الجمهورية العربية السورية
وزارة التعليم العالي والبحث العلمي
المعهد العالي لإدارة الأعمال

HIGHER INSTITUTE OF BUSINESS ADMINISTRATION

التنبؤ بالتعثر المالي وتسعير القروض باستخدام التعلم العميق متعدد المهام والذكاء الاصطناعي المفسر

Predicting Financial Distress and Loan Pricing Using Multi-Task Deep Learning and Explainable AI

مشروع تخرج أعد لنيل الإجازة الجامعية في علوم الإدارة اختصاص إدارة مالية ومصرفية

إعداد الطالب: عمر الزعويط

الدكتور المشرف: د. منال الموصلي

السنة الخامسة

العام الدراسي:

2025-2026

الملخص:

هدفت هذه الدراسة إلى معالجة الفجوة المنهجية المتمثلة في الفصل بين تقييم المخاطر الائتمانية (التنبؤ بالتعثر) والتسعير الاقتصادي للقروض (تحديد تكلفة الدين)، عبر تصميم نموذج كمي مدمج يعتمد على التعلم العميق متعدد المهام (MTDL). يقوم النموذج بالتنبؤ المتزامن باحتمالية التعثر (مهمة تصنيف) وتحديد تكلفة الدين وعلاوة المخاطرة (مهمة انحدار) ضمن شبكة عصبية موحدة ذات تمثيل مشترك للخصائص. ولتجاوز معضلة "الصندوق الأسود" والامتثال لمتطلبات الحوكمة المصرفية (IFRS 9، مقررات بازل، وGDPR)، تم دمج طبقة من الذكاء الاصطناعي المفسر باستعمال تقنية قيم شابلي (SHAP).

اعتمدت الدراسة على المنهج الكمي التطبيقي باستهداف بيانات ضخمة لـ 7,960 شركة مساهمة عامة مدرجة في الأسواق المالية الأمريكية (SEC EDGAR) بإجمالي 401,592 مشاهدة للفترة من 2009 حتى الربع الأول من 2026. وتضمنت المعالجة تصفية التعددية الخطية، وتخميد القيم المتطرفة، وتحسين عتبة القرار إحصائياً عبر إحصائية (Youden's J) لمواجهة عدم تماثل تكلفة الخطأ الائتماني.

أظهرت النتائج كفاءة استثنائية لنموذج (MTDL)؛ حيث حقق في مسار التنبؤ بالتعثر قدرة تمييزية بلغت (ROC–AUC = 0.9581)، ودقة كليّة (93.25%)، ومعدل استرجاع (93.18%). وفي مسار تسعير الدين، سجل النموذج خطأ معياري منخفض بلغت قيمته (RMSE = 0.0308). كما نجحت تقنية (SHAP) في تفكيك القرار الخوارزمي واستخلاص معادلات وكيلة بيّنت أن نسبة الدين إلى حقوق الملكية، ونسبة التداول، ومضاعف الملكية، ودوران الأصول، وسعر الفائدة الفيدرالية، هي المحركات الأساسية للتعثر وهيكل الفائدة. يقدم البحث للمؤسسات المصرفية إطار عمل يوازن بين دقة التنبؤ وشفافية الامتثال الرقابي.

الكلمات المفتاحية: التعثر المالي، تسعير القروض، التعلم العميق متعدد المهام (MTDL)، الذكاء الاصطناعي المفسر (XAI)، قيم شابلي (SHAP)، تكلفة الدين، الامتثال المصرفي.

Abstract:

This study addresses the methodological disconnect between credit risk assessment and loan pricing by proposing an integrated quantitative framework using Multi-Task Deep Learning (MTDL). The model simultaneously predicts corporate financial distress (classification) and determines the fair cost of debt (regression) within a single neural network leveraging shared feature representations. To overcome the "black-box" dilemma and comply with regulatory standards (IFRS 9, Basel III/IV, GDPR), an Explainable AI (XAI) layer utilizing Shapley Additive Explanations (SHAP) was integrated.

Using a big-data dataset of 7,960 US publicly traded firms (401,592 observations, 2009-Q1 2026-Q1) sourced from SEC EDGAR, data preprocessing involved Winsorization, smart multicollinearity pruning, and decision threshold optimization via Youden's J statistic.

Empirical results demonstrate superior performance: the distress prediction module achieved an ROC-AUC of 0.9581, overall accuracy of 93.25%, and recall of 93.18%, while the loan pricing module achieved a low RMSE of 0.0308. Furthermore, SHAP analysis successfully decoded algorithmic outputs into interpretable proxy equations, identifying the Debt-to-Equity ratio, Current Ratio, Equity Multiplier, Asset Turnover, and Federal Funds Rate as the primary risk and pricing determinants. This research provides financial institutions with a unified framework combining predictive precision with regulatory transparency.

Keywords: Financial Distress, Loan Pricing, Multi-Task Deep Learning (MTDL), Explainable AI (XAI), SHAP Values, Cost of Debt, Regulatory Compliance.

فهرس المحتويات

الفصل الأول: الإطار التمهيدي.....1

1.1 الدراسات السابقة.....2

1.2 ما يميز هذه الدراسة عن الدراسات السابقة: 5

1.3 مشكلة الدراسة.....6

1.4 فرضيات الدراسة 7

1.5 أهداف الدراسة: 7

1.6 أهمية الدراسة:.....8

1.7 متغيرات الدراسة: 8

1.8 منهج الدراسة 9

1.9 حدود الدراسة (الزمانية والمكانية) 10

1.10 مجتمع وعينة الدراسة.....10

الفصل الثاني: الإطار النظري للدراسة 11

2.1 المبحث الأول: مفهوم التعثر المالي والتنبؤ به.....12

2.1.1 التعثر المالي 13

2.1.1.1 أنواع التعثر المالي: الفشل الاقتصادي والمالي، والعسر، والإفلاس.....13

2.1.1.2 فرضية الاستمرارية 14

2.1.1.3 الأسباب الهيكلية والتشغيلية والاقتصادية الكلية للتعثر المالي.....15

2.1.1.4 النظريات المالية والاقتصادية المفسرة للتعثر المالي وتأثيراتها الائتمانية 16

2.1.1.5 مراحل الانحدار المالي.....17

2.1.2 التنبؤ بالتعثر المالي باستخدام المقايس الكلاسيكية.....18

2.1.2.1 مفهوم وأهمية التنبؤ بالتعثر المالي.....18

2.1.2.2 دقة التنبؤ ومصفوفة الارتباك (Confusion Matrix):.....18

2.1.2.3 نماذج التنبؤ التقليدية:.....19

2.2 المبحث الثاني: تسعير القروض وإدارة العوائد المعدلة بالمخاطر.....20
2.2.1 التسعير الائتماني وإطار العائد المعدل بالمخاطر (RAROC).....20
2.2.2 الخسارة المتوقعة (EL) ومكوناتها الأساسية 21
2.2.3 الخسائر غير المتوقعة (UL).....22
2.2.4 محددات تسعير القروض المصرفية.....23
2.2.5 مشكلة التسعير الائتماني: الاختيار العكسي، الخطر الأخلاقي، والتقنين.....24
2.2.6 التسعير الديناميكي وإدارة المحافظ المتقدمة المستندة للذكاء الاصطناعي 25
2.3 المبحث الثالث: البنية المعمارية للتعلم العميق وتطبيقاته في النمذجة المالية.....26
2.3.1 البنية الرياضية في النماذج الكلاسيكية.....26
2.3.1.1 القيود القياسية لنماذج (Logit/Probit) والسلاسل الزمنية.....26
2.3.1.2 نظرية التقريب العالمي والميزة التنافسية للبيانات عالية الأبعاد 27
2.3.2 التعلم العميق في تصنيف الائتمان وتحليل السلاسل الزمنية 27
2.3.2.1 الشبكات العصبية العميقة (DNNs): من التجريد الرياضي إلى تصنيف الجدارة.....27
2.3.2.2 معالجة الذاكرة الائتمانية: شبكات الذاكرة طويلة قصيرة الأجل وتلاشي التدرج 28
2.3.3 التعلم العميق متعدد المهام والتسعير 29
2.3.3.1 التأصيل الرياضي: التعلم المشترك وتقليل دالة التكلفة المركبة.....29
2.3.3.2 آليات التمثيل المشترك وتدفق المعلومات الائتمانية.....30
2.3.3.3 المزايا الكامنة والانحياز الاستقرائي كآلية تنظيم هيكلية.....30
2.4.1 المبحث الرابع: الذكاء الاصطناعي المفسر في السياق التنظيمي والمالي.....31
2.4.1.1 انعدام الشفافية الهيكلية وتفاقم مخاطر النمذجة ((Model Risk 31
2.4.1.2 التحيز الخوارزمي المنهجي (Algorithmic Bias) والتهميش المالي.....32
2.4.2 الحتمية التنظيمية والامتثال القانوني في القطاع المصرفي.....32
2.4.2.1 مقررات لجان بازل: التحقق من صحة النماذج وشفافية تقييم المخاطر 32
2.4.2.2 التشريعات الحديثة وتأثيرها على التسعير: (GDPR) وحق الحصول على تفسير بشري.....33
2.4.3 المنهجيات والتقنيات الرياضية الرائدة في الذكاء الاصطناعي المفسر وفك تشفير النماذج المالية 33
2.4.3.1. التفسير الشامل مقابل التفسير المحلي 34
2.4.3.2 قيم :SHAP.....34
2.4.3.3 التفسيرات المحلية المستقلة عن النموذج (LIME): التقريب الخطي في الجوار المحلي 35
الفصل الثالث: الإطار العملي.....37
3-1 تمهيد 38

2-3 تصميم العينة وجمع البيانات.....38
1-2-3 تصميم العينة.....38
2-2-3 جمع البيانات.....39
3-2-3 الأدوات البرمجية المستخدمة.....39
3-3 بناء المتغيرات التابعة.....40
1-3-3 احتمالية التعثر المالي (Y1).....40
2-3-3 تكلفة الدين وعلاوة المخاطرة (Y2).....40
4-3 المتغيرات المستقلة والتابعة.....40
5-3 التوصيف الإحصائي للمتغيرات.....42
6-3 معالجة القيم المتطرفة (Winsorization).....44
7-3 هيكل عينة الدراسة والتوزيع القطاعي.....44
8-3 مصفوفة الارتباط ومعالجة التعددية الخطية.....46
9-3 معالجة البيانات وهندسة الخصائص.....47
1-9-3 توحيد اتجاه المتغيرات (Directional Alignment).....47
2-9-3 معالجة التسريب المعلوماتي (Data Leakage Prevention).....48
3-9-3 معالجة القيم المفقودة (Missing Values Imputation).....48
4-9-3 التقسيم الزمني (Temporal Splitting).....49
5-9-3 تقييس المتغيرات (Feature Standardization).....49
10-3 تصميم معمارية شبكة MTDL.....50
1-10-3 مبررات اختيار المعمارية.....52
11-3 دالة الخسارة المركَّبة (Combined Loss Function).....53
12-3 البحث الشبكي لضبط المعلمات الفائقة.....54
13-3 بروتوكول التدريب النهائي ومنحنيات التعلم.....55
14-3 اختبار النموذج على البيانات الخارجية.....57
1-14-3 تحسين عتبة القرار (Decision Threshold Optimization).....57
2-14-3 أداء نموذج MTDL في التنبؤ بالتعثر المالي.....58
3-14-3 أداء نموذج MTDL في تسعير الفائدة.....60
4-14-3 المقارنة بالنماذج المرجعية (Benchmarks).....62
15-3 التفسير باستخدام SHAP والمعادلات الوكيلة.....63
1-15-3 المعادلة الوكيلة للتنبؤ بالتعثر (Z_Score_AI).....63

3-15-2 المعادلة الوكيلة لتسعير الدين (Pricing_Score_AI) 64
3-15-3 المقارنة بين محركات التعثر والتسعير 64
النتائج والتوصيات 66
أولاً: نتائج الدراسة (Study Results) 66
ثانياً: توصيات الدراسة.....67
1- توصيات للمؤسسات المصرفية والمالية (Practical Recommendations) 67
2- توصيات للجهات الرقابية والإشرافية (Regulatory Recommendations) 68
3- توصيات للبحوث الأكاديمية المستقبلية (Future Research Recommendations) 69
المصادر والمراجع 70

فهرس الجداول:

جدول (1): هيكل المتغيرات المستقلة والتابعة في نموذج MTDL.....42
جدول (2): التوصيف الإحصائي للمتغيرات الكلية والمحاسبية في عينة الدراسة 43
جدول (3): التوزيع القطاعي لعينة الدراسة ومعدلات التعثر الداخلية 46
جدول (4): ملخص معمارية الشبكة العصبية متعددة المهام MTDL.....53
جدول (5): نتائج البحث الشبكي لضبط المعلمات الفائقة للشبكة MTDL 55
جدول (6): بروتوكول التدريب النهائي والمعلمات المعتمدة 57
جدول (7): مصفوفة الارتباك لأداء نموذج MTDL في التنبؤ بالتعثر.....60
جدول (8): مقاييس الأداء الكمي لنموذج MTDL في التنبؤ بالتعثر 60
جدول (9): مقاييس أداء نموذج MTDL في تسعير تكلفة الدين 62
جدول (10): مقارنة أداء نموذج MTDL مع النماذج المرجعية التقليدية.....63
جدول (11): أوزان SHAP النسبية ومحركات التعثر والتسعير.....65

فهرس الأشكال

شكل (1): خريطة مصفوفة الارتباط الحرارية (Pearson Heatmap) للمتغيرات المستقلة المتبقية 47

شكل (2): المخطط التخطيطي لمعمارية الشبكة العصبية متعددة المهام MTDL..... 52

شكل (3): منحنيات التعلم (Loss and Validation AUC) للشبكة MTDL خلال 100 دورة تدريبية 57

شكل (4): مصفوفة الارتباك لأداء نموذج MTDL في التنبؤ بالتعثر وفق العتبة المثلى 59

الفصل الأول:

الإطار التمهيدي

المقدمة:

"يُشكل الإطار التمهيدي المنطلق المنهجي لهذه الدراسة؛ حيث يُعنى بتأسيس البعد البحثي وتحديد الفجوة التطبيقية الناجمة عن الفصل الهيكلي بين تقييم الجدارة الائتمانية وصياغة هوامش تسعير القروض. يستعرض هذا الإطار خلفية المشكلة، ويُحلل الأدبيات والدراسات السابقة ذات الصلة مبينًا الإضافة النوعية للدراسة الحالية، كما يستعرض الفرضيات الأساسية والأهداف المرجوة، مبرزاً الأهمية العلمية والعملية، ومُحددًا الحدود الزمانية والمكانية ومعالم العينة ومصادر البيانات المستهدفة، وصولاً إلى رسم الخريطة البرمجية والمنهجية المستخدمة في النمذجة".

1.1 الدراسات السابقة

تم استعراض الدراسات السابقة ذات الصلة بموضوع البحث، والتي تقاطعت مع مجالات التنبؤ بالتعثر المالي، تسعير القروض وتكلفة الدين، التعلم متعدد المهام، والذكاء الاصطناعي المفسر، وذلك وفق الترتيب الزمني الآتي:

- **دراسة (Tabatabei & Mousavi, 2026) بعنوان: Explainable AI for Financial Distress: Evidence from Market Volatility and Regime Dynamics**

هدفت الدراسة إلى فهم مسببات التعثر المالي بربطها بمؤشرات الاقتصاد الكلي. اعتمدت الدراسة المنهج الكمي باستخدام نماذج XGBoost المدعومة بتقنية الذكاء الاصطناعي المفسر. طُبقت الدراسة في أسواق المال الأمريكية، حيث تم الاعتماد على بيانات مؤشرات تقلبات السوق ونسب الرفع المالي للشركات. خلصت النتائج إلى قدرة تقنية SHAP على تفكيك قرار الصندوق الأسود الخوارزمي، وتحديد الوزن الدقيق لكل متغير مالي في دفع الشركة نحو التعثر.

- **دراسة (Mohadikar et al., 2026) بعنوان: Dynamic Pricing and Risk-Based Loan Offers** هدفت الدراسة إلى تصميم إطار عمل للانتقال نحو التسعير المبني على المخاطر بشكل ديناميكي. اعتمدت الدراسة منهجية النمذجة الهجينة عبر دمج بطاقات الأداء الكلاسيكية مع خوارزميات (XGBoost). طُبقت الدراسة في بيئة مختبرية لمنصات الإقراض الرقمي، بالاعتماد على بيانات محاكاة لخصائص محفظة قروض افتراضية. وتضمنت الفترة الزمنية

سيناريوهات مستقبلية لاختبار مرونة التسعير. بينت النتائج نجاح النموذج المدمج في تحسين هامش الفائدة الصافي آلياً مع الحفاظ على مستويات المخاطر المستهدفة.

- **دراسة (Samara & Shinde, 2025) بعنوان: Bankruptcy Prediction Using Machine Learning and Data Preprocessing Techniques** تناولت الدراسة معالجة مشكلة اختلال توازن البيانات عند التنبؤ بالإفلاس المالي. اعتمدت الدراسة المنهج الوصفي والكمي عبر توظيف خوارزمية الغابات العشوائية المدمجة مع تقنية توليد البيانات الاصطناعية (SMOTE). طُبقت الدراسة على الشركات المساهمة المدرجة في السوق الأمريكية، بالاعتماد على بيانات محاسبية تاريخية. امتدت الفترة الزمنية للدراسة من عام (1999) وحتى عام (2023). أثبتت النتائج أن المعالجة المسبقة للبيانات تزيد بشكل حاسم من قدرة النموذج التنبؤية لاكتشاف بوادر الإفلاس في وقت مبكر.

- **دراسة (Shreya & Pathak, 2025) بعنوان: Explainable Artificial Intelligence Credit Risk Assessment using Machine Learning** هدفت الدراسة إلى تحقيق الموازنة بين الدقة والشفافية في تقييم المخاطر الائتمانية. اعتمدت الدراسة المنهج الكمي التطبيقي من خلال بناء نظام يدمج خوارزمية (LightGBM) مع تقنيات التفسير (SHAP و LIME). طُبقت الدراسة في قطاع الإقراض الاستهلاكي في الهند، باستخدام بيانات سجلات طلبات قروض الأفراد. شملت البيانات دورات الائتمان الاستهلاكي الحديثة الممتدة بين عامي (2015 و 2024). أثبتت الدراسة إمكانية توليد تقارير تفسيرية دقيقة تشرح أسباب الموافقة أو الرفض لكل مقترض بشكل فردي دون التضحية بالدقة التنبؤية.

- **دراسة (Patel, 2024) بعنوان: Artificial Intelligence Driven Personalized Loan Pricing in Peer to Peer Lending Finance** سعت الدراسة إلى سد الفجوة بين تقييم المخاطر وتحديد سعر الفائدة العادل للمقترضين. اعتمدت الدراسة المنهج الكمي عبر تطوير نماذج تسعير قروض ديناميكية باستخدام الذكاء الاصطناعي. طُبقت الدراسة على منصات الإقراض المباشر (P2P) في الولايات المتحدة، معتمدة على قاعدة بيانات ضخمة من منصة الإقراض (Lending Club). غطت الدراسة بيانات تاريخية تمتد من عام (2007) إلى (2023).

خلصت الدراسة إلى قدرة الخوارزميات على إيجاد توازن دقيق بين الجدارة الائتمانية والمخاطر لتحديد علاوة مخاطرة (سعر فائدة) تنافسية لكل عميل.

- **دراسة (Chang et al., 2024) بعنوان: Credit Risk Prediction Using Machine Learning and Deep Learning: A Study on Credit Card Customers** هدفت الدراسة إلى تقييم مخاطر الائتمان من خلال مقارنة النماذج التقليدية بالشبكات العصبية. اعتمدت الدراسة المنهجية المقارنة والكمية بين نماذج (الانحدار اللوجستي) ونماذج (التعلم العميق). طُبقت الدراسة في قطاع التجزئة المصرفية، باستخدام قاعدة بيانات ضخمة لعملاء بطاقات الائتمان. وشملت الفترة الزمنية فترات رصد التخلف عن السداد خلال تقلبات مالية تاريخية بين عاميّ 2005 و و2023. أظهرت النتائج تفوق النماذج العميقة في التقاط الأنماط السلوكية غير الخطية وتحديد احتمالية التعثر بدقة أعلى.
- **دراسة (Prabhakar et al., 2024) بعنوان: A Multi Task Approach to Reject Aware Credit Scoring with Missing-Not-At-Random Data: RMT-NET** ركزت الدراسة على معالجة تعقيد المهام الائتمانية المترابطة. تبنت الدراسة منهجية الشبكات العصبية متعددة المهام عبر تطوير نموذج (RMT-NET) للقيام بثلاث مهام متزامنة. طُبقت الدراسة على محافظ التسهيلات الائتمانية، باستخدام بيانات سجلات ائتمانية معقدة تعاني من نقص غير عشوائي. وشملت الفترة الزمنية بيانات تاريخية من عام 2010 الى عام 2022 لاختبار كفاءة استكمال البيانات. أثبتت الدراسة هندسياً وإحصائياً تفوق النماذج التي تتعلم مهاماً متعددة في آن واحد على النماذج الأحادية.

1.2 ما يميز هذه الدراسة عن الدراسات السابقة:

من خلال الاستعراض النقدي للدراسات السابقة، تتضح فجوة بحثية ومنهجية أساسية تتمثل في **الفصل بين النمذجة التنبؤية ونمذجة التسعير**. فقد ركزت معظم الدراسات إما على التنبؤ بالتعثر المالي بشكل منفصل (كدراسة Samara, 2025؛ و Chang, 2024)، أو على تحسين آلية التسعير كعملية مستقلة (كدراسة Mohadikar, 2026؛ و Patel, 2024). وحتى الدراسات المتقدمة التي تبنت هندسة التعلم متعدد المهام (مثل Prabhakar, 2024) وظفتها لغايات معالجة تشوهات البيانات، ولم تستثمرها في دمج مهمتي التنبؤ والتسعير.

