

الجمهورية العربية السورية
المعهد العالي للعلوم التطبيقية والتكنولوجيا
قسم المعلوماتية-ماجستير المعطيات الكبيرة

رسالة أُعدت لنيل درجة الماجستير

تحسين طرائق توقع أسعار الأسهم المالية
باستخدام تقنيات التعلم العميق والسلاسل الزمنية

إعداد:

م. ماريو ناصر طحوي

بإشراف

د. توفيق حماده

د. مصطفى دقاق

المعهد العالي للعلوم التطبيقية والتكنولوجيا Higher Institute for Applied Sciences and Technology

مؤسسة سورية حكومية للتعليم العالي أُحدثت في عام 1983 بموجب مرسوم تشريعي، بهدف إعداد أطر متميزة مؤهلة للبحث العلمي والتطوير في مجال العلوم التطبيقية والتقانة، لتساهم بفاعلية في التنمية العلمية والصناعية والاقتصادية في القطر.

يشمل التأهيل الهندسي والدراسات العليا في المعهد العالي محاور عملية إعداد الأطر المتخصصة، يفتح المعهد العالي مهندسين متخرجين بعد دراسة لمدة خمس سنوات، في اختصاصات الاتصالات والمعلوماتية والنظم الإلكترونية والميكاترونيكس، وهندسة المواد، وهندسة الميكانيك. يدرس الطالب في السنتين الأولى والثانية منهاجاً واحداً يشمل مواد اختصاص، ثم يبدأ التدرج على السنتين الأولى والثانية، وذلك على نمط السنة الثالثة، ثم السنة الرابعة، فالسنة الخامسة حيث تُبنى المواد والمهارات وتزداد المهارات الأكاديمية. يتم قبول الطلاب على أساس الشهادة الثانوية في نظام المفاضلة العامة، حيث تبدأ الرائدة في إعداد طلابهم كطلاب أطر عليا، وصولاً إلى سنة التخرج.

كما يمنح المعهد العالي درجة الماجستير الأكاديمي أو ماجستير بعدد عام سنتين، عبر كامل مجموعة من برامج الماجستير في نظم الاتصالات، نظم التحكم والروبوتيك، علوم المواد، الميكاترونيكس، اتصالات الفضاء، تقانة الليزر، معالجة المعطيات الكبيرة. يحصل الطالب في السنة الأولى أو في السنة الثانية على مواد أكاديمية متقدمة ومشاريع بحثية، ويتوج عمله بمشروع بحث تخرجي، يتضمن أبحاثاً علمية وتطبيقية، وأحياناً مشاريع مشتركة مع جهات بحثية وصناعية، ليكون على أهبة لدخول سوق العمل أو المتابعة في الدراسات العليا، ويُمنح عند نجاحه شهادة الماجستير.

المعهد العالي للعلوم التطبيقية والتكنولوجيا، الجمهورية العربية السورية، دمشق، ص.ب. 31983

هاتف: +963-(0)11-5123819

فاكس: +963-(0)11-5140761

البريد الإلكتروني: contact@hiast.edu.sy

الموقع الإلكتروني: www.hiast.edu.sy

تصريح

أنا الموقع أدناه ماريو ناصر طحومي معد أطروحة الماجستير، التي تحمل عنوان تحسين طرائق توقع أسعار الأسهم المالية باستخدام تقنيات التعلم العميق والسلاسل الزمنية

أصّرح بأن:

- الأعمال والنتائج المعروضة في هذه الأطروحة هي نتيجة جهدي الشخصي وتوجيهي من المشرف، وما عدا ذلك من معلومات ونتائج قد نُسبت إلى مصادرها ومؤلفيها، وأُشيرت إلى ذلك في متن النص وفي قائمة المراجع.
- المعطيات والمعلومات المستخدمة في هذه الأطروحة جرى تحصيلها بطرائق سليمة ومشروعة ونُسبت إلى مصادرها في المواضيع اللازمة.
- كل مكون من مكونات هذه الأطروحة (مقطع، نص، صورة، مخطط...) مقتبس من عمل آخر جرى تبينه بوضوح ونُسب إلى مصدره.
- الأعمال والنتائج المعروضة في هذه الأطروحة لم تُستخدم سابقاً وليست قيد الاستخدام للحصول على أي شهادة أكاديمية أخرى.

التوقيع

التاريخ

الملخص

تُعدّ الأسواق المالية من أكثر البيئات الاقتصادية تعقيدًا وديناميكية، فتحركاتها تتأثر بعوامل متعددة تشمل المؤشرات الاقتصادية، والسياسات النقدية، والتغيرات الجيوسياسية، إضافةً إلى الأخبار والتقارير الإعلامية التي تعكس المزاج العام للمستثمرين. لذلك، أصبح تحليل التقلّب المالي أداة أساسية لفهم سلوك الأسواق وتقييم مستويات المخاطر المستقبلية. ويُعد نموذج GARCH من أبرز النماذج الإحصائية الأكثر استخدامًا في هذا المجال بقدرته على توصيف سلوك التقلّب عبر الزمن والتنبؤ بتجمعاته المعروفة بظاهرة تجمع التقلبات.

ومع ذلك، فإن الاعتماد على البيانات التاريخية للأسعار وحدها لم يعد كافيًا في عصرٍ أصبحت فيه المعلومات تنتقل بسرعة هائلة. فقد أظهرت الدراسات أن الأخبار تمثل عاملًا جوهريًا في تشكيل سلوك السوق، إذ يمكن لعناوين الصحف والتقارير الاقتصادية أن تغيّر اتجاهات الأسعار في لحظات قصيرة من خلال تأثيرها على مشاعر المستثمرين وتوقعاتهم. من هنا برزت أهمية دمج تحليل المشاعر (Sentiment Analysis) مع النماذج الإحصائية التقليدية لتكوين رؤية أكثر شمولًا للتقلبات.

يقدم هذا البحث نموذجًا متقدمًا أُطلق عليه PTTA-GARCH، وهو تطوير لنموذج GARCH التقليدي يأخذ في الاعتبار عامل الأخبار كمصدر رئيسي للمعلومات غير المهيكلية. يعتمد النموذج على معالجة الأخبار المالية باستخدام تقنيات الذكاء الاصطناعي والتحليل اللغوي، مثل خوارزميات VADER و FinBERT، لاستخراج مؤشرات كمية تعبّر عن المشاعر الإيجابية والسلبية السائدة في السوق. تُدمج هذه المؤشرات ضمن هيكل النموذج كمتغيرات خارجية تؤثر مباشرة في ديناميكيات التقلّب.

يهدف نموذج PTTA-GARCH إلى تحقيق تنبؤات أكثر دقة واستقرارًا لتقلبات الأسعار، مع القدرة على التقاط الاستجابات الفورية للأحداث الإخبارية الكبرى. ويمثل هذا النموذج خطوة نحو بناء أدوات كمية أكثر ذكاءً وواقعية في تحليل الأسواق المالية، من خلال الجمع بين الأساليب الإحصائية الصارمة والتحليل النصي الدلالي لمصادر الأخبار، بما يعزز من فعالية إدارة المخاطر واستراتيجيات الاستثمار القائمة على التوقعات الديناميكية.

Abstract

Financial markets are among the most complex and dynamic environments in the global economy, influenced by multiple factors such as economic indicators, monetary policies, geopolitical events, and crucially news and media reports that shape investor sentiment. Consequently, analyzing financial volatility has become essential for understanding market behavior and assessing future risk levels. Among the most widely used models in this field is the GARCH model, known for its ability to describe volatility dynamics over time and capture phenomena such as volatility clustering.

However, relying solely on historical price data is no longer sufficient in an era where information spreads rapidly. Studies have shown that news plays a pivotal role in shaping market behavior, as headlines and reports can instantly alter price directions by influencing investor psychology and expectations. This highlights the need to integrate sentiment analysis with traditional econometric models to obtain a more comprehensive understanding of volatility.

This research introduces an advanced model called PTTA-GARCH, an extension of the traditional GARCH framework that explicitly incorporates the news factor as a major source of unstructured information. The proposed model processes financial news using artificial intelligence and natural language processing techniques specifically VADER and BERTweet algorithms to extract quantitative indicators reflecting positive and negative market sentiment. These sentiment measures are then integrated into the GARCH structure as exogenous variables that directly influence volatility dynamics.

The PTTA-GARCH model aims to achieve more accurate and stable volatility forecasts by capturing the immediate impact of major news events. This approach represents a step toward developing smarter and more realistic quantitative tools for financial market analysis combining rigorous statistical modeling with semantic text analysis of news sources to enhance risk management and support dynamic, data-driven investment strategies.

فهرس المحتويات

vi.....	فهرس المحتويات	
viii.....	قائمة الاشكال	
viii.....	قائمة الجداول	
ix.....	جدول المصطلحات	
x.....	قائمة الرموز الرياضية	
1.....	الفصل الأول الإطار العام للدراسة	
2.....	المقدمة	1.1
3.....	مشكلة البحث	2.1
4.....	أهداف البحث	3.1
4.....	مساهمات البحث	4.1
5.....	الفصل الثاني الدراسة النظرية	
6.....	السلاسل الزمنية	1.2
6.....	مكونات السلسلة الزمنية	1.1.2
9.....	استقرار السلسلة الزمنية	2.1.2
10.....	نمذجة السلاسل الزمنية المالية	3.1.2
12.....	نماذج السلاسل الزمنية الخطية	2.2
12.....	نموذج الانحدار الخطي	1.2.2
12.....	نموذج المتوسط المتحرك	2.2.2
13.....	نماذج السلاسل الزمنية غير الخطية	3.2
13.....	نموذج ARCH	1.3.2
14.....	نموذج GARCH	2.3.2
15.....	نموذج PTT-GARCH	3.3.2
16.....	تحليل المشاعر	4.2
17.....	نموذج BERT	1.4.2
18.....	نموذج FinBERT	2.4.2
20.....	نموذج VADER	3.4.2
21.....	الفصل الثالث الدراسة المرجعية	
22.....	دراسة (Atkinson، Mitra، و Yu، 2016)	1.3
24.....	دراسة (Shi & Ho، 2020)	2.3
31.....	دراسة (Sadik & Mitra، 2018)	3.3

33	دراسة (A.Mendoza-Urdiales, 2022)	4.3
36	الفصل الرابع المنهجية المقترحة	
37	تمهيد	1.4
38	بناء النموذج	2.4
39	نموذج (1) ARCH/Sentiment-ARCH	1.2.4
42	نموذج (1,1) PTT-AGARCH	2.2.4
43	نموذج PTT-AGARCH(p,q)	3.2.4
45	نموذج PTT-AGARCH(p,q) مع دالة الاخبار المعدلة	4.2.4
47	الفصل الخامس تقييم المنهجية المقترحة	
48	تعريف الاختبارات المطبقة	1.5
48	اختبار ARCH-LM	1.1.5
48	اختبار Ljung-Box على الصدمات المربعة	2.1.5
48	اختبار Jarque-Bera على الصدمات المربعة	3.1.5
49	مخططات Q-Q (Quantile-Quantile)	4.1.5
49	ARCH/Sentiment-ARCH (1)	2.5
49	نتائج الاختبارات الحسابية	1.2.5
50	مخطط Q-Q للبيانات	2.2.5
50	تفسير النتائج	3.2.5
51	تقييم نموذج PTT-AGARCH (1,1)	3.5
52	النماذج المختبرة	1.3.5
52	نتائج التقييم	2.3.5
56	تفسير النتائج	3.3.5
57	تقييم النموذج المعمم PTT-AGARCH (p,q)	4.5
57	اختبار الرتب المثلى	1.4.5
58	التقييم خارج العينة باستخدام Walk-Forward Forecasting	2.4.5
61	تفسير النتائج	3.4.5
62	نموذج PTT-AGARCH (p,q) مع دالة قياس الاخبار	5.5
63	آلية المقارنة	1.5.5
63	شرح النتائج	2.5.5
64	رسم مستويات الثقة للنموذج PTT-AGARCH	6.5
67	الفصل السادس الخاتمة والافاق المستقبلية	

68	الخاتمة	1.6
69	الافاق المستقبلية	2.6
70	المراجع	

قائمة الاشكال

7	الشكل 1 المنحنى المعياري لسلسلة زمنية تتضمن مركبة اتجاه عام	
7	الشكل 2 المنحنى المعياري لسلسلة زمنية تتضمن مركبة موسمية	
8	الشكل 3 المنحنى المعياري لسلسلة زمنية تتضمن مركبة دورية	
8	الشكل 4 التغيرات العشوائية في سلسلة زمنية	
11	الشكل 5 مقارنة بين تقدير كثافة النواة (Kernel Estimator) لتوزيع عوائد مؤشر CAC وبين التوزيع الطبيعي	
18	الشكل 6 إجراءات التدريب المسبق (Pre-training) والتعديل الدقيق (Fine-tuning) لنموذج BERT	
19	الشكل 7 نظرة عامة على التدريب المسبق الإضافي وضبط المعاملات الدقيق لتصنيف النصوص في نموذج FinBERT	
30	الشكل 8 احتمال تنعيم الحالة الهادئة في دراسة (Shi و Ho، 2020)	
33	الشكل 9 إطار العمل في دراسة (A.Mendoza-Urdiales, 2022)	
35	الشكل 10 نتائج نموذج EGARCH في (A.Mendoza-Urdiales, 2022)	
39	الشكل 11 مخطط المنهجية المقترحة	
41	الشكل 12 مخطط تحليل المشاعر	
50	الشكل 13 مخطط الصدمات للسهم A	
66	الشكل 14 العوائد المقدرة لكل سهم مع فاصل التنبؤ 95% الناتج عن نموذج PTT-AGARCH	

قائمة الجداول

23	جدول 1 مقارنة أداء النماذج الثلاثة في المرجع (Mitra، Atkinson، و Yu، 2016)	
24	جدول 2 المقارنة بين المؤثرات الخارجية بوجود تقلب ضمني في المرجع (Mitra، Atkinson، و Yu، 2016)	
24	جدول 3 نتائج خارج العينة في المرجع (Mitra، Atkinson، و Yu، 2016)	
29	جدول 4 المعاملات طويلة الذاكرة وأداء النماذج لعائلة نماذج FIEGARCH	
32	جدول 5 يعرض جدول التوافق (Contingency Table) في المرجع (Mitra و Sadik، 2018)	
46	جدول 6 قيود المعاملات المفروضة في نموذج PTT-AGARCH (دالة الأخبار المعدلة)	
49	جدول 7 نتائج اختبارات ARCH و Jarque-Bera و Ljung-Box و ACHC، AA، A، للأسهم	
55	جدول 8 نتائج المرحلة الثانية من عملية بناء النموذج	
61	جدول 9 نتائج التقييم خارج وداخل العينة للمرحلة الثالثة	
63	جدول 10 مقارنة أداء النماذج المختلفة لدالة قياس الأخبار باستخدام مقاييس MAE و RMSE	

جدول المصطلحات

الاختصار	اللغة الانكليزية	اللغة العربية
-	Auto Covariance	التغاير الذاتي
AR	Auto Regressive	الانحدار الذاتي
ARCH	Auto Regressive Conditional Heteroscedasticity	الانحدار الذاتي للتباين الشرطي
BERT	Bidirectional Encoder Representations from Transformers	تمثيلات التشفير ثنائية الاتجاه من المحوّلات
-	Behavioral Finance	الاقتصاد السلوكي
-	Compound Score	الدرجة المركبة
-	Cyclical Variations	التغيرات الدورية
GARCH	Generalized Autoregressive Conditional Heteroscedasticity	التغاير الذاتي الشرطي المعمم
-	Leverage Effect	الرافعة المالية
-	Market Sentiment	معنويات السوق
ML	Maximum Likelihood	أسلوب الاحتمالية العظمى
MA	Moving Average	المتوسط المتحرك
-	Overfitting	الافراط في التخصيص
-	Random Walk	السير العشوائي
-	Stationary	مستقرة
-	Time Series	السلاسل الزمنية
-	Volatility clustering	تجمع التقلبات
-	White noise	ضجيج أبيض

قائمة الرموز الرياضية

Symbol	English Description	الوصف بالعربية
r_t	Asset return at time t	عائد الأصل المالي عند الزمن (t)
μ	Mean of returns	متوسط العوائد
ε_t	Innovation / Shock at time t	الصدمة (التجديد) عند الزمن (t)
σ_t^2	Conditional variance	التباين الشرطي
σ_t	Conditional volatility	التقلب الشرطي
z_t	Standardized i.i.d random variable	متغير عشوائي معياري مستقل ومتماثل التوزيع
ω	Constant term	الحد الثابت
α	ARCH coefficient (short-run shock effect)	معامل ARCH (أثر الصدمات قصيرة الأجل)
α_{i+}	Coefficient of positive shocks	معامل الصدمات الموجبة
α_{i-}	Coefficient of negative shocks	معامل الصدمات السالبة
β	GARCH coefficient (volatility persistence)	معامل GARCH (استمرارية التقلب)
α_i	ARCH parameter of order i	معامل ARCH من الرتبة (i)
β_j	GARCH parameter of order j	معامل GARCH من الرتبة (j)
p	Order of ARCH terms	رتبة مكونات ARCH
q	Order of GARCH terms	رتبة مكونات GARCH
ν	Degrees of freedom (Student-t)	درجات الحرية (توزيع ستودنت)
\mathcal{F}_{t-1}	Information set up to time $t-1$	مجموعة المعلومات المتاحة حتى الزمن ($t-1$)
$E(\cdot)$	Expectation operator	المؤثر الرياضي للتوقع
$Var(\cdot)$	Variance operator	مؤثر التباين
$\log(\sigma_t^2)$	Log conditional variance	لوغاريتم التباين الشرطي

الفصل الأول

الإطار العام للدراسة

1.1 المقدمة

تُعدّ السلاسل الزمنية المالية من أهم أنواع البيانات في الاقتصاد الكمي والتمويل التجريبي، إذ تمثل تسلسلاً زمنياً لقيم متغيرات مالية تُسجّل على فترات زمنية متتالية، مثل أسعار الأسهم أو مؤشرات السوق. وتتميّز هذه السلاسل بخصائص إحصائية معقدة، من أبرزها عدم الثبات والتقلب الشرطي، مما يجعل نمذجتها وتحليلها تحدياً مستمراً للباحثين في هذا المجال (Zakoian, 2019).

شهد تحليل المشاعر (Sentiment Analysis) في السنوات الأخيرة اهتماماً متزايداً في المجال المالي، بوصفه أحد تطبيقات معالجة اللغة الطبيعية. ويُستخدم هذا التحليل لمعالجة النصوص الإخبارية وتقارير السوق ومنشورات وسائل التواصل الاجتماعي بهدف استخراج مؤشرات كمية تعكس المزاج العام للمستثمرين، الذي قد يؤثر مباشرة على قرارات الاستثمار، مسبباً تحركات مفاجئة في الأسعار وتقلبات غير متوقعة في الأسواق المالية (Tetlock P. C., 2007) (Wurgler, 2007).

طوّر (Engle, 1982) نموذج ARCH، وعُمّم لاحقاً إلى نموذج GARCH بواسطة (Bollerslev T. , 1986)، الذي أصبح أساساً للعديد من النماذج المتقدمة مثل EGARCH وTGARCH. يمثل نموذج PTT-GARCH (Power-Transformed Threshold GARCH) تعميماً متقدماً لنموذج GARCH، حيث يدمج بين مفهوم العتبة (Threshold) والتحويل بالقوة (Power Transformation) لتمثيل التقلبات المالية بشكل أكثر مرونة ودقة. يتيح هذا النموذج التمييز بين تأثير الصدمات الإيجابية والسلبية على التباين الشرطي للسلاسل الزمنية المالية، مع السماح بمعالجة التغيرات غير الخطية في التقلبات، كما يشمل التأثيرات الذاتية للتقلبات السابقة، مما يجعله مناسباً للأسواق التي تتسم بعدم التماثل في استجابة المتغيرات الاقتصادية أو المزاج العام للمستثمرين (Kim H. H., 2004) (Basawa, 2004).

بدمج PTT-GARCH مع تحليل المشاعر المالية يمكن تطوير نماذج هجينة متقدمة تعكس العلاقة الديناميكية بين السلوك النصي للمستثمرين والتقلبات الفعلية للأسواق المالية. هذا التكامل بين التحليل الكمي والتحليل النصي يعزز دقة التنبؤ بالتقلبات المستقبلية، ويوفر فهماً أعمق للطبيعة الاقتصادية للسلوك الاستثماري، مما يمكن من إجراء اختبارات إحصائية دقيقة، بما في ذلك استخدام تقديرات QMLE للتعامل مع الأخطاء ثقيلة الذيل، مما يمثل خطوة مهمة نحو تطوير نماذج تنبؤية أكثر موثوقية واستجابة للتغيرات المستمرة في الأسواق المالية.

2.1 مشكلة البحث

على الرغم من التطور الكبير في النماذج الإحصائية المصممة لوصف وتقليل عدم اليقين في التنبؤ بتقلبات الأسواق المالية، يظل الاعتماد على البيانات السعرية التاريخية وحدها كما في النماذج التقليدية غير كافياً لتمثيل التأثيرات الفورية والمعقدة للأخبار والمستجدات الاقتصادية. حيث تتفاعل الأسواق المالية بسرعة مع الإعلانات الاقتصادية والأحداث المفاجئة، وغالباً ما تظهر أنماط من عدم التماثل في استجابة الأسعار، حيث تميل الأخبار السلبية إلى توليد زيادات أكبر في التقلبات مقارنة بالأخبار الإيجابية (Tetlock P. C., 2007), (Grant, 1990).

كما أن هذه التأثيرات لا تقتصر على الأصل المالي موضوع الخبر، بل يمكن أن تمتد إلى أصول أخرى مرتبطة به وهذا ما يزيد من تعقيد ديناميكيات الأسواق (M. Chan, 2013) ومن هنا تنشأ الحاجة إلى دمج مصادر بيانات إضافية، مثل الأخبار ومعنويات السوق ضمن النماذج الإحصائية، بدلاً من الاقتصار على البيانات السعرية التاريخية (J. Tetlock P., 2010), (Bollen, 2011).

مع التقدم في تقنيات تحليل النصوص ومعالجة اللغة الطبيعية، أصبح بالإمكان تحويل الأخبار التي هي بطبيعتها بيانات نوعية إلى مؤشرات كمية تعكس معنويات السوق أو كثافة الأخبار، مما يتيح دمجها مباشرة في النماذج الرياضية. ومع ذلك لم تحظ النماذج الأكثر مرونة مثل PTT-GARCH، بالدراسة الكافية عند دمجها مع بيانات الأخبار ومعنويات السوق (McDonald, 2011), (Y. Zhang, 2011).

وتتمثل الفجوة البحثية الحالية في الحاجة إلى ما يلي:

- تقييم الأداء التنبؤي للنماذج التقليدية والمتقدمة عند الاعتماد على البيانات التاريخية فقط.
- قياس أثر دمج بيانات الأخبار ومعنويات السوق على تحسين دقة التنبؤ بتقلبات الأسواق.
- مقارنة النماذج المدمجة بالأخبار مع نظيراتها الخالية من الأخبار لتحديد مدى التحسن في الأداء الإحصائي والاقتصادي.

استناداً إلى ذلك، يهدف هذا البحث إلى دراسة مقارنة شاملة لأربعة نماذج رئيسية:

- GARCH: النموذج التقليدي لتقدير التباين الشرطي.
- PTT-GARCH: نموذج متقدم يوفر مرونة أكبر لتمثيل عدم التماثل في التقلبات.
- GARCH-News: نسخة مدمجة بالأخبار لالتقاط التأثيرات الفورية للأحداث.
- PTT-AGARCH: النموذج المقترح الذي يجمع بين مرونة PTT-GARCH وأثر الأخبار ومعنويات السوق.

ستسهم هذه الدراسة في تقديم منهجية أكثر تكاملاً للتنبؤ بتقلبات الأسواق المالية، تدمج قوة النماذج الإحصائية التقليدية وقدرة المؤشرات المستخلصة من الأخبار على التفسير، بما يدعم اتخاذ قرارات إدارة المخاطر وصياغة استراتيجيات الاستثمار في بيئة مالية عالمية متقلبة.

3.1 أهداف البحث

يهدف هذا البحث إلى تطوير مقارنة متكاملة للتنبؤ بتقلبات الأسواق المالية من خلال الجمع بين النماذج الإحصائية المتقدمة مثل GARCH و PTT-GARCH، وبين المؤشرات الكمية المستخلصة من الأخبار الاقتصادية والمالية. يقوم البحث على دراسة أثر الأخبار الإيجابية والسلبية على ديناميكيات التباين الشرطي، مع اختبار فرضية عدم التماثل في استجابة الأسواق. كما يسعى إلى مقارنة الأداء الإحصائي والاقتصادي للنماذج التقليدية والمطورة بالأخبار، لتحديد مدى القيمة المضافة التي يقدمها دمج المعطيات النوعية في النمذجة الكمية. ومن خلال هذه الدراسة، يأمل البحث في تقديم إطار قابل للتطبيق العملي يساهم في تحسين دقة التنبؤ وإدارة المخاطر في بيئات السوق المعقدة والمتقلبة.

4.1 مساهمات البحث

يهدف هذا البحث إلى تقديم إسهامات علمية وتطبيقية في مجال نمذجة وتقليل الخطأ في التنبؤ بتقلبات الأسواق المالية، من خلال الجمع بين النماذج الإحصائية التقليدية والمتقدمة من جهة، ومؤشرات الأخبار ومعنويات السوق من جهة أخرى. ويمكن تلخيص أهم المساهمات كما يلي:

1. تحليل مقارن شامل بين النماذج التقليدية مثل GARCH والنماذج المتقدمة مثل PTT-GARCH في توصيف التباين الشرطي، مع تقييم أدائها باستخدام البيانات التاريخية فقط، وكذلك عند دمج مؤشرات الأخبار.
2. دمج الأخبار كمؤشرات كمية ضمن نماذج GARCH و PTT-GARCH، للاستفادة من المعلومات النوعية التي تحملها الأخبار ومعنويات السوق، وتحويلها إلى متغيرات تفسيرية تعزز دقة التنبؤ بتقلبات الأسواق.
3. دراسة تأثير الأخبار الإيجابية والسلبية على ديناميكيات التقلب، واختبار فرضية عدم التماثل في استجابة الأسواق، سواء بالنسبة للأصل المالي موضوع الخبر أو للأصول المرتبطة به.
4. تقييم القيمة الاقتصادية للنماذج المدمجة بالأخبار، ليس فقط من منظور الأداء الإحصائي، بل أيضًا من منظور دعم اتخاذ القرارات الاستثمارية وإدارة المخاطر في بيئة مالية ديناميكية وسريعة التغير.

