

أثر تبني الذكاء الاصطناعي على اداء المصارف في العراق: تحليل قياسي باستخدام بيانات بانل للفترة (2015-2024)

م. عدنان طالب بختيار¹
جامعة كركوك - العراق

المقدمة:

يشهد القطاع المصرفي العالمي تحولاً تكنولوجياً عميقاً، إذ برز الذكاء الاصطناعي بوصفه محركاً رئيساً للابتكار والكفاءة والميزة التنافسية. وقد دفعت هذه الثورة التكنولوجية المصارف حول العالم إلى استثمار مليارات الدولارات في البنية التحتية للذكاء الاصطناعي، واستقطاب الكفاءات، على أمل تحقيق عوائد كبيرة بتحسين الكفاءة التشغيلية، وتعزيز إدارة المخاطر وتقديم تجارب مصرفية متميزة.

مشكلة البحث:

تتمثل مشكلة البحث في غياب أدلة قياسية حول أثر التبني الشامل للذكاء الاصطناعي على ربحية المصارف في الاقتصادات الخارجة من النزاعات، ولاسيما العراق، نتيجة تركّز الأدبيات على الأسواق المتقدمة، وقصر الأطر الزمنية، وضعف التحكم في الصدمات الاقتصادية الكلية.

أسئلة البحث:

- هل يؤثر تبني الذكاء الاصطناعي تأثيراً إيجابياً ومعنوياً على ربحية المصارف، مقاسة بـ ROA و ROE؟
- هل يستمر الأثر الإيجابي لتبني الذكاء الاصطناعي على ربحية المصارف بعد التحكم في المحددات التقليدية للأداء المصرفي؟
- هل يبقى أثر تبني الذكاء الاصطناعي على ربحية المصارف مستقرًا وذا دلالة إحصائية عبر الزمن؟ حتى في ظل الصدمات الاقتصادية الكلية؟

¹ جامعة كركوك، كلية الإدارة والاقتصاد، كركوك، العراق.

أهداف البحث:

مما تقدم في مشكلة البحث وأسئلته السابقة تشكلت مجموعة من الأهداف والغايات التي يمكن أن تسهم في توضيح هذه الأهداف:

1. الفحص التجريبي للعلاقة بين تبني الذكاء الاصطناعي وربحية المصارف (ROA) و ROE في العراق خلال الفترة 2015-2024.
2. بناء مؤشر شامل لتبني الذكاء الاصطناعي يعكس اتساع وعمق دمج هذه التكنولوجيا في الوظائف المصرفية.
3. تقييم استمرار العلاقة بين الذكاء الاصطناعي والربحية بعد التحكم في حجم المصرف، وكفاية رأس المال، والسيولة، ومخاطر الائتمان، وكفاءة التكاليف.
4. اختبار متانة النتائج باستعمال نماذج Pooled OLS والآثار الثابتة مع اختبارات تشخيصية شاملة.
5. تقديم رؤى سياساتية للجهات الرقابية، وإدارات المصارف، ووكالات التنمية

أهمية البحث:

يسهم البحث في توسيع منظور الموارد وأدبيات تبني التكنولوجيا باختبار دور الذكاء الاصطناعي في تعزيز ربحية المصارف داخل الاقتصادات الخارجة من النزاعات. وتقدم أول دليل قياسي لمنطقة الشرق الأوسط وشمال أفريقيا، بالاعتماد على تحليل بانل طويل الأجل (2015-2024)، وتطور مؤشراً ملائماً لقياس تبني الذكاء الاصطناعي في الأسواق الناشئة باستعمال إطار قياسي صارم.

منهج البحث:

تعتمد الدراسة على بيانات بانل متوازنة لـ 15 مصرفاً عراقياً خلال المدة (2015-2024) وبإجمالي 150 مشاهدة مصرف-سنة. واستعمال نماذج الانحدار التجميعي ونموذج الآثار الثابتة مع أخطاء معيارية متينة مجمعة، لقياس أثر تبني الذكاء الاصطناعي على ربحية المصارف المقاسة بالعائد على الموجودات (ROA) والعائد على حقوق الملكية (ROE)، مع التحكم في المحددات التقليدية للربحية والصدمات الاقتصادية الكلية.

الكلمات المفتاحية: الذكاء الاصطناعي، ربحية المصارف، العراق، بيانات البانل، الآثار الثابتة.

The Impact of Adopting Artificial Intelligence on the Performance of Banks in Iraq: An Econometric Analysis Using Panel Data for The Period(2024-2015)

Adnan Taleb Bakhtiar¹

Abstract:

This study analyses the impact of AI adoption on the profitability of commercial banks in Iraq, in the context of a post-conflict emerging economy, addressing a clear research gap in the banking literature. The study used balanced panel data from 15 Iraqi banks for 2015–2024, totalling 150 bank-year observations. A comprehensive AI adoption index was developed, reflecting the extent, breadth, and depth of AI integration across customer service, risk management, and operational processes. The study employed pooled regression models and a fixed-effects model with robust pooled standard errors to measure the impact of AI adoption on bank profitability, as measured by return on assets (ROA) and return on equity (ROE), while controlling for traditional determinants of profitability and macroeconomic shocks. The results showed a strong and significant positive impact of AI adoption on bank profitability. The fixed-effects model estimates that a one-unit increase in the AI adoption index raises return on assets by approximately 1.80 percentage points and return on equity by approximately 14.65 percentage points, at a high statistical significance level. These results remained robust even after accounting for fixed-time effects, reflecting the many shocks such as the COVID-19 pandemic. The study concludes that AI is an effective tool for enhancing banking performance, even in fragile institutional environments. This supports the hypothesis of technological leaps in post-conflict economies and provides important insights for policymakers and bank management regarding technology investment priorities.

Keywords: AI, bank profitability, Iraq, panel data, fixed effects, ROA, ROE, post-conflict economy.

¹ Kirkuk university, college of administration and economics, Kirkuk, Iraq.

المقدمة:

يشهد القطاع المصرفي العالمي تحولاً تكنولوجياً عميقاً، حيث برز الذكاء الاصطناعي بوصفه محركاً رئيسياً للابتكار والكفاءة والميزة التنافسية (Brynjolfsson & McAfee, 2017). فمن التداول الخوارزمي والمستشارين الآليين إلى روبوتات المحادثة وأنظمة كشف الاحتيال، انتشرت تطبيقات الذكاء الاصطناعي في مختلف جوانب العمل المصرفي، مما أعاد تشكيل كيفية تفاعل المؤسسات المالية مع الزبائن، وإدارة المخاطر، وتحقيق الأرباح (Buchanan, 2019). وقد دفعت هذه الثورة التكنولوجية المصارف حول العالم إلى استثمار مليارات الدولارات في البنية التحتية للذكاء الاصطناعي، واستقطاب الكفاءات، ودمج الأنظمة، على أمل تحقيق عوائد كبيرة من خلال تحسين الكفاءة التشغيلية، وتعزيز إدارة المخاطر، وتقديم تجارب مصرفية متميزة (Lee & Shin, 2018).

ويمثل القطاع المصرفي العراقي حالة بحثية فريدة ومهمة، لكنها لا تزال غير مدروسة بشكل كافٍ فيما يتعلق بأثر الذكاء الاصطناعي على الأداء المصرفي. إذ يعمل النظام المالي العراقي في بيئة شديدة التعقيد، تتسم بآثار الصراعات الممتدة، والاضطرابات المؤسسية، وتكرار الصدمات الاقتصادية الكلية (World Bank, 2023; International Monetary Fund, 2024). وخلال الفترة 2015-2024، واجهت المصارف العراقية تحديات كبرى تمثلت في صراع كثيرة ومنها جائحة كوفيد-19 العالمية (2020-2021)، إضافة إلى تقلبات أسعار النفط، مما خلق حاجة ملحة لتحسين الكفاءة التشغيلية، وفي الوقت نفسه فرض قيوداً شديدة على القدرة الاستثمارية.

مشكلة البحث: تتمثل مشكلة البحث في غياب أدلة قياسية حول أثر التبني الشامل للذكاء الاصطناعي على ربحية المصارف في الاقتصادات الخارجة من النزاعات، ولا سيما العراق، نتيجة تركّز الأدبيات على الأسواق المتقدمة، وقصر الأطر الزمنية، وضعف التحكم في الصدمات الاقتصادية الكلية.

أهداف البحث :

6. الفحص التجريبي للعلاقة بين تبني الذكاء الاصطناعي وربحية المصارف (ROA) و (ROE) في العراق خلال الفترة 2015-2024.
 7. بناء مؤشر شامل لتبني الذكاء الاصطناعي يعكس اتساع وعمق دمج هذه التكنولوجيا في الوظائف المصرفية.
 8. تقييم استمرار العلاقة بين الذكاء الاصطناعي والربحية بعد التحكم في حجم المصرف، وكفاية رأس المال، والسيولة، ومخاطر الائتمان، وكفاءة التكاليف.
 9. اختبار متانة النتائج باستخدام نماذج Pooled OLS والآثار الثابتة مع اختبارات تشخيصية شاملة.
 10. أخذ الصدمات الاقتصادية الكلية (كوفيد-19) وغيرها الكثير بنظر الاعتبار من خلال الآثار الزمنية الثابتة.
 11. تقديم رؤى سياساتية للجهات الرقابية، وإدارات المصارف، ووكالات التنمية
- ### أهمية البحث:

يسهم البحث في توسيع منظور الموارد وأدبيات تبني التكنولوجيا من خلال اختبار دور الذكاء الاصطناعي في تعزيز ربحية المصارف داخل الاقتصادات الخارجة من النزاعات. كما تقدّم أول دليل قياسي لمنطقة الشرق الأوسط وشمال أفريقيا، بالاعتماد على تحليل بانل طويل الأجل (2015-2024)، وتطوّر مؤشراً ملائماً لقياس تبني الذكاء الاصطناعي في الأسواق الناشئة باستخدام إطار قياسي صارم.

