

Talep Tahminleme Değişkenlerinin Üssel Düzeltme Yöntemi ile Belirlenmesi

Determination of Demand Forecasting Variables by Exponential Smoothing Method

Miray Betül Yılmaz 

YL Öğrencisi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, Türkiye

Özgül Vupa Çilengiroğlu 

Doç. Dr., Dokuz Eylül Üniversitesi, İstatistik Bölümü, İzmir, Türkiye

* Corresponding author: miraybetuly@gmail.com

Geliş Tarihi / Received: 13.06.2022
Kabul Tarihi / Accepted: 31.07.2022

Araştırma Makalesi/Research Article
DOI: 10.5281/zenodo.6948405

ÖZET

Günümüzde birçok sektörde olduğu gibi ticari soğutucu sektöründe de üretim planlama için en doğru stratejileri belirleme durumunda önemli olan talep tahminlemede birçok yöntem kullanılmaktadır. Bu yöntemlerin başında zaman serisi yaklaşımları yer almaktadır. Özellikle müşterilerin gelecekteki talep eğilimleri, piyasa durumu ve mevsimsellik gibi birçok faktörden etkilenebilir. İşletmelerin üretim ile ilgili yaptıkları maliyet ve ürün planlanması ile kaynakların bu hedeflere uygun olarak düzenlenmesi ve yapılandırılması önemlidir. Bu hedeflerin amacı doğru ve güvenilir tahminler yaparak işletmeleri maddi ve ticari açıdan piyasada sağlam yerlere taşımaktır. Bu çalışmada 2003-2022 yılları arasında Manisa ilinde üretim sektöründeki soğutucu buzdolabı satışlarının tahmininde kullanılacak olan Dolar, Tüketici Fiyat Endeksi (TÜFE), Üretici Fiyat Endeksi (ÜFE) ve tüketici güven endeksi (TGE) değişkenlerinin gelecek tahminlerinin üssel düzeltme (ETS) yöntemleri ile bulunması planlanmıştır.

Talep değişkenine ait kurulacak olan modeldeki diğer değişkenlerin tahmini için üssel düzeltme yöntemi (ETS) kullanılarak hata, trend ve mevsimsellik gibi üç farklı bileşen dikkate alınıp tahminleme yapılmıştır. ETS modelleri içinde en iyi performansı yakalamak için ortalama mutlak yüzde hata (MAPE) değerinden yararlanılmıştır. Eldeki veriler ile kurulan ETS modelleri TGE için ETS (A, N, N) ve TÜFE, ÜFE ve Dolar için de ETS(M, Ad, N) şeklinde bulunmuştur. Tüm bu değişkenlerde mevsimsellik tespit edilememiştir. Ayrıca TGE’de trend yok iken diğer değişkenlerde ise trendin zamanla etkisi azaldığı bulunmuştur. Ancak akan veri ile veri havuzu genişler ve başka bir ETS modelinin bulunabilme durumu ortaya kolaylıkla çıkabilmektedir. Bu yöntemin en büyük avantajlarından birisi de akan verinin de kolaylıkla dikkate alınarak yeni modellemelere izin vermesi olarak görülmektedir.

Anahtar Kelimeler: Talep Tahmini, ETS, Ortalama Mutlak Yüzde Hata

ABSTRACT

Today, as in many sectors, many methods are used in demand forecasting, which is important in determining the most accurate strategies for production planning in the commercial refrigerator sector. The first of these methods is time series approaches. In particular, future demand trends of customers can be affected by many factors, such as market conditions and seasonality. It is important that the enterprises are planning the cost and product related to production, and that the resources are organized and structured in accordance with these goals. The purpose of these goals is to carry businesses to a solid place in the market financially and commercially by making accurate and reliable forecasts. In this study, the future estimations of dollar, TUFEE, UFE and consumer confidence index variables, which will be used in the estimation of refrigerator sales in the production sector in Manisa between 2003 and 2022, were made using exponential correction (ETS) methods.

For the estimation of the other variables in the model to be established in the demand variable, the exponential correction method (ETS) was used and three different elements such as error, trend and seasonality were taken into account and estimation was made. The mean absolute percent error (MAPE) value was used to achieve the best performance among the ETS models. ETS models established with the available data are ETS (A, N, N) for TGE and ETS (M, Ad, N) for TUFE, UFE and dollar. There is no seasonality in all these variables. In addition, while there is no trend in TGE, the effect of the trend decreases over time in other variables. However, with the flowing data, the data pool expands and the another ETS model can be found by using ETS methods. One of the biggest advantages of this method is that it allows new models by taking into account the flowing data easily.

Keywords: Demand Forecasting, ETS, Mean Absolute Percent Error

1. GİRİŞ

Zaman serisi, günlük, haftalık, aylık ve yıllık gibi zamanla ölçülen gözlem değerlerinin yer aldığı serilerdir. Günümüzde sıklıkla kullanılan zaman serileri meteorolojik veriler (günlük, haftalık sıcaklık, basınç vb.), ekonomik veriler (borsanın açılış ve kapanış değerleri, haftalık yatırım oranları, döviz kuru değerleri, aylık satış sayıları vb.), tarım verileri (yıllık buğday, arpa, mısır fiyatları veya miktarları vb.) ve tüketim verileri (günde, ayda kullanılan elektrik, internet miktarları vb.) gibi seriler olarak her alanda bulunmaktadır. Zaman serisinin temel amacı seri içerisindeki ilişkileri bulmaya çalışmaktır. Aynı şekilde tek bir zaman serisi değil birden fazla zaman serileri arasındaki anlamlı istatistiksel ilişkilerin ortaya çıkarılması için zaman serileri analizi de yapılmaktadır. Zaman serisi analizi gerçekleştirildikten sonra o seride gelecekte olabilecek verileri mevcut verilerinden tahmin etme çalışmaları da yapılabilmektedir. Bu durumda zaman serilerinde analiz ve tahmin olmak üzere iki amaç bulunmaktadır. Bu iki amacın ilkinde zaman serisindeki gözlem değerleri arasındaki ilişkinin ortaya çıkarılması farklı modellerle yapılmaktadır. t zaman ve y bağımlı değişken olarak ele alınırsa zamana bağlı farklı fonksiyonlar kullanılabilir. Bu fonksiyonlar $y = \beta_0 + \beta_1 t$ ile doğrusal, $y = \beta_0 + \beta_1^t$ ile üssel(logaritmik), $y = \beta_0 + e^{\beta_1 t}$ ile üssel ya da $y = \beta_0 + \beta_1 t + \beta_2 t^2$ ile parabolik olabilir. İkinci amaçta ise tahminleme söz konusudur. t biliniyor iken $t+1$, $t+2$ vb değerler ilk amaçta elde edilen fonksiyonlar kullanılarak elde edilmektedir. Zaman serisindeki değerler bir önceki değerlerden de etkilenebilir. Yani t ile ilgileniyorken $t-1$ 'inde dikkate alınması gereklidir. Bazen zaman serisi birden fazla değişkenden de etkilenebilir. Bu durumda aslında çok değişkenli zaman serisinden yararlanılmaktadır. Zaman serisinde y ile t arasındaki ilişki ilk olarak doğrusal ilişki ile bakılmalıdır. Daha sonra üssel ve parabolik ilişkilere bakılmaktadır.