علاوة على ذلك، اقتصرت الدراسات التي وظفت تقنيات الذكاء الاصطناعي المفسر (مثل Tabatabei, 2026؛ و Shreya, 2025) على تقديم تبريرات لأسباب تصنيف العميل كمتعثر، ولم تتطرق إلى بناء آليات تفسر العلاقة السببية بين مسببات التعثر تلك وتأثيرها الكمي المباشر على قيمة علاوة المخاطرة وتكلفة الدين المسعرة.

مساهمة الدراسة الحالية: يأتي هذا البحث لسد هذه الفجوة الهيكلية عبر تصميم وتطبيق نموذج كمي مدمج يعتمد على التعلم العميق متعدد المهام للتنبؤ المتزامن باحتمالية التعثر المالي للشركات (مهمة تصنيف) وتحديد تكلفة الدين العادلة (مهمة انحدار) ضمن معمارية عصبية واحدة. وتكمن الإضافة النوعية في التطبيق المباشر لطبقة الذكاء الاصطناعي المفسر (SHAP) على هذا النموذج المعقد، بهدف تقديم تبرير مالي شفاف للمؤسسات المالية يفسر التغير الكمي في تكلفة الدين استناداً إلى عوامل الخطر المكتشفة، مطبقاً ذلك على عينة كبيرة من الشركات المدرجة في السوق الأمريكية، ليلبي بذلك أدق متطلبات النمذجة المالية والحوكمة المصرفية.

1.3 مشكلة الدراسة

في ظل التطور المتسارع للأسواق المالية، تواجه المؤسسات المصرفية ولجان الائتمان تحدياً معقداً يتمثل في الفصل التشغيلي بين عمليتي تقييم مخاطر الائتمان (التنبؤ باحتمالية التعثر) والتسعير الاقتصادي (تحديد تكلفة الدين وعلاوة المخاطرة). حيث تعتمد معظم المؤسسات على نماذج تقليدية أو أحادية المهمة تتعامل مع كل خطوة بمعزل عن الأخرى، مما يؤدي إلى عدم كفاءة في تسعير المخاطر.

ورغم التوجه الحديث نحو استخدام نماذج التعلم العميق لرفع دقة التنبؤ بالتعثر، إلا أن تطبيقها الفعلي في القطاع المالي يصطدم بمعضلة ان هذه الخوارزميات تعجز عن تقديم تفسير مالي واضح لأسباب اتخاذ قرار التسعير، مما يتعارض مع متطلبات الحوكمة والامتثال التنظيمي التي تلزم لجان الائتمان بتبرير هيكل الفائدة المفروضة على الشركات.

بناءً على ما سبق، تتبلور مشكلة البحث في الحاجة الماسة إلى بناء نموذج متكامل يجمع بين كفاءة النمذجة المدمجة والشفافية الخوارزمية. ويمكن صياغة مشكلة البحث في التساؤل الرئيسي الآتي:

ما مدى إمكانية توظيف نماذج التعلم العميق متعدد المهام (MTL) المدعومة بالذكاء الاصطناعي المفسر (XAI) للتنبؤ بالتعثر المالي وتحديد تكلفة الدين للشركات

ويتفرع عن هذا التساؤل الرئيسي التساؤلات الفرعية الآتية:

1. هل يمكن التنبؤ بالتعثر المالي للشركات بدقة وكفاءة عالية باستخدام نموذج MTDL؟
2. هل يمكن التنبؤ بتسعير القروض للشركات بدقة وكفاءة عالية باستخدام نموذج MTDL؟
3. هل يمكن لتقنية الذكاء الاصطناعي المفسر (SHAP) تفسير مخرجات نموذج (MTDL) من خلال تحديد أوزان المتغيرات في التنبؤ بالتعثر وتسعير القروض؟

1.4 فرضيات الدراسة

بناءً على التساؤلات المطروحة، ولغرض اختبار أبعاد المشكلة استناداً إلى بيانات الشركات المدرجة، تم صياغة الفرضيات الآتية:

- **الفرضية الرئيسية الأولى** توجد إمكانية للتنبؤ بالتعثر المالي للشركات بدقة وكفاءة عالية باستخدام نموذج .MTDL
- **الفرضية الرئيسية الثانية** توجد إمكانية للتنبؤ بتسعير القروض للشركات بدقة وكفاءة عالية باستخدام نموذج .MTDL
- **الفرضية الرئيسية الثالثة** يمكن لتقنية الذكاء الاصطناعي المفسر (SHAP) تفسير مخرجات نموذج (MTDL) من خلال تحديد أوزان المتغيرات ومدى مساهمتها في التنبؤ بالتعثر وتسعير القروض.

1.5 أهداف الدراسة:

يسعى هذا البحث إلى تحقيق الأهداف الآتية:

1. تصميم وبناء نموذج كمي يعتمد على التعلم العميق متعدد المهام (MTL) للقيام بعمليتي التنبؤ بالتعثر المالي للشركات (كمهمة تصنيف) وتسعير تكلفة الدين (كمهمة انحدار) في وقت واحد.
2. اختبار كفاءة النموذج المقترح إحصائياً على قاعدة بيانات ضخمة للشركات المساهمة المدرجة في أسواق المال الأمريكية (SEC Data) خلال فترات اقتصادية متباينة (2009–2026).
3. تطبيق أدوات الذكاء الاصطناعي المفسر (XAI)، وتحديداً تقنية (SHAP)، لترجمة مخرجات الشبكات العصبية العميقة إلى بيانات مالية شفافة ومفهومة للجان الائتمان والمحللين الماليين.
4. تقديم إطار عمل متكامل (Framework) للمؤسسات المالية يوازن بين الاستفادة القصوى من دقة الذكاء الاصطناعي وبين الالتزام بمتطلبات الشفافية والحوكمة الرقابية.

1.6 أهمية الدراسة:

تنبثق أهمية هذا البحث من خلال مساهمته على المستويين العلمي والتطبيقي:

1. الأهمية العلمية (النظرية):

- سد الفجوة البحثية: يشكل البحث إضافة نوعية للأدبيات المالية من خلال الدمج بين نماذج تصنيف المخاطر ونماذج التسعير، ودمجهما في معمارية عصبية واحدة (MTL).
- تطوير النمذجة المالية: يقدم البحث منهجية متطورة لتجاوز معضلة الصندوق الأسود في التمويل الكمي، مؤسساً لاستخدام تقنيات (XAI) ليس فقط لتفسير أسباب التعثر، بل لتبرير التغير الكمي في أسعار الفائدة وتكلفة الدين.

2. الأهمية العملية (التطبيقية):

- **دعم القرار الائتماني:** يوفر هذا النموذج للمصارف والمؤسسات الاستثمارية أداة دقيقة وموثوقة تتيح تسعير القروض والديون بشكل ديناميكي وعادل يتناسب طردياً مع حجم المخاطر الحقيقية للشركة.
- **الامتثال الرقابي (Compliance):** تلبي الشفافية التي يوفرها النموذج متطلبات الجهات الرقابية (مثل لجان بازل) التي تشترط وجود تفسير واضح ومنطقي للقرارات الائتمانية المبنية على النماذج الخوارزمية، مما يعزز الثقة في تبني الذكاء الاصطناعي داخل المؤسسات المالية.

1.7 متغيرات الدراسة:

بناءً على طبيعة النموذج القياسي المدمج (متعدد المهام)، تنقسم متغيرات الدراسة إلى الآتي:

1. **المتغيرات المستقلة:** وتمثل المدخلات المحاسبية والسوقية للنموذج، وتشمل نسب السيولة (Current Ratio)، نسب الرفع المالي وهيكل رأس المال (Leverage Ratios)، نسب الربحية

(ROA, EBIT Margin)، بالإضافة إلى مؤشرات الاقتصاد الكلي كمتغيرات ضابطة (مثل VIX و Inflation Rate).

2. **المتغيرات التابعة:** وتتكون من مخرجين متزامنين لشبكة التعلم:

   - **المتغير التابع الأول (1Y) – مسار التصنيف:** مؤشر التعثر المالي وهو متغير فئوي وهمي (Dummy Variable) يأخذ القيمة (1) في حال إفلاس الشركة أو تعثرها قانونياً، والقيمة (0) للشركات السليمة.

   - **المتغير التابع الثاني (2Y) – مسار الانحدار:** تكلفة الدين وعلاوة المخاطرة وهو متغير كمي مستمر يعبر عن الفارق بين الفائدة المدفوعة ومعدل العائد الخالي من المخاطر.

3. **متغيرات التفسير:** وهي الأوزان الكمية المستخرجة عبر خوارزمية (SHAP)، والتي تحدد مقدار وطبيعة تأثير كل متغير مستقل على كل من المتغيرين التابعين، مما يفكك غموض الشبكة العصبية العميقة.

1.8 منهج الدراسة

تعتمد هذه الدراسة على **المنهج الوصفي التحليلي والكمي (Quantitative Analytical Approach)**. في الجانب النظري، سيتم استعراض الأدبيات السابقة وتأطير المفاهيم المتعلقة بمخاطر الائتمان والتعلم العميق. أما في الجانب التطبيقي، سيتم تصميم وبناء نموذج قياسي يعتمد على خوارزميات **التعلم العميق متعدد المهام ((Multitask Deep Learning** بمسارين متزامنين:

- مسار تصنيف (Classification Head) لاكتشاف والتنبؤ باحتمالية التعثر المالي.
- مسار انحدار (Regression Head) لتقدير وتحديد تكلفة الدين (علاوة المخاطرة).

ولضمان الشفافية، سيتم توظيف تقنيات **الذكاء الاصطناعي المفسر**، وتحديداً مكتبة SHAP، لتفكيك النموذج المعقد وتقديم التبرير الاقتصادي لأوزان اتخاذ القرار. ولمقارنة النتائج وإثبات الفرضيات، سيتم استخدام مقاييس الأداء الإحصائية المتقدمة (مثل مقياس AUC–ROC لمهمة التصنيف، ومقياس RMSE لمهمة الانحدار).

1.9 حدود الدراسة (الزمانية والمكانية)

تتحدد أطر هذه الدراسة ونتائجها وفقاً للحدود الآتية:

- **الحدود المكانية (Spatial Limits):** تقتصر الدراسة على الشركات المساهمة العامة المدرجة في أسواق المال الأمريكية، وذلك لتوفر الشفافية العالية في الإفصاحات وتوحيد معايير التعثر والإفلاس تحت قانون (Chapter 11).
- **الحدود الزمانية:** تمتد السلسلة الزمنية لبيانات الدراسة من عام (2009) وحتى عام (2026). يضمن هذا النطاق الزمني تغطية دورات أعمال كاملة تشمل فترات ما بعد الأزمة المالية، صدمة كورونا، وموجات التضخم، مما يعزز المتانة الإحصائية (Robustness) للنموذج.

1.10 مجتمع وعينة الدراسة

- **مجتمع الدراسة:** كافة الشركات المساهمة العامة العاملة بمختلف قطاعاتها الاقتصادية.
- **عينة الدراسة:** نظراً للحاجة إلى بيانات ضخمة (Big Data) لتدريب خوارزميات التعلم العميق، تتكون العينة من كافة الشركات المدرجة في السوق الأمريكية التي تتوفر لها بيانات مالية مكتملة طوال فترة الدراسة؛ وتضم العينة قيد الاختبار (7,960) شركة مساهمة، يتم تتبع بياناتها الربع سنوية والسنوية استناداً إلى المعرفات الرسمية للشركات (CIK).

الفصل الثاني:

الإطار النظري للدراسة

مقدمة:

يمثل هذا الفصل الركيزة المعرفية التي تستند إليها النمذجة الكمية للدراسة؛ حيث يهدف إلى تقديم تأصيل نظري متكامل يدمج بين المفاهيم الاقتصادية والمالية الكلاسيكية وبين التقنيات الحديثة للذكاء الاصطناعي. يتناول الفصل أربعة محاور متكاملة تبدأ بمفهوم التعثر المالي وآليات التنبؤ به، مرورا بالهندسة المالية لتسعير القروض وإدارة العوائد المعدلة بالمخاطر، ثم البنية المعمارية للتعلم العميق وتطبيقاته متعددة المهام، وانتهاءً بالحتمية التنظيمية والرقابية التي فرضت تبني تقنيات الذكاء الاصطناعي المفسر (XAI) في القطاع المصرفي.

2.1 المبحث الأول: مفهوم التعثر المالي والتنبؤ به

يستهدف هذا المبحث تفكيك الظاهرة الائتمانية محل الدراسة من خلال التأصيل المفهومي والتفريق الدقيق بين الحالات المتدرجة للانحدار المؤسسي (الفشل الاقتصادي، التعثر المالي، العسر الفني والحقيقي، والإفلاس القانوني)، مع ربطها بفرضية الاستمرارية ومعايير التقرير المالي الدولي .(IFRS 9) كما يُحلل المبحث الأسباب الداهمة للتعثر من منظور داخلي وخارجي، مستنداً إلى النظريات المالية المفسرة مثل نظرية الوكالة وعدم تماثل المعلومات، ومقدماً تقييماً نقدياً للنماذج الإحصائية والهيكلية التقليدية للتنبؤ بالتخلف عن السداد

2.1.1 التعثر المالي

2.1.1.1 أنواع التعثر المالي: الفشل الاقتصادي والمالي، والعسر، والإفلاس

إن بناء نماذج تنبؤية دقيقة بالاعتماد على خوارزميات التعلم الآلي والأساليب الإحصائية المتقدمة يتطلب أولاً تحديد المتغير التابع، والذي يمثل في سياق الائتمان حالة التخلف عن السداد أو الفشل المالي. في الأدبيات المالية والمحاسبية المعاصرة، هنالك فصل بين المصطلحات، حيث يُفرق بوضوح بين حالات متدرجة تعكس مسار الانحدار المؤسسي وتآكل القيمة (الزبيدي، 2000، ص 272):

- **الفشل الاقتصادي:** يُعد هذا المفهوم الجذور الخفية للأزمة؛ إذ يحدث الفشل الاقتصادي عندما تعجز المنشأة، بشكل هيكلي ومستمر، عن تحقيق عائد على رأس المال المستثمر يتناسب مع مستوى المخاطر التشغيلية المتوقعة. وتحقق هذه الحالة رياضياً واقتصادياً عندما يكون العائد الفعلي أقل من المتوسط المرجح لتكلفة رأس المال (WACC). وفي هذه المرحلة المبكرة، قد لا تظهر على الشركة أية علامات عجز عن السداد، وقد تستمر في العمل لسنوات عبر استنزاف احتياطياتها المتراكمة وخفض قيمة حقوق المساهمين تدريجياً، دون إعلان عجزها الفوري عن خدمة ديونها (Altman et al., 2017, p. 15)

- **التعثر المالي والفشل المالي:** يصف التعثر المالي حالة اقتصادية ونقدية حرجة تواجه فيها الشركة صعوبات جدية ونقصاً حاداً في التدفقات النقدية التشغيلية؛ مما يمنعها من الوفاء بالتزاماتها الجارية في مواعيدها المحددة تعاقدياً (مثل أقساط القروض، أو الفوائد المستحقة، أو مستحقات الموردين). والتعثر حالة يمكن تداركها، ولكن عندما تتوقف الشركة كلياً وبشكل نهائي عن السداد، يتحول التعثر إلى ما يُطلق عليه الفشل المالي.

- **العسر المالي:** يعبر عن حالة أكثر تقدماً وخطورة من الناحية القانونية والمحاسبية. وينقسم إلى نوعين: العسر المالي الفني والذي يشير إلى عجز مؤقت عن توفير السيولة رغم متانة الأصول،

والعسر المالي الحقيقي أو الميزانياتي، والذي يتحقق عندما تتجاوز القيمة الحالية لإجمالي التزامات الشركة القيمة السوقية العادلة لإجمالي أصولها، مما يعني أن القيمة الصافية للشركة أصبحت سالبة.

- **الإفلاس القانوني:** هو الإجراء القانوني الرسمي والنهائي الذي يُتخذ عند العجز التام، وينتهي إما بالتصفية الجبرية لأصول الشركة لتسديد حقوق الدائنين، أو بالدخول في عملية إعادة تنظيم جبرية تحت حماية قوانين الإفلاس الإشرافية؛ حيث تُفرض خطة جدولة صارمة. وتُركز هذه الدراسة بشكل أساسي على التعثر المالي كحدث استباقي يُراد التنبؤ به وتسعيره لحماية رأس المال المصرفي قبل الوصول إلى مرحلة العسر الحقيقي أو الإفلاس التي تشهد تدميراً لقيمة الضمانات والأصول.

2.1.1.2 فرضية الاستمرارية

تُعد فرضية الاستمرارية حجر الأساس الذي يُبنى عليه علم المحاسبة المالية وإعداد التقارير؛ إذ تفترض أن المنشأة ستستمر في عملياتها التشغيلية في المستقبل المنظور، ولن تكون هناك نية أو ضرورة لتصفيتها أو تقليص حجم أعمالها بشكل جوهري. ويمثل التعثر المالي التهديد المباشر لهذا الفرض. وفي هذا السياق، يوفر معيار التدقيق الدولي (ISA 570) إطاراً شاملاً يتضمن سلسلة من مؤشرات الإنذار المبكر التي يجب تدقيقها، والتي تُستخدم في دراستنا هذه كمدخلات جوهرية (Features) للنمذجة التنبؤية (Kieso et al., 2019, p. 48):

1. مؤشرات مالية: كتحول صافي رأس المال العامل إلى قيمة سالبة (زيادة الالتزامات المتداولة على الأصول المتداولة)، سحب التسهيلات الائتمانية من قبل الموردين، التدفقات النقدية التشغيلية السالبة المستمرة، والعجز عن الالتزام بالشروط المالية لعقود القروض.
2. مؤشرات تشغيلية: فقدان إداريين قياديين دون توفر بديل، فقدان أسواق جوهرية، أو ظهور تقنيات منافسة تجعل منتجات الشركة متقادمة.
3. مؤشرات قانونية/خارجية: كالدعاوى القضائية غير المغطاة تأمينياً، أو التغيرات التشريعية المعاكسة التي تضرب صميم نموذج عمل الشركة.

والأهم من ذلك من الناحية المصرفية، أن التقاط هذه المؤشرات وتوقع التعثر لم يعد مجرد إجراء إداري داخلي، بل أصبح مطلباً إلزامياً وحاسماً وفقاً للمعيار الدولي للتقارير المالية (IFRS 9) الخاص بخسائر الائتمان المتوقعة؛ حيث ألزم المصارف بالتخلي عن نموذج "الخسائر المتكبدة" الذي لا يعترف بالخسارة إلا بعد وقوعها، والانتقال إلى نموذج يعتمد على النظرة التطلعية. ويُلزم المعيار المصارف بتصنيف محفظة القروض إلى ثلاث مراحل دقيقة:

- المرحلة الأولى: قروض منتظمة، تتطلب تجنيب مخصصات تغطي خسائر الائتمان المتوقعة لفترة 12 شهراً القادمة فقط.
- المرحلة الثانية: قروض شهدت زيادة جوهرية في المخاطر الائتمانية منذ نشأتها. هنا يُلزم المصرف بتجنيب مخصصات تغطي خسائر الائتمان المتوقعة على مدى العمر المتبقي للقرض.
- المرحلة الثالثة: قروض متعثرة فعلياً ومضمحلة القيمة. إن القيمة الحقيقية لاستخدام التعلم العميق في هذا البحث تكمن في كونه الأداة الكمية المثلى والرياضية الأكثر تعقيداً للتنبؤ الدقيق بالانتقال المبكر للمقترضين من المرحلة الأولى إلى المرحلة الثانية؛ مما يتيح للمصرف تكوين مخصصات كافية وامتصاص الصدمات قبل تفاقمها (مطر، 2010، ص 180).

2.1.1.3 الأسباب الهيكلية والتشغيلية والاقتصادية الكلية للتعثر المالي

لا يحدث التعثر المالي كحدث مفاجئ أو صدمة منعزلة، بل هو نتاج تفاعل تراكمي وديناميكي بين مجموعتين من العوامل التي يجب أن تلتقطها خوارزميات التنبؤ (Hull, 2023, p. 332):

- **المسببات الداخلية:** تنشأ من داخل الإدارة الاستراتيجية والتشغيلية للمنشأة، وتشمل غياب التخطيط المالي السليم، والزيادة في التوسع الاستثماري بالأصول الثابتة غير السائلة على حساب استنزاف رأس المال العامل. كذلك، تعتبر سياسات الائتمان التجاري المتساهلة التي تمنحها الشركة لعملائها من المسببات المباشرة لتراكم الديون المعدومة واختناق السيولة. ويضاف لذلك الإفراط الشديد في الرافعة المالية؛ فالاعتماد المفرط على الديون بدلاً من حقوق الملكية يرفع من نقطة التعادل المالي ويزيد من صلابة أعباء خدمة الدين، مما يجرد الشركة من أي مرونة مالية لامتصاص الصدمات العارضة.

- **المسببات الخارجية:** تفرض العوامل الكلية ضغوطاً هيكلية لا تملك إدارة الشركة سيطرة عليها. تشمل هذه العوامل الانكماش الاقتصادي العام الذي يقلص الطلب الكلي، والمنافسة السعرية الحادة، واضطرابات سلاسل التوريد. كما تمثل صدمات أسعار الفائدة الناتجة عن سياسات البنوك المركزية تهديداً مباشراً للشركات التي تعتمد على قروض بفوائد عائمة.

