



BIST30 HİSSE SENETLERİ ÜZERİNE BİR UYGULAMA: ETS, MLP, BATS VE TBATS YÖNTEMLERİ İLE ÖNGÖRÜDE BULUNMA

AN APPLICATION ON BIST30 STOCKS: FORECASTING WITH ETS, MLP, BATS AND TBATS METHODS

 Cebeli İNAN¹

¹ **Sorumlu Yazar:** Dr. Öğr. Gör., Bingöl Üniversitesi, Sosyal Bilimler MYO, Finans Bankacılık ve Sigortacılık Bölümü, Maliye Programı, cinan@bingol.edu.tr

Received / Alınma: 15.08.2024

Accepted / Kabul: 27.10.2024

ÖZET

Ekonomide geleceği tahmin etmek ve öngöründe bulunmak, ekonomistlerin ve politika yapımcıların önemli amaçlarından biridir. Bunun için yapılan ekonometrik modellemelerde, istatistiksel ve matematiksel yöntemleri kullanarak ekonomik ilişkileri tanımlamaya ve gelecekteki ekonomik değişkenleri tahmin etmeye çalışılır. Bundan dolayı bu modeller genellikle geçmiş verilerin analizine dayanır yani geçmiş fiyat hareketlerini ve hacim verilerini inceleyerek gelecekteki trendleri ve fiyat hareketlerini tahmin etmeyi amaçlar. Günümüzde teknolojinin hızlı bir şekilde ilerlemesi, büyük verileri işleyebilecek paket programlarının gelişmesi ve yapay zekanın yardımı ile öngöründe bulunmak daha kolaylaşmış ve bunun sonucunda yapılan tahminlerin hata oranları azalmıştır. Bu çalışmada, BIST30 hisse senetlerinden bazı bankaların kapanış değerlerinin ETS, MLP, BATS ve TBATS modelleri kullanılarak zaman serisi analizleri yapılmış ve 24 aylık öngörülerini hesaplanmıştır. Bu modellerin tahmin doğruluklarını karşılaştırmak için çeşitli performans ölçüt kriterleri uygulanmıştır. Bu performans ölçüt kriterlerine göre en düşük hata değerini veren model diğer modellere göre daha başarılı olduğu sonucuna varılmıştır.

Anahtar Kelimeler: ETS, BATS, TBATS, MLP, Zaman Serileri.

ABSTRACT

Forecasting future economic conditions is a primary objective for economists and policymakers. Econometric modeling uses statistical and mathematical methods to define economic relationships and forecast future economic variables. These models generally rely on historical data analysis, aiming to predict future trends and price movements by examining past price changes and volume data. Today, with the rapid advancement of technology, the development of software capable of processing big data, and the assistance of artificial intelligence, forecasting has become more efficient, resulting in reduced error rates in predictions. This study performs time series analyses on the closing values of selected banks from the BIST30 index using ETS, MLP, BATS, and TBATS models, calculating 24-month forecasts. Various performance criteria were applied to assess the predictive accuracy of these models. Based on these criteria, the model with the lowest error value was determined to be more successful than the others.

Keywords: ETS, BATS, TBATS, MLP, Time Series.

1. GİRİŞ

Zaman serileri analizi, gelecekteki trendleri ve desenleri tahmin etmek, veri setlerindeki anlamlı değişiklikleri belirlemek ve kararlar almak için kullanılan güçlü bir yöntemdir. Gerçek hayattaki zaman serisi verileri genellikle periyodiklik sergiler ve bu periyodiklik, gelecek hakkında öngörüle bulunmak için önemli ipuçları sunar. Özellikle finans piyasalarında belirsizlik seviyesi yüksek olduğundan, hisse senedi fiyat endekslerini öngörmek için tek bir model kullanmak zor olabilir (Du, 2018). Gelişen teknoloji ve büyük veri analizi araçları, borsa verilerindeki dalgalanmaları daha etkin bir şekilde modellemeyi mümkün kılarak kısa ve uzun vadeli tahminlerde önemli bir rol oynamaktadır. Ancak, karmaşık mevsimsel örüntülerin geleneksel yöntemlerle tahmin edilmesi zor olduğundan, ETS, MLP, BATS ve TBATS gibi gelişmiş modeller, bu tür karmaşık zaman serilerini analiz etmek için giderek daha çok tercih edilmektedir.

Bu modeller, zaman serisi verilerindeki trendleri, mevsimsel desenleri ve diğer bileşenleri daha etkin bir şekilde modellemeye yardımcı olur ve borsa verilerinde yatırımcılar için kritik öngörüler sağlar. Örneğin, BATS modeli, zaman serilerinde doğrusal olmayan çoklu mevsimsellik ve değişken örüntüleri olan verilerde etkili bir performans gösterir (De Livera, Hyndman & Snyder, 2011). BATS modelinin gelişmiş bir versiyonu olan TBATS ise birden fazla mevsimsel ve trend bileşeni içeren veri setleri için uyarlanmıştır ve özellikle büyük veri setlerinde yüksek doğruluk sunar (Hyndman & Athanasopoulos, 2018). MLP modeli, karmaşık ve doğrusal olmayan ilişkilerin bulunduğu zaman serilerini öngörmeye güçlü bir yapay sinir ağı olarak öne çıkar ve borsa verilerindeki kısa vadeli fiyat hareketlerini tahmin etmede faydalıdır (Goodfellow, Bengio & Courville, 2016). Ayrıca, ETS modeli, hata, trend ve mevsimsellik bileşenlerini ayrı ayrı değerlendirerek özellikle düzenli yapıya sahip verilerin analizinde yüksek performans sunar (Hyndman & Khandakar, 2008).

Bu modeller, finansal piyasalarda veri analizinin doğruluğunu artırmak ve borsa verilerindeki trendleri daha iyi anlamak için sıklıkla tercih edilmektedir. Bu sayede, gelecekteki fiyat hareketlerini öngörme açısından önemli bilgiler sunarak yatırımcıların karar alma süreçlerini destekler.

2. LİTERATÜR

Indro ve diğerleri, (1999) çalışmalarında bir fonun faaliyet özelliklerini ve geçmiş performansını belirlemek için 1993±1995 dönemine ait Morningstar Yatırım Fonları Veri Tabanı kullanılmıştır. Burada değer, karma ve büyüme yatırım tarzlarını takip eden hisse senedi yatırım fonlarının performansını tahmin etmek için yapay sinir ağı (YSA) yaklaşımı kullanmışlardır. Çok katmanlı perceptron modeli (MLP) ve GRG2 doğrusal olmayan optimize edici kullanılarak, yatırım fonlarının riske göre ayarlanmış getirisini tahmin etmek için fona özgü tarihsel faaliyet özellikleri kullanmışlardır. Büyüme fonlarının performansını tahmin etmede sinir ağları aracılığıyla sezgisel bir değişken seçimi yaklaşımı kullanılmış ve bunu doğrusal regresyonun aşamalı seçim yöntemiyle karşılaştırmışlardır. Sonuç olarak ANN'nin tüm tarzlardaki fonlar için doğrusal modellerden daha iyi tahmin sonuçları ürettiğini göstermişlerdir.

Kalteh, (2008) çalışmasında Kuzey İran'daki bir su havzasında aylık yüzey akışını tahmin etmek için bir yapay sinir ağı modeli olan MLP modelini kullanmıştır. Modelleme mekanizmalarını anlamak için sinirsel yorumlama diyagramı (NID), Garson algoritması ve Rastgeleleştirme yaklaşımı dahil olmak üzere üç yaklaşımı ele alınmıştır.

