



القدرة التفسيرية والتنبؤية للنماذج الاقتصادية بين نماذج تعلم الآلة ونماذج الاقتصاد القياسي

إعداد

د. حسني إبراهيم عبد الواحد حسن

أستاذ مساعد الاقتصاد

المعهد العالي للعلوم الإدارية – ٦ أكتوبر

Drhossny2013@yahoo.com

المجلة العلمية للدراسات والبحوث المالية والتجارية

كلية التجارة – جامعة دمياط

المجلد السابع – العدد الأول – الجزء الرابع – يناير ٢٠٢٦

التوثيق المقترح وفقاً لنظام APA:

حسن، حسني إبراهيم عبد الواحد (٢٠٢٦). القدرة التفسيرية والتنبؤية للنماذج الاقتصادية بين نماذج تعلم الآلة ونماذج الاقتصاد القياسي، المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة، جامعة دمياط، ٧(١)، ٣٢٩-٢٨٧.

رابط المجلة: <https://cfdj.journals.ekb.eg/>

القدرة التفسيرية والتنبؤية للنماذج الاقتصادية بين نماذج تعلم

الآلة ونماذج الاقتصاد القياسي

د. حسني إبراهيم عبد الواحد حسن

الملخص:

تهدف الدراسة للتأكد من مدى صحة الفرضيات الأساسية والمتمثلة في تفوق نماذج تعلم الآلة والتعلم العميق من حيث القدرة التنبؤية مع انخفاض القابلية للتفسير مقارنة بنماذج الاقتصاد القياسي التقليدية. لذا فقد بدأت الدراسة بتناول المقاييس التقليدية للقدرة التفسيرية والتنبؤية لنماذج الاقتصاد القياسي. وتوصلت الدراسة إلى أن هذه النماذج تعاني من أوجه قصور عديدة في مجال التنبؤ وأهمها فشلها في التعامل مع كثير من التحديات خاصة الأزمنة المالية العالمية، كما لا يمكنها معالجة البيانات المفقودة وذلك لاعتمادها على قابلية النموذج للتفسير وليس دقة النموذج وقدرته التنبؤية. ثم تناولت الدراسة أهم المقاييس الحديثة لجودة التوفيق الذي قدمته دراسة (Apesteguia & Ballester, 2020) وهو الحد الأقصى من البيانات التي يمكن التوفيق بينها وبين النموذج. كما تناولت الدراسة آلية ضبط البيانات Cross Validation في نماذج تعلم الآلة وهي طريقة لتقييم جودة التوفيق خارج العينة وتهدف أساساً لتجنب التوفيق الزائد Overfitting أو Underfitting. كذلك تناولت الدراسة مفهوماً حديثاً لتقييم القدرة التنبؤية للنماذج الاقتصادية وهو مفهوم الكمال Completeness الذي اقترحتة دراسة (Fudenberg et al., 2021) ويوضح الحيز المتاح لتحسين القدرة التنبؤية. تناولت الدراسة نماذج الانحدار لتعلم الآلة Machine Learning والتعليم العميق Deep Learning والتي زاد الاعتماد عليها في مجال التنبؤ الاقتصادي خلال العقد الثاني للقرن الحادي والعشرين للاستفادة من عصر البيانات الضخمة Big Data خاصة بعد فشل النماذج الإحصائية التقليدية في التنبؤ بالأزمات المالية العالمية ٢٠٠٨. تم استعراض نتائج الكثير من الدراسات الحديثة التي استهدفت مقارنة القدرة التنبؤية والتفسيرية للنماذج الإحصائية التقليدية ونماذج تعلم الآلة من أهمها (Seifipour & Azadeh, 2025; Juanhua & Xu, 2025; Makridakis et al, 2024; Franck et al., 2020; Richardson et al., 2021; Nicolas, 2023). من أهم النتائج التي توصلت إليها الدراسة: (١) تركيز الأساليب الحديثة على قياس الأداء الأمثل للنموذج أى أقصى أداء ممكن، (٢) أن القدرة التنبؤية لنماذج تعلم الآلة تتفوق على النماذج التقليدية، انخفاض القدرة التفسيرية لنماذج تعلم الآلة، حيث من الصعب شرح العوامل التي تحرك التنبؤات، (٣) يؤدي الجمع بين الطرق التقليدية ونماذج ML باستخدام أوزان ترجيح مناسبة إلى مزيد من التحسينات في الأداء، وهو ما يثبت صحة فرضيات الدراسة.

الكلمات الرئيسية: تعلم الآلة - التعلم العميق - التنبؤ الاقتصادي - منهج أشجار الانحدار - الغابات العشوائية - الشبكات العصبية المتكررة.

مقدمة

تعرضت نماذج الاقتصاد القياسي للعديد من الانتقادات فيما يتعلق بقدرتها التنبؤية أهمها عدم قدرتها على التعامل مع العديد من مشاكل العالم الحقيقي خاصة التنبؤ بالأزمات الاقتصادية، لا يمكنها معالجة البيانات المفقودة وأنها غير مناسبة للتنبؤ في الأجل الطويل (Liang et al., 2025). يضاف إلى ذلك، أن نماذج الاقتصاد القياسي تركز بشكل كبير على قابلية النموذج للتفسير وليس دقة النموذج وقدرته التنبؤية.

منذ بداية العقد الثاني للقرن الحادي والعشرين، تزايد اهتمام عدد كبير من الدراسات التطبيقية باستخدام نماذج تعلم الآلة Machine Learning والتعلم العميق Deep Learning في التطبيقات الاقتصادية والتجارية خاصة في مجال التنبؤ لمعالجة أوجه قصور النماذج التقليدية ومن أهمها (Seifipour & Azadeh, 2025; Verona, 2025; Makridakis et al, 2024; Franck et al., 2023; Richardson et al., 2021; Nicolas, 2020). وساعد على انتشار هذا الاتجاه توفر مجموعات هائلة من البيانات في عصر البيانات الضخمة Big Data مع توافر وتطور حزم من البرامج ذات القدرات الحسابية الهائلة، وهو ما أدى إلى تحسن كبير في دقة تنبؤات هذه النماذج. وظهر ذلك بوضوح بدخول هذه النماذج ضمن المنافسين الأساسيين في مسابقات التنبؤ الشهيرة M4 عام 2018، M5 عام 2020 وكذلك M6 عام 2024 وأظهرت تفوقاً واضحاً على النماذج الإحصائية التقليدية (Makridakis et al, 2024).

على الرغم من تفوق نماذج تعلم الآلة من حيث القدرة التنبؤية، أشارت دراسات كثيرة إلى انخفاض القدرة التفسيرية لها خاصة بالنسبة للنماذج شديدة التعقيد مثل النماذج المحولة Transformers مما يخفض من الاعتماد عليها من جانب السياسات التي تتطلب أساساً منطقياً وواضحاً على الرغم من ارتفاع قدرتها التنبؤية. وفي هذا الصدد، أشارت دراسات كثيرة منها (André et al., 2021; Hu et al., 2025) إلى أنه لا توجد طريقة تنبؤ واحدة تقدم أفضل أداء لجميع السلاسل الزمنية، حيث يؤدي تحسين جانب واحد إلى تدهور في الأداء لبعض الجوانب الأخرى ويستوجب ذلك ضرورة البحث عن منهجية تجمع بين تحسين القدرة التنبؤية مع الحفاظ على القابلية للتفسير (Chen et al., 2025; Kabir et al., 2025; Hao & Sun, 2025).

أ - مشكلة الدراسة:

تمثل قضية التنبؤ الدقيق بالمؤشرات الاقتصادية أمراً بالغ الأهمية لصنع السياسات الاقتصادية الرشيدة والتخطيط المالي وإدارة المخاطر وتجنب عدم الاستقرار الاقتصادي. تعتمد المناهج التقليدية بشكل كبير على النماذج الخطية للسلاسل الزمنية مثل ARIMA وVAR، والتي على الرغم من فعاليتها في التنبؤات قصيرة الأجل، إلا أنها فشلت في التعامل مع العديد من مشاكل العالم الحقيقي خاصة التنبؤ بالأزمات الاقتصادية، التقاط التفاعلات غير الخطية، التنبؤات طويلة الأجل، التعامل مع البيانات المعقدة والمتعددة الأبعاد وتقلب الديناميكيات الاقتصادية العالمية المتأصلة في البيانات الاقتصادية (Mahmud & Mohammed, 2021; McCloskey & Remor, 2025; Oo et al., 2025).

يمثل ظهور خوارزميات تعلم الآلة والتعلم العميق تطوراً كبيراً في التنبؤ الاقتصادي، مما يوفر تنبؤات أكثر دقة ومرونة، حيث أظهرت دراسات كثيرة تفوق هذه النماذج على نماذج الاقتصاد القياسي من حيث القدرة التنبؤية والتغلب على المشكلات السابقة ذكرها، ومن أهم هذه الدراسات (Chen et al., 2025; Juanhua & Xu, 2025; Oo et al., 2025; Kabiret al., 2025; Brahim et al., 2025).

على الرغم من هذه التطورات، لا يزال التنبؤ الاقتصادي يواجه الكثير من التحديات بسبب الطبيعة متعددة الأوجه للمؤشرات الاقتصادية ووجود ضوضاء Noise وعدم التأكد في البيانات. تشير الدراسات الحديثة إلى وجود فجوة كبيرة تتعلق بدمج قابلية التفسير مع الأداء التنبؤي، لا سيما في النماذج التي تجمع بين التعلم العميق وتقدير عدم التأكد الاحتمالي (Sivakumar, 2025; Liang et al., 2025). (Chen et al., 2025; Kumar et al., 2025). على تفوق نماذج تعلم الآلة والتعلم العميق مثل Transformers و Gated recurrent units (GRUs) في النقاط الأنماط الزمنية المعقدة، بينما تشير دراسات أخرى للحاجة إلى قابلية التفسير الذي يناسب التحليل الاقتصادي ويستفيد منه صانعو السياسة الاقتصادية (Sivakumar, 2025; Seifipour & Azadeh, 2025).

يُضاف إلى ذلك، توجد خلافات كبيرة بين الدراسات التطبيقية فيما يتعلق بالاختيار الأمثل لمتغيرات الاقتصاد الكلي وبناء النماذج، حيث يدعو البعض إلى مناهج متعددة الوسائط تتضمن البيانات النصية والعوامل الخارجية (Mou et al., 2025; Hossain et al., 2025)، بينما يركز آخرون على نماذج السلاسل الزمنية الكمية البحتة (Pârțachi & Mija, 2025; Hu et al., 2025). وفي هذا الصدد، أشارت دراسة (Kumar et al., 2025) إلى أن هذه الفجوة تؤدي إلى محدودية الثقة بالتنبؤات الاقتصادية لخوارزميات تعلم الآلة ونماذج التعلم العميق في صنع القرار الاقتصادي. بالتالي فإن مشكلة الدراسة تتمثل في كيفية سد الفجوة بين الأداء التنبؤي وقابلية التفسير لخوارزميات تعلم الآلة ونماذج التعلم العميق. أي أن مشكلة الدراسة تكمن في الإجابة على التساؤلات التالية:

- ما هي أهم أوجه قصور القدرة التنبؤية لنماذج الاقتصاد القياسي؟
- كيف يمكن لخوارزميات تعلم الآلة ونماذج التعلم العميق أن تحسن دقة التنبؤات الاقتصادية مقارنة بالنماذج الاقتصادية التقليدية؟
- ما هي الخوارزميات الأكثر فعالية في تحليل البيانات الاقتصادية المتعددة الأبعاد والمعقدة؟
- ما مدى تأثير حجم وجودة البيانات المتاحة على دقة التنبؤات الاقتصادية باستخدام خوارزميات تعلم الآلة؟
- ما هي التحديات الرئيسية التي تواجه تطبيق تعلم الآلة في التنبؤ الاقتصادي؟
- كيف يمكن لتقنيات الذكاء الاصطناعي القابل للتفسير XAI مواجهة التحديات والقيود التي تواجهها أساليب تعلم الآلة في التنبؤ بالمؤشرات الاقتصادية؟

ب. فرضية الدراسة: Hypothesis

تختبر الدراسة فرضيتين رئيسيتين هما:

- ١- تفوق نماذج تعلم الآلة والتعلم العميق على نماذج الاقتصاد القياسي من حيث القدرة التنبؤية.
- ٢- انخفاض القدرة التفسيرية لنماذج تعلم الآلة والتعلم العميق عن نظيرتها في نماذج الاقتصاد القياسي.

ج - هدف الدراسة:

تهدف الدراسة إلى تقييم القدرة التنبؤية والتفسيرية لنماذج الاقتصاد القياسي التقليدية والنماذج الحديثة المتمثلة في تعلم الآلة والتعلم العميق وتوضيح مزايا وعيوب كل منها فيما يتعلق بالتنبؤ بالسلاسل الزمنية الاقتصادية. كما تهدف الدراسة لمواجهة التحديات والقيود التي تواجهها أساليب تعلم الآلة في التنبؤ بالمؤشرات الاقتصادية، وأهمها انخفاض قدرتها التفسيرية. وأخيراً تحديد لطريقة المثلى التي تجمع بين تعزيز القدرة التنبؤية التي تتميز بها أساليب تعلم الآلة مع الحفاظ على القابلية للتفسير التي تضمنها نماذج الاقتصاد القياسي.

د - أهمية الدراسة:

تكمن أهمية الدراسة في أن تحسين القدرة التنبؤية والتفسيرية للنماذج الاقتصادية له آثار هامة على نتائج السياسات الاقتصادية الكلية للدولة، حيث يؤدي التنبؤ غير الدقيق للمتغيرات الاقتصادية لفشل سياسات الاستقرار. فقد يؤدي التنبؤ الخاطئ المتعلق بالمتغيرات الاقتصادية الهامة لقيام الاقتصاديين بتوقعات خاطئة وتقديم تحليل غير صحيح لصانعي السياسة، بالتالي تكون النتائج على عكس المتوقع لها، وبالتالي اتباع سياسات مختلفة عن السياسات المطلوبة والمستهدفة.

كما تأتي أهمية الدراسة من كونها تساعد في التعرف على آخر ما توصلت إليه النماذج الحديثة في الأدب الاقتصادي وكيفية استخدامها في التنبؤ الدقيق، وكذلك التعديلات التي شملتها لمعالجة أوجه القصور التي عانت منها نماذج الاقتصاد القياسي. كما تمهد الدراسة الطريق أمام الباحثين المهتمين بهذا المجال لاستحداث وصياغة نماذج جديدة خاصة أن هذا النوع من الدراسات يعاني من ندرة شديدة في مصر والدول النامية.

هـ - المنهجية: Methodology

اعتمدت الدراسة على المنهج الاستنباطي Induction Approach لتحقيق أهداف الدراسة واختبار فرضياتها، حيث ركزت على أسلوب التحليل الاقتصادي للتطور التاريخي والنظري لنماذج الاقتصاد القياسي التقليدية والمناهج الحديثة المتمثلة في نماذج تعلم الآلة لقياس القدرة التفسيرية والتنبؤية للنماذج الاقتصادية، وكذلك بيان أهم نقاط القوة والضعف لكل منها. كما تم الاعتماد على المنهج الإستقرائي Deduction Approach وذلك بتناول المعادلات الإحصائية للنماذج التقليدية وخوارزميات تعلم الآلة، وإن كانت بهدف الاستدلال بها وليس قياسها ولتوضيح تطور عملية صياغتها.

و- خطة الدراسة:

تناولت الدراسة الموضوع في ثماني نقاط رئيسة بالإضافة لنتائج وتوصيات الدراسة وتتمثل في: أولاً: الدراسات السابقة، ثانياً: الأساليب التقليدية لقياس القدرة التفسيرية والتنبؤية، ثالثاً: المقاييس الحديثة للقدرة التفسيرية والتنبؤية، رابعاً: التنبؤ في نماذج الاقتصاد القياسي التقليدية، خامساً: أوجه قصور نماذج الاقتصاد القياسي في التنبؤ الاقتصادي، سادساً: المناهج الحديثة للتنبؤ الاقتصادي، سابعاً: مقارنة القدرة التنبؤية والتفسيرية للنماذج التقليدية ونماذج انحدار تعلم الآلة، ثامناً: الذكاء الاصطناعي القابل للتفسير (XAI).