فرضيات البحث:

يقوم البحث على الفرضيات التالية

H1: يؤثر تبني الذكاء الاصطناعي تأثيراً إيجابياً ومعنوياً على ربحية المصارف، مقاسة بـ

ROA و ROE.

H2: يستمر الأثر الإيجابي لتبني الذكاء الاصطناعي على ربحية المصارف بعد التحكم في المحددات التقليدية للأداء المصرفي.

H3: يبقى أثر تبني الذكاء الاصطناعي على ربحية المصارف مستقرًا وذا دلالة إحصائية عبر الزمن، حتى في ظل الصدمات الاقتصادية الكلية.

نطاق وتنظيم الدراسة

تغطي الدراسة 15 مصرفًا تجاريًا عراقيًا خلال الفترة 2015–2024، تمثل نحو 85٪ من موجودات القطاع. وتشمل حدود الدراسة: (1) اعتماد مؤشر الذكاء الاصطناعي على مؤشرات قابلة للملاحظة؛ (2) استنتاج الآليات دون قياسها المباشر؛ (3) اعتماد التفسير السببي على افتراضات بيانات بانل؛ (4) خصوصية النتائج للسياق العراقي مع إمكانية تعميمها نظريًا.

هيكل الدراسة: يتناول القسم الأول الإطار النظري، ويستعرض القسم الثاني الأدبيات السابقة، ويعرض القسم الثالث المنهجية، ويقدم القسم الرابع النتائج، ويناقش القسم الخامس النتائج والدلالات، ويختتم القسم السادس الدراسة بالاستنتاجات.

1. مراجعة الأدبيات

لقد حظيت العلاقة بين الابتكار التكنولوجي والأداء المصرفي باهتمام واسع في الأدبيات المصرفية. ومع ذلك، لا تزال الدراسات التي تفحص بشكل مباشر أثر تبني الذكاء الاصطناعي (AI) على ربحية المصارف في الأسواق الناشئة محدودة. يستعرض هذا القسم الأدبيات السابقة المتعلقة بالذكاء الاصطناعي وتبني التكنولوجيا في القطاع المصرفي، مع التركيز على الدراسات التي تناولت مخرجات الأداء المالي. وقد تم تنظيم المراجعة بصورة موضوعية، بدءًا من الدراسات العامة حول تبني التكنولوجيا، ثم الانتقال إلى التطبيقات المحددة للذكاء الاصطناعي في المصارف، وصولًا إلى تحديد الفجوة البحثية التي تسعى هذه الدراسة إلى معالجتها.

1.1. الدراسات التجريبية حول الذكاء الاصطناعي والتكنولوجيا في المصارف

1.1.1. تبني الذكاء الاصطناعي والكفاءة التشغيلية

أجرى Cheng و Qu (2020) دراسة شاملة لفحص أثر تطبيق الذكاء الاصطناعي على الكفاءة التشغيلية للمصارف التجارية في الصين. وباستخدام عينة مكونة من 45 مصرفًا تجاريًا

صينياً خلال الفترة 2012-2018، اعتمدا أسلوب تحليل مغلف البيانات (DEA) لقياس مؤشرات الكفاءة، ثم قاما بتحليل العلاقة بين كثافة تبني الذكاء الاصطناعي وهذه المؤشرات. وأظهرت النتائج أن تبني الذكاء الاصطناعي أدى إلى تحسين الكفاءة الفنية بنسبة 12.3٪ وكفاءة التكاليف بنسبة 15.7٪، مع تحقيق المصارف الكبيرة فوائد أكبر نتيجة وفورات الحجم في نشر التكنولوجيا. كما بينت الدراسة أن الأتمتة المعتمدة على الذكاء الاصطناعي، ولا سيما في خدمات الزبائن والعمليات الخلفية، تسهم في خفض التكاليف التشغيلية وتحسين جودة الخدمة في آن واحد. إلا أن Cheng و Qu (2020) أشارا إلى أن مكاسب الكفاءة تعتمد على توفر التدريب الكافي للموظفين وجاهزية المنظمة، مما يؤكد أن التكنولوجيا وحدها لا تكفي دون استثمارات مكملة في رأس المال البشري.

1.1.2. التعلم الآلي في إدارة مخاطر الائتمان

ركز Khandani وآخرون (2021) على تقييم تطبيق خوارزميات التعلم الآلي في تحسين دقة التنبؤ بتعثر القروض وأثر ذلك في ربحية المصارف. واعتمدت دراستهم على محفظة الإقراض لأحد المصارف التجارية الكبرى في الولايات المتحدة خلال الفترة 2015-2019، حيث أظهرت النتائج أن نماذج التعلم الآلي—ولا سيما الغابات العشوائية وآلات التعزيز التدرجي—تفوقت على أساليب التقييم الائتماني التقليدية بنسبة 23٪ من حيث دقة التنبؤ. والأهم من ذلك، أن تطبيق هذه النماذج أدى إلى خفض نسبة القروض المتعثرة بمقدار 1.8 نقطة مئوية، وزيادة العائد على الموجودات (ROA) بمقدار 0.4 نقطة مئوية خلال ثلاث سنوات من التطبيق. وعزا الباحثون هذه التحسينات إلى تحسين التسعير المعدل بالمخاطر، وتعزيز تنوع المحافظ، والاكتشاف المبكر لحالات التعثر المحتملة، مما يسمح بالتدخل الاستباقي. كما أبرزت الدراسة أن فوائد الذكاء الاصطناعي في إدارة مخاطر الائتمان لا تقتصر على دقة التنبؤ، بل تشمل تسريع اتخاذ القرار وخفض تكاليف المعالجة.

1.1.3. التحول الرقمي والأداء المصرفي في أوروبا

في سياق أوسع للتحول الرقمي، قام Hornuf وآخرون (2021) بتحليل العلاقة بين تبني التقنيات الرقمية والأداء المالي للمصارف الأوروبية. وباستخدام بيانات بانل لـ 156 مصرفاً

في 15 دولة أوروبية خلال الفترة 2014-2019، أنشأ الباحثون مؤشراً شاملاً للتحويل الرقمي يشمل الذكاء الاصطناعي، وتحليلات البيانات الضخمة، والحوسبة السحابية، والخدمات المصرفية عبر الهاتف المحمول. وأظهرت نتائج نماذج الآثار الثابتة وجود علاقة إيجابية ذات دلالة إحصائية بين التحويل الرقمي والربحية، حيث ارتبطت زيادة انحراف معياري واحد في مؤشر التحويل الرقمي بزيادة قدرها 0.35 نقطة مئوية في العائد على حقوق الملكية (ROE). كما بينت الدراسة أن هذا الأثر يختلف باختلاف حجم المصرف ونموذج أعماله، إذ حققت المصارف ذات التوجه التجزئي مكاسب ربحية أكبر مقارنة بالمصارف الاستثمارية. إضافة إلى ذلك، تم رصد أثر منحني (J)، حيث تنخفض الربحية في السنوات الأولى نتيجة ارتفاع التكاليف الاستثمارية، قبل أن تتحقق مكاسب كبيرة في المراحل اللاحقة مع نضوج التكنولوجيا.

1.1.4. منافسة شركات التكنولوجيا المالية وأداء المصارف التقليدية

بحث Lee وآخرون (2021) في كيفية تأثير تبني المصارف التقليدية لتقنيات الذكاء الاصطناعي والابتكارات المالية على مركزها التنافسي وربحيتها في ظل تصاعد منافسة شركات التكنولوجيا المالية. واعتمدت الدراسة على تحليل 89 مصرفاً في ست اقتصادات آسيوية خلال الفترة 2016-2020 باستخدام أسلوب الفرق في الفرق (Difference-in-Differences). وأظهرت النتائج أن المصارف التي تبنت الذكاء الاصطناعي بشكل مكثف حققت نمواً في العائد على الموجودات أعلى بمقدار 2.1 نقطة مئوية مقارنة بالمصارف ذات التبني المحدود. وحدد الباحثون ثلاث قنوات رئيسة لتعزيز الربحية: تحسين استقطاب الزبائن والاحتفاظ بهم، خفض التكاليف التشغيلية عبر الأتمتة، وتعزيز الإيرادات من خلال البيع المتقاطع المدعوم بالذكاء الاصطناعي. كما كشفت الدراسة أن تبني الذكاء الاصطناعي ساعد المصارف التقليدية على تقليص فقدان الحصة السوقية بنسبة 40٪ مقارنة بالمصارف غير المتبينة.

1.1.5. الذكاء الاصطناعي في كشف الاحتيال وإدارة المخاطر

ركّز Ngai وآخرون (2022) على فعالية أنظمة كشف الاحتيال المعتمدة على الذكاء الاصطناعي في خفض الخسائر المالية وتحسين ربحية المصارف. وشملت دراستهم 67 مصرفاً في أمريكا الشمالية وأوروبا خلال الفترة 2017-2021 باستخدام منهجية دراسة الحدث. وأظهرت النتائج أن هذه الأنظمة أسهمت في خفض الخسائر الناتجة عن الاحتيال بنسبة 58٪ في السنة الأولى و 73٪ في السنة الثالثة، مما انعكس على تحسن سنوي في ROA بمقدار 0.22 نقطة مئوية. كما بينت الدراسة أن الخوارزميات المتقدمة، ولا سيما الشبكات العصبية العميقة، قادرة على كشف أنماط احتيال معقدة لا ترصدها الأنظمة التقليدية، فضلاً عن تعزيز ثقة الزبائن وزيادة الودائع.

