



DÜNYA BORSALARINDA İKİLİ İŞLEM STRATEJİLERİNİN KARŞILAŞTIRMASI: MAKİNE ÖĞRENMESİ İLE Z-SKOR TAHMİNİ VE DİNAMİK EŞİK DEĞERİ BELİRLEME MODELLERİNİN İSTATİSTİKSEL ARBİTRAJ PERFORMANS ANALİZİ

COMPARATIVE ANALYSIS OF PAIRS TRADING STRATEGIES IN GLOBAL MARKETS:
EVALUATING STATISTICAL ARBITRAGE USING MACHINE LEARNING-BASED Z-SCORE
PREDICTION AND DYNAMIC THRESHOLDS

 Egemen KAHRAMAN¹

¹ Arş. Gör., Muğla Sıtkı Koçman Üniversitesi, İİBF, egemenkahraman@mu.edu.tr

Geliş Tarihi /Date Applied
15.01.2025

Kabul Tarihi / Date Accepted
24.02.2025

ÖZET

İstatistiksel arbitraja dayalı ikili işlem stratejilerinin modern makine öğrenmesi teknikleriyle birleştirilmesi, finansal piyasalarda işlem performansını artırmak için yenilikçi bir yaklaşım sunmaktadır. Çalışmada, altı önemli küresel piyasa endeksinden (FCHI, GDAXI, GSPC, HSI, IXIC ve N225) oluşan endeks verileri kullanılmıştır. İkili işlemlere uygun endeks çiftlerinin seçimi için öncelikle Genişletilmiş Dickey-Fuller (ADF) testi kullanılarak zaman serilerinin durağanlık analizi gerçekleştirilmiş, ardından Engle-Granger eşbütünlük testi ile arasında uzun dönemli ilişkinin varlığı tespit edilen endeks çiftleri belirlenmiştir.

Araştırmada, statik z-puanı eşiklerine dayalı temel stratejinin yanı sıra, Lojistik Regresyon, Rastgele Orman, XGBoost ve SVM gibi denetimli makine öğrenmesi tekniklerinin kullanıldığı hibrit bir yaklaşım geliştirilmiştir. Ayrıca, sürekli optimize edilen eşik değerlerine dayanan dinamik bir model de oluşturulmuştur. Stratejilerin performansı, Sharpe Oranı, Sortino Oranı, maksimum düşüş ve F1 skoru gibi metriklerle değerlendirilmiştir. Sonuçlar, dinamik eşik değeri ve makine öğrenmesi destekli modellerin geleneksel yaklaşımlara kıyasla üstün performans gösterdiğini ortaya koymuştur.

Anahtar Kelimeler: İstatistiksel Arbitraj, Makine Öğrenmesi, Eşbütünlük Analizi, Dinamik Eşikleme, Piyasa Endeksleri.

ABSTRACT

This study explores the integration of machine learning methodologies with traditional statistical arbitrage techniques to enhance performance in financial markets. Using data from six major global indices—CAC 40 (FCHI), DAX (GDAXI), S&P 500 (GSPC), Hang Seng (HSI), NASDAQ Composite (IXIC), and Nikkei 225 (N225)—the research applies the Augmented Dickey-Fuller (ADF) test to assess stationarity and the Engle-Granger cointegration test to identify statistically significant index pair relationships. The study evaluates three strategic approaches. First, a baseline strategy employs static z-score thresholds as a reference model. Second, a dynamic approach continuously adjusts threshold values in response to market fluctuations. Finally, a hybrid methodology incorporates machine learning algorithms—including Logistic Regression, Random Forest, XGBoost, and SVM—to enhance predictive capabilities. Performance is assessed using key financial metrics such as the Sharpe Ratio, Sortino Ratio, maximum drawdown, and F1 score. Results indicate that both dynamic thresholding and machine learning-augmented models outperform traditional approaches, offering improved risk-adjusted returns.

Keywords: Pairs Trading, Machine Learning, Cointegration Analysis, Dynamic Thresholding, Market Indices.