١. الدراسات السابقة

يمكن تقسيم الدراسات السابقة وفقاً للنتائج التي توصلت إليها والتي تتعلق بالجوانب التالية: أداء النموذج والدقة التنبؤية، المرونة والقدرة على التكيف مع التقلبات وعدم التأكد، أفق التنبؤ.

أولاً: أداء النماذج والدقة التنبؤية

أظهرت دراسة (Chen et al., 2025) أن نموذج المحول Transformer حقق أعلى R^2 وأدنى أخطاء. كما أشارت دراسات (Sivakumar, 2025) إلى أن دمج نماذج HMM - LSTM أدى إلى تحسين دقة التنبؤ مقارنة باستخدام نموذج LSTM بشكل منفرد. أثبتت دراسة (Hao & Sun, 2025) أن نموذج المحول قد خفض خطأ التنبؤ MSE بالنتائج المحلي الإجمالي والتضخم بنسبة ٢,٦٪، كما أثبتت دراسة (Mou et al., 2025) انخفاض النسبة السابقة إلى ٢٦,٧٩٪.

قام (Hossain et al., 2025) بدراسة عن تحسين التنبؤ باتجاهات السوق باستخدام نماذج تعلم الآلة، وتوصلت الدراسة إلى أن تعزيز التدرج يحقق أعلى دقة (٩٢,٧٪) وأدنى MSE. أشارت دراسة (Kumar et al., 2025) إلى أن استخدام الذكاء الاصطناعي التوليدي أدى إلى تحسين دقة التنبؤ المالي ونمذجة السيناريو.

أظهرت دراسة (Oo et al., 2025) تفوق الشبكة الصناعية المتكررة ANN على الغابات العشوائية RF، GBR، XGBoost، SVR مع $R^2=0.89$ وذلك فيما يتعلق بالتنبؤ بالنمو الاقتصادي في الأجل الطويل.

أوضحت دراسة (Naaz et al., 2024) أنه يمكن لنماذج مثل الغابة العشوائية وانحدار الشبكة العصبية أن تتعامل بفعالية مع العلاقات المعقدة وغير الخطية بين المتغيرات الاقتصادية، مما يؤدي إلى تنبؤات أكثر دقة للنتائج المحلي الإجمالي. كما توصلت دراسة (Tenorio & Pérez, 2024) إلى أن أفضل خوارزميات تعلم الآلة ML الرئيسية للتنبؤ الآن بالنتائج المحلي الإجمالي هي آلة تعزيز التدرج، LASSO والشبكة المرنة، وأنها حسنت الدقة من خلال تقليل أخطاء التنبؤ بنسبة ٢٠٪ إلى ٢٥٪ مقارنة بالنماذج التقليدية مثل AR و DFM.

أثبتت نتائج دراسة (Mohamed et al., 2023) أن استخدام تقنيات تعلم الآلة في التنبؤ بالاقتصاد الكلي يتميز بقوة تنبؤية عالية. وقامت الدراسة بتقييم أداء خوارزميات تعلم الآلة وخاصة الغابات العشوائية RF وانحدار الدعم الآلي SVM والانحدار اللوجستي LR وخوارزميات بايز البسيطة NB وانحدار الجيران الأقرب KNN وتعزيز التدرج GB، من خلال التنبؤ بقيم الناتج المحلي الإجمالي لمصر. وقد أثبتت خوارزمية GB دقة هذا النموذج في التنبؤ بالنتائج المحلي الإجمالي مقارنة بالخوارزميات الأخرى.

ثانياً: المرونة والقدرة على التكيف مع التقلبات وعدم التأكد

أشارت دراسات (Sivakumar, 2025; Hossain et al., 2025) إلى أن النماذج الهجينة التي تجمع بين LSTM و HMM تعمل على التخفيف من آثار التقلبات. كما أظهرت دراسة (Chen et al., 2025) قدرة نموذج TCN و Transformer على التعامل بكفاءة مع التقلبات في المدى القصير.

أشارت دراسة (Sadreeva et al., 2024) إلى أنه يمكن لنماذج تعلم الآلة تحليل مجموعات البيانات الضخمة، ودمج المؤشرات الاقتصادية المتنوعة والعوامل الخارجية التي تؤثر على الأداء الاقتصادي. كما أثبتت دراسة (Zhangyin, 2024) أن تقنيات الشبكات العصبية المتكررة (RNNs) فعالة بشكل خاص في التعامل مع السلاسل الزمنية طويلة المدى والأنماط الدورية في بياناتها.

اعتمدت دراسة (Jin, 2024) على خوارزمية الانحدار الرمزي Symbolic Regression في التنبؤ بالنتائج المحلي الإجمالي، وتوصلت الدراسة إلى قدرة هذه الآلية على تحسين التنبؤ في ظل التقلبات الملحوظة للنتائج المحلي الإجمالي. قامت دراسة (Niko et al., 2024) باستخدام أشجار الانحدار الإضافي البايزي (BART) كخوارزميات رئيسية تستخدم في التنبؤ الآني للنتائج المحلي الإجمالي، مما يعزز الدقة من خلال الاستفادة من البيانات الضخمة للاقتصاد الكلي بكفاءة. وأثبتت الدراسة تحسين الدقة التنبؤية لنمو الإنتاج الأمريكي والتضخم، كما أنه تتفوق أساليب تعلم الآلة البايزي على معيار نموذج AR (P L).

أثبتت دراسة (Sadreeva et al., 2024) أن مناهج تعلم الآلة تسمح باستجابة أكثر مرونة للتغيرات الاقتصادية، مما يتيح إجراء تعديلات في الوقت الفعلي للتنبؤات بناءً على البيانات الجديدة. كما أشارت دراسة (Zhangyin, 2024) إلى أن القدرة على تقييم عدم التأكد المتوقع وتقديم الإنذارات المبكرة تعزز عملية صنع القرار لصانعي السياسات والمحللين الاقتصاديين.

أوضحت دراسة (Németh & Hadházi, 2024) أن الشبكات العصبية الاصطناعية (ANNs) تتفوق لا سيما مع Bayes by Backprop ومونتي كارلو على النماذج التقليدية مثل نماذج العوامل الديناميكية (DFM) من خلال توفير البث الآني عالي الكثافة والذي يأخذ في الحسبان عدم التأكد في التنبؤات خاصة خلال فترات الركود.

استخدمت دراسة (Utama & Firinda, 2024) خوارزميات تعلم الآلة مثل الشبكة المرنة Elastic Net، الغابات العشوائية Random Forest، XGBoost و SVM في التنبؤ الآني بالنتائج المحلي الإجمالي لإنдонيسييا، وتوصلت الدراسة إلى تفوق هذه النماذج في التعامل مع المؤشرات الاقتصادية المتنوعة، مما يؤدي إلى أداء قوي عبر ظروف مختلفة.

ثالثاً: أفق التنبؤ

اختلفت الدراسات التطبيقية المهمة باستخدام خوارزميات تعلم الآلة والتعلم العميق من حيث أفق التنبؤ، حيث أظهرت بعض الدراسات فعالية التنبؤ في المدى القصير فقط ومن أهمها (Chen et al., 2025; Sivakumar, 2025; Hossain et al., 2025).

بينما أظهرت دراسات أخرى فعالية التنبؤ في المدى المتوسط ومنها (Juanhua & Xu, 2025; Kabir et al., 2025; Mou et al., 2025; Yemets et al., 2025; Uddin et al., 2025)

وأخيراً، أثبتت دراسات كثيرة فعالية التنبؤ في الأجل الطويل ومن أهمها (Oo et al., 2025; Pârțachi, & Mija, 2025; McCloskey & Remor, 2025; Verona, 2025)

من عرض الدراسات السابقة، يتضح أن معظم الدراسات التطبيقية اتفقت على تفوق خوارزميات تعلم الآلة على نماذج الاقتصاد القياسي التقليدية فيما يتعلق بالقدرة التنبؤية، ومع ذلك، لا تزال هناك تحديات في قابلية تفسير النموذج، وإدارة تقلب البيانات، وقوة التنبؤ على المدى الطويل. (Sivakumar, 2025; Seifipour & Azadeh, 2025)

٢. الأساليب التقليدية لقياس القدرة التفسيرية والتنبؤية

٢.١.٢ مقاييس القدرة التفسيرية

يتناول هذا البند أهم مقاييس القدرة التفسيرية المعروفة وهو معامل التحديد.

٢.١.١.٢ معامل التحديد Coefficient Determination

يُعد معامل التحديد R^2 من أهم مقاييس القدرة التفسيرية للنموذج ، ويشير إلى النسبة التي يمكن تفسيرها من التغير الكلي في المتغير التابع بدلالة المتغيرات المستقلة المدرجة في دالة الانحدار المتعدد. ويتم حسابه وفقاً للمعادلة التالية: (Devore, 2016)

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - y)^2}{\sum_{i=1}^n (y_i - y)^2} = \frac{ESS}{TSS} \quad (2.1)$$

تشير ESS لتباين الانحدار (التباين المفسر) ، TSS التباين الكلي. يتم تصحيح قيمة معامل التحديد بحيث لا يتأثر بعدد المتغيرات التفسيرية وذلك بالأخذ في الحسبان درجات الحرية (n-k)، ويقدر معامل التحديد المعدل Adjusted R^2 كما يلي:

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n-1}{n-k} \quad (2.2)$$

وكلما اقتربت القيمة من الواحد ازدادت القدرة التفسيرية للنموذج. ومن المعروف أنه لكي يتم الاعتماد على هذا المقياس يجب التأكد أولاً من استقرار السلاسل الزمنية لتجنب ما يعرف بالانحدار الزائف.

٢٠٢ مقاييس القدرة التنبؤية

يتناول هذا الجزء من الدراسة مقاييس خطأ التنبؤ شائعة الاستخدام وحدود استخدام كل مقياس منها بشكل مختصر. وفقاً لدراسة (Rob & Koehler, 2006)، يمكن تقسيم مقاييس دقة التنبؤ إلى أربعة أقسام رئيسية، المقاييس المعتمدة على وحدات القياس، مقاييس النسبة المئوية للأخطاء، مقاييس الأخطاء النسبية Measures based on relative errors، المقاييس النسبية Relative measures.

١٠٢٠٢ المقاييس المعتمدة على وحدات القياس Scale dependent measures

تستند المقاييس المعتمدة على المقياس الأكثر شيوعاً إلى الخطأ المطلق أو الأخطاء التربيعية وأهمها ما يلي:

أ- متوسط مربعات الخطأ (MSE) Mean Square Error

$$MSE = \frac{\sum_{t=1}^n |F_t - y_t|^2}{n} \quad (2.3)$$

ب- الجذر التربيعي لمتوسط مربعات الخطأ (RMSE) Root Mean Square Error

$$RMSE = \frac{1}{n} \sqrt{\sum_{t=1}^n |F_t - y_t|^2} \quad (2.4)$$

ج- متوسط القيم المطلقة للخطأ (MAE) Mean Absolute Error

$$MAE = \frac{\sum_{t=1}^n |F_t - y_t|}{n} \quad (2.5)$$

د- وسيط القيم المطلقة للخطأ (MdAE) Median Absolute Error

$$MdAE = \frac{\sum_{t=1}^n |F_t - y_t|}{n} \quad (2.6)$$

تشير Y_t يشير إلى القيمة الفعلية ، تشير F_t إلى قيمة Y_t المتوقعة.

ومن عيوب هذا النوع من مقاييس الخطأ أنه يعتمد على وحدات قياس البيانات، بالتالي تُستخدم فقط عند مقارنة طرق مختلفة على نفس مجموعة البيانات، ولا تُستخدم عند المقارنة بين مجموعات البيانات التي لها مقاييس مختلفة.

أشارت دراسات (Galoppo & Kogan, 2020; Makridakis et al., 2024) إلى أن مقاييس RMSE ، MSE هي الأكثر استخداماً إلى حد كبير بسبب أهميتها النظرية في النمذجة الإحصائية. ومع ذلك، فهي أكثر حساسية للقيم المتطرفة من MAE أو MdAE .

٢٠٢٠٢ مقاييس النسبة المئوية للأخطاء Measures based on percentage errors

تتميز مقاييس النسبة المئوية للأخطاء بأنها لا تعتمد على المقياس، ولذلك تُستخدم بشكل متكرر لمقارنة الأداء المتوقع بين مجموعات البيانات المختلفة. ومن أهم هذه المقاييس:

أ- متوسط نسب القيم المطلقة للخطأ (MAPE) Mean Absolute Percentage Error

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - F_t}{y_t} \right| * 100 \quad (2.7)$$

ب- وسيط نسب القيم المطلقة للخطأ (MdAPE) Median Absolute Percentage Error

$$MdAPE = \text{Median} \left(\left| \frac{y_t - F_t}{y_t} \right| \right) * 100 \quad (2.8)$$

ومن عيوب هذا النوع من المقاييس أنه لا يمكن استخدامها عندما $Y_t = 0$ ، كما أن لها توزيع منحرف عندما تقترب قيمة Y_t من الصفر. وأخيراً، تفرض هذه المقاييس عقوبة أشد على الأخطاء الإيجابية مقارنة بالأخطاء السالبة. ولمعالجة العيوب السابقة، يتم استخدام ما يسمى بالمقاييس "المتماثلة symmetric" كما يلي: (Rob & Koehler, 2006)

• المتوسط المتماثل لنسب القيم المطلقة للخطأ

Symmetric Mean Absolute Percentage Error (sMAPE)

$$sMAPE = \text{Mean} (200|Y_t - F_t| / (Y_t + F_t))$$

• الوسيط المتماثل لنسب القيم المطلقة للخطأ

Symmetric Median Absolute Percentage Error (sMdAPE)

$$sMdAPE = \text{Median} (200|Y_t - F_t| / (Y_t + F_t))$$

٣.٢.٢.٢ مقاييس الأخطاء النسبية Measures based on relative errors

يتم الحصول على مقاييس هذا النوع بقسمة أخطاء النموذج محل التقييم على الخطأ الذي تم الحصول عليه باستخدام طريقة قياسية أخرى للتنبؤ، وغالباً ما تكون طريقة السير العشوائي Random Walk، حيث تساوي F_t قيمة المشاهدة الأخيرة. أي أن الخطأ النسبي r_t يساوي e_t/e_t^* ، حيث تشير e_t^* إلى خطأ التنبؤ الذي تم الحصول عليه من طريقة القياس المعيارية. ومن أهم أمثلة هذا النوع ما يلي: (Makridakis et al., 2024)

أ- متوسط الخطأ المطلق النسبي (MRAE) Mean Relative Absolute Error

$$MRAE = \text{mean}(|r_t|)$$

ب- وسيط الخطأ المطلق النسبي (MdRAE) Median Relative Absolute Error

$$MdRAE = \text{median}(|r_t|)$$

ج- المتوسط الهندسي للخطأ المطلق النسبي

Geometric Mean Relative Absolute Error (GMRAE)

$$GMRAE = \text{gmean}(|r_t|)$$

من عيوب مقاييس الخطأ النسبي، أنه لا يمكن استخدامها عندما $e_t^* = 0$.

٤.٢.٢.٢ المقاييس النسبية Relative measures

يختلف هذا النوع عن النوع السابق في أنه بدلاً من قسمة أخطاء طريقة تقدير معينة على أخطاء طريقة معيارية، يتم قسمة قيمة مقياس معين على مقياس آخر. بفرض أن MAE_b يشير إلى MAE من طريقة القياس المعيارية Benchmark Method، يمكن حساب MAE النسبي كما يلي:

$$RelMAE = MAE/MAE_b$$

وبنفس الطريقة يمكن حساب $RelRMSEs$ ، $RelMAPEs$ وهكذا.

