الجمهورية العربية السورية

وزارة التعليم العالي والبحث العلمي

المعهد العالي لإدارة الأعمال

كفاءة خوارزميات الذكاء الاصطناعي في بناء وإعادة توازن المحافظ الاستثمارية مقارنة بالنماذج التقليدية: دراسة تطبيقية على السوقين السعودي والأمريكي

The Efficiency of Artificial Intelligence Algorithms in Portfolio Construction and Rebalancing Compared to Traditional Models: An Empirical Study on the Saudi and US Markets

مشروع تخرج أُعدّ استكمالاً لمتطلبات نيل الإجازة الجامعية في علوم إدارة الأعمال

إعداد الطالب

علي الطفيلي

إشراف الدكتورة:

منال الموصلي

العام الدراسي

2026-2025

جميع الآراء الواردة في هذه الدراسة تعبر عن وجهة نظر معدة، ولا يتحمل المعهد اي مسؤولية عن مدى دقة أو مصداقية الآراء المطروحة فيه

الشكر والتقدير:

الشكر والتقدير

أتقدم بخالص الشكر والتقدير لكل من ساهم في إتمام هذا البحث العلمي، وكان له أثر في مسيرتي الجامعية والعلمية.

وأود أن أعبر عن عميق امتناني وخالص تقديري لمشرفة بحثي، الدكتورة منال الموصلي، على ما قدمته من توجيه علمي قيّم ودعم متواصل، وعلى إسهاماتها وملاحظاتها البنّاءة التي كان لها الأثر الكبير في إثراء هذا العمل وتطويره. فقد كانت رؤيتها العلمية ونصائحها الدقيقة مصدر إلهام وتعلّم لي طوال فترة إعداد البحث، ولها مني أسمى عبارات الشكر والعرفان.

كما أتوجه بجزيل الشكر والتقدير إلى الدكتور أحمد العلي، والدكتورة خلود اليونس، والدكتورة مرام اسلمبولي، تقديراً لما قدموه من علم ومعرفة وتوجيه أكاديمي، وما تركوه من أثر طيب في مسيرتي الجامعية، وأسهموا به في تنمية معارفي وتوسيع آفاقي العلمية.

وأخص بالشكر أصدقائي وزملائي في الجامعة، زاهر الريس، وحيدر قيروط، وعمر الزعويط، الذين لم يبخلوا عليّ بدعمهم وتشجيعهم ومساندتهم، وكانوا خير رفاق خلال مسيرتي الجامعية، وأسهموا بأفكارهم وملاحظاتهم ومواقفهم الطيبة في تجاوز التحديات وإتمام هذا البحث.

وأخيراً، لا يسعني إلا أن أتقدم بخالص الحب والامتنان إلى عائلتي العزيزة، التي كانت السند الأول والداعم الأكبر لي طوال مسيرتي العلمية، لما قدمته من دعم معنوي ومادي، وتشجيع مستمر وثقة لا تنضب. فلولا وقوفهم إلى جانبي، لما كان لهذا العمل أن يكتمل.

إلى كل من علّمني، وساندني، وشجعني، وكان له أثر في وصولي إلى هذه المرحلة، أقدم ثمرة هذا الجهد بكل تقدير وامتنان.

شكراً لكم جميعاً.

الملخص:

هدفت هذه الدراسة إلى اختبار كفاءة خوارزميات الذكاء الاصطناعي في بناء وإعادة توازن المحافظ الاستثمارية مقارنة بالنموذج التقليدي القائم علىMarkowitz/MVO ، وذلك من خلال دراسة تطبيقية على السوقين السعودي والأمريكي خلال الفترة 2024–2025، باستخدام بيانات يومية مع اعتماد إعادة توازن نصف سنوية. اعتمدت الدراسة منهجاً كمياً تطبيقياً يقوم على بناء محافظ افتراضية وفق منهجين: منهج تقليدي ومنهج قائم على الذكاء الاصطناعي، وقياس الأداء باستخدام العائد المتوقع، والمخاطر المقاسة بالانحراف المعياري، ومؤشرSharpe ، إضافة إلى تحليل CAPM واختبارات الفروق الإحصائية.

أظهرت النتائج أن المحافظ التقليدية حققت عوائد متوقعة أعلى في أغلب الفترات، بينما تميزت محافظ الذكاء الاصطناعي بانخفاض واضح في مستوى المخاطر، ولا سيما في السوق الأمريكي. كما أظهرت النتائج تفوقاً وصفياً لمحافظ الذكاء الاصطناعي في مؤشر Sharpe في بعض الفترات، إلا أن هذا التفوق لم يكن معنوياً إحصائياً بصورة حاسمة. كذلك لم تقدم نتائج CAPM دليلاً كافياً على تحقيق Alpha/Intercept معنوي لمحافظ الذكاء الاصطناعي، كما لم يظهر اختبار الفروق بين السوقين وجود اختلاف معنوي في حجم الفرق بين المنهجين.

اختتمت الدراسة بمجموعة من التوصيات، أهمها أن خوارزميات الذكاء الاصطناعي تمثل أداة واعدة في إدارة المخاطر وخفض التذبذب، لكنها لم تثبت تفوقاً شاملاً ومستقراً على النماذج التقليدية خلال فترة الدراسة، لذلك توصي الدراسة بالنظر إلى الذكاء الاصطناعي كأداة داعمة يمكن دمجها مع النماذج التقليدية، وليس كبديل كامل عنها.

الكلمات المفتاحية:

الذكاء الاصطناعي، التعلم التعزيزي العميق، المحافظ الاستثمارية، إعادة التوازن، نموذج ماركويتز، مؤشر Sharpe، CAPM.

Abstract:

This study aims to examine the efficiency of artificial intelligence algorithms in portfolio construction and rebalancing compared with the traditional Markowitz mean-variance optimization model. The empirical analysis is applied to the Saudi and U.S. markets over the period 2024–2025, using daily data with semi-annual rebalancing. The study adopts a quantitative empirical approach by constructing hypothetical portfolios using two methods: a traditional portfolio construction approach and an artificial intelligence-based approach. Portfolio performance is evaluated using expected return, risk measured by standard deviation, Sharpe ratio, CAPM regression analysis, and statistical difference tests.

The results indicate that traditional portfolios achieved higher expected returns in most periods, while artificial intelligence portfolios showed a clear reduction in risk, particularly in the U.S. market. AI portfolios also recorded descriptive improvements in the Sharpe ratio during some periods; however, this superiority was not statistically significant in a conclusive manner. In addition, CAPM results did not provide sufficient evidence of statistically significant Alpha/Intercept for AI portfolios, and the comparison between the Saudi and U.S. markets did not reveal statistically significant differences in the magnitude of performance gaps between the two approaches.

The study concludes with a set of recommendations, the most important of which is that artificial intelligence algorithms represent a promising tool for risk management and volatility reduction, but they did not demonstrate comprehensive and stable superiority over traditional models during the study period. Accordingly, AI should be viewed as a supportive tool that can be integrated with traditional portfolio models rather than as a complete substitute.

Keywords:

Artificial intelligence, deep reinforcement learning, portfolio construction, portfolio rebalancing, Markowitz model, Sharpe ratio, CAPM.

جدول المحتويات:

الشكر والتقدير: II

الملخص: III

Abstract: IV

الفصل الأول: 1

الاطار العام للدراسة 1

اولاً: المقدمة: 2

ثانياً: الأدبيات السابقة: 3

ثالثاً: الفجوة البحثية: 10

رابعاً: مشكلة الدراسة: 10

خامساً: فرضيات الدراسة: 12

سادساً: أهداف الدراسة: 12

سابعاً: متغيرات الدراسة: 14

ثامناً: أهمية الدراسة: 14

تاسعاً: حدود الدراسة ومحدداتها: 15

محددات الدراسة: 16

الحادي عشر: منهج الدراسة: 16

الفصل الثاني: 17

الاطار النظري للدراسة 17

المبحث الأول: المحافظ الاستثمارية وكفاءة الأسواق ومقاييس أداء المحافظ 19

1.1 تعريف المحفظة ومفهوم العائد والمخاطرة: 19

1.2 توزيع الأوزان والتنويع والارتباط: 20

1.3 كفاءة الأسواق وخصائص بيئة التطبيق: 20

1.4 مقاييس أداء المحافظ الاستثمارية: 21

المبحث الثاني: نماذج بناء وإعادة توازن المحافظ الاستثمارية بين المنهج التقليدي والذكاء الاصطناعي: 23

2.1 الأساس الكمي لبناء المحافظ: العوائد والمخاطر ومصفوفة التغاير: 23
2.2. نموذج ماركويتز (MVO) ومصفوفة التغاير وقيود الأوزان: 25
2.3 إعادة التوازن التقليدية وتكاليف التداول ولماذا قد تُضعِف النتائج: 26
2.4 الذكاء الاصطناعي والتعلم التعزيزي العميق في بناء المحافظ: 27
2.5 آلية عمل DRL في توليد الأوزان وإعادة التوازن: 28
2.6 المقارنة النظرية بين MVO وDRL في حساب أوزان المحافظ: 29
الفصل الثالث: 34
الاطار العملي للدراسة 34
المبحث الأول: منهجية الدراسة التطبيقية وعينة الدراسة 36
1.1 منهجية الدراسة التطبيقية: 36
1.2 عينة الدراسة والأسواق محل التطبيق: 37
1.3 فترة الدراسة وتقسيمها الزمني: 40
1.4 مصادر البيانات والمتغيرات المستخدمة: 41
1.5 آلية بناء المحافظ وإعادة التوازن: 42
المبحث الثاني: اختبار الفرضيات ومناقشة النتائج 43
2.1 مؤشرات القياس المستخدمة في التحليل التطبيقي: 43
2.2 عرض نتائج الأداء المالي للمحافظ: 44
2.3التوصيف الإحصائي لعوائد المحافظ اليومية: 47
2.4. تحليل الانحدار وفق نموذج CAPM: 47
2.5 اختبارات الفروق الإحصائية: 48
2.6 اختبار الفروق بين السوق السعودي والسوق الأمريكي: 50
2.7مناقشة الفرضيات ومقارنة النتائج مع الدراسات السابقة: ..... خطأ! الإشارة المرجعية غير معرّفة.
2.8. مناقشة فرضيات الدراسة: ..... خطأ! الإشارة المرجعية غير معرّفة.
2.9. مقارنة نتائج الدراسة مع الدراسات السابقة: 53
2.10 نتائج الدراسة: 55
2.11 التوصيات: 56

2.12 الخاتمة: ..... **خطأ! الإشارة المرجعية غير معرّفة.**

2.13.الكتب والمراجع: 57

فهرس الجداول:

جدول 1 مقارنة الدراسات السابقة..... 8
جدول 2 رقم (2-1) المدخلات الكمية المستخدمة في بناء المحافظ الاستثمارية..... 24
جدول 3 رقم (2-2)مقارنة نظرية بين نموذج MVO وخوارزميات DRL في بناء المحافظ..... 30
جدول 4 عينة السوق السعودي 37
جدول5 عينة السوق الأمريكي..... 39
جدول6 تقسيم فترات الدراسة 40
جدول7 مؤشرات القياس المستخدمة في التحليل التطبيقي 41
جدول 8 المؤشرات والبيانات المحسوبة 43
جدول 9 الأداء المالي للمحافظ في السوق السعودي 44
جدول 10 الأداء المالي للمحافظ في السوق الأمريكي..... 45
جدول 11 التوصيف الإحصائي لعوائد المحافظ اليومية 47
جدول 12 نتائج تحليل الانحدار وفق نموذج CAPM 48
جدول 13 نتائج اختبار Paired Samples T-Test 49
جدول 14 نتائج اختبار Independent Samples T-Test..... 51
جدول 15 مناقشة الفرضيات..... 52
جدول 16 مقارنة نتائج الدراسة مع الدراسات السابقة..... 54

فهرس الأشكال:

رسم توضيحي 1 متغيرات البحث..... 14
رسم توضيحي 2 العلاقة بين العائد والمخاطرة ومقاييس تقييم الأداء المالي 22
رسم توضيحي 3 الفرق بين النموذجين 31

المصطلح	الاختصار	مفهوم المصطلح
نموذج متوسط–التباين لماركويتز	MVO	المنهجية التقليدية المستخدمة في بناء المحافظ وتحديد الأوزان وفق العلاقة بين العائد والمخاطرة
التعلم التعزيزي العميق	DRL	منهجية ذكاء اصطناعي تتعلم قرارات تخصيص الأوزان وإعادة التوازن من خلال التفاعل مع بيانات السوق
نموذج تسعير الأصول الرأسمالية	CAPM	نموذج يستخدم لتحليل العلاقة بين عائد المحفظة وحركة السوق من خلال Beta وAlpha/Intercept
مؤشر شارب	Sharpe Ratio	مؤشر يقيس الأداء المعدّل بالمخاطر من خلال مقارنة العائد الزائد بالمخاطرة الكلية
معامل بيتا	Beta	مؤشر يقيس حساسية عوائد المحفظة تجاه حركة السوق
ألفا / القاطع	Alpha/Intercept	مؤشر يعبّر عن الجزء من العائد غير المفسر بحركة السوق ضمن تحليل CAPM
برنامج التحليل الإحصائي	SPSS	البرنامج المستخدم في تنفيذ التحليلات الإحصائية واختبارات الفروق
برنامج الجداول الإلكترونية	Excel	الأداة المستخدمة في تنظيم البيانات وحساب مؤشرات الأداء وبناء الجداول التطبيقية

الفصل الأول:

الاطار العام للدراسة

اولاً: المقدمة:

يُعدّ الاستثمار في الأسواق المالية عملية تقوم في جوهرها على المفاضلة بين العائد والمخاطر، إذ يتأثر أداء الأصول المالية بتغيرات متكررة في الظروف الاقتصادية والمالية وما يرافقها من تقلبات في أسعار الفائدة والسيولة والتوقعات، الأمر الذي يجعل إدارة المحافظ الاستثمارية محوراً أساسياً في اتخاذ القرار المالي، وقد انطلقت الأدبيات المالية الكلاسيكية من نماذج المحفظة الحديثة ونماذج تسعير الأصول في تفسير العلاقة بين العائد والمخاطر وبناء المحافظ المثلى، إلا أن التطورات المتسارعة في بنية الأسواق وتعقّد سلوك الأسعار حدت الاعتماد الحصري على افتراضات الثبات والخطية في العديد من النماذج، ولا سيما عندما تتبدل أنظمة السوق بين حالات استقرار واضطراب أو بين موجات صعود وهبوط.

وفي السنوات الأخيرة، برز الذكاء الاصطناعي والتعلم الآلي والتعلم العميق كاتجاه بحثي وتطبيقي في التمويل، عبر خوارزميات قادرة على استيعاب حجم أكبر من البيانات والتقاط أنماط غير خطية وتكييف قراراتها مع تغير ظروف السوق، مما أعاد طرح أسئلة جوهرية حول مدى كفاءة "التشكيل الخوارزمي" للمحافظ مقارنةً بالأساليب التقليدية من حيث العائد المعدّل بالمخاطر واستقرار القرارات عبر الزمن، وتزداد أهمية هذا النقاش عند اختلاف البيئات السوقية من حيث الكفاءة والعمق والسيولة وتكاليف التنفيذ، إذ قد تتباين نتائج النماذج والخوارزميات باختلاف خصائص السوق وآليات التسعير وتوافر المعلومات.

ومن ثم تبرز الحاجة إلى معالجة بحثية منهجية تُعيد تقييم دور الخوارزميات الذكية في تشكيل المحافظ ضمن سياق مقارن يأخذ بالاعتبار ديناميكيات السوق وتبدل أنظمته، بما يتيح استنتاجات أكثر صلابة وقابلية للتعميم في مجال إدارة المحافظ.

ثانياً: الأدبيات السابقة:

1.الأدبيات العربية:

1-1 (القضماني، 2024): تقييم أداء محافظ الاستثمار وفق استراتيجية أنظمة السوق الصاعد والهابط (دراسة تطبيقية باستخدام نموذج ماركوف متعدد العوامل على سوق تداول السعودية)

هدفت هذه الدراسة إلى تقسيم السوق إلى نظامين (صاعد/هابط) ثم تقييم أداء محافظ استثمار تُبنى وتُعاد موازنتها وفق تغيّر النظام، مقارنة بالمحافظ التقليدية الثابتة، اعتمدت الدراسة بيانات شهرية لعينة من 20 سهماً من قطاعات مختلفة خلال الفترة نيسان 2010 – حزيران 2024، واستخدمت نموذج ماركوف متعدد العوامل (Markov Switching Multi-Factor) لتحديد حالات السوق، ثم استخدمت مخرجاته لبناء الأوزان المثلى عبر أسلوبي تعظيم شارب وتعظيم العائد الإضافي (ألفا) مع فرض قيود على المخاطر (بيتا)، وبعد ذلك تُعدَّل الأوزان عند كل تغيّر في نظام السوق لقياس الأداء السنوي ومقارنته بالمحافظ التقليدية التي لا تراعي تقلبات السوق. تمثلت المتغيرات التفسيرية/الضابطة في خمسة عوامل: عوامل فاما–فرنش الثلاثي إضافة إلى عوائد النفط والفرق بين SAIBOR3 ومعدل إعادة الشراء المعاكس (RRR)، بينما تمثلت متغيرات المخرجات (التابعة) في أداء المحافظ ومقاييسه ولاسيما Sharpe وAlpha ضمن قيود Beta.

خلصت الدراسة إلى إمكانية تمييز أنظمة السوق السعودي بوضوح عبر نموذج ماركوف، وأن سلوك ومعاملات الأسهم تختلف بين النظامين، كما أظهرت أن استراتيجية الصاعد/الهابط مع إعادة موازنة الأوزان عند تغيّر النظام يمكن أن تنتج محافظ تتفوق في الأداء على المحافظ التقليدية الثابتة، وأن أسلوبي تعظيم شارب وتعظيم ألفا يقدمان نتائج أفضل من الطرق التقليدية التي تتجاهل تقلبات السوق.

2-1(العيد، سمية،2024): تقييم أداء المحافظ الاستثمارية لصناديق الأسهم السعودية بالاعتماد على العائد والمخاطرة – دراسة تحليلية من 2013 إلى 2022:

هدفت هذه الدراسة الى تقييم أداء محافظ صناديق أسهم وفق "الأسلوب المزدوج" الذي يجمع بين العائد والمخاطرة، اعتمد الباحثان منهجاً وصفياً تحليلياً مع دراسة حالة على عينة من 5 محافظ تابعة لصناديق الأسهم لدى الرياض المالية خلال الفترة من 2013 الى 2022 (مثل: الدخل المتوازن، الأسهم السعودية، الأسهم الخليجية، الإعمار، الأسهم القيادية) مع اعتبار محفظة السوق مرجعاً للمقارنة، واستخدمت الدراسة مؤشرات/أدوات قياس المخاطر والعوائد مثل المتوسط الحسابي للعائد، التباين/التغاير، الانحراف المعياري، ومعامل بيتا، ثم قيّمت الجودة وفق مقاييس الأسلوب المزدوج مثل Sharpe وTreynor وJensen وFama ومؤشر الأداء المعدّل بالمخاطر، مع اعتماد معدل خالٍ من المخاطر مذكور في الدراسة، تتمثل المتغيرات المستقلة عملياً في نوع/سياسة المحفظة (صندوق الأسهم محل القياس)، والمتغيرات التابعة في مؤشرات الأداء والمخاطرة (Sharpe, Treynor, Alpha... إلخ) والعائد/التذبذب/البيتا، بينما تتمثل المتغيرات الضابطة في الفترة الزمنية نفسها، ومحفظة السوق كمرجع، والمعدل الخالي من المخاطر، ومنهج القياس الموحد عبر جميع المحافظ. خلصت الدراسة إلى وجود علاقة طردية بين العائد والمخاطرة، وأن التنويع يساهم بوضوح في تعظيم العائد وتقليل المخاطر، كما أظهرت أن أداء محافظ الصناديق كان مميزاً وفق نماذج الأداء المزدوج ويُعزى ذلك لسياسات واستراتيجيات مديري المحافظ رغم تعدد الأزمات التي أثّرت على الأسواق العالمية خلال فترة الدراسة، مع تفاوت الأداء بين المحافظ بحسب درجة المخاطرة وهيكل الاستثمار.

