



İstatistikçiler Dergisi: İstatistik & Aktüerya
Journal of Statisticians: Statistics and Actuarial Sciences
IDIA 15, 2022, 2, 60-71
Geliş/Received: 13.10.2022, Kabul/Accepted: 07.12.2022
Araştırma Makalesi / Research Article

Yangın ve doğal afet sigortası priminin Box-Jenkins modelleri ve yapay sinir ağları ile tahmin edilmesi

Berke Dilmen

AgeSA Hayat ve Emeklilik A.Ş.
İstanbul, Türkiye
berkedilmen1@gmail.com
ID 0000-0003-2100-9752

Şeyma Gencer

Groupama Sigorta
İstanbul, Türkiye
gencer.seyma@hotmail.com
ID 0000-0002-9160-4883

Furkan Arıkel

Ray Sigorta A.Ş.
İstanbul, Türkiye
fuarike@gmail.com
ID 0000-0002-2290-2457

Şeydanur Kayır

Hacettepe Üniversitesi
Aktüerya Bilimleri Bölümü
Ankara, Türkiye
seydanurkayir@gmail.com
ID 0000-0002-6279-0592

Övgücan Karadağ Erdemir*

Hacettepe Üniversitesi
Aktüerya Bilimleri Bölümü
Ankara, Türkiye
ovgucan@hacettepe.edu.tr
ID 0000-0002-4725-3588

Öz

Bu çalışmada Türkiye yangın ve doğal afet sigortası primlerinin gelecekteki öngörüsü için Box-Jenkins modelleri ve yapay sinir ağları ele alınmıştır. Bu amaçla Türkiye Sigorta Birliği tarafından yayınlanmış 2011-2021 yılları arasındaki yangın ve doğal afet sigortası prim istatistikleri kullanılmıştır. Her iki zaman serisi yöntemi ile iki yıllık prim öngörüsü yapılmış ve sonuçlar karşılaştırılmıştır. Yapay sinir ağları ile elde edilen tahmini prim değerleri ile daha düşük hata kare ortalama ve ortalama mutlak yüzde hata değeri hesaplanmıştır.

Anahtar sözcükler: ARIMA, Box-Jenkins Modelleri, Prim, Yangın ve doğal afet sigortası, Yapay sinir ağları, Zaman serileri analizi.

Abstract

Estimation of Premium of Fire and Natural Disaster Insurance with Box-Jenkins Models and Artificial Neural Networks

In this study, Box-Jenkins models and artificial neural networks are discussed for the prediction of Turkey's fire and natural disaster insurance premiums. For this purpose, fire and natural disaster insurance premium statistics for the years 2011-2021 published by the Insurance Association of Turkey were used. A two-year premium forecast was made with both time series methods and the results were compared. With the estimated premium values obtained by artificial neural networks, lower mean square error and mean absolute percent error value were calculated.

Keywords: ARIMA, Box-Jenkins Models, Premium, Fire and natural disaster insurance, Artificial neural networks, Time series analysis.

1. Giriş

Doğal afet çok sık meydana gelmeyen ancak gerçekleştiği zaman yüksek maddi kayıplara neden olabilecek deprem, hortum, kasırga gibi doğa olaylarını ve insan kaynaklı olarak toplumsal kayıplara yol açan terör, iklim değişikliği ve hava kirliliği gibi felaketleri içerir [1]. Afetlerin Epidemiyolojisi Araştırma Merkezi [2]'ne göre bir olayın doğal afet olabilmesi için en az 100 insanın etkilenmesi, 10 insanın ölmesi, olağanüstü hâl ilan edilmesi veya uluslararası yardım talep edilmesi gerekmektedir. Yangın ise ateşin kontrol edilemediği durumlarda ortaya çıkmakta, canlıların ölümüne, yaralanmasına ve ciddi maddi kayıplara neden olmaktadır.

İklim değişikliği, küresel ısınma, doğal kaynakların bilinçsiz kullanımı, sanayileşme, teknolojinin yaygın kullanımı ve kontrolsüz nüfus artışı gibi nedenler doğal afet riskini artırmaktadır. Her türlü canlı ve doğa için tehdit oluşturan doğal afetler, insanları fiziksel, sosyolojik, psikolojik ve ekonomik olarak etkilemektedir. İnsan sağlığını ve psikolojisi tehdit etmenin yanında, mal varlığını da olumsuz olarak etkileyen doğal afetlerin finansal etkileri incelenmelidir. Doğal afet riski proaktif ve reaktif risk yönetimi yöntemleri ile değerlendirilebilir. Afet meydana gelmeden önce gerçekleşme ihtimali ve olası zararlarının tahmini proaktif yöntem olarak, afet meydana geldikten sonra uygulanacak yöntemler ise reaktif yöntemler olarak adlandırılır. Proaktif risk yönetimi kapsamında afet gerçekleşmeden önce belirli finansal araçlar ile önlemler alınmalıdır. Finansal etkilerinden korunma yöntemleri afet sigortası, reasürans, afet rezerv fonu, afet tahvilleri ve olağanüstü durum kredisi şeklinde sıralanabilir [3].

Doğal afet riskinin finansmanında risk bilinci, riski önleme, risk transferi, piyasalardan faydalanmak, risk transfer ürünü geliştirmek, riski yönetmek, riskin etkisini azaltmak, uygun risk primine karar vermek, finansal olarak desteklemek, süreci başlatmak ve yol göstermek gibi süreçler mevcuttur ve bu süreçlerde kamu ve özel sektör işbirliği önemlidir. Her ülkenin doğal afet riski ile mücadelesi farklılık göstermektedir. Türkiye'de doğal afet riskinden korunma yöntemlerinin başında kuşkusuz doğal afet sigortası, zorunlu deprem sigortası ve tarım sigortası gibi sigortalar gelir. Sigorta sistemi, tanımı ve amacı gereği belirli prim tutarlarından bir havuz oluşturarak, risk ya da hasar meydana geldiğinde oluşacak finansal zararları en aza indirmeye çalışır. Ayrıca reasürans yoluyla sigorta şirketlerindeki riskin bir kısmı reasürans şirketlerine transfer edilir [4].

Sigorta sisteminin doğru çalışması için prim tutarının yükümlülükleri karşılayacak düzeyde doğru belirlenmesi gerekmektedir. Primin doğru belirlenmesi her sigorta türü için önemlidir ancak doğal afet sigortalarında meydana gelecek finansal kaybın oldukça yüksek olması riskinden dolayı şirketlerin yükümlülük karşılamada sorun yaşamaması açısından diğer sigorta türlerine göre daha fazla önem arz etmektedir. Bu nedenle matematiksel, istatistiksel ve aktüeryal yöntemlerden yararlanılabilir ve belirli bilgisayar yazılımları ile tahminler desteklenebilir. Prim tahminleri için doğrusal modeller, regresyon modelleri, genelleştirilmiş doğrusal modeller, genelleştirilmiş doğrusal karma modeller, bireysel veya kolektif risk modelleri, makine öğrenim teknikleri veya zaman serisi modelleri kullanılabilir.

