

## ***Building investment portfolios using the Python programming language: Experimental comparison between machine learning algorithms and the traditional method of Markowitz in the Iraq Stock Exchange***

Ali A. Ibrahim<sup>1</sup>, Faril M. Edan<sup>2</sup>, Maryam H. Mohsen<sup>3\*</sup>

<sup>1,2,3</sup>Department of Banking Management Economics, College of Business Economics, Al-Nahrain University, Baghdad, Iraq

[prof.ali@nahrainuniv.edu.iq](mailto:prof.ali@nahrainuniv.edu.iq), [Fryal@nahrainuniv.edu.iq](mailto:Fryal@nahrainuniv.edu.iq), [maryam.mebe23@ced.nahrainuniv.edu.iq](mailto:maryam.mebe23@ced.nahrainuniv.edu.iq)

### **Article information:**

Received: 12-06- 2025

Revised: 15-07- 2025

Accepted: 22-07- 2025

Published: 25-04- 2026

### **Corresponding author:**

Maryam H. Mohsen

[maryam.mebe23@ced.nahrainuniv.edu.iq](mailto:maryam.mebe23@ced.nahrainuniv.edu.iq)



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

### **Abstract:**

This study aims to improve the methods of building investment portfolios for a sample of Iraqi banks listed on the Iraq Stock Exchange, by comparing traditional methods such as the Markowitz model with modern techniques based on machine learning. Markowitz's model focuses on balancing return and risk using the Medium-Variance Optimization Framework, a traditional model that many financial institutions rely on. In contrast, the study seeks to explore the possibilities of machine learning techniques such as key component analysis (PCA), Supporting Vector Machine (SVM), logistic regression, and random forest in improving the performance of the investment portfolios of these banks in a volatile environment such as the Iraq Stock Exchange. These techniques are based on the processing and analysis of big financial data to detect hidden patterns and relationships that can contribute to increasing returns and reducing risk more effectively than traditional methods. The historical financial data of the shares and assets of the banks concerned were also used to evaluate the performance of portfolios using indicators such as expected return, variance, and Sharpe ratio, with the aim of providing innovative solutions that help banks make smarter and more effective investment decisions commensurate with local market conditions and the economic and political challenges they face. As for the methods used in the research, the following mathematical equations were used in building an optimal investment portfolio: expected return, which measures the expected performance of a portfolio based on asset weights and return expectations; the Sharpe rate, which measures the return achieved by a portfolio per unit of risk and is an indicator of risk-adjusted performance; and variance, which is used to measure the volatility of returns and analyze the risks associated with each portfolio. The study proved that the use of machine learning techniques can improve portfolio performance more than Traditional methods in volatile market environments such as the Iraq Stock Exchange. Techniques such as key component analysis (PCA) and random forest have shown a significant ability to increase returns and reduce risk compared to the traditional Markowitz model. Accordingly, it is recommended that Iraqi banks adopt machine learning techniques in portfolio building strategies, as these technologies can help deal with local economic and political challenges and achieve more effective investments.

**Keywords:** Markowitz model, support vector machine, logistic Regression, random forests principal Component analysis, machine learning.



## Conclusions:

1. The machine learning algorithms presented showed a clear variation in performance when used to optimize portfolio building, as the Key Components Analysis (PCA) algorithm outperformed other algorithms by achieving the highest Sharpe ratio, reflecting its great ability to achieve stable returns with very low risk.
2. The SVM algorithm has shown strong performance in terms of reward-risk balance, making it an effective choice especially for investors looking to reduce risk while maintaining reasonable returns.
3. Although the Random Forest algorithm offered relatively superior returns, it was accompanied by higher risks compared to PCA and SVM algorithms, suggesting that it should be used with caution by more risk-tolerant investors.
4. Despite the simplicity of logistic regression, its performance was lower compared to other algorithms in terms of matching return and risk, limiting its efficiency in optimizing investment portfolios in complex environments.
5. These results confirm the importance of using advanced machine learning algorithms in portfolio management, especially in markets characterized by volatility and changing economic and political conditions such as the Iraq Stock Exchange.

## بناء المحافظ الاستثمارية باستخدام لغة البرمجة Python: مقارنة تجريبية بين خوارزميات التعلم الآلي والطريقة التقليدية لماركويتز في سوق العراق للأوراق المالية

علي عبد الحافظ ابراهيم<sup>1</sup>، فريال مشرف عيدان<sup>2</sup>، مريم حسين محسن<sup>3\*</sup>  
ادارة قسم اقتصاديات ادارة المصارف ، كلية اقتصاديات الاعمال ، جامعة النهريين ، بغداد، العراق  
[prof.ali@nahrainuniv.edu.iq](mailto:prof.ali@nahrainuniv.edu.iq) , [Fryal@nahrainuniv.edu.iq](mailto:Fryal@nahrainuniv.edu.iq) , [maryam.mebe23@ced.nahrainuniv.edu.iq](mailto:maryam.mebe23@ced.nahrainuniv.edu.iq)

### المستخلص:

تهدف هذه الدراسة إلى تحسين طرق بناء المحافظ الاستثمارية لعينة من المصارف العراقية المدرجة في سوق العراق للأوراق المالية، من خلال مقارنة الأساليب التقليدية مثل نموذج ماركويتز مع تقنيات حديثة تعتمد على التعلم الآلي. يركز نموذج ماركويتز على تحقيق تحسين في نسبة العائد إلى المخاطرة مقارنةً بالأساليب التقليدية باستخدام إطار تحسين وسط-التباين، وهو نموذج تقليدي يعتمد عليه العديد من المؤسسات المالية. في المقابل، تسعى الدراسة إلى استكشاف إمكانيات تقنيات التعلم الآلي مثل التحليل بالمكونات الرئيسية (PCA)، آلة المتجهات الداعمة (SVM)، الانحدار اللوجستي، والغابة العشوائية في تحسين أداء المحافظ الاستثمارية لهذه المصارف في بيئة متقلبة مثل سوق العراق للأوراق المالية. وتستند هذه التقنيات إلى معالجة وتحليل البيانات المالية الضخمة لاكتشاف الأنماط والعلاقات المخفية التي يمكن أن تساهم في تحقيق تحسين في نسبة العائد إلى المخاطرة مقارنة بالطرق التقليدية. كما تم استخدام البيانات المالية التاريخية الخاصة بأسهم وأصول المصارف المعنية لتقييم أداء المحافظ باستخدام مؤشرات مثل العائد المتوقع، التباين، ونسبة شارب، بهدف تقديم حلول مبتكرة تساعد المصارف على اتخاذ قرارات استثمارية أكثر ذكاءً وفاعلية بما يتناسب مع ظروف السوق المحلية والتحديات الاقتصادية والسياسية التي تواجهها. اما الأساليب المستخدمة في البحث، تم استخدام المعادلات الرياضية التالية في بناء محفظة استثمارية مثلى: العائد المتوقع، الذي يقيس الأداء المتوقع للمحفظة بناءً على أوزان الموجودات وتوقعات العوائد؛ معدل شارب، الذي يقيس العائد الذي تحققه المحفظة مقابل كل وحدة مخاطرة ويعد مؤشرًا للأداء المعدل بالمخاطر؛ والتباين، الذي يُستخدم لقياس مدى تذبذب العوائد وتحليل المخاطر المرتبطة بكل محفظة. أثبتت الدراسة أن استخدام تقنيات التعلم الآلي يمكن أن يحسن أداء المحافظ الاستثمارية بشكل أكبر من الأساليب التقليدية في بيئات الأسواق المتقلبة مثل سوق العراق للأوراق المالية. أظهرت تقنيات مثل التحليل بالمكونات الرئيسية (PCA) والغابة العشوائية قدرة كبيرة على تحقيق تحسين في نسبة العائد إلى المخاطرة مقارنة بنموذج ماركويتز التقليدي. بناءً على ذلك، يُوصى بتبني المصارف العراقية لتقنيات التعلم الآلي في استراتيجيات بناء المحافظ الاستثمارية، حيث يمكن لهذه التقنيات أن تساعد في التعامل مع التحديات الاقتصادية والسياسية المحلية وتحقيق استثمارات أكثر فاعلية

**الكلمات المفتاحية:** نموذج ماركويتز ، آلة ناقلات الدعم ، الانحدار اللوجستي ، تحليل المكونات الرئيسية للغابات العشوائية ، التعلم الآلي.

### معلومات البحث:

- تاريخ استلام البحث: 12-06-2025
- تاريخ ارسال التعديلات: 15-07-2025
- تاريخ قبول النشر: 22-07-2025
- تاريخ النشر: 25-04-2026

### المؤلف المراسل:

مريم حسين محسن

[maryam.mebe23@ced.nahrainuniv.edu.iq](mailto:maryam.mebe23@ced.nahrainuniv.edu.iq)



هذا العمل مرخص بموجب  
المشاع الإبداعي نسب المصنف 4.0  
دولي (CC BY 4.0)

### المقدمة:

يُعد بناء محفظة استثمارية من أبرز التحديات التي تواجه المستثمرين في الأسواق المالية، وخاصة في سوق العراق للأوراق المالية الذي يتسم بتقلبات عالية نتيجة لتأثره بعوامل اقتصادية وسياسية واجتماعية متعددة. الهدف الأساسي من تكوين المحافظ الاستثمارية هو تحقيق تحسين في نسبة العائد إلى المخاطرة من خلال تنوع الموجودات، بهدف تقليل المخاطر إلى أدنى حد ممكن مع تحقيق عوائد مقبولة، أو تحقيق عوائد مرتفعة مع مستوى مخاطرة مقبول، وهو ما يعرف بالمحفظة الاستثمارية المثلى. وعلى الرغم من الاعتماد التقليدي على نموذج ماركويتز لتحسين المحافظ، فإن التطورات الحديثة في الأسواق المالية والتعقيدات المتزايدة، بالإضافة إلى دخول تقنيات الذكاء الاصطناعي والتعلم الآلي، أثبتت الحاجة إلى تبني طرق أكثر تطوراً ومرونة في تحليل البيانات المالية الضخمة واتخاذ قرارات استثمارية دقيقة. تستعرض هذه الدراسة الإمكانيات الكبيرة التي توفرها تقنيات التعلم الآلي في تحسين أداء المحافظ الاستثمارية للمصارف العراقية، من خلال تقديم حلول تتكيف مع تغيرات السوق وتساعد في اتخاذ قرارات استثمارية أكثر فاعلية.