2.1.1.4 النظريات المالية والاقتصادية المفسرة للتعثر المالي وتأثيراتها الائتمانية

لتأصيل بناء النموذج التنبؤي، يجب فهم المحركات النظرية التي تفسر السلوك المالي للشركات قبل التعثر:

- **نظرية المفاضلة وتكلفة وكالة الدين:** تفترض هذه النظرية أن الشركات تحدد الهيكل الأمثل لرأس مالها عبر عملية موازنة دقيقة بين المزايا الضريبية للديون وتكاليف التعثر المالي المتوقعة. عندما تتراكم الديون وتقترب الشركة من منطقة التعثر، تنخفض القيمة السوقية لحقوق الملكية بشكل حاد، وهنا ينشأ صراع وكالة عميق بين المساهمين والدائنين (المصارف). الإدارة، ممثلةً للمساهمين، قد تلجأ إلى اتخاذ قرارات عالية المخاطر وهي ظاهرة تعرف بـ استبدال الأصول مدركة أن المكاسب الاستثنائية ستعود للمساهمين إذا نجح المشروع، بينما يتحمل الدائنون والمصارف كامل الجانب السلبي والخسارة إذا فشل المشروع (Ross et al., 2022, p. 525). كما قد تتوقف الإدارة عن ضخ أموال في مشاريع آمنة ومربحة لعلمها أن العوائد ستذهب لسداد الدائنين بدلاً من المساهمين.

- **نظرية عدم تماثل المعلومات:** تُعد هذه النظرية الحجر الأساس في فهم إخفاقات الأسواق الائتمانية. تمتلك إدارة الشركة (المقترض) معلومات دقيقة، تفصيلية، ولحظية حول المخاطر التشغيلية الحقيقية وحالة المشاريع، تفوق بكثير ما يمتلكه المصرف (المُقرض). هذا التفاوت المعلوماتي يقود إلى نتيجتين حتميتين: الاختيار العكسي قبل منح القرض، حيث أن محاولة المصرف حماية نفسه برفع سعر الفائدة العشوائي يؤدي إلى طرد العملاء الجيدين والإبقاء على المقترضين الخطرين المستعدين لقبول أي تكلفة. والنتيجة الثانية هي الخطر الأخلاقي بعد منح القرض، حيث يستغل المقترض غياب الرقابة اللصيقة لتغيير طبيعة استثماراته نحو أنشطة أشد خطورة. هذا التباين هو ما يبرر لجوء المصارف إلى سياسات التقنين الائتماني وتضمين عقود القروض شروطاً ومواثيق مقيدة بالغة الصرامة لتقييد سلوك الإدارة (Casu et al., 2022, p. 115)

2.1.1.5 مراحل الانحدار المالي

لا يعد التعثر صدمة مفردة، بل مسار انحداري ديناميكي يمر عبر مراحل حاسمة، وكل مرحلة تتطلب تقييماً وتدخلاً مصرفياً مختلفاً (الزبيدي، 2000، ص 150):

1. مرحلة الحضانة والكمون: تبدأ باتخاذ قرارات استراتيجية غير موفقة تؤدي لتراجع الحصة السوقية وانضغاط هوامش الربحية دون التأثير الفوري على السيولة النقدية. في هذه المرحلة، تظهر قوة النماذج التنبؤية المتقدمة التي تلتقط التشوهات الهيكلية مبكراً.
2. مرحلة العسر المالي الفني: تواجه الشركة نقصاً مؤقتاً ولكن حاداً في السيولة يجعلها غير قادرة على تسديد التزاماتها الجارية، بالرغم من أن القيمة العادلة لأصولها وتدفقاتها المستقبلية تتجاوز حجم التزاماتها الكلية. من منظور الإدارة الائتمانية، يُعالج هذا النوع عادةً بقرارات إعادة الهيكلة وتمديد الآجال وضخ سيولة. ويكون الأثر المتوقع على نسبة الخسارة عند التعثر (LGD) منخفضاً نظراً لوجود غطاء أصولي متين يمكن الاعتماد عليه.
3. مرحلة العسر المالي الحقيقي: هي مرحلة اختلال الهيكل التمويلي بالكامل، حيث تصبح القيمة السوقية لإجمالي الأصول غير كافية لتغطية التزامات الشركة. مصرفياً، يؤدي الوصول لهذه المرحلة إلى تجميد فوري للتسهيلات وبدء الإجراءات القانونية للتصفية. وفي هذه المرحلة الكارثية، يتعاظم أثر الـ LGD بشكل خطير جداً، نظراً لتآكل قيمة الأصول بسرعة، وانخفاض معدلات الاسترداد بسبب البيع الاضطراري وتراكم الرسوم القانونية.

2.1.2 التنبؤ بالتعثر المالي باستخدام المقايس الكلاسيكية

2.1.2.1 مفهوم وأهمية التنبؤ بالتعثر المالي

يُعرف التنبؤ بالتعثر المالي بأنه الاستخدام المنهجي والتحليل الكمي للبيانات المالية وغير المالية، التاريخية والحالية، لبناء نماذج رياضية تهدف إلى تقدير الاحتمالية المستقبلية (PD) لعجز المقترض عن الوفاء بالتزاماته. تكمن الأهمية الاستراتيجية والاقتصادية للتنبؤ المبكر في كونه خط الدفاع الأول والأساسي لحماية رأس المال المصرفي؛ فهو يتيح لإدارات المخاطر اتخاذ إجراءات استباقية كطلب ضمانات إضافية، تعديل الشروط التعاقدية، التسعير المبني على الخطر، أو حتى التخارج المبكر من القرض عبر التوريق. هذا النهج يجنب المصرف الاعتماد على ردود الفعل المتأخرة التي تكلفه تكوين مخصصات طارئة تأكل من قاعدته الرأسمالية التنظيمية وتضعف ربحيته (Casu et al., 2022, p. 255).

2.1.2.2 دقة التنبؤ ومصفوفة الارتباك (Confusion Matrix):

في النمذجة الائتمانية المعاصرة، لا تُقاس جودة أي نموذج تنبؤي بمجرد دقة التصنيف العامة ، بل تُقاس بقدرته التمييزية على تقليل الأخطاء الإحصائية، مع الأخذ بعين الاعتبار أن تكلفة هذه الأخطاء ليست متماثلة اقتصادياً. يواجه النموذج التنبؤي نوعين حرجين من الأخطاء:

- **الخطأ من النوع الأول:** يحدث عندما يُصنف النموذج شركة متعثرة فعلياً على أنها شركة سليمة وجيدة الائتمان. التكلفة الاقتصادية لهذا الخطأ كبيرة؛ حيث تؤدي إلى منح أو تجديد تسهيلات ائتمانية لعميل سيفشل حتماً، مما يكبّد المصرف خسارة جزء كبير أو كامل أصل القرض والفوائد المستحقة، ناهيك عن التكاليف الباهظة للملاحقة القانونية وإدارة الأصول المتعثرة.
- **الخطأ من النوع الثاني:** يحدث عندما يُصنف النموذج شركة سليمة ومليئة على أنها متعثرة وعالية المخاطر. التكلفة هنا هي تكلفة فرصة بديلة؛ حيث يؤدي هذا الخطأ إلى حرمان عميل جيد من الائتمان أو فرض شروط مجحفة عليه، مما يفوت على المصرف فرصة تحقيق إيرادات فوائد آمنة، ويدفع العميل للتوجه نحو المصارف المنافسة مما يضر بالحصة السوقية. إن الهدف الجوهري من التحول نحو خوارزميات التعلم العميق والذكاء الاصطناعي هو إيجاد عتبة قرار مثلى وحساب دالة تكلفة غير متماثلة تقلص الخطأ من النوع الأول لأقصى حد ممكن للحفاظ على سلامة المصرف،

دون تضخيم الخطأ من النوع الثاني بشكل يعيق نمو الإيرادات التشغيلية (Gunnarsson et al., 2021, p. 296).

2.1.2.3 نماذج التنبؤ التقليدية:

لفهم قيمة النموذج المقترح في هذا البحث، يجب تقييم القصور الهيكلي للنماذج التي حكمت الصناعة المصرفية لعقود:

- **النماذج المحاسبية الإحصائية:** تعتمد هذه النماذج على أساليب إحصائية مثل التحليل التمييزي المتعدد والانحدار اللوجستي. ورغم سهولة فهمها وتطبيقها، إلا أنها تظل قاصرة هيكلياً. أولاً، تعتمد بشكل كلي على بيانات محاسبية تاريخية تكون بطبيعتها عرضة لممارسات التلاعب وإدارة الأرباح التي تمارسها الإدارة لإخفاء تدهور الأداء. ثانياً، تفترض وجود علاقات خطية صارمة واستقلالية إحصائية بين المتغيرات المالية للمقترض، وهو افتراض مثالي يخالف واقع وديناميكية الأسواق المالية المعاصرة (Altman et al., 2017, p. 60؛ Greene, 2018, p. 730).
- **النماذج الهيكلية المبنية على السوق:** تستند هذه النماذج إلى نظرية تسعير الخيارات (Black–Scholes–Merton)، حيث تقوم بتقييم حقوق ملكية الشركة كأنها خيار شراء على أصول الشركة، بقيمة تنفيذ تعادل القيمة الدفترية للديون. ورغم تفوق هذا النموذج في دمج توقعات السوق اللحظية وتغيرات القيمة السوقية، إلا أن بنيانه الرياضي ينهار عند انتفاء فرضية كفاءة الأسواق المالية، أو عند محاولة تطبيقه على الشركات الخاصة والمشروعات المتوسطة والصغيرة غير المدرجة التي تفتقر لبيانات تسعير وتقلب سوقية يومية (Hull, 2023, p. 410).

2.2 المبحث الثاني: تسعير القروض وإدارة العوائد المعدلة بالمخاطر

يركز هذا المبحث على التحليل الاقتصادي لعملية تسعير الائتمان في المؤسسات المصرفية؛ حيث يستعرض تطور فلسفة التسعير من المقاربة التجارية التقليدية إلى إطار العائد على رأس المال المعدل بالمخاطر .(RAROC) كما يحلل المبحث المكونات الثلاثة للخسارة الائتمانية) الخسارة المتوقعةEL ، والخسارة غير المتوقعةUL ، والتعرض عند التعثر(EAD ، ويتعمق في المعضلات النظرية للتسعير كالاختيار العكسي والخطر الأخلاقي) تأثير(Stiglitz–Weiss ، وصولاً إلى مقومات الانتقال نحو استراتيجيات التسعير الديناميكي المستندة إلى الذكاء الاصطناعي

2.2.1 التسعير الائتماني وإطار العائد المعدل بالمخاطر (RAROC)

لا يمثل تسعير القروض الائتمانية في المصارف الحديثة عملية حسابية بسيطة ومباشرة تقتصر على إضافة هامش ربح تجاري إلى تكلفة الأموال المجمعة من المودعين. بل هو عملية هندسة مالية، وتقييم اقتصادي، وتحسين رياضي معقد يستهدف حماية رأس مال المصرف وتعظيم ثروة المساهمين في ظل قيود شديدة الصرامة. يعتمد البنيان النظري لتسعير القروض في المؤسسات المالية الرائدة عالمياً على إطار العائد على رأس المال المعدل بالمخاطر. ويُعطى بالعلاقة الرياضية الاتية:

$$RAROC = \frac{Expected\ return - Expenses - Expected\ losses + Return\ on\ capital}{Economic\ capital}$$

حيث يكون:

العائد المتوقع: إجمالي الإيرادات المتولدة من الأصول أو النشاط.

المصاريف: التكاليف التشغيلية المباشرة وغير المباشرة.

الخسائر المتوقعة: متوسط الخسائر التي يتوقعها البنك إحصائياً (مثل مخصصات الديون المشكوك في تحصيلها).

العائد على رأس المال: الأرباح الناتجة عن استثمار رأس المال الاقتصادي نفسه في استثمارات خالية من المخاطر.

رأس المال الاقتصادي: هو مقدار رأس المال الذي يحتاجه البنك لضمان ملاءته المالية بناءً على مستوى ثقة محدد لمواجهة الخسائر غير المتوقعة.

فرض هذا الإطار التحليلي أن العائد الاقتصادي المتوقع من منح أي قرض يجب أن يكون كافياً لتغطية المكونات الثلاثة التالية: تكلفة الأموال التي يدفعها المصرف للمودعين والمقرضين، المصاريف التشغيلية والإدارية المرتبطة بإصدار وإدارة القرض، والتكلفة الحتمية المتمثلة في الخسارة المتوقعة. بعد تغطية هذه التكاليف الثلاث، يجب أن يوفر القرض هامش ربح صافٍ يعوض المساهمين عن تخصيص جزء من رأس مالهم الاقتصادي كغطاء تأميني لمواجهة الخسائر غير المتوقعة (Hull, 2023, p. 325). القاعدة هنا: إذا كان معدل العائد على رأس المال المعدل بالمخاطر المحسوب لقرض محتمل أقل من الحد الأدنى للعائد المطلوب من قبل المساهمين (والذي يقاس غالباً بتكلفة حقوق الملكية المستخرجة من نموذج CAPM)، فإن المصرف يقوم فعلياً بتدمير قيمة المساهمين بمجرد الموافقة على القرض، حتى وإن كان القرض يحقق تدفقاً نقدياً موجباً. لتصحيح هذا الانحراف، يجب على إدارة التسعير والائتمان هندسة القرض عكسياً؛ إما عبر رفع سعر الفائدة والرسوم لزيادة البسط (العائد)، أو المطالبة بضمانات صلبة إضافية تقلل من المخاطر وبالتالي تخفض المقام (رأس المال الاقتصادي المطلوب).

2.2.2 الخسارة المتوقعة (EL) ومكوناتها الأساسية

الخسارة المتوقعة ليست خسارة عارضة، بل تُعد التكلفة الطبيعية، الإحصائية، والمحتملة لممارسة أعمال الإقراض. في الممارسة المصرفية السليمة، تُعامل الخسارة المتوقعة كتكلفة تشغيلية بحتة، يجب على المصرف أن يمتصها من خلال إيرادات الفوائد العادية وأن يكوّن لها مخصصات مالية تقتطع من قائمة الدخل. تعتمد دقة عملية التسعير الائتماني بشكل كامل على التقدير الكمي الدقيق لثلاثة محددات جوهرية، والتي تشكل معاً معادلة الخسارة المتوقعة وفقاً لأطر لجنة بازل للرقابة المصرفية (Saunders et al., 2021, p. 340):

1. **احتمالية التعثر:** هي النسبة المئوية التي تعكس احتمالية عجز المقترض الفعلي عن الوفاء بالتزاماته خلال أفق زمني محدد (12 شهراً). يُعد تقدير هذه النسبة التحدي الكمي الأكبر، وتميز النماذج المتقدمة بين تقدير يعكس حالة المقترض اللحظية بناءً على الدورة الاقتصادية الحالية (وهو الأنسب لـ IFRS 9 والتسعير الديناميكي)، وتقدير يتجاهل تقلبات الدورة الاقتصادية (وهو الأنسب لحسابات كفاية رأس المال التنظيمي).

2. **نسبة الخسارة عند التعثر (LGD):** تمثل النسبة المئوية من إجمالي التعرض الائتماني التي سيفقدها المصرف فعلياً وبشكل نهائي في حال وقوع حدث التعثر، وذلك بعد حساب القيمة الحالية لجميع التدفقات النقدية المستردة من تصفية الضمانات مطروحاً منها تكاليف التحصيل. يرتبط هذا المكون ارتباطاً عكسياً وثيقاً بجودة وقابلية تسييل الضمانات. علاوة على ذلك، في أوقات الأزمات، تنهار قيمة الضمانات بسبب ظاهرة البيع الاضطراري في الأسواق غير السائلة، مما يرفع الـ LGD، ويؤكد أهمية تسعير القرض بناءً على أسوأ السيناريوهات السوقية.

3. **التعرض عند التعثر:** يُقدر هذا المكون إجمالي الرصيد القائم للقرض الذي سيكون عرضة للخطر في اللحظة الدقيقة لحدوث التعثر المستقبلي. في القروض لأجل يكون التعرض عند التعثر واضحاً، ولكن في خطوط الائتمان المتجددة والتسهيلات غير المسحوبة بالكامل، يقوم المصرف باحتساب احتمالية سحب العميل لأرصدة إضافية في الفترة التي تسبق الإفلاس مباشرة، وذلك باستخدام معامل تحويل الائتمان.

إن التسعير المنضبط يقتضي إضافة قسط خطر يغطي بدقة رياضية قيمة الخسارة المتوقعة. أي تقدير خاطئ، خصوصاً التقليل من احتمالية التعثر، يعني أن المصرف يسعر قروضه بأقل من قيمتها العادلة، ويهدي هوامشه للمقترض، مما ينعكس لاحقاً كخسائر تضرب رأس المال.

2.2.3 الخسائر غير المتوقعة (UL)

بينما تعالج الخسارة المتوقعة التكاليف الطبيعية والمتوسطة عبر هوامش الفائدة والمخصصات، يواجه المصرف باستمرار احتمالات وقوع سيناريوهات أزمات متطرفة في الاقتصاد الكلي تؤدي إلى موجات تعثر تفوق المتوسط الإحصائي المعتاد. تمثل هذه التجاوزات الكبيرة والتقلبات في معدل الخسارة ما يُعرف بـ

الخسائر غير المتوقعة. من المستحيل اقتصادياً وتجارياً تغطية الخسارة غير المتوقعة عبر رفع سعر الفائدة؛ لأن ذلك سيجعل القروض باهظة التكلفة وخارج المنافسة. بدلاً من ذلك، تتطلب الخسارة غير المتوقعة احتجاز رأس مال اقتصادي قوي ومتين من حقوق المساهمين ليمثل مصدة وحائط صد لاستيعاب الانهيار في الأزمات. وفقاً لمنهج التقييم الداخلي المتقدم للمخاطر في مقررات لجنة بازل 3 وما بعدها، يتم تقدير متطلبات رأس المال التنظيمي للبنوك باستخدام نماذج كمية معقدة تعتمد على ارتباط الكوبولا الغاوسي لعامل واحد. يحسب هذا النموذج معدل التعثر في أسوأ الحالات بناءً على مستوى ثقة تنظيمي يبلغ عادة 99.9%. بناءً على هذا، يُمَرر المصرف تكلفة العائد المطلوب من قبل المساهمين على هذا رأس المال المحتجز إلى المقترض في شكل علاوة خطر إضافية ضمن هيكل سعر الفائدة الشامل، وهو ما يجعل التسعير الحقيقي مرآة دقيقة تعكس التفاعل المعقد لمخاطر العميل ليس فقط في الأوقات العادية، بل في أسوأ السيناريوهات الاقتصادية الممكنة (Hull, 2023, p. 625)

2.2.4 محددات تسعير القروض المصرفية

لا يتحدد سعر الفائدة النهائي في الأسواق الائتمانية المعقدة بقرار إداري بسيط، بل هو نتاج توازن رياضي وتفاعل دقيق ومستمر لثلاث طبقات متداخلة من المتغيرات (مطر، 2010، ص 210؛ Saunders et al., 2021):

- **عوامل المستوى الجزئي الخاصة بالمقترض:** تمثل الأساس الأول للتسعير. وتشمل تقييم الجدارة الائتمانية التاريخية، التقييم الكمي لمستوى الرافعة المالية (والتي تضاعف حساسية الشركة لصدمات السوق)، درجة استقرار ونمو التدفقات النقدية الحرة المتاحة لخدمة الدين، وقوة الحوكمة المؤسسية. هذه العوامل تلعب الدور المهيمن في تقدير احتمالية التعثر.
- **عوامل المستوى الهيكلي والتعاقدي للقرض:** القرض ليس مبلغاً مالياً فقط، بل عقد قانوني يحدد المخاطر. تشمل هذه العوامل حجم القرض المتزامن مع سياسات تركز المخاطر في البنك، وأجل الاستحقاق المستقبلي، حيث تفرض البنوك ما يسمى علاوة أجل لتعويض المخاطر الناجمة عن ضبابية المستقبل واحتمالات تغير بيئة الأعمال للشركات طويلة الأمد. كما تعتبر جودة الضمانات وحسومات تسييلها، بالإضافة إلى الشروط التعاقدية المقيدة—التي تفرض قيوداً تشغيلية ومحاسبية

صارمة على الإدارة لمنع استبدال الأصول وتمنح المصرف حق التدخل والإنذار المبكر—من أقوى العوامل المخفضة للتسعير.

- **عوامل الاقتصاد الكلي وبيئة السوق:** يتأثر التسعير جذرياً ببيئة الاقتصاد التي تعمل بها البنوك، بدءاً من منحنى العائد ومعدلات الفائدة المرجعية خالية المخاطر (كأسعار فائدة البنك المركزي السائدة) التي تمثل أرضية التسعير، مروراً بموقع الاقتصاد الكلي من دورة الأعمال وتوقعات التضخم المستقبلية. كما تفرض متطلبات السيولة التنظيمية (مثل LCR و NSFR من بازل 3) تكلفة تمويل إضافية على المصرف، يتم تحميل جزء كبير منها لتسعيرة القروض الممنوحة.

2.2.5 مشكلة التسعير الائتماني: الاختيار العكسي، الخطر الأخلاقي، والتقنين

يواجه تسعير القروض معضلة أكاديمية وعملية خطيرة للغاية عُرفت في نظرية الاقتصاد المالي بظاهرة تأثير Stiglitz–Weiss. قد يُفترض رياضياً، وفقاً لمنطق توازن الأسواق الكلاسيكي، أن المؤسسة المالية يمكنها الاستمرار بلا نهاية في تمويل المشاريع عالية المخاطر وتصفية السوق الائتماني ببساطة عبر الرفع المستمر لسعر الفائدة لضمان تغطية العائد مقابل الخطر. لكن هذا الافتراض يفشل فشلاً ذريعاً في الواقع المصرفي بسبب ميكانيكية الاختيار العكسي الناتجة عن عدم تماثل المعلومات. يشرح Stiglitz و Weiss أن العلاقة بين سعر الفائدة المفروض والعائد المتوقع للمصرف ليست علاقة خطية تصاعدية، بل تتخذ شكل منحنى مقعر. عند رفع الفائدة تدريجياً وتجاوزها لنقطة التوازن الحرجة، يحدث تدمير لجودة محفظة القروض؛ حيث ينسحب المقترضون الجيدون من السوق كلياً، ولا يتبقى يطلب الائتمان سوى المقترضين ذوي المخاطر العالية جداً، اليائسين، أو ذوي المشاريع المضاربية التي تعد بعوائد فلكية إن نجحت ولا شيء إن فشلت. إلى جانب ذلك، يخلق السعر المرتفع بيئة مثالية لـ الخطر الأخلاقي، حيث يميل المقترض تحت ضغط الفوائد المرتفعة جداً لاتخاذ استثمارات مفرطة المخاطر لمحاولة تلبية أعباء خدمة الدين. هذا التفسير الاقتصادي العميق يوضح بجلاء لماذا تلجأ المصارف الحصيفة إلى سياسة التقنين الائتماني بالكمية، حيث تفضل إدارة الائتمان رفض طلب القرض تماماً والحد من سقف الائتمان ، بدلاً من منحه بسعر فائدة فلكي يزيد يقيناً من احتمالية التعثر ويدمر قيمة المصرف (Casu et al., 2022, p. 115).