Doğrusal temelli modellerde bir yıllık veri yardımıyla tahminler yapılabildiği için kullanımı daha yaygın ve kullanışlıdır. Zaman serisi yöntemlerinden yararlanabilmek için geçmiş prim ya da hasar verilerinin belli bir zaman aralığında kayıt altına alınmış olması gerekir. Bu nedenle diğer yöntemlere göre aktüerya bilimleri literatüründe çok sık rastlanmamaktadır. Ancak geleceğe dair bir öngörü çalışmasında tek bir yılı baz almak yerine bir yıldan daha uzun süreli bir veriyi baz alarak tahmin yapmak istatistiksel açıdan daha doğru tahminler sağlayabilir. Bir yıldan daha uzun süreli verilerle modelleme yapılacaksa zaman serileri yöntemlerinden yararlanmak gerekir.

Zaman serisi yöntemleri doğrusal ve doğrusal olmayan yöntemler olarak ayrılabilir. Doğrusal zaman serileri yöntemlerinden en sık kullanılan Box-Jenkins modelleri veya diğer adıyla ARIMA modelleridir. Üstel düzleştirme yöntemlerinin genelleştirilmiş biçimi olan Box-Jenkins modelleri mevsimsel veya mevsimsel olmayan zaman serilerine belirli aşamalardan geçerek uygulanır. Model belirleme, modelin tahmini, tanıtım denetim ve öngörü olmak üzere dört aşamadan oluşan bu sürece Box-Jenkins yöntemi denir. Doğrusal olmayan zaman serileri yöntemlerinden özellikle son zamanlarda yoğun olarak kullanılanlardan biri yapay sinir ağlarıdır. Biyolojik sinir ağlarına benzeyen yapay sinir ağları, insan beyninin çalışma şeklini taklit eder ve çok sayıda değişken ile çalışıp, genelleme yapabilir [5, 6]. Box-Jenkins modelleri ve yapay

sinir ağları dışında, üstel düzleştirme yöntemleri, zaman serileri için regresyon yöntemleri, çok değişkenli zaman serisi yöntemleri de zaman serilerinin analizinde kullanılmaktadır [7, 8].

Zaman serisi yöntemleri birçok finansal ve istatistiksel verinin geleceğe dair öngörüsü amacıyla kullanılmaktadır. Bir hisse senedi portföyü üzerinde veri madenciliği analizi ve yapay sinir ağları kullanarak çeşitli finansal ve ekonomik değişkenlerin yapısal ilişkisi ortaya çıkarılmaya çalışılmıştır [9]. Kaynar ve Taştan [6] aylık ve günlük döviz kuru verilerini kullanarak Box-Jenkins modelleri ile ileri beslemeli yapay sinir ağlarını karşılaştırmıştır. Schumacher ve diğerleri [10] aktüerya öğrencilerinin başarılarının ölçülmesinde yapay sinir ağlarını, lojistik regresyon modelleri ve karar ağaçlarını karşılaştırmıştır. İhracat miktarının tahmininde Box-Jenkins ve yapay sinir ağları karşılaştırması yapılmıştır [11]. Başka bir çalışmada Box-Jenkins modelleri ve yapay sinir ağları enflasyon verilerini içeren bir zaman serisine uygulanmıştır [12]. Tkáč ve Verner araştırmasında yapay sinir ağlarını; denetim ve muhasebe, maliyet izleme, kredi puanlama, döviz ve faiz oranları, mali sorun ve iflas, hisse senedi ve tahviller vb. alanlar için kullanmıştır [13]. Onocak ve Koç [14], emeklilik yatırım fonu hisse senedi fiyatlarını yapay sinir ağları ile tahmin etmiştir. BIST 100 endeksinin 2009-2019 dönemleri arasında altın, döviz kuru sepeti, mevduat faizi, emisyon, doğrudan sermaye yatırımları, portföy yatırımları ve sanayi üretim endeksi verileri otoregresif hareketli ortalama modelleri ve yapay sinir ağları ile Kantar [15] tarafından tahmin edilmeye çalışılmıştır. Genel sigorta tazminatı rezervi için çapraz sınıflandırılmış aşırı dağılım Poisson modelinin yapay sinir ağı özellikleri ile geliştirilmesi üzerine bir çalışma yapılmıştır [16]. Türkiye ev fiyatları tahmininde Box-Jenkins modelleri, çok değişkenli zaman serisi yöntemlerinden vektör otoregresif (VAR) model ve genelleştirilmiş doğrusal model (GLM) ile karşılaştırılmıştır [17]. Elektrik piyasası fiyatlarının öngörüsü için bir çalışmada [18] çoklu regresyon, Box-Jenkins ve yapay sinir ağları karşılaştırılmıştır.

Zaman serisi yöntemleri ile prim tahmini üzerine yapılan çalışmalar nispeten daha azdır. Prim tahmininde risk faktörü ve enflasyon gibi fiyatlandırmayı önemli düzeyde etkileyen faktörlerin devre dışı bırakılıp, sadece zamanın etkisinin dikkate alınması eksik prim tahminlerine neden olabilir. Prim tahmini üzerine yapılmış çalışmaların birkaçı incelenmiştir. Çekici [19], 1986 – 2009 yılları arasındaki yangın ve doğal afet sigortası prim tutarlarından ve hasar prim oranlarından oluşan zaman serisi ele almış ve 2011 yılı için yangın ve doğal afet sigortası prim tutarı tahminini Pegels'in üstel düzeltme tekniği ile yapmıştır. Çekici ve İnel [20], Hazine Müsteşarlığı tarafından 1981-2011 yılları arasında yayınlanan direkt prim üretim verilerinin yardımıyla basit ortalama tahmin yöntemi, basit hareketli ortalama tahmin yöntemi, ağırlıklı hareketli ortalama tahmin yöntemi, basit üstel düzeltme tahmin yöntemi, Holt'un iki parametrelili üstel düzeltme tahmin yöntemi, Brown'nun üstel düzeltme yöntemi ve doğrusal regresyon modeli ile bir yıllık prim öngörüsü yapmışlardır. Çetinkaya [21], 2006-2019 yılları arasında Türkiye Sigorta Birliği (TSB) internet sitesinde yayınlanan Türkiye hayat sigortası prim üretimi verilerinden yararlanarak Holt'un iki parametrelili üstel düzeltme tahmin yöntemi, Box-Jenkins modelleri ve yapay sinir ağları ile prim öngörüsü yapmıştır. İstatistiksel yöntemler dışında analitik hiyerarşi süreci gibi normalde finansal performans ve sıralama çalışmalarında kullanılan yöntemlerden de prim hesabında yararlanılabilir. Gümüş ve Uzekmek [22] İstanbul, Bursa ve Sakarya'da konutların yangın risklerini ve uygun prim tutarlarının hesaplanması için analitik hiyerarşi sürecinden yararlanmıştır.

