



## Volatilitenin Modellenmesi: Nasdaq 100 Endeksi Örneği

### Modelling Volatility: Nasdaq 100 Index Example

Mehmet Erkan Soykan<sup>a</sup>

<sup>a</sup>Dr. Öğr. Üyesi, Kayseri Üniversitesi, Sosyal Bilimler Meslek Yüksekokulu, Yönetim ve Organizasyon Bölümü, Kayseri / Türkiye, mehmeterkan.soykan@kayseri.edu.tr, ORCID: 0000-0003-2329-4315 (Sorumlu Yazar/Corresponding Author)

#### MAKALE BİLGİSİ

#### ÖZ

##### Makale Türü

Araştırma Makalesi

##### Anahtar Kelimeler

Nasdaq 100 Endeksi  
Volatilité Modellemesi  
GARCH Modelleri

**Geliş Tarihi:** 29 Aralık 2023

**Kabul Tarihi:** 26 Şubat 2024

Bu çalışmada ABD'de teknoloji ağırlıklı firmalardan oluşan Nasdaq 100 endeksinin volatilitésinin tahmini ve modellenmesinin gerçekleştirilmesi amaçlanmaktadır. Analizde 09/01/1998 ile 10/11/2023 tarihleri arasındaki haftalık veriler kullanılmaktadır. Veri sapan gözlemlerden arındırılmakta, ayrıca varyansta kırılma tarihleri de saptanmaktadır. Analizde Akaike bilgi kriterine göre toplam 11 adet farklı Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (GARCH) sınıfı model kıyaslanmakta ve endeksi en iyi modelleyen model tespit edilmeye çalışılmaktadır. Analiz sonuçlarına göre student dağılımı için en uygun modelin Akaike bilgi kriterine göre ARMA(5,5)-EGARCH (Üssel GARCH) olduğu belirlenmiştir. Dağılım student yerine GED (Genelleştirilmiş hata dağılımı) yapıldığında ise en uygun model Parçalı Bütünleşik Üssel GARCH (FIEGARCH) çıkmaktadır. Ayrıca Üssel GARCH (EGARCH) modelinin de sıralamada en iyi ikinci model olduğu görülmektedir.

#### ARTICLE INFO

#### ABSTRACT

##### Article Type

Research Article

##### Keywords

Nasdaq-100 Index  
Volatility Modelling  
GARCH Models

**Received:** Dec, 29, 2023

**Accepted:** Feb, 26, 2024

In this study, it is aimed to estimate and model the volatility of the Nasdaq 100 index, which consists of technology-oriented companies in the USA. Weekly data between 09/01/1998 and 10/11/2023 is used in the analysis. Observations that deviate extremely from the data are eliminated, and break dates in the variance are also determined. In the analysis, a total of 11 different GARCH models are compared according to the Akaike information criterion and the model that models the index best is tried to be determined. According to analysis results, it is determined that the most appropriate model for the student distribution is ARMA (5,5)-EGARCH model according to the Akaike criterion. When the distribution is changed to GED (Generalized Error Distribution) instead of student distribution, the best model becomes FIEGARCH. Also EGARCH becomes the second best model in GED distribution.

#### Extended Abstract

**Aim:** In this article, it is aimed to determine the GARCH model that best models the volatility of Nasdaq 100 index. In past studies, it has been observed that a choice of at most 3-4 GARCH methods is generally made. In some studies, it is seen that the GARCH (1,1) model is preferred without any comparison. It is believed that this article will contribute to the literature as it compares a total of 11 GARCH models by making a more detailed analysis (for example, by modifying outliers and detecting structural breaks in variance), determines the GARCH method that provides the most appropriate modelling, and uses the most up-to-date data. In addition, since the data range is kept wide, the 2001 recession, 2008 crisis and 2020 COVID cases are taken into account. As a result of this analysis, investors, academics and policy makers can also use the directly recommended model when they analyse Nasdaq 100 index in their research. In addition, while researchers are performing tests such as causality in variance in the series in question, Diebold Yilmaz tests, and, for example looking at the effect of the volatility of the exchange rate, the EGARCH model, which is directly

**Atıf/Cite as:** Soykan, M. E. (2024). Volatilitenin Modellenmesi: Nasdaq 100 Endeksi Örneği. *Uluslararası Ekonomi, İşletme ve Politika Dergisi*, 8(1), 139-153.



Bu makale, [Creative Commons Atıf \(CC BY\)](https://creativecommons.org/licenses/by/4.0/) lisansının hüküm ve koşulları altında dağıtılan açık erişimli bir makaledir. / This article is an open access article distributed under the terms and conditions of the [Creative Commons Attribution \(CC BY\)](https://creativecommons.org/licenses/by/4.0/) license.

suggested in this research and is believed to best represent the data, can be used by adding structural breaks if necessary.

**Methods:** In the analysis, weekly returns of Nasdaq 100 index between 09/01/1998 and 10/11/2023 are utilised. There is a total of 1349 data used in the research. The formula  $\ln(P_t/P_{t-1})$  is utilised when converting the price level data to return data. The extreme values (outliers) in the data can affect GARCH model parameters and volatility estimation negatively. Verardi and Vermandele (2018) suggested a simple outlier test for series which have high kurtosis and skewness. Their test is basically based on boxplot graphical calculation. In literature there are various methods to correct these extreme values(outliers). For example, Bodart and Candelon approach (2009) which has also been applied in this article, has advised to take average of 10 days around the extreme value. Another abnormal situation which arises in financial series is breaks in variance. Also breakpoints in the variance are calculated in this research by following Sanso etc. (2004) method, which is modified for series that do not have normal distribution and that have ARCH effects. After taking extreme values into consideration, descriptive statistics are reported and unit root tests (ADF and PP) are done for the return index. Before passing to GARCH modelling, ARMA structure of the index is decided according to the lowest Akaike Information Criteria. After deciding on the suitable ARMA structure, information criteria for different GARCH models is calculated. 11 different candidate GARCH models tried are GARCH, EGARCH, GJR GARCH, APARCH, IGARCH, FIGARCH\_BBM, FIGARCH\_CHUNG, FIEGARCH, FIAPARCH\_BBM, FIAPARCH\_CHUNG and HYGARCH and best GARCH model is recommended based on the lowest Akaike Criterion findings. Models are first estimated by using student distribution and also by utilising GED distribution to see robustness of the results.

**Findings:** After the extreme values(outliers) are adjusted in the return index by using Bodart and Candelon approach (2009), descriptive statistics are calculated. Minimum and maximum values are -14.697 and 10.909 respectively. The average value is 0.18003. Standard deviation of return index is 3.2948. Also the index has high kurtosis and negative skewness. According to the Jarque-Bera test the probability is 0, therefore the data does not have normal distribution. ARCH and Q tests indicate that there is no autocorrelation but there is ARCH effect at 1% significance level. Also ADF and PP unit root tests show that the return index is stationary at 1% significance level. In the analysis, two breaks are detected in the variance of Nasdaq 100 index after Sanso et al. (2004) method, which is especially appropriate for the series with ARCH effect and not normal distribution is applied. The breakdates are 21.01.2000 and 26.10.2001 respectively.

According to the Akaike criteria ARMA (5,5) is chosen as appropriate method since it has lowest value. Afterwards, 11 different candidate GARCH models are tried and ARMA (5,5)-EGARCH is found as the best model for Nasdaq 100 index for student distribution since it has the lowest Akaike information criteria among the models which do not have convergence problem. According to the model estimation there is leverage effect in the return index since theta1 parameter is negative and significant. This means that negative shocks increase the volatility more than the positive shocks. Also ARCH and Q tests show that there is no autocorrelation and heteroscedacity in the model. For robustness model comparison is also made for GED distribution and FIEGARCH is found as the best method and EGARCH is found as the second best model for the index among the candidate models which do not have convergence problems.