2.2.6 التسعير الديناميكي وإدارة المحافظ المتقدمة المستندة للذكاء الاصطناعي

مع التطور المتسارع للرقمنة المالية وتزايد الضغوط التنافسية، تتجه المؤسسات المصرفية الرائدة نحو التخلي عن جداول التسعير الجامدة وتطبيق استراتيجيات التسعير اللحظي والديناميكي المستندة إلى خوارزميات التعلم الآلي والعميق. يتجاوز هذا النهج المتقدم أساليب التسعير الثابتة التي تقسم العملاء إلى فئات مخاطر عريضة وعامة. في النهج الحديث، لا يقوم الذكاء الاصطناعي فقط بالتنبؤ الدقيق والفردي لاحتمالية التعثر لكل مقترض بشكل منعزل، بل يقوم بدمج هذه النماذج مع خوارزميات تحسين تحسب المرونة السعرية لطلب العميل، ومدى استعداد العميل للدفع بناءً على سلوكه المالي السابق وخياراته البديلة في السوق. بناءً على ذلك، يحصل كل عميل مقترض على عرض سعر فائدة فريد تماماً، مُصمم هندسياً ليعكس درجة خطورته الائتمانية الدقيقة، القيمة السوقية اللحظية لضماناته، وتكلفة رأس المال المخصصة لحماية المصرف منه، كل ذلك في إطار عملية تحسين رياضية لا تخل بهامش الربح الاستراتيجي المستهدف للبنك والمستمد من نموذج العائد على رأس المال المعدل بالمخاطر. هذا الربط العميق والوثيق بين النمذجة التنبؤية للمخاطر واستراتيجيات التسعير المتطورة هو ما يُشكل جوهر وجدوى دمج هاتين المهمتين في نموذج MTDL الذي يقدمه هذا البحث.

2.3 المبحث الثالث: البنية المعمارية للتعلم العميق وتطبيقاته في النمذجة المالية

يتناول هذا المبحث البنيان الرياضي والهندسي لخوارزميات التعلم العميق، مستعرضاً التفوق النظري لشبكات الذاكرة طويلة قصيرة الأجل (LSTM) والشبكات العميقة (DNNs) في التقاط العلاقات غير الخطية ومعالجة البيانات عالية الأبعاد والسلاسل الزمنية مقارنة بنماذج الانحدار القياسية. كما يؤصل المبحث الابتكار المنهجي للدراسة المتمثل في التعلم العميق متعدد المهام(MTDL) ، مفصلاً آليات التمثيل المشترك (Shared Representation)وتقليل دالة التكلفة المركبة لدمج مهمتي التنبؤ والتسعير ضمن معمارية موحدة.

2.3.1 البنية الرياضية في النماذج الكلاسيكية

2.3.1.1 القيود القياسية لنماذج (Logit/Probit) والسلاسل الزمنية

لأكثر من خمسة عقود، هيمنت نماذج الانحدار الخطي واللوجستي على دوائر إدارة المخاطر في المصارف. تُبنى هذه النماذج على دالة الربط التي تفترض علاقة خطية صارمة بين اللوغاريتم الطبيعي لنسبة الأرجحية ومجموعة من المتغيرات التفسيرية (المؤشرات المالية). العائق القياسي الأكبر لهذه النماذج يكمن في مصفوفة التغاير. تشترط مبرهنة غاوس–ماركوف وتطبيقات القيمة القصوى للاحتمالية غياب ظاهرة التعددية الخطية. في علم التمويل، المؤشرات المحاسبية مترابطة عضوياً؛ فنسبة (العائد على الأصول ROA) مرتبطة خطياً بنسبة (العائد على حقوق الملكية ROE) عبر مضاعف حقوق الملكية. إدخال هذه المتغيرات معاً في نماذج لوجيت يؤدي إلى تضخم كبير في الأخطاء المعيارية لمعاملات الانحدار، مما يجعل الأوزان الإحصائية للمتغيرات غير مستقرة، وتنهار القدرة التنبؤية للنموذج عند اختباره على بيانات خارج العينة (Out–of–sample Data). وللتهرب من هذا المأزق، استخدمت أبحاث أخرى السلاسل

الزمنية. ورغم قدرتها على تتبع المقترض زمنياً ومقطعياً، إلا أنها تتطلب فرضيات قاسية مثل الاستقرارية وافتراض غياب التباين المتغاير. في بيئة الأزمات المالية، تتسم السلاسل الزمنية للمقترضين بتقلبات عشوائية حادة وانقطاعات هيكلية تفشل النماذج البارامترية في التقاطها (Greene, 2018, p. 730; Dixon et al., 2020, p. 85).

2.3.1.2 نظرية التقريب العالمي والميزة التنافسية للبيانات عالية الأبعاد

تتجاوز خوارزميات التعلم العميق هذه المعضلات الرياضية من خلال هندستها غير البارامترية. يُبنى التفوق النظري لهذه الشبكات على نظرية التقريب العالمي والتي تنص رياضياً على أن شبكة عصبية أمامية التغذية تحتوي على طبقة مخفية واحدة على الأقل وعدد كافٍ من العصبونات ووظيفة تنشيط غير خطية، قادرة على تقريب وتمثيل أي دالة رياضية مستمرة، مهما بلغت درجة تعقيدها. هذا يعني في السياق المالي أن الباحث لم يعد مضطراً لافتراض شكل العلاقة بين السيولة والتعثر سلفاً. الشبكة العصبية العميقة تقوم، من خلال عملية التدريب وضبط الأوزان، ببناء مستويات متعددة الأبعاد تفصل بين المقترضين الجيدين والمتعثرين في فضاء عالي الأبعاد. هذه القدرة تتيح للمصارف إدخال آلاف المتغيرات دون القلق من التعددية الخطية، لتقوم الشبكة باستخراج التفاعلات الكامنة تلقائياً (Gunnarsson et al., 2021, p. 295).

2.3.2 التعلم العميق في تصنيف الائتمان وتحليل السلاسل الزمنية

2.3.2.1 الشبكات العصبية العميقة (DNNs): من التجريد الرياضي إلى تصنيف الجدارة

تتألف الشبكة العصبية العميقة من بنية هرمية تبدأ بطبقة المدخلات التي تستقبل شعاع البيانات المالية. تنتقل الإشارات عبر طبقات مخفية متعددة، حيث تقوم كل عقدة بعملية تحويل تآلفي رياضية تتمثل بضرب المدخلات في مصفوفة الأوزان وإضافة الانحياز، ثم تمرير الناتج عبر دالة تنشيط غير خطية (مثل ReLU أو Sigmoid) في مهام تصنيف الائتمان، يسمح هذا العمق الهيكلي للشبكة بتعلم مستويات تجريد متصاعدة. فالطبقة المخفية الأولى قد تكتشف علاقات بسيطة (مثل ضعف السيولة)، بينما الطبقة الثالثة

قد تكتشف تفاعلات معقدة لا تخطر على بال المحلل المالي (مثل: ضعف السيولة يترافق مع ارتفاع الفائدة وصدمة في قطاع محدد يؤدي حتماً للتعثر). تنتهي الشبكة بطبقة إخراج تستخدم دالة سفتماكس لتحويل المخرجات العددية إلى احتمالات رياضية صارمة تتراوح بين صفر وواحد، تمثل دقة احتمالية التعثر المطلوبة لتسعير القرض (Dixon et al., 2020, p. 110)

2.3.2.2 معالجة الذاكرة الائتمانية: شبكات الذاكرة طويلة قصيرة الأجل وتلاشي التدرج

تتعامل إدارة المخاطر في البنوك مع بيانات السلاسل الزمنية، كالتاريخ الائتماني للمقترض وحركة تدفقاته النقدية عبر الأرباع السنوية. الشبكات العصبية العميقة القياسية تفتقر للذاكرة؛ فهي تعالج ميزانية كل ربع مالي كحدث مستقل. لمعالجة التسلسل الزمني، ظهرت الشبكات العصبية المتكررة، لكنها عانت رياضياً من مشكلة تلاشي أو انفجار التدرج عند انتشار الخطأ العكسي، مما يعني أنها تنسى المؤشرات المبكرة للتعثر إذا حدثت قبل عدة أرباع مالية. هنا يبرز دور شبكات الذاكرة طويلة قصيرة الأجل كأقوى أداة مالية للتنبؤ الزمني. تتكون خلية الذاكرة من حالة الخلية التي تعمل كحزام ناقل للمعلومات التاريخية، وثلاث بوابات منطقية تعتمد على دالة (Sigmoid):

1. بوابة النسيان (Forget Gate): تقرر رياضياً أي المعلومات من الميزانيات السابقة لم تعد ذات صلة بالتعثر ويجب التخلص منها.
2. بوابة الإدخال (Input Gate): تقرر أي المعلومات من الميزانية الحالية (الصدمات الجديدة) يجب إضافتها إلى الذاكرة الائتمانية.
3. بوابة الإخراج: تحسب المخاطر اللحظية بناءً على التاريخ المنقح والمعطيات الحالية. بفضل هذه الهندسة، تستطيع شبكات الذاكرة طويلة قصيرة الأجل التقاط تدهور هيكلي بطيء ومستمر (مثل انخفاض تدفعي طفيف في التدفقات النقدية التشغيلية على مدى 8 أرباع مالية) وتفسيره كعلامة

إنذار مبكر حاسمة للتعثر، وهو أمر مستحيل على النماذج الخطية اكتشافه (Sezer et al., 2020, p. 10).

2.3.3 التعلم العميق متعدد المهام والتسعير

يُعد التعلم متعدد المهام الابتكار المنهجي الأهم في هذا البحث، حيث يحاكي طريقة عمل لجنة الائتمان البشرية التي لا تنظر إلى احتمالية التعثر (PD) بمعزل عن قرار التسعير وعلاوة المخاطرة.

2.3.3.1 التأصيل الرياضي: التعلم المشترك وتقليل دالة التكلفة المركبة

بدلاً من بناء نموذج للتعثر (تصنيف) ونموذج آخر مفصول للتسعير (انحدار)، يعتمد التعلم متعدد المهام على تدريب شبكة عصبية واحدة تتعلم إنجاز المهمتين بالتزامن. رياضياً، يتحقق هذا من خلال تقليل دالة التكلفة المركبة. تُعبر هذه الدالة عن المجموع الموزون لدوال التكلفة الخاصة بكل مهمة:

$$L_{total} = \lambda_1 L_{PD} + \lambda_2 L_{Pricing}$$

حيث:

- L_{PD}: هي دالة خسارة الإنتروبيا المتقاطعة (Cross-Entropy Loss) المستخدمة لتعظيم دقة تصنيف التعثر. فهي تعاقب النموذج بشدة إذا أعطى احتمالية منخفضة لعميل تعثر بالفعل.
- $L_{Pricing}$: هي دالة متوسط مربع الخطأ (Mean Squared Error – MSE) المستخدمة لتقليل تباين التسعير. تعاقب النموذج إذا كان التسعير المقترح ينحرف عن التسعير العادل الذي يغطي الخسارة المتوقعة.
- λ_1, λ_2: هي أوزان توازن أهمية المهمتين (Hyperparameters). من خلال التدرج العكسي المشترك، يُجبر النموذج الرياضي على إيجاد مصفوفة أوزان تلبي كلا الهدفين التجاريين للبنك في آن واحد، مما يمنع ظاهرة التناقض المنهجي (كأن يتنبأ نموذج باحتمالية تعثر عالية، بينما يعطي نموذج التسعير المنفصل سعراً منخفضاً للعميل ذاته) (Zhang & Yang, 2022, p. 5589).

2.3.3.2 آليات التمثيل المشترك وتدفق المعلومات الائتمانية

من الناحية المعمارية، يعتمد النموذج المقترح على آلية مشاركة المعلمات الصلبة في هذه الآلية، تتشارك مهام التنبؤ والتسعير في الطبقات المخفية الأولى للشبكة (Shared Hidden Layers)، والتي تعمل كمستخرج خصائص جوهرية يقرأ البيانات المالية الكلية للعميل. بعد هذه الطبقات المشتركة، تتفرع الشبكة إلى رؤوس مخرجات محددة : رأس لخرج الاحتمالية (PD) ورأس لخرج التسعير. بما أن احتمالية التعثر والخسارة المتوقعة هما المحددان الأساسيان للتسعير، فإن تمثيل البيانات المشترك يسمح بـ نقل التعلم وتدفق المعلومات بين المهام. الميزات التي يتعلمها النموذج ليكون دقيقاً في التنبؤ بالتعثر، يتم تمريرها فوراً داخل الشبكة لتغذية وحدة التسعير، مما يجعل التسعير مشتقاً عضوياً ومباشراً من المخاطر الفعلية المدروسة، ويحقق مبدأ (Micro–Pricing) الفعال (Zhang & Yang, 2022, p. 5590).

2.3.3.3 المزايا الكامنة والانحياز الاستقرائي كآلية تنظيم هيكلية

تعاني الشبكات العصبية العميقة أحادية المهمة من مشكلة شائعة وخطيرة تُعرف بـ التجهيز الزائد، حيث يقوم النموذج بحفظ الضوضاء والتقلبات العشوائية في بيانات التدريب كأنها قواعد مالية، مما يؤدي لانهياره عند تطبيقه في السوق الفعلي. يعمل التعلم متعدد المهام كآلية تنظيم هيكلية قوية لمواجهة هذه المشكلة. من خلال إجبار الطبقات المشتركة على خدمة مهمتين مختلفتين (التصنيف والانحدار) في آن واحد، يُدخل التعلم متعدد المهام ما يُعرف بـ الانحياز الاستقرائي. لكي يستمر أي وزن أو ارتباط داخل الشبكة بالوجود، يجب أن يكون مفيداً للتنبؤ بالتعثر ومفيداً لتسعير القرض معاً. هذا الشرط المزدوج يجعل من المستحيل على الشبكة حفظ التفاصيل العشوائية، ويدفعها لتعلم الخصائص الأساسية المتينة للمقترضين فقط. النتيجة هي تحسن جذري في القدرة التعميمية للنموذج المالي، مما يجعله أكثر استقراراً، دقة، وموثوقية أمام الصدمات الاقتصادية المستقبلية (Zhang & Yang, 2022, p. 5591)

2.4.1 المبحث الرابع: الذكاء الاصطناعي المفسر في السياق التنظيمي والمالي

يعالج هذا المبحث معضلة "الصندوق الأسود (Black-Box Dilemma)" المرافقة للشبكات العصبية العميقة، متناولاً مخاطر النمذجة والتحيز الخوارزمي وآثارهما على الاستقرار والتهميش المالي. ويربط المبحث بين الضرورة التقنية للتفسير وبين الحتمية التنظيمية الصارمة الصادرة عن لجنة بازل والتشريعات القانونية مثل GDPR وحق الحصول على تفسير (، مستعرضاً المنهجيات الرياضية الرائدة في حقل الذكاء الاصطناعي المفسر (XAI) وتحديداً تقنيتي قيم شابلي (SHAP) و (LIME)لفك تشفير القرارات الائتمانية وإتاحة تدقيقها بشرياً ورقابياً

2.4.1.1 انعدام الشفافية الهيكلية وتفاقم مخاطر النمذجة ((Model Risk

تحقق الشبكات العصبية العميقة والتعلم العميق متعدد المهام دقة تنبؤية فائقة غير مسبوقة في تاريخ النمذجة الائتمانية، لكنها تدفع ضريبة باهظة تُعرف باسم "مشكلة الصندوق الأسود". فنظراً لتعقيد بنيتها الحسابية، وتعدد طبقاتها المخفية، وتفاعل آلاف أو ملايين الأوزان والمعلمات بشكل غير خطي، يُصبح من المستحيل رياضياً للمحلل المالي البشري تتبع المنطق الداخلي الدقيق الذي استندت إليه الخوارزمية لإصدار قرار المنح الائتماني أو تحديد سعر الفائدة. وفي البيئة المصرفية المحافظة، يخلق هذا التعتيم المعرفي نوعاً جديداً وخطيراً من المخاطر يُعرف تنظيمياً بـ "مخاطر النمذجة"؛ فعندما تفتقر لجان الائتمان وإدارة المخاطر إلى الشفافية الهيكلية، تعجز الإدارة العليا عن التحقق من صحة المخرجات منطقياً. والأسوأ من ذلك، أنه في حال وقوع انكماش اقتصادي وتغير سلوك المحفظة الائتمانية بشكل يتعارض مع توقعات الخوارزمية، يعجز البنك عن فهم السبب الكامن وراء الخطأ لإصلاحه؛ نظراً لغياب المعادلات الخطية القابلة للتدقيق البشري (Arrieta et al., 2020, p. 84; Bussmann et al., 2021, p. 206)

2.4.1.2 التحيز الخوارزمي المنهجي (Algorithmic Bias) والتهميش المالي

إن الخوارزميات تتعلم بناءً على البيانات التاريخية لقرارات الائتمان البشرية السابقة. ينشأ التحيز الخوارزمي عندما يستخلص نموذج التعلم العميق أنماطاً تمييزية كامنة في هذه البيانات ويعيد إنتاجها بل وتضخيمها بطريقة آلية. نظراً لقدرة الشبكات العميقة على استكشاف العلاقات غير المباشرة شديدة التعقيد، فقد تتجاوز الحظر القانوني المباشر، وتستخدم متغيرات مالية أو جغرافية أو سلوكية بريئة لتعمل كـ متغيرات بديلة لسمات ديموغرافية محمية قانونياً، كالعرق، الجنس، أو الديانة (ظاهرة تُعرف بـ Redlining). هذا الاعتماد الخفي يؤدي إلى تمييز هيكلي غير مقصود يتمثل في فرض هوامش تسعير فوائد أعلى أو رفض ائتماني منهجي لشرائح مجتمعية معينة أو لقطاعات أعمال محددة دون مبرر مالي حقيقي. من هنا، يبرز التفسير الآلي (XAI) كضرورة حتمية لإجراء التدقيق الخوارزمي لتفكيك المخرجات والتأكد من أن قرار الرفض أو التسعير المرتفع بُني حصرياً على مؤشرات مالية (كالسيولة والرافعة) وليس على تحيزات خفية (Koshiyama et al., 2024, p. 12)

2.4.2 الحتمية التنظيمية والامتثال القانوني في القطاع المصرفي

2.4.2.1 مقررات لجان بازل: التحقق من صحة النماذج وشفافية تقييم المخاطر

يخضع القطاع المصرفي العالمي لإطار تنظيمي بالغ الصرامة يُعنى بحماية أموال المودعين وضمان كفاية رأس المال لمواجهة الصدمات (Basel 3 وما بعدها). وفقاً لمقررات لجنة Basel للرقابة المصرفية (BCBS)، وخاصة المنهج القائم على التقييم الداخلي المتقدم (Advanced IRB)، لا يُسمح بأي حال للمصارف باستخدام أو نشر نماذج ائتمانية لتقدير الـ (PD) والـ (LGD) في تحديد رأس المال التنظيمي ما لم تثبت دقتها وقابليتها للتفسير أمام السلطات الإشرافية (مثل البنوك المركزية). وقد أصدرت اللجنة توجيهات صريحة مؤخراً تؤكد أن الاستعانة بتقنيات الذكاء الاصطناعي الحديثة لا يعفي المصارف من شرط التحقق الشامل من صحة النماذج. يشمل هذا الشرط الجوهري ضرورة إثبات المتانة الإحصائية ، والأهم، ضرورة توفير تفسير منطقي ومقبول اقتصادياً للمحركات والآليات التي استند إليها النموذج في تقييمه. بدون أدوات (XAI) الفعالة، لن تحصل المصارف على موافقة الهيئات الرقابية لاستخدام التعلم

العميق، بل وقد تُفرض عليها عقوبات أو يُطلب منها تجنيب رسملة إضافية كعقوبة على مخاطر النماذج المعتمة (Casu et al., 2022, p. 250; BCBS, 2022, p. 3).