## المبحث الاول: منهجية البحث والاسهامات العلمية السابقة

### الاول: منهجية البحث

#### 1- مشكلة البحث:

تكمن مشكلة هذا البحث في مدى قدرة الأساليب المختلفة، خاصة تقنيات التعلم الآلي، على التعامل مع التقلبات المستمرة في أسعار الموجودات والعوائد والمخاطر داخل سوق العراق للأوراق المالية، وتأثير هذه التقلبات على أداء المحافظ الاستثمارية من حيث العائد والمخاطرة. فضلا عن ذلك، يتطلب الأمر تقييم مدى فاعلية هذه الأساليب في تحقيق تحسين في نسبة العائد إلى المخاطرة، بما يضمن تحقيق هدف المستثمر في الحصول على أعلى عائد ممكن بأقل مستوى من المخاطر، مقارنةً بالمحافظ التقليدية ذات التوزيع الثابت. تسعى الدراسة إلى تقديم حلول مبتكرة وفعالة لهذه المشكلة من خلال تحليل شامل لأبعادها، وذلك عبر توجيه البحث بسؤال رئيسي يعكس جوهر التحدي الذي تواجهه إدارة المحافظ الاستثمارية في ظل ظروف السوق المعقدة. يتمثل السؤال الرئيسي للدراسة هو: ما مدى قدرة تقنيات التعلم الآلي المختلفة في تحسين بناء المحافظ الاستثمارية مقارنة بنموذج ماركوفيتز التقليدي، في تحقيق أداء أفضل من حيث العائد والمخاطرة في سوق العراق للأوراق المالية؟

وكما تنبثق من السؤال الرئيسي أسئلة فرعية هامة توجه مسار البحث، وهي:

1. كيف تؤثر خوارزميات التعلم الآلي مثل الانحدار اللوجستي، آلة المتجهات الداعمة، تحليل المكونات الرئيسية، والغابة العشوائية على تحسين نسب العائد مقابل المخاطرة في المحافظ الاستثمارية مقارنة بنموذج ماركوفيتز؟
2. ما مدى ملائمة وكفاءة تقنيات التعلم الآلي في التكيف مع التقلبات العالية والظروف الاقتصادية والسياسية غير المستقرة في سوق العراق للأوراق المالية؟

#### 2- أهمية البحث:

1. تعزيز كفاءة الاستثمار: تقدم الدراسة حلولاً عملية لتحسين كفاءة المحافظ الاستثمارية من خلال تطوير أدوات تحليلية تعتمد على لغة Python، مما يساعد المستثمرين على تحقيق المبادلة بين العائد والمخاطرة.
2. اتخاذ القرار: تسهم الدراسة في بناء ودعم عمليات صنع القرار بشأن تقديم نموذج عملي يساند صناع القرار والمستثمرين، من خلال توفير تحليلات دقيقة ومعلومات موثوقة تستند إلى تقنيات التعلم الآلي والنماذج الكمية الحديثة، مما يعزز من جودة القرارات الاستثمارية في بيئات تتسم بالتقلب وعدم الاستقرار.
3. تمكين التكنولوجيا المالية: يمكن ان يكون في تحديد مفاهيم التكنولوجيا المالية الحديثة، مثل التنوع الفعال ونظرية ماركوفيتز، مما يساهم في بناء محافظ استثمارية مثلى، خاصة في سوق العراق للأوراق المالية الذي يواجه تحديات كبيرة.

#### 3- أهداف البحث:

وتتمثل الأهداف الأساسية للدراسة في:

- 1) مقارنة أداء المحافظ المبنية باستخدام تقنيات التعلم الآلي مع المحافظ المبنية وفق نموذج ماركوفيتز من حيث العائد المتوقع، مستوى المخاطر (التقلب)، ونسبة شارب مقياس لكفاءة تحسين نسبة العائد إلى المخاطرة.
- 2) تحليل مدى قدرة تقنيات التعلم الآلي على تحقيق تخصيص أوزان أكثر كفاءة داخل المحفظة الاستثمارية تتيح تحسين نسبة العائد مقابل المخاطرة، مع مراعاة تقلبات السوق والتغيرات الديناميكية في بيئة سوق العراق المالية.
- 3) تقديم توصيات مستندة إلى نتائج الأداء المقارن تدعم اتخاذ قرارات استثمارية أكثر دقة ومرونة لمستثمري سوق العراق، تساهم في تعزيز قدرة هذه المحافظ على تحقيق أفضل النتائج الاستثمارية الممكنة.

#### 4- الفرضيات:

الفرضية الأولى: تقنيات التعلم الآلي، مثل تحليل المكونات الرئيسية (PCA)، الانحدار اللوجستي، آلة المتجهات الداعمة (SVM)، والغابات العشوائية، تحقق أداءً أفضل من حيث تحسين نسبة شارب وتقليل المخاطر مقارنةً بنموذج ماركوفيتز التقليدي في بناء المحافظ الاستثمارية.

الفرضية الثانية: تُظهر تقنيات التعلم الآلي مرونة أكبر في تخصيص الأوزان داخل المحافظ الاستثمارية، مما يمكنها من التكيف بشكل أفضل مع تقلبات السوق المتزايدة وتحقيق عوائد متوقعة أعلى مع مستويات مخاطرة أقل مقارنةً بالمحافظ المبنية باستخدام النموذج التقليدي لماركوفيتز.

#### 5- مجتمع وعينة البحث:

تم اختيار سوق العراق للأوراق المالية كمجتمع دراسة المدة الزمنية الممتدة من عام 2014 إلى 2024. وقد تم اختيار العينة من 9 مصارف مدرجة في السوق اذ شمل اختيار هذه المصارف عدة عوامل أساسية، أبرزها توفر البيانات المالية التاريخية بشكل كامل وموثوق، مما يتيح إمكانية استخدام سلسلة زمنية طويلة للمشاهدات. كما تم الأخذ في الاعتبار استقرار التداول في هذه المصارف، حيث أن استقرار السوق يعد من العوامل الحاسمة لضمان دقة التحليل. إضافة إلى ذلك، تم اختيار المصارف بناءً على تنوع أدائها، هذا يساهم في تحسين دقة النتائج .

الجدول (1): المصارف عينة البحث

تسلسل	اسم المصرف	سنة التأسيس	الرمز	نوع النشاط
1	المصرف التجاري العراقي	1992	BCOI	مصرف تجاري
2	بنك بغداد	1992	BBOB	خدمات مصرفية عامة
3	المصرف الإسلامي العراقي	1993	BIIB	مصرف إسلامي
4	مصرف الاستثمار العراقي	1993	BIBI	استثمار وتمويل
5	مصرف سومر التجاري	1999	BSUC	مصرف تجاري
6	مصرف الاقتصاد للاستثمار والتمويل	1999	BEFI	استثمار مالي
7	مصرف كردستان الدولي الاسلامي	2005	BKUI	مصرف إسلامي
8	مصرف المنصور للاستثمار	2006	BMNS	إدارة الموجودات
9	المصرف المتحد للاستثمار	1994	BUND	استثمار وتمويل

المصدر : الجدول من عمل الباحثة بالاعتماد على تقارير سوق العراق للاوراق المالية  
6- أسلوب البحث:

الاساليب المستخدمة في البحث تم استخدام المعادلات الرياضية (العائد المتوقع\_ معدل شارب\_ التباين) لبناء محفظة استثمارية مثلى و جدول (2) يوضح المعادلات الرياضية المستخدمة في البحث:

الجدول (2): المعادلات الرياضية المستخدمة في بناء المحفظة الذكية

رقم	المعادلات الرياضية	الصيغة الرياضية	الوصف
1	العائد المتوقع (Expected Return)	$E(R_p) = \sum_{i=1}^n w_i \times E(R_i)$	يقيس الأداء المتوقع للمحفظة بناءً على أوزان الموجودات وتوقعات العوائد.
2	معدل شارب (Sharpe Ratio)	$S = \frac{E(R_p) - R_f}{\sigma_p}$	يقيس العائد الذي تحققه المحفظة مقابل كل وحدة مخاطرة، ويعد مؤشرًا للأداء المعدل بالمخاطر.
3	التباين (Variance)	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$	يقيس مدى تباين عوائد الموجود عن المتوسط، ويعد مؤشرًا للمخاطر.

المصدر: الجدول من عمل الباحثة بالاعتماد على (Guerard, 2017:257) (Bodie et al., 2018:242) (Deng et al., 2023:4)

ثانيا : الاسهامات العلمية السابقة

اولا: الدراسة الاولى تمثلت في "بناء المحفظة المثلى للأسهم وتحسين أدائها في ظل بيئة ضبابية باستخدام الخوارزمية الوراثية" حيدر عدنان غناوي 2019" تُعد الدراسة التي أعدها الباحث حيدر عدنان غناوي في عام 2019م، مساهمة علمية هامة في مجال إدارة المحافظ الاستثمارية، وتحمل عنوان "بناء المحفظة المثلى للأسهم وتحسين أدائها في ظل بيئة ضبابية باستخدام الخوارزمية الوراثية". تهدف الدراسة إلى تطوير نموذج متكامل لبناء محفظة استثمارية مثلى للأسهم المدرجة في سوق العراق للأوراق المالية، وذلك من خلال توظيف أدوات حديثة مثل السلاسل الزمنية الضبابية والخوارزمية الوراثية متعددة الأهداف. وتم اختيار مجتمع الدراسة من بين الشركات المدرجة في سوق العراق للأوراق المالية، حيث شملت العينة 34 شركة تم انتقاؤها بطريقة المعاينة غير العشوائية المتجانسة، وذلك خلال المدة الزمنية من الأول من يناير 2006 حتى الأول من يونيو 2018. تعكس هذه المدة اختياراً دقيقاً يضمن تمثيلاً جيداً لواقع السوق المالي العراقي خلال المدة زمنية كافية لتحليل الأداء والتقلبات. واتبعت الدراسة منهجية تحليلية تعتمد على الأساليب الكمية المتقدمة، حيث تم استخدام السلاسل الزمنية الضبابية لمعالجة وعدم يقين البيانات

المالية، بالإضافة إلى الخوارزمية الوراثية متعددة الأهداف التي مكنت من تحسين أداء المحفظة من خلال إعادة توزيع الأوزان الاستثمارية بشكل أمثل. كما استُخدمت البرمجة الهدفية لتحديد المبادلة المناسب بين عوائد المحفظة ومستوى المخاطرة المقبول. وكما أظهرت نتائج الدراسة نجاح النموذج المقترح في بناء أربع محافظ استثمارية، حيث برزت المحفظة التي تم تحسينها باستخدام الخوارزمية الوراثية متعددة الأهداف على البيانات الضبابية كالأكثر كفاءة من حيث الأداء. فقد تجاوزت هذه المحفظة المحافظ التقليدية ومؤشر سوق العراق، مما يؤكد فاعلية دمج التقنيات الحاسوبية الحديثة مع أدوات التحليل المالي في ظل بيئة بيانات غير مؤكدة.

وتكمن أهمية هذه الدراسة في تقديمها إطار علمي منهجي لبناء محافظ استثمارية في أسواق مالية تشهد عدم استقرار وغياب اليقين، مثل سوق العراق. وتثبت الدراسة قدرة الجمع بين السلاسل الزمنية الضبابية والخوارزمية الوراثية على تحسين عملية اتخاذ القرار الاستثماري، وتعزيز مستوى العائد المحقق مقابل المخاطرة، مما يحقق هدف تعظيم ثروة المستثمرين في ظل الموارد المحدودة والظروف المعقدة للسوق

ثانيا: الدراسة الثالثة " Portfolio Optimization Using Machine Learning " Oladimeji Kazeem "2023"

المحفظة المثلى المبنية باستخدام خوارزمية دعم متجهات الآلة وتحسين خوارزمية الأسد أداءً متفوقاً على الطرق التقليدية إذ تحقيق تحسين في نسبة العائد إلى المخاطرة، كما بينت النتائج ثبات وقوة النموذج المقترح عبر معظم السنوات المدروسة. تقدم الدراسة إطاراً عملياً وعلمياً لتطبيق خوارزميات الذكاء الاصطناعي في بناء محافظ استثمارية مثلى في أسواق مالية معقدة وغير مستقرة مثل سوق العراق، كما توفر حلولاً مبتكرة تساعد المستثمرين على تحقيق تحسين في نسبة العائد إلى المخاطرة بكفاءة أعلى مقارنة بالنماذج التقليدية، وتفتح آفاقاً مستقبلية لاستخدام تقنيات الذكاء الاصطناعي في مجال الإدارة المالية والاستثمار، مما يسهم في تقليل الوقت والتكاليف المرتبطة بتحليل البيانات واتخاذ القرار الاستثماري

## المبحث الثاني : الاطر المفاهيمية للمحافظ الاستثمارية

### أولاً: نشأة المحفظة الاستثمارية

تعود بدايات مفهوم المحفظة الاستثمارية إلى أوائل خمسينيات القرن العشرين، حينما قدّم المحلل الأمريكي هاري ماركويتز الأسس النظرية الأولى لهذا المفهوم في بحثه المنشور عام 1952، واضعاً بذلك حجر الأساس لما يعرف اليوم بنظرية المحفظة الحديثة. وقد ساهم عدد من الباحثين والمحللين لاحقاً، مثل ويليام شارب وكورين، في تطوير هذا المفهوم، مما أدى إلى انتشاره في كل من الولايات المتحدة الأمريكية وبريطانيا.