Bu çalışmada yangın ve doğal afet sigortası prim tahmini için doğrusal zaman serisi yöntemlerinden Box-Jenkins modelleri ve doğrusal olmayan zaman serisi yöntemlerinden ise yapay sinir ağları ele alınmıştır. TSB'nin internet sayfasında [23], 2011-2021 yılları arasında yayınlanan yangın ve doğal afet sigortası prim istatistiklerinden yararlanılmıştır. Sayısal hesaplamalar R Studio [24] programında yapılmıştır. Her iki yöntemle de 2011-2019 verileri yardımıyla iki yıllık prim öngörüsü yapılmış ve tahmin sonuçları 2020-2021 yıllarındaki gerçek prim değerleri ile karşılaştırılmıştır. Bu çalışma, prim tahmininde çok sık kullanılmayan zaman serisi analizi yöntemleri ile yapıldığından prim tahminine farklı istatistiksel bir bakış açısı sunması bakımından önem arz etmektedir. Ayrıca yayınlanan son güncel istatistikler kullanıldığından, Türkiye yangın ve doğal afet sigortası primleri ile ilgili güncel bir tahmin çalışması sunulmaktadır.

Bu çalışmanın İkinci Bölümü'nde zaman serisi analizinde kullanılan Box-Jenkins modelleri ve yapay sinir ağları hakkında kısaca bilgi verilmiştir. Üçüncü Bölüm'de TSB'de yayınlanan istatistiklerden elde edilmiş zaman serisi her iki zaman serisi yöntemi ile modellenmiş ve iki yıllık prim öngörüsü yapılmıştır. Çalışmanın sonucunda elde edilen sonuç ve bulgulara ise Dördüncü Bölüm'de yer verilmiştir.

2. Zaman Serisi Analizi

2.1. Box-Jenkins Modelleri

Box-Jenkins modelleri üstel düzleştirme yöntemlerinin genelleştirilmiş halidir ve en genel haliyle $ARIMA(p,d,q)(P,D,Q)_s$ biçiminde ifade edilmektedir. Bu gösterimde p ve q sırasıyla otoregresyon (AR) ve hareketli ortalama (MA) modellerinin derecelerini gösterirken; d , durağan olmayan bir sürecin durağanlaşması için gerekli olan fark alma sayısını göstermektedir. Box-Jenkins modelleri, mevsimsel olmayan ($ARIMA(p,d,q)$) ve mevsimsel ($ARIMA(p,d,q)(P,D,Q)_s$) modeller olarak iki farklı biçimde ifade edilebilir. Mevsimsel modellerde P ve Q sırasıyla mevsimsel otoregresyon (SAR) ve mevsimsel hareketli ortalama (SMA) modellerinin derecelerini gösterirken; D , mevsimsel fark alma sayısını göstermektedir [7].

z_t durağan bir zaman serisini, ε_t ak gürültü olan hata terimini ve $(1 - B)^d$ terimi d . dereceden fark işleminin kapalı formunu göstermek üzere, mevsimsel olmayan Box-Jenkins modelinin diğer bir ifade ile $ARIMA(p,d,q)$ modelinin genel gösterimi Eşitlik (1) ile verilmiştir.

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d z_t = (1 - \theta_1 B - \theta_1 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (1)$$

Mevsimsel Box-Jenkins modeli olan $ARIMA(p,d,q)(P,D,Q)_s$ modelinin genel gösterimi ise Eşitlik (2) ile verilmiştir.

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps})(1 - B)^d (1 - B^s)^D z_t = (1 - \theta_1 B - \theta_1 B^2 - \dots - \theta_q B^q)(1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}) \varepsilon_t \quad (2)$$

Eşitlik (1) ve Eşitlik (2)'de verilen ϕ ve θ terimleri, sırasıyla otoregresyon ve hareketli ortalama modellerinin katsayılarını gösterirken, Φ ve Θ terimleri mevsimsel modellerin katsayılarıdır. Box-Jenkins yöntemi olarak adlandırılan modelleme yöntemi dört ana aşamadan oluşur. Bunlar sırasıyla; zaman serisine uygun modelin belirlenmesi, modelin tahmin edilmesi, tanısıl denetimi ve son olarak öngörü işlemidir [7].

2.2. Yapay Sinir Ağları

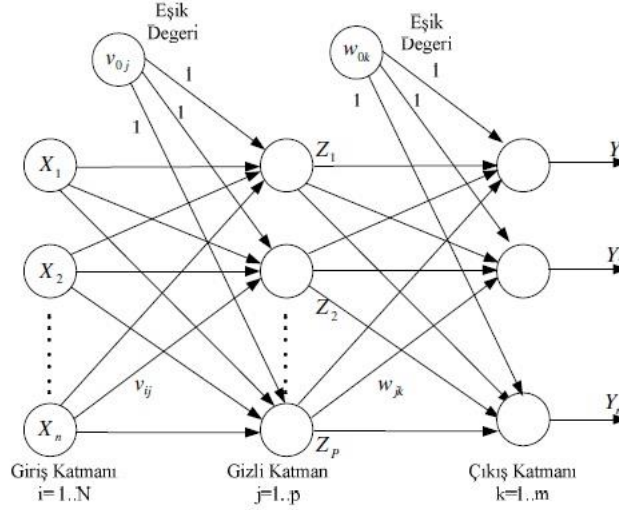
Gerçek veri yardımıyla elde edilmiş zaman serilerinin doğrusal modeller ile modellenmesinden elde edilen artıklarının doğrusallığı Mc-Leod ve Li [25] testi gibi doğrusal olmayış testleri ile incelendiğinde aslında birçoğunun doğrusal olmadığı görülür. Bu durumda zaman serilerinin doğrusal olmayan zaman serileri yöntemleri yardımıyla modellenmesi gerekir. Yapay sinir ağları sık tercih edilen doğrusal olmayan yöntemlerden birisidir ve çok katmanlı algılayıcı ağlar, Elman yapay sinir ağları, Jordan yapay sinir ağları, geri beslemeli ağlar, uzun kısa dönem hafıza ağları ve geçitli geri beslemeli ağlar gibi çeşitlere ayrılır [8]. Biyolojik sinir ağlarına benzeyen yapay sinir ağları, bilgiyi insan gibi analiz eden ve işleyen bir bilgi işleme sistemidir [5].