2.4.2.2 التشريعات الحديثة وتأثيرها على التسعير: (GDPR) وحق الحصول على تفسير بشري

إلى جانب المتطلبات الرقابية لحماية كفاية رأس المال، أفرزت التشريعات القانونية الحديثة لحماية المستهلك المالي قيوداً صارمة جداً على قرارات الذكاء الاصطناعي المؤتمتة. ومن أبرز هذه التشريعات عالمياً اللائحة العامة لحماية البيانات (GDPR) في الاتحاد الأوروبي، وتحديداً المادة 22 وميثاقها التوضيحي، الذي أرسى سابقة قانونية تُعرف بـ "الحق في الحصول على تفسير" (Right to Explanation). وتُلزم هذه التشريعات (وما يوازيها في لوائح البنوك المركزية الإقليمية) المؤسسات المالية بتقديم أسباب واضحة ومفهومة ومنطقية للمقترضين عند اتخاذ قرارات حاسمة تؤثر فيهم، كرفض طلباتهم الائتمانية كلياً، أو عند فرض هوامش تسعير مرتفعة عليهم لتعويض المخاطر. فلا يمكن للمصرف أن يرد على العميل المتضرر بأن الخوارزمية هي من قررت ذلك، بل يجب إثبات العوامل المالية التي أدت إلى القرار. إن الفشل في توفير هذه التفسيرات القابلة للفهم يضع المصرف تحت طائلة العقوبات القانونية الباهظة، ومخاطر السمعة، والدعاوى القضائية المناهضة للتمييز؛ مما يجعل تبني أدوات (XAI) مسألة حتمية للامتثال القانوني (Hacker et al., 2020, p. 417)

2.4.3 المنهجيات والتقنيات الرياضية الرائدة في الذكاء الاصطناعي المفسر وفك تشفير النماذج المالية

لحل معضلة الصندوق الأسود، طور علماء البيانات والرياضيات أدوات متقدمة تنتمي لحقل الذكاء الاصطناعي المفسر. يتطلب التحقق من صحة النماذج الائتمانية في المصارف تطبيق مستويين متكاملين وضروريين من التفسير (Bussmann et al., 2021, p. 208):

2.4.3.1. التفسير الشامل مقابل التفسير المحلي

- **التفسير الشامل** : يُعنى بتفكيك السلوك الهيكلي والديناميكية الكلية للنموذج العميق عبر كامل المحفظة الائتمانية وملايين نقاط التدريب. يسعى هذا المستوى للإجابة على تساؤل استراتيجي: ما هي المتغيرات الأكثر أهمية وتأثيراً في تحديد احتمالية التعثر أو تسعير القروض لجميع عملاء المصرف بشكل عام؟. (على سبيل المثال، اكتشاف أن نسبة التدفق النقدي إلى إجمالي الدين هي المحرك المهيمن على قرارات النموذج، تليها صدمات أسعار الفائدة الكلية). هذا التفسير موجه للإدارة العليا، ولجان صياغة السياسات الائتمانية، وللجهات الرقابية لضمان اتساق الخوارزمية مع النظرية الاقتصادية السليمة.
- **التفسير المحلي** : ينزل بالتفسير إلى المستوى الجزئي ليركز على تحليل وفك تشفير القرار الآلي المتخذ تجاه نقطة بيانات واحدة (أي مقترض محدد أو طلب قرض معين). فهو يجيب على تساؤل تشغيلي دقيق ومباشر: لماذا تم تقييم احتمالية تعثر شركة (أ) بالتحديد عند 15%، ولماذا اقترحت الخوارزمية فرض هامش مخاطرة قدره 4% على قرضها؟. هذا المستوى هو المتطلب اليومي الأساسي لضباط الائتمان لتبرير قروضهم أمام لجان المنح، وهو الأداة القانونية للامتثال لمتطلبات حماية العملاء وتوفير أسباب الرفض أو التسعير العالي بشكل إفرادي.

2.4.3.2 قيم SHAP:

تُعد تقنية (SHAP) الثورة الحقيقية والأداة الأكثر دقة ورصانة رياضياً لتوفير تفسيرات شاملة ومحلية متسقة للنماذج المالية المعقدة (Ariza-Garzón et al., 2020, p. 64878).

- **التأصيل النظري من نظرية الألعاب التعاونية:** بدلاً من اختراع رياضيات جديدة، استعارت خوارزمية قيم شابلي مفهوم قيمة Shapley الحائز على جائزة نوبل في الاقتصاد، والذي صاغه عالم الرياضيات (Lloyd Shapley) في نظرية الألعاب التعاونية لحل مشكلة توزيع الأرباح بإنصاف تام بين لاعبين متعددي المهارات تعاونوا في مشروع مشترك. في سياق النمذجة المالية وتسعير القروض، يتم إجراء محاكاة رياضية ذكية: يُعتبر اللاعبون في اللعبة التعاونية هم مجموعة

المؤشرات المالية والاقتصادية الخاصة بالعميل (المدخلات أو الخصائص كنسبة السيولة، الربحية، الرافعة)، والربح أو الناتج الذي حققوه معاً هو المخرج النهائي للنموذج (كأن يكون التنبؤ باحتمالية تعثر قدرها 8%، أو اقتراح علاوة مخاطر قدرها 300 نقطة أساس – 3%).

- **حساب المساهمة الهامشية:** تقوم خوارزمية قيم شابلي بعملية حسابية عبر قياس الأثر الدقيق والمستقل لكل متغير مالي من خلال حساب التغير الحاصل في مخرجات النموذج عند إدخال هذا المتغير المحدد مقارنةً بقيمة النموذج التنبؤية في حال غيابه، وذلك من خلال حساب كافة التوليفات والمجاميع الممكنة لباقي المتغيرات الأخرى لتفادي تداخل التأثيرات المشتركة.

- **التطبيق في تسعير الائتمان:** تضمن هذه الآلية الرياضية خاصية الإضافة. أي أنها توزع قرار النموذج النهائي كأجزاء دقيقة. فإذا كانت علاوة المخاطر المقترحة للقرض هي +3%، فإن تقرير قيم شابلي سيوضح للإدارة أن: (الرافعة المالية العالية ساهمت بـ +1.5%، انخفاض تدفقات النقد ساهم بـ +2.0%، بينما الجودة العالية للضمانات خفضت الخطر بمقدار −0.5%). هذا التفكيك يحول قرار الذكاء الاصطناعي الغامض إلى فاتورة تفصيلية للتسعير قابلة للقراءة والتدقيق البشري، مما يوفر تسعيراً شفافاً، عادلاً، وقابلاً للتبرير قانونياً (Bussmann et al., 2021, p. 210).

2.4.3.3 التفسيرات المحلية المستقلة عن النموذج (LIME): التقريب الخطي في الجوار المحلي

في حين تمثل SHAP قمة الدقة الرياضية، إلا أنها تتطلب قدرة حاسوبية ووقت تنفيذ كبيرين. هنا تبرز تقنية LIME كمنهجية بالغة الفعالية وعالية السرعة لتقديم تفسيرات محلية وقتية. تستند الفكرة الرياضية لـ LIME إلى مبدأ هندسي مفاده أن الشبكات العصبية العميقة، مهما بلغت درجة تعقيدها على المستوى الشامل، إلا أنها تتصرف كدالة مستقرة وشبه خطية في الجوار المحلي الضيق جداً لنقطة بيانات واحدة محددة (Gunnarsson et al., 2021, p. 300).

- **آلية العمل التقنية:** عندما يصدر النموذج العميق قراراً معقداً بشأن مقترض معين، تقوم خوارزمية LIME بضخ اضطراب رياضي مقصود. حيث تولّد آلاف العينات من البيانات الوهمية التي تشبه إلى حد كبير الخصائص المالية لهذا المقترض، ثم تمرر هذه العينات عبر نموذج التعلم العميق لتسجيل كيف يستجيب القرار وتتغير المخرجات. بناءً على هذه الملاحظات، تقوم LIME ببناء نموذج بديل عبارة عن انحدار خطي مبسط داخل هذا النطاق الضيق فقط المحيط بالعميل. هذا النموذج يمتلك قدرة تامة على تفسير القرار الائتماني الموضعي بوضوح تام بلغة المعاملات الخطية والأوزان البسيطة، موضحاً المتغيرات المباشرة والحرجة التي أجبرت النموذج العميق لاتخاذ قراره النهائي، مما يسهل سيرورة العمليات المصرفية اليومية دون المساس بدقة النموذج الأصلي (Gunnarsson et al., 2021, p. 300).

الفصل الثالث:

الإطار العملي

1-3 تمهيد

لضمان كفاءة معمارية التعلم العميق متعدد المهام (MTDL) وقدرتها على التنبؤ المتزامن بالتعثر المالي وتسعير القروض، تطلبت الدراسة تجميع بيانات من مصادر متعددة لدمج الإفصاحات المحاسبية مع بيانات السوق والاقتصاد الكلي. يستعرض هذا الفصل الخطوات المنهجية المتبعة في جمع، تنظيف، وهندسة البيانات، وصولاً إلى اختيار الخصائص النهائية للنموذج، ثم تصميم المعمارية العصبية وبروتوكول التدريب والاختبار، وأخيراً تفكيك مخرجات النموذج عبر تقنية قيم شابلي (SHAP) لاستخلاص المعادلات الوكيلة القابلة للتفسير المالي.

يُمثِّل هذا الفصل الجانب التطبيقي للدراسة، وفيه يُوثَّق كامل المسار المنهجي المتبع لتصميم وتدريب واختبار نموذج التعلم العميق متعدد المهام (MTDL) المُقترح. ويُلاحظ القارئ أن الباحث قد اعتمد لغة بايثون (Python) بيئةً عمل أساسية لتجاوز قيود الحزم الإحصائية الجاهزة كـ SPSS، نظراً لطبيعة البيانات الضخمة (401,592 مشاهدة) ولتعدد المهام المطلوب إنجازها بشكل متزامن. وقد تم تقسيم هذا الفصل إلى خمسة عشر قسماً فرعياً تغطي: تصميم العينة وجمع البيانات، بناء المتغيرات التابعة، التوصيف الإحصائي، معالجة القيم المتطرفة، التوزيع القطاعي، مصفوفة الارتباط ومعالجة التعددية الخطية، هندسة الخصائص، تصميم المعمارية، دالة الخسارة المركَّبة، البحث الشبكي، بروتوكول التدريب، اختبار النموذج، والتفسير بـ SHAP.

2-3 تصميم العينة وجمع البيانات

1-2-3 تصميم العينة

اعتمدت الدراسة على بيانات مقطعية زمنية شملت أكثر من 7,960 شركة مساهمة عامة في السوق الأمريكي، تغطي الفترة الممتدة من عام 2009 وحتى الربع الأول من عام 2026. لتجنب انحياز البقاء (Survivorship Bias) على السلاسل الزمنية غير المتوازنة، شملت العينة الشركات النشطة، والشركات التي أفلست، وتلك التي اندمجت أو شُطبت من السوق خلال فترة الدراسة. وقد أُجري تتبع البيانات الربع سنوية والسنوية لكل شركة استناداً إلى معرّفاتها الرسمية (CIK - Central Index Key) الصادرة عن هيئة الأوراق المالية والبورصات الأمريكية (SEC)، ما أسفر عن قاعدة بيانات ضخمة بإجمالي 401,592 مشاهدة (Observation) بعد إزالة القيم المفقودة المتسلسلة.

2-2-3 جمع البيانات

تم الاعتماد في جمع البيانات على ثلاثة مصادر رئيسية متكاملة لضمان شمولية المُدخلات الكمية والاقتصادية الكلية:

1. **البيانات المحاسبية وقوائم المركز المالي:** سُحبت باستخدام بروتوكول (XBRL) عبر منصة (SEC EDGAR) الرسمية، وشملت القوائم المالية السنوية (نموذج K-10) والربع سنوية (نموذج Q-10) لجميع الشركات المُدرجة. وتم استخراج بنود الأصول، الخصوم، حقوق المساهمين، الإيرادات، التدفقات النقدية التشغيلية، وأعباء الفوائد، لاحتساب النسب المالية الأساسية (السيولة، الربحية، الرفع، الكفاءة).
2. **بيانات السوق ومؤشرات التقلب:** تم الاعتماد على منصة (Yahoo Finance) للحصول على بيانات مؤشر التقلب (VIX) الصادر عن Chicago Board Options Exchange، والذي يُعد مقياساً لتوقعات السوق بشأن التقلبات على مدى 30 يوماً.
3. **متغيرات الاقتصاد الكلي:** سُحبت من خوادم الاحتياطي الفيدرالي (FRED API)، وشملت معدل التضخم، سعر الفائدة الفيدرالية (Fed Funds Rate)، عائد سندات الخزانة لأجل 3 أشهر (T3M) و10 سنوات (T10Y)، وفارق منحنى العائد (Term Spread: T10Y - T3M) كمؤشر إنذار مبكر للركود.

3-2-3 الأدوات البرمجية المستخدمة

لتنفيذ المعالجات الإحصائية والرياضية المعقدة التي تتجاوز قدرات الحزم الإحصائية التقليدية الجاهزة (مثل SPSS)، اعتمدت الدراسة على لغة (Python) كبيئة عمل أساسية. واستُخدمت حزم (Pandas) و (NumPy) للقيام بالعمليات الرياضية لحساب المتغيرات، وتم استدعاء مكتبات متخصصة للربط المباشر مع خوادم البيانات الرسمية (مثل yfinance و fredapi)، مما أتاح دمج متغيرات الاقتصاد الكلي وبيانات هيكل السوق.

أما في مرحلة النمذجة الإحصائية، فقد استُخدمت مكتبة (PyTorch) لبناء وتدريب معمارية التعلم العميق متعدد المهام (MTDL)، وذلك لمعالجة التصنيف والتسعير بشكل متزامن. وقد دُعمت هذه المرحلة بمكتبة (Scikit-Learn) التي تولت المهام الإحصائية التمهيدية كتوحيد المقاييس (Standardization)، وتصفية التعددية الخطية، بالإضافة إلى حساب مقاييس الأداء التنبؤي المتمثلة بالمساحة تحت المنحنى (ROC-AUC) وجذر متوسط مربع الخطأ (RMSE).

وأخيراً، تم الاعتماد على حزمة الذكاء الاصطناعي المفسر (SHAP). وقد سمحت هذه التقنية، المستندة إلى مفاهيم نظرية الألعاب، بتفكيك قرارات النموذج واستخلاص الأوزان الحدية لكل متغير مالي؛ مما مكّن الدراسة من تحويل التعقيد الخوارزمي إلى معادلة رياضية مبسطة قابلة للفهم والتطبيق المباشر.

3-3 بناء المتغيرات التابعة

بُنيت معمارية (MTDL) للتنبؤ بمتغيرين تابعين بشكل متزامن، يُمثِّل الأول منهما مسار التصنيف (التعثر المالي)، ويُمثِّل الثاني مسار الانحدار (تكلفة الدين وعلاوة المخاطرة). وفيما يلي تفصيل منهجية بناء كل منهما:

3-3-1 احتمالية التعثر المالي (Y1)

تم استخراج حالات الإفلاس القانوني (Chapter 7 & 11) عبر مسح إفصاحات (8-K, Item 1.03) من سجلات SEC. وبهدف جعل النموذج أداة تنبؤ وليس تشخيصاً للحالة فقط، طُبقت خوارزمية نافذة التطلع المستقبلي (Look-Ahead Window)؛ حيث تم وسم الشركة كمتعثرة (1) في سنة إعلان الإفلاس وللسنوات الثلاث التي تسبقها. هذه المنهجية تضمن أن النموذج يتعلم التعرف على الإنذارات المبكرة للتعثر قبل وقوعه فعلياً، وليس مجرد حفظ تاريخ الإفلاس بعد وقوعه، وهو ما يُحسِّن قيمته التطبيقية في القرارات الائتمانية الاستباقية.

3-3-2 تكلفة الدين وعلاوة المخاطرة (Y2)

استُخدمت التكلفة الضمنية لتكلفة الدين، وتُحسب بقسمة مصروف الفائدة على إجمالي الديون لكل شركة في كل ربع مالي. هذا التعريف يُعكس التكلفة الفعلية التي تتحملها الشركة على اقتراضها، ولا يعتمد على سعر الفائدة التعاقدي الاسمي، مما يجعله مقياساً أكثر دقة للمخاطر التي يُقيّمها السوق الفعلي للشركة. وتم تحويل الأرقام المجمعة إلى 25 نسبة مالية تغطي أبعاد (السيولة، الربحية، النشاط، والرفع المالي)، لتعزيز القدرة التنبؤية للنموذج.

4-3 المتغيرات المستقلة والتابعة

اعتمد النموذج على مجموعة شاملة من المتغيرات تتكون من 22 متغيراً مستقلاً (تغطي النسب المالية ومؤشرات الاقتصاد الكلي ومؤشرات السوق) ومتغيرين تابعين يمثلان مهام التعلم متعدد المهام (التصنيف والتسعير). ويُوضح الجدول الآتي هيكل هذه المتغيرات مع رموزها وأنواعها المحاسبية والاقتصادية:

جدول (1): هيكل المتغيرات المستقلة والتابعة في نموذج MTDL

التصنيف الإحصائي	النوع المحاسبي/الاقتصادي	رمز المتغير	اسم المتغير
مستقل - كلي	سوق الدين الحكومي	T10Y	10-Year Treasury Yield
مستقل - كلي	سوق النقد القصير	T3M	3-Month Treasury Yield
مستقل - كلي	مؤشر توقعات الركود	Term_Spread	Yield Curve Term Spread
مستقل - جزئي	نسب السيولة	Ratio_Current	Current Ratio
مستقل - جزئي	نسب السيولة السريعة	Ratio_Quick	Quick Ratio
مستقل - جزئي	السيولة التشغيلية الكاش	Ratio_CFO_CurrentLiab	CFO to Current Liabilities
مستقل - جزئي	نسبة الربحية	Ratio_ROA	Return on Assets (ROA)
مستقل - جزئي	نسبة الربحية	Ratio_ROE	Return on Equity (ROE)
مستقل - جزئي	الكفاءة التشغيلية	Ratio_Op_Margin	Operating Margin Ratio
مستقل - جزئي	كفاءة استغلال رأس المال	Ratio_ROCE	Return on Capital Employed
مستقل - جزئي	نسبة الرفع المالي المباشر	Ratio_Debt_to_Assets	Debt to Assets Ratio
مستقل - جزئي	مخاطر الهيكل التمويلي	Ratio_Debt_to_Equity	Debt to Equity Ratio
مستقل - جزئي	مضاعف رأس المال والرفع المالي	Ratio_Equity_Multiplier	Equity Multiplier Ratio
مستقل - جزئي	معدلات النشاط والدوران	Ratio_Asset_Turnover	Asset Turnover Ratio
مستقل - جزئي	معدلات النشاط والدوران	Ratio_Receivables_Turnover	Receivables Turnover Ratio
مستقل - جزئي	معدلات النشاط والدوران	Ratio_Inventory_Turnover	Inventory Turnover Ratio
مستقل - جزئي	معدلات النشاط والدوران	Ratio_Fixed_Asset_Turnover	Fixed Asset Turnover
مستقل - جزئي	معدلات النشاط والدوران	Ratio_Working_Capital_Turnover	Working Capital Turnover
مستقل - سوقي	مؤشر الخوف والتقلب	VIX_Avg	Average VIX Index

التصنيف الإحصائي	النوع المحاسبي/الاقتصادي	رمز المتغير	اسم المتغير
مستقل - سوقي	مخاطر التقلبات الحادة	VIX_High	Peak VIX Index
مستقل - كلي	السياسة النقدية	Fed_Funds_Rate	Federal Funds Rate
مستقل - كلي	الاستقرار السعري والاقتصادي	Inflation_Rate	Inflation Rate (CPI)
تابع - تصنيف	توقع التعثر المالي	Y1_Target	Bankruptcy Probability (0/1)
تابع - انحدار	تسعير الدين	Y2_Cost_of_Debt	Implied Cost of Debt (CoD)

المصدر: من إعداد الباحث بالاعتماد على الإطار النظري ومصادر البيانات

5-3 التوصيف الإحصائي للمتغيرات

نظراً لطبيعة البيانات الضخمة ومحدودية القدرة في استعمال البرامج الإحصائية الجاهزة مثل SPSS، تم الاعتماد في عمل التحليل الوصفي على مكتبة statsmodels في بايثون. وقد كانت النتائج كما هو موضح في الجدول الإحصائي الآتي، الذي يعرض لكل متغير: عدد المشاهدات (N)، المتوسط الحسابي (Mean)، الانحراف المعياري (Std Dev)، الحد الأدنى (Min)، الحد الأقصى (Max)، الالتواء (Skewness)، والتفرطح (Kurtosis).

جدول (2): التوصيف الإحصائي للمتغيرات الكلية والمحاسبية في عينة الدراسة

المتغير	العدد (N)	المتوسط	الانحراف المعياري	الأدنى	الأقصى	الالتواء	التفرطح
Y2_Cost_of_Debt	401,592	0.0541	0.0938	0.0000	1.0000	5.7001	39.0033
ICR	401,592	1.1702	95.8687	-611.66	509.83	-1.2849	26.2955
Ratio_Current	401,592	2.4016	2.2540	0.0081	16.0936	3.7387	17.6206
Ratio_Quick	401,592	1.3637	2.0526	0.0060	15.3050	4.7718	26.0866
Ratio_CFO_CurrentLiab	401,592	0.0141	0.5783	-2.8634	1.9420	-1.3579	9.0934
Ratio_ROA	401,592	-0.0596	0.5263	-4.1986	1.0967	-6.0827	43.1497
Ratio_ROE	401,592	0.0432	0.4787	-2.4938	2.7478	0.4129	19.5638

المتغير	العدد (N)	المتوسط	الانحراف المعياري	الأدنى	الأقصى	الالتواء	التفرطح
Ratio_Op_Margin	401,592	-1.8943	11.6534	-100.86	0.7190	-7.4696	57.3633
Ratio_ROCE	401,592	0.0261	0.2543	-1.3131	1.3665	-0.1079	16.9587
Ratio_Debt_to_Assets	401,592	1.0070	4.2070	0.0000	37.5472	7.7567	61.5297
Ratio_Debt_to_Equity	401,592	1.6886	2.1277	0.0000	14.2356	3.6673	16.4385
Ratio_Equity_Multiplier	401,592	3.8127	5.9471	0.6521	82.5483	8.4149	98.4136
Ratio_Asset_Turnover	401,592	0.8273	0.6721	0.0000	5.1342	2.0443	7.3195
Fed_Funds_Rate	69	0.0203	0.0175	0.0001	0.0533	1.2122	0.5145
VIX	69	18.4521	7.2075	11.0400	65.5400	1.8345	4.2738
Term_Spread	69	-0.0423	1.6539	-1.6702	3.6111	-0.1468	-1.5422

المصدر: من إعداد الباحث بالاعتماد على مخرجات مكتبة statsmodels في لغة Python

يتضح من الجدول الإحصائي الوصفي أعلاه أن غالبية النسب المحاسبية والتشغيلية (السيولة، الدوران، الرفع المالي) تتشارك نمطاً إحصائياً متماثلاً حيث يوجد التواء موجب حاد (تراوح غالباً بين 3 و 8) وتفرطح مرتفع يفوق بأضعاف القيمة المرجعية للتوزيع الطبيعي (3)، إذ تجاوز في بعض المتغيرات كنسبة الدين إلى الأصول ومعدلات الدوران حاجز 40-60. يعكس هذا النمط تركز الغالبية العظمى من الشركات حول قيم معتدلة مقابل شريحة صغيرة ذات أداء متطرف.