Değişkenler arasında modelleme söz konusu olduğunda zaman serisi modelleri ile klasik regresyon modelleri arasında temel farklılıklar bulunmaktadır. Zaman serisinde zamana bağlı bir bağımlı değişken varken klasik regresyonda zamandan bağımsız bir bağımlı değişken vardır. Zaman serisinde değişkenler arasındaki korelasyon çok da önemli değildir. Bu özellik ile de klasik regresyondan ayrılmaktadır. Zaman serisinde bir önceki değer bir sonraki değeri etkiler ya da etkilemez durumu söz konusudur. Eğer değer bir sonraki değer ile ilişkili ise zaten yüksek korelasyonlu çıkacaktır. Ancak burada bu korelasyon göz ardı edilmektedir. Bu özellik ile de klasik regresyondan farklılık göstermektedir. Bu özelliği ile de zaman serisinin kullanımı günümüzde sıklıkla gerçekleşmektedir.

Zaman serisindeki en önemli problem “Tahmin edilen değer geçmiş verilerden etkileniyor mu?” ya da “Kaç veriden etkileniyor?” sorularıdır. Bunların analizden önce hesaplanması önemlidir. Zaman serisindeki diğer önemli bir durumda bileşenlerdir. Zaman serisinde “trend”, “mevsimsellik”, “döngüsellik” ve “düzensizlik” gibi dört bileşen bulunmaktadır. Zaman serisinde bu dört bileşen mutlaka incelenmelidir. Trend kavramı zaman serisinin uzun dönemde gitmek istediği yön (yukarı, aşağı veya yönü yok) olarak tanımlanmaktadır. Zaman serisindeki değerler bir aşağı bir yukarı gidiyorsa trend yoktur denir. Yukarı ise “artan trend”, aşağı ise “azalan trend” vardır denir. Mevsimsellik kavramı zaman serilerinde belirli bir zaman dilimindeki dalgalanmadır. Yani sürekli aynı dönemde aynı dalgalanmaların söz konusu olmasıdır. Döngüsellik kavramında periyodik dalgalanmalar söz konusudur. Genellikle orta vadede inişler ve çıkışlar varsa bu seride döngüsellik

vardır denilebilir. Düzensizlik kavramında ise seride herhangi bir düzenin bulunmamasıdır. Ani artışlar ve düşüşler gösterebilir. Salgın, afet, savaş, ekonomik krizler buna örnektir.

Zaman serisinde kullanılan birçok yöntem bulunmaktadır. Bu yöntemler basit ortalama yöntemi, otoregresif model (AR), hareketli ortalamalar modeli (MA), otoregresif hareketli ortalamalar modeli (ARIMA), üssel düzeltme yöntemi (exponential smoothing, ETS), trend analizi yöntemi ile mevsimsel dalgalanmalar ve trende oranlama yöntemi olarak sıralanabilir. Son yıllarda bu yöntemlerden üssel düzeltme yöntemi sıklıkla kullanılmaktadır. Üssel düzeltme dediğimiz ETS yöntemi “Error-Trend-Seasonality (Hata-Trend-Mevsimsellik)” anlamına gelir ve bileşenlerin birbirleriyle nasıl özel olarak etkileşime girdiğini tanımlar. Bu yöntem ilk olarak Pegels (1969) tarafından tanımlanırken Hyndman vd. tarafından bir taksonomi ile geliştirilmiştir (Hyndman ve ark., 2008). Geliştirilen bu yöntemle oluşturulan modelde zaman serisini bu 3 bileşene ayırıp her birinin zaman üzerindeki değişimi katlanarak (exponential) değişiyorsa çarpımsal (multiplicative, M), doğrusal değişiyorsa toplamsal (additive, A) model seçilip tahminleme buna göre yapılır. Bu yüzden hata, trend ve mevsimselliğin içerikleri belli bir taksonomiye göre verilir. Hata: “M” veya “A”, Trend: “yok, Null (N)”, “A”, “Toplamsal sönümlü, (Ad)”, “M”, “çarpımsal sönümlü, (Md)”, Mevsimsellik: “yok, N”, “M”, “A”. ETS taksonomisindeki bileşenlerin net yorumları vardır. Ayrıca ETS, farklı hata, trend ve mevsimsellik türlerine sahip 30 modeli desteklemektedir. Zaman serisi verilerinin bu yöntemle sokarak en iyi bileşene sahip olan yöntem seçilerek tahminleme yapılabilmektedir (Gardner, 1985, 2006, Gardner, McKenzie, 1989).

Ekonomik değişkenler söz konusu olduğunda geleceğin doğru tahmin edilmesi önem taşımaktadır. Özellikle talep ve üretim gibi uluslararası alanlarla işbirliği olan bölümlerde döviz kurunun tahmin edilmesindeki hata oranı, geleceğe dair yapılacak plan ve programların başarısıyla direkt ilişkili olduğundan son derece önemlidir. Ayrıca talep tahmininde döviz kuru yanında sektörlerin çeşitliliğine göre tüketici fiyat endeksi (TÜFE), üretici fiyat endeksi (ÜFE) değerleri, ilgilenilen talep ürünü ile ilgili daha birçok farklı değişkenlerin kullanıldığı görülmektedir.

Literatürde talep tahminin yapıldığı farklı alanlardaki birçok değişik uygulama bulunmaktadır. Asilkan ve Irmak (2009), ikinci el otomobil piyasasının gelecekte olabilecek fiyatlarını tahmin etmek için yapay sinir ağları ve zaman serileri (ARIMA, üssel düzeltme) yöntemlerini 2005-2007 yılları için farklı değişkenlerde (otomobil modeli, detayı, kasa tipi, motor gücü vb...) kullanmışlardır. Farklı test-eğitim verilerine göre ortalama mutlak yüzde hata (MAPE) değerleri karşılaştırmasında yapay sinir ağları yönteminin daha iyi tahminlerde bulunduğunu tespit etmişlerdir (Asilkan ve Irmak, 2009).

Uğurlu ve Saraçoğlu (2010), 2003-2008 yılları arasında TÜFE verilerini kullanarak TÜFE'nin gelecek yıl tahmininde zaman serisi analizlerinden ARIMA modelinin en iyi tahminlerde bulunduğu tespit etmişlerdir. Kullanılan ARIMA modelinde mevsimselliğin TÜFE verisi için olmadığını bulmuşlardır (Uğurlu ve Saraçoğlu, 2010).