1.1.6. تبني الذكاء الاصطناعي في مصارف الأسواق الناشئة

أجرى Gomber وآخرون (2023) دراسة مقارنة حول أنماط تبني الذكاء الاصطناعي وأثرها في ربحية المصارف في الاقتصادات الناشئة والمتقدمة. وشملت العينة 234 مصرفاً في 25 سوقاً ناشئاً و 189 مصرفاً في 15 اقتصاداً متقدماً خلال الفترة 2015-2022. وأظهرت النتائج أن تبني الذكاء الاصطناعي يؤدي إلى زيادة ربحية المصارف في كلا السياقين، إلا أن الأثر كان أقوى في الأسواق الناشئة، حيث ارتفع ROA بمقدار 1.6 نقطة مئوية خلال أربع سنوات، مقابل 0.9 نقطة مئوية في الاقتصادات المتقدمة. وعزا الباحثون ذلك إلى ظاهرة القفز التكنولوجي، رغم التحديات التنظيمية والبنوية التي تواجهها المصارف في الأسواق الناشئة.

1.1.7. معالجة اللغة الطبيعية في خدمة الزبائن

درس Zhang و Liu (2023) أثر تطبيق تقنيات معالجة اللغة الطبيعية، مثل روبوتات المحادثة والمساعدات الافتراضيين، على رضا الزبائن وربحية المصارف. وتبعت الدراسة 42 مصرفاً طبقت هذه التقنيات بين 2018-2022، وأظهرت النتائج انخفاض تكاليف خدمة الزبائن بنسبة 35٪ وتحسن رضا الزبائن بنسبة 18٪، مما أدى إلى زيادة ROA بمقدار 0.31 نقطة مئوية وانخفاض معدل فقدان الزبائن بنسبة 2.8٪.

1.1.8. التخصيص المعتمد على الذكاء الاصطناعي وتوليد الإيرادات

تناول Barman وآخرون (2024) أثر أنظمة التخصيص والتوصية المعتمدة على الذكاء الاصطناعي في توليد الإيرادات وربحية المصارف. وأظهرت النتائج زيادة نجاح البيع المتقاطع بنسبة 47٪ وارتفاع متوسط الإيرادات لكل زبون بنسبة 23٪، مما انعكس على تحسن ROE بمقدار 0.45 نقطة مئوية خلال ثلاث سنوات.

1.2. استخلاص الأدبيات والفجوة البحثية

تشير الأدبيات المستعرضة إلى وجود أثر إيجابي واضح لتبني الذكاء الاصطناعي في تحسين كفاءة المصارف، وإدارة المخاطر، ورضا الزبائن، وتوليد الإيرادات. ومع ذلك، لا تزال هناك فجوات بحثية مهمة، أبرزها محدودية الدراسات في الأسواق الناشئة والشرق الأوسط، وغياب الأبحاث التي تتناول سياقات ما بعد الصراع مثل العراق، فضلاً عن قلة الدراسات التي تعتمد مقارنة شاملة لتبني الذكاء الاصطناعي وفترات زمنية طويلة مع التحكم في الصدمات الاقتصادية الكلية.

وتسعى هذه الدراسة إلى سد هذه الفجوات من خلال تقديم أول تحليل تجريبي شامل لأثر تبني الذكاء الاصطناعي على ربحية المصارف العراقية باستخدام بيانات بانل للفترة 2015-2024، مع تطبيق أساليب قياسية متقدمة للتحكم في التغيرات غير المرصود والصدمات الاقتصادية الكلية المتغيرة عبر الزمن.

3. الإطار النظري – (Theoretical Background) :-

يمثل الذكاء الاصطناعي (AI) نموذجًا تكنولوجيًا تحويليًا يمكن الأنظمة الحاسوبية من أداء مهام معرفية كانت حكرًا على البشر، مثل التعلم واتخاذ القرار (Brynjolfsson & McAfee، 2017). وفي القطاع المصرفي، يشمل الذكاء الاصطناعي تطبيقات متنوعة، من خوارزميات التعلم الآلي لتقييم مخاطر الائتمان إلى تقنيات معالجة اللغة الطبيعية لأتمتة خدمات الزبائن (Buchanan، 2019). وقد تسارع تبني هذه التقنيات في الخدمات المالية خلال العقد الأخير نتيجة التقدم في القدرات الحاسوبية وتوافر البيانات الضخمة وتطور الخوارزميات (Lee & Shin، 2018).

ويستند تفسير أثر الذكاء الاصطناعي على الأداء المصرفي إلى عدة أطر نظرية مترابطة. فمن منظور الموارد، تُعد تقنيات الذكاء الاصطناعي موارد استراتيجية قادرة على توليد ميزة تنافسية مستدامة عند توظيفها بكفاءة. (Barman et al., 2024) كما تفسر نظريات تبني التكنولوجيا وانتشار الابتكارات تباين معدلات التبني بين المصارف باختلاف الحجم والثقافة التنظيمية والموقع التنافسي. (Gomber et al., 2023) إضافة إلى ذلك، تؤكد فرضية الكفاءة في العمل المصرفي أن الابتكارات التكنولوجية تسهم في خفض التكاليف التشغيلية وتحسين تخصيص الموارد، بما ينعكس إيجاباً على الربحية. (Berger & Humphrey, 1997)

وتغطي تطبيقات الذكاء الاصطناعي في القطاع المصرفي أربعة مجالات رئيسة تشمل: التطبيقات الموجهة للزبائن، وإدارة المخاطر والامتثال، وتحسين الكفاءة التشغيلية عبر أتمتة العمليات، ودعم القرار الاستراتيجي. (Zhang & Liu, 2023) وتعمل هذه التطبيقات على تعزيز الربحية من خلال قنوات أساسية تتمثل في خفض التكاليف التشغيلية (Cheng & Qu, 2020؛ Fiordelisi et al., 2011)، وتحسين إدارة المخاطر وجودة الائتمان وتقليل الخسائر (Khandani et al., 2021؛ Ngai et al., 2022)، فضلاً عن تعزيز الإيرادات عبر التخصيص وتحليل سلوك الزبائن (Barman et al., 2024؛ Zhang & Liu, 2023)، وتحسين الموقع التنافسي والحصة السوقية. (Lee et al., 2021)

ورغم عمومية هذه الآليات، فإن فاعليتها تختلف باختلاف السياق المؤسسي. ففي الأسواق الناشئة، تتيح فرص القفز التكنولوجي تجاوز قيود الأنظمة التقليدية، ما قد يعزز الأثر الربحي للذكاء الاصطناعي. (Gomber et al., 2023) غير أن هذه الأسواق تواجه تحديات تتعلق بضعف البنية التحتية للبيانات، وندرة الكفاءات، وعدم اليقين التنظيمي. ويجسد القطاع المصرفي العراقي هذه الخصوصية، إذ يتزامن التحديث التكنولوجي مع إعادة البناء المؤسسي في ظل صدمات اقتصادية وأمنية متكررة، ما يجعل دراسة أثر الذكاء الاصطناعي على ربحية المصارف ذات أهمية نظرية وتطبيقية.

2. المنهجية (METHODOLOGY)

2.1. البيانات والعينة (Data and Sample)

تعتمد هذه الدراسة على بيانات بانل متوازنة تغطي 15 مصرفاً تجارياً عراقياً خلال الفترة 2015-2024، وإجمالي 150 مشاهدة مصرف-سنة. وتشمل العينة مصارف مملوكة للدولة (مصرفان)، ومصارف تجارية خاصة (11 مصرفاً)، ومصارف إسلامية (مصرفان)، بما يمثل نحو 85٪ من إجمالي موجودات القطاع المصرفي العراقي. تم جمع البيانات من التقارير المالية السنوية للمصارف، والنشرات الإحصائية للبنك المركزي العراقي، مع استكمالها بمؤشرات الاقتصاد الكلي المستمدة من قواعد بيانات البنك الدولي وصندوق النقد الدولي. وتغطي فترة الدراسة أحداثاً محورية، من بينها جائحة كوفيد-19 (2020-2021)، مما يوفر تبايناً غنياً في الظروف الاقتصادية الكلية.

2.2. قياس المتغيرات (Variable Measurement)

المتغيرات التابعة.: تم قياس ربحية المصارف باستخدام مقياسين شائعين في الأدبيات المصرفية، هما:

- العائد على الموجودات (ROA)، ويُحسب بقسمة صافي الدخل على إجمالي الموجودات.
 - العائد على حقوق الملكية (ROE)، ويُحسب بقسمة صافي الدخل على إجمالي حقوق الملكية.
- وتعكس هذه المقاييس كفاءة استخدام الموجودات والعوائد المحققة للمساهمين.
- المتغير المستقل.: يتم التعبير عن تبني الذكاء الاصطناعي من خلال مؤشر شامل لتبني الذكاء الاصطناعي (AI Adoption Index) (AI) تتراوح قيمته بين 0 و1، وقد تم بناؤه استناداً إلى مدى تطبيق المصارف للتقنيات الرقمية، بما في ذلك أنظمة الأتمتة، ومنصات تحليل البيانات، وخوارزميات التعلم الآلي لتقييم الجدارة الائتمانية وكشف الاحتيال، وتطبيقات روبوتات المحادثة، وأنظمة إدارة علاقات الزبائن المعتمدة على الذكاء الاصطناعي. ويعكس هذا المؤشر كلاً من الاتساع (عدد تطبيقات الذكاء الاصطناعي) والعمق (شدة الاستخدام) في تكامل الذكاء الاصطناعي داخل العمليات المصرفية.

المتغيرات الضابطة.: اتباعاً للأدبيات المصرفية (Athanasoglou et al., 2008; Petria et al., 2015)، تم التحكم في مجموعة من المتغيرات، تشمل:

1. حجم المصرف (Bank Size) ويقاس باللوغاريتم الطبيعي لإجمالي الموجودات.
 2. كفاية رأس المال (Capital Adequacy) وتُقاس بنسبة حقوق الملكية إلى إجمالي الموجودات.
 3. السيولة (Liquidity Ratio) وتُقاس بنسبة الموجودات السائلة إلى إجمالي الموجودات.
 4. مخاطر الائتمان (Credit Risk) ويُعبر عنها بنسبة القروض المتعثرة (NPL).
 5. كفاءة التكاليف (Cost Efficiency) وتُقاس بنسبة التكاليف إلى الإيرادات.
- كما تم تضمين الآثار الزمنية الثابتة (Year Fixed Effects) للتحكم في الصدمات الاقتصادية الكلية والاتجاهات العامة المتغيرة عبر الزمن.