Bir yapay sinir ağı hücresinin 5 ana bileşeni vardır. Bunlar; girdiler (x_1, x_2, \dots, x_n), ağırlıklar (w_1, w_2, \dots, w_n), birleştirme fonksiyonu, $f(\cdot)$ aktivasyon fonksiyonu ve çıktı (y)'dir. Eşitlik (3)'te b eşik değeri ve $net = \sum_{i=1}^n w_i x_i + b$ olmak üzere bir yapay sinir hücresi doğrusal ya da doğrusal olmayan bir aktivasyon fonksiyonu yardımıyla,

$$y = f(net) = f(\sum_{i=1}^n w_i x_i + b) \quad (3)$$

biçiminde ifade edilir [6]. Çok katmanlı yapay sinir ağlarında nöronlar katmanlar olarak düzenlenmiştir ve giriş katmanı, gizli katman ve çıkış katmanı bulunmaktadır. Çok katmanlı yapay sinir ağları ileri

beslemeli ile geri beslemeli yapay sinir ağları olarak ikiye ayrılabilir. İleri beslemeli yapay sinir ağlarında aktarılan bilgiler girişten çıkışa doğru, diğer bir ifade ile ileriye doğru hareket ederken, geri beslemeli ağlarda en az bir hücrenin çıkışı, diğer herhangi bir hücreye giriş olarak verilir. İleri beslemeli yapay sinir ağları, giriş katmanındayken dışarıdan gelen bilgilere herhangi bir değişiklik yapmadan, orta ve çıkış katmanında fonksiyonlarla belli ağırlıklarla çıkış nöronuna aktarılır [26]. Çok katmanlı ileri beslemeli bir yapay sinir ağının gösterimi Şekil (1) ile aşağıda verilmiştir.



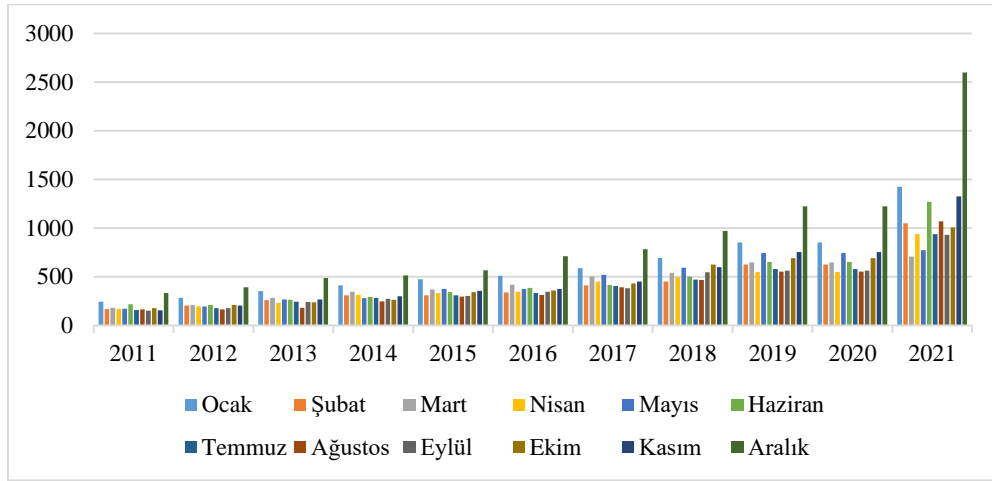
Şekil 1. Çok katmanlı ileri beslemeli yapay sinir ağı [6]

3. Uygulama: Yangın ve Doğal Afet Sigortası Priminin Zaman Serileri Analizi Yöntemleri ile Tahmini

3.1. Yangın ve Doğal Afet Sigortası Prim Verisi

Türkiye’de toplam prim üretiminde hayat dışı sigorta branşının katkısı hayat sigortası branşına göre oldukça yüksektir. TSB’de 2011-2021 yıllarında yayınlanan prim üretimi verilerine göre tüm prim üretiminde hayat dışı sigorta branşının katkısının %82-%91 aralığında değiştiği gözlenmiştir. TSB verilerine göre 2011-2021 yılları hayat dışı sigorta prim üretiminde yangın ve doğal afet sigortası primlerinin önemli bir katkısı vardır. Zorunlu mali sorumluluk, hastalık/sağlık ve kara araçları sigortalarından sonra toplam hayat dışı prim üretimine en yüksek katkıyı %13 civarında yangın ve doğal afet sigortaları yapmıştır.

TSB’de yayınlanan genel sigorta istatistiklerinden Ocak 2011’den Aralık 2021’e kadar tüm aylara ait yangın ve doğal afet sigortası prim üretimi verisi alınmıştır [23]. 2011 yılının Ocak ayından 2021 yılının Aralık ayına kadar yangın ve doğal afet sigortası prim üretim tutarlarına ait histogram Şekil 2’de verilmiştir.

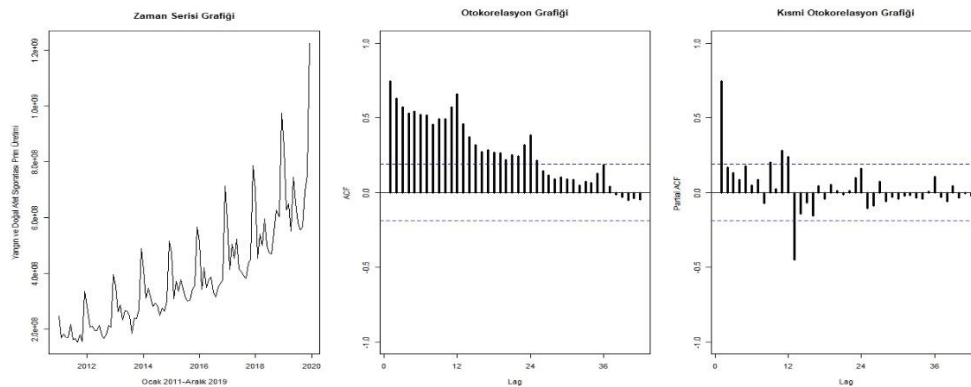


Şekil 2. 2011-2021 yılları arasında aylar bazında Türkiye yangın ve doğal afet sigortası prim üretimi (milyon)

Prim üretiminin 2011'den 2021 yılına kadar arttığı ve her yılın aralık ayında yüksek bir artış olduğu gözlenmektedir. Her yılın ay sonlarında gözlenen artışın, şirketler için raporlama dönem sonunun aralık ayı olmasından kaynaklandığı düşünülmektedir.