وفي عام 1958، قام الباحث جيمس توبن بإحداث تطور نوعي في هذه النظرية، مما ساهم في توسيع نطاق فهمها وتطبيقاتها ضمن الحقول الاقتصادية والمالية. وبالتزامن مع تزايد الوعي بأهمية استثمار المدخرات الفردية لتحقيق دخل مستدام، بدأت المؤسسات المصرفية والشركات المالية بتقديم خدمات إدارة المحافظ الاستثمارية كوسيلة لجمع هذه المدخرات وتوجيهها نحو استثمارات مدروسة، تضمن تحقيق عوائد جيدة لجميع الأطراف المعنية (القاضي، 2016: 11). ومع تراكم حجم المدخرات وتعدد أنماط المستثمرين، أصبحت الحاجة ملحة لاعتماد آليات علمية فعالة في توظيف هذه الموارد. إلا أن غياب الكفاءة لدى عدد كبير من مديري المحافظ غير المتخصصين، والذين لم يلتزموا بتطبيق المبادئ العلمية لنظرية إدارة المحافظ، أدى إلى فشل عدد من المؤسسات وخروجها من السوق. في المقابل، نجحت المؤسسات التي اعتمدت على مديري محافظ متخصصين بتطبيق نظرية المحفظة الحديثة، وحققَت نتائج إيجابية على مستوى الأداء الاستثماري، الأمر الذي دفع الباحثين والأكاديميين إلى التركيز بشكل متزايد على دراسة هذا المجال. وقد ساهمت جهود ماركويتز البحثية، التي استمرت لأكثر من 25 عاماً، في ترسيخ إدارة المحافظ الاستثمارية كأحد المحاور الأساسية في حقل الإدارة المالية، ما أدى إلى إدراج هذا التخصص ضمن مناهج كليات إدارة الأعمال (سلماني وغازيل، 2017: 750). وفي عام 1962، قام ويليام شارب بتوسيع نطاق نظرية ماركويتز من خلال تطوير ما يُعرف بـ"نظرية المؤشر

"تحسين المحفظة باستخدام التعلم الآلي" نموذجاً متقدماً لبناء المحافظ الاستثمارية المثلى باستخدام تقنيات التعلم الآلي، حيث تهدف الدراسة إلى تحقيق تحسين في نسبة العائد إلى المخاطرة عبر مختلف أفق الاستثمار القصير والمتوسط والطويل الأجل. وتعتمد الدراسة على تحليل بيانات أسعار إغلاق ست شركات كبرى خلال المدة من 2015 فصاعداً، مستفيدة من نموذج ماركويتز للتنوع الأمثل (Mean-Variance Optimization) ومقاييس المخاطر مثل الانحراف المعياري، معامل بيتا، وقيمة المخاطرة (VaR)، إضافة إلى تقييم الأداء المالي للمحفظة باستخدام مؤشرات متقدمة. توصلت النتائج إلى أن المحفظة التي تم تصميمها عبر التعلم الآلي تقدم أداءً متبادلاً بين العوائد والتقلبات مقارنة بالاستثمار في الأسهم الفردية، حيث أظهرت المحفظة تنوعاً فعالاً ساهم في تقليل المخاطر الإجمالية، مؤكداً الدور الحيوي لإدارة المخاطر والتنوع في تحسين جودة المحفظة الاستثمارية. تبرز أهمية الدراسة في توفير إطار علمي عملي يساعد المستثمرين على تحسين قراراتهم الاستثمارية من خلال استخدام البيانات الكبيرة والتقنيات الحديثة، مما يعزز الاستقرار المالي ويحد من الخسائر المحتملة، ويقدم إضافة قيمة للممارسين والباحثين في مجال التمويل والاستثمار.

ثالثاً: الدراسة تمثلت في "بناء المحفظة المثلى للأسهم وتحسين أدائها باستخدام تقنيات حديثة في مجال الذكاء الاصطناعي، مع التركيز على خوارزمية (الأسد) دعاء ذيب عبد القادر 2024، تتناول دراسة الباحثة دعاء ذيب عبد القادر، المقدمة إلى الجامعة المستنصرية - كلية الإدارة والاقتصاد في عام 2024، موضوع بناء المحفظة المثلى للأسهم وتحسين أدائها باستخدام تقنيات حديثة في مجال الذكاء الاصطناعي، مع التركيز على خوارزمية "الأسد" وخوارزمية دعم متجهات الآلة (SVM) لتطبيقها على أسهم الشركات المدرجة في سوق العراق وسوق نيويورك للأوراق المالية خلال المدة من 2010 إلى 2019. تهدف الدراسة إلى استخدام خوارزميات الذكاء الاصطناعي، وخصوصاً خوارزمية دعم متجهات الآلة وخوارزمية الأسد، لبناء محفظة استثمارية تحقيق تحسين في نسبة العائد إلى المخاطرة، مما يمكن المستثمرين من تعظيم ثروتهم بموارد محدودة وبكلفة ووقت أقل مقارنة بالنماذج التقليدية. شمل مجتمع الدراسة الأسهم المدرجة في سوق العراق للأوراق المالية وسوق نيويورك (S&P 100)، حيث تكونت العينة من 34 شركة عراقية و40 شركة من سوق نيويورك، وتم تحليل بيانات العوائد الشهرية وأسعار الإغلاق من 2010 حتى 2019. استخدمت الدراسة أساليب متقدمة تشمل خوارزمية دعم متجهات الآلة لبناء المحافظ المثلى، وخوارزمية الأسد لتحسين أداء المحافظ الاستثمارية، بالإضافة إلى نموذج معدل القطع لتصنيف الأسهم واختيار الأوراق المالية ضمن المحفظة، مع تحليل العوائد والمخاطر النظامية واللانظامية عبر مقاييس إحصائية مثل الانحراف المعياري ومعامل بيتا (CAPM)، مستفيدة من تقنيات الذكاء الاصطناعي والتعلم الآلي لتقليل تكلفة ووقت بناء المحافظ. أظهرت النتائج فاعلية خوارزمية الأسد في تحسين بناء المحافظ، خصوصاً عند تطبيقها على بيانات سوق العراق وسوق نيويورك، حيث حققت

تحقيق هدفين أساسيين: الأول يتمثل في الاحتفاظ بالسيولة، أي قدرة المستثمر على تحويل استثماراته إلى نقد بسهولة عند الحاجة، دون تكبد خسائر كبيرة أو مواجهة تأخيرات زمنية طويلة؛ أما الهدف الثاني فهو تحقيق العوائد المالية من خلال هذه الأوراق، سواء عبر توزيعات الأرباح، الفوائد، أو تحسين قيمة الموجودات المحتفظ بها (Kouki, 2023: 580). ويتحقق ذلك عادة من خلال تطبيق مبدأ التنوع، أي توزيع الاستثمارات عبر مجموعة من الأسهم أو السندات المتنوعة، مع تركيز خاص على التنوع القطاعي الذي يضم شركات تنتمي إلى صناعات مختلفة. وتتميز المحافظ التقليدية غالباً بالاستثمار في الشركات الكبرى المعروفة، انطلاقاً من الاعتقاد بأن تلك الشركات أقل مخاطرة، وأوراقها المالية أكثر سيولة، مما يسهل عملية ترويجها للمستثمرين. وتعرف هذه الظاهرة بـ"التبرج المصرفي" Window dressing، حيث يُدرج مديرو المحافظ المؤسساتية أسهماً ناجحة ومعروفة ضمن المحافظ لتسهيل بيعها لاحقاً. وبالإضافة إلى ذلك، يُلاحظ في سلوك بعض المستثمرين المؤسسيين ميلهم لمحاكاة استراتيجيات منافسيهم، عبر اتباع ما يُعرف بـ"سلوك القطيع" أو اتباع القطيع herd behavior، والذي يتمثل بالاستثمار في ذات الأسهم التي يستثمر فيها الآخرون (Smart et al., 2020: 220–221).

أما على المستوى النظري، فتعتمد النظرية التقليدية للمحفظة الاستثمارية على مجموعة من الفرضيات الأساسية، كما يوضح (Singh, 2014: 345)، وتشمل:

1. إمكانية استغلال أوجه القصور في السوق من خلال تحليل البيانات المالية الداخلية للشركات بما يؤدي إلى تحقيق عوائد تفوق المتوسط.
2. السعي لتحقيق أرباح أعلى من خلال عمليات انتقائية تستند إلى أسس تحليلية دقيقة.
3. الاعتماد على التنبؤ بالاتجاهات المستقبلية لأسعار الأسهم، ما يتيح للمستثمرين استكشاف فرص النمو المحتملة لأسهم شركات معينة.

وبناءً على هذه الأسس، تسعى نظرية المحفظة إلى تحقيق تحسين في نسبة العائد إلى المخاطرة، بما يُمكن المستثمر من اتخاذ قرارات استثمارية مدروسة في بيئة مالية تتسم بالتقلب والتعقيد.