ومن مزايا المقاييس النسبية، أنه يمكن من خلالها مقارنة القدرة التنبؤية لطرق التنبؤ المختلفة، ولذلك تتطلب عدة تنبؤات على نفس السلسلة.

ويعاب على هذه الطريقة أنها تشترط وجود عدة تنبؤات على نفس السلسلة، بالتالي لا يمكن استخدامها لقياس دقة التنبؤ خارج العينة في أفق تنبؤ واحد. (Naaz et al., 2024)

٥.٢.٢.٢ المقاييس الخالية من وحدات القياس Scale-Free Error Metrics

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |y_i - y_{i-1}|} \quad (2.9)$$

اقترحت دراسة Rob & Koehler (2006) مقاييس جديدة تهدف إلى التغلب على أثر اختلاف وحدات القياس وكذلك معالجة أوجه قصور كل من المقاييس النسبية ومقاييس الأخطاء النسبية. ويتم ذلك من خلال قياس الخطأ بناءً على نموذج MAE في العينة من طريقة التنبؤ السير العشوائي. بالتالي، يتم حساب خطأ المقياس Scaled Error وفقاً للمعادلة التالية :

وتوضح المعادلة السابقة أن الخطأ المحسوب مستقل عن مقياس البيانات. ويكون الخطأ المحسوب أقل من واحد إذا نشأ عن تنبؤ أفضل من متوسط التنبؤ المعياري بخطوة واحدة، وعلى العكس من ذلك، يكون أكبر من واحد إذا كانت التوقعات أسوأ من متوسط التنبؤ الساذج بخطوة واحدة المحسوبة في العينة. ووفقاً لذلك يكون متوسط خطأ المقياس المطلق Mean Absolute Scaled Error (MASE) كالآتي:

$$MASE = \text{mean} (|q_t|)$$

وبنفس الطريقة يمكن حساب المقاييس الأخرى مثل RMSSE، MdASE وهكذا.

وأوصت دراسات (Galoppo & Kogan, 2020; Mou et al., 2025) أن تصبح مقاييس الأخطاء غير المعتمدة على وحدات القياس هي المنهج القياسي في مقارنة دقة التنبؤ عبر السلاسل على مستويات مختلفة. حيث أنها مقاييس ذات مغزى، قابلة للتطبيق على نطاق واسع ولا تخضع لمشاكل المقاييس الأخرى التي سبق ذكرها.

وتجدر الإشارة إلى أن هذه المقاييس شائعة الاستخدام في مسابقات التنبؤ العالمية، فعلى سبيل المثال اعتمدت مسابقة التنبؤ الشهيرة M5 في عام ٢٠٢٠ على مقياس RMSSE المرجح (WRMSSE) كأساس لمقارنة القدرة التنبؤية للطرق الإحصائية وطرق تعلم الآلة كما سيتم تناوله في البنود القادمة. (Makridakis et al., 2020)

٣.٠ المقاييس الحديثة للقدرة التفسيرية والتنبؤية

تركز المقاييس الحديثة على مقارنة القدرة التفسيرية والتنبؤية بأفضل أداء ممكن باستخدام نفس المتغيرات التي تمثل العلاقة محل الدراسة، بعبارة أخرى تهتم هذه المقاييس بتحديد الأداء الأمثل أي أقصى قدرة تفسيرية وتنبؤية ممكنة للنموذج. وتتناول الدراسة في هذا الجزء مقياس الحد الأقصى للقدرة التفسيرية للنموذج، كمال النموذج الاقتصادي Completeness of Economic Model وآلية الضبط Cross validation.

٣.١٠٣ مقياس الحد الأقصى للقدرة التفسيرية للنموذج

قدمت دراسة (Apesteguia & Ballester, 2020) مقياساً جديداً لجودة التوفيق الخاصة بنماذج الاختيار العشوائية، أي الحد الأقصى من البيانات التي يمكن التوفيق بينها وبين النموذج.

ولتحقيق هذا الهدف، قسمت الدراسة البيانات إلى جزأين: الأول هو الناتج عن أفضل توصيف للنموذج ويسمى بالعشوائية المتوقعة Predicted Randomness والآخر يمثل سلوك البواقي Residual Behavior. ويتمثل الهدف الأساسي لهذا المقياس في تعظيم نسبة البيانات التي يمكن تفسيرها بواسطة النموذج، أي تعظيم نسبة العشوائية المتوقعة. ويمكن توضيح هذا الاجراء من خلال المعادلة التالية:

$$\rho = \lambda_{(\delta, \epsilon)} \delta + (1 - \lambda_{(\delta, \epsilon)}) \epsilon \quad (3.1)$$

تشير ρ إلى بيانات دالة الاختيار العشوائي Stochastic Choice Function (SCF)، δ تمثل العشوائية المتوقعة للنموذج ($\delta \in \Delta$)، بينما تشير λ إلى نسبة البيانات التي يمكن تفسيرها من خلال النموذج وتتحصر قيمته بين الصفر والواحد الصحيح ($\lambda \in [0, 1]$)، وأخيراً تشير ϵ إلى سلوك البواقي في دالة الاختيار العشوائي. ووفقاً لما سبق، يمكن القول أن الثلاث معلمات $(\lambda, \delta, \epsilon)$ هي معلمات تقسيم البيانات ρ . يتم تحديد الحد الأقصى من البيانات المفسرة من خلال المعادلات التالية:

$$\lambda^* = \max_{\delta \in \Delta} \times \min_{(a, A) \in Q} \frac{\rho(a, A)}{\delta(a, A)} \quad (3.2)$$

$$\delta^* = \arg \max_{\delta \in \Delta} \times \min_{(a, A) \in Q} \frac{\rho(a, A)}{\delta(a, A)} \quad (3.3)$$

حيث $\rho(a, A)$ ، $\delta(a, A)$ احتمالات المشاهدة والتوقع لاختيار البديل a من القائمة A . وتسمى البيانات (a, A) بالبيانات الحرجة Critical Observations.

يعتمد تحديد دالة الاختيار العشوائي للبواقي على العنصرين λ ، ρ ، ويتم حسابها في حالة تحديد الحد الأقصى للبيانات المفسرة كما يلي:

$$\epsilon^* = \frac{\rho - \lambda^* \delta^*}{1 - \lambda^*} \quad (3.4)$$

باستمرار زيادة قيمة λ تنخفض قيمة ϵ حتى تصل لحدود دالة الاختيار العشوائي SCF، ويحدث ذلك عندما $\epsilon(a, A) = 0$. وفي هذه الحالة تصبح قيمة λ تساوي ρ/δ ، بالتالي يتم الوصول للملاحظات التي تخفض نسبة $\rho(a, A)/\delta(a, A)$ إلى أقل حد ممكن، مما يعني تحديد الحد الأقصى من البيانات المفسرة.

٢٠٣ مقياس كمال النموذج الاقتصادي Completeness of Economic Model

اقترحت دراسة (Fudenberg et al., 2021) مفهوماً جديداً لقياس القدرة التنبؤية وهو كمال النموذج الاقتصادي الذي يوضح الحيز المتاح لتحسين القدرة التنبؤية. ولتوضيح الفكرة، قسمت الدراسة خطأ التنبؤ لأي نموذج إلى مصدرين: الأول: الخطأ غير القابل للاختزال Irreducible Error، ويرجع إلى القيود المفروضة على متغيرات النموذج، ويُسمى بالضوضاء الجوهرية أو الفعلية Intrinsic Noise. أما المصدر الثاني، يرجع إلى عوامل متعلقة ببيانات النموذج.

يوفر الخطأ غير القابل للاختزال معياراً مرجعياً لمدى نجاح أي نموذج، ويُستخدم لقياس كمال أي نموذج سلوكي كما يلي:

$$\frac{\epsilon_{naive} - \epsilon_{model}}{\epsilon_{naive} - \epsilon_{irreducible}} \quad (3.5)$$

تشير ϵ_{naive} إلى خطأ التنبؤ خارج العينة out-of-sample error الخاص بالنموذج المعياري، ϵ_{model} خطأ التنبؤ خارج العينة للنموذج، $\epsilon_{irreducible}$ تمثل الخطأ غير القابل للاختزال.

وتوضح المعادلة السابقة أن الكمال هو تخفيض خطأ التنبؤ للنموذج (بالنسبة للنموذج المعياري) مقسوماً على التخفيض الممكن تحقيقه في خطأ التنبؤ. إذا كان مقياس الكمال يساوي (صفر)، معنى ذلك عدم وجود أي تحسن للنموذج مقارنة بالنموذج المعياري. أما إذا بلغ مقياس الكمال (الواحد الصحيح)، دل ذلك على إزالة النموذج جميع أخطاء التنبؤ باستثناء الخطأ غير القابل للاختزال. ووفقاً لدراسة (Fudenberg et al., 2021)، من الممكن أن يكون النموذج مكتملاً بالنسبة للمتغيرات المحددة حتى لو كان التنبؤ ضعيفاً وقيمة R^2 منخفضة.

وأوضحت الدراسة كيفية قياس المفاهيم الواردة في المعادلة السابقة كما يلي:

يُقاس خطأ التنبؤ من خلال $\epsilon_P(f) = E_P[\ell(f(x), y)]$ ، قاعدة التنبؤ المعلمية F_Θ التي تقلل خطأ التنبؤ المتوقع هي:

$$f^*_\Theta = \arg \min_{f \in F_\Theta} \epsilon_P(f) \quad (3.6)$$

الخطأ المتوقع لهذه القاعدة هو $\epsilon_P(f^*_\Theta)$

$$\epsilon_P(f^*) = E_P[\ell(f^*(x), y)] \quad (3.7)$$

الخطأ غير القابل للاختزال: ويعبر عن مقياس الكمال كما يلي :

$$\frac{\epsilon_P(f_{naive}) - \epsilon_P(f^*_\Theta)}{\epsilon_P(f_{naive}) - \epsilon_P(f^*)} \quad (3.8)$$

يعتبر التمييز بين النموذج الكامل والنموذج ذو القدرة التنبؤية الكاملة أمراً هاماً في علم الاقتصاد، حيث من المتوقع وجود قدر من الأخطاء غير قابلة للاختزال في معظم النتائج ترجع لخصائص المتغيرات في النموذج. بعبارة أخرى، من الصعب وجود نموذج اقتصادي ذو قدرة تنبؤية تامة، ولكن يمكن أن يكون كامل نسبياً.

٣.٣ آلية الضبط Cross validation

وهي من أهم تقنيات تعلم الآلة Machine Learning، وهي طريقة لتقييم جودة التوفيق خارج العينة ويتم استخدامها لاختيار النموذج الأنسب. وتهدف أساساً لتجنب التوفيق الزائد أو المنخفض Overfitting أو Underfitting. وسوف نتناول الدراسة شرح مفصل لهذه الأداة في البند السادس.

٤.٠ التنبؤ في نماذج الاقتصاد القياسي التقليدية

يمكن تقسيم نماذج الاقتصاد القياسي إلى ثلاث مجموعات أساسية هي النماذج الخطية المعتمدة على فترات الإبطاء، مناهج التكامل المشترك وأخيراً نماذج الانحدار الذاتي المشروطة بعدم تجانس البيانات. وسوف نركز الدراسة على نماذج السلاسل الزمنية باعتبارها الأكثر استخداماً من جانب الدراسات التطبيقية.

٤.١٠٤ النماذج الخطية المعتمدة على فترات الإبطاء

ومن أهم هذه النماذج الانحدار الذاتي والمتوسط المتحرك.

٤.١٠٤.٠ التنبؤ وفقاً لمنهجية بوكس – جينكنز Box-Jenkins Methodology

تم تقديم منهجية Box & Jenkins في عام ١٩٧٠ والتي تُعد من أهم مناهج تحليل السلاسل الزمنية. وتُستخدم هذه المنهجية لتقدير نماذج الانحدار الذاتي والمتوسطات المتحركة (ARMA) Autoregressive Moving Average أو نماذج الانحدار الذاتي والمتوسط المتحرك Autoregressive Integrated Moving Average (ARIMA) بهدف الحصول على أفضل توفيق Best Fit لنموذج السلاسل الزمنية. أي أن نماذج ARIMA تجمع بين نماذج الانحدار الذاتي والمتوسطات المتحركة.

تفترض نماذج ARMA استقرار السلاسل الزمنية، أما في حالة السلاسل غير المستقرة كما هو الحال في معظم المتغيرات الاقتصادية، فيجب تحديد درجة تكامل هذه السلاسل أي الفروق (d) التي تحول هذه السلاسل إلى سلاسل مستقرة. وبإضافة الفروق يتحول نموذج ARMA(p,q) إلى نموذج ARIMA(p,d,q) ويُسمى نموذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة Autoregressive Integrated Moving Average (ARIMA) وهو من أكثر نماذج السلاسل الزمنية استخداماً. ويتم تقدير نماذج ARIMA من خلال أربع خطوات وهي التعرف، التقدير، الفحص والتنبؤ. (McCloskey & Remor, 2025)

٢٠١٠٤. التنبؤ باستخدام نموذج متجه الانحدار الذاتي (VAR) Vector autoregression

يرجع الفضل في تقديم هذا النموذج لدراسة Sims (1980)، وتُعرف منهجية VAR بأنها نظام يتكون من مجموعة من المتغيرات يوجد بينهم تأثير متبادل، أي أن جميع المتغيرات داخلية Endogenous ودالة لجميع المتغيرات الأخرى في نفس فترات الإبطاء. ويترتب على ذلك أن نظام VAR يتكون من عدد من المعادلات يتساوى مع عدد المتغيرات وأن كل معادلة في النظام تشمل نفس المتغيرات.

أما من حيث القدرة التنبؤية، يتميز هذا النموذج بأنه أفضل في كثير من الحالات من نموذج المعادلات الانية المعقد. بافتراض أن نموذج VAR يحتوى على متغيرين فقط Bivariate، يمكن كتابة النموذج كما يلي:

$$Y_{1t} = \alpha_1 + \sum_{j=1}^k \beta_{1j} Y_{1t-j} + \sum_{i=1}^k \delta_{1i} Y_{2t-i} + U_{1t} \quad (4.1)$$

$$Y_{2t} = \alpha_2 + \sum_{j=1}^k \beta_{2j} Y_{1t-j} + \sum_{i=1}^k \delta_{2i} Y_{2t-i} + U_{2t} \quad (4.2)$$

تعرض نموذج VAR للعديد من الانتقادات أهمها صعوبة تفسير معاملات النموذج، كثرة المتغيرات والمعلومات الناتجة عن زيادة عدد فترات الإبطاء وزيادة عدد المتغيرات، وكذلك عدم الأخذ في الحسبان نتائج النظرية الاقتصادية والدراسات التطبيقية بالإضافة إلى إهمال العلاقات الهيكلية بين المتغيرات. Kilian & Lutkepohl (2017)

- منهجية متجه الانحدار الذاتي الهيكلي Structural Vector Autoregression (SVAR)

يُعد منهج SVAR تطويراً لمنهج VAR للتغلب على الانتقادات التي تعرض لها في دراسة Sims (1980). ومن أهم مزايا منهج SVAR الأخذ في الاعتبار التفاعل بين المتغيرات الداخلية وكذلك تقدير الاستجابات للصدمات الهيكلية من البيانات التجريبية. كما تستخدم نماذج SVAR القيود على أساس النظرية الاقتصادية ونتائج الدراسات التطبيقية لتحديد النظام والحصول على التفسير الاقتصادي لدالة الاستجابة للصدمات Kilian & Lutkepohl (2017).

كما يُعد منهج SVAR الطريقة المناسبة لمعالجة قضايا المشاكل الداخلية Endogeneity والسببية التي تعتبر واحدة من أكثر القضايا إثارة للجدل في الدراسات التطبيقية، ودراسة الآثار الديناميكية لأثر المتغير المستقل على المتغيرات التابعة.