2.3. الصياغة القياسية (Econometric Specification)

لفحص العلاقة بين تبني الذكاء الاصطناعي وربحية المصارف مع التحكم في التغير غير المرصود، تم تقدير نموذج بيانات بانل الآتي:

$$Profitability_{it} = \alpha + \beta AI_{it} + \gamma_1 Size_{it} + \gamma_2 Capital_{it} + \gamma_3 Liquidity_{it} + \gamma_4 NPL_{it} + \gamma_5 CostEfficiency_{it} + \mu_i + \lambda_t + \varepsilon_{it}$$

حيث يشير الرمز iii إلى المصارف، ويشير الرمز ttt إلى السنوات، وتمثل μ_i الآثار الثابتة الخاصة بكل مصرف، بينما تمثل λ_t الآثار الزمنية الثابتة، ويعبر ε_{it} عن حد الخطأ العشوائي. ويُعد المعامل β محل الاهتمام الرئيس في هذه الدراسة، إذ يقيس الأثر المتوسط لتبني الذكاء الاصطناعي على ربحية المصارف.

2.4. استراتيجية التقدير (Estimation Strategy)

تعتمد الدراسة على منهجين تكميليين في التقدير. أولاً، يتم تقدير نموذج الانحدار التجميعي بطريقة المربعات الصغرى الاعتيادية (Pooled Ordinary Least Squares – OLS) باستخدام أخطاء معيارية متينة لمعالجة مشكلة تباين التباين غير المتجانس (White, 1980)، وذلك بهدف الحصول على نتائج مرجعية أولية.

ثانيًا، ونظرًا لاحتمال ارتباط الخصائص غير المرصودة الخاصة بالمصارف—مثل جودة الإدارة، والثقافة التنظيمية، والقدرات التكنولوجية—بكل من تبني الذكاء الاصطناعي والربحية، يتم اعتماد نموذج الآثار الثابتة (Fixed Effects – FE) باستخدام تحويل المتوسطات الداخلية (Within Transformation) كما ورد في (Baltagi (2021). ويعمل مقدّر الآثار الثابتة على إزالة التغير غير المرصود الثابت عبر الزمن من خلال طرح المتوسط الزمني لكل مصرف من جميع المتغيرات، مما يسمح بتقدير أكثر دقة للآثار الصافي لتبني الذكاء الاصطناعي.

ولمعالجة احتمال وجود ارتباط تسلسلي وتباين تغاير غير متجانس في نموذج الآثار الثابتة، يتم استخدام أخطاء معيارية متينة مجمعة على مستوى المصرف (Cluster-Robust Standard Errors) وفقًا لما اقترحه Cameron و (2005) Trivedi كما يتم إجراء اختبار هاوسمان (Hausman Test) للمقارنة الرسمية بين نموذجي الآثار الثابتة والآثار العشوائية، وتحديد النموذج الأنسب للتقدير.

إضافة إلى ذلك، يتم تنفيذ مجموعة شاملة من الاختبارات التشخيصية للتحقق من سلامة النماذج القياسية، وتشمل اختبار بريوش-باغان (Breusch-Pagan Test) للكشف عن تباين التغاير غير المتجانس، واختبار جارك-بيرا (Jarque-Bera Test) للتحقق من طبيعية المتبقيات، وتحليل عامل تضخم التباين (Variance Inflation Factor – VIF) لتقييم مشكلة التعدد الخطي بين المتغيرات المستقلة.

وقد أُجريت جميع التحليلات الإحصائية باستخدام لغة البرمجة (Python) الإصدار (3.12)، بالاعتماد على مكتبات Pandas و NumPy و SciPy، بما يضمن الدقة وقابلية إعادة التكرار في التحليل القياسي.

النتائج (RESULTS) والتحليل القياسي

يعرض هذا القسم النتائج التجريبية المستخلصة من تحليل بيانات البائل الذي يهدف إلى فحص أثر تبني الذكاء الاصطناعي (AI) على ربحية المصارف العراقية خلال الفترة 2015-2024. وقد تم تنظيم التحليل على النحو الآتي: يقدم القسم 3.1 الإحصاءات الوصفية والتحليل الأولي للبيانات؛ ويعرض القسم 3.2 تحليل الارتباط بين المتغيرات؛ بينما يقدم القسم 3.3 نتائج نماذج الانحدار الرئيسة باستخدام كل من نموذج الانحدار التجميعي (Pooled OLS) ونموذج الآثار الثابتة (Fixed Effects)؛ ويتناول القسم 3.4 اختبارات المتانة والاختبارات التشخيصية؛ في حين يخصص القسم 3.5 لتفسير النتائج من الناحية الاقتصادية.

3.1. الإحصاءات الوصفية (Descriptive Statistics)

يعرض الجدول (1) الإحصاءات الوصفية للمتغيرات الرئيسة المستخدمة في التحليل. وتتكون العينة من 150 مشاهدة مصرف-سنة تمثل 15 مصرفاً عراقياً خلال فترة زمنية امتدت لعشر سنوات. ويُظهر مؤشر تبني الذكاء الاصطناعي—وهو المتغير المستقل الرئيس محل الاهتمام—تبايناً ملحوظاً بين المصارف وعبر الزمن، حيث بلغ متوسطه 0.217 بانحراف معياري قدره 0.138. كما تراوحت قيم المؤشر بين حد أدنى بلغ 0.046 وحد أقصى بلغ 0.542، مما يشير إلى وجود تباين كبير في مستويات تبني تقنيات الذكاء الاصطناعي بين المصارف العراقية، ويعكس اختلافات واضحة في الاستراتيجيات التكنولوجية والقدرات الرقمية بين هذه المصارف.

Table 1: Descriptive Statistics

Variable	N	Mean	Std. Dev.	Min	25%	Median	75%	Max
AI Adoption Index	150	0.2166	0.1382	0.0462	0.0834	0.1962	0.3240	0.5423
ROA	150	-0.0036	0.0068	-0.0200	-0.0084	-0.0040	0.0006	0.0125
ROE	150	-0.0266	0.0571	-0.1500	-0.0655	-0.0292	0.0134	0.1059
Bank Size Log	150	21.3965	0.9265	19.3619	20.8580	21.3293	21.9280	23.6424
Capital Adequacy	150	0.1260	0.0155	0.0864	0.1146	0.1262	0.1373	0.1628
Liquidity Ratio	150	0.2878	0.0356	0.2201	0.2608	0.2828	0.3145	0.3862
NPL Ratio	150	0.0967	0.0223	0.0448	0.0806	0.0963	0.1129	0.1503
Cost to Income Ratio	150	0.6113	0.0684	0.4614	0.5661	0.6116	0.6493	0.7724

Notes: This table presents descriptive statistics for the main variables used in the analysis.


المصدر: إعداد الباحث بالاعتماد على: التقارير المالية السنوية للمصارف التجارية العراقية للفترة 2015-2024، والمستقاة من المواقع الرسمية للمصارف و وحدات علاقات المستثمرين؛ النشرة الإحصائية السنوية للبنك المركزي العراقي (2015-2024) تقارير القطاع المصرفي الصادرة عن البنك المركزي العراقي؛ قاعدة بيانات التنمية المالية العالمية الصادرة عن البنك الدولي. وقد أُجريت العمليات والحسابات الإحصائية باستخدام لغة البرمجة (Python) الإصدار (3.12) وبالاعتماد على مكتبات NumPy وPandas تُظهر المتغيرات التابعة، والمتمثلة في العائد على الموجودات (ROA) والعائد على حقوق الملكية (ROE)، متوسطات بلغت -0.36% و -0.36% على التوالي، وهو ما يعكس بيئة التشغيل الصعبة التي واجهتها المصارف العراقية خلال فترة الدراسة، والتي تزامنت مع صدمات اقتصادية كلية كبرى، منها جائحة كوفيد-19 (2020-2021). ومع ذلك، يلاحظ وجود تباين ملحوظ في مؤشري الربحية، إذ بلغ الانحراف المعياري 0.68% للعائد على الموجودات و 5.69% للعائد على حقوق الملكية، مما يشير إلى اختلافات كبيرة في مستويات الأداء بين المصارف.

وفيما يخص المتغيرات الضابطة، بلغ متوسط حجم المصرف—المقاس باللوغاريتم الطبيعي لإجمالي الموجودات—نحو 21.45، وهو ما يعادل تقريباً 2.1 تريليون دينار عراقي من إجمالي الموجودات. كما بلغ متوسط نسبة كفاية رأس المال 11.7% ، مما يدل على أن المصارف العراقية تحافظ عموماً على هوامش رأسمالية تفوق الحدود الرقابية الدنيا. في المقابل، بلغ متوسط نسبة القروض المتعثرة 9.67% (NPL)، وهو ما يعكس التحديات الكبيرة المرتبطة بمخاطر الائتمان في القطاع المصرفي العراقي. أما نسبة التكاليف إلى الإيرادات، فقد بلغ متوسطها 61.1% ، مما يشير إلى مستوى متوسط من الكفاءة التشغيلية.

يوضح الشكل (1) تطور المتغيرات الرئيسة خلال فترة الدراسة. يبين الجزء (A) اتجاهات تبني الذكاء الاصطناعي حسب نوع المصرف، حيث يتضح أن المصارف الخاصة كانت الأسرع في تبني تقنيات الذكاء الاصطناعي مقارنة بالمصارف المملوكة للدولة. ويعرض الجزء (B) متوسط العائد على الموجودات عبر الزمن، مبرزاً الأثر الشديد لكل الصدمات

ومنها جائحة كوفيد-19، إذ تحولت الربحية إلى قيم موجبة فقط في السنوات الأخيرة (2022-2024) مع تسارع وتيرة تبني الذكاء الاصطناعي. كما يعرض الجزآن (C) و (D) توزيعات كل من مؤشر تبني الذكاء الاصطناعي والعائد على الموجودات، حيث يظهر كلا التوزيعين درجة معقولة من التقارب مع التوزيع الطبيعي مع ميل إيجابي طفيف، كما هو موضح في الشكل (1).

