

DÖVİZ KURU VOLATİLİTESİNİ ÖNGÖRMEDE MELEZ BİR MODEL: YAPAY SİNİR AĞI TABANLI EGARCH

Müge SAĞLAM BEZGİN¹ , Ebru KAYA²

Gönderim tarihi: 13.01.2020 Kabul tarihi:18.02.2022

Öz

Döviz kurlarında yaşanan dalgalanmalar, volatilité modellerinde yeni arayışlar yapılmasına neden olmaktadır. Bu çalışmada 2018-2019 dönemi günlük verileriyle ABD doları/Türk Lirası reel alış kuru üzerinde öngörü yapılması amaçlanmıştır. Bu bağlamda GARCH Tipi modellerin kabiliyetini artırmak amacıyla geliştirilmiş yapay sinir ağı tabanlı EGARCH modeli ile öngörü yapılmıştır. GARCH tipi modellerden GARCH (1,1), GJR-GARCH (1,1) ve EGARCH (1,1) ile modellemeler yapılmış, ilgili bilgi kriterine göre etkin model olan EGARCH (1,1) modelinden elde edilen hatalar ile sinir ağı modeli kurulmuştur ve melez bir öngörü modeli inşa edilmiştir. Yapılan incelemeler sonucunda uygulanan melez modelin öngörü performansının GARCH tipi modellere kıyasla daha iyi olduğu görülmüştür.

Anahtar Kelimeler: Volatilité, Zaman Serisi Analizi, GARCH Model, Yapay Sinir Ağı, Öngörü

JEL Sınıflaması: C53, C58, E47

A HYBRID MODEL FOR FOREIGN EXCHANGE RATE VOLATILITY: ARTIFICIAL NEURAL NETWORK BASED EGARCH

Abstract

Fluctuations in exchange rates cause new searches for volatility models. In this study, it is aimed to predict the real buying rate of US Dollar / Turkish Lira with daily data of 2018-2019 period. In this context, an artificial neural network based EGARCH model was developed to increase the capability of GARCH type models. GARCH type models were modeled with GARCH (1,1), GJR-GARCH (1,1) and EGARCH (1,1). A hybrid prediction model was constructed by channeling the errors obtained from the EGARCH (1,1) model, which is the effective model according to the relevant information criteria, to the artificial neural network. As a result of the examinations, the predictive performance of the hybrid model was found to be better than the GARCH type models.

Keywords: Volatility, Time Series Analysis, GARCH Model, Artificial Neural Network, Forecasting

JEL Classification: C53, C58, E47

¹ Dr., Karamanoğlu Mehmetbey Üniversitesi İİBF, İşletme Bölümü, mugesaglam@kmu.edu.tr, ORCID: 0000-0001-8674-2707

² Karamanoğlu Mehmetbey Üniversitesi, SBE Yüksek Lisans Mezunu Bağımsız Araştırmacı, ebru.kaya.4470@gmail.com, ORCID-ID: 0000-0001-6690-2996

1. Giriş

Para ve sermaye piyasalarında volatilité; bir varlığın fiyatının zamana bağılı olarak gösterdiği dalgalanma olarak ifade edilmektedir. Borsa İstanbul terimler sözlüğünde ise volatilité “bir menkul kıymetin fiyatının veya piyasanın genelinin kısa bir zaman aralığı içerisinde gösterdiği dalgalanma özelliği” olarak tanımlanmaktadır (BİST, 2019).

Risk ve belirsizliğin arttığı, finansal krizlerin yoğunlaştığı günümüz dünyasında uluslararası ticaret akımının sektöre uğramaması ve etkin olabilmesi için döviz kuru volatilitésinin öngörülmesi ihtiyacı vardır. Volatilité kavramı 1973’ten bu yana piyasaları meşgul etmekte, reel ve finansal sektör karar vericileri için ekonomik karar alma noktasında önem arz etmektedir. Karar alıcıların döviz kuru oranının öngörülebilmesiyle optimal kararlar almaları mümkün olacaktır. Bu nedenle yapılacak öngörünün başarılı olması gerekmektedir. Öngörü tekniklerinin hızla gelişmesinde ve birçok ekonometrik yöntem önerilmesinde esas neden de bu gerekliliktir. Hem akademik araştırmalarda hem de piyasa katılımcılarınca yapılan çalışmaların odak noktası olan volatilité piyasa riskinin göstergesi olarak genel kabul görmektedir. Volatilité varlık getirilerinin standart sapması ve varyansı ile ölçülmektedir (Brooks, 2008). Volatilité bir değişkenin belirli bir ortalama değere göre artarak veya azalarak ne kadar saptığını gösteren bir parametredir. Finans literatüründe bir finansal varlığın fiyatında ve getirisinde meydana gelen dalgalanmaların değişkenliğini ölçmek ve açıklamak için kullanılmaktadır. (Karcıoğlu ve Özer, 2017: 1572). Finansal zaman serilerinde genellikle büyük fiyat değişikliklerini büyük fiyat değişiklikleri, küçük fiyat değişikliklerini ise küçük fiyat değişiklikleri izlemektedir (Adlığ, 2009: 39; Şahin ve Öncü, 2014: 137, Sağlam ve Başar, 2016: 24). Diğer bir ifadeyle finansal zaman serilerinin gösterdiği bu hareket, hata teriminin değişen varyansa sahip olduğunun ve volatilité kümelenmesinin varlığının bir kanıtı olarak gösterilmektedir (Akel, 2011: 22, Şahin ve Öncü, 2014: 137). Bu kümelemelerin modellenmesinde ise otoregresif koşullu değişen varyans (ARCH) ve genelleştirilmiş otoregresif koşullu değişen varyans (GARCH) modelleri hâkimdir. Ancak bu çalışmada; Hajizadeh vd. (2014), Hamdi ve Chkili (2019) tarafından ARCH grubu modeller temel olarak önerilmiş olan ve yapay sinir ağları kullanılarak geliştirilmiş melez modele dayanarak ABD doları/Türk Lirası reel kurunun volatilitésini modelleneyecektir. Bu bağlamda çalışmanın metodolojik literatüre katkı sağlaması amaçlanmıştır.

Çalışma 5 ana başlıktan oluşmaktadır. İkinci bölümde volatilitéyle ilgili literatür ve ARCH grubu modellerin uygulanmasına yer verilmiş, üçüncü bölümde veri seri ve melez model tanıtılmıştır. Dördüncü bölüm bulgulardan oluşmaktadır ve beşinci bölüm elde edilen çıktılar yorumlandığı sonuç bölümü olarak sunulmuştur.

2. Volatilitéyle İlgili Yapılmış Çalışmalar

Çalışmaların metodolojisi ARCH grubu modellerden oluşmaktadır. Yazın taraması incelendiğinde volatilité modellemesinde simetrik koşullu varyans modellerinden asimetrik koşullu varyans modellerine bir artış olduğu görülmüştür. Bu modellerde öne çıkanlar AGARCH; ARCH-M; EGARCH, GJR-GARCH; QGARCH; TARCH; NGARCH ve IGARCH, EAR-GARCH, SWARCH olarak sıralanabilir. Asimetri etkisini modelleyen AGARCH modelini Engle 1990 yılında geliştirmiştir. 1987 yılında ARCH modelinin bir uzantısı olarak Engle, Lien ve Robbins tarafından geliştirilen ARCH-M (ortalama ARCH) modeli; hisse senedi piyasalarında beklenen getiride yer alan değişen varyansların etkisini direkt olarak ölçmektedir. ARCH-M modeli ile ARCH modeli arasındaki en önemli fark, koşullu ortalama fonksiyonunda yer alan açıklayıcı değişkenler kümesinin içindeki koşullu varyanstır (Çabuk, Özmen ve Kökçen, 2011: 8).