2.الأدبيات الأجنبية:

1.2-(Yu & Chang, 2025):

Smart Tangency Portfolio: Deep Reinforcement Learning for Dynamic Rebalancing and Risk–Return Trade–Off

محفظة التماس الذكية: التعلّم المعزز العميق لإعادة التوازن الديناميكي والمفاضلة بين المخاطرة والعائد

هدفت هذه الدراسة إلى تصميم إطار تخصيص ديناميكي للمحافظ يدمج بين خوارزميات التعلّم التعزيزي العميق (DRL) والتحسين الكلاسيكي للمحافظ (نموذج ماركويتز) بهدف تعزيز استراتيجيات إعادة التوازن (Rebalancing) وإدارة المخاطر، طُبقت الدراسة على بيانات يومية ممتدة لـ 12 صندوق مؤشرات متداول

(ETFs) للقطاعات الأمريكية (2003–2023) و28 سهماً من مكونات مؤشر داو جونز الصناعي (2005–2023).

ابتكر الباحثون مقاربة فريدة لا يقوم فيها وكيل الذكاء الاصطناعي بتقدير أوزان الأصول مباشرة، بل يحتفظ بالهيكل الرياضي للتحسين التقليدي (محفظة التماس – Tangency Portfolio) ويفوض للوكيل الذكي مهمة تحديد "مستوى تجنب المخاطرة" و"التوقيت الأمثل لإعادة التوازن" بشكل ديناميكي وفقاً لتغيرات السوق.

أظهرت النتائج التجريبية أن الاستراتيجيات الموجهة بالذكاء الاصطناعي تفوقت باستمرار وبشكل منهجي على المحافظ الثابتة والمؤشرات المرجعية للسوق في كافة المقاييس، محققةً عائداً سنوياً أعلى، وتذبذباً أقل، وقيمة أفضل لمؤشر شارب.

2.2- (Álvaro García–Sánchez، Espiga–Fernández، 2024):

A Systematic Approach to Portfolio Optimization: A Comparative Study of Reinforcement Learning Agents, Market Signals, and Investment Horizons

منهجية لتحسين المحافظ الاستثمارية: دراسة مقارنة لوكلاء التعلّم التعزيزي، وإشارات السوق، وآفاق الاستثمار.

هدفت هذه الدراسة إلى تقييم كفاءة وكلاء التعلّم التعزيزي العميق (مثل DQN وDDPG وPPO) في تحسين المحافظ الاستثمارية، من خلال اختبار تأثير المتغيرات المنهجية كطول النافذة التاريخية وتواتر إعادة التوازن (مستمر مقابل دوري).

طُبقت الدراسة على محفظة تضم ستة مؤشرات أسهم عالمية رئيسية بالإضافة إلى أصل خالٍ من المخاطر للفترة الممتدة بين (1988–2024).

قارن الباحثون بين بنى شبكات عصبية مختلفة (CNN مقابل MLP) وإشارات إدخال متعددة، مع تقييم الأداء خارج العينة بناءً على مقاييس العائد ومؤشرات (Sharpe، Sortino، وCalmar). أظهرت النتائج تفوق وكلاء الذكاء الاصطناعي (تحديداً DQN المعزز بشبكات CNN ذات النوافذ التاريخية الأطول) على المؤشرات

المرجعية، محققة عوائد سنوية قاربت 26% مقارنة بـ 14.18% لمحفظة السوق (S&P 500)، مع تحسن ملحوظ في مؤشر سورتينو (1.12). كما أثبتت النتائج بشكل قاطع أن إعادة التوازن الدورية تتفوق من منظور (العائد/المخاطرة) على إعادة التوازن المستمرة التي تؤدي إلى تآكل الأرباح نتيجة تكاليف التداول والانزلاق السعري.

3.2(Haifeng Li، 2024):

Deep Reinforcement Learning Model for Stock Portfolio Management Based on Data Fusion

نموذج التعلم العميق المعزز لإدارة محافظ الأسهم بناءً على دمج البيانات:

هدفت هذه الدراسة إلى تصميم نظام تعاوني متعدد الوكلاء لإدارة المحافظ الاستثمارية (CMPS) استناداً إلى التعلّم التعزيزي العميق (DRL) وآلية دمج البيانات (Data Fusion).

طُبقت الدراسة على بيانات مؤشر الأسهم الصينية (SSE 50) للفترة (2009–2021) ، مع تقسيم البيانات لاختبار النموذج في فترات السوق الصاعدة (Bull) والهابطة (Bear). منهجياً، تجاوزت الدراسة الاعتماد المحدود على أسعار الأسهم فقط، وصممت ثلاثة وكلاء (Agents) باستخدام شبكات (DQN) لاستخراج السمات من ثلاث فئات: الأسعار التاريخية، المؤشرات المالية، ومصفوفة التغاير (وفق نظرية ماركويتز) لقياس الارتباط بين الأصول.

وتم دمج مخرجات الوكلاء باستخدام شبكة الانتباه الذاتي (Self–attention). كما ابتكرت الدراسة استراتيجية موازية (CMPS–RF) لتخصيص الأوزان ديناميكياً بين الأصول الخطرة والأصل الخالي من المخاطر. أظهرت النتائج تفوق النموذج المقترح على النماذج المعيارية الحديثة (مثل FINRL و MAPS) بتحقيقه عوائد تراكمية وسنوية أعلى ، بينما أثبتت استراتيجية (CMPS–RF) قدرة استثنائية على امتصاص الصدمات والحد من التراجع الأقصى (MDD) في فترات انهيار السوق، مسجلةً أفضل القيم لمؤشري (Sharpe) و(Calmar).

كما حافظ النموذج على كفاءته حتى بعد إخضاعه لاختبار حساسية تكاليف التداول.

4.2 (Huang2024 ،)

Single-stage Portfolio Optimization with Automated Machine Learning for M6

تحسين المحافظ الاستثمارية أحادية المرحلة باستخدام تقنيات التعلم الآلي المؤتمت: تطبيق على مسابقة M6

هدفت هذه الدراسة إلى تطوير إطار مبتكر لتشكيل المحافظ الاستثمارية بمرحلة واحدة (Single-stage) باستخدام التعلّم الآلي المؤتمت (AutoML)، متجاوزةً المنهج التقليدي القائم على التقدير ثم التحسين.

طُبقت الدراسة على بيانات مسابقة (M6) وعينات عشوائية من مؤشر (S&P 500) للفترة من 2021 إلى 2023.

صاغ الباحثون عملية اختيار الأوزان كمسألة انحدار مقيد مع تطبيق عقوبات رياضية (Regularization) لمعالجة مشكلة تعدد الترابط والحد من تركز الأصول. واعتمدت الدراسة استراتيجية النوافذ المتدحرجة (Sliding Windows) مقسمة إلى: 9 أشهر للتدريب، 3 أشهر للتحقق، وشهر واحد للاحتفاظ والتداول.

تمت مقارنة هذا النموذج المعزز بخوارزمية (MMA) مع استراتيجيات تقليدية أبرزها نموذج التباين-المتوسط (Mean-Variance)، ومحفظة الحد الأدنى للتباين (MinVar)، والتوزيع المتساوي (N/1).

أظهرت النتائج تفوق نموذج الذكاء الاصطناعي (APO) بتحقيقه عائداً مركباً بلغ 9.5% ونسبة معلومات (IR) استثنائية (5.045)، محتفظاً بتفوقه المتين وأدائه المستقر ضد النماذج التقليدية حتى بعد إدراج تكاليف التداول المختلفة.

5.2 (Sood، Papasotiriou، 2023):

Deep Reinforcement Learning for Optimal Portfolio Allocation: A Comparative Study with Mean-Variance Optimization

التعلّم التعزيزي العميق لتخصيص المحافظ الاستثمارية بصورة مثلى: دراسة مقارنة مع تحسين متوسط–تباين (ماركويتز):

هدفت هذه الدراسة إلى مقارنة كفاءة تشكيل المحافظ الاستثمارية باستخدام خوارزميات التعلّم التعزيزي العميق (DRL) مع نموذج التباين–المتوسط التقليدي (MVO) بهدف تعظيم الأداء المعدل بالمخاطر (مؤشر شارب). اعتمدت الدراسة على البيانات اليومية لقطاعات مؤشر (S&P 500) للفترة (2006–2021)، مطبقة إطاراً تجريبياً يعتمد على النوافذ المتدحرجة (Sliding Windows) لضمان دقة الاختبارات خارج العينة.

وُظفت خوارزمية (PPO) للذكاء الاصطناعي لتحديد الأوزان بناءً على العوائد التاريخية ومؤشرات التقلب لالتقاط تغيرات نظام السوق، مقابل استخدام نموذج (MVO) التقليدي المعزز بتقنية (Ledoit–Wolf Shrinkage) لتحسين تقدير مصفوفة التغاير.

أثبتت النتائج تفوق استراتيجية الذكاء الاصطناعي بتسجيل عائد سنوي أعلى (12.11% مقابل 6.53%) وتذبذب أقل (12.49% مقابل 14.60%)، مما انعكس إيجاباً على مؤشرات (Sharpe، Sortino، وCalmar). كما تميز نموذج (DRL) بانخفاض معدل دوران المحفظة (Turnover)، مما يشير عملياً إلى تقليل تكاليف التداول.

جدول 1 مقارنة الأدبيات السابقة

الدراسة	مقاييس التقييم	منهج الدراسة	تصميم الاختبار وإعادة التوازن	منهج بناء المحفظة	سوق / عينة التطبيق
القضماني (2024)	Sharpe + Alpha + ضمن إطار Beta قيود متعدد العوامل	محافظ تقليدية ثابتة لا تراعي تغيّر الأنظمة	إعادة موازنة عند تغيّر نظام السوق Regime–based Rebalancing	Markov Switching متعدد العوامل لتحديد الصاعد/الهابط، السوق Sharpe ثم تعظيم Beta مع قيود Alphaو	سوق تداول السعودية؛ 20 سهماً؛ بيانات شهرية 2010–2024
العيد & سمية (2024)	المتوسط، التباين، الانحراف المعياري، Beta + Sharpe، Jensen ،Treynor Fama ومؤشر أداء معدل بالمخاطر	محفظة السوق كمرجع	تقييم تاريخي عبر سنوات الدراسة دون Walk– forward واضح	تقييم محافظ قائمة وفق الأسلوب المزدوج عائد/مخاطرة	السوق السعودي؛ 5 محافظ لصناديق أسهم 2013–2022

Sood & Papasotiriou (2023)	مؤشرات الأداء المعدّل بالمخاطر مثل Sharpe + دوران المحفظة Turnover	MVO/Markowitz	Sliding/Rolling Windows واختبارات خارج العينة؛ أوزان ديناميكية	DRL باستخدام PPO مع MVO مقابل Ledoit–Wolf	الولايات المتحدة؛ قطاعات S&P 500؛ بيانات يومية 2006–2021
Huang et al. (2024)	العائد + المخاطر + Information Ratio مع حساسية تكاليف التداول	1/N، MinVar ، Mean–Variance	9 أشهر تدريب + 3 أشهر تحقق + شهر احتفاظ/تداول؛ مع اختبار تكاليف التداول	AutoML / APO بانحدار مقيد مع Regularizationو MMA	بيانات M6 + عينات من S&P 500؛ 2021–2023
Espiga–Fernández et al. (2024)	Sharpe ،Sortino ، Calmar ،MaxDD وغيرها	Market Portfolio وEqual–weight	اختبار تواتر إعادة التوازن مستمر مقابل دوري + Lookback + تقييم خارج العينة	مقارنة وكلاء RL مثل DQN وDDPG وPPO مع CNN/MLP	مؤشرات أسهم عالمية + أصل خالٍ من المخاطر؛ 1988–2024
Li & Hai (2024)	العائد، المخاطر، Drawdown، Calmar ،Sharpe	نماذج DRL معيارية مثل FINRL وMAPS	اختبار منفصل لفترات Bull/Bear	نظام متعدد الوكلاء DQN + Data Fusion + Self–CMPS– + attention RF	الصين؛ SSE؛ 2009–2021
Yu & Chang (2025)	العائد + التذبذب + Sharpe والأداء المعدّل بالمخاطر	محافظ ثابتة ومؤشرات معيارية	إعادة توازن ديناميكية وفق إشارات السوق	إطار هجين يحافظ على Tangency Portfolio ويستخدم DRL لتحديد تجنب المخاطر وتوقيت إعادة التوازن	الولايات المتحدة؛ 12 ETF قطاعية 2003–2023 + 28 سهم Dow 2005–2023

المصدر: من إعداد الباحث.

وبالتالي وبناءً على الجدول أعلاه تتميز هذه الدراسة عن الأدبيات السابقة في مجال بناء وإعادة توازن المحافظ الاستثمارية بثلاث نقاط منهجية رئيسية:

1. التصميم المقارن عبر الأسواق: تعتمد الدراسة تصميماً مقارناً متناظراً يختبر كفاءة خوارزميات الذكاء الاصطناعي مقابل النماذج التقليدية ضمن سوقين مختلفين في البنية والكفاءة والسيولة (السوق السعودي والسوق الأمريكي).

2. التقييم الديناميكي: لا تكتفي الدراسة بتقييم المحفظة على فترة واحدة، بل تعتمد سلسلة فترات مع إعادة توازن نصف سنوية لإنتاج مسار زمني للأداء يسمح بقياس الاستقرار عبر الزمن وتقليل تحيز اختيار فترة بعينها.

3. توحيد أدوات التقييم :تعتمد الدراسة مقاييس الأداء المعدّل بالمخاطر (Sharpe) إلى جانب استخراج ألفا (α)من نماذج تسعير الأصول، بما يتيح التمييز بين التفوق الحقيقي في جودة الأداء وبين التفوق الناتج عن التعرض للمخاطر النظامية أو ظروف سوقية مؤقتة.

ثالثاً: الفجوة البحثية:

رغم تزايد الأدبيات التي تناولت استخدام خوارزميات الذكاء الاصطناعي (مثل التعلم التعزيزي وAutoML) في بناء المحافظ، فإن معظم الدراسات ركّزت على سوق واحد أو كون أصول واحد وبدرجات متفاوتة من الواقعية من حيث تواتر إعادة التوازن وتضمين تكاليف التداول، كما أن مقاييس التقييم المستخدمة تختلف بين الدراسات (Sharpe/Sortino مقابل IR/Drawdown)، ما يحدّ من إمكانية المقارنة العامة وتعميم النتائج. إضافةً إلى ذلك، لا تزال الأدلة التطبيقية محدودة فيما يخص المقارنة المتناظرة بين المحافظ المبنية بالذكاء الاصطناعي والمحافظ التقليدية ضمن أسواق تختلف في الكفاءة والسيولة (سوق ناشئ مقابل سوق متقدم) وباستخدام سلسلة فترات تنتج بيانات أداء قابلة للاختبار الإحصائي. وعليه، تتمثل الفجوة في الحاجة إلى إطار تطبيقي موحّد يقارن الطريقتين عبر سوقين وبإعادة توازن دورية واقعية، مع اعتماد مقاييس موحّدة لجودة الأداء لتمييز التفوق الحقيقي عن التفوق المرتبط بخصائص السوق أو الفترة الزمنية.

رابعاً: مشكلة الدراسة:

تتمثل مشكلة الدراسة في عدم حسم الأدبيات المالية الحديثة لمسألة تفوق خوارزميات الذكاء الاصطناعي على النماذج التقليدية في بناء وإعادة توازن المحافظ الاستثمارية، ولا سيما عند تقييم الأداء من منظور العائد

والمخاطرة والأداء المعدّل بالمخاطر. فرغم أن بعض الدراسات تشير إلى قدرة خوارزميات التعلم التعزيزي العميق على تحسين الأوزان والتكيف مع تغيرات السوق، فإن هذا التفوق قد لا يكون ثابتاً في جميع الأسواق أو عبر جميع الفترات.

وتزداد أهمية هذه المشكلة عند تطبيق المقارنة في بيئتين سوقيتين مختلفتين، هما السوق السعودي والسوق الأمريكي، نظراً لاختلاف خصائصهما من حيث العمق والسيولة وتوافر المعلومات والتقلب، ومن ثم فإن المشكلة لا تقتصر على معرفة ما إذا كانت خوارزميات الذكاء الاصطناعي أكثر كفاءة من النموذج التقليدي، بل تمتد أيضاً إلى معرفة ما إذا كانت نتائج هذه المقارنة تختلف باختلاف بيئة التطبيق.

تتمثل مشكلة الدراسة بالاجابة على السؤالين الرئيسي التاليين:

1- ما مدى كفاءة خوارزميات الذكاء الاصطناعي، ولا سيما التعلم التعزيزي العميق DRL، في بناء وإعادة توازن المحافظ الاستثمارية مقارنة بالنموذج التقليدي Markowitz/MVO من حيث جودة الأداء المالي؟

ويتفرع عنه الأسئلة الفرعية التالية:

1.هل تحقق محافظ الذكاء الاصطناعي أداءً معدّلاً بالمخاطر (Sharpe) أعلى من المحافظ التقليدية في السوق السعودي عند إعادة توازن نصف سنوية؟

2.هل تحقق محافظ الذكاء الاصطناعي أداءً معدّلاً بالمخاطر (Sharpe) أعلى من المحافظ التقليدية في السوق الأمريكي عند إعادة توازن نصف سنوية؟

3.هل تولّد محافظ الذكاء الاصطناعي ألفا (α) معنوية مقارنة بالمحافظ التقليدية في كل سوق بعد التحكم بالمخاطر النظامية عبر نموذج تسعير الأصول؟

2- إلى أي مدى تختلف نتائج المقارنة بين محافظ الذكاء الاصطناعي والمحافظ التقليدية عند تطبيقها في بيئتين سوقيتين مختلفتين، هما السوق السعودي والسوق الأمريكي؟

1.هل تختلف نتائج المقارنة بين السوق السعودي والسوق الأمريكي بما يعكس أثر اختلاف الكفاءة والسيولة على فعالية منهج التشكيل؟

2. إلى أي مدى تختلف درجة استقرار أداء محافظ الذكاء الاصطناعي مقارنة بالمحافظ التقليدية عبر الفترات نصف السنوية؟

خامساً: فرضيات الدراسة:

استناداً إلى مشكلة الدراسة وأسئلته، ولغرض اختبار كفاءة خوارزميات الذكاء الاصطناعي مقابل النماذج التقليدية، يسعى هذه الدراسة إلى اختبار الفرضيات الرئيسية التالية:

1. توجد فروق ذات دلالة إحصائية في مستوى الأداء المعدّل بالمخاطر، مقاساً بمؤشر Sharpe ، بين المحافظ المبنية باستخدام خوارزميات الذكاء الاصطناعي والمحافظ التقليدية في السوق السعودي .
2. توجد فروق ذات دلالة إحصائية في مستوى الأداء المعدّل بالمخاطر، مقاساً بمؤشر Sharpe ، بين المحافظ المبنية باستخدام خوارزميات الذكاء الاصطناعي والمحافظ التقليدية في السوق الأمريكي .
3. تحقق محافظ الذكاء الاصطناعي Alpha/Intercept موجباً وذا دلالة إحصائية مقارنة بالمحافظ التقليدية، بعد أخذ الحساسية السوقية Beta في الاعتبار وفق نموذجCAPM .
4. يختلف حجم الفرق في الأداء بين محافظ الذكاء الاصطناعي والمحافظ التقليدية باختلاف بيئة التطبيق، أي بين السوق السعودي والسوق الأمريكي .
5. تختلف درجة استقرار أداء محافظ الذكاء الاصطناعي مقارنة بالمحافظ التقليدية عبر الفترات نصف السنوية، وذلك بالاعتماد على تغيرات العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe .

سادساً: أهداف الدراسة:

بناءً على مشكلة الدراسة وأسئلته، تسعى هذه الدراسة إلى تحقيق هدفين رئيسيين، يتفرع عنهما عدد من الأهداف الفرعية، وذلك على النحو الآتي:

الهدف الرئيسي الأول:

تقييم كفاءة خوارزميات الذكاء الاصطناعي، ولا سيما التعلم التعزيزي العميق DRL، في بناء وإعادة توازن المحافظ الاستثمارية مقارنة بالنموذج التقليدي Markowitz/MVO من حيث أداء المحافظ.

