر أحكاماً ويمتلك قدرات معرفية تفوق قدرات البشر.

ستتطور التطبيقات التي تمتلك قدرات الذكاء الاصطناعي الفائق إلى ما هو أبعد من مجرد فهم المشاعر والتجارب البشرية، لتشعر بالعواطف وتمتلك احتياجات ومعتقدات ورغبات خاصة بها.

3.3 أنواع الذكاء الاصطناعي الوظيفية:

هناك أربعة أنواع من الذكاء الاصطناعي مصنفة حسب الأداء الوظيفي، منها نوعان وظيفيان يندرجان تحت الذكاء الاصطناعي الضيق هما:

1.3.3 الذكاء الاصطناعي الآلي التفاعلي:

تعد الآلات التفاعلية أحد أبسط أشكال الذكاء الاصطناعي، إذ تعمل دون ذاكرة ولا تمتلك القدرة على تخزين التجارب أو نتائج القرارات السابقة. وهي مصممة لأداء مهمة محددة بدقة اعتماداً على البيانات المتاحة في لحظة أداء مهامها. ونظراً لغياب الذاكرة، فإن هذه الأنظمة لا تتعلم من التجارب ولا تطور أداءها بمرور الوقت. يستند هذا النوع من الذكاء الاصطناعي في أداء مهامه إلى الأسس الرياضية والإحصائية؛ مما يمكنه من معالجة كميات ضخمة من البيانات وتحليلها لإنتاج مخرجات تبدو ذكية، رغم محدودية قدراته بالمقارنة مع الأنواع الأكثر تطوراً من الذكاء الاصطناعي.

2.3.3 الذكاء الاصطناعي محدود الذاكرة:

على خلاف الآلات التفاعلية التي تفتقر إلى الذاكرة، يمتلك الذكاء الاصطناعي محدود الذاكرة القدرة على الاستفادة من بيانات الماضي إلى جانب البيانات الحالية من أجل اتخاذ قرارات أفضل، فهو قادر على تذكر أحداث أو حالات سابقة لفترة زمنية قصيرة، ومراقبة سلوكيات أو مواقف معينة عبر الزمن؛ مما يمكنه من اختيار مسار العمل الأكثر احتمالاً لتحقيق النتيجة المطلوبة.

ومع ذلك، فإن قدرة هذا النوع من الذكاء الاصطناعي على الاحتفاظ بالبيانات تبقى محدودة مؤقتًا؛ إذ أنه لا يستطيع بناء قاعدة من التجارب السابقة كما يفعل البشر لاستخدامها على المدى الطويل. لكنه مع تزويده المستمر بالبيانات وتدريبه عليها، يملك القدرة على تحسين أدائه تدريجياً مع مرور الوقت.

3.3.3 الذكاء الاصطناعي الواعي بذاته:

يُعدّ الذكاء الاصطناعي الواعي بذاته أحد أكثر أشكال الذكاء الاصطناعي تقدماً من الناحية النظرية، ويندرج ضمن الفئات الوظيفية التي تُفترض لها قدرات معرفية فائقة تتجاوز ما هو موجود حالياً. وعلى غرار الذكاء الاصطناعي القائم على نظرية العقل، فإن هذا النوع ما يزال افتراضياً بالكامل ولم يُثبت وجوده في أي تطبيق عملي حتى الآن.

ويُتوقع - نظرياً - أن يمتلك الذكاء الاصطناعي الواعي بذاته القدرة على فهم حالته الداخلية وخصائصه الذاتية، إلى جانب القدرة على إدراك وتفسير مشاعر البشر وأفكارهم ونواياهم؛ بل إن بعض التصورات تشير إلى إمكانية امتلاكه مجموعة خاصة من المشاعر والمعتقدات؛ الأمر الذي يجعله أقرب إلى شكل من الوعي الذاتي المشابه للبشر، رغم أن هذا الاحتمال لا يزال محل جدل علمي واسع.

4.3.3 الذكاء الاصطناعي العاطفي:

الذكاء الاصطناعي العاطفي يُعد امتداداً لمفهوم الذكاء الاصطناعي القائم على نظرية العقل، وهو من المجالات قيد التطوير الفعلي في الوقت الراهن. ويهدف الباحثون إلى تمكينه من تحليل الأصوات والصور والإشارات المتنوعة للتعرف على المشاعر البشرية ومحركاتها ومراقبتها والاستجابة لها بطريقة ملائمة.

ومع ذلك، ورغم التقدم المحرز، لا يزال الذكاء الاصطناعي العاطفي غير قادر على فهم المشاعر الإنسانية بصورة حقيقية أو التفاعل معها بعمق معرفي، مما يجعله في مرحلة ما قبل النضج التقني.

4.3 التعلم الآلي والتعلم العميق:

1.4.3 التعلم الآلي:

يشير التعلّم الآلي إلى عملية تحسين أداء أنظمة الحاسوب، من خلال اكتساب الخبرة الناتجة عن التعامل المتكرر، مع فئة محددة من المهام ووفق مقاييس أداء واضحة. ويهدف هذا المجال إلى أتمتة بناء النماذج التحليلية اللازمة لتنفيذ مهام معرفية مثل: اكتشاف الكائنات أو ترجمة اللغة الطبيعية، وذلك عبر استخدام

خوارزميات تتعلم بصورة متكررة من بيانات التدريب الخاصة بالمشكلة محل الدراسة. وعن طريق هذه العملية، تتمكن الأنظمة من اكتشاف أنماط خفية وعلاقات معقدة داخل البيانات، من دون الحاجة إلى برمجة صريحة لكل خطوة. يُظهر التعلّم الآلي قدرة عالية على التعامل مع البيانات متعددة الأبعاد في مهام مثل التصنيف، والانحدار، والتجميع. فمن خلال التعلّم من النتائج الحسابية السابقة واستنباط السمات المشتركة من قواعد البيانات الضخمة، يصبح النظام قادرًا على تقديم قرارات دقيقة وقابلة للتكرار. ولهذا السبب، أثبتت خوارزميات التعلّم الآلي نجاحًا واسعًا في العديد من المجالات، بما في ذلك كشف الاحتيال، وتقييم الجدارة الائتمانية، وتحليل العروض المثلى، والتعرف على الكلام والصور، ومعالجة اللغة الطبيعية. بناءً على طبيعة المشكلة والبيانات المتوفرة، تُصنّف خوارزميات التعلّم الآلي في ثلاث فئات رئيسية - والتعلّم المُشرف، التعلّم غير المُشرف، والتعلّم المُعزّز. تُعد خوارزميات التعلّم المُشرف الأكثر استخدامًا في الأسواق الإلكترونية، حيث تُوظّف للتنبؤ بحركة أسواق الأسهم، وفهم تصورات العملاء، وتحليل احتياجاتهم، وتحسين عمليات البحث عن المنتجات. كما توجد تطبيقات معروفة للنوعين الآخرين، مثل صناعة السوق باستخدام التعلّم المُعزّز، وتجزئة السوق باستخدام التعلّم غير المُشرف اعتمادًا على تقييمات العملاء (Janiesch, Zschech, & Heinrich, 2021).

2.4.3 التعلّم العميق:

يُعدّ التعلّم العميق أحد الفروع المتقدمة للتعلّم الآلي، ويتميّز باستخدامه طبقات متعددة من وحدات المعالجة لاستخلاص تجريدات (مفاهيم) معقدة من البيانات. ويتم ذلك عبر بناء تسلسل هرمي من مستويات التمثيل؛ إذ يعتمد كل مستوى تجريد على التجريدات الأبسط التي تعلمها المستوى السابق، مما يمكن النموذج من فهم المفاهيم المعقدة عبر تجميع مفاهيم بسيطة ومتدرجة.

تتضمن نماذج التعلّم العميق طبقات حسابية متعددة بين المدخلات والمخرجات، تنتج عنها تحويلات خطية وغير خطية متعاقبة؛ وتعمل هذه الطبقات على استخراج سمات البيانات على مستويات مختلفة، بحيث يعبر كل مستوى من السمات عن درجة أعلى من التجريد مقارنة بالمستوى الذي قبله. وبشكل مبسّط، يمكن النظر إلى نموذج التعلّم العميق على أنه سلسلة من التحويلات الرياضية المتتابة التي تربط فضاء متجهات الإدخال بفضاء متجهات الإخراج، بالاعتماد على كمية كبيرة من بيانات التدريب.

تتطلب عملية تعلّم هذه التحويلات تقدير مجموعة كبيرة من المعلمات مثل: الأوزان والانحيازات، والتي تُحدّث بشكل تكراري باستخدام خوارزميات تحسين تعتمد غالبًا على الانحدار التدريجي (Gradient-

(Based Optimization). ونظرًا لتعقيد هذه النماذج وكثافة عدد معلماتها، فإنها تحتاج عادةً إلى كمية ضخمة من البيانات حتى تعمل بكفاءة.

على خلاف أساليب التعلّم الآلي التقليدية، لا يحتاج التعلّم العميق إلى هندسة ميزات بشرية الصنع، وذلك بفضل قدرته على تعلّم الميزات تلقائيًا عبر مستوياته الهرمية. وتسمح هذه القدرة للنموذج بتكوين خصائص عالية المستوى انطلاقًا من خصائص منخفضة المستوى، مما يتيح له تعلم دوال معقدة مباشرةً من البيانات، دون الحاجة إلى تدخل الإنسان في تصميم الميزات (Misr & Li, 2020)؛ لهذا، أصبح التعلّم العميق من أكثر الأساليب شيوعًا للتعامل مع البيانات غير المنظمة، مثل: الصور والفيديو، الصوت والكلام، النصوص واللغات الطبيعية، البيانات الطبية، البيانات الوصفية والبيانات التناظرية، ألعاب الفيديو.