الشكل (1): الإحصاءات الوصفية – اتجاهات تبني الذكاء الاصطناعي وتوزيع الربحية



المصدر: إعداد الباحث بالاعتماد على بيانات بانل تغطي 15 مصرفاً عراقياً خلال الفترة 2024-2015.

يوضح الجزء (A) مسارات تبني الذكاء الاصطناعي حسب نوع ملكية المصرف (مصارف مملوكة للدولة، مصارف خاصة، ومصارف إسلامية)، وذلك استناداً إلى مؤشر تبني الذكاء الاصطناعي. ويعرض الجزء (B) تطور متوسط العائد على الموجودات (ROA) عبر الزمن. أما الجزآن (C) و (D) فيقدمان التوزيعات التكرارية لكل من مؤشر تبني الذكاء الاصطناعي والعائد على الموجودات (ROA) على التوالي، مع إظهار تقديرات كثافة النواة (Kernel Density Estimates). تم تجميع البيانات من التقارير السنوية للمصارف والنشرات الإحصائية للبنك المركزي العراقي، كما جرى إعداد الرسوم البيانية باستخدام لغة البرمجة Python الإصدار 3.12) وبالاتماد على مكتبات Matplotlib وSeaborn، وبدقة عرض 300 DPI.

3.2. تحليل الارتباط (Correlation Analysis)

يعرض الجدول (2) معاملات ارتباط بيرسون بين المتغيرات الرئيسة محل الدراسة. وبما يتسق مع فرضيات البحث، يُظهر تبني الذكاء الاصطناعي ارتباطاً إيجابياً قوياً مع كل من مؤشري الربحية، حيث بلغ معامل الارتباط مع العائد على الموجودات (ROA) 0.820 ومع العائد على حقوق الملكية (ROE) 0.806، وكلاهما ذو دلالة إحصائية عالية عند مستوى $p < 0.001$. وتوفر هذه النتائج دليلاً أولياً يدعم الأثر الإيجابي لتبني الذكاء الاصطناعي في تحسين الأداء المصرفي.

كما يقدم الشكل (2) تأكيداً بصرياً لهذه العلاقات من خلال مخططات الانتشار المصحوبة بخطوط الانحدار المقدّرة، والتي تُظهر ارتباطات إيجابية واضحة بين تبني الذكاء الاصطناعي وكل من العائد على الموجودات (الجزء A) والعائد على حقوق الملكية (الجزء B)، كما هو موضح في الجدول (2).

Table 2: Correlation Matrix


Variable	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
(1) AI Adoption	1.000	0.820	0.806	0.036	0.211	-0.213	-0.528	-0.667
(2) ROA	0.820	1.000	0.975	0.286	0.186	-0.244	-0.775	-0.704
(3) ROE	0.806	0.975	1.000	0.301	0.300	-0.222	-0.740	-0.687
(4) Bank Size	0.036	0.286	0.301	1.000	0.308	-0.051	-0.303	-0.351
(5) Capital Adequacy	0.211	0.186	0.300	0.308	1.000	-0.138	0.056	-0.148
(6) Liquidity	-0.213	-0.244	-0.222	-0.051	-0.138	1.000	0.204	0.192
(7) NPL Ratio	-0.528	-0.775	-0.740	-0.303	0.056	0.204	1.000	0.581
(8) Cost/Income	-0.667	-0.704	-0.687	-0.351	-0.148	0.192	0.581	1.000

Notes: Pearson correlation coefficients are reported. Shaded cells indicate $|r| > 0.5$.

المصدر: إعداد الباحث بالاعتماد على بيانات بانل تم تجميعها من:
 (1) القوائم المالية السنوية لـ 15 مصرفاً تجارياً عراقياً للفترة 2015-2024؛
 (2) مؤشرات تبني الذكاء الاصطناعي المستخلصة من التقارير السنوية للمصارف،
 وإفصاحات التكنولوجيا، والاستبيانات التكميلية الموجهة إلى مسؤولي التكنولوجيا في

المصارف؛ (3) بيانات الرقابة والإشراف الصادرة عن البنك المركزي العراقي. وقد تم احتساب معاملات ارتباط بيرسون باستخدام لغة البرمجة Python الإصدار 3.12 (وبالاعتماد على مكتبة SciPy، مع اختبار الدلالة الإحصائية عند مستويات 1% و 5% و 10%.

الشكل (2): العلاقة بين تبني الذكاء الاصطناعي والربحية (مخططات الانتشار)




المصدر: إعداد الباحث بالاعتماد على تحليل ثنائي المتغيرات بين مؤشر تبني الذكاء الاصطناعي ومقاييس الربحية. يوضح الجزء (A) العلاقة بين تبني الذكاء الاصطناعي والعائد على الموجودات (ROA) حيث بلغ معامل الارتباط $r = 0.820$ عند مستوى دلالة إحصائية $p < 0.001$ ، بينما يوضح الجزء (B) العلاقة بين تبني الذكاء الاصطناعي والعائد على حقوق الملكية (ROE) حيث بلغ معامل الارتباط $r = 0.806$ عند مستوى دلالة إحصائية $p < 0.001$. وتمثل كل نقطة مشاهدة مصرف-سنة ($N = 150$)، مع تمييزها لونيًا بحسب السنة لإبراز الأنماط الزمنية. كما تم إظهار خطوط الانحدار الخطي مع فواصل الثقة عند مستوى 95%. وقد تم عرض معاملات ارتباط بيرسون ومستويات الدلالة الإحصائية، فيما تعود مصادر

البيانات إلى ما هو موضح في الجدول (1). وتم إنشاء الرسوم البيانية باستخدام لغة البرمجة

(Python الإصدار 3.12) وبالاعتماد على مكتبات Matplotlib و Seaborn.

ما هو متوقع، تُظهر نسبة القروض المتعثرة (NPL) ارتباطات سلبية قوية مع مؤشري الربحية، حيث بلغ معامل الارتباط -0.775 مع العائد على الموجودات (ROA) و -0.756 مع العائد على حقوق الملكية (ROE)، مما يشير إلى أن مخاطر الائتمان تُضعف الأداء المصرفي بشكل كبير. وبالمثل، تُظهر نسبة التكاليف إلى الإيرادات ارتباطاً سلبياً مع الربحية ($r = -0.704$) مع (ROA)، وهو ما يدل على أن عدم الكفاءة التشغيلية يسهم في انخفاض الربحية. في المقابل، يُظهر حجم المصرف ارتباطات إيجابية ضعيفة مع مؤشري الربحية، بينما تُسجل نسب كفاية رأس المال والسيولة ارتباطات معتدلة، بما يعكس أدواراً داعمة ولكنها أقل تأثيراً مقارنة بمخاطر الائتمان والكفاءة التشغيلية. وفيما يتعلق بمخاوف التعدد الخطي، يبيّن مصفوفة الارتباط (الشكل 3) أنه على الرغم من وجود ارتباطات متوسطة بين بعض المتغيرات الضابطة—مثل الارتباط السلبي بين تبني الذكاء الاصطناعي ونسبة التكاليف إلى الإيرادات—($r = -0.667$) إلا أن أيًا من معاملات الارتباط لا يتجاوز العتبة الشائعة البالغة 0.80 التي تشير إلى وجود مشكلة تعدد خطي حادة. ويتم تأكيد ذلك بشكل إضافي من خلال تحليل عامل تضخم التباين (VIF) المعروض في القسم (3.4)، حيث جاءت جميع قيم VIF دون الحد التقليدي البالغ 10، مما يشير إلى عدم وجود مشكلات جوهرية تتعلق بالتعدد الخطي بين المتغيرات المستقلة انظر الشكل 3

الشكل (3) خريطة حرارية لمصفوفة الارتباط



المصدر: إعداد الباحث بوصفه تمثيلاً بصرياً لمعاملات ارتباط بيرسون المعروضة في الجدول (2). تستخدم الخريطة الحرارية تدرجاً لونياً متبايناً بالأزرق-الأحمر (لوحة الألوان $RdBu_r$)، حيث يشير اللون الأحمر الداكن إلى ارتباطات إيجابية قوية، بينما يشير اللون الأزرق الداكن إلى ارتباطات سلبية قوية. ولتجنب التكرار، تم عرض الجزء السفلي فقط من مصفوفة الارتباط. كما تم توضيح قيم معاملات الارتباط داخل الخلايا لتسهيل القراءة الدقيقة. وتشمل المصفوفة جميع المتغيرات الرئيسة الثمانية، وهي: مؤشر تبني الذكاء الاصطناعي، العائد على الموجودات (ROA)، العائد على حقوق الملكية (ROE)، حجم المصرف، كفاية رأس المال، نسبة السيولة، نسبة القروض المتعثرة (NPL)، ونسبة التكاليف إلى الإيرادات. وقد تم إنشاء الخريطة الحرارية باستخدام لغة البرمجة Python الإصدار

3.12 (وبالاعتماد على مكتبة Seaborn).

3.3. النتائج الرئيسة للانحدار (Main Regression Results)

يعرض الجدول (3) النتائج الرئيسة لنماذج الانحدار المقدرة باستخدام كل من طريقة المربعات الصغرى الاعتيادية التجميعية (Pooled Ordinary Least Squares – OLS) ونموذج بيانات البانل ذي الآثار الثابتة (Fixed Effects – FE). وتوضح الأعمدة (1) و(2) نتائج نموذج الانحدار التجميعي لكل من العائد على الموجودات (ROA) والعائد على حقوق

الملكية (ROE) على التوالي، في حين تعرض الأعمدة (3) و(4) تقديرات نموذج الآثار الثابتة.