**Conclusion:** In this article, using weekly data between 09.01.1998 and 10.11.2023, it is tried to determine the GARCH method that best models the volatility of the Nasdaq 100 index, which is traded in the USA and consists mainly of technology companies. Since the importance of technology and innovation is increasing today, and considering that indices in the USA are generally taken into consideration for comparison purposes in studies on volatility, it is believed that the findings of this study will be guiding for analysts and practitioners. Because when academics use this index directly

or as a benchmark, they generally utilise the GARCH (1,1) model directly or try at most 3 or 4 methods and try to determine the best model. It is believed that this article contributes to the literature by trying 11 different GARCH candidate methods and determining the most appropriate model according to the information criterion. In addition, outliers are detected and adjusted in the analysis, and structural breaks in volatility are examined. As far as it is known such a detailed study has not been conducted for this index before. When the student distribution, which is generally used in analyses, is utilised, the most appropriate model is found to be EGARCH according to the Akaike information criterion. When the distribution is GED, it is found that the FIEGARCH method is the best model, again according to the Akaike information criterion, and EGARCH is the second best model in this distribution. Therefore, investors, academicians and analysts may be advised to use the EGARCH model directly when it comes to modelling the volatility of this Nasdaq 100 index, or the investor can estimate the EGARCH and FIEGARCH methods and choose the model that gives the best results. In future studies, the most appropriate method that is successful in modelling the volatility of other important indices traded in the USA (for example S&P 500) can be tried to be determined and the findings can be compared with the outputs of this article. Additionally, the robustness of the results can be examined by changing the data range and data frequency (weekly) utilised in this analysis.

## 1. Giriş

Finansal piyasalarda uluslararası ve ulusal çok sayıda oyuncu rol oynamaktadır. Oyuncular sınırlı kaynaklarla faydayı maksimize etmeyi ve bunları en düşük riskle gerçekleştirmeyi amaçlamaktadırlar. Fakat her piyasa ekonomik ve politik şartlar, teknolojik ilerlemeler ve küreselleşme ile etkilenebilmekte ve bu yüzden makro bakımından volatil(oyunak) yapıya sahip olmaktadır. Bu koşullar altında yatırımcı ilerde edineceği kazanç için belirsizlik ve risk içerisinde kararını vermek zorundadır. Yatırımcı bir yandan faydasını en yükseğe çıkartırken bir yandan da piyasada oluşan risk ve volatilitelere ihtiyatlı bir yaklaşım sergilemektedir (Tuna ve İsabetli, 2014: 21).

Literatür bölümünde de ayrıntılı belirtileceği gibi Nasdaq 100 endeksini analiz eden ve volatilitate tahmini yapan çoğu çalışmada en fazla 3-4 çeşit GARCH modeli (Genelleştirilmiş Otoregresif Koşullu Değişen Varyans) kullanıldığı ve en uygun modelin bazı bilgi kriterlerine dayanarak saptandığı bazen de direkt hiçbir kıyaslama yapılmadan sadece temel GARCH(1,1) modelinin kullanıldığı görülmektedir. Ayrıca çoğu çalışmada detaylı bir sapan gözlem tespiti ve varyansta kırılmaların dikkate alınmadığı anlaşılmaktadır. Nasdaq 100 endeksi sadece ABD'de ilgili endeksin volatilitelerini tahmin ederken değil başka ülke borsalarıyla ilişkilerini incelerken de kullanıldığından bu endeksi modelleyen en uygun ekonometrik modelin bulunması önem arz etmektedir. Bu bağlamda bu makalede çok farklı GARCH sınıfı modelleri (toplam 11 adet) kullanarak, endekste sapan gözlem ve varyansta yapısal kırılmaları da tespit ederek Nasdaq'daki volatilitateyi en iyi tahmin eden volatilitate modelini tespit etmek amaçlanmaktadır. Böylece yatırımcı veya analist benzer zaman aralığında bu endeksi kullanırken direkt bu makalede önerilen volatilitate modelini de dikkate alabilir. Teknoloji ve inovasyon unsuru günümüzde büyük önem kazandığı ve yapılan analizlerde genellikle Nasdaq endeksi kullanıldığından özellikle bu endeks seçilmiştir. Ayrıca araştırmacılar ilgili Nasdaq serisinde varyansta nedensellik, Diebold Yılmaz testleri gibi başka analizler gerçekleştirirken ve örneğin döviz kurunun Nasdaq endeksinin volatilitesine olan etkisini incelerken de bu araştırmada direkt önerilen ve veriyi en iyi temsil ettiğine inanılan modeli gerekirse yapısal kırılmalar da ilave ederek kullanabilirler.

Girişten sonra volatilitate ve Nasdaq 100 endeksi kavramsal ve teorik olarak ikinci bölümde açıklanmıştır. Üçüncü bölümde Nasdaq ile ilgili literatür taraması sunulmakta, dördüncü bölümde

analiz ile ilgili bilgi verilmekte bu bağlamda sırasıyla veri seti, metodoloji ve elde edilen bulgulara yer verilmekte, son olarak makalenin sonuç bölümüne yer verilmiştir.

## 2. Volatilite ve NASDAQ 100 Endeksi

Volatilite kavramı oynaklık olarak da anılmakta olup, değişkenin değerinin belli bir ortalama değer baz alındığında aşırı artış ya da azalış sergilemesidir. Finansal piyasada meydana gelen volatilitelere ele alınan endeks ya da menkul kıymetlerin değerinde belirli bir periyotta aniden artış ya da azalış yaşanmasıdır. İstatistiksel olarak ifade edilirse, volatilite ilgili serideki gözlem değerlerinin aritmetik ortalamasının etrafında yayılmasının ya da dağılımının bir ölçümüdür (Eraslan, 2022:57; Özdemir, 2011: 39).

Volatilite kavramı 30 yılı aşkın süredir çok sayıda akademisyenin, politika oluşturucuların ve uygulamacıların yoğun ilgisini çekmiş, hem uygulamalı hem de teoriye dayanan araştırmaların da odak noktası olmuştur. ABD’de özellikle 1987’de meydana gelen borsa krizinin ardından finansal piyasada volatilite kavramının önem derecesi katlanarak artış göstermiştir ve günümüzde piyasada volatilite kavramı halen önemini korumaktadır (Telçeken, 2014:9; Brooks, 1998: 59; Yu, 2002:193).

Volatilitede etkide bulunan en önemli unsur, piyasalara ulaşan bilgilerin sıklığı ve önemidir. Yatırımcı piyasalara gelen ciddi haberi dayanak tutarak karar vermeye çalışır. Volatilitenin yükselmesine yol açacak bazı nedenler aşağıdaki gibi ifade edilebilir (Gürbüz, 2018: 59; Akel, 2011:7):

- Yeterince derinlik sağlanamamış finansal piyasanın varlığı
- Enflasyonda meydana gelen dalgalanma ve enflasyonun yüksek olması
- Ekonomik büyüme verisinde meydana gelen yüksek dalgalanma
- Kısa dönem faiz oranında yaşanan oynaklık
- Resesyon ve düşük büyüme hızı

Finansal piyasa volatilitesi varlık fiyatlandırması, varlık dağıtımı ve risk yönetiminde merkezi rol oynamaktadır (Andersen vd., 2001: 44). Ayrıca finansal piyasalar, özellikle de borsalar, ekonomik büyüme ve gelişme sürecinde önemli bir rol oynamaktadır. Finansal veri yüksek frekanslı getirinin koşullu dağılımının aşırı basıklık, negatif çarpıklık ve koşullu hareketlerde geçici ısrarcılık gibi birçok özelliği olduğuna işaret etmektedir. Bunları dikkate almak için, ekonometrisler volatilitenin modellenmesi ve tahmin edilmesi için çok sayıda araç geliştirmişlerdir (Uğurlu vd., 2014: 73).