5.3 أثر البيانات على تطبيقات الذكاء الاصطناعي:

تؤثر كمية البيانات وجودتها على الأنظمة القائمة على الذكاء الاصطناعي؛ لذلك ظهر ما يعرف بالذكاء الاصطناعي المُركّز على البيانات "Data-Centric AI" الذي روج له (Andrew Ng)¹ في سلسلة من ورش العمل، وذلك بدلاً من مفهوم الذكاء الاصطناعي المرتكز على النموذج "Model-Centric AI" الذي يركز على اختيار نوع النموذج المناسب والهندسة المعمارية والمعلمات الفائقة من مجموعة واسعة من الاحتمالات لبناء أنظمة فعالة وكفؤة تعتمد على الذكاء الاصطناعي. جاء نموذج "Data-Centric AI" لتطوير أفضل الأساليب والأدوات والممارسات، لتصميم البيانات بشكل منهجي، ولهندسة جودة البيانات وكميتها لتحسين أداء الأنظمة القائمة على الذكاء الاصطناعي (Malerba & Pasquadibisceglie, 2024) p507. لا شك أن تطوير نماذج البيانات يأتي بسبب أهمية البيانات لتطبيقات الذكاء الاصطناعي واعتماده عليها في تطوير مخرجاته. يعتمد اختيار نوع البيانات لتطبيقات الذكاء الاصطناعي على الغرض ومتطلباته؛ لذلك لا يوجد حل واحد يناسب جميع الأغراض. في بعض الحالات، تكون البيانات المُولدة من قبل البشر أكثر ملاءمة، كما هو الحال عندما يحتاج نموذج الذكاء الاصطناعي إلى فهم البشر أو التفاعل معهم أو حتى محاكاتهم. في حالات أخرى، تكون البيانات المُولدة آليًا أكثر ملاءمة، كما هو الحال عندما يحتاج نموذج الذكاء الاصطناعي إلى تحسين العمليات أو مراقبتها أو أتمتتها. في كثير من الحالات، يكون الجمع بين كلا النوعين من البيانات هو الأمثل، كما هو الحال عندما يحتاج نموذج الذكاء الاصطناعي إلى تحسين البيانات البشرية أو

¹ عالم حاسوب وباحث متخصص في مجال الذكاء الاصطناعي، وعالم حاسوب، وأستاذ جامعي، ورائد أعمال.

استكمالها أو التحقق منها. فيما يلي بعض الأمثلة على تطبيقات الذكاء الاصطناعي التي تستخدم أنواعًا مختلفة من البيانات (Maroto, 2025):

1.5.3 الذكاء الاصطناعي التوليدي:

يهدف إلى إنشاء محتوى أو بيانات جديدة من بيانات موجودة، مثل الصور والنصوص والموسيقى والرموز البرمجية. يستخدم الذكاء الاصطناعي التوليدي غالبًا البيانات المُولدة من قبل الإنسان والبيانات المُولدة آليًا.

2.5.3 تحليل المشاعر:

يهدف إلى تحديد واستخراج الحالة العاطفية أو السلوكية لشخص أو مجموعة من الأشخاص من النصوص أو الكلام أو الصور. يعتمد تحليل المشاعر بشكل أساسي على البيانات المُولدة من قبل البشر، مثل منشورات مواقع التواصل الاجتماعي، والمراجعات، والتعليقات، والاستطلاعات، كمدخلات، كما يُمكنه أيضًا استخدام البيانات المُولدة آليًا، مثل: المعاجم، والأنطولوجيات، والنماذج، كموارد أو أدوات.

3.5.3 كشف الاحتيال:

يهدف كشف الاحتيال إلى منع وكشف الأنشطة أو المعاملات الاحتيالية والحد منها في مختلف المجالات، مثل: الخدمات المصرفية والتأمين والتجارة الإلكترونية والرعاية الصحية. يعتمد كشف الاحتيال بشكل أساسي على البيانات المُولدة آليًا، مثل: سجلات المعاملات وسجلات الشبكة وقراءات أجهزة الاستشعار، كمدخلات. كما يُمكنه أيضًا استخدام البيانات المُولدة بشريًا، مثل: ملفات تعريف العملاء أو ملاحظاتهم أو تقاريرهم، كمعلومات تكميلية أو سياقية .

6.3 الذكاء الاصطناعي وتحليل المخاطر:

تعرف المخاطر بأنها مقياس لمدى تعرض المؤسسة لتهديد محتمل ناجم عن ظرف أو حدث معين، وهي تمثل علاقة تعتمد على عاملين أساسيين: أثر الحدث في حال وقوعه واحتمال وقوعه. ويتطلب تقييم المخاطر إجراء تحليل شامل لمعلومات التهديدات والثغرات لتحديد حجم التأثيرات السلبية المحتملة على المؤسسة، فضلاً عن تقدير درجة احتمالية حدوث هذه التهديدات.

يتضمن التقييم النوعي للمخاطر مجموعة من الاعتبارات، مثل: نتائج التدقيق، واختبارات التحمل،

والتغيرات التي تطرأ على بيئة المخاطر نتيجةً لمبادرات التغيير المؤسسي. أمّا التقييم الكمي، فيعتمد على تحليل مؤشرات الرقابة والمخاطر الرئيسية والحوادث المسجلة، سواء كانت داخلية أو خارجية.

تُعدّ تقييمات المخاطر عنصرًا محوريًا في إدارة المخاطر الفعّالة، إذ تزوّد صانعي القرار بفهم شامل ودقيق للمخاطر المحتملة التي قد تواجه المؤسسة؛ غير أنّ دقة هذه التقييمات كانت تقليديًا، تعتمد بدرجة كبيرة على جودة البيانات المتاحة، وعلى مهارات وخبرة القائمين بإجراء التقييم.

لتحقيق تقييمات أكثر موضوعية ودقة؛ يمكن توظيف الذكاء الاصطناعي، إذ يمتلك قدرات فائقة في جمع البيانات وتحليلها واستخلاص الأنماط، مما يجعله أداة فعّالة لتعزيز جودة تقييم المخاطر وتحسين موثوقيتها (Chan, 2023).

1.6.3 تقنيات الذكاء الاصطناعي في تقييم المخاطر:

تعدّ تقنيات الذكاء الاصطناعي ذات فاعلية عالية في تقييم المخاطر، نظرًا لقدرتها على اكتشاف التهديدات وتحليلها والاستجابة لها بسرعة تفوق الأنظمة التقليدية. فالأدوات المدعومة بالذكاء الاصطناعي، مثل: تحليلات سلوك المستخدم والحدث (UEBA)، تستطيع رصد أي شذوذ في الأنماط السلوكية مما قد يُشير إلى محاولة اختراق غير معروفة المصدر؛ ومن ثم تحليلها والاستجابة لها بصورة تلقائية ودقيقة. ويُسهّم ذلك في تقليل معدل التقييمات الخاطئة الذي يشكّل إحدى أبرز الإشكاليات في أدوات الكشف التقليدية.

يُسهّم الذكاء الاصطناعي كذلك في تحسين دقة تقييم المخاطر من خلال قدرته على تحديد أولويات الثغرات الأمنية ووضعها في سياقها التشغيلي الصحيح. فعلى سبيل المثال، قد يمثل أحد الأصول التقنية القديمة خطرًا محتملاً، إلا أنه قد يُهمل عند استخدام النظم التقليدية. أمّا أنظمة الذكاء الاصطناعي، فيمكنها تقييم المخاطر والإجراءات المتخذة لمواجهةها بصورة مستقلة، مما يمكنها من تحليل عناصر المخاطر تحليلًا مقارنًا، وربطها ببعضها البعض، الأمر الذي يؤدي إلى تقديرات أكثر دقة وموضوعية (SentinelOne, 2025).

2.6.3 الاعتبارات النوعية والتحليل التنبؤي:

يمتلك الذكاء الاصطناعي القدرة على تحليل البيانات غير المنظمة واستخلاص الأنماط المرتبطة بالحوادث السابقة، ثم تحويل هذه الأنماط إلى مؤشرات كمية ونوعية للمخاطر. وبمجرد اكتشاف الاتجاهات وأنماط

السلوك المتكررة في البيانات، يمكن للأنظمة الذكية بناء سيناريوهات استشرافية تُمكن من التنبؤ بالأحداث المستقبلية، وتقييم مخاطر المشروع بدرجة عالية من الدقة.

يُساهم الذكاء الاصطناعي في تعزيز شفافية العلاقة بين العمليات التشغيلية والمخاطر، من خلال تحويل البيانات المعقدة إلى رؤى واضحة وقابلة للتفسير. ومع ارتفاع مستوى شفافية البيانات، يصبح من الممكن تقييم ضوابط المخاطر، وقياس مدى كفايتها؛ مما يساعد المؤسسات على اتخاذ الإجراءات التصحيحية المناسبة للحد من المخاطر وتعزيز استمرارية الأعمال (Boulwood, 2020).

3.6.3 التحليل الكمي وتحسين معالجة الأدلة:

تُستخدم أجهزة إنترنت الأشياء (IoT) اليوم في تنفيذ عمليات التحقق الآلي من الأدلة وفحص الضوابط بصورة استباقية، بعد أن أصبحت جزءًا متكاملًا من وظائف ضمان الجودة في المؤسسات. فقد أُدمجت أجهزة إنترنت الأشياء القادرة على استشعار الأحداث والأفراد والتعرف عليهم في العديد من البيئات التشغيلية؛ فعلى سبيل المثال: تُستخدم بطاقات الهوية البيومترية للتحكم في الدخول إلى مراكز البيانات، بينما تراقب أنظمة التعرف على الوجوه حركة الأفراد داخل تلك المراكز، وتعمل أنظمة تحليل السجلات على فحص سجلات الخوادم للكشف عن أي تجاوز للصلاحيات.

أما في سياق التدقيق، يمكن للمدقق الذي يُجري تدقيق تقارير ضوابط النظام والتنظيم (SOC 2) الاستفادة من أنظمة مدعومة بتقنيات التعلم الآلي، تعمل على تجميع البيانات من أنظمة مراقبة مختلفة واستخدامها كأدلة على تنفيذ المهام. كما يمكن استغلال الشذوذ المكتشف في البيانات كدليل إضافي. ورغم قدرة أنظمة الذكاء الاصطناعي على تحليل البيانات غير المهيكلة واستخلاص الأنماط، إلا أن الدور البشري يظل أساسيًا، إذ يقع على المدقق مسؤولية تحديد معايير التقييم المناسبة. فالمُدققون هم الأكثر دراية بطبيعة البيانات؛ ولذلك يحتاجون إلى مهارات متقدمة لإدارتها بكفاءة، إضافة إلى ضرورة استخدام تقنيات تصور البيانات لعرض النتائج على الأطراف المعنية. وهكذا يتطور دور المدقق من مجرد مراجع إلى مفسر لنتائج أنظمة الذكاء الاصطناعي.

