

تقييم أداء المحافظ الاستثمارية بتطبيق خوارزميات التعلم العميق :
حالة بورصة العملات المشفرة (2020-2022م)

**Evaluating the Performance of Investment Portfolios Using Deep Learning Algorithms:
A Case study of the Cryptocurrency Market (2020-2022)**

د.زواوي الحبيب - أستاذ محاضر-أ-

Dr.ZOUAOUI Habib

كلية الاقتصاد/ جامعة غليزان / الجزائر

habib.zouaoui@univ-relizane.dz

د. نعاس مريم نجا - أستاذ محاضر-ب-

Dr.NAAS Meryem-Nadjat

meryemnadjat.naas@univ-rlizane.dz

تاريخ تقديم البحث: 2023/01/02

تاريخ قبول النشر: 2023/02/04

المستخلص :

يهدف البحث إلى محاولة تقييم أداء سلوك عوائد المحافظ الاستثمارية والمساعدة على اتخاذ القرارات المثلى في ظروف عدم التأكد في الأسواق العالية المخاطر ،حيث تم إسقاط الدراسة على الاستثمار في العملات المشفرة التي تتميز أسواقها بالتداول عالي التردد ، وتم باستخدام نماذج المالية السلوكية المبنية على مفهوم العائد-المخاطرة والتعلم العميق المبني على عمل خوارزميات الشبكات العصبية الاصطناعية (ANN) وشبكة الذاكرة الطويلة المدى (LSTM) .

تم اختيار محفظة عشوائية مشكلة من 10 أصول عبارة عن عملات مشفرة بالاعتماد على قاعدة بيانات موقع : <https://finance.yahoo.com/crypto> خلال الفترة 2020 - 2022 م وبرمجة لغة البايثون (Python) . ومحاولة تقييم أداء النماذج المستخدمة في التنبؤ الدقيق بالأوزان النسبية المثلى للمحفظة الاستثمارية، والتي أثبتت فعالية نسبية لنماذج التعلم العميق من خلال تقدير قيم متوسط الخطأ التربيعي (MSE) بمستوى 0.1602 % لنماذج التعلم العميق مقابل قيمة 1.3038 % لمخرجات نموذج العائد- المخاطرة لماركوفيتز بناءا على تدريب 80% واختبار 20 % من بيانات الدراسة .

وفي الأخير تم قبول الفرضية الثانية التي تنص على فعالية خوارزميات التعلم العميق من الاستفادة من أسلوب التنويع في بناء محافظ مثلى ذات عائد قدر ب 99% ومخاطرة ب 65% وقيمة لمؤشر شارب قدرت ب 1.99% ، وفي المقابل جاءت محفظة نموذج العائد - المخاطرة لماركوفيتز بمعدل عائد قدر ب 16.49 % ومخاطرة ب 12.23 % مع عدم تنويع الاستثمار على كل أصول المحفظة وقيمة مؤشر شارب ب 0.33 % .

الكلمات المفتاحية: نموذج ماركوفيتز ، التعلم العميق ، المحفظة المثلى ، التنويع ، العملات المشفرة ، الشبكات العصبية الاصطناعية

Abstract:

The research aims to evaluate the performance of the behavior of investment portfolio returns and to help make optimal decisions in conditions of uncertainty as well as high-risk investments. The study was applied on cryptocurrency market whose are characterized by high-frequency trading. Moreover, we have used Markowitz model based on the concept of return-risk (Mean-Variance) and deep learning based on the work of artificial neural networks algorithms(ANN) and the long short term memory network(LSTM). A random portfolio of 10 assets consisting of cryptocurrencies was selected based on the database of the website: <https://finance.yahoo.com/crypto/> during the period 2020-2022 with Python programming.

Finally, we try to evaluate the performance of the models used in accurately predicting the optimal relative weights of the investment portfolio. Which proved the relative effectiveness of the deep learning models by estimating the values of the mean squared error (MSE) at the level of 0.1602% for the deep learning models, compared to a value of 1.3038% for the outputs of the return-risk model for Markowitz, it was based on training 80% and testing 20% of the Dataset.

Finally, the second hypothesis was accepted, which stipulates the effectiveness of deep learning algorithms by taking advantage of the diversification method in building optimal portfolios with an estimated return of 99%, a risk of 65%, and a value of the Sharpe index estimated at 1.99%. An estimated return of 16.49% and a risk of 12.23%, with no diversification of investment on all portfolio assets, and a Sharpe index value of 0.33%.

Keywords: Markowitz Model, Deep Learning, Optimal Portfolio, Cryptocurrencies, Diversification, Neural Networks Artificial.

مقدمة :

يعتبر الذكاء الاصطناعي أحد العلوم التي بدأ العالم الاعتماد عليه بشتى مجالات الحياة نظراً لقدرة هذا العلم لتحصيل وتحليل بيانات ضخمة (Big Data) واتخاذ قرارات والوصول لنتائج دقيقة تفوق قدرة العنصر البشري .

أما في مجال الأسواق المالية ومع زيادة تعقيدات العولمة المالية التي زادت من ظروف عدم التأكد المستقبلي والمخاطر العالية، وعدم تماثل المعلومات المتداولة ومشاكل الخوف والذعر لدى المستثمرين، وفي ظل ظهور الثورة الصناعية الرابعة وأتمتة الخدمات المالية والتداول العالي التردد ، فقد أصبحت أكثر من 80% من تداولات الأسواق الأسهم العالمية اليومية هي تداولات تتم عن طريق الذكاء الاصطناعي (AI) والتداول اللوغاريتمي (Algorithmic Trading) حيث أنها تداولات تتم من دون أي تدخل بشري. والذكاء الاصطناعي يخول المستثمرين بالتداول من خلال إنشاء وفحص واختبار البيانات واتخاذ القرارات الاستثمارية آلياً من خلال تعلم الآلة (Machine Learning)

حيث أن تعلم الآلة يتم برمجتها من خلال اللوغاريتمات ووضع أوامر وفق معايير محددة مثل متوسط التداولات اليومية ومقارنتها مع متوسطات التداول في الفترات الماضية، وتغير الأسعار والكميات المعروضة وتذبذب السوق ككل وتغير الأسعار في سوق المشتقات والنظرة المستقبلية للاقتصاد مع الأخذ بعين الاعتبار مثلاً الأخبار المتعلقة بالحزم التحفيزية أو أي أخبار مؤثرة على السوق من قبل صناع القرار وذلك ليتم دراستها وتحليلها والوصول الى نتيجة نهائية من قبل تعلم الآلة مما يؤدي إلى تنفيذ أمر استثماري محدد.

وينجم عن التداول في هذه الطريقة المبتكرة الموضوعية في القرار الاستثماري. حيث يغلب تأثير التمويل السلوكي (Behavioral Finance) على البشر أثناء التداول، بمعنى أنه يغلب عليهم التأثير سلوكياً في المحيط والتغيرات الاقتصادية مما يؤدي إلى تغيير في القرار الاستثماري الذي تم اتخاذه مسبقاً، وقد ينجم عن هذا التغيير في السلوك والقرار الاستثماري خسائر غير متوقعة. وتعد من مكتسبات هذه الطريقة المبتكرة من التداول هي السرعة في إجراء أوامر التداول حيث أنه يتم البحث عن فرصة استثمارية وجمع المعلومات عنها وتحليلها بعدد ضخم من البيانات بدقة واتخاذ القرار الاستثماري المناسب من خلال تعلم الآلة وتتم كل هذه العملية في خلال ثواني معدودة. حيث أن قدرة الإنسان البشري تستغرق وقت أطول للبحث عن فرصة مشابهة وتنفيذ القرار الاستثماري المناسب بشأنها مما قد يؤدي لتضييع الفرصة الاستثمارية .