- استجابة الصدمات الهيكلية Structural Impulse Responses

تستخدم دالة استجابة الصدمات (النبضات) للتنبؤ بآثار الصدمات الهيكلية على المتغيرات الداخلية في نظام SVAR عندما تحدث صدمة لحد الخطأ. كما توضح نوع الاستجابة (سلبية أو إيجابية) والفترة المستقبلية اللازمة لهذه التأثيرات وأيضاً كيفية استجابة المتغيرات الداخلية للصدمات سواء التي تحدث لها أو للمتغيرات الأخرى. أي استجابة المتغيرات الداخلية عند حدوث صدمة لأحد المتغيرات بمقدار وحدة انحراف معياري وذلك لفترات مستقبلية معينة.

- تحليل التباين الهيكلي Structural Variance Decomposition Analysis

يهدف تحليل التباين لتوضيح الأهمية النسبية لكل صدمة من صدمات النظام في تفسير التباين والتقلبات المتوقعة للمتغير نفسه والمتغيرات الأخرى وذلك في إطار SVAR.

٢٠٤. التنبؤ باستخدام منهجيات التكامل المشترك ونماذج تصحيح الخطأ

يُقصد بالتكامل المشترك Cointegration وجود علاقة توازنية بين السلاسل الزمنية في الأجل الطويل، على الرغم من وجود اختلال في الزمن القصير. فهو ينظر إلى هذه العلاقات التوازنية حتى وإن احتوت كل سلسلة زمنية على اتجاه عام عشوائي (عدم الاستقرار)، لأنه في المدى الطويل ستتحرك هذه السلاسل في تقارب عبر الزمن ويكون الفرق بينهم ساكناً. تم تقديم هذا المفهوم لأول مرة في دراسة Engle & Granger (1987)، ثم قام بتطويره Johansen (1991) والذي قدم نموذج VECM، ثم نموذج الانحدار الذاتي للفجوات الزمنية الموزعة ARDL الذي صاغه Pesaran et al. (2001).

تتميز هذه النماذج بأنها تهتم بالعلاقة في الأجلين الطويل والقصير وتقدير الفترة اللازمة لتصحيح انحرافات الأجل القصير بناءً على قيمة معامل تصحيح الخطأ.

٣٠٤. نماذج الانحدار الذاتي المشروطة بعدم تجانس البيانات ARCH ، GARCH

تهدف نماذج الانحدار الذاتي المشروطة بعدم تجانس البيانات Autoregressive Conditional Heteroskedasticity (ARCH) & (GARCH) إلى نمذجة التباين Variance. ويكثر استخدامها في نماذج البيانات المالية التي تتمتع بدرجة عالية من التقلبات Volatility، حيث يهتم المستثمر بدراسة عدم التأكد Uncertainty بجانب اهتمامه بالتنبؤ بالعائد المتوقع للأسهم في سوق المال.

ويرجع الفضل في ظهور نموذج ARCH إلى Robert Engle (1982) في دراسته عن تباين التضخم في المملكة المتحدة، أما نموذج Generalized ARCH (GARCH) فقد اقترحه Bollerslev عام ١٩٨٦، وقد أدت هذه النماذج إلى حدوث تحول كبير في الاقتصاد القياسي.

١٠٣٠٤. نموذج ARCH

قام Engle بصياغة هذا النموذج لمعالجة مشكلة التقلبات أو عدم الثبات في السلاسل الزمنية المالية والذي كانت تعاني منه نماذج ARMA. تتم صياغة النموذج على أساس الانحدار الذاتي للتباين الشرطي بمعنى أن تباين حد الخطأ الحالي يكون تابعاً لحدود الخطأ المربعة للفترة السابقة كما يلي:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 \quad (4.3.1)$$

وأشارت دراسة Edward (2011) إلى أن من عيوب هذا النموذج أن التوسع في قيمة (q) قد ينتج عنه أن تكون قيم α سالبة وهو ما يتناقض مع إحدى فرضيات النموذج، وتم التغلب على هذه المشكلة بصياغة نموذج GARCH.

٢٠٣٠٤ نموذج GARCH

قام Engle & Bollerslov (1986) بصياغة نموذج الانحدار الذاتي المعمم المشروط بعدم (GARCH) من خلال إضافة حدود الانحدار الذاتي لنموذج ARCH ليصبح النموذج بالصيغة الآتية:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (4.3.2)$$

وتبدأ عملية التنبؤ بالخطوة الأولى: التشخيص، ويتم فيها تحويل السلسلة الزمنية غير المستقرة إلى سلسلة مستقرة. وتتمثل الخطوة الثانية في اختبارات وجود تأثير ARCH و GARCH للتعرف على وجود مشكلة عدم تجانس تباين الخطأ العشوائي. ومن أهم الاختبارات المستخدمة في هذا الشأن هي اختبار Ljung-Box من خلال حساب معاملات الارتباط الذاتي للبواقي، اختبار ARCH والذي يستند على مضاعف لاجرانج Lagrange Multiplier والذي يتميز بسهولة حسابه واشتقاقه، اختبار McLeod-Li لاختبار التأثيرات اللاخطية في بيانات السلسلة الزمنية.

وتختص الخطوة الثالثة بتقدير معاملات نموذج GARCH باستخدام طريقة الامكان الأعظم Maximum Likelihood Method كما يلي:

$$L(y_t/\Theta) = -T/2 \log(2\pi) - 1/2 \sum_{t=1}^T \log \sigma_t^2 - 1/2 \sum_{t=1}^T (\varepsilon_t^2 / \sigma_t^2) \quad (4.3.3)$$

أما الخطوة الرابعة فيتم خلالها فحص ملائمة النموذج المقدر، وذلك بفحص سلسلة البواقي القياسية والمربعة. ويتم استخدام اختبار Ljung-Box على سلسلة البواقي القياسية بالنسبة لمعادلة المتوسط، وعلى مربع سلسلة البواقي القياسية بالنسبة لمعادلة التباين. وتتم عملية التنبؤ باستخدام طريقة التنبؤ داخل العينة In Sample Forecasting. وأخيراً يتم استخدام عدد من المعايير لاختبار دقة التنبؤ مثل (MAE)، (MAPE)، (RMSE).

تعرضت نماذج ARCH & GARCH للعديد من الانتقادات خاصة فيما يخص علاقة مربع الخطأ العشوائي مع التباين الشرطي. أشارت دراسات (Nelson, 1991; Cao & Tsay, 1992) إلى أن العلاقة السابقة تتحقق فقط عندما تكون الصدمات لها نفس الإشارة وحجم التأثير، أما إذا اختلفت إشارة وحجم التقلبات فلا تستطيع هذه النماذج أخذها في الاعتبار.

وأمام هذه الانتقادات، ظهر العديد من النماذج للتغلب على أوجه القصور السابق ذكرها، ويُطلق على هذه النماذج عائلة GARCH. وتهدف هذه النماذج لاستيعاب مختلف التأثيرات السلبية والايجابية للصدمات، ويتمثل وجه الخلاف الرئيس بينها وبين نموذج ARCH في التخلي عن فرضية التماثل symmetric المرتبطة بالتباين الشرطي. ويمكن تناول أمثلة من هذه النماذج على الوجه التالي:

أ- نموذج GARCH-M

قدمت دراسة Engle & Robins (1987) نماذج GARCH in Mean وفيها يكون التباين الشرطي متغيراً مفسراً للمتوسط الشرطي. ويعتبر هذا النموذج من أهم أدوات التحليل المستخدمة في الاقتصاد القياسي والمعنية بتحليل بقياس العلاقة بين العائد والمخاطرة في ظل تعرض السوق لصدمات سلبية. ويمكن صياغة النموذج على الوجه التالي:

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}^2 \quad (4.3.4)$$

وتعبر h_t عن التباين الشرطي، α_0 ، α_i ، β_j أعداد حقيقية

ب- نموذج IGARCH

ويُسمى بنموذج GARCH التكاملی Integrated GARCH وقدمته دراسة Engle & Bollerslev (1986)، ويتعلق بوجود جذر الوحدة في معادلة التباين الشرطي مما يفيد بأن كل صدمة يتعرض لها التباين الشرطي الحالي ستؤثر على القيم المستقبلية. وتتم صياغة هذا النموذج على الوجه التالي:

$$h_t = \alpha_0 + \sum_{i=1}^Q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}^2 \quad (3.3.5) \quad \alpha_0 > 0, \alpha_i \geq 0, \beta_j \geq 0$$

ويشترط في نموذج IGARCH:

$$\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j = 1$$

ويكون النموذج مستقراً من الرتبة الثانية في حالة:

$$\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j < 1$$

ج- نموذج Exponential GARCH (EGARCH)

طور هذا النموذج (Nelson, 1991) والذي اهتم بالتغير غير المتماثل Asymmetries للتباين في دراسة عائد الأصول المالية. وتقوم هذه النماذج بإدخال اللوغاريتم على التباين الشرطي، بالتالي إمكانية نمذجة مختلف التأثيرات السلبية والإيجابية للصدمات على التباين الشرطي. وتكتب معادلة النموذج EGARCH(p,q) على النحو التالي:

$$\text{Log}(\sigma_t^2) = \omega + \sum_{j=1}^q \beta_j \log(\sigma_{t-j}^2) + \sum_{i=1}^p \alpha_i \frac{\varepsilon_{t-i}}{\sigma_{t-i}} + \sum_{k=1}^r \gamma_k \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \quad (3.3.6)$$

د- نماذج Threshold GARCH (TGARCH)

وتُعرف بنماذج ARCH ذات الحدود والذي قدمته دراسة (Engle & Bollerslev, 1986) ثم قامت دراسة (Rabemananjara & Zakoian, 1991) بتعميمها. ويهدف هذا النموذج إلى التفرقة بين الصدمات السلبية والإيجابية في أسواق المال وهو ما يتجاهله نموذج ARCH ونموذج GARCH. فوفقاً لهذين النموذجين، يكون للصدمات السلبية نفس الأثر (التمائل) للصدمات الإيجابية. ويتنافى هذا الأمر مع واقع سوق المال، حيث يكون للصدمات السالبة (الأخبار السيئة) أثر أكبر على مخاطر الأسهم مقارنة بالصدمات الإيجابية (الأخبار الجيدة). وتُصاغ معادلة نموذج TGARCH (p,q) كما يلي:

$$h^{1/2}_t = \alpha_0 + \sum_{i=1}^Q \alpha_i^+ \varepsilon_{t-i}^+ + \sum_{i=1}^q \alpha_i^- \varepsilon_{t-i}^- + \sum_{j=1}^p \beta_j h_{t-j} \quad (4.3.7)$$

$$\alpha_0 > 0, \alpha_i^+ \geq 0, \alpha_i^- \geq 0, \beta_j \geq 0$$

تعبر α_i^+ عن تأثير الأخبار الجيدة، بينما تمثل α_i^- تأثير الأخبار السلبية.

٥. أوجه قصور نماذج الاقتصاد القياسي في التنبؤ الاقتصادي

أثبتت الدراسات التجريبية وجود قصور في القدرات التنبؤية لنماذج الاقتصاد القياسي التقليدية، ظهر ذلك بوضوح من نتائج مسابقات التنبؤ M Competition وغيرها من الدراسات المهمة بمقارنة طرق التنبؤ والتي سيتم تناولها في البنود القادمة. أشارت دراسات (Mahmud & Mohammed, 2021; Uddin et al., 2025) أن من أهم عيوب النماذج التقليدية أنها محدودة وغير قادرة على التعامل مع العديد من مشاكل العالم الحقيقي خاصة التنبؤ بالأزمات الاقتصادية، لا يمكنها معالجة البيانات المفقودة وأنها غير مناسبة للتنبؤ في الأجل الطويل.

كما أشارت دراسة (Nicolas, 2020; Liang et al., 2025) إلى أن نماذج الاقتصاد القياسي التقليدية فشلت في التعامل مع كثير من التحديات خاصة الأزمات المالية العالمية وظهر ذلك في فشل التنبؤ بالأزمات الاقتصادية العالمية منها أزمة عام ٢٠٠٨. وأرجعت الدراسة ذلك إلى أن الاقتصاد القياسي الخطي واجه كثير من التحديات تتعلق بالتعقيد الاقتصادي والذي يلعب دوراً هاماً في الاقتصاد الكلي ومن أهمها عدم الخطية في سلوك الكثير من متغيرات الاقتصاد الكلي. كذلك وجود تغييرات هيكلية تؤدي إلى تغير توزيعات الاحتمالات بمرور الوقت، في حين تفترض النماذج القياسية للاقتصاد القياسي وجود علاقات مستقرة وتفترض أن توزيع البيانات لا يتغير طالما لم يتم تحديد الفواصل الهيكلية بشكل صريح.

أوضحت دراسة (Jung et al., 2018; Yemetset al., 2025) ، أن معظم نماذج التنبؤ التقليدية للمتغيرات الاقتصادية تعتمد على توفيق البيانات لعلاقة محددة مسبقاً بين متغيرات الإدخال ومتغير الإخراج (الذي سيتم توقعه). وبالتالي تفترض هذه النماذج عملية عشوائية تقوم عليها العلاقة الحقيقية بين المتغيرات محل الدراسة. في مثل هذه الحالات ، يمكن أن يكون أداء النموذج جيداً داخل العينة بينما يكون الأداء غير جيد في حالة تطبيق النموذج على بيانات جديدة وهو ما يعرف بالتوفيق الزائد Overfitting.

وفي هذا الصدد، أشارت دراسة (Tiffin, 2016; Sivakumar, 2025) إلى أن الاقتصاد القياسي يركز بشكل عام على التفسير، مع الاهتمام الخاص بقضايا السببية. يتم تقييم النموذج الجيد في هذا الإطار غالباً على أساس المعنوية الإحصائية وملاءمة النموذج. بعبارة أخرى أن نماذج الاقتصاد القياسي تركز بشكل كبير على قابلية النموذج للتفسير وليس دقة النموذج وقدرته التنبؤية.

٦. المناهج الحديثة للتنبؤ الاقتصادي : نماذج تعلم الآلة Machine Learning

أشارت دراسات (Ciaburro & Iannace, 2021; Verona, 2025) إلى أن أساليب تعلم الآلة ML أصبحت من أهم أدوات اختيار النماذج والتنبؤ الاقتصادي. وساعد على هذا الاتجاه توفر مجموعات هائلة من البيانات في عصر البيانات الضخمة Big Data ، وهو ما أدى إلى الحصول على تنبؤات موثوقة وقوية.

أوضحت دراسات (Schnaubelt, 2019; Utama & Firinda, 2024) أسباب تزايد استخدام أساليب التعلم الآلي بشكل متزايد لتنبؤات السلاسل الزمنية الاقتصادية والتجارية. ومن هذه الأسباب، أولاً: القدرة على اختيار المتغيرات ذات الصلة من بين عدد كبير من المتغيرات للإدخال وإهمال المتغيرات غير المهمة. ثانياً: إمكانية التعامل مع مجموعات البيانات عالية الأبعاد، حيث قد

يتجاوز عدد المتغيرات حجم العينة. ثالثاً: لا تضع فروض حول العملية الأساسية التي تولد السلسلة الزمنية، وتكون قادرة على التعامل بشكل جيد مع الديناميكيات غير الخطية. وللأسباب السابقة، ترتفع قدرتها على التعميم على البيانات غير المرئية. وقد ثبت أنها تتفوق في الأداء على نماذج السلاسل الزمنية الكلاسيكية لمهام التنبؤ المختلفة.

عرفت دراسة (Ricardo et al. (2020) تعلم الآلة بأنه "مزيج من خوارزميات الكمبيوتر الآلية مع الأساليب الإحصائية القوية لتعلم واكتشاف الأنماط الخفية في مجموعات البيانات الكبيرة". ويدل التعريف السابق على أن تعلم الآلة يركز بصفة أساسية على نظرية التعلم الإحصائي Statistical Learning Theory.