ويتفرع عن هذا الهدف الأهداف الفرعية الآتية:

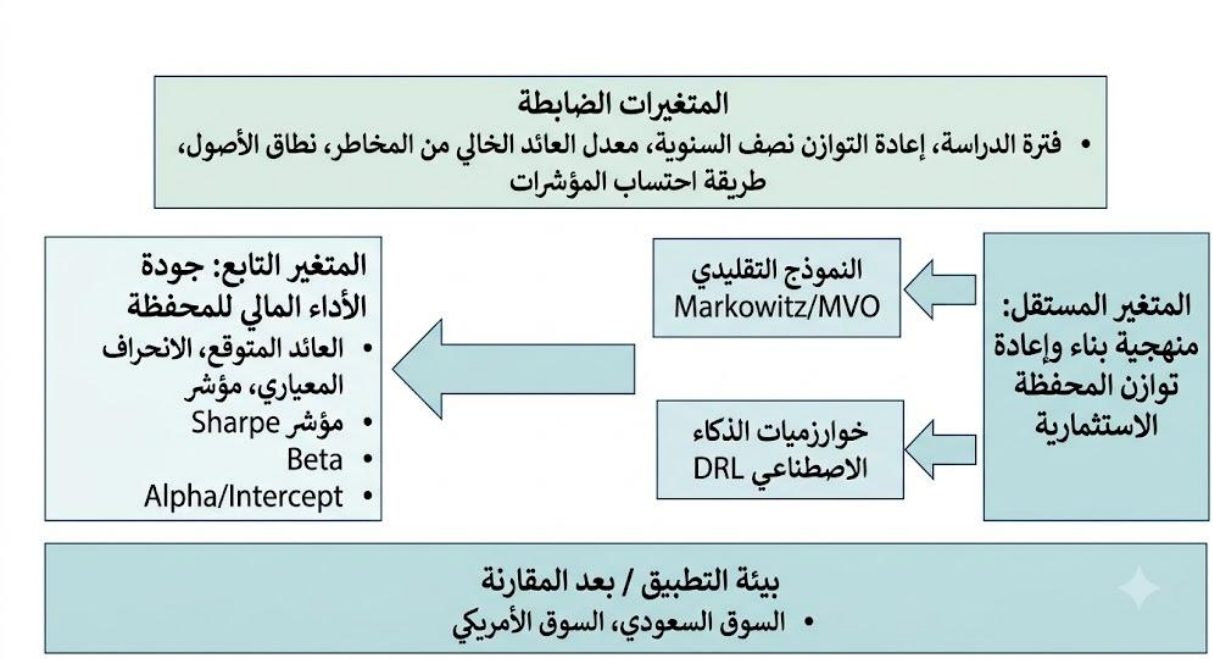
1. قياس الفروق في الأداء المعدّل بالمخاطر، مقاساً بمؤشر Sharpe ، بين محافظ الذكاء الاصطناعي والمحافظ التقليدية في السوق السعودي.
2. قياس الفروق في الأداء المعدّل بالمخاطر، مقاساً بمؤشر Sharpe ، بين محافظ الذكاء الاصطناعي والمحافظ التقليدية في السوق الأمريكي.
3. تقدير Alpha/Intercept و Betaللمحافظ باستخدام نموذجCAPM ، بهدف معرفة ما إذا كانت محافظ الذكاء الاصطناعي تحقق أداءً غير مفسر بحركة السوق مقارنة بالمحافظ التقليدية.

الهدف الرئيسي الثاني:

تحليل مدى اختلاف نتائج المقارنة بين محافظ الذكاء الاصطناعي والمحافظ التقليدية عند تطبيقها في بيئتين سوقيتين مختلفتين، هما السوق السعودي والسوق الأمريكي.

4. مقارنة حجم الفرق في الأداء بين محافظ الذكاء الاصطناعي والمحافظ التقليدية في السوق السعودي والسوق الأمريكي، بهدف معرفة أثر اختلاف بيئة التطبيق في نتائج المقارنة.
5. تحليل درجة استقرار أداء محافظ الذكاء الاصطناعي مقارنة بالمحافظ التقليدية عبر الفترات نصف السنوية، بالاعتماد على تغيرات العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe .

سابعاً: متغيرات الدراسة:



رسم توضيحي 1 متغيرات الدراسة، المصدر: من إعداد الباحث.

ثامناً: أهمية الدراسة:

1.الأهمية النظرية:

تتمثل الأهمية النظرية لهذه الدراسة في مساهمتها في إثراء أدبيات إدارة المحافظ الاستثمارية من خلال المقارنة بين منهجيتين مختلفتين في بناء وإعادة توازن المحافظ، هما المنهجية التقليدية القائمة على نموذج Markowitz/MVO، والمنهجية القائمة على خوارزميات الذكاء الاصطناعي، ولا سيما التعلم التعزيزي العميق .DRL وتساعد هذه المقارنة على توضيح ما إذا كان اختلاف منهجية بناء الأوزان ينعكس على أداء المحافظ من حيث العائد، والمخاطرة، والأداء المعدّل بالمخاطر.

كما تكتسب الدراسة أهمية نظرية من اعتمادها على مجموعة من مقاييس أداء المحافظ، مثل العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe، وBeta، وAlpha/Intercept، بما يسمح بقراءة أكثر شمولاً

للأداء بدلاً من الاكتفاء بمؤشر واحد. إضافة إلى ذلك، تسهم الدراسة في توضيح أثر اختلاف بيئة التطبيق بين السوق السعودي والسوق الأمريكي في نتائج المقارنة بين المنهجين، دون التعامل مع بيئة السوق كمتغير معدل بالمعنى الإحصائي الصارم.

2. الأهمية العملية:

تكمن الأهمية العملية للدراسة في تقديم مقارنة تطبيقية تساعد على فهم الفروق بين المحافظ المبنية وفق النموذج التقليدي والمحافظ المبنية باستخدام خوارزميات الذكاء الاصطناعي، وذلك من خلال مؤشرات واضحة وقابلة للقياس. وتساعد نتائج الدراسة المستثمرين والباحثين والمهتمين بإدارة المحافظ على تكوين تصور أوضح حول المنهجية الأكثر ملاءمة عند بناء المحافظ وإعادة توازنها، سواء من حيث تحقيق العائد أو ضبط المخاطرة أو تحسين الأداء المعدّل بالمخاطر.

كما تبرز الأهمية العملية في أن الدراسة لا تكتفي بعرض تفوق نظري لخوارزميات الذكاء الاصطناعي، بل تختبر أداءها مقارنة بالمنهج التقليدي في سوقين مختلفين، وباستخدام إعادة توازن نصف سنوية. وهذا يتيح فهماً أكثر واقعية لمدى قدرة الذكاء الاصطناعي على دعم قرارات بناء المحافظ، ويبيّن ما إذا كان دوره يظهر بصورة أوضح في تحسين العائد، أم في خفض المخاطرة، أم في دعم استقرار الأداء عبر الزمن.

تاسعاً: حدود الدراسة ومحدداتها:

تتحدد نتائج هذه الدراسة بمجموعة من الحدود والمحددات التي ينبغي أخذها في الاعتبار عند تفسير النتائج.

حدود زمانية:

1 .حدود الدراسة:

الحدود الزمانية: تقتصر الدراسة على الفترة الممتدة من بداية عام 2024 حتى نهاية عام 2025، مع اعتماد إعادة توازن نصف سنوية، بما ينتج أربع فترات تقييم نصف سنوية.

الحدود المكانية: تقتصر الدراسة على سوقين ماليين هما السوق السعودي والسوق الأمريكي، بوصفهما بيئتين تطبيقيتين مختلفتين من حيث العمق والسيولة وخصائص التداول.

حدود العينة: تقتصر الدراسة على عينة محددة من الأسهم داخل كل سوق، تم اختيارها وفق توافر البيانات وملاءمتها للتحليل والمقارنة بين المنهجيتين.

حدود المنهجيات المستخدمة: تعتمد الدراسة على منهجيتين في بناء المحافظ، هما المنهجية التقليدية القائمة على Markowitz/MVO، ومنهجية الذكاء الاصطناعي القائمة على DRL

محددات الدراسة:

تتمثل محددات الدراسة في مجموعة من العوامل التي قد تؤثر في تعميم النتائج. فقد اعتمدت الدراسة على فترة زمنية قصيرة نسبياً، وهي 2024–2025، الأمر الذي يجعل النتائج مرتبطة بخصائص هذه الفترة وظروفها السوقية. كما أن حجم العينة وعدد فترات إعادة التوازن نصف السنوية محدودان، مما قد يؤثر في قوة الاختبارات الإحصائية.

إضافة إلى ذلك، تعتمد الدراسة على البيانات التاريخية المتاحة من مصادر مالية إلكترونية، وقد تختلف دقة البيانات أو طريقة عرضها بين سوق وآخر. كما لم يتم إدخال تكاليف التداول والانزلاق السعري والسيولة بصورة مباشرة في النتائج النهائية، رغم أهميتها في تقييم أداء استراتيجيات إعادة التوازن. وبناءً على ذلك، تُقرأ نتائج الدراسة بوصفها نتائج تطبيقية ضمن حدود البيانات والمنهجية المستخدمة، وليست حكماً نهائياً مطلقاً على تفوق إحدى المنهجيتين في جميع الأسواق والفترات.

عاشراً: منهج الدراسة:

تعتمد هذه الدراسة على المنهج الوصفي–التحليلي في توصيف مفاهيم المحافظ الاستثمارية ومنهجيات بنائها ومقاييس أدائها. كما تعتمد على المنهج الكمي التطبيقي من خلال تشكيل محافظ استثمارية وفق منهجيتين: منهجية تقليدية قائمة على Markowitz/MVO، ومنهجية قائمة على خوارزميات الذكاء الاصطناعي DRL، ثم تحليل البيانات المالية الناتجة عن هذه المحافظ باستخدام المحاكاة التاريخية ومقارنة الأداء في السوقين السعودي والأمريكي.

الفصل الثاني:

الاطار النظري للدراسة

يهدف هذا الفصل إلى بناء الأساس النظري للدراسة من خلال عرض المفاهيم المالية المرتبطة ببناء المحافظ الاستثمارية، وبيان العلاقة بين العائد والمخاطرة، ومقاييس تقييم جودة الأداء المالي، كما يتناول الفصل النماذج المستخدمة في بناء وإعادة توازن المحافظ، بدءاً من النموذج التقليدي القائم على ماركويتز، وصولاً إلى خوارزميات الذكاء الاصطناعي والتعلم التعزيزي العميق، وبذلك يمهّد هذا الفصل للجانب التطبيقي الذي يقارن بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوقين السعودي والأمريكي.

وسيتم تناول الإطار النظري من خلال مبحثين رئيسيين:

المبحث الأول: المحافظ الاستثمارية وكفاءة الأسواق ومقاييس أداء المحافظ.

المبحث الثاني: نماذج بناء وإعادة توازن المحافظ بين المنهج التقليدي والذكاء الاصطناعي.

المبحث الأول: المحافظ الاستثمارية وكفاءة الأسواق ومقاييس أداء المحافظ

يتناول هذا المبحث الأساس المفاهيمي الذي تستند إليه الدراسة في تقييم أداء المحافظ الاستثمارية، من خلال توضيح مفهوم المحفظة، والعلاقة بين العائد والمخاطرة، ودور الأوزان والتنويع في تشكيل خصائص المحفظة. كما يعرض المبحث مفهوم كفاءة الأسواق بوصفه إطاراً تفسيرياً للمقارنة بين السوقين السعودي والأمريكي، ثم يوضح أهم مقاييس تقييم جودة الأداء المالي المستخدمة في الجانب التطبيقي، ولا سيما الانحراف المعياري، ومؤشر Sharpe، وBeta، وAlpha/Intercept.

1.1 ومفهوم العائد والمخاطرة ومفهوم المحفظة:

تُعرَّف المحفظة الاستثمارية بأنها تجميع منظم لمجموعة من الأصول المالية (مثل الأسهم والسندات والنقد وما في حكمه) يتم اختيارها وتوزيع الأوزان بينها بهدف تحقيق مزيج ملائم من العائد المتوقع والمخاطرة، ويقوم منطق المحفظة على أن قرار الاستثمار لا يُفهم بوصفه اختيار أصل منفرد، بل بوصفه قرار تخصيص للأموال بين عدة أصول تتفاعل عوائدها معاً، وهو ما يجعل "هيكل المحفظة" **(الأوزان)** عنصراً حاسماً في النتائج النهائية للاستثمار. (عوض، 2018)

ويُقصد بـ العائد مقدار التغير الذي يطرأ على قيمة الاستثمار خلال فترة زمنية محددة، ويمكن التعبير عنه كعائد بسيط أو عائد لوغاريتمي بحسب طبيعة التحليل، فعلى المستوى التطبيقي، يُستخدم العائد لقياس الأداء خلال فترة الاحتفاظ، كما يُستخدم في تقدير العائد المتوقع للمحفظة انطلاقاً من عوائد أصولها، ويأخذ مفهوم العائد بعدين متكاملين: العائد المحقق الذي يُقاس بعد نهاية الفترة، والعائد المتوقع الذي يمثل تقديراً مبنياً على بيانات سابقة أو افتراضات نموذجية.

أما المخاطرة في السياق المالي فتشير إلى عدم اليقين المرتبط بالعوائد المستقبلية، أي احتمال انحراف العائد المحقق عن العائد المتوقع. ويُقاس جانب مهم من المخاطرة كمياً عبر تشتت العوائد حول متوسطها، وهو ما يُعبَّر عنه غالباً بالتباين والانحراف المعياري. ومن منظور إدارة المحافظ، لا تُقاس المخاطرة فقط بارتفاع/انخفاض العائد، بل بدرجة "عدم الاستقرار" في العوائد، وبحساسية المحفظة لتغيرات السوق، وباحتمال التعرض لخسائر كبيرة خلال فترات التراجع. (Bodie، 2023)

وتنبع أهمية العلاقة بين العائد والمخاطرة من كونها تمثل جوهر القرار الاستثماري: فالسعي إلى عائد أعلى يرتبط عادةً بتحمل مخاطرة أعلى، لكن هذه العلاقة ليست خطية أو ثابتة عبر الزمن، إذ تتأثر بتغيرات ظروف السوق والدورات الاقتصادية وتبدّل الأنظمة السوقية بين حالات هدوء واضطراب، لذلك يصبح بناء المحفظة في جوهره محاولة لتحقيق مفاضلة بين هدفين متعارضين نسبياً: تعظيم العائد من جهة، والتحكم بالمخاطرة من جهة أخرى، ومن هنا يظهر دور "إدارة المحفظة" كعملية مستمرة تتضمن الاختيار والتوزيع والمتابعة وإعادة التوازن عندما تتغير خصائص الأصول أو يتغير السياق السوقي. (الزامل، 2018)

1.2 توزيع الأوزان والتنويع والارتباط:

تُعد عملية توزيع الأوزان جوهر بناء المحفظة الاستثمارية، لأن اختيار الأصول وحده لا يحدد أداء المحفظة ما لم يتم تحديد وزن كل أصل داخلها. فوزن الأصل يحدد مقدار مساهمته في العائد الكلي وفي المخاطرة الكلية للمحفظة، ولذلك تُفهم إدارة المحافظ بوصفها مسألة تخصيص أوزان قبل أن تكون مجرد عملية اختيار أسهم. (Bekaert، 2023)

ولا تتحقق فائدة التنويع بمجرد زيادة عدد الأصول داخل المحفظة، بل تعتمد على طبيعة العلاقة بين عوائد هذه الأصول. فإذا كانت الأصول تتحرك في الاتجاه نفسه بدرجة عالية، فإن أثر التنويع يكون محدوداً، أما إذا كانت الارتباطات بينها منخفضة أو سالبة، فإن ذلك يساعد على تخفيض تذبذب المحفظة الكلي. لذلك يُستخدم الارتباط بوصفه أداة لفهم العلاقة بين الأصول، بينما تُستخدم مصفوفة التغاير لاحقاً في نماذج بناء المحافظ لأنها تجمع بين اتجاه العلاقة ومستوى تذبذب كل أصل.(Dahlquist & Knight, 2026, Sec. 15.2)

وبذلك يمهّد مفهوم الأوزان والارتباط للانتقال إلى النماذج الكمية في بناء المحافظ، سواء في النموذج التقليدي القائم على Markowitz/MVO أو في نماذج الذكاء الاصطناعي التي تسعى أيضاً إلى إنتاج أوزان تحقق علاقة أفضل بين العائد والمخاطرة. (لأسعد، 2020)

1.3 كفاءة الأسواق وخصائص بيئة التطبيق:

تمثل كفاءة الأسواق المالية إطاراً تفسيرياً مهماً لفهم طبيعة حركة الأسعار واختلاف فرص تحقيق الأداء المتفوق بين سوق وآخر، فوفق فرضية كفاءة الأسواق، تعكس أسعار الأصول المالية المعلومات المتاحة بدرجات متفاوتة، وكلما زادت سرعة انعكاس المعلومات في الأسعار أصبح تحقيق تفوق مستمر على السوق أكثر

صعوبة. لذلك ترتبط فعالية نماذج بناء المحافظ بخصائص السوق من حيث العمق، والسيولة، وتوافر المعلومات، وسرعة انعكاس الأخبار في الأسعار.

ويُعد اختلاف خصائص الأسواق عاملاً مهماً عند دراسة أداء المحافظ الاستثمارية، لأن الأسواق الأكثر عمقاً وسيولة قد توفر بيانات أكثر انتظاماً وفرصاً أوسع للتنويع، في حين قد تتسم الأسواق الناشئة بدرجات أعلى من التذبذب أو محدودية البيانات أو تأثر أكبر بعوامل قطاعية محددة. ومن ثم فإن قراءة أداء المحافظ لا تنفصل عن البيئة السوقية التي تُطبق فيها النماذج(MSCI, 2025) .

كما تتأثر عوائد المحافظ بمجموعة من الظروف الاقتصادية والسوقية مثل أسعار الفائدة، والتضخم، والسيولة، وأسعار السلع الرئيسة في الأسواق المرتبطة بها، وتساعد هذه العوامل على تفسير تغير العلاقة بين العائد والمخاطرة عبر الزمن، مما يعزز أهمية استخدام مقاييس تجمع بين العائد والمخاطرة عند تقييم أداء المحافظ.

1.4 مقاييس أداء المحافظ الاستثمارية:

لا يكفي تقييم المحفظة الاستثمارية من خلال العائد المتوقع فقط، لأن ارتفاع العائد قد يكون ناتجاً عن تحمل مستوى أعلى من المخاطرة. لذلك تعتمد الدراسات المالية على مجموعة من المقاييس التي تربط بين العائد والمخاطرة، وتساعد على التمييز بين التفوق الحقيقي والتفوق الناتج عن التعرض لمخاطر أعلى (Dahlquist & Knight, 2026, Sec. 15.4) .

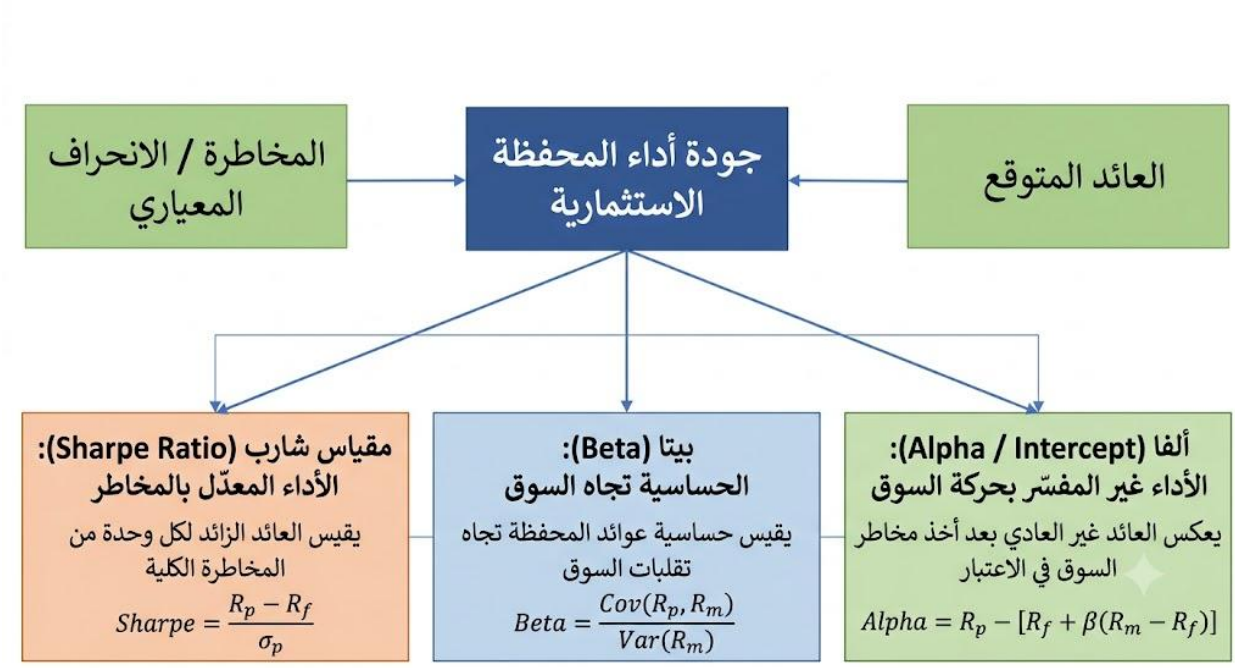
يُعد الانحراف المعياري من أكثر المقاييس استخداماً لقياس تذبذب العوائد، إذ يعكس درجة تشتت العوائد حول متوسطها. وكلما ارتفع الانحراف المعياري دلّ ذلك على ارتفاع مستوى المخاطرة الكلية للمحفظة. أما مؤشر Sharpeفيقيس العائد الإضافي الذي تحققه المحفظة مقابل كل وحدة من المخاطرة، ولذلك يُستخدم بوصفه مؤشراً للأداء المعدّل بالمخاطر. وتكون قيمة Sharpe الأعلى دلالة على أداء أفضل، بشرط قراءة المؤشر مع بقية خصائص المحفظة(Bank for International Settlements, 2024) .