منهجية البحث :

1- مشكلة البحث : من خلال البحث سوف نستعرض إشكالية رئيسية والمتعلقة :

بمدى فعالية نماذج المالية السلوكية وتقنيات التعلم العميق في ترشيد القرارات الاستثمارية على مستوى سوق العملات المشفرة؟

2- أهمية البحث : تتمثل أهمية البحث في النقاط التالية:

- تسليط الضوء على موضوع حديث في مجال اتخاذ القرارات الاستثمارية باستخدام خوارزميات الذكاء الاصطناعي وتطورها السريع في خضم الثورة الصناعية الرابعة (بلوكتشين) .
- المساهمة في مواكبة التحديات المستقبلية في مجال مالية الأسواق المبنية على استخدام التعلم الآلي وتحليل البيانات الضخمة ومحاولة تشجيع الحكومات العربية على تبني العملات المشفرة والرقمية للاستثمار فيها.

3- أهداف البحث :

- التأكيد على أهمية أتممة عمليات الاستثمار المالي في الأسواق المالية باستخدام الذكاء الاصطناعي.
- التعرف على مراحل استخدام خوارزميات التعلم الآلي في بناء محافظ استثمارية مثلى.
- تطبيق خوارزميات التعلم العميق في مجال إدارة المخاطر وبناء محافظ استثمارية مثلى في سوق العملات المشفرة.

4- فرضيات البحث :

- الفرضية الأولى :** يتميز استخدام نموذج العائد- المخاطرة لماركيتز وفقا لأسلوب التنوع في إدارة المحافظ الاستثمارية للعملات المشفرة ببناء محافظ مثلى ذات مخاطر محدودة وعوائد مرتفعة بالمقارنة مع نماذج التعلم العميق .
- الفرضية الثانية:** يتميز استخدام نماذج التعلم العميق وفقا لأسلوب التنوع في إدارة المحافظ الاستثمارية للعملات المشفرة ببناء محافظ مثلى ذات مخاطر محدودة وعوائد مرتفعة بالمقارنة مع نموذج العائد - المخاطر لماركيتز .

5- عينة البحث :

تم تطبيق الدراسة على محفظة عشوائية مشكلة من 10 أصول عبارة عن عملات مشفرة بالاعتماد على قاعدة بيانات موقع : <https://finance.yahoo.com/crypto> خلال الفترة 2020 - 2022 م.

6- محاور البحث :

وللإجابة على السؤال المطروح سوف نقسم البحث إلى المحاور التالية :

- المحور الأول : الاتجاهات الحديثة في إدارة الاستثمار المالي
- المحور الثاني : علم البيانات والتعلم الآلي
- المحور الثالث : تقييم أداء محفظة العملات المشفرة (2020-2022م)

7- الدراسات السابقة :

تبقى الدراسات السابقة الحديثة في الموضوع قليلة في هذا المجال وأغلبها باللغة الانجليزية وجاء هذا البحث الأصيل باللغة العربية كمبادرة للولوج في فهم مجال الحوسبة المالية والبيانات الضخمة، ونذكر بعض الدراسات على سبيل الحصر ما يلي :

- دراسة Jinjun Liang & Zhengyao Jiang (2017) تقدم هذه الورقة شبكة عصبية تلافيفية بدون نموذج مع أسعار تاريخية لمجموعة من الأصول المالية كمدخلاتها ، وإخراج أوزان محفظة المجموعة .تم تدريب الشبكة على بيانات أسعار 0.7 سنة من بورصة العملات المشفرة .يتم التدريب بطريقة التعزيز ، مما يزيد من العائد التراكمي ، والذي يعتبر بمثابة وظيفة مكافأة للشبكة .يتم إجراء تجارب التداول Backtest مع فترة تداول مدتها 30 دقيقة في نفس السوق ، محققة عوائد بمقدار 10

أضعاف في فترات 1.8 شهر. تُستخدم أيضًا بعض استراتيجيات اختيار المحفظة التي تم نشرها مؤخرًا لإجراء نفس الاختبارات الخلفية ، والتي تتم مقارنة نتائجها مع الشبكة العصبية . لا تقتصر الشبكة على العملات المشفرة ، ولكن يمكن تطبيقها في أي أسواق مالية أخرى.


- دراسة Lamiaa Zrara (2020) : ساعدت الدراسة في تحديد مجموعة الأوزان المرتبطة بكل سهم مشمول في المحفظة النهائية . النهج المحدد في هذا المشروع يعتمد بشكل رئيسي على الأداء المتوقع للأسهم في المستقبل لبناء محافظ تتوافق مع النفور من المخاطرة لكل مستثمر . تم تنفيذ النموذج باستخدام لغة البرمجة Python ويلجأ إلى الوظائف والمكتبات المحددة مسبقًا التي يمكن الوصول إليها لتحسين وتسريع التحليل والحسابات . تمثل الذاكرة طويلة المدى (LSTM) المحرك الرئيسي للتعلم العميق المستخدم للتنبؤ بحركة الأسهم خلال نطاق استثمار محدد . بعد التنبؤ بأسعار الأصول في المستقبل ، تم حساب كل من العوائد المتوقعة ومصفوفة التباين لكل سهم واستخدمت لإنشاء المحفظة التي تحتوي على أعلى نسبة شارب . بعد تقييم النتائج ، اتضح أن النتائج المسترجعة باستخدام نموذج LSTM تفوقت على بعض الطرق التقليدية مثل تحليل متوسط التباين الذي طرحه ماركويتز . بالإضافة إلى ذلك ، تم إجراء تحليل شامل لتحديد مدى إمكانية تسريع DNN باستخدام وحدة معالجة الرسومات مقارنةً بوحدة المعالجة المركزية . أخيرًا ، توفر الخوارزمية التي تم إنشاؤها نتائج واعدة على الرغم من مستويات عدم اليقين والتقلب وتوفر استراتيجيات تداول فعالة من شأنها أن تمكن جميع أنواع المستثمرين من تحقيق عوائد كبيرة.

- دراسة Jaydip Sen و آخرون (2021) : قامت الدراسة بتحليل السلسلة الزمنية للأسعار التاريخية لأكثر خمسة أسهم من تسعة قطاعات مختلفة في سوق الأسهم الهندية من 1 يناير 2016 إلى 31 ديسمبر 2020 . لكل من هذه القطاعات ، تم بناء محافظ مثالية . للتنبؤ بأسعار الأسهم المستقبلية ، قمنا بتصميم وصقل نموذج للذاكرة طويلة وقصيرة المدى (LSTM) بعد فترة خمسة أشهر من إنشاء المحفظة ، أي في 1 يونيو 2021 ، قمنا بمقارنة العوائد والمخاطر الفعلية والمتوقعة لكل محفظة . تم العثور على العوائد المتوقعة والفعلية لكل محفظة لتكون عالية ، مما يشير إلى مستوى عال من الدقة لنموذج LSTM.