GİRİŞ

İstatistiksel arbitraja dayalı işlem stratejileri, finansal piyasalarda birbiriyle ilişkili enstrümanların geçmiş fiyat hareketleri arasındaki ilişkilerin analizine dayanan niceliksel bir yaklaşımdır. İstatistiksel arbitraj stratejileri arasında en yaygın olarak kullanılan yöntemlerin başında ise ikili işlem stratejileri gelmektedir. İkili işlem stratejileri, seçilen iki finansal varlık arasındaki fiyat sapmasının zaman içerisinde tarihsel ortalama seviyelerine geri döneceği (mean reversion) öngörüsüne dayanmaktadır. Bu varsayımdan hareketle oluşturulan ikili işlem stratejilerinde, seçilen finansal varlık çiftlerinin uzun vadeli fiyat ilişkilerinden meydana gelen geçici sapmalar, piyasa katılımcıları tarafından arbitraj fırsatı olarak değerlendirilmektedir. İkili işlem stratejileri, ilk kez 1980'lerde ABD merkezli yatırım bankası Morgan Stanley'de çalışan finans uzmanı Nunzio Tartaglia ve ekibi tarafından geliştirilmiştir. Tartaglia ve ekibi, belirli menkul kıymetler arasındaki fiyat hareketlerinin birbiriyle bağlantılı olduğunu keşfetmiş, çeşitli işlem çiftleri belirlemiş ve özellikle 1987'deki borsa çöküşünden (Kara Pazartesi) önce büyük başarı elde etmiştir (Caldeira ve Moura, 2012: 3). Zamanla, ikili işlem stratejileri birden fazla hisse senedinden, farklı sektörleri ve karmaşık portföyleri de kapsayacak şekilde geliştirilmiş ve sistematik olmayan risklere karşı korunma imkânı sağlamıştır. 1985-2000 yılları arasında ikili işlem stratejileri önemli kazançlar sağlamış, hedge fonlar ve kurumsal yatırımcılar tarafından yaygın olarak kullanılmıştır (Zhu, 2022: 470).

İkili işlem stratejilerinde, eşleşen çiftlerin belirlenmesi ve finansal işlem stratejilerinin geliştirilmesi için eş bütünleşme analizi, kopula yöntemi ve z skoru hesaplamaları gibi çeşitli ekonometrik yöntemler kullanılır. Ancak finansal piyasaların gelişmesi ve veri hacmindeki artış, geleneksel yöntemlerin büyük ölçekli verileri analiz etme ve aralarındaki bağlantıları keşfetme kapasitesini zorlamaktadır. Bu noktada, makine öğrenmesine dayalı yöntemler, ikili işlem stratejilerinin performansını artırmak için bir araç olarak öne çıkmıştır. Veriler arasındaki ilişkileri temsil eden desenlerin belirlenmesi ve bu ilişkilerin modellenmesi gibi alanlarda makine öğrenimi yöntemlerine dayalı uygulamalar giderek yaygın hale gelmektedir. İkili işlem stratejilerinin etkinliğini artırmak için makine öğrenmesi modelleri; piyasa anomalilerinin tespiti, alım-satım eşiklerinin optimizasyonu ve sinyal kalitesinin iyileştirilmesi gibi alanlarda çeşitli faydalar sağlamaktadır.