ARMA (p,q) modellerinin kısıtlanmış versiyonu olan, oynaklık üzerindeki şokların etkisini asimetrik olarak göstermek için elde edilen ve Nelson tarafından 1991 yılında geliştirilen, Üssel GARCH (EGARCH) modeli volatilitelerdeki olası asimetriyi test edebilmek için koşullu varyansa ait olan gecikmeli hata terimlerinin işaretlerini dikkate almaktadır (Çabuk, Özmen ve Kökçen, 2011:8 ; Kayral, 2017: 169) .

GJR-GARCH modeli Glosten, Jagannathan ve Runkle tarafından 1993 yılında geliştirilen, pozitif ve negatif beklenmeyen getiriler koşullu varyans üzerinde farklı etkilere sahip olan bu model mevcut olan koşullu varyansın bu getirilere farklı bir tepki vermesine müsaade ederek asimetrik bir davranışı yakalamaya çalışmaktadır. Bununla beraber, borsa getirilerinin koşullu ortalama ve koşullu varyansı arasında negatif yönlü bir ilişki vardır (Glosten vd., 1993: 1799). EGARCH modelinin ampirik tahmini teknik açıdan zordur, çünkü yüksek sayıda doğrusal olmayan algoritmalar içermektedir. Bu modelin aksine, GJR-GARCH modeli çok daha basittir ve tahmini daha kolaydır (Wang, 2007: 38).

Sentana'nın 1995 yılında geliştirdiği Kuadratik GARCH (QGARCH) modeli, pozitif ve negatif şokların asimetrik etkilerini modellemek amacıyla kullanılmaktadır. EGARCH modelinde kaldıraç etkisi logaritmik modeller yardımıyla açıklanırken, Zakoian (1994) tarafından ortaya koyulan TARCH modellerinde söz konusu kaldıraç etkisi kuadratik formdaki modeller kullanılarak açıklanmaktadır (Kayral, 2017: 170). Mutlak değer genelleştirilmiş otoregresif koşullu değişen varyans modeli NGARCH, normal dağılım sebebiyle TGARCH modeliyle benzer görünmektedir (Gluham,2013: 60). Entegre Genelleştirilmiş Otoregresif Koşullu değişen varyans (IGARCH), kalıcı parametrelerin toplamının bir olduğu ve GARCH sürecinde bir birim kök aldığı GARCH modelinin sınırlı bir versiyonudur ve po-

zitif ile negatif şoklara karşı asimetrik tepkileri ölçebilen bir modeldir (Topaloğlu, 2018: 3377)

Booth ve Koutmos'ın 1998 yılında geliştirdikleri koşullu heteroskedastik hata terimine sahip üstel otoregresif volatilitite modeli (EAR-GARCH) volatilitite ile otokorelasyon arasında var olan ilişkiyi belirleme imkânı sağlamaktadır (Akar, 2008: 135). SWARCH modeli ise Hamilton ve Susmel tarafından 1994 yılında geliştirilmiştir. SWARCH modelinin en önemli özelliği rejim değişikliklerinin araştırmacılar tarafından gözlenmesine gerek olmamasıdır. Model kendi içerisinde farklı farklı rejimlerin ortaya çıkmasına izin vermektedir (Akar,2007: 207). Araştırmacıların veri seti ve inceleme dönemlerindeki farklılaşma bu modellerin öngörü performansında da aynı şekilde farklılaşmaya sebep olmuştur. Örneğin; Akar (2007), araştırmasında SWARCH ile öngörü modellemesi yaparken Demirgil ve Gök (2014) VAR-EGARCH modelini tercih etmişlerdir.

Tuna ve İsabetli (2014), 2002-2012 döneminde İMKB 100 endeksi için volatilitite modellemesi yapmışlardır. Araştırmacılar, GARCH (1,1) modelini kullanmışlardır ve modelin katsayısının yüksek değerde çıkmasını volatilitide süreklilik olarak yorumlamışlardır. Karcıoğlu ve Özer (2017) ise BIST'te yılın ayları anomalilerin varlığı tespit etmek, belirlenen anomalilerin BIST'te oluşan getiri ve volatilitite üzerindeki etkilerini saptamak amacıyla 2002-2016 tarihleri arasında, BIST Mali, BIST Hizmet, BIST 100, BIST Teknoloji ve BIST Sinai endekslerine ait günlük kapanış verileri kullanarak, ARCH-GARCH yöntemleri ile modelleme yapmışlardır. Ayrıca yapılan bu çalışmada 2008 Küresel Krizinin etkisini görebilmek amacıyla 02.01.2008-30.08.2009 tarihleri arası için kriz dönemi ve kriz olmayan dönem olmak üzere iki dönem şeklinde ele alıp incelemişler ve sonuç olarak kriz olan ve kriz olmayan dönemde Türkiye piyasalarında yaşanan volatilitite üzerinde yılın ayları anomalileri saptamışlardır. Bu iki çalışma inceledikleri endeks ve modelleme bazında karşılaştırıldığında; Borsa İstanbul'da GARCH (1,1) ile modelleme yapan Tuna ve İsabetli (2014)'nin volatilitide süreklilik olduğu yorumu yaparken birçok ARCH-GARCH modeli kullanan Karcıoğlu ve Özer (2017)'in volatilitide hem modelleme hem de finansal kriz gibi bir şok arayarak incelemeyi bir adım öteye taşıdığı görülmektedir.

Kayahan, Aydemir ve Akçay (2009), 2005 ve 2007 yılları arasına ait döviz kurlarını (Avro ve ABD doları) kullanarak EWMA modeliyle volatilitite tahminleri yapmışlardır. EWMA modelinde kullanılan lambda katsayılarının güvenilirliğini test etmek için volatilitite tahminlerinin geriye dönük test etmiş, %97 ile %99 arasında kullanılan katsayılar anlamlı sonuçlar vermiştir. Bu derece yüksek bir yüzdenin yakalanması EWMA modelinin kurlar üzerine volatilitite tahminlerinde oldukça başarılı sonuçlar verdiğini göstermektedir. Yapılan analiz ile, hesaplamalar aşamasında kullanılan lambda katsayılarının EWMA modelinde

belirlenen güven aralıkları içerisinde anlamlı tahminler oluşturduğu gözlenmiş ve böylece modelin güvenilirliği de test edilmiştir. Gökteş (2019) ise döviz kurları arasındaki volatilitenin etkileşimini araştırmak amacıyla 20.03.2012-28.09.2018 dönemini kapsayan günlük veriler üzerinde çalışarak, Dinamik Korelasyonlu Çok Değişkenli Stokastik Volatilitenin (DC-MSV) modelini kullanmış ve kur savaşları çerçevesinde döviz piyasaları arasındaki volatilitenin etkileşiminin varlığını işaret eden sonuçlar bulmuştur. Yapılan analiz neticesinde araştırmacı belirleyici piyasaların sırasıyla Yuan, Euro, Amerikan Doları ve Yen piyasaları olduğunu tespit etmiştir. Yuan, kur savaşları çerçevesinde en güçlü piyasa iken Yen döviz piyasasının ise bu savaşta en güçsüz piyasa olduğu belirlenmiştir.