■ المحور الأول : الاتجاهات الحديثة في إدارة الاستثمار المالي

- تشهد Fintech تطورًا مستمرًا في مشهد إدارة الاستثمار . التكنولوجيا المتقدمة واعتماد الحلول ، بما في ذلك استخدام البيانات الضخمة ، والذكاء الاصطناعي ، والتعلم الآلي (ML) ، لمساعدة الشركات على تقييم فرص الاستثمار ، وتحسين محافظهم الاستثمارية ، وتخفيف المخاطر المرتبطة بها ، كان أمرًا إكلينيكيًا في اعتماد التكنولوجيا .
- على سبيل المثال ، تخضع خدمات الاستشارات الاستثمارية لتغييرات جذرية مع نمو وتطور مستشاري الثروة الآليين . يمكن لهؤلاء المستشارين مساعدة المستثمرين دون تدخل مستشار بشري ويمكن أيضًا استخدامهم بالاشتراك مع مستشار بشري . إنه يوسع القدرة على تقديم مشورة مخصصة وقابلة للتنفيذ لمستثمريها مع سهولة الوصول بتكلفة أقل جزئيًا .
- في مجال حفظ السجلات المالية ، تعمل تقنية blockchain ودفتر الأستاذ الموزع على زيادة اعتماد الذكاء الاصطناعي من خلال إنشاء طرق جديدة لتسجيل المعاملات للأصول المالية وتتبعها وتخزينها . على سبيل المثال ، تستخدم شركة "سينتيفي" ، وهي شركة سويسرية للتكنولوجيا المالية تأسست عام 2012 ، الذكاء الاصطناعي والتعلم الآلي لتمكين المستثمرين وأصحاب المصلحة الآخرين في السوق المالية من الاستفادة من المعلومات المالية المتاحة عبر الإنترنت لملايين الأشخاص والمؤسسات .
- علاوة على ذلك ، يمكن لشركات إدارة الأصول تحقيق فوائد كبيرة من خلال اعتماد الذكاء الاصطناعي والتعلم الآلي . تساعد هذه التقنيات في توفير رؤى قابلة للتنفيذ في الوقت الفعلي وتسهيل قرارات إدارة المحافظ . يمكن للمجموعات الفرعية من الذكاء الاصطناعي تمكين مديري الأصول من تبسيط العمليات لتحسين قرارات وعمليات الاستثمار .
- في أكتوبر 2019 ، أعلنت MDOTM و Raiffeisen Capital Management ، أحد أكبر مديري الصناديق في النمسا ، عن شراكة استراتيجية جديدة . من خلال هذه المبادرة الجديدة ، قد تستخدم MDOTM مجموعة صناديق RCM المستدامة لتوفير حلول الاستثمار SRI للسوق التي تستفيد من الكفاءة التي توفرها تقنية الذكاء الاصطناعي في إنشاء المحفظة .

- علاوة على ذلك ، في مايو 2020 ، أعلنت Boosted.ai ، منصة ML الموزعة البارزة لمحترفي الاستثمار العالميين ، عن إغلاق جولة تمويل بقيمة 8 ملايين دولار أمريكي من الفئة أ. قد تستخدم Boosted.ai التمويل لمواصلة تحسين Boosted Insights ومنصة ML الخاصة بها والتي تمكن مديري المحافظ والمحللين وكبار مسؤولي الاستثمار (CIO's) من زيادة عمليات الاستثمار الحالية وتوليد أفكار جديدة وإدارة المخاطر¹.



المحور الثاني : علم البيانات والتعلم الآلي

■ ما هو التعلم الآلي؟

التعلم الآلي هو شكل من أشكال الذكاء الاصطناعي الذي يتيح للنظام التعلم من البيانات وليس من خلال البرمجة الصريحة. ولكن، التعلم الآلي ليس بالعملية البسيطة. وبقية الخوارزميات باستيعاب بيانات التدريب، يمكن عندئذ إنتاج نماذج أكثر دقة بناءً على تلك البيانات. يعد نموذج التعلم الآلي هو الناتج الذي يتم تكوينه عند القيام بتدريب خوارزمية التعلم الآلي الخاصة بك مع البيانات. بعد التدريب، عندما تقوم بتقديم نموذج بأحد المدخلات، سيتم منحك مخرجات. على سبيل المثال، ستقوم الطرق التنبؤية بتكوين أحد نماذج التنبؤ. بعد ذلك، عندما تقوم بتقديم نموذج التنبؤ بالبيانات، ستقوم باستلام تنبؤ بناءً على البيانات التي قامت بتدريب النموذج.²

■ التعلم التكراري (Reccurent Learning) :

يتيح التعلم الآلي للنماذج التدريب على مجموعات البيانات قبل نشرها. بعض نماذج التعلم الآلي متصلة ومتواصلة. هذه العملية التكرارية للنماذج عبر الانترنت تؤدي الى تحسن في أنواع الارتباطات التي تتم بين عناصر البيانات. ونظرا لتعقيدها وحجمها، فإن هذه الأنماط والروابط يمكن أن يتم التغاضي عنها بسهولة عن طريق ملاحظة الإنسان. بعد أن يتم تدريب أحد النماذج، يمكن استخدامه في الوقت الفعلي للتعلم من البيانات. التحسينات في الدقة تكون نتيجة لعملية التدريب والتشغيل الآلي والتي تعد جزءا من التعلم الآلي.

■ نهج التعلم الآلي (Machine Learning):

تكون تقنيات التعلم الآلي مطلوبة لتحسين دقة النماذج التنبؤية. وتبعاً لطبيعة مشكلة الأعمال التي يجري التصدي لها، هناك نهج مختلف يستند الى نوع البيانات وحجمها. في هذا القسم، نحن نناقش فئات التعلم الآلي.

■ التعلم تحت الإشراف (Supervised Learning) :

يبدأ التعلم تحت الإشراف عادةً بمجموعة محددة من البيانات وبفهم معين لكيفية تصنيف تلك البيانات. ويهدف التعلم تحت الإشراف الى ايجاد أنماط في البيانات يمكن تطبيقها على عملية التحليل. يكون لهذه البيانات خصائص مميزة تقوم بتعريف معنى البيانات. على سبيل المثال، يمكنك تكوين تطبيق للتعلم الآلي يميز بين ملايين الحيوانات، بناءً على الصور والوصف الكتابي.

¹ . <https://www.mordorintelligence.com/ar/industry-reports/ai-in-fintech-market>

² . <https://www.ibm.com/sa-ar/cloud/deep-learning>

■ تعلم بدون مراقب (Unsupervised Learning):

يتم استخدام التعلم بدون مراقب عندما تتطلب المشكلة كمية هائلة من البيانات غير محددة العنوان. على سبيل المثال، تطبيقات وسائل التواصل الاجتماعي، مثل Twitter و Instagram و Snapchat، كلها تحتوي على كميات كبيرة من البيانات غير محددة العنوان. فهم معنى هذه البيانات يتطلب طرق حسابية لتصنيف البيانات بناء على النماذج أو أنظمة المجموعة التي يتم العثور عليها. يقوم التعلم غير الخاضع للإشراف بإجراء عملية متكررة، حيث يقوم بتحليل البيانات دون تدخل بشري. يتم استخدامه مع تقنية اكتشاف البريد الإلكتروني غير الهام. هناك عدد كبير جدا من المتغيرات في الرسائل الإلكترونية الشرعية والرسائل غير الهامة لكي يقوم المحلل بوضع علامة على البريد الإلكتروني غير المرغوب فيه. وبدلاً من ذلك، يتم تطبيق مصنفات التعلم الآلي، بناءً على التجميع والإرفاق، لتحديد البريد الإلكتروني غير المرغوب فيه.


■ تعزيز التعلم (Reinforcement Learning):

تعزيز التعلم هو نموذج للتعلم السلوكي. حيث تتلقى الطرق الحسابية المعلومات المرجعية من تحليل البيانات، وتوجه المستخدم إلى أفضل النتائج. ويختلف تعزيز التعلم عن الأنواع الأخرى من التعلم تحت الإشراف، لأن النظام لم يتم تدريبه باستخدام عينة من مجموعة من البيانات. بدلاً من ذلك، فإن النظام يتعلم من خلال التجربة والخطأ. ولذلك، فإن سلسلة من القرارات الناجحة ستؤدي إلى تعزيز العملية، لأنها تحل المشكلة على أفضل وجه.