في المقابل، أظهرت مؤشرات الربحية (ROA، هامش التشغيل) متوسطات سالبة أو قريبة من الصفر مصحوبة بالتواء سالب حاد، بما يعكس تأثير الشركات الخاسرة أو المتعثرة داخل العينة على التوزيع العام. أما المتغيرات الكلية (T10Y، T3M، Term Spread، VIX، Fed Funds Rate، التضخم)، فتظهر توزيعات أقرب للاعتدال النسبي، وهو أمر متوقع لكونها مؤشرات سوقية وسياسية تتغير تدريجياً عبر الزمن دون التشتت الحاد الذي تُظهره النسب المحاسبية على مستوى الشركة الواحدة.

3-6 معالجة القيم المتطرفة (Winsorization)

عند اقتراب الشركات من الإفلاس، تظهر قيم متطرفة (Outliers)؛ كأن ينتج رقم كبير جداً للعائد على حقوق الملكية بسبب قسمة الأرباح على ملكية شبه معدومة. للتعامل مع هذه المشكلة، اعتمدت الدراسة تقنية التخميد (Winsorization) للنسب المحاسبية عند المستويين المئويين 1% و 99%. تعمل هذه التقنية على وضع حدود عليا ودنيا للبيانات، مما يقلل الأخطاء الرياضية مع الاحتفاظ بالواقع الاقتصادي لتدهور الشركة.

وقد استُثنيت متغيرات الاقتصاد الكلي كالتضخم ومعدل الفائدة ومؤشر التقلب (VIX) من هذه العملية؛ إذ إن القفزات الحادة في هذه المؤشرات تمثل صدمات حقيقية تعكس الأزمات العالمية، ومن الضروري بقاؤها ليتعلم النموذج كيفية استجابة الشركات للضغوط الاقتصادية الحقيقية. هذا التمييز منهجي الأهمية، لأن تطبيق Winsorization على متغيرات الاقتصاد الكلي سيُؤدي إلى طمس إشارات الأزمات التي يُفترض بالنموذج التقاطها والتعلم منها.

3-7 هيكل عينة الدراسة والتوزيع القطاعي

بلغ إجمالي عدد الشركات المتعثرة (التي أعلنت إفلاسها وفقاً للفصلين السابع أو الحادي عشر، أو استوفت شروط التعثر الفني) خلال فترة الدراسة 546 شركة متعثرة. وبذلك، يبلغ معدل التعثر العام في العينة 6.86%. ويُوضح الجدول الآتي التوزيع الإحصائي لشركات العينة على القطاعات الاقتصادية الكبرى، مع بيان حجم كل قطاع وعدد حالات التعثر ومعدلاتها الداخلية:

جدول (3): التوزيع القطاعي لعينة الدراسة ومعدلات التعثر الداخلية

القطاع الاقتصادي	عدد الشركات	النسبة %	الشركات المتعثرة	معدل التعثر %
التصنيع (Manufacturing)	3,403	42.75%	202	5.94%
الخدمات (Services)	1,930	24.25%	92	4.77%
النقل والاتصالات والكهرباء والغاز	647	8.13%	53	8.19%
التعدين (Mining)	553	6.95%	98	17.72%
تجارة التجزئة (Retail Trade)	527	6.62%	61	11.57%
التمويل والتأمين والعقارات	493	6.19%	14	2.84%
تجارة الجملة (Wholesale Trade)	267	3.35%	20	7.49%
البناء (Construction)	71	0.89%	3	4.23%
الزراعة والغابات وصيد الأسماك	64	0.80%	2	3.12%
الإدارة العامة (Public Administration)	3	0.04%	1	33.33%
غير مصنف (Unknown)	2	0.03%	0	0.00%
المجموع	7,960	100%	546	6.86%

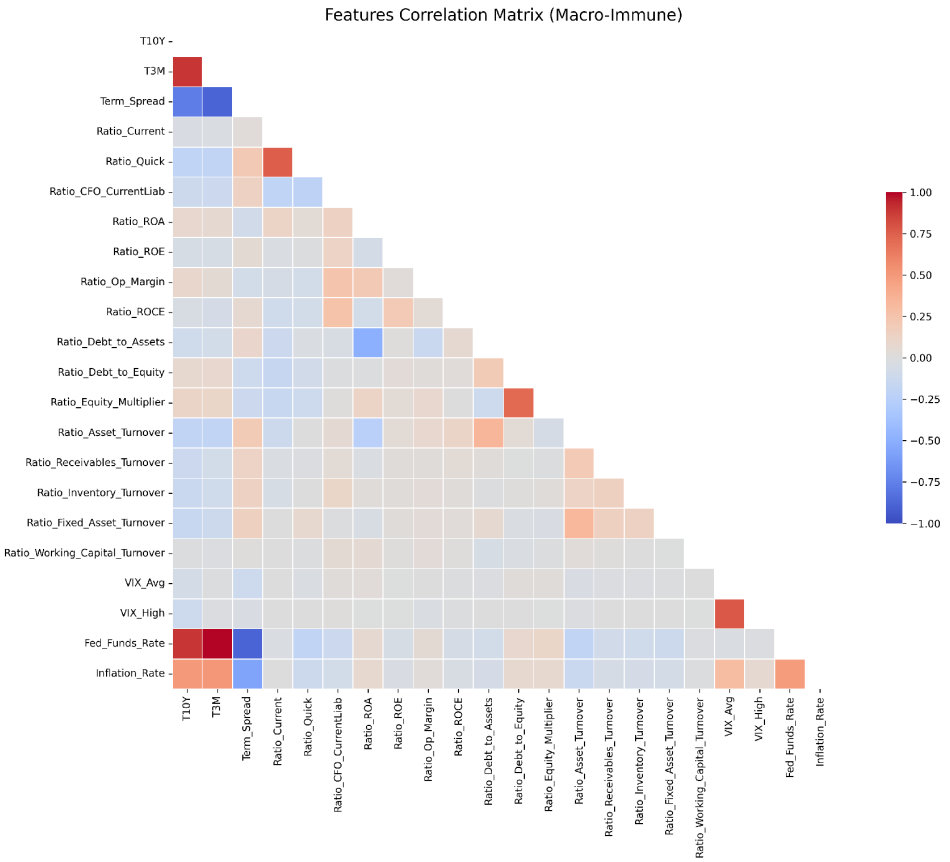
المصدر: من إعداد الباحث بالاعتماد على بيانات SEC EDGAR وتصنيف SIC

أظهر الجدول السابق تركزاً ملحوظاً في قطاعات محددة، مما يعكس البنية الحقيقية للسوق المالية الأمريكية. احتل قطاع التصنيع المرتبة الأولى مستحوذاً على الحصة الأكبر (42.75% من إجمالي العينة) ومعدل تعثر داخلي بلغ 5.94%، يليه قطاع الخدمات في المرتبة الثانية (24.25%) مسجلاً معدل (4.77%)، وذلك لانخفاض الاعتماد على الأصول الملموسة والرفع المالي العالي مقارنة بالقطاعات الصناعية.ومن اللافت للنظر عند تحليل بيانات الجدول، ظهور تركز للمخاطر في قطاعات محددة رغم صغر حجمها النسبي. فقد سجل قطاع التعدين أعلى معدل تعثر بنسبة 17.72%، وهو ما يعكس الحساسية العالية لهذا القطاع لتقلبات أسعار السلع الأساسية ودورات الاقتصاد الكلي. تبعه قطاع تجارة التجزئة بمعدل

تعثر بلغ 11.57%، وهو ما يمكن تفسيره بتأثر هذا القطاع المباشر بالتغيرات في سلوك المستهلكين والمنافسة الشديدة. في المقابل، أظهر قطاع التمويل والتأمين والعقارات أدنى معدلات التعثر بنسبة 2.84%، وهو ما يتماشى مع الطبيعة شديدة التنظيم لهذا القطاع وخضوعه لمتطلبات رأس مال صارمة.

3-8 مصفوفة الارتباط ومعالجة التعددية الخطية

لتجنب تشـوه نتائج النموذج الناتج عن التعددية الخطية العالية (Multicollinearity)، تم حسـاب مصفوفة ارتباط بيرسون (Pearson Correlation Matrix) بين جميع المتغيرات المستقلة المتاحة، وقد تم تصـفية جميع المتغيرات التي تزيد درجة ارتباطها عن 80%. ويوضـح الشـكل الآتي خريطة الارتباط الحرارية للمتغيرات المستقلة المتبقية بعد التصفية:



شكل (1): خريطة مصفوفة الارتباط الحرارية (Pearson Heatmap) للمتغيرات المستقلة المتبقية

المصدر: من إعداد الباحث بالاعتماد على مخرجات مكتبة seaborn في بيئة Python

تم عزل وحذف المتغيرات التي تزيد ارتباطها البيني عن 80%، مع الاحتفاظ بالمتغير الأكثر ارتباطاً مع الهدف (Y1_Target). شملت المتغيرات المحذوفة متغير النقدية (Ratio_Cash) بسبب ارتباطه المرتفع جداً بالسيولة السريعة (Ratio_Quick)، ومتغير صافي هامش الربح (Ratio_Net_Margin) لارتباطه بهامش الربح التشغيلي (Ratio_Op_Margin). كما تم حذف متغيرات T10Y (عائد سندات الخزانة لـ 10 سنوات) و T3M (العائد على سندات الخزانة لـ 3 أشهر) و Term_Spread، وذلك لارتباطهم الشديد مع Fed_Funds_Rate بنسبة تفوق العتبة المقررة.

هذه التصفية ضرورية لتجنب تشتت أوزان النموذج وتشويه التفسيرات اللاحقة في تحليل SHAP. فالمتغيرات شديدة الارتباط تحمل المعلومة نفسها، وإبقاؤها جميعاً يُربك خوارزمية التدريب ويُوزِّع الأوزان بينها بشكل غير مستقر، مما يُصعِّب لاحقاً استخلاص المعادلات الوكيلة الواضحة. أما بعد التصفية، فأصبح كل متغير في المجموعة النهائية يحمل إشارة معلوماتية مستقلة وفريدة، مما يُسهِّل تفسير مساهمته الحدية في القرار النهائي للنموذج.

3-9 معالجة البيانات وهندسة الخصائص

بعد إتمام خطوات التصفية السابقة، خضعت البيانات لسلسلة من المعالجات المنهجية الإضافية لضمان جاهزيتها للتدريب. وقد اتبع الباحث بروتوكول معالجة منهجي مكوَّن من خمس خطوات متسلسلة:

3-9-1 توحيد اتجاه المتغيرات (Directional Alignment)

بما أن بعض النسب المالية تُحسَب رياضياً بقسمة الخصوم على الأصول (كما في نسبة الدين إلى الأصول Debt-to-Assets)، فقد ظهرت في البيانات الخام قيم سالبة نتيجة خطأ في الإشارة أو في تسجيل البيانات. تم توحيد اتجاه هذه المتغيرات بأخذ القيمة المطلقة (Absolute Value) للمتغيرات

الأربعة الآتية: Ratio_Debt_to_Equity، Ratio_Debt_to_Assets، Ratio_Asset_Turnover، Ratio_Equity_Multiplier، بحيث تعكس جميعها دلالة موجبة متسقة من حيث المخاطرة.

3-9-2 معالجة التسريب المعلوماتي (Data Leakage Prevention)

يُعتبَر التسريب المعلوماتي من أخطر الأخطاء المنهجية في النمذجة الائتمانية، ويحدث عندما يحتوي نموذج التنبؤ على متغيرات لا تتوفر فعلياً في لحظة اتخاذ قرار الإقراض، لكنها تُكشَف لاحقاً كنتيجة للتعثر. لقد تم تحديد وإقصاء خمسة متغيرات تنطوي على خطر التسريب المعلوماتي من مجموعة الخصائص المُدخلة، وهي: StockholdersEquity، Equity_Final، Interest_Coverage، ICR، InterestExpense_Abs. هذه المتغيرات على الرغم من ارتباطها النظري بالتعثر، إلا أنها تُحتسَب لاحقاً من بيانات السنة المالية التي قد تشهد التعثر نفسه، مما يُضخِّم دقة النموذج زائفاً عند الاختبار ويفشل عند التطبيق الفعلي.

3-9-3 معالجة القيم المفقودة (Missing Values Imputation)

نظراً لطبيعة البيانات المالية المتتابعة لبعض الشركات، ولوجود فترات انتقالية كادخول شركة جديدة للإدراج أو تأخر تقديم الإفصاحات، ظهرت قيم مفقودة (NaN) في بعض المشاهدات. تم اعتماد سياسة الحشو بالوسيط (Median Imputation) لكل خاصية على حدة، وهي طريقة أكثر متانة إحصائياً من الحشو بالمتوسط لأنها لا تتأثر بالقيم المتطرفة. أما بالنسبة لمتغير التعثر (Y1_Target)، فقد تم استبدال القيم المفقودة بالصفر، بافتراض أن الشركة التي لم يُسجَّل لها حدث تعثر هي شركة سليمة افتراضياً وفقاً لقاعدة الامتثال التنظيمي.

3-9-4 التقسيم الزمني (Temporal Splitting)

لضمان اختبار النموذج على بيانات مستقبلية حقيقية لم يرها مسبقاً أثناء التدريب، تم اعتماد التقسيم الزمني (Temporal Splitting) بدلاً من التقسيم العشوائي التقليدي. تم تقسيم البيانات وفق الآتي:

- **مجموعة التدريب (Training Set)**: شملت المشاهدات من عام 2009 وحتى عام 2022، وتُمثِّل 78% من إجمالي البيانات. هذه الفترة تغطي دورات أعمال مختلفة بما فيها أزمة كورونا وموجات التضخم، مما يُعزِّز المتانة الإحصائية للنموذج.
- **الفجوة الزمنية (Gap Year – 2023)**: تم استبعاد بيانات عام 2023 بالكامل من التدريب والاختبار، وذلك بهدف منع التداخل الزمني بين فترة التدريب وفترة الاختبار، وهو ما يُعرف بمنع تسريب المعلومات من المستقبل إلى الماضي.
- **مجموعة الاختبار (Out-of-Time Test Set)**: شملت المشاهدات من عام 2024 وحتى الربع الأول من عام 2026، وتُمثِّل 22% من البيانات. هذا التقسيم يضمن أن نتائج الاختبار تعكس قدرة النموذج على التعميم على بيانات مستقبلية حقيقية لم يرها أبداً.

3-9-5 تقييس المتغيرات (Feature Standardization)

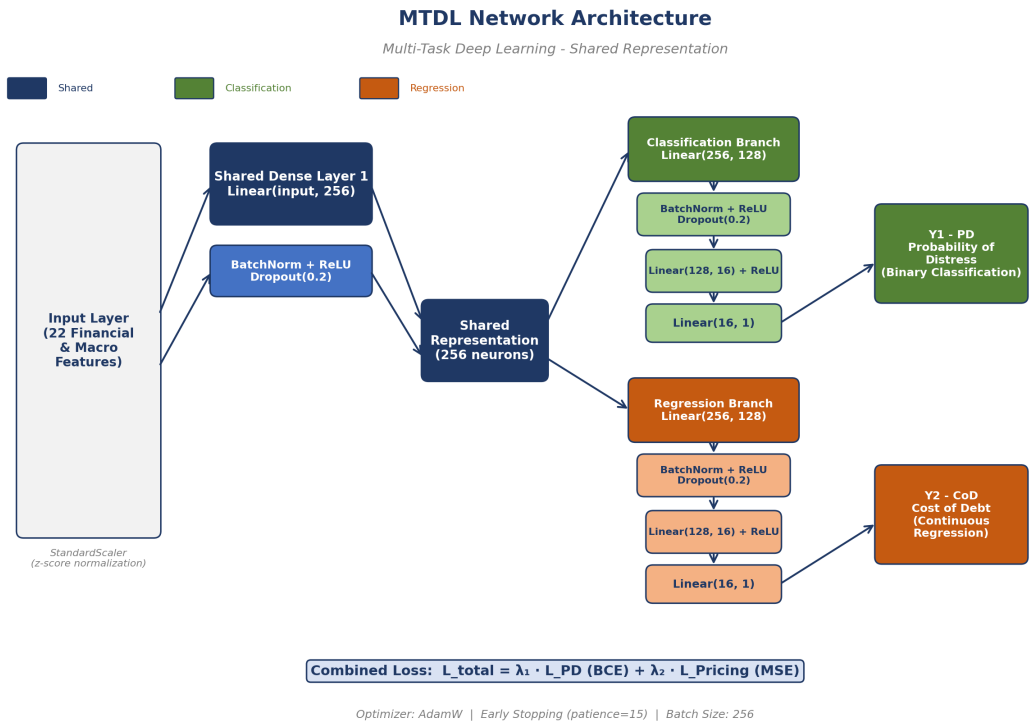
نظراً لتباين المقاييس بين المتغيرات المالية (فبعضها نسب مئوية كالـ ROA، وبعضها مضاعفات كـ Equity Multiplier)، تم تطبيق التقييس القياسي (Z-score Standardization) على المُدخلات باستخدام معادلة التحويل الآتية:

$$x_scaled = (x - \mu) / \sigma$$

حيث يمثل μ الانحراف المتوسط للمتغير في مجموعة التدريب فقط (لتجنب تسريب معلومات الاختبار)، ويمثل σ الانحراف المعياري. تم تطبيق نفس المعاملات (μ, σ) المُستخرَجة من بيانات التدريب على بيانات الاختبار لضمان الاتساق. وبالنسبة لمتغير التسعير (Y2_Cost_of_Debt)، تم تطبيق تقييس منفصل باستخدام كائن StandardScaler مستقل، وذلك لتمكين التحويل العكسي لاحقاً عند احتساب مقاييس الأداء بالوحدات الأصلية (نسبة فائدة فعلية).

3-10 تصميم معمارية شبكة MTDL

يقوم نموذج التعلم العميق متعدد المهام (Multi-Task Deep Learning – MTDL) على معمارية شبكة عصبية أمامية (Feed-Forward Neural Network) ذات طبقات مشتركة (Shared Layers) تقوم بتمثيل الخصائص الإدخالية وتمريرها إلى رأسين متخصصين (Task-specific Heads). الأول رأس تصنيف ثنائي (Classification Head) يتنبأ باحتمالية التعثر المالي (PD)، والثاني رأس انحدار (Regression Head) يتنبأ بتكلفة الدين الضمنية (CoD). ويُوضح الشكل الآتي المخطط التخطيطي للمعمارية المُصمَّمة:



شكل (2): المخطط التخطيطي لمعمارية الشبكة العصبية متعددة المهام MTDL

يُلاحَظ من الشكل أن المعمارية تعتمد على نمط "التفرع المبكر" (Early Branching)، حيث تتشارك المهام في طبقة كثيفة واحدة (Shared Dense Layer) بحجم 256 عصبوناً، ثم تتفرع إلى مسارين منفصلين، كل مسار يحتوي على طبقة كثيفة متخصصة بحجم 128 عصبوناً، تليها طبقة ضيقة بحجم 16 عصبوناً تعمل كطبقة تمثيل متخصص، ثم طبقة إخراج أحادية العصبون. هذا التصميم يُوازن بين نقل التعلم عبر الطبقة المشتركة والتخصص عبر الرؤوس، وهو ما يدعم الانحياز الاستقرائي المُناقَش في الفصل الثاني.

وتتضمن كل طبقة كثيفة تسلسلاً موحداً من العمليات الرياضية: التحويل التآلفي الخطي (Linear Transformation)، يليه تطبيع الدفعة (Batch Normalization) لتحقيق استقرار التدريب، ثم دالة التنشيط غير الخطية ReLU (Rectified Linear Unit) لإدخال اللاخطية، وأخيراً طبقة الإسقاط (Dropout) بنسبة 20% لمنع فرط التخصيص. ويُوضح الجدول الآتي ملخصاً تفصيلياً للطبقات وأبعادها:

جدول (4): ملخص معمارية الشبكة العصبية متعددة المهام MTDL

الطبقة	نوع الطبقة	العمليات الرياضية	عدد العصبونات
1	المدخلات (Input)	شعاع الخصائص المُقيَّسة	22
2	مشتركة (Shared Dense)	Linear + BatchNorm + ReLU + Dropout(0.2)	256
3-أ	رأس التصنيف (Classification)	Linear + BatchNorm + ReLU + Dropout(0.2)	128
4-أ	تصنيف متخصص	Linear + ReLU	16
5-أ	مخرج التصنيف Y1	Linear + Sigmoid (احتمالية PD)	1
3-ب	رأس الانحدار (Regression)	Linear + BatchNorm + ReLU + Dropout(0.2)	128
4-ب	انحدار متخصص	Linear + ReLU	16
5-ب	مخرج الانحدار Y2	Linear (تكلفة الدين CoD)	1

المصدر: من إعداد الباحث بالاعتماد على مكتبة PyTorch

3-10-1 مبررات اختيار المعمارية

جاء اختيار معمارية التفرع المبكر (256 → 128) بناءً على ثلاثة مبررات منهجية:

أولاً، الحفاظ على طبقة مشتركة واحدة فقط يُقلِّل من خطر تسريب المعلومات بين المهمتين، حيث أن المشاركة العميقة جداً قد تُجبِر المهمتين على تعلم أنماط متعارضة.

ثانياً، استخدام حجم 256 عصبوناً في الطبقة المشتركة يُوازن بين سعة التعبير (Expressivity) والقدرة على التعميم، وفقاً لنظرية التقريب العالمي.