Zaman serilerinin incelenmesinde elde edilen verilerin ortalama ve varyansının modellenmesi gerçekleştirilmektedir. Teorik olarak ortalamayla volatilitenin modellenmesinde iki farklı yaklaşım vardır. Bunun birincisinde (koşulsuzluk varsayımı) hali hazırdaki değer daha önceki dönemlerdeki değerden bağımsız olduğu kabul edilir. Ekonometrik olarak varlığın getirisinin benzer ve bağımsız dağılıma sahip olduğu iddia edilir. İkinci yaklaşımda (koşulluluk varsayımı) şu anki değer daha önceki hata terimlerinden ve gözlem değerlerinden belli bir gecikme için de olsa etkilenebilmektedir (Altuntaş ve Çolak, 2015: 212). Her ne kadar bazı çalışmalar volatilite ve korelasyonların sabit olduğunu (birinci yaklaşım) varsaysa bile, çoğu finans akademisyenleri ve uygulayıcılar tarafından günümüzde volatilitenin zamanla belirgin şekilde değiştiği düşünülmektedir (Andersen vd., 2001: 44). Burada ikinci yaklaşım daha kabul gördüğünden, volatilite modellenmesinde bu yaklaşımdan faydalanılacaktır. Bu bağlamda GARCH ve GARCH modeline dayanan diğer GARCH modellerinden faydalanılacaktır. GARCH modeli esasen Bollerslev (1986) tarafından ARCH modelinin üzerine inşa edilmiştir. GARCH modeli temel olarak serinin ortalaması tahmin edilirken aynı anda volatilitenin de hesaplanmasına dayanmaktadır. Bu modelde şu anki volatilitenin geçmiş şok ve volatilitenin geçmiş değerlerinden etkilendiği öne sürülmektedir.

Diğer GARCH sınıfı modelleri de bu GARCH modeli üzerinden geliştirilmiş, örneğin kaldıraç etkisi, uzun hafıza gibi diğer unsurları da göz önüne almıştır.

Nasdaq önde gelen bir global teknoloji firmasıdır ve kurumsal müşterilerine, yatırım yöneticilerine, bankalara, brokerlara ve döviz operatörlerine global sermaye piyasalarıyla ve daha geniş finansal sistemle etkileşimde bulduklarında hizmet etmektedir. Global ekonominin likidite, şeffaflık ve bütünlüğünü geliştiren dünyada öncü platformlar sunmayı amaçlamaktadırlar. Firmanın veri, analitik, yazılım, takas kabiliyetleri ve müşteri odaklı geniş çaplı hizmetleri müşterilerine kendi işletme vizyonunu optimize etmede ve gerçekleştirmede yardımcı olmaktadır (About Nasdaq, 2024, ir.nasdaq.com). Nasdaq 100 endeksi Nasdaq'da işlem görmekte olan en yüksek piyasa değerli genelde teknoloji alanında faaliyet gösteren 100 firmadan meydana gelen kapitalizasyona dayanmakta olan bir endekstir. Bu büyük firmalar genelde teknoloji ile ilişkilidir fakat Nasdaq 100 endeksi piyasadan da bir kısım farklı firmaları da içermektedir. Firmalar, piyasadaki değerlerine bağlı olarak bu endekse her sene ilave edilebilir veya endeksten çıkartılabilir. Bu endeks ağırlıklı olarak ABD firmalarını kapsasa da ülke dışında bulunan başka firmaları da içermektedir (NASDAQ Nedir?, 2023).

### 3. Literatür Taraması

Bu kısımda daha önce literatürde Nasdaq endeksi üzerine gerçekleştirilen çalışmaların bir kısmı hakkında bilgiler verilmeye çalışılmaktadır. Genel olarak bu çalışmalar değerlendirildiğinde geçmişte Nasdaq endeksinin çok farklı açılardan ele alındığı görülmektedir (volatilite davranışı, işlem hacmi ilişkisi, 5-dakikalık veri ile, rassal seviye kaymalı model, Lomax dağılım, Modifiye Gri-GARCH modeli, volatilite yayılımı, çoklu fraktal analiz vs). Bu çalışmaların çoğunda uygun Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (GARCH) modelinin seçiminin sınırlı sayıda model arasından yapıldığı, bazı durumlarda direkt hiçbir kıyaslama yapılmadan GARCH(1,1) modelinin kullandığı görülmektedir.

Schwert (2002) çalışmasında Nasdaq'daki hisse senetlerinin volatilite davranışını ele almaktadır. Özellikle teknoloji firmalarındaki irrasyonel hareketleri incelemektedir. Genel olarak hisse senedi volatilitésinin ekonomik faaliyet için öncü gösterge olduğunu ifade etmektedir. Volatiliteler yükseldiğinde genellikle ekonomik resesyona yaşandığını belirtmektedir. Ayrıca genelde işlem hacmi ile volatilitenin birlikte meydana geldiğini söylemektedir. Veriden hareketle yüksek Nasdaq teknoloji hisse senedi işlem hacminin Nasdaq volatilitésinin yüksek olduğu zaman meydana geldiği ifade edilmektedir. Çalışmasında genel olarak GARCH(1,1) modeli kullanılmaktadır.

Rahman vd. (2002) makalelerinde Nasdaq 100 endeksindeki 30 firma için gün içi getirilerin dağılım ve zaman serisi özellikleri için detaylı bir analiz yapmaktadırlar. Temel amaçları süreçte zamanla değişen varyansa izin veren GARCH modelinin gün içi veri volatilitésini temsil edip etmediğini incelemektir. Verileri 5-dakikalık getirileri, işlem hacimleri ve bid-ask spread'lerini 1 Ocak 1999 ile 31 Mart 1999 tarihleri arasında Nasdaq 100 endeksindeki 30 firma için kapsamaktadır. Elde ettikleri sonuçlar gün içi getirilerin volatilitésini en iyi GARCH(1,1) modelinin temsil ettiğini işaret etmektedir. Halihazırdaki volatilite zamanla ısrar etme eğilimi gösteren geçmiş volatilite tarafından açıklanabilmektedir.

Wu (2004) makalesinde Nasdaq'daki sık işlem görmeyen getiri volatilitésini, bilgi akışı ve işlem masrafını ele almaktadır. Dağılım karışımı modeli hacmi bilgilili ve likidite parçalarına ayırmak için kullanılmıştır. Bulguları sık işlem görmeyen hisse senetleri için bilgiye sahip alım satım yoğunluğunun daha yüksek olduğu yönündedir. Bu bilgilili alım satımın daha yüksek yoğunluğu daha geniş spreadlere neden olmaktadır. Pozitif volatilite-işlem hacmi ilişkisi bilgilili hacim ham hacmin yerine volatilite regresyonunda kullanıldığında daha güçlüdür. Ayrıca volatilite ile likidite hacmi arasında güçlü negatif ilişki ortaya çıkarılmıştır. Son olarak sık işlem görmeyen hisse senedi fiyatları sık işlem gören hisse senetlerine göre bilgilili alım satımına daha duyarlı çıkmaktadır.



Lu ve Perron (2010) çalışmalarında rassal seviye kaymalı modeli Nasdaq, Dow Jones, AMEX ve S&P 500 günlük getirilerin logaritmalarına uygulamaktadırlar. Tüm seriler için nokta tahminçiler az sayıda seviye kaymasını göstermektedir. Fakat bunlar dikkate alındığında, kalan gürültüde seri korelasyonun dolayısıyla uzun hafızanın varlığına dair kanıt bulunamamıştır. Getiri serilerine uygulanan standart GARCH modeline tahmin edilen kaymalar ilave edildiğinde, GARCH etkisi ortadan kaybolmaktadır. Tahminler yapıldığında, bu basit rassal seviye kaymalı model açık bir şekilde standart GARCH(1,1) modelinden daha iyi performans göstermektedir ve çoğu durumda ayrıca uzun hafızalı GARCH modeli (FIGARCH) modelinden de daha iyi tahminler sağlamaktadır.