Naim ve diğerleri, (2018) çalışmalarında Bharat Heavy Electricals Limited (BHEL), Hindistan'ın bir üretim birimi olan Central Foundry Forge Plant (CFFP)'den Döküm ürünlerinin üretimi için

Nisan 2014'ten Ocak 2017'ye kadar doğal gaz tüketim verileri toplanarak aylık bir veri seti karmaşık zaman serilerinin kısa vadeli tahmini için BATS ve TBATS modellerini karşılaştırdıktan sonra MAPE ve RMSE performans ölçüt kriterlerine göre başarılı bir tahmin modeli geliştirmektedir. Analiz sonuçları, TBATS'ın farklı kısa vadeli tahmin ufukları için BATS modelinden daha iyi performans gösterdiği sonucuna varmıştır. Bunun temel nedeni, TBATS modelinde BATS modeline kıyasla daha az sayıda parametrenin tahmin edilmesinin gerekmesidir.

Wiri ve Essi (2018), çalışmalarında 2003-2016 yılları arasında Nijerya'daki enflasyon oranını modellemek için Mevsimsel otoregresif entegre hareketli ortalama (SARIMA) uygulamışlardır. Enflasyon oranınının 12. gecikmedeki mevsimsel farkının zaman grafiği mevsimsel bir seri olduğunu göstermiştir. Nijerya'daki enflasyon oranlarının mevsimsel olmayan farklılaştırması, 12. gecikmede mevsimsel bir bileşen gösteren ACF ve PACF grafikleri ile bir korelogram üretmiştir. Beş model tahmin edilmiştir ve en iyi model Akaike bilgi kriterini (AIC) en aza indiren modeldir (SARIMA (001)*(211)12) ve AIC değeri (3.320166)'dir. Ocak 2017'den Aralık 2017'ye kadar bir yıllık (12 aylık) tahmin, en uygun modele dayandırdıklarını belirtmişlerdir.

Lima ve Laporta (2020) çalışmalarında, Ocak 2000'den Aralık 2017'ye kadar Brezilya'nın 26 eyaletinde ve federal bölgesinde doğrulanmış dang vakalarının görülme sıklığının aylık zaman serisi analizlerini yapmışlardır. Bu yeni dang vakalarının zaman serisini tahmin etmek için 10 istatistiksel modelin (ARIMA, ETS, TBATS, BATS, STLM, StructTS, NNETAR, ELM, MLP ve null model) doğruluğunu değerlendirmek ve onaylamak için istatistiksel ve hesaplamalı bir yaklaşım uygulanmışlar. Deterministik modellerin dang hastalığını tahmin etmek ve salgınların ortaya çıkmasından önce müdahalelerin önceden planlanmasıyla ilgili karar vermek için bu modellerin (ARIMA, TBATS ve ELM) daha etkili olduğunu belirlemişlerdir.

Badr ve diğerleri, (2021) çalışmalarında 01-07-2015 ile 31-12-2016 tarihleri arasında Kaggle yarışması tarafından bir veri tabanından elde edilen veriler üzerinde gerçekleştirilmiştir. Wikipedia'ya gelen ziyaretçi sayısına ilişkin kümülatif veriler kullanılmış ve Facebook, Energy, Android ve Apple olmak üzere dört sayfa seçilmiştir. Farklı web sayfaları için Holt'un Lineer Trend, BATS ve TBATS gibi farklı zaman serisi modelleri kullanılmıştır. Doğruluklarını kıyaslamak için de MAPE, model performans kriterlerini kullanılmışlardır.

Oukhouya ve El Himdi, (2023) çalışmalarında yeni Fas Hisse Senedi Endeksi 20'nin (MSI 20) günlük fiyatlarının modellenmesini ve tahmin edilmesini ele almışlardır. Bu amaçla, çeşitli Makine Öğrenimi (ML) yöntemlerinin uygulanmasından elde edilen sonuçlar arasında karşılaştırmalı bir çalışma yapmışlardır. Destek Vektör Regresyon (SVR), eXtreme Gradient Boosting (XGBoost), Çok Katmanlı Algılayıcı (MLP) ve Uzun Kısa- Dönem Belleği (LSTM) modelleri. Sonuçlar, Izgara Arama (GS) optimizasyon algoritmasını kullanan SVR ve MLP modellerinin diğer modellere göre daha iyi performans gösterdiğini ve günlük fiyat tahminlerinde yüksek doğruluk elde ettiğini gösterdiğini ortaya koymuşlardır.

Tektaş ve Karataş (2004) çalışmalarında, BIST'teki hisse senedi fiyatlarını tahmin etmek için Yapay Sinir Ağları (ANN) kullanmışlardır. Çalışma, performansı analiz etmek için haftalık ve günlük verileri karşılaştırarak yedi şirketin hisse senedi fiyatlarını tahmin etmek için ANN yönteminin kullanmışlardır. Hisse senedi fiyatlarını tahmin etmek için Çoklu Doğrusal Regresyon (MLR) ve ANN gibi farklı modeller kullanarak gelişmiş tahmin doğruluğu potansiyeli göstermeye çalışmışlardır. Araştırmalarında, günlük verilerin dahil edilmesinin, hisse senedi fiyatı tahmini için ANN modellerinin tahmin doğruluğunu artırdığını ve ANN'nin finansal tahminler için alternatif bir yöntem olarak potansiyelini gösterdiğini öne sürmüşlerdir. Finansal

karar vermede doğru tahminlerin önemini vurgulayarak ANN'nin borsa verilerindeki karmaşık ilişkileri yakalamadaki önemini ortaya koyduklarını ifade etmişlerdir.

Akşehir ve Kılıç (2019) çalışmalarında, Yapay Sinir Ağları (ANN), Destek Vektör Makineleri (SVM), Karar Ağaçları (DT), Çoklu Doğrusal Regresyon (MLR) ve Rastgele Orman (RF) gibi çeşitli yöntemler kullanarak BIST'teki bazı banka verilerin analizde Göreceli Güç Endeksi (RSI), Para Akışı Endeksi (MFI), Bollinger Bantları (BB) ve diğerleri gibi farklı teknik göstergeler kullanmışlardır. Çalışma, borsa hareketlerini tahmin etmedeki çeşitli modellerin etkinliğini karşılaştırarak finansal karar verme için doğru tahminlerin önemini vurgulamışlardır.

Arslankaya ve Toprak (2021) çalışmalarında, Polinom Regresyonu, Rastgele Orman Regresyonu, Tekrarlayan Sinir Ağları (RNN) ve Uzun Kısa Süreli Bellek (LSTM) algoritmaları gibi çeşitli makine öğrenimi ve derin öğrenme yöntemlerini kullanarak borsadaki hisse senedi fiyatlarını tahmin etmek için Polinom Regresyonu ve Rastgele Orman Regresyonu gibi makine öğrenimi modelleri kullanmışlar ve Rastgele Orman Regresyonu, Polinom Regresyonuna kıyasla üstün sonuçlar verdiğini ortaya koymuşlardır. LSTM, hem eğitim hem de test veri kümeleri için RNN'den daha düşük hata değerleri göstermiştir.

3. YÖNTEM

İlk olarak değişkenin durağan olup olmadığı Artırılmış Dickey-Fuller testi ile incelenmiştir. İnceleme sonucunda durağan olmayan değişkenlerin birinci dereceden farkları alınmıştır. Daha sonra farkları alınan bu BIST30 hisse senetlerinden olan Yapıkerdi bankası, İş bankası ve Garanti bankasının 1996-2021 yılları arası, Vakıfbank hissesenetlerinin ise 2005-2021 yılları arası kapanış değerlerine ETS, MLP, BATS ve TBATS yöntemleri uygulandı. Bu yöntemler ile 24 aylık öngörüler elde edilmiştir. Bu öngörüler arasından en iyi öngürüyü belirlemek adına da MAE, MAPE, MSE ve RMSE gibi performans ölçüt kriterleri uygulandı. Analizlerin tamamı R-Project yazılımı (R Core Team, 2021) ve bu yazılımda bulunan forecast (Hyndman vd., 2008) ile nnfor (Kourentzes, 2019) paketleri kullanılarak hazırlanmıştır.