4.6.3 اعتماد الذكاء الاصطناعي كأداة لتقييم المخاطر الديناميكية:

عند إجراء تقييمات المخاطر، ينصبّ التركيز عادةً على مدى كفاية الضوابط وفعاليتها. غير أن التنبؤ بوجود ضوابط قد تم تجاهلها قبل ظهور نتائج التدقيق ظلّ يمثل تحديًا كبيرًا لمُقيمي المخاطر. ومع تطور تقنيات

الذكاء الاصطناعي، أصبح بالإمكان دمج القياسات الآلية داخل الأنظمة المدعومة بالذكاء الاصطناعي، الأمر الذي يُعزّز القدرة على التنبؤ الدقيق بالنتائج المتوقعة والتحقق الفوري من مدى اتساق القيم الفعلية مع التوقعات. ويمثل هذا النهج شكلاً مبتكراً من التحقق من الضوابط، يتسم بكونه استباقياً بدلاً من أن يكون مجرد رد فعل.

لم يعد مديرو المخاطر والمدققون مُجبرين على الاعتماد فقط على الأدلة المُقدمة. فبفضل خوارزميات مثل التعلم العميق، يمكن استخلاص معلومات ذات قيمة من كمّ هائل من المصادر المتنوعة، مثل: العقود، والمكالمات الجماعية، ورسائل البريد الإلكتروني، واستخدامها كأدلة داعمة. وعند ورود بيانات مُحدّثة، يستطيع نظام الذكاء الاصطناعي تحليلها لحظياً وتحويلها إلى معلومات قابلة للتنفيذ. ومن خلال خوارزميات التعلم العميق، يمكن لنظام المراقبة المستمرة للضوابط إعادة تكوين نفسه استناداً إلى التغذية الراجعة من نتائج سابقة؛ وبذلك يضمن تصميم الضوابط وتكوينها وتنفيذها بصورة مثلى مع أقل قدر من التدخل البشري.

يُعدّ نوع البيانات ومصادرها عنصراً حاسماً لنجاح هذه الأنظمة، إذ يُؤثر توفر البيانات وجودتها بشكل مباشر في جودة المخرجات. كما أن بناء نظام بيئي متكامل للذكاء الاصطناعي يتطلب حرصاً على مستوى العمليات التشغيلية كافة. وكما هو الحال مع أية أداة من أدوات إدارة المخاطر، يجب تقييم أنظمة الذكاء الاصطناعي وتحديثها باستمرار لضمان استمرار فعاليتها (Bevin, 2021).

7.3 التأمين المعتمد على البيانات:

أحدثت التقنيات والتقنيات الصناعية المبتكرة ثورةً في عمليات سلسلة التأمين التأمينية المدمجة من تطوير المنتجات، مروراً بالمبيعات، والاكتتاب، والتسعير، وصولاً إلى المطالبات. يُعدّ التأمين القائم على البيانات نموذج أعمال شامل ومتكامل، قادراً على الإسهام في تحقيق أهداف استراتيجية جوهرية في قطاع التأمين. ويمكن لتطبيق تقنيات الذكاء الاصطناعي عن طريق تحليل البيانات أن تُحدث نقلة نوعية في تصميم منتجات التأمين وتقديم خدماته، من خلال تحسين القدرة على التنبؤ بالمخاطر وتعزيز كفاءة اتخاذ القرار. ويمتد أثر تطبيق التأمين القائم على البيانات والذكاء الاصطناعي ليشمل المنظومة التأمينية بأكملها، بما في ذلك الموارد البشرية والشركاء الرئيسيين، الأمر الذي يجعل نجاح هذا التحول مرهوناً بتبني نهج إداري متكامل يبدأ من المستويات العليا للإدارة. ولا ينبغي النظر إلى هذا التحول من منظور تكنولوجي ضيق يقتصر على كونه مجرد تطبيق تقني، بل يجب التعامل معه بوصفه مهمة إدارية واستراتيجية عليا تتطلب إعادة هيكلة

العمليات المؤسسية، وتطوير الثقافة التنظيمية، وضمان التكامل بين التكنولوجيا والحوكمة. وعليه، فإن الذكاء الاصطناعي لا يُعد بديلاً للإدارة الرشيدة، وإنما أداة داعمة لها ضمن إطار التأمين القائم على البيانات (Eling, Nuesle, & Staubli, 2022).

1.7.3 مفهوم التأمين القائم على البيانات:

التأمين القائم على البيانات (Data-Driven Insurance) هو نموذج أعمال على مستوى المؤسسة، يُحقق ميزة استراتيجية في منظومة التأمين. ويمكن أن يؤدي استخدام الذكاء الاصطناعي المُبتكر لتحليل البيانات إلى الابتكار في العمليات التشغيلية وتطوير منتجات وخدمات جديدة. وقد كان للذكاء الاصطناعي والتقنيات المرتبطة به تأثيرٌ كبير على العمليات عبر سلسلة قيمة التأمين، بدءًا من تطوير المنتجات، مرورًا بالمبيعات، والاكتمال، والتسعير، وصولًا إلى المطالبات. بالإضافة إلى ذلك، يُحدث الذكاء الاصطناعي تحولًا جذريًا في منتجات وخدمات التأمين من خلال تأثيره على التأمين القائم على الاستخدام، والتأمين الفوري، والتأمين المُدمج. ومع ذلك، لكي يُطبّق التأمين القائم على البيانات بنجاح واستدامته، لا بد من وجود قيادة تنازلية/تصاعدية. يُساعد هذا النهج على ضمان الاستخدام الاستراتيجي للبيانات الحالية أو المُكتسبة حديثًا، والتطبيق الموسّع لخوارزميات الذكاء الاصطناعي الحديثة، والتحول المُخطط له جيدًا في قطاع التأمين (CGI, 2023).

2.7.3 نماذج التسعير التقليدية مقابل التسعير الديناميكي:

يُعد التسعير الديناميكي أحد أكثر التطبيقات المتقدمة للذكاء الاصطناعي في قطاع التأمين. فعلى خلاف نماذج التسعير التقليدية التي تعتمد على البيانات التاريخية وفئات المخاطر العامة، يستخدم التسعير الديناميكي بيانات آنية وتحليلات تنبؤية لتعديل الأقساط بصورة دقيقة تعكس الأنماط الفعلية للمخاطر وظروف السوق. ويحقق هذا النهج فوائد متبادلة؛ إذ يمكّن شركات التأمين من تحسين الإيرادات وتقليل التعرض للمخاطر، بينما يحصل العملاء على أقساط أكثر عدالة ومواءمة لسلوكهم الفردي، ودرجة تعرضهم الفعلية للمخاطر (Thomas, 2017).

1.2.7.3 نماذج التسعير التقليدية:

تعتمد نماذج التسعير التقليدية في صناعة التأمين على منهجيات ثابتة وواسعة النطاق، تركز أساسًا على نموذج التكلفة المضافة، والمتوسطات الإحصائية لمجموعات كبيرة من البيانات التاريخية، إضافةً إلى

الجدول الاكتوارية والعوامل الديموغرافية مثل العمر، والموقع الجغرافي، وطرز المركبة. كما تستند إلى بيانات مقارنة أداء المنافسين ودراسات السوق الدورية لتحديد أقساط موحدة وثابتة تُطبق على فئات واسعة من المؤمن لهم.

وتتسم هذه النماذج بأن الأقساط فيها ثابتة لفترة محددة -غالبًا لمدة عام كامل لوثائق التأمين- ولا تتغير بغض النظر عن التغيرات في سلوك الفرد أو مستوى مخاطره الفعلية خلال مدة الوثيقة. وتعتمد هذه النماذج على فرضية مفادها وجود استقرار نسبي في ظروف السوق والتجانس داخل فئات المخاطر؛ مما يجعلها غير قادرة على رصد التغيرات اللحظية في الطلب أو السلوك الاستهلاكي.

أولاً: مزايا التسعير التقليدي:

- أ. البساطة: يعتمد على منهجيات واضحة وسهلة الفهم لكل من شركات التأمين والعملاء.
- ب. القدرة على التنبؤ: يمنح العملاء وضوحًا عاليًا بشأن التكلفة، إذ تبقى الأقساط ثابتة طوال مدة الوثيقة.
- ت. استقرار تشغيلي أكبر: لا يحتاج إلى تحديثات متكررة مقارنة بالنماذج الديناميكية.
- ث. متطلبات تشغيلية منخفضة: يتطلب موارد تقنية وإدارية أقل، مما يقلل التعقيد التشغيلي.
- ج. سهولة الإدارة: تعتمد الشركات على أساليب اكتوارية تقليدية مستقرة تقلل الحاجة إلى التعديل المستمر.

ثانيًا: سلبيات النماذج التقليدية للتسعير:

- تواجه هذه النماذج عدة تحديات، من أهمها:
- أ. انخفاض الدقة على مستوى الأفراد؛ إذ تُعامل العملاء ضمن مجموعات واسعة دون مراعاة الفروق الفردية الجوهرية في مستوى المخاطر.
 - ب. غياب العدالة السعرية، حيث يتحمل العملاء منخفضو المخاطر جزءًا من تكاليف العملاء مرتفعي المخاطر ضمن نفس الفئة التأمينية.
 - ت. عدم القدرة على التكيف مع المخاطر الناشئة والجديدة -مثل: مخاطر تغير المناخ أو الأنماط السلوكية الحديثة- بسبب اعتمادها على بيانات تاريخية ثابتة.

ث. الحاجة إلى تدخل طويل من فرق تكنولوجيا المعلومات لإجراء التعديلات على نماذج التسعير، مما يجعل التطوير بطيئًا ومكلفًا.