■ التعلم العميق (Deep Learning):

التعلم العميق هو طريقة محددة للتعلم الآلي التي تضم الشبكات العصبية في الطبقات المتعاقبة للتعلم من البيانات بطريقة تكرارية. التعلم العميق يفيد بشكل خاص عندما تحاول تعلم أنماط من بيانات غير محددة الهيكل. تم تصميم الشبكات العصبية المعقدة للتعلم العميق لمحاكاة كيفية عمل الدماغ البشري، بحيث يمكن تدريب أجهزة الكمبيوتر على التعامل مع التجريدات والمشاكل التي تتسم بضعف التعريف. يمكن للطفل البالغ من العمر خمس سنوات أن يتعرف بسهولة على الفرق بين وجه معلمته ووجه حارس البوابة. وفي المقابل، يجب على الحاسب أن يقوم بالكثير من العمل لمعرفة من يكون من. وكثيراً ما يتم استخدام الشبكات العصبية والتعلم العميق في التعرف على الصور والكلام وتطبيقات الرؤية للحاسب.³

■ البيانات الضخمة (Big Data) في سياق التعلم الآلي :



يتطلب التعلم الآلي أن يتم تطبيق مجموعة البيانات الصحيحة على عملية التعلم. ولا يتعين على المؤسسة أن تحصل على بيانات كبيرة لاستخدام تقنيات التعلم الآلي؛ إلا أن البيانات الكبيرة يمكن أن تساعد في تحسين دقة نماذج التعلم الآلي. باستخدام البيانات الكبيرة، أصبح من الممكن الآن تطبيق المحاكاة الافتراضية على البيانات بحيث يمكن تخزينها بأكثر الطرق كفاءة وفعالية من حيث التكلفة، سواء كانت في بيئة تشغيل محلية أو بيئة تشغيل سحابية. بالإضافة إلى ذلك، فإن التحسينات في سرعة الشبكة وموثوقيتها أزلت القيود المادية الأخرى المرتبطة بإدارة كميات هائلة من البيانات بالسرعة المقبولة. أضف إلى هذا تأثير التغييرات

³. للتفصيل أكثر انظر : ميلاد وزان ، علاء طعيمة ، التعلم العميق بلغة بايثون ، العراق ، 2022 ، ص 141-150

في سعر وتطور ذاكرة الكمبيوتر، حيث أصبح الآن من الممكن تخيل كيف يمكن للشركات الاستفادة من البيانات بطرق لم يكن من الممكن تصورها قبل خمس سنوات فقط. كما أن ميزة التعلم الآلي هو أنه من الممكن الاستفادة من الطرق الرياضية والنماذج للتنبؤ بالنتائج. وتتمثل الخدعة في ضمان قيام علماء البيانات الذين يقومون بالعمل باستخدام الطرق الحسابية الصحيحة، واستيعاب البيانات الأكثر ملاءمة (الدقيقة والواضحة) واستخدام أفضل النماذج أداء. إذا اجتمعت جميع هذه العناصر معاً، فمن الممكن استمرار تدريب النموذج والتعلم من النتائج من خلال التعلم من البيانات. ويؤدي التشغيل الآلي لعملية تكوين النماذج والتدريب والاختبار إلى تنبؤات دقيقة لدعم تغيير الأعمال. والشكل الموالي يوضح تشكيل الذكاء الاصطناعي:


■ خوارزميات التعلم العميق :

تم تخصيص هذا القسم لوصف المبدأ الأساسي لأربعة نماذج غير خطية للتعلم الآلي أو نماذج التعلم العميق التي سيتم استخدامها لاحقاً للتنبؤ باستخدام السلاسل الزمنية لأسعار العملات المشفرة وخاصة الشبكات العصبية المتكررة (RNN) و نموذج الذاكرة الطويلة المدى (LSTM) :⁴

1.1- الشبكات العصبية المتكررة (Recurrent Neural Networks) :

تختلف الشبكات العصبية المتكررة (RNNs) عن الشبكة العصبية التقليدية لأنها تقدم وزناً انتقاليًا لإرسال المعلومات بمرور الوقت. يعني هذا الوزن الانتقالي أن الحالة التالية تعتمد على الحالة السابقة. هذا يعني أن النموذج يحتوي الآن على ذاكر في RNNs، تعمل الطبقات المخفية كمخزن داخلي للمعلومات التي تم التقاطها في المراحل السابقة. مصطلح "متكرر" مشتق من حقيقة أن النموذج يؤدي نفس المهمة لكل عنصر من عناصر التسلسل باستخدام المعلومات التي تم الحصول عليها مسبقاً للتنبؤ بالقيم المستقبلية. يتم تمثيل RNN في الشكل 2 :

الشكل 2: الشبكة العصبية المتكررة مع خطوات الوقت p



هناك نوعان من نماذج RNN القوية التي تعتمد على الوقت في بيانات السلاسل الزمنية وهما LSTM و GRU أظهرت نماذج التعلم العميق هذه نجاحاً كبيراً في النمذجة والتنبؤ مقارنة بنماذج السلاسل الزمنية الكلاسيكية وأظهرت الشبكات التقليدية أنها يمكن أن تصل إلى نتائج جيدة في العديد من مجالات التطبيق باستخدام السلاسل الزمنية.

⁴. للتفصيل أكثر انظر :

- ميلاد وزان ، علاء طعيمة ، التعلم العميق بلغة بايثون ، العراق ، 2022 ، ص 141-150

- Nikhil Ketkar ,Jojo Moolayildeep (2021) , learning with python: Learn Best Practices of Deep Learning Models with PyTorch, Bangalore, Karnataka, India .

2.1- نموذج الذاكرة الطويلة المدى (Long Short Term Memory) :

يتكون نموذج LSTM من ثلاثة بوابات : بوابة النسيان (f) وبوابة الإدخال (i) وبوابة الإخراج (o) .
 أ- بوابة النسيان (Forget Gate) : تقرر هذه البوابة ما إذا كنا نريد مسح خلية الحالة أو لا. يعتمد قرار البوابة المنسية على المخرجات السابقة h_{t-1} والمدخلات الحالية x_t . تستخدم sigmoid لتوليد إخراج بين صفر (0) وواحد (1) لكل عنصر في خلية الحالة. يتم تنفيذ الضرب بين مخرج بوابة النسيان وخلية الحالة. تعني قيمة واحد في مخرج بوابة النسيان أن معلومات العنصر مخزنة بالكامل في خلية الحالة. في المقابل ، الصفر (0) يعني النسيان الكامل للمعلومات في عنصر خلية الحالة.
 هذا يعني أن LSTM يمكنها إزالة المعلومات غير ذات الصلة من متجه خلية الحالة الخاص بها. معادلة بوابة النسيان كالتالي:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t]) + U_f x_t + b_t$$

ب- بوابة الإدخال (Input Gate) : تقرر هذه البوابة إضافة معلومات جديدة إلى خلية الذاكرة. يتم ذلك في جزأين هما : تحديد القيم المراد تحديثها ثم إنشاء القيم المراد تحديثها. يتم استخدام المتجه i_t أولاً لتحديد قيم المرشحين الجدد المحتملين لتضمينها في خلية الحالة. يحتوي متجه المرشح a_t أيضاً على مصفوفة وزن خاصة به ويستخدم الحالة والمدخلات المخفية السابقة لتشكيل متجه بأبعاد مماثلة لخلية الحالة. لإنشاء هذا المتجه المرشح، يتم استخدام دالة $\tanh$ كدالة غير خطية. تظهر هذه العملية في المعادلات التالية:

$$i_t = \sigma(W_i \cdot h_{t-1} + U_i x_t + b_i)$$

$$a_t = \tanh(W_c \cdot h_{t-1} + U_c x_t + b_f)$$

تحدد بوابة النسيان كيفية تحديث خلية الحالة في كل خطوة زمنية يتم تحديث خلية الحالة في خطوة زمنية عبر المعادلة التالية:

$$c_t = f_t * c_{t-1} + i_t * a_t$$


ج- بوابة الإخراج (Output Gate) : تقرر ما هو الإخراج . الناتج النهائي لخلية LSTM هو الحالة المخفية h_t . بوابة الإخراج تأخذ h_{t-1} و x_t كمدخل . كمرحلة أولى يتم استخدام sigmoid لحساب المتجه بقيم بين صفر وواحد لتحديد قيم خلية الحالة في الخطوة الزمنية. ثم قمنا بتعيين قيمة خلية الحالة إلى طبقة $\tanh$ لمضاعفة قيمتها أخيراً بمخرجات الطبقة السابقة sigmoid ، بحيث تتم مشاركة الأجزاء المرغوبة في الإخراج. يعني الإخراج 0 أن كتلة الخلية لا تنتج أي معلومات، بينما يعني الإخراج 1 أن الذاكرة الكاملة لكتلة الخلية يتم نقلها إلى إخراج الخلية. تظهر المعادلات التالية هذا الاتجاه :

$$o_t = \sigma(W_o \cdot h_{t-1} + U_o x_t + b_o)$$

$$h_t = o_t * \tanh.(c_t)$$

الآن كيف تحمينا LSTM من تلاشي التدرج؟ لاحظ أنه إذا كانت بوابة النسيان 1 وكانت بوابة الإدخال 0، فسيتم نسخ حالة الخلية بالضبط خطوة بخطوة. فقط بوابة النسيان يمكنها محو ذاكرة الخلية تماماً. نتيجة لذلك، يمكن أن تظل الذاكرة دون تغيير لفترة طويلة. والشكل رقم 3 يوضح كيفية فتح LSTM بمرور الوقت في الشكل أدناه :

الشكل 3: تشكيل خوارزمية الذاكرة الطويلة المدى (LSTM)



في البداية ، يتم إعطاء قيمة 4.2 للشبكة كمدخلات، تم ضبط بوابة الإدخال على 1، لذلك يتم حفظ القيمة الكاملة. ثم بالنسبة للخطوتين التاليتين، يتم ضبط بوابة النسيان على 1. لذلك يتم تخزين جميع المعلومات أثناء هذه الخطوات ولا تتم إضافة أي معلومات جديدة، لأن البوابات مضبوطة على 0. أخيراً، يتم ضبط بوابة الإخراج على 1 ويتم إنشاء 4.2 وتبقى دون تغيير.

المحور الثاني : نماذج المالية السلوكية

اعتمدت نظرية المالية السلوكية في بناء فرضياتها على نموذج ماركويتز المستخدم على نطاق واسع اتخاذ القرارات الاستثمارية، حيث يعد ماركويتز (Markowitz) الحائز على جائزة نوبل سنة 1990 م، أول من أشار إلى مفهوم العائد والمخاطرة في الاستثمار ،بالإضافة إلى تطرقه لأهميته التنوع (Diversification) تدنية المخاطرة ، حيث قام بصياغة كل هذا في نظرية المحفظة المثلى التي تتضمن ضرورة الاختيار الدقيق للاستثمارات المكونة للمحفظة وذلك بمراعاة درجة الارتباط بين عائد تلك الإستثمارات⁵. فكلما كانت هذه العلاقة عكسية أو مستقلة أي ليس هناك علاقة، فإن المخاطر التي تتعرض لها عائد المحفظة تكون أقل مما لو كانت هناك علاقة طردية بين عائد تلك الإستثمارات. يضاف إلى ذلك أن هذا الأسلوب في التنوع قد ينجح، ليس فقط في التخلص من المخاطر غير النظامية (الخاصة) ، بل والتخلص من جزء من المخاطر العامة (النظامية). إذ يعتبر أفضل استثمار مقترح هو ذلك الإستثمار الذي يكون معامل الارتباط بين العائد المتوقع من ورائه وبين معدل المتوقع من الإستثمارات القائمة بالفعل ارتباطاً سالباً. وترتكز دراستنا على هذا النموذج في شكله الساكن (Static Model) و الديناميكي (Dynamics Model) المعمول به حديثاً في اتخاذ القرارات الاستثمارية في الأسواق المالية العالمية لكن بإحداث تغيير على قيود النموذج حسب متطلبات الدراسة ،وهو الشيء الذي سوف نتطرق له بشكل مفصل في الجانب التطبيقي من البحث .⁶

⁵ H. Markowitz, « Portfolio Selection », Journal of Finance, Volume 7, March-1952 ;P :77-97.

⁶ برارمة ريمة ، أثر المالية السلوكية على تقلبات عوائد المحافظ الاستثمارية : حالة بورصة باريس ولندن، دكتوراه جامعة سطيف ،الجزائر، 2019.

أولاً- نموذج ماركوفيتز :

1.1.3.2.4- فرضيات النموذج :

قام هاري ماركوفيتز بتقديم إضافة جديدة في مجال اتخاذ القرارات الاستثمارية من خلال استخدام نموذج البرمجة التربيعية في اختيار المحفظة الاستثمارية عام 1952م ، الذي يعد من بين التقنيات الكمية الحديثة في مجال الرياضيات المالية المعمول بها في مجال اتخاذ القرارات الاستثمارية، ويستند هذا النموذج على عدة افتراضات نذكر منها :⁷

- ✓ المنافسة التامة وعدم وجود مصاريف عمولة .
- ✓ لا يوجد بيع على المكشوف.
- ✓ يوجد عدد كافي من الأصول المالية من ناحية الكم والنوع، ولا توجد أي قيود على بيع أو شراء الأصول المالية.
- ✓ نفس التوقعات العقلانية لدى الأفراد اتجاه العوائد .

يضع كل مستثمر في عين الاعتبار عاملين عند اختيار أصول المحفظة الاستثمارية هما، العائد والمخاطرة، لذلك يكون الهدف الرئيسي من نموذج المحفظة الاستثمارية إما تدنية مخاطرة المحفظة مع تحقيق مستوى مقبول من العائد أو تعظيم العائد عند مستوى معين من المخاطرة. وفي نموذج ماركوفيتز يظهر عنصر المخاطرة من خلال إيجاد تباين المحفظة الاستثمارية. ولتضمين المخاطرة (النظامية وغير النظامية) التي تأتي من الارتباط بين عوائد الأسهم يستخدم التباين المشترك (Covariance) لمعرفة درجة الارتباط، حيث أن بعض عوائد الأسهم قد تتحرك سوية باتجاه نحو الأعلى أو الأسفل (علاقة طردية أو عكسية) خلال الزمن، وعادة يحاول المستثمرون التقليل من هذه المخاطرة من خلال التنوع، أي يقوم المستثمر بتوزيع أمواله بين كم ونوع من الأصول المالية.⁸

ثانياً- الصيغة الرياضية للنموذج الساكن (Static Model) :

كما قام ماركوفيتز بالصياغة الشعاعية لدالة الهدف في نموذج تدنية المخاطرة لمحفظة استثمارية مكونة من مجموعة أسهم كما يلي :⁹

$$\begin{aligned} \text{Max} : w' \bar{R}; & \quad \text{Min} : [w' V w] \quad \text{صيغة تعظيم} \\ s/c : \begin{cases} w' V w = k \\ w' e = 1 \end{cases} & \quad \dots (2.1) \dots \quad s/c : \begin{cases} w' \bar{R} = E[R_P] \\ w' e = 1 \end{cases} \end{aligned}$$

حيث يمثل .

$$w = (w_1, \dots, w_n)$$

شعاع الأوزان النسبية لمكونات المحفظة :

$$R = (R_1, \dots, R_n)$$

شعاع عوائد الأصول :

$$\bar{R} = (\bar{R}_1, \dots, \bar{R}_n)$$

شعاع العوائد المتوقعة للأصول

$$e = (1, \dots, 1)$$

شعاع إحداثياته تساوي 1 :

$$V = [\sigma_{ij}]_{1 \leq i, j \leq n}$$

مصفوفة تباين- تباين مشترك للعوائد:

كما يحسب العائد المتوقع $E[R_P]$ وفق العلاقة التالية :

$$E[R_P] = \sum_{i=1}^n w_i E[R_i] = w \cdot \bar{R} \quad (2.2)$$

⁷ محمد عبد محمد مصطفى، تقييم شركات المالية لأغراض التعامل في البورصة، دار الجامعة للنشر، 1998، ص 30.
⁸ عدنان عبد الفتاح صوفي، غازي عبيد مدني و ياسين عبد الرحمن جفري، « إمكانية الاستفادة من التنويع الاستثماري في سوق الأسهم في المملكة العربية السعودية »، مجلة الاقتصاد والادارة، المجلد 2، جامعة الملك عبد العزيز، 1989م، ص 109-134.