Kurt ve Senal (2018) ise 2006 - 2017 dönemi içerisinde Borsa İstanbul'da işlem gören kote sigorta şirketlerine ait olan günlük hisse senedi kapanış fiyatlarından elde edilen zaman serilerine ARCH-M modeli uygulayarak, her bir zaman serisine ait olan volatilitenin analiz edilmesini amaçlamışlardır. Araştırmacılar Ray Sigorta A.Ş.-RAYSG ve Anadolu Hayat Emeklilik A.Ş.-ANHYT hisselerinde gözlemlenen volatilitenin hareketlerini inceledikleri dönemde, BİST100 endeksi, tahvil faiz oranı ve dolar kurundan etkilendiği tespit etmişlerdir. Görüleceği üzere bu çalışmada volatilitenin neden olan faktörler açısından bir yaklaşım bulunmaktadır. Baykut ve Kula (2018) ise BİST-50 endeksinin 2007-2016 dönemi için günlük kapanış değerleri üzerinden volatilitenin yapısını tespit etmek ve BİST-50 endeksinin asimetric durumunun da ortaya çıkarılması amacıyla doğrusal modeller olan ARCH ve GARCH ile asimetric modeller olan PARCH, EGARCH ve TGARCH modelleri ile analiz yapmışlar ve bulunan sonuçlara göre endeksin volatilitenin yapısını GARCH (2,1) modeli açıklamıştır. BİST-50 endeksinin volatilitenin ısrarcılığı 16.14 gün, günlük volatilitesi ise %1.76 olarak hesaplanmıştır.

Zor (2013), yaptığı bu çalışmada varant yatırımcılarının volatilitenin algılarına etki eden faktörleri belirleyebilmek amacıyla 2012 yılında BIST' de işlem görmüş ve BIST-30 endeksinin dayalı 61 alım varantının işlem gördüğü toplamda 3.187 gün verisi kullanılarak bu piyasa için etkin opsiyon fiyatlama modeli belirlemiştir, daha sonra ise bulunan etkin modelin belirlediği fiyatları piyasa fiyatlarına eşitleyen volatilitenin değerlerini bularak bu değerleri etkileyen faktörler ile regresyon analizi yapmıştır. Yapılan tüm analizler sonucunda, varantın vadesine kalan gün, dayanak varlık kapanış fiyatı ve Türk Lirası Bankalar arası Satış Oranı arttıkça yatırımcı tarafından algılanan volatilitenin azaldığı, varantın kapanış fiyatı arttığı zaman ise algılanan volatilitenin arttığı, pazartesi günü için algılanan volatilitenin yüksek olduğu, varant ihracısının volatilitenin algısını etkilediği ve enflasyonun dört dönem arttıktan sonra azalış göstermeye başladığı ilk ayda, volatilitenin algısını da düşürdüğü sonuçlarına ulaşmıştır.

Volatilite konusunda yukarıda bahsedilen Türkiye’de yapılmış çalışmalar incelendiğinde genel olarak uzun dönem günlük verilerin kullanıldığı görülmektedir. Çalışmalarda hem risk ölçüsü hem de piyasanın yönüne dair beklentileri yansıttığı düşünülen volatiliteye etki eden faktörlerin uzun dönemli araştırılması sonucu faiz oranı ve döviz kurlarının genel olarak volatiliteyi etkilediği tespit edilmiştir. Günümüzde yapılan pek çok çalışmada özellikle yüksek piyasa volatilitelerine karşı EWMA ve GARCH modellerinin daha iyi ve güvenilir sonuçlar oluşturduğu düşünülmektedir. Bu modellerin taramasında da görüleceği üzere çok fazla tercih edilmesinin nedeni budur. Nitekim bir diğer araştırma olan Kayahan, Aydemir ve Akçay (2009)’ın 2005 ve 2007 yılları arasına ait döviz kurlarını kullanarak EWMA modeliyle volatilite tahminleri yapması buna örnek olabilir. Çalışmanın modelinde kullanılan lambda katsayılarının güvenilirliğini test edilmesi ve kullanılan katsayılar %97 ile %99 arasında anlamlı sonuçlar vermesi, EWMA modelinin kurlar üzerine volatilite tahminlerinde oldukça başarılı sonuçlar verdiğini göstermektedir. EWMA modelini kullanan bir başka çalışma Özgül ve Kök (2014)’e aittir. Bu çalışmada Özgül ve Kök (2014) Londra Metal Borsasında işlem gören metallerdeki fiyat hareketleri, ilgili borsadaki volatilite yapısının belirlenmesi amacıyla yaptığı çalışmada EWMA yöntemi kullanmış ve bu yöntem ile hesaplanan volatilite değerlerinin çalışmada kullanılan diğer yöntemlere oranla piyasa oynaklığını daha iyi açıkladığı belirtmiştir.

Uluslararası yazında ise GARCH ailesi modelleri kullanan oldukça fazla sayıda çalışma bulunmaktadır. Bunlardan bazılarına; Rashid ve Kocaaslan (2013); Samman ve Otaify (2017); Bunnag (2016); Hsing (2012); Carchano, Lucia ve Pardo (2017); Hamdi ve Chkili (2019) çalışmaları örnek olarak gösterilebilir. Rashid ve Kocaaslan (2013); İngiltere’de enerji tüketimi volatilitesi ile gerçek gayri safi yurtiçi hasıladaki (GSYİH) öngörülemeyen varyasyonlar arasındaki ilişkiyi ampirik olarak incelemişlerdir. ARCH modelinden elde edilen sonuçlar, enerji tüketimindeki değişkenliğin GSYİH dalgalanmalarının davranışını belirlemede önemli bir rolü olduğunu göstermektedir. Ayrıca, araştırmacıların bulduğu sonuçlar enerji tüketimindeki öngörülemeyen değişikliklerin GSYİH dalgalanması üzerindeki etkilerinin, dalgalanmanın yoğunluğuna bağlı olarak asimetric olduğunu göstermektedir. Samman ve Otaify (2017), Temmuz 2002-Haziran 2015 dönemini kapsayan Mısır verilerine dayanarak, özelliklere göre sıralanmış portföylerin volatilitésinin makroekonomik volatiliteye nasıl tepki verdiğini araştırmışlardır. Yapılan GARCH analizi sonucuna göre para arzındaki volatilitenin, özelliklerine göre sıralanmış portföyler için baskın volatilite kaynağı olduğunu göstermektedir. Bunnag (2016), bu çalışmada ham petrol, altın, SP500 ve ABD Doları Endeksi vadeli işlemlerinde volatilite iletimini incelemiştir. Araştırmada 2010’dan 2015’e kadar günlük veriler kullanarak VAR- MGARCH modeli ile analiz yapılmıştır. Sonuç olarak ham petrol vadeli işlem volatilitésinin altın vadeli volatilite üzerinde