ج. عدم مكافأة السلوك الإيجابي أو الوقائي، مثل القيادة الآمنة أو الالتزام الصحي، لكون الأقساط لا تعكس السلوك الحقيقي للمؤمن لهم (Olabowale, 2024).

2.2.7.3 نماذج التسعير الديناميكية:

يُعد التسعير الديناميكي من أبرز التطبيقات المتقدمة للذكاء الاصطناعي في قطاع التأمين، حيث يعتمد على خوارزميات التعلم الآلي لتحليل مجموعات ضخمة ومتغيرة من البيانات. وتشمل هذه البيانات سلوك العملاء، واتجاهات السوق، واستراتيجيات المنافسين، ومستويات المخزون، والتقلبات الموسمية. ويتميز هذا النظام بقدرته على تحديث قرارات التسعير بصورة مستمرة، بما يعكس رؤى لحظية مستمدة من البيانات في الوقت الفعلي، الأمر الذي يتيح إجراء تعديلات ديناميكية وموضوعية على الأسعار بناءً على التطورات الفعلية.

يستخدم التسعير الديناميكي مزيًا من تقنيات الذكاء الاصطناعي وإنترنت الأشياء والبيانات عن بُعد لتحليل بيانات آنية عالية الدقة، مثل: عادات القيادة في التأمين على السيارات، والمؤشرات الصحية في التأمين الصحي، وتغيرات السوق في التأمين التجاري. ويسمح ذلك بتحديد أقساط فردية تعكس مستوى المخاطر الحقيقي لكل مستهلك.

أولاً: مزايا التسعير الديناميكي:

يتميز هذا النهج بعدد من الإيجابيات، من أهمها:

أ. أقساط عالية التخصيص تتناسب مع السلوك الفردي والمخاطر الفعلية.

ب. مكافأة السلوك الآمن من خلال خفض الأقساط لمن يلتزم بمعايير السلامة (مثل القيادة الآمنة).

ت. القدرة على التكيف مع تقلبات السوق بصورة مستمرة.

ث. تسريع دورة تحديث المنتجات نظرًا لمرونة النظام القائم على البيانات.

ج. تحقيق ميزة تنافسية لشركات التأمين التي تعتمد هذا الأسلوب مقارنة بالنماذج التقليدية.

ثانياً: تحديات وسلبيات التسعير الديناميكي:

- رغم فوائده الكبيرة، يواجه التسعير الديناميكي عدداً من التحديات، من أبرزها:
- أ. احتمالية انخفاض رضا العملاء إذا اعتُبرت الأسعار غير عادلة أو مبالغاً فيها.
 - ب. الحاجة إلى استثمارات تقنية ضخمة في البنية التحتية ومعالجة البيانات.
 - ت. مخاوف متزايدة تتعلق بخصوصية البيانات نتيجة جمع بيانات حساسة ودقيقة عن السلوك الفردي.
- (Aizawa & Ko, 2025)

8.3 البيانات المستخدمة في التأمين:

تستخدم شركات التأمين طيفاً واسعاً من البيانات يضمّ البيانات التقليدية لحاملي الوثائق - مثل: العمر، والموقع الجغرافي، وسجل المطالبات - إضافةً إلى المعلومات المالية كالدرجات الائتمانية. وإلى جانب ذلك، تعتمد الشركات على البيانات "البديلة" الحديثة المستمدة من تقنيات إنترنت الأشياء والمعلوماتية عن بُعد، مثل سلوك القيادة في الوقت الفعلي، وبيانات الطقس، ونشاط وسائل التواصل الاجتماعي، وصور الأقمار الصناعية. وتُسهم هذه البيانات مجتمعةً في تحسين تقييم المخاطر، وتحديد أسعار الوثائق بدقة أعلى، وكشف الاحتيال، وتخصيص المنتجات، فضلاً عن تبسيط العمليات بدءاً من الاكتتاب وحتى معالجة المطالبات، مما يزوّد الشركات برؤية شاملة لاتخاذ قرارات أكثر جودة. فيما يلي أبرز أنواع البيانات المستخدمة في قطاع التأمين (Srivastava, Malhotra, & Mukherjee, 2024):

- أ. بيانات العملاء: وتشمل البيانات الديموغرافية (العمر، والجنس، والموقع)، والتاريخ الصحي، والمعلومات المالية مثل الدخل والدرجة الائتمانية.
- ب. بيانات وثائق التأمين والمطالبات: تفاصيل الوثائق، وسجلات المطالبات، وأنواع الخسائر (الحوادث، والسرقه، والمرض)، ومبالغ التسوية، وحالات الرفض.
- ت. البيانات السلوكية (المعلوماتية عن بُعد/إنترنت الأشياء) مثل: عادات القيادة من السيارات المتصلة، وبيانات أجهزة استشعار المنازل الذكية، والأجهزة الصحية القابلة للارتداء.
- ث. البيانات الخارجية: وتشمل أنماط الطقس، ومعدلات الجريمة، والمؤشرات الاقتصادية، وبيانات الصحة العامة، ونشاط وسائل التواصل الاجتماعي، وصور الأقمار الصناعية.

ج. البيانات غير المنظمة: مثل تقارير التفتيش، وملاحظات مراكز الاتصال، ورسائل البريد الإلكتروني، والصور، والتي تضيف سياقًا غنيًا للقرارات التحليلية.

9.3 دور البيانات في تقييم المخاطر:

تُعدّ البيانات الركيزة الأساسية لتقييم مخاطر التأمين، إذ تُتيح لشركات التأمين الانتقال من الاعتماد على الإحصاءات التقليدية إلى توظيف البيانات الضخمة، والذكاء الاصطناعي، ونظم المعلومات عن بُعد لتقييم المخاطر بدقة أكبر وبطابع شخصي. ويسهم هذا التحول في تطوير تسعير ديناميكي أكثر عدالة، وكشف الاحتيال بكفاءة أعلى، وتحسين الربحية ورضا العملاء من خلال التنبؤ الدقيق بالخسائر وتصميم وثائق تأمين ملائمة لملفات المخاطر الفردية. وتساعد البيانات في تحديد احتمالية وقوع الخسائر وشدتها، واستخلاص عوامل الخطر الدقيقة (مثل أنماط القيادة أو المؤشرات الصحية)، وبناء نماذج اکتوارية وتنبؤيه متقدمة تُنتج نظامًا أكثر إنصافًا لكلّ من شركة التأمين والمؤمن عليه. فيما يلي نذكر في نقاط دور البيانات في تقييم المخاطر (Leidman، 2021).

أ. التسعير والاکتتاب الدقيقان: تحليل مجموعات ضخمة من البيانات (مثل الطقس، والموقع الجغرافي، ووسائل التواصل الاجتماعي، والبيانات عن بُعد) لفهم طبيعة المخاطر الدقيقة وتحديد أقساط تعكس الملف الحقيقي للمخاطر.

ب. النمذجة التنبؤية: استخدام خوارزميات التعلم الآلي لاكتشاف الأنماط والتنبؤ باحتمالية المطالبة وتوقع المخاطر المحتملة – مثل الكوارث الطبيعية أو أعطال المعدات – مما يُمكن من اتخاذ تدابير استباقية.

ت. سياسات مُخصّصة: بناء منتجات تأمينية مرنة ومصممة خصيصًا بالاعتماد على بيانات مفصّلة، بدلاً من الاعتماد على خطط عامة وموحدة.

ث. كشف الاحتيال: تحليل بيانات المطالبات لاكتشاف الأنماط غير الطبيعية والأنشطة الاحتيالية، بما يقلّل الخسائر ويحسن كفاءة العمليات.

ج. المراقبة الفورية: الاستفادة من إنترنت الأشياء والبيانات عن بُعد لتوفير تدفقات مستمرة من البيانات (مثل سلوك القيادة أو أجهزة استشعار الممتلكات) لتعديل المخاطر والأقساط بصورة ديناميكية، بل ومنع الخسائر قبل وقوعها.

ح. تحسين تجربة العملاء: تسريع معالجة الطلبات، وتعزيز الدعم الاستباقي، وتوفير تسعير أكثر عدالة

ودقة بفضل التحليل المتقدم للبيانات.

ينبغي أن نشير إلى أن جوهر التأمين يكمن في تجميع المخاطر، وجوهر التجميع هو التمييز "the act of distinguishing": وهو ضرورة تجارية لشركات التأمين للتمييز بين المؤمن عليهم من خلال تصنيفهم في مجموعات مخاطر مختلفة ولكل مجموعة احتمالية خسائر مماثلة. يفيد تصنيف المخاطر شركات التأمين لأنه يقلل من الاختيار غير السليم والمخاطر الأخلاقية ويعزز الكفاءة الاقتصادية. خشية المستهلكين ذوي المخاطر العالية من التعرض للتمييز غير العادل من قبل شركات التأمين، خاصة مع استخدامها المتزايد للبيانات الضخمة وأدوات التحليلات المتطورة. تقليدياً، لا يُسمح لشركات التأمين باستخدام بعض الخصائص المحمية (استخدام هذه الخصائص للتمييز أمر غير مقبول اجتماعياً) للتمييز المباشر ضد حاملي الوثائق في الاكتتاب أو التقييم، مثل العرق أو الدين أو الأصل القومي (Xin & Huang, 2024).

10.3 أثر البيانات في تحسين العدالة السعرية:

أحدث الذكاء الاصطناعي عن طريق تحليل البيانات نقلة نوعية في إدارة منتجات التأمين، وحسّن بشكل كبير عملية اتخاذ القرارات، وأساليب إدارة المخاطر لدى شركات التأمين. ونظرًا لتوفر قواعد بيانات ضخمة تستخدم شركات التأمين حلولاً مثل التحليل التنبئي، والذكاء الاصطناعي، والتعلم الآلي لفهم سلوك العملاء وظروفهم بشكل أعمق، وتقييم مخاطرتهم، بالإضافة إلى اختيار المنتجات المناسبة لكل عميل على حدة. ويساعد تحليل البيانات في تصميم منتجات تأمينية تلي احتياجات العملاء، كما تساعد في تحسين دقة الأسعار، والبيانات الديموغرافية، وسجل المطالبات، والعوامل الخارجية، بما في ذلك الأحوال الجوية. عندما تستخدم شركات التأمين هذه الأشكال من التكنولوجيا، يُمكنها التنبؤ بسلوك العملاء، وتقليل حالات الاحتيال، وفي الوقت نفسه تحديد المجالات التي يُمكنها فيها خفض التكاليف وتحسين تجربة العملاء.