ويتكون تعلم الآلة من عنصرين أساسيين: الأول هو طريقة التعلم، حيث يتم استخدام البيانات لتحديد أفضل توفير لمتغيرات الإدخال. ويتمثل العنصر الثاني في تحديد خوارزمية تحدد العلاقة بين المدخلات (المتغيرات المستقلة) والمخرجات (Jung. et al. (2018).

يمكن تقسيم أساليب تعلم الآلة إلى ثلاث مجموعات رئيسية: التعلم تحت الإشراف Supervised learning، والتعلم غير الخاضع للإشراف Unsupervised learning، والتعلم المعزز Reinforcement Learning. ويتعلق النوع الأول بالمشكلات التي يتم فيها تحديد المخرجات المطلوبة من نموذج معين، أي المتغيرات التابعة بوضوح. وتندرج النماذج الاقتصادية القياسية التقليدية (القائمة على الانحدار مثل OLS) ضمن فئة التعلم الخاضع للإشراف، حيث تحدد تأثير سلسلة من المتغيرات المستقلة على واحد أو أكثر من المتغيرات التابعة المعروفة. ويكثر استخدام هذا النوع في التطبيقات الاقتصادية والمالية.

١٠٦. تقنيات أساسية لتعلم الآلة

١٠٦.١. آلية الاختبار وضبط المعاملات المتلى Cross Validation

تتشترك معظم خوارزميات التعلم الآلي في عدد من الإجراءات العملية لتجنب ما يسمى بظاهرة الإفراط في التوفيق Over-Fitting. ويقصد به التعميم المفرط لعلاقة المدخلات والمخرجات المقدرة، حيث يرتفع أداء النموذج بالنسبة للبيانات التي تم تدريبه عليها، ومع ذلك قد يؤدي أداءً ضعيفاً إذا تم تطبيقه باستخدام بيانات جديدة.

أشارت دراسات (Schnaubelt, 2019; Makridakis et al., 2020; Jin, 2024) إلى أن آلية الضبط Cross Validation تعتبر أداة جوهرية في تعلم الآلة لتحديد المعاملات المتلى Hyperparameters للخوارزمية المستخدمة لتحسين القدرة التنبؤية للانحدار. وهي طريقة لقياس الأداء المحتمل خارج العينة Out-Of-Sample باستخدام البيانات الموجودة، ويمكن من خلالها ضبط معاملات النموذج المختلفة مثل عدد الأشجار المطلوب في خوارزمية شجرة القرار، والمعاملات α ، λ في نموذج الشبكة المرنة، وعدد العقد والطبقات في الشبكة العصبية، وذلك بهدف تخفيض دالة خطأ التنبؤ إلى أقل ما يمكن.

وتعمل هذه الآلية من خلال تقسيم بيانات العينة إلى جزأين: الجزء الأول (الأكبر عادة) يسمى مجموعة التدريب المستخدمة لتدريب خوارزمية معينة وجزء ثانٍ (عادةً ما يكون أصغر) يمثل مجموعة بيانات الاختبار المستخدمة لقياس القدرة التنبؤية للنموذج على بيانات "غير مرئية" Unseen Data. لم يتم تدريب النموذج عليها. لذلك توضع بيانات الاختبار "خارج العينة". وبالتالي يمكن تقييم أي تعميم خلال تطبيق النموذج على هذه البيانات الجديدة. يجب أيضاً تقييم القدرة التنبؤية والأداء عبر خوارزميات التعلم المختلفة من خلال مقارنة مقاييس الخطأ في هذه البيانات خارج العينة لتجنب المقارنة المضللة للنماذج التي تم توفيقها بشكل زائد (Jung et al., Over-Fitted Models, 2018; Stavros, 2024)

وتوجد عدة أنواع لآلية ضبط البيانات أهمها وأكثرها استخداماً K-Fold Cross-Validation. يتم تقسيم مجموعة بيانات التدريب الحالية مرة أخرى إلى عدد من الطيات k وإعادة تقديرها بشكل متكرر. ثم يتم تدريب النموذج عدد من المحاولات Iteration يساوي k. وفي كل محاولة يتم ضبط معلمات النموذج اعتماداً على الأداء الذي يمكن تحقيقه. وكلما كانت قيمة k أعلى، كانت عملية الضبط أو التوليف الناتجة أفضل، ومن الشائع تطبيق ١٠ طيات لتحقيق هذا الهدف. (Richardson et al, 2021, Hao & Sun, 2025)

٢٠١٠٦. التبادل بين التحيز والتباين Bias-Variance Trade-Off

تهدف خوارزميات تعلم الآلة الخاضعة للإشراف إلى تعظيم الدقة التنبؤية خارج العينة معبراً عنها بدالة الخطأ للمتغير المستهدف. تعتبر مشكلة التبادل بين التحيز والتباين Bias-Variance Trade-Off من أهم مشكلات تعلم الآلة. وتنشأ هذه المشكلة بسبب أنه كلما كان النموذج أكثر تعقيداً، كانت جودة التوفيق داخل العينة أفضل. ومع ذلك، بعد تجاوز حد معين، تبدأ جودة التوفيق خارج العينة في التناقص بسبب Overfitting. بعبارة أخرى، النموذج البسيط للغاية سيكون له تباين منخفض وتحيز كبير Underfitting، في حين أن النماذج المعقدة للغاية قد يكون لها تباين كبير وتحيز منخفض Overfitting.

ولتوضيح الفكرة، يمكن تقسيم متوسط مربع الخطأ خارج العينة إلى ثلاثة أقسام هي: التحيز والتباين وحد الخطأ كما يلي: (Nicolas, 2020; Yemets, 2025)

يتم حساب التحيز كما يلي:

$$E[(y - \hat{f}(x))^2] = \text{Bias}(\hat{f}(x))^2 + \text{Var}[\hat{f}(x)] + \sigma^2 \quad (6.1)$$

$$\text{Bias}(\hat{f}) = E[\hat{f} - f] \quad (6.2)$$

كما يتم حساب التباين كما يلي:

$$\text{Var}[\hat{f}] = E[(\hat{f} - E(\hat{f}))^2] \quad (6.3)$$

المصطلح الأخير σ^2 هو الجزء غير القابل للاختزال من الخطأ.

يعتمد التعلم الآلي على تقنية Cross-Validation بهدف تجنب Overfitting وضبط مستوى تعقيد النموذج من أجل تحقيق أقصى قدر من الملاءمة خارج العينة. أي تحديد التوليفة المثلى من التحيز والتباين لتحديد الدرجة الصحيحة من تعقيد النموذج وتقليل الخطأ خارج العينة.

٢٠٦. النماذج الخطية : انحدار الشبكة المرنة Elastic Net Regression

طبقت دراسات كثيرة خوارزمية الشبكة المرنة في مجال التنبؤ بالمتغيرات الاقتصادية الكلية من أهمها (Tiffin, 2016; Jung et al., 2018; Ricardo, 2020; Hossain et al., 2025). يجمع انحدار الشبكة المرنة بين انحدار ريدج Ridge Regression وانحدار LASSO وهما شكلان من أشكال الانحدار المعاقب Penalized Regression لتحسين انحدارات المربعات الصغرى العادية (OLS).

يتشابه انحدار ريدج مع انحدار OLS في هدف تدنية مجموع مربعات البواقي (RSS)، ويتميز عنه من خلال محاولة تقليل عقوبة الانكماش الإضافي الذي يتناقص عندما تقترب معاملات الانحدار المقدرة من الصفر. وعند تخفيض كل من مجموع مربعات البواقي والعقوبة للحد الأدنى، تتحقق النتيجة المثلى من خلال تقليص معاملات الانحدار المرتبطة فقط، ويمكن التعبير عن مشكلة التدنية على النحو التالي: (Richardson et al (2021)

$$\hat{\beta} = \arg \min_{\hat{\beta}_j} \left[\underbrace{\sum_{i=1}^n (Y - X\hat{\beta})^2}_{\text{RSS}} + \lambda \underbrace{\sum_{j=1}^P (\hat{\beta}_j)^2}_{\text{Ridge penalty}} \right] \quad (6.4)$$

تشير n إلى عدد المشاهدات، p عدد المتغيرات المستقلة. تتحدد عقوبة الانكماش بقيمة المعلمة λ والتي تتحدد قيمتها المثلى باستخدام Cross-Validation. بشكل عام، سيؤدي ارتفاع λ إلى انكماش أكبر لمعاملات الانحدار لتقترب من الصفر، ولكنها لا يمكن أن تصل إلى الصفر، بالتالي لا يمكن استخدامه لاختيار المتغيرات.

بالمثل يمكن التعبير عن مشكلة التدنية في نموذج LASSO كما يلي:

$$\hat{\beta} = \arg \min_{\hat{\beta}_j} \left[\underbrace{\sum_{i=1}^n (Y - X\hat{\beta})^2}_{\text{RSS}} + \lambda \underbrace{\sum_{j=1}^P |\hat{\beta}_j|}_{\text{LASSO}} \right] \quad (6.5)$$

يختلف انحدار LASSO عن انحدار ريدج في إمكانية وصول المعاملات للصفر، عندما تكون معلمة الضبط λ كبيرة بما يكفي. أي يتضمن LASSO عنصراً من اختيار المتغير Variable Selection، يؤدي للوصول لنموذج يحتوي على عدد أقل من المتغيرات المفسرة.

تجمع خوارزمية انحدار الشبكة المرنة بين النموذجين وتنظم حجم العقوبة من خلال المعلمة λ من المعادلتين (١) و (٢):

$$\hat{\beta} = \arg \min_{\beta_j} \left[\underbrace{\sum_{i=1}^n (Y - X\hat{\beta})^2}_{\text{RSS}} + \lambda \underbrace{\sum_{j=1}^P [(1 - \alpha)(\hat{\beta}_j)^2 + \alpha|\hat{\beta}_j|]}_{\text{Ridge LASSO}} \right] \quad (5.6)$$

يحدد α الأوزان النسبية للعقوبتين ويتم تحديده من خلال Cross-Validation ، كذلك المعلمة λ .

ومن أهم مزايا انحدار الشبكة المرنة الكفاءة الحسابية العالية ، المرونة في حالة وجود ارتباط خطي متعدد بين المتغيرات المستقلة ودمج كل من تقليل الأبعاد واختيار المتغير في نموذج واحد. أشارت دراسة (Smeeke & Wijler, 2018) إلى أن طرق الانحدار المعاقب هي أكثر قوة في من منهج العامل الديناميكي المعروف. علاوة على ذلك ، من الممكن أن تنتج الشبكة المرنة مخرجات تشير إلى المتغيرات المحددة والأوزان الخاصة بكل منها في النموذج النهائي ، وبالتالي تمكين الفهم الأساسي لعلاقة المدخلات والمخرجات المحددة حسابياً ، وهي ميزة غالباً ما تكون مفقودة من قدرات نماذج تعلم الآلة التي يتم انتقادها إلى حد ما بسبب "طبيعة الصندوق الأسود" (Chakraborty & Joseph, 2017; Stavros, 2024; Sivakumar, 2025)

٣٠٦ . النماذج غير الخطية

١٠٣٠٦ . منهج أشجار الانحدار Regression Trees Approach

أشارت دراسة (Nicolas, 2020; Franck et al., 2023) إلى أن أشجار الانحدار تتميز بفعاليتها من الناحية الحسابية، وتعمل بشكل جيد مع المشكلات التي توجد فيها علاقات غير خطية ، ولذلك تعبر عن الأساليب الهامة للتنبؤ بمتغيرات الاقتصاد الكلي. كما أنها مناسبة تماماً للتعامل مع البيانات المفقودة Missing Data. تتنبأ أشجار الانحدار بقيمة المتغير المستهدف من خلال تعلم قواعد قرار بسيطة "If, Then".

تقسم أشجار الانحدار عينة المشاهدات بشكل متكرر إلى مجموعات فرعية لتقليل التباين داخل المجموعة للمتغير المتوقع مثل نمو الناتج المحلي الإجمالي. وتتمثل نقطة البداية لاختيار الخوارزمية في متغير التقسيم ونقطة التقسيم التي تقلل من تباين المتغير المستهدف ضمن المجموعتين الفرعيتين الناتجتين بناءً على مراعاة جميع المتغيرات. يكرر هذا الإجراء في كل عقدة حتى الوصول إلى العقد النهائية (الأوراق). تشير القيمة في كل عقدة إلى متوسط قيمة المتغير التابع داخل العقدة.

بفرض تقسيم شجرة الانحدار مجموعة المتغيرات المستقلة بكفاءة إلى عدد M مناطق $R_1, R_2, \dots, R_M$. يتم نمذجة المتغير التابع (y) على أنه متوسط المنطقة كما يلي: (Tiffin, 2016; Zhangyin, 2024)

$$\hat{f}(x) = \sum_m \hat{C}_m I(x \in R_m) \quad (6.7) \quad \text{حيث:}$$

$$\hat{C}_m = \text{avg}(y_i | x_i \in R_m) \quad (6.8)$$

من أهم عيوب أشجار الانحدار وجود مشكلة Over fit خاصة مع وجود ارتباط خطي بين المتغيرات، حيث تؤدي النماذج بشكل جيد في عينة التدريب ولكنها تؤدي بشكل ضعيف عند إجراء تنبؤات خارج العينة. والحل الشائع لمواجهة هذه المشكلة هو تقليل درجة تعقيد الشجرة واختيار درجة التعقيد المثالية باستخدام تقنيات Cross-Validation. (Ricardo et al, 2020; Franck et al., 2023)

سنتناول الدراسة نموذجين من أهم نماذج أشجار الانحدار وهما الغابات العشوائية والأشجار المعدلة.

أ- الغابات العشوائية Random Forest

الغابات العشوائية هي تجميع لأشجار الانحدار باستخدام تجميع التمهيدي Bootstrap Aggregation أو التعبئة Bagging. بمعنى آخر، تتخذ خوارزمية RF نهجاً بديلاً لتقليل درجة تعقيد الشجرة، وتسعى إلى تحسين القدرة التنبؤية للنموذج من خلال زراعة العديد من الأشجار (غير المقلمة) والجمع بين النتائج. وتُبنى الشجرة الفردية على عينة عشوائية من مجموعة البيانات، ما يقرب من ثلثي إجمالي المشاهدات، ويُسمى الثلث المتبقي بالمشاهدات خارج الحقيبة (Out-Of Bag (OOB ويمكن استخدامها لقياس دقة الشجرة. يتكرر هذا مئات أو آلاف المرات ويتم حساب متوسط النتائج. (Jung et al., 2018; Oo et al., 2025)

$$\hat{y}_{t+h|t} = \frac{1}{B} \sum_{b=1}^B \left[\begin{array}{c} T_b \\ \sum_{i=1}^n \beta_{i,b} B_{J_{i,b}}(X_t; \theta_{i,b}) \end{array} \right] \quad (6.9)$$

وتجدر الملاحظة أنه على الرغم من أن عدم تقليل أبعاد الأشجار يؤدي إلى زيادة التباين في كل شجرة على حدة، إلا أنه من خلال حساب متوسط النتائج، يمكن تقليل التباين دون زيادة التحيز.

ب- الأشجار المعدلة Adaptive Tree

تم اقتراح هذا المنهج من جانب Nicolas (2020)، وهو منهج جديد لتعلم الآلة مصمم خصيصاً للتنبؤ الاقتصادي. والأشجار التكيفية خوارزمية جديدة تعتمد على أشجار الانحدار التي تعالج العوامل غير الخطية والتغيير الهيكلي في بيانات الاقتصاد الكلي. تنتج الأشجار التكيفية من تعديل تدريجي لأدائها يهدف إلى معالجة التغييرات الهيكلية. يقال إن الخوارزمية "تكيفية" بقدر ما تتكيف مع كمية التغييرات الهيكلية التي تكتشفها في الاقتصاد من خلال إعطاء وزن أكبر للمشاهدات الأحدث. ومن أهم مميزات الأشجار التكيفية التعامل مع البيانات بأبعاد عالية، أي عدد كبير من المتغيرات مقارنة بعدد الملاحظات.