⁹ Jean-Luc Prigent, « Portfolio Optimization and Performance Analysis », Financial Mathematics Series, Chapman & Hall/CRC is an imprint of Taylor & Francis Group, 2007, U.S, P : 70-78.

ويحسب عنصر المخاطرة (النظامية وغير النظامية) الذي يعبر عن تشتت العائد للمحفظة وفق العلاقة التالية :

$$\sigma^2(R_P) = \mathbf{w}'\mathbf{V}\mathbf{w} = \sum_{i=1}^n \sum_{j=1}^n w_i w_j \sigma_{ij} = 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i w_j \sigma_{ij} + \sum_{i=1}^n w_i^2 \sigma_i^2. \quad (2.3)$$

حيث تنقسم العلاقة السابقة إلى جزئين :

$$\text{حيث يمثل عنصر المخاطر النظامية للمحفظة :} \quad 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i w_j \sigma_{ij}$$

$$\text{حيث يمثل عنصر المخاطر غير النظامية بين أصول المحفظة :} \quad \sum_{i=1}^n w_i^2 \sigma_i^2$$

يتضمن نموذج المحفظة المثلى ثلاث قيود هي:

الأول : الحد الأدنى من العائد المتوقع من المحفظة الذي يرغب المستثمر بتحقيقه ويأخذ الصيغة الآتية:

$$w_1 R_1 + w_2 R_2 + \dots + w_n R_n \geq R_m \quad \text{حيث أن :}$$

R_i : العائد المتوقع السنوي من السهم i .

w_i : نسبة النقود المستثمرة في السهم i .

R_m : الحد الأدنى من العائد السنوي المرغوب على المحفظة .

الثاني : يحدد شرط استثمار المبلغ بأكمله، ويكون وفق الصيغة الآتية:

$$w_1 + w_2 + \dots + w_n = 1.0$$

$$R_i \geq 0 \quad \text{الثالث : شرط عدم السلبية}$$

■ المحور الثالث : تقييم أداء محفظة العملات المشفرة (2020-2022م)

سوف نقوم ببناء محفظة استثمارية مثلى على مستوى بورصات العملات المشفرة ذات التردد العالي والمخاطر المرتفعة وذلك بعمل دراسة مقارنة بين نموذج ماركويتز (العائد-المخاطرة) ، ونماذج التعلم العميق المبني على خوارزميات التعلم الآلي .


■ معطيات الدراسة : تم تطبيق الدراسة على معطيات حقيقية لسلاسل زمنية لأسعار يومية لعشرة (10) عملات مشفرة

خلال الفترة ما بين (2020-2022م) بمعدل 6871 ملاحظة وذلك بالاعتماد على قاعدة بيانات موقع :

<https://finance.yahoo.com/crypto> وبرمجة لغة البايثون (Python) .

حيث تم تشكيل محفظة عملات مشفرة مكونة من :

"ADA-USD", "BNB-USD", "BTC-USD", "DAI-USD", "DOGE-USD", "ETH-USD", "LINK-USD", "LTC-USD", "USDT-USD", "XRP-USD".



المصدر : قاعدة yahoo.finance لتداول العملات المشفرة

عرف سوق العملات المشفرة خلال فترة الدراسة تقلبات عديدة خاصة مع بداية أزمة كوفيد-19 الذي كان عاماً صعباً وقاسياً ، وصولاً إلى عام 2022م إذ واجهت العملات الرقمية المشفرة أكثر من مأزق تسببت في أن تواجه أكبر موجة خسائر منذ أزمة كورونا. والخسائر لا ترجع فقط إلى عودة البنوك المركزية على مستوى العالم للتحذير من هذه السوق التي لا توجد لها أية ضوابط حتى الآن.

لكن مع اتجاه البنوك المركزية إلى تشديد السياسة النقدية ورفع الفائدة الأميركية إلى مستويات كبيرة، شهد عام 2022 موجة هرب جماعية للمستثمرين من أسواق الأصول الخطرة، ومن بينها "الكريبتو" والأسهم إلى الاحتفاظ بالدولار الأمريكي. وبسبب موجات النزوح الجماعي للمستثمرين فقد فشلت بعض المنصات في رد مستحقات العملاء، وهو ما حدث مع منصة "إف تس إكس" التي أعلنت إفلاسها وتجرى تحقيقات في شأنها حتى الآن، ومن المقرر أن يمثل رئيسها التنفيذي أمام لجنة تحقيق بالكونغرس الأمريكي.

وعلى صعيد التداولات خلال عام 2022 نزلت القيمة السوقية المجمعة للعملات الرقمية المشفرة بنسبة 614 في المئة، خسارة نحو 1340 مليار دولار بعد أن انخفضت قيمتها الإجمالية من مستوى 2182.5 مليار دولار في بداية تعاملات العام إلى نحو 842.5 مليار دولار بنهايته.

■ تطبيق نموذج المحفظة المثلى :

قبل تطبيق نموذج العائد-المخاطرة وإيجاد الأوزان المثلى للمحفظة بالإضافة إلى عائد ومخاطرة المحفظة الاستثمارية، قمنا بحساب مدخلات النموذج لأسعار العملات المشفرة المراد الاستثمار بها فيها حساب العوائد والانحراف المعياري واستخراج مصفوفة التباين - التباين المشترك التي تعطينا فكرة عن فعالية التنوع في تعظيم دالة الهدف كما هي موضحة في الجداول أدناه :

■ تنزيل معطيات الدراسة باستخدام شاشة *Jupyter* في لغة *Python* :

```

Entrée [1]: import numpy as np
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import yfinance as yf

Entrée [2]: from pyfport.efficient_frontier import EfficientFrontier
from pyfport import risk_models
from pyfport import expected_returns
from pyfport import objective_functions #para la regularización L2
from pyfport import plotting
from pyfport import HRPopt

Entrée [5]: symbol = ["ADA-USD", "BNB-USD", "BTC-USD", "DAI-USD", "DOGE-USD", "ETH-USD", "LINK-USD", "LTC-USD", "USDT-USD", "XRP-USD"]

Entrée [6]: df = yf.download(symbol, start='2020-01-01', rounding=True)
[*****100%*****] 10 of 10 completed

Entrée [7]: df.dropna(inplace=True)

Entrée [8]: cl = df.Close.astype('float32')

```

■ عوائد العملات المشفرة باستخدام شاشة *Jupyter* في لغة *Python* :

```

Entrée [19]: df['Close']
df = df['Close']
returns = df.pct_change()
returns