Karahan (2011), gıda sektöründe yapılan 2004-2011 yılları arasında talep tahmininde regresyon-korelasyon analizini, zaman serisi yöntemlerini (ARIMA) ve yapay sinir ağları yöntemini kullanmıştır. Bu çalışmaya göre aylık kuru kayısı fiyatı, pazar sayısı, iç ve dış talep miktarı için en iyi tahminin yapay sinir ağları ile bulunduğu karar vermiştir. Ek olarak tahmin hatası olarak bakıldığında (MAPE) yapay sinir ağları modelinin, ARIMA modelinden daha az tahmin hatası yaptığı ifade edilmiştir (Karahan, 2011).

Sabır ve Batuk (2013), 2004-2008 yılları arasında tekstil sektöründe zaman serileri modellerini kullanarak en uygun tahmin modelini bulmuşlardır. Boya terbiye işletmelerinin talep tahmininde talebin mevsimsel olarak değiştiğini ve basit üssel düzeltme yönteminin en iyi model olduğunu bulmuşlardır (Sabır ve Batuk, 2013).

Arslankaya (2019), lojistik sektöründe talep tahmini ile ilgili yapmış olduğu çalışmada 2015-2017 tekstil grubuna ait talep miktarı tahmini için yapay sinir ağları ve zaman serileri yöntemlerini kullanmıştır. Basit ortalama, hareketli ortalama ve trend analizi gibi zaman serisi yöntemlerinin

performansının MAPE gibi değerler dikkate alındığında daha düşük olduğunu göstermiştir (Arslankaya, 2019).

Bağcı (2020) Türkiye’de sık kullanılan ekonomik araçlardan döviz kuru (Amerikan Doları ve Euro) fiyatlarına ait 2014-2020 yıllarına ait verileri zaman serileri yöntemlerinden hareketli ortalama ve üssel düzeltme yöntemlerini kullanarak Fourier serileri ile düzeltilmiş ve düzeltilmemiş hali ile hesaplamıştır. Buna göre düzeltme işlemi yapmadan önce döviz kuru tahminlemesinde üssel düzeltmenin daha iyi sonuç verdiğini bulmuştur. Düzeltme işlemi ile de her iki yöntemin iyi sonuçlar verdiğini tespit etmiştir (Bağcı, 2020).

Bu çalışmanın amacı Manisa ilinde üretim sektöründe faaliyet gösteren uluslararası bir şirketin talep tahmininde kullanılan TGE, TÜFE, ÜFE ve Dolar değişkenlerinin tahminlemesini zaman serileri yöntemlerinden ETS ile bulunmasıdır.

2. MATERYAL ve YÖNTEMLER

Çalışma Tasarımı ve Grubu: Geriye doğru tanımlayıcı bir çalışmadır. Çalışma kapsamındaki tüm veriler Manisa ilinde soğutucu buzdolabı alanında faaliyet gösteren uluslararası firmanın bilgi sistemi kayıtlarından elde edilmiştir.

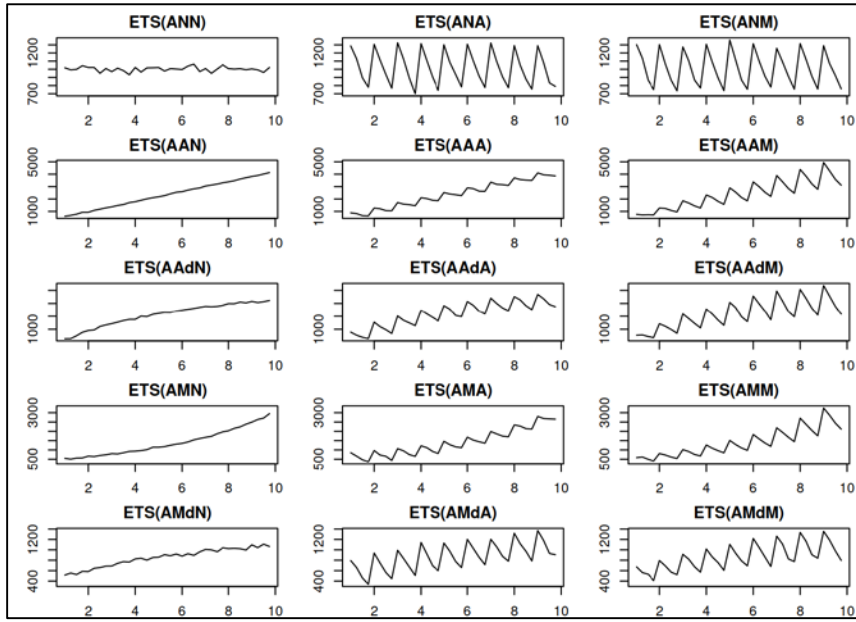
Modelleme ve tahminlemede büyük örneklemelerin daha çok bilgi içereceğinden sonuçlarının daha güvenli olduğu bilinmektedir. Bu yüzden temel amaç her değişken için mümkün olduğunca veriye ulaşmaktır. Bu çalışmada verilerinin bitiş zamanı tüm değişkenler için Nisan 2022 iken başlangıç zamanları 2003-2012 yılları arasında değişmektedir. Bunun nedeni tüm değişkenlere ait veri ulaşılabilirliğinin farklı olmasından kaynaklanmaktadır.

Bağımlı ve Bağımsız Değişkenler: Çalışmanın bağımlı değişkeni soğutucu dolapların satışları iken bağımsız değişkenleri “TGE”, “TÜFE”, “ÜFE” ve “dolar” olarak belirlenmiştir. Soğutucu dolapların satışı zamana bağlı bir değişkendir. Aynı zamanda tüm diğer bağımsız değişkenlerde zaman serisini oluşturan değişkenlerdir.

Veriler Türkiye Cumhuriyeti Merkez Bankası Elektronik Veri Dağıtım Merkezi web sitesinden alınmıştır (<https://www.tcmb.gov.tr>). Tüketici güven endeksi (TGE), tüketicilerin kişisel mali durumları ve genel ekonomiye ilişkin mevcut durum değerlendirmeleri ve gelecek dönem beklentileri ile yakın gelecekteki harcama ve tasarruf eğilimlerini ölçmeyi amaçlayan bir göstergedir. Tüketici fiyat endeksi (TÜFE), tüketicinin satın aldığı belirli bir ürün ve hizmet grubunun fiyatlarındaki ortalama değişimleri gösteren bir ölçüttür. Yıllık enflasyon değerindeki değişimi ölçmek için kullanılır. Üretici Fiyat Endeksi (ÜFE), belirli bir referans döneminde ülke ekonomisinde üretimi yapılan ve yurt içine satışa konu olan ürünlerin, üretici fiyatlarını zaman içinde karşılaştırarak fiyat değişikliğini ölçen fiyat endeksidir [<https://tr.wikipedia.org>].