يؤثر تحليل البيانات بشكل كبير على عدالة تسعير التأمين عن طريق توفير أقساط تأمين شخصية وقائمة على المخاطر (مثل: استخدام المعلوماتية للقيادة عن بُعد) تتجاوز الصور النمطية الشائعة، مما قد يجعل التأمين أكثر عدالة للأفراد ذوي السلوك الجيد. ومع ذلك، فإنها تُدخل أيضًا مخاطر التحيز الخوارزمي والتمييز بالوكالة (باستخدام بيانات تبدو محايدة مثل حجم المحرك كمؤشر على الجنس)، مما يخلق تحديات جديدة تتعلق بالعدالة تتطلب تصميمًا دقيقًا، وإشرافًا أخلاقيًا، وأطرًا تنظيمية لضمان نتائج منصفة وتجنب معاقبة الفئات بشكل غير عادل. تُحسّن البيانات العدالة عن طريق الآتي (Lohani, Asthana, & Osama, 2024):

1.10.3 تقييم المخاطر التفصيلي:

تتيح البيانات الضخمة لشركات التأمين استخدام بيانات فردية آنية (مثل عادات القيادة الفعلية عبر المعلوماتية عن بُعد والبيانات الصحية) للتسعير بناءً على المخاطر الفعلية، وليس فقط متوسطات المجموعات، مما قد يُخفض أقساط التأمين للأفراد ذوي المخاطر المنخفضة.

2.10.3 مؤشرات موضوعية:

يمكن أن يؤدي الانتقال من العوامل الديموغرافية العامة إلى مؤشرات مخاطر أكثر مباشرة (مثل سلوك القيادة) إلى تقليل الاعتماد على المعلومات البديلة للخصائص المحمية، مما يجعل التسعير أكثر عدالة.

3.10.3 التسعير الديناميكي:

تُمكن البيانات الفورية من إجراء تعديلات ديناميكية، مما يُكافئ السلوك الآمن فوراً، وهو ما يبدو أكثر عدالة للعملاء من الأسعار الثابتة طويلة الأجل.

4. الدراسة الميدانية

هدفت الدراسة إلى تحليل أثر بيانات الذكاء الاصطناعي على أقساط التأمين، معدل المطالبات، وفرضية التحيز وعدالة أقساط العملاء منخفضي الدخل. حيث تم تحليل بيانات الدراسة التطبيقية باستخدام الأساليب الإحصائية المناسبة، واختبار تحقق فرضيات الدراسة، ثم بعد ذلك عرض النتائج وتوصيات الدراسة التي توصل إليها الباحث من خلال الدراسة الميدانية.

1.4 أدوات الدراسة

بناء نموذج تطبيقي باستخدام بيانات تخيلية تحاكي واقع التأمين التقليدي (ضد الغير) الذي يعتمد على نموذج تسعير ثابت مبني على سعة محرك السيارة. ثم تقييم أثر الذكاء الاصطناعي عبر مؤشرات كمية عن طريق مقارنة النموذج مع الأقساط الثابتة.

2.4 متغيرات الدراسة

متغيرات الدراسة بالنسبة للفرضية الأولى والثانية والثالثة:

المتغير التابع (Dependent Variable):

أ. قيمة القسط التأميني (Insurance Premium).

المتغيرات المستقلة (Independent Variables):

أ. عمر السائق (Age Bracket)

ب. عمر المركبة (Car Age)

ت. المدينة (City)

ث. السجلّ التأميني (Claims)

متغيرات الدراسة بالنسبة للفرضية الرابعة:

المتغير التابع (Dependent Variable):

أ. حالات الاحتيال (Fraud Cases).

المتغيرات المستقلة (Independent Variables):

أ. مؤشر المخاطر (Risk Score).

ب. مخاطر المركبة (Vehicle Risk).

ت. مخاطر العمر (Age Risk).

ث. مؤشر استخدام الذكاء الاصطناعي (AI_Usage_Score).

3.4 الأساليب الإحصائية المستخدمة

1.3.4 التحليل الإحصائي:

أ. المتوسطات.

ب. التوزيعات التكرارية.

ت. معامل الارتباط.

2.3.4 تقنيات التعلم الآلي:

سيتم تدريب ثلاثة نماذج:

أ. الانحدار الخطي (Linear Regression).

ب. نموذج انحدار الغابة العشوائية (Random Forest Regressor).

ت. نموذج الانحدار المعزز بالتدرج (Gradient Boosting Regressor).

4.4 مجتمع وخصائص عينة الدراسة

يتكون مجتمع الدراسة من عدد (20) حالة افتراضية في قطاع تأمين السيارات باستخدام الذكاء الاصطناعي (حالة تقدير الأقساط التأمين التقليدية، والأقساط المولده آليا).

5.4 طريقة تحليل البيانات

تم تحليل بيانات الجداول التخليية بالحاسب الآلي باستعمال برنامج Excel؛ وذلك لقياس الفروق والاختلافات بين التسعير التقليدي في الجدول الافتراضي والتسعير الديناميكي باستخدام الذكاء الاصطناعي لدراسة العلاقة بينها.

6.4 الأساليب الإحصائية المستخدمة

استعين في هذه الدراسة بالأساليب القياسية الحديثة لتحليل البيانات من خلال استخدام معاملات الارتباط (Coefficients Correlation)، حيث تم استخدام الانحدار الخطي (Linear Regression) وتحليل التباين (ANOVA) لقياس قوة العلاقة الخطية بين متغيرات الدراسة، حيث من خلال نتيجة معاملات الارتباط والانحدار الخطي يمكن الاستدلال على وجود أو عدم وجود أثر بين كل المتغيرات المستقلة والمتغير التابع.

7.4 اختبار الفرضيات

1.7.4 اختبار الفرضية الأولى:

H0₁: نماذج الذكاء الاصطناعي المحسنة تزيد من دقة التنبؤ بمعدل المطالبات بنسبة معنوية مقارنة بالنماذج

التقليدية.

في الجدول رقم (1) الخاص بتحليل التباين بالنسبة إلى قيم معامل الارتباط الثلاثة، نجد أن قيمة معامل الارتباط البسيط (R) قد بلغت (0.997)، بينما معامل التحديد (R Square) بلغ (0.992)، أما معامل التحديد المعدل (Adjusted R Square) بلغ (0.050)؛ مما يعني بأن المتغيرات المستقلة التفسيرية (مخاطر المركبة، ومخاطر العمر، وقسط التأمين AI) فسرت (0.96) من التغيرات الحاصلة في عدد المطالبات والباقي (0.003) يعزى إلى عوامل عشوائية أخرى.

الجدول رقم (1): تحليل التباين لقيم معامل الارتباط - عدد المطالبات

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
M ₀	.000	.000	.000	0.550
M ₁	.997	.993	.992	.050

a. Note. M₁ includes VehicleRisk, AgeRisk, AIPremium_formula

أما الجدول رقم (2) الذي تضمن قيم تحليل التباين والذي يمكن من خلاله معرفة القوة التفسيرية للنموذج ككل عن طريق إحصائية (F)، يلاحظ من جدول تحليل التباين قيمة المعنوية أصغر من (0.05) والتي بلغت (P ≤ 0.001)، مما يؤكد وجود قوة تفسيرية لنموذج الانحدار الخطي المتعدد من الناحية الإحصائية.

الجدول رقم (2): تحليل التباين (ANOVA)

Model	Sum of Squares	df	Mean Square	F	Sig.
Regression	5.710	3	1.903	759.403	<.001b
Residual	0.040	16	.003		
Total	5.750	19			

b. Dependent Variable: المطالبات المتوقعة

b. Predictors: (Constant), مخاطر المركبة، ومخاطر العمر، وقسط التأمين

في الجدول رقم (3) الذي تظهر فيه قيمة الثبات ومعاملات الانحدار ودلالاتها الإحصائية للمتغير المستقل على المتغير التابع، ونستنتج أن المتغيرات المستقلة كانت معنوية من الناحية الإحصائية، وحسب اختبار (t) كانت أقساط التأمين عند مستوى معنوية (P ≥ 0.001)، بمستوى معنوية (0.001)؛ وهي أصغر من مستوى معنوية (0.050)، مما يشير إلى أن النموذج دال إحصائياً، حيث كانت المتغيرات المستقلة ذات تأثير معنوي في نموذج الانحدار المتعدد حسب اختبار (t).

الجدول رقم (3): معاملات الانحدار

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta		
1 (Constant)	0.358	0.065		5.480	< .001
2 VehicleRisk	-0.563	0.031	-0.407	-18.159	< .001
2 AgeRisk	-1.141	0.034	-0.841	-33.188	< .001
3 AI Premium	0.004	9.563×10 ⁻⁵	1.099	45.759	< .001

a. Dependent Variable: المطالبات المتوقعة

ويمكن صياغة الفرض في الصيغة الصفرية Null Hypothesis والبدلية كالآتي:

الفرضية الصفرية: لا يوجد أثر ذو دلالة إحصائية لنماذج الذكاء الاصطناعي المحسنة تزيد من دقة التنبؤ بمعدل المطالبات بنسبة معنوية مقارنة بالنماذج التقليدية.

الفرضية البديلة: يوجد أثر ذو دلالة إحصائية لنماذج الذكاء الاصطناعي المحسنة تزيد من دقة التنبؤ بمعدل المطالبات بنسبة معنوية مقارنة بالنماذج التقليدية.