Etik Onay: Çalışma konusu etik kurul iznini gerektirmemektedir. Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder.

3.1. ETS (Exponential smoothing) Modeli

Üstel yumuşatma yöntemleri kullanılarak üretilen tahminler, geçmiş gözlemlerin ağırlıklı ortalamalarıdır ve gözlemler eskidikçe ağırlıklar katlanarak azalır. Başka bir deyişle, gözlem ne kadar yeni olursa, ilgili ağırlık o kadar yüksek olur. Üstel Yumuşatma, esnekliği, hesaplama kolaylığı ve iyi performansı nedeniyle en popüler yumuşatma tekniklerinden biridir.

Üstel yumuşatma 1950'lerin sonlarına doğru ortaya çıktı. Holt (1957) ve Winters (1960) önemli öncü isimlerdir. Üstel düzeltme yöntemleri ilk olarak Pegels'in (1969) taksonomisi ile sınıflandırılmıştır. Bu daha sonra Gardner (1985) tarafından genişletilmiş, Hyndman ve diğerleri, (2002) tarafından modifiye edilmiş ve Taylor (2003) tarafından tekrar genişletilerek aşağıdaki tabloda görülen toplam on beş yöntem elde edilmiştir.

Tablo 1. Trend, Mevsimsellik ve Hatayı İçeren Toplamsal ETS Modelleri

Trend kalıpları	Mevsimsel kalıplar		
Toplamsal şekilli ETS çerçevesi	N (Hiçbiri)	A (Toplamsal)	M (Çarpımsal)
N (Hiçbiri)	N, A, N	N, A, A	N, A, M
A (Toplamsal)	A, A, N	A, A, A	A, A, M
A _d (Toplamsal sönümlü)	A _d , A, N	A _d , A, A	A _d , A, M
M (Çarpımsal)	M, A, N	M, A, A	M, A, M
M _d (Çarpımsal sönümlü)	M _d , A, N	M _d , A, A	M _d , A, M

Farklı durum uzayı modellerini ayırt etmek için ETS (Error-Trend-Seasonal veya Üstel Düzeltme) kısaltması kullanılır. Örneğin ETS'nin (M,A,N) anlamı, modelin çarpımsal hataların toplam trendlerinden oluşması ve mevsimselliğin olmamasıdır.

En genel tahmin denklemi üç düzleştirme denklemini içerir- biri l_t düzeyi için, biri trend b_t için ve biri mevsimsel bileşen s_t için ve karşılık gelen sırasıyla düzleştirme parametreleri α, β ve γ dir. Ayrıca e_t bu denklemlerin tahmini sonucu ile gerçek değer arasındaki hata payıdır

Holt (1957), verilerin bir trendle tahmin edilmesini sağlamak için basit üstel düzeltmeyi genişletti. Bu yöntem, bir tahmin denklemi ve iki düzleştirme denklemi içerir (biri seviye için, diğeri trend için):

Tahmin denklemi

$$\hat{y}_{t+h|t} = l_t + hb_t + s_{t+h-m(k+1)}$$

Seviye (Düzye) denklemi

$$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$$

Trend denklemi

$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1}$$

Mevsimsel denklem

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}$$

Hata denklemi


$$e_t = y_t - l_{t-1} = y_t - \hat{y}_{t|t-1}$$

l_t , serinin t zamanındaki seviyesinin bir tahminini gösterirken, b_t , serinin t zamanındaki trendini (eğiminin) ve s_t , t zamanındaki mevsimsel bileşeni m ise bir yıldaki mevsim sayısını; α, β ve γ ($0 \leq \gamma \leq (1 - \alpha)$) yumuşatma parametreleridir. α, β^* ($0 \leq \alpha, \beta^* \leq 1$) trend ve seviye için düzleştirme parametresidir. e_t beyaz gürültü hata terimidir.

3.2. MLP (Multi Layer Perceptron) Modeli

Artificial Neural Network ANN'ler yani yapay sinir ağlar (YSA)'ın yapısı, genellikle katmanların sayısı, her katmanda bulunan düğüm sayısı ve bu düğümlerin nasıl bağlandığı ile karakterize edilir. En yaygın olan ANN çeşidi feed-forward multilayer perceptron (MLP), yani ileri beslemeli çok katmanlı algılayıcıdır. İlk veya giriş katman, harici bilgilerin alındığı bir katmandır. Giriş ve çıkış katmanları arasında en az bir ara veya gizli katman kullanan yapay bir sinir ağı türüdür. Son veya çıkış katman ise ağın aldığı bilgiyi bir çıktıya dönüştüren katmandır (Hargrave vd., 1994). Giriş katman (Input Layer) her bir bağımsız değişkene karşılık gelen çok sayıda nöron içermektedir. Gizli katmanlar (Hidden Layers), değişkenler arasındaki doğrusal olmayan ilişkileri belirlemeyi sağlar. Çıkış katman (Output Layer) da tahminde bulunan sınıflandırmaya ya da öneriye karşılık gelmektedir (Hendricks vd., 1993).

Şekil 1. Multilayer Perception



Kaynak: Çok Katlı Algılayıcı (Deveci, 2012)

MLP'nin mimarisi ağın çıkışının hesaplandığı ileriye doğru hesaplama (feed forward) ve ağırlıkların güncellendiği geriye doğru (back forward) hesaplama olmak üzere iki şekilde çalışmaktadır (İclal, 2016).

İleri doğru hesaplama da esas amaç verilen giriş değerlerine karşılık gelen çıkış değerinin tahmin etmek ve hedeflenen değer kullanılarak hatanın hesaplanmasıdır. Giriş hücrelerindeki bilgiler gizli katman hücrelerine aktarılırken her bir nöron, ileriye doğru hesaplama sürecinde ilgili ağırlıklarla çarpılan girdileri alarak (NET) bir aktivasyon fonksiyonundan geçirir ve çıkış değerini hesaplar

$$NET_p = \sum_i w_{ip} x_i$$

Burada; NET_p gizli katmanın p . hücresine olan girdi, w_{ip} giriş katmanının i . hücresini, gizli katmanın p . hücresine bağlayan ağırlık, x_i giriş katmanındaki i . hücresinin çıkışını temsil etmektedir. Bulunan NET girdi, bir aktivasyon fonksiyonundan geçirilerek, gizli katman hücrelerinin çıkışı bulunmaktadır.

$$F_p = f(NET_p)$$

Burada F_p gizli katmanın p . hücresinin aktivasyon fonksiyonunu göstermektedir. Bu aşamadan hata hesaplaması:

$$\varepsilon_p = (T_p) - (F_p)$$

ε_p hata; T_p çıkış değeri; F_p p . hücresinin hesaplanan değerini göstermektedir. İkinci aşama olan geriye doğru hesaplama sürecinde ise, hata değerleri geriye doğru yayılır ve ağırlıklar bu hatalara göre güncellenir. Bu süreç, modelin öğrenme kapasitesini artırarak daha doğru tahminler yapmasını sağlar. İlk önce hata çıkış katmanı ile gizli katman arasındaki ağırlık değerleri; sonra gizli katman ile giriş katmanı arasındaki ağırlık değerleri hesaplatılarak geriye doğru ilerler (Öğücü, 2006). Verilerin %70'i eğitim, %30'u test amaçlı kullanılarak gerçekleştirilir ve test sürecinde öğrenilen modelin doğruluğu kontrol edilir (Kayakuş & Terzioğlu 2021).