3.2. Zaman Serileri Yöntemleri ile Prim Tahmini

Zaman serileri yöntemleri ile prim öngörüsü yapmak amacıyla gerekli olan sayısal hesaplamalar R Studio [24] ortamında yapılmıştır. Box-Jenkins modelleri için “forecast” paketi altında arima() fonksiyonu, yapay sinir ağları için “neuralnet” paketi altında nnetar() fonksiyonu kullanılmıştır. Ek olarak “rJava”, “XLConnect”, “ggplot2”, “zoo”, “lmtest” ve “readxl” gibi diğer birçok paket kullanılmıştır. Zaman serileri tahmin yöntemleri 2011 yılı Ocak ayından 2019 yılı Aralık ayını kapsayan toplam 108 ayın verisine uygulanmıştır. Box-Jenkins modelleri ve yapay sinir ağları ile iki yıllık prim öngörüsü yapılmıştır. Son iki yıla ait olan 2020 Ocak-2021 Aralık verisi ise tahmin değerleri ile gerçek verilerin karşılaştırılması amacıyla örneklem dışı test verisi olarak belirlenmiştir. 2011 yılının Ocak ayından 2019 yılının Aralık ayına kadar yangın ve doğal afet sigortası aylık primlerine ait zaman serisi grafiği ile ACF ve PACF grafikleri Şekil 3 ile aşağıda verilmiştir.



Şekil 3. Ocak 2011- Aralık 2019 dönemleri arasında Türkiye yangın ve doğal afet sigortası primlerine ait zaman serisi, ACF ve PACF grafikleri

Aylık veri kullanıldığı için zaman serisinin frekansı 12 alınmıştır. Şekil 2’de verilen zaman serileri grafiği incelendiğinde artan bir trend ve mevsimsellik gözlenmektedir. ACF grafiği incelendiğinde ilk dört ve daha

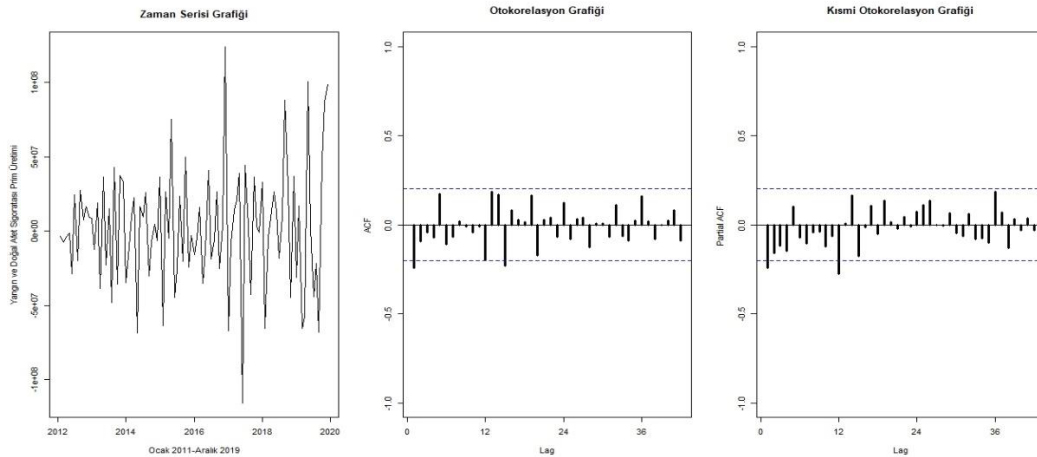
fazla gecikmenin güven sınırları dışında olması trend varlığı ihtimalini güçlendirmektedir. Zaman serisi grafiği ile ACF ve PACF grafiklerinden serinin durağan olmadığı gözlenmektedir. Durağanlığın tespiti için Augmented Dickey-Fuller (ADF) birim kök testi uygulanmıştır [27, 28]. “urca” R paketi yardımıyla serinin durağanlığı incelendiğinde seride birim kök varlığı gözlenmiştir ve serinin durağan olmadığı birim kök terstleri ile de doğrulanmıştır. Birim kök testine ait sonuçlar Tablo 1 yardımıyla aşağıda verilmiştir.

Tablo 1. Yangın ve doğal afet sigortası prim serisi için durağanlık testi sonuçları

	ADF Birim Kök Testi		
	Sabit	Sabit ve Trend	Sabitsiz ve Trendsiz
p-değeri	0.1615	2.505e-05	0.3097
ADF Test İstatistiği	-1.1792	-4.7853	0.4636
MacKinnon Kritik Değeri (%1)	-3.46	-3.99	-2.58
MacKinnon Kritik Değeri (%5)	-2.88	-3.43	-1.95
MacKinnon Kritik Değeri (%10)	-2.57	-3.13	-1.62
Düzeltilmiş R²	0.0160	0.1855	0.0035

Tablo 1’de verilen birim kök testi sonuçlarına göre sabit model ile sabitsiz ve trendsiz kurulan modellere göre ADF test istatistiği değerleri kritik değerlerden büyük ve $p > 0.05$ olduğundan seride birim kök mevcuttur. Seride birim kök bulunması serinin durağan olmadığı anlamına gelmektedir. Sabit ve trendli model serinin durağan olduğu hipotezini doğrulasa da diğer modellerde reddedilmiş ve serinin grafiklerinde durağanlık gözlenmemiştir. Fark işlemleri ile seri durağanlaştırmaya çalışılmış ve birim kök testleri yinelenmiştir.

Seri grafiklerinde trend ve mevsimsellik gözlemlendiği için sırasıyla bir fark ve bir mevsimsel fark işlemi uygulanmıştır. Fark işlemlerinden sonra yangın ve doğal afet prim serisine ait zaman serileri grafiği ile otokorelasyon ve kısmi otokorelasyon grafikleri tekrar çizdirilmiş ve Şekil 4 ile aşağıda verilmiştir.



Şekil 4. Ocak 2011- Aralık 2019 dönemleri arasında Türkiye yangın ve doğal afet sigortası primlerine ait bir fark ve bir mevsimsel farkı alınmış zaman serisi, ACF ve PACF grafikleri

Şekil 4’te verilen zaman serisi grafiği incelendiğinde, fark işlemlerinden sonra trend ve mevsimsellik yapısının kaybolduğu gözlenmektedir. ACF ve PACF grafiklerinde güven sınırlarını aşan çok fazla değer olmadığı ve ilk 4 değer güven sınırı içerisinde bulunduğu serinin durağan hale geldiği varsayılmıştır. ADF testleri de fark işlemlerinden sonra tekrarlanmıştır ve tüm model türlerine göre birim kök test sonuçları Tablo 2 ile verilmiştir.

Tablo 2. Yangın ve doğal afet sigortası prim serisi için durağanlık testi sonuçları (fark ve mevsimsel işlemleri sonrası)

	ADF Birim Kök Testi		
	Sabit	Sabit ve Trend	Sabitsiz ve Trendsiz
p-değeri	< 2.2e-16	< 2.2e-16	< 2.2e-16
ADF Test İstatistiği	-8.5185	-8.5137	-8.5226
MacKinnon Kritik Değeri (%1)	-3.51	-4.04	-2.6
MacKinnon Kritik Değeri (%5)	-2.89	-3.45	-1.95
MacKinnon Kritik Değeri (%10)	-2.58	-3.15	-1.61
Düzeltilmiş R²	0.6196	0.618	0.6177

Tablo 2’de verilen birim kök testi sonuçlarına göre tüm modeller için ADF test istatistiği değerleri kritik değerlerden küçük ve $p < 0.05$ olduğundan seride birim kök olduğunu ileri süren hipotez reddedilir. Fark işlemlerinden sonra prim serisinin durağan hale geldiği birim kök testleri ile de desteklenmiştir. Ayrıca fark işlemlerinden sonra birim kök testleri ile elde edilen düzeltilmiş R^2 değerleri artmıştır. Prim verisinin durağanlaştığı ve modellemeye uygun olduğu düşünülerek belirlenen iki zaman serisi ile prim tahmini yapılmıştır.