يلاحظ من الجداول أعلاه أن جميع المتغيرات المستقلة تمتلك أثراً معنوياً قوياً على المطالبات المتوقعة لأن قيمة (Sig.) أقل من 0.001، معامل AI Premium هو الأكبر (Beta = 1.099)، مما يعني أن الذكاء الاصطناعي يساهم بأكبر وزن في تفسير التغير في المطالبات المتوقعة. متغيراً VehicleRisk و AgeRisk لهما تأثيران سلبيان، مما يعني أن انخفاض مستوى المخاطر يقود إلى انخفاض المطالبات المتوقعة. إذن نرفض الفرضية الصفرية، ونقبل الفرضية البديلة؛ حيث يوجد أثر قوي وذو دلالة إحصائية لنماذج الذكاء الاصطناعي في تحسين دقة التنبؤ بالمطالبات مقارنة بالنماذج التقليدية، وهذا مدعوم بقوة معاملات الانحدار وقيمة الدلالة (Sig.).

2.7.4 اختبار الفرضية الثانية:

H₀₂: التأمين المعتمد على البيانات يؤدي إلى أقساط أكثر عدلاً للعملاء منخفضي المخاطر.

في الجدول رقم (4) الخاص بتحليل التباين بالنسبة إلى قيم معامل الارتباط الثلاثة، نجد أن قيمة معامل الارتباط البسيط (R) قد بلغت (0.997)، بينما معامل التحديد (R Square) بلغ (0.992)، أما معامل التحديد المعدل (Adjusted R Square) بلغ (0.993)؛ مما يعني بأن المتغيرات المستقلة التفسيرية (RiskScore, VehicleRisk, AgeRisk) فسرت (0.97) من التغيرات الحاصلة في عدد المطالبات والباقي

(0.003) يعزى إلى عوامل عشوائية أخرى.

الجدول رقم (4): تحليل التباين لقيم معامل الارتباط

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
M ₀	0.000	0.000	0.000	138.173
M ₁	0.997	0.994	0.993	11.397

a. Predictors: (Constant), RiskScore, VehicleRisk, AgeRisk

أما الجدول رقم (5) الذي تضمن قيم تحليل التباين؛ والذي يمكن من خلاله معرفة القوة التفسيرية للنموذج ككل عن طريق إحصائية (F)، يلاحظ من الجدول أن تحليل التباين قيمة المعنوية أصغر من (0.05)، والتي بلغت ($P \leq 0.001$)، مما يؤكد وجود قوة تفسيرية لنموذج الانحدار الخطي المتعدد من الناحية الإحصائية.

الجدول رقم (5): تحليل التباين (ANOVA)

Model	Sum of Squares	df	Mean Square	F	Sig.
Regression	360663.17	3	120220.055	925.527	<.001
Residual	2078.32	16	129.895		
Total	362741.481	19			

Note. M₁ includes AgeRisk, VehicleRisk, Expected claims

Note. The intercept model is omitted, as no meaningful information can be shown

في الجدول رقم (6) الذي تظهر فيه قيمة الثبات ومعاملات الانحدار ودلالاتها الإحصائية للمتغير المستقل على المتغير التابع، ونستنتج أن المتغيرات المستقلة كانت معنوية من الناحية الإحصائية، وحسب اختبار (t) كانت أقساط التأمين عند مستوى معنوية ($P \geq 0.001$)، بمستوى معنوية (0.001) وهي أصغر من مستوى معنوية (0.050)، مما يشير إلى أن النموذج دال إحصائياً، حيث كانت المتغيرات المستقلة ذات تأثير معنوي في نموذج الانحدار المتعدد حسب اختبار (t).

الجدول رقم (6): معاملات الانحدار

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta		
1 (Intercept)	466.535	30.896		15.100	<.001
2 (Intercept)	-79.863	15.381		-5.192	<.001
3 AgeRisk	260.04	7.036	.763	36.959	<.001
4 VehicleRisk	128.16	7.078	.369	18.107	<.001
5 Expected claims	128.16	4.956	.903	45.759	<.001

a. Dependent Variable: AIPremium_formula

ويمكن صياغة الفرض في الصيغة الصفرية Null Hypothesis والبديلة كالآتي:

الفرضية الصفيرية: لا يوجد أثر ذو دلالة إحصائية للتأمين المعتمد على البيانات باستخدام الذكاء الاصطناعي يؤدي إلى أقساط أكثر عدالة للعملاء منخفضي المخاطر.

الفرضية البديلة: يوجد أثر ذو دلالة إحصائية للتأمين المعتمد على البيانات باستخدام الذكاء الاصطناعي يؤدي إلى أقساط أكثر عدالة للعملاء منخفضي المخاطر.

هدفت هذه الفرضية إلى التحقق مما إذا كان التأمين المعتمد على البيانات يساهم في تحديد أقساط أكثر عدالة للعملاء منخفضي المخاطر مقارنة بالأساليب التقليدية. ولتحقيق ذلك، تم استخدام نموذج الانحدار الخطي المتعدد، حيث اعتُبرت المتغيرات: AgeRisk و VehicleRisk و Expected Claims و متغيرات مستقلة، بينما اعتُبر قسط الذكاء الاصطناعي AI Premium_formula المتغير التابع.

أظهرت نتائج الانحدار أن النموذج يتمتع بقوة تفسيرية عالية جدًا؛ إذ بلغ معامل التحديد ($R^2 = 0.994$)، وهو ما يشير إلى أن المتغيرات المستقلة تفسر نحو (99.4%) من التغير في الأقساط المحسوبة عبر الخوارزمية. كما كشف تحليل التباين (ANOVA) عن معنوية النموذج الإحصائية ($F = 925.527, p < 0.001$)؛ مما يدل على أن النموذج ككل يتمتع بدلالة إحصائية قوية.

كذلك جاءت معاملات الانحدار لجميع المتغيرات الثلاثة معنوية عند مستوى دلالة أقل من (0.001)؛ وهو ما يثبت وجود أثر مهم لكل من مستوى مخاطر العمر، ومستوى مخاطر المركبة، والمطالبات المتوقعة في تحديد قسط التأمين الناتج من نموذج الذكاء الاصطناعي. كما أظهر الانخفاض الكبير في جذر متوسط مربع الخطأ (RMSE) من 138.173 في النموذج الابتدائي (M_0) إلى 11.397 في النموذج المحسّن (M_1) دقة أعلى بكثير في التسعير عند استخدام البيانات المتقدمة.

لذلك يرفض الفرضية الصفيرية، ويقبل الفرضية البديلة؛ حيث يوجد أثر ذي دلالة إحصائية يؤدي إلى أقساط أكثر عدالة للعملاء منخفضي المخاطر؛ وهذا مدعوم بقوة معاملات الانحدار وقيمة الدلالة (Sig).

3.7.4 اختبار الفرضية الثالثة:

H02: اعتماد بيانات بديلة في التقدير (سلوكية، عمرية) يؤدي إلى تحيز بالتالي يضر بعض العملاء.

في الجدول رقم (7) الخاص بتحليل التباين بالنسبة إلى قيم معامل الارتباط الثلاثة، نجد أن قيمة معامل الارتباط البسيط (R) قد بلغت (1.000)، بينما معامل التحديد (R Square) بلغ (1.000)، أما معامل التحديد المعدل (Adjusted R Square) بلغ (1.000)؛ مما يعني بأن المتغيرات المستقلة التفسيرية (Claims, AgeRisk, VehicleRisk, Expected claims, RiskScore, Age) فسرت (0.0) من التغيرات

الحاصلة في عدد المطالبات.

الجدول رقم (7): تحليل التباين لقيم معامل الارتباط

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
M ₀	0.000	0.000	0.000	138.173
M ₁	1.000	1.000	1.000	0.002

a. Predictors: (Constant), includes Claims, AgeRisk, VehicleRisk, Expected claims, RiskScore, Age

أما الجدول رقم (8) الذي تضمن قيم تحليل التباين، والذي يمكن من خلاله معرفة القوة التفسيرية للنموذج ككل عن طريق إحصائية (F)، يلاحظ من جدول تحليل التباين أن قيمة المعنوية أصغر من (0.05) حيث بلغت ($P \leq 0.002$)؛ مما يؤكد وجود قوة تفسيرية لنموذج الانحدار الخطي المتعدد من الناحية الإحصائية.

الجدول رقم (8): تحليل التباين (ANOVA)

Model	Sum of Squares	df	Mean Square	F	Sig.
Regression	362741.481	6	60456.914	1.570×10+10	<.001
Residual	5.006×10-5	13	3.851×10-6		
Total	362741.481	19			

Note. M₁ includes Claims, AgeRisk, VehicleRisk, Expected claims, RiskScore, Age

Note. The intercept model is omitted, as no meaningful information can be shown

في الجدول رقم (9) الذي تظهر فيه قيمة الثبات ومعاملات الانحدار ودلالاتها الإحصائية للمتغير المستقل على المتغير التابع، ونستنتج أن المتغيرات المستقلة كانت معنوية من الناحية الإحصائية، وحسب اختبار (t) كانت أقساط التأمين عند مستوى معنوية ($P \geq 0.001$)، بمستوى معنوية (0.001) وهي أصغر من مستوى معنوية (0.05)، مما يشير إلى أن النموذج دال إحصائياً، حيث كانت المتغيرات المستقلة ذات تأثير معنوي في نموذج الانحدار المتعدد حسب اختبار (t).

الجدول رقم (9): معاملات الانحدار

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta		
1 (Intercept)	466.535	30.896		15.100	<.001
2 (Intercept)	300.020	0.023		131044.348	<.001
3 Claims	-0.006	0.012		-0.491	0.500
4 AgeRisk	-0.009	0.015	-2.329×10-5	-0.587	0.567
5 VehicleRisk	-0.002	0.007	-2.564×10-5	-0.321	0.753
6 Expected claims	0.004	0.002	-6.221×10-6	2.449	0.029
7 RiskScore	500.010	0.027	1.000	18660.511	<.001
8 Age	-1.673×10-4	7.746×10-5	-1.536×10-5	-2.160	0.050

Note. Missing coefficients are undefined because of singularities. Check the data for anything out of order!

^a Standardized coefficients can only be computed for continuous predictors.