وإلى جانبSharpe ، يُستخدم نموذج تسعير الأصول الرأسمالية CAPM لتفسير أداء المحفظة بعد أخذ المخاطر النظامية في الاعتبار. ويقيس معامل Beta حساسية عوائد المحفظة تجاه حركة السوق، بينما تمثل Alpha/Interceptالجزء من العائد الذي لا يفسره تعرض المحفظة للسوق، غير أن قراءة Alpha يجب أن ترتبط دائماً بالدلالة الإحصائية، لأن القيمة الموجبة وحدها لا تكفي للحكم على وجود تفوق استثماري مستقل.

وبناءً على ذلك، تعتمد الدراسة التطبيقية لاحقاً على العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe، إضافة إلى Beta وAlpha/Intercept ضمن تحليل CAPM، من أجل تقديم تقييم أكثر شمولاً لأداء المحافظ التقليدية ومحافظ الذكاء الاصطناعي.

الشكل رقم (1-1): العلاقة بين العائد والمخاطرة ومقاييس تقييم الأداء المالي

رسم توضيحي 2 العلاقة بين العائد والمخاطرة ومقاييس تقييم الأداء المالي



المصدر: من إعداد الباحث.

يوضح الشكل السابق أن تقييم جودة أداء المحفظة لا يعتمد على العائد المتوقع وحده، بل يتطلب قراءة مشتركة للعائد والمخاطرة والحساسية تجاه السوق، لذلك تُستخدم مقاييس مثل Sharpe وBeta وAlpha/Intercept لتقديم تقييم أكثر شمولاً للأداء المالي للمحفظة.

المبحث الثاني: نماذج بناء وإعادة توازن المحافظ الاستثمارية بين المنهج التقليدي والذكاء الاصطناعي:

يناقش هذا المبحث الأسس النظرية والمنهجية التي تقوم عليها عملية بناء وإعادة توازن المحافظ الاستثمارية، من خلال مقارنة المنهج التقليدي القائم على نموذج متوسط–التباين لماركويتز (MVO) مع المنهج الحديث القائم على خوارزميات الذكاء الاصطناعي، ولا سيما التعلم التعزيزي العميق (DRL) ويأتي هذا العرض انطلاقاً من أن جوهر إدارة المحفظة لا يتمثل في اختيار الأصول فقط، بل في تحديد الأوزان المناسبة لكل أصل، ومتابعة تغير هذه الأوزان عبر الزمن، وإعادة ضبطها عند فترات محددة.

ويعرض المبحث أولاً منطق النموذج التقليدي في استخدام العوائد التاريخية، والانحرافات المعيارية، ومصفوفة التغاير لاشتقاق أوزان المحفظة ضمن قيود محددة، ثم يناقش دور إعادة التوازن في ضبط انحراف الأوزان الناتج عن تغير الأسعار، بعد ذلك ينتقل المبحث إلى خوارزميات الذكاء الاصطناعي، موضحاً كيف يمكن لنماذج التعلم التعزيزي العميق أن تتعامل مع بناء المحفظة بوصفه سلسلة قرارات متتابعة تعتمد على حالة السوق، وقرار الأوزان، ودالة المكافأة.

وبذلك يربط هذا المبحث بين الأساس النظري لحساب الأوزان وبين المقارنة التطبيقية بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي، بما يوضح الفروق بين المنهجين من حيث مدخلات القرار، وطريقة حساب الأوزان، والتعامل مع المخاطرة، وآلية إعادة التوازن.

2.1 الأساس الكمي لبناء المحافظ: العوائد والمخاطر ومصفوفة التغاير:

تبدأ عملية بناء المحفظة الاستثمارية من تحويل البيانات السعرية للأصول المالية إلى عوائد قابلة للقياس والمقارنة، لأن سعر السهم وحده لا يعبّر عن الأداء الاستثماري ما لم يتم ربطه بنسبة التغير خلال فترة زمنية محددة. لذلك تمثل العوائد التاريخية نقطة البداية في أغلب النماذج الكمية لبناء المحافظ، سواء في النماذج التقليدية أو في النماذج الخوارزمية، لأنها توفر الأساس الذي تُشتق منه مؤشرات العائد والمخاطرة والعلاقات المشتركة بين الأصول. (Li، 2024)

ويُستخدم متوسط العوائد التاريخية بوصفه مؤشراً تقريبياً للعائد المتوقع، بينما يُستخدم الانحراف المعياري لقياس درجة تذبذب العوائد حول متوسطها. وكلما ارتفع الانحراف المعياري دلّ ذلك على زيادة عدم الاستقرار في عوائد الأصل أو المحفظة، غير أن تقييم المحفظة لا يعتمد على مخاطر كل أصل منفرداً فقط، لأن الأصول داخل المحفظة لا تتحرك بصورة مستقلة دائماً، بل قد ترتبط عوائدها بدرجات مختلفة من الارتباط أو التغاير.

ومن هنا تبرز أهمية مصفوفة التغاير، لأنها لا تقيس تذبذب كل أصل بشكل منفرد فحسب، بل تقيس أيضاً طبيعة الحركة المشتركة بين الأصول داخل المحفظة. فإذا كانت الأصول تتحرك بالاتجاه نفسه بدرجة مرتفعة، فإن قدرة التنويع على خفض المخاطرة تكون محدودة، أما إذا كانت العلاقات بينها منخفضة أو متباينة، فإن ذلك يساعد على تخفيض المخاطرة الكلية للمحفظة، لذلك تُعد مصفوفة التغاير مدخلاً أساسياً في النماذج التقليدية مثلMVO ، كما تبقى مهمة في النماذج الحديثة لأنها تساعد على فهم بنية المخاطر داخل مجموعة الأصول(Xu et al., 2024) .

وبناءً على ذلك، فإن البيانات الكمية المستخدمة في بناء المحافظ لا تقتصر على حساب العائد فقط، بل تشمل قياس التذبذب والعلاقات المشتركة بين الأصول، ثم تحويل هذه المعلومات إلى أوزان استثمارية قابلة للتطبيق. وهذا ما يجعل عملية بناء المحفظة عملية كمية مترابطة تبدأ من الأسعار والعوائد، وتنتهي بتحديد الأوزان وإعادة توازنها عبر الزمن. (Ledoit، Markowitz portfolios under transaction costs، 2025)

جدول رقم (2-1): المدخلات الكمية المستخدمة في بناء المحافظ الاستثمارية:

جدول 2 رقم (2-1) المدخلات الكمية المستخدمة في بناء المحافظ الاستثمارية

المدخل الكمي	دوره في بناء المحفظة
أسعار الإغلاق	تمثل نقطة البداية لاشتقاق العوائد التاريخية للأصول
العوائد التاريخية	تُستخدم لتقدير العائد المتوقع وتحليل سلوك الأصل عبر الزمن
متوسط العائد	يمثل مؤشراً تقريبياً للعائد المتوقع
الانحراف المعياري	يقيس درجة تذبذب العوائد ومخاطر الأصل أو المحفظة
الارتباط	يوضح اتجاه وقوة العلاقة بين عوائد الأصول
مصفوفة التغاير	تقيس الحركة المشتركة بين الأصول وتدخل في حساب مخاطرة المحفظة
قيود الأوزان	تساعد على منع التركز المفرط وجعل المحفظة أكثر واقعية
إعادة التوازن	تعيد ضبط الأوزان بعد تغيرها نتيجة حركة الأسعار

يوضح الجدول أن بناء المحفظة الاستثمارية يبدأ من البيانات السعرية، لكنه لا يتوقف عند حساب العوائد، بل يمتد إلى قياس المخاطرة والعلاقات المشتركة بين الأصول، وتُستخدم هذه المدخلات لاحقاً لاشتقاق أوزان المحفظة سواء وفق النموذج التقليدي أو وفق خوارزميات الذكاء الاصطناعي.

2.2. نموذج ماركويتز (MVO) ومصفوفة التغاير وقيود الأوزان:

يُعد نموذج متوسط–التباين لماركويتز (Mean–Variance Optimization: MVO) من أهم النماذج التقليدية المستخدمة في بناء المحافظ الاستثمارية، لأنه يحوّل قرار الاستثمار من مجرد اختيار مجموعة من الأسهم إلى مسألة كمية تهدف إلى تحديد الأوزان المثلى لكل أصل داخل المحفظة. ويقوم هذا النموذج على المفاضلة بين العائد المتوقع والمخاطرة، بحيث لا يكون الهدف تعظيم العائد فقط، بل تحقيق أفضل توازن ممكن بين العائد المتوقع ومستوى التذبذب الذي تتحمله المحفظة. (Boyd، 2024)

يعتمد نموذج MVO على ثلاثة مدخلات رئيسية: العوائد المتوقعة للأصول، والانحرافات المعيارية، ومصفوفة التغاير، وتظهر أهمية مصفوفة التغاير لأنها لا تكتفي بقياس تذبذب كل أصل بشكل منفرد، بل تقيس أيضاً الحركة المشتركة بين عوائد الأصول داخل المحفظة، فمخاطرة المحفظة لا تنتج عن مخاطر كل أصل على حدة فقط، وإنما تتشكل من طريقة تفاعل الأصول مع بعضها. لذلك قد يؤدي الجمع بين أصول ذات ارتباط منخفض أو تغاير محدود إلى تخفيض المخاطرة الكلية للمحفظة، حتى لو كانت بعض هذه الأصول مرتفعة التذبذب منفردة.

غير أن التطبيق العملي لنموذج ماركويتز لا يعتمد على المعادلات النظرية وحدها، بل يتطلب إدخال قيود تجعل الأوزان الناتجة أكثر واقعية وقابلة للتنفيذ. ومن أهم هذه القيود أن يكون مجموع الأوزان مساوياً للواحد الصحيح، وأن تكون الأوزان موجبة في حالة منع البيع على المكشوف، إضافة إلى إمكانية وضع حد أعلى لوزن الأصل الواحد بهدف تجنب التركز المفرط داخل المحفظة. وتساعد هذه القيود على منع النموذج من إنتاج محافظ شديدة التركز في عدد محدود من الأسهم، وهي مشكلة قد تظهر عند الاعتماد الكامل على البيانات التاريخية أو عند وجود تقديرات غير مستقرة للعوائد والتغايرات. (Xu، 2024)

وتبرز أهمية هذه القيود بصورة أوضح عند ربط بناء المحفظة بعملية إعادة التوازن، لأن تغير أسعار الأصول مع مرور الوقت يؤدي إلى تغير الأوزان الفعلية داخل المحفظة وانحرافها عن الأوزان المستهدفة. كما أن تعديل الأوزان يتطلب تنفيذ عمليات بيع وشراء قد ترتبط بتكاليف تداول وانزلاق سعري، الأمر الذي يجعل

المحفظة المثلى نظرياً مختلفة عن المحفظة المثلى عملياً. لذلك تُعد قراءة نموذج MVO مع قيود الأوزان وتكاليف التداول أكثر ملاءمة للتطبيق الواقعي من الاعتماد على النموذج في صورته النظرية المجردة .

وبناءً على ذلك، يشكّل نموذج ماركويتز أساساً تقليدياً مهماً للمقارنة مع خوارزميات الذكاء الاصطناعي، لأنه يوضح كيف يمكن تحويل العوائد والمخاطر والعلاقات بين الأصول إلى أوزان استثمارية قابلة للقياس. كما يوفّر هذا النموذج معياراً واضحاً يمكن من خلاله تقييم ما إذا كانت النماذج الحديثة، مثل التعلم التعزيزي العميق، قادرة على إنتاج أوزان أكثر كفاءة أو أكثر استقراراً عبر الزمن. (Ledoit، 2025)

2.3 إعادة التوازن التقليدية وتكاليف التداول ولماذا قد تُضعِف النتائج:

تُعرَّف إعادة التوازن الدورية (Periodic Rebalancing) بأنها عملية إعادة ضبط أوزان المحفظة إلى مستوياتها المستهدفة وفق جدول زمني محدد (شهري/ربع سنوي/نصف سنوي...)، وذلك لأن تغير أسعار الأصول يؤدي تلقائياً إلى انحراف الأوزان (Weight Drift) بمرور الوقت. هذا الانحراف لا يغيّر "شكل" المحفظة فقط، بل قد يحوّلها فعلياً إلى محفظة مختلفة من حيث التعرّض للمخاطر، فالأصل الذي يرتفع سعره يزداد وزنه، وبالتالي يرتفع تأثيره على المخاطرة الكلية وعلى سلوك العوائد، لذلك تُفهم إعادة التوازن في جوهرها كأداة لضبط هيكل المخاطر أكثر من كونها محاولة لتعظيم العائد بحد ذاته، لأنها تمنع التركز غير المقصود وتحافظ على الاتساق مع سياسة الاستثمار المستهدفة عبر الزمن، كما تشير الأدبيات الحديثة إلى أن إعادة التوازن الدوري تغيّر خصائص النتائج طويلة الأجل للمحفظة عبر الحدّ من تراكم التركز الناتج عن "فائزين قليلين" يهيمنون على المحفظة مع الزمن في استراتيجيات الشراء والاحتفاظ. (Arnott، 2024)

غير أن القيمة العملية لإعادة التوازن لا تكتمل دون إدخال البعد التنفيذي، لأن أي إعادة توازن تعني تنفيذ صفقات بيع وشراء ينتج عنها دوران للمحفظة(Turnover) ، ومن ثم تتحول "النتائج الورقية" (Backtests) إلى نتائج صافية قد تختلف جذرياً عند تطبيقها على أرض الواقع، ويشمل ذلك تكاليف مباشرة (عمولات، فروق أسعار البيع والشراء) وتكاليف غير مباشرة مثل الانزلاق السعري (Slippage) وتأثير السوق عند تنفيذ أوامر كبيرة. (Arnott، 2024)

لذلك قد يظهر تفوق نظري لاستراتيجية ما عندما تُقيّم بعوائد إجمالية قبل التكاليف، ثم يتلاشى جزء كبير من هذا التفوق عند إدخال التكاليف، وهو ما يُعرف بفجوة القصور التنفيذي أو الفجوة بين النتائج الحية والورقية (Implementation Shortfall).وتؤكد دراسات حديثة أن تقليل الدوران عبر "تصفية" أو "ترتيب" عمليات

إعادة التوازن (أي تنفيذ أهم الصفقات فقط) يمكن أن يحافظ على جزء كبير من مكاسب الاستراتيجية مع خفض جوهري للتكاليف، ما يبرز حساسية الأداء الصافي لتصميم سياسة إعادة التوازن.

وتتعاظم هذه الإشكالية عندما يتم تجاهل التكاليف في مرحلة بناء المحفظة ثم "دفعها بعد ذلك"، لأن ذلك قد يؤدي إلى أوزان مثالية رياضياً لكنها غير فعّالة اقتصادياً عند احتساب التكاليف، وتُظهر أدبيات حديثة في إطار ماركويتز أن إدخال تكاليف التداول بشكل صحيح داخل مرحلة الاختيار أو التحسين يمكن أن يُحسّن الأداء الصافي خصوصاً في الاستراتيجيات عالية الدوران وأن افتراض تكاليف متجانسة أو إضافتها بصورة لاحقة قد يعطي انطباعاً مضللاً عن جودة الأداء، كما تدعم دراسات أخرى الفكرة نفسها من زاوية مختلفة عبر إبراز أن الاستراتيجيات منخفضة الدوران أكثر قدرة على الاستمرار وأقل تعرضاً لتآكل العوائد بسبب التكاليف، وأن تقييد إعادة التوازن بطرق واقعية قد يرفع "قابلية التنفيذ" (Capacity) ويحد من تلاشي العائد الصافي. (Guo، 2024)

وبناءً على هذا المنطق، فإن اعتماد إعادة توازن نصف سنوية في هذه الدراسة يقدم كتسوية منهجية بين هدفين: (1) الحفاظ على انضباط هيكل المخاطر ومنع الانحراف الكبير في الأوزان، و(2) الحد من الدوران وتكاليف التنفيذ التي قد تُضعف النتائج إذا كانت إعادة التوازن عالية التواتر، وتدعم الأدبيات الحديثة هذا التوجه عبر إبراز أن تخفيض تواتر إعادة التوازن يقلل التكاليف ويحد من الفجوة بين الأداء الورقي والأداء الصافي، مع إمكانية الحفاظ على خصائص تنويع مقبولة إذا كان اختيار الأصول وأوزان البداية مبنياً على أسس كمية سليمة. (Ledoit، Markowitz portfolios under transaction costs، 2025)

2.4 الذكاء الاصطناعي والتعلم التعزيزي العميق في بناء المحافظ:

أدى تطور الذكاء الاصطناعي إلى ظهور اتجاهات حديثة في إدارة المحافظ الاستثمارية تقوم على استخدام الخوارزميات لاستخلاص أنماط من البيانات المالية واتخاذ قرارات تخصيص أكثر مرونة، ويختلف هذا المدخل عن النماذج التقليدية التي تعتمد غالباً على علاقات تاريخية محددة مسبقاً مثل العائد المتوقع ومصفوفة التغاير، إذ تسعى نماذج الذكاء الاصطناعي إلى التعامل مع البيانات بوصفها بيئة متغيرة يمكن التعلم منها بصورة مستمرة.

وضمن هذا الإطار، يُعد التعلم الآلي مدخلاً عاماً لبناء نماذج قادرة على التنبؤ أو التصنيف أو اكتشاف الأنماط، بينما يمثل التعلم العميق امتداداً أكثر تعقيداً يعتمد على الشبكات العصبية لاستخلاص العلاقات غير

الخطية من البيانات. أما التعلم التعزيزي، فيختلف عن هذين المدخلين لأنه لا يركز على التنبؤ فقط، بل يتعامل مع المشكلة بوصفها سلسلة قرارات متتابعة، حيث يتعلم النموذج من نتائج قراراته السابقة من خلال نظام مكافأة وعقوبة. (Espiga-Fernández، 2024)

وتظهر أهمية التعلم التعزيزي العميق في إدارة المحافظ لأنه يناسب طبيعة القرار الاستثماري الذي لا يتم مرة واحدة فقط، بل يتكرر عبر الزمن من خلال تحديد الأوزان، ومراقبة الأداء، وإعادة التوازن عند تغير ظروف السوق. لذلك يمكن النظر إلى DRL بوصفه إطاراً يحاول تعلم سياسة تخصيص قادرة على تحسين العلاقة بين العائد والمخاطرة، من خلال الاستفادة من البيانات التاريخية والإشارات السوقية المختلفة. (Li، 2024)

ولا يعني ذلك أن خوارزميات الذكاء الاصطناعي تتفوق دائماً على النماذج التقليدية، إذ إن فعاليتها تعتمد على جودة البيانات، وطريقة بناء دالة المكافأة، وحجم العينة، وتكاليف التداول، وقدرة النموذج على تجنب الإفراط في التعلم على البيانات التاريخية، لذلك تُعد المقارنة بين MVO وDRL مسألة تطبيقية مهمة، لأنها تسمح بفهم ما إذا كانت النماذج الحديثة تضيف فعلاً كفاءة في بناء المحافظ، أم أنها تحقق نتائج جيدة فقط في ظروف أو عينات محددة.