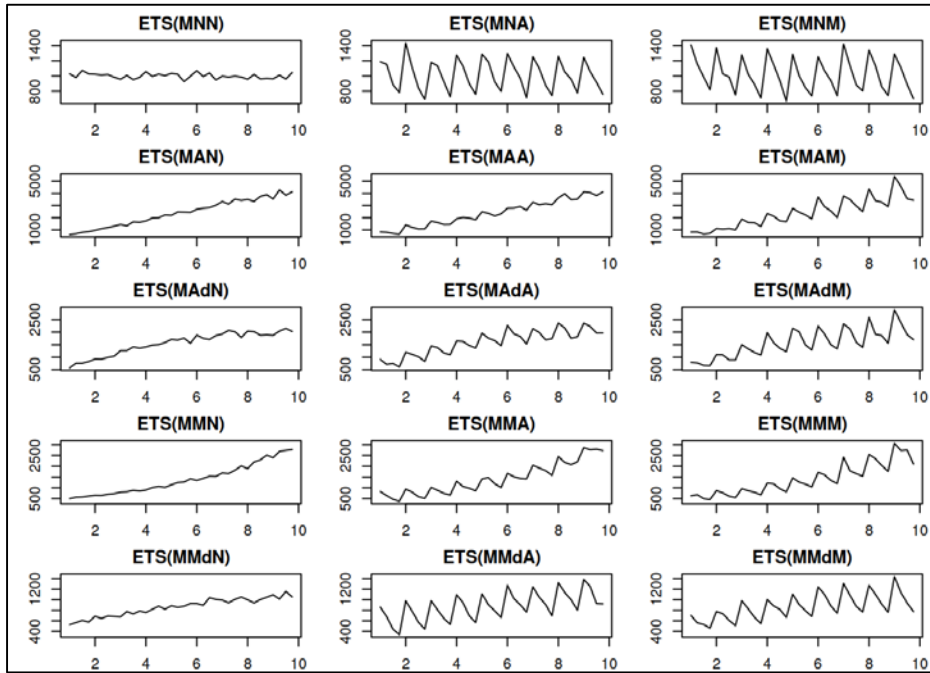
İstatistiksel Analizler: Veriler R 4.2.0 programında analiz edilmiştir. Talep tahmini değişkenine ait tüm bağımsız değişkenler için zaman serisi yaklaşımlarından ETS yöntemi kullanılmıştır. Bu yöntem ile en iyi ETS modeli tespit edilip talep tahmininde kullanılacak olan değişkenlerin tahminlemesi yapılmıştır.

ETS, “Hata-Trend-Mevsimsellik” anlamına gelen bu yöntemin bileşenlerinin birbiri ile olan etkileşimleri ile 30 farklı model tanımlanmaktadır (ETS = Hata: A, M; Trend: N, A, A_d, M, M_d; Mevsimsellik: N, A, M). Toplamsal ve çarpımsal hatanın olduğu ETS modelleri Şekil 1 ve Şekil 2’de verilmiştir.



Şekil 1. Toplamsal hata ETS modellerine karşılık gelen zaman serileri (Svetunkov, 2022)

Mevsimsellik çarpımsal olduğunda, veri seviyesinin artmasıyla genliği artarken, toplamsal mevsimsellik ile genlik sabittir. Trend çarpımsal olduğunda, veriler üstel büyüme/azalma sergiler. Sönümlü trend modelleri hem toplamsal hem de çarpımsal eğilimleri yavaşlatır. Serinin seviyesi değişmiyorsa, mevsimselliğin genliği her iki durumda da sabit olacağından, toplamsal ve çarpımsal mevsimselliği ayırt etmek pratik olarak imkansızdır.



Şekil 2. Çarpımsal hata ETS modellerine karşılık gelen zaman serileri(Svetunkov, 2022)

Şekil 2'deki grafikler, toplamsal durumla benzer sonuçları göstermektedir. Bununla birlikte, ana fark, veri seviyesinin artmasıyla hatanın varyansının artmasıdır. Bu özelliğe istatistikte değişen varyans denir ve Hyndman ve ark. (2008), çarpımsal hata modellerinin temel faydasının bu özelliği yakalamak olduğunu iddia etmektedir. ETS modelleri farklı bileşenler ile aşağıdaki gibi yazılabilir (L_t = veri

seviyesi, ϵ_t =hata terimi, α =yumuşatma parametresi, β =Trend bileşeni için yumuşatma parametresi, ϕ =Sönümlenme parametresi, γ =Mevsimsellik yumuşatma parametresi) (Svetunkov, 2022). ETS modellerinin bazıları Holt yönteminin temelidir (Holt, 2004).

ETS(A,N,N): ARIMA(0,1,1) yöntemine denk gelmektedir. Trend ve mevsimselliğin olmadığı hata teriminin toplamsal yöntemle elde edildiği yöntemdir.

$$Y_t = Y_{t-1} + \epsilon_t \quad Y_{t+1} = Y_t + \alpha * \epsilon_t \quad Y_t = I_{t-1} + \epsilon_t \quad L_t = I_{t-1} + \alpha * \epsilon_t$$

ETS(M,N,N): Trend ve mevsimselliğin olmadığı hata teriminin çarpımsal yöntemle elde edildiği yöntemdir. ETS(A,N,N) yöntemine çok benzerdir, seviye değişikliği ile hata teriminin değişen varyansını göstermektedir.

$$Y_t = I_{t-1} * (\epsilon_t + 1) \quad L_t = I_{t-1} * (1 + \epsilon_t * \alpha) \quad Y_{t+1} = Y_t + \hat{a} * (y_t - \hat{y}_t)$$

ETS(A,A,N): Holt's yönteminin temelini oluşturur, ARIMA(0,2,2) modeline denk gelir. Mevsimselliğin olmadığı, trendin ve hata teriminin toplamsal olarak ele alındığı bir yöntemdir. α ve β değerleri bu modelde eğilim deterministik değildir: hem kesme hem de eğim zamanla değişir. Düzgünleştirme parametreleri ne kadar yüksekse, seviye ve eğim o kadar belirsiz olacaktır; bu nedenle, gelecekteki değerlerle ilgili belirsizlik o kadar yüksek olur.

$$Y_t = I_{t-1} + \epsilon_t + b_t \quad L_t = I_{t-1} + b_{t-1} + \alpha * \epsilon_t \quad b_t = b_{t-1} + \beta * \epsilon_t$$

ETS(A,A_d,N): Sönümlü trend yöntemi olarak da bilinir. ARIMA(1,1,2) modeline denk gelir. ϕ tipik olarak 0 ile 1 arasında yer alan sönümlenme parametresidir. Sıfıra eşitse, model ETS(A,N,N) e düşer. Bire eşitse, ETS(A,A,N)'ye eşdeğer olur. Sönümlenme parametresi, trendi yavaşlatarak doğrusal olmayan hale getirir.

$$Y_t = I_{t-1} + \epsilon_t + b_{t-1} * \phi \quad L_t = I_{t-1} + b_{t-1} * \phi + \alpha * \epsilon_t \quad b_t = b_{t-1} * \phi + \beta * \epsilon_t$$