### ثالثاً: المحفظة الاستثمارية المثلى

لا يُعد مفهوم المحفظة الاستثمارية المثلى تصوراً مطلقاً، بل هو مفهوم نسبي يعتمد بشكل أساسي على خصائص وتفضيلات المستثمر الفردي. فمصطلح "المثلى" في هذا السياق يُشير إلى مدى توافق المحفظة مع أهداف ومستوى تقبل المخاطر لدى مستثمر معين، وقد لا يتطابق هذا التوافق مع تفضيلات مستثمرين آخرين. وبالتالي، ما يُعد محفظة استثمارية مثلى لمستثمر ذي ميول عقلانية معينة، قد لا يُحقق نفس المستوى من "المثالية" لمستثمر آخر تختلف نظريته أو تحمله للمخاطر. فعلى سبيل المثال، قد يرى المستثمر (أ) أن محفظته الاستثمارية تحقق تحسين في نسبة العائد إلى المخاطرة، في حين أن المستثمر (ب) قد يُفضل محفظة مختلفة تماماً بناءً على أهدافه الشخصية وسلوكه الاستثماري،

الفردي، التي تعالج إشكالية تعدد الأوراق المالية ضمن المحفظة، وتُجيب عن تساؤل جوهري مفاده: ماذا يحدث إذا اعتمد جميع المستثمرين نموذج المحفظة المثلى؟ وكيف سينعكس ذلك على تسعير الأوراق المالية في السوق؟ وللإجابة عن هذا التساؤل والتغلب على صعوبات التنبؤ بالعلاقة بين العائد والمخاطرة ضمن نموذج ماركويتز، طوّر كل من ويليام شارب، وجون لينتنر، وجان موسين في عام 1964 أول نموذج لتسعير الموجودات، والذي أُطلق عليه اسم نظرية تسعير الموجودات الرأسمالية (CAPM)، ليصبح لاحقاً أحد المعايير الأساسية في قياس كفاءة المحافظ الاستثمارية (شبيب، 2010: 14) (باكير، 2008: 2). ومن خلال النظر في التطورات التي طرأت على الأسواق المالية نتيجة لاعتماد نظرية المحفظة الاستثمارية من قبل المستثمرين، يمكن التأكيد على أن هذا الاعتماد ساهم في إحداث تغييرات جوهريّة في أسعار الأوراق المالية، ناتجة عن إعادة توزيع الاستثمارات وتغيير تفضيلات المستثمرين. كما أدى إلى تعزيز المبادلة بين العوائد المتوقعة والمخاطر المحتملة، الأمر الذي انعكس إيجاباً على كفاءة المحافظ الاستثمارية وعلى فاعلية سوق الأوراق المالية ككل. ويستند أنموذج ماركويتز إلى افتراضات مهمة عدة تتعلق بسلوك المستثمر وهي كالآتي: (Reilly et al., 2019: 173)

1. التمثيل الاحتمالي للعوائد: ينظر المستثمرون إلى كل بديل استثماري على أنه يتمثل في توزيع احتمالي للعوائد المتوقعة خلال مدة الاحتفاظ بالمحفظة الاستثمارية، مما يعني إدراكهم لوجود درجة من عدم اليقين في النتائج المستقبلية.
2. تعظيم المنفعة المتوقعة: يسعى المستثمرون إلى تعظيم منفعتهم المتوقعة في المدة زمنية معينة، ويتم التعبير عن تفضيلاتهم من خلال منحنيات المنفعة الحدية للثروة، والتي توضح مدى رضاهم عن مستويات مختلفة من العائد والمخاطرة.
3. تقييم المخاطرة عبر التباين: يتم تقييم مخاطر المحفظة من قبل المستثمرين باستخدام مقياس تباين العائد المتوقع أو ما يُعرف بالتقلب (Volatility)، كأداة كمية لقياس مستوى عدم اليقين المرتبط بالعوائد المستقبلية.
4. الاعتماد على العائد والتباين فقط: تتخذ قرارات المستثمر بناءً على عاملين أساسيين فقط، هما العائد المتوقع والمخاطرة المتوقعة، وبناءً عليه فإن دالة المنفعة تعتمد فقط على هذين العاملين، دون النظر إلى اعتبارات نفسية أو سلوكية أخرى.
5. تفضيل العائد الأعلى والمخاطرة الأقل: يُضلل المستثمرون دائماً تحقيق عائد أعلى عند مستوى معين من المخاطرة، كما يفضلون مستوى مخاطرة أقل عند ثبات العائد المتوقع، وهو ما يعكس سلوكاً عقلانياً وهادفاً نحو تحسين العوائد دون تعريض الثروة لمخاطر غير مبررة.

### ثانياً: نظرية المحفظة الاستثمارية

تشير نظرية المحفظة الاستثمارية إلى المفهوم الذي يقوم على امتلاك المستثمر لمجموعة متنوعة من الأوراق المالية بهدف

الاصطناعي يختص بتطوير خوارزميات تُمكن الأنظمة الحاسوبية من تعلم أداء المهام بناءً على البيانات المتاحة، دون الحاجة إلى برمجتها بشكل مباشر مسبقاً. ويعتمد التعلم الآلي على مبدأ أن البيانات تحتوي على أنماط وعلاقات يمكن استغلالها لأداء مهام محددة مثل التصنيف أو التنبؤ بالبيانات غير المرئية سابقاً. (Al-Hchemi, 2023:84)

تنقسم خوارزميات التعلم الآلي إلى ثلاثة أنواع رئيسية:

1. التعلم الخاضع للإشراف (Supervised Learning): يتم فيه تزويد الخوارزمية ببيانات الإدخال مع مخرجاتها المصاحبة بهدف تدريب النموذج على التنبؤ أو التصنيف لاحقاً. (Munoko, 2020:3)

2. التعلم غير الخاضع للإشراف (Unsupervised Learning): تعتمد فيه الخوارزمية على بيانات الإدخال فقط، وتحاول اكتشاف الأنماط أو البنى الكامنة داخل البيانات دون وجود مخرجات معلومة سلفاً.

3. التعلم المعزز (Reinforcement Learning): يقوم على مبدأ التجربة والخطأ من خلال نظام مكافآت يعزز اتخاذ القرارات الصحيحة لتحسين أداء النموذج مع مرور الوقت. (Matsuo, 2022:270)

يركز هذا البحث بشكل خاص على خوارزميات التعلم الخاضع للإشراف نظراً لفعاليتها في التعامل مع السلاسل الزمنية لأسعار الأسهم، حيث تُستخدم هذه الخوارزميات بشكل واسع في حل مشكلتي التصنيف والانحدار. تعتمد الخوارزميات على التدريب باستخدام البيانات التاريخية لبناء نماذج تنبؤية يمكنها التعامل مع بيانات جديدة غير مألوفة سابقاً.

يمتاز التعلم الآلي الخاضع للإشراف بقدرته على التعامل مع العلاقات غير الخطية في البيانات، مما يجعله أكثر كفاءة مقارنة بالأساليب الإحصائية التقليدية، خاصة عند التعامل مع السلاسل الزمنية العشوائية أو غير المستقرة. ويتطلب اختيار الخوارزمية المناسبة دراسة دقيقة للهيكلية والأسلوب الخاص بكل خوارزمية، حيث لا توجد معايير موحدة للاختيار، ويعتمد الأمر في كثير من الحالات على التجربة والخطأ والمقارنة بين خوارزميات مختلفة وفقاً لمقاييس الأداء المعتمدة.

#### سادساً: خوارزميات التعلم الآلي

##### 1- خوارزمية الغابة العشوائية

تُعد خوارزمية الغابة العشوائية إحدى تقنيات التعلم الآلي التجميعية التي تعتمد على بناء عدد من أشجار القرار بشكل متوازٍ. ونظراً لكون هذه الخوارزمية شديدة الحساسية للإفراط في التعلّم (Overfitting)، فإن من الضروري اتباع منهجية صارمة لضبط معلماتها الفائقة (Hyperparameters). يشمل ذلك استخدام أسلوب التحقق المتقاطع (K-fold Cross Validation) لتحديد القيم المثلى لكل من العمق الأقصى للشجرة، وعدد العينات الأدنى المطلوب لتقسيم الفرع، وعدد العينات الأدنى في كل ورقة. علاوة على ذلك، تتطلب الغابة العشوائية ضبط معلمتين إضافيتين هما: عدد الأشجار في الغابة، وعدد المتغيرات المختارة عند كل تقسيم، حيث يُعد ذلك من العوامل المؤثرة في الدقة التنبؤية للنموذج (Kaczmarek & Perez, 2021: 7)

##### 2- تحليل المكونات الرئيسية

رغم أن كليهما يستندان إلى أدوات واستراتيجيات تحليلية صحيحة. وعليه، فإن ما يُعد محفظة مثلى هو أمر خاضع لاختلاف الرؤى وتقدير الأهداف الفردية للمستثمرين (عبد العالي، 2019: 13)

#### رابعاً: الذكاء الاصطناعي (Artificial Intelligence)

الذكاء الصناعي هو فرع من علم الحاسوب يهدف إلى تطوير البرمجيات والأنظمة التي تمتلك القدرة على محاكاة الذكاء البشري وتنفيذ المهام بشكل ذكي وآلي (Norvig & Russell, 2016:1). يشمل الذكاء الصناعي تقنيات متنوعة مثل التعلم الآلي والتعلم العميق ومعالجة اللغة الطبيعية، والتي تمكن الآلات من التعلم والتحسين المستمر بناءً على البيانات والتجارب (Goodfellow, Bengio, & Courville, 2016:23). يعتبر الذكاء الصناعي مجالاً متزايد الأهمية في العصر الحالي، حيث أصبحت تطبيقاته تغزو مختلف المجالات بدءاً من الرعاية الصحية والتعليم، وصولاً إلى الصناعة والمالية (Bughin et al., 2017:8). ويرجع الاعتماد المتزايد على الذكاء الصناعي إلى قدرته على معالجة كميات هائلة من البيانات واستخلاص الأنماط والعلاقات المفيدة التي يصعب على البشر تحقيقها بسرعة ودقة مماثلة (Agrawal, Gans, & Goldfarb, 2018:15). وبالإضافة إلى ذلك، يمكن للذكاء الصناعي تحسين كفاءة العمليات والوقت والموارد عن طريق إتمام المهام الروتينية والمعقدة بشكل أسرع وأكثر دقة (Chui, Manyika, & Bughin, 2015:4). ويُعد قطاع الاستثمار أحد المجالات التي تستفيد من الذكاء الصناعي بشكل كبير، حيث يُستخدم في توجيه القرارات الاستثمارية والاستراتيجية بناءً على تحليلات متقدمة ودقيقة (Hilpisch, 2020:55)

على الرغم من الفوائد العديدة التي يوفرها الذكاء الصناعي في مجال الاستثمار، إلا أن هناك تحديات تواجه استخدامه تتعلق بقضايا الأمان، الخصوصية، التحيز، والقضايا القانونية والتنظيمية

(Surden, 2019:610). فمن الممكن أن تنشأ قضايا الأمان من الاختراقات الأمنية والهجمات الإلكترونية التي تستهدف البيانات الحساسة (Papernot et al., 2018:400)، في حين قد يؤدي استخدام البيانات الشخصية لتدريب النماذج إلى انتهاك الخصوصية وتسريب المعلومات. ويمكن أن يؤدي التحيز والتمييز في تطبيقات الذكاء الصناعي إلى نتائج غير عادلة، خصوصاً عندما تكون البيانات المستخدمة في تدريب النماذج غير متوازنة أو متحيزة (Barocas, Hardt, & Narayanan, 2017:35). لذلك تأتي أهمية قوانين عقود الاستثمار في تنظيم استخدام الذكاء الصناعي وضمان استيفاء متطلبات الشفافية والمساءلة والامتثال للقوانين والتنظيمات المعمول بها، مما يعزز من ثقة المستثمرين والمستهلكين في هذا المجال.

#### خامساً: التعلم الآلي (Machine Learning)

التعلم الآلي هو مجموعة من الخوارزميات والتقنيات التي تمكن الأنظمة من التعلم من البيانات وتحسين الأداء التنبؤي دون الحاجة إلى برمجة واضحة (Ibrahim et al., 2023:59) ويعد التعلم الآلي فرعاً من فروع الذكاء

## المبحث الثالث : بناء المحافظ الاستثمارية الذكية لعينة من المصارف العراقية في سوق العراق للأوراق المالية باستخدام تقنيات ماركويتز والتعلم الآلي

أولاً: ماركويتز (Markowitz Method) بالاعتماد على الرسم البياني رقم (1) المقدم لطريقة ماركويتز (Markowitz Method)، يمكن تحليل مخرجات المحفظة المثلى وفقاً لمنهج إحصائي دقيق يُبرز العلاقة بين العائد المتوقع والمخاطرة. يُظهر المنحنى الأزرق في الشكل ما يُعرف بـ"الحدود كفؤة" (Efficient Frontier)، وهي تمثل العلاقة المثلى بين العائد المتوقع والمخاطرة المقاسة بالانحراف المعياري. يشير كل موضع على هذا المنحنى إلى مزيج من الموجودات يحقق أعلى عائد ممكن عند مستوى معين من المخاطرة، مما يجعل المحافظ الواقعة عليه محققة لأفضل مبادلة ممكن بين العائد والمخاطرة، في حين أن المحافظ الواقعة تحته تُعد غير كفؤة لأنها لا تحقق العائد الأمثل مقارنةً بالمخاطر المحتملة.