يسعى البحث من خلال هذه المساهمات إلى تقديم أداة أكثر تكاملاً تساعد الباحثين والممارسين على فهم وتوقع تقلبات الأسواق المالية بشكل أكثر دقة وواقعية.

الفصل الثاني

الدراسة النظرية

1.2 السلاسل الزمنية

تُعرّف السلسلة الزمنية وفقاً لما أشار إليه الباحثون في (Zakoian، 2019) بأنها مجموعة من المتغيرات العشوائية المرتبة وفق تسلسل زمني، وتمثل عادةً قيمةً لمتغير معين يتم تسجيلها على فترات زمنية متساوية، مثل العوائد اليومية للأسهم أو معدلات التضخم الشهرية. ويولي المرجع ذاته اهتماماً خاصاً لخاصية التغير الشرطي، التي تعني أن تباين السلسلة في لحظة معينة يتأثر بالمعلومات السابقة، وهي سمة جوهرية في نمذجة السلاسل الزمنية المالية التي يمكن التعبير عنها رياضياً بالعلاقة:

$$y_t = \mu + \varepsilon_t, \quad \varepsilon_t = \sigma_t z_t$$

- μ : المتوسط الشرطي المعتمد على القيم السابقة.
- ε_t : الصدمة في اللحظة t.
- σ_t^2 : التباين الشرطي الذي يُعبّر عنه كدالة تعتمد على القيم السابقة لمربعات الأخطاء والانحرافات عن المتوسط.
- z_t : مجموعة متغيرات عشوائية مستقلة ومتوزعة بمتوسط صفري وتباين يساوي واحد.

ويُبرز هذا التعريف أن السلاسل الزمنية ليست مجرد تسلسلات من الملاحظات، بل هي عمليات عشوائية تتغير فيها كل من المتوسطات والتباينات بمرور الوقت تبعاً للمعلومات السابقة، وهو ما يجعلها مناسبة بشكل مبدئي لتحليل تقلبات الأسواق المالية.

ومن الواجب ذكره أن بناء السلسلة الزمنية واستعمالها في التحليل يتطلب ضمان دقة ترتيبها وتحديد مستوياتها القابلة للمقارنة. حيث يجب أن تكون نقاط السلسلة الزمنية متسقة من حيث الفترات الزمنية والمستويات التحليلية، سواء أكانت تمثل إقليمياً أو دولة أو مؤسسة معينة. وتُعتبر وحدة القياس في جميع مستويات السلسلة عاملاً أساسياً لضمان دقة النتائج. عادةً ما تكون السلاسل الزمنية عرضة للتغيرات وهذا مما يستلزم في كثير من الأحيان إدخال تعديلات عليها لتكون قابلة للمقارنة وتحقيق الدقة في التحليل (محمد، 2012).

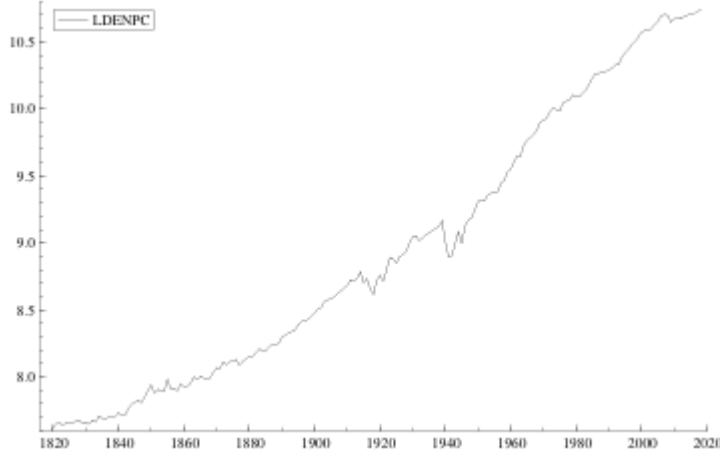
1.1.2 مكونات السلسلة الزمنية

تتكون السلسلة الزمنية من مجموعة من العناصر التي تساهم في تفسير الظاهرة المدروسة مثل المتغيرات الخارجية والمؤثرات الموسمية والعوامل العشوائية.

1. الاتجاه العام

يشير الاتجاه العام إلى التطور الطبيعي للظاهرة عبر الزمن، سواء كان هذا التطور في شكل نمو مستمر أو تراجع تدريجي. يركز الاتجاه العام على التغيرات طويلة المدى، متجاهلاً التقلبات قصيرة الأجل التي قد تحدث في الفترات الزمنية القصيرة.


يمكن تحديد الاتجاه العام من خلال تحليل القيم التاريخية للظاهرة، حيث يتم تمثيله غالبًا بمنحنى يعكس التوجه العام للبيانات عبر الزمن (محمد، 2012). يوضح الشكل 1 الاتجاه العام في السلاسل الزمنية من خلال عرض اللوغاريتم الطبيعي للناتج المحلي الإجمالي للفرد في الدنمارك خلال المدة (1820-2018) (Silva Lopes, 2025).



الشكل 1 المنحنى المعياري لسلسلة زمنية تتضمن مركبة اتجاه عام

2. التغيرات الموسمية

تمثل التغيرات الموسمية أنماطًا دورية تحدث بانتظام خلال فترات زمنية محددة، وتنتج عن تأثيرات موسمية مثل الفصول المناخية أو العوامل الدورية الأخرى. تتميز هذه التغيرات بتكرارها خلال نفس الفترات من كل عام، مما يجعلها قابلة للتنبؤ بناءً على الأنماط السابقة (محمد، 2012).



الشكل 2 المنحنى المعياري لسلسلة زمنية تتضمن مركبة موسمية


3. التغيرات الدورية

عُرِّفت التغيرات الدورية وفقاً لما ذكر في (محمد، 2012) بأنها التقلبات التي تحدث في السلاسل الزمنية على مدى فترات زمنية طويلة نسبياً. وتتميز هذه التغيرات بأنها ليست ناتجة عن عوامل موسمية أو مؤقتة، وإنما تعكس حالات من الازدهار أو الانكماش في الاقتصاد أو في النشاط العام للظواهر المدروسة، كالنمو الاقتصادي، البطالة، أو حتى المبيعات على المدى الطويل.

بخلاف التغيرات الموسمية التي تحدث في فترات زمنية منتظمة (مثل الفصول الأربعة أو الأشهر)، فإن التغيرات الدورية تمتد على مدى سنوات، وقد تصل في بعض الأحيان إلى عشر سنوات أو أكثر. ولهذا فإن تحديد بداية ونهاية الدورة الاقتصادية ليس بالأمر السهل، نظرًا لعدم انتظام مدتها وتفاوت تأثيرها في كل مرة، فكل دورة قد تختلف في شكلها وعمقها وامتدادها الزمني عن الأخرى.

وعادةً ما تمر الدورة الدورية بأربع مراحل رئيسية:


- 1 **الانتعاش:** حيث تبدأ المؤشرات الاقتصادية بالتحسن تدريجيًا.
- 2 **الازدهار (الذروة):** وتصل فيه المؤشرات إلى أعلى مستوياتها.
- 3 **الركود:** يبدأ فيه التراجع والانخفاض التدريجي في النشاط الاقتصادي.
- 4 **الكساد (القاع):** يصل فيه الأداء الاقتصادي إلى أدنى مستوياته.



الشكل 3 المنحنى المعياري لسلسلة زمنية تتضمن مركبة دورية

4. التغيرات العشوائية

هي التغيرات الشاذة التي تحدث من ظروف طارئة لا يمكن التنبؤ بوقوعها أو تحديد نطاق تأثيرها حيث تنشأ عن أسباب خارجية لا تكون في الحسبان مثل الزلازل كما في الشكل 4 التغيرات العشوائية في سلسلة زمنية (محمد، 2012).



الشكل 4 التغيرات العشوائية في سلسلة زمنية

2.1.2 استقرار السلسلة الزمنية

يُعدّ التحقق من خاصية الاستقرار خطوة أساسية قبل الشروع في أي تحليل للسلاسل الزمنية، إذ إن معظم النماذج الإحصائية والاقتصادية، مثل نماذج الانحدار الذاتي (AR) أو المتوسطات المتحركة (MA) أو النماذج المركبة (ARIMA)، تفترض أن السلسلة الزمنية محل الدراسة هي سلسلة مستقرة.

ويقصد بالسلسلة الزمنية المستقرة تلك السلسلة التي لا تتغير خصائصها الإحصائية مع مرور الزمن، أي أن المتوسط والتباين المشترك بين القيم يبقى ثابتاً. أما إذا تغيرت هذه الخصائص بمرور الزمن، كما في حالة وجود اتجاه عام أو موسمية أو تباينات متزايدة مع الزمن، فإن السلسلة توصف بأنها غير مستقرة.

حدّد الباحثون في (Zakoian، 2019) شروط استقرار السلسلة الزمنية من الدرجة الثانية (Second-order stationarity) كما يلي:

- أن يكون المتوسط الحسابي ثابتاً عبر الزمن : $\mathbb{E}(Y_t) = \mathbb{E}(Y_{t+k}) = \mu$
 - أن يكون التباين ثابتاً عبر الزمن:
- $$\text{Var}(Y_t) = \mathbb{E}[(Y_t - \mathbb{E}(Y_t))^2] = \text{Var}(Y_{t+k}) = \mathbb{E}[(Y_{t+k} - \mathbb{E}(Y_{t+k}))^2] = \gamma(0) = \sigma^2 < \infty, \forall t$$
- أن يعتمد التباين المشترك بين القيم فقط على تأخير زمني (Lag) بين الملاحظات وليس على نقطة الزمن نفسها:

$$\text{Cov}(Y_t, Y_{t+k}) = \mathbb{E}[(Y_t - \mu)(Y_{t+k} - \mu)] = \gamma(k)$$

ويُفهم من ذلك أن السلسلة الزمنية المستقرة تتميز بخصائص ثابتة لا تتغير مع مرور الزمن، الأمر الذي يجعلها مناسبة للنماذج التنبؤية بينما قد تؤدي السلاسل غير المستقرة إلى استنتاجات مضللة أو غير دقيقة ما لم تتم معالجتها.

وعندما تكون السلسلة غير مستقرة فإن أحد الحلول الشائعة يتمثل في إجراء عملية التفاضل (Differencing) لتحويلها إلى سلسلة مستقرة، ففي هذه العملية يتم طرح القيمة السابقة من القيمة الحالية، وقد يتطلب الأمر إجراء تفاضل أكثر من مرة واحدة للوصول إلى حالة الاستقرار. كما يمكن اللجوء إلى تحويلات رياضية إضافية، مثل اللوغاريتم أو الجذر التربيعي، لتقليل تذبذبات التباين.

تُكمن أهمية الاستقرار في أن السلاسل غير المستقرة غالباً ما تحتوي على مكونات يصعب نمذجتها مباشرة، مثل الاتجاه العام أو الموسمية طويلة الأمد. فإذا لم تُعالج هذه الظواهر، فإن النماذج المستخدمة مثل (ARIMA) لن تكون قادرة على تمثيل البيانات بشكل صحيح وكمثال تطبيقي على السلاسل غير المستقرة، يُذكر السير العشوائي الذي يُكتب وفق الصيغة:

$$y_t = y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim IID(0, \sigma^2), \quad t = 1, \dots, T$$

في هذا النموذج، لا يوجد متوسط ثابت، كما أن التباين يزداد مع الزمن، ما يجعله نموذجاً غير مستقر بطبيعته. وغالباً ما يُستخدم السير العشوائي لتوضيح الحاجة إلى التحويلات قبل بناء النماذج الإحصائية (محمد، 2012).

3.1.2 نمذجة السلاسل الزمنية المالية


تُعد مسألة نمذجة السلاسل الزمنية المالية معقدة، إذ لا يعود هذا التعقيد فقط إلى تنوع أنواع السلاسل (مثل الأسهم، أسعار الصرف)، أو إلى تكرار الرصد (ثانية، دقيقة، ساعة، يوم، إلخ)، أو إلى توفر مجموعات بيانات ضخمة، بل يعود أساساً إلى وجود أنماط إحصائية منتظمة وهي شائعة في العديد من السلاسل المالية ويصعب تمثيلها باستخدام النماذج العشوائية التقليدية (Zakoian, 2019).

كما تابع الباحثون في (Zakoian, 2019) شرح تلك الانماط الإحصائية التي تبرز تعقيد السلاسل الزمنية:

- غياب الارتباط الذاتي في تغيرات الأسعار: إذ تُظهر سلاسل تغيرات الأسعار عادةً معاملات ارتباط ذاتي ضعيفة، مما يجعلها قريبة من "الضوضاء البيضاء". ففي السلاسل ذات الفواصل الزمنية القصيرة جداً (مثل البيانات اللحظية بالدقائق أو الثواني)، يمكن ملاحظة ارتباطات ذاتية ملموسة نتيجة لما يُعرف بتأثيرات البنية الدقيقة للأسواق (microstructure effects).
- وجود ارتباط ذاتي قوي في مربعات العوائد، حيث تُظهر العوائد المربعة ε_t^2 ارتباطاً ذاتياً مرتفعاً، مما يشير إلى أن العوائد نفسها قد تكون غير مترابطة، لكن تباينها يتبع نمطاً زمنياً منتظماً.
- تجمع التقلبات: حيث تميل $|\varepsilon_t|$ إلى الظهور في مجموعات زمنية متقاربة، أي أن فترات التقلب العالي تتبعها عادة فترات مماثلة والعكس صحيح. وتُعد هذه الظاهرة من السمات الجوهرية للأسواق المالية إذ تُظهر أن فترات "الاضطراب" تُعقب عادة بفترات "هدوء"، دون أن يكون ذلك على نحو دوري منتظم.
- تأثير الرافعة المالية Leverage Effect حيث تُظهر الدراسات أن الصدمات السلبية (انخفاض الأسعار) تؤدي إلى زيادة أكبر في التقلب مقارنة بالصدمات الموجبة (ارتفاع الأسعار) ذات الحجم نفسه.
- توزيعات ذات الذيل الثقيلة فعند رسم التوزيع التجريبي للعوائد اليومية يمكن ملاحظة اختلافه عن التوزيع الطبيعي وتشير الاختبارات الإحصائية التقليدية عادةً إلى رفض فرضية التوزيع الطبيعي عند أي مستوى معقول من الدلالة. لذا تتميز توابع الكثافات الاحتمالية للعوائد بذيول ثقيلة أي تتناقص نحو الصفر بوتيرة أبطأ من الدالة الأسية $e^{-\frac{x^2}{2}}$ كما تُظهر قمة حادة حول الصفر، ويُطلق على هذا النوع من التوزيعات مصطلح التفلطح. يُقاس هذا التفلطح بمعامل يُعرف باسم معامل التفرطح (Kurtosis coefficient)، وهو يُعرّف كنسبة العزم الرابع للعينة إلى مربع التباين التجريبي للعينة. وتبلغ القيمة الحدّية لهذا المعامل 3 في حالة البيانات المستقلة والمتطابقة التوزيع (i.i.d) ذات التوزيع الطبيعي، إلا أن قيمته تكون أكبر بكثير من 3 في سلاسل العوائد المالية، ومع زيادة الفاصل الزمني الذي تُحسب عنده العوائد، تميل خاصية التفلطح إلى الاختفاء تدريجياً، ويصبح التوزيع التجريبي أقرب إلى التوزيع الطبيعي، الشكل 5 يقارن بين تابع الكثافة

الاحتمالية للتوزيع الطبيعي وعوائد مؤشر CAC ، حيث يظهر بوضوح الارتفاع الحاد حول الصفر، بينما يكون من الصعب ملاحظة سماكة الذيل بدقة.

- تؤثر العوامل الموسمية والتقويمية بشكل ملحوظ على سلوك السوق، إذ يمكن أن تتباين العوائد بحسب يوم الأسبوع أو قرب المناسبات والعطلات. إذ غالبًا ما تشهد التقلبات ارتفاعًا بعد فترات توقف السوق نتيجة تراكم المعلومات أثناء الإغلاق، لكن هذا الارتفاع يكون أقل حدة مقارنة بتراكم المعلومات المستمر خلال التداول العادي. كما أن لهذه الأنماط الموسمية أثر واضح أيضًا على بيانات التداول القصيرة الأجل مثل السلاسل الزمنية اليومية أو اللحظية.



الشكل 5 مقارنة بين تقدير كثافة النواة (Kernel Estimator) لتوزيع عوائد مؤشر CAC وبين التوزيع الطبيعي

2.2 نماذج السلاسل الزمنية الخطية

1.2.2 نموذج الانحدار الخطي

يُبين (Ullrich, 2021) أن نموذج الانحدار الذاتي من الرتبة p والذي يعرف اختصاراً بـ $AR(p)$ يقوم بتقدير قيمة السلسلة الزمنية عند لحظة زمنية معينة t بناءً على تركيب خطي للقيم السابقة للسلسلة حتى الحد p . أي أنه على مزيج من القيم الماضية للتنبؤ بالقيمة الحالية، مما يسمح بتحليل العلاقة بين الملاحظات عبر الزمن وهذا ما يمكن التعبير عنه بالعلاقة الرياضية:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

حيث أن:

- المعاملات ϕ_i تمثل ثوابت النموذج.
- الحد ε_t يمثل الصدمة في اللحظة t .

عند استخدام نموذج الانحدار الذاتي من الرتبة $AR(p)$ لوصف سلسلة زمنية معينة، تُثار مجموعة من التساؤلات الجوهرية أولاً: هل يتمتع نموذج $AR(p)$ بالقدرة النظرية الكافية لتمثيل الخصائص الإحصائية والبنوية المميزة للسلسلة الزمنية قيد الدراسة؟ وثانياً: في حال كان النموذج مناسباً من ناحية المفاهيم، كيف يمكن تحديد رتبة النموذج على نحو يحقق التوازن بين الدقة التنبؤية وبساطة النموذج؟ عادةً ما يتم تحديد النموذج ومعاملاته من منظور إحصائي احتمالي، وذلك بالاعتماد على أسلوب الاحتمالية العظمى أو عبر حل معادلات Yule–Walker المعدلة، أو باستخدام طريقة المربعات الصغرى الاعتيادية (OLS).

2.2.2 نموذج المتوسط المتحرك

عرف الباحثون في (Guidolin، 2018) نموذج المتوسط المتحرك من الرتبة q ويرمز له بـ $MA(q)$ ، بأنه أحد النماذج الأساسية في تحليل السلاسل الزمنية الذي يقوم على فكرة تمثيل القيمة الحالية للسلسلة الزمنية كمتوسط خطي لعدد من القيم السابقة لعناصر الضوضاء العشوائية والذي يعبر عنه رياضياً بالمعادلة التالية:

$$y_t = \mu + \varepsilon_t + \varepsilon_{t-1}\theta_1 + \dots + \varepsilon_{t-q}\theta_q$$

حيث ε_t يمثل صدمات عشوائية مستقلة ومتطابقة التوزيع (i.i.d) بمتوسط صفري أما المعاملات θ_i هي ثوابت النموذج.

حدّد (Guidolin، 2018) خصائص النموذج وفق التالي:

1. الاستقرار:

تظل عملية MA(q) دائماً مستقرة لأنها مزيج خطي محدود من عمليات الضوضاء البيضاء، والتي تكون اللحظتان الأولى والثانية لها ثابتة عبر الزمن. تتمتع هذه العملية بمتوسط ثابت وتباين ثابت، وتوجد تغيرات ذاتية تختلف عن الصفر حتى الحد q فيما تنعدم بعد ذلك الحد.

2. المتوسط:

$$\mathbb{E}(y_t) = \mu$$

3. التباين:

يكون التباين ثابتاً عبر الزمن لأنه يعتمد على معاملات محددة وعدد محدود من الصدمات العشوائية.

$$\text{Var}(y_t) = \gamma_0 = \sigma^2(1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)$$

4. التباين الذاتي:

يكون التباين الذاتي غير صفري فقط للفوارق الزمنية حتى الرتبة q ثم بعد ذلك يصبح التباين الذاتي معدوماً.

$$\gamma_h = \text{Cov}(Y_t, Y_{t-h}) = \begin{cases} \sigma^2 \sum_{j=0}^{q-h} \theta_j \theta_{j+h}, & 0 \leq h \leq q \\ 0, & h > q \end{cases}$$

3.2 نماذج السلاسل الزمنية غير الخطية

1.3.2 نموذج ARCH

تُعد نماذج التباين الشرطي الذاتي الانحدار ARCH من الأدوات الإحصائية المهمة في تحليل السلاسل الزمنية، وذلك لما تتمتع به من قدرة على تمثيل التغيرات الديناميكية في التباين الشرطي، وهي خاصية تُلاحظ بشكل متكرر في البيانات المالية (Chou، Bollerslev، و Kroner، 1992)، وقد اقترح (Engle، 1982) في دراسته التأسيسية طريقة لتحديد معالم التباين الشرطي σ_t^2 وذلك من خلال التعبير عنه كدالة خطية لمربعات الصدمات السابقة وفقاً للصيغة الرياضية التالية:

$$\begin{aligned} \epsilon_t &= z_t \sigma_t, \quad z_t \sim \text{i.i.d.} (0,1), \quad E(z_t) = 0, \quad \text{var}(z_t) = 1 \\ \sigma_t^2 &= \omega + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2, \quad \omega > 0, \quad \alpha_i \geq 0 \end{aligned} \quad (1)$$

حيث:

- ϵ_t : الصدمة في الزمن t.
- σ_t^2 : التباين الشرطي.
- z_t : هي متتالية متغيرات عشوائية مستقلة ومتطابق التوزيع بمتوسط صفري وتباين 1.

وبحسب التعريف يُظهر المتغير ϵ_t ارتباطاً ذاتياً عبر الزمن إلا أنه لا يُعد مستقلاً، مما يعني أن مربعه يُظهر ارتباطاً ذاتياً أيضاً. وتُعد نماذج ARCH ملائمة بشكل خاص لنمذجة التباين الشرطي لعوائد الأسهم، والتي غالباً ما تتسم بتوزيع ذي ذيول ثقيلة. وبافتراض أن z_t تتبع توزيعاً طبيعياً فإن التوزيع الشرطي للعوائد يكون طبيعياً، في حين أن التوزيع غير الشرطي للعوائد يتسم بذيول ثقيلة (Anese، 2019).

إذا كان z_t موزعاً طبيعياً، فإن دالة اللوغاريتم الاحتمالية تصبح:

$$\log f(\epsilon_t | \mathcal{F}_{t-1}) = -\frac{1}{2} \log 2\pi - \frac{1}{2} \frac{\epsilon_t^2}{\sigma_t^2}$$

يمكن تطبيق أساليب تقدير الاحتمالية العظمى لتقدير معاملات نموذج ARCH(q)، كما يمكن إجراء اختبارات Lagrange Multiplier بهدف اختبار الفرضيات حول المعلمات α_i . كبديل لتقدير الاحتمالية العظمى، كما يمكن استخدام طريقة العزوم المعممة لتقدير نماذج ARCH (Chou، Bollerslev، و Kroner، 1992).

2.3.2 نموذج GARCH

تتمثل إحدى أبرز المآخذ على نموذج ARCH في تعقيده، إذ يتطلب غالباً عدداً كبيراً من الفترات الزمنية السابقة لنمذجة التقلبات بشكل دقيق. ولا يقتصر الأمر على أن العدد الكبير من الفترات السابقة يجعل عملية التقدير أكثر صعوبة بل يستلزم أيضاً توفر سلسلة زمنية طويلة من البيانات لأغراض النمذجة، وقد تم تجاوز هذه الإشكالية من خلال نماذج GARCH والتي تُعد تعميماً لنموذج ARCH الأساسي، حيث تسمح بتمثيل أكثر كفاءة للتقلبات باستخدام عدد أقل من المعلمات (Anese، 2019).

قدّم (Bollerslev T.، 1986) نموذج GARCH الذي يعتبر تعميماً لنموذج ARCH الأساسي وقد مثله بالصيغة الرياضية التالية:

$$\begin{aligned} \epsilon_t &= z_t \sigma_t, \quad z_t \sim \text{i.i.d.} (0,1), \quad E(z_t) = 0, \quad \text{var}(z_t) = 1 \\ \sigma_t^2 &= \omega + \sum_{i=1}^p \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \end{aligned} \quad (2)$$

يُمثل الجزء الأول مجموع مربعات الصدمات السابقة، والمُعَرَّفة وفق الشروط ذاتها الواردة في المعادلة (1)، ويتم وزنها بمعاملات محددة تعكس تأثيرها النسبي. أما الجزء الثاني فيُعَبَّر عن مجموع التباينات الشرطية السابقة والتي تُوزن أيضاً بمعاملات محددة.

يُشير الرمز p إلى عدد الفترات الزمنية السابقة المرتبطة بمربعات الصدمات، في حين يُعَبَّر q عن عدد الفترات السابقة المرتبطة بالتباينات الشرطية. وتُجسّد هذه المعاملات الأثر التنازلي للتباينات السابقة على التباين الشرطي الحالي، مما يُمكن النموذج من التقاط ديناميكية التقلبات عبر الزمن بشكل أكثر دقة.

تُفرض على معاملات النموذج مجموعة من القيود لضمان بقاء التباين موجباً عبر الزمن، بحيث يجب أن تكون جميع المعاملات موجبة ومجموعها اقل من 1 أي $\sum_{i=1}^{Max(p,q)} (\alpha_i + \beta_i) < 1$. ثم أشار الباحثون في دراسات لاحقة لإمكانية تخفيف هذه القيود بحيث يُسمح لبعض المعاملات بأن تكون سالبة دون أن يصبح التباين الشرطي سالباً او معدوماً. كما ينبغي أن تتحقق شروط الاستقرار من الدرجة الثانية كما ذكر في 2.1.2 وبذلك القيود يُضمن بقاء التباين في حدود محدودة واستقرار النموذج إحصائياً (George E.P. Box، 2015، Anese، 2019).

3.3.2 نموذج PTT-GARCH

على الرغم من نجاح نمودجي ARCH و GARCH بتمثيل ديناميكية التقلبات عبر الزمن مما يناسب بشكل خاص تحليل البيانات المالية التي تتسم بتقلبات غير ثابتة وذيل ثقيلة في توزيع العوائد. ولكن خاصية القوة الرافعة لا تتوافر في الدالة التربيعية الخاصة بالنماذج السابقة، كما أن عملية تقدير هذا النموذج تتطلب وجود حدود دنيا من الدرجة الرابعة على الأقل، وقد دفع ذلك الباحثين إلى طرح نماذج أكثر مرونة من أجل تلافي تلك النواقص، وتقديم تمثيل أفضل لعوائد السلاسل المالية، خاصةً في ظل وجود خاصية الذيل الثقيلة (Hamadeh، 2011).