```

	ADA-USD	BNB-USD	BTC-USD	DAI-USD	DOGE-USD	ETH-USD	LINK-USD	LTC-USD	USDT-USD	XRP-USD
Date										
2019-12-31	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
2020-01-01	0.018663	-0.002913	0.000913	0.002202	0.002465	0.009181	0.022599	0.016449	0.000157	-0.001177
2020-01-02	-0.021131	-0.048210	-0.029819	-0.002419	-0.011805	-0.025917	-0.038674	-0.052356	0.001729	-0.024000
2020-01-03	0.043632	0.048350	0.051451	0.004372	0.067695	0.053057	0.040230	0.065294	0.002623	0.029132
2020-01-04	0.012142	0.016837	0.008956	0.005598	0.044755	0.006708	0.016575	0.021452	0.003266	0.004310
...	...	...	...	...	...	...	...	...	...	...
2022-05-04	0.163130	0.049598	0.051600	0.000244	0.048556	0.056462	0.092626	0.069760	-0.000007	0.068819
2022-05-05	-0.117945	-0.058957	-0.078674	-0.000455	-0.054334	-0.065098	-0.101235	-0.087983	-0.000050	-0.073612
2022-05-06	-0.009850	0.001399	-0.014606	0.000310	-0.004119	-0.019726	-0.010989	-0.001341	-0.000006	0.006151
2022-05-07	-0.027417	-0.035908	-0.014954	-0.000531	-0.002885	-0.021852	-0.051852	-0.022936	-0.000061	-0.033561
2022-05-08	-0.027637	-0.018705	-0.026878	0.000035	-0.020795	-0.029760	-0.023438	-0.024109	-0.000083	-0.014606

860 rows x 10 columns

■ مصفوفة التباين- التباين المشترك لعوائد العملات المشفرة باستخدام شاشة *Jupyter* في لغة *Python* :

```

Entrée [20]: cov_matrix_annual = returns.cov()*252
cov_matrix_annual

```


	ADA-USD	BNB-USD	BTC-USD	DAI-USD	DOGE-USD	ETH-USD	LINK-USD	LTC-USD	USDT-USD	XRP-USD
ADA-USD	0.953310	0.551370	0.391027	0.020663	0.603824	0.558411	0.684612	0.578109	-0.008560	0.571117
BNB-USD	0.551370	0.936280	0.392793	0.015456	0.408816	0.528195	0.624737	0.540271	-0.008385	0.532855
BTC-USD	0.391027	0.392793	0.384573	0.015586	0.445721	0.404421	0.434517	0.429513	-0.006961	0.370989
DAI-USD	0.020663	0.015456	0.015586	0.017111	0.012445	0.022299	0.019299	0.019706	0.000342	0.015167
DOGE-USD	0.603824	0.408816	0.445721	0.012445	5.609378	0.505951	0.662325	0.609195	-0.007114	0.518319
ETH-USD	0.558411	0.528195	0.404421	0.022299	0.505951	0.654596	0.655276	0.572227	-0.009449	0.515835
LINK-USD	0.684612	0.624737	0.434517	0.019299	0.662325	0.655276	1.136104	0.656476	-0.007918	0.633438
LTC-USD	0.578109	0.540271	0.429513	0.019706	0.609195	0.572227	0.656476	0.739038	-0.008551	0.591147
USDT-USD	-0.008560	-0.008385	-0.006961	0.000342	-0.007114	-0.009449	-0.007918	-0.008551	0.003444	-0.007464
XRP-USD	0.571117	0.532855	0.370989	0.015167	0.518319	0.515835	0.633438	0.591147	-0.007464	1.150935

■ الأوزان المثلى لمحفظه العملات المشفرة المختارة :



المصدر : مخرجات محاكاة برنامج : <https://www.portfoliovisualizer.com/optimize-portfolio>

■ منحى الكفاءة الحدودي لمحفظه العملات المشفرة المختارة :




المصدر : مخرجات محاكاة برنامج : <https://www.portfoliovisualizer.com/optimize-portfolio>

■ تطبيق نموذج التعلم العميق :

لإنشاء هذا النوع من المحافظ ، والذي يتكون من أصول بمستويات مخاطر مختلفة ، تم إجراء تحليل شامل .على عكس المحافظ السابقة التي تم إنشاؤها بناءً على البيانات التاريخية فقط ، ستستفيد هذه المحفظة من تنبؤات نموذج LSTM لتوقع التركيبة المثلى للأصول التي ستحقق أعلى العوائد .تتضمن العملية المتبعة لبناء هذه المحفظة المتنوعة مجموعة من الخطوات المتسلسلة .يوضح الشكل أدناه ويلخص النهج العام المعتمد لإنشاء النموذج.

الشكل : الخطوات المتبعة لبناء المحفظة المتنوعة باستخدام التعلم العميق



بعد ذلك ، تم تعريف العمود الذي يحتوي على أسعار الإغلاق للعمليات المشفرة على أنه مجموعة التدريب وتم تعيينه إلى DataFrame. في الخطوة التالية ، سنعمل على تطبيع البيانات التي نعمل معها .عادةً ما تتضمن المعالجة المسبقة للبيانات أربع مراحل رئيسية: تحديد البيانات ▪ تحويل البيانات ▪ تنظيف البيانات ▪ تكامل البيانات للحصول على الأداء الأمثل ، تم قياس ميزات البيانات وتعيينها لتقع بين 0 و 1 كحد أدنى وأقصى للقيم على التوالي .باستخدام MinMaxScaler ، تم تغيير حجم الميزات إلى النطاق المحدد.

```
# Feature Scaling
from sklearn.preprocessing import MinMaxScaler
scale = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = scale.fit_transform(training_set)
```

من المتوقع أن تأخذ البيانات الموجودة في نموذج LSTM تنسيقاً معيناً .يتم تحويل بنية البيانات التي تحتوي على 60 خطوة زمنية إلى مصفوفة ثلاثية الأبعاد باستخدام NumPy بشكل أساسي.

```
# Creating a data structure consisting of 60 timesteps and one output
X_train = []
y_train = []
for i in range(60, 1469):
    X_train.append(training_set_scaled[i-60:i, 0])
    y_train.append(training_set_scaled[i,0])
X_train, y_train = np.array(X_train), np.array(y_train)

# Reshaping the X_train
X_train = np.reshape(X_train, (X_train.shape[0],X_train.shape[1],1))
```

في الخطوة التالية ، شرعنا في بناء نموذج LSTM. من أجل بناء ال RNN ، كان لابد من استيراد بعض الوحدات من Keras. بعد ذلك ، تمت إضافة طبقة LSTM وطبقات متسربة أخرى .فيما يتعلق بطبقة LSTM ، تم تخصيص أبعاد مساحة الإخراج بقيمة 50 وحدة .تم تحديد 20٪ من الطبقة ليتم إسقاطها وإضافة طبقة كثيفة بإخراج وحدة واحدة .تم اختيار Adam كمحسّن لتجميع النموذج وتم تعيين الخسارة على أنها متوسط الخطأ التربيعي (MSE) .بعد ذلك ، كان النموذج مناسباً لـ 100 عصر وحجم دفعة يساوي 32.

```
Entrée [11]: from keras.layers.core import Dense, Activation, Dropout
from keras.layers.recurrent import LSTM
from keras.models import Sequential
model = Sequential()
model.add(LSTM(units=50,input_shape=(1b,1)))
model.add(Dense(1))
model.compile(optimizer='adam',loss='mse')
X_train=X_train.reshape((X_train.shape[0],X_train.shape[1],1))
X_test=X_test.reshape((X_test.shape[0],X_test.shape[1],1))
history = model.fit(X_train,Y_train,epochs=50,validation_data=(X_test,Y_test),shuffle=False)
model.summary()
```

```
Epoch 48/50
215/215 [=====] - 2s 8ms/step - loss: 0.0224 - val_loss: 0.0226
Epoch 49/50
215/215 [=====] - 2s 8ms/step - loss: 0.0224 - val_loss: 0.0225
Epoch 50/50
215/215 [=====] - 2s 8ms/step - loss: 0.0224 - val_loss: 0.0225
Model: "sequential"
```

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 50)	10400
dense (Dense)	(None, 1)	51

```
====
Total params: 10,451
Trainable params: 10,451
Non-trainable params: 0
```

■ العائد المتوقع والمخاطرة للمحفظة المثلى :


```

Entrée [24]: percent_var = str(round(port_variance,2)*100)+'%'
percent_vola = str(round(port_volatility,2)*100)+'%'
percent_ret = str(round(portfolio_simple_annual_return,2)*100)+'%'
print('Expected annual return: '+percent_ret)
print('Annual volatility/ risk: '+percent_vola)
print('Annual variance: '+percent_var)

Expected annual return: 99.0%
Annual volatility/ risk: 65.0%
Annual variance: 42.0%