حيث تُمثل النقطة المميزة بالنجمة الحمراء المحفظة المثلى التي توصل إليها النموذج، وتُعد هذه النقطة الأكثر كفاءة بناءً على نسبة شارب (Sharpe Ratio)، والذي بلغ في هذه الحالة (2.0723)، مما يشير إلى أن المحفظة تحقق عائداً مرتفعاً نسبياً مقابل كل وحدة مخاطرة يتم تحملها. وبلغ العائد المتوقع لهذه المحفظة (0.0068) أي ما يعادل 0.68%، في حين بلغ الانحراف المعياري (0.0033) أو 0.33%، وهو ما يعكس انخفاضاً كبيراً في درجة تقلب العوائد، ما يعزز جاذبية هذه المحفظة بالنسبة للمستثمرين ذوي الميل المنخفض للمخاطرة. عند تحليل الأوزان النسبية للأصول الداخلة في المحفظة، يتبين أن بنك بغداد (BBOB) استحوذ على النسبة الأكبر من التخصيص بنسبة بلغت 76.97%، ما يُشير إلى تركيز استثماري كبير في أصل واحد، وهو ما قد يُعرض المحفظة لمخاطر غير نظامية إذا ما تعرض هذا الأصل لتقلبات مفاجئة. وعلى الرغم من ذلك، تم تخصيص نسب معتدلة لمصرفي كوردستان الدولي (BKUI) بنسبة 8.47%، والمصرف الأهلي العراقي (BELF) بنسبة 15.30%، مما أسهم جزئياً في تخفيض تركيز المخاطرة. أما باقي الموجودات مثل المصرف التجاري العراقي (BCOI)، بنك الاستثمار العراقي (BIBI)، المصرف المتحد للاستثمار (BMNS)، وبنك الاتحاد (BUND)، فقد أُعطيت أوزاناً تساوي صفر، ما يعني استبعادها لعدم مساهمتها في تعزيز العائد أو تحسين نسبة العائد إلى المخاطرة. انظر إلى الجدول (3) يوضح نتائج ماركويتز

أول من وصف تقنية تحليل المكونات الرئيسية في شكل مبسط هو Karl Pearson, 1901 غير ان الاجراءات العامة المعروفة حالياً تعود لأعمال Harold Hotelling سنة 1933. وساعد في تطور هذه التقنية تطور أنظمة التشغيل الحاسوبية. ويهتم تحليل المكونات الرئيسية بشرح وتفسير هيكل تباينات والتباينات المشتركة للمتغيرات الأصلية باستخدام توليفات خطية قليلة من المتغيرات وتهدف هذا الطريقة أساساً إلى تخفيض البيانات ومن ثم إتاحة إيجاد تفسيرات جديدة. (الشيخ وربيعي، 2018: 380)

3- خوارزمية متجه دعم الآلة  
تُعد خوارزمية متجه دعم الآلة (Support Vector Machine - SVM) من أبرز خوارزميات تعلم الآلة المستخدمة في مهام التصنيف، سواء الخطي أو غير الخطي. وتتمثل فكرتها الأساسية في إيجاد أفضل مستوى فاصل بين الفئات المختلفة داخل البيانات، بحيث تكون المسافة بين هذا المستوى الفاصل ونقاط البيانات القصوى من كل فئة هي الأكبر، مما يعزز من دقة التصنيف وفعاليتيه في بيانات التعلم المختلفة (الهالي و خليل، 2022: 78)

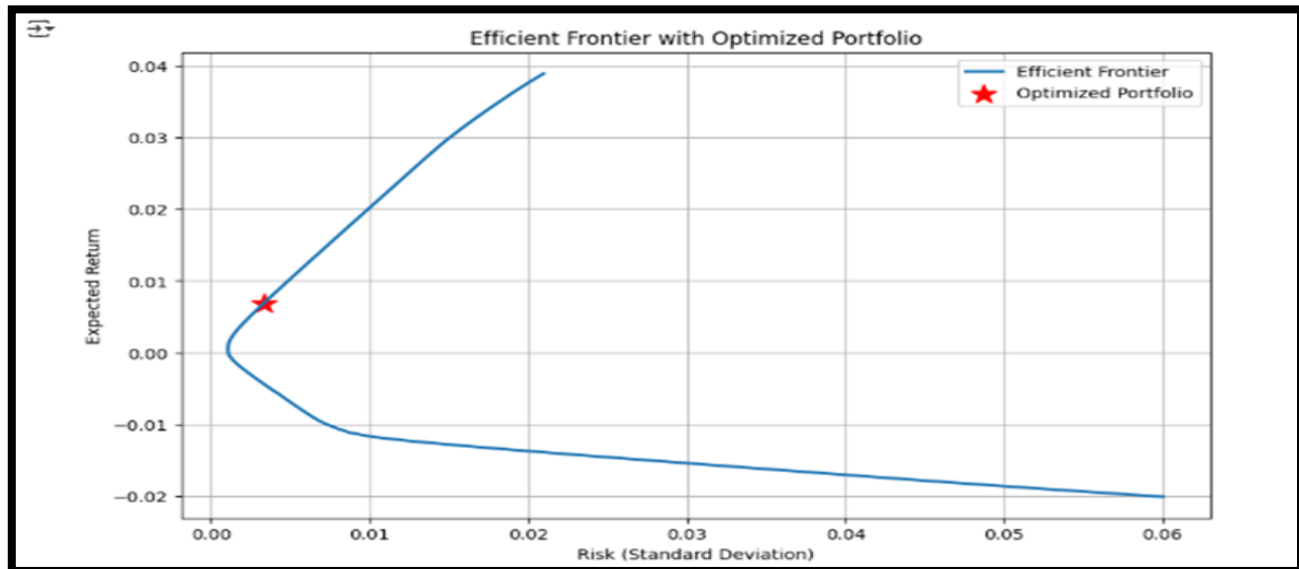
4- الانحدار اللوجستي (Logistic Regression)  
يُعد الانحدار اللوجستي أحد النماذج الإحصائية واسعة الاستخدام في تحليل البيانات، ويُستخدم بشكل خاص في التنبؤ باحتمالية وقوع حدث معين من خلال ملاءمة البيانات لمنحنى لوجستي. ويعتمد هذا النموذج على مجموعة من المتغيرات المستقلة التي قد تكون كمية (نسبية) أو نوعية (فئوية أو اسمية)، بهدف تقدير متغير تابع ثنائي يُعبّر عن وجود أو غياب الحدث قيد الدراسة. وعلى خلاف الانحدار الخطي الذي يسعى إلى تقليل مجموع مربعات الأخطاء، فإن الانحدار اللوجستي يعتمد على تعظيم دالة الاحتمالية (Likelihood Function) لتقدير أفضل المعاملات التي تصف النموذج بدقة. يُعد هذا النموذج أداة تحليلية قوية وفعالة في المجال المالي، إذ يُستخدم على نطاق واسع للتنبؤ باحتمالية تعرّض أصل مالي معين لمخاطر مستقبلية. وتكمن فاعلية النموذج في قدرته على تحويل مجموعة من المتغيرات المستقلة – مثل العوائد التاريخية، نسب المديونية، أو تقلبات السوق – إلى احتمالات ثنائية (0 أو 1). ويساعد هذا التحويل المستثمرين في اتخاذ قرارات مبنية على تحليل كمي دقيق للمخاطر المحتملة (da, 2021: 9) (silva Lourenco)

### الجدول (3) يوضح نتائج ماركويتز

تسلسل	رمز المصرف	اسم المصرف	Weights: Optimized Portfolio
1	BCOI	المصرف التجاري العراقي	0.0000
2	BBOB	مصرف بغداد	0.7697
3	BIIB	المصرف الإسلامي العراقي	0.0279
4	BIBI	مصرف الاستثمار العراقي	0.0000
5	BSUC	مصرف سومر التجاري	0.0015

0.0000	مصرف المنصور للاستثمار	BMNS	6
0.0000	المصرف المتحد للاستثمار	BUND	7
0.1530	مصرف الاقتصاد للاستثمار والتمويل	BELF	8
0.0478	مصرف كردستان الدولي الاسلامي	BKUI	9
<b>Expected Return: 0.0068</b>			
<b>Risk (Std Dev): 0.0033</b>			
<b>Sharpe Ratio: 2.0723</b>			

المصدر : من إعداد الباحثين بالاعتماد على برنامج Python



الشكل (1): الرسم البياني المقدم لطريقة ماركويتز (Markowitz Method) **المصدر : من إعداد الباحثين بالاعتماد على برنامج Python**

تعكس تحقيق تحسين في نسبة العائد إلى المخاطرة بناءً على ما توفره الخوارزمية من تنبؤات مدروسة. وتشير بيانات الأداء إلى أن العائد المتوقع لهذه المحفظة بلغ 0.0150، أي ما يعادل 1.50%، بينما بلغ الانحراف المعياري للمخاطرة 0.0288 (2.88%)، ما يعكس درجة مخاطرة متوسطة. وقد تم احتساب مؤشر شارب بقيمة 0.5203، وهي قيمة تُعد منخفضة نسبياً مقارنة بالنماذج الأكثر كفاءة، مما يشير إلى أن المحفظة تُحقق عوائد معتدلة مقابل مستوى المخاطرة، لكنها لا ترتقي إلى المستوى الأمثل في الأداء المعدل حسب المخاطر. أما من حيث توزيع الموجودات داخل المحفظة، فيُظهر النموذج مرونة أكبر في التخصيص مقارنة بنموذج ماركويتز، حيث تم توزيع الأوزان بين عدد من المصارف بنسب متقاربة نسبياً. أبرزها بنك بغداد (BBOB) بنسبة 29.76%، المصرف الإسلامي العراقي (BIIB) بنسبة 26.52%، والمصرف المتحد للاستثمار (BMNS) بنسبة 27.27%، ما يشير إلى استراتيجية تنوع مقبولة تقلل من التركيز في أصل واحد. في المقابل، استُبعدت بعض الموجودات الأخرى مثل BCOI، BIBI، BELF، وBKUI حيث منحت أوزاناً تساوي صفراً، ما يدل على أن هذه المصارف لم تضيف قيمة ملموسة من حيث تحسين العائد أو تقليل المخاطر ضمن إطار النموذج الاحصائي المستخدم. انظر الجدول (4) ، بالنظر إلى هذه النتائج، يمكن القول إن


تجدر الإشارة إلى أن هذا النموذج، رغم بساطته ووضوحه في تحديد المحفظة المثلى ضمن إطار الحدود كفاءة، إلا أن النتائج تُظهر وجود بعض القصور في تنوع الموجودات بالشكل الأمثل، ما يفتح المجال للنظر في اعتماد أساليب أكثر تقدماً، مثل تقنيات التعلم الآلي، لتحسين كفاءة المحفظة وتعزيز أدائها في بيئات سوقية أكثر تعقيداً. وبالتالي، فإن هذا التحليل يُبرز قدرة نموذج ماركويتز على تقديم محفظة ذات مخاطرة منخفضة وعائد معتدل، لكنه في ذات الوقت يُظهر حاجة ماسة إلى أدوات تحليل أكثر تطوراً لرفع كفاءة التنوع وتحقيق مستويات أعلى من العائد المعدل حسب المخاطرة.