3.3. BATS Modeli ve TBATS Modeli

BATS ve TBATS, karmaşık mevsimsel zaman serisi değişimlerini ele alabilen iki yenilik durum uzayı modelleme çerçevesidir (Jeong vd., 2014). BATS, entegre Box-Cox dönüşümü (Sakia, 1992) ile doğrusal olmamayı içeren doğrusal bir homoskedastik modeldir ve artıklardaki herhangi bir otokorelasyonu yakalamak için sabit bir ARMA (Riise and Tjozstheim, 1984) gösterimi kullanılır. BATS modeli (B - Box-Cox dönüşümü, A - ARMA artıkları, T - trend bileşeni, S - mevsimsel bileşen) baş harflerinin birleşimidir. Bu modele trigonometrik ifadenin eklenmesi ile TBATS modeli oluşur. TBATS modeli (Mevsimsel bileşenlerin T- trigonometrik gösterimi, B - Box-Cox dönüşümü, A - ARMA artıkları, T - trend bileşeni, S - mevsimsel bileşen) baş harflerinin birleşimidir. Box-Cox Dönüşümü doğrusal olmayan verilerle başa çıkmak içindir ve artıklar için ARMA modeli zaman serisi verilerini yeniden düzenler. BATS modeli, basit Durum Uzayı Modeline kıyasla tahmin performansını artırabilir. TBATS, BATS'ın birden fazla mevsimsel yanlış döngüye izin veren bir iyileştirme modifikasyonudur. Modelleme çerçevesinin bir başka avantajı da, sıfır değerlerle veri işlemenin uyarılana bilirliliğidir (De Livera vd., 2011).

Sırasıyla BATS ve TBATS modellerinin matematiksel formülasyonları ve parametreleri aşağıdaki gibidir.

$$y_t^{(\omega)} = \begin{cases} \frac{y_t^{(\omega)} - 1}{\omega} & \omega \neq 0 \\ \log y^{(\omega)} & \omega = 0 \end{cases} \quad (2.3.1)$$

Eşitlik (2.3.1) bir Box-Cox dönüşümüdür

$$y_t^{(\omega)} = l_{t-1} + \phi b_{t-1} + \sum_{i=1}^T S_{t-m_i}^{(i)} + d_t \quad (2.3.2)$$

Denklem (2.3.2), mevsimsel M modelini temsil eder

$$l_t = l_{t-1} + \phi b_{t-1} + \alpha d_t \quad (2.3.3)$$

$$b_t = (1 - \phi)b + \phi b_{t-1} + \beta d_t \quad (2.3.4)$$

$$s_t^{(i)} = s_{t-m_i}^{(i)} + \gamma_i d_t \quad (2.3.5)$$

Eşitlik (2.3.3), (2.3.4) ve (2.3.5) küresel trendler ve yerel trendlerdir.

$$d_t = \sum_{i=1}^p \varphi_i d_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (2.3.6)$$

Eşitlik (2.3.6), ARMA tarafından modellenen hatadır. Burada m_1, m_2, \dots, m_T ($i = 1, 2, \dots, T$) mevsimsel kalıpların periyotlarını temsil eder, b_t t dönemdeki kısa dönem trend, b ise uzun dönem trend, l_t seviye bileşeni, $s_t^{(i)}$ t zamanındaki mevsimsel bileşeni gösterir, ve d_t düzensiz bileşeni ise ARMA(p, q) bileşenini temsil eder ve ε_t beyaz gürültü sürecidir (Iwok ve Udoh, 2016). ARMA(p, q) parametreleri φ_i ($i = 1, 2, \dots, p$) ve θ_i ($i = 1, 2, \dots, q$) ve ε_t Gaus beyaz gürültülü süreç sıfır ortalama ve sabit varyanslı σ^2 (yani NIID($0, \sigma^2$)) dır. t zamanındaki i . İnci mevsimsel bileşen

$$s_t^{(i)} = s_{t-m_i}^{(i)} + \gamma_i d_t \quad (t = 1, 2, \dots, n; i = 1, 2 \dots T)$$

Burada ω Box-Cox dönüşümü operatörü, ϕ üstel yumuşatma operatörü (yani düşürme parametresi), için Yumuşatma parametreleri, düzeltme parametreleri ($i = 1 \dots T$) α, β ve γ_i ile verilir. ϕ trend bileşeni sönümlendiğinde trend extrapolasyonu üzerinde daha fazla kontrol sağlayan sönümleme parametresidir (Taylor, 2003).

Herhangi bir tahmin tekniğinin tahmin doğruluğu açısından değerlendirilmesi gerekir. Doğruluk ölçümleri, tahmin sırasında elde edilen değerler ile gerçek değerler arasındaki hataları kontrol eder. Kök ortalama karesel hata (RMSE) (Huffman, 1997) ve Ortalama mutlak yüzde hata (MAPE) (Armstrong & Collopy, 1992) ölçümleri, tahmin yönteminin doğruluğunu ölçmek için yaygın olarak kullanılmaktadır.

Aşağıda verilen formüllerde N toplam gözlem sayısı, Y_t gerçek değer ve \hat{Y}_t ise tahmin değeridir. MAE ve MSE her zaman pozitif değerlidir ve MAE ile MSE'nin değeri sıfıra yaklaşması daha iyi bir performans gösterdiği demektir (Sammut & Webb, 2010).

$$MAE = \frac{1}{N} \sum_{t=1}^N |Y_t - \hat{Y}_t|$$

$$MAPE = \left[\frac{1}{N} \sum_{t=1}^N \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \right] \times 100$$


$$MSE = \frac{1}{N} \sum_{t=1}^N (Y_t - \hat{Y}_t)^2$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (Y_t - \hat{Y}_t)^2}$$

4. BULGULAR

BIST30 hisse senedi verilerinden olan bazı bankaların kapanış değerleri verilerine R paket programını kullanarak ilk önce serileri durağanlığını belirledik. Daha sonra da ETS, MLP, BATS ve TBATS modelleri uyguladık. Bu uygulama sonucu elde ettiğimiz öngörülere de MAE, MAPE, MSE ve RMSE performans ölçüt kriterlerini uygulayıp en iyi öngörü sonucunu bulmaya çalıştık. Son olarak da performans ölçüt kriterlerine göre en iyi yöntem ile 24 aylık öngörülerde bulunduk.

Şekil 2. 1996-2021 Yılları Arası Yapı Kredi Hisse Senedi Kapanış Değerleri



Şekil 2'de 1996-2021 yılları arası Yapı Kredi hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Tablo 2. Yapı Kredi Hisse Senedi Kapanış Değerlerine Ait Tanımlayıcı İstatistikler

Ort	SS	Medyan	Min	Maks	Çarpıklık	Basıklık
1.610	1.000	1.620	0.010	3.470	-0.060	-1.310

Ort: Ortalama, SS: Standart sapma, Min: Minimum, Maks: Maksimum


Tablo 2’de 1996-2021 yılları arası Yapı Kredi hisse senedi kapanış değerlerine ait tanımlayıcı istatistik değerleri gösterilmektedir. Bulgulara göre, Yapı Kredi hisse senedi kapanış değer ortalaması 1.610 ve standart sapması da 1.000’dir.

Tablo 3. Kullanılan Tahmin Tekniklerini Seçme Kriterleri

Model	Performans ölçütleri			
	MSE	RMSE	MAE	MAPE
ETS	0.400	0.632	0.507	24.058
BATS	0.205	0.453	0.376	17.508
TBATS	0.187	0.433	0.344	13.808
MLP	0.521	0.722	0.591	27.861


Tablo 3’te bazı tahmin tekniklerine ait modellerin test veri seti üzerindeki performans ölçütlerinden MSE, RMSE, MAE ve MAPE değerleri gösterilmektedir. Performans ölçütleri incelendiğinde MSE (0.187), RMSE (0.433), MAE (0.344) ve MAPE (13.808) performans ölçütleri için en düşük değerler TBATS tekniğinde gerçekleşmiştir. Bu bulgu ışığında, TBATS modeli diğer modellere göre Yapı Kredi hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır. Gelecek 24 aylık öngörü için TBATS modeli kullanılacaktır.