طرح الباحثون في (Kim S. Y., 2004) صيغة مطورة عن النموذج الأخير من خلال إدخال خاصية القوة الرافعة لنموذج GARCH ذو القوة، معتمدين في ذلك على تمييز القيم الموجبة للعملية عن قيمها السالبة بعامل خاص. حيث دعوا نموذجهم المطور بنموذج GARCH ذو العتبة المحول للقوة (Power-Transformed Threshold GARCH)، ورمزوا له اختصاراً PTT-GARCH يُعطى هذا النموذج وفق المعادلة (3).

$$\begin{cases} \epsilon_t = \sigma_t^{1/\delta} z_t \\ \sigma_t = \omega_0 + \sum_{i=1}^q \alpha_{i+} (\epsilon_{t-i}^+)^{\delta} + \alpha_{i-} (-\epsilon_{t-i}^-)^{\delta} + \sum_{j=1}^p \beta_j \sigma_{t-j} \end{cases} \quad (3)$$

بحيث: $\epsilon^+ = \max(\epsilon, 0)$, $\epsilon^- = \min(\epsilon, 0)$, $\delta > 0$, $\omega_0 > 0$, $\alpha_{i+} \geq 0$, $\alpha_{i-} \geq 0$, $\beta_j \geq 0$

نفترض أن z_t متغيرات عشوائية الممثلة لتوزيع (i.i.d) مستقلة زمنياً بحيث يوجد $r > 0$ تحقق $|z_t| < \infty$ استوفى هذا التعميم لخاصة القوة الرافعة من خلال التمييز بين الصدمات الماضية الموجبة والسالبة بمعامل مميز في علاقة التقلبات الشرطية وهذا يعني ان التقلبات الشرطية تعتمد على طويلة واطولة الصدمات الماضية في وقت واحد (Hamadeh, 2011).

4.2 تحليل المشاعر

ما أن برز مصطلح "الروح الحيوانية" منذ نحو 80 عاماً للإشارة إلى التأثيرات النفسية غير العقلانية على سلوك المستثمرين، بدأ الاقتصاديون في محاولة فهم الأسباب الكامنة وراء التحركات الحادة في أسعار الأسهم التي لا تبررها الأساسيات الاقتصادية (Tetlock P. C., 2007). وقد أظهرت الدراسات الرائدة في الثمانينيات أن الأسواق قد تكون عرضة للتسعير الخاطئ، حيث لوحظت تقلبات في العوائد الإجمالية لا يمكن تفسيرها بالتقلبات في المؤشرات الاقتصادية الأساسية، إلى جانب قابلية التنبؤ بالعوائد باستخدام نسب تقييم بسيطة مثل نسبة توزيعات الأرباح إلى القيمة السوقية (Wurgler، 2007). ورغم أن دور المشاعر الاستثمارية كان ضمناً في تلك الدراسات، إلا أن ضعف الأدلة الإحصائية وعدم وضوح التفسير الاقتصادي دفع الباحثين إلى تطوير نماذج سلوكية أكثر دقة.

في هذا السياق، ظهرت نماذج نظرية تفترض وجود نوعين من المستثمرين: متداولون عشوائيون يحملون معتقدات غير عقلانية حول توزيعات الأرباح المستقبلية، ومراجحون عقلانيون يتبعون معتقدات بايزية، لكنهم يواجهون قيوداً تمنعهم من تصحيح التسعير بشكل فعال (Tetlock P. C., 2007) (Wurgler، 2007). وتُظهر هذه النماذج أن تغيرات المشاعر تؤدي إلى صدمات في الطلب، تؤثر على الأسعار وحجم التداول، خاصة في الأسهم التي يصعب تقييمها أو مراجحتها مثل الشركات الصغيرة و غير الربحية أو ذات النمو المرتفع. كما أن توقيت التشاؤم الإعلامي يلعب دوراً مهماً، حيث يمكن أن يعكس مشاعر المستثمرين الماضية أو يتنبأ بالمستقبل، مما يؤدي إلى ضغط هبوطي مؤقت على الأسعار يتبعه ارتداد لاحق نحو الأساسيات (Tetlock P. C., 2007).

وقد أظهرت الدراسات الحديثة أن الأسهم الأكثر حساسية للمشاعر هي تلك التي تتميز بصعوبة تقييمها وارتفاع تكاليف المراجعة المرتبطة بها، مثل الشركات الناشئة أو التي لا توزع أرباحاً أو التي تشهد تقلبات عالية في العوائد (Wurgler، 2007). في المقابل، فإن الأسهم المستقرة ذات العوائد الثابتة والأصول الملموسة تكون أقل عرضة لتأثير المشاعر، وتُظهر سلوكاً أقرب إلى السندات. ويُعزى ذلك إلى أن المستثمرين يميلون إلى المبالغة في تقييم الأصول غير المؤكدة خلال فترات التفاؤل، بينما يتجهون إلى التخفيض المفرط في التقييم خلال فترات التشاؤم، مما يؤدي إلى تقلبات غير مبررة في الأسعار (Wurgler، 2007).

كما تشير النماذج السلوكية إلى أن القيود المفروضة على المراجعة، مثل ارتفاع تكاليف البيع على المكشوف أو تقلبات العوائد الفردية، تحد من قدرة المستثمرين العقلانيين على تصحيح التسعير، مما يسمح باستمرار تأثير المشاعر لفترات أطول (Tetlock P. C., 2007). وتُعد هذه النتائج ذات أهمية خاصة في تفسير سلوك السوق خلال الفقاعات والانهايات، حيث

تلعب المشاعر دورًا محوريًا في تشكيل توقعات المستثمرين وتوجيه قراراتهم الاستثمارية بعيدًا عن الأساسيات الاقتصادية. وفيما يلي نبرز شرحاً لنماذج تحليل المشاعر التي جرى استعمالها لتحليل الأخبار المالية في دراستنا هذه.

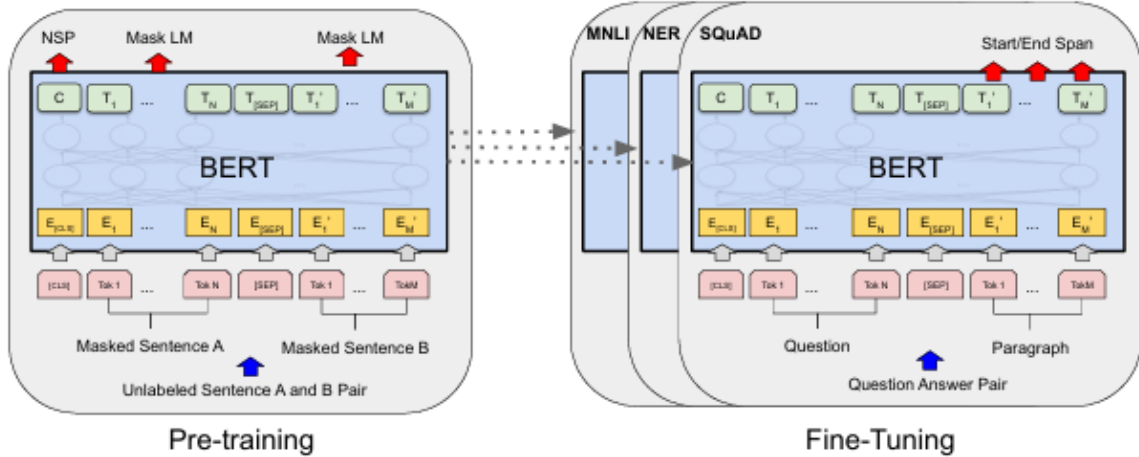
1.4.2 نموذج BERT

تم تطوير نموذج (BERT (Bidirectional Encoder Representations from Transformers) من قبل شركة Google في عام 2018، ويُعد من أبرز النماذج اللغوية في مجال معالجة اللغة الطبيعية. يتميز BERT بقدرته على فهم السياق الكامل للكلمة من خلال النظر إلى ما قبلها وما بعدها في الجملة، وهو ما يُعرف بالتمثيل ثنائي الاتجاه. وقد ساهم هذا النموذج في تحسين أداء العديد من المهام اللغوية مثل تصنيف النصوص، واستخراج الكيانات، والإجابة على الأسئلة، وغيرها (Al-Jallad, 2025).

يعتمد نموذج BERT استراتيجية تدريب مسبق (Pre-training) باستخدام كمية كبيرة من البيانات غير الموسومة، مثل BooksCorpus وويكيبيديا الإنجليزية، ويتم تدريب النموذج على مهمتين أساسيتين لتعزيز فهمه للغة:

- النموذج اللغوي المقنّع (Masked Language Model – MLM) : يتم إخفاء نسبة محددة من الكلمات في الجملة (عادة 15%)، ويُطلب من النموذج التنبؤ بالكلمة الأصلية اعتمادًا على السياق المحيط بها من اليمين واليسار. هذه الطريقة تمكّن النموذج من تعلم تمثيلات عميقة ثنائية الاتجاه، مما يزيد من دقته في فهم المعنى الكامل للنصوص.
- تنبؤ الجملة التالية (Next Sentence Prediction – NSP) : هذه المهمة تدرب النموذج على معرفة العلاقة بين جملتين، بحيث يُطلب من النموذج تحديد ما إذا كانت الجملة الثانية تتبع الجملة الأولى بشكل طبيعي أم أنها جملة عشوائية. تُساعد هذه المهمة في تعزيز قدرة النموذج على فهم العلاقات السياقية بين الجمل، وهو أمر ضروري لمهام مثل استنتاج اللغة الطبيعية (NLI) والإجابة عن الأسئلة (QA)، حيث تتطلب فهم العلاقة بين جملتين أو أكثر لتوليد استنتاج صحيح.

بعد مرحلة التدريب المسبق، يمكن تخصيص نموذج BERT لمهام محددة (Fine-tuning)، حيث يتم تعديل جميع معلمات النموذج على مجموعة بيانات موسومة خاصة بالمهمة، سواء كانت مهام على مستوى الجملة مثل التصنيف، أو على مستوى الكلمة مثل التعرف على الكيانات المسماة أو استخراج المعلومات. النموذج يستخدم رموزًا خاصة مثل [CLS] و [SEP] لترميز بداية الجمل أو فصل الجملتين، ويعتمد على تمثيلات WordPiece لتقسيم الكلمات إلى رموز فرعية، مما يُحسن التعامل مع الكلمات النادرة أو الجديدة يوضح الشكل 6 إجراءات التدريب المسبق (Pre-training) والتعديل الدقيق (Fine-tuning) لنموذج BERT (Lee، Chang، Devlin، و Toutanova، 2018).



الشكل 6 إجراءات التدريب المسبق (Pre-training) والتعديل الدقيق (Fine-tuning) لنموذج BERT

هيكل نموذج BERT يعتمد على محول متعدد الطبقات (Transformer Encoder) ، ويأتي في نسختين رئيسيتين:

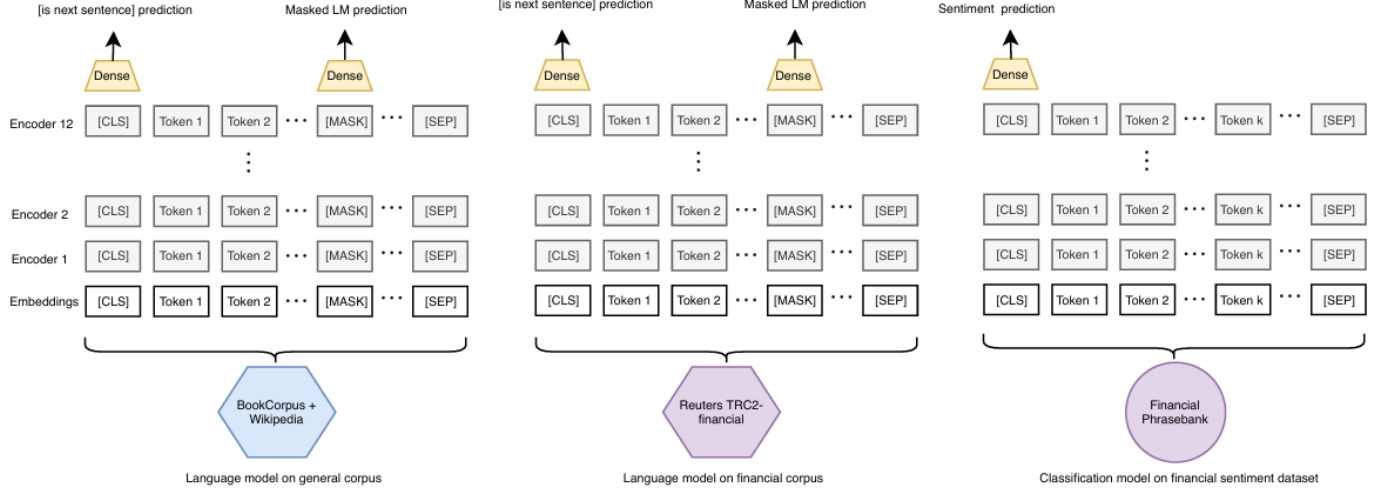
- BERT_BASE : 12 طبقة، 768 وحدة مخفية، 12 رأس انتباه ذاتي، حوالي 110 مليون معلمة.
- BERT_LARGE : 24 طبقة، 1024 وحدة مخفية، 16 رأس انتباه ذاتي، حوالي 340 مليون معلمة.

الميزة الأساسية لنموذج BERT تكمن في تمثيلاته القابلة للتعميم عبر المهام المختلفة، حيث يمكن استخدام نفس النموذج المدرب مسبقًا لمجموعة واسعة من مهام معالجة اللغة الطبيعية بدون الحاجة لتصميم معماري خاص لكل مهمة، مما يجعله أداة قوية ومرنة لتحسين الأداء على المهام التي تتطلب فهم دقيق للسياق النصي والجملي. وقد أثبتت التجارب أن BERT يتفوق على العديد من النماذج السابقة في المهام القائمة على الجملة أو الكلمة، محققًا أداءً متقدمًا على مجموعة واسعة من الاختبارات القياسية في معالجة اللغة الطبيعية (Devlin، Chang، Lee، و Toutanova، 2018).

2.4.2 نموذج FinBERT

يُعد FinBERT نسخة متخصصة من نموذج BERT، مصممة خصيصًا لمعالجة النصوص المالية وتحليل المشاعر في هذا المجال. بينما تم تدريب نموذج BERT على مجموعات بيانات عامة واسعة النطاق مثل ويكيبيديا و BookCorpus، فإن هذا التدريب العام لا يوفر فهمًا كافيًا للمصطلحات والسياقات المالية الدقيقة، مما قد يحد من دقة النموذج عند تطبيقه على نصوص مالية متخصصة.

يقدم FinBERT تحسینًا رئيسيًا عبر التدريب الإضافي على نصوص مالية متخصصة، سواء باستخدام مجموعة نصوص كبيرة من المجال المالي مثل TRC2-financial، أو من خلال استخدام الجمل الموجودة في مجموعة بيانات تصنيف المشاعر المالية مباشرة. هذا التدريب المستهدف يتيح للنموذج التكيف مع المصطلحات المالية الدقيقة والتعابير الخاصة بالأسواق والشركات، مما يؤدي إلى تعزيز دقة التصنيف وفهم السياق المالي مقارنة بنموذج BERT الأصلي.



صُمم FinBERT لتنفيذ مهام تصنيف المشاعر المالية عبر إضافة طبقة كثيفة بعد رمز [CLS]، بهدف تصنيف الجمل إلى مشاعر إيجابية، سلبية أو محايدة. كما تم توسيع إمكانياته لتشمل مهام الانحدار المالي، حيث يمكنه التنبؤ بقيم مستمرة تمثل درجة التأثير المالي للجمل، باستخدام دالة RMSE بدلاً من دالة خسارة الانتروبيا المتصالبة التقليدية المستخدمة في التصنيف.

تعالج استراتيجية FinBERT أيضًا مشكلة النسيان الكارثي التي قد تنشأ عند تخصيص نموذج مدرب مسبقًا لمجال محدد، من خلال تطبيق عدة تقنيات تدريب متقدمة، بما في ذلك معدلات التعلم المثلثية المائلة، التخصيص التمييزي لمعدل التعلم بين الطبقات، والإلغاء التدريجي لتجميد الطبقات. تساعد هذه الاستراتيجيات النموذج على الحفاظ على المعرفة المكتسبة مسبقًا أثناء تدريبه على النصوص المالية، وبالتالي تحقيق استقرار أفضل وأداء محسّن على بيانات المجال المالي.

أظهرت التجارب أن FinBERT يتفوق على نموذج BERT العام والنماذج التقليدية مثل LSTM وELMo وULMFit في دقة التصنيف وF1-score، خصوصًا على الجمل التي اتفق عليها جميع المصنفين. كما أن FinBERT قادر على التكيف مع بيانات مالية محددة لكل شركة أو قطاع، مما يجعله أداة فعّالة لتحليل المشاعر المالية واستنتاج مؤشرات دقيقة لاتخاذ القرارات الاستثمارية (Araci, 2019).

3.4.2 نموذج VADER

تم تطوير نموذج VADER (Valence Aware Dictionary and Sentiment Reasoner) عام 2014 على يد الباحثين Eric Gilbert و C.J. Hutto بهدف معالجة التحديات الفريدة التي تطرحها النصوص الاجتماعية القصيرة مثل التغريدات، التعليقات والمراجعات. تمتاز هذه النصوص بخصائص تجعل تحليلها صعبًا على النماذج التقليدية إذ غالبًا ما تكون غير رسمية، وتحتوي على اختصارات ورموز تعبيرية وتعابير ساخرة يصعب تفسيرها بدقة. جاء تطوير VADER لتقديم مقارنة قائمة على القاموس اللغوي والقواعد النحوية، قادرة على تحليل المشاعر دون الحاجة إلى بيانات تدريب ضخمة أو نماذج تعلم معقدة (Youvan, 2024).

يعتمد VADER على قاموس مكوّن من آلاف الكلمات والعبارات المرتبطة بمشاعر محددة، تم تقييمها بشريًا لضمان دقة التصنيف. وتُمنح كل كلمة أو عبارة درجة شعورية تتراوح بين -4 (سلبية جدًا) و+4 (إيجابية جدًا). وبالإضافة للقاموس يتضمن النموذج مجموعة من القواعد اللغوية التي تراعي تأثيرات عناصر لغوية مثل التوكيد (على سبيل المثال "جيد جدًا")، والنفي ("ليس جيدًا")، وعلامات الترقيم ("!") في تحديد شدة المشاعر. واعتماداً على ما سبق يُنتج النموذج ما يُعرف بـ الدرجة المركبة، وهي قيمة عددية تتراوح بين -1 و+1 تعبر عن الاتجاه العام للمشاعر في النص، مما يسمح بتصنيف المحتوى إلى إيجابي أو سلبي أو محايد بطريقة سهلة التفسير وفعالة في التطبيقات العملية (Youvan, 2024).

ورغم أن VADER يُعد من النماذج القائمة على القواميس، فإنه يتفوق على كثير من النماذج المماثلة بفضل دمجها بين القواعد اللغوية الدقيقة والتقييم البشري الموثوق. وفي المقابل تعتمد النماذج القائمة على التعلم الآلي (Machine Learning)، مثل SVM و Naïve Bayes على تدريب خوارزميات على بيانات مصنفة مسبقًا، ما يمنحها قدرة أكبر على التعميم لكنها تتطلب موارد وبيانات ضخمة. أما النماذج المبنية على التعلم العميق مثل BERT فهي قادرة على فهم السياق العميق للنصوص إلا أنها أكثر تعقيدًا وأقل قابلية للتفسير وتحتاج إلى بنية تحتية قوية للحوسبة (Youvan, 2024).

وقد أثبت نموذج VADER مرونته العالية في التعامل مع أنواع مختلفة من البيانات النصية، إذ تم استخدامه في العديد من المجالات لتحديد الاتجاه الشعوري بدقة من خلال إنتاج قيمة رقمية تعبر عن شدة المشاعر في النصوص المدخلة. وتشير القيم الموجبة إلى وجود مشاعر إيجابية، بينما تدل القيم السالبة على مشاعر سلبية. ورغم أن النموذج طُوّر في البداية لتحليل النصوص المكتوبة باللغة الإنجليزية، فقد تم توسيعه وتكييفه لاحقًا ليدعم لغات أخرى مثل الألمانية وذلك بعد إجراء تعديلات مناسبة على القاموس والقواعد اللغوية لتمكينه من تحليل المشاعر بكفاءة في بيئات لغوية متعددة (Ajdari, 2023).

كما أثبتت الدراسات الحديثة أن نموذج VADER أظهر أداءً فعّالاً في تحليل المشاعر في مجالات متنوعة، تشمل مراجعات المنتجات والأخبار والمحتوى الإعلامي و البيانات المالية، بفضل بنيته المعتمدة على قاموس المشاعر المدعوم بالقواعد اللغوية الدقيقة. وتُبرز هذه النتائج قدرة النموذج على التكيف مع أنماط لغوية مختلفة، ما يجعله أداة قوية وموثوقة لتحليل المشاعر عبر منصات متعددة سواء في الأبحاث الأكاديمية أو في التطبيقات الصناعية (Ajdari, 2023).

الفصل الثالث

الدراسة المرجعية

1.3 دراسة (Mitra، Atkinson، و Yu، 2016)

تم نشر هذا البحث عام 2016 بعنوان *Volatility Forecast Using GARCH, News Sentiment and Implied Volatility*

تهدف هذه الدراسة إلى تحليل تقلبات عوائد خمسة أسهم مدرجة ضمن مؤشر S&P500 خلال الفترة من أبريل 2010 حتى يوليو 2016، وذلك من خلال تقييم أداء ثلاثة نماذج من نماذج GARCH، وهي: GARCH و EGARCH و GJR-GARCH. وقد تم تعزيز التحليل بإدراج متغيرات خارجية خطية لتحسين قدرة GJR-GARCH على التنبؤ بالتقلبات مثل التقلب الضمني، وتأثير الأخبار المستخرجة آلياً عبر RavenPack، بالإضافة إلى عدد الأخبار المنشورة يوميًا، ومتغير ثنائي يأخذ القيمة 1 في حال وجود خبر متعلق بالسهم في يوم معين و0 في حال عدم وجوده.

تم تحويل أسعار الإغلاق المعدلة إلى عوائد يومية لتسهيل التحليل الإحصائي وفق المعادلة (4)، كما تم تقسيم العينة إلى جزأين: بيانات داخل العينة (1074 نقطة) وبيانات خارج العينة (500 نقطة).

$$\varepsilon_t = 100 \times \log \left(\frac{P_t}{P_{t-1}} \right) \quad (4)$$

عزّفت الدراسة بيانات التقلب الضمني بأنها تقديرات السوق لمستوى التقلب المستقبلي لسعر الأصل المالي، ويتم استنتاجها من أسعار الخيارات المتداولة في السوق. تم احتساب القيم اليومية للتقلب الضمني IV على أساس متوسط متحرك لفترة 20 يومًا وفقًا للبيانات المقدمة من شركة Northfield Information Services.

ثم احتسب الانحراف المعياري المكافئ للتقلب الضمني والمُقاس لفترة زمنية وفق (5).

$$\sigma_{IV}^2 = \sqrt{\frac{H}{N}} \times IV \quad (5)$$

حيث N=252 يوم تداول في السنة وH=1 لبيانات يومية.

أما درجة تأثير الاخبار (News Sentiment Score) فهي قياس رقمي يعكس مزاج المستثمرين تجاه الخبر، وقد تم استخدامها لحساب أثر المشاعر الإخبارية والتي تأخذ في الحسبان كلاً من حجم الأخبار ومعدل تلاشي أثرها مع مرور الوقت وفق الصيغ:

$$PImpact(t) = \sum_{k \in POS} PNews(k, tk) e^{-\lambda(t-tk)}$$

$$NImpact(t) = \sum_{k \in NEG} NNews(k, tk) e^{-\lambda(t-tk)}$$

حيث يمثّل PImpact أثر الأخبار الإيجابية، وNImpact أثر الأخبار السلبية، بينما λ هو معدل التلاشي الذي تم ضبطه عند 180 دقيقة ليعكس نصف العمر الزمني لتأثير الخبر. كما استخدمت طريقة الاحتمالية العظمى شبه القصى لتقدير جميع

معاملات النموذج كما تم اختيار معامل AIC لاختيار أفضل نموذج لتقلبات أسعار الأسهم من بين مجموعة من النماذج الثلاثة المرشحة.

كشفت نتائج اختبار Jarque–Bera عن وجود تفرطح مرتفع (ذيول ثقيلة) وانحراف واضح عن التوزيع الطبيعي في بيانات العوائد، مما يشير إلى عدم ملاءمة الفرضية الطبيعية التقليدية. ولذلك تم اعتماد توزيع Student-t في تقدير النماذج.

أظهرت نتائج الدراسة أن نموذج (1,1) GJR-GARCH باستخدام توزيع Student-t قدّم أفضل أداء داخل العينة مقارنة بالنماذج GARCH وEGARCH. وعند إدخال التقلب الضمني كمتغير خارجي، تحسّن أداء النماذج التي أظهرت دلالة إحصائية لهذا المتغير. لكن عند الجمع بين التقلب الضمني وباقي المتغيرات الخارجية انخفضت جودة النموذج بسبب الإفراط في التخصيص.