Caporale ve Gil-Alana (2010) uzun hafızalı stokastik volatilité modelini kullanarak finansal zaman serilerinde volatilitenin ısrarcılık seviyesini incelemektedirler. Bu amaçla Nasdaq endeksindeki günlük veri analiz edilmektedir. Bulgular volatilitenin uzun hafıza davranışı özelliğine sahip olduğunu, entegrasyon seviyesinin 0.3 ile 0.5 arasında değiştiğini ve bu nedenle serilerin durağan ve ortalamaya dönme eğiliminde bulunduğunu göstermektedir.

Chen vd. (2012) makalelerinde bir sonraki gün hisse senedi volatilitésini tahmin etmek için saatlik yüksek frekanslı hisse senetlerine dayanan gerçekleşen volatilitéyi kullanmaktadırlar. Bu amaçla ilave bilgi eklemek için saatler sonrası tüm periyot, açılış öncesi gerçekleşen volatilité, kapanış sonrası gerçekleşen volatilité ve gecelik getirinin karesini ekleyerek GARCH modelini genişletmektedirler. En aktif 30 adet Nasdaq hisse senedi kullanarak, hisse senetlerinin çoğunun pozitif ve anlamlı açılış öncesi katsayı sergilediğini ve açılış öncesi varyansın eklenmesinin bir sonraki günün koşullu volatilitésinin örneklem dışı tahminini geliştirdiğini tespit etmişlerdir. Elde ettikleri bulgular önceki çalışmaların sonuçlarını desteklemektedir, alım satımcılar çoğunlukla kapanış sonrası periyotta bilgi dışı nedenlerle ve açılış öncesi periyotta bilgiye dayalı nedenlerle işlem yapmaktadırlar.

Altun (2018)'in makalesinde çift taraflı Lomax dağılımı önerilmektedir. Önerilen dağılımın yararlılığı VaR (Riske maruz değer) tahmin etmek için ilgili Lomax dağılımını GARCH modellerine uygulayarak gösterilmektedir. Bu amaçla bu önerilen dağılımdaki GARCH modelinin normal, student-t ve GED dağılımındaki GARCH modellerine kıyasla performansını göstermek için reel veri Nasdaq 100'e uygulanmaktadır. Tüm güven seviyelerinde çift taraflı Lomax dağılımı altında tanımlanan GARCH modellerinin diğer modellere kıyasla daha gerçekçi VaR tahminleri ürettiğini belirlenmektedir.

Chang vd. (2019) araştırmalarında Nasdaq endeksinin volatilitésini hata terimlerinin analizi yoluyla volatilité aktarımı vasıtasıyla incelemek için modifiye Gri-GARCH modeli geliştirmektedirler. Genelde örneklem hacmi büyüdükçe, GARCH modellerinin değişimi daha iyi modellediğini bulmaktadırlar. Sonuç olarak sunulan modifiye GARCH modelinin geleneksel GARCH modeli ve Gri-GARCH modeline kıyasla daha iyi performans gösterdiğini ifade etmektedirler.

Aliyev vd. (2020) makalelerinde Nasdaq 100 endeksinin volatilitésini tek değişkenli asimetric GARCH modelleri (EGARCH ve GJR-GARCH) kullanarak 4 Ocak 2000 ile 19 Mart 2019 tarihleri arasındaki günlük veriler ile modellemekte ve tahmin etmektedir. Yazarlar, endeks getirileri üzerinde volatilité şoklarının yüksek derecede kalıcı olduğunu tespit etmektedirler. Buna ilave olarak, bulguları endekste kaldıraç etkisinin bulunduğunu ve şokların etkisinin asimetric olduğunu yani pozitif şoklara kıyasla negatif şokların volatilité üzerindeki etkisinin daha fazla olduğunu tespit etmektedirler.

Arashi ve Rounaghi (2022) makalelerinde Nasdaq endeksi için günlük getiri serileri kullanarak çoklu fraktal analiz gerçekleştirmekte ve piyasa etkinliği, finansal risk, risk değerlemesi ve çökme tahminini içeren finansal piyasanın çok sayıda stilize unsurunu araştırmaktadırlar. Ayrıca çalışmalarında etkin piyasa hipotezini ve fraktal yapıyı test etmektedirler. En uygun ARMA-GARCH modeli 2000-2016 arasındaki tarih aralığında modellenmektedir. Bir sonraki aşamada

2017 yılı için endekse ilişkin değerleri tahmin etmektedirler ve %1 hata seviyesinde ARMA-GARCH modelinin çok iyi tahminde bulunduğunu tespit etmektedirler. Son olarak Nasdaq'ın etkin piyasa olduğunu ve fraktal olmayan piyasa olduğunu ifade etmektedirler.

Demirel (2023)'nin çalışmasında 04.01.2016 ile 09.06.2021 arasındaki günlük endeks getirileri kullanılarak BİST 100 ile Nasdaq da dahil olmak üzere dünyada seçilmiş altı borsa endeksi arasında volatilité yayılma etkileri incelenmektedir. Bu amaçla çok değişkenli GARCH modellerinden biri olan Diagonal VECH(DVECH) modeli kullanılmaktadır. Bulguları BİST 100'ün en fazla etkilendiği endeksin DAX olduğu, bunu DJIA ve Nasdaq'ın takip ettiğini işaret etmektedir.

Knutli (2023) yapmış olduğu yüksek lisans tez çalışmasında Bitcoin, S&P 500 ve Nasdaq Composite için yatırım stratejilerini, volatilitéyi, korelasyonu, aşağı yönlü risk ölçümleri ve farklı risk performans oranlarını Ocak 2013 ile Aralık 2022 arasındaki zaman aralığında karşılaştırmaktadır. Bulguları Bitcoin'in diğer iki endekse kıyasla risk-ayarlanmış getiriler cinsinden 10 ve 3 yıllık tutma periyotlarında daha iyi performans gösterdiğini fakat 5 yıllık tutma periyodunda daha zayıf performans sergilediğini göstermektedir.

Literatür tarandığında her ne kadar geçmişte Nasdaq 100 endeksini konu alan çok sayıda çalışma yapılmış olmasına rağmen, bu çalışmada olduğu gibi 11 adet GARCH sınıfı modelin birden bilgi kriterlerine göre karşılaştırılması ve bu endeks için en uygun GARCH modelinin saptanması ve önerilmesi analizinin aşırı gözlemlerden arındırılarak ve farklı dağılımlar için yapılmadığı görülmektedir.

#### 4. Analiz

##### 4.1. Veri ve Öntestler


Analizde veri seti olarak ABD'deki Nasdaq 100 endeksinin 09-01-1998 ile 10-11-2023 tarihleri arasındaki haftalık borsa kapanış fiyatları kullanılmaktadır. Veri Refinitiv Eikon veri tabanından elde edilmiştir. Toplamda tek bir veri seti (zaman serisi) vardır ve bu veri setinde 1349 adet haftalık fiyat verisi bulunmaktadır. Durağanlığı sağlamak için fiyat seviyesi verisinin logaritmik farkı alınmak suretiyle (bileşik getiri formülü ile) haftalık fiyat endeksi değeri yerine haftalık endeks getirileri hesaplanmıştır (Altuntaş ve Çolak, 2015:216):

$$R_t = \ln(P_t/P_{t-1}) \quad R_t = \ln(P_t) - \ln(P_{t-1})$$

Burada  $R_t$ ; Nasdaq 100 endeksinin t dönemine ait getirisi,  $P_t$ ; t dönemindeki Nasdaq 100 endeksinin kapanış fiyatıdır.