3.2.1. Serinin Box-Jenkins (ARIMA(p,d,q)(P,D,Q)s) Modelleri ile Modellenmesi


Yangın ve doğal afet primlerine ait zaman serisine 1. fark ve 1. mevsimsel fark işlemleri uygulandığı için $d=1$ ve $D=1$ olarak belirlenmiştir. Şekil 4’te verilen ACF ve PACF grafiğinde ilk değerler güven sınırını aştığı için $p=1$ ve $q=1$ model dereceleri ile modeller kurulmuştur. ACF grafiği daha hızlı azalıyor gibi görüldüğünden hareketli ortalama modellerinin daha uygun olabileceği düşünülmektedir. Birinci dereceden hareketli ortalama (MA(1)) modelleri kapsamında ARIMA(0,1,1)(0,1,0)[12], ARIMA(0,1,1)(0,1,1)[12], ARIMA(0,1,1)(1,1,0)[12] ve ARIMA(0,1,1)(1,1,1)[12] modelleri kurulmuştur. Bu modellerden ARIMA(0,1,1)(0,1,0)[12] modeli dışındaki modellerde bazı katsayılar istatistiksel olarak anlamlı bulunmamıştır ($p > 0.05$). Grafikselsel olarak hareketli ortalama modeli prim zaman serisine daha uygun görüldüğü için birinci dereceden bazı otoregresyon (AR(1)) modelleri ile bazı otoregresif hareketli ortalama (ARMA(1,1)) modelleri denenmiştir. Denenen AR(1) modellerinden bazıları ARIMA(1,1,0)(0,1,0)[12], ARIMA(1,1,0)(1,1,0)[12], ARIMA(1,1,0)(2,1,0)[12], ARIMA(1,1,0)(0,1,1)[12] ve ARIMA(1,1,0)(1,1,1)[12] modelleridir. Bu modellerde istatistiksel olarak anlamsız katsayılar rastlanmıştır. ARMA (1,1) modellerinden ise ARIMA(1,1,1)(0,1,0)[12], ARIMA(1,1,1)(1,1,0)[12], ARIMA(1,1,1)(0,1,1)[12] ve ARIMA(1,1,1)(1,1,1)[12] modelleri denenmiştir. Bu modellerden ARIMA(1,1,1)(0,1,0)[12] modeli dışındaki modellerde anlamsız katsayılar ile karşılaştırılmıştır. Katsayıları istatistiksel olarak anlamlı olan Box-Jenkins modelleri arasında bilgi kriterine göre bir karşılaştırma yapılmıştır. Bu sebeple en uygun Box-Jenkins modeli, en düşük BIC değerini veren ARIMA(1,1,1)(0,1,0)[12] modeli olarak kabul edilmiştir.

Tablo 3. Box-Jenkins (ARIMA(1,1,1)(0,1,0)[12]) modelinin parametre tahminleri ve bazı istatistikleri

Değişkenler	Katsayı	Standart Hata	z değeri	p
AR (1)	0,4282	0,1246	3,4359	0,0005905*
MA (1)	-0,8814	0,0582	-15,1499	< 2,2e-16*
İstatistikler				
Log-likelihood	-1788,92			
AIC	3583,83			
AICC	3584,1			
BIC	3591,49			

*İstatistiksel olarak anlamlı katsayı ($\alpha=0,05$)

Belirlenen Box-Jenkins modeli ile elde edilen tahmini prim değerleri ile aylar bazındaki gerçek prim değerleri aynı düzlemde çizdirilmiş, hataların ACF ve PACF grafikleri elde edilmiştir. Bu grafikler Şekil 5 ile verilmiştir.

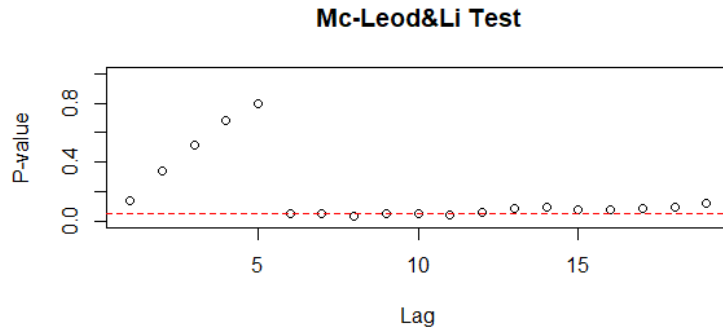


Şekil 5. ARIMA(1,1,1)(0,1,0)[12] modeli ile elde edilen tahmin değeri ile gerçek değerlerin birlikte grafiği, ARIMA(1,1,1)(0,1,0)[12] modeline ait hataların ACF ve PACF grafikleri

Şekil 5'te verilen ilk grafikte, ARIMA(1,1,1)(0,1,0)[12] modeli yardımıyla elde edilmiş tahmin değerleri, 2011-2019 yılları arasındaki gerçek aylık Türkiye yangın ve doğal afet sigortası prim değerlerine büyük ölçüde yakınsamıştır. Hataların ACF ve PACF grafikleri incelendiğinde, güven sınırını aşan çok fazla gecikme olmadığından hataların ak gürültü sürecine uyduğu söylenebilir. Hataların ak gürültü sürecine uyup uymadığı ayrıca Box-Ljung testi [29] ile test edilmiştir. Test sonucuna göre hataların bağımsız olduğunu diğer bir ifade ile ak gürültü sürecine uyduğunu ileri süren yokluk hipotezi kabul edilir ($p=0,7097>0,05$; $X^2 = 8.9209$, $df = 12$).

3.2.2. Serinin Yapay Sinir Ağları ile Modellenmesi

Yapay sinir ağları doğrusal olmayan zaman serilerinde sıklıkla kullanılan bir model sınıfı olduğundan ilk olarak yangın ve doğal afet aylık prim verilerinin doğrusallığı Mc-Leod&Li testi [25] ile test edilmiş ve grafiği Şekil 6 ile verilmiştir.




Şekil 6. Yangın ve doğal afet sigortası aylık prim tutarları zaman serisi için Mc-Leod&Li testi grafiği

Doğrusal zaman serilerinde tüm gecikmeler için p-değerlerinin kesik çizgi ile belirtilen referans çizgisinin üstünde olması beklenir [8]. Prim verisinde bazı noktalar referans noktasında ve altında olduğundan doğrusal olmama durumu vardır. Bu durumda yapay sinir ağları prim verisine uygulanabilir.