**ثانياً: خوارزميات التعلم الآلي Machine learning algorithms**

**1- الانحدار اللوجستي Logistic regression**  
يعكس الرسم البياني رقم (2) المرفق نتائج بناء المحفظة الاستثمارية باستخدام خوارزمية الانحدار اللوجستي (Logistic Regression)، والتي تُعد من أبرز تقنيات التعلم الآلي الإحصائي المعتمدة في تصنيف البيانات وتحليل المخاطر المحتملة. يظهر في المنحنى الأزرق ما يُعرف بالحدود كفاءة (Efficient Frontier)، والتي تمثل مجموعة المحافظ المثلى التي تحقق أعلى عائد ممكن عند كل مستوى معين من المخاطرة، ويشير وجود النقطة الحمراء على المنحنى إلى المحفظة المثلى التي توصل إليها النموذج، والتي

في التصنيف والتقدير، لا يزال بحاجة إلى مزيد من التطوير أو الدمج مع تقنيات تعلم آلي أخرى لتحسين الأداء الكلي للمحفظة الاستثمارية، خاصة في الأسواق التي تتسم بالتقلب والتعقيد كما هو الحال في سوق العراق للأوراق المالية.

خوارزمية الانحدار اللوجستي نجحت في تحقيق التحسين الأمثل لتوزيع الموجودات مقارنة بالنماذج التقليدية، إلا أن انخفاض مؤشر شارب يشير إلى محدودية الأداء من حيث الكفاءة المعدلة للمخاطر. وهذا يعكس أن النموذج، رغم كفاءته



الشكل رقم (2) بناء المحفظة الاستثمارية باستخدام خوارزمية الانحدار اللوجستي (Logistic Regression) المصدر : من إعداد الباحثين بالاعتماد على برنامج Python

الجدول (4) نتائج بناء المحفظة الاستثمارية باستخدام خوارزمية الانحدار اللوجستي (Logistic Regression)

Weights: Optimized Portfolio	اسم المصرف	رمز المصرف	تسلسل
0.0000	المصرف التجاري العراقي	BCOI	1
0.2976	مصرف بغداد	BBOB	2
0.2652	المصرف الإسلامي العراقي	BIIB	3
0.0000	مصرف الاستثمار العراقي	BIBI	4
0.0710	مصرف سومر التجاري	BSUC	5
0.2272	مصرف المنصور للاستثمار	BMNS	6
0.1391	المصرف المتحد للاستثمار	BUND	7
0.0000	مصرف الاقتصاد للاستثمار والتمويل	BELF	8
0.0000	مصرف كردستان الدولي الاسلامي	BKUI	9
<b>Expected Return: 0.0150</b>			
<b>Volatility (Risk): 0.0288</b>			
<b>Sharpe Ratio: 0.5203</b>			

المصدر : من إعداد الباحثين بالاعتماد على برنامج Python

إلى أن العائد المتوقع للمحفظة بلغ 0.0085 (0.85%)، بينما المخاطرة (الانحراف المعياري) كانت 0.0041 (0.41%) فقط، وهو ما يعكس قدرة الخوارزمية على تقليل التقلبات بشكل كبير. كما أن مؤشر شارب وصل إلى 2.0639، مما يدل على أداء مرتفع للمحفظة بعد تعديل العائد وفقاً للمخاطرة، ويُعد من المؤشرات الجيدة جداً عند مقارنته بالنماذج الأخرى مثل ماركويتز والانحدار اللوجستي. بالنظر إلى توزيع الموجودات داخل المحفظة، منحت خوارزمية SVM الوزن الأعلى مصرف كردستان الدولي الاسلامي (BKUI) بنسبة

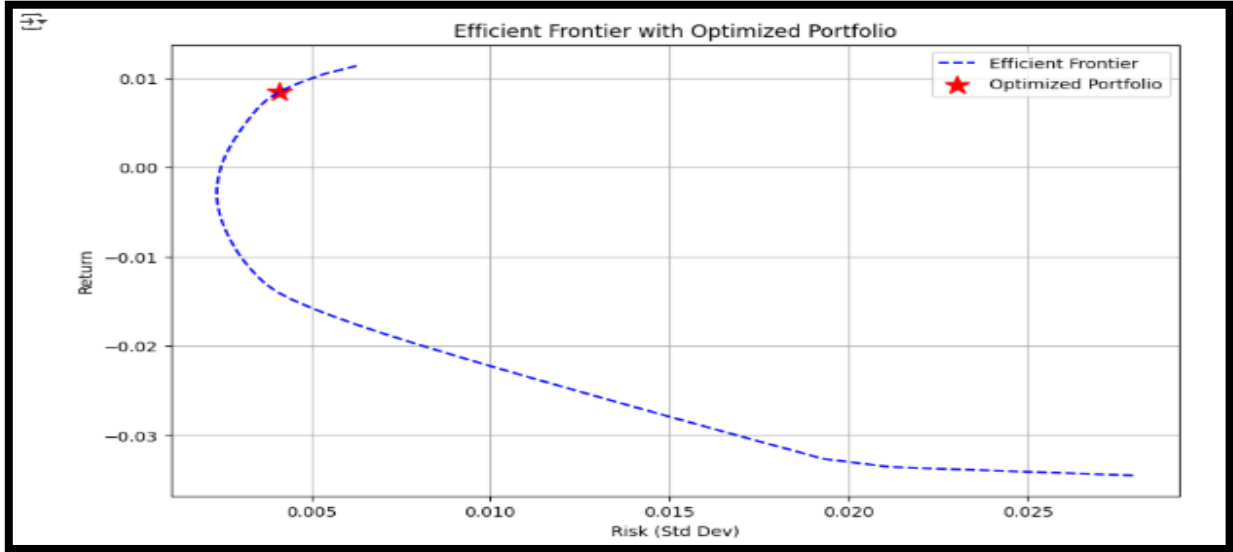
## 2-خوارزمية SVM (آلة الدعم الناقل)

### algorithm(Convoy Support Machine)

يعكس الرسم البياني رقم(3) لمحفظة SVM (آلة الدعم الناقل) أداءً قوياً وفعالاً في تحليل البيانات المالية وتكوين محفظة استثمارية محسنة بناءً على تقنيات تعلم الآلة المتقدمة. تعتمد خوارزمية SVM على تحديد الحدود الفاصلة المثلى بين البيانات لتصنيفها بطريقة دقيقة، وهو ما يساعد على التنبؤ بأداء الموجودات وتوزيعها داخل المحفظة بطريقة تُحقق مبادلة مقبولة بين العائد والمخاطرة. تشير البيانات الرقمية المصاحبة

النماذج التقليدية التي تعتمد على فرضيات خطية مثل نموذج ماركويتز. وتُعد هذه النتائج مؤشراً على مدى كفاءة نموذج SVM في تقديم حلول استثمارية دقيقة وقابلة للتكيف مع بيانات الأسواق المتغيرة مثل سوق العراق للأوراق المالية، مما يجعله مناسباً للمستثمرين الذين يفضلون استراتيجيات تعتمد على التحليل الذكي والتوزيع الديناميكي للأصول.

61.38%، تلاه المصرف الأهلي العراقي (BIBI) بنسبة 25.61%، والمصرف الإسلامي العراقي (BIIB) بنسبة 13.02%. بينما استُبعدت أصول مثل BCOI، BBOB، BSUC، BMNS، BUND، BELF، حيث كانت أوزانها صفرية، ما يدل على أن الخوارزمية لم تجد لها تأثيراً ملموساً في تحسين الأداء أو تقليل الخطر. انظر جدول رقم (5) يُبرز هذا النموذج ميزة خوارزميات التعلم الآلي في اكتشاف الأنماط المعقدة وغير الخطية بين العوائد والمخاطر، وهو ما يميزه عن



شكل (3) الرسم البياني الخاص بالمحفظة SVM (آلة الدعم الناقل)  
المصدر : من إعداد الباحثين بالاعتماد على برنامج Python

الجدول (5) الرسم البياني الخاص بالمحفظة SVM (آلة الدعم الناقل)

تسلسل	رمز المصرف	اسم المصرف	Weights: Optimized Portfolio
1	BCOI	المصرف التجاري العراقي	0.0000
2	BBOB	مصرف بغداد	0.0000
3	BIIB	المصرف الإسلامي العراقي	0.1302
4	BIBI	مصرف الاستثمار العراقي	0.2501
5	BSUC	مصرف سومر التجاري	0.0060
6	BMNS	مصرف المنصور للاستثمار	0.0000
7	BUND	المصرف المتحد للاستثمار	0.0000
8	BELF	مصرف الاقتصاد للاستثمار والتمويل	0.0000
9	BKUI	مصرف كردستان الدولي الاسلامي	0.6138
<b>Expected Return: 0.0085</b>			
<b>Volatility (Risk): 0.0041</b>			
<b>Sharpe Ratio: 2.0639</b>			

المصدر : من إعداد الباحثين بالاعتماد على برنامج Python

### 3-الغابات العشوائية Random Forest

يعكس الرسم البياني رقم (4) الخاص بمحفظة "Random Forest" نتائج استخدام إحدى أبرز خوارزميات التعلم الآلي المعتمدة على مبدأ التعلم التجميعي (Ensemble Learning) في بناء المحافظ الاستثمارية. تُظهر الحدود كفاءة (Efficient Frontier) في الشكل المرفق مجموعة المحافظ الممكنة التي تقدم أفضل تحقيق تحسين في نسبة العائد إلى

المخاطرة، ويُمثل موقع النجمة الحمراء المحفظة المثلى التي تم اشتقاقها باستخدام نموذج الغابات العشوائية. وفقاً للنتائج، فإن العائد المتوقع للمحفظة بلغ (0.0252) أي 2.52%، وهو يُعد الأعلى بين المحافظ المدروسة في النماذج التقليدية والحديثة، بينما بلغت المخاطرة (الانحراف المعياري) مستوى (0.0337) أو 3.37%، وهو ما يعكس مستوى مخاطرة متوسطاً، متناسباً مع العوائد المحققة. وبلغ مؤشر شارب

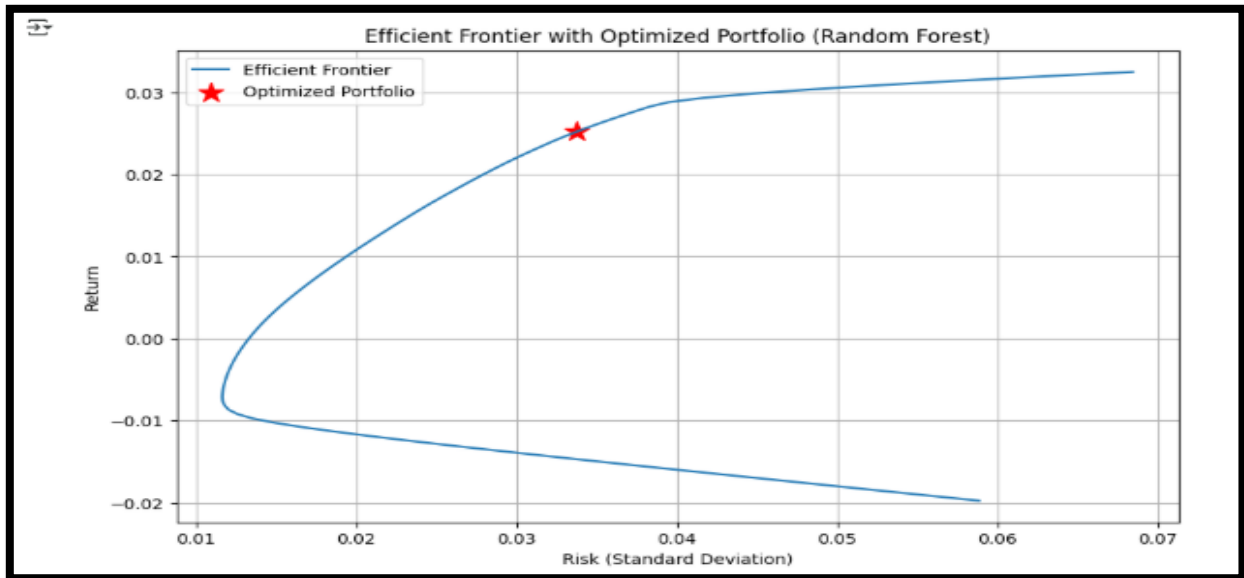
وBKUI تمامًا، حيث منحت أوزانًا تساوي صفرًا، ما يشير إلى أن الخوارزمية لم تجد قيمة مضافة من حيث العائد أو تقليل المخاطرة لهذه الموجودات. انظر جدول رقم (6) يُظهر نموذج Random Forest قدرة عالية على تحليل العلاقات غير الخطية واستخلاص الأنماط الخفية من البيانات التاريخية، مما ساعده على تقديم محفظة ذات عائد أعلى وتوزيع أكثر تنوعًا نسبيًا.