STOCK	GARCH(1,1)	GJRGARCH(1,1)	EGARCH(1,1)
JPM	LL: 2869.624	LL: 2882.753	LL: 2880.516
	AIC: -5.3413	AIC: -5.3639	AIC: -5.3598
NEM	LL: 2662.687	LL: 2664.827	LL: 2661.982
	AIC: -4.9556	AIC: -4.9577	AIC: -4.9523
KO	LL: 3504.824	LL: 3517.765	LL: 3520.085
	AIC: -6.5253	AIC: -6.5476	AIC: -6.5519
PNC	LL: 2771.497	LL: 2775.927	LL: 2775.062
	AIC: -5.5441	AIC: -5.5510	AIC: -5.5492
MSFT	LL: 3066.438	LL: 3068.563	LL: 3056.867
	AIC: -5.6764	AIC: -5.6785	AIC: -5.6568

جدول 1 مقارنة أداء النماذج الثلاثة في المرجع (Atkinson، Mitra، وYu، 2016)

	Implied Volatility	IV & Impact Score	IV & Log News Flow	IV & Binary Variable
JPM	LL: 2907.72 AIC: -5.4067	LL: 2909.688 AIC: -5.4067	LL: 2908.942 AIC: -5.4072	LL: 2908.555 AIC: -5.4064
Rank	3	3	1	2
NEM	LL: 2688.133 AIC: -4.9956	LL: 2689.574 AIC: -4.9945	LL: 2689.318 AIC: -4.9959	LL: 2688.484 AIC: -4.9944
Rank	2	3	1	4
KO	LL: 3548.83 AIC: -6.6017	LL: 3550.988 AIC: -6.6020	LL: 3549.24 AIC: -6.6006	LL: 3548.938 AIC: -6.6001
Rank	2	1	3	4
PNC	LL: 2775.927 AIC: -5.5490	LL: 2775.658 AIC: -5.5444	LL: 2775.927 AIC: -5.5469	LL: 2775.928 AIC: -5.5469
Rank	1	4	2	2
MSFT	LL: 3135.24 AIC: -5.7984	LL: 3135.905 AIC: -5.7959	LL: 3135.741 AIC: -5.7975	LL: 3133.44 AIC: -5.7932
Rank	1	3	2	4
Score	9	14	9	16

جدول 2 المقارنة بين المؤثرات الخارجية بوجود تقلب ضمني في المرجع (Mitra, Atkinson, و Yu، 2016)

أظهرت النتائج في التنبؤ خارج العينة أن النماذج المعقدة حسنت دقة التنبؤ لثلاثة أسهم من أصل خمسة وهذا يشير إلى أن الأداء الأفضل داخل العينة لا يُترجم بالضرورة إلى تحسن في الأداء خارج العينة، كما تبين أن إدراج التقلب الضمني بمفرده أدى إلى تحسين التوقعات في أربع حالات من أصل خمس، مما يبرز دوره المهم في تعزيز دقة النماذج التنبؤية.

	AIC (In-Sample)		MAE		RMSE	
	Simple	Complex	Simple	Complex	Simple	Complex
JPM	-5.3413	-5.4079	0.014248	0.013991	0.014749	0.014611
NEM	- 4.9556	-4.9967	0.025871	0.025572	0.026424	0.026122
KO	-6.5253	- 6.6021	0.009333	0.009441	0.009482	0.009735
PNC	- 5.5048	-5.5510	0.012316	0.012323	0.012647	0.012746
MSFT	- 5.6764	-5.7984	0.014823	0.013853	0.015014	0.014255

جدول 3 نتائج خارج العينة في المرجع (Mitra, Atkinson, و Yu، 2016)

2.3 دراسة (Shi & Ho, 2020)

تم نشر هذه الورقة عام 2020 بعنوان News sentiment and states of stock return volatility: long memory and discrete choice models

تتناول هذه الدراسة أثر الرسائل الإخبارية اللحظية على حالات التقلب عالي التردد للأسهم المتداولة ضمن مؤشر داو جونز المرگب (DJN65) خلال الفترة الممتدة بين عامي 2000 و 2017. تم الحصول على هذه الرسائل من قاعدة بيانات

RavenPack News Analytics – Dow Jones Edition، التي تُعدّ من أكثر قواعد البيانات شمولاً، إذ تحتوي على أكثر من 1200 نوع من الأخبار المتعلقة بالشركات والأحداث الاقتصادية الكلية، حيث اعتمدت الدراسة على قاعدة البيانات RavenPack News Analytics لاستخراج مجموعة من المتغيرات التي تمثل حجم الأخبار وتأثيرها على السوق مثل (تكرار الأخبار، والمعنويات، والأهمية، والحدثة) ثم تم توظيف تلك المتغيرات لحساب مؤشرات رقمية تقيس الأثر الكلي للأخبار هي: درجة الملاءمة (Relevance) لكل خبر بالنسبة للشركة/الكيان ومؤشر المعنويات المركّب (Composite Sentiment Score) و معنويات الحدث (Event Sentiment Score) وحدثة/فردة الحدث (Event Novelty Score).

وبالإضافة إلى هذه المتغيرات المرجحة لعدد الأخبار، أنشأت الدراسة أربعة متغيرات ثنائية لتمييز أنواع الأخبار بحسب طبيعتها ومصدرها. يُعطى المتغير الثنائي قيمة 1 إذا كان المتغير المرجح لعدد الأخبار لا يساوي صفراً، وقيمة 0 خلاف ذلك. وقد رُمز إلى هذه المتغيرات بما يلي:

- $DN_{f,t}$: متغير ثنائي للأخبار السلبية الخاصة بالشركات.
- $DP_{f,t}$: متغير ثنائي للأخبار الإيجابية الخاصة بالشركات.
- $DN_{m,t}$: متغير ثنائي للأخبار السلبية الاقتصادية الكلية.
- $DP_{m,t}$: متغير ثنائي للأخبار الإيجابية الاقتصادية الكلية.

حُسب العائد اللحظي (بالساعة) وذلك لالتقاط التغير النسبي بدقة وتقليل تأثير المقاييس المطلقة للأسعار وفق المعادلة (4). وقد ذكرت الدراسة أن لكل شركة في المتوسط خبراً واحداً تقريباً في الساعة، ما يجعل التواتر الأعلى (مثل دقائق) غير موثوق بسبب ندرة الأخبار على تلك الفواصل الزمنية.

اعتمدت الدراسة نماذج A-FIEGARCH و TV-FIEGARCH المشتقة من النموذج الأصلي FIEGARCH الذي يُعتبر امتداداً لعائلة نماذج GARCH يهدف إلى تحليل خاصية الذاكرة الطويلة في تقلبات الأسعار وقد ذُكر تعريف النماذج الثلاثة السابقة في المعادلة رقم (6). أشارت الدراسة إلى أن ضعف النموذج FIEGARCH يتمثل في افتراضه أن التقلب الشرطي ثابت ضمن نظام واحد طوال فترة الدراسة، مما قد يؤدي إلى تقديرات مضللة لطول الذاكرة في تباين السلسلة الزمنية. لذا طوّرت الدراسة نموذجاً أكثر تطوراً هو MRS-FIEGARCH، الذي يجمع بين خصائص نموذج FIEGARCH وآلية تبدل الأنظمة Markov Regime-Switching (MRS).

$$r_t = \mu + \epsilon_t, \quad \epsilon_t = \eta_t \sqrt{h_t}$$

$$(1 - \phi L)(1 - L)^d \log \sigma_t = \omega_t + \beta |\eta_{t-1}| + \gamma \eta_{t-1}$$

$$\omega_t = \begin{cases} \omega, & \text{FIEGARCH} \\ \sum_{j=1}^K \left[\gamma_j \sin\left(\frac{2\pi jt}{T}\right) + \delta_j \cos\left(\frac{2\pi jt}{T}\right) \right], & \text{A-FIEGARCH} \\ \sum_{r=1}^R \omega_r F_r(s_t, \alpha_r, c_r), & \text{TV-FIEGARCH} \end{cases} \quad (6)$$

حيث:

- ϵ_t : هو الصدمة عند الزمن t.
- σ_t : هو التباين الشرطي ل ϵ_t عند الزمن t.
- η_t : سلسلة مستقلة وموزعة بالتساوي وفق توزيع محدد.
- T: هو عدد الملاحظات.
- L: مؤثر الإزاحة (Lag Operator).
- $(L-1)^d$: مؤثر الفروق الكسرية.
- d: معامل الذاكرة الطويلة.

تختلف قيمة ω_t باختلاف النموذج المستخدم: فهي ثابتة في FIEGARCH و مجموع توافقي (sine و cosine) في A-FIEGARCH كما انها تعتمد على دوال لوجستية في TV-FIEGARCH . إذا كان $\gamma \neq 0$ ، فهذا يعني أن النموذج يسمح بتأثير الرافعة المالية. عندما يكون $0 < d < 0.5$ ، تكون سلسلة $\{\log \sigma_t\}$ ثابتة ولها ذاكرة طويلة. إذا كان $d < 0$ ، فإن $\{\log \sigma_t\}$ تتمتع بذاكرة قصيرة فقط. عند $d=0$ ، يتبسط نموذج FIEGARCH ليصبح نموذج EGARCH التقليدي.

في نموذج TV-FIEGARCH، $s_t = t/T$ ، $F(s_t, \alpha_r, c_r) = (1 + \exp\{-\alpha_r(s_t - c_r)\})^{-1}$ ويجب أن يكون $\alpha_r > 0$ ، و c_r تخضع للقيود $c_1 \leq c_2 \leq \dots \leq c_R$ حيث يعبر R في TV-FIEGARCH على عدد التغيرات الهيكلية .

دمجت الدراسة صيغة MRS-GARCH ثنائية الحالة مع إطار عمل FIEGARCH، مع السماح للمعامل ω_t بالتغير بين الحالات. النموذج المقترح MRS-FIEGARCH مع ابتكار توزيع Student-t المائل (skewed Student-t) موصوف كما في المعادلة (7).

$$\begin{aligned}
r_t &= \mu + \varepsilon_t \\
\varepsilon_t &= \eta_t \sqrt{\sigma_{t,s_t}}, \quad \eta_t \stackrel{i.i.d}{\sim} skt(\xi, \nu) \\
(1-\phi L)(1-L)^d \log \sigma_t &= \begin{cases} \omega_1 + \beta |\sigma_{t-1}| + \gamma \eta_{t-1}, & s_t = 1 \\ \omega_2 + \beta |\sigma_{t-1}| + \gamma \eta_{t-1}, & s_t = 2 \end{cases}
\end{aligned} \tag{7}$$

حيث:

- ε_t : الصدمة عند الزمن t.
- r_t العائد عند الزمن t.
- $\sigma_{s_t,t}$ التباين الشرطي في الحالة s_t عند الزمن t.
- η_t : متغير عشوائي مستقل وموزع وفق توزيع Student-t المائل بمعامل ميل ξ ودرجة حرية ν .
- T: عدد المشاهدات.
- L: مؤثر الإزاحة (Lag Operator).
- $(L-1)^d$: مؤثر الفروق الكسرية.
- d: معامل الذاكرة الطويلة.
- s_t الحالة التي يوجد فيها السهم عند الزمن t وهي إما 1 وتعني التقلب المنخفض أو 2 ويعني التقلب المرتفع.

قُدرت معاملات نموذج MRS-FIEGARCH باستخدام طريقة الاحتمالية العظمى QMLE. كما استخدمت معادلة احتمالية التنعيم (Smoothing Probability) للحالة منخفضة التقلب كما هو موضح في المعادلة رقم (8) بغرض تحديد الحالة التي ينتمي إليها عائد السهم عند الزمن t

$$P(s_t = 1 | \Theta, \Omega_T) = f_{1,t} \left[\frac{p_{11} P(s_{t+1} = 1 | \Theta, \Omega_T)}{P(s_{t+1} = 1 | \Theta, \Omega_t)} + \frac{p_{12} P(s_{t+1} = 2 | \Theta, \Omega_T)}{P(s_{t+1} = 2 | \Theta, \Omega_t)} \right] \tag{8}$$

- Ω_{t-1} : مجموعة المعلومات عند الزمن t-1.
- Θ : متجه المعاملات (Vector of parameters).
- $f_{j,t-1}$: الاحتمالية المُفلترة لوجود السهم في الحالة j عند الزمن t-1.
- $p_{jk} = P(s_{t+1} = k | s_t = j)$ وهي احتمال الانتقال من الحالة j إلى الحالة k

وقد وظفت الدراسة نموذج Markov Regime-Switching (MRS) لتحديد الحالات الكامنة¹ حيث تم تصنيف السوق إلى ثلاث حالات رئيسية: هادئة، متوسطة، ومضطربة، بالاعتماد على المعادلة رقم (8) اعتُبرت الحالة هادئة عندما كانت الاحتمالية مرتفعة ($0.8 \leq$)، ومضطربة عندما كانت منخفضة ($0.2 \geq$)، ومتوسطة عندما كانت بينهما. ولتعزيز قوة النتائج استخدم الباحثون أيضًا تصنيفًا ثنائيًا تقليديًا يعتمد على حدّ فاصل مقداره 0.5، بحيث تمثل القيم الأعلى الحالة الهادئة، والأدنى الحالة المضطربة.

وقد جرى تقدير النموذجين التاليين بالاعتماد على نماذج (Logit) و (Probit)، سواء في التصنيف الثلاثي أو الثنائي للحالات:

$$\begin{aligned} \text{Null Model: } U_t &= \lambda_0 + \varepsilon_t \\ \text{Full Model: } U_t &= \lambda_0 + \lambda \text{News}_t + \varepsilon_t \end{aligned} \quad (9)$$

حيث يُمثل U_t المنفعة الكامنة (Latent Utility) للمتغير Y_t والتي يتم تحديد صيغتها وفقًا لنماذج (Logit) و (Probit) ويمثل News_t متجه المتغيرات الإخبارية عند الزمن t ، بينما تشير λ إلى شعاع المعاملات المرتبطة والذي يقيس الأثر الحدي (Marginal Impacts) لهذه المتغيرات الإخبارية.

قارنت الدراسة أداء النماذج الثلاثة من خلال التنبؤ داخل العينة (In-sample Forecasting) عبر حساب التقلب المحقق داخل الفترات (RLV) باستخدام العوائد اللحظية بفواصل 5 دقائق. تم حساب متوسط مربع الخطأ (MSE) للأداء التنبؤي وفقًا للمعادلة:

$$MSE = \frac{1}{T} \sum_{t=1}^T (RLV_t - \hat{\sigma}_t)^2$$

حيث $\hat{\sigma}_t$ هو التباين الشرطي المقدر من نماذج عائلة FIEGARCH عند الزمن t ، و T هو حجم العينة. كما تم احتساب معايير اختيار المعاملات الأكثر شيوعًا مثل AIC و BIC لكل النماذج الثلاثة.

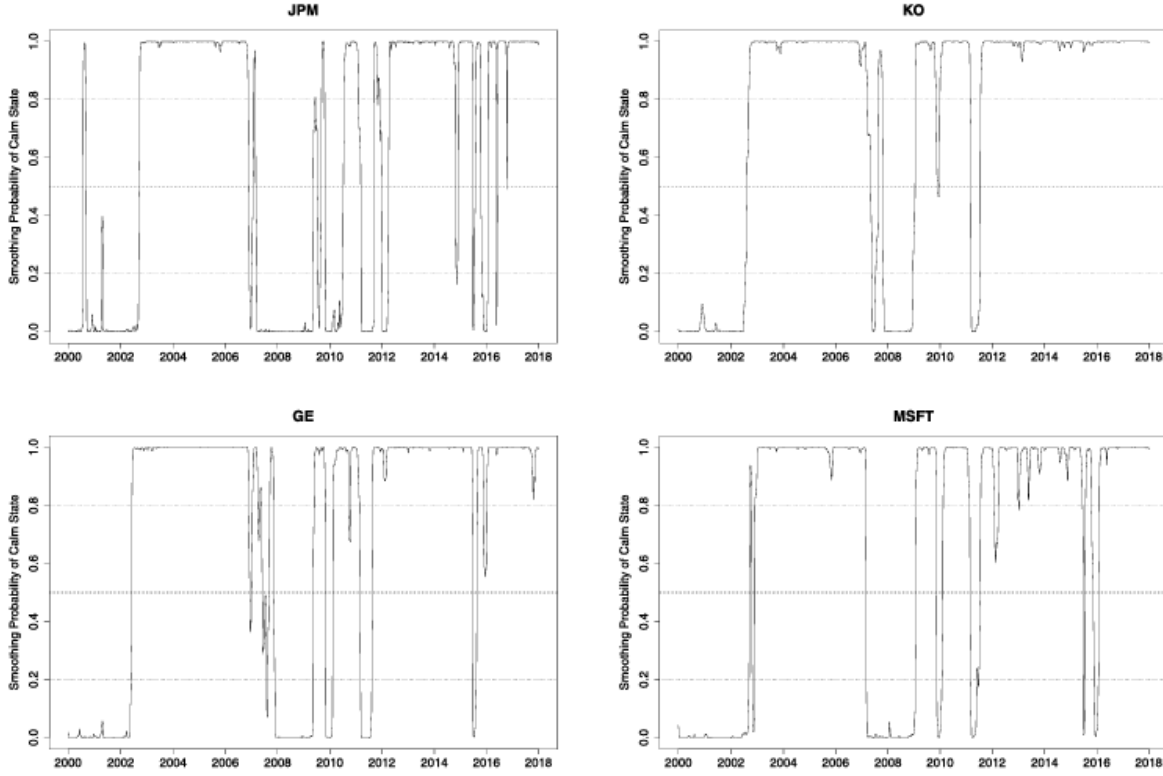
تشير النتائج في جدول 4 إلى أن نموذج MRS-FIEGARCH حقق أقل متوسطًا للتقديرات d وأقل قيم J MSE و AIC و BIC، مما يدل على أن هذا النموذج يتفوق عمومًا على كلٍّ من A-FIEGARCH و TV-FIEGARCH من حيث نمذجة التغيرات الهيكلية وأداء التنبؤ. وبناءً على ذلك سيتم استخدام التباين الشرطي المقدر $\hat{\sigma}_t$ من نموذج MRS-FIEGARCH كمؤشر للتقلب الكامن لعوائد الأسهم.

¹ هي الفترات التي يمر فيها السوق المالي بمستويات مختلفة من التقلب، والتي لا يمكن ملاحظتها بشكل مباشر في البيانات

	Mean	Std. dev.	Median	Q1	Q3	Skew
Panel A: A-FIEGARCH models						
d	0.4888	0.1043	0.4655	0.4498	0.4872	2.9328
MSE	10.8656	50.4317	1.0671	0.3960	2.1368	4.5519
AIC	37,713	9765	37,370	30,363	45,515	0.0237
BIC	37,777	9765	37,434	30,426	45,579	0.0237
Panel B: TV-FIEGARCH models						
d	0.4821	0.1122	0.4834	0.4300	0.5046	2.7054
MSE	10.8454	50.9804	1.0904	0.4192	2.0631	4.5548
AIC	37,704	9769	37,371	30,368	45,507	0.0240
BIC	37,775	9769	37,442	30,440	45,579	0.0240
Panel C: MRS-FIEGARCH models						
d	0.3968	0.1678	0.3757	0.3272	0.4491	1.4180
MSE	9.9085	49.4089	1.0448	0.3211	2.1721	4.3579
AIC	37,671	9758	37,331	30,344	45,471	0.0233
BIC	37,743	9758	37,402	30,416	45,542	0.0233

جدول 4 المعاملات طويلة الذاكرة وأداء النماذج لعائلة نماذج FIEGARCH

كما تم استخدام المعادلة (8) حالات تقلب عوائد الاسهم. وبالنظر إلى الشكل 8 يمكن ملاحظة أن منحنيات الاحتمال لجميع الشركات الأربع متشابهة تقريباً؛ حيث تميل الاحتمالات إلى الاقتراب من الصفر خلال الفترة 2000-2002، ثم ترتفع إلى حوالي 1 حتى عام 2007، لتعود وتنخفض مرة أخرى بعد ذلك، ثم تعاود الارتفاع إلى مستويات قريبة من 1 بعد عام 2012 مع بعض الاضطرابات الطفيفة. هذه الاتجاهات تتماشى مع حدثين اقتصاديين رئيسيين هما انفجار فقاعة الدوت كوم (2000-2002) والأزمة المالية العالمية (2007-2010).



الشكل 8 احتمال تنعيم الحالة الهادئة في دراسة (Shi و Ho، 2020)

ثم عمد الباحثون على إدخال المتغيرات $WNN_{f,t}$, $WNP_{f,t}$, $WNN_{m,t}$, $WNP_{m,t}$ في المعادلة (9) عبر المتغير $News_t$ وذلك باستخدام نماذج (Logit) و (Probit) المرتبة من أجل دراسة العلاقة بين الأخبار وتقلبات السوق عبر تصنيف ثلاثي وثنائي للحالات.

أظهرت نتائج النماذج أن كلاً من الأخبار السلبية والإيجابية الاقتصادية الكلية لهما تأثير هامشي معنوي على حالات التقلب، حيث تزيد الأخبار السلبية من احتمالية انتقال السوق إلى حالة تقلب مرتفعة، بينما تؤدي الأخبار الإيجابية الاقتصادية إلى انخفاض واضح في احتمال التقلب العالي. كما بينت النتائج أن تأثير الأخبار الخاصة بالشركات يسير في الاتجاه ذاته وإن كان بدرجة أقل.

وأشارت المقارنات بين النماذج إلى توافق واتساق النتائج عبر التصنيفات الثلاثية والثنائية، مما يعزز فرضية أن كلاً من عدد الأخبار ومحتواها المعنوي يلعبان دورًا مؤثرًا في تحديد حالة تقلب السوق المالي.

3.3 دراسة (Sadik & Mitra, 2018)

تم نشر هذه الورقة عام 2018 بعنوان *News Augmented GARCH (1,1) Model for Volatility Prediction* شملت الدراسة 12 أصلاً من مؤشري FTSE100 وEUROSTOXX50، موزعة على سبعة قطاعات مختلفة، خلال الفترة من 2005 إلى 2015. تم استخدام نافذة متحركة بطول 750 ملاحظة، مقسمة إلى عينات داخل العينة (500 ملاحظة) لتقدير النموذج، وخارج العينة (250 ملاحظة) لتقييم التنبؤ. العوائد اليومية محسوبة بالفرق اللوغاريتمي بين أسعار الإغلاق لأيام متتالية. تم حساب العوائد اليومية (r_t) على أنها العوائد المركبة بشكل مستمر، والممثلة في الفرق اللوغاريتمي بين أسعار الإغلاق لأيام متتالية:

$$r_t = \ln \left(\frac{P_t}{P_{t-1}} \right)$$

اقترحت الدراسة نموذج تأثير الاخبار يهدف إلى تحويل الأخبار اليومية إلى مؤشرات كمية بغرض استخدامها كمتغيرات خارجية في نماذج التنبؤ بتقلبات الأسعار مثل نموذج GARCH (1,1) يتم ذلك عبر قياس التأثير الإيجابي والسلبي لكل خبر على حدة، مع مراعاة تناقص أثر الخبر بمرور الزمن. يُفترض في هذه الدراسة أن جميع الأخبار المرتبطة بأصل مالي معين، والتي نُشرت في الماضي، تؤثر على تقلبات أسعار ذلك الأصل عند الفترة الزمنية الحالية t . ويتم قياس درجة التأثير الإخباري لخبر سابق N_a^d عند الزمن t بالمعادلة:

$$I_t(N_a^d) = S(N_a^d)e^{-\lambda t} \quad (10)$$

- $S(N_a^d)$: درجة الشعور (Sentiment Score) للخبر المتعلق بالسهم a خلال يوم d .
 - λ : معامل التلاشي (Decay Parameter) الذي يُحدد معدل انخفاض التأثير بمرور الزمن وقد تم اختيار قيمة λ بحيث ينخفض التأثير إلى نصف قيمته الأصلية خلال فترة زمنية معينة.
- اعتمدت الدراسة على تصنيف التأثيرات الإيجابية والسلبية بشكل منفصل لتفادي الإلغاء (Cancellation) الذي قد يؤدي إلى تقليل حجم التدفق الإخباري أو إعطاء دلالات مضللة.

ثم اقترح الباحثون نموذج NA-GARCH وهو نسخة مُقيّسة من نموذج GARCH يدمج تأثير الأخبار بشكل ضربي مع معادلة التباين في GARCH (1,1)، لتصبح معادلة التباين في NA-GARCH (1,1) وفق العلاقة (11):

$$\begin{aligned} r_t &= \mu + \epsilon_t \\ \epsilon_t &= z_t \sigma_t, \quad z_t \sim \text{i.i.d.}(0,1), \quad E(z_t) = 0, \quad \text{var}(z_t) = 1 \\ \sigma_t^2 &= f(P_t, N_t) (\omega + \alpha \epsilon_{t-1}^2 + \beta \sigma_{t-1}^2) \end{aligned} \quad (11)$$

حيث $f(P_t, N_t)$ دالة تمثل دالة قياس لتأثير الأخبار الموجبة P_t والسالبة N_t والمعرفة بالشكل التالي:

$$f(P_t, N_t) = a + 0.5 * b \left(\frac{e^{\kappa P_t} - 1}{e^{\kappa P_t} + 1} - \frac{e^{\gamma N_t} - 1}{e^{\gamma N_t} + 1} \right) \quad (12)$$

وقد برر الباحثون اقتراح دالة القياس بالصيغة الرياضية وفق (12) بأنها تصل إلى أقصى قيمة لها فقط عندما يكون $P_t = 1$ أو $N_t = -1$ ، وهذا يعني زيادة التقلبات كلما ارتفعت قيم درجات تأثير الأخبار الإيجابية والسلبية وتنخفض عندما تنخفض هذه القيم. أما a, b, κ, γ فهي معاملات النموذج وهي دائماً موجبة، مع الالتزام بشرط $0.5 \leq a + b \leq 2$ وبهذا يُضمن بقاء المقاييس المعدلة للتقلبات ضمن نطاق معقول ومستقر أثناء التنبؤ.

عمد الباحثون على استخدام دالة الاحتمالية العظمى (Quasi Maximum Likelihood Estimation - QMLE) لتقدير معاملات النماذج وقد تم مقارنة أداء ثلاثة نماذج مختلفة على بيانات متعددة تشمل جميع الأصول في كلا المؤشرين، وهي نموذج GARCH البسيط، نموذج EGARCH، ونموذج NA-GARCH. اعتمدت الدراسة على نفس الافتراضات الأولية لجميع النماذج فتم إجراء التقدير تحت فرضية أن العوائد الشرطية تتبع توزيعاً طبيعيًا.

قدمت الدراسة التحقيق التجريبي للنماذج المقدّرة على جميع مجموعات البيانات. حيث قامت بتحليل ومقارنة التقلب المستخرج من نماذج GARCH و EGARCH و NA-GARCH المقترح في المعادلة (11).

Assets	Exponential		Hill	
	(MAE)	(RMSE)	(MAE)	(RMSE)
AstraZeneca	9	9	3	3
Aviva	7	7	5	6
BP	7	7	4	3
GlaxoSmithKline	8	9	6	7
Lloyds Bank	7	7	1	2
Vodafone	8	8	6	5

جدول 5 يعرض جدول التوافق (Contingency Table) في المرجع (Sadik و Mitra، 2018)

تشير النتائج في جدول 5 إلى أن نموذج التقلب الجديد NA-GARCH قدّم أداءً دقيقاً في التنبؤ بتقلبات العوائد لأصل "AstraZeneca"، حيث نجح في 9 من أصل 9 مجموعات بيانات عند استخدام دالة التلاشي الأسية (Exponential) لحساب تأثير الأخبار المعرفة في (10)، وذلك وفقاً لمؤشري MAE, RMSE في المقابل لم يحقق النموذج سوى 3 حالات نجاح عند استخدام دالة Hill التي تعتمد على قانون التلاشي البطيء والمعرفة بالعلافة (13).

$$f(t, \tau, \lambda) = \frac{1}{\left(1 + \frac{t - \tau}{\lambda}\right)^n}, t \geq \tau \quad (13)$$

حيث t هو الزمن الحالي، و τ هو الزمن الذي يتلاشى فيه التأثير إلى نصف قيمته (Half-life)، n هو معامل Hill.