Nasdaq 100 endeksi için ham getirilerin seyri Şekil 1'de sunulmaktadır:


Şekil 1: Nasdaq Ham Veri Getiri Grafiği



Burada ham veri ile kastedilen veriden sapan gözlemlerin arındırılmadan önceki halidir. Veri incelendiğinde sapan gözlemlerin varlığı dikkat çekmekte ayrıca volatilité kümelenmesi olduđu görülmektedir.


Öncelikle bu veride Verardi ve Vermandele (2018) tarafından önerilen özellikle aşırı basık ve çarpık seriler için uygun olan boxplot grafik hesaplanmasına dayanan yöntem kullanılarak sapan gözlemler (aşırı gözlemler) saptanmıştır. Model kurulurken ilgili veride mevcut olan sapan gözlemler GARCH model parametrelerini ve volatilité tahmini olumsuz etkilediğinden veride sapan gözlemlerin tespiti yapılmaya çalışılmıştır. Sapan gözlemler Şekil 2’de gösterilmektedir:

Şekil 2: Sapan Gözlemler



Eldeki getiriler sapan (aşırı) gözlemlerden Bodart ve Candelon (2009)’un önerdiği 10 günlük merkezi ortalamanın alınması şeklinde yöntem ile arındırıldıktan sonra elde edilen düzeltilmiş getiriler Şekil 3’de sunulmaktadır:

Şekil 3: Nasdaq Düzeltilmiş Veri Getiri Grafiği





Sapan değerlerden arındırılmış getirinin tanımlayıcı istatistikleri Tablo 1'deki gibidir. Bu bilgilere göre endeks getirisinde minimum değer ve maksimum değer sırasıyla -14.697 ve 10.909'dur. Serinin ortalama değeri ise 0.18003'tür. Getirinin standart hatası da 3.2948 olarak hesaplanmıştır. Verinin ayrıca negatif çarpıklığa sahip olduğu yani sola çarpık yapı gösterdiği ve aşırı basık olduğu görülmektedir. Jarque-Bera testine göre olasılık 0 çıktığından verinin normal dağılım sergilemediği ifade edilebilir. ARCH ve Q testleri %1 anlamlılık seviyesinde otokorelasyon bulunmadığını fakat ARCH etkisinin olduğunu göstermektedir.

**Tablo 1: Tanımlayıcı İstatistikler**

Tanımlayıcı İstatistikler	
Gözlem Sayısı	1349
Minimum	-14.697
Maksimum	10.909
Ortalama	0.18003
Std Hata	3.2948
Çarpıklık	-0.48567
Basıklık	4.5715
Jarque-Bera	191.84 [0.000]
ARCH(1-2)	61.909 [0.000]
Q(20)	36.5539 [0.0132289]
Q <sup>2</sup> (20)	988.143 [0.000]

Analize geçmeden önce eldeki getirinin durağan olup olmadığı test edilmelidir. Birim kök testi bulgularının özetlendiği Tablo 2 incelendiğinde ilgili Nasdaq 100 getiri endeksinin gerek ADF birim kök testi gerekse PP birim kök testine göre %1 anlamlılıkta durağan olduğu görülmektedir.

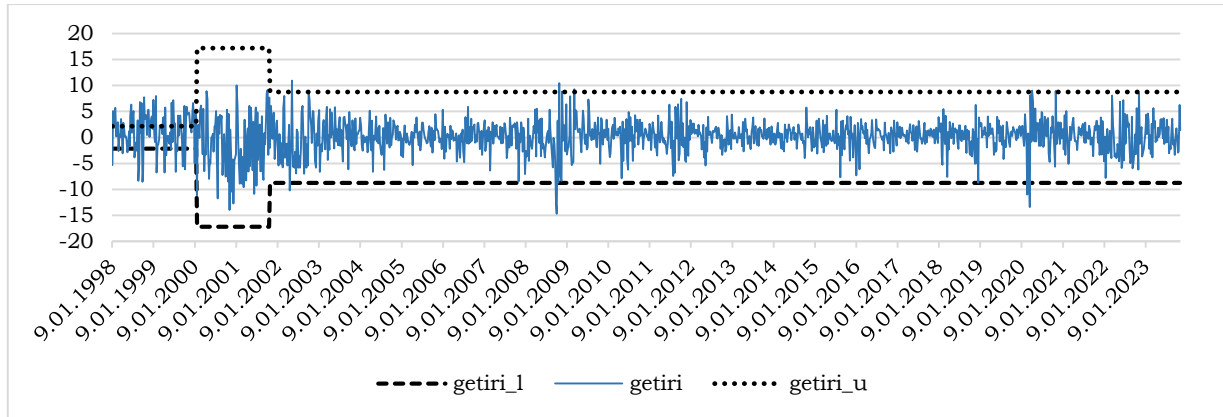
**Tablo 2: Birim Kök Testi Sonuçları**

Endeks	ADF Birim Kök Testi		PP Birim Kök Testi	
	Sabitli	Sabitli ve Trendli	Sabitli	Sabitli ve Trendli
Nasdaq 100 Endeks Getirisi	-36.5844* (0.0000)	-36.5851* (0.0000)	-19.5108* (0.0000)	-19.5304* (0.0000)

**Not:** Parantez içindeki değerler olasılık değerleridir. Burada \* ilgili  $H_0$  birim kök var hipotezinin %1 anlamlılıkla reddedildiğini göstermektedir.

Bu analizde Sanso vd. (2004) tarafından geliştirilen ve özellikle serinin ARCH etkisine sahip olduğu ve normal dağılım sergilemediği durumlarda uygun olan varyansta yapısal kırılma testi uygulandığında Nasdaq 100 getiri serisinin varyansında iki adet kırılma tespit edilmiştir. Kırılma tarihleri sırasıyla 21/01/2000 ile 26/10/2001'dir.

**Şekil 4: Getirinin Varyansında Yapısal Kırılmaların Olduğu Tarihler**



## 4.2. Metodoloji

Bu bölümde analizde izlenen metodoloji ile ilgili bilgi verilmeye çalışılacaktır. Çalışmada öncelikle verinin ortalamasının modellenmesi ARMA (Oto regresif Hareketli Ortalama) ile yapılacaktır. ARMA modeli esasen Box Jenkins(1976)'a dayanmaktadır (Sevüktekin ve Nargeleçekenler, 2006: 258). ARMA modeli ilk kez 1921 yılında Yule tarafından AR modelinin geliştirilmesiyle ortaya çıkmıştır. Daha sonraları bu kez 1927 yılında Shutsky MA modelini öne sürmüştü ve 1954 tarihinde Wold ile bunların bileşimi olan ARMA modeli geliştirilmiştir (Çevik, 1999: 39; Kaya, 2019:35) Eldeki zaman serisine sahip veri hem oto regresif (AR) hem de hareketli ortalamaya(MA) sahip olabilmektedir. Örneğin ARMA(1,1) sürecindeki bir model denklemini aşağıdaki gibi ifade edilebilir (Mert ve Çağlar, 2019: 186):

$$(1 - \rho L)(y_t - u) = (1 + \phi L)e_t$$

Tutumluluk prensibine göre genelde ARMA(p,q) yapısının mümkün olduğu kadar küçük olması istenir. Bu ARMA modelinin gecikme derecesine karar verirken de Akaike(AIC) gibi bilgi kriterlerine bakılır. Akaike bilgi kriterinin minimum olduğu gecikmenin en uygun gecikme yapısı olduğuna karar verilir.