2.5 آلية عمل DRL في توليد الأوزان وإعادة التوازن:

يقوم التعلم التعزيزي العميق في إدارة المحافظ على تحويل عملية الاستثمار إلى بيئة قرار متتابعة، حيث يتفاعل وكيل ذكي مع السوق من خلال مراقبة حالة معينة، واتخاذ قرار استثماري، ثم الحصول على مكافأة تعكس جودة هذا القرار. وبهذا المعنى، لا يكون الهدف مجرد تقدير عائد أصل معين، بل تعلم سياسة تخصيص يمكنها إنتاج أوزان للمحفظة أو تعديل الأوزان القائمة استجابة لتغيرات السوق. (Jiang، 2024)

تتكون آلية DRL عادة من مجموعة عناصر رئيسية. تمثل البيئة السوق المالي أو بيانات المحفظة التي يتفاعل معها النموذج، بينما يمثل الوكيل الذكي الخوارزمية التي تتعلم القرار. أما الحالة فتشير إلى المعلومات المتاحة للنموذج عند لحظة اتخاذ القرار، مثل العوائد التاريخية، والتقلب، ومؤشرات السيولة، ومصفوفة التغاير، أو إشارات سوقية أخرى. في المقابل، يمثل الفعل القرار الاستثماري نفسه، وقد يكون تحديد أوزان جديدة للمحفظة أو تعديل الأوزان الحالية. أما المكافأة فهي المعيار الذي يتم على أساسه تقييم القرار، وقد تُصاغ على أساس العائد، أو العائد المعدّل بالمخاطر، أو العائد بعد خصم تكاليف التداول. (Li، 2024)

وتكمن أهمية دالة المكافأة في أنها توجه سلوك النموذج؛ فإذا كانت المكافأة مبنية على العائد فقط، فقد يميل النموذج إلى تحمل مخاطر مرتفعة، أما إذا تضمنت مؤشرات مثل التذبذب أو Sharpe أو تكاليف التداول، فإنها قد تدفع النموذج إلى البحث عن توازن أفضل بين العائد والمخاطرة. لذلك تُعد صياغة دالة المكافأة من أهم القرارات المنهجية في تطبيق DRL على المحافظ الاستثمارية، لأنها تحدد ما الذي يعتبره النموذج أداءً جيداً. (Espiga-Fernández، 2024)

ومن الناحية التطبيقية، يمكن أن ينتج DRL أوزان المحفظة بطريقتين رئيسيتين: إما من خلال توليد متجه أوزان مباشر يحدد حصة كل أصل داخل المحفظة، أو من خلال تحديد مقدار التعديل المطلوب على الأوزان الحالية. وتُعد الطريقة الثانية أكثر ارتباطاً بإدارة إعادة التوازن، لأنها تسمح للنموذج بمراعاة تكلفة التعديل وعدم إجراء تغييرات كبيرة في الأوزان إلا عندما تكون الفائدة المتوقعة من التعديل أكبر من تكلفته.

وبذلك تختلف آلية DRL عن النموذج التقليدي من حيث طبيعة القرار؛ فبينما يحل MVO مسألة تحسين رياضي بالاعتماد على مدخلات تاريخية محددة، يتعلم DRL سياسة قرار متتابعة تتغير مع تغير حالة السوق. وهذا الاختلاف لا يعني بالضرورة تفوق أحد المنهجين بشكل مطلق، لكنه يوضح أن المقارنة بينهما يجب أن تشمل طريقة إنتاج الأوزان، واستقرارها، وأثرها على العائد والمخاطرة عبر الزمن.

2.6 المقارنة النظرية بين MVO وDRL في حساب أوزان المحافظ:

بعد عرض النموذج التقليدي وخوارزميات الذكاء الاصطناعي، يتضح أن الاختلاف بين MVO و DRLلا يقتصر على اختلاف الأداة المستخدمة، بل يمتد إلى فلسفة بناء القرار الاستثماري. فالنموذج التقليدي ينطلق من تقدير العائد المتوقع ومصفوفة التغاير ثم يحل مسألة تحسين رياضي لاشتقاق الأوزان، بينما ينطلق DRL من قراءة حالة السوق وتعلم سياسة قرار من خلال التفاعل المتكرر مع البيانات ودالة المكافأة.

يتميز MVO بوضوحه الرياضي وسهولة تفسير نتائجه، لأن كل وزن ينتج عن علاقة مباشرة بين العائد المتوقع والمخاطرة والتغاير بين الأصول. وهذا يجعله نموذجاً معيارياً مهماً في الدراسات المالية، كما يجعله مناسباً للمقارنة مع المناهج الحديثة. غير أن هذا الوضوح يقابله قيد مهم، وهو حساسية النموذج للمدخلات التاريخية؛

فقد تؤدي تغيرات بسيطة في تقديرات العائد أو التغاير إلى تغيرات كبيرة في الأوزان المثلى. (Ledoit، Markowitz portfolios under transaction costs، 2025)

أما DRL فيتميز بقدرته النظرية على التعامل مع قرارات متتابعة ومعطيات سوقية متغيرة، لأنه لا يعتمد فقط على حل رياضي ثابت، بل يتعلم من خلال التجربة السابقة والعلاقة بين القرار والمكافأة. ويمكن لهذا المدخل أن يكون أكثر مرونة في بيئات السوق المتغيرة، خصوصاً عندما تُدمج في الحالة مؤشرات مثل التقلب والسيولة أو عندما تُصمم المكافأة لتجمع بين العائد والمخاطرة. ومع ذلك، فإن DRL يواجه تحديات تتعلق بتعقيد النموذج، وصعوبة تفسير القرار، واحتمال الإفراط في التكيف مع بيانات التدريب. (Jiang، 2024)

وبناءً على ذلك، فإن المقارنة بين MVO وDRL يجب ألا تُختزل في أيهما يحقق عائداً أعلى فقط، بل يجب أن تشمل قدرة كل منهج على إنتاج أوزان مستقرة، وضبط المخاطرة، وتحسين الأداء المعدّل بالمخاطر، والتعامل مع إعادة التوازن. ومن هذا المنطلق، يمثل هذا المبحث أساساً نظرياً للمقارنة التطبيقية اللاحقة بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي من حيث العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe، وBeta، وAlpha/Intercept.

جدول رقم (1-2): مقارنة نظرية بين نموذج MVO وخوارزميات DRL في بناء المحافظ:

جدول 3 رقم (2-2)مقارنة نظرية بين نموذج MVO وخوارزميات DRL في بناء المحافظ

البعد المقارن	النموذج التقليدي MVO	خوارزميات الذكاء الاصطناعي / DRL
أساس القرار	العائد المتوقع ومصفوفة التغاير	حالة السوق، البيانات التاريخية، ودالة المكافأة
طريقة حساب الأوزان	تحسين رياضي مباشر ضمن قيود محددة	تعلم سياسة قرار تنتج أوزاناً أو تعديلات على الأوزان
طبيعة النموذج	ساكن نسبياً ويعتمد على تقديرات تاريخية	ديناميكي وقابل للتكيف مع تغيرات السوق
التعامل مع المخاطرة	من خلال التباين أو الانحراف المعياري	من خلال دالة مكافأة قد تدمج العائد والمخاطرة والتكاليف
إعادة التوازن	تتم دورياً وفق قاعدة محددة	يمكن أن تتم وفق سياسة متعلمة أو توقيت ديناميكي
أبرز نقطة قوة	وضوح رياضي وسهولة تفسير	قدرة أعلى على التقاط العلاقات غير الخطية
أبرز قيد	حساسية عالية للمدخلات التاريخية	تعقيد النموذج وصعوبة تفسير القرار

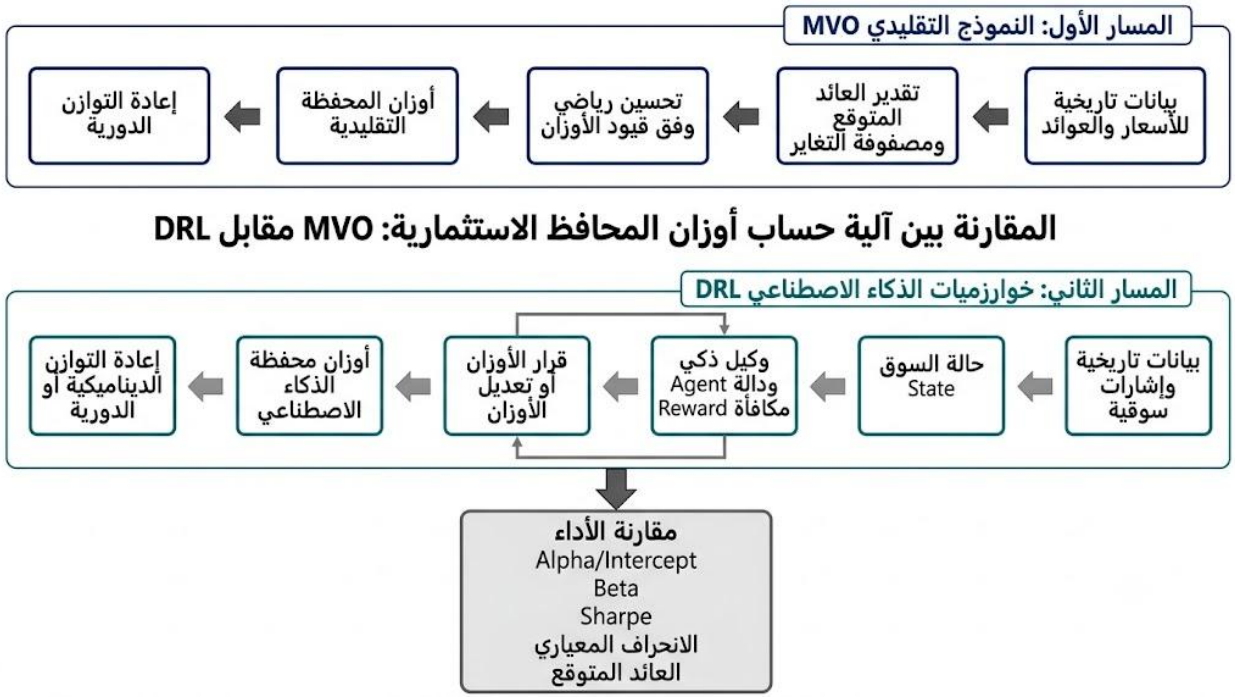
المصدر: من إعداد الباحث.

يوضح الجدول أن الاختلاف بين النموذج التقليدي وخوارزميات الذكاء الاصطناعي لا يقتصر على نتائج الأداء، بل يبدأ من طريقة إنتاج أوزان المحفظة. فبينما يعتمد نموذج MVO على تحسين رياضي مبني على

العوائد التاريخية ومصفوفة التغاير، تعتمد خوارزميات DRL على تعلم سياسة قرار تتفاعل مع حالة السوق ودالة المكافأة.

بعد عرض أوجه المقارنة النظرية بين نموذج MVO وخوارزميات DRL في الجدول السابق، يصبح من المفيد تقديم عرض بصري يوضح تسلسل خطوات بناء المحفظة في كل منهج، فالجدول يبيّن الفروق من حيث طبيعة القرار والمدخلات وطريقة التعامل مع المخاطرة، بينما يوضح الشكل الآتي المسار العملي الذي يبدأ من البيانات وينتهي إلى أوزان المحفظة ثم مقارنة الأداء.

الشكل رقم (1-2): آلية حساب أوزان المحافظ في النموذج التقليدي وخوارزميات الذكاء الاصطناعي:



رسم توضيحي 3 الفرق بين النموذجين ، المصدر: من إعداد الباحث.

يوضح الشكل السابق أن الاختلاف بين المنهج التقليدي ومنهج الذكاء الاصطناعي يبدأ من آلية إنتاج أوزان المحفظة، فالنموذج التقليدي يعتمد على البيانات التاريخية لتقدير العائد المتوقع ومصفوفة التغاير، ثم يستخدم التحسين الرياضي لاستخراج الأوزان ضمن قيود محددة. أما خوارزميات DRL فتعتمد على قراءة حالة السوق، وتعلّم سياسة قرار من خلال الوكيل الذكي ودالة المكافأة، وصولاً إلى إنتاج أوزان أو تعديل الأوزان عبر الزمن. وفي النهاية تُقارن مخرجات المنهجين من خلال مؤشرات العائد المتوقع، والانحراف المعياري، وSharpe، وBeta، وAlpha/Intercept.

يتضح من هذا المبحث أن بناء وإعادة توازن المحافظ الاستثمارية يمكن أن يتم وفق منطقين مختلفين. يقوم المنهج التقليدي، ممثلاً بنموذجMarkowitz/MVO ، على استخدام العوائد التاريخية ومصفوفة التغاير لاشتقاق أوزان تحقق توازناً بين العائد والمخاطرة ضمن قيود محددة. ويتميز هذا المنهج بالوضوح الرياضي وسهولة التفسير، إلا أنه يبقى حساساً للمدخلات التاريخية ولتغيرات السوق.

في المقابل، تقدم خوارزميات الذكاء الاصطناعي، ولا سيما التعلم التعزيزي العميقDRL ، مدخلاً أكثر ديناميكية لبناء المحافظ، لأنها تتعامل مع الاستثمار بوصفه سلسلة قرارات متتابعة تعتمد على حالة السوق ودالة المكافأة. ويتيح ذلك للنموذج إنتاج أوزان أو تعديلها بما يتلاءم مع تغيرات البيئة السوقية، مع إمكانية إدخال المخاطرة وتكاليف التداول ضمن آلية القرار.

وبذلك يوضح المبحث أن المقارنة بين النموذج التقليدي وخوارزميات الذكاء الاصطناعي لا ينبغي أن تقتصر على العائد المحقق فقط، بل يجب أن تشمل طريقة إنتاج الأوزان، واستقرارها، وقدرتها على ضبط المخاطرة، وتحسين الأداء المعدّل بالمخاطر. وهذا ما يمهّد للانتقال إلى الجانب التطبيقي، حيث سيتم اختبار أداء المحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوقين السعودي والأمريكي وفق مؤشرات مالية وإحصائية موحدة.

خاتمة الفصل الثاني:

خلص الفصل النظري إلى بناء إطار مفاهيمي ومنهجي يوضح الأساس الذي تقوم عليه الدراسة في مقارنة المحافظ التقليدية ومحافظ الذكاء الاصطناعي. فقد تناول المبحث الأول مفهوم المحفظة الاستثمارية، والعلاقة بين العائد والمخاطرة، ودور التنويع وكفاءة الأسواق في تفسير اختلاف الأداء، إضافة إلى عرض مقاييس تقييم جودة الأداء المالي مثل الانحراف المعياري، وSharpe، وBeta، و.Alpha/Intercept

أما المبحث الثاني فقد ركز على نماذج بناء وإعادة توازن المحافظ، من خلال عرض نموذج Markowitz/MVOبوصفه الإطار التقليدي المعتمد على العوائد التاريخية ومصفوفة التغاير، ثم عرض خوارزميات الذكاء الاصطناعي والتعلم التعزيزي العميق DRL بوصفها مدخلاً حديثاً لتوليد الأوزان وتعديلها عبر الزمن. كما بيّن الفصل أن الاختلاف بين المنهجين لا يتعلق بالنتائج النهائية فقط، بل يبدأ من طريقة معالجة البيانات، وآلية اتخاذ القرار، والتعامل مع المخاطرة، وسياسة إعادة التوازن.

وبناءً على ذلك، يوفر هذا الفصل الأساس النظري اللازم للانتقال إلى الفصل العملي، الذي سيختبر كفاءة كل من النموذج التقليدي وخوارزميات الذكاء الاصطناعي في بناء وإعادة توازن المحافظ الاستثمارية، من خلال

تطبيق المقارنة على السوقين السعودي والأمريكي وقياس الأداء باستخدام مؤشرات العائد، والمخاطرة، والأداء المعدّل بالمخاطر، وتحليل CAPM، واختبارات الفروق الإحصائية.

الفصل الثالث:

الاطار العملي للدراسة

في هذا الفصل سوف يتم عرض الجانب التطبيقي للدراسة، من خلال توضيح منهجية بناء المحافظ الاستثمارية وفق النموذج التقليدي ونموذج الذكاء الاصطناعي، ثم مقارنة أداء المحافظ في السوقين السعودي والأمريكي. وتعتمد المقارنة على مؤشرات العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe ، إضافة إلى تحليل الانحدار وفق نموذج CAPM واختبارات الفروق الإحصائية، بما يسمح بمناقشة فرضيات الدراسة في ضوء النتائج التطبيقية.

وينقسم الفصل إلى مبحثين رئيسيين؛ يتناول المبحث الأول منهجية الدراسة التطبيقية وعينة البحث، بينما يتناول المبحث الثاني عرض النتائج التطبيقية واختبار الفرضيات.

وسيتم تناول الإطار العملي من خلال المباحث الآتية:

المبحث الأول: منهجية الدراسة التطبيقية وعينة البحث

المبحث الثاني: اختبار الفرضيات ومناقشة النتائج

المبحث الأول: منهجية الدراسة التطبيقية وعينة الدراسة

في هذا المبحث سوف يتم عرض المنهجية التطبيقية المعتمدة في الدراسة، من حيث تحديد أسلوب بناء المحافظ، وعينة الدراسة في السوقين السعودي والأمريكي، وفترة الدراسة وتقسيمها الزمني، ومصادر البيانات والمتغيرات المستخدمة، وآلية بناء المحافظ وإعادة توازنها.

وتنبع أهمية هذا المبحث من كونه يشكل الجسر بين الإطار النظري والجانب العملي، إذ يتم من خلاله توضيح الطريقة التي تم بها تحويل المفاهيم النظرية المرتبطة بالعائد والمخاطرة، ونموذج ماركويتز ، وخوارزميات الذكاء الاصطناعي، إلى إجراءات كمية قابلة للقياس والمقارنة.

1.1 منهجية الدراسة التطبيقية:

تعتمد الدراسة الحالية على منهج كمي تطبيقي مقارن، يقوم على بناء محافظ استثمارية وفق منهجين رئيسيين: منهج تقليدي، ومنهج قائم على خوارزميات الذكاء الاصطناعي. وقد استند الجزء المتعلق بالمحافظ التقليدية إلى دراسة رنيم القضماني (2024) بعنوان: "تقييم أداء محافظ الاستثمار وفق استراتيجية أنظمة السوق الصاعد والهابط: دراسة تطبيقية باستخدام نموذج ماركوف متعدد العوامل على سوق تداول السعودية"، ولا سيما من حيث منطق بناء المحافظ، وإعادة الموازنة، وتقييم الأداء باستخدام مؤشرات مثل Sharpe و Alpha.

أما الجزء المتعلق بمحافظ الذكاء الاصطناعي، فقد استند إلى دراسة Sood and Papasotiriou (2023) بعنوان : "Deep Reinforcement Learning for Optimal Portfolio Allocation: A Comparative Study with Mean–Variance Optimization"، التي قارنت بين خوارزميات التعلم التعزيزي العميق ونموذج متوسط–التباين التقليدي في تخصيص المحافظ الاستثمارية، مع الاعتماد على مؤشرات الأداء المعدّل بالمخاطر.

وبناءً على ذلك، تم تصميم الدراسة الحالية لمقارنة كفاءة المحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوقين السعودي والأمريكي، من خلال قياس العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe، إضافة إلى تحليل Alpha و Beta باستخدام نموذج CAPM، بما يسمح بتقييم جودة الأداء بصورة كمية ومقارنة.

1.2 عينة الدراسة والأسواق محل التطبيق:

تم اختيار عينة الدراسة بما ينسجم مع هدف الدراسة في مقارنة كفاءة خوارزميات الذكاء الاصطناعي والنموذج التقليدي في بناء وإعادة توازن المحافظ الاستثمارية ضمن بيئتين سوقيتين مختلفتين، وقد تم تقسيم العينة إلى سوقين رئيسيين: السوق السعودي بوصفه سوقاً ناشئاً/صاعداً، والسوق الأمريكي بوصفه سوقاً متقدماً.

ويتيح هذا التقسيم اختبار مدى اختلاف أداء النماذج باختلاف خصائص السوق من حيث السيولة، وعمق التداول، وكفاءة انعكاس المعلومات في الأسعار.

وقد تم اعتماد طريقة عرض العينة في جداول مستقلة لكل سوق، بحيث يوضح كل جدول رمز الشركة، واسمها، والقطاع الذي تنتمي إليه، وتصنيف السهم، وسبب إدراجه ضمن العينة، ويهدف هذا العرض إلى إظهار التنوع القطاعي والسلوكي للعينة، من خلال الجمع بين أسهم دفاعية، وأسهم استثمارية/متوازنة، وأسهم هجومية، دون اعتبار هذا التصنيف متغيراً مستقلاً في الاختبارات الإحصائية.