bir etkisi olduğu ve altın vadeli volatilitenin SP500 vadeli volatilité üzerinde etkisi olduğu, altın vadeli oynaklığının ABD Doları Endeksi üzerinde etkisi olduğu sonuçlarına ulaşmıştır. Hsing (2012), yaptığı çalışmada Yunanistan'ın döviz kuru istikrarı, parasal bağımsızlık ve finansal entegrasyon arasında bir dengesizlik olduğunu sonucuna ulaşmıştır. Carchano, Lucia ve Pardo (2017), bu çalışmada, açık ve kapalı pozisyonların ayrılmasına dayanan yeni bir birleştirici perspektiften vadeli işlem piyasalarındaki ticaretle ilgili değişkenler ve volatilité arasındaki ilişkiyi incelenmiştir. Sonuç olarak, açık ve kapalı pozisyonların sayısındaki günlük değişikliklerin her ikisinin de volatilité ile pozitif ilişkili olduğunu saptamışlardır. Hamdi ve Chkili (2019) de çalışmalarında GARCH modellerini kullandıkları görülmektedir. Ancak bu çalışmada EGARCH modelinden elde edilen artıklarla oluşturulan melez model kullanarak yapılan analizler sonucunda melez modellerin öngörü performansının GARCH ailesi modellere göre daha başarılı olduğu iddia edilmekte ve GARCH ailesi modelleri yapay sinir ağı tabanıyla geliştirilmektedir.

Literatürdeki çalışmaların kullandıkları modellere dikkat edildiğinde çok çeşitli olan ARCH grubu modellerin çalışmaların amacı ve veri özelliğine göre kullanım çeşitliliği olduğu görülmektedir. Bu çalışmada ise Hamdi ve Chkili (2019) modelinin ABD doları / Türk Lirası kuru volatilité modellemesinde seçilen diğer ARCH grubu modellere göre gerçekten üstün performans sergileyip sergilemediği araştırılarak uygulamalı çalışma literatürüne katkı sağlamak amaçlanmıştır.

3. Veri Seti ve Metodoloji

3.1. Veri Seri

Bu çalışmada veri seti olarak Türkiye Cumhuriyeti Merkez Bankası Elektronik Veri Dağıtım Sistemi (TCMB EVDS)'den elde edilen Amerikan Doları/Türk Lirası- (\$/₺) reel alış kuru incelenmiştir. Veri dönemi 2018 dönemi itibariyle ₺'nin majör dövizler karşısında hızlı değer kaybı yaşaması ve volatilitenin artması nedeniyle Ocak 2018-Aralık 2019 günlük kapanış değerleri olarak belirlenmiştir.

Piyasalarda varlık fiyat hareketlerinin analizinde varlıkların fiyat verilerini yerine getiri serilerinin kullanımı Campbell, Lo ve Mackinlay (1997) tarafından tavsiye edilmektedir. Campbell, Lo ve Mackinlay getiri serilerinin ampirik çalışmalarda kullanılmasını önerirken iki sebep belirtmektedirler. Bunlar (Çil, 2018: 7):


- “Finansal varlığın getirisi, yatırım fırsatları açısından tam ve ölçü biriminden bağımsız özet bir bilgi sağlamaktadır

- *Getiri serilerinin istatistiksel özellikleri fiyat serilerine göre daha fazla bilgi içerir. Fiyat serileri stokastik özellik gösterirken getiri serileri ortalamaya daha yakındır ve dolayısıyla genellikle durağandır”*

olarak ifade edilmektedir.

Buradan hareketle $\text{₺}/\text{\$}$ değişkenine ait logaritmik getiri serisi elde edilmiştir. $\text{₺}/\text{\$}$ kuruna ait günlük kapanışlar Grafik 1.’de verilmiştir.


Grafik 1. ABD Doları/Türk Lirası Kuru Günlük Kapanış



Kaynak: Türkiye Cumhuriyeti Merkez Bankası Elektronik Veri Dağıtım Sistemi (2019)

Grafik 1’de yer alan $\text{\$/₺}$ kuru kapanış verileri incelendiğinde 2018 Ağustos döneminde kurun en üst seviyesine eriştiği görülmektedir. Aynı dönem içerisinde yapılan müdahale (Ekonomi Haber, 2018) ile kur 6 ₺ seviyesinin altına inse bile dönem başındaki seviyesi olan 4 ₺ alt sınırına erişememiştir. Bu fiyat değişimleri, genel olarak, büyük fiyat hareketlerinin büyük fiyat hareketlerini takip ettiği yönündeki volatilité kümelemesi varlığına dair ön fikir verebilir.

Zaman serisi analizi yapan araştırmacılar veri setlerinin içerdiği özellikler nedeniyle fiyat serisi ile genel bir yargıya varamamaktadır. Bu nedenle logaritmik getiri serileriyle genel fikir edinilmektedir. Bu nedenle fiyat serisine ait logaritmik getiri serileri elde edilmiştir. Serilerin logaritmik getirilerinin kullanılmaması analizlerde aşırı uç değerler nedeniyle hatalı ekonomik yorumlar yapılmasına neden olabilir ve bu olumsuz etkinin giderilmesi için logaritmik getiri serilerinin kullanılması önemlidir. Grafik 2’de $\text{₺}/\text{\$}$ kuru kapanış verilerinin logaritmik getiri serisi verilmiştir.

Grafik 2. ABD Doları/Türk Lirası Serisi Logaritmik Getiri

Kaynak: Yazarlar tarafından oluşturulmuştur.

3.2. GARCH Tipi Modeller

GARCH modeli Bollerslev tarafından 1986 yılında ortaya atılmıştır ve bu modelde anahtar kavram koşullu varyanstır. GARCH modeli cari koşullu varyansın geçmiş ilk p koşullu varyansa ve elbette ki q geçmiş şokların karesine bağlı olduğunu kabul eder. Model genellikle koşullu varyansı her bir değişkenin bir gecikmeli değerini alarak oluşturmaktadır. GARCH modeli aşağıdaki gibi ifade edilebilir:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

Bir başka model ise Engle ve Bollerslev tarafından oluşturulan bütünleşik GARCH (IGARCH) modeli olup koşullu varyansın sonsuz bir sürekliliğe sahip olduğu varsayımına dayanır. GJR-GARCH modeli Glosten, Jagannathan ve Runkle tarafından 1993 yılında ortaya çıkarılmıştır. Pozitif ve negatif beklenmeyen getirilerin koşullu varyans üzerinde farklı etkileri vardır. Bununla beraber, borsa getirilerinin koşullu ortalama ve koşullu varyansı arasındaki ilişki negatiftir (Glosten vd., 1993: 1799). GJR-GARCH modeli ile de asimetrik etkinin yakalanması mümkündür. Bu modelde, iyi haberlerin ve kötü haberlerin koşullu varyans üzerindeki etkileri ayrıştırılmaktadır. GJR-GARCH modeli aşağıdaki gibi ifade edilebilir:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{k=1}^r \gamma_k \varepsilon_{t-k}^2 d_{t-k} + \sum_{j=1}^p \beta_j \sigma_{t-1}^2$$

Bir diğer model ise asimetri etkisini tanımlayan Nelson (1991) tarafından geliştirilen üs-sel GARCH (EGARCH) modelidir. EGARCH (p,q) modeli aşağıdaki gibi ifade edilebilir:

$$\ln(\sigma_t^2) = \alpha_0 + \sum_{i=1}^p \alpha_i \frac{|\varepsilon_{t-i}| + \gamma_i \varepsilon_{t-i}}{\sigma_{t-i}} + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

EGARCH modelinin avantajları olmasına rağmen modelin ampirik tahmini teknik açıdan çok zordur. Sebebi ise yüksek sayıda doğrusal olmayan algoritmalar içermesidir. EGARCH modelinin aksine, GJR- GARCH modeli çok daha basittir ve tahmini daha kolaydır (Wang, 2007: 38).