ARMA(p,q) modeli tahmin edildikten sonra da gecikmede değişen varyans tespit edilmesi halinde bu durumda varyansı da modelleyen GARCH (Genelleştirilmiş Oto regresif Koşullu Değişen Varyans) modellenmesine geçilir. Bu analizde toplamda 11 adet farklı GARCH sınıfı model denenmektedir. En temel GARCH(1,1) modeli Bollerslev(1986) tarafından geliştirilmiştir ve literatürde getiri serilerinin zamanla değişen volatilitenin incelenmesi için çok sık kullanılmaktadır. Bu aşağıdaki gibi ifade edilebilir (Yıldırım vd, 2020: 5):

$$r_t = u_t + e_t$$

$$e_t(e_{t-1}, e_{t-2}, \dots, r_{t-1}, r_{t-2}, \dots) \sim GED(0, h_t^2)$$

$$h_t^2 = w + \alpha e_{t-1}^2 + \beta h_{t-1}^2$$

Burada  $r_t$  getiri serisi,  $u_t$ ,  $r_t$ 'nin ortalaması ve  $e_t$   $r_t$  için inovasyon prosesidir. Ayrıca  $\alpha$  volatilitede şokların etkisini,  $\beta$ , ise volatilitenin kümelenmesinin kalıcılığını temsil etmektedir. Tahmin edilen parametrelerde sıfır olmama koşulu bulunmaktadır (Yıldırım vd, 2020: 5).

Diğer GARCH sınıfı modellerden, EGARCH modeli log-doğrusal yapısında olduğundan negatif olmama kısıtı bu modelde kalkmaktadır. EGARCH ve GJR GARCH modellerinde volatilitedeki asimetri yani kaldıraç etkisi de göz önüne alınmaktadır. APARCH Arch modelinin asimetrik güç kullanılmış versiyonudur. Bütünleşik GARCH yani IGARCH koşullu volatilitenin durağan olmadığı durumlarda kullanılmaktadır. HYGARCH hiperbolik GARCH formundadır. Son olarak çalışmada kullanılan diğer modeller uzun hafızayı dikkate alan FIGARCH üzerine inşa edilmiştir (Çağlayan ve Dayıoğlu, 2009: 4; Türkyılmaz ve Balıbey 2014, 3-4; Li vd., 2015: 428).

## 4.3. Elde Edilen Bulgular

Öncelikle veri için en uygun ARMA (Oto regresif Hareketli Ortalama) yapısının bulunması gerekmektedir. Bunun için eldeki getirinin özelliğine göre en uygun olan model formunun saptanması için farklı p ve q değerlerine göre EKK (En küçük kareler) yöntemi ile tahmin yapılmalıdır. Aşağıda Tablo 3'de gösterildiği gibi Akaike bilgi kriterine göre en uygun yapı minimum değeri veren ARMA(5,5) olarak belirlenmiştir (Işıklar, 2016: 5).

**Tablo 3: Uygun ARMA Yapısının Akaike Kriterine Göre Belirlenmesi**

AR / MA	0.000000	1.000000	2.000000	3.000000	4.000000	5.000000
0.000000	5.220545	5.223469	5.222513	5.222587	5.223275	5.223875
1.000000	5.223464	5.217129	5.217887	5.223328	5.224520	5.218224
2.000000	5.222621	5.217863	5.219274	5.219456	5.221210	5.219673
3.000000	5.222429	5.223122	5.219446	5.218633	5.219653	5.220988
4.000000	5.223028	5.224300	5.221084	5.219677	5.221083	5.220098
5.000000	5.223680	5.218182	5.219582	5.220944	5.220035	5.214588

Bu ARMA modeli çalıştırıldığında Box-Pierce Q ve  $Q^2$  istatistiklerine göre seride otokorelasyonda sıkıntı olmadığı fakat değişen varyans etkisinin halen olduğunu göstermektedir. Yani hata teriminde koşullu değişen varyans etkisi vardır. Bu yüzden getiri serisini modellerken sadece ortalamayı değil aynı zamanda serinin volatilitésinin de modellenmesi gerekmektedir. Analizde GARCH modelleri hesaplanırken literatürde yaygın olarak kullanılan student dağılımı kullanılmaktadır. Çalışmanın sonuçlarının sağlamlığını incelemek için uygun GARCH modelinin seçiminde GED (Genelleştirilmiş Hata Dağılımı) dağılımı da ayrıca kullanılmaktadır (Çağlayan ve Dayıoğlu, 2009: 5).

Aşağıda Tablo 4’de ARMA(5,5) için student dağılımı ile farklı GARCH modellerinin uyum istatistikleri hesaplanmıştır. Farklı GARCH modelleri arasından en uygun modelin belirlenmesinin gerekçesi ilgili endeksi gerçeğe en yakın tahmin eden modelin tespit edilebilmesidir. Tablo 4’de görüldüğü üzere en düşük Akaike uyum istatistiği değerine sahip modelin diğer en iyi (yani en düşük) uyum kriterine sahip üç GARCH model sonuçlarında (FIAPARCH\_CHUNG, FIAPARCH\_BBM ve FIEGARCH) yakınsama sorunu çıktığından Nasdaq 100 için ARMA(5,5)-EGARCH modeli olduğu sonucuna ulaşılmıştır. Yakınsama problemi ile burada kastedilen ekonometri paket yazılımının ilgili model için tutarlı bir sonuca ulaşamamasıdır. Bu nedenle student dağılımı altında en uygun modelin ARMA (5,5)-EGARCH olduğu ifade edilebilir.

**Tablo 4: Nasdaq 100 Endeksi İçin Farklı GARCH Modellerinin Uyum İstatistikleri (Student Dağılımı İçin)**

Modeller	Akaike Değeri	Schwarz Değeri	Shibata Değeri	Hannan-Quinn Değeri
GARCH	4.9575	5.0154	4.9572	4.9792
EGARCH	4.9407	5.0063	4.9404	4.9652
GJR GARCH	4.9520	5.0137	4.9517	4.9751
APARCH	4.9415	5.0071	4.9412	4.9661
IGARCH	4.9578	5.0118	4.9576	4.9780
FIGARCH_BBM	4.9539	5.0157	4.9536	4.9770
FIGARCH_CHUNG	4.9554	5.0172	4.9551	4.9785
FIEGARCH	4.9404	5.0099	4.9401	4.9665
FIAPARCH_BBM	4.9403	5.0098	4.9400	4.9664
FIAPARCH_CHUNG	4.9388	5.0083	4.9384	4.9648
HYGARCH	4.9554	5.0210	4.9551	4.9800

Tablo 5’de modellerin kıyaslanmasında en uygun model olarak öne çıkan EGARCH modelinin tahmin neticeleri sunulmaktadır. Ortalama denklemde AR(4) ve MA(4) anlamsız çıkmıştır fakat bu gibi modellerde önemli olan bazı katsayıların anlamsız olması değil genel olarak bir bütün olarak modelin veriyi en iyi temsil etmesidir. Varyans denkleminde de sadece ARCH katsayısı anlamsız çıkmıştır. Diğer katsayılar anlamlıdır. EGARCH modelinde log olarak kurulduğundan bazı katsayıların negatif çıkması sorun teşkil etmemektedir. Bulgularda ayrıca  $\theta_1$  katsayısı negatif ve anlamlı çıkmıştır. Bu da getiri serisinde kaldıraç etkisinin bulunduğunu, negatif şokların pozitif şoklara kıyasla volatilitéyi daha fazla artırdığını göstermektedir. Ayrıca modelin bulgularına yapılan Q,  $Q^2$  ve ARCH testlerinde de otokorelasyonun ve değişen varyansının olmadığı görülmektedir.