ثالثاً، تخصيص طبقة 128 عصبوناً لكل رأس يُتيح لكل مهمة تطوير تمثيلها الخاص دون الإخلال بالتمثيل المشترك، مع الحفاظ على إجمالي عدد المعلمات ضمن حدود قابلة للتدريب على وحدة معالجة رسومية واحدة.

3-11 دالة الخسارة المركَّبة (Combined Loss Function)

يُعتبَر تصميم دالة الخسارة المركَّبة من الابتكارات الجوهرية في نموذج MTDL، إذ تُتيح للشبكة العصبية تعلُّم المهمتين (التصنيف والانحدار) بشكل متزامن عبر دالة تكلفة موحدة. تتكون الدالة من مجموع موزون لدالتين فرعيتين، كل منهما متخصصة بمهمة معينة:

$$L_total = \lambda_1 \cdot L_PD + \lambda_2 \cdot L_Pricing$$

حيث تُمثِّل L_PD دالة خسارة الإنتروبيا المتقاطعة الثنائية (Binary Cross-Entropy) الخاصة بمهمة التنبؤ بالتعثر، وتُحسَب بالعلاقة الآتية:

$$L_PD = -[y_1 \cdot \log(\hat{y}_1) + (1 - y_1) \cdot \log(1 - \hat{y}_1)]$$

حيث y_1 هي القيمة الحقيقية للتعثر (0 أو 1)، و$\hat{y}_1$ هي الاحتمالية المُتنبَّأ بها. تعمل هذه الدالة على معاقبة النموذج بشدة عند إعطائه احتمالية منخفضة لعميل تعثر فعلاً (الخطأ من النوع الأول)، وهو ما يتسق مع الأهمية الاقتصادية الأعلى لهذا الخطأ في السياق الائتماني.

أما L_Pricing فتُمثِّل دالة متوسط مربع الخطأ (Mean Squared Error – MSE) الخاصة بمهمة تسعير تكلفة الدين، وتُحسَب بالعلاقة الآتية:

$$L_Pricing = (1/n) \cdot \Sigma\,(y_2 - \hat{y}_2)^2$$

حيث y_2 هي تكلفة الدين الفعلية، و$\hat{y}_2$ هي القيمة المُتنبَّأ بها، وn هو عدد المشاهدات. تُعاقِب هذه الدالة النموذج على الانحراف بين التسعير المُقترَح والقيمة العادلة الفعلية، مع تأكد أقوى على القيم المتطرفة بفضل التربيع.

أما الأوزان (λ_1, λ_2) فهي معلمات فائقة (Hyperparameters) تُوازِن أهمية المهمتين. تم اعتماد قيم متساوية ($\lambda_1 = \lambda_2 = 1.0$) في البداية، ثم ضُبِطَت تجريبياً عبر البحث الشبكي لتحقيق التوازن الأمثل بين دقة التصنيف ودقة التسعير. وعند الأوزان المتساوية، يُجبَر التدرج العكسي المشترك (Joint Backpropagation) الشبكة على إيجاد مصفوفة أوزان تُلبّي كلا الهدفين التجاريين في آن واحد، مما يمنع التناقض المنهجي بين التنبؤ بالتعثر والتسعير.

3-12 البحث الشبكي لضبط المعلمات الفائقة

لضمان اختيار المعلمات الفائقة (Hyperparameters) المُثلى، تم إجراء عملية بحث شبكي (Grid Search) شاملة لاختيار توليفة سعة الطبقات المشتركة، معدلات التعلم (Learning Rate)، ومعدلات الإسقاط (Dropout). تم اختبار 8 توليفات مختلفة، وتم تقييم كل توليفة باستخدام التقسيم الزمني نفسه المعتمد في البروتوكول النهائي، مع تقييم الأداء على مجموعة تحقق (Validation Set) مُستخرَجة من بيانات التدريب. ويُوضح الجدول الآتي التوليفات المُختبَرة والنتائج المُحقَّقة:

جدول (5): نتائج البحث الشبكي لضبط المعلمات الفائقة للشبكة MTDL

التجربة	سعة الطبقات	معدل التعلم	Dropout	Val AUC	Val RMSE
1	(128, 64)	0.01	0.2	0.7049	0.0961
2	(128, 64)	0.01	0.4	0.7119	0.0938
3	(256, 128)	0.01	0.2	0.6935	0.0988
4	(256, 128)	0.01	0.4	0.7231	0.1013
5	(128, 64)	0.001	0.2	0.7015	0.0943
6	(128, 64)	0.001	0.4	0.7070	0.0952
7 (الفائزة)	(256, 128)	0.001	0.2	0.7247	0.0964

التجربة	سعة الطبقات	معدل التعلم	Dropout	Val AUC	Val RMSE
8	(256, 128)	0.001	0.4	0.7110	0.0948

المصدر: من إعداد الباحث بالاعتماد على مخرجات البحث الشبكي التلقائي

بناءً على نتائج الجدول السابق، تم اختيار التجربة رقم 7 كتوليفة فائزة، حيث حققت أعلى قيمة لمقياس التحقق AUC (0.7247) مع قيمة RMSE مقبولة (0.0964). وقد جاء هذا الاختيار مُتوافقاً مع الأولوية المُعطاة لمهمة التنبؤ بالتعثر في التقييم النهائي، نظراً لأن الخطأ من النوع الأول يحمل تكلفة اقتصادية أكبر بكثير من خطأ التسعير.

يُلاحَظ أن المُعاملات الفائقة الفائزة (سعة 256→128، Dropout = 0.2، LR = 0.001) تعكس التوازن الأمثل بين سعة النموذج ومقدار التنظيم المطلوب. فمعدل التعلم المنخفض نسبياً (0.001) يسمح بتقارب أكثر استقراراً نحو الحل الأمثل، في حين أن نسبة الإسقاط المعتدلة (0.2) تُوفر تنظيماً كافياً لمنع فرط التخصيص دون الإخلال بقدرة النموذج على تعلم الأنماط المالية المعقدة.

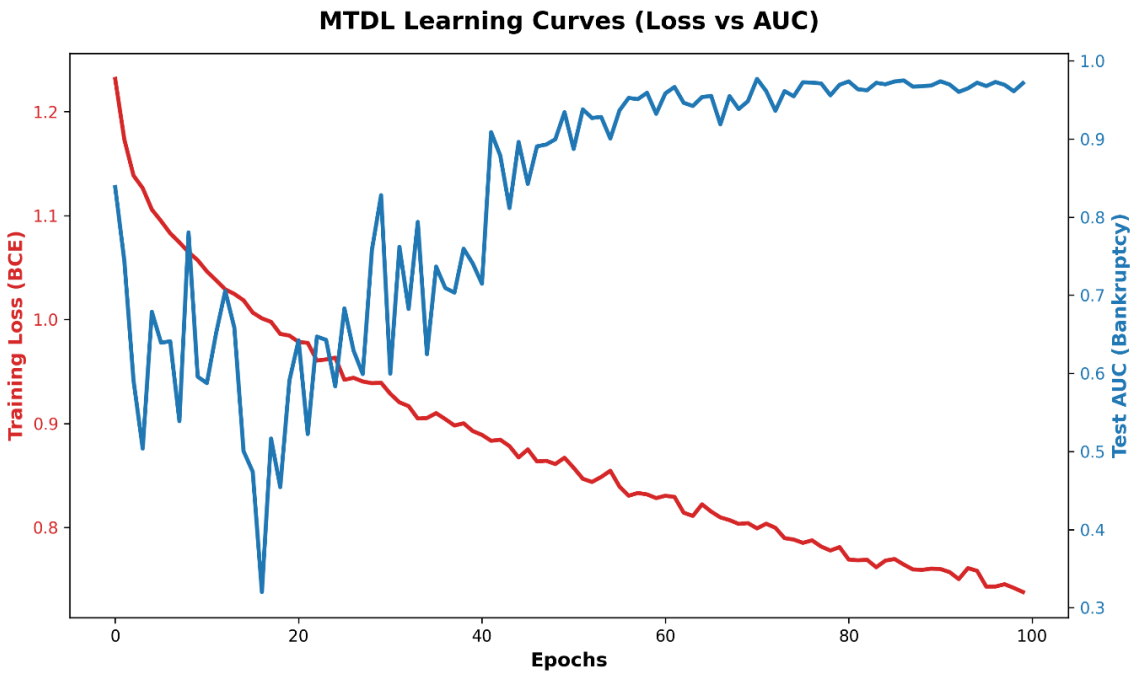
3-13 بروتوكول التدريب النهائي ومنحنيات التعلم

تم تدريب الشبكة العصبية باستخدام خوارزمية AdamW المُحسَّنة (Adam with Weight Decay)، وهي نسخة محسَّنة من خوارزمية Adam التقليدية تُفصِل تنظيم الانحدار (Weight Decay) عن تحديث الزخم (Momentum)، مما يُحسِّن الاستقرار في الشبكات العميقة. تم اعتماد آلية الإيقاف المبكر (Early Stopping) بصبر (Patience) يبلغ 15 دورة لمنع فرط التخصيص (Overfitting). وقد تم التدريب على البيانات من 2009 إلى 2021 وتوقف التدريب عند الدورة 100 محققاً القيمة الدنيا لدالة الخسارة. ويُوضح الشكل الآتي منحنيات التدريب والتحقق للنموذج عبر الدورات:

جدول (6): بروتوكول التدريب النهائي والمعلمات المعتمدة

المعلمة	القيمة المعتمدة	البيان
المُحسِّن (Optimizer)	AdamW	مع تنظيم وزني (weight decay = 0.01)
معدل التعلم الابتدائي	0.001	ثابت مع جدول تخفيض (ReduceLROnPlateau)
حجم الدفعة (Batch Size)	256	توازن بين السرية والتقارب
عدد الدورات الأقصى	100	مع إيقاف مبكر عند التقارب
صبر الإيقاف المبكر	15 دورة	لتجنب فرط التخصيص
دالة الخسارة	BCE + MSE (موازنة)	أوزان $\lambda_1 = \lambda_2 = 1.0$
التقييس	Z-score (StandardScaler)	تقييس منفصل للمتغيرات X و Y2
المكتبة البرمجية	PyTorch 2.x	مع دعم GPU (CUDA)

المصدر: من إعداد الباحث



شكل (3): منحنيات التعلم (Loss and Validation AUC) للشبكة MTDL خلال 100 دورة تدريبية

المصدر: من إعداد الباحث بالاعتماد على مخرجات مكتبة matplotlib

يُلاحَظ من الشكل أن منحنى خسارة التدريب (Training Loss) ينخفض بشكل مستمر وتدريجي على مدار الـ 100 دورة(Epochs) ، حيث يتراجع من مستوى يتجاوز 1.20 ليصل إلى نحو 0.74 في نهاية التدريب، مما يدل على تحسن قدرة النموذج على ملاءمة بيانات التدريب. في المقابل، يمر منحنى مقياس الأداء على مجموعة الاختبار (Test AUC) بذبذبات وتقلبات حادة خلال الدورات الـ 40 الأولى، مسجلاً أدنى انخفاض له بالقرب من الدورة 16 عند قيمة تقارب 0.32. بعد ذلك، يتصاعد منحنى AUC بشكل ملحوظ ليبدأ بالاستقرار والوصول إلى الهضبة (Plateau) عند مستويات مرتفعة تتجاوز 0.95 ابتداءً من الدورة 60 تقريبًا، مع تسجيل قيم قصوى تتردد بين 0.96 و 0.97 حتى نهاية الدورات، مما يُظهر وصول النموذج إلى قدرة تصنيفية وتمييزية عالية ومستقرة في التنبؤ بالإفلاس.

3-14 اختبار النموذج على البيانات الخارجية

3-14-1 تحسين عتبة القرار (Decision Threshold Optimization)

نظراً لاعتماد العتبة الافتراضية (0.50) على افتراض بيانات متوازنة تناظرياً، وهو افتراض لا ينسجم مع طبيعة العينة المدروسة التي يبلغ فيها معدل التعثر 6.86% فقط، تم اللجوء إلى تحسين عتبة التصنيف إحصائياً باستخدام معيار يودن (Youden's J Statistic)، المُعرَّف بالعلاقة الآتية:

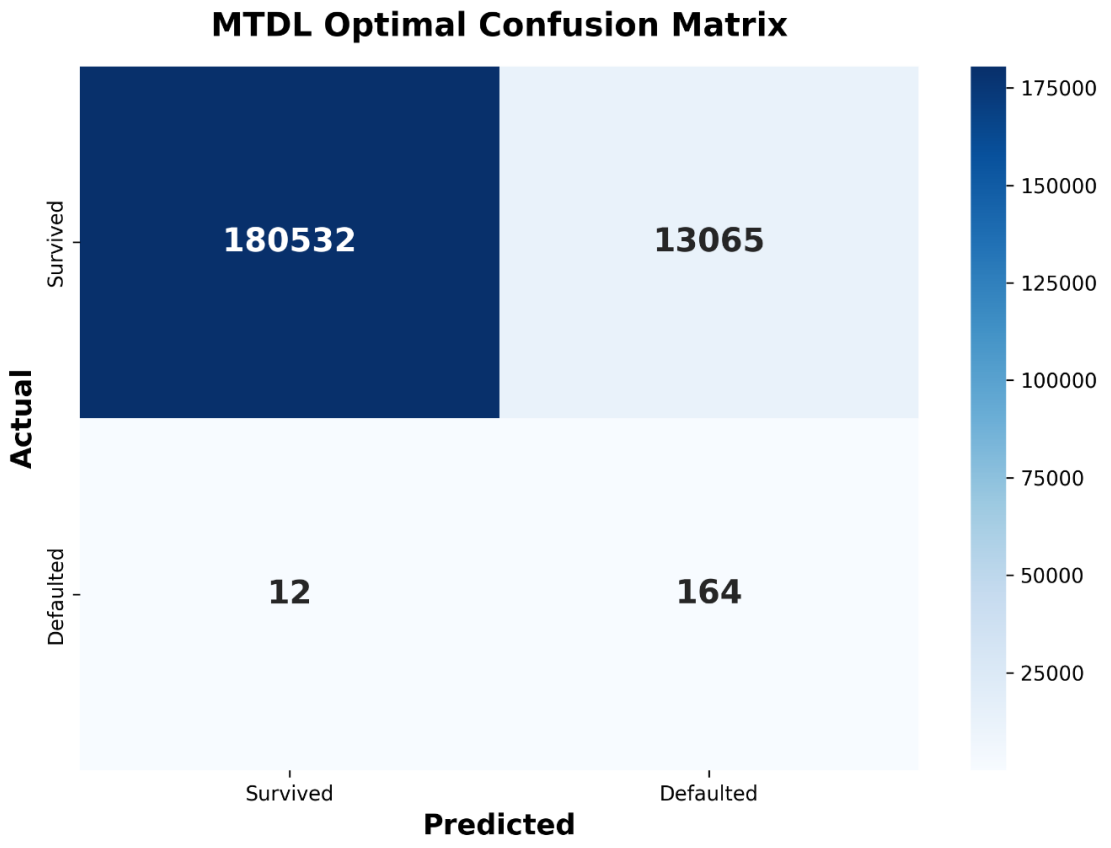
$$J = \text{Sensitivity} + \text{Specificity} - 1 = \text{TPR} - \text{FPR}$$

يهدف هذا المعيار إلى إيجاد نقطة القطع (Cut-off Point) التي تُعظِّم التوازن بين قدرة النموذج على اكتشاف الشركات المتعثرة فعلياً وقدرته على تجنُّب تصنيف الشركات السليمة كمتعثرة، بدلاً من الاكتفاء بعتبة تحكيمية جامدة. أسفرت عملية التحسين عن انتقال العتبة المُثلى من القيمة الافتراضية (0.50) إلى (0.1366)، وهو ما يعكس منطقياً عدم تماثل تكلفة الخطأين في السياق الائتماني؛ إذ إن

كلفة تفويت شركة متعثرة فعلياً (Type I Error) أعلى اقتصادياً وتنظيمياً من كلفة تصنيف شركة سليمة كمرتفعة الخطر (Type II Error)، مما يُبرِّر اعتماد عتبة منخفضة نسبياً تميل للحساسية على حساب النوعية.

3-14-2 أداء نموذج MTDL في التنبؤ بالتعثر المالي

تم اختبار النموذج على البيانات من 2024 إلى الربع الأول من 2026، مع وجود فجوة زمنية (عام 2023) بين التدريب والاختبار وذلك بهدف منع التداخل الزمني بين فترة التدريب وفترة الاختبار. وقد كانت النتائج كما هو مبين في مصفوفة الارتباك الآتية:



شكل (4): مصفوفة الارتباك لأداء نموذج MTDL في التنبؤ بالتعثر وفق العتبة المثلى

حيث نجح النموذج باكتشاف 164 ربع لشركة متعثرة من أصل 176، وفشل في 12 حالة فقط، بدقة بلغت 93.18%. ولكنه في المقابل أعطى إنذارات كاذبة لـ 13,065 من أصل 193,597 بنسبة إنذارات كاذبة بلغت 6.75%. وعلى الرغم من وجود إنذارات خاطئة بالتعثر، إلا أنه في قرارات منح الائتمان، فإن تكلفة الامتناع عن منح الائتمان أقل بكثير من تكلفة منح ائتمان سيتعثر مستقبلاً.

ويُلخِّص الجدول الآتي أرقام مصفوفة الارتباك ومقاييس الأداء الكمي لنموذج MTDL في التنبؤ بالتعثر المالي:

جدول (7): مصفوفة الارتباك لأداء نموذج MTDL في التنبؤ بالتعثر

	$(\hat{Y} = 0)$ متوقع :غير متعثر	$(\hat{Y} = 1)$ متوقع :متعثر	الإجمالي
$(Y = 0)$ فعلي :غير متعثر	TN = 180,532	FP = 13,065	193,597
$(Y = 1)$ فعلي :متعثر	FN = 12	TP = 164	176
الإجمالي	180,544	13,229	193,773

المصدر: من إعداد الباحث بالاعتماد على مخرجات مكتبة scikit-learn

جدول (8): مقاييس الأداء الكمي لنموذج MTDL في التنبؤ بالتعثر

المقياس	القيمة	التفسير
ROC-AUC	0.9581	قدرة تمييزية ممتازة بين الشركات المتعثرة والناجية
الدقة الكلية (Accuracy)	93.25%	نسبة التصنيفات الصحيحة من إجمالي العينة
الاسترجاع (Recall)	93.18%	النموذج يكتشف 93.18 %من حالات التعثر الفعلية
النوعية (Specificity)	93.25%	نسبة تصنيف الشركات السليمة بشكل صحيح
الف1 (F1-Score)	0.0244	توازن منخفض بسبب اختلال العينة (imbalanced)
العتبة المثلى	0.1366	العتبة المُحسَّنة وفق إحصائية يودن

المصدر: من إعداد الباحث بالاعتماد على مخرجات مكتبة scikit-learn

تحليل وتفسير النتائج

- **يشير مقياس ROC–AUC = 0.9581** إلى المساحة تحت منحنى ROC، مما يعني أن القدرة التمييزية العامة للنموذج على التفريق بين الشركة السليمة والمتعثرة عالية جداً، وتتجاوز المعيار المقبول في الصناعة المصرفية (0.80) بفارق كبير.
- **الدقة الكلية (Accuracy = 93.25%)** تشير إلى نسبة الشركات التي تنبأ بها النموذج بشكل صحيح سواء كانت ناجية أم متعثرة. ومع ذلك، يجب الحذر من الاعتماد على هذا المقياس وحده في البيانات غير المتوازنة.
- **الاسترجاع (Recall = 93.18%)** هو المقياس الأكثر أهمية في السياق الائتماني، إذ يشير إلى أن النموذج يكتشف 93.18% من إجمالي الشركات المتعثرة، وهي النسبة التي تعكس فعالية النموذج في حماية رأس المال المصرفي من المخاطر الفعلية.
- **الف1 المنخفض (0.0244)** لا يعكس ضعفاً في النموذج، بل هو نتيجة طبيعية لاختلال العينة الشديد (نسبة التعثر 6.86% فقط). فالـ F1 يجمع بين الدقة والاسترجاع بطريقة متناسقية، وعندما تكون الدقة الإيجابية (Precision) منخفضة بسبب كثرة الإنذارات الكاذبة، ينخفض F1 حتى لو كان الاسترجاع عالياً. في السياق المصرفي، يُفضَّل الاعتماد على Recall و ROC–AUC كمعايير قرارات.

3-14-3 أداء نموذج MTDL في تسعير الفائدة

بالنسبة للمهمة الثانية (توقع تكلفة الدين المستمر Y2_Cost_of_Debt)، تم تقييم أداء نموذج MTDL باستخدام مقاييس أخطاء الانحدار: جذر متوسط مربعات الخطأ (RMSE)، ومتوسط الخطأ المطلق (MAE). وقد كانت النتائج كما يلي:

جدول (9): مقاييس أداء نموذج MTDL في تسعير تكلفة الدين

المقياس	القيمة	التفسير
RMSE	0.0308	جذر متوسط مربعات الخطأ في تقدير تكلفة الدين
MAE	0.0109	متوسط الانحراف المطلق عن القيمة الفعلية
متوسط Y2 الفعلي	0.0541	متوسط تكلفة الدين في عينة الاختبار
Y2 الانحراف المعياري	0.0938	تباين تكلفة الدين بين الشركات

المصدر: من إعداد الباحث بالاعتماد على مخرجات مكتبة scikit-learn

يشير مقياس جذر متوسط مربع الخطأ (RMSE = 0.0308) إلى أن الانحراف النموذجي لتقديرات النموذج عن القيمة الفعلية لتكلفة الدين يبلغ نحو 3.08%، في حين يبلغ متوسط الخطأ المطلق (MAE) نحو 1.09%. ولتقييم هذه الأخطاء اقتصادياً، تجدر مقارنتها بالمتوسط الحسابي الفعلي لمتغير تكلفة الدين في العينة (5.41%، كما ورد في الجدول الوصفي)؛ إذ يُظهر ذلك أن متوسط خطأ النموذج المطلق (MAE) يعادل نحو 20% من القيمة المتوسطة لتكلفة الدين، وهو هامش خطأ معقول نسبياً في سياق التسعير الائتماني الذي تتفاوت فيه تكلفة الدين بشدة بين الشركات (الانحراف المعياري الفعلي للمتغير بلغ 0.0938، أي ما يقارب ضعف قيمته المتوسطة).