```

■ الأوزان المثلى لمحفظة العملات المشفرة المختارة :



■ نتائج و خلاصة البحث :

من خلال المحاكاة السابقة للسلاسل الزمنية لعوائد العملات المشفرة باستخدام أحد نماذج المالية السلوكية التقليدية (نموذج ماركوفيتز) ونماذج التعلم العميق ، وتم تلخيص مخرجات الدراسة المقارنة في الجدول التالي :

أصول المحفظة	الأوزان المثلى لماركوفيتز (%)	الأوزان المثلى للتعلم العميق (%)
ADA-USD	0.2100	0.2939
BNB-USD	0.0000	0.3392
BTC-USD	0.0000	-0.1391
DAI-USD	0.0000	-0.3798
DOGE-USD	0.0598	0.0761
ETH-USD	0.7302	1.0000
LINK-USD	0.0000	-0.2849
LTC-USD	0.0000	-0.8167
USDT-USD	0.0000	1.0000
XRP-USD	0.0000	-0.0886
مخاطرة المحفظة المثلى (%)	0.1223	0.65
عائد المحفظة المثلى (%)	0.1649	0.99
مؤشر Sharpe (%)	0.3323	1.90

من خلال النتائج الموضحة أعلاه و وفقا لتوزيع الأوزان المثلى لتوظيفات المستثمر المتوقعة ، نلاحظ فعالية نموذج التعلم العميق بمعدل عائد متوقع للمحفظة المثلى قدر بـ : 99% أعلى وأدنى درجة مخاطرة قدرت بـ 65% بالمقارنة مع مخرجات نموذج ماركوفيتز الذي قدر معدل العائد للمحفظة المثلى بـ 16.49% ، ومعدل مخاطرة أعلى نسبيا قدر بـ 12.23% . والنتائج تؤكد صحة الفرضية الثانية التي نصت على إمكانية استفادة خوارزميات التعلم العميق بشكل أفضل من أسلوب التنويع الاستثماري.

أما بالنسبة لأوزان محفظة ماركويتز لم يتم توزيع الاستثمار في معظم العملات المشفرة والاكتفاء بثلاثة فقط نظرا لمحدودية تشغيل النموذج المبني على أساس معامل الارتباط وتوليد عدد محدود من المحافظ الممكنة والذي حقق مؤشر شارب متوسط غير محفز للاستثمار وفق المحفظة المختارة قدر بـ 0.33% . على عكس نموذج التعلم العميق الذي يقوم بتدريب عدد كبير من المحافظ المتنبؤ بها والذي أعطى مؤشر شارب ممتاز (1.9%) لأداء المحفظة المثلى المختارة . فهذا يعني أن هذا قد يكون قرارًا استثماريًا مثاليًا. بينما تؤدي إضافة فئة أصول جديدة إلى المحفظة إلى زيادة المخاطر، فإن النسبة الأعلى الحادة تشير إلى أنها مخاطرة تستحق المخاطرة.

كما يمكن تفسير المخاطرة العالية لتقلبات أسعار العملات المشفرة بالظروف العالمية التي مر بها العالم خاصة أن فترة الدراسة تصادفت مع جائحة كورونا (كوفيد-19) وحرب أوكرانيا أين عرفت منصات تداول العملات المشفرة عدة انهيارات بسبب مخاوف المستثمرين على أصولهم. إلى أن نتائج الدراسة تبقى نسبية خاصة في مجال التعلم العميق الذي يطرح إشكالية شفافية البيانات الضخمة التي يعتمد على تدريبها في مجال اتخاذ القرارات الاستثمارية في الأسواق المالية.

■ الاستنتاجات والتوصيات :

أولا - الاستنتاجات :

بعد استعراض الجانب النظري والتطبيقي للبحث تم استخلاص ما يلي :

- استخدام خوارزميات الذكاء الاصطناعي وخاصة التعلم العميق ضرورة حتمية في مجال اتخاذ القرارات الاستثمارية وتحليل البيانات الضخمة على مستوى بورصة العملات المشفرة العالية المخاطر.
- بناء المحافظ المثلى ذات المخاطر المحدودة والعوائد المرتفعة في بورصة العملات المشفرة تعتمد السرعة في اتخاذ القرار وهو ما يقودنا إلى استخدام تقنية التعلم العميق وفقا لمتطلبات نموذج العائد - المخاطر لماركويتز وهو الأمر الذي تؤكد الفرضية الثانية للبحث.
- تساعد تقنيات التعلم العميق على تدريب (training) نموذج العائد - المخاطرة وتجريبه (test) على عينة كبيرة من الأصول بهدف إدارة محافظ استثمارية مثلى .
- استخدام نماذج التعلم العميق في مجال الأسواق المالية كدعامة لتوجهات أصحاب الفكر الكمي للمالية على حساب المنطق السلوكي.

ثانيا - التوصيات :

- بناء على الاستنتاجات السابقة التي تم التوصل إليها يمكن تقديم مجموعة من التوصيات للعمل بها مستقبلا نذكر منها :
- سرعة البورصات العربية في التوجه نحو أتممة عمليات الاستثمار في الأسواق المالية بصفة عامة وبورصة العملات المشفرة والرقمية بصفة خاصة .
- تشجيع البحوث الأكاديمية والتطبيقية في مجال الذكاء الاصطناعي (AI) وعلم المالية على مستوى مراكز البحث والجامعات.
- محاولة تغيير في معلمات نموذج التعلم العميق للرفع من دقة النتائج المتوصل إليها في البحث.

■ المصادر باللغة العربية:

1. ميلاد وزان ، علاء طعيمة ، التعلم العميق بلغة بايثون ، العراق ، 2022 ، ص 141-150
2. ريم سليمان الخش ، "الحركة البروانية و الحسابات العشوائية"، منشورات جامعة دمشق ، كلية العلوم ، 2010-2011، ص: 108-120.
3. برارمة ريمة ، أثر المالية السلوكية على تقلبات عوائد المحافظ الاستثمارية : حالة بورصة باريس ولندن، دكتوراه جامعة سطيف ،الجزائر، 2019.
4. محمد عبد محمد مصطفى، تقييم شركات المالية لأغراض التعامل في البورصة، دار الجامعة للنشر، 1998، ص 30.
5. عدنان عبد الفتاح صوفي، غازي عبيد مدني و ياسين عبد الرحمن جفري، «إمكانية الاستفادة من التنويع الاستثماري في سوق الأسهم في المملكة العربية السعودية» ،مجلة الاقتصاد والادارة ، المجلد 2 ، جامعة الملك عبد العزيز ، 1989م، ص109-134 .

■ المصادر باللغة الأجنبية :

1. Jean-Luc Prigent, « Portfolio Optimization and Performance Analysis », Financial Mathematics Series, Chapman & Hall/CRC is an imprint of Taylor & Francis Group, 2007, U.S, P : 70-78.
2. Nikhil Ketkar ,Jojo Moolayildeep (2021) , learning with python: Learn Best Practices of Deep Learning Models with PyTorch, Bangalore, Karnataka, India .
3. Sarah Ibri, Mohamed Slimane (2022) , Probability Stochastic Processes and Simulation In Python, Algeria. <https://www.researchgate.net/publication/360767027> .
4. Safaa Zaki (2021), A Deep Learning Portfolio Optimization Framework Using Cryptocurrencies, school of science & engineering – al akhawayn university , Morocco.

■ المواقع الالكترونية :

1. <https://www.ibm.com/sa-ar/cloud/deep-learning>
2. <https://finance.yahoo.com/crypto/>
3. <https://pypi.org/>