Yapay sinir ağları için “neuralnet” R paketi içindeki nnetar() fonksiyonu kullanılmıştır. Box-Jenkins modellerinde olduğu gibi son iki yıla ait olan veri test verisi olarak alınmıştır. nnetar() fonksiyonu mevsimsel olmayan zaman serileri için AR(p) modeline benzer şekilde, k gizli katman sayısını göstermek üzere bir yapay sinir ağı modelini NNAR(p,k) modeli olarak belirtmektedir. Mevsimsel zaman serileri için, ARIMA(p,0,0)(P,0,0)[m] modeline benzer şekilde yapay sinir ağlarını NNAR(p,P,k)[m] modeli olarak belirler. İlk başta seriye uygun modelin tanımlanması için parametre belirlenmemiş, yangın ve doğal afet aylık prim serisine uygun yapay sinir ağı modeli nnetar() fonksiyonu yardımıyla belirlenmeye çalışılmıştır. Fonksiyon, parametreleri NNAR(2,1,2)[12] olarak belirlemiştir. Paketin belirlediği model dışında başka birçok model uygulanmıştır. Bunlar arasından diğerlerine göre gerçek veriye daha yakın tahmin sağlayanlar NNAR(2,1,2)[12], NNAR(2,2,3)[12] ve NNAR(1,2,2)[12] modelleridir. Bu üç yapay sinir ağı modeli içinden gerçek veriye en yakın tahmin sağlayan model NNAR(1,2,2)[12] modelidir.

3.2.3. Box-Jenkins Modeli ile Yapay Sinir Ağları Sonuçlarının Karşılaştırılması

Box-Jenkins modelleri ve yapay sinir ağları ile elde edilen öngörü değerleri karşılaştırma amacıyla Şekil 7’de birlikte verilmiştir. Şekil 7’de verilen grafiklerde her iki model içinde tahmini ve gerçekleşen değerler uyumludur. Karşılaştırma kriterleri yardımıyla her iki yöntem karşılaştırılmıştır. Hata kare ortalama (MSE) değerleri Box Jenkins modeli için 2,8542 iken yapay sinir ağları için 2,3996 olarak hesaplanmıştır. Ortalama mutlak yüzde hata (MAPE) değerleri ise Box-Jenkins modelleri ve yapay sinir ağları için sırasıyla 4,5597 ve 4,4364 olarak hesaplanmıştır. MSE ve MAPE dışında MAE ve RMSE değerleri de incelenmiştir. Yapay sinir ağları ile daha düşük hata değerleri elde edilmiştir. Ancak, sadece zaman serileri yöntemlerinden yararlanarak yapılan gelecek öngörüsünde hesaplanan karşılaştırma kriteri ölçütleri yüksek çıkmıştır. Prim hesabında; yaşanan bölge, bina yapısı, iklim, sıcaklık vb. risk faktörlerinin devre dışı bırakıldığı bir tahmin yönteminin gerçeğe yakın tahminlerde sorun yaşadığı gözlenmektedir. Bu çalışmayı neticede iki zaman serisi yönteminin prim tahmininde karşılaştırılması gibi düşünmek daha doğru olacaktır.



Şekil 7. Box-Jenkins modeli ve yapay sinir ağları ile Ocak 2020 - Aralık 2021 dönemi için tahmin edilen prim değerlerinin gerçek değerlerle grafiği

4. Sonuç ve öneriler

Tüm dünyada olduğu gibi Türkiye’de de küresel ısınma, iklim değişikliği, doğal kaynakların bilinçsiz bir şekilde tüketilmesi, sanayileşme, yaygın teknoloji kullanımı ve yoğun nüfus artışı gibi nedenler ile doğal afetlerin meydana gelme sıklığı artmıştır. Doğal afetlerin finansal etkilerini en aza indirmek için tercih edilen yöntemlerin başında sigorta gelmektedir. Sigorta sisteminin etkin çalışması için sistemin girdisi olan prim tutarlarının yükümlülükleri karşılayacak düzeyde doğru belirlenmesi önemlidir. Ayrıca TSB’de 2011-2021 yılları arasında yayınlanan istatistikler incelendiğinde Türkiye’de toplam hayat dışı prim üretiminde yangın ve doğal afet sigortalarının önemli bir katkısı olduğu görülmektedir.

Prim tahmini üzerine yapılmış aktüeryal çalışmalar incelendiğinde, prim hesabında doğrusal modellerin, regresyon modellerinin, genelleştirilmiş doğrusal modellerin, genelleştirilmiş doğrusal karma modellerin,

bireysel veya kolektif risk modellerinin sıklıkla kullanıldığı görülür. Doğrusal temelli bu modellerde sıklıkla bir yıllık veri kullanılarak geleceğe dair öngörü yapılmaktadır. Bu çalışmalarda yaşanan bölge, sıcaklık, bina türü gibi fiyatlandırmayı önemli ölçüde etkilen risk faktörleri modellemeye dahil edilmektedir.

Bu çalışmada prim tahmininde kullanımına çok sık rastlanmayan zaman serisi yöntemleri ile prim öngörüsü yapılmış ve sonuçları incelenmiştir. Bu amaçla doğrusal zaman serilerinden Box-Jenkins modelleri ve doğrusal olmayan yöntemlerden yapay sinir ağları seçilmiştir. 2011-2019 yılları arasında kaydedilmiş 108 aylık prim zaman serisi yardımıyla iki yıllık prim öngörüsü yapılmıştır. Öngörü değerleri 2020-2021 yılları arasında yayınlanan 24 aylık gerçek prim değerleri ile karşılaştırılmıştır. Zaman serisi yöntemlerinde mekansal ve iklimsel etki göz önünde bulundurulmadan sadece zaman etkisi yardımıyla modelleme yapılmıştır.

Yangın ve doğal afet sigortası aylık primlerinin tahmininde Box-Jenkins modelleri ile yapay sinir ağları kendi içinde karşılaştırılmıştır. Grafiksel incelemelerde her iki yöntem ile elde edilen öngörü değerleri gerçek prim değerleri ile uyuşmuştur. Daha detaylı bir karşılaştırma amacıyla her iki zaman serisi yöntemi için MSE ve MAPE gibi model karşılaştırma kriterlerinden yararlanılmıştır. Yapay sinir ağları ile daha düşük MSE ve MAPE değeri hesaplanmıştır. Analiz sonucunda yapay sinir ağları yönteminin daha tutarlı sonuç verdiği gözlenmiştir. Bir tahmin çalışmasına göre hata değerleri beklenenden biraz fazla hesaplanmıştır. Bunun nedeni prim tahmininde sadece zaman etkisinin dikkate alınması diğer bir ifade ile risk faktörlerinin devre dışı bırakılması olarak yorumlanabilir. Ayrıca bu çalışmada prim tutarları üzerinde herhangi bir enflasyon düzeltmesi yapılmadan TSB tarafından yayınlanan istatistik bilgileri ham hali ile kullanılmıştır. Enflasyon oranları prim üzerinde önemli bir etkiye sahip olduğundan, çalışmanın devamı niteliğinde, enflasyon etkisinden arındırılmış prim verisi ile zaman serisi analizlerinin tekrarlanması ve enflasyonun zaman serileri yöntemleri ile öngörü çalışmalarına etkisinin incelenmesi planlanmaktadır.