0.7463 (Sharpe Ratio)، ما يشير إلى مستوى أداء أفضل مقارنة بمحفظة الانحدار اللوجستي، لكنه لا يصل إلى مستوى محفظة PCA. من حيث التوزيع النسبي للأصول داخل المحفظة، يلاحظ أن النموذج منح النسبة الأعلى لبنك بغداد (BBOB) بنسبة 47.30%، تليه BELF بنسبة 34.58%، ثم المصرف الإسلامي العراقي (BIIB) بنسبة 9.20%، والمصرف الأهلي العراقي (BIBI) بنسبة 18.12%، فيما استُبعدت أصول مثل BUND، BMNS، BSUC، BCOI،

الجدول (6) النتائج خوارزمية الغابات العشوائية "Random Forest"

تسلسل	رمز المصرف	اسم المصرف	Weights: Optimized Portfolio
1	BCOI	المصرف التجاري العراقي	0.0000
2	BBOB	مصرف بغداد	0.4730
3	BIIB	المصرف الإسلامي العراقي	0.0000
4	BIBI	مصرف الاستثمار العراقي	0.1812
5	BSUC	مصرف سومر التجاري	0.0000
6	BMNS	مصرف المنصور للاستثمار	0.0000
7	BUND	المصرف المتحد للاستثمار	0.0000
8	BELF	مصرف الاقتصاد للاستثمار والتمويل	0.3458
9	BKUI	مصرف كردستان الدولي الاسلامي	0.0000
<b>Expected Return: 0.0252</b>			
<b>Volatility (Risk): 0.0337</b>			
<b>Sharpe Ratio: 0.7463</b>			

المصدر : من إعداد الباحثين بالاعتماد على برنامج Python



الشكل (4) الرسم البياني الخاص بمحفظة "Random Forest"

المصدر : من إعداد الباحثين بالاعتماد على برنامج Python

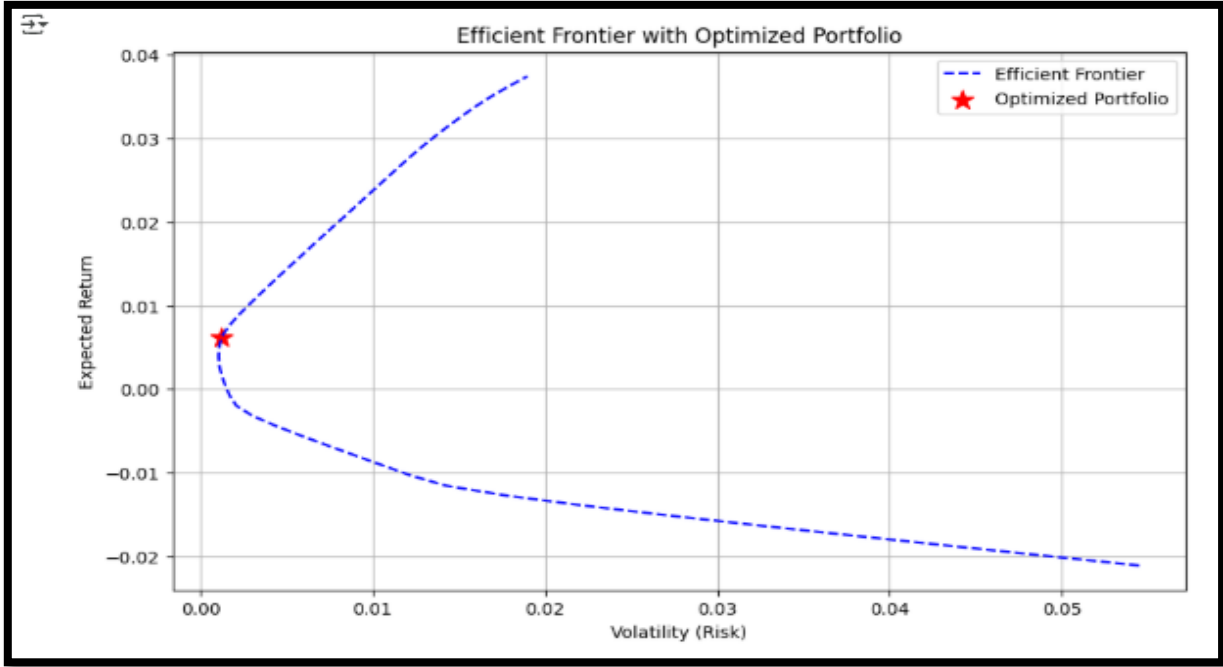
مع الحفاظ على مستوى مخاطرة مقبول، لاسيما في الأسواق النامية مثل سوق العراق للأوراق المالية، حيث تتسم البيانات بالتقلبات وعدم اليقين، ما يجعل النماذج الذكوية مثل الغابات العشوائية أكثر ملاءمة ودقة في تقدير الأداء المستقبلي للمحافظ.

ورغم أن مؤشر شارب لم يكن الأعلى، إلا أن نسبة العائد إلى المخاطرة المُتحققة تُعد جيدة، وتشير إلى كفاءة نسبية في إدارة المخاطر عبر مزيج متبادل من الموجودات ذات الأوزان المتباينة. وعليه، يمكن اعتبار محفظة Random Forest خيارًا مناسبًا للمستثمرين الذين يسعون إلى تحقيق عوائد أعلى

تباين البيانات المالية. يوضح المنحنى الأزرق ما يُعرف بـ “الحدود كفاءة”، والذي يمثل مزيج المحافظ التي تحقق أعلى عائد ممكن لكل مستوى من المخاطرة، في حين تُشير النقطة الحمراء إلى موقع المحفظة المثلى التي تم تحديدها من خلال نموذج PCA، والتي تقع عند مستوى منخفض جدًا من المخاطرة مع عائد ملحوظ.

### 3- تحليل المكونات الرئيسية

يعكس الرسم البياني رقم (5) لمحفظة PCA (تحليل المكونات الرئيسية) مستوى متقدمًا من الكفاءة في إدارة المحفظة الاستثمارية من خلال اعتماد خوارزميات تعلم آلي متخصصة في تقليل الأبعاد واستخلاص العوامل المؤثرة الأساسية في



الشكل (5) الرسم البياني لخوارزمية تحليل المكونات الرئيسية (PCA)  
المصدر : من إعداد الباحثين بالاعتماد على برنامج Python

### الجدول (7) نتائج خوارزمية تحليل المكونات الرئيسية (PCA)

Weights: Optimized Portfolio	اسم المصرف	رمز المصرف	
0.0000	المصرف التجاري العراقي	BCOI	1
0.9375	مصرف بغداد	BBOB	2
0.0029	المصرف الإسلامي العراقي	BIIB	3
0.0000	مصرف الاستثمار العراقي	BIBI	4
0.0000	مصرف سومر التجاري	BSUC	5
0.0000	مصرف المنصور للاستثمار	BMNS	6
0.0372	المصرف المتحد للاستثمار	BUND	7
0.0224	مصرف الاقتصاد للاستثمار والتمويل	BELF	8
0.0000	مصرف كردستان الدولي الاسلامي	BKUI	9
<b>Expected Return: 0.0061</b>			
<b>Volatility (Risk): 0.0012</b>			
<b>Sharpe Ratio: 5.0805</b>			

المصدر : من إعداد الباحثين بالاعتماد على برنامج Python

(0.12%) فقط، ما يُظهر قدرة النموذج العالية على تقليل التقلبات. اللافت في النتائج هو أن مؤشر شارب بلغ 5.8805، وهو الأعلى على الإطلاق مقارنة بجميع النماذج التقليدية

وفقًا للنتائج الرقمية، يظهر أن العائد المتوقع بلغ 0.0061 (0.61%)، وهو أقل نسبيًا من بعض النماذج الأخرى، إلا أن مستوى المخاطرة كان في حدوده الدنيا عند 0.0012

- لكفاءتها العالية في تحقيق تحسين في نسبة العائد إلى المخاطرة.
2. ينبغي للمؤسسات المالية ومديري المحافظ الاستثمارية تعزيز قدراتهم في تقنيات التعلم الآلي والاستثمار في بناء نظم تحليل متقدمة تعتمد على هذه الخوارزميات لتحسين أداء المحافظ وتقليل المخاطر.
3. يُنصح بإجراء دراسات موسعة تشمل خوارزميات أخرى وتطبيقات متعددة الأسواق المالية، لاختبار مدى تعميم نتائج البحث وتحسين النماذج بما يتناسب مع بيئات سوقية مختلفة.
4. ينصح بإدخال عوامل إضافية في النماذج، مثل المتغيرات الاقتصادية والسياسية المؤثرة، لتعزيز دقة التنبؤات وتحسين استراتيجيات إدارة المحافظ في الأسواق ذات الظروف غير المستقرة.
5. يجب على الباحثين توخي الحذر عند استخدام خوارزميات مثل الغابة العشوائية في الأسواق ذات تقلبات عالية، والعمل على تطوير نماذج تقلل من مخاطر الأداء المتذبذب.

### توافر البيانات:

تم تضمين البيانات المستخدمة لدعم نتائج هذه الدراسة في المقالة.

### تضارب المصالح:

يعلم المؤلفون أنه ليس لديهم تضارب في المصالح.

### موارد التمويل:

لم يتم تلقي أي دعم مالي.

### شكر وتقدير:

لا احد.