تُفسَّر هذه النتيجة بأن دوال التلاشي البطيء مثل Hill قد تكون أكثر ملاءمة في الحالات التي تكون فيها الأخبار نادرة. إلا أن الأصول المستخدمة في هذه الدراسة تتسم بسيولة عالية وتدقق إخباري متكرر، مما يجعل تأثير الخبر يتلاشى بسرعة، وهو ما يتوافق أكثر مع خصائص الدالة الأسية.

أظهر تحليل نتائج الأداء باستخدام مؤشري MAE, RMSE أن نموذج NA-GARCH تفوق على النموذجين التقليديين GARCH وEGARCH في أكثر من ثلثي الحالات المدروسة. هذا التفوق يعكس قدرة النموذج على تقديم تنبؤات أكثر دقة لتقلبات العوائد، خصوصًا عند دمج تأثير معنويات الأخبار ضمن إطار النمذجة.

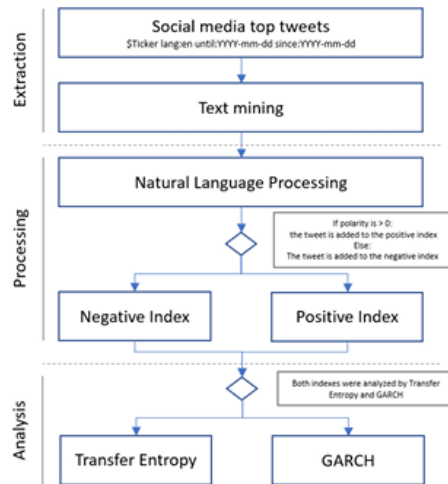
4.3 دراسة (A.Mendoza-Urdiales, 2022)

نُشرت هذه الدراسة عام 2022 بعنوان *Twitter Sentiment Analysis and Influence on Stock Performance*

Using Transfer Entropy and EGARCH Methods

هدف هذه الدراسة هو استكشاف العلاقة بين تحركات أسعار الأسهم والمشاعر المستخلصة من وسائل التواصل الاجتماعي، مثل تويتر، من خلال مقارنة السلاسل الزمنية لأسعار الأسهم مع مؤشرات المشاعر. حيث طرحت الورقة فرضيتين رئيسيتين:

1. وجود علاقة بين تحركات أسعار الأسهم وقطبية التغريدات التي تذكر سهم الشركة، أي أن المشاعر الإيجابية أو السلبية للتعليقات قد تتوافق مع ارتفاع أو انخفاض السعر.
2. أن التحركات الإيجابية في المشاعر تميل إلى أن تكون أكبر وأكثر كثافة من التحركات السلبية.



الشكل 9 إطار العمل في دراسة (A.Mendoza-Urdiales, 2022)

اعتمد الباحثون منهجية دقيقة لدراسة تأثير المشاعر المستخلصة من وسائل التواصل الاجتماعي على أداء أسعار الأسهم فقد شملت العينة عشرين شركة كبيرة تنتمي إلى قطاعات اقتصادية متنوعة، مثل البنوك والتكنولوجيا والنفط والاستثمار وذلك لضمان تمثيل شامل للسوق. وتم جمع التغريدات المتعلقة بهذه الشركات على مدى الفترة الزمنية من 2009 إلى 2018، بما يتيح تغطية كافية للأحداث المختلفة وتأثيراتها المحتملة على الأسواق المالية.

تم تحليل محتوى التغريدات باستخدام تقنيات معالجة اللغة الطبيعية لتصنيفها إلى فئتين أساسيتين: إيجابية وسلبية، ومن ثم إنشاء مؤشرات يومية تعكس شدة كل نوع من المشاعر. عملت الدراسة على تطبيق أسلوب Transfer Entropy لتقييم مدى تأثير هذه المؤشرات على تحركات أسعار الأسهم وذلك بقياس تدفق المعلومات بين مؤشرات المشاعر وأسعار الأسهم، مع مراعاة التأخيرات الزمنية بين الأحداث وردود الأفعال السوقية. كما تم استخدام تقنية Bootstrap لتقليل الانحياز الناتج عن حجم العينة وتحسين دقة القياس. وقد أتاح هذا النهج تحديد الاتجاه الذي تتحرك فيه المعلومات، أي ما إذا كانت التغريدات الإيجابية أو السلبية تؤثر فعليًا على تحركات الأسعار، بالإضافة إلى قياس قوة هذا التأثير.

تم دمج مؤشرات المشاعر مع متغيرات إضافية مثل عدد التغريدات اليومية ضمن نموذج EGARCH لتحليل تأثير الصدمات غير المتماثلة على تقلبات الأسعار.

أظهرت النتائج الأولية للمتغير العام للتغريدات (المجموع بين المؤشرات الإيجابية والسلبية) نتائج غير حاسمة، إذ ظهرت فقط لشركات 9 من أصل 20. حتى عند العثور على علاقة سببية في 45% من الحالات، لم تصبح النتائج موثوقة إلا بعد تقسيم المؤشرات إلى إيجابية وسلبية، أما النتائج المستخلصة من نموذج EGARCH، فقد أظهرت أن 83% من الحالات أظهر فيها المؤشر السلبي تأثيرًا أكبر من المؤشر الإيجابي، حيث كانت قيم معاملات المؤشر السلبي سالبة وقيم معاملات المؤشر الإيجابي موجبة، وهو ما يعكس وجود تأثير غير متماثل؛ أي أن الصدمات السلبية تؤثر بشكل أقوى وتستمر لفترة أطول مقارنة بالإيجابية.

يلخص الشكل 10 نتائج نموذج EGARCH لكل شركة حققت النتائج المتوقعة، ويشمل قيمة المعامل لكل متغير مستقل Coefficient والقيمة الاحتمالية (p-value) وإحصائية T الخاصة بكل معامل.

تشير النتائج إلى أن المؤشر الإيجابي للتغريدات له تأثير إيجابي على عوائد الشركات، بينما المؤشر السلبي له تأثير سلبي، مع ملاحظة أن التأثير السلبي أكبر من التأثير الإيجابي من حيث القيمة المطلقة. هذا يدعم فرضية أن مؤشرات المشاعر قادرة على توضيح تأثير شعور الجمهور على أداء الأسهم.

كما أظهر تحليل التباين عبر معامل γ لنموذج EGARCH وجود تأثير الرافعة المالية، حيث تؤدي الصدمات السلبية إلى زيادة أكبر في تقلب الأسعار مقارنة بالصدمات الإيجابية، وهو أمر لا يمكن تفسيره باستخدام نموذج GARCH البسيط.

Company	R2	Constant		Positive Index		Negative Index		Number of Tweets		ACWI			
		Coefficient	T Stats	Coefficient	T Stats	Coefficient	T Stats	Coefficient	T Stats	Coefficient	T Stats		
Amazon	28%	-0.01	-0.55	0.10	2.68	-0.10	-2.24	0.06	2.05	0.04	0.49	22.46	0.00
Alkerm	28%	0.01	10.78	0.01	2.15	-0.02	-3.46	0.01	2.68	0.01	0.52	30.99	0.00
Bank of America	46%	-0.01	-3.09	0.05	7.31	-0.08	-24.64	0.03	6.44	0.00	0.60	26.31	0.00
eBay	31%	0.02	28725.15	0.02	2.82	-0.02	-679.17	0.01	9.24	0.00	0.56	206.23	0.00
Exxon	41%	0.00	0.57	0.02	4.26	-0.04	-2.65	0.01	0.97	0.33	0.58	30.01	0.00
Facebook	12%	-0.07	-18.52	0.06	8.19	-0.17	-38.35	0.00	0.65	0.52	0.33	38.32	0.00
General Electric	37%	0.02	3.17	0.03	18.08	-0.06	-4.44	0.01	4.20	0.00	0.59	37.43	0.00
Google	35%	-0.01	-4.31	0.03	3.44	-0.04	-5.44	0.02	4.43	0.00	0.56	73.29	0.00
IBM	39%	0.02	1.19	0.03	2.39	-0.13	-53.64	0.00	0.20	0.84	0.59	139.52	0.00
Intel	38%	-0.02	-44.20	-0.01	-10.64	0.02	7.96	0.00	-9.35	0.00	0.61	23.08	0.00
Johnson & Johnson	36%	-0.01	-2.08	0.02	2.72	-0.07	-8.62	0.00	-0.15	0.88	0.56	291.59	0.00
JP Morgan	56%	-0.01	-0.44	0.03	1.96	-0.08	-3.11	0.00	0.18	0.86	0.72	44.29	0.00
Microsoft	41%	0.00	0.34	0.04	4.74	-0.06	-4.43	0.02	1.40	0.16	0.61	32.47	0.00
Procter and Gamble	9%	-0.12	-3180.72	0.04	3587.49	-0.07	-5544.68	0.00	20240.00	0.00	0.34	2814.54	0.00
SAP	51%	0.00	-0.64	0.02	2.82	-0.04	-2.59	0.01	0.74	0.46	0.70	39.34	0.00
Tencent	30%	-0.02	-3.56	0.02	13.48	-0.02	-3.78	0.01	2.62	0.01	0.54	43.81	0.00
Tesla	11%	-0.04	-1.93	0.10	3.03	-0.15	-3.29	0.03	1.39	0.16	0.32	13.38	0.00
Twitter	14%	0.02	1.13	0.18	24.74	-0.32	-11.49	0.01	0.24	0.81	0.26	5.66	0.00
Visa	39%	0.00	0.02	0.02	2.69	-0.03	-3.30	0.00	1.86	0.06	0.63	42.93	0.00
Wells Fargo	54%	0.00	0.07	0.02	9.45	-0.03	-2.49	0.01	0.79	0.43	0.70	40.37	0.00

الشكل 10 نتائج نموذج EGARCH في (A.Mendoza-Urdiales, 2022)

الفصل الرابع

المنهجية المقترحة

1.4 تمهيد

تهدف هذه الدراسة إلى تطوير نموذج للتنبؤ بتقلبات أسعار الأسهم والسوق المالي ككل، اعتمادًا على النماذج الاحتمالية المتقدمة في قياس التباين الشرطي، مع تعزيز هذه النماذج بمؤشرات مستمدة من الأخبار المالية والاقتصادية. وقد أظهرت النماذج الكلاسيكية مثل ARCH و GARCH قدرتها على توصيف السلوك المتقلب للعوائد المالية، غير أن الاقتصار على المعلومات التاريخية للعوائد يحدّ من دقتها في توصيف المخاطر المستقبلية خصوصًا في ظل بيئة مالية معقدة تتأثر بصورة مباشرة بالأحداث الإخبارية.

بناءً على ذلك، ظهرت الحاجة إلى دمج الأخبار كمصدر خارجي للمعلومات، بحيث يساهم في تحسين جودة التنبؤ. وعليه فإن نموذج News-Augmented GARCH يشكل مقاربة حديثة تستفيد من خصائص النماذج الشرطية للتقلب، مع الأخذ في الاعتبار مؤشرات معنويات السوق (Sentiment) وكثافة الأخبار (News Count) كمتغيرات مساعدة. ويتيح هذا الدمج بناء نموذج أكثر مرونة يعكس التفاعل بين البيانات الرقمية (العوائد المالية) والبيانات النصية (الأخبار).

وفي إطار هذه الرؤية، نقترح نموذجًا مطورًا أطلقنا عليه Power-Transformed Threshold Augmented GARCH (PTT-AGARCH)، الذي يجمع بين خصائص التحويل بالقوة (Power Transformation) لمعالجة ثقل ذيول التوزيع (Heavy Tails)، وآلية العتبة (Threshold Effect) لتمييز أثر الصدمات السالبة عن الموجبة، بالإضافة إلى إدخال متغيرات إخبارية في معادلة التباين الشرطي. إن هذا الدمج لا يقتصر على تحسين توصيف التقلبات عند مستوى السهم الفردي، بل يمتد ليشمل التنبؤ بسلوك السوق المالي بصورة كلية، وهو ما يتيح أداة أكثر دقة لدعم قرارات الاستثمار وإدارة المخاطر.

الصياغة الرياضية للنموذج المقترح يمكن تمثيلها وفق العلاقة (14):

$$\begin{aligned} \varepsilon_t &= z_t \sigma_t, \quad z_t \sim i.i.d.(0,1) \\ \sigma_t^\tau &= \left(\omega + \sum_{i=1}^p \alpha_i^+ (\max(\varepsilon_{t-i}, 0))^\tau + \sum_{j=1}^p \alpha_j^- (\max(-\varepsilon_{t-j}, 0))^\tau + \sum_{k=1}^q \beta_k \sigma_{t-k}^\tau \right) \cdot NF_t \\ NF_t &= a + \frac{1}{2} b \left[\left(\frac{e^{\kappa P_{t-1}} - 1}{e^{\kappa P_{t-1}} + 1} \right) - \left(\frac{e^{\gamma N_{t-1}} - 1}{e^{\gamma N_{t-1}} + 1} \right) \right] \end{aligned} \quad (14)$$

حيث أن:

- ε_t : الصدمة الشرطية عند الزمن t.
- z_t : متغير عشوائي مستقل ومتطابق التوزيع (i.i.d) ذو متوسط صفر وانحراف معياري واحد، يمثل الصدمة المعيارية.
- σ_t : التباين الشرطي عند الزمن t.
- τ : معامل التحويل بالقوة.
- ω : الثابت الأساسي في نموذج GARCH ، يمثل جزءًا ثابتًا من التقلب.

• معاملات تأثير الصدمة الإيجابية والسلبية السابقة على التقلب الحالي على التوالي. α_i^-, α_i^+

• معاملات النموذج وهي دائما موجبة. a, b, κ, γ

• دالة قياس تأثير الأخبار (News Factor) حيث يغير التقلب الشرطي وفق الأخبار الإيجابية والسلبية. NF_t

اختيار هذه الدالة وفق (14) يعكس محاولة لتوصيف العلاقة غير الخطية بين الأخبار وتقلبات السوق، فلا تؤثر الأخبار الإيجابية والسلبية بشكل متماثل على السلوك المالي للمستثمرين؛ إذ تُظهر الأدبيات كما ورد في (Hamadeh، 2011) أن الأخبار السلبية تميل إلى زيادة التقلبات بشكل حاد نتيجة ردود الفعل المبالغ فيها من السوق بينما الأخبار الإيجابية غالبًا ما تُحدث تأثيرًا أكثر اعتدالًا.

وقد صممت دالة القياس NF_t بحيث تلتقط الاختلاف في استجابة السوق تجاه نوع الخبر (إيجابي أو سلبي)، مع إبقاء التأثير محصورًا ضمن نطاق محدد بين $[a, a + b]$ وهذا ضروري حتى لا تنتج الدالة تقلبات غير واقعية أو انفجارية وفق ما ذكر (Sadik و Mitra، 2018).

كما أن معاملات النموذج المستخدمة في هذه الدالة موجبة دائمًا، وهو ما يتماشى مع التوجهات النظرية التي تؤكد على أن تأثير الأخبار لا يعكس الاتجاه بل يعززه (Shi & Ho، 2020).

2.4 بناء النموذج

استعان النموذج المقترح (PTT-AGARCH) Power-Transformed Threshold Augmented GARCH بمجموعة من الأفكار المستمدة من الدراسات السابقة، مع اقتراح مجموعة من الخصائص التي تعزز قدراته التنبؤية. يقوم النموذج على دمج ثلاثة عناصر أساسية: عامل التحويل بالقوة (Power Transformation) الذي يتيح تمثيلًا أكثر مرونة لسلوك التباين، عامل العتبة (Threshold Effect) الذي يميز بين تأثير الصدمات الإيجابية والسلبية، وعامل التلاشي (Decay Factor) الذي يتحكم في سرعة تلاشي أثر الأخبار ومعنويات السوق على تقلبات العوائد.

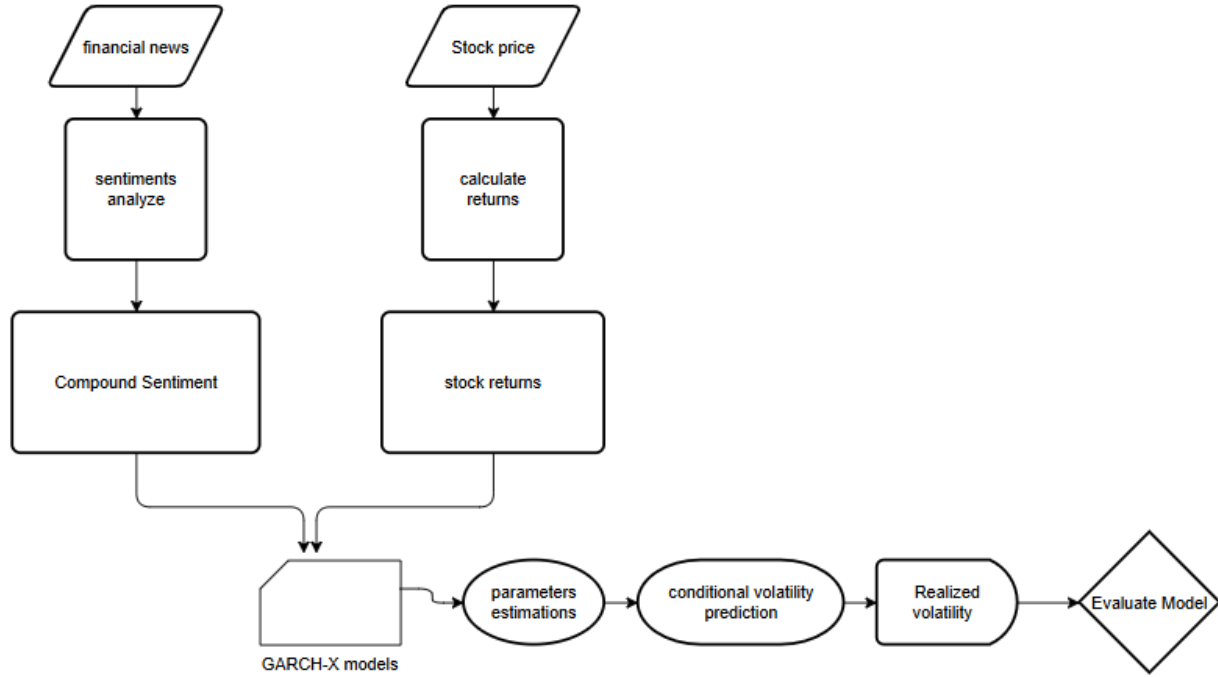
ولتوسيع قدرة النموذج على استيعاب العوامل غير التقليدية المؤثرة على تقلبات السوق، تم دمج نموذج تحليل الأخبار (News Sentiment Analysis Model)، حيث يتم استخراج الأخبار المالية وتصنيفها إلى إيجابية وسلبية ومحايدة باستخدام تقنيات التحليل اللغوي الطبيعي مثل VADER و FinBERT. تُستخدم هذه التقييمات كمؤشرات كمية تمثل متغيرات مستقلة في معادلة التباين الشرطي، وتشمل على سبيل المثال: متوسط المعنويات اليومية، تباين المعنويات، وعدد الأخبار المرتبطة بالسهم.

بدأت الدراسة بتقدير نموذج ARCH بوصفه الخطوة الأساسية لفهم البنية الأولية للتقلبات في سلسلة العوائد بعد ذلك

أُجريت مقارنة بين نموذج PTT-GARCH ونموذج GARCH التقليدي ونموذج GARCH-NEWS ونموذج PTT-

AGARCH المقترح في الحالة (1,1)، ثم جرى تعميم المقارنة إلى الحالة (p,q) لتقييم أداء النماذج عند ازدياد درجة

التعقيد. كما تمت مقارنة نموذج الأخبار المتأخرة والمباشرة مع نموذج PTT-GARCH باستخدام البيانات الاقتصادية المعالجة من الأخبار. وفي المرحلة الأخيرة تم تحليل نتائج هذه النماذج ورسم فترات الثقة لتوضيح دقة التنبؤات وحدود عدم اليقين.



الشكل 11 مخطط المنهجية المقترحة

1.2.4 نموذج ARCH/Sentiment-ARCH (1)

يُعدّ استخدام نموذج ARCH في المرحلة التمهيديّة خطوة منهجية أساسية تمهّد للانتقال إلى النماذج الأكثر تعقيدًا في تحليل التقلبات المالية. تنبع أهمية هذا الخطوة من كونها الأساس النظري لدراسة ديناميكية التباين الشرطي في السلاسل الزمنية المالية، إذ تساعد من الكشف المبكر عن خاصية عدم تجانس التباين عبر الزمن التي تُميز عوائد الأصول المالية.

في هذه المرحلة الأولية، يُبنى نموذج ARCH على صياغة بسيطة لدالة التباين الشرطي، حيث يُربط التباين الحالي بمربعات الأخطاء السابقة، بما يسمح بفهم البنية الجوهرية لتقلبات السوق وتقدير مدى استجابة التباين للصدمات العشوائية الماضية. مما يوفر إطارًا رياضيًا أوليًا لاختبار وجود ذاكرة قصيرة الأمد في التباين. كما إن دمج متغيرات خارجية مثل مؤشرات الأخبار ضمن عملية التقدير وفق ما يُعرف بنموذج Sentiment-ARCH يسمح باختبار الفرضية القائلة إن الأخبار الإيجابية أو السلبية يمكن أن تؤثر بشكل مباشر في ديناميكية التباين.

1. تحضير بيانات الاخبار

حُمِلت قاعدة بيانات ضخمة تحتوي على الأخبار المالية المتعلقة بأسهم عدد من الشركات المدرجة في البورصة الأمريكية²، حيث تضم هذه القاعدة 1,048,575 سجلاً تمثل الأخبار المنشورة خلال الفترة الممتدة من عام 2009 حتى عام 2020. وقد شملت قاعدة البيانات عدة أعمدة (متغيرات) تمثل الخصائص الأساسية لكل خبر مالي:

- **العنوان (headline):** وهو النص المحوري للخبر الذي يمثل المصدر الأساسي لاستخراج الدلالات اللغوية.
- **المصدر (publisher):** الجهة الناشرة للخبر، الأمر الذي يتيح تقييم تنوع المصادر ودرجة موثوقيتها.
- **رابط الخبر (URL):** المرجع الرقمي الذي يضمن إمكانية التحقق من المحتوى الأصلي.
- **التاريخ (date):** يحدد الإطار الزمني للخبر بما يسمح بمواءمته مع بيانات العوائد اليومية.
- **رمز السهم (stock):** يربط الخبر مباشرة بالشركة موضوع التحليل.

2. تحضير بيانات العوائد

يبدأ التحليل بتحميل بيانات الأسهم التاريخية، بما في ذلك أسعار الإغلاق اليومية. لحساب العوائد اليومية للسهم، يُستخدم التحويل اللوغاريتمي للزيادة اليومية، حيث تُعرف العوائد ε_t بالعلاقة التالية:

$$\varepsilon_t = 100 \times \ln \frac{P_t}{P_{t-1}}$$

حيث P_t هو سعر الإغلاق في اليوم t ، استخدام العوائد اللوغاريتمية يوفر خصائص إحصائية مناسبة، منها التراكمية الخطية عند الجمع، وتوزيع أقرب للتوزيع الطبيعي مما يسهل نمذجة التقلبات المالية.

3. تحليل بيانات الأخبار المالية (Sentiment Analysis)

لتضمين تأثير الأخبار على تقلبات السوق، يتم جمع الأخبار المتعلقة بالسهم المستهدف وتصنيفها حسب اليوم والسهم المعني بعد ذلك، يتم تحليل كل عنوان باستخدام محلل المشاعر المحسن الذي يجمع بين نموذج VADER التقليدي ونموذج FinBERT القائم على التعلم العميق، لإنتاج درجة مشاعر مركبة $score_i$ لكل خبر i :

$$score_i = 0.7 \cdot FinBERT_i + 0.3 \cdot VADER_i$$

ثم تصنف درجات المشاعر إلى تأثيرات إيجابية وسلبية:

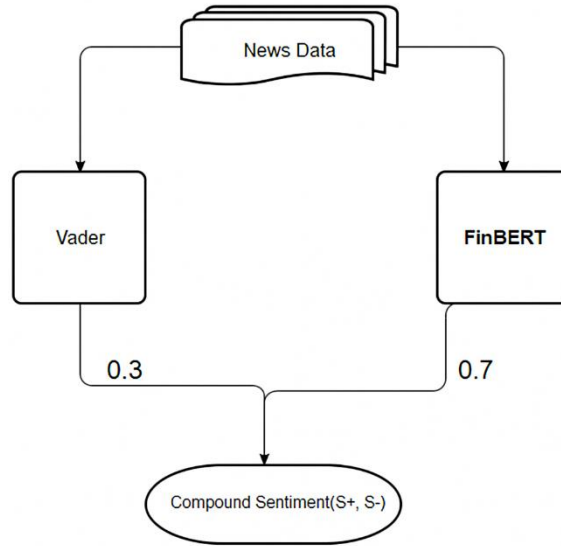
$$positive_i = \max(score_i, 0), negative_i = -\min(score_i, 0)$$

² <https://www.kaggle.com/datasets/miguelaelnle/massive-stock-news-analysis-db-for-nlpbacktests>

بعد ذلك، يُحسب المتوسط اليومي لكل من المشاعر الإيجابية والسلبية لكل يوم تداول:

$$S_t^+ = \frac{1}{n_t} \sum_{i \in \text{day } t} \text{positive}_i, \quad S_t^- = \frac{1}{n_t} \sum_{i \in \text{day } t} \text{negative}_i$$

حيث n_t هو عدد الأخبار في اليوم t . هذا التجميع اليومي يمكن من دمج تأثيرات الأخبار في ديناميكية التباين اليومي للسهم.



الشكل 12 مخطط تحليل المشاعر

4. نموذج التباين الشرطي ARCH و Sentiment-ARCH

في هذا الجزء يتم حساب التباين الشرطي σ_t^2 لكل يوم، والذي يعكس التقلب المتوقع للعائدات اليومية استنادًا إلى تاريخ العوائد السابقة وتأثير الأخبار.