ETS(A,A,M): Toplamsal hata ve eğilime sahip ancak çarpımsal mevsimselliğe sahip bir modeldir. Holt-Winters method olarak da karşımıza çıkar.

$$Y_t = (I_{t-1} + b_{t-1}) * S_{t-m} + \epsilon_t \quad L_t = (I_{t-1} + b_{t-1}) + \alpha * (\epsilon_t / S_{t-m})$$

$$b_t = b_{t-1} + \beta * (\epsilon_t / S_{t-m}) \quad S_t = S_{t-m} + \gamma * (\epsilon_t / (I_{t-1} + b_{t-1}))$$

ETS(M, A_d,N): Çarpımsal hata ,sönümlü toplamsal trende ve mevsimselliğe sahip olmayan modeller için kullanılır.

$$y_t = (I_{t-1} + \phi * b_{t-1}) * S_{t-m} * (1 + \epsilon_t) \quad I_t = (I_{t-1} + \phi * b_{t-1})(1 + \alpha * \epsilon_t)$$

$$b_t = \phi * b_{t-1} + \beta * (I_{t-1} + \phi * b_{t-1}) * \epsilon_t \quad S_t = S_{t-m} * (1 + \gamma * \epsilon_t)$$

ETS(M,N,M): ARIMA (0,1,0)×(1,1,1)₁₂ modeline denk gelir. Çarpımsal hata ve mevsimselliğe sahip, trendi olmayan modeller için kullanılır.

$$y_t = I_t * S_{t-m} * (1 + \epsilon_t) \quad I_t = I_{t-1} * (1 + \alpha * \epsilon_t) \quad S_t = S_{t-m} * (1 + \gamma * \epsilon_t)$$

ETS modellerinin istatistiklerinde istenilen sonuç, en küçük değere sahip hata kareler ortalaması (MSE), ortalama hata (ME), hata kareler ortalamasının karakökü (RMSE), hatanın mutlak ortalaması (MAE), ortalama yüzde hata (MPE) ve ortalama mutlak yüzde hata (MAPE) istatistiklerine sahip tahmin modelini oluşturmaktır. Ancak hangi istatistiğin kullanılması gerektiği konusunda belirli bazı kriterler takip edilmektedir.

Hata değerlerinin büyüklükleri benzer ise MSE kullanılabilir. Ancak, tahmin edilen değerlerden bir ya da birden fazla ortalamasının üzerinde büyük hata(lar) elde edilmiş ise, bu ölçüm fazla uygun olmayabilir. MSE istatistiği, hataların karelerini aldığı için büyük sapmaların olması durumunda abartılı sonuçlar vermektedir. Bu istatistiğin yerine bu durumda, MAE kullanılabilir. Bazen bir tahmin yönteminin yansız olup olmadığının belirlenmesi gerekebilir. Modelden hesaplanan değerler, gerçekleşen değerlerin altında veya üstünde çıkıyorsa yansızlık gerçekleşmez. Bu gibi durumlarda MPE kullanılmaktadır. Hata değerlerinin birim değerleri farklılık gösteriyorsa, örneğin bir tahmin


modeli gerçek değerleri kullanıyor iken bir başka tahmin modeli doğal logaritması alınmış değerleri kullanıyorsa, yararlanılabilecek istatistik MAPE'dir.

MAPE istatistiği, farklı birim değerlere sahip modellerin karşılaştırılmasında ortaya çıkabilecek dezavantajları elimine etmektedir. Sayılan kriterler arasında (MAPE)'nin öngörü hatalarını yüzde olarak ifade etmesi nedeni ile tek başına da bir anlamının olması, diğer kriterlere göre üstünlüğü olarak kabul edilmektedir. MAPE %10 un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, %10-%20 arasında olan değerleri ise doğru tahminler olarak sınıflandırmıştır ($MAPE = \frac{100}{n} \sum_j \frac{|e_j|}{|A_j|}$).


Matematiğin bir dalı olan bilgi teorisinde bilginin niceleştirilmesi yapılmaktadır. Akaike bilgi kriteri (AIC) belirli bir veri seti için ETS modellerinin göreceli kalitesini ölçmek için bu modellerin her birinin göreceli kalitesini tahmin eder. Dolayısıyla, AIC model seçimi için istatistiksel bir yol sağlamaktadır. AIC, $(-2\log(L)+2k)$ ile hesaplanmaktadır (L=modelin olabilirlik fonksiyonunun maksimum değeri, k=modeldeki tahmin edilen parametre sayısı).

3. BULGULAR


Zaman serisi verilerinde ilk olarak zamana bağlı bağımsız değişkenlerimizin zaman serisi grafikleri çizilmiştir (Şekil 3-7). Bu grafiklerde mevsimsellik yapısı elde edilmemiştir. Sadece satış verisinde mevsimsellik kendini göstermiştir. Trend olarak incelendiğinde özellikle TGE verisinde belirgin bir trend görülmemiştir. Ancak belli bir noktada kırılma olmuş seri o şekilde devam etmiştir. Bununla birlikte diğer değişkenlerde trend'in net etkisini görmek için Hyndman'ın önermiş olduğu ETS yöntemi verilere uygulanmıştır.




Şekil 3. TGE için zaman serisi




Şekil 4. ÜFE için zaman serisi



Şekil 5. TÜFE için zaman serisi



Şekil 6. Dolar için zaman serisi



Şekil 7. Satış için zaman serisi

Elde edilen ETS algoritmaları Tablo 1’de verilmiştir. Bu ETS algoritmaların seçiminde en düşük AIC’ne sahip olan model seçilmiştir. Ayrıca hata, trend ve mevsimselliği dikkate alan ETS modellerinde en iyi performansı yakalamak için ortalama mutlak yüzde hata (MAPE) değerinden yararlanılmıştır. TGE için ETS (A, N, N) ve TÜFE, ÜFE ve dolar için de ETS(M, A_d, N) modelleri kurulmuştur.