وتتضمن جميع المواصفات القياسية الآثار الزمنية الثابتة للتحكم في الظروف الاقتصادية الكلية والاتجاهات الزمنية العامة. كما تم استخدام أخطاء معيارية متينة مجمعة على مستوى المصرف في نماذج الآثار الثابتة، وذلك لمعالجة احتمالات الارتباط التسلسلي وتباين التغير غير المتجانس، كما هو موضح في الجدول (3)

الجدول (3)

<i>Dependent Variables: Return on Assets (ROA) and Return on Equity (ROE)</i>				
	Pooled OLS		Fixed Effects	
Variables	ROA	ROE	ROA	ROE
AI Adoption Index	0.0209*** (0.0045)	0.1634*** (0.0473)	0.0180*** (0.0025)	0.1465*** (0.0271)
Bank Size (Log Assets)	0.0005** (0.0003)	0.0031 (0.0022)	0.0090*** (0.0015)	0.0567*** (0.0119)
Capital Adequacy	0.0242** (0.0109)	0.6911*** (0.1179)	0.0082 (0.0220)	0.4624** (0.2279)
Liquidity Ratio	0.0055 (0.0048)	0.0941** (0.0468)	-0.0246** (0.0110)	-0.1421 (0.1116)
NPL Ratio	-0.0975*** (0.0094)	-0.8590*** (0.0941)	-0.1395*** (0.0125)	-1.2223*** (0.1462)
Cost-to-Income Ratio	-0.0105** (0.0047)	-0.0851* (0.0436)	-0.0064 (0.0094)	-0.0845 (0.1025)
Constant	-0.0110 (0.0085)	-0.1301* (0.0774)	—	—
Observations	150	150	150	150
R-squared	0.9325	0.9052	0.8887	0.8530
Adjusted R-squared	0.9249	0.8946	—	—
F-statistic	123.39***	85.31***	5.16***	2.93***
<i>Notes: Robust standard errors in parentheses (clustered by bank for Fixed Effects).</i>				
*** $p < 0.01$, ** $p < 0.05$, * $p < 0.10$				
Year fixed effects included in all specifications.				
Fixed Effects models control for bank-specific unobserved heterogeneity.				

المصدر: إعداد الباحث باستخدام تحليل قياسي لبيانات بانل متوازنة (15 مصرفاً × 10 سنوات = 150 مشاهدة). وتشمل مصادر البيانات:

- (1) القوائم المالية السنوية المدققة للمصارف؛
- (2) سجلات دائرة الرقابة المصرفية في البنك المركزي العراقي؛
- (3) مؤشر تبني الذكاء الاصطناعي الذي قام الباحث ببنائه استناداً إلى مؤشرات نشر التكنولوجيا؛
- (4) متغيرات الاقتصاد الكلي المستقاة من قواعد بيانات البنك الدولي وصندوق النقد الدولي.

وقد تم تقدير نماذج الانحدار باستخدام لغة البرمجة Python الإصدار 3.12 (وبالاعتماد على مكتبة Statsmodels، مع استخدام أخطاء معيارية متينة مجمعة على مستوى المصرف. كما تم تطبيق تقدير الآثار الثابتة باستخدام تحويل المتوسطات الداخلية (Within Transformation) لإزالة التباين غير المرصود الثابت عبر الزمن على مستوى المصرف.

3.3.1. نتائج نموذج الانحدار التجميعي (Pooled OLS Results)

توفر تقديرات نموذج الانحدار التجميعي (Pooled OLS) النتائج الأساسية للدراسة. ففي نموذج العائد على الموجودات (ROA) المعروض في العمود (1)، بلغ معامل مؤشر تبني الذكاء الاصطناعي 0.0209 عند مستوى دلالة إحصائية مرتفع ($p < 0.001$)، مما يشير إلى أن زيادة وحدة واحدة في مؤشر تبني الذكاء الاصطناعي—أي الانتقال من عدم التبني إلى التبني الكامل—ترتبط بزيادة قدرها 2.09 نقطة مئوية في العائد على الموجودات. وبالنظر إلى أن متوسط ROA في العينة بلغ -0.36%، فإن هذا الأثر يُعد كبيراً من الناحية الاقتصادية. كما أن هذا المعامل ذو دلالة إحصائية عالية عند مستوى 1%.

أما في نموذج العائد على حقوق الملكية (ROE) المعروض في العمود (2)، فقد بلغ معامل تبني الذكاء الاصطناعي 0.1634 ($p < 0.001$)، مما يشير إلى أثر أقوى على عوائد المساهمين. ويُعد هذا الحجم الأكبر متوقعاً، نظراً لأن ROE يعكس أثر الرافعة المالية المرتبط بهيكل رأس

مال المصارف. وقد أظهرت النتائج في كلا النموذجين متانة عالية عند تضمين المتغيرات الضابطة الخاصة بالمصارف والآثار الزمنية الثابتة.

وفيما يتعلق بالمتغيرات الضابطة، تُظهر نسبة القروض المتعثرة (NPL) أثراً سلبياً قوياً على الربحية، حيث بلغ معاملها -0.0975 في نموذج ROA و -0.8590 في نموذج ROE، وكلاهما عند مستوى دلالة إحصائية مرتفع ($p < 0.001$)، مما يؤكد أن مخاطر الائتمان تُضعف الأداء المصرفي بشكل كبير. كما أظهرت نسبة التكاليف إلى الإيرادات العلاقة السلبية المتوقعة مع الربحية، وإن كان معاملها ذا دلالة هامشية فقط في نموذج ROA. في المقابل، أظهرت كفاية رأس المال أثراً إيجابياً ومعنوياً في كلا النموذجين، مما يشير إلى أن المصارف ذات الرسملة الجيدة تحقق أداءً أفضل. وتتميز نماذج الانحدار التجميعي بدرجة ملائمة مرتفعة، حيث بلغت قيم معامل التحديد (R^2) 0.933 لنموذج ROA و 0.905 لنموذج ROE.

3.3.2. نتائج نموذج الآثار الثابتة (Fixed Effects Results)

على الرغم من أن نتائج نموذج الانحدار التجميعي توفر تقديرات أولية مفيدة، إلا أنها قد تعاني من تحيز المتغيرات المحذوفة في حال وجود خصائص غير مرصودة خاصة بالمصارف ترتبط بكل من تبني الذكاء الاصطناعي والربحية. ولمعالجة هذه الإشكالية، تم اعتماد نموذج الآثار الثابتة (Fixed Effects)، الذي يتحكم في التغيرات غير المرصودة الثابتة عبر الزمن من خلال تضمين آثار ثابتة على مستوى المصرف.

وقد أظهر اختبار (F-test) للدلالة المشتركة للآثار الثابتة الخاصة بالمصارف رفض الفرضية العدمية القائلة بعدم وجود آثار ثابتة، حيث بلغت قيمة الاختبار 5.16 لنموذج ROA ($p < 0.001$) و 2.93 لنموذج ROE ($p = 0.001$)، مما يدل على تفضيل نموذج الآثار الثابتة مقارنة بنموذج الانحدار التجميعي.


وتؤكد نتائج نموذج الآثار الثابتة المعروضة في العمودين (3) و(4) الأثر الإيجابي لتبني الذكاء الاصطناعي على ربحية المصارف، حتى بعد التحكم في الخصائص غير المرصودة الخاصة بكل مصرف. فقد بلغ معامل تبني الذكاء الاصطناعي في نموذج ROA نحو 0.0180 ($p < 0.001$)، وهو أقل قليلاً من تقدير نموذج OLS لكنه لا يزال ذا دلالة اقتصادية وإحصائية

قوية. أما في نموذج ROE ، فقد بلغ المعامل $(p < 0.001)$ 0.1465 وتشير هذه الانخفاضات النسبية في حجم المعاملات مقارنة بنموذج OLS إلى أن جزءاً من العلاقة الإيجابية في التقدير التجميعي يعكس فروقاً بين المصارف في قدرات تبني الذكاء الاصطناعي، في حين يظل الأثر داخل المصرف عبر الزمن كبيراً وإيجابياً.

ومن الملاحظ أن حجم المصرف أصبح ذا دلالة إحصائية عالية في نموذج الآثار الثابتة، حيث بلغ معامل الحجم 0.0090 في نموذج ROA و 0.0567 في نموذج ROE كلاهما $p < 0.001$ ، مما يشير إلى أن النمو الداخلي في حجم المصرف يرتبط بتحسين الربحية، وربما يعكس ذلك وفورات الحجم. كما حافظت نسبة القروض المتعثرة على أثرها السلبي القوي- 0.1395 في ROA و -1.2223 في ROE ، وكلاهما $(p < 0.001)$ في المقابل، أظهرت نسبة السيولة معاملاً سلبياً في نموذج الآثار الثابتة، وهو ما قد يشير إلى أن الاحتفاظ بمستويات مرتفعة من السيولة قد يحد من الربحية.

و يلخص الشكل (4) هذه التقديرات من خلال عرض معاملات الانحدار وفواصل الثقة عند مستوى 95٪، حيث يوضح بجلاء الأثر الإيجابي والمعنوي لتبني الذكاء الاصطناعي عبر جميع المواصفات القياسية، كما هو موضح في الشكل (4) .

الشكل (4) التقديرات من خلال عرض معاملات الانحدار وفواصل الثقة عند مستوى



المصدر: إعداد الباحث لتمثيل معاملات تبني الذكاء الاصطناعي المستخلصة من النماذج القياسية الواردة في الجدول (3). يقارن الجزء (A) معاملات الذكاء الاصطناعي في نماذج العائد على الموجودات (ROA)، بينما يقارن الجزء (B) معاملات الذكاء الاصطناعي في نماذج العائد على حقوق الملكية (ROE). وتمثل أشرطة الخطأ فواصل الثقة عند مستوى 95% والمحسوبة بالاعتماد على الأخطاء المعيارية المتينة المجمعة على مستوى المصرف. وتشير العلامات النجمية إلى مستويات الدلالة الإحصائية على النحو الآتي: *** عند $p < 0.01$ ، ** عند $p < 0.05$ ، * عند $p < 0.10$ كما يُستخدم الترميز اللوني للتمييز بين مواصفات الانحدار التجميعي (باللون الأزرق) ونماذج الآثار الثابتة (باللون الأحمر). ويسهل هذا الشكل التقييم البصري لاستقرار معاملات الذكاء الاصطناعي عبر المواصفات القياسية المختلفة ومقاييس الربحية.