3.3. Yapay Sinir Ağları

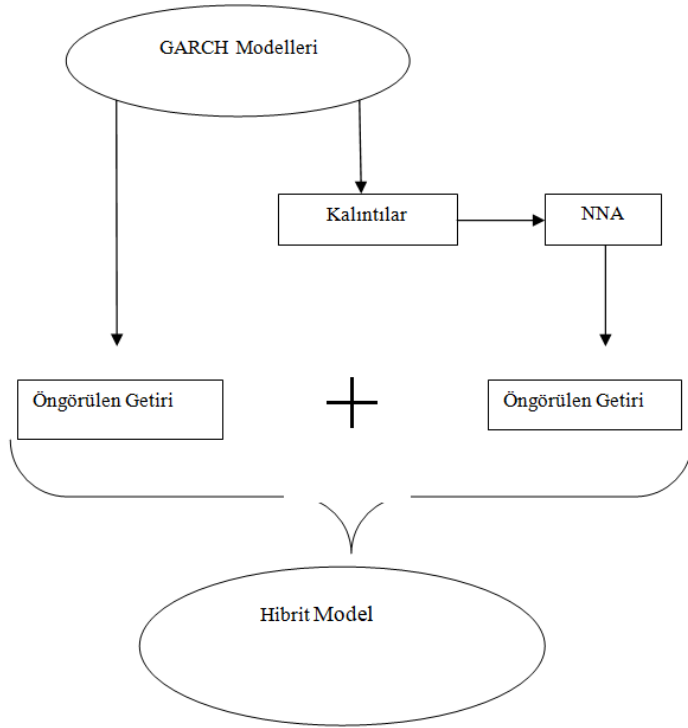
Yapay sinir ağları insan beyninin öğrenme yetisinden esinlenerek yeni bilgilerin üretilmesi için geliştirilmiş bilgisayar sistemleridir. Yapay sinir ağları paralel olarak dağılmış zeka gerektiren bir bilgi işleme merkezine sahiptir. Nörolog olan Donald Hebb (1949) beynin öğrenme yapısı ile ilgili araştırmalar yaparak şu anda kullanılan yapay sinir ağlarının temel modelini oluşturmuştur. İlk yapay sinir ağı modelini oluşturan Hebb, beyindeki sinir hücrelerini inceleyerek iki sinir hücresinin birbiri ile nasıl bir ilişki içerisinde olduğunu gözlemlemiştir. Genel olarak YSA'lar insan beynindeki sinir hücrelerinin birbirleri ile etkileşim halinde olan karmaşık sistemler bütünü şeklindedir. Bu sistemler, çözülmesi zor ve karmaşık olan problemleri sonuca ulaştırabilmek için kullanılan bir bilim dalı olarak geliştirilmiştir (Yılmaz, 2019: 1).

3.4. Melez Model

Önerilen melez model, incelenen zaman serisinin doğrusal ve doğrusal olmayan kısımlarıyla başa çıkmak için bir GARCH yaklaşımının sinir ağı yayılımı (NNBP) modeliyle birleştirilmesinden oluşmaktadır. Melez bir model oluşturmak için üç adım izlenmektedir. Birincisi aşamada GARCH ailesi modeller ile artıkların belirlenir. İkinci aşamada, yapay sinir ağı kullanılarak kalıntılar tahmin edilmeye çalışılır. Üçüncü ve son adımda, GARCH modeli ile öngörülen getiriler yapay sinir ağı modelinde elde edilen artıklara eklenir (Hamdi ve Chkili, 2019: 5).

Melez metodolojinin tasarımı Şekil 1.'de ifade edilmiştir.

Şekil 1. Melez Model Aşamaları



Kaynak: Hamdi ve Chkili, (2019)

4. Bulgular

Modelin tanım aşamasında verilen adımların ilki olan GARCH ailesi modellerle öngörülen elde edilecek kalıntılar için süreç birkaç adımdan oluşmaktadır. Bu süreçlerin ilki olan veri setinin tanımlayıcı özellikleri ve durağanlık seviyelerinin ifade edilmesidir. Durağanlık zaman serisinin ortalama ve varyansa uzun dönemde ortalamaya dönme eğilimini ifade etmektedir. Başka bir deyişle durağan olmayan bir seride, zaman serisinin davranışı sadece ele alınan dönem içerisinde incelenebilir. Dolayısıyla durağan olmayan seriler öngörü yapmaya müsait değildir (Çil, 2018). Bu nedenle durağanlaştırma süreçlerinden yararlanır. Durağanlaştırma süreçleri incelenen serinin farkı alınmak suretiyle yapılır. Farkı alınan yeni serilerin durağanlıklarının sınanması için birim kök testlerinden yararlanır. Bu çalışmada incelenen seri seviyede durağan değildir. Bu nedenle serinin 1. düzey farkı incelenmiştir. Tanımlayıcı istatistikler Tablo 1.'de ve Düzey ve fark değerlerine ilişkin durağanlık sınamaları Tablo 2'de verilmiştir.

Tablo 1. Tanımlayıcı İstatistikler

Ortalama	5.240425
Maksimum	6.879800
Minimum	3.737100
Standart Sapma	0.767166
Çarpıklık Katsayısı	-0.705490
Basıklık Katsayısı	2.377453
Jarque-Bera İstatistiği	49.55069 (0.0000)

Tablo 1.'de yer alan sonuçlardan da görüleceği üzere \$/₺ logaritmik getiri serisi basıklık ve çarpıklık katsayısı normal dağılım sergileyen serilerde olması gereken eşitlikten farklıdır. Çil (2018) belirttiğine göre “Jarque-Bera testi, 2 serbestlik derecesiyle ki-kare dağılımına uygunluk göstermektedir. J-B testinin kritik değerlerden büyük değerleri, getirilerin normal dağıldığı savını öne süren temel hipotezin reddedildiğini gösterir. Basıklık dağılımının kuyruklarının kalınlığını ölçer. Normal dağılım için çarpıklık 0, basıklık 3'e eşittir.” Jarque Bera testinin boş hipotezi serinin normal dağılıma uyduğunu söylemektedir. Yokluk hipotezi reddedilmesi serinin normal dağılıma uymadığının ifadesidir (Uğurlu vd. 2014; Uğurlu, 2014; Cihangir Kurt ve Uğurlu, 2017). İncelenen serinin normal dağılım sergilemediği, farkı alınan serinin çarpıklık ve basıklık değerleri incelendiğinde ise kuyruklarda kalınlık ve aşırı sivrilik sergilediği ve serinin leptokörtik dağılım sergilediği görülmektedir.