وتشير الدراسة إلى أن التغييرات الهيكلية تؤدي إلى تغيير توزيع البيانات بمرور الوقت، سواء كان ذلك بشكل مفاجئ أو تدريجياً وهو ما يسمى بمفهوم الانجراف. وفقاً لهذا المفهوم، يكون الماضي القريب أكثر تأثيراً على التنبؤ من الماضي البعيد. ومع ذلك، فإن التنبؤ الذي يستخدم التاريخ

الحديث فقط كدليل قد يؤدي إلى نتائج مضللة، فقد يؤدي التعرف على نمط من الماضي البعيد إلى تحسين الدقة في حالة تكرار حدوث هذا النمط. ينتج السلوك التكيفي عن استخدام أوزان متزايدة للمشاهدات الأحدث أثناء تدريب الأشجار المعززة بالتدرج، بدلاً من وضع أوزان متساوية لجميع المشاهدات.

بفرض أن $w(t)$ هو وزن المشاهدة في الزمن t ، $t \in [1, N]$ ، N : عدد المشاهدات. وفقاً لهذه المنهجية، يتم حساب وزن المشاهدة كما يلي:

$$w(t) = e^{-\gamma(1-t/N)} \quad (6.10)$$

ومن خلال اختيار قيمة y المثلى باستخدام تقنية Cross Validation يؤدي تطبيق المعادلة السابقة إلى إعطاء وزن أكبر للمشاهدات الأحدث.

أما عن تقييم القدرة التنبؤية للأشجار المعدلة، فقد قامت دراسة (Nicolas 2020) بمقارنة الأداء باستخدام طريقة محاكاة الوقت الحقيقي للتنبؤ بنمو الناتج المحلي الإجمالي في دول مجموعة الستة (الولايات المتحدة والمملكة المتحدة وفرنسا وألمانيا واليابان وإيطاليا). تشمل مجموعات المعلومات على نفس مجموعة المتغيرات المستخدمة لنماذج مؤشرات منظمة التعاون الاقتصادي والتنمية. توفر عمليات المحاكاة تقييماً لدقة التنبؤ مقارنة بنموذج مؤشر منظمة التعاون الاقتصادي والتنمية ونموذج $AR(1)$. أثبتت النتائج أن خوارزمية Adaptive Trees تتفوق على نموذج مؤشر OECD في المملكة المتحدة، وتتساوى معه في فرنسا واليابان والولايات المتحدة، وأسوأ منه في ألمانيا وإيطاليا. كما تتفوق الأشجار المعدلة بشكل عام على نموذج $AR(1)$. تتفوق الأشجار التكيفية باستمرار على الغابة العشوائية Random Forest والأشجار المعززة بالتدرج Gradient Boosted Trees.

٢٠٣٠٦ الشبكات العصبية Neural Networks

نموذج الشبكة العصبية هو نموذج قادر على تمثيل العلاقات المعقدة. يتكون نموذج الشبكة العصبية من طبقة إدخال تتكون من مجموعة من الخلايا بعدد المتغيرات المستقلة في النموذج. وعدة طبقات مخفية وطبقة الناتج (المخرجات)، ويقصد بالطبقة مجموعة الخلايا في نفس المستوى. يعمل النموذج من خلال أخذ بيانات الإدخال واستخدام الأوزان ومعادلة التفعيل Activation Function لتمريرها إلى عدد N من الطبقات المخفية. يتم ترجيح كل إدخال وتمريره عبر معادلة التفعيل لتحديد قيمة عقدة معينة داخل الطبقة الأولى من الخلايا ويتكرر هذا لكل عقدة في الطبقة الأولى. تصبح كل عقدة من الطبقة الأولى متغير الإدخال الجديد للطبقة الثانية. تتكرر العملية السابقة حتى الحصول على قيمة المتغير التابع. (Mahmud & Mohammed, 2021)

يتم تعيين الأوزان مبدئياً بقيم عشوائية ويتم تحديثها في كل محاولة Iteration باستخدام خوارزمية تسمى الانتشار الخلفي Back Propagation، يتم تقديم بيانات الإدخال بشكل متكرر إلى الشبكة العصبية حيث يتم إنتاج إخراج الشبكة العصبية والإخراج المطلوب.

بفرض وجود نموذج للشبكة العصبية بغرض تعميم نموذج الانحدار الذاتي (AR (p) يتكون من طبقة إدخال وطبقتين مخفية، حيث تحتوى طبقة الإدخال على عدد من الخلايا بعدد فترة إبطاء، يمكن تمثيل النموذج من خلال المعادلات التالية: (Salinas et al., 2020; Juanhua & Xu, 2025)

$$X_t = [y_{t-p}, \dots, y_{t-1}, t]$$

$$Y_t = W_3^t f_2(W_2^t f_1(W_1^t X_t + b_1) + b_2) + b_3 + \varepsilon_t \quad (6.11)$$

حيث $b_1 \in \mathbb{R}^{nh}$ ، بينما الأوزان، $W_1 \in \mathbb{R}^{(p+1)*nh}$ ، $W_2 \in \mathbb{R}^{nh*nh}$ ، $W_3 \in \mathbb{R}^{nh*n0}$ ، $b_3 \in \mathbb{R}^{n0}$ ، $b_2 \in \mathbb{R}^{nh}$ ، f_1 ، f_2 إلى دوال التفعيل Activation Functions للطبقات المخفية. ويمكن التعبير عن المعادلة السابقة بالصورة المختزلة كما يلي:

$$A = \sum X_i W_i + b_q \quad (6.12)$$

تشير A إلى صافي المجموع ، وهو نتيجة تطبيق دالة التفعيل.

٣.٣.٦ . الشبكات العصبية المتكررة Recurrent Neural Networks

الشبكات العصبية المتكررة (RNNs) هي شبكات NN التي تسمح بالتغذية المرتدة بين الطبقات المخفية. وتتمكن RNNs من استخدام الذاكرة الداخلية لمعالجة تسلسل المدخلات، ويمكن صياغة المعادلة الرياضية لها كالتالي: (Javeri et al., 2021; Brahim et al., 2025)

$$H_t = f(H_{t-1}, X_t) \quad (6.13)$$

$$\hat{Y}_{t+h|t} = g(H_t)$$

حيث $\hat{Y}_{t+h|t}$ هو التنبؤ بـ Y_{t+h} للمشاهدات حتى الفترة t ، و f و g هي دوال يتم تعريفها و H_t ما نسميه الحالة (المخفية). من منظور السلاسل الزمنية ، يمكن رؤية RNNs كنوع من نموذج فضاء الحالة غير الخطي Nonlinear State-Space Model.

أشارت دراسة (Ricardo, 2020; Brahim et al., 2025) إلى أن شبكات RNN يمكنها أن تتذكر الترتيب الذي تظهر به المدخلات، ويمكنها أيضاً نمذجة تسلسل البيانات بحيث يمكن افتراض أن كل عينة تعتمد على العينة السابقة ، كما هو الحال في نماذج السلاسل الزمنية. ويمكن صياغة دالة خطأ التنبؤ كالتالي:

$$Q_T(\theta) = \sum_{t=1}^{T-h} (Y_{t+h} - \hat{Y}_{t+h|t})^2 \quad (6.14)$$

تشير (θ) إلى متجه المعلمات المطلوب تقديرها.

أشارت دراسات كثيرة إلى القدرة التنبؤية العالية للشبكات العصبية المتكررة ، حيث أشارت دراسة (Makridakis et al., 2018) . إلى أن النماذج الأفضل أداءً في منافسة M4 هي الطريقة الهجين التي تجمع بين التمهيد الأسّي exponential smoothing والشبكات العصبية المتكررة.

٧. مقارنة القدرة التنبؤية والتفسيرية للنماذج التقليدية ونماذج انحدار تعلم الآلة

أثبتت دراسات (Chen et al., 2025; Juanhua & Xu, 2025; Oo et al., 2025; Kabiret al., 2025) تفوق نماذج تعلم الآلة والتعلم العميق مثل Transformers و LSTM و GRU على مناهج الاقتصاد القياسي التقليدية في التنبؤ بالمتغيرات الاقتصادية الكلية وأهمها الناتج المحلي الإجمالي والتضخم، بالإضافة لقدرتها الفائقة على نمذجة العلاقات غير الخطية والمعقدة. وفي دراسة (Uddin et al., 2025) عن تعزيز التنبؤ بالمخاطر المالية وتحسين المحفظة باستخدام تقنيات تعلم الآلة، توصلت الدراسة إلى تفوق LSTM و Transformer في دقة التنبؤ بالمخاطر.

قامت دراسة (Seifipour & Azadeh, 2025) بتطبيق الشبكات العصبية الاصطناعية في العلوم الاقتصادية والمالية، وأثبتت الدراسة تفوق الشبكات العصبية على النماذج التقليدية في مختلف المهام الاقتصادية.

قامت دراسة (Franck et al., 2023) بالتنبؤ بالناتج المحلي الإجمالي لمدغشقر باستخدام Random Forest و XGBoost، واستنتجت الدراسة تفوق هذه الخوارزميات على نماذج الاقتصاد القياسي التقليدية، كما أنها توفر تنبؤات أداء اقتصادي دقيقة وفي الوقت المناسب. كما أشارت دراسة (Stavros, 2024) إلى تفوق النموذج D الذي يعتمد على خوارزميات تعلم الآلة على النماذج الأخرى في دقة التنبؤ بالناتج المحلي الإجمالي، بالإضافة إلى أنه يوفر تنبؤات موثوقة وفي الوقت المناسب للناتج المحلي الإجمالي. كما أوضحت دراسة (Jung et al., 2018) أن خوارزميات تعلم الآلة، مثل Elastic Net و Super Learner تتفوق على النماذج الإحصائية التقليدية في دقة التنبؤ.

قارنت دراسة (Richardson et al., 2021) دقة التنبؤ بين خوارزميات تعلم الآلة والنماذج الإحصائية التقليدية فيما يتعلق بنمو الناتج المحلي الإجمالي في نيوزيلندا. شملت خوارزميات تعلم الآلة انحدار الجيران الأقرب (K-Nearest Neighbors Regression (KNN)، الأشجار المعززة (Boosted Trees (BT)، انحدار الشبكة المرن (ENET)، انحدار الدعم الآلي Support Vector Machine Regression (SVM) الشبكة العصبية NN.

أثبتت الدراسة أن غالبية نماذج ML تنتج تنبؤات آنية تفوق معيار AR البسيط، حيث نتج عن استخدام النماذج عالية الأداء مثل SVM، ENET و NN انخفاض متوسط أخطاء التنبؤ الآني بحوالي ١٦-١٨٪ مقارنة بمعيار AR. وكان نظام الدعم الآلي والشبكات العصبية أفضل أداء حيث بلغت نسبة RMSE الخاصة بها إلى نظيرتها في AR حوالي ٨٢٪ و ٨٢,١٪ على الترتيب.

علاوة على ذلك ، يؤدي الجمع بين التنبؤات الآنية لنماذج ML باستخدام أوزان ترجيح مناسبة إلى مزيد من التحسينات في الأداء. كما تتفوق غالبية خوارزميات ML أيضاً على المعيارين الإحصائيين الشائعين الاستخدام، وهما نموذج العامل (FM) Factor Model ونموذج Bayesian VAR (BVAR).

اقترحت دراسة (André et al., 2021) معيار LIBRA وهو معيار تنبؤي يقوم تلقائياً بتقييم وتصنيف طرق التنبؤ بناءً على أدائها في مجموعة متنوعة من سيناريوهات التقييم. يشمل المعيار أربع تطبيقات مختلفة منها الاقتصاد والتمويل، تغطي كل منها 100 سلسلة زمنية غير متجانسة تظهر تنوعاً أعلى بكثير من مسابقات التنبؤ M-Competitions. ويعتمد معيار LIBRA على مقاييس الخطأ: sMAPE، MASE. وشملت الدراسة خمسة من طرق التنبؤ بالسلاسل الزمنية الكلاسيكية (ETS, sARIMA, sNaïve, TBATS, Theta)، وخمسة طرق تعلم الآلة القائمة على الانحدار تتفوق على طرق التنبؤ الكلاسيكية في حالة الجمع بين أكثر من طريقة، بينما تختلف النتيجة في حالة استخدامها بشكل منفرد. وتتفق هذه النتيجة مع نتائج M4-Competition، التي تفيد بأن استخدام طريقة واحدة من تعلم الآلة ينتج عنها خطأ أكبر للتنبؤ، أما في حالة استخدام الطريقة الهجين تختلف النتائج بشكل كبير. (Makridakis et al, 2018)

تعتبر أفضل الطرق لقياس دقة التنبؤ للطرق المختلفة والمقارنة بينها هي ما يعرف بمسابقات التنبؤ Forecasting Competitions. وفي هذا الصدد، أشارت دراسة (Hyndman et al, 2020) إلى أن الهدف من مسابقات التنبؤ هو التقييم التجريبي لدقة طرق التنبؤ، مما يسمح بما يعادل التجربة المستخدمة على نطاق واسع في العلوم المادية. ومن أشهر سلسلة مسابقات التنبؤ هي مسابقات Makridakis والمعروفة باسم M-Competitions، والتي تهدف إلى تحديد أكثر طرق التنبؤ دقة لتحسين دقة التنبؤ للنهوض بنظرية وممارسة التنبؤ. وظهرت هذه المسابقات منذ عام 1982 وتم عقد ست مسابقات آخرها M6 عام 2024. وتتلخص فكرتها في اختيار معيار أو أكثر لقياس دقة التنبؤ واستخراج نتائج كل طريقة باستخدام نفس السلاسل الزمنية ثم مقارنة تلك النتائج بالمعيار المستخدم. (Makridakis et al, 2024)

أشارت دراسات (Onkal, 2020 ; Makridakis et al, 2018) إلى أنه بدأ ظهور طرق تعلم الآلة ضمن المنافسين لأول مرة في M4 عام 2018 والتي جرت باستخدام 100000 سلسلة زمنية. تم استخدام مقياس مركب Comb ليكون أساس عمليات المقارنة بين الطرق المختلفة، وهو عبارة عن المتوسط الحسابي البسيط لنماذج التمهيد الأسّي البسيط والهابط Damped exponential smoothing models و Holt.

وكان من أهم نتائج M4 أن أفضل طرق التنبؤ هي المنهج المختلط hybrid approach الذي يجمع بين طريق إحصائية وطريقة من طرق تعلم الآلة (نموذج التمهيد الأسّي البسيط والشبكة العصبية المتكررة RNN)، حيث كان متوسط sMAPE لهذه الطريقة أكثر دقة بما يقرب من 10٪ من مقياس الأداء المركب Comb المستخدم لمقارنة الطرق المقدمة. ويعتبر ذلك تحسناً كبيراً، حيث كانت أفضل طريقة في مسابقة M3 أكثر دقة بنسبة 4٪ فقط. (Fry Makridakis et al, 2018) & Brundage, 2020;

أشارت دراسة (Makridakis et al, 2018) إلى أن ثانی الطرق من حيث دقة التنبؤ هي الجمع بين سبع طرق إحصائية وطريقة ML واحدة، مع حساب أوزان المتوسط بواسطة خوارزمية ML التي تم تدريبها لتقليل أخطاء التنبؤ. أشارت الدراسة أيضاً إلى أن أداء طرق ML بمفردها كان ضعيفاً، حيث لم يكن أي منها أكثر دقة من معيار Comb المستخدم.

أما بالنسبة لنتائج M5، أوضحت دراسة (Makridakis et al, 2020) أن طرق تعلم الآلة حققت تفوقاً واضحاً على الطرق الإحصائية التقليدية حتى بتطبيق كل منها منفرداً، وذلك باستخدام ٤٢٨٤٠ سلسلة زمنية تمثل مبيعات أكبر شركة بيع بالتجزئة في العالم وهي وول مارت.