Şekil 3. Test Tahmin Sonuçlarına Ait Zaman Serisi Grafiği



Şekil 3’te TBATS modeli kullanılarak test veri seti üzerinden tahmin edilen Yapı Kredi hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Şekil 4. TBATS Modeline Göre 24 Aylık Öngörüler




Şekil 4'te TBATS modeline göre 24 aylık Yapı Kredi hisse senedi kapanış değerlerine ait öngörüler gösterilmektedir.

Tablo 4. TBATS Modeline Göre 24 Aylık Öngörü Değerleri

Ay	Yıl	Tahmin	%95 - Alt sınır	%95 - Üst sınır	%99 - Alt sınır	%99 - Üst sınır
Mart	2021	2.870	2.328	3.481	2.172	3.688
Nisan	2021	2.870	2.140	3.731	1.937	4.031
Mayıs	2021	2.870	2.001	3.934	1.766	4.310
Haziran	2021	2.870	1.887	4.110	1.628	4.557
Temmuz	2021	2.870	1.790	4.270	1.512	4.781
Ağustos	2021	2.870	1.704	4.419	1.411	4.991
Eylül	2021	2.870	1.627	4.558	1.322	5.188
Ekim	2021	2.870	1.558	4.690	1.242	5.376
Kasım	2021	2.870	1.494	4.817	1.169	5.557
Aralık	2021	2.870	1.436	4.938	1.103	5.731
Ocak	2022	2.870	1.381	5.055	1.042	5.900
Şubat	2022	2.870	1.330	5.169	0.986	6.065
Mart	2022	2.870	1.282	5.280	0.933	6.225
Nisan	2022	2.870	1.237	5.387	0.885	6.381
Mayıs	2022	2.870	1.194	5.492	0.839	6.535
Haziran	2022	2.870	1.154	5.595	0.797	6.685
Temmuz	2022	2.870	1.116	5.696	0.757	6.833
Ağustos	2022	2.870	1.079	5.795	0.719	6.978
Eylül	2022	2.870	1.045	5.893	0.683	7.121
Ekim	2022	2.870	1.011	5.988	0.650	7.263
Kasım	2022	2.870	0.980	6.083	0.618	7.402
Aralık	2022	2.870	0.949	6.176	0.588	7.540
Ocak	2023	2.870	0.920	6.267	0.559	7.676
Şubat	2023	2.870	0.892	6.358	0.532	7.810

Tablo 4'te TBATS modeline göre 24 aylık Yapı Kredi hisse senedi kapanış değerlerine ait öngörü sonuçları gösterilmektedir.

Şekil 5. 1996-2021 Yılları Arası Türkiye İş Bankası Hisse Senedi Kapanış Değerleri



Şekil 5'te 1996-2021 yılları arası Türkiye İş Bankası hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Tablo 5. Türkiye İş Bankası Hisse Senedi Kapanış Değerlerine Ait Tanımlayıcı İstatistikler

Ort	SS	Medyan	Min	Maks	Çarpıklık	Basıklık
2.960	2.080	2.900	0.010	7.710	0.190	-1.140

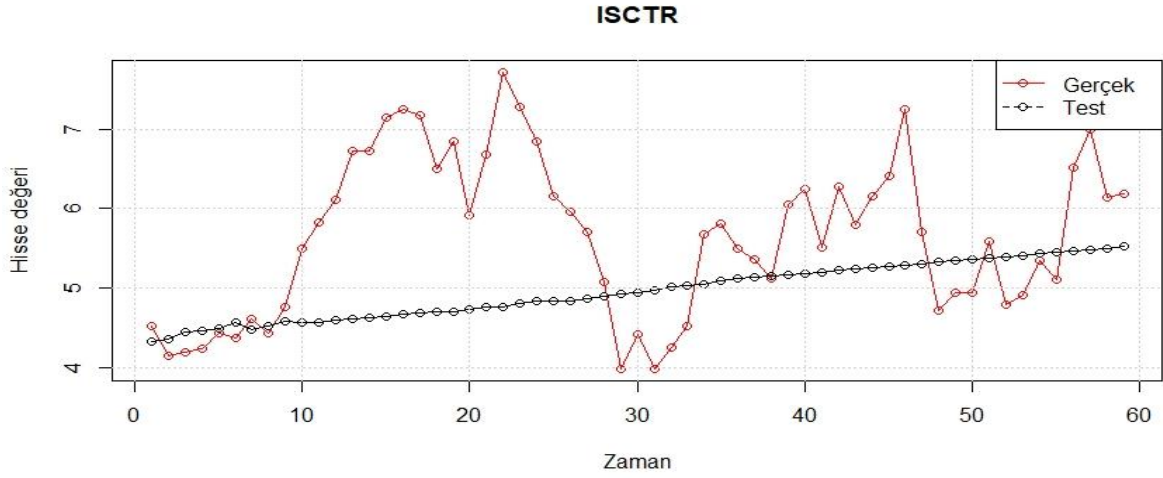
Ort: Ortalama, SS: Standart sapma, Min: Minimum, Maks: Maksimum

Tablo 5'te 1996-2021 yılları arası Türkiye İş Bankası hisse senedi kapanış değerlerine ait tanımlayıcı istatistik değerleri gösterilmektedir. Bulgulara göre, Türkiye İş Bankası hisse senedi kapanış değer ortalaması 2.960 ve standart sapması 2.080'dir.


Tablo 6. Kullanılan Tahmin Tekniklerini Seçme Kriterleri

Model	Performans ölçütleri			
	MSE	RMSE	MAE	MAPE
ETS	2.122	1.457	1.149	18.327
BATS	2.884	1.698	1.406	22.663
TBATS	4.528	2.128	1.853	30.509
MLP	1.484	1.218	0.947	15.427

Tablo 6'da bazı tahmin tekniklerine ait modellerin test veri seti üzerindeki performans ölçütlerinden MSE, RMSE, MAE ve MAPE değerleri gösterilmektedir. Performans ölçütleri incelendiğinde MSE (1.484), RMSE (1.218), MAE (0.947) ve MAPE (15.427) performans ölçütleri için en düşük değerler MLP tekniğinde gerçekleşmiştir. Bu bulgu ışığında, MLP modeli diğer modellere göre Türkiye İş Bankası hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır. Gelecek 24 aylık öngörü için MLP modeli kullanılacaktır.

Şekil 6. Test Tahmin Sonuçlarına Ait Zaman Serisi Grafiği

Şekil 6'da MLP modeli kullanılarak test veri seti üzerinden tahmin edilen Türkiye İş Bankası hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Şekil 7. MLP Modeline Göre 24 Aylık Öngörüler


Şekil 7'de MLP modeline göre 24 aylık Türkiye İş Bankası hisse senedi kapanış değerlerine ait öngörüler gösterilmektedir.

Tablo 7. MLP modeline göre 24 aylık öngörü değerleri

Ay	Yıl	Tahmin
Mart	2021	6.272
Nisan	2021	6.013
Mayıs	2021	6.242
Haziran	2021	6.267
Temmuz	2021	6.016
Ağustos	2021	6.063
Eylül	2021	6.104
Ekim	2021	6.189
Kasım	2021	6.180
Aralık	2021	6.311
Ocak	2022	6.444
Şubat	2022	6.601
Mart	2022	6.515
Nisan	2022	6.542
Mayıs	2022	6.775
Haziran	2022	6.714
Temmuz	2022	6.696
Ağustos	2022	6.655
Eylül	2022	6.603
Ekim	2022	6.565
Kasım	2022	6.557
Aralık	2022	6.626
Ocak	2023	6.629
Şubat	2023	6.745

Tablo 7’de MLP modeline göre 24 aylık Türkiye İş Bankası hisse senedi kapanış değerlerine ait öngörü sonuçları gösterilmektedir.