Tablo 2. Durağanlık Sınaması

	Düzye Değerleri (I(0))	Fark Serisi (I(1))
ADF Birim Kök Testi	-1.819376 (0.3710)	-11.04737 (0.0000)
PP Birim Kök Testi	-1.755998 (0.4024)	-17.87525 (0.0000)

Parantez içi değerler istatistiklere ait olasılık sonuçlarıdır. Durağanlık testlerine ait hipotezler ise;

$H_0: \delta \geq 0$ birim kök vardır / veri durağan değildir. $H_1: \delta < 0$ birim kök yoktur / veri durağandır. Şeklinde. Düzye değerleri ADF ve PP Birim kök testi sonuçları incelendiğinde olasılık değerleri %1 anlamlılık düzeyinden yüksektir. Bu nedenle serinin durağan olduğuna dair alternatif hipotez reddedilmektedir. Durağanlaştırma sürecinde farklı alınan serinin (I(1)) ise ADF ve PP birim kök testi olasılık değerleri incelendiğinde %1 anlamlılık düzeyinde serinin birim durağan olmadığına dair yokluk hipotezi reddedilir ve serinin durağan olduğu yönündeki alternatif hipotez kabul edilir.

Getiri serisinin tanımlayıcı istatistiklerinden yola çıkarak volatil yapısı olduğu varsayılmıştır. Ancak ARCH etkisinin varlığı için ön test yapılması ve bu varsayımın geçerliliğinin sınanması modelleme yapmak noktasında önemlidir. Tsay (2010) finansal bir varlığın, koşullu değişen varyans modelleriyle volatilité modelini oluşturmak için ARCH etkisini test etmek ve ortalama denklem kalıntılarının hesaplanması gerekliliğini ifade etmiştir. Daha açık bir ifadeyle kurulan ortalama modelin artıklarında ARCH etkisinin varlığı kanıtlanıyorsa ARCH modeli kurmak anlamsızdır.

ARCH etkisi, genellikle değişen varyansın seri korelasyonu olarak adlandırılan değişen varyans içindeki bir ilişki ile ilgilidir. Belirli bir değişkenin varyansında veya volatilitesinde kümelenme olduğunda ve bazı faktörler tarafından belirlenen bir model ürettiğinde genellikle belirgin hale gelir. Döviz kurunun volatilitesi kurun riskini temsil etmek için kullanıldığı göz önüne alındığında, ARCH etkisinin bir finansal varlığın riskini ölçmek olduğu söylenebilir. ARCH LM (ARCH etkisi) modeli hipotezleri;

$$H_0 = \text{ARCH etkisi yoktur}$$

$$H_1 = \text{ARCH etkisi vardır}$$

ARCH ortalama denklemi ve ARCH LM testine ait sonuçlar Tablo 3.'te verilmiştir.

Tablo 3. Getiri Serisi ARCH ortalama modeli ve ARCH-LM Testi Sonuçları

Ortalama Model	Katsayılar	z-istatistiği	Olasılık
α_0	0.196575	18.06805	0.0000
α_1	0.000171	52.38780	0.0000
ARCL-LM Testi	Gecikme Uzunluğu	F-İstatistiği	Gözlemlenen*R ²
	1	368.1342 (0.0000)	212.1555 (0.0000)

Tablo 3.'te yer alan ARCH ortalama denklemi katsayıları %1 anlamlılık düzeyinde istatistiksel olarak anlamlıdır. ARCH testi sonuçları modelde ARCH etkisi olduğunu göstermektedir. Yine ortalama modelden elde edilen hatalar ile yapılan ARCH LM testi F istatistiği ve Gözlemlenen*R² sonuçları incelendiğinde sonuçların %1 düzeyinde istatistiksel olarak anlamlı olduğu görülmektedir. Buradan hareketle ARCH etkisinin olmadığını varsayan yokluk hipotezi reddedilir. Alternatif hipotezin kabulüyle ARCH etkisi içeren serinin volatilitesini modellemek adımına geçilebilir. En iyi modeli belirlemek için Akaiki Bilgi Kriterinden (AIC) yararlanılacaktır.

Tablo 4. Volatilite Modelleri

	GARCH(1,1)	GJR-GARCH(1,1)	EGARCH(1,1)
α	0.261120	0.305671	0.342003
β	0.757264	0.788286	0.958053
γ	-	-0.179102	0.114692
AIC	-6.477474	-6.492359	-6.504581*

Akaike Bilgi Kriteri (AIC)'ye göre en iyi öngörü performansına sahip model EGARCH (1,1) modelidir. Buradan hareketle EGARCH (1,1) öngörü modelinden elde edilen hata terimleri yapay sinir ağı modeli kullanılarak öngöründe bulunulmuştur. Öngörü performansının değerlendirilmesinde çok çeşitli hata istatistikleri kullanılabilir (Akar, 2007). Bu çalışmada öngörü performansının değerlendirilmesinde ortalama hata karesinin karekökü (root mean square error: RMSE), ortalama mutlak hata (mean absolute error: MAE) katsayılarından yararlanılmıştır. Bu katsayılardan en küçük değere sahip olan modelin tahmin performansı en iyi olduğu kabul edilir. Melez modelin performansının diğer modellerle de kıyaslanabilmesi için GARCH (1,1) ve GJR-GARCH (1,1) modellerine ait katsayılar da NN-EGARCH modeli ve EGARCH modelleri katsayılarıyla birlikte Tablo 5.'te verilmiştir.

Tablo 5. Öngörü Performansları

	RMSE	MAE
GARCH(1,1)	1.337516	0.764734
GJR-GARCH(1,1)	1.336837	0.766294
EGARCH(1,1)	1.336793	0.767053
Melez Model NN-EGARCH(1,1)*	1.036893	0.757453

Tablo 5.'te yer alan sonuçlar incelendiğinde en küçük ortalama hata karesinin karekökü (RMSE) ve ortalama mutlak hata (MAE) katsayılarının NN-EGARCH(1,1) modelinde olduğu görülmektedir. Bu sonuçlardan hareketle melez modelin öngörü performansının GARCH ailesi modellere göre daha başarılı olduğu iddia edilebilir. NN-EGARCH modeli sonuçlarına en yakın ve açıklayıcı modelin hata istatistiklerine göre EGARCH modeli olduğu Tablo 5'te yer alan sonuçlarda görülmektedir. Ancak bu modeller arasındaki bu farkların istatistiksel olarak anlamlı olup olmadığının sınanması genellenabilir sonuçlara erişme noktasında önemlidir. Bu nedenle bu farkların istatistiksel olarak anlamlı olup olmadığının sınanmasında Diebold-Mariano testi kullanılmıştır. DM testinde, kayıp fonksiyonlarda hata kareleri ortalaması (MSE) ve mutlak hata kareleri (MAE) tercih edilen kayıp fonksiyonlarıdır. Bu çalışmada MAE kullanımı tercih edilmiştir ve tahmin hataları farkının beklenen değeri (Ersin, 2011);

$$E(d_t) = \bar{d} = \frac{1}{H} \sum_{t=1}^H [MAE(e_{1t}) - MAE(e_{2t})]$$

Olarak hesaplanmıştır. DM testinde yokluk hipotezi $H_0 : d = 0$ 'dır. Diebold Mariano testine ilişkin sonuçlar Tablo 6.'da verilmiştir.