1.2.1 السوق السعودي:

يمثل السوق السعودي، أو السوق المالية السعودية "تداول"، السوق المالي الرئيس في المملكة العربية السعودية، ويُعد من أكبر وأكثر الأسواق سيولة في منطقة الشرق الأوسط وشمال إفريقيا بحسب وصف Saudi Exchange. كما تم تصنيف السوق السعودي ضمن الأسواق الناشئة في مؤشرات MSCI، حيث أعلنت MSCI إدراج الأسهم السعودية ضمن مؤشر MSCI للأسواق الناشئة على مرحلتين ابتداءً من عام 2019. لذلك يُعد السوق السعودي مناسباً لاختبار أداء النماذج في بيئة سوقية ناشئة تتميز بخصائص مختلفة عن الأسواق المتقدمة من حيث العمق والسيولة وسرعة استيعاب المعلومات.(MSCI، 2019)

جدول عينة السوق السعودي:

جدول 4 عينة السوق السعودي، المصدر: من إعداد الباحث بالاعتماد على بيانات الشركات والأسواق المالية محل الدراسة..

رمز الشركة / رقم التداول	اسم الشركة	القطاع	تصنيف السهم	سبب الإدراج في العينة
1120.SR	مصرف الراجحي	المصارف	استثماري / متوازن	تم إدراجها لتمثيل قطاع مصرفي قيادي عالي السيولة داخل السوق السعودي، بما يضيف مكوناً مستقراً نسبياً للمحفظة.
1180.SR	البنك الأهلي السعودي	المصارف	استثماري / متوازن	تم إدراجها لتمثيل بنك كبير ذي وزن سوقي واضح، بما يسمح باختبار أداء المحفظة ضمن القطاع المالي.

2010.SR	سابك	المواد الأساسية / البتروكيماويات	هجومي / دوري	تم إدراجها لتمثيل الأسهم الدورية المرتبطة بالطلب الصناعي وأسعار المواد، بما يختبر حساسية النماذج للتقلبات القطاعية.
2222.SR	أرامكو السعودية	الطاقة	استثماري / متوازن	تم إدراجها لتمثيل قطاع الطاقة والشركات ذات الوزن السوقي الكبير، بما يعزز تنويع العينة داخل السوق السعودي.
2280.SR	المراعي	الأغذية والمشروبات	دفاعي	تم إدراجها لتمثيل قطاع استهلاكي أساسي أقل حساسية نسبياً للتقلبات السوقية، بما يضيف مكوناً دفاعياً للمحفظة.
4002.SR	المواساة للخدمات الطبية	الرعاية الصحية	دفاعي	تم إدراجها لتمثيل قطاع الرعاية الصحية، باعتباره قطاعاً يرتبط بطلب مستقر نسبياً مقارنة بالقطاعات الدورية.
7010.SR	الاتصالات السعودية STC	الاتصالات	دفاعي	تم إدراجها لتمثيل قطاع الاتصالات ذي الإيرادات المتكررة نسبياً، بما يدعم اختبار الأصول الأكثر استقراراً داخل المحفظة.
7020.SR	اتحاد اتصالات / موبايلي	الاتصالات	استثماري / متوازن	تم إدراجها لتوسيع تمثيل قطاع الاتصالات وعدم حصر العينة في شركة واحدة داخل القطاع نفسه.
7030.SR	زين السعودية	الاتصالات	هجومي نسبي	تم إدراجها لتمثيل سهم اتصالات أكثر حساسية للمنافسة والنمو التشغيلي، بما يضيف درجة أعلى من التباين داخل القطاع.
7202.SR	الشركة العربية لخدمات الإنترنت والاتصالات / solutions by stc	تقنية المعلومات	هجومي	تم إدراجها لتمثيل شركات الخدمات الرقمية والتقنية ذات الطابع النموّي داخل السوق السعودي.
7203.SR	شركة علم	تقنية المعلومات / الخدمات الرقمية	هجومي	تم إدراجها لتمثيل الشركات التقنية ذات النمو المرتبط بالتحول الرقمي، بما يختبر أداء النماذج في أصول أكثر نمواً وتقلباً.
9405.SR	صندوق البلاد المتداول للذهب	صندوق ETF / ذهب	دفاعي / تحوّطي	تم إدراجه كأداة تنويع وتحوط مرتبطة بالذهب، بما يساعد على اختبار قدرة النماذج على توزيع الأوزان خارج الأسهم التقليدية.

1.2.2 السوق الأمريكي:

يمثل السوق الأمريكي أحد أبرز الأسواق المالية المتقدمة عالمياً، ويتميز بارتفاع السيولة وعمق التداول وتنوع القطاعات والشركات المدرجة. ويُصنف ضمن الأسواق المتقدمة في مؤشرات MSCI، حيث يندرج مؤشر MSCI USA ضمن فئة Developed Markets، كما يغطي مؤشر MSCI USA الشركات الكبيرة والمتوسطة ويمثل نحو 85% من القيمة السوقية الحرة المعدلة في السوق الأمريكي. لذلك تم اعتماد السوق الأمريكي في الدراسة بوصفه بيئة متقدمة للمقارنة مع السوق السعودي، بهدف اختبار ما إذا كانت خوارزميات الذكاء الاصطناعي تقدم أداءً مختلفاً عند تطبيقها في سوق أكثر نضجاً وكفاءة.(2025) .MSCI

جدول عينة السوق الأميركي:

جدول 5 عينة السوق الأمريكي.، المصدر: من إعداد الباحث بالاعتماد على بيانات الشركات والأسواق المالية محل الدراسة

رمز الشركة / رقم التداول	اسم الشركة	القطاع	تصنيف السهم	سبب الإدراج في العينة
AMD	Advanced Micro Devices, Inc.	التكنولوجيا / أشباه الموصلات	هجومي	تم إدراجها لتمثيل أسهم النمو في قطاع أشباه الموصلات، بما يسمح باختبار أداء النماذج في أصول عالية الحساسية للتقلبات.
BIL	SPDR Bloomberg 1–3 Month T-Bill ETF	صندوق ETF / أذونات خزانة قصيرة الأجل	دفاعي	تم إدراجه لتمثيل أصل منخفض المخاطر نسبياً وشبيه بالنقد، بما يضيف مكوناً دفاعياً داخل المحفظة.
GOOGL	Alphabet Inc.	التكنولوجيا / خدمات الإنترنت والإعلانات الرقمية	استثماري / متوازن	تم إدراجها لتمثيل شركة تقنية كبرى ذات مركز سوقي قوي وسيولة مرتفعة، بما يضيف مكوناً متوازناً بين النمو والاستقرار.
JNJ	Johnson & Johnson	الرعاية الصحية	دفاعي	تم إدراجها لتمثيل قطاع الرعاية الصحية، باعتباره أقل حساسية نسبياً للدورات الاقتصادية مقارنة بقطاعات النمو.
JPM	JPMorgan Chase & Co.	الخدمات المالية / المصارف	استثماري / متوازن	تم إدراجها لتمثيل القطاع المالي الأمريكي من خلال بنك كبير عالي السيولة ومرتبط بأداء الاقتصاد الكلي.
META	Meta Platforms, Inc.	التكنولوجيا / المنصات الرقمية	هجومي	تم إدراجها لتمثيل شركات النمو المرتبطة بالإعلانات الرقمية والذكاء الاصطناعي، بما يضيف مكوناً عالي الحساسية للتقلبات.
MSFT	Microsoft Corporation	التكنولوجيا / البرمجيات	استثماري / متوازن	تم إدراجها لتمثيل شركة تقنية قيادية ذات نموذج أعمال متنوع وسيولة عالية، بما يضيف مكوناً مستقراً نسبياً داخل قطاع التكنولوجيا.
NVDA	NVIDIA Corporation	التكنولوجيا / أشباه الموصلات	هجومي	تم إدراجها لتمثيل سهم نمو عالي الحساسية لقطاع الذكاء الاصطناعي وأشباه الموصلات، بما يختبر أداء النماذج في الأصول الأكثر تقلباً.
PG	Procter & Gamble Co.	السلع الاستهلاكية	دفاعي	تم إدراجها لتمثيل الشركات الاستهلاكية الدفاعية ذات الطلب المستقر نسبياً، بما يوازن مخاطر أسهم التكنولوجيا والنمو.

TLT	iShares 20+ Year Treasury Bond ETF	صندوق ETF / سندات خزانة طويلة الأجل	دفاعي / تحوّطي	تم إدراجه كأداة تنويع مرتبطة بالسندات الحكومية طويلة الأجل، بما يسمح باختبار توزيع الأوزان بين الأسهم والدخل الثابت.
WMT	Walmart Inc.	التجزئة / السلع الاستهلاكية	دفاعي	تم إدراجها لتمثيل قطاع التجزئة الاستهلاكية الأساسية، بما يضيف سهماً أكثر استقراراً نسبياً داخل العينة.
XOM	Exxon Mobil Corporation	الطاقة	استثماري / دوري	تم إدراجها لتمثيل قطاع الطاقة الأمريكي، بما يوسّع التنويع القطاعي ويختبر حساسية المحفظة لتقلبات أسعار النفط والطاقة.

تم تصنيف الأسهم داخل كل سوق إلى أسهم دفاعية، وأسهم استثمارية/متوازنة، وأسهم هجومية، بهدف ضمان تنوع العينة وعدم حصر المحافظ في نمط واحد من الأصول. فالأسهم الدفاعية تمثل شركات أقل حساسية نسبياً للتقلبات الاقتصادية والسوقية، بينما تمثل الأسهم الاستثمارية/المتوازنة شركات ذات استقرار نسبي ومركز سوقي مناسب، في حين تعكس الأسهم الهجومية شركات أكثر حساسية للنمو والتقلبات. ويساعد هذا التنويع على اختبار قدرة كل من النموذج التقليدي وخوارزميات الذكاء الاصطناعي على بناء محافظ موزعة بين مستويات مختلفة من المخاطرة والعائد.

ويُستخدم هذا التصنيف لأغراض وصفية ومنهجية تتعلق بتوضيح تنوع العينة فقط، ولا يُعامل كمتغير مستقل إضافي في الاختبارات الإحصائية. وتبقى المقارنة الأساسية في الدراسة قائمة على منهج بناء المحفظة، أي النموذج التقليدي مقابل خوارزميات الذكاء الاصطناعي، مع تطبيق المقارنة في بيئتين سوقيتين مختلفتين: السوق السعودي والسوق الأمريكي.

1.3 فترة الدراسة وتقسيمها الزمني:

اعتمدت الدراسة على فترة تطبيقية مقسمة إلى أربع فترات نصف سنوية، وذلك بهدف قياس أداء المحافظ عبر الزمن بدلاً من الاكتفاء بفترة واحدة فقط. ويسمح هذا التقسيم باختبار مدى استقرار أداء المحافظ التقليدية ومحافظ الذكاء الاصطناعي عند إعادة التوازن بصورة دورية.

جدول 6 تقسيم فترات الدراسة. المصدر: من إعداد الباحث

رقم الفترة	الفترة الزمنية	الإجراء التطبيقي
الفترة الأولى	النصف الأول من عام 2024	بناء المحفظة وقياس الأداء
الفترة الثانية	النصف الثاني من عام 2024	إعادة توازن وقياس الأداء

إعادة توازن وقياس الأداء	النصف الأول من عام 2025	**الفترة الثالثة**
إعادة توازن وقياس الأداء	النصف الثاني من عام 2025	**الفترة الرابعة**

ويساعد هذا التقسيم الزمني على تقليل أثر اختيار فترة واحدة قد تكون منحازة صعوداً أو هبوطاً، كما يسمح بمقارنة أداء المنهجين عبر أكثر من مرحلة سوقية. كما أن اعتماد إعادة التوازن نصف السنوية ينسجم مع طبيعة الدراسات التي تقيس كفاءة المحافظ عبر فترات متتالية، بدلاً من التعامل مع المحفظة كقرار استثماري ثابت طوال فترة الدراسة.

وبناءً على هذا التقسيم، نتج عن الدراسة ثماني مشاهدات تحليلية على مستوى الأداء نصف السنوي، تتمثل في أربع مشاهدات للسوق السعودي وأربع مشاهدات للسوق الأمريكي، وتمثل كل مشاهدة أداء محفظة تقليدية ومحفظة ذكاء اصطناعي ضمن السوق والفترة نفسها، الأمر الذي يسمح بالمقارنة بين المنهجين عبر المؤشرات نفسها، كما يتيح لاحقاً استخدام اختبارات الفروق الإحصائية.

1.4 مصادر البيانات والمتغيرات المستخدمة:

اعتمدت الدراسة على بيانات مالية يومية تخص الأصول محل الدراسة في كل من السوق السعودي والسوق الأمريكي، إضافة إلى بيانات مؤشر السوق ومعدل العائد الخالي من المخاطر. وقد استُخدمت هذه البيانات في حساب عوائد الأصول، وعوائد المحافظ، والعوائد الزائدة، ومؤشرات الأداء المالي.

ويمكن تلخيص اهم البيانات من خلال الجدول التالي:

مؤشرات القياس المستخدمة في التحليل التطبيقي7 جدول

الغرض من استخدامها	نوع البيانات
حساب العوائد اليومية للأصول الداخلة في المحافظ	**أسعار الإغلاق اليومية للأصول**
قياس أداء المحافظ التقليدية ومحافظ الذكاء الاصطناعي	**عوائد المحافظ اليومية**
CAPM استخدامه كممثل لعائد السوق في تحليل	**عائد مؤشر السوق**
حساب العوائد الزائدة للمحفظة والسوق	**العائد الخالي من المخاطر**
تحديد توزيع الاستثمار بين الأصول في كل فترة	**أوزان المحافظ**
قياس الأداء والمخاطرة	**العائد المتوقع والانحراف المعياري**
قياس الأداء المعدل بالمخاطر	**مؤشر Sharpe**
تقييم الأداء غير العادي والحساسية تجاه السوق	**Alpha وBeta**

أما من حيث متغيرات الدراسة، فيمكن تحديدها كما يأتي:

المتغير المستقل: منهج بناء المحفظة: تقليدي أو ذكاء اصطناعي.

المتغيرات التابعة: العائد المتوقع، الانحراف المعياري، مؤشر Sharpe، Alpha، Beta

المتغيرات الضابطة: السوق محل التطبيق، فترة الدراسة، تواتر إعادة التوازن، طريقة القياس، العائد الخالي من المخاطر.

بيئة التطبيق: السوق السعودي والسوق الأمريكي.

1.5 آلية بناء المحافظ وإعادة التوازن:

تم بناء المحافظ الاستثمارية في الدراسة وفق منهجين رئيسيين. يتمثل المنهج الأول في النموذج التقليدي القائم على نموذج ماركويتز، والذي يعتمد على العوائد التاريخية، والانحرافات المعيارية، ومصفوفة التغاير بين الأصول بهدف تحديد الأوزان المثلى للمحفظة وفق العلاقة بين العائد والمخاطرة.

أما المنهج الثاني فيتمثل في خوارزميات الذكاء الاصطناعي، التي تهدف إلى إنتاج أوزان استثمارية أكثر قدرة على التكيف مع تغيرات السوق من خلال تحليل البيانات التاريخية ومؤشرات الأداء والمخاطرة. وبذلك، تقوم المقارنة بين منهج تقليدي يعتمد على العلاقات التاريخية بين الأصول، ومنهج خوارزمي يسعى إلى تعديل الأوزان بصورة أكثر ديناميكية.

ولضمان عدالة المقارنة، تم توحيد آلية إعادة التوازن في كلا المنهجين، بحيث تتم إعادة بناء المحافظ بصورة نصف سنوية. ويتيح ذلك اختبار قدرة كل منهج على الاستجابة لتغيرات السوق عبر الزمن، بدلاً من الاكتفاء بقياس أداء محفظة ثابتة خلال كامل فترة الدراسة.

المبحث الثاني: اختبار الفرضيات ومناقشة النتائج

بعد عرض منهجية الدراسة التطبيقية، يتم في هذا المبحث عرض النتائج التطبيقية للمقارنة بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوقين السعودي والأمريكي. ويبدأ التحليل بتقييم الأداء المالي للمحافظ، ثم عرض التوصيف الإحصائي لعوائدها اليومية، وبعد ذلك تحليل نتائج نموذج CAPM واختبارات الفروق الإحصائية، وصولاً إلى مناقشة الفرضيات ومقارنة النتائج مع الدراسات السابقة.

2.1 مؤشرات القياس المستخدمة في التحليل التطبيقي:

بعد تحديد منهجية الدراسة التطبيقية وعينة الدراسة، ينتقل هذا المبحث إلى عرض النتائج التطبيقية واختبار فرضيات الدراسة.

يعتمد عرض النتائج التطبيقية على تسلسل تحليلي يبدأ بتقييم الأداء المالي للمحافظ من حيث العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe، ثم ينتقل إلى التوصيف الإحصائي لعوائد المحافظ اليومية من خلال المتوسط، والانحراف المعياري، والالتواء، والتفلطح. وبعد ذلك يتم استخدام تحليل الانحدار وفق نموذج CAPM لقراءة Alpha/Intercept وBeta وR^2، ثم تُستخدم اختبارات الفروق الإحصائية للتحقق من دلالة الفروق بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي، وبين السوقين محل الدراسة.

وبناءً على هذا التقسيم، نتج عن الدراسة ثماني مشاهدات تحليلية على مستوى الأداء نصف السنوي، تمثلت في أربع فترات للسوق السعودي وأربع فترات للسوق الأمريكي، وتمثل كل مشاهدة أداء محفظة تقليدية ومحفظة ذكاء اصطناعي ضمن السوق والفترة نفسها، الأمر الذي يسمح بإجراء المقارنة بين المنهجين باستخدام اختبارات الفروق المرتبطة، إضافة إلى مقارنة حجم الفروق بين السوقين.

جدول مؤشرات القياس المستخدمة في التحليل التطبيقي:

جدول 8 المؤشرات والبيانات المحسوبة المصدر: من إعداد الباحث بالاعتماد على الأدبيات المالية ومقاييس تقييم أداء المحافظ.

المؤشر	الغرض من استخدامه	تفسيره
العائد المتوقع	قياس قدرة المحفظة على توليد عائد	القيمة الأعلى تعكس عائداً أفضل
المخاطر / الانحراف المعياري	قياس المخاطرة والتذبذب في عوائد المحفظة	القيمة الأقل تعكس مخاطرة أقل

مؤشر Sharpe	قياس الأداء المعدّل بالمخاطر	القيمة الأعلى تعكس أداءً أفضل مقابل كل وحدة مخاطرة
Mean Rp	متوسط العائد اليومي للمحفظة	يستخدم في التوصيف الإحصائي ودعم قراءة الأداء
Std Rp	الانحراف المعياري للعائد اليومي	يستخدم لقياس تذبذب العوائد اليومية
Skewness	قياس اتجاه عدم تماثل توزيع العوائد	القيم الموجبة أو السالبة تشير إلى ميل التوزيع
Kurtosis	قياس حدة التوزيع ووجود القيم المتطرفة	القيم المرتفعة تشير إلى ذيول سميكة وقيم متطرفة
Beta	قياس حساسية المحفظة تجاه حركة السوق	القيمة الأقل تعكس تعرضاً سوقياً أخف
Alpha / Intercept	مؤشر داعم للأداء غير المفسر بحركة السوق	تُقرأ مع قيمة الدلالة الإحصائية
p-value / Sig.	اختبار معنوية النتيجة	أقل من 0.05 يعني وجود دلالة إحصائية

يبيّن الجدول السابق المؤشرات المعتمدة في تقييم أداء المحافظ، حيث يُستخدم العائد المتوقع لقياس العائد، والانحراف المعياري لقياس المخاطرة، ومؤشر Sharpe لقياس الأداء المعدّل بالمخاطر، بينما تُستخدم مؤشرات Alpha/Intercept وBeta وR^2 لدعم قراءة الأداء وفق نموذج CAPM.

2.2 عرض نتائج الأداء المالي للمحافظ:

يبيّن هذا الجزء نتائج تقييم الأداء المالي للمحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوقين السعودي والأمريكي خلال الفترات نصف السنوية الأربع. ويعتمد التقييم على ثلاثة مؤشرات رئيسية، هي: العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe، وذلك بهدف المقارنة بين المنهجين من حيث القدرة على تحقيق العائد، وضبط المخاطرة، وتحسين الأداء المعدّل بالمخاطر.

2.2.1 تقييم الأداء المالي للمحافظ في السوق السعودي:

يبيّن الجدول الآتي نتائج تقييم الأداء المالي للمحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوق السعودي خلال الفترات نصف السنوية الأربع، وذلك من حيث العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe.

جدول 9 الأداء المالي للمحافظ في السوق السعودي

المصدر: من إعداد الباحث بالاعتماد على مخرجات Excel.