Tablo 1. Talep tahmini değişkenlerinin ETS modelleri

Model	AIC	Zaman	Tahmin	L095	Li95	MAPE
TGE ETS(A,N,N)	848.7970	Mayıs 22	67.80914	62.50074	73.11754	2.409225
		Haz. 22	67.80914	60.67924	74.93904	
		Tem. 22	67.80914	59.23640	76.38187	
		Ağust. 22	67.80914	58.00362	77.61466	
		Eyl. 22	67.80914	56.90939	78.70889	
		Ek. 22	67.80914	55.91540	79.70287	
TÜFE ETS(M,A _d ,N)	1708.594	Nisan 22	879.7774	859.0625	900.4923	0.7721426
		Mayıs 22	910.5938	868.8605	952.3271	
		Haz. 22	936.8720	871.8369	1001.9071	
		Tem. 22	959.2803	869.4910	1049.0695	
		Ağust. 22	978.3886	862.9687	1093.8085	
		Eyl. 22	994.6829	853.1555	1136.2104	
ÜFE ETS(M,A _d ,N)	1583.124	Nisan 22	1418.110	1373.011	1463.209	1.022645
		Mayıs 22	1501.287	1404.590	1597.985	
		Haz. 22	1573.194	1417.277	1729.111	
		Tem. 22	1635.357	1414.948	1855.766	
		Ağust. 22	1689.097	1400.498	1977.696	
		Eyl. 22	1735.555	1376.186	2094.925	
Dolar ETS(M,A _d ,N)	159.8746	Mayıs 22	14.84094	13.634651	16.04724	2.789133
		Haz. 22	14.96794	12.588116	17.34777	
		Tem. 22	15.07046	11.439295	18.70163	
		Ağust. 22	15.15323	10.239782	20.06667	
		Eyl. 22	15.22004	9.021715	21.41836	
		Ek. 22	15.27397	7.804641	22.74329	

TGE için hatanın toplamsal olduğu, trend ve mevsimselliğin olmadığı ETS (A, N, N) modeli en uygun model olarak belirlenmiştir. Bu model, ARIMA(0,1,1) yöntemine denk gelen modeldir. MAPE değeri %10 un altında kaldığı için yüksek doğruluk değerine sahip bir model olduğu görülmektedir. TGE için ETS modeli tek nokta tahmini vermiştir. 6 aylık satış tahminlerinin ortalamasının 67.80

değerinde olacağı %2.4 ortalama mutlak hata değeriyle tespit edilmiştir. Ek olarak %95 güven aralığında haziran 2022 için TGE değeri 60.60 ile 74.93 değerleri arasında olacağı öngörülmüştür. Bununla birlikte TGE için tek nokta tahmini yapıldığından dolayı aylar arasındaki değişimi yorumlamak için %95 güven aralığında alınan değerler incelenmiştir. Buna göre mayıs'dan başlayarak ekim ayında biten çıkarımlar için tahmin aralığının açıldığı ve bir güvensizlik ortamının oluştuğu tespit edilmiştir.

TÜFE, ÜFE ve Dolar için hatanın çarpımsal, trendin sönümlü toplamsal ve mevsimselliğin olmadığı ETS(M,A_d,N) modeli en uygun model olarak belirlenmiştir. Trendin sönümlü olması, trendin yavaşlaması anlamına gelmektedir. Verilerde güçlü ve tutarlı bir trend varsa, ϕ 'nin 1'e yakın bir değere yaklaşacağı ve tahminlerin Holt'unkiyle neredeyse aynı olacağı düşünülmektedir. Verilerdeki trend düzensizse, sönümlü bir tahmin işlevi oluşturmak için ϕ 'nin 1'den küçük bir değere yakınsaması gerekmektedir.(Taylor, 2003, McKenzie ve Gardner Jr., 2010) MAPE değerleri belirtilen 3 değişken içinde %10 un altında kaldığı için yüksek doğruluk değerine sahip bir model olduğu da tespit edilmiştir.

TÜFE ve ÜFE için çalışma yapıldığında Nisan verisi henüz açıklanmadığı için Nisan 2022 den başlayarak 6 aylık tahmin verisi oluşturulmuştur. TÜFE ve ÜFE'nin sırasıyla 6 aylık tahmin değerleri incelendiğinde; TÜFE'nin %0.77 MAPE ile Nisan 2022 de 879.77 değerinde ve de ÜFE'nin %1.02 MAPE ile Nisan 2022 de 1418.11 değerinde olacağı öngörülmüştür. Nisan'dan başlayarak Eylül'de biten tahminler için her ay TÜFE ve ÜFE değerlerinde artış öngörülmektedir.

Dolar'ın 6 aylık tahmin değerleri incelendiğinde; %2.78 MAPE ile Haziran 2022 de 14.96 değerinde olacağı tespit edilmiştir. Ayrıca mayıs'dan başlayarak ekim ayında biten çıkarımlar için tahmin değerlerinde de aylara göre artan bir durum öngörülmektedir.

Ekonomik olarak belirsizliğin enflasyonu arttırdığı bunun da TGE, TÜFE, ÜFE değerlerinde artışa sebep olduğu yorumu yapılabilir. Dolar da aylara göre artış göstermeye devam edeceği öngörülmektedir. Sönümleyici trendin olması artan trendin yavaşlayarak arttığını göstermekle beraber gerçekleşen değerler ile tahmin değerleri arasındaki farklılığın azaldığını da göstermektedir.

Satış verisi için hatanın çarpımsal, trendin olmadığı ve mevsimselliğin çarpımsal olarak hesaplandığı ETS(M,N,M) modeli en uygun model olarak seçilmiştir. MAPE değeri %16.9 değeriyle %10-%20 değerleri arasında kaldığı için doğru tahminlenen model olarak öngörülmektedir. Buna göre %16.9 MAPE ile Mayıs 2022 de satış'ın 30.567 değerinde olacağı bulunmuştur. Ancak satış verisinin diğer veri tiplerinden farklı olduğu belirlenmiştir (Tablo 2).

Tablo 2. Satış tahmini değişkeninin ETS modeli

Model	AIC	Zaman	Tahmin	L095	Li95	MAPE
Satış ETS(M,N,M)	1319.131	Mayıs 22	30567.69	17299.198	43836.18	16.90557
		Haz. 22	18030.13	9999.984	26060.28	
		Tem. 22	18002.76	9785.846	26219.68	
		Ağust. 22	19200.29	10229.112	28171.47	
		Eyl. 22	19946.43	10415.240	29477.62	
		Ek. 22	22655.86	11594.539	33717.18	

Satış verisinin mayıs ayından sonra düşüşe geçtiği ağustos ayından sonra tekrar artış gösterdiği belirlenmiştir. Seçilen ETS yönteminde de mevsimselliğin olduğunu tespit edilmiştir. Buna göre yaz aylarına girişle birlikte satışların düştüğü güz ayına girerken satışların tekrar arttığı yorumu yapılabilmektedir. Daha önceki veriler de incelendiğinde bu sonucu destekler nitelikte olduğu da görülmektedir .

4. TARTIŞMA

Literatürde farklı alanlarda çeşitli talep tahminleme yöntemleri kullanılmaktadır. Talep tahmininde bu farklı alanların yanında birçok değişkende ele alınmaktadır. Satış sektöründe TÜFE, ÜFE, TGE, döviz kuru gibi bazı belli başlı ortak değişkenler bulunmaktadır. Bu değişkenlerinin tahminin yapıldığı yapay sinir ağları, karar ağaçları gibi makine yöntemleri ile ETS, ARIMA gibi zaman serisi yöntemleri de çalışılmaktadır.