ويمكن صياغة الفرض في الصيغة الصفرية Null Hypothesis والبدلية كالآتي:

الفرضية الصفرية: لا يوجد أثر ذو دلالة إحصائية عند اعتماد بيانات بديلة في التقدير (سلوكية، عمرية) باستخدام الذكاء الاصطناعي يؤدي إلى تحيز بالتالي يضر بعض العملاء.

الفرضية البديلة: يوجد أثر ذو دلالة إحصائية عند اعتماد بيانات بديلة في التقدير (سلوكية، عمرية) باستخدام الذكاء الاصطناعي يؤدي إلى تحيز بالتالي يضر بعض العملاء.

هدفت هذه الفرضية إلى فحص ما إذا كان اعتماد بيانات بديلة في تقدير القسط (مثل البيانات السلوكية والعمرية) يؤدي إلى تحيز قد يضر بعض العملاء مقارنة بالنماذج التقليدية للتسعير. وقد تم اختبار الفرضية باستخدام نموذج انحدار خطي متعدد شمل المتغيرات: $Expected$ ، $VehicleRisk$ ، $AgeRisk$ ، $Claims$ ، Age ، $RiskScore$ ، $Claims$ بوصفها متغيرات مستقلة، وفي حين اعتُبر قسط الذكاء الاصطناعي AI $Premium_formula$ المتغير التابع.

أظهرت نتائج نموذج الانحدار المحسّن (M_1) قيمة معامل ارتباط $R = 1.000$ ، ومعامل تحديد $R^2 = 1.000$ ، مما يشير إلى تفسير شبه كامل للتباين في الأقساط. كما عكس انخفاض جذر متوسط مربع الخطأ ($RMSE$) من 138.173 في النموذج الابتدائي إلى 0.002 في النموذج المحسّن دقة عالية للغاية للنموذج في التنبؤ بالقسط عند استخدام البيانات البديلة.

أظهر تحليل التباين (ANOVA) دلالة قوية للنموذج $F = 1.57 \times 10^{10}$ ، $(p < 0.001)$ ، مما يثبت أن المتغيرات الداخلة في النموذج تساهم في تفسير التغير في القسط بدرجة ذات دلالة إحصائية.

عند تحليل معاملات الانحدار، تبين وجود تأثير ذي دلالة إحصائية لبعض المتغيرات مثل: $RiskScore$ ($p < .001$)، $Expected$ $Claims$ ($p = .029$)، Age ($p = .050$) على الحدود المقبولة للدلالة، في حين لم تكن المتغيرات الأخرى ذات تأثير معنوي) مثل $AgeRisk$ ، $Claims$ ، $VehicleRisk$ ، مما يشير إلى أن اعتماد بعض البيانات البديلة لا يؤدي بالضرورة إلى تأثير مباشر أو تحيز كبير في نموذج التسعير. ومع ذلك، فإن قوة تأثير المتغيرات الأساسية، وخاصة $RiskScore$ ، توضح أن النموذج يعتمد بدرجة كبيرة على البيانات السلوكية /التنبؤية أكثر من البيانات الديموغرافية التقليدية؛ دون أن يظهر ذلك أثراً سلبياً واضحاً على شريحة معينة من العملاء.

بناءً على القيم الاحتمالية الكلية ($p < 0.001$)، يمكن القول إن النموذج ذا دلالة إحصائية واضحة، إلا أن عدم دلالة معظم المتغيرات البديلة يشير إلى غياب تحيز مثبت إحصائياً عند استخدامها. لذلك عدم رفض الفرضية الصفرية H_0 ، ورفض الفرضية البديلة H_1 ، وذلك لأن البيانات البديلة (AgeRisk، VehicleRisk، Claims) لم تظهر تأثيراً ذا دلالة إحصائية يؤدي إلى تحيز أو ضرر على العملاء، باستثناء المتغيرات الجوهرية المرتبطة فعلياً بالخطر الحقيقي (RiskScore)، (Expected Claims)، بالإضافة إلى ذلك لم تُظهر التحليلات أي دليل قوي يشير إلى وجود تحيز ناتج عن اعتماد البيانات البديلة.

4.7.4 اختبار الفرضية الرابعة:

H_0 : استخدام الذكاء الاصطناعي يقلل من حالات الاحتيال التأميني.

في الجدول رقم (10) الخاص بتحليل التباين بالنسبة إلى قيم معامل الارتباط الثلاثة، نجد أن قيمة معامل الارتباط البسيط (R) قد بلغت (0.394)، بينما معامل التحديد (R Square) بلغ (0.155)، أما معامل التحديد المعدل (Adjusted R Square) بلغ (-0.070)؛ مما يعني بأن المتغيرات المستقلة التفسيرية (e) (RiskScore، VehicleRisk، AgeRisk، AI_Usage_Score) فسرت فقط (0.16) من التغيرات الحاصلة في عدد حالات الاحتيال (FraudCases).

الجدول رقم (10): تحليل التباين لقيم معامل الارتباط

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
M ₀	0.000	0.000	0.000	1.432
M ₁	0.394	0.155	-0.070	1.481

Note. M₁ includes RiskScore, VehicleRisk, AgeRisk, AI_Usage_Score

أما الجدول رقم (11) الذي تضمن قيم تحليل التباين والذي يمكن من خلاله معرفة القوة التفسيرية للنموذج ككل عن طريق إحصائية (F)، يلاحظ من جدول تحليل التباين قيمة المعنوية أكبر من (0.05) والتي بلغت ($P \geq 0.688$)، وقيمة (P) (0.611) بالتالي فإن النموذج غير دال إحصائياً ككل، مما يؤكد عدم وجود قوة تفسيرية لنموذج الانحدار الخطي المتعدد من الناحية الإحصائية.

الجدول رقم (11): تحليل التباين (ANOVA)

Model	Sum of Squares	df	Mean Square	F	Sig.	
M ₁	Regression	6.038	4	1.510	0.688	0.611
	Residual	32.912	15	2.194		
Total	38.950	19				

Note. M₁ includes RiskScore, VehicleRisk, AgeRisk, AI_Usage_Score

Note. The intercept model is omitted, as no meaningful information can be shown.

في الجدول رقم (12) الذي تظهر فيه قيمة الثبات ومعاملات الانحدار ودلالاتها الإحصائية للمتغيرات المستقل على المتغير التابع، ونستنتج أن المتغيرات المستقلة كانت غير معنوية من الناحية الإحصائية، وحيث بلغ معامل (AI_Usage_Score) $\beta = -0.139$ ، و $t = -0.128$ ، $p = 0.900$ ، مما يشير إلى أن النموذج غير دال إحصائياً، حيث كانت المتغيرات المستقلة غير ذات تأثير معنوي في نموذج الانحدار المتعدد حسب اختبار (t).

الجدول رقم (12): معاملات الانحدار

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	
	B	Std. Error	Beta			
1	(Intercept)	2.050	0.320	6.41	< .001	
2	(Intercept)	1.816	2.799	0.649	0.526	
3	RiskScore	-0.018	0.016	-0.268	-1.099	0.289
4	VehicleRisk	1.108	0.984	0.270	1.126	0.278
5	AgeRisk	-0.277	1.829	-0.037	-0.152	0.882
6	AI_Usage_Score	-0.139	1.084	-0.032	-0.128	0.900

ويمكن صياغة الفرض في الصيغة الصفرية Null Hypothesis والبديلة كالآتي:

الفرضية الصفرية: لا يوجد أثر ذو دلالة إحصائية على أن استخدام الذكاء الاصطناعي يقلل من حالات الاحتيال التأميني.

الفرضية البديلة: يوجد أثر ذو دلالة إحصائية على أن استخدام الذكاء الاصطناعي يقلل من حالات الاحتيال التأميني.

أظهرت نتائج تحليل الانحدار الخطي المتعدد أن النموذج الإحصائي غير دال معنوياً ($F = 0.688$)، $p = 0.611$)، كما لم يُظهر متغير استخدام الذكاء الاصطناعي أثراً ذا دلالة إحصائية على عدد حالات الاحتيال التأميني ($\beta = -0.139$)، $p = 0.900$ وبناءً عليه، لا تتوافر أدلة إحصائية كافية تدعم وجود أثر لاستخدام الذكاء الاصطناعي في تقليل حالات الاحتيال التأميني ضمن عينة الدراسة، وعليه قبول الفرضية الصفرية ورفض الفرضية البديلة.

8.4 الترابط بين الفرضيات

تُظهر الفرضيات الثلاث مساراً تكاملياً لاستخدام الذكاء الاصطناعي في التأمين؛ إذ يبدأ بتحسين دقة وعدالة التسعير (الفرضية الثانية)، ثم معالجة إشكالية التحيز الناتج عن البيانات البديلة (الفرضية الثالثة)، وينتهي

بمحاولة الحد من الاحتمال التأميني (الفرضية الرابعة). ويؤكد هذا التسلسل أن الذكاء الاصطناعي يمثل أداة تنظيمية شاملة، وليس مجرد وسيلة تقنية معزولة.

5. الخاتمة

1.5 الاستنتاجات

1. استخدام الذكاء الاصطناعي في قطاع التأمين يُحدث أثرًا جوهريًا في تحسين كفاءة القرارات التأمينية، لا سيما في مجالات التنبؤ بالمخاطر وتسعير الأقساط.
2. وقد أظهرت النتائج الإحصائية دعمًا قويًا للفرضيات المرتبطة بعدالة التسعير وتقليل التحيز.
3. لم تظهر نتائج قاطعة فيما يتعلق بتقليل الاحتمال التأميني، وهو ما يُعزى إلى محدودية البيانات وطبيعة المتغير المدروس.
4. إدماج الذكاء الاصطناعي ضمن النظم التأمينية يعزز القدرة التفسيرية للنماذج، ويقلل من الاعتماد على متغيرات تقليدية قد تتسم بالتحيز أو القصور التحليلي.
5. التحول نحو التأمين المعتمد على البيانات يمثل اتجاهًا واعدًا، شريطة تبني أطر حوكمة واضحة تضمن الشفافية والعدالة في استخدام الخوارزميات.