السوق السعودي	العائد المتوقع التقليدي	العائد المتوقع AI	الانحراف التقليدي/ المخاطرة	الانحراف AI/المخاطرة	Sharpe تقليدي	Sharpe AI
الفترة 1: النصف الأول 2024	20.03%	10.33%	13.47%	15.20%	1.302	0.318
الفترة 2: النصف الثاني 2024	24.52%	18.95%	9.35%	0.35%	2.356	38.835

الفترة 3: النصف الأول 2025	27.68%	6.34%	14.01%	2.29%	1.583	0.366
الفترة 4: النصف الثاني 2025	20.68%	6.73%	10.50%	1.61%	1.445	0.762

يبين الجدول نتائج تقييم أداء المحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوق السعودي عبر الفترات نصف السنوية، وذلك بالاعتماد على العائد المتوقع، والمخاطر المقاسة بالانحراف المعياري، ومؤشر Sharpe وتوضح النتائج أن المحافظ التقليدية حققت عوائد متوقعة أعلى من محافظ الذكاء الاصطناعي في جميع الفترات، مما يشير إلى أن المنهج التقليدي كان أكثر قدرة على توليد العائد داخل السوق السعودي خلال فترة الدراسة.

أما من حيث المخاطر، فقد أظهرت محافظ الذكاء الاصطناعي قدرة أوضح على خفض المخاطر في أغلب الفترات، وهو ما يعكس توجهاً أكثر تحفظاً في توزيع الأوزان مقارنة بالمحافظ التقليدية، غير أن هذا الانخفاض في المخاطر لم ينعكس دائماً على تفوق شامل في الأداء المعدّل بالمخاطر.

وبالنسبة إلى مؤشر Sharpe، فقد تفوقت المحافظ التقليدية في أغلب الفترات، باستثناء الفترة الثانية التي سجلت فيها محفظة الذكاء الاصطناعي قيمة مرتفعة جداً بلغت 38.835. ويمكن تفسير هذه القيمة أساساً بانخفاض المخاطر بدرجة كبيرة في تلك الفترة، وليس بارتفاع العائد وحده، وبناءً على ذلك، يمكن القول إن المحافظ التقليدية كانت أفضل في السوق السعودي من حيث العائد المتوقع وSharpe في معظم الفترات، بينما ظهرت ميزة محافظ الذكاء الاصطناعي بصورة أوضح في جانب خفض المخاطر.

2.2.2 تقييم الأداء المالي للمحافظ في السوق الأمريكي:

يبيّن الجدول الآتي نتائج تقييم الأداء المالي للمحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوق الأمريكي خلال الفترات نصف السنوية الأربع، وذلك من حيث العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe.

جدول 10 الأداء المالي للمحافظ في السوق الأمريكي

المصدر: من إعداد الباحث بالاعتماد على مخرجات Excel.

السوق الاميركي	العائد المتوقع التقليدي	العائد المتوقع AI	الانحراف التقليدي/ المخاطرة	الانحراف AI/المخاطرة	Sharpe تقليدي	Sharpe AI
الفترة 1: النصف الأول 2024	60.03%	22.76%	10.01%	1.62%	5.446	10.672
الفترة 2: النصف الثاني 2024	6.71%	4.20%	10.69%	2.21%	0.113	-0.588
الفترة 3: النصف الأول 2025	32.34%	36.47%	14.75%	1.46%	1.819	21.238
الفترة 4: النصف الثاني 2025	27.77%	13.00%	10.03%	0.91%	2.221	8.283

يبين الجدول نتائج تقييم أداء المحافظ في السوق الأمريكي، من خلال مقارنة المحافظ التقليدية بمحافظ الذكاء الاصطناعي وفق العائد المتوقع، والمخاطر، ومؤشر .Sharpe وتشير النتائج إلى أن المحافظ التقليدية حققت عوائد متوقعة أعلى في أغلب الفترات، بينما تفوقت محافظ الذكاء الاصطناعي في فترة واحدة فقط من حيث العائد المتوقع.

أما من حيث المخاطر، فقد أظهرت محافظ الذكاء الاصطناعي انخفاضاً واضحاً في مستوى المخاطر خلال جميع الفترات، مقارنة بالمحافظ التقليدية، ويعكس ذلك قدرة أعلى نسبياً لخوارزميات الذكاء الاصطناعي على ضبط التذبذب داخل السوق الأمريكي، وهو ما ينسجم مع طبيعة النماذج الخوارزمية التي تميل إلى تعديل الأوزان بصورة أكثر تحفظاً عند ارتفاع درجة التذبذب.

وبالنسبة إلى مؤشر Sharpe، فقد حققت محافظ الذكاء الاصطناعي أداءً أفضل في معظم الفترات، ما يدل على أن ميزتها في السوق الأمريكي ظهرت بصورة أوضح من خلال الأداء المعدّل بالمخاطر، وليس من خلال العائد المتوقع فقط. وبناءً على ذلك، يمكن القول إن السوق الأمريكي أظهر نتائج وصفية أكثر ملاءمة لمحافظ الذكاء الاصطناعي مقارنة بالسوق السعودي، ولا سيما من جانب خفض المخاطر وتحسين Sharpe في عدد من الفترات.

مما سبق نستنتج:

بالمقارنة بين السوقين تظهر النتائج الوصفية أن المحافظ التقليدية حققت عوائد متوقعة أعلى في السوق السعودي بصورة أكثر استقراراً، بينما لم تُظهر محافظ الذكاء الاصطناعي تفوقاً واضحاً إلا في جانب خفض التذبذب، أما في السوق الأمريكي، فقد كان تفوق المحافظ التقليدية واضحاً في العائد المتوقع في أغلب الفترات، إلا أن محافظ الذكاء الاصطناعي أظهرت أداءً أفضل وفق مؤشر Sharpe في معظم الفترات، نتيجة انخفاض الانحراف المعياري بشكل ملحوظ. وبذلك تشير المقارنة الأولية إلى أن أداء الذكاء الاصطناعي لم يكن متفوقاً من حيث العائد المطلق، لكنه بدا أكثر فاعلية في خفض المخاطرة وتحسين الأداء المعدّل بالمخاطر، ولا سيما في السوق الأمريكي.

2.3التوصيف الإحصائي لعوائد المحافظ اليومية:

بعد عرض مؤشرات الأداء المالي للمحافظ، يتم في هذا الجزء تقديم توصيف إحصائي مختصر لعوائد المحافظ اليومية، بهدف توضيح خصائص توزيع العوائد قبل الانتقال إلى تحليل الانحدار واختبارات الفروق.

وقد تم التركيز على المتوسط، والانحراف المعياري، والالتواء، والتفلطح، لأن هذه المؤشرات تساعد في فهم طبيعة العوائد اليومية ومدى وجود تذبذب أو قيم متطرفة في البيانات.

تم اختصار مخرجات SPSS في الجدول أعلاه، مع التركيز على المؤشرات الأكثر ارتباطاً بهدف الدراسة، بينما تم استبعاد القيم التفصيلية غير الضرورية مثل الخطأ المعياري والحدين الأدنى والأعلى تجنباً للإطالة.

جدول 11 التوصيف الإحصائي لعوائد المحافظ اليومية

المصدر: من إعداد الباحث بالاعتماد على مخرجات.SPSS

السوق	المنهج	N	أدنى قيمة Minimum	أعلى قيمة Maximum	Mean Rp	Std Rp	Skewness	Kurtosis
السعودي	تقليدي	486	−2.924	3.357	1.7537	4.97329	1.031	13.142
السعودي	ذكاء اصطناعي	501	−0.00052	0.000423	4.28E−06	7.74E−05	−0.157	7.085
الأمريكي	تقليدي	502	−0.00769	0.02118	−2.3E−05	0.001377	6.993	114.46
الأمريكي	ذكاء اصطناعي	502	−0.00186	0.000615	7.15E−06	0.000123	−6.663	106.725

يبين الجدول التوصيف الإحصائي لعوائد المحافظ اليومية في السوقين السعودي والأمريكي، من خلال عدد المشاهدات، وأدنى قيمة، وأعلى قيمة، والمتوسط، والمخاطر المقاسة بالانحراف المعياري، إضافة إلى الالتواء والتفلطح. ويهدف هذا الجدول إلى تقديم قراءة أولية لطبيعة توزيع العوائد قبل الانتقال إلى تحليل CAPM واختبارات الفروق الإحصائية.

في السوق السعودي، أظهرت المحفظة التقليدية نطاق تذبذب أوسع بين أدنى وأعلى قيمة مقارنة بمحفظة الذكاء الاصطناعي، كما سجلت مستوى مخاطر أعلى، في المقابل، جاءت محفظة الذكاء الاصطناعي بمخاطر أقل وتفلطح أقل نسبياً، مما يشير إلى أن توزيع عوائدها كان أكثر هدوءً مقارنة بالمحفظة التقليدية.

أما في السوق الأمريكي، فتشير قيم التفلطح المرتفعة إلى وجود قيم متطرفة وذيول سميكة في عوائد المحافظ اليومية، وهي سمة شائعة في بيانات الأسواق المالية، كما يظهر أن محافظ الذكاء الاصطناعي سجلت مستوى مخاطر أقل من المحافظ التقليدية، رغم وجود التواء واضح في توزيع العوائد. وبناءً على ذلك، فإن قراءة المتوسط وحده لا تكفي للحكم على الأداء، بل يجب ربطه بالمخاطر، وأدنى وأعلى القيم، وشكل توزيع العوائد، ثم دعمه بنتائج CAPM واختبارات الفروق.

2.4. تحليل الانحدار وفق نموذج CAPM:

بعد عرض مؤشرات الأداء المالي للمحافظ، تم استخدام تحليل الانحدار وفق نموذج CAPM بهدف تقييم أداء المحافظ بعد أخذ المخاطر النظامية في الاعتبار، ويتيح هذا التحليل استخراج معامل Beta الذي يقيس حساسية المحفظة تجاه السوق، وقيمة Alpha/Intercept بوصفها مؤشراً داعماً للأداء غير المفسر بحركة السوق، إضافة إلى قيمة R^2 التي توضح مدى قدرة عائد السوق على تفسير تغيرات عوائد المحفظة، وبذلك يساعد هذا التحليل على دعم المقارنة بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي، وعدم الاكتفاء بالمقارنة الوصفية للعائد والمخاطرة فقط.

جدول 12 نتائج تحليل الانحدار وفق نموذج CAPM

المصدر: من إعداد الباحث بالاعتماد على مخرجات تحليل الانحدار في SPSS.

السوق	المنهج	Mean Rp	Std Rp	Alpha / Intercept daily	Alpha / Intercept annual	Beta	R^2	p-alpha
السعودي	تقليدي	0.000175	0.004973	-1.3E-05	-0.00326	0.224	0.137	0.951
السعودي	ذكاء اصطناعي	4.28E-06	7.74E-05	5.84E-06	0.00147	0.009	0.844	0.342
الأمريكي	تقليدي	-2.3E-05	0.001377	2.03E-05	0.00511	-0.085	0.519	0.635
الأمريكي	ذكاء اصطناعي	7.15E-06	0.000123	4.22E-06	0.00106	0.006	0.296	0.361

يبين الجدول نتائج تحليل الانحدار وفق نموذجCAPM ، من خلال Alpha/Intercept و Betaو R^2وقيمة الدلالة الإحصائية. وتساعد هذه النتائج على فهم ما إذا كان أداء المحافظ ناتجاً عن التعرض لحركة السوق، أم عن أداء غير مفسر بحركة السوق.

تشير النتائج إلى أن محافظ الذكاء الاصطناعي سجلت معاملات Beta منخفضة في السوقين، مقارنة بالمحافظ التقليدية. ويدل ذلك على أن محافظ الذكاء الاصطناعي كانت أقل حساسية لحركة السوق خلال فترة الدراسة، وهو ما ينسجم مع النتائج السابقة التي أظهرت انخفاض مستوى المخاطر لديها.

أما من حيث Alpha/Intercept، فقد جاءت القيم اليومية صغيرة في جميع المحافظ، وهو أمر متوقع عند التعامل مع عوائد يومية. كما أن قيم الدلالة الإحصائية المرتبطة بـ Alpha/Intercept لا تقدم دليلاً كافياً على وجود Alpha معنوية لمحافظ الذكاء الاصطناعي عند مستوى الدلالة 5%، وبناءً على ذلك، لا تدعم نتائج CAPM فرضية تحقيق محافظ الذكاء الاصطناعي عائداً غير عادي ومعنوياً، لكنها تدعم القراءة التي تشير إلى أن ميزتها ظهرت بصورة أوضح في خفض المخاطر والحساسية السوقية.

2.5 اختبارات الفروق الإحصائية:

للمقارنة بين أداء المحافظ التقليدية ومحافظ الذكاء الاصطناعي عبر الفترات نصف السنوية، تم استخدام اختبار **Paired Samples T-Test**، وذلك لقياس ما إذا كانت الفروق بين المنهجين ذات دلالة إحصائية، يخدم هذا الاختبار الفرضيات المتعلقة بالفروق بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي من حيث العائد المتوقع وSharpe والانحراف المعياري.

بعد عرض مؤشرات الأداء المالي وتحليل الانحدار وفق نموذج CAPM، يتم في هذا الجزء اختبار ما إذا كانت الفروق بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي ذات دلالة إحصائية، ولهذا الغرض تم استخدام اختبار Paired Samples T-Test، نظراً لأن المقارنة تتم بين منهجين مطبقين على الفترات نفسها، وبالاعتماد على المؤشرات نفسها: العائد المتوقع، مؤشر Sharpe، والانحراف المعياري.

ويسمح هذا الاختبار بتحديد ما إذا كانت الفروق الظاهرة في الجداول السابقة تمثل فروقاً معنوية، أم أنها فروق وصفية غير كافية للحكم الإحصائي.

ويبين الجدول التالي نتائج اختبار الفروق بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي باستخدام Paired Samples T-Test:

جدول 13 نتائج اختبار Paired Samples T-Test

المؤشر	متوسط التقليدي	متوسط الذكاء الاصطناعي	الفرق: تقليدي - AI	t	df	Sig.	النتيجة
العائد المتوقع	0.2747	0.1485	0.1262	2.808	7	0.026	فرق معنوي لصالح التقليدي
مؤشر Sharpe	2.0357	9.6312	-7.5955	-1.633	7	0.146	لا يوجد فرق معنوي
الانحراف المعياري	0.116	0.0321	0.084	5.336	7	0.001	فرق معنوي لصالح الذكاء الاصطناعي من حيث انخفاض المخاطرة

المصدر: من إعداد الباحث بالاعتماد على مخرجات اختبار Paired Samples T-Test في SPSS.

يبين الجدول نتائج اختبار Paired Samples T–Test المستخدم للمقارنة بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي عبر الفترات نفسها وبالاعتماد على المؤشرات نفسها. ويساعد هذا الاختبار على معرفة ما إذا كانت الفروق الظاهرة في الجداول الوصفية فروقاً معنوية إحصائياً أم مجرد فروق وصفية.

تشير النتائج إلى وجود فرق معنوي في العائد المتوقع لصالح المحافظ التقليدية، حيث جاءت قيمة الدلالة أقل من مستوى 5%. وهذا يعني أن تفوق المحافظ التقليدية في العائد المتوقع لا يقتصر على كونه فرقاً وصفياً، بل يظهر كفرق معنوي إحصائياً.

أما بالنسبة إلى مؤشر Sharpe ، فرغم أن متوسطه كان أعلى لدى محافظ الذكاء الاصطناعي، إلا أن قيمة الدلالة لم تكن معنوية عند مستوى 5%. ولذلك لا يمكن الحكم إحصائياً بوجود تفوق حاسم لمحافظ الذكاء الاصطناعي من حيث الأداء المعدّل بالمخاطر.

وفيما يتعلق بالمخاطر، أظهر الاختبار وجود فرق معنوي لصالح محافظ الذكاء الاصطناعي، إذ كانت المخاطر المقاسة بالانحراف المعياري أقل لديها مقارنة بالمحافظ التقليدية. وبناءً على ذلك، يمكن القول إن التفوق الإحصائي الأكثر وضوحاً لمحافظ الذكاء الاصطناعي ظهر في جانب خفض المخاطر، بينما بقي التفوق في Sharpe غير محسوم إحصائياً.

2.6 اختبار الفروق بين السوق السعودي والسوق الأمريكي:

بعد اختبار الفروق بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي، يتم في هذا الجزء اختبار ما إذا كان حجم الفرق بين المنهجين يختلف باختلاف بيئة السوق.

وللمقارنة بين السوق السعودي والسوق الأمريكي من حيث حجم الفرق بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي، تم استخدام اختبار Independent Samples T–Test.

ولهذا الغرض، تم استخدام اختبار Independent Samples T–Test للمقارنة بين السوق السعودي والسوق الأمريكي، بالاعتماد على فرق الأداء المحسوب بين محافظ الذكاء الاصطناعي والمحافظ التقليدية وفق الصيغة: AI – Traditional. وقد شمل الاختبار فرق العائد المتوقع وفرق مؤشر Sharpe، بهدف

تحديد ما إذا كانت بيئة السوق تؤثر إحصائياً في حجم تفوق أو تراجع محافظ الذكاء الاصطناعي مقارنة بالمحافظ التقليدية.

يخدم هذا الاختبار الفرضية المتعلقة باختلاف حجم الفرق بين المنهجين باختلاف بيئة السوق.

جدول نتائج اختبار الفروق بين السوق السعودي والسوق الأمريكي:

جدول 14 نتائج اختبار Independent Samples T-Test

المؤشر	متوسط الفرق في السوق السعودي	متوسط الفرق في السوق الأمريكي	فرق المتوسطات	Levene Sig.	t	df	Sig.	النتيجة
فرق العائد المتوقع AI - تقليدي	-0.1264	-0.1260	-0.0003	0.15	-0.004	6	0.997	لا يوجد فرق معنوي بين السوقين
فرق مؤشر Sharpe AI - تقليدي	8.3989	6.7921	1.6068	0.128	0.16	6	0.878	لا يوجد فرق معنوي بين السوقين

المصدر: من إعداد الباحث بالاعتماد على مخرجات اختبار Independent Samples T-Test في SPSS.

تشير نتائج اختبار Independent Samples T-Test إلى عدم وجود فروق ذات دلالة إحصائية بين السوق السعودي والسوق الأمريكي في حجم الفرق بين محافظ الذكاء الاصطناعي والمحافظ التقليدية، فقد بلغ متوسط فرق العائد المتوقع −0.1264 في السوق السعودي مقابل −0.1260 في السوق الأمريكي، مع قيمة دلالة بلغت 0.997، وهي أعلى بكثير من مستوى الدلالة 5%. وهذا يعني أن تراجع محافظ الذكاء الاصطناعي مقارنة بالمحافظ التقليدية من حيث العائد المتوقع كان متقارباً بين السوقين، ولم يظهر اختلاف معنوي بينهما.

أما بالنسبة إلى فرق مؤشر Sharpe ، فقد بلغ متوسط الفرق 8.3989 في السوق السعودي مقابل 6.7921 في السوق الأمريكي، وكانت قيمة الدلالة 0.878، وهي أيضاً أكبر من 0.05. وبذلك، لا يمكن القول إن اختلاف بيئة السوق أدى إلى فرق معنوي في الأداء المعدّل بالمخاطر بين السوقين.

وبناءً على ذلك، فإن النتائج لا تدعم وجود اختلاف إحصائي جوهري بين السوق السعودي والسوق الأمريكي في حجم تفوق أو تراجع محافظ الذكاء الاصطناعي مقارنة بالمحافظ التقليدية. ومع ذلك، يمكن الإشارة وصفياً إلى أن الذكاء الاصطناعي أظهر قدرة أوضح على خفض المخاطرة وتحسين Sharpe في بعض الفترات، لكن هذا الاختلاف لم يصل إلى مستوى الدلالة الإحصائية عند المقارنة بين السوقين.

2.7 مناقشة الفرضيات ومقارنة النتائج مع الدراسات السابقة:

بعد عرض مؤشرات الأداء المالي للمحافظ، والتوصيف الإحصائي لعوائدها اليومية، وتحليل الانحدار وفق نموذج CAPM، واختبارات الفروق الإحصائية، يتم في هذا الجزء مناقشة فرضيات الدراسة في ضوء النتائج التطبيقية. كما تتم مقارنة هذه النتائج مع الأدبيات السابقة التي اعتمدت عليها الدراسة، بهدف توضيح نقاط الاتفاق والاختلاف بين نتائج الدراسة الحالي ونتائج الدراسات السابقة.