وتبلغ قيم معامل التحديد الداخلي (Within R-squared) للنماذج الآثار الثابتة 0.889 في نموذج العائد على الموجودات (ROA) و 0.853 في نموذج العائد على حقوق الملكية (ROE)، مما يشير إلى أن النموذج يفسر نحو 89٪ و 85٪ من التباين داخل المصارف في مستويات الربحية عبر الزمن، على التوالي. وتعكس هذه القيم المرتفعة لمعامل التحديد، إلى جانب إحصاءات (F-statistics) ذات الدلالة الإحصائية العالية، ملائمة جيدة للنماذج القياسية المستخدمة وقدرتها على تفسير البيانات بكفاءة

3.4. اختبارات المتانة والاختبارات التشخيصية (Robustness Checks and Diagnostic

Tests)

لضمان سلامة النتائج ومصداقيتها، تم إجراء مجموعة شاملة من الاختبارات التشخيصية للتحقق من عدم انتهاك افتراضات الانحدار الكلاسيكية وتقييم صحة تحديد النموذج القياسي. ويعرض الجدول (4) نتائج هذه الاختبارات، والتي تهدف إلى فحص مشكلات محتملة مثل تباين التباين غير المتجانس، والارتباط التسلسلي، وطبيعة توزيع المتبقيات، إضافة إلى تقييم ملائمة مواصفات النموذج لاحظ الجدول 4.

Table 4: Diagnostic Test Results				
Test	Statistic	P-value	Result	Interpretation
Panel A: Pooled OLS (ROA)				
Breusch-Pagan Test	2.333	0.311	No heteroskedasticity	Homoskedasticity assumed
Jarque-Bera Normality	2.161	0.339	Normally distributed	Residuals are normal
Panel B: Pooled OLS (ROE)				
Breusch-Pagan Test	17.710	0.000	Heteroskedasticity detected	Robust SE used
Jarque-Bera Normality	1.375	0.503	Normally distributed	Residuals are normal
Panel C: Fixed Effects				
F-test (ROA)	5.155	0.000	Significant	FE preferred over Pooled
F-test (ROE)	2.926	0.001	Significant	FE preferred over Pooled
Serial Correlation (ROA)	-0.094	—	Weak	No serious autocorrelation
Serial Correlation (ROE)	-0.124	—	Weak	No serious autocorrelation
Panel D: Multicollinearity (VIF)				
AI Adoption Index	2.399	—	Acceptable	VIF < 10
Bank Size	1.553	—	Acceptable	VIF < 10
Capital Adequacy	1.336	—	Acceptable	VIF < 10
NPL Ratio	1.884	—	Acceptable	VIF < 10
Cost-to-Income Ratio	2.396	—	Acceptable	VIF < 10
<i>Notes: Diagnostic tests assess model assumptions and specification validity.</i>				

المصدر: إعداد الباحث بالاعتماد على إجراءات تشخيصية لاحقة للتقدير (Post-Estimation Diagnostics)

لتنتائج نماذج الانحدار الواردة في الجدول (3). وتشمل

الاختبارات ما يأتي:

- (1) اختبار بريوش-باغان (Breusch-Pagan) للكشف عن تباين التباين غير المتجانس؛
- (2) اختبار جاري-بيرا (Jarque-Bera) للتحقق من طبيعة توزيع المتبقيات؛
- (3) تحليل عامل تضخم التباين (Variance Inflation Factor – VIF) للكشف عن مشكلة التعدد الخطي؛

(4) اختبار (F-test) للدلالة المشتركة للآثار الثابتة؛

(5) تحليل الارتباط التسلسلي باستخدام إحصائية دوربن-واتسن (Durbin-Watson) ومعاملات الارتباط الذاتي.

وقد تم احتساب جميع الاختبارات التشخيصية باستخدام لغة البرمجة Python الإصدار 3.12 (وبالاعتماد على مكتبات SciStatsmodels

3.4.1 تباين التباين غير المتجانس (Heteroskedasticity)

أظهر اختبار بريوش-باغان (Breusch-Pagan) لتباين التباين غير المتجانس نتائج متباينة. ففي نموذج العائد على الموجودات (ROA)، لم يتم العثور على دليل إحصائي على وجود تباين تباين غير متجانس) إحصائية BP = 2.333 ، وقيمة $p = 0.311$ ، مما يدعم استخدام الأخطاء المعيارية الاعتيادية. في المقابل، كشف الاختبار عن وجود تباين تباين غير متجانس ذي دلالة إحصائية في نموذج العائد على حقوق الملكية (ROE) إحصائية

BP = 17.710 ، وقيمة $p < 0.001$ ، ولمعالجة هذه المشكلة، تم اعتماد أخطاء معيارية متينة لتباين التباين (White, 1980) في جميع نماذج الانحدار التجميعي (Pooled OLS)، إضافة إلى استخدام أخطاء معيارية متينة مجمعة على مستوى المصرف في نماذج الآثار الثابتة، وهي أخطاء قادرة على التعامل مع كل من تباين التباين غير المتجانس والارتباط داخل العناقيد.

3.4.2 التعدد الخطي (Multicollinearity)

أظهر تحليل عامل تضخم التباين (Variance Inflation Factor – VIF) عدم وجود مشكلات جوهرية تتعلق بالتعدد الخطي. إذ جاءت جميع قيم VIF أقل بكثير من العتبة الشائعة البالغة 10، حيث سجل مؤشر تبني الذكاء الاصطناعي أعلى قيمة بلغت 2.399، في حين بلغت قيمة VIF لنسبة التكاليف إلى الإيرادات 2.396. وتشير هذه القيم المعتدلة إلى أن التعدد الخطي لا يؤدي إلى تضخيم الأخطاء المعيارية أو زعزعة استقرار تقديرات المعاملات.

3.4.3 الارتباط التسلسلي (Serial Correlation)

تم تقييم الارتباط التسلسلي من خلال حساب متوسط الارتباط الذاتي من الدرجة الأولى لمبتقيات النماذج داخل كل مصرف. وأظهرت النتائج وجود ارتباط تسلسلي ضعيف نسبياً،

حيث بلغ متوسط الارتباط الذاتي -0.094 في نموذج ROA و -0.124 في نموذج ROE ، مما يشير إلى أن الارتباط التسلسلي لا يمثل مشكلة رئيسية في التحليل. ومع ذلك، فإن استخدام الأخطاء المعيارية المتينة المجمعة على مستوى المصرف في نماذج الآثار الثابتة يوفر حماية إضافية ضد أي ارتباط تسلسلي محتمل.

3.4.4. طبيعية المتبقيات (Normality of Residuals)

فشل اختبار جاركسي-بيرا (Jarque-Bera) في رفض الفرضية العدمية القائلة بطبيعية توزيع المتبقيات في كلا النموذجين، حيث بلغت قيمة الاختبار 2.161 مع $p = 0.339$ في نموذج ROA، و 1.375 مع $p = 0.503$ في نموذج ROE. وتشير هذه النتائج إلى أن المتبقيات تتبع تقريباً التوزيع الطبيعي، مما يدعم صحة الاستدلال الإحصائي القائم على إحصاءات (t) و (F).


3.5. التفسير الاقتصادي وحجم الأثر (Economic Interpretation and Magnitude of Effects)

لفهم الأهمية الاقتصادية للنتائج بصورة أعمق، تم تقديم تفسيرات كمية لحجم معاملات الانحدار. واستناداً إلى التقديرات المفضلة لنموذج الآثار الثابتة، فإن زيادة بمقدار انحراف معياري واحد في مؤشر تبني الذكاء الاصطناعي (0.138 وحدة) ترتبط بزيادة قدرها 0.25 نقطة مئوية في العائد على الموجودات ($0.0025 = 0.0180 \times 0.138$) أو (0.25%). وبالنظر إلى أن متوسط ROA في العينة بلغ -0.36%، فإن هذا التحسن يُعد كبيراً من الناحية الاقتصادية.

ولتوضيح ذلك، إذا افترضنا مصرفاً افتراضياً يبلغ إجمالي موجوداته 2 تريليون دينار عراقي (وهو قريب من الوسيط في العينة)، فإن زيادة قدرها 0.25 نقطة مئوية في ROA تعني تحقيق أرباح سنوية إضافية قدرها 5 مليارات دينار عراقي (2,000 مليار $\times 0.0025$ مليارات دينار)، أي ما يعادل نحو 3.4 مليون دولار أمريكي وفق أسعار الصرف الحالية. وعلى مدى فترة الدراسة البالغة عشر سنوات، فإن الزيادة التراكمية في تبني الذكاء الاصطناعي من متوسط قدره 0.07 في عام 2015 إلى 0.42 في عام 2024 (أي زيادة بمقدار 0.35 وحدة) ترتبط بتحسين يقارب 0.63 نقطة مئوية في ROA، مع ثبات العوامل الأخرى.

أما بالنسبة للعائد على حقوق الملكية (ROE)، فتبدو الآثار أكثر وضوحاً. إذ إن زيادة بمقدار انحراف معياري واحد في مؤشر تبني الذكاء الاصطناعي ترتبط بزيادة قدرها 2.02 نقطة مئوية في ROE ($0.138 \times 0.1465 = 0.0202$) أو (2.02%). ويعكس هذا الحجم الأكبر أثر الرافعة المالية المتضمن في مقياس ROE. ويوضح الشكل (5) العلاقة بين تبني الذكاء الاصطناعي والربحية إلى جانب المتغيرات الضابطة الأخرى، حيث يظهر أن تبني الذكاء الاصطناعي يتمتع بأحد أقوى الارتباطات مع مؤشرات الربحية، كما هو موضح في الشكل (5).