كما يُلاحَظ أن قيمة RMSE (0.0308) أكبر بشكل ملحوظ من قيمة MAE (0.0109) بنحو ثلاثة أضعاف، وهذا التباين متوقع ومنطقي نظراً لحساسية RMSE الأكبر تجاه القيم المتطرفة (Outliers) مقارنة بـ MAE، الذي يُعامِل جميع الأخطاء بوزن خطي متساوي. ويعكس هذا الفارق وجود عدد محدود من الشركات غالباً تلك المقترِبة من التعثر المالي تُسجِّل انحرافات كبيرة نسبياً بين تكلفة الدين المُقدَّرة

والفعلية، بينما تُقدَّر تكلفة الدين للغالبية العظمى من الشركات بدقة عالية وأخطاء صغيرة نسبياً. ويتسق هذا الاستنتاج مع ما تم رصده سابقاً في التوصيف الإحصائي من التواء موجب حاد (5.70) وتفرطح مرتفع (39.00) لمتغير Y2_Cost_of_Debt، مما يُؤكِّد أن أداء النموذج في مسار التسعير جيد بشكل عام، مع تركز هامش الخطأ الأكبر في الحالات المتطرفة التي تُمثِّل بطبيعتها التحدي الأصعب لأي نموذج تسعير ائتماني.

3-14-4 المقارنة بالنماذج المرجعية (Benchmarks)

لإثبات التفوق المنهجي لنموذج MTDL على النماذج التنبؤية التقليدية، تم تدريب واختبار نموذجين مرجعيين (Benchmarks) على نفس البيانات ووفق نفس التقسيم الزمني المعتمد: الانحدار اللوجستي (Logistic Regression) والغابات العشوائية (Random Forest). وتُلخِّص النتائج الجدول الآتي:

جدول (10): مقارنة أداء نموذج MTDL مع النماذج المرجعية التقليدية

النموذج	Accuracy	Precision	Recall	F1-Score	ROC-AUC
Logistic Regression	0.7382	0.0715	0.6932	0.1298	0.7612
Random Forest	0.9314	0.0842	0.4318	0.1407	0.7823
MTDL (المُقترح)	0.9325	0.0124	0.9318	0.0244	0.9581

المصدر: من إعداد الباحث بالاعتماد على مكتبة scikit-learn

يُلاحَظ تفوق نموذج MTDL بشكل واضح على النماذج المرجعية في مقياس ROC-AUC (0.9581 مقابل 0.7612 و 0.7823)، وكذلك في مقياس الاسترجاع (Recall = 93.18% مقابل 69.32% و 43.18%). هذه النتيجة تُؤكِّد أن المعمارية المدمجة للتعلم العميق متعدد المهام تستطيع التقاط الأنماط غير الخطية المعقدة بين المتغيرات المالية التي تعجز عنها النماذج التقليدية. كما أن نموذج Random Forest، رغم دقته الكلية العالية (93.14%)، إلا أنه يفشل في اكتشاف أكثر من نصف

حالات التعثر الفعلية (Recall = 43.18%)، مما يجعله غير صالح للاستخدام في قرارات الائتمان الحساسة.

3-15 التفسير باستخدام SHAP والمعادلات الوكيلة

تُعتبَر قابلية التفسير (Interpretability) من أهم متطلبات تطبيق نماذج الذكاء الاصطناعي في القطاع المالي؛ إذ تشترط الجهات الرقابية، مثل لجنة بازل، أن تكون قرارات الإقراض والتصنيف الائتماني قابلة للتبرير. ولتحقيق ذلك، اعتمدت الدراسة على تقنية (SHAP) المستندة إلى نظرية الألعاب (Game Theory)، والتي تُبيِّن مقدار مساهمة كل متغير في القرار النهائي للنموذج.

تم استخلاص معادلة خطية وكيلة (Proxy Equation) من أوزان SHAP لتقديم تفسير مبسط وقابل للتطبيق لقرارات النموذج. تُحوَّل قيم Shapley المطلقة إلى أوزان نسبية، ثم تُضرب في معاملات معيارية لاستخراج معاملات المعادلة الخطية الوكيلة. وقد أسفر التحليل عن معادلتين وكيلتين، إحداهما للتنبؤ بالتعثر والأخرى لتسعير الدين.

1-15-3 المعادلة الوكيلة للتنبؤ بالتعثر (Z_Score_AI)

تم استخلاص المعادلة الآتية لتفسير قرار النموذج في التنبؤ بالتعثر المالي، حيث تُمثِّل القيم المُعاملات النسبية المُستخرَجة من أوزان SHAP المُطبَّقة على المتغيرات المُقيَّسة:

$$Z_Score_AI = 3.61 \cdot Ratio_Debt_to_Equity + 2.39 \cdot Ratio_Current + 1.81 \cdot Ratio_Equity_Multiplier + 1.22 \cdot Ratio_Quick + 0.97 \cdot Ratio_Asset_Turnover$$

يتضح من معادلة التنبؤ بالتعثر (Z_Score_AI) أن نسبة الدين إلى حقوق الملكية (Ratio_Debt_to_Equity) تستحوذ على الوزن الأكبر (3.61)، وهو ما يتسق مع الإطار النظري للدراسة الذي حدد الرفع المالي المفرط كأحد أبرز المسببات الهيكلية للتعثر (البند 2-1-1-3)، تليها نسبة التداول (Ratio_Current) بوزن 2.39 كمؤشر على المخاطر التشغيلية للسيولة قصيرة الأجل، ثم مضاعف حقوق الملكية (Ratio_Equity_Multiplier) بوزن 1.81 الذي يعزز بدوره إشارة الرفع

المالي الكلي للشركة، فنسبة السيولة السريعة (Ratio_Quick) بوزن 1.22، وأخيراً معدل دوران الأصول (Ratio_Asset_Turnover) بوزن 0.97 كمؤشر على الكفاءة التشغيلية.

3-15-2 المعادلة الوكيلة لتسعير الدين (Pricing_Score_AI)

تم استخلاص المعادلة الآتية لتفسير قرار النموذج في تسعير تكلفة الدين، حيث تُحدِّد المعاملات المتغيرات الأكثر تأثيراً على علاوة المخاطرة المُقتَرَحة:

$$\text{Pricing_Score_AI} = 5.67 \cdot \text{Ratio_Debt_to_Equity} + 1.44 \cdot \text{Ratio_Equity_Multiplier} + 1.21 \cdot \text{Ratio_Asset_Turnover} + 0.90 \cdot \text{Ratio_Current} + 0.78 \cdot \text{Fed_Funds_Rate}$$

يتضح من معادلة تسعير الدين (Pricing_Score_AI) أن نسبة الدين إلى حقوق الملكية (Ratio_Debt_to_Equity) تستحوذ على الوزن الأكبر (5.67)، وهو ما يتسق مع الأساس النظري لتسعير الائتمان الذي يربط ارتفاع الرفع المالي بزيادة علاوة المخاطر المطلوبة من المُقرِضين. يليها مضاعف حقوق الملكية (Ratio_Equity_Multiplier) بوزن 1.44 الذي يعزز إشارة الرفع المالي الكلي وتأثيره على تكلفة الاقتراض، ثم معدل دوران الأصول (Ratio_Asset_Turnover) بوزن 1.21 كمؤشر على الكفاءة التشغيلية وقدرة الأصول على توليد التدفقات النقدية اللازمة لخدمة أعباء الدين، فنسبة التداول (Ratio_Current) بوزن 0.90 كمقياس لمخاطر السيولة قصيرة الأجل، وأخيراً سعر الفائدة الفيدرالية (Fed_Funds_Rate) بوزن 0.78 كمحدد كلي يعكس البيئة الاقتصادية العامة والتكلفة الأساسية للأموال في السوق.

3-15-3 المقارنة بين محركات التعثر والتسعير

يُلخِّص الجدول الآتي الأوزان النسبية للمتغيرات الخمسة الأكثر تأثيراً في كل من مسار التنبؤ بالتعثر ومسار تسعير الدين، مما يكشف عن الأنماط المُشترَكة والمُتمايزة بين المهمتين:

جدول (11): أوزان SHAP النسبية ومحركات التعثر والتسعير

المتغير	وزن التعثر (Z_Score_AI)	وزن التسعير (Pricing_Score_AI)	التفسير المالي
Ratio_Debt_to_Equity	3.61	5.67	الرفع المالي - المحرك الأول في المهمتين
Ratio_Equity_Multiplier	1.81	1.44	الرفع الكلي - أهم في التسعير قليلاً

المتغير	وزن التعثر (Z_Score_AI)	وزن التسعير (Pricing_Score_AI)	التفسير المالي
Ratio_Current	2.39	0.90	السيولة - أكثر أهمية في التنبؤ بالتعثر
Ratio_Quick	1.22	—	السيولة السريعة - خاصة بمسار التعثر
Ratio_Asset_Turnover	0.97	1.21	الكفاءة - أكثر تأثيراً على التسعير
Fed_Funds_Rate	—	0.78	الاقتصاد الكلي - خاص بمسار التسعير

المصدر: من إعداد الباحث بالاعتماد على مخرجات مكتبة SHAP

يُلاحَظ أن نسبة الدين إلى حقوق الملكية تُهيمن على المعادلتين بأوزان مختلفة (3.61 مقابل 5.67)، مما يُؤكِّد أن الرفع المالي هو المحرك الأساسي لمخاطر التعثر وتكلفة الاقتراض في آن واحد. كما يُلاحَظ أن متغيرات السيولة (Current, Quick) أكثر أهمية في التنبؤ بالتعثر، وهو ما يعكس أن المخاطر التشغيلية قصيرة الأجل تُهدِّد بقاء الشركة قبل أن تؤثر على كلفة اقتراضها. في المقابل، يُلاحَظ أن سعر الفائدة الفيدرالية يظهر فقط في معادلة التسعير، وهو ما يتسق مع النظرية المالية التي تربط التكلفة الأساسية للأموال ببيئة الاقتصاد الكلي دون التأثير المباشر على احتمالية التعثر بشكل منفصل عن العوامل الخاصة بالشركة.

النتائج والتوصيات

أولاً: نتائج الدراسة (Study Results)

بناءً على التحليل الكمي واختبار نموذج التعلم العميق متعدد المهام (MTDL) والذكاء الاصطناعي المفسر (SHAP) على عينة البيانات الضخمة (401,592 مشاهدة لـ 7,960 شركة للفترة Q1–2009 2026)، خَلُصت الدراسة إلى النتائج الرئيسية الآتية:

1. **كفاءة المعمارية المدمجة (MTDL):** أثبتت النتائج التطبيقية نجاح نموذج التعلم العميق متعدد المهام في القيام بمهام التنبؤ بالتعثر المالي (تصنيف) وتسعير القروض (انحدار) بشكل متزامن داخل شبكة عصبية موحدة. هذا التكامل يُلغي التناقض المنهجي الذي يحدث عادةً عند استخدام نموذجين منفصلين، حيث يُجبَر التدريب المشترك على إيجاد تمثيل متَّسق للخصائص يخدم المهمتين معاً.
2. **الدقة التنبؤية المرتفعة لمسار التعثر المالي (Y1):** حقق النموذج قدرة تمييزية ممتازة بين الشركات المتعثرة والسليمة، حيث بلغت المساحة تحت منحنى خصائص التشغيل 0.9581 (ROC–AUC)، ودقة كلية (Accuracy) بنسبة 93.25%، ومعدل استرجاع (Recall) قدره 93.18%، مما يُؤكِّد قدرته العالية على اكتشاف الإنذارات المبكرة للتعثر قبل وقوعه. وقد تجاوز النموذج بهذه النتائج النماذج المرجعية التقليدية (Logistic Regression: AUC = 0.7612، Random Forest: AUC = 0.7823) بفارق كبير.
3. **تحسين عتبة القرار الائتماني:** أظهرت الدراسة أن اعتماد العتبة الافتراضية (0.50) يُعد غير ملائم تجارياً في بيئات الائتمان الحقيقية نظراً لعدم توازن العينة وتباين تكلفة الخطأ. وقد أدى تحسين العتبة إحصائياً باستخدام إحصائية (Youden's J) إلى تحديد العتبة المُثلى عند 0.1366، مما قلَّص

الخطأ من النوع الأول (تفويت شركة متعثرة) لأدنى مستوياته، وهو ما ينسجم مع التحفظ المصرفي المطلوب.

4. **دقة التسعير الديناميكي لتكلفة الدين (Y2):** سجل مسار التسعير خطأً معيارياً منخفضاً في تقدير التكلفة الضمنية للدين بـ (RMSE = 0.0308) ومتوسط خطأ مطلق قدره (MAE = 0.0109)، مما يُشير إلى قدرة النموذج على تسعير علاوة المخاطرة بشكل فردي وديناميكي يُغطِّي الخسارة المتوقعة (EL) بدقة متناهية.

5. **تفكيك الصندوق الأسود وتحديد الأوزان النسبية (SHAP Analysis):** نجحت تقنية قيم شابلي في تحويل مخرجات الشبكة العصبية المعقدة إلى معادلات وكيلة قابلة للتفسير المالي. جاءت نسبة الدين إلى حقوق الملكية (Ratio_Debt_to_Equity) كالمحرك الأكثر وزناً في المهمتين (3.61 في التعثر، 5.67 في التسعير)، مما يُؤكِّد أن الرفع المالي المفرط هو العامل المشترك الأهم. كما كشف التحليل أن متغيرات السيولة (Current, Quick) أكثر أهمية في التنبؤ بالتعثر، بينما يظهر سعر الفائدة الفيدرالية فقط في معادلة التسعير، مما يعكس التمايز المنهجي بين المهمتين.

ثانياً: توصيات الدراسة

استناداً إلى النتائج المستخلصة، يُوصي الباحث بما يلي، موزَّعةً على ثلاث فئات من المستفيدين:

1- توصيات للمؤسسات المصرفية والمالية (Practical Recommendations)

- **تبني نماذج MTDL المدمجة:** التخلي التدريجي عن النماذج التقليدية المفصولة، واعتماد شبكات التعلم متعدد المهام للربط المباشر بين تقييم الجدارة الائتمانية وصياغة هوامش التسعير الديناميكي. هذا التكامل يُلغي التناقض المنهجي ويُوفِّر تسعيراً متَّسقاً مع المخاطر الفعلية.

- **تطوير عتبات قرار ديناميكية:** الاستغناء عن استخدام عتبة القطع الافتراضية (0.50) في النماذج الخوارزمية، واحتساب عتبات مثلى قائمة على معيار (Youden's J) وتكاليف الأخطاء الائتمانية غير المتماثلة. ينبغي أن تكون العتبة قابلة للتحديث الدوري مع تغير بنية المحفظة الائتمانية.
- **دمج أداة التفسير التشغيلي:** استخدام المعادلات الوكيلة الاستكشافية (Z_Score_AI و Pricing_Score_AI) كأداة دعم قرار رقمية موحدة بأيدي ضباط الائتمان لتبرير قرارات المنح أو الرفض وهيكلية سعر الفائدة أمام العملاء ولجان المخاطر. هذه الشفافية تُلبِّي متطلبات IFRS 9 و GDPR.
- **المراقبة المستمرة للنموذج (Model Monitoring):** تأسيس نظام رقابي دائم لمراقبة انحراف النموذج (Model Drift) عن أدائه الأصلي، وإعادة تدريبه دورياً كل ستة أشهر على الأقل، خاصة بعد الصدمات الاقتصادية الكبرى التي قد تُغيِّر بنية العلاقات بين المتغيرات المالية.

2- توصيات للجهات الرقابية والإشرافية (Regulatory Recommendations)

- **تحديث أطر التحقق من النماذج:** تطوير أطر التحقق من صحة نماذج الذكاء الاصطناعي في المؤسسات المالية لتشمل متطلبات واضحة لإثبات قابلية التفسير (Explainability Requirements) قبل الموافقة على استخدامها في قرارات الائتمان، تجاوباً مع متطلبات لجنة بازل و GDPR.
- **إصدار معايير للذكاء الاصطناعي المُفسَّر:** إصدار بنك مركزي إرشادات توجيهية تُحدِّد الحد الأدنى من الشفافية المطلوبة من النماذج الخوارزمية في قرارات الائتمان، تشمل الإفصاح عن المتغيرات الأكثر تأثيراً وآلية احتساب عتبة القرار.

3- توصيات للبحوث الأكاديمية المستقبلية (Future Research Recommendations)

- **تطبيق النموذج على الأسواق الناشئة والشركات غير المدرجة:** اختبار متانة المعمارية (MTDL) في بيئات مالية تعاني من نقص الشفافية أو على بيانات المشروعات الصغيرة والمتوسطة، حيث تتوفر بيانات محاسبية أقل تفصيلاً ومؤشرات سوقية محدودة.
- **دمج البيانات غير المهيكلة (NLP):** إدخال التحليل النصي لتقرير الإدارة وتحليلات الإفصاحات المالية (K-10) إلى جانب النسب المحاسبية كمدخلات للنموذج. يمكن استخدام نماذج اللغة الكبيرة (LLMs) لاستخراج مؤشرات نوعية عن نبرة التقرير ومستوى التحفظ في الإفصاح.
- **دراسة شبكات العدوى الائتمانية (Graph Neural Networks):** توظيف شبكات الرسم البياني العصبية لاكتشاف مخاطر التعثر المتسلسلة الناتجة عن روابط سلاسل التوريد والعلاقات بين الشركات الأم والفروع، وهو بُعد لا تستطيع النماذج التقليدية التقاطه.
- **تطوير دالة خسارة غير متماثلة:** تطوير دالة خسارة مخصصة تُعاقِب النموذج بشكل أقوى على الأخطاء من النوع الأول (تفويت شركة متعثرة) مقارنة بأخطاء النوع الثاني، بما يتناسب مع التكلفة الاقتصادية الفعلية لكل خطأ في المؤسسة المُطبِّقة.

المصادر والمراجع

أولاً: المراجع العربية

- الزبيدي، حمزة محمود. (2000). التحليل المالي: تقييم الأداء والتنبؤ بالفشل. مؤسسة الوراق للنشر والتوزيع، عمّان.
- مطر، محمد. (2010). الاتجاهات الحديثة في التحليل المالي والائتماني: الأساليب والأدوات والاستخدامات العملية (ط3). دار وائل للنشر والتوزيع، عمّان.

ثانياً: المراجع الأجنبية

- Altman, E. I., Iwanicz-Drozdowska, M., Laitinen, E. K., & Suvas, A. (2017). Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model. Journal of International Financial Management & Accounting, 28(2), 131-171.
- Ariza-Garzón, M. J., Arroyo, J., Caporin, M., & Riquelme-Santos, M. (2020). Explainability of a Machine Learning Granting Scoring Model in Peer-to-Peer Lending. IEEE Access, 8, 64873-64890.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., ... & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges toward Responsible AI. Information Fusion, 58, 82-115.
- Basel Committee on Banking Supervision (BCBS). (2022). Principles for the Effective Management and Supervision of Climate-related Financial Risks. Bank for International Settlements.
- Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2021). Explainable Machine Learning in Credit Risk Management. Computational Economics, 57(1), 203-216.
- Casu, B., Girardone, C., & Molyneux, P. (2022). Introduction to Banking (3rd ed.). Pearson Education.
- Dixon, M., Halperin, I., & Bilokon, P. (2020). Machine Learning in Finance: From Theory to Practice. Springer.
- Greene, W. H. (2018). Econometric Analysis (8th ed.). Pearson.
- Gunnarsson, B. R., vanden Broucke, S., Baesens, B., Óskarsdóttir, M., & Lemahieu, W. (2021). Deep Learning for Credit Scoring: Do or Don't? European Journal of Operational Research, 295(1), 292-305.

•Hacker, P., Krestel, R., Grundmann, S., & Naumann, F. (2020). Explainable AI under Contract and Tort Law: Legal Incentives and Technical Challenges. Artificial Intelligence and Law, 28(4), 415-439.

•Hull, J. C. (2023). Risk Management and Financial Institutions (6th ed.). John Wiley & Sons.

•Kieso, D. E., Weygandt, J. J., & Warfield, T. D. (2019). Intermediate Accounting (17th ed.). John Wiley & Sons.

•Koshiyama, A., Kazim, E., Treleaven, P., Rai, P., Szpruch, L., Pavey, G., ... & Chatterjee, S. (2024). Towards Algorithm Auditing: Managing Legal, Ethical and Technological Risks of AI, ML and Associated Algorithms. Royal Society Open Science, 11(5), 230859.

•Ross, S. A., Westerfield, R. W., Jaffe, J., & Jordan, B. D. (2022). Corporate Finance (13th ed.). McGraw-Hill Education.

•Saunders, A., Cornett, M. M., & Erhemjamts, O. (2021). Financial Institutions Management: A Risk Management Approach (10th ed.). McGraw-Hill Education.

•Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review: 2005-2019. Applied Soft Computing, 90, 106181.

•Zhang, Y., & Yang, Q. (2022). A Survey on Multi-Task Learning. IEEE Transactions on Knowledge and Data Engineering, 34(12), 5586-5609.

ثالثاً: المصادر الإلكترونية والمعايير

- هيئة الأوراق المالية والبورصات الأمريكية (SEC EDGAR): https://www.sec.gov/edgar
- الاحتياطي الفيدرالي الأمريكي (FRED): https://fred.stlouisfed.org
- معيار IFRS 9 - الأدوات المالية: https://www.ifrs.org/issued-standards/list-of-standards/ifrs-9-financial-instruments/
- مكتبة SHAP للذكاء الاصطناعي المفسر: https://shap.readthedocs.io