استناداً إلى مؤشرات الأداء المالي، ونتائج تحليل CAPM، واختبارات الفروق الإحصائية، يمكن مناقشة فرضيات الدراسة كما يأتي:

جدول 15 مناقشة الفرضيات

الفرضية	أداة الحكم	النتيجة
الفرضية الأولى: تفوق محافظ الذكاء الاصطناعي على المحافظ التقليدية في السوق السعودي من حيث Sharpe	جدول الأداء الوصفي للسوق السعودي	غير مدعومة وصفياً، إذ تفوقت المحافظ التقليدية في مؤشر Sharpe في أغلب الفترات، باستثناء الفترة الثانية التي ارتفع فيها Sharpe للذكاء الاصطناعي بسبب انخفاض الانحراف المعياري.
الفرضية الثانية: تفوق محافظ الذكاء الاصطناعي على المحافظ التقليدية في السوق الأمريكي من حيث Sharpe	جدول الأداء الوصفي للسوق الأمريكي + Paired T-Test العام	مدعومة وصفياً جزئياً، إذ تفوق الذكاء الاصطناعي في Sharpe في ثلاث فترات من أصل أربع، لكن اختبار Paired T-Test لم يُظهر فرقاً معنوياً في Sharpe عند مستوى 5% حيث بلغت Sig. = 0.146.
الفرضية الثالثة: تحقيق محافظ الذكاء الاصطناعي Alpha موجبة ومعنوية مقارنة بالتقليدي	CAPM / Regression	غير مدعومة إحصائياً، لأن قيم p-alpha كانت أعلى من 0.05، مما يعني عدم وجود دليل كافٍ على Alpha معنوية لمحافظ الذكاء الاصطناعي.
الفرضية الرابعة: اختلاف حجم تفوق الذكاء الاصطناعي بين السوق السعودي والسوق الأمريكي	Independent Samples T-Test	غير مدعومة إحصائياً، إذ بلغت Sig. لفرق العائد المتوقع 0.997، وSig. لفرق Sharpe 0.878، وكلاهما أكبر من 0.05.
الفرضية الخامسة: اختلاف درجة استقرار أداء محافظ الذكاء الاصطناعي مقارنة بالمحافظ التقليدية عبر الفترات نصف السنوية	االتحليل الوصفي للفترات نصف السنوية بالاعتماد على العائد المتوقع، والانحراف المعياري، ومؤشر Sharpe	مدعومة وصفياً جزئياً؛ إذ أظهرت محافظ الذكاء الاصطناعي قدرة أوضح على خفض المخاطرة، لكن تفوقها لم يكن مستقراً في العائد المتوقع أو Sharpe عبر جميع الفترات.

المصدر: من إعداد الباحث بالاعتماد على نتائج التحليل التطبيقي.

تُظهر نتائج الدراسة أن محافظ الذكاء الاصطناعي لم تحقق تفوقاً عاماً ومستقراً على المحافظ التقليدية في جميع المؤشرات. ففي السوق السعودي، كانت المحافظ التقليدية أفضل من حيث العائد المتوقع ومؤشر Sharpeفي أغلب الفترات، بينما ظهرت ميزة الذكاء الاصطناعي بشكل أوضح في جانب خفض الانحراف المعياري. أما في السوق الأمريكي، فقد أظهرت محافظ الذكاء الاصطناعي أداءً أفضل نسبياً وفق مؤشر Sharpeفي معظم الفترات، إلا أن هذا التفوق لم يكن معنوياً إحصائياً حسب اختبار Paired Samples T-Test.

كما بينت نتائج CAPM أن محافظ الذكاء الاصطناعي اتسمت عموماً بانخفاض معاملBeta ، بما يعكس حساسية محدودة تجاه حركة السوق، إلا أن قيم Alpha / Intercept لم تكن معنوية إحصائياً، وبالتالي لا يمكن الجزم بوجود قدرة مستقلة لمحافظ الذكاء الاصطناعي على توليد عائد غير عادي بعد ضبط أثر السوق.

أما اختبار الفروق بين السوقين، فقد أظهر أن اختلاف بيئة السوق بين السعودي والأمريكي لم ينتج فروقاً معنوية إحصائياً في حجم الفرق بين الذكاء الاصطناعي والنموذج التقليدي، سواء من حيث العائد المتوقع أو مؤشر Sharpe.

2.8. مقارنة نتائج الدراسة مع الدراسات السابقة:

تتفق الدراسة الحالية جزئياً مع دراسة القضماني (2024) من حيث أهمية إعادة التوازن واستخدام مؤشرات الأداء المعدّل بالمخاطر مثل Sharpe و Alphaفي تقييم المحافظ الاستثمارية، ولا سيما في بيئة السوق السعودي. فقد اعتمدت الدراسة الحالية، كما في دراسة القضماني، على منطق المقارنة بين المحافظ وقياس أدائها عبر مؤشرات تجمع بين العائد والمخاطرة. إلا أن نتائج الدراسة الحالية اختلفت من حيث عدم إثبات تفوق مستقر لمحافظ الذكاء الاصطناعي في السوق السعودي، حيث بقيت المحافظ التقليدية أفضل من حيث العائد المتوقع و Sharpeفي أغلب الفترات.

كما تختلف نتائج الدراسة الحالية جزئياً عن دراسة(2023) Sood and Papasotiriou ، التي أظهرت تفوق خوارزميات التعلم التعزيزي العميق على نموذج Mean-Variance Optimization من حيث العائد والأداء المعدّل بالمخاطر. ففي الدراسة الحالية، لم يظهر هذا التفوق بصورة شاملة أو معنوية إحصائياً، بل تركزت ميزة الذكاء الاصطناعي بصورة أوضح في خفض الانحراف المعياري وإدارة المخاطر، بينما بقيت المحافظ

التقليدية أفضل في العائد المتوقع في عدة فترات. ويمكن تفسير هذا الاختلاف باختلاف فترة الدراسة، وحجم العينة، وطريقة بناء النموذج، وخصائص السوقين محل التطبيق.

وبذلك، تقدم الدراسة الحالية نتيجة أكثر تحفظاً من بعض الدراسات الأجنبية؛ فهي لا تنفي أهمية الذكاء الاصطناعي في إدارة المحافظ، لكنها لا تؤكد تفوقه المطلق على النماذج التقليدية. فالنتائج تشير إلى أن الذكاء الاصطناعي قد يكون أكثر فاعلية في جانب ضبط المخاطر وخفض التذبذب، بينما لا يزال تفوقه في تحقيق عوائد أعلى أو Alpha معنوية بحاجة إلى اختبارات أوسع وفترات زمنية أطول.

جدول 16 مقارنة نتائج الدراسة مع الدراسات السابقة

الدراسة السابقة	مجال الاتفاق مع الدراسة الحالية	مجال الاختلاف
القضماني (2024)	الاتفاق في أهمية إعادة التوازن واستخدام Sharpe و Alpha لتقييم أداء المحافظ	الدراسة الحالية لم تجد تفوقاً مستقراً لمحافظ AI في السوق السعودي
Sood and Papasotiriou (2023)	الاتفاق في مقارنة DRL/AI مع نموذج MVO التقليدي	الدراسة السابقة وجدت تفوقاً أوضح للذكاء الاصطناعي، بينما الدراسة الحالية وجدت تفوقاً أساسياً في خفض المخاطرة لا في العائد
Yu and Chang (2025)	الاتفاق في أهمية الدمج بين الذكاء الاصطناعي وإعادة التوازن الديناميكي	الدراسة الحالية لم تثبت تفوقاً معنوياً شاملاً للذكاء الاصطناعي
Espiga-Fernández et al. (2024)	الاتفاق في أهمية تواتر إعادة التوازن وتأثيره على نتائج المحافظ	نتائج الدراسة الحالية أكثر تحفظاً بسبب محدودية الفترة والعينة

المصدر: من إعداد الباحث بالاعتماد على نتائج التحليل التطبيقي.

2.9 نتائج الدراسة:

بناءً على التحليلات السابقة، يمكن تلخيص أبرز النتائج التي توصلت إليها الدراسة في ضوء المقارنة بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي في السوقين السعودي والأمريكي بالنتائج التالية:

1. لم تُظهر محافظ الذكاء الاصطناعي تفوقاً واضحاً على المحافظ التقليدية في السوق السعودي من حيث مؤشر Sharpe ، إذ تفوقت المحافظ التقليدية في أغلب الفترات، باستثناء الفترة الثانية التي ارتفع فيها Sharpe لمحافظ الذكاء الاصطناعي نتيجة الانخفاض الكبير في الانحراف المعياري. وبذلك لا تدعم النتائج الفرضية الأولى بصورة مستقرة.

2. أظهرت محافظ الذكاء الاصطناعي في السوق الأمريكي تفوقاً وصفياً في مؤشر Sharpe في ثلاث فترات من أصل أربع، إلا أن اختبار الفروق العام لم يثبت معنوية هذا التفوق إحصائياً، حيث بلغت قيمة .Sig لمؤشر Sharpe مقدار 0.146. وبذلك تُعد الفرضية الثانية مدعومة وصفياً جزئياً، وغير مثبتة إحصائياً بشكل حاسم.

3. لم تقدم نتائج نموذج CAPM دليلاً كافياً على تحقيق محافظ الذكاء الاصطناعي Alpha موجبة ومعنوية، إذ لم تكن قيم Alpha/Intercept ذات دلالة إحصائية عند مستوى 5%. وبذلك لا تدعم النتائج الفرضية الثالثة المتعلقة بتحقيق عائد غير عادي بعد ضبط أثر السوق.

4. لم يظهر اختبار Independent Samples T-Test وجود فروق معنوية بين السوق السعودي والسوق الأمريكي في حجم الفرق بين المحافظ التقليدية ومحافظ الذكاء الاصطناعي، سواء من حيث فرق العائد المتوقع أو فرق مؤشر Sharpe ، حيث بلغت قيم الدلالة 0.997 و0.878 على التوالي. وبذلك لا تدعم النتائج الفرضية الرابعة المتعلقة باختلاف حجم التفوق بين السوقين.

5. أظهرت النتائج أن محافظ الذكاء الاصطناعي كانت أكثر قدرة على خفض المخاطر المقاسة بالانحراف المعياري، ولا سيما في السوق الأمريكي، إلا أن هذا التفوق لم يكن ثابتاً في جميع المؤشرات. فقد بقيت المحافظ التقليدية أفضل من حيث العائد المتوقع في معظم الفترات، بينما ظهر تفوق الذكاء الاصطناعي بصورة أوضح في جانب ضبط المخاطرة وتحسين Sharpe في بعض الفترات. وبذلك، فإن استقرار أداء الذكاء الاصطناعي يُعد نتيجة وصفية جزئية، وليس تفوقاً شاملاً ومؤكداً عبر الزمن.

2.10 التوصيات:

في ضوء النتائج التي توصلت إليها الدراسة، يمكن تقديم التوصيات الآتية:

1. توصي الدراسة بعدم التعامل مع خوارزميات الذكاء الاصطناعي كبديل كامل للنماذج التقليدية في بناء المحافظ الاستثمارية، بل كأداة داعمة يمكن دمجها مع نموذج Markowitz/MVO بهدف الاستفادة من مزايا كل منهجية .

2. توصي الدراسة بالتركيز على استخدام خوارزميات الذكاء الاصطناعي في جانب إدارة المخاطر وخفض التذبذب، نظراً لأن نتائج الدراسة أظهرت أن ميزتها كانت أوضح في خفض المخاطر المقاسة بالانحراف المعياري مقارنة بتحقيق تفوق ثابت في العائد المتوقع .

3. توصي الدراسة بتقييم أداء المحافظ الاستثمارية من خلال مجموعة متكاملة من المؤشرات، تشمل العائد المتوقع، والمخاطر، ومؤشر Sharpe ، و Beta، و Alpha/Intercept، وعدم الاكتفاء بالعائد المتوقع وحده عند الحكم على كفاءة المنهجية المستخدمة .

4. توصي الدراسة بقراءة نتائج النماذج الخوارزمية في ضوء خصائص بيئة التطبيق، لأن أداء خوارزميات الذكاء الاصطناعي قد يتأثر بعمق السوق، ومستوى السيولة، وتوافر البيانات، وطبيعة التقلبات السعرية .

5. توصي الدراسة بإجراء دراسات لاحقة تعتمد فترات زمنية أطول وعينات أوسع، بما يسمح باختبار استقرار النتائج بصورة أدق، وتعزيز القدرة على تعميم النتائج على أسواق أو قطاعات أخرى .

6. توصي الدراسة بإدخال تكاليف التداول والانزلاق السعري والسيولة ضمن التحليل في الدراسات المستقبلية، لأن هذه العوامل قد تؤثر في الأداء الفعلي لاستراتيجيات إعادة التوازن، ولا سيما عند استخدام نماذج ديناميكية أو خوارزمية .

7. توصي الدراسة باستخدام مقاييس أداء إضافية في الأبحاث اللاحقة، مثل Sortino و Calmar و Max Drawdown، لأنها قد تقدم قراءة أعمق لأداء المحافظ خلال فترات الهبوط والتقلبات الحادة.

الكتب والمراجع:

الكتب العربية:

عوض، سمير. (2019). إدارة المحافظ الاستثمارية. الإسكندرية: دار الفكر الجامعي.

الزامل، خالد .(2018) .*التحليل المالي وتقييم الأداء* .الرياض: دار المريخ.

المجلات والمقالات العربية:

الأسعد، نبيل. (2020). تأثير الأزمات الجيوسياسية على أداء الأسواق المالية العربية .*مجلة الدراسات الاقتصادية والمالية*.

العيد، سمية. (2024). تقييم أداء المحافظ الاستثمارية لصناديق الأسهم السعودية بالاعتماد على العائد والمخاطرة: دراسة تحليلية من 2013 إلى 2022.

القضماني، رنيم. (2024). تقييم أداء محافظ الاستثمار وفق استراتيجية أنظمة السوق الصاعد والهابط: دراسة تطبيقية باستخدام نموذج ماركوف متعدد العوامل على سوق تداول السعودية،HIBA.

Books:

Bodie, Z., Kane, A., & Marcus, A. J. (2023). *Investments* (13th ed.). McGraw Hill.

Dahlquist, J., & Knight, R. (2026). *Principles of finance 2e*. OpenStax. https://openstax.org/details/books/principles-finance-2e

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.

Foreign references (refereed articles and research)

Acero, F., Zehtabi, P., Marchesotti, N., Cashmore, M., Magazzeni, D., & Veloso, M. (2024). Deep reinforcement learning and mean-variance strategies for responsible portfolio optimization. *arXiv preprint arXiv:2403.16667*.

Ardia, D., Barras, L., Gagliardini, P., & Scaillet, O. (2024). Is it alpha or beta? Decomposing hedge fund returns when models are misspecified. *Journal of Financial Economics, 154*, Article 103805. https://doi.org/10.1016/j.jfineco.2024.103805

Arnott, R. D., Li, F., & Linnainmaa, J. T. (2024). Smart rebalancing. *Financial Analysts Journal*, *80*(2), 26–51.

Bekaert, G., & Harvey, C. R. (2023). Emerging equity markets and market integration. *Journal of Finance*.

Boyd, S., Johansson, K., Kahn, R., Schiele, P., & Schmelzer, T. (2024). Markowitz portfolio construction at seventy. *Journal of Portfolio Management, 50*(8), 117–160.

De Nard, G., & Zhao, Z. (2023). Using, taming or avoiding the factor zoo? A double-shrinkage estimator for covariance matrices. *Journal of Empirical Finance, 72*, 23–35. https://doi.org/10.1016/j.jempfin.2023.02.003

Espiga-Fernández, F., García-Sánchez, Á., & Ordieres-Meré, J. B. (2024). A systematic approach to portfolio optimization: A comparative study of reinforcement learning agents, market signals, and investment horizons. *Algorithms, 17*(12), 570. https://doi.org/10.3390/a17120570

Goodarzi, M., & Meinerding, C. (2025). Asset allocation with recursive parameter updating and macroeconomic regime identifiers. *European Journal of Finance, 31*(9), 1141–1167.

Guo, S., Gu, J.-W., Ching, W.-K., & Lyu, B. (2024). Adaptive online mean-variance portfolio selection with transaction costs. *Quantitative Finance*, *24*(1), 59–82. https://doi.org/10.1080/14697688.2023.2287134

Huang, X. (2024). Single-stage portfolio optimization with automated machine learning for M6. *International Journal of Forecasting*. https://doi.org/10.1016/j.ijforecast.2024.08.004

Irvine, P., Kim, J. H., & Ren, J. (2024). The beta anomaly and mutual fund performance. *Management Science, 70*(1), 143–163. https://doi.org/10.1287/mnsc.2022.4639

Jang, B., & So, I. (2024). Stock returns and monetary policy stance. *International Review of Economics & Finance*, *92*, 851–869. https://doi.org/10.1016/j.iref.2024.02.062

Jeon, J. H., Lee, Z., & Park, D. (2025). Reinforcement learning based dynamic asset allocation with technical and macro-economic analysis. *Journal of Economic Development*, *50*(3), 123–145.

Jiang, Y., Olmo, J., & Atwi, M. (2024). Deep reinforcement learning for portfolio selection. *Global Finance Journal, 62*, Article 101016. https://doi.org/10.1016/j.gfj.2024.101016

Ledoit, O., & Wolf, M. (2025). Markowitz portfolios under transaction costs. *The Quarterly Review of Economics and Finance*, *100*, Article 101962. https://doi.org/10.1016/j.qref.2025.101962

Li, H., & Hai, M. (2024). Deep reinforcement learning model for stock portfolio management based on data fusion. *Neural Processing Letters, 56*, 108.

Sood, S., Papasotiriou, K., Vaiciulis, M., & Balch, T. (2026). Deep reinforcement learning for optimal portfolio allocation: A comparative study with mean-variance optimization. *arXiv preprint arXiv:2602.17098*.

Steuer, R. E., Qi, Y., & Wimmer, M. (2024). Computing cardinality constrained portfolio selection efficient frontiers via closest correlation matrices. *European Journal of Operational Research, 313*(2), 628–636. https://doi.org/10.1016/j.ejor.2023.08.026

Sutiene, K., Schwendner, P., Sipos, C., Lorenzo, L., Mirchev, M., Lameski, P., Kabasinskas, A., Tidjani, C., Ozturkkal, B., & Cerneviciene, J. (2024). Enhancing

portfolio management using artificial intelligence: A literature review. *Frontiers in Artificial Intelligence, 7*, Article 1371502.

Valadkhani, A. (2025). Inflation-driven instability in US sectoral betas. *Journal of Asset Management, 26*, 506–513. https://doi.org/10.1057/s41260-025-00413-3

Vendrame, V., Guermat, C., & Tucker, J. (2023). A conditional higher-moment CAPM. *International Review of Financial Analysis, 86*, Article 102524. https://doi.org/10.1016/j.irfa.2023.102524

Xu, W., Tang, J., Yiu, K. F. C., & Peng, J. W. (2024). An efficient global optimal method for cardinality constrained portfolio optimization. *INFORMS Journal on Computing, 36*(2), 690–704.

Yu, J., & Chang, K.-C. (2025). Smart tangency portfolio: Deep reinforcement learning for dynamic rebalancing and risk–return trade-off. *International Journal of Financial Studies, 13*(4), 227. https://doi.org/10.3390/ijfs13040227

التقارير والمصادر المؤسساتية الأجنبية:

Bank for International Settlements. (2024). *Annual economic report 2024*. BIS. https://www.bis.org/publ/arpdf/ar2024e.pdf

International Monetary Fund. (2025). *Global financial stability report: Shifting ground beneath the calm, Chapter 2: Risk and resilience in the global foreign exchange market*. IMF. https://www.imf.org/-/media/files/publications/gfsr/2025/october/english/ch2.pdf

MSCI. (2019). *Saudi Arabia inclusion and emerging markets*. MSCI. https://www.msci.com/www/blog-posts/saudi-arabia-inclusion-and/01297979912

MSCI. (2025). *MSCI market classification framework 2025*. MSCI. https://www.msci.com/downloads/web/msci-com/indexes/index-resources/market-classification/MSCI_MARKET_CLASSIFICATION_FRAMEWORK_2025.pdf

المواقع الإلكترونية ومصادر البيانات:

Argaam. (n.d.). *Argaam*. Retrieved July 27, 2026, from https://www.argaam.com

Google. (n.d.). *Google Colab*. Retrieved July 27, 2026, from https://colab.research.google.com

Investing.com. (n.d.). *Investing.com*. Retrieved July 27, 2026, from https://www.investing.com

Yahoo Finance. (n.d.). *Yahoo Finance*. Retrieved July 27, 2026, from https://finance.yahoo.com