Asilkan (2009), ikinci el otomobil piyasasının gelecekte olabilecek fiyatlarını tahmin etmek için yapay sinir ağları ve zaman serileri yöntemlerini kullanmıştır. Performans ölçütleri karşılaştırıldığında yapay sinir ağları yönteminin daha iyi tahminlerde bulunduğunu tespit etmiştir. Zaman serileri yönteminde Box-Jenkins(ARIMA) yöntemi kullanılmış olup, veri seti 36 adet veriden oluştuğu ve Box- Jenkins(ARIMA) yönteminin iyi sonuç vermesi için en az 50 adet veriye ihtiyaç duyulduğundan dolayı yapay sinir ağları tahmin sonuçlarının zaman serisi yöntemine göre iyi sonuç verdiğini ifade etmiştir. Bu çalışmada ise değişkenlerin örneklem hacmi değişiktir. Sırasıyla satış verileri için 64, ÜFE için 195, TÜFE için 231, TEG için 198 ve dolar için 160 adet veri bulunmaktadır. Verilerin sayıları önceki çalışmada önerilen 50 sayısını aştığından elde edilen bu çalışmadaki sonuçların zaman serisi yöntemlerinde daha tutarlı olacağını desteklemektedir (Asilkan, 2009).

Uğurlu ve Saraçoğlu (2010), 2003-2008 yılları arasında TÜFE verilerini kullanarak 2008 yılının kalan ayları için TÜFE değerlerini zaman serisi analizleri kullanılarak belirlenmiştir. ARIMA modelinin en iyi tahminlerde bulunduğu tespit edilmiştir. Kullanılan zaman serisi yöntemlerinde mevsimselliğin TÜFE verisi için olmadığı tespit edilmiştir. Bununla birlikte bu çalışmada da TÜFE veri seti içinde mevsimselliğin olmadığı ve model doğruluk değerinin yüksek olarak bulunmuştur (Uğurlu ve Saraçoğlu, 2010).

Yapılan bu çalışmaya ait MAPE değerleri incelendiğinde ÜFE, TÜFE, TGE ve dolar veri setleri %10'un altında değerler olarak seçilen modellerin yüksek doğruluk değerine sahip olduğunu göstermektedir. Satış verisinin MAPE değeri %10-%20 değerleri arasında yer alarak doğru tahminlenen bir model olarak kabul edildiğini düşünülmektedir. Satış verisine ait MAPE değerinin diğer değişkenlere göre daha yüksek bir değer almasının sebebinin veri setinin diğerlerine göre daha az veri içermesi gösterilebilir.

Karahan (2011), gıda sektöründe yaptıkları talep tahmininde regresyon-korelasyon analizini, zaman serisi yöntemlerini (ARIMA) ve yapay sinir ağları yöntemini kullanmıştır. Bu çalışmaya göre en iyi tahminin MAPE değerine göre yapay sinir ağları olduğuna karar vermiştir. Ancak yapay sinir ağlarında trend ve mevsimsellik gibi bileşenlerin model içindeki durumunu açıklamamıştır. Bu çalışmada ise model kurmak için gerekli olan tahminlerin trend ve mevsimselliği dikkate alınarak yapılması dikkat çekici olarak belirtilmiştir (Karahan, 2011).

Karaatlı ve ark. (2012), otomobil satış tahmini için yaptıkları çalışmada 2007-2011 yılları arasında TGE ve dolar gibi birçok değişkeni ele almışlardır. Yapay sinir ağları yöntemi ile yapacakları veri tahmini için zaman serisi yöntemlerinde kullanılabileceğini vurgulamışlardır. Özellikle çalışmada farklı zaman serisi yöntemlerinin daha iyi sonuç vereceğini ifade etmişlerdir. Bu çalışmada da hata, trend ve mevsimselliği dikkate alan ETS'nin kullanılması ile talep tahmini için kullanılacak olan değişkenlerinin tahmin değerleri iyi bir performans (düşük MAPE) ile elde edilmiştir (Karaatlı ve ark., 2012).

Üretim dışında farklı alanlarda da olsa talep tahmininde mevsimselliğin önemli olduğu ve dikkate alınması gerektiği bir çok çalışmada vurgulanmaktadır. Sabır & Batuk (2013), tekstil sektöründe talep tahmini ile ilgili yaptıkları çalışmada talebin mevsimsel olarak değiştiğini ve basit üssel düzeltme yönteminin en iyi model olduğunu bulmuşlardır. Bu çalışmada da diğer değişkenler için olmasa da buzdolabı satışında mevsimselliğin olduğu ve tahminin ETS ile yapılmasının daha doğru olacağı vurgulanmıştır.

Arslankaya (2019), lojistik sektöründe tekstil grubuna ait talep miktarı tahmini için yaptıkları çalışmada basit ortalama, hareketli ortalama ve trend analizi gibi zaman serisi yöntemlerinin

performansının MAPE gibi değerler dikkate alındığında yapay sinir ağlarına göre daha düşük olduğunu göstermiştir. Bu çalışmada da tahminlemelerde zaman serisi yöntemlerinden AR, MA, ARIMA gibi birçok yöntemi içinde bulunduran ETS yöntemi kullanılmıştır (Arslankaya, 2019).

Son yıllarda ETS modellerinin kullanım alanı genişlemiştir. Özellikle ekonomik araçlardan biri olan döviz kuru tahmininde ETS modeli sıklıkla kullanılmaktadır ve çok iyi sonuçlar vermektedir (Bağcı, 2020). Buzdolabı satış talebi için kullanılacak olan değişkenlerden biri olan dolar tahminlemesinde de ETS yöntemi kullanılmış ve MAPE değerine göre de iyi sonuçlar versiyi tespit edilmiştir.

5. SONUÇ ve ÖNERİLER

İşletmelerin üretim planlamasında doğru talep tahminlerinin yapılması oldukça önemli bir durumdur. Müşterilerin gelecekteki talep tahmin eğilimleri, piyasanın durumu ve mevsimsellik gibi faktörlerden etkilenebilir. Bu yüzden işletmelerdeki üretim planlaması işletmelerin hedefleri doğrultusunda üretim politikaları, üretim programları ve üretimle ilgili süreçlerin planlanması şeklinde devam eder. Doğru talep tahmini işletmelerin kaynaklarını daha verimli kullanması bakımından oldukça önemli bir kriter olarak günümüzde kendini göstermektedir. Özellikle son yıllarda yaşanan ekonomik zorluklar üretim planlamasının ne kadar önemli ve gerekli olduğunu göstermiştir. Talep tahmini için günümüzde işletmeler artık sayısal yöntemleri kullanmaya başlamıştır. Bu yöntemlerin başında makine öğrenim analizleri bulunmaktadır. Özellikle üretim planlamasında yer alan talep tahmininde makine öğrenimin içinde yer alan denetimli algoritmalarından yapay sinir ağları, karar ağaçları, sınıflandırma yöntemleri ile verinin zaman bileşenlerini içerdiği durumdaki ARIMA ve ETS algoritmaları sıklıkla kullanılmaktadır.