وأكدت الدراسة على أن جميع طرق تعلم الآلة كانت أفضل أداءً وبشكل ملحوظ من جميع الطرق الإحصائية التقليدية وذلك باستخدام مقياس WRMSSE. كما أثبتت خوارزمية Light GBM إمكانية الاعتماد عليها بفعالية للتعامل مع العديد من السلاسل المترابطة، حيث حققت الأداء الأفضل متفوقة بأكثر من ١٤٪ مقارنةً بالمعيار الإحصائي. وفي هذا الصدد، أشارت دراسة (Gilliland, 2020) إلى أن طرق التعلم العميق Deep Learning وما توفره من تطبيقات متقدمة وحديثة من ML، أحدثت تحولاً كبيراً في مجال التنبؤ وهو ما يزيد من الدوافع لمزيد من البحث في هذا الاتجاه. كذلك تشير نتائج M6 إلى أن أساليب تعلم الآلة من بين أفضل المشاركات من حيث الأداء. (Makridakis et al, 2024)

قامت دراسة (Jung et al, 2018) باستخدام ثلاث نماذج لتعلم الآلة لتقدير التنبؤ قصير الأجل لنمو الناتج المحلي الإجمالي لسبعة دول متنوعة من الاقتصادات الناشئة والنامية (المكسيك والفلبين وفيتنام). هذه النماذج هي انحدار الشبكة المرنة، الشبكة العصبية المتكررة والمنهج التجميعي Super Learner. أثبتت الدراسة وجود تحسن في الدقة الناتجة من تنبؤات تعلم الآلة على نطاق WEO في سنوات الأزمة المالية العالمية، يتراوح بين ٤٩٪ - ٨٢٪ (حسب الدولة) للتنبؤات ربع السنوية وبين ٤٪ - ٣٨٪ للتنبؤات السنوية. وتتفوق النماذج الثلاث على النماذج الإحصائية التقليدية وهي الانحدار الذاتي (AR)، متجه الانحدار الذاتي (VAR) ونموذج متوسط بايزي Bayesian Averaging. وأخيراً، يتفوق المنهج القائم على المجموعة (المتعلم الفائق) على أساليب تعلم الآلة الأخرى.

وفيما يتعلق بالقدرة التفسيرية، أشار العديد من الدراسات إلى أنه على الرغم من تفوق القدرة التنبؤية لنماذج تعلم الآلة، إلا أنها تعتبر صناديق سوداء يصعب تفسيرها. تُعد الشبكات العصبية المستخدمة في التعلم العميق من أصعب الشبكات التي يمكن فهمها. بالإضافة إلى أنه قد ينحرف أداء نموذج تعلم الآلة أو يتدهور بسبب اختلاف بيانات الإنتاج عن بيانات التدريب. هذا يجعل من الضروري مراقبة النماذج وإدارتها باستمرار لتعزيز قابلية تفسير الذكاء الاصطناعي مع قياس تأثير استخدام هذه الخوارزميات على الأعمال. (Sivakumar, 2025; Juanhua & Xu, 2025; Oo et al., 2025).

وفي ضوء العرض السابق، يرى الباحث أن الفروق بين المنهجين من حيث القدرة التنبؤية تكمن في أن نماذج الاقتصاد القياسي التقليدية تعتمد في الغالب على نماذج خطية تفترض وجود شكل محدد للعلاقة بين المتغيرات، بالتالي ترتفع دقة التنبؤ في حالات معينة أهمها ثبوت العلاقات الخطية، ثبات التباين، عدم وجود ارتباط ذاتي. ولكن تضعف القدرة التنبؤية بشكل كبير عندما تكون العلاقات معقدة أو غير خطية وكذلك التنبؤ بالأزمات الاقتصادية. بينما تتفوق نماذج تعلم الآلة على النماذج التقليدية في الدقة التنبؤية خاصة مع البيانات الضخمة والمعقدة لأنها لا تفترض شكلاً محدداً للعلاقة بين المتغيرات، كما أنها تتميز بمرونة كبيرة وقدرة أعلى في التقاط الأنماط المعقدة وغير الخطية.

أما فيما يتعلق بالقدرة التفسيرية، تتفوق نماذج الاقتصاد القياسي التقليدية على نماذج تعلم الآلة، حيث توفر معاملات Coefficients يمكن تفسيرها بسهولة، كما أنها تسمح باختبار الفرضيات الاقتصادية وتقديم تفسير سببي وتحليل العلاقات. أما نماذج تعلم الآلة فتعمل غالباً كصندوق أسود، حيث يصعب تفسير سبب وصول النموذج للتنبؤ معين. وعلى الرغم من دقة نتائج نماذج تعلم الآلة، إلا أنها تفتقر في كثير من الأحيان إلى وضوح العلاقة بين المتغيرات. بالتالي، إذا كان الهدف من الدراسة هو التفسير وفهم العلاقات الاقتصادية، يُفضل الاعتماد على النماذج الاقتصادية القياسية، أما إذا كان الهدف هو التنبؤ بدقة عالية خاصة مع بيانات ضخمة ومعقدة، فمن الأفضل استخدام نماذج تعلم الآلة. ويرى البحث أنه من الأفضل الدمج بين المنهجين، استخدام تعلم الآلة للتنبؤ، والاقتصاد القياسي للتحليل والتفسير.

وفي هذا الصدد، توصي دراسات كثيرة بضرورة الاعتماد على الذكاء الاصطناعي القابل للتفسير XAI للتغلب على ما يعرف بالصندوق الأسود لنماذج تعلم الآلة، وهو ما سيتم تناوله في الجزء التالي.

٨. الذكاء الاصطناعي القابل للتفسير (XAI)

من أهم التحديات التي تواجه نماذج تعلم الآلة، فهم كيفية وصول الخوارزمية إلى النتيجة وتتبعها. حيث تتحول عملية الحساب بأكملها إلى ما يُعرف باسم "الصندوق الأسود" الذي يستحيل تفسيره حتى من جانب علماء البيانات الذين يُطورون الخوارزمية (Sajid, et al, 2023). وتزداد أهمية الذكاء الاصطناعي القابل للتفسير بشكل خاص في القطاعات عالية المخاطر مثل الرعاية الصحية والمالية، حيث يُعد فهم قرارات الذكاء الاصطناعي أمراً بالغ الأهمية (Zodage et al., 2024).

ويمكن القول أن بداية ظهور مفهوم (XAI) ترجع لدراسة (Van et al, 2004) والتي وصفت قدرة النظام على شرح تصرفات الوحدات التي يتحكم بها الذكاء الاصطناعي في تطبيقات ألعاب المحاكاة. ثم بدأ الاهتمام البحثي في هذا المجال من خلال دراسة (Mueller et al, 2019)، حيث نشرت تحليلاً منهجياً لأساليب الذكاء الاصطناعي وأنظمة تفسيره.

تعرف دراسة (Van et al., 2004) الذكاء الاصطناعي القابل للتفسير Explainable AI بأنه مجموعة من العمليات والأساليب التي يمكن من خلالها فهم النتائج والمخرجات الناتجة عن خوارزميات تعلم الآلة والثقة بها. ويُستخدم لوصف نموذج الذكاء الاصطناعي، وتأثيره المتوقع، وتحيزاته المحتملة. كما يُساعد في تحديد دقة النموذج، ونزاهته، وشفافيته، ونتائجه في عملية اتخاذ القرارات (Zodage et al., 2024). يمكن للذكاء الاصطناعي القابل للتفسير المساعدة على فهم وشرح خوارزميات تعلم الآلة، والتعلم العميق، والشبكات العصبية. ويؤدي ذلك لتعزيز ثقة المستخدم النهائي، وقابلية تدقيق النماذج، والاستخدام الهادف لنماذج تعلم الآلة. بالتالي، إمكانية الوصول إلى آلية صنع القرار الموثوق به وإجراء التعديلات اللازمة. بالإضافة إلى تسريع وقت الحصول على نتائج الذكاء الاصطناعي وتقليل مخاطر وتكلفة حوكمة النموذج. (Rawat et al., 2024)

يمكن تصنيف هذه الأساليب إلى مناهج لاحقة وأخرى سابقة ومن أهمها التفسيرات المحلية غير المستقلة عن النموذج Local Interpretable Model-Agnostic Explanations (LIME)، والتي تشرح تنبؤات المصنفات بواسطة خوارزمية تعلم الآلة. وكذلك تقنيات SHAP، Grad-CAM، Anchors، LRP والنماذج السببية (Holzinger et al., 2020).

كما أشارت دراسة (Rawat et al., 2024) إلى أهمية توافر قابلية التتبع في تقنيات الذكاء الاصطناعي القابل للتفسير، ويتحقق ذلك من خلال تقييد طريقة اتخاذ القرارات وتضييق نطاق قواعد وميزات تعلم الآلة. ومن أمثلة تقنيات الذكاء الاصطناعي (XAI) القابلة للتتبع تقنية DeepLIFT (ميزات التعلم العميق المهمة Deep Learning Important Features)، التي تقارن نشاط كل خلية عصبية بالخلية العصبية المرجعية لها، وتُظهر رابطاً يمكن تتبعه بين كل خلية عصبية مُنشطة، بل وتُظهر أيضاً التبعيات بينهما..

٩. نتائج الدراسة

هدفت الدراسة لاستعراض وتقييم الأساليب الحديثة لقياس القدرة التفسيرية والتنبؤية للنماذج الاقتصادية، وقد خلصت الدراسة إلى النتائج التالية:

- ١- تركز الأساليب الحديثة لقياس القدرة التفسيرية والتنبؤية على قياس الأداء الأمثل للنموذج وليس مجرد تقييم أدائه بأنه جيد أو سيئ.
- ٢- لا توجد طريقة تنبؤ واحدة تقدم أفضل أداء لجميع السلاسل الزمنية، فكل طريقة لها مزاياها وعيوبها ويتوقف اختيار طرق التنبؤ على الحالة التي تُستخدم فيها وطبيعة السلاسل الزمنية محل الدراسة.
- ٣- تعتمد معظم نماذج التنبؤ التقليدية على توفيق البيانات Fitting Data لعلاقة محددة مسبقاً بين المتغيرات المستقلة والمتغير التابع المطلوب التنبؤ به، بالتالي تفترض هذه النماذج عملية عشوائية تقوم عليها العلاقة الحقيقية بين المتغيرات المعنية. على النقيض من ذلك، تعتمد نماذج تعلم الآلة على نهج خوارزمي لإيجاد أفضل دالة لتمثيل العلاقة بين بيانات المدخلات والمخرجات.
- ٤- من أهم عيوب نماذج الاقتصاد القياسي التقليدية عدم القدرة على معالجة مشاكل العالم الحقيقي خاصة التنبؤ بالأزمات الاقتصادية، لا يمكنها معالجة البيانات المفقودة، غير مناسبة للتنبؤ في الأجل الطويل. ويرجع ذلك لأن هذه النماذج تركز بشكل كبير على قابلية النموذج للتفسير وليس دقة النموذج وقدرته التنبؤية.
- ٥- تتفوق غالبية نماذج تعلم الآلة على النماذج الاحصائية التقليدية من حيث القدرة التنبؤية، كما أن المنهج التجميعي أي استخدام مجموعة من نماذج تعلم الآلة يؤدي إلى تحسن دقة التنبؤ بشكل ملحوظ.
- ٦- من عيوب منهج تعلم الآلة انخفاض القدرة التفسيرية، حيث من الصعب شرح العوامل التي تحرك التنبؤات.
- ٧- يمكن أن تعالج تقنيات الذكاء الاصطناعي القابل للتفسير بعضاً من أوجه قصور القدرة التفسيرية لنماذج تعلم الآلة.

٨- يعتبر المنهج المختلط الذي يجمع بين النماذج الإحصائية وخصائص تعلم الآلة أفضل طرق التنبؤ. حيث يمكن من خلال المنهج المختلط الجمع بين القدرة التفسيرية العالية للنماذج الإحصائية والقدرة التنبؤية المرتفعة لمنهج تعلم الآلة.

١٠. التوصيات

بعد العرض السابق يمكن طرح بعض التوصيات والتي يمكن تقسيمها إلى توصيات خاصة بالباحثين وتوصيات لصانعي السياسة الاقتصادية.

أولاً: توصيات خاصة بالباحثين الأكاديميين

- ١- التحديد الدقيق لمتغيرات النموذج بناءً على نتائج النظرية أو الدراسات التجريبية الموثوقة بها. وضرورة الاستعانة بالطرق الحديثة مثل اختيار المتغيرات Variable Selection ، حيث يمثل توصيف النموذج نقطة البداية التي ستبنى عليها باقي المراحل.
- ٢- اختيار النموذج الملائم للظاهرة محل الدراسة بناءً على طبيعة العلاقة بين المتغيرات المفسرة والمتغير التابع. ويمكن الاسترشاد بالنماذج التي اعتمدت عليها الدراسات السابقة في هذا المجال.
- ٣- استخدام أكثر من طريقة للتنبؤ، حيث لا توجد طريقة تنبؤ واحدة تقدم أفضل أداء لجميع السلاسل الزمنية، فكل طريقة لها مزاياها وعيوبها اعتماداً على الحالة التي تُستخدم فيها.
- ٤- الإلمام بطرق التنبؤ الحديثة ذات القدرات التنبؤية العالية ومن أهمها تعلم الآلة وأهم أدواتها مثل Cross Validation وغيرها، ويفضل دراسة البرمجيات اللازمة لتنفيذها.
- ٥- الإلمام بتقنيات الذكاء الاصطناعي القابل للتفسير وأجراء مزيد من الدراسات لتحسين القدرة التفسيرية لنماذج أساليب تعلم الآلة.
- ٦- لا يعنى تفوق أساليب تعلم الآلة من حيث القدرة التنبؤية إهمال الباحثين للنماذج الاقتصادية التقليدية أو أنها فقدت أهميتها. فالنماذج الاقتصادية تتميز بالقدرة التفسيرية العالية وبالتالي فهي الأنسب لتحليل الظواهر الاقتصادية واختبار فروض الدراسات التطبيقية.
- ٧- دمج نماذج الاقتصاد القياسى المعروفة مع خوارزميات تعلم الآلة، حيث أثبتت نتائج مسابقات التنبؤ أنها أفضل الطرق وأكثرها دقة وهي ما تسمى بالطريقة الهجين Hyper Method.

ثانياً: توصيات خاصة بصانعي السياسة

- ١- إنشاء أنظمة الإنذار المبكر خاصة بالتنبؤ الاقتصادي، وتوفير كافة الامكانيات المادية من أنظمة التشغيل والبرمجيات اللازمة والموارد البشرية من اقتصاديين وفنيين وخبراء في الذكاء الصناعى وتعلم الآلة والتعليم العميق. وأن تكون نتائجه أساس عملية اتخاذ القرارات الاقتصادية.

٢- دعم الباحثين في مجال التنبؤ الاقتصادي وتنظيم مسابقات للتنبؤ على غرار مسابقات التنبؤ العالمية يديرها خبراء اقتصاديون، ويمكن تحديد المجالات محل الاهتمام مع توفير بيانات السلاسل الزمنية اللازمة. ويمكن مشاركة الجهات الخاصة المستفيدة من نتائج التنبؤ في التمويل اللازم.

٣- تطوير عملية جمع البيانات التي تستخدم في بناء المؤشرات الاقتصادية، والاهتمام بدقة البيانات المنشورة والتي تمثل المادة الخام لعملية التنبؤ للحصول على نتائج دقيقة مفيدة في صنع القرار. كذلك نشر البيانات المتعلقة بالمؤشرات الاقتصادية الهامة في الوقت المناسب.