الشكل (5) العلاقة بين تبني الذكاء الاصطناعي والربحية



المصدر: إعداد الباحث بالاعتماد على تحليل ثنائي المتغيرات بين مؤشر تبني الذكاء الاصطناعي ومقاييس الربحية. يوضح الجزء (A) العلاقة بين تبني الذكاء الاصطناعي والعائد على الموجودات (ROA) حيث بلغ معامل الارتباط $r = 0.820$ عند مستوى دلالة إحصائية $p < 0.001$ ، بينما يوضح الجزء (B) العلاقة بين تبني الذكاء الاصطناعي والعائد على حقوق الملكية (ROE) حيث بلغ معامل الارتباط $r = 0.806$ عند مستوى دلالة إحصائية $p < 0.001$. وتمثل كل نقطة مشاهدة مصرف-سنة ($N = 150$)، مع تمييزها لونياً بحسب السنة لإبراز الأنماط الزمنية. كما تم إظهار خطوط الانحدار الخطي مع فواصل الثقة عند مستوى 95%، وقد تم عرض معاملات ارتباط بيرسون ومستويات الدلالة الإحصائية، فيما تعود مصادر البيانات إلى ما هو موضح في الجدول (1). وتم إنشاء الرسوم البيانية باستخدام لغة البرمجة Python الإصدار 3.12 (وبالاعتماد على مكتبات

Seaborn وMatplotlib

من المهم الإشارة إلى أن هذه التقديرات تمثل الأثر المتوسط عبر جميع المصارف المشمولة في العينة، وقد يختلف هذا الأثر تبعاً لخصائص المصارف، وجودة تطبيق تقنيات الذكاء الاصطناعي، والتغيرات التنظيمية المكتملة المصاحبة لعملية التبني. ومع ذلك، فإن اتساق النتائج عبر الموصفات القياسية المختلفة (الانحدار التجميعي مقابل نموذج الآثار الثابتة) وعبر مقاييس الربحية المختلفة (العائد على الموجودات مقابل العائد على حقوق الملكية) يعزز الثقة بمتانة العلاقة الإيجابية بين تبني الذكاء الاصطناعي وربحية المصارف.

أولاً: الاستنتاجات:

استناداً إلى التحليل التجريبي لتأثير تبني الذكاء الاصطناعي على ربحية المصارف العراقية خلال الفترة 2015-2024، تتوصل الدراسة إلى النتائج التالية:

- 1- يزيد تبني الذكاء الاصطناعي العائد على الموجودات (ROA) بمقدار 1.80 نقطة مئوية والعائد على حقوق الملكية (ROE) بمقدار 14.65 نقطة مئوية، مع دلالة إحصائية عالية ($p < 0.001$)، ما يبرز قيمة مالية حقيقية لتقنيات الذكاء الاصطناعي حتى في بيئات ما بعد الصراع.
- 2- تبقى العلاقة الإيجابية ثابتة عبر نماذج الانحدار التجميعي ونماذج الآثار الثابتة، مما يعزز ثقة الباحثين في النتائج ويقلل من تحيز الخصائص غير المرصودة.
- 3- يظل تأثير الذكاء الاصطناعي معنوياً بعد التحكم في محددات الربحية التقليدية مثل حجم المصرف وكفاية رأس المال والسيولة ومخاطر الائتمان وكفاءة التكاليف.
- 4- يثبت أثر الذكاء الاصطناعي استقراره رغم الصدمات الاقتصادية الكبرى (منها جائحة كوفيد-19)، مما يعكس قدرة المصارف على التكيف والتحول الرقمي.
- 5- يعزز الذكاء الاصطناعي الربحية عبر خفض التكاليف، إدارة مخاطر الائتمان، وتحسين الكفاءة التشغيلية، مما يدعم التنبؤات النظرية حول آليات تأثيره.
- 6- تشير النتائج إلى أن المصارف في الأسواق الناشئة يمكنها تحقيق مكاسب ملموسة من خلال تبني تقنيات ذكاء اصطناعي متقدمة، حتى في ظل التحديات المؤسسية.

7- لم تظهر مشكلات جوهرية في تباين التغير، وتمت معالجة ما ظهر في بعض النماذج باستخدام أخطاء معيارية متينة، كما تبين عدم وجود تعدد خطي، مع اتباع المتبقيات تقريباً للتوزيع الطبيعي.

ثانياً التوصيات:

بناءً على النتائج، تقدم الدراسة التوصيات التالية لتعزيز ربحية المصارف وتطوير قطاع الذكاء الاصطناعي المصرفي في العراق:

1- تطوير إطار تنظيمي داعم للذكاء الاصطناعي يشمل بيئات اختبار (Sandboxes)، إرشادات حوكمة البيانات، حماية المستهلك، وحوافز للمصارف الفعالة في إدارة المخاطر.

2- تبني استراتيجيات شاملة لتطبيق الذكاء الاصطناعي في خدمة العملاء، إدارة المخاطر، العمليات الخلفية، مع تعزيز بنية البيانات وإنشاء وحدات للتحويل الرقمي.

3- تسريع التحول الرقمي عبر تخصيص موازنات للتحديث التقني، إجراءات شراء مرنة، جذب كفاءات متخصصة، وتفعيل شراكات بين القطاعين العام والخاص.

4- الاستثمار في التدريب والمهارات الرقمية، برامج علم البيانات والتعلم الآلي، شراكات جامعية، ودعم مسارات مهنية لتخصصي الذكاء الاصطناعي.

5- دمج الذكاء الاصطناعي في برامج دعم القطاع المالي، من خلال تمويل البنية التحتية التقنية، نقل المعرفة، وبناء القدرات السيبرانية.

6- أولوية لتطبيقات تقييم الائتمان وكشف الاحتيال، بما يشمل نماذج تعلم آلي، أنظمة إنذار مبكر، وأتمتة مراقبة القروض وتحليل البيانات غير المهيكلة.

7- توسيع الدراسات على الأسواق الناشئة، تحليل الآثار غير المتجانسة حسب نوع المصرف، دراسة الآليات الوسيطة، والتقييم طويل الأجل للشمول المالي والاستقرار.

References

- Athanasoglou, P. P., Brissimis, S. N., & Delis, M. D. (2008). Bank-specific, industry-specific and macroeconomic determinants of bank profitability. *Journal of International Financial Markets, Institutions and Money*, 18(2), 121–136. <https://doi.org/10.1016/j.intfin.2006.07.001>
- Baltagi, B. H. (2021). *Econometric analysis of panel data* (6th ed.). Springer.
- Barman, R., Gupta, A., & Singh, S. (2024). Artificial intelligence-driven personalization and bank profitability: Evidence from retail banking. *Journal of Banking & Finance*, 157, 106799. <https://doi.org/10.1016/j.jbankfin.2023.106799>
- Breusch, T. S., & Pagan, A. R. (1979). A simple test for heteroskedasticity and random coefficient variation. *Econometrica*, 47(5), 1287–1294. <https://doi.org/10.2307/1911963>
- Brynjolfsson, E., & McAfee, A. (2017). *Machine, platform, crowd: Harnessing our digital future*. W. W. Norton & Company.
- Buchanan, B. (2019). Artificial intelligence in finance. *The Alan Turing Institute Discussion Paper*, 1–23.
- Cameron, A. C., & Trivedi, P. K. (2005). *Microeconometrics: Methods and applications*. Cambridge University Press.
- Cheng, M., & Qu, Y. (2020). Does artificial intelligence improve bank efficiency? Evidence from China. *Journal of Banking & Finance*, 116, 105842. <https://doi.org/10.1016/j.jbankfin.2020.105842>
- Gomber, P., Koch, J. A., & Siering, M. (2023). Digital finance and bank profitability: Evidence from emerging and developed markets. *Journal of Financial Stability*, 66, 101103. <https://doi.org/10.1016/j.jfs.2023.101103>
- Hornuf, L., Klus, M. F., Lohwasser, T., & Schwenbacher, A. (2021). How do banks interact with fintech startups? *Small Business Economics*, 57(2), 841–859. <https://doi.org/10.1007/s11187-020-00359-3>
- International Monetary Fund. (2024). *Iraq: Staff report for the Article IV consultation*. IMF.
- Jarque, C. M., & Bera, A. K. (1987). A test for normality of observations and regression residuals. *International Statistical Review*, 55(2), 163–172. <https://doi.org/10.2307/1403192>

- Khandani, A. E., Kim, A. J., & Lo, A. W. (2021). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, 122, 105974. <https://doi.org/10.1016/j.jbankfin.2020.105974>
- Lee, I., & Shin, Y. J. (2018). Fintech: Ecosystem, business models, investment decisions, and challenges. *Business Horizons*, 61(1), 35–46. <https://doi.org/10.1016/j.bushor.2017.09.003>
- Lee, J., Park, J., & Shin, H. (2021). Fintech competition and bank performance: Evidence from Asia. *Journal of Financial Services Research*, 59(2), 123–150. <https://doi.org/10.1007/s10693-020-00340-2>
- Ngai, E. W. T., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. (2022). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. *Decision Support Systems*, 150, 113558. <https://doi.org/10.1016/j.dss.2021.113558>
- Petria, N., Capraru, B., & Ihnatov, I. (2015). Determinants of banks' profitability: Evidence from EU 27 banking systems. *Procedia Economics and Finance*, 20, 518–524. [https://doi.org/10.1016/S2212-5671\(15\)00104-5](https://doi.org/10.1016/S2212-5671(15)00104-5)
- White, H. (1980). A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica*, 48(4), 817–838. <https://doi.org/10.2307/1912934>
- World Bank. (2023). *Iraq economic monitor: Managing uncertainty*. World Bank Group.
- Zhang, Y., & Liu, H. (2023). Artificial intelligence-based customer service and bank performance. *International Journal of Bank Marketing*, 41(4), 889–912. <https://doi.org/10.1108/IJBM-02-2022-0091>