## References:

1. Abdul-‘Ali, Salhi. (2020). Dawr al-Barmijah al-Riyadiyah fi Idarat al-Muhafazah al-Istithmariyyah al-Muthla: Dirasah Halat Borsa ‘Amman [The Role of Mathematical Programming in Managing the Optimal Investment Portfolio: A Case Study of the Amman Stock Exchange] (Unpublished Doctoral Dissertation). University of Algiers, Faculty of Economic and Commercial Sciences and Management Sciences, Department of Economic Sciences.
2. Abdulqader, D. D. (2024). Binaa’ al-Muhafazah al-Muthla lil-As-hum wa Tahseen Ada’iha Bisti’maal Khawarezmiyat al-Asad wa Khawarezmiyat Da’m Mutajihat al-Alaah: Dirasah Tatbeeqiyyah ‘ala As-hum

والحديثة، ما يعني أن كل وحدة مخاطرة يقابلها عائد مرتفع، مما يعكس كفاءة غير مسبوقه في الأداء المعدل حسب المخاطرة. أما فيما يتعلق بتوزيع الموجودات، فيلاحظ أن نموذج PCA أعطى الوزن الأكبر لبنك بغداد (BBOB) بنسبة 93.75%، يليه بنك بابل (BELF) بنسبة 22.4%، بينما تم استبعاد عدد من الموجودات الأخرى مثل BCOI، BIBI، BIBI، BSUC، BMNS، BUND، وBKUI والتي منحت جميعها أوزاناً تساوي صفراً، ما يشير إلى أن مساهمتها في تحسين العائد أو تقليل المخاطرة كانت ضئيلة ضمن التحليل المعتمد على المكونات الأساسية. انظر الى جدول رقم (7) تشير هذه النتائج إلى أن خوارزمية PCA توفر أداة قوية في استخراج القيم الجوهرية الكامنة وراء تقلبات السوق، مما يجعلها مناسبة جداً للمستثمرين المحافظين الذين يبحثون عن عوائد مستقرة مع أدنى مستويات المخاطرة الممكنة. كما تُظهر نتائجها أن النموذج يمتاز بالبساطة الرياضية والانضباط الإحصائي، مما يجعله مرشحاً قوياً عند الحاجة إلى تقنيات تنبؤية دقيقة في بيئات مالية تتسم بالتقلب، مثل سوق العراق للأوراق المالية.

## المبحث الرابع: الاستنتاجات و التوصيات

### اولا: الاستنتاجات

1. أظهرت خوارزميات التعلم الآلي المقدمة تبايناً واضحاً في الأداء عند استخدامها لتحسين بناء المحافظ الاستثمارية، حيث تفوقت خوارزمية تحليل المكونات الرئيسية (PCA) على غيرها من الخوارزميات بتحقيق أعلى نسبة شارب، ما يعكس قدرتها الكبيرة على تحقيق عوائد مستقرة مع مخاطر منخفضة جداً.
2. أظهرت خوارزمية آلة المتجهات الداعمة (SVM) أداءً قوياً من حيث المبادلة بين العائد والمخاطرة، ما يجعلها خياراً فعالاً خاصةً للمستثمرين الباحثين عن تقليل المخاطر مع المحافظة على عوائد معقولة.
3. بالرغم من أن خوارزمية الغابة العشوائية (Random Forest) قدمت عوائد متفوقة نسبياً، إلا أنها صاحبتها مخاطر أعلى مقارنةً بخوارزميات PCA و SVM، ما يشير إلى ضرورة استخدامها بحذر من قبل المستثمرين الأكثر تقبلاً للمخاطر.
4. على الرغم من بساطة الانحدار اللوجستي (Logistic Regression)، إلا أن أدائه كان أقل مقارنةً بالخوارزميات الأخرى من حيث التوفيق بين العائد والمخاطرة، مما يحد من كفاءته في تحسين المحافظ الاستثمارية في بيئات معقدة.
5. تؤكد هذه النتائج أهمية استخدام خوارزميات التعلم الآلي المتقدمة في إدارة المحافظ الاستثمارية، لا سيما في الأسواق التي تتسم بالتقلبات والظروف الاقتصادية والسياسية المتغيرة مثل سوق العراق للأوراق المالية.

### ثانيا: التوصيات

1. ينصح الباحثون والمستثمرون بتبني خوارزميات تحليل المكونات الرئيسية (PCA) وآلة المتجهات الداعمة (SVM) في عمليات بناء المحافظ الاستثمارية نظراً

- fi Takwin Mu'ashir lil-Tanmiyah al-Bashariyah al-Mustadamah fi al-Duwal al-'Arabiyah [Using Principal Component Analysis to Construct an Indicator for Sustainable Human Development in Arab Countries]. *Journal of Economic and Administrative Sciences*, 24(4), 673–690. <https://jeasiq.uobaghdad.edu.iq/index.php/JEASIQ/article/view/1337/1232>
9. Bakir, M. M. A.-D. (2008). *Muhafaz Istithmariyah: Idaratuha wa Istratijiyatuha [Investment Portfolios: Their Management and Strategies]*. Dar Shuaa' lil-Nashr wal-Uloom.
  10. Barocas, S., Hardt, M., & Narayanan, A. (2017). *Fairness in machine learning*. NIPS Tutorial, 1.
  11. Bodie, Zvi, Kane, Alex, & Marcus, Alan J. (2018). *Investment and portfolio management* (9th ed.). McGraw-Hill, Inc.
  12. Bughin, J., Hazan, E., Ramaswamy, S., Chui, M., Allas, T., & Dahlström, P. (2017). *Artificial intelligence: The next digital frontier?* McKinsey Global Institute.
  13. Chui, M., Manyika, J., & Bughin, J. (2015). *Ten IT-enabled business trends for the decade ahead*. McKinsey Quarterly, 1, 1–12.
  14. da Silva Lourenço, Camila. (2021). *Introduction to logistic regression in financial analysis*. *Journal of Applied Statistics*, 45(3), 1–15.
  15. Deng, Wei, Polak, Peter, Safikhani, Ahmad, & Shah, Ronak. (2023). *A unified framework for fast large-scale portfolio optimization*. Department of Applied Mathematics and Statistics, Stony Brook University; Department of Statistics, George Mason University; Institute for Advanced Computational Science, Stony Brook University.
  16. Ghanawi, H. A. (2019). *Binaa' al-Muhafazah al-Muthla lil-As-hum wa Tahseen Ada'iha fi Zill Bii'ah Dhababiyah Bisti'maal al-Khawarezmiya al-Wirathiyah al-Muta'addidah al-Ahdaf* (Unpublished doctoral dissertation). University of Baghdad, College of Administration and Suq al-Iraq wa Suq New York lil-Awraq al-Maliyyah fi al-Fatrah min 2010 ila 2019 (Unpublished doctoral dissertation). Al-Mustansiriya University, College of Administration and Economics, Department of Financial Management, Baghdad, Iraq.
  3. Agrawal, A., Gans, J., & Goldfarb, A. (2018). *Prediction machines: The simple economics of artificial intelligence*. Harvard Business Review Press.
  4. Al-Hchemi, L. H. M. (2023, December). *A proposed model for portfolio optimization using machine learning techniques and genetic algorithm*. In *Proceedings of the First International Specialized Conference of the College of Imam Al-Kadhim (AS): The Banking Sector as a Path to Sustainable Development and Green Economy Financial Technology, Digital Transformation, Green Bonds* (December 6–7, 2023), Najaf, Iraq.
  5. Al-Hilali, Sami Abdullah, & Khalil, Fouad Abdul Karim. (2022). *Ta'thir Khawarzamiyat Muttaj Da'am al-Alaah 'ala Shabakat al-Tasneef al-'Amiq [The Impact of the Support Vector Machine Algorithm on Deep Classification Networks]*. *Journal of Engineering Sciences and Information Technology*, 6(4), 73–88. <https://journals.ajsrp.com/index.php/jesit/article/view/5279/5027>
  6. Al-Qadhi, Laureen Ibrahim. (2016). *Athar Kafa'at Idarat al-Muhafazah al-Istithmariyah 'ala Ribhiyat al-Bunuk al-Tijariyah: Dirasah Ikhtiyariyah 'ala al-Bunuk al-Tijariyah al-Urduniyah lil-Fatrah min 2012–2014 [The Effect of Investment Portfolio Management Efficiency on the Profitability of Commercial Banks: A Selective Study on Jordanian Commercial Banks for the Period 2012–2014]* (Unpublished Master's Thesis). College of Business, Middle East University, Jordan.
  7. Al-Shabib, Duraid Kamil. (2010). *Idarat al-Muhafaz al-Istithmariyah [Investment Portfolio Management]*. Amman, Jordan: Dar Al-Maseera for Publishing and Distribution.
  8. Al-Sheikh, Sajida, & Rubai'i, Huda. (2018). *Istikhdam Tahlil al-Mukawwinat al-Ra'isiya*

- Sugiyama, Masashi, ... & Morimoto, Jun. (2022). Deep learning, reinforcement learning, and world models. *Neural Networks*, 152, 267–275.
25. Munoko, Isaac, Brown-Liburd, Helen L., & Vasarhelyi, Miklos. (2020). The ethical implications of using artificial intelligence in auditing. *Journal of Business Ethics*, 167, 209–234.
26. orvig, P., & Russell, S. (2016). *Artificial intelligence: A modern approach (3rd ed.)*. Pearson Education Limited.
27. Papernot, N., McDaniel, P., Sinha, A., & Wellman, M. P. (2018). Sok: Security and privacy in machine learning. In 2018 IEEE European Symposium on Security and Privacy (EuroS&P) (pp. 399–414). IEEE.
28. Reilly, F. K., Brown, K. C., & Leeds, S. J. (2019). *Investment analysis & portfolio management (11th ed.)*. Cengage Learning, Inc.
29. Selmani, Adel, & Ghazil, Mohammed Mouloud. (2017). Al-Muhafazah al-Maliyyah al-Istithmariyyah bayn al-Mafhoom al-Taqleedi wa al-Mafhoom al-Islami: Dirasah Muqaranah [The Investment Portfolio Between the Traditional and Islamic Concept: A Comparative Study]. University of Mohamed Khider Biskra, *Journal of Human Sciences*, 17(49).
30. Singh, S., & Gautam, J. (2014). The Single Index Model & the construction of optimal portfolio: A case of banks listed on NSE India. *Risk Governance & Control: Financial Markets & Institutions*, 4(2).
31. Smart, S. B., & Zutter, C. J. (2020). *Fundamentals of investing (14th ed.)*. Pearson Education.
- Economics, Department of Business Administration, Baghdad, Iraq.
17. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
18. Hilpisch, Y. (2020). *Artificial intelligence in finance*. O'Reilly Media, Inc.
19. Ibrahim, A. A., Saeed, B. N., & Fadel, M. A. (2023). Using valuation multiples to predict stock prices and their relationship to the market value of the stock: An applied study of a sample of stocks listed on the Iraq Stock Exchange. *Entrepreneurship Journal for Finance and Business (EJFB)*, 4(4), 170–183. <https://doi.org/10.56967/ejfb2023350>
20. Kaczmarek, T., & Perez, K. (2021). Building portfolios based on machine learning predictions. *Economic Research-Ekonomska Istraživanja*, 34(1), 2597–2616. <https://doi.org/10.1080/1331677X.2021.1875865>
21. Kazeem, O. (2023). *Portfolio optimization using machine learning (Unpublished doctoral dissertation)*. University of Stirling. Retrieved from <https://www.researchgate.net/publication/374084001>
22. Kouki, I. (2023). Building an investment portfolio from virtual currencies using linear programming. *Tikrit Journal of Administration and Economics Sciences*, 19(64 part 2).
23. Marshan, A. (2021). Artificial intelligence: Explainability, ethical issues and bias. *Annals of Robotics and Automation*, 5(1), 034–037. <https://doi.org/10.17352/ara.000011>
24. Matsuo, Yutaka, LeCun, Yann, Sahani, Maneesh, Precup, Doina, Silver, David,