Şekil 8. 1996-2021 Yılları Arası Akbank Hisse Senedi Kapanış Değerleri



Şekil 8’de 1996-2021 arası Garanti hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Tablo 8. Garanti Hisse Senedi Kapanış Değerlerine Ait Tanımlayıcı İstatistikler

Ort	SS	Medyan	Min	Maks	Çarpıklık	Basıklık
4.130	3.470	3.540	0.010	11.900	0.240	-1.390


Ort: Ortalama, SS: Standart sapma, Min: Minimum, Maks: Maksimum

Tablo 8’de 1996-2021 yılları arası Garanti hisse senedi kapanış değerlerine ait tanımlayıcı istatistik değerleri gösterilmektedir. Bulgulara göre, Garanti hisse senedi kapanış değer ortalaması 4.130 ve standart sapması 3.470’dir.

Tablo 9. Kullanılan Tahmin Tekniklerini Seçme Kriterleri


Model	Performans ölçütleri			
	MSE	RMSE	MAE	MAPE
ETS	2.126	1.458	1.136	12.621
BATS	3.182	1.784	1.425	15.216
TBATS	2.993	1.730	1.372	14.690
MLP	6.946	2.636	2.158	27.236

Tablo 9’da bazı tahmin tekniklerine ait modellerin test veri seti üzerindeki performans ölçütlerinden MSE, RMSE, MAE ve MAPE değerleri gösterilmektedir. Performans ölçütleri incelendiğinde MSE (2.126), RMSE (1.458), MAE (1.136) ve MAPE (12.621) performans ölçütleri için en düşük değerler ETS tekniğinde gerçekleşmiştir. Bu bulgu ışığında, ETS modeli diğer modellere göre Garanti hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır. Gelecek 24 aylık öngörü için ETS modeli kullanılacaktır.

Şekil 9. Test Tahmin Sonuçlarına Ait Zaman Serisi Grafiği

Şekil 9’da ETS modeli kullanılarak test veri seti üzerinden tahmin edilen Garanti hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Şekil 10. ETS Modeline Göre 24 Aylık Öngörüler




Şekil 10'da ETS modeline göre 24 aylık Garanti hisse senedi kapanış değerlerine ait öngörüler gösterilmektedir.

Tablo 10. ETS Modeline Göre 24 Aylık Öngörü Değerleri

Ay	Yıl	Tahmin	%95 - Alt sınır	%95 - Üst sınır	%99 - Alt sınır	%99 - Üst sınır
Mart	2021	9.398	6.399	12.397	5.457	13.339
Nisan	2021	9.406	5.296	13.516	4.005	14.807
Mayıs	2021	9.414	4.416	14.412	2.846	15.983
Haziran	2021	9.422	3.654	15.190	1.842	17.002
Temmuz	2021	9.430	2.968	15.892	0.938	17.923
Ağustos	2021	9.438	2.335	16.542	0.103	18.774
Eylül	2021	9.446	1.741	17.151	-0.680	19.572
Ekim	2021	9.454	1.178	17.731	-1.422	20.331
Kasım	2021	9.462	0.640	18.285	-2.133	21.058
Aralık	2021	9.471	0.121	18.820	-2.817	21.758
Ocak	2022	9.479	-0.382	19.339	-3.480	22.437
Şubat	2022	9.487	-0.870	19.844	-4.125	23.098
Mart	2022	9.495	-1.348	20.337	-4.755	23.744
Nisan	2022	9.503	-1.815	20.821	-5.371	24.377
Mayıs	2022	9.511	-2.274	21.296	-5.977	24.999
Haziran	2022	9.519	-2.726	21.764	-6.573	25.611
Temmuz	2022	9.527	-3.171	22.225	-7.162	26.215
Ağustos	2022	9.535	-3.612	22.682	-7.743	26.813
Eylül	2022	9.543	-4.047	23.134	-8.318	27.404
Ekim	2022	9.551	-4.479	23.582	-8.888	27.990
Kasım	2022	9.559	-4.908	24.026	-9.454	28.572
Aralık	2022	9.567	-5.333	24.468	-10.016	29.150
Ocak	2023	9.575	-5.757	24.907	-10.574	29.725
Şubat	2023	9.583	-6.178	25.345	-11.131	30.298

Tablo 10'da ETS modeline göre 24 aylık Garanti hisse senedi kapanış değerlerine ait öngörü sonuçları gösterilmektedir.

Şekil 11. 2005-2021 Yılları Arası Vakıfbank Hisse Senedi Kapanış Değerleri

Şekil 11’de 2005-2021 yılları arası Vakıfbank hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Tablo 11. Vakıfbank Hisse Senedi Kapanış Değerlerine Ait Tanımlayıcı İstatistikler

Ort	SS	Medyan	Min	Maks	Çarpıklık	Basıklık
3.940	1.230	3.900	1.000	7.420	0.210	0.400

Ort: Ortalama, SS: Standart sapma, Min: Minimum, Maks: Maksimum


Tablo 11’de 2005-2021 arası birinci derece farkları alınmış Vakıfbank hisse senedi kapanış değerlerine ait tanımlayıcı istatistik değerleri gösterilmektedir. Bulgulara göre, Vakıfbank hisse senedi kapanış değer ortalaması 3.940 ve standart sapması 1.230’dur.

Tablo 12. Kullanılan Tahmin Tekniklerini Seçme Kriterleri

Model	Performans ölçütleri			
	MSE	RMSE	MAE	MAPE
ETS	8.020	2.832	2.703	62.041
BATS	7.960	2.821	2.692	61.798
TBATS	7.974	2.824	2.681	61.688
MLP	12.767	3.573	3.410	77.542


Tablo 12’de bazı tahmin tekniklerine ait modellerin test veri seti üzerindeki performans ölçütlerinden MSE, RMSE, MAE ve MAPE değerleri gösterilmektedir. Performans ölçütleri incelendiğinde MSE (7.960) ve RMSE (2.821) performans ölçütleri için en düşük değerler BATS tekniğinde gerçekleşmiştir. Diğer performans ölçütlerinden MAE (2.681) ve MAPE (61.688) ölçütleri için TBATS tekniği en düşük değeri vermiştir. Bu bulgu ışığında, BATS modeli diğer modellere göre Vakıfbank hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır. Gelecek 24 aylık öngörü için BATS modeli kullanılacaktır.

Şekil 12. Test Tahmin Sonuçlarına Ait Zaman Serisi Grafiği



Şekil 12’de BATS modeli kullanılarak test veri seti üzerinden tahmin edilen Vakıfbank hisse senedi kapanış değerlerine ait zaman serisi grafiği gösterilmektedir.

Şekil 13. BATS Modeline Göre 24 Aylık Öngörüler



Şekil 13’te BATS modeline göre 24 aylık Vakıfbank hisse senedi kapanış değerlerine ait öngörüler gösterilmektedir.

Tablo 13. BATS Modeline Göre 24 Aylık Öngörü Değerleri

Ay	Yıl	Tahmin	%95 - Alt sınır	%95 - Üst sınır	%99 - Alt sınır	%99 - Üst sınır
Mart	2021	4.369	3.481	5.359	3.222	5.690
Nisan	2021	4.369	3.152	5.784	2.810	6.269
Mayıs	2021	4.369	2.910	6.123	2.512	6.735
Haziran	2021	4.369	2.712	6.417	2.273	7.141
Temmuz	2021	4.369	2.544	6.682	2.072	7.509
Ağustos	2021	4.369	2.397	6.927	1.898	7.850
Eylül	2021	4.369	2.265	7.155	1.744	8.171
Ekim	2021	4.369	2.145	7.372	1.607	8.475
Kasım	2021	4.369	2.036	7.578	1.484	8.766

Aralık	2021	4.369	1.935	7.775	1.371	9.046
Ocak	2022	4.369	1.841	7.966	1.268	9.316
Şubat	2022	4.369	1.754	8.150	1.174	9.578
Mart	2022	4.369	1.672	8.328	1.086	9.832
Nisan	2022	4.369	1.596	8.502	1.005	10.080
Mayıs	2022	4.369	1.523	8.671	0.930	10.322
Haziran	2022	4.369	1.455	8.836	0.861	10.560
Temmuz	2022	4.369	1.390	8.998	0.795	10.792
Ağustos	2022	4.369	1.328	9.156	0.735	11.020
Eylül	2022	4.369	1.270	9.312	0.678	11.244
Ekim	2022	4.369	1.214	9.464	0.625	11.464
Kasım	2022	4.369	1.161	9.614	0.575	11.681
Aralık	2022	4.369	1.110	9.762	0.528	11.895
Ocak	2023	4.369	1.061	9.907	0.485	12.106
Şubat	2023	4.369	1.015	10.051	0.444	12.315

Tablo 13'de BATS modeline göre 24 aylık Vakıfbank hisse senedi kapanış değerlerine ait öngörü sonuçları gösterilmektedir.