2.5 التوصيات

1. توصي الدراسة بضرورة التوسع في استخدام نماذج الذكاء الاصطناعي، ولا سيما في مجالات تقييم المخاطر والتنبؤ بالمطالبات وتسعير الأقساط، لما أثبتته النتائج من قدرة هذه النماذج على تحسين كفاءة القرار التأميني ورفع دقته مقارنة بالنماذج التقليدية.
2. التحول التدريجي نحو التسعير المخصص (Personalized Pricing) القائم على البيانات الفعلية للمؤمن لهم، بما يحد من التمييز غير المبرر ويحقق قدرًا أعلى من العدالة، خاصة للعملاء منخفضي المخاطر.
3. وضع ضوابط واضحة لاستخدام البيانات البديلة (السلوكية والعمرية وغيرها)، بحيث يتم توظيفها ضمن نماذج متوازنة قائمة على الذكاء الاصطناعي، مع إجراء اختبارات دورية للكشف عن أي تحيز

محتمل قد يضر بفئات معينة من العملاء.

4. ضرورة توسيع قواعد البيانات وزيادة حجم العينة، والاعتماد على بيانات زمنية ممتدة، بما يسمح ببناء نماذج أكثر ملاءمة لطبيعة الاحتيال، مثل نماذج التصنيف والتعلم الآلي غير الخطي.
5. تبني أطر حوكمة للذكاء الاصطناعي في قطاع التأمين، تتضمن مبادئ الشفافية، وقابلية التفسير، والمساءلة، وذلك لضمان الاستخدام العادل والمسؤول للخوارزميات، وتعزيز ثقة العملاء والجهات الرقابية في القرارات المؤتمتة.
6. تشجيع الجهات التنظيمية بتحديث التشريعات التأمينية بما يتلاءم مع نماذج التأمين المعتمد على البيانات، مع وضع معايير واضحة لاختبار النماذج الخوارزمية والتحقق من عدالتها وأثرها الاجتماعي.
7. تقترح الدراسة على الباحثين المستقبليين التوسع في دراسة أثر الذكاء الاصطناعي على الاحتيال التأميني باستخدام نماذج أكثر تقدمًا، مثل الشبكات العصبية وأشجار القرارات، إضافة إلى دراسة الأبعاد القانونية والأخلاقية المصاحبة لاستخدام الذكاء الاصطناعي في قطاع التأمين.

6. المراجع

1. Adeline Chan. (28 Apr, 2023). Can AI Be Used for Risk Assessments? تاريخ الاسترداد Dec, 2025 ، من ISACA: <https://www.isaca.org/resources/news-and-trends/industry-news/2023/can-ai-be-used-for-risk-assessments>
2. Ansel Durant ،Farren McClure ،Maheshwari Karunakaran و،Liam Anderson.(2022). ARTIFICIAL INTELLIGENCE IS TRANSFORMING THE INSURANCE INDUSTRY, INTRODUCING INNOVATIVE METHODS THAT REVOLUTIONIZE THE BUYING PROCESS FOR CUSTOMERS . من Nov, 2025 ، 12(9)، 105-113. تاريخ الاسترداد 18 *Journal of Transformative Global Research* <https://www.researchgate.net/publication/386050902>
3. Association of International Certified Professional Accountants (AICPA). (13 Jul, 2022). Artificial intelligence is a game changer for auditors 4 تاريخ الاسترداد Dec, 2025 ، من AICPA & CIMA: <https://www.aicpa-cima.com/news/article/artificial-intelligence-is-a-game-changer-for-auditors>.

4. B.J. Copeland. (6 SEP, 2025). artificial intelligence. من الاسترداد تم Encyclopedia Britannica: <https://www.britannica.com/technology/artificial-intelligence>.
5. Babalola Olabowale. (Sep, 2024). AI-Driven Dynamic Pricing Models in Insurance Policies. تاريخ الاسترداد 7 Dec, 2025 ، من https://www.researchgate.net/publication/397435431_AI-Driven_Dynamic_Pricing_Models_in_Insurance_Policies.
6. Benjamin Leidman. (Mar, 2021). The impact of artificial intelligence and predictive analytics on insurance risk assessment in the digital age. Periodicals of Engineering and Natural Sciences (PEN) ،9(3) ،375-388. doi:10.21533/pen.v13.i2.392.
7. Brenda Boulwood. (18 Dec, 2020). How Artificial Intelligence Will Change Qualitative Risk Management. تاريخ الاسترداد 4 Dec, 2025 ، من GARP: <https://www.garp.org/risk-intelligence/technology/how-artificial-intelligence-will-change-qualitative-risk-management>.
8. CGI .(2023) .*Data-driven insurance: A path to strategic* 6 تاريخ الاسترداد Dec, 2025 ، من CGI: <https://www.cgi.com/sites/default/files/2023-06/whitepaper-cgi-data-driven.pdf>.
9. Christian Janiesch ،Patrick Zschech ، Kai Heinrich. (8 Apr, 2021). Machine learning and deep learning. Electronic Markets ،31 ،685-695. doi:doi.org/10.1007/s12525-021-00475-2.
10. Christopher P. Holland .(2022) .Artificial Intelligence (AI) and Digital Transformation in the Insurance Market: A Case Study Analysis of BGL Group .*The 55th Hawaii International Conference on System Sciences* 19 تاريخ الاسترداد (الصفحات 4548-4539) Nov, 2025 من <https://scholarspace.manoa.hawaii.edu/server/api/core/bitstreams/dc20bb63-6143-4f40-9137-9ce1298d078c/content>.
11. Citigroup Inc. (29 Apr, 2019). Citi Global Trade Uses AI to Digitize Compliance in Next Generational Project. تاريخ الاسترداد 4 Dec, 2025 ، من Citigroup Inc: <https://www.citigroup.com/global/news/press-release/2019/citi-global-trade-uses-ai-to-digitie-compliance-in-next-generational-project>.
12. Donato Malerba و ، Vincenzo Pasquadibisceglie. (Oct, 2024). Data-Centric AI. Journal of Intelligent Information Systems ،62(6) ،1-10. doi:10.1007/s10844-024-00901-9.

-
13. Guy Thomas. (4 May, 2017). Risk Classification and Moral Hazard. In: Loss Coverage: Why Insurance Works Better with Some Adverse Selection. doi:<https://doi.org/10.1017/9781316178843.012>.
 14. Iryna Fedorovych ،Oleksiy Rykhalskyy و ،Dmytro Poltavskyy .(2025) .Digital Transformation of Insurance Industry: Implications of AI Tools Integration .*International Journal of Organizational Leadership* 18 تاريخ الاسترداد 522-508 ،(1)14 ،Nov، 2025 من https://ijol.cikd.ca/article_60837_6a17e2d107742a968a15329f786a2473.pdf.
 15. Libby Bevin. (9 Sep, 2021). Using Artificial Intelligence in Risk Management. 4 تاريخ الاسترداد Dec، 2025 من ، zenGRC.
 16. Martin Eling ،Davide Nuessle و ، Julian Staubli . (Apr, 2022). The impact of artificial intelligence along the insurance value chain and on the insurability of risks. *The Geneva Papers on Risk and Insurance - Issues and Practice* ،47 ،205–241. doi:<https://doi.org/10.1057/s41288-020-00201-7>.
 17. Naoki Aizawa و ، Ami Ko. (8 Aug, 2025). Dynamic Pricing Regulation and Welfare in Insurance Markets. *Journal of Political Economy* ،133 ،2371-2413. doi:<https://doi.org/10.1086/735512>.
 18. Patricia Maroto. (3 Jul, 2025). Impact of AI on Data Analytics. 4 تاريخ الاسترداد Dec، 2025 من ، Halian International: <https://www.halian.com/article/impact-of-ai-on-data-analytics>.
 19. Paul Kirvan و ، Sean Michael Kerner. (20 Oct, 2025). What is a large language model (LLM)? 4 تاريخ الاسترداد Dec، 2025 من ، TechTarget: <https://www.techtarget.com/whatis/definition/large-language-model-LLM>.
 20. Pradeep Viswanathan. (28 Mar, 2023). Microsoft announces Security Copilot, an AI-powered security analysis tool for enterprises. 4 تاريخ الاسترداد Dec، 2025 من ، BigTechWire: <https://www.bigtechwire.com/2023/03/28/microsoft-announces-security-copilot-an-ai-powered-security-analysis-tool-for-enterprises/>.
 21. Satyam Prakash Srivastava ،Rupa Khanna Malhotra و ، Ranjit Kumar Mukherjee. (2024). Data Driven Decision Making in Insurance. 2023 International Conference on Smart Devices (ICSD) ، (الصفحات 5-1). Dehradun. doi:10.1109/ICSD60021.2024.10751068.

-
22. SentinelOne. (29 Aug, 2025). AI Vulnerability Management: Risks, Tools & Best Practices. تاريخ 6 الاسترداد Dec, 2025 من ، SentinelOne: <https://www.sentinelone.com/cybersecurity-101/cybersecurity/ai-vulnerability-management/>.
23. Sergiu Gatlan. (28 Mar, 2023). Microsoft brings GPT-4-powered Security Copilot to incident response. تاريخ 4 الاسترداد Dec, 2025 من ، BleepingComputer: <https://www.bleepingcomputer.com/news/microsoft/microsoft-brings-gpt-4-powered-security-copilot-to-incident-response/>.
24. Shashank Lohani ،Nimisha Asthana و ، Mohammad Osama. (2024). Data Analytics in Insurance Product Management. *Journal of Artificial Intelligence General science (JAIGS)* ،6(1) ،3006-4023. doi:10.60087.
25. Siddharth Misr و ،Hao Li .(2020) .Deep neural network architectures to approximate the fluid-filled pore size distributions of subsurface geological formations تأليف Siddharth Misra ،Hao Li و ،Jiabo He ،*Machine Learning for Subsurface Characterization* .(الصفحات 216-184) Elsevier Inc .doi:<https://doi.org/10.1016/C2018-0-01926-X>.
26. Xi Xin و ،Fei Huang .(2024) .Antidiscrimination Insurance Pricing: Regulations, Fairness Criteria,and Models .*North American Actuarial Journal* .319–285 ،28 ، doi:10.1080/10920277.2023.2190528.