Bu çalışmada zaman serisi yöntemlerinden sadece ikisi ele alınmış ve bir öngörü çalışması yapılmıştır. Yangın ve doğal afet sigortası prim serisine uygun olabilecek başka zaman serisi yöntemleri ile çalışma tekrarlanıp, sonuçlar karşılaştırılabilir. Zaman serisi yöntemleri ile elde edilen sonuçlar doğrusal modeller veya makine öğrenmesi ve derin öğrenme gibi veri madenciliği yöntemleri ile elde edilecek sonuçlarla karşılaştırılabilir. Ayrıca bu çalışmada 2022 yılı verilerinin hepsi yayınlanmadığından en güncel yıl olarak 2021 seçilmiştir. Daha güncel bir çalışma için 2022 yılı verilerinin hepsi yayınlandığında çalışma güncellenebilir.

Kaynaklar

- [1] S. Erpek, 2007, Sigorta Şirketlerinin alternatif risk finansmanı yöntemlerinden afet tahvilleri ve Türk sermaye piyasasında uygulanabilirliği, *Sermaye Piyasası Kurulu Yeterlik Etüdü*, 1-54.
- [2] <https://www.emdat.be/explanatory-notes>
- [3] A. Yavuz, S. Dikmen, 2015, Doğal afetlerin zararlarının finansmanında kullanılan afet öncesi finansal araçlar, *Marmara Üniversitesi Siyasal Bilimler Dergisi*, 3(2), 303-322.
- [4] N. Dalkılıç, 2014, Kamu-özel sektör işbirliği çerçevesinde doğal afet risk finansmanı, *Amme İdaresi Dergisi*, 47(4), 117-137.
- [5] L. Fausett, 1994, Fundamentals of neural networks: architectures, algorithms and applications, Prentice Hall.
- [6] O. Kaynar, S. Taştan, 2009, Zaman serisi analizinde MLP yapay sinir ağları ve ARIMA modelinin karşılaştırılması, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161-172.
- [7] C. Kadılar, H. Öncel Çekim, 2020, SPSS ve R uygulamalı zaman serileri analizine giriş, Seçkin Yayıncılık, Ankara, 1-379.
- [8] E. Eğrioğlu, E. Baş, 2020, Zaman serileri ve öngörü yöntemleri (R uygulamalı), Atlas Akademik Basım Yayın Dağıtım Tic. Ltd. Şti., 1-270.
- [9] S. Thawornwong, D. Enke, 2004, The adaptive selection of financial and economic variables for use with artificial neural networks, *Neurocomputing*, 56, 205-232.
- [10] P. Schumacher, A. Olinsky, J. Quinn, R. Smith, 2010, A comparison of logistic regression, neural networks, and classification trees predicting success of actuarial students, *Journal of Education for Business*, 85(5), 258-263.
- [11] M. Karahan, 2015, Yapay sinir ağları metodu ile ihracat miktarlarının tahmini: ARIMA ve YSA metodunun karşılaştırmalı analizi, *Ege Akademik Bakış*, 15(2), 165-172.

- [12] M. Akdağ, Y. Yiğit, 2016, Box-Jenkins ve yapay sinir ağı modelleri ile enflasyon tahmini, *Ankara Üniversitesi İktisadi ve İdare Bilimler Dergisi*, 30(2), 273.
- [13] M. Tkáč, R. Verner, 2016, Artificial neural networks in business: two decades of research, *Applied Soft Computing*, 38, 788-804.
- [14] D. Onocak, S. Koç, 2018, Yapay sinir ağları ile emeklilik yatırım fonu hisse senedi fiyatlarının tahmini. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 3(3), 590-600.
- [15] L. Kantar, 2020, BİST 100 endeksinin yapay sinir ağları ve ARMA modeli ile tahmini, *Muhasebe ve Finans İncelemeleri Dergisi*, 3(2), 121-131.
- [16] A. Gabrielli, R. Richman, M. V. Wüthrich, 2020, Neural network embedding of the over-dispersed Poisson reserving model, *Scandinavian Actuarial Journal*, 1, 1-29.
- [17] B. Yılmaz, A. S. Kestel, 2020, Forecasting house prices in Turkey: GLM, VAR and time series approaches, *Journal of Business Economics and Finance*, 9 (4), 274-291.
- [18] B. Arslan, İ. Ertuğrul, 2022, Çoklu regresyon, ARIMA ve yapay sinir ağı yöntemleri ile Türkiye elektrik piyasasında fiyat tahmin ve analizi, *Journal of Management and Economics Research*, 20(1), 331-353.
- [19] E. Çekici, 2011, Doğal afetler ve Türk sigorta sektöründe risk transferi, *Öneri Dergisi*, 9(36), 53-62.
- [20] M. Çekici, M. İnel, 2013, Türk sigorta sektörünün direkt prim üretimlerinin tahmin teknikleri ile incelenmesi. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 34(1), 135-152.
- [21] T. Çetinkaya, 2019, Hayat sigortası prim üretimlerini tahminleme yöntemlerini karşılaştırarak gelecek yıllar prim üretimini tahminleme, Doktora tezi, Marmara Üniversitesi, Türkiye.
- [22] F. Gümüş, F. Uzekmek, 2019, Yangın sigortası risk ve prim hesaplaması üzerine bir uygulama, *Journal of Accounting, Finance and Auditing Studies*, 5(1), 269-297.
- [23] <https://www.tsb.org.tr/istatistikler>
- [24] RStudio Team (2020). RStudio: Integrated Development for R. RStudio, PBC, Boston, MA URL <http://www.rstudio.com/>.
- [25] A. I. McLeod, W. K. Li, 1983, Diagnostic checking ARMA time series models using squared-residual autocorrelations, *Journal of Time Series Analysis*, 4(4), 269-273.
- [26] <https://www.veribilimiokulu.com/yapay-sinir-aglari/>
- [27] D. A. Dickey, W. A. Fuller, 1979, Distributions of the Estimators For Autoregressive Time Series with a Unit Root, *Journal of the American Statistical Association*, 75, 427-431.
- [28] D. A. Dickey, W. A. Fuller, 1981, Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root, *Econometrica*, 49, 1057-1072.
- [29] G. M. Jung, G. E. P., Box, 1978, On a measure of lack of fit in time series models, *Biometrika*, 65, 297-303.