4. SONUÇ

Tahmin, ya insan yargısına (nitel tahmin) ya da geçmiş verilere (nicel tahmin) dayalı olarak geleceği tahmin ederek belirsizlikle başa çıkmaktadır. Günümüzün rekabetçi piyasasında rekabet avantajı oluşturabilecek faydalı bir araçtır. Son dönemlerde hisse senetleri önemli getiri kaynağına dönüşmüştür. Borsa ile ilgilenen insanların hisse senetlerinin trendlerini bilmek ve en doğru tahminlerine ulaşmak isterler. Genellikle borsa verileri ile ilgili oluşturulan zaman serileri doğrusal değildir. Bundan dolayı, BIST'teki hisse senetlerinin trendlerini tahmin etmek için doğrusal olmayan modellerin kullanılması, geleneksel modellere göre daha iyi bir tahmin sonucu verir.

BIST30 hisse senetleri üzerinden zaman serisi analizleri yapılmış ve 24 aylık öngörüler hesaplanmıştır. Buna göre, performans kriterlerine bakıldığında birinci dereceden farkı alınmış Performans ölçütleri incelendiğinde MSE (0.187), RMSE (0.433), MAE (0.344) ve MAPE (13.808) performans ölçütleri için en düşük değerler TBATS tekniğinde gerçekleşmiştir. Bu bulgu ışığında, TBATS modeli diğer modellere göre Yapı Kredi hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır. Benzer şekilde birinci dereceden farkı alınmış İş Bankası hisse senedini kapanış değerlerinin performans ölçütleri incelendiğinde MSE (1.484), RMSE (1.218), MAE (0.947) ve MAPE (15.427) performans ölçütleri için en düşük değerler MLP tekniğinde gerçekleşmiştir. Bu bulgu ışığında, MLP modeli diğer modellere göre Türkiye İş Bankası hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır

Benzer şekilde Garanti Bankası hisse senedinin kapanış değerlerine baktığımızda performans ölçütleri MSE (2.126), RMSE (1.458), MAE (1.136) ve MAPE (12.621) en düşük değerler ETS tekniğinde gerçekleşmiştir. Bu bulgu ışığında, ETS modeli diğer modellere göre Garanti hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır. Son olarak Vakıfbank hisse senedi kapanış değerlerine bakıldığında MSE (7.960) ve RMSE (2.821) performans ölçütleri için en düşük değerler BATS tekniğinde gerçekleşmiştir. Diğer performans ölçütlerden MAE (2.681) ve MAPE (61.688) ölçütleri için TBATS tekniği en düşük değeri vermiştir. Bu bulgu ışığında, BATS modeli diğer modellere göre Vakıfbank hisse senedi kapanış değerlerini tahmin etmede daha başarılıdır.

Hisse senedi piyasası getirilerini öngörmek, bu alanda yatırım yapmak isteyenlerin borsa verilerinin eğilimlerini anlamalarına ve karar vermelerine, piyasa ile ilişkili yatırım risklerini en aza indirmelerine ve getirilerini maksimize etmelerini sağlar (Lin vd., 2009). Hisse senedi trend tahmininin ana gayesi, maksimum kâr getirisi olan hisse senetlerini tahmin etmek için yenilikçi yaklaşımlar geliştirmektir (Karan, 2020). Bu nedenle, yenilikçi yaklaşımlar yatırımcıların tahminlerinin doğruluğunu arttırmayı veya bu doğru tahminler arasından en doğru tahmine ulaşmayı sağlar.

Bu çalışmanın amacı, karmaşık ve devasa verilerin üstesinden gelmek ve yenilikçi yaklaşımlarla elde edilen tahminler arasından en doğru tahmin sonucuna ulaşmak noktasında fayda göstereceği kanaatindeyim.

KAYNAKÇA

- Akşehir, Z. D., & Kılıç, E. (2019). Makine öğrenmesi teknikleri ile banka hisse senetlerinin fiyat tahmini. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 12(2), 30-39.
- Armstrong, J. S., & Collopy, F. (1992). Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, 8(1), 69-80. [https://doi.org/10.1016/0169-2070\(92\)90008-W](https://doi.org/10.1016/0169-2070(92)90008-W)
- Arslankaya, S., & Toprak, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *International Journal of Engineering Research and Development*, 13(1), 178-192. <https://doi.org/10.29137/umagd.771671>
- Badr, A., Makarovskikh, T., Mishra, P., Abotaleb, M., Al Khatib, A. M. G., Karakaya, K., & Attal, E. (2021). Modelling and forecasting of web traffic using Holt's linear, BATS and TBATS models. *J. Math. Comput. Sci.*, 11(4), 3887-3915.
- De Livera, A. M., Hyndman, R. J., & Snyder, R. D. (2011). Forecasting time series with complex seasonal patterns using exponential smoothing. *Journal of the American Statistical Association*, 106(496), 1513-1527. <https://doi.org/10.1198/jasa.2011.tm09771>
- Du, Y. (2018). Application and analysis of forecasting stock price index based on combination of ARIMA model and BP neural network. In *2018 Chinese Control and Decision Conference (CCDC)* (pp. 2854-2857). IEEE. <https://doi.org/10.1109/CCDC.2018.8407611>
- Gardner, E. S. (1985). Exponential smoothing: The state of the art. *Journal of Forecasting*, 4(1), 1-28. <https://doi.org/10.1002/for.3980040103>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Hamilton, D. J. (1994). *Time series analysis*. Princeton University Press. <https://doi.org/10.1515/9780691218632>
- Hargrave, B. C., Wilson, R. L., & Walstrom, K. A. (1994). Predicting graduate student success: A comparison of neural networks and traditional techniques. *Computers & Operations Research*, 21(3), 249-263. [https://doi.org/10.1016/0305-0548\(94\)90088-4](https://doi.org/10.1016/0305-0548(94)90088-4)
- Hendricks, D., Patel, J., & Zeckhauser, R. (1993). Hot hands in mutual funds: Short-run persistence of relative performance. *The Journal of Finance*, 48(1), 93-130. <https://doi.org/10.1111/j.1540-6261.1993.tb04703.x>
- Holt, C. C. (1957). Forecasting trends and seasonals by exponentially weighted averages. ONR Memorandum No. 52. Carnegie Institute of Technology, Pittsburgh, USA. (Published in *International Journal of Forecasting*, 2004, 20, 5-13). <https://doi.org/10.1016/j.ijforecast.2003.09.017>