Bu çalışma kapsamında soğutucu buzdolabı talep (satış) tahmininde kurulacak olan modelin değişkenlerine literatür taraması yapılarak karar verilmiştir. Bu değişkenler döviz kuru (dolar), tüketici güvend endeksi (TGE), tüketici fiyat endeksi (TÜFE) ve üretici fiyat endeksi (ÜFE) olarak belirlenmiştir. Literatürde son yıllarda kullanılan yapay sinir ağları yöntemi ile talep tahmini yapılmaktadır. Ancak yapay sinir ağları için seçilen değişkenlerin tahminleri için zaman serileri yöntemleri sıklıkla kullanılmakla beraber performans olarak da yüksek oran vermektedir. Bu yüzden bu çalışmada talep değişkeninde kurulacak olan modeldeki diğer değişkenlerin tahmini için üssel düzeltme yöntemi (ETS) kullanılarak hata, trend ve mevsimsellik gibi üç farklı öge dikkate alınıp tahminleme yapılmıştır. ETS modelleri içinde en iyi performansı yakalamak için ortalama mutlak yüzde hata (MAPE) değerinden yararlanılmıştır. Bu çalışma için veriler akan veri olduğundan elde edilen ETS modeline giren her bir zaman (ay) değişkeni ile model kendini yenilemekte ve geliştirmektedir. Eldeki veriler ile kurulan ETS modelleri TGE için ETS (A, N, N) ve TÜFE, ÜFE ve dolar için ETS(M, A_d, N) şeklindedir. Tüm bu değişkenlerde mevsimsellik söz konusu değildir. Ayrıca TGE’de trend yok iken diğer değişkenlerde ise trendin zamanla etkisi azalmaktadır. Ancak akan veri ile veri havuzu genişlediğinden farklı ETS modeli kurulabilir. Bu yöntemin en büyük avantajlarından birisi de akan verinin de kolaylıkla dikkate alınarak yeni modellemelere izin vermesidir.

Bu çalışma devamında elde edilen yeni verilerle soğutucu buzdolabı talebinde yapay sinir ağları kullanılarak model kurulması planlanmaktadır. Yapay sinir ağları için girdi değişkenlerinin belirlenmesi ve bu değişkenlerin ETS yöntemi ile belli bir süre tahminlerinin yapılarak ağa sokulması ve çıktı değişkenine döndürülmesi sağlanacaktır.

KAYNAKLAR

Arslankaya, S. (2019). Bir Lojistik Firmasında Zaman Serileri Analizi ve Yapay Sinir Ağları İle Talep Tahminin Karşılaştırılması. 4th International Symposium on Innovative Approaches in Engineering and Natural Sciences, ISAS WINTER-2019, Samsun, Turkey, Conference Proceedings, 4(6): 239-245.

- Asilkan, Ö., Irmak, S. (2009). İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(2): 375-391.
- Bağcı, B. (2020). Hareketli Ortalamalar ve Üssel Düzeltme Yöntemlerinin Tahmin Gücünün Artırılması: Türkiye’de Döviz Kuru Tahmini. Turkuaz Uluslararası Sosyo-Ekonomik Stratejik Araştırmalar Dergisi, 2(2):1-12.
- Gardner, E.S. (1985). Exponential Smoothing: The State of the Art. Journal of Forecasting. 4: 1–28. <https://doi.org/10.1002/for.3980040103>
- Gardner, E.S., McKenzie, E. (1989). Seasonal Exponential Smoothing with Damped Trends. Management Science. 35: 372–376. <https://doi.org/10.1287/mnsc.35.3.372>
- Gardner, E.S. (2006). Exponential Smoothing: The State of the Art-Part II. International Journal of Forecasting. 22: 637–666. <https://doi.org/10.1016/j.ijforecast.2006.03.005>
- Holt, C.C., 2004. Forecasting Seasonals and Trends by Exponentially Weighted Moving Averages. International Journal of Forecasting, 20:5-10. <https://doi.org/10.1016/j.ijforecast.2003.09.015>
- Hyndman, R.J., Koehler, A.B., Snyder, R.D. & Grose, S. (2002). A State Space Framework for Automatic Forecasting Using Exponential Smoothing Methods. International Journal of Forecasting. 18(3): 439–454. [https://doi.org/10.1016/S0169-2070\(01\)00110-8](https://doi.org/10.1016/S0169-2070(01)00110-8)
- Hyndman, R. J., Koehler, A. B., Ord, J. K., & Snyder, R. D. (2008). Forecasting with Exponential Smoothing: The State Space Approach. Berlin: Springer-Verlag.
- Karaatlı, M, Helvacıoğlu, Ö. C. Ömürbek, N. & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. Uluslararası Yönetim İktisat ve İşletme Dergisi, 8(17): 87-100.
- Karahan, M. (2011). İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmin Uygulaması. TC Selçuk Ün. Sosyal Bilimler Enstitüsü İşletme ABD Yayınlanmamış Doktora Tezi, Konya, Türkiye.
- McKenzie, E., Gardner, E.S. (2010). The Damped Trend: A Modeling Viewpoint. International Journal of Forecasting.
- Pegels, C.C. (1969). Exponential Forecasting: Some New Variations. Management Science. 15(5): 311–315. <https://www.jstor.org/stable/2628137>.
- Sabır, C., Batuk, E. (2013). Demand Forecasting with of Using Time Series Models in Textile Dyeing-Finishing Mills. Tekstil ve Konfeksiyon, 23(2):143-151.
- Svetunkov, I. (2022). Forecasting and Analytics with ADAM. [https://openforecast.org/adam/Svetunkov%20\(2022\)%20-%20ADAM.pdf](https://openforecast.org/adam/Svetunkov%20(2022)%20-%20ADAM.pdf)
- Svetunkov, I. (2022) Statistics for Business Analytics. <https://openforecast.org/sba/>
- Taylor, J.W. (2003). Exponential Smoothing with a Damped Multiplicative Trend. International Journal of Forecasting. 19: 715–725. [https://doi.org/10.1016/S0169-2070\(03\)00003-7](https://doi.org/10.1016/S0169-2070(03)00003-7)
- TC Merkez Bankası. (2022). <https://www.tcmb.gov.tr>
- Uğurlu, E. & Saraçoğlu, B. (2010). Türkiye’de Enflasyon Hedeflemesi ve Enflasyonun Öngörüsü. Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 25(2): 57-72.
- Wikipedia, Üretici fiyat endeksi, Wikipedia, (version: 2021-12-07). URL https://tr.wikipedia.org/wiki/%C3%9Cretici_fiyat_endeksi
- Wikipedia, Tüketici fiyat endeksi, Wikipedia, (version: 2021-07-01). URL https://tr.wikipedia.org/wiki/T%C3%BCketici_fiyat_endeksi
- Wikipedia, Tüketici Güven Endeksi, Wikipedia, (version: 2022-04-29). URL https://tr.wikipedia.org/wiki/T%C3%BCketici_G%C3%BCven_Endeksi