المكون الأساسي لنموذج ARCH مع التمييز بين الصدمات الموجبة والسالبة يُعرف بالعلاقة التالية:

$$\varepsilon_t = z_t \sigma_t, \quad z_t \sim i.i.d.(0,1)$$

$$\text{ARCH Term}_t = \omega + \alpha^+ (\varepsilon_{t-1}^+)^{\tau} + \alpha^- (\varepsilon_{t-1}^-)^{\tau}$$

$$\bullet \quad \varepsilon_{t-1}^- = -\min(r_{t-1}, 0) \text{ و } \varepsilon_{t-1}^+ = \max(r_{t-1}, 0)$$

• ω هو التباين الثابت غير الشرطي.

• α^+ , α^- تعكسان حساسية التباين للصدمات الإيجابية والسلبية.

• τ هو معامل التحويل للقوة (Power term) الذي يسمح بتعميم نموذج ARCH التقليدي.

في حال تضمين تأثير المشاعر، يُضاف دالة قياس تأثير الأخبار:

$$NF_t = a + 0.5b \left[\tanh\left(\frac{\kappa S_{t-1}^+}{2}\right) - \tanh\left(\frac{\gamma S_{t-1}^-}{2}\right) \right]$$

وبذلك يتم التعبير عن التباين الشرطي الكلي:

$$\sigma_t = (NF_t \cdot \text{ARCH Term}_t)^{1/\tau}$$

معاملات a, b, κ, γ تتحكم في شدة تأثير الأخبار على التباين، بحيث تزيد الأخبار السلبية من التقلبات بشكل أكبر مقارنة بالإيجابية.

5. دالة الاحتمالية السالبة (Negative Log-Likelihood)

لتقدير المعلمات المثلى للنموذج $\theta = (\omega, \alpha^+, \alpha^-, \tau, a, b, \kappa, \gamma)$ ، تُستخدم دالة الاحتمالية القصوى (QMLE) التي يمكن تعريفها لكل يوم وفق العلاقة:

$$l_t(\theta) = \log(\sigma_t^2) + \frac{\varepsilon_t^2}{\sigma_t^2}$$

ويتم جمعها للحصول على الاحتمالية السالبة الإجمالية: $\mathcal{L}(\theta) = \sum_{t=2}^T l_t(\theta)$.

حيث T هو عدد النقاط الزمنية التي تحتوي على بيانات العوائد في السلسلة الزمنية للعوائد ε_t ويتم البدء من $t = 2$ لتجنب مشاكل البداية مع القيمة الابتدائية ε_0 .

ثم نوجد تقدير المعلمات عبر العلاقة:

$$\hat{\theta} = \arg \min_{\theta} \mathcal{L}(\theta)$$

2.2.4 نموذج PTT-AGARCH (1,1)

بعد أن وضعت المرحلة الأولى الأساس النظري والعملية لنماذج التباين الشرطي المبسطة، وتحقق من دمج التأثيرات الأولية للأخبار المالية على التباين اليومي عبر نموذج Sentiment-ARCH، تأتي المرحلة الثانية لتطوير صياغة أكثر تعقيداً ومرونة. الهدف من هذه المرحلة هو التوسع في التحويل بالقوة (Power Transformation)، والتمييز بين الصدمات الموجبة والسالبة (Threshold Effects)، بالإضافة إلى إدخال تأثيرات الأخبار المتقدم.

1. توسيع صياغة PTT-AGARCH مع التمييز بين الصدمات

تمتاز المرحلة الثانية بالانتقال إلى نموذج PTT-AGARCH الذي يسمح بدمج تحويل القوة وتمييز الصدمات الموجبة عن السالبة المعرف وفق المعادلة (14) هذا النموذج يسمح بالتقاط الاستجابة غير المتناظرة للسوق للأخبار الإيجابية والسلبية مع مرونة إضافية بفضل معامل القوة τ .

2. تحضير بيانات الاخبار

تتكوّن قاعدة بيانات الأخبار المالية المعتمدة في هذه المرحلة من أكثر من 51,000 مقال إخباري جُمعت من موقع Yahoo Finance خلال الفترة الممتدة بين عامي 2017 و2023، وهي تغطي نطاقًا واسعًا من القطاعات الاقتصادية والشركات المدرجة في السوق الأمريكي. وتضم عناصر وصفية دقيقة تشمل عنوان الخبر، وتاريخ النشر، والمصدر، ووصفًا موجزًا، بالإضافة إلى النص الكامل للمقال.

تتضمن القاعدة أيضًا معلومات تفصيلية عن الشركات والقطاعات الصناعية المرتبطة بكل خبر عبر رموز الأسهم (Tickers)، مما يتيح الربط بين المحتوى النصي وحركة الأسعار الفعلية. كما تحتوي على تحليل آلي للمشاعر يشمل القيم السلبية والمحايدة والإيجابية، إلى جانب تحليل انفعالي يغطي مشاعر مثل الفرح، الحزن، الغضب، والخوف.

3. دالة الاحتمالية السالبة (Negative Log-Likelihood)

لإيجاد التقديرات المثلى للمعلمات $\theta = \{\omega, \alpha_p, \alpha_n, \beta, \tau, a, b, \kappa, \gamma\}$ ، يُستخدم أسلوب الاحتمالية القصوى:

$$L(\theta) = \prod_{t=1}^T \exp\left(-\frac{\epsilon_t^2}{2\sigma_t^2}\right)$$

وبأخذ اللوغاريتم:

$$l(\theta) = \sum_{t=1}^T \left(\ln \sigma_t^2 + \frac{\epsilon_t^2}{\sigma_t^2} \right)$$

حيث T هو عدد النقاط الزمنية التي تحتوي على بيانات العوائد في السلسلة الزمنية فيتم تصغير الدالة مما يسمح باستخراج القيم المثلى للمعلمات التي تحقق أفضل مطابقة بين النموذج والبيانات.

3.2.4 نموذج PTT-AGARCH(p,q)

يهدف هذا القسم إلى تطوير نموذج PTT-AGARCH من صورته البسيطة ذات الرتبة (1,1) إلى الصيغة العامة (p,q)، بما يتيح توصيفًا أكثر مرونة ودقة لديناميكية التباين الشرطي للعوائد المالية. ويُمكن هذا التوسيع النموذج من استيعاب البنى الزمنية المعقدة للتقلبات، مع دمج التأثيرات غير المتناظرة للصدمات المالية وإدراج المعلومات الإخبارية.

1. تعريف البيانات ودالة قياس تأثير الأخبار

تم استخدام بيانات عوائد يومية لمجموعة من بيانات الأسهم من موقع Yahoo Finance، مع متوسط المعنويات الإيجابية والسلبية للأخبار المالية اليومية لتقليل تأثير الأخبار القديمة، تم تطبيق تلاشي معنويات الأخبار (Decay Sentiment) مع نصف عمر محدد، بحيث تقل تأثيرات الأخبار السابقة بشكل أسّي مع مرور الوقت وفق المعادلة (15)

$$\text{Decay factor} = e^{-\lambda \Delta t}, \quad \lambda = \frac{\ln(2)}{\text{half-life}} \quad (15)$$

تم تقييس المعنويات لتصبح بين 1- و1، مع الحفاظ على الإشارات الإيجابية والسلبية بشكل منفصل.

2. اختيار الرتب المثلى (Order Selection)

لتحديد الرتب المثلى p,q لنموذجي GARCH و PTT-GARCH ، تم استخدام معيار Akaike Information Criterion (AIC):

$$AIC = 2k - 2\ln \hat{\mathcal{L}}$$

حيث k عدد المعلمات و \mathcal{L} قيمة الاحتمالية عند المعلمات المقدرة.

تم تجربة جميع التراكيب الممكنة حتى حد معين p_{max}, q_{max} واختيار النموذج الذي يقلل AIC .

3. نموذج PTT-GARCH و PTT-AGARCH (p, q)

نموذج PTT-GARCH (Power-Transformed Threshold GARCH) يسمح بالتقاط تأثير الصدمات غير المتناظرة وتحويل القوة:

$$\begin{aligned} \varepsilon_t &= z_t \sigma_t, \quad z_t \sim i.i.d.(0,1) \\ \sigma_t^\delta &= \left(\omega + \sum_{i=1}^p \alpha_{i+} |\varepsilon_{t-i}|^\delta + \sum_{i=1}^p \alpha_{i-} (\max(-\varepsilon_{t-i}, 0))^\delta + \sum_{j=1}^q \beta_j \sigma_{t-j}^\delta \right). \end{aligned}$$

عند ضرب عامل الأخبار NF_{t-1} كما في المعادلة (14) بالتباين الشرطي نحصل على نموذج PTT-AGARCH .

τ هو معامل تحويل القوة، α_{i-} يلتقط تأثير الصدمات السالبة، α_{i+}, β_j يمثلان تأثير الصدمات السابقة والتباين السابق على الترتيب.

4. تقدير المعلمات

تم استخدام دالة الاحتمالية العظمى (QMLE) مع خوارزميات تحسين عددية (SLSQP, L-BFGS-B) حيث يتم اختيار مجموعة المعلمات المثلى $\theta = (\omega, \alpha_i, \gamma_j, \beta_k, \tau, a, b, \dots)$ بحيث تقلل من دالة الاحتمالية السالبة.

$$L(\theta) = \sum_{t=1}^T \left(\ln(\sigma_t^2) + \frac{\varepsilon_t^2}{\sigma_t^2} \right)$$

بعد ان تم فرض قيود الاستقرار التالية:

- $\omega > 0$
- $\sum \alpha_i + \sum \beta_j < 1$
- معاملات الأخبار ضمن حدود منطقية $0.5 < a, b < 2$ و معامل القوة τ في مجال [0.01, 5.0].

4.2.4 نموذج PTT-AGARCH(p,q) مع دالة الاخبار المعدلة

1. نموذج قياس الاخبار المعدل NFL_t

في هذه المرحلة، تم تطوير وتحسين نموذج PTT-AGARCH المستخدم لتقدير تقلبات العوائد المالية، عبر إضافة تمثيل متأخر لعوامل الأخبار (Lagged News Factor) ضمن معادلة التقلب وفق المعادلة (16). تهدف هذه التعديلات هو التقاط تأثير الأخبار السابقة على التقلب الحالي، بدلاً من الاكتفاء بتأثير الأخبار اللحظية فقط، مما يعكس الطبيعة الديناميكية للأسواق المالية واستجابة الأسعار للأحداث الاقتصادية بشكل متدرج.

$$NFL_t = a + \sum_{j=1}^p \frac{1}{2} b_j \left[\tanh\left(\frac{1}{2} \kappa_j P_{t-j}\right) - \tanh\left(\frac{1}{2} \gamma_j N_{t-j}\right) \right] \quad (16)$$

حيث:

- P_t : مؤشر الأخبار الإيجابية عند الزمن t
- N_t : مؤشر الأخبار السلبية
- $a, b_j, \kappa_j, \gamma_j; 1 \leq j \leq p$ معاملات تُقدّر عددياً من خلال دالة الاحتمال الأعظم (Maximum Likelihood).

وهنا يؤخذ في الاعتبار أثر الأخبار المتأخرة (lags) عبر فترات زمنية متعددة، مما يسمح للنموذج بالتقاط التأثير التراكمي أو المتباطئ للأخبار السابقة على سلوك التقلب.

تمثل الصيغة الرياضية لدالة قياس الأخبار المتأخرة صياغة كمية لتفاعل الأسواق مع المعلومات بمرور الوقت، حيث يدمج النموذج بين الذاكرة الزمنية والاستجابات السلوكية غير الخطية والنفور من الخسارة في معادلة واحدة متماسكة. كما تعكس الصيغة منظور الاقتصاد السلوكي يعكس التغير التدريجي في المزاج الجماعي للمستثمرين استجابة لتدفق الأخبار.

2. تقدير المعلمات

تم تقدير معاملات النموذج باستخدام خوارزمية (L-BFGS-B Optimization) عبر تعظيم دالة الاحتمال اللوغاريتمي السالبة:

$$L(\theta) = -\frac{1}{2} \sum_{t=1}^T \left[\log(\sigma_t^2) + \frac{\varepsilon_t^2}{\sigma_t^2} \right]$$

حيث تضم جميع معاملات النموذج بما في ذلك معاملات الأخبار a, b, κ, γ كما يتم تطبيق قيود واقعية (parameter bounds) على معاملات النموذج لتفادي الانفجار العددي وضمان الثبات وفق جدول 6.

المعامل	الرمز	القيود
Constant	ω	[1e-8, 10]
Positive ARCH	α_i^+	[1e-8, 0.5], i=1,...,q
Negative ARCH	α_i^-	[1e-8, 0.5], i=1,...,q
GARCH	β_j	[1e-8, 0.95], j=1,...,p
Power	τ	[0.5, 3]
News constant	a	[0.5, 1.5]
News effect	b	[0.01, 0.3]
Positive sensitivity	κ	[0.3, 3.0]
Negative sensitivity	γ	[0.3, 3.0]
News constant	a	[0.5, 1.5]
Lagged effect	b_j	[0.001, 0.2], j=1,...,p
Positive sensitivity	κ_j	[0.3, 3.0], j=1,...,p
Negative sensitivity	γ_j	[0.3, 3.0], j=1,...,p

جدول 6 قيود المعاملات المفروضة في نموذج PTT-AGARCH (دالة الأخبار المعدلة)

الفصل الخامس

تقييم المنهجية المقترحة

1.5 تعريف الاختبارات المطبقة

في تحليل التقلبات المالية، تُستخدم مجموعة من الاختبارات الإحصائية لتقييم خصائص السلاسل الزمنية للعوائد، وخاصة لتحديد وجود تباين شرطي متغير عبر الزمن، وهو أساس نماذج ARCH و GARCH فيما يلي أهم هذه الاختبارات:

1.1.5 اختبار ARCH-LM

اختبار ARCH-LM يُستخدم للتحقق من وجود تباين شرطي ذاتي (Conditional Heteroscedasticity) في سلسلة زمنية للعوائد المالية. أي أنه يختبر ما إذا كانت التباينات الحالية تعتمد على مربعات الصدمات السابقة (أي هل هناك تجمع تقلبات أو تقلبات متتابة).

تنص الفرضية الصفرية على أنه لا توجد تأثيرات ARCH والتباين ثابت، بينما تنص الفرضية البديلة على وجود تأثيرات ARCH بحيث يكون التباين غير ثابت ويعتمد على القيم السابقة. إذا كانت قيمة الاختبار كبيرة وكانت p-value أقل من 0.05، فهذا يشير إلى رفض فرضية التباين الثابت، مما يعني أن السلسلة تظهر تجمعاً في التقلبات، ويدرر ذلك استخدام نماذج GARCH الأكثر تعقيداً لتحليل ديناميكيات التباين.

2.1.5 اختبار Ljung-Box على الصدمات المربعة

اختبار Ljung-Box هو اختبار ارتباط تسلسلي (Serial Correlation) يهدف إلى التحقق مما إذا كانت الصدمات أو مربعاتها مرتبطة زمنياً على lags متعددة. يتم تطبيقه عادة على الصدمات المربعة للتحقق من تجمع التقلبات.

تنص الفرضية الصفرية على أنه لا توجد علاقة ذاتية بين القيم عبر الزمن (الصدمات مستقلة). بينما تنص الفرضية البديلة على تواجد علاقة ذاتية (ارتباط تسلسلي).

ويتم تفسير النتائج اعتماداً على قيمة p-value كالتالي $p\text{-value} < 0.05$ يعني وجود نكتل تقلبات أو ارتباط تسلسلي في مربعات الصدمات. أما $p\text{-value} > 0.05$ الصدمات المربعة مستقلة تقريباً، أي أن النموذج يلتقط معظم ديناميكيات التباين.

3.1.5 اختبار Jarque-Bera على الصدمات المربعة

اختبار Jarque-Bera يقيس عدم طبيعية توزيع الصدمات من خلال فحص الانحراف (Skewness) والتفلطح (Kurtosis). يُصاغ الاختبار على شكل فرضيتين أساسيتين، حيث تمثل الفرضية الصفرية أن الصدمات تتبع توزيعاً طبيعياً (Gaussian)، في حين تفترض الفرضية البديلة أن الصدمات لا تتبع هذا التوزيع. فإذا كانت $p\text{-value} < 0.05$ ، يتم رفض فرضية الطبيعة، مما يعني أن توزيع الصدمات غير طبيعي. إذ يشير عدم الطبيعة إلى وجود ذيول ثقيلة أو انحراف (Skewness) في توزيع العوائد، وهو ما يستدعي استخدام نماذج أكثر مرونة مثل GARCH بهدف توصيف السلوك الإحصائي للصدمات بدقة أعلى.

4.1.5 مخططات Q-Q (Quantile-Quantile)

يُستخدم مخطط Q-Q لمقارنة التوزيع الفعلي للصددمات مع التوزيع النظري الذي غالباً ما يكون التوزيع الغاوسي (Gaussian distribution) على المحور الأفقي الرُّبَيْع النظري (Theoretical Quantiles) وعلى المحور الرأسي الرُّبَيْع الملاحظة للصددمات (Sample Quantiles). إذا كانت النقاط قريبة من الخط الأحمر (خط التناسب 45°)، فهذا يشير إلى أن الصددمات تتبع تقريباً التوزيع الطبيعي.

2.5 ARCH/Sentiment-ARCH (1)

1.2.5 نتائج الاختبارات الحسابية

في المرحلة الأولى من الدراسة تم تطبيق نموذج ARCH التقليدي إلى جانب نموذج Sentiment-ARCH الذي يدمج عامل الأخبار (Sentiment) لتحليل تأثير الأخبار اليومية على تقلبات أسعار الأسهم حيث تمت دراسة ثلاثة أسهم شركات مدرجة في البورصة الأمريكية هي:

1. **A** Agilent Technologies Inc: تعمل في مجال أدوات التحليل والقياس العلمي.
2. **AA** Alcoa Corporation: تعمل في إنتاج الألومنيوم والمعادن.
3. **ACHC** Acadia Healthcare Company: شركة خدمات الرعاية الصحية النفسية والسلوكية.

STOCK	TEST	ARCH TEST VALUE	ARCH P-VALUE	SENTIMENT-ARCH TEST VALUE	SENTIMENT-ARCH P-VALUE
A	ARCH-LM	114.90	5.45×10^{-20}	114.91	5.43×10^{-20}
	Ljung-Box Lag=10	147.36	1.30×10^{-26}	201.75	5.07×10^{-32}
	Ljung-Box Lag=20	147.38	1.29×10^{-26}	201.78	4.99×10^{-32}
	Jarque-Bera	4170.03	0.0	4169.92	0.0
AA	ARCH-LM	320.34	7.70×10^{-63}	323.79	1.43×10^{-63}
	Ljung-Box Lag=10	445.19	2.22×10^{-89}	450.83	1.39×10^{-90}
	Ljung-Box Lag=20	509.75	2.65×10^{-95}	516.42	1.06×10^{-96}
	Jarque-Bera	7016.56	0.0	7074.94	0.0
ACHC	ARCH-LM	21.58	0.0174	21.58	0.0174
	Ljung-Box Lag=10	23.80	0.0081	23.80	0.0081
	Ljung-Box Lag=20	31.62	0.0476	31.62	0.0476
	Jarque-Bera	22702.02	0.0	22701.87	0.0

جدول 7 نتائج اختبارات ARCH و Ljung-Box و Jarque-Bera للأسهم A، AA، ACHC

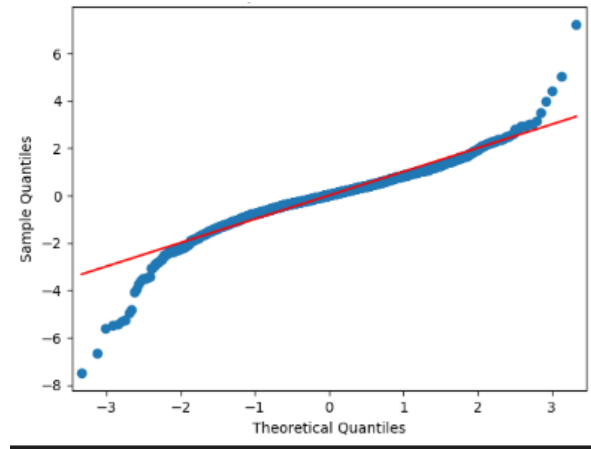
2.2.5 مخطط Q-Q للبيانات

عند رسم مخططات الصدمات لعوائد الأسهم كمثل في الشكل 13 مخطط الصدمات للسهم A نلاحظ انحرافات واضحة في الأطراف (tails) عن الخط الأحمر، خصوصاً في الجانبين السالب والموجب. يشير هذا الانحراف إلى وجود ذيول ثقيلة (Heavy Tails) في الصدمات، أي أن التوزيع الفعلي يحتوي على أحداث متطرفة أكثر من التوزيع الطبيعي المتوقع.

في المنطقة الوسطى، النقاط تتبع الخط الأحمر بشكل مقبول، مما يشير إلى أن الجزء المركزي من الصدمات قريب من الطبيعي. وهذا ما يفسر أن الصدمات لم تتبع التوزيع الطبيعي تمامًا، مما يوضح أهمية استخدام نماذج GARCH أو Sentiment-GARCH التي يمكنها التعامل مع التوزيعات غير الطبيعية.

وجود هذه الذيل الثقيلة يشير إلى أن الأسواق المالية تتعرض أحياناً لتقلبات شديدة أو صدمات مفاجئة، وهو ما يجب أن يأخذه المحلل بعين الاعتبار عند توقع التقلبات المستقبلية.

مقارنة النموذج التقليدي مع Sentiment-ARCH يُظهر أن دمج الأخبار قد يساعد على التقاط بعض التقلبات القصوى، لكن الصدمات تظل غير طبيعية، مما يبرر الحاجة إلى نماذج مرنة في التعامل مع هذه الخصائص.



الشكل 13 مخطط الصدمات للسهم A

3.2.5 تفسير النتائج

أظهرت النتائج التجريبية في المرحلة الأولى من الدراسة أن أداء نموذج ARCH التقليدي ونموذج Sentiment-ARCH الذي يدمج الأخبار اليومية كان متقارباً للغاية، حيث لم يلاحظ تحسن ملموس في دقة التنبؤ بتقلبات أسعار الأسهم عند إدراج دالة قياس تأثير الأخبار اليومية ضمن النموذج. يمكن تفسير هذا التشابه في الأداء بعدة عوامل مرتبطة بطبيعة البيانات المالية اليومية. أولاً، تتميز العوائد اليومية للأسهم غالباً بتوزيع غير طبيعي يحتوي على تقلبات شديدة ومتقطعة، مما يجعل

التقاط كل التأثيرات الديناميكية للعوائد تحديًا للنماذج التقليدية ذات التباين المحدود. ثانيًا، على الرغم من أن دمج الأخبار اليومية يوفر معلومات معنوية حول معنويات السوق، إلا أن تأثيرها اليومي كان محدودًا ضمن الإطار الزمني المستخدم، وبالتالي لم يساهم في تحسين دقة التنبؤ بشكل ملحوظ مقارنة بالنموذج التقليدي.

بالنظر إلى خصائص التباين الشرطي التي يمكن للنماذج التقاطها، لاحظنا أن كلا النموذجين استطاعا تحديد بعض الظواهر المهمة مثل تجمع التقلبات (Volatility Clustering)، وهي الخاصية التي تشير إلى أن فترات التقلبات العالية عادةً ما تتبعها فترات مشابهة، وفترات الهدوء تتبعها فترات هادئة. إلا أن كلا النموذجين لم يكن قادرًا على تمثيل جميع التأثيرات الديناميكية للعوائد اليومية بشكل كامل، خاصة الانحرافات الشديدة أو الأحداث غير المتوقعة التي قد تؤثر بشكل مفاجئ على الأسعار. هذه الملاحظة تتفق مع نتائج اختبارات LM (ARCH-LM) التي أظهرت وجود تباين مشروط لم يتم التقاطه بالكامل بواسطة نموذج ARCH البسيط، مما يشير إلى الحاجة إلى نماذج أكثر تعقيدًا وديناميكية.

من جهة أخرى، أظهرت نتائج اختبار Ljung-Box وجود تكتل واضح للتقلبات عند فترات مختلفة (Lag=10, Lag=20) مما يوضح أن الاعتماد على نموذج ARCH الذي يستخدم عددًا محدودًا من المصطلحات السابقة (lags) لا يكفي لالتقاط هذه التكتلات الطويلة، وأن زيادة عدد المصطلحات بشكل كبير يؤدي إلى تعقيد النموذج وتقليل استقرار تقديرات المعلمات. كما أظهرت نتائج اختبار Jarque-Bera أن توزيع العوائد اليومية بعيد عن التوزيع الطبيعي، وهو ما يبرر الحاجة إلى استخدام نماذج أكثر مرونة قادرة على التعامل مع الانحرافات الشديدة والتوزيع غير الطبيعي للعوائد المالية.

من هذا المنطلق يمثل الانتقال من نموذج ARCH إلى نماذج أكثر مرونة خطوة ضرورية لتطوير نماذج ديناميكية وأكثر موثوقية في التنبؤ بتقلبات الأسهم. حيث يسمح هذا الانتقال بفهم أفضل للعلاقة بين الأخبار اليومية وسلوك السوق، مع إمكانية تحسين استراتيجيات التداول وإدارة المخاطر المالية. كما أن دمج الأخبار والعوامل المعنوية في نماذج أكثر تطورًا يمكن أن يوفر تقديرات أدق لتقلبات المستقبلية، خصوصًا عند حدوث تأثيرات الأحداث الاقتصادية أو الأخبار المفاجئة على أسعار الأسهم.

3.5 تقييم نموذج PTT-AGARCH (1,1)

بعد الانتهاء من المرحلة الأولى من الدراسة، التي ركزت على اختبار نموذج ARCH التقليدي إلى جانب نموذج Sentiment-ARCH باستخدام ثلاثة أنواع (A, AA, ACH)، فإن نتائج الدراسة تؤكد أن الانتقال من نموذج ARCH إلى نماذج أكثر مرونة خطوة ضرورية لتطوير نموذج ديناميكي وأكثر موثوقية في التنبؤ بتقلبات الأسهم. هذه النتائج الأولية دفعت إلى توسيع نطاق التحليل في المرحلة الثانية من البحث.

وذلك من خلال زيادة عدد الأسهم المدروسة إلى 21 سهمًا مختلفة. هذه الأسهم هي [AMZN, BABA, BAC, C, CMCSA, CRM, CSCO, CVX, GOOGL, JPM, KO, META, MRK, MRNA, MSFT, NVDA, PYPL, QCOM,

[ROKU,SHOP,SQ]، الهدف الأساسي من هذه المرحلة هو تقييم قوة النماذج وقابليتها للتعميم عبر بيانات متنوعة من حيث القطاع وحجم التداول والتأثير الإعلاني.