قائمة المراجع

1. André,B. et al. (2021), " Libra: A Benchmark for Time Series Forecasting Methods", **In Proceedings of the 2021 ACM/SPEC International Conference on Performance Engineering (ICPE '21), April 19–23, 2021**, Virtual Event, France. ACM, New York, NY, USA, <https://doi.org/10.1145/3427921.3450241>.
2. Apesteguia, J. & Ballester, M. (2020), "Separating Predicted Randomness from Noise", **Economics Working Papers 1757**, Department of Economics and Business, Universitat Pompeu Fabra.
3. Bollerslev et al. (1992), "ARCH modeling in finance: areview of the theory and empirical evidence" , Journal of Econometrics, Vol. 52.
4. Box, G. & Jenkins, G., (1970), **Time Series Analysis: Forecasting and Control**. San Francisco: Holden-Day.
5. Brahim, R. et al., (2025). "Power forecasting using ANN and ELM: A comparative evaluation of machine learning approaches", **Mathematical modelling of engineering problems**, 12 (1), 1-8. <https://doi.org/10.18280/mmep.120101>.
6. Cao, C. & Tsay. R. (1992). " Nonlinear Time-Series Analysis of Stock Volatilities", **Journal of Applied Econometrics**, Vol. 7.
7. Cerqueira, V. et al. (2020), "Evaluating time series forecasting models: an empirical study on performance estimation methods", **Machine Learning**, 109, 10.1007/s10994-020-05910-7.
8. Chakraborty, C. & Joseph, A. (2017), "Machine learning at central banks," **Bank of England working papers 674**, Bank of England.
9. Chen, X. et al., (2025). "Development of per capita GDP forecasting

-
-
- model using deep learning: Including consumer goods index and unemployment rate", **Sustainability**, 17 (3), 843843. <https://doi.org/10.3390/su17030843>.
10. Ciaburro, G.& Iannace, G. (2021), "Machine Learning-Based Algorithms to Knowledge Extraction from Time Series Data: A Review", *Data* 2021, 6, 55. Available at: <https://doi.org/10.3390/data6060055>.
 11. Devore, J. (2016). *Probability and Statistics for Engineering and the Sciences*. Boston, MA: Cengage Learning. ISBN: 978-1-305-25180-9.
 12. Edward, N., (2011). "Modeling and Forecasting using Time Series GARCH Models: An Application of Tanzania Inflation Rate Data", **Master thesis of Science** (Mathematical Modeling) of the university of Dares Salaam, Morocco.
 13. Engle, R. & Bollerslev T. (1986), "Modeling the persistence of conditional variances", **Econometric Reviews**, Vol.5(1).
 14. Engle, R. & Bollerslev T. (1986), "Modeling the persistence of conditional variances", **Econometric Reviews**, Vol.5(1).
 15. Engle, R. & Granger, C. (1987), "Co-integration and Error Xrection: Representation, Estimation, and Testing", **Econometrica**, Econometric Society, vol. 55(2)
 16. Engle, R. (1982), "Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation", **Econometrica**, Vol. 50 (4).
 17. Engle, R.& Robbins, R. (1987), "Estimating Time Varying Risk Premia in the Term Structure: The ARCH-M Model", **Econometrica**, Vol. 55.
 18. Engle, R.& Robbins, R. (1987), "Estimating Time Varying Risk Premia in the Term Structure: The ARCH-M Model", **Econometrica**, Vol. 55.
 19. Franck et al., (2023). "Nowcasting Madagascar's real GDP using machine learning algorithms", **arXiv.org**, doi: 10.48550/arxiv.2401.10255.
 20. Fry, C., & Brundage, M. (2020), "The M4 forecasting competition - A practitioner's view", **International Journal of Forecasting**, vol.36.
 21. Fudenberg, D., et al. (2022), "Measuring the Completeness of Economic Models", Available at: <http://economics.mit.edu/files/20972>.

-
-
22. Galoppo, T. & Kogan, C. (2020), "Measuring prediction accuracy against noisy target values, with application to demand response forecasting", Available at: <https://www.researchgate.net/publication/342612193>
 23. Gilliland, M. (2020), "The value added by machine learning approaches in forecasting" **International Journal of Forecasting**, vol.36.
 24. Hao, J., & Sun, Q. (2025). "An adaptive learning time series forecasting model based on decoder framework", <https://doi.org/10.3390/math13030490>.
 25. Holzinger, A. et al, (2020). Explainable AI Methods - A Brief Overview. **xxAI@ICML**, https://doi.org/10.1007/978-3-031-04083-2_2
 26. Hossain, M. et al., (2025). "Enhanced market trend forecasting using machine learning models: A study with external factor integration", **Journal of global education and research**, 06 (01), 5-12. <https://doi.org/10.55640/business/volume06issue01-02>.
 27. Hu, H. et al., (2025). "Pattern-oriented attention mechanism for multivariate time series forecasting. **ACM Transactions on Knowledge Discovery from Datanull**, <https://doi.org/10.1145/3712606>.
 28. Hyndman, R. et al. (2020), "**forecast: Forecasting functions for time series and linear models**", R package version 8.12.
 29. Javeri, I. et al. (2021). Improving Neural Networks for Time Series Forecasting using Data Augmentation and AutoML, <https://www.researchgate.net/publication/349758704>.
 30. Jin, L., (2024). "Nowcasting GDP using Bayesian shrinkage approach and identifying Implied Volatility Surface using Symbolic Regression", doi: 10.31274/td-20240329-550.
 31. Johansen, S. (1991), "Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models", **Econometrica**, Vol. 59 (6)
 32. Juanhua, M., & Xu, D. (2025). "China's economic growth from a comprehensive analysis perspective: A synergistic application of gra, pca, and gru models. **Journal of economics and management sciences**, 8 (1), p1-p1. <https://doi.org/10.30560/jems.v8n1p1>.
 33. Jung, J. et al. (2018). "An algorithmic crystal ball: forecasts-based on machine learning". **IMF Working Papers**, 18. 1.

10.5089/9781484380635.001.

34. Kabir, M. et al., (2025). "Lstm-transformer-based robust hybrid deep learning model for financial time series forecasting. Sci, 7 (1), 7-7. <https://doi.org/10.3390/sci7010007>.
35. Kilian, L., Lutkepohl, H. (2017), "Structural vector autoregressive analysis (themes in modern econometrics)". **Cambridge University Press**, Cambridge.
36. Kumar, T. et al., (2025). Generative artificial intelligence (gai) for accurate financial forecasting. <https://doi.org/10.1002/9781394271078.ch4>.
37. Liang, F. et al., (2025). Adaprl: Adaptive pairwise regression learning with uncertainty estimation for universal regression tasks. <https://doi.org/10.48550/arxiv.2501.05809>.
38. Mahmud, A.& Mohammed, A. (2021), **A Survey on Deep Learning for Time-Series Forecasting**. 10.1007/978-3-030-59338-4_19.
39. Makridakis, S. et al. (2020), " The M5 Accuracy competition: Results, findings and conclusions", Available At: <https://www.researchgate.net/publication/344487258>.
40. Makridakis, S. et al. (2018), "The M4 Competition: Results, findings, conclusion and way forward", **International Journal of Forecasting**. 34. 10.1016/j.ijforecast.2018.06.001.
41. Makridakis, S. et al., (2024). "The M6 forecasting competition: Bridging the gap between forecasting and investment decisions", **International Journal of Forecasting**, <https://doi.org/10.1016/j.ijforecast.2024.11.002>.
42. McCloskey, P., & Remor, R. (2025). Comparative analysis of ARIMA, VAR, and linear regression models for UAE GDP forecasting. <https://doi.org/10.2139/ssrn.5010124>.
43. Mohamed, F. et al., (2023). " Nowcasting Egypt GDP Using Machine Learning Algorithms", **Journal of Computing and Communication**, Vol.2, No.1.
44. Mou, S. et al., (2025). "Mm-itransformer: A multimodal approach to economic time series forecasting with textual data. **Applied Sciences**, 15 (3), 1241-1241. <https://doi.org/10.3390/app15031241>.

-
-
45. Mueller, S. et al (2019), " Explanation in human-AI systems: A literature meta-review, synopsis of key ideas and publications, and bibliography for explainable AI, **arXiv preprint**, arXiv: 1902.01876.
 46. Naaz, S. et al., (2024). "Forecasting GDP Per Capita Using Machine Learning Algorithms," **Second International Conference on Emerging Trends in Information Technology and Engineering (ICETITE)**, Vellore, India, 2024, pp. 1-5, doi: 10.1109/ic-ETITE58242.2024.10493237.
 47. Nelson, D. (1991). "Conditional Heteroskedasticity in Asset Returns: A New Approach", **Econometrica**, Vol. 59(2).
 48. Nelson, R. & Plosser, R. (1982), " Trends and random walks in macroeconomic time series: Some evidence and implications", **Journal of Monetary Economics**, Vol. 10(2).
 49. Németh & Hadházi, (2024). "Generating density nowcasts for U.S. GDP growth with deep learning: Bayes by Backprop and Monte Carlo dropout", doi: 10.48550/arxiv.2405.15579.
 50. Nicolas, W. (2020), " Adaptive Trees: A New Approach To Economic Forecasting", **Economics Department Working Papers**, OECD, No. 1593.
 51. Niko et al., (2024)." Nowcasting with mixed frequency data using Gaussian processes. doi: 10.48550/arxiv.2402.10574.
 52. Onkal, D. (2020), "M4 competition: What's next?", **International Journal of Forecasting**, vol.36.
 53. Oo, Z. et al., (2025). "Deciphering long-term economic growth: An exploration with leading machine learning techniques", **Journal of Forecastingnull**, <https://doi.org/10.1002/for.3254>.
 54. Pârțachi, I., & Mija, S. (2025). "Moldova GDP forecasting using bayesian multivariate models", **Revista economică**, 76 (1), 85-93. <https://doi.org/10.56043/reveco-2024-0008>
 55. Pesaran, M., et al. (2001), "Bounds Testing Approaches to the Analysis of Level Relationships", **Journal of Applied Econometrics**, 16.
 56. Rabemananjara, R.& Zakoian, J. (1991), " Threshold ARCH models and asymmetries in volatility", **Journal of Applied Econometrics**, Vol. 8

-
-
57. Rawat, B. et al, (2024), "Towards Transparent Intelligence: A Comprehensive Review of Explainable AI Methods and Applications", International Conference on Communication, Computing and Energy Efficient Technology, 953-958. 10.1109/I3CEET61722.2024.10993679.
58. Ricardo, P. et al. (2020), "Machine Learning Advances for Time Series Forecasting", **Papers 2012.12802**, arXiv.org, Available at: <https://ideas.repec.org/p/arx/papers/2012.12802.html>
59. Richardson, A. el al (2021), "Nowcasting GDP using machine-learning algorithms: A real time assessment", **International Journal of Forecasting**, Vol. 37(2).
60. Rob, H. & Koehler, A. (2006), "Another look at measures of forecast accuracy", International Journal of Forecasting. 22. 679-688. 10.1016/j.ijforecast.2006.03.001.
61. Sadreeva, A. et al., (2024). "Artificial intelligence and forecasting macroeconomic indicators", **Ekonomika I Upravljenje: Problemy, Resheniya**. 12/4. 93-102. 10.36871/ek.up.p.r.2024.12.04.012.
62. Sajid, A et al. (2023), "Explainable Artificial Intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence", **Information Fusion**. 99. 101805. 10.1016/j.inffus.2023.101805.
63. Salinas, D. et al. (2020), "DeepAR: Probabilistic forecasting with autoregressive recurrent networks", **International Journal of Forecasting**, vol. 36.
64. Schnaubelt, M. (2019), "A comparison of machine learning model validation schemes for non-stationary time series data", **FAU Discussion Papers in Economics, No. 11/2019**, Friedrich-Alexander-Universität Erlangen-Nürnberg, Institute for Economics, Nürnberg.
65. Seifipour, R., & Azadeh, M. (2025). Application of artificial neural networks in economic and financial sciences. <https://doi.org/10.5772/intechopen.1007604>.
66. Sims, C. (1980), "Macroeconomics and Reality", **Econometrica, Econometric Society**, vol. 48(1).
67. Sivakumar, G. (2025). Hmm-lstm fusion model for economic forecasting. <https://doi.org/10.48550/arxiv.2501.02002>.
68. Stavros, D., (2024). " The D-Model for GDP nowcasting", **Social Science**

Research Network, doi: 10.2139/ssrn.4764606.

69. Tenorio & Pérez. (2024). "Monthly GDP nowcasting with Machine Learning and Unstructured Data", doi: 10.48550/arxiv.2402.04165.
70. Tiffin, A. (2016), "Seeing in the Dark; A Machine-Learning Approach to Nowcasting in Lebanon", **IMF Working Papers 2016/056**, International Monetary Fund.
71. Uddin, A. et al., (2025). "Advancing financial risk prediction and portfolio optimization using machine learning techniques", **The American journal of management and economics innovations**, 07 (01), 5-20. <https://doi.org/10.37547/tajmei/volume07issue01-02>.
72. Utama & Firinda, (2024). "Nowcasting GDP with Machine Learning: The Case of Indonesia", doi: 10.21203/rs.3.rs-3903568/v1.
73. Van, L. et al. (2004), " An explainable artificial intelligence system for small-unit tactical behaviour", **Proceedings of the National Conference on Artificial Intelligence**, EID: 2-s2.0-9444223800.
74. Verona, F. (2025). From waves to rates: Enhancing inflation forecasts through combinations of frequency domain models. <https://doi.org/10.2139/ssrn.5092410>
75. Yemets, K. et al., (2025). Time series forecasting model based on the adapted transformer neural network and fft-based features extraction. **Sensors**, 25 (3), 652-652. <https://doi.org/10.3390/s2503065>.
76. Zhangyin, C. (2024). " Research on machine learning forecasting model of economic indicators based on big data", **International Conference on Electronics and Devices**, Computational Science (ICEDCS), Marseille, France, 2024, pp. 809-816, doi: 10.1109/ICEDCS64328.2024.00151.
77. Zodge, P. et al (2024), " Explainable AI (XAI): History, Basic Ideas and Methods.", **International Journal of Advanced Research in Science, Communication and Technology**, Mumbai, Maharashtra, India. IJAR SCT. <https://doi.org/10.48175/ijarsct-16988>

Explanatory and Predictive Power of Economic Models Between Machine Learning Models and Econometric Models

Abstract:

The study aims to verify the validity of the basic hypotheses, namely the superiority of machine learning and deep learning models in terms of predictive ability, with lower interpretability compared to traditional econometric models. Therefore, the study began by examining traditional measures of the explanatory and predictive ability of econometric models. The study concluded that these models suffer from numerous shortcomings in the field of prediction, the most important of which is their failure to deal with many challenges, especially global financial crises. They also cannot handle missing data because they rely on the model's interpretability rather than its accuracy and predictive ability. The study then examined the most important modern measure of goodness of fit, presented by Apesteguia & Ballester (2020), which is the maximum amount of data that can be reconciled with the model. The study also addressed the mechanism of cross-validation in machine learning models, which is a method for assessing the goodness of fit out of sample and aims primarily to avoid overfitting and underfitting. The study also examined a modern concept for assessing the predictive ability of economic models, namely completeness, proposed by Fudenberg et al. (2021) illustrates the scope for improving predictive power. The study addressed regression models for machine learning and deep learning, which have become increasingly relied upon in the field of economic forecasting during the second decade of the twenty-first century to benefit from the era of big data, especially after the failure of traditional statistical models to predict the 2008 global financial crisis. The results of many recent studies were reviewed that aimed to compare the predictive and explanatory power of traditional statistical models and machine learning models, the most important of which are (Seifipour & Azadeh, 2025; Juanhua & Xu, 2025; Makridakis et al., 2024; Franck et al., 2023; Richardson et al., 2021; Nicolas, 2020). The most important results reached by the study are: (1) Modern methods focus on measuring the optimal performance of the model, i.e. the maximum possible

performance, (2) the predictive ability of machine learning models is superior to traditional models, the explanatory ability of machine learning models is low, as it is difficult to explain the factors that drive the predictions, (3) the combination of traditional methods and ML models using appropriate weightings leads to further improvements in performance, which proves the validity of the study hypotheses.

Keywords: Machine learning - Deep learning - Economic forecasting - Regression tree approach - Random forests - Recurrent neural networks.