Tablo 6. Diebold-Mariano Test Sonuçları

Model \ Karşılaştırılan Model	GARCH (1,1)	GJR-GARCH (1,1)	EGARCH (1,1)
GJR-GARCH (1,1)	2.619591 (0.009) **	-	-
EGARCH (1,1)	2.753965 (0.006) **	2.804116 (0.005) **	-
Melez Model NN-EGARCH (1,1)	2.984005 (0.002) **	3.044271 (0.002) **	3.217110 (0.001) **

DM testi sonuçlarında görüleceği üzere oluşturulan melez modelin hata istatistikleri ve GARCH(1,1), GJR-GARCH(1,1) ve EGARCH(1,1) modellerine ait hata istatistiklerinin birbirlerinden farklı olmadığını söyleyen yokluk hipotezi %5 anlamlılık seviyesinde reddedilmektedir. Modellerin hata istatistiklerinin birbirlerinde farklı olduğu istatistiksel olarak anlamlıdır.

O halde hata istatistiklerine ve hata istatistiklerinin birbirlerinden farklı olduğuna dair kanıtlar ışığında kurulan melez modelin diğer tüm modellere göre Türk Lirası ve ABD Doları kuru getiri serisinin volatilitisini modellemede daha etkin olduğu iddia edilebilir.

5. Sonuç

Uluslararası ticaret hacmi ve ülkelerin, kurumların ekonomik performansları, bireysel ve kurumsal yatırımcıların risk algıları ve optimal kararları için son derece önemli olan döviz kuru volatilitésinin öngörülmesinde yeni modellerin geliştirilmesi hedefiyle yapılan bu çalışmada ABD doları ve Türk Lirası günlük kuru incelenmiştir. Özellikle Türk Lirasının 2018 yılında ABD Doları karşısında hızla değer kaybetmesi ve artan risk algısı volatilité modelinin Türk Lirası üzerinden denenmesine neden olmuştur. Çalışmada GARCH ailesi modellerinden yola çıkarak yapay sinir ağı tabanlı bir model uygulanmış ve bu modelin GARCH modellerine göre öngörü performansının ne olduğu çeşitli hata istatistikleri vasıtasıyla yorumlanmıştır. Üç adımda gerçekleşen incelemenin ilk adımında EGARCH modelinin öngörü performansı diğer GARCH ailesi modellerine kıyasla daha yüksektir. Üstsel GARCH olarak tanımlanan bu model döviz kuru volatilitésinde aşağı yönlü hareketlerin yukarı yönlü hareketlere göre daha belirleyici olduğunu ifade etmektedir. Başka bir deyişle volatilitéde kaldıraç etkisi mevcuttur. EGARCH modelinden elde edilen artıklarla oluşturulan melez modelin öngörü performansının ise EGARCH modelinden daha iyi olduğu sonucuna varılmıştır. Bu sonuç Hamdi ve Chkili (2019)'un sonuçlarıyla benzerlik göstermektedir. Diebold-Mariano testi sonuçları da kurulan modellere ilişkin hata istatistiklerindeki farklılıkların istatistiksel olarak anlamlı olduğunu göstermiştir.

Buradan hareketle melez NN-EGARCH modelinin ABD doları/Türk lirası günlük getirilerinin modellenmesinde GARCH (1,1), GJR-GARCH (1,1) ve EGARCH (1,1) modellerine göre daha iyi volatilité modelleme performansı gösterdiği söylenebilir. Çalışmada kullanılan melez model varyans dinamiklerinin modellenmesinde GARCH türü modellerin performansının daha öteye taşınabileceğini göstermesi bakımından önemlidir. Bu açıdan çalışma literatüre katkı sağlamaktadır. Melez modelin öngörü performansının GARCH ailesi modellere göre daha başarılı olduğu kanaatine varıldığından benzer çalışmalar için melez modeller önerilmektedir.

Kaynakça

- ADLIĞ, Şevket G; (2009), “Finansal Piyasalarda Ardışık Bağlanımlı Koşullu Varyans Et-kileri, Oynaklık Tahmini ve Türkiye Üzerine Bir Uygulama”, Yüksek Lisans Tezi, İstan-bul Üniversitesi Sosyal Bilimler Enstitüsü.
- AKAR, Cüneyt; (2007), Volatilite Modellerinin Öngörü Performansları: ARCH, GARCH ve SWARCH Karşılaştırması, İşletme Fakültesi Dergisi, Cilt 8, Sayı 2, 2007, ss. 201-217
- AKAR, Cüneyt; (2008), “Hisse Senedi Getirilerinde Volatilite ve Otokorelasyon İlişkisi: EAR-GARCH Modeli”, Elektronik Sosyal Bilimler Dergisi, 7(23), ss.134-142
- AKEL, Veli; (2011), Kriz Dönemlerinde Finansal Piyasalar Arasındaki Volatilite Yayılma Etkisi, 1. Basım, Detay Yayıncılık, Ankara.
- BAYKUT, Ender ve Veysel KULA; (2018), “Borsa İstanbul Pay Endekslerinin Volatilite Yapısı: BİST-50 Örneği (2007-2016 Yılları)”, Afyon Kocatepe Üniversitesi Sosyal Bi-limler Dergisi, 20(1), ss. 279-303
- BİST, (2018),<https://www.borsaistanbul.com>, 31.12.2019.
- BOOTH, Geoffrey and Gregory KOUTMOS; (1998), “Interaction Of Volatility And Auto-correlation in Foreign Stock Returns”, Applied Economics Letters, 5 (11), pp. 715-717.
- BROOKS, Chris; (2008), Introductory Econometrics For Finance. Second Edition, Camb-ridge University Press, Cambridge.
- BUNNAG, Tanatrin; (2016), “Volatility Transmission in Crude Oil, Gold, Standard and Poor’s 500 and US Dollar Index Futures using Vector Autoregressive Multivariate Ge-neralized Autoregressive Conditional Heteroskedasticity Model”, International Journal of Energy Economics and Policy, 6(1), pp. 39-52
- CAMPBELL, John Y., Andrew W LO. and Craig A MACKINLAY.; (1997), The Econo-metrics of Financial Markets, Princeton University Press, New Jersey.
- CARCHANO, Oscar, Julio LUCÍA and Angel PARDO. ; (2017), “A New Perspective on the Relationship between Trading Variables and Volatility in Futures Markets”, Interna-tional Journal of Economics and Financial Issues, 7(2), pp. 397-407
- ÇABUK, Altan, Mehmet ÖZMEN ve Arzu KÖKCEN; (2011), “Koşullu Varyans Modelle-ri: İmkb Serileri Üzerine Bir Uygulama”, Çukurova Üniversitesi İİBF Dergisi, 15(2), ss.1-18
- ÇİL, Nilgün; (2018), Finansal Ekonometri, Der Yayınları, İstanbul.
- CİHANGİR KURT Çiğdem ve Erginbay UĞURLU; (2017), “Altın Piyasasında Asimetrik Oynaklık: Türkiye İçin Model Önerisi”, İşletme Araştırmaları Dergisi, 9(3), ss. 284-299.
- DEMİRGİL, Hakan ve İbrahim Y GÖK.; (2014), “Türkiye Ve Başlıca AB Pay Piyasaları Arasında Asimetrik Volatilite Yayılımı”, Yönetim ve Ekonomi Araştırmaları Dergisi, 23, ss. 315-340