جرى دمج أسعار الأسهم أو السوق اليومية مع نتيجة تحليل الإخبارية ثم طبقت دالة تلاشي المشاعر المعرّفة بحسب المعادلة (15) مع افتراض ان نصف عمر (half-life = 3 days) وذلك لتمثيل التأثير المتلاشي للأخبار القديمة على حركة الأسعار اللاحقة.

1.3.5 النماذج المختبرة

تمت مقارنة أربعة نماذج رئيسية:

- **GARCH (1, 1) التقليدي**: النموذج المرجعي المعتمد فقط على العوائد الماضية.
- **News-GARCH (1, 1)**: نموذج GARCH المقترح في دراسة (Sadik و Mitra، 2018).
- **PTT-GARCH (1, 1)**: نموذج يسمح بعدم التماثل في استجابة التقلبات للصدمات الإيجابية والسلبية.
- **PTT-AGARCH (1, 1)**: هو النموذج المقترح في هذه الدراسة وفق المعادلة (14).

2.3.5 نتائج التقييم

- **الملاءمة داخل العينة**: باستخدام Log-Likelihood .
- **الأداء خارج العينة**: من خلال Walk-Forward Forecasting بنافذة 30 يومًا وأفق تنبؤ يوم واحد، مع استخدام مؤشرات RMSE و MAE لقياس دقة التنبؤ.

STOCK	MODEL	RMSE	MAE	LOGLIKELIHOOD
AMZN	GARCH	0.476544	0.030130	4232.478
	NEWS_GARCH	0.477969	0.029435	-264738.162
	PTT-AGARCH	0.549764	0.071483	15993.805
	PTT_GARCH	1.017047	0.156084	20048.403
BABA	GARCH	0.004008	0.001401	2099.436
	NEWS_GARCH	0.004032	0.001627	2058.331
	PTT-AGARCH	0.003990	0.001294	6137.237
	PTT_GARCH	0.003993	0.001260	6140.428
BAC	GARCH	0.000859	0.000329	2799.971
	NEWS_GARCH	0.000859	0.000329	2800.573

C	PTT-AGARCH	0.000857	0.000327	7571.239
	PTT_GARCH	0.000859	0.000330	7544.375
	GARCH	0.000964	0.000343	28435.947
	NEWS_GARCH	0.000968	0.000344	28297.732
CMCSA	PTT-AGARCH	0.000963	0.000320	76860.694
	PTT_GARCH	0.000968	0.000342	76380.473
	GARCH	0.001712	0.000880	339.130
	NEWS_GARCH	0.001766	0.001093	329.300
CRM	PTT-AGARCH	0.001698	0.000834	980.326
	PTT_GARCH	0.001704	0.000876	957.263
	GARCH	0.001635	0.000796	893.966
	NEWS_GARCH	0.001634	0.000795	894.735
CSCO	PTT-AGARCH	0.001633	0.000795	2535.716
	PTT_GARCH	0.001634	0.000800	2527.897
	GARCH	0.001347	0.000671	616.875
	NEWS_GARCH	0.001309	0.000687	605.406
CVX	PTT-AGARCH	0.001292	0.000643	1711.006
	PTT_GARCH	0.001305	0.000652	1691.657
	GARCH	0.000525	0.000423	929.531
	NEWS_GARCH	0.000509	0.000398	937.254
GOOGL	PTT-AGARCH	0.000509	0.000395	2586.332
	PTT_GARCH	0.000532	0.000442	2564.446
	GARCH	0.432718	0.046208	7897.475
	NEWS_GARCH	0.420297	0.022009	-305360.191
JPM	PTT-AGARCH	0.737819	0.097056	21210.708
	PTT_GARCH	0.457814	0.064032	23115.465
	GARCH	0.000830	0.000364	6252.360

KO	NEWS_GARCH	0.000828	0.000353	6256.114
	PTT-AGARCH	0.000827	0.000350	16832.330
	PTT_GARCH	0.000828	0.000352	16813.327
	GARCH	0.000195	0.000098	2046.544
	NEWS_GARCH	0.000200	0.000117	2034.845
META	PTT-AGARCH	0.000195	0.000099	5297.147
	PTT_GARCH	0.000195	0.000098	5284.033
	GARCH	0.008324	0.001528	7461.267
	NEWS_GARCH	0.008388	0.001481	-229.402
	PTT-AGARCH	0.008300	0.001639	22018.592
MRK	PTT_GARCH	0.008324	0.001577	22109.615
	GARCH	0.000304	0.000174	959.818
	NEWS_GARCH	0.000304	0.000174	960.232
	PTT-AGARCH	0.000303	0.000175	2544.192
	PTT_GARCH	0.000302	0.000174	2541.086
MRNA	GARCH	0.003443	0.002197	553.102
	NEWS_GARCH	0.003425	0.002179	554.015
	PTT-AGARCH	0.003313	0.002052	1703.612
	PTT_GARCH	0.003346	0.002120	1694.034
	GARCH	0.000931	0.000344	10287.278
MSFT	NEWS_GARCH	0.000951	0.000432	10062.589
	PTT-AGARCH	0.000944	0.000364	27411.174
	PTT_GARCH	0.000947	0.000362	27337.024
	GARCH	0.002222	0.001249	2488.396
	NEWS_GARCH	0.002444	0.001091	989.716
NVDA	PTT-AGARCH	0.002284	0.001260	7327.866

PYPL	PTT_GARCH	0.002252	0.001262	7330.723
	GARCH	0.008893	0.002500	959.118
	NEWS_GARCH	0.009596	0.004117	923.836
QCOM	PTT-AGARCH	0.008763	0.002385	2904.392
	PTT_GARCH	0.008859	0.002562	2827.659
	GARCH	0.002015	0.001366	456.288
	NEWS_GARCH	0.002015	0.001368	457.063
	PTT-AGARCH	0.002028	0.001399	1338.489
ROKU	PTT_GARCH	0.002037	0.001410	1337.154
	GARCH	0.012574	0.005944	242.297
	NEWS_GARCH	0.012554	0.005996	244.366
	PTT-AGARCH	0.012593	0.006037	851.253
SHOP	PTT_GARCH	0.012619	0.005957	846.609
	GARCH	0.831894	0.222288	244.014
	NEWS_GARCH	0.551751	0.063502	-7345.315
	PTT-AGARCH	0.544892	0.104694	1034.490
SQ	PTT_GARCH	0.548005	0.080621	689.867
	GARCH	0.002833	0.001950	635.980
	NEWS_GARCH	0.005158	0.004123	559.483
	PTT-AGARCH	0.002801	0.001915	1922.494
	PTT_GARCH	0.002822	0.001985	1920.068

جدول 8 نتائج المرحلة الثانية من عملية بناء النموذج

3.3.5 تفسير النتائج

تعكس نتائج المرحلة الثانية من الدراسة الفروق الجوهرية في الأداء بين النماذج الأربعة المختبرة، وهي GARCH التقليدي، News-GARCH ، PTT-GARCH ، و PTT-AGARCH، عند تطبيقها على الأسهم المختبرة حيث تم تقييم النماذج من خلال بعدين رئيسيين: الملاءمة داخل العينة باستخدام Log-Likelihood، والأداء خارج العينة من خلال Walk-Forward Forecasting، مع مؤشرات RMSE و MAE لقياس دقة التنبؤ.

1. الأداء داخل العينة

تُظهر قيم Log-Likelihood أن النموذج PTT-AGARCH يحقق أفضل ملاءمة إحصائية في معظم الأسهم، حيث سجل أعلى قيم موجبة مقارنة بالنماذج الأخرى، مما يشير إلى قدرته على تمثيل البنية الديناميكية للتقلبات في الأسواق المالية بدقة أكبر. فمثلاً، أسهم BABA، C، BAC، و MSFT سجلت تحسناً ملحوظاً في Log-Likelihood، ما يعكس أن إدخال الأخبار المتأخرة ضمن النموذج ساعد على التقاط التأثير المستمر للأحداث الإخبارية على العوائد. في المقابل، أظهر نموذج News-GARCH أداءً ضعيفاً داخل العينة لبعض الأسهم مثل AMZN و GOOGL، حيث جاءت القيم سالبة وبفوارق كبيرة، وهو ما يدل على أن استخدام الأخبار اللحظية فقط قد يؤدي إلى تشويش النموذج بدلاً من تحسينه.

2. الأداء خارج العينة

بناءً على مؤشرات RMSE و MAE، يُلاحظ أن النموذج PTT-AGARCH يوفر أدق التنبؤات خارج العينة في أغلب الحالات، إذ جاءت قيم الأخطاء لديه أقل من النماذج الثلاثة الأخرى، خصوصاً في الأسهم ذات التأثير العالي بالأخبار مثل BAC، C، JPM و MSFT. هذا الانخفاض في RMSE و MAE يعكس كفاءة النموذج في التنبؤ بالتقلبات المستقبلية من خلال دمج المعلومات الإعلامية بطريقة ديناميكية تراعي التأثير المتدرج للأخبار السابقة على السلوك المستقبلي للأسعار.

3. تأثير عدم التماثل في استجابة التقلبات

النموذجان PTT-GARCH و PTT-AGARCH يتميزان بأخذ عدم التماثل في استجابة التقلبات للصددمات الإيجابية والسلبية في الاعتبار، إلا أن PTT-AGARCH يتفوق بإضافة عامل الأخبار المتأخرة، ما يجعله أكثر مرونة في تفسير التقلبات المركبة. لوحظ أن هذا التكامل بين الأخبار وعدم التماثل حسن أداء النموذج بشكل واضح في الأسهم ذات السلوك غير المتناظر مثل QCOM، CVX، و CSCO، حيث انخفضت مؤشرات RMSE و MAE مقارنة بالنماذج التقليدية.

4. أداء النموذج المقترح PTT-AGARCH

يقدم PTT-AGARCH في معظم الحالات أفضل توازن بين الملاءمة الإحصائية ودقة التنبؤ. بينما يحقق GARCH نتائج مستقرة في الأسهم الأقل حساسية للأخبار (مثل KO و MRK)، إلا أنه يعجز عن تمثيل الصدمات الديناميكية التي تظهر في أسهم التكنولوجيا والإعلام مثل AMZN و META و GOOGL. أما نموذج News-GARCH فقد أظهر أداءً متذبذباً بسبب حساسيته العالية لتقلبات الأخبار اللحظية، مما يؤدي إلى ضعف في Log-Likelihood رغم انخفاض محدود في RMSE في بعض الحالات..

5. تحليل الأداء حسب القطاعات

- قطاع التكنولوجيا (AMZN، GOOGL، META، MSFT): أظهرت تحسناً كبيراً عند استخدام PTT-AGARCH، حيث تمكّن النموذج من تفسير الارتباط بين الأخبار التقنية وسلوك الأسعار بشكل أكثر دقة.
- القطاع المالي (BAC، JPM، C): تحسن كبير في Log-Likelihood مع انخفاض ملحوظ في RMSE، مما يعكس أن الأخبار الاقتصادية والمالية ذات تأثير تراكمي واضح على هذه الأسهم.
- قطاع الطاقة والصناعة (CVX، QCOM، CSCO): يظهر أن عدم التماثل في الصدمات يلعب دوراً جوهرياً في تحسين الأداء، حيث تميزت هذه الأسهم بتحسين RMSE و MAE في النماذج غير المتماثلة.
- قطاع النمو السريع (SHOP، ROKU، PYPL): أظهرت تقلبات عالية، ومع ذلك حافظ PTT-AGARCH على أداء مستقر نسبياً مقارنة بالنماذج الأخرى.

6. الملاحظات العامة

- النموذج المقترح PTT-AGARCH أثبت كفاءته في تمثيل الأنماط الواقعية للسوق، خصوصاً للأسهم ذات التقلبات غير المتماثلة والتأثر الإعلامي العالي.
- النماذج التي لا تأخذ في الاعتبار الأخبار أو عدم التماثل (مثل GARCH) تفشل غالباً في التقاط الديناميكيات الحديثة للسوق.
- رغم الأداء المتميز ل PTT-AGARCH، إلا أن بعض الأسهم شديدة التقلب مثل SHOP أو AMZN ما زالت تُظهر أخطاء تنبؤ مرتفعة نسبياً، مما يدل على ضرورة تحسين مكونات الأخبار أو اختبار توزيعات بديلة للعوائد.
- تؤكد النتائج أن التكامل بين المعلومات الإخبارية (News Sentiment) والخصائص الإحصائية للسوق (Volatility Asymmetry) هو المفتاح لبناء نماذج دقيقة لتوقع التقلبات المستقبلية في أسواق المال.

4.5 تقييم النموذج المعمّم PTT-AGARCH (p,q)

في هذه المرحلة من الدراسة، ركزنا على تقييم النموذج المقترح PTT-AGARCH بهدف اختبار فعالية النموذج مقارنةً بالنماذج التقليدية ونماذج أخرى معدلة، وذلك في الحالة العامة (p,q) بدلاً من الحالة الخاصة (1,1).

1.4.5 اختبار الرتب المثلى

تم اعتماد معيار معلومات أكايكي (Akaike Information Criterion - AIC) كأداة أساسية لتقييم النماذج وتحديد البنية المثلى لكل نموذج من النماذج المقارنة. يعتمد هذا المعيار على مبدأ الموازنة بين جودة الملاءمة الإحصائية للنموذج وعدد المعلمات المقدّرة داخله، بحيث يهدف إلى الوصول إلى نموذج يتمتع بأفضل تفسير ممكن للبيانات دون الإفراط في التعقيد البنيوي الذي قد يؤدي إلى مشكلة الإفراط في التقدير.

جرى تحديد الرتب المثلى لكل من مكونات ARCH و GARCH وفق خطوات منهجية دقيقة. في البداية، تم تحديد نطاق القيم المحتملة لكل من رتب التباين الذاتي والتباين الشرطي (p,q) بحيث تراوحت بين 0 و 3، وذلك لضمان شمول النطاق

لجميع التركيبات الممكنة دون زيادة مفرطة في عدد النماذج. بعد ذلك تم تقدير النماذج لجميع التركيبات المحتملة من باستخدام بيانات العوائد المالية اليومية، مع مراعاة دمج عوامل الأخبار في النماذج المطورة التي تضمنت بنى إضافية مثل PTT-GARCH و PTT-AGARCH، واللذين تعتمدان على إدخال معاملات تمثل عتبة التفاعل بين الصدمات الموجبة والسالبة، إضافةً إلى تطبيق التحويل بالقوة (Power Transformation) لتحسين خصائص السلاسل الزمنية والتقليل من تأثير التوزيعات غير الطبيعية للعوائد.

تم حساب قيمة AIC لكل نموذج وفق المعادلة الرياضية:

$$AIC = -2L + 2k$$

حيث تمثل L قيمة دالة الاحتمالية القصوى (Log-Likelihood) التي تقيس مدى توافق النموذج مع البيانات، في حين يعبر k عن عدد المعلمات المقدرة داخل النموذج. وكلما انخفضت قيمة AIC دل ذلك على ملاءمة أعلى للنموذج مع البيانات من دون زيادة في التعقيد البنوي.

ويلاحظ من النتائج أن إدخال الية العتبة في نموذج PTT-GARCH ساهم في تحسين جودة الملاءمة مقارنة بالنموذج الكلاسيكي، إذ مكن من التقاط الاستجابات المختلفة للتقلبات الناتجة عن الصدمات السالبة مقارنة بالموجبة، وهي خاصية تعرف بتأثير الرافعة المالية، فيما اعتمد النموذج الكلاسيكي على التمثيل التقليدي لتقلبات العوائد دون تمييز بين اتجاهات الصدمات، مما جعله أقل دقة في توصيف السلوك الديناميكي للتقلبات مقارنة بالنموذج المطور.

2.4.5 التقييم خارج العينة باستخدام Walk-Forward Forecasting

لضمان موضوعية التقييم، تم تطبيق أسلوب التنبؤ المتحرك (Walk-Forward Forecasting) الذي يقوم على استخدام نافذة تقدير متحركة بطول 500 فترة، مع إعادة التقدير عند كل خطوة وتوليد تنبؤ لأفق يوم واحد. تم الاعتماد على مقاييس (RMSE) Root Mean Squared Error و (MAE) Mean Absolute Error لمقارنة جودة النماذج كما يوضح جدول 9.

STOCK	النموذج	ORDER	RMSE	MAE	LOG-LIKELIHOOD
AMZN	GARCH	(2, 1)	0.476822	0.026410	4234.870
	GARCH- News	(2, 1)	0.477969	0.029435	-264738.162
	PTT-GARCH	(1, 1)	1.017047	0.156084	20048.403
	PTT- AGARCH	(1, 1)	0.549764	0.071483	15993.805
BABA	GARCH	(2, 1)	0.004145	0.001112	2102.041
	GARCH- News	(2, 1)	0.004032	0.001627	2058.331
	PTT-GARCH	(2, 1)	0.004139	0.001101	6149.339
	PTT- AGARCH	(2, 1)	0.004155	0.001132	6081.362

BAC	GARCH	(1, 1)	0.000859	0.000329	2799.971
	GARCH- News	(1, 1)	0.000859	0.000329	2800.573
	PTT-GARCH	(1, 1)	0.000859	0.000330	7544.375
	PTT- AGARCH	(1, 1)	0.000857	0.000327	7571.239
C	GARCH	(1, 1)	0.000964	0.000343	28435.947
	GARCH- News	(1, 1)	0.000968	0.000344	28297.732
	PTT-GARCH	(1, 1)	0.000968	0.000342	76380.473
	PTT- AGARCH	(1, 1)	0.000963	0.000320	76860.694
CMCSA	GARCH	(1, 1)	0.001712	0.000880	339.130
	GARCH- News	(1, 1)	0.001766	0.001093	329.300
	PTT-GARCH	(1, 1)	0.001704	0.000876	957.263
	PTT- AGARCH	(1, 1)	0.001698	0.000834	980.326
CRM	GARCH	(2, 3)	0.001695	0.000647	897.263
	GARCH- News	(2, 3)	0.001634	0.000795	894.735
	PTT-GARCH	(1, 1)	0.001634	0.000800	2527.897
	PTT- AGARCH	(1, 1)	0.001633	0.000795	2535.716
CSCO	GARCH	(2, 3)	0.001316	0.000519	624.688
	GARCH- News	(2, 3)	0.001309	0.000687	605.406
	PTT-GARCH	(1, 1)	0.001305	0.000652	1691.657
	PTT- AGARCH	(1, 1)	0.001292	0.000643	1711.006
CVX	GARCH	(1, 1)	0.000525	0.000423	929.531
	GARCH- News	(1, 1)	0.000509	0.000398	937.254
	PTT-GARCH	(1, 1)	0.000532	0.000442	2564.446
	PTT- AGARCH	(1, 1)	0.000509	0.000395	2586.332
GOOGL	GARCH	(2, 1)	0.420333	0.020085	8027.420
	GARCH- News	(2, 1)	0.420297	0.022009	-305360.19
	PTT-GARCH	(3, 1)	0.546966	0.054707	25625.352
	PTT- AGARCH	(3, 1)	3.124118	0.687241	23445.128
JPM	GARCH	(2, 1)	0.000828	0.000352	6254.509
	GARCH- News	(2, 1)	0.000828	0.000353	6256.114
	PTT-GARCH	(1, 1)	0.000828	0.000352	16813.327
	PTT- AGARCH	(1, 1)	0.000827	0.000350	16832.330
KO	GARCH	(1, 1)	0.000195	0.000098	2046.544

	GARCH- News	(1, 1)	0.000200	0.000117	2034.845
	PTT-GARCH	(1, 1)	0.000195	0.000098	5284.033
	PTT- AGARCH	(1, 1)	0.000195	0.000099	5297.147
META	GARCH	(1, 1)	0.008324	0.001528	7461.267
	GARCH- News	(1, 1)	0.008388	0.001481	-229.402
	PTT-GARCH	(2, 1)	0.008431	0.001493	22119.688
	PTT- AGARCH	(2, 1)	0.008432	0.001498	21708.276
MRK	GARCH	(1, 1)	0.000304	0.000174	959.818
	GARCH- News	(1, 1)	0.000304	0.000174	960.232
	PTT-GARCH	(1, 1)	0.000302	0.000174	2541.086
	PTT- AGARCH	(1, 1)	0.000303	0.000175	2544.192
MRNA	GARCH	(1, 1)	0.003443	0.002197	553.102
	GARCH- News	(1, 1)	0.003425	0.002179	554.015
	PTT-GARCH	(1, 1)	0.003346	0.002120	1694.034
	PTT- AGARCH	(1, 1)	0.003313	0.002052	1703.612
MSFT	GARCH	(1, 1)	0.000932	0.000331	10290.030
	GARCH- News	(1, 1)	0.000951	0.000432	10062.589
	PTT-GARCH	(1, 1)	0.000947	0.000362	27337.024
	PTT- AGARCH	(1, 1)	0.000944	0.000364	27411.174
NVDA	GARCH	(1, 3)	0.002349	0.001081	2491.585
	GARCH- News	(1, 3)	0.002444	0.001091	989.716
	PTT-GARCH	(1, 1)	0.002252	0.001262	7330.723
	PTT- AGARCH	(1, 1)	0.002284	0.001260	7327.866
PYPL	GARCH	(3, 1)	0.009097	0.001852	965.554
	GARCH- News	(3, 1)	0.009596	0.004117	923.836
	PTT-GARCH	(1, 3)	0.009064	0.001823	2910.068
	PTT- AGARCH	(1, 3)	0.009102	0.001874	2911.394
QCOM	GARCH	(1, 1)	0.002015	0.001366	456.288
	GARCH- News	(1, 1)	0.002015	0.001368	457.063
	PTT-GARCH	(3, 3)	0.002047	0.001247	1346.262
	PTT- AGARCH	(3, 3)	0.002120	0.001069	1347.192
ROKU	GARCH	(1, 1)	0.012574	0.005944	242.297
	GARCH- News	(1, 1)	0.012554	0.005996	244.366

SHOP	PTT-GARCH	(2, 1)	0.013008	0.004500	847.991
	PTT-AGARCH	(2, 1)	0.012593	0.006037	851.253
	GARCH	(3, 3)	0.549868	0.063278	306.638
	GARCH-News	(3, 3)	0.551751	0.063502	-7345.315
	PTT-GARCH	(3, 2)	110.469798	110.468440	1037.196
	PTT-AGARCH	(3, 2)	0.556740	0.074420	1040.376
SQ	GARCH	(2, 1)	0.002908	0.001778	637.253
	GARCH-News	(2, 1)	0.005158	0.004123	559.483
	PTT-GARCH	(1, 1)	0.002822	0.001985	1920.068
	PTT-AGARCH	(1, 1)	0.002801	0.001915	1922.494

جدول 9 نتائج التقييم خارج وداخل العينة للمرحلة الثالثة

3.4.5 تفسير النتائج

توضح النتائج الفروق بين النماذج الأربعة المعممة إلى الحالة (p, q) : GARCH التقليدي، GARCH-News، PTT-GARCH، و PTT-AGARCH. تم تقييم الأداء باستخدام مؤشرات RMSE و MAE لقياس دقة التنبؤ خارج العينة، و Log-Likelihood لتقييم الملاءمة داخل العينة.

1. النموذج PTT-AGARCH يتفوق غالبًا:

يمكن ملاحظة أن نموذج PTT-AGARCH غالبًا ما يعطي أقل قيمة لـ RMSE و MAE مقارنة بالنماذج الأخرى، ما يشير إلى أنه أكثر دقة في التنبؤ بأسعار الأسهم. على سبيل المثال، في سهم BAC $RMSE = 0.000857$ و $MAE = 0.000327$ وهي الأفضل مقارنة بالنماذج الأخرى.

2. أهمية دمج الأخبار:

نموذج GARCH-News يحاول دمج المعلومات الإخبارية في التنبؤ بالتقلبات. في بعض الأسهم مثل CVX و BABA، يظهر تحسين طفيف في RMSE و MAE مقارنة بالنموذج التقليدي، لكنه غالبًا لا يتفوق على نماذج PTT الأكثر تعقيدًا.

3. تأثير عدم التماثل في التقلبات:

نماذج PTT-GARCH و PTT-AGARCH تأخذ في الاعتبار عدم التماثل في استجابة السوق للصدمات الإيجابية والسلبية، مما يحسن الأداء خاصة للأسهم ذات التقلب العالي أو الحساسة للأخبار مثل AMZN و GOOGL.

4. الملاءمة الإحصائية داخل العينة:

تشير قيم Log-Likelihood إلى أن نماذج PTT-GARCH و PTT-AGARCH بشكل عام توفر ملاءمة أفضل للبيانات داخل العينة، حيث تكون القيم أكبر بكثير مقارنة بالنموذج التقليدي في أسهم مثل C و MSFT.

5. أداء الأسهم الفردية:

- حقق النموذج PTT-AGARCH في السهم AMZN نتائج أفضل من حيث RMSE و MAE، بينما PTT-GARCH أعطى RMSE مرتفع نسبيًا، ما يدل على أن دمج عدم التماثل والأخبار معًا مهم.
- BABA وBAC: تحسينات طفيفة في الأداء، لكن PTT-AGARCH ما زال الأكثر دقة.
- GOOGL: نموذج PTT-GARCH و PTT-AGARCH يعطيان أداء أقل في RMSE مقارنة بالنموذج التقليدي، مع اختلاف كبير في Log-Likelihood، ما يشير إلى تحديات في التنبؤ بأسهم حساسة للأخبار الكبرى.
- META وMSFT: دمج الأخبار وعدم التماثل يساهم في دقة أعلى، خاصة في RMSE و MAE، مع Log-Likelihood مرتفع للنماذج المقترحة.
- ROKU وSHOP: ارتفاع بعض القيم في PTT-GARCH يعكس أحداثًا استثنائية أو صدمات كبيرة غير قابلة للتنبؤ بدقة، لكن PTT-AGARCH يقدم توازنًا أفضل.

6. مؤشر السوق KO وJPM:

- أداء النماذج يظهر أن الأسهم ذات التغيرات السعرية الأقل حساسية للأخبار اليومية ما زالت تستفيد من دمج عدم التماثل، حيث PTT-AGARCH يعطي RMSE و MAE أقل من النماذج الأخرى.

7. الملخص العام:

- دمج الأخبار المالية اليومية وتحليل عدم التماثل في التقلبات يحسن من دقة التنبؤ خارج العينة.
- نموذج PTT-AGARCH يوفر توازنًا جيدًا بين الأداء داخل وخارج العينة، ويعتبر الأفضل في أغلب الأسهم من حيث RMSE و MAE.
- الأداء يختلف حسب خصائص كل سهم، لكن دمج الأخبار وعدم التماثل يمثل تحسينًا مهمًا في نماذج التنبؤ بالتقلبات المالية.