- Huffman, G. J. (1997). Estimates of root-mean-square random error for finite samples of estimated precipitation. *Journal of Applied Meteorology and Climatology*, 36(9), 1191-1201. [https://doi.org/10.1175/1520-0450\(1997\)036<1191>2.0.CO;2](https://doi.org/10.1175/1520-0450(1997)036<1191>2.0.CO;2)
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice*. OTexts.
- Hyndman, R. J., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3), 1-22. <https://doi.org/10.18637/jss.v027.i03>
- 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)
- Indro, D. C., Jiang, C. X., Patuwo, B. E., & Zhang, G. P. (1999). Predicting mutual fund performance using artificial neural networks. *Omega*, 27(3), 373-380. [https://doi.org/10.1016/S0305-0483\(98\)00048-6](https://doi.org/10.1016/S0305-0483(98)00048-6)
- Iwok, I. A., & Udoh, G. M. (2016). A comparative study between the ARIMA-Fourier model and the Wavelet model. *American Journal of Scientific and Industrial Research*, 7(6), 137-144.
- İclal, G. (2016). Çok katmanlı algılayıcı yapay sinir ağı ile lineer diferansiyel denklem sisteminin çözümü. *18. Akademik Bilişim Konferansı*, Aydın, 3-5 Şubat, 738-745.
- Jeong, K., Koo, C., & Hong, T. (2014). An estimation model for determining the annual energy cost budget in educational facilities using SARIMA and ANN. *Energy*, 71, 71-79. <https://doi.org/10.1016/j.energy.2014.04.027>
- Kalteh, A. M. (2008). Rainfall-runoff modelling using artificial neural networks: Modelling and understanding.
- Karan, M. B. (2020). *Yatırım analizi ve portföy yönetimi*. Gazi Kitapevi.
- Kayakuş, M., & Terzioğlu, M. (2021). Yapay sinir ağları ve çoklu doğrusal regresyon kullanarak emeklilik fonu net varlık değerlerinin tahmin edilmesi. *Bilişim Teknolojileri Dergisi*, 14(1), 95-103. <https://doi.org/10.17671/gazibtd.742995>
- Kourentzes, N. (2019). nnfor: Time series forecasting with neural networks. R package version 0.9.6. <https://CRAN.R-project.org/package=nnfor>
- Lima, M. V. M. D., & Laporta, G. Z. (2020). Evaluation of the models for forecasting dengue in Brazil from 2000 to 2017: An ecological time-series study. *Insects*, 11(11), 794.
- Lin, J. C., Singh, A. K., & Yu, W. (2009). Stock splits, trading continuity, and the cost of equity capital. *Journal of Financial Economics*, 93(3), 474-489. <https://doi.org/10.1016/j.jfineco.2008.09.008>
- Öğücü, M. O. (2006). Yapay sinir ağları ile sistem tanıma (Yayımlanmamış Doktora Tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Naim, I., Mahara, T., & Idrisi, A. R. (2018). Effective short-term forecasting for daily time series with complex seasonal patterns. *Procedia Computer Science*, 132, 1832-1841. <https://doi.org/10.1016/j.procs.2018.05.136>
- Oukhouya, H., & El Himdi, K. (2023). Comparing machine learning methods—svr, xgboost, lstm, and mlp—for forecasting the Moroccan stock market. *Computer Sciences & Mathematics Forum*, 7(1), 39. <https://doi.org/10.3390/IOCMA2023-14409>
- Pegels, C. C. (1969). Exponential forecasting: Some new variations. *Management Science*, 15(5), 311-315. <https://doi.org/10.1287/mnsc.15.5.311>
- R Core Team. (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing. <https://www.R-project.org/>

- Riise, T., & Tjozstheim, D. (1984). Theory and practice of multivariate ARMA forecasting. *Journal of Forecasting*, 3(3), 309-317. <https://doi.org/10.1002/for.3980030308>
- Sakia, R. M. (1992). The Box-Cox transformation technique: A review. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 41(2), 169-178. <https://doi.org/10.2307/2348250>
- Taylor, J. W. (2003). Exponential smoothing with a damped multiplicative trend. *International Journal of Forecasting*, 19(4), 715-725. [https://doi.org/10.1016/S0169-2070\(03\)00003-7](https://doi.org/10.1016/S0169-2070(03)00003-7)
- Tektaş, A., & Karataş, A. (2004). Yapay sinir ağları ve finans alanına uygulanması: Hisse senedi fiyat tahminlemesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4).
- Yavuz, S., & Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.
- Webb, G. I., & Sammut, C. (Eds.). (2010). *Encyclopedia of machine learning*. Springer.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6, 324-342. <https://doi.org/10.1287/mnsc.6.3.324>
- Wiri, L., & Essi, I. D. (2018). Seasonal autoregressive integrated moving average (SARIMA) modelling and forecasting of inflation rates in Nigeria (2003-2016). *International Journal of Applied Science and Mathematical Theory*, 4(1), 2-4.

* * * * *

Çıkar Çatışması Beyanı: Bu çalışmada taraf olabilecek herhangi bir kişi, kurum veya kuruluş arasında bir çıkar çatışması bulunmamaktadır.

Destek ve Teşekkür: Çalışma için herhangi bir kurum ya da kuruluştan finansal destek alınmamıştır. Gösterdikleri ilgi ve emekten dolayı Dicle Akademi Dergisi Editörlerine ve katkılarından dolayı hakemlere teşekkür ederiz.

Etik Kurul İzni: Çalışma konusu etik kurul iznini gerektirmemektedir. Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder.

Katkı Oranı: Çalışma tek yazarlıdır.

* * * * *

EXTENDED ABSTRACT

Introduction

A stock exchange is an environment that enables investors within a country to engage in trading activities securely, competitively, and on an equal footing. In our country, this function is performed by Borsa Istanbul (BIST). Borsa Istanbul serves as a marketplace for various financial instruments, including both long-term and short-term stocks, bonds, bills, and precious metals, accommodating all investor profiles. The key characteristics of the stock exchange include efficient and effective trading in a secure environment, governed by principles of free competition, transparency, and stability.

The analysis of stocks has long attracted researchers, resulting in the evolution of various analytical methods that have been refined over time. This study aims to apply newly developed methods, such as ETS, MLP, BATS, and TBATS, to stocks derived from BIST data to address the challenges of multiple seasonality and complexity, ultimately enhancing forecast accuracy.

Econometric studies typically pursue three main objectives: analyzing current conditions and systems, formulating policy, and forecasting future outcomes. Econometric time series forecasting holds particular importance for assessing the present at both macro and micro scales and for enabling informed preliminary preparations and decision-making based on anticipated future conditions. Given the limitations of traditional forecasting methods in capturing complex seasonality, advanced forecasting methods like ETS, MLP, BATS, and TBATS have gained prominence. These models are specifically designed to handle complex time series, thereby aiding users in modeling trends, seasonal patterns, and other time-series components with greater effectiveness.

Method

Initially, the stationarity of the variables was examined using the Augmented Dickey-Fuller test. For non-stationary variables, first-order differencing was applied. Subsequently, the ETS (Exponential Smoothing State Space Model), MLP (Multilayer Perceptron), BATS (Box-Cox-based ARIMA, Trend, and Seasonality Model), and TBATS (Box-Cox-based ARIMA, Trend, and Seasonality Model with Fourier transformations) models were applied to the closing values of selected BIST30 stocks. To evaluate model performance, metrics such as Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Mean Squared Error (MSE), and Root Mean Squared Error (RMSE) were used.

Findings

According to the performance metrics applied to forecast the closing values of BIST30 stocks, the TBATS model provided the most accurate predictions for Yapı Kredi Bank, the MLP model for İş Bank, the ETS model for Garanti Bank, and the BATS model for Vakıfbank.

Discussion, Conclusion, and Recommendations

In this study, time series analyses of the closing values of certain banks from the BIST 30 index were conducted using various models, leading to the calculation of 24-month forecasts. To determine the most accurate forecasts, several performance criteria were applied. Rather than focusing solely on the superiority of one model over another in predicting nonlinear data with multiple seasonality components, this study utilized four distinct performance criteria to achieve the most accurate forecasts. This approach contributes a unique perspective to the literature by emphasizing the accuracy of predictions across different metrics.