Tablo 5: ARMA (5,5) - EGARCH(1,1) Model Tahmini

Ortalama Denklemi	Katsayı	Olasılık
Sabit	0.307318	0.0000
AR(1)	-0.865106	0.0000
AR(2)	0.143857	0.0062
AR(3)	0.778409	0.0000
AR(4)	0.231790	0.3152
AR(5)	-0.359592	0.0002
MA(1)	0.846462	0.0000
MA(2)	-0.166646	0.0147
MA(3)	-0.779997	0.0000
MA(4)	-0.215626	0.2649
MA(5)	0.352882	0.0001
<b>Varyans Denklemi</b>		
Sabit	2.030295	0.0000
ARCH(ALPHA1)	-0.008228	0.9741
GARCH(BETA1)	0.951604	0.0000
EGARCH(THETA1)	-0.101620	0.0056
EGARCH(THETA2)	0.284282	0.0000
Student DF	14.0975	0.0161

Not: Q(20)=11.4224[0.3255714], Q<sup>2</sup>(20)=15.4990[0.6274685], ARCH(1-2) Test=0.34375[0.7092]

EGARCH(1,1)  $\log(h_t^2) = w + \alpha(|e_{t-1}/\sqrt{h_{t-1}^2}| - E|e_{t-1}/\sqrt{h_{t-1}^2}|) + \nu e_{t-1}\sqrt{h_{t-1}^2}$  şeklinde formüle edilmektedir.

Dağılımı student yerine GED dağılımı yaptığımızda ise diğer önceki en iyi iki yöntemde (FIAPARCH\_BBM ve FIAPARCH\_CHUNG) yakınsama sorunu çıktığı için en uygun model FIEGARCH modeli olarak bulunmaktadır. Ayrıca EGARCH modelinin de sıralamada en iyi ikinci model olduğu görülmektedir. Dolayısıyla araştırmacıya Nasdaq 100 ile ilgili volatilité modellemesi yaparken sadece EGARCH ve onun türevi olan FIEGARCH modelini uygulayıp ikisi arasında en uygun modeli son model olarak seçmesi önerilebilir.

Tablo 5: Nasdaq 100 Endeksi İçin Farklı GARCH Modellerinin Uyum İstatistikleri (GED Dağılımı İçin)

Modeller	Akaike Değeri	Schwarz Değeri	Shibata Değeri	Hannan-Quinn Değeri
GARCH	4.9617	5.0196	4.9615	4.9834
EGARCH	4.9450	5.0106	4.9447	4.9695
GJR GARCH	4.9563	5.0181	4.9561	4.9795
APARCH	4.9454	5.0110	4.9451	4.9700
IGARCH	4.9620	5.0161	4.9618	4.9823
FIGARCH_BBM	4.9586	5.0204	4.9583	4.9817
FIGARCH_CHUNG	4.9592	5.0209	4.9589	4.9823
FIEGARCH	4.9446	5.0140	4.9442	4.9706
FIAPARCH_BBM	4.9440	5.0135	4.9437	4.9700
FIAPARCH_CHUNG	4.9442	5.0137	4.9438	4.9702
HYGARCH	4.9563	5.0219	4.9560	4.9809

## 5. Sonuç

Bu çalışmada 09-01-1998 ile 10-11-2023 tarihleri arasındaki haftalık veriler kullanarak ABD'de işlem gören ve ağırlıklı olarak teknoloji firmalarından oluşan Nasdaq 100 endeksinin volatilitésini en iyi modelleyen GARCH yöntemi tespit edilmeye çalışılmıştır. Teknoloji ve inovasyonun günümüzde önemi arttığı için ve volatilité üzerine yapılan çalışmalarda ABD'deki endekslerin de genelde karşılaştırma amacı ile dikkate alındığı düşünüldüğünde bu çalışmanın bulgularının analistlere ve uygulamacılara yol gösterici olacağına inanılmaktadır. Çünkü

araştırmacılar bu endeksi direkt veya benchmark olarak kullandıklarında genelde direk GARCH(1,1) modelini kullanmakta veya en fazla 3-4 yöntemi deneyip en iyi modeli tespit etmeye çalıştığı görülmektedir. Bu çalışmanın 11 adet farklı GARCH türevi yöntemi deneyip bilgi kriterine göre en uygun modeli tespit ettiği için literatüre katkı sunabileceğine inanılmaktadır. Ayrıca analizde sapan gözlemler tespit edilip düzeltilmekte ve volatilitedeki yapısal kırılmalar da araştırılmaktadır. Bilindiği kadarıyla daha önce bu endeks için böyle detaylı bir çalışma daha önce yapılmamıştır. Analizlerde genellikle kullanılan student dağılımı kullanıldığında en uygun modelin Akaike bilgi kriterine göre EGARCH olduğu bulunmaktadır. Dağılım GED yapıldığında ise yine Akaike bilgi kriterine göre FIEGARCH yönteminin en iyi model olduğu, bu dağılımda EGARCH'ın ise en iyi ikinci model olduğu bulunmaktadır. Dolayısıyla yatırımcıya, akademisyene ve analiste bu endeksin volatilitésinin modellenmesi söz konusu olduğunda direkt EGARCH modeli kullanması önerilebilir ya da yatırımcı EGARCH ve FIEGARCH yöntemlerini tahmin edip ikisinden en iyi sonucu veren modeli tercih edebilirler. Finansal açıdan bu sonuçlar ele alındığında her iki önerilen modelde (EGARCH ve FIEGARCH) üssel terim de bulunduğu ve ilgili katsayı anlamlı olduğundan ilgili seride kaldıraç etkisinin önemli olduğu ifade edilebilir. Yani piyasaya gelen negatif şoklar pozitif şoklara kıyasla volatilitéyi daha fazla artırmaktadır. Literatürde de daha önce de ifade edildiği gibi genellikle GARCH (1,1) modeller kullanılmaktadır, fakat Aliyev vd. (2020) de 2000-2019 yılları arasındaki veriyi analiz ederek GARCH modeline ilave olarak EGARCH ve GJR GARCH modellerini de tahmin etmişler, bu makalenin bulgularını destekleyerek Nasdaq endeksinde kaldıraç etkisi tespit etmişlerdir.

**Destek ve Teşekkür Beyanı:** Bu araştırmanın hazırlanmasında herhangi bir dış destek alınmamıştır.

**Araştırmacıların Katkı Oranı Beyanı:** Makalenin hazırlanması tüm katkı tarafınca yapılmıştır.

**Çatışma Beyanı:** Araştırmanın yazarı olarak herhangi bir çıkar çatışma beyanım bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı:** Bu araştırmanın her aşamasında “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi”nde belirtilen tüm kurallara uyulmuştur. Yönergenin “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir. Bu çalışmanın yazım sürecinde etik kurallarına uygun alıntı yapılmış ve kaynakça oluşturulmuştur. Çalışma intihal denetimine tabi tutulmuştur.

## Kaynakça

- About Nasdaq (2024). Erişim Adresi: [ir.nasdaq.com/news-releases/news-release-details/nasdaq-host-2024-investor-day](https://ir.nasdaq.com/news-releases/news-release-details/nasdaq-host-2024-investor-day)
- Akel, Veli (2011). *Kriz Dönemlerinde Finansal Piyasalar Arasındaki Oynaklık Yayılma Etkisi*. Detay Yayıncılık: Ankara
- Aliyev, F., Ajayi, R. and Gasim, N. (2020). Modelling Asymmetric Market Volatility with Univariate GARCH Models: Evidence from Nasdaq-100. *The Journal of Economic Asymmetries*, 22, 1-10.
- Altun, E. (2018). A New Approach to Value-At-Risk: GARCH-Tslx Model with Inference. *Communication in Statistics-Simulation and Computation*, 49(12), 3134-3151.
- Altuntaş, S.T. ve Çolak, F.D. (2015). BİST-100 Endeksinde Volatilitenin Modellenmesi ve Öngörülmesinde ARCH Modelleri, *İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Yönetim Dergisi*, 26(79), 208-223.
- Andersen, T.G., Bollerslev, T., Diebold, F.X. and Ebens, H. (2001). The Distribution of Realized Stock Return Volatility. *Journal of Financial Economics*, 61(1), 43-76.
- Arashi, M. and Rounaghi, M.M. (2022). Analysis of Market Efficiency and Fractal Feature of NASDAQ Stock Exchange: Time Series Modelling and Forecasting of Stock Index Using ARMA-GARCH Model, *Future Business Journal*, 8(1), 1-12.
- Bodart, V. and Candelon, B. (2009). Evidence of Interdependence and Contagion Using a Frequency Domain Framework, *Emerging Markets Review*, 10(2), 140-150.



- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity, *Journal of Econometrics*, 31(3), 307-327.
- Box, G. E. P. and Jenkins, G.M. (1976). *Time Series Analysis Forecasting and Control*. San Francisco Holden-Day.
- Brooks, C. (1998). Predicting Stock Index Volatility: Can Market Volume Help?. *Journal of Forecasting*, 17, 59-80.
- Caporale, G.M. and Gil-Alana, L.A. (2010). Estimating Persistence in The Volatility of Asset Returns with Signal Plus Noise Models. *DIW Berlin German Institute for Economic Research*, Discussion Paper, 1-18.
- Chang, T.G., Wang, H. and Yu, S. (2019). A GARCH Model with Modified Grey Prediction Model for US Stock Return Volatility. *Journal of Computational Methods in Sciences and Engineering*, 19(1), 197-208.
- Chen, C.H., Yu, W.C. and Zivot, E. (2012). Predicting Stock Volatility Using After-Hours Information: Evidence from The NASDAQ Actively Traded Stocks. *International Journal of Forecasting*, 28(2), 2012, 366-383.
- Çağlayan, E. ve Dayıoğlu, T. (2009). Döviz Kuru Getiri Volatilitésinin Koşullu Değişen Varyans Modelleri ile Öngörüsü. *Ekonometri ve İstatistik*, 9, 1-16.
- Çevik, O. (1999). Zaman Serileri Analizinde Box-Jenkins Yöntemi ve Turizm Verileri Üzerine Bir Uygulama. (Yayımlanmamış Doktora Tezi). Kırıkkale Üniversitesi Sosyal Bilimler Enstitüsü, Kırıkkale.
- Demirel, E. (2023). BİST 100 ve Seçilmiş Ülke Endeksleri Arasındaki Volatilité Yayılım Etkisi: Diyagonal VECH GARCH Modeli. *Uluslararası Ekonomi, İşletme ve Politika Dergisi*, 7(1), 104-117.
- Eraslan, M. (2022). Pay Senedi Endeksleri ile Endeks Vadeli İşlemler Arasındaki Volatilité İlişkisi: Türkiye ve Dünya Örnekleri Arasında Karşılaştırmalı Analiz. (Yayımlanmamış Doktora Tezi), Sivas Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.
- Gürbüz, S. (2018). Türev Piyasaların Hisse Senedi Piyasaları Oynaklığına ve İstikrarına Etkileri: BİST 30 Örneği. (Yayımlanmamış Doktora Tezi). Necmettin Erbakan Üniversitesi Sosyal Bilimler Enstitüsü, Konya.
- Işıklar, Z. E. (2016). İMKB Ulusal 100 Endeksi Getiri Volatilitésinin Analizi Üzerine Bir Araştırma. *Selçuk Üniversitesi Sosyal ve Teknik Araştırmalar Dergisi*, 12, 245-260.
- Kaya, E. (2019). Zaman Serileri Analizinde Box-Jenkins Yöntemi ile Savunma Sanayi Verileri Üzerine Bir Uygulama. (Yayımlanmamış Yüksek Lisans Tezi). Karamanoğlu Mehmet Bey Üniversitesi Sosyal Bilimler Enstitüsü, Karaman.
- Knutli, A.N. (2023). Bitcoin Vs. Traditional Indices-Analysing Performance And Risk Metrics For Long-Term Savings. (Yayımlanmamış Yüksek Lisans Tezi). Oslo Metropolitan Üniversitesi, Oslo.
- Li, M., Li, W.K. and Li, G. (2015). A New Hyberbolic GARCH Model, *Journal of Econometrics*, 189(2), 428-436.
- Lu, Y.K and Perron, P. (2010). Modelling and Forecasting Stock Return Volatility Using a Random Level Shift Model, *Journal of Empirical Finance*, 17(1), 138-156.

- Mert, M. ve Çağlar, A.E. (2019). *Eviews ve Gauss Uygulamalı Zaman Serileri Analizi*. Detay Yayıncılık: Ankara.
- NASDAQ Nedir? (2023). Erişim Adresi: [www.trive.com.tr/blog/nasdaq-nedir](http://www.trive.com.tr/blog/nasdaq-nedir)
- Özdemir, Letife (2011). Vadeli İşlem Piyasası ile Spot Piyasa Oynaklığı Arasındaki İlişki: İzmir Vadeli İşlem ve Opsiyon Borsası Üzerine Bir Uygulama. (Yayımlanmamış Doktora Tezi), Afyon Kocatepe Üniversitesi Sosyal Bilimler Enstitüsü, Afyonkarahisar.
- Rahman, S., Lee, C.F. And Ang, K.P. (2002). Intraday Return Volatility Process: Evidence from NASDAQ Stocks. *Review of Quantitative Finance and Accounting*, 19, 155-180.
- Refinitiv Eikon (2023). Erişim Adresi: [Https://Eikon.Refinitiv.Com](https://Eikon.Refinitiv.Com)
- Sanso, A., Arago, V. and Carrion, J.L. (2004). Testing for Change in The Unconditional Variance Of Financial Time Series. *Revista De Economia Financiera*, 4, 32-53.
- Schwert, G.W. (2002). Stock Volatility In The New Millennium: How Wacky Is Nasdaq?. *Journal of Monetary Economics*, 49, 3-26.
- Sevüktekin, M. ve Nargeleçekenler, M. (2006). İstanbul Menkul Kıymetler Borsasında Getiri Volatilitésinin Modellenmesi ve Önraporlanması, *Ankara Üniversitesi SBF Dergisi*, 61(4), 243-265.
- Telçeken, N. (2014). Volatilite Endeksleri, Önemi ve Türkiye Volatilite Endeksi. (Yayımlanmamış Doktora Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Tuna, K. ve İsaetli, İ. (2014). Finansal Piyasalarda Volatilite ve Bist-100 Örneği, *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, 27, 21-31.
- Türkyılmaz, S. ve Balıbey, M. (2014). Türkiye Hisse Senedi Piyasası Oynaklığındaki Asimetrik Uzun Hafıza Özelliği. *Gazi Üniversitesi Bankacılık ve Finansal Araştırmalar Dergisi*, 1(1), 1-10.
- Uğurlu, E., Thalassinou, E. and Muratoğlu, Y. (2014). Modelling Volatility in The Stock Markets Using GARCH Models: European Emerging Economies and Turkey. *International Journal in Economics and Business Administration*, 2(3), 72-87.
- Verardi, V. and Vermandele, C. (2018). Univariate and Multivariate Outlier Identification for Skewed or Heavy-Tailed Distributions. *The Stata Journal*, 18(3), 517-532.
- Wu, C. (2004). Information Flow, Volatility and Spreads of Infrequently Traded Nasdaq Stocks. *The Quarterly Review of Economics and Finance*, 44, 20-43.
- Yıldırım, D.Ç., Çevik, E.İ. and Esen, Ö. (2020). Time-Varying Volatility Spillovers Between Oil Prices and Precious Metal Prices. *Resources Policy*, 68, 1-14
- Yu, J. (2002). Forecasting Volatility in The New Zealand Stock Market. *Applied Financial Economics*, 12, 193-202.