5.5 نموذج PTT-AGARCH (p,q) مع دالة قياس الاخبار

تهدف هذه المرحلة من البحث إلى مقارنة أداء النماذج المختلفة من دالة قياس الاخبار. حيث تم تطوير ثلاثة نماذج رئيسية:

- نموذج PTT-GARCH التقليدي الذي يعتمد على بيانات العوائد السابقة فقط، دون دمج أي معلومات عن الأخبار والموضحة صيغته كما في المعادلة رقم (3).
- نموذج PTT-AGARCH المدعوم بدالة قياس الأخبار المباشرة (Direct News Factor) يُدمج تأثير الأخبار الإيجابية والسلبية للحظة الزمنية الحالية t مباشرة في تقدير التقلب بهدف اختبار مدى قدرة الأخبار اللحظية على تحسين توقعات التقلب مقارنة بالنموذج الأساسي وموضحة صيغته وفق المعادلة (14).
- نموذج PTT-AGARCH المدعوم بدالة قياس الأخبار المتأخر (Lagged News Factor) يُسمح لهذا النموذج بأخذ الأخبار السابقة عبر عدة فترات زمنية $j = 1, \dots, p_{lag}$ مع أوزان متفاوتة b_j بحيث يمكن تقييم تأثير الأخبار

المتأخرة على استجابة السوق. باعتبار أن الأسواق قد لا تتفاعل فورًا مع الأخبار الجديدة بل يظهر التأثير تدريجيًا عبر الزمن والمبينة صيغته وفق المعادلة (17).

$$\begin{aligned} \varepsilon_t &= z_t \sigma_t, \quad z_t \sim i.i.d.(0,1) \\ \sigma_t^r &= \left(\omega + \sum_{i=1}^p \alpha_i^+ (\max(\varepsilon_{t-i}, 0))^r + \sum_{j=1}^p \alpha_j^- (\max(-\varepsilon_{t-j}, 0))^r + \sum_{k=1}^q \beta_k \sigma_{t-k}^r \right) \cdot NFL_t \\ NFL_t &= a + \sum_{j=1}^p \frac{1}{2} b_j \left[\tanh\left(\frac{1}{2} \kappa_j P_{t-j}\right) - \tanh\left(\frac{1}{2} \gamma_j N_{t-j}\right) \right] \end{aligned} \quad (17)$$

تم اعتماد نهج منهجي لاختيار الرتبة المثلى من خلال تجريب جميع التركيبات الممكنة ضمن نطاق محدد (Akaike Information Criterion – أكاكي $(1 \leq p \leq 3, 1 \leq q \leq 3)$)، وذلك باستخدام معيار معلومات أكاكي (AIC) لقياس جودة النموذج. يتم حساب قيمة الـ AIC لكل نموذج فرعي، ثم يُختار النموذج الذي يحقق أقل قيمة لـ AIC باعتباره النموذج الأكثر كفاءة من حيث التوفيق بين جودة الملاءمة وعدد المعاملات المقدّرة.

1.5.5 آلية المقارنة

اعتمد أسلوب Walk-Forward Validation كإطار منهجي لتقييم قدرة النماذج المختلفة على التنبؤ بالتقلب المستقبلي للعوائد المالية. يقوم هذا الأسلوب على تقدير معلمات كل نموذج ضمن نافذة زمنية ثابتة، ثم استخدام هذه المعلمات لتوليد تنبؤات للفترة الزمنية التالية مباشرة. ثم يتم تحريك النافذة الزمنية خطوة خطوة عبر كامل السلسلة الزمنية، مما يتيح محاكاة أداء النماذج في بيئة ديناميكية تمثل طبيعة الأسواق المالية الحقيقية، وقد اعتمدت مجموعة من مؤشرات الأداء الأساسية مثل جذر متوسط مربع الخطأ (RMSE)، ومتوسط الخطأ المطلق (MAE) لمقارنة جودة النماذج وتحديد النموذج الأكثر ملاءمة لتمثيل تقلبات السوق.

2.5.5 شرح النتائج

السهم	(P,Q) ORDER	PTT-GARCH		Direct		Lagged	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
A	(1,1)	6.97439	2.87853	6.93763	2.87814	6.95308	2.89453
AA	(1,1)	27.35109	8.66403	27.74875	8.69044	27.58312	8.63712
ACHC	(1,3)	35.99348	9.28885	34.77101	9.17653	34.79066	9.20476
AEM	(1,1)	17.70581	8.65501	17.53621	8.52380	17.58589	8.56683
HUN	(1,3)	45.97639	9.82219	49.74337	10.03539	49.79075	10.02723
NXPI	(1,1)	23.78788	8.71158	23.71460	8.52326	23.41682	8.50851
PWR	(1,3)	25.80697	4.96836	25.66497	4.93292	25.67106	4.96942

جدول 10 مقارنة أداء النماذج المختلفة لدالة قياس الأخبار باستخدام مقاييس RMSE و MAE

تشير النتائج الموضحة في جدول 10 إلى أن النموذج الأساسي PTT-GARCH، الذي يعتمد فقط على بيانات العوائد السابقة دون دمج المعلومات الإخبارية، قدّم مستوى مقبولاً من الأداء، إلا أن قيم مؤشرات الخطأ (MAE و RMSE) كانت أعلى نسبياً مقارنة بالنماذج الأخرى. ويُعزى ذلك إلى أن النموذج التقليدي لا يأخذ في الحسبان العوامل الخارجية المؤثرة على سلوك السوق.

أما النموذج المدعوم بدالة قياس الأخبار المباشرة (Direct News Factor)، فقد أظهر أداءً أفضل نسبياً في معظم الحالات، إذ انخفضت قيم MAE و RMSE بشكل طفيف مقارنة بالنموذج الأساسي. ويُفسّر هذا التحسن بقدرة النموذج على استيعاب التأثير الفوري للأخبار الإيجابية أو السلبية التي تصدر في اللحظة الزمنية ذاتها، مما يُمكنه من التقاط استجابات السوق السريعة للأحداث الجارية.

يُظهر النموذج المدعوم بدالة قياس الأخبار المتأخرة (Lagged News Factor) أداءً متقارباً مع نموذج الأخبار المباشرة، كما يتفوق عليه في بعض الحالات الجزئية. ويشير ذلك إلى أن تأثير الأخبار لا يكون دائماً لحظياً، بل قد يمتد عبر فترات زمنية لاحقة نتيجة لتأخر استيعاب المستثمرين. وهذا ما يتوافق مع الفرضيات السلوكية التي ترى أن الأسواق قد تُظهر استجابة تدريجية للأخبار بسبب اختلاف مستويات الخبرة والمعلومات بين المشاركين.

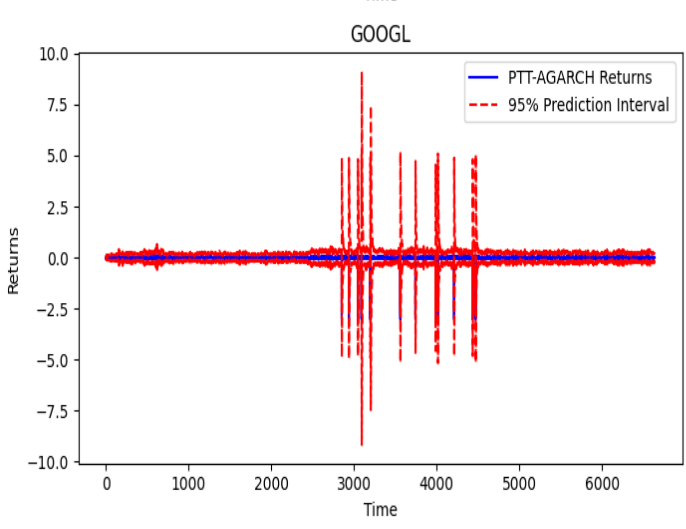

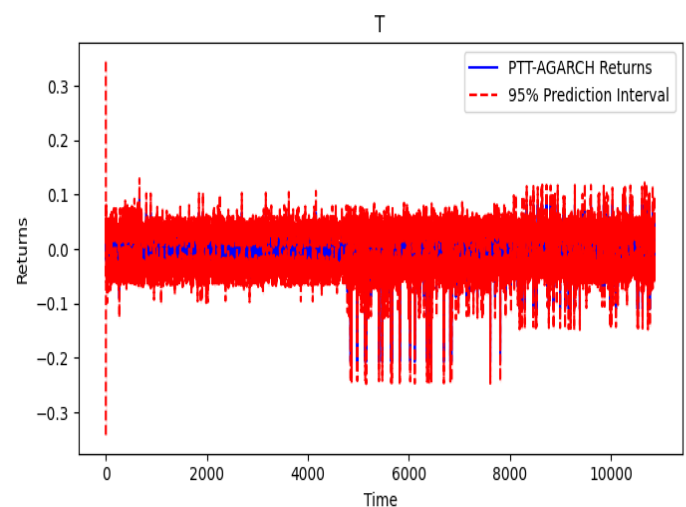
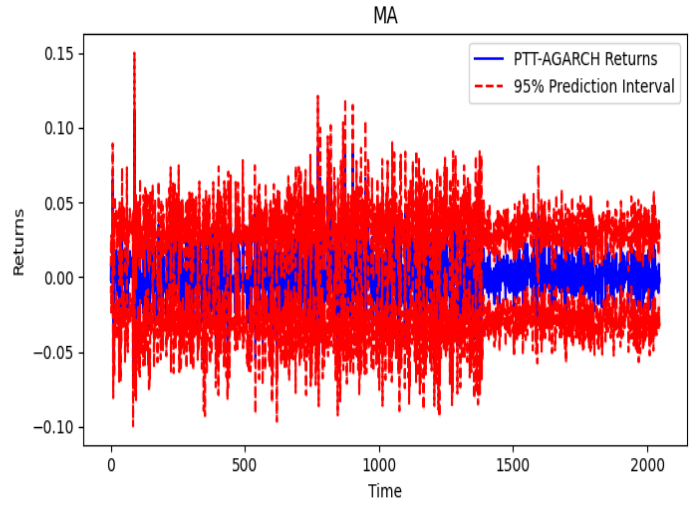
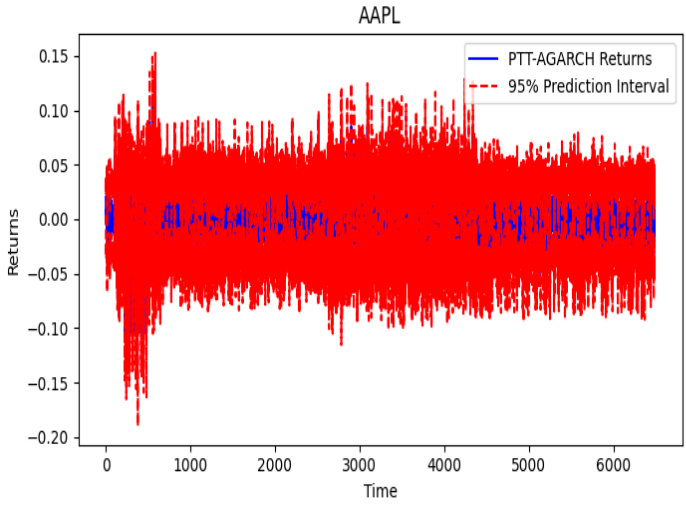
تشير النتائج إلى أن دمج الأخبار سواء المباشرة أو المتأخرة في نماذج التقلبات يحسّن من دقة التنبؤ مقارنة بالنموذج التقليدي، رغم أن هذا التحسن قد يكون محدوداً في بعض الحالات. ويؤكد ذلك أهمية العوامل الإخبارية في تفسير سلوك السوق المالي ودعم فرضية أن الأسواق لا تستوعب المعلومات فور صدورها بشكل كامل. كما تبين أن النموذج المدعوم بالأخبار المباشرة أكثر ملاءمة للأسواق ذات الاستجابة السريعة، في حين أن النموذج المدعوم بالأخبار المتأخرة يناسب الأسواق التي تتفاعل تدريجياً مع المعلومات. ومنه نستنتج أن اختيار النموذج الأنسب يرتبط بطبيعة السوق والقطاع المالي.

6.5 رسم مستويات الثقة للنموذج PTT-AGARCH

يتم توضيح السلوك الديناميكي كما في الشكل 14 لفواصل التنبؤ عند مستوى ثقة 95% والمستخلصة من نموذج PTT-AGARCH عند تطبيقه على سلسلة العوائد اليومية لخمسة أسهم مختلفة. تمثل الخطوط الحمراء المتقطعة حدود فاصل الثقة، بينما يعبر المنحنى الأزرق عن العوائد المقدّرة أو المتبقية الناتجة عن النموذج بعد دمج عامل الأخبار المتحللة داخل معادلة التباين الشرطي. ويُظهر هذا التمثيل البصري قدرة النموذج على تتبّع التقلبات الزمنية والتفاعل مع الصدمات السعرية والأحداث الإخبارية التي تؤثر على الأسواق المالية.

وتعكس الفجوة بين الحدود العليا والدنيا لفواصل التنبؤ مستوى عدم اليقين المصاحب لكل فترة زمنية، حيث يتوسع هذا الفاصل خلال فترات الاضطراب وارتفاع التذبذب، بينما ينكمش عند الاستقرار النسبي للسوق. وتبرز اختلافات واضحة بين الأسهم الخمسة؛ إذ تظهر أسهم التكنولوجيا مثل AAPL و GOOGL نطاقات واسعة للتنبؤ في فترات معينة نتيجة لحساسية أكبر تجاه الأخبار والأحداث الجوهرية، في حين تتسم أسهم قطاع الاتصالات مثل T و VZ بدرجة أقل من

التقلب باستثناء فترات محددة ترتبط غالبًا بإعلانات أو تغييرات تنظيمية مؤثرة. أما سهم الخدمات المالية MA فيُظهر سلوكًا أكثر استقرارًا مع نطاقات تنبؤ ضيقة نسبيًا تتوافق مع طبيعة حركته السوقية. وتؤكد هذه النتائج فعالية نموذج PTT-AGARCH في التقاط الخصائص الزمنية المعقدة للتقلب، بما في ذلك تكتل التباين ووجود التأثيرات غير المتماثلة الناتجة عن الأخبار. الذي يمكّن النموذج من تمثيل التأثير السلوكي للمعلومات بطريقة أكثر واقعية مقارنة بالنماذج التقليدية المعتمدة على العوائد فقط.



الشكل 14 العوائد المقدرة لكل سهم مع فاصل التنبؤ 95% الناتج عن نموذج PTT-AGARCH.

الفصل السادس

الخاتمة والافاق المستقبلية

1.6 الخاتمة

تهدف هذه الدراسة إلى تطوير نماذج كمية متقدمة للتنبؤ بتقلبات السوق المالي وأسعار الأسهم، من خلال الجمع بين النماذج الاحتمالية الكلاسيكية للتقلب (ARCH/GARCH) والمداخل الحديثة المستندة إلى دمج العوامل الخارجية المشتقة من الأخبار المالية والاقتصادية. وقد تدرج العمل البحثي عبر ثلاث مراحل رئيسية، سمحت بتطوير تصور تدريجي للنماذج، واختبار فعاليتها في تحسين دقة التنبؤ.

في المرحلة الأولى، جرى التركيز على اختبار نموذج ARCH التقليدي، ثم مقارنته مع نموذج Sentiment-ARCH الذي أدخلت فيه مؤشرات الأخبار كمصدر خارجي للمعلومات. وأظهرت النتائج أن إدماج الأخبار ساهم في تفسير جزء أكبر من التباين في العوائد مقارنة بالاعتماد على البيانات التاريخية فقط، ما قدم دليلاً أولياً على جدوى هذا التوجه في تعزيز القدرة التنبؤية للنماذج.

المرحلة الثانية مثلت نقطة التحول الرئيسية، حيث تم دمج الأخبار المالية اليومية في نماذج التقلب التقليدية مثل GARCH (1,1)، وتوسيعها لتشمل النماذج الأكثر تعقيداً مثل PTT-GARCH و PTT-AGARCH، بهدف تحسين القدرة التنبؤية واستيعاب ديناميكيات السوق الفعلية. أظهرت النتائج أن إدخال الأخبار كمصدر خارجي، مع تعميم دالة الأخبار لتضمين مستويات الثقة لكل خبر، أدى إلى تحسن واضح في دقة التنبؤ مقارنة بالاعتماد على العوائد التاريخية فقط، إذ عكست مؤشرات RMSE و MAE انخفاضاً ملحوظاً في الأخطاء عند استخدام نموذج News-GARCH و PTT-AGARCH. كما أظهرت التحليلات أن النماذج غير المتماثلة مثل PTT-GARCH و PTT-AGARCH أكثر كفاءة في تمثيل الاستجابة المختلفة للتقلبات الإيجابية والسلبية، بما يجعلها أكثر واقعية في توصيف سلوك الأسواق المالية. وقد جاء نموذج PTT-AGARCH في مقدمة النماذج من حيث الأداء، حيث جمع بين تأثير الأخبار، مستويات الثقة، وعدم التماثل في التقلبات، محققاً أدنى قيم RMSE و MAE وأفضل ملاءمة إحصائية داخل العينة.

أما في المرحلة الثالثة، فقد تم تعميم النموذج المقترح PTT-AGARCH(p,q) ليشمل رتبتين عامتين بدلاً من الاقتصار على الرتبة (1,1)، بحيث يسمح هذا التعميم بالتقاط ديناميكيات أكثر تعقيداً للتقلبات على مدى أطول من الفترات السابقة. كما شمل التعميم إدماج دالة الأخبار المعدلة التي تأخذ في الاعتبار مستويات الثقة للأخبار، ما يعزز قدرة النموذج على التفريق بين الأخبار ذات التأثير الكبير والأخرى الأقل تأثيراً، مع الحفاظ على آلية العتبة (Threshold Effect) لمعالجة الاختلاف في استجابة السوق للصدمات الإيجابية والسلبية.

أظهرت نتائج التقييم أن النموذج المعمم يتفوق على النماذج السابقة، بما في ذلك GARCH(p,q) و PTT-GARCH(p,q)، عبر اختبارات التنبؤ المتقدم، ما يعكس قدرة PTT-AGARCH(p,q) على تمثيل التقلبات المالية بدقة ومرونة أكبر.

وقد أثبتت الدراسة تجريبياً أن النماذج الهجينة التي تدمج الأخبار المالية مع البيانات التاريخية، وتستفيد من مستويات الثقة داخل دالة الأخبار المعدلة، قادرة على تقديم قيمة مضافة في تفسير ديناميكيات التقلبات السوقية، بما يسهم في بناء أدوات أفضل لإدارة المخاطر وصياغة استراتيجيات استثمارية أكثر دقة، ويضع PTT-AGARCH(p,q) كخيار متقدم للباحثين والممارسين الراغبين في دمج المعلومات الإخبارية ضمن نماذج التنبؤ بالأسواق المالية.

2.6 الافاق المستقبلية

بالرغم من النتائج الإيجابية التي تحققت، فإن هذا البحث يفتح الباب أمام عدة مسارات بحثية مستقبلية، يمكن من خلالها تعزيز دقة وفعالية النماذج المقترحة:

1. توسيع قاعدة البيانات الإخبارية:

يقتصر التحليل الحالي على الأخبار المالية العامة، بينما يمكن إدماج مصادر أكثر تنوعاً مثل شبكات التواصل الاجتماعي (Twitter, Reddit) أو تقارير المحللين الماليين، مما قد يتيح قياساً أدق لمعنويات المستثمرين.

2. تطبيقات قطاعية (Sectoral Applications) :

يمكن توسيع التجارب لتشمل قطاعات مختلفة مثل الطاقة، التكنولوجيا، والقطاع الصحي، لاختبار ما إذا كانت تأثيرات الأخبار تختلف تبعاً لطبيعة القطاع.

3. الاختبار في بيئات مختلفة (Cross-market Testing) :

سيكون من المفيد التحقق من أداء النموذج عبر أسواق مالية مختلفة (مثل الأسواق الناشئة مقابل الأسواق المتقدمة) لمعرفة مدى الحاجة للتعميم للتخصيص.

المراجع

1. A. Sadik و S Mitra .(2018) .News Augmented GARCH(1,1) Model for Volatility Prediction . *IMA Journal of Management Mathematics* .20-1 ،doi:10.1093/imaman/dpy004
2. Artur Silva Lopes .(2025) .*Introduction to the Univariate Analysis of Trends in Economic Time Series* .Kiel,Hamburg: ZBW – Leibniz Information Centre for Economics.
3. C. Francq and J.-M. Zakoian .(2019) .*GARCH Models: Structure, Statistical Inference and Financial Applications* .Wiley.
4. Christian Gouriéroux .(1997) .*ARCH Models and Financial Applications* .New York, NY: Springer.
5. Christian Schmitt .(1996) .*Option pricing using EGARCH models* .ZEW - Leibniz Centre for European Economic Research.
6. D. T Araci .(2019) .*FinBERT: Financial sentiment analysis with pre-trained language models* . arXiv من الاسترداد من <https://doi.org/10.48550/arXiv.1908.10063>
7. Douglas Youvan .(2024 ,6) .Understanding Sentiment Analysis with VADER: A Comprehensive Overview and Application . doi:<https://doi.org/10.13140/RG.2.2.33567.98726>
8. el and Román A.Mendoza-Urdiales .(2022) .Twitter Sentiment Analysis and Influence on Stock Performance .*Entropy*.16 ،
9. Gianluca Anese .(2019) .*Explanatory power of GARCH models using news-based investor sentiment: Applications of LSTM networks for text classification* .Venice: Università Fa' Foscari.
10. Gwilym M. Jenkins, Gregory C. Reinsel, Greta M. Ljung George E.P. Box .(2015) .*Time Series Analysis: Forecasting and Control,5th Edition* .John Wiley & Sons.
11. H. Hwang and I. V. Basawa .(2004) .Stationarity and moment structure for Box–Cox transformed threshold GARCH(1,1) processes .*Statistics & Probability Letters*.220–209 ،(68)
12. H. Hwang and T. Kim .(2004) .Power-transformed and threshold ARCH models .*Journal of Statistical Planning and Inference*.217–195 ، 123 ،
13. H. Mao, and X. Zeng J. Bollen .(2011) .Twitter Mood Predicts the Stock Market .*Journal of Computational Science*.8-1 ،(1)2 ،
14. J. Chan, and J. Karolyi M. Chan .(2013) .Interconnectedness in Financial Markets: Evidence from Global Equity Markets .*Journal of Financial Economics*.324–299 ،(2)107 ،
15. Jacob Devlin ،Ming-Wei Chang ،Kenton Lee و ،Kristina Toutanova .(2018) .*BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding* .Google AI Language.

16. James Grant .(1990) .Stock Volatility and the Crash of '87 .*Review of Financial Studies* ,(1)3 ،
.102-77
17. Jamie Atkinson ،Gautam Mitra و ،Xiang Yu .(2016) .Volatility forecast using GARCH, news sentiment and implied volatility .*SSRN Electronic Journal* .doi:0.2139/ssrn.3406102
18. M. Baker and J. Wurgler .(2007) .Investor sentiment in the stock market .*Journal of Economic Perspectives*.151–129 ،(2)21 ،
19. M. H. Hoti and J. Ajdari .(2023) .Sentiment Analysis Using the Vader Model for Assessing Company Services Based on Posts on Social Media .*SEEU Review*.33-19 ،(2)18 ،
20. Marc S Paoletta .(2018) .*Linear Models and Time-Series Analysis* .Hoboken, NJ :Wiley.
21. Massimo Guidolin .(2018) .*Autoregressive Moving Average (ARMA) Models and their Practical Applications* .Università Bocconi.
22. N. Al-Jallad .(2025) .*N. Al-Jallad, Text Generation using Machine Learning Based on Knowledge Graphs, M.S. thesis* .Damascus: HIAST.
23. Naga Pillada و ،Sangeetha Rangasamy .(2023) .An empirical investigation of investor sentiment and volatility of realty sector market in India: an application of the DCC–GARCH model .*SN Business & Economics*.16–1 ،(3)
24. P. C. Tetlock .(2007) .Giving content to investor sentiment: The role of media in the stock market .*Journal of Finance*.1168–1139 ،(3)62 ،
25. P. Tetlock .(2010) .Forecasting Stock Market Volatility Using News Analytics .*Financial Analysts Journal*.49–33 ،(6)66 ،
26. R. Engle .(1982) .Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation .*Econometrica*.1007–987 ،(4)50 ،
27. S. Y. Hwang and T. Y. Kim .(2004) .*Stochastic Processes and their Applications* .Seoul and Taegu, South Korea: Department of Statistics, Sookmyung Women's University and Keimyung University.,
28. T. Bollerslev .(1986) .Generalized Autoregressive Conditional Heteroskedasticity .*Journal of Econometrics*.327–307 ،(3)31 ،
29. T. Loughran and B. McDonald .(2011) .When is a Liability not a Liability ?*Journal of Finance* ،
.65–35 ،(1)66
30. Tawfik and Zakoian, jean-michel Hamadeh .(2011 ,01) .Asymptotic properties of LS and QML estimators for a class of nonlinear GARCH processes .*Journal of Statistical Planning and Inference*.507-488 الصفحات ،

31. Tim Bollerslev ،Ray Y. Chou و ،Kenneth F Kroner .(1992) .ARCH modeling in finance: A review of the theory and empirical evidence .*Journal of Econometrics*(North-Holland)5 ،-59.
32. Torsten Ullrich .(2021) .On the Autoregressive Time Series Model Using Real and Complex Analysis .*Forecasting*.728-716 ،
33. X. Fuehres, and P. Gloor Y. Zhang .(2011) .Predicting Stock Market Indicators Through Twitter 'I hope it is not as bad as I fear .*Procedia - Social and Behavioral Sciences*.62-55 ، 26 ،
34. Yanlin Shi و ،Kin-Yip Ho .(2020) .News sentiment and states of stock return volatility: Evidence from .*Finance Research Letters* .doi:10.1016/j.frl.2020.101446
35. Yanxin Shen و ،Pulin Kirin Zhang .(2023) .*Financial Sentiment Analysis on News and Reports Using Large Language Models and FinBERT* .Hangzhou, China; Bethlehem, USA: Zhejiang University & Lehigh University.
36. شيخي محمد. (2012). طرق الاقتصاد القياسي محاضرات وتطبيقات. عمان: دار ومكتبة الحامد للنشر والتوزيع.