- EKONOMİHABER, TCMB'den Dolara Müdahale <https://www.ekonomihaber.com/doviz/tcmbden-dolara-mudahale-h19563.html>,03.01.2020
- ERSİN, Ö. Ömer; (2011), "Türkiye'de Mali Sürdürülebilirliğin Doğrusal Olmayan Bir Analizi: MLSTAR Çoklu Lojistik Yumuşak Geçişli Otoregresif Modeli", Ege Akademik Bakış, 11(Özel Sayı), ss. 41-58.
- GLOSTEN, Lawrance, Ravi JAGANNATHAN ve David RUNKLE; (1993), On the relation between the expected value and the volatility of the nominal excess return on stocks. *The Journal of Finance*, 48(5), pp.1779-1801
- GLUHAM. Ali (2013), "EGARCH, GJR-GARCH, TGARCH, AVGARCH, NGARCH, IGARCH and APARCH Models for Pathogens at Marine Recreational Sites", *Journal of Statistical and Econometric Methods*, vol. 2(3), pp.57-73
- GÖKTAŞ, Özlem; (2019), "Kur Savaşları Çerçevesinde Döviz Kurları Arasındaki Volatilitate Etkileşimi", *Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi*, 10(3), ss.627-638
- HAJİZADEH, Ehsan, Masoud MAHOOTCHİ, Akbar İPOURESFAHAN and MahdiKh MASSAHİ; (2015), "A New NN-PSO Hybrid Model For Forecasting Euro/Dollar Exchange Rate Volatility", *Theory And Applications Of Soft Computing Methods*, 7(31), pp. 2063-2071
- HAMDİ, Manel ve Walid CHKİLİ; (2019), "An Artificial Neural Network Augmented GARCH Model For Islamic Stock Market Volatility: Do Asymmetry And Longmemory matter?", *In Economic Research Forum Working Papers*, 1325(13), pp. 1-13.
- HSING, Yu; (2012), "Impacts of the Trilemma Policies on Inflation, Growth and Volatility in Greece", *International Journal of Economics and Financial Issues* 2(3), pp.373-378
- KARCIOĞLU, Reşat ve Nevin ÖZER; (2017), "Hisse Senedi Piyasasında Yılım Ayları Anomalilerinin Getiri ve Volatilitate Üzerindeki Etkisinin İncelenmesi: Borsa İstanbul Uygulaması", *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 21(4), ss. 1571-1596
- KAYAHAN, Cantürk, Oğuzhan AYDEMİR ve Barış AKÇAY; (2009), "Döviz Piyasalarında EMWA Modeli Kullanılarak Hesaplanan Volatilitate Tahminlerinin Test Edilmesi", *SÜ İİBF Sosyal ve Ekonomik Araştırmalar Dergisi*, 16(1), ss. 503-522
- KAYRAL, İhsan Erdem; (2017), "Koşullu Değişen Varyans Modelleri ile Türkiye Altın Piyasası Endeksi Volatilitelerinin Tahmin Edilmesi", *Yönetim ve Araştırmaları Dergisi*, 15(2), ss.163-181
- KURT, Fatma Esin ve Serpil SENAL; (2018), "Sigorta Sektörü Hisse Senedi Piyasasında Volatilitate Modellemesi: ARCH-M Yöntemi İle Borsa İstanbul'da Bir Uygulama", *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 3(32), ss. 314-332
- NELSON, B. Daniel; (1991), "Conditional Heteroskedasticity in Asset Returns: A New Approach", *Econometrica*, 59(2), pp. 347-370.
- ÖZGÜL, Ali Ulvi ve Dündar KÖK.; (2014), "Londra Metal Borsası Volatilitate Analizi: 1995-2013", *Pamukkale Journal Of Eurasian Socioeconomic Studies*, 1(1), ss.23-43

- RASHİD, Abdul ve Özge KANDEMİR KOCAASLAN; (2013), “Does Energy Consumption Volatility Affect Real GDP Volatility? An Empirical Analysis for the UK”, *International Journal of Energy Economics and Policy* 3(4), pp.384-39
- SAĞLAM, Müge ve Mehmet BAŞAR; (2016), “Döviz Kuru Oynaklığının Öngörülmesi: Türkiye Örneği”, *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 18(31), ss.23-29
- SAMMAN, Ahmed Al ve Mahmoud Moustafa OTAIFY; (2017), “How Does Volatility of Characteristics-sorted Portfolios Respond to Macroeconomic Volatility?”, *International Journal of Economics and Financial Issues*, 7(4), pp. 300-315
- SENTANA, Enrique; (1995), “Quadratic ARCH Models”, *Review of Economic Studies*, 62(4), pp. 639-661.
- ŞAHİN, Özkan ve ÖNCÜ Mehmet A; (2015), “Volatilite Alanında Yapılmış Lisansüstü Tezlere Yönelik Bir İçerik Analizi”, *Muhasebe ve Finansman Dergisi*, Ekim, 1(68) ss. 135-156
- TCMB EVDS, (2020), <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, 31.12.2019
- TOPALOĞLU, Emre Esat; (2018), “Döviz Kuru Getiri Oynaklığı Modellemesi: DOLAR, EURO ve STERLİN Serileri Üzerine GARCH, EGARCH ve IGARCH Modelleri ile Bir İnceleme”, *Manas Sosyal Araştırmalar Dergisi*, 8 (4), ss. 3352-3378
- TSAY, Ruey S; (2010), *Analysis Of Financial Time Series: Third Edition*,. John Wiley & Sons, Chicago
- TUNA, Kadir ve İlayda İSABETLİ; (2014), “Finansal Piyasalarda Volatilite ve BİST-100 Örneği”, *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, 27 pp. 21-31
- UĞURLU, Erginbay, Eleftherios THALASSİNOS ve YUSUF Muratoglu; (2014), “Modelling Volatility in the Stock Markets using GARCH Models: European Emerging Economies and Turkey”, *International Journal of Economics and Business Administration*, 2(3), pp. 72-87.
- UĞURLU, Erginbay; (2014), “Modelling Volatility: Evidence form the Bucharest Stock Exchange”. *Journal of Applied Economic Sciences*, 9 (4). pp. 718-726.
- WANG, Peijie; (2007), *Financial econometrics methods and models*. London; New York: Routledge.
- YILMAZ, Oğuzhan; (2019), “Pi-Sigma Yapay Sinir Ağlarının Difarensiyel Gelişim Algoritması İle Eğitimi”, Yüksek Lisans Tezi, Giresun Üniversitesi Fen Bilimleri Enstitüsü.
- ZAKOIAN, Jean-Michel; (1994), “Threshold Heteroskedastic Models”, *Journal of Economic Dynamics and Control*, 18(5), pp. 931-955.
- ZOR, İsrail; (2013), “Varant Yatırımcısının Volatilite Algısına Etki Eden Faktörler: BİST’de Ampirik Bir Uygulama”, *Celal Bayar Üniversitesi Yönetim ve Ekonomi Dergisi*, 20(2), ss. 219-232.