Bu çalışmada, istatistiksel arbitraja dayalı geleneksel ikili işlem stratejileriyle makine öğrenmesi tekniklerinin birleştirilmesinin etkinliği araştırılmaktadır. Araştırmanın veri seti, altı büyük küresel piyasa endeksinden (FCHI, GDAXI, GSPC, HSI, IXIC ve N225) oluşmaktadır. İlk olarak zaman serilerinin durağanlığı Genişletilmiş Dickey-Fuller (ADF) testi ile değerlendirilmiş, ardından istatistiksel açıdan anlamlı ve güçlü eş bütünleşik endeks çiftleri Engle-Granger eş bütünleşme testi ile belirlenmiştir. Analiz kapsamında uygulanan temel strateji, işlem sinyallerinin oluşturulmasında giriş ve çıkış noktaları için statik z-puanı eşiklerini temel almaktadır. Buna ek olarak, Lojistik Regresyon, Rastgele Orman, XGBoost ve SVM gibi makine öğrenmesi algoritmaları, farklı statik eşik değerleri için geçmiş fiyat farkı serileri üzerinde eğitilerek gelecekteki fiyat hareketlerini tahmin etmek ve alım-satım kararlarını iyileştirmek için kullanılmıştır. Dinamik eşiklendirmeye dayalı model ise, strateji süresince sabit eşik değerleri kullanmak yerine, eşik değerlerini sürekli olarak optimize ederek işlem gerçekleştirmiştir. Geliştirilen stratejiler; Sharpe Oranı, Sortino Oranı, maksimum düşüş ve F1 skoru gibi performans ölçütleriyle değerlendirilmiştir.

1. FİNANS ALANINDA İKİLİ İŞLEM STRATEJİLERİ

Finans alanındaki ikili işlem stratejileri, tarihsel veriler kullanılarak birlikte hareket eden iki yatırım enstrümanını belirleme esasına dayanır. Bu stratejilerde temel mantık, fiyatların birbirinden uzaklaştığı dönemlerde görece düşük değerlenmiş enstrümanı alıp yüksek değerlenmiş enstrümanı satmak, ardından fiyatlar denge noktasına döndüğünde pozisyonları kapatarak getiri elde etmektir. Zeng ve Lee (2014) ikili işlem stratejilerinde uygulanan adımları şu şekilde belirtmektedir:

- Eşleşen finansal enstrümanların belirlenmesi: Tarihsel veriler kullanılarak fiyatları birlikte hareket eden iki yatırım aracı seçilir. Bu yatırım araçlarının fiyat ortalamaları ve standart sapmaları hesaplanır.
- Stratejinin yürütülmesi: Enstrümanlar arasındaki fiyat oranı, belirlenen standart sapma sayısı kadar (genellikle iki standart sapma) uzaklaştığında, aşırı değerlenmiş enstrümanda satış, düşük değerlenmiş enstrümanda ise alış pozisyonları açılır. Bu eşik değeri, piyasa koşullarına veya diğer faktörlere bağlı olarak dinamik şekilde ayarlanabilir.
- İşlemlerin sonlandırılması: Fiyat oranları tekrar ortalama seviyeye döndüğünde pozisyonlar kapatılarak getiri elde edilir.

İkili işlem stratejilerinin başarılı olabilmesi için ilk aşama, eşleşen finansal enstrümanların doğru belirlenmesidir. Alan yazınında farklı yöntemler önerilmekle birlikte, en yaygın kullanılan yöntemler minimum mesafe yöntemi (The minimum distance approach), birleşik tahmin ve çok kriterli karar verme yöntemleri (Combined forecasts and multi-criteria decision methods) ile eşbütünleşme gibi ortalamaya geri dönüş modellemeleri (The modelling of mean reversion) olmak üzere üç ana kategoriye ayrılabilir (Huck ve Afawubo, 2015: 600).

1.1. Minimum Mesafe Yaklaşımı

Minimum mesafe yaklaşımı, genellikle düzeltme işlemi uygulanmış zaman serileri arasındaki metrikleri (örneğin, karelerinin toplamı) kullanarak iki finansal enstrüman arasındaki mesafeyi ölçer ve bu mesafeye dayalı olarak işlem çiftlerini belirler. Çiftler belirlendikten sonra, işlem sinyallerini oluşturmak için parametrik olmayan eşik kuralları kullanılır. Bu yöntem diğerlerine kıyasla daha basit olup kapsamlı ampirik analizler için uygundur (Krauss, 2017: 514). Minimum mesafe yönteminin en bilinen uygulamalarından biri Gatev, Goetzmann ve Rouwenhorst (2006) tarafından gerçekleştirilmiştir. Bu çalışmada, ABD hisse senetlerinin fiyatları normalize edildikten sonra, 12 aylık oluşum dönemlerinde normalize edilmiş fiyatlar arasındaki mesafe şu şekilde hesaplanmıştır:

$$D = \sum (P_{A(t)} - P_{B(t)})^2$$

$P_{A(t)}$ ve $P_{B(t)}$, A ve B hisselerinin t zamanındaki normalize edilmiş fiyatlarını gösterirken, t değeri T oluşum dönemi içindeki gün sayısını temsil eder. Tüm olası hisse senedi çiftleri için bu mesafe hesaplandıktan sonra, en yakın değerlere sahip hisseler eşleştirilir ve böylece en güçlü çiftler belirlenerek stratejiler uygulamaya konulur

1.2. Eş bütünleşme Yaklaşımı

Engle ve Granger (1987), eş bütünleşme yöntemine göre iki veya daha fazla zaman serisi, tek başlarına durağan olmasalar bile aralarında uzun dönemli bir denge ilişkisi varsa, bu seriler eş bütünleşik (koentegre) kabul edilir. Eş bütünleşme yöntemine göre:

$$Z_t = Y_t - \beta X_t$$

İki zaman serisi (Y_t ve X_t) durağan olmasa bile, bu seriler arasında uzun dönemli bir denge ilişkisi olabilir. Bu ilişki, Y_t serisinin X_t serisi ile β katsayısı kullanılarak doğrusal bir kombinasyonundan elde edilen Z_t serisi ile ifade edilir. Z_t Serisi zamanla durağan hale gelir ve ortalama etrafında sabit bir şekilde dalgalanarak uzun dönemde belirli bir denge noktasına geri döner. Bu durum, iki zaman serisinin eş bütünleşik olduğunu gösterir.

Engle-Granger İki Aşamalı Eş Bütünleşme Testi aşağıdaki adımlardan oluşur:

1. İlk adımda $Y_t = \beta X_t + \epsilon_t$ denklemi kullanılarak Y_t ve X_t serisi arasında regresyon analizi yapılır. Bu analiz sonucunda β katsayısı ve ϵ_t hata terimi hesaplanır.
2. İkinci adımda, hesaplanan ϵ_t hata terimi için Genişletilmiş Dickey-Fuller (ADF) testi kullanılarak durağanlık kontrolü yapılır. Eğer hata terimleri durağan ise (Y_t ve X_t) serilerinin eş bütünleşik olduğu kabul edilir.

Eş bütünleşme ilişkisi tespit edilen iki finansal varlık arasındaki ilişki, fiyat farkı serisi $F_t = Y_t - \beta X_t$ şeklinde ifade edilir. Burada F_t , iki finansal enstrümanın fiyatları arasındaki denge noktasından sapmayı temsil ederken, β katsayısı Y_t ve X_t arasındaki uzun vadeli ilişkiyi belirler. Bu denklem, fiyatlar arasındaki uzun vadeli dengenin sapmasını ifade eder. Vidyamurthy (2004) ise Granger Teoremini temel alarak, eş bütünleşme ilişkisi Hata Düzeltme Modeli (Error Correction Model - ECM) çerçevesinde incelemiştir. ECM, fiyat farklılıklarında görülen sapmaları gidermeye yönelik bir düzeltme mekanizması sunarak finansal işlem stratejilerinin temelini oluşturur. Bu model, eş bütünleşik zaman serilerinin hem kısa hem de uzun vadeli ilişkilerini bir arada ele alır. Modele göre, eş bütünleşik seriler uzun vadede dengeye ulaşırken, kısa vadede ortaya çıkan sapmalar ECM'nin hata terimi vasıtasıyla düzeltilir. ECM denklemi aşağıdaki gibi ifade edilir:

$$\Delta Y_t = \alpha_y(\epsilon_{t-1}) + \beta_1 \Delta Y_{t-1} + \beta_2 \Delta X_{t-1} + \eta_t$$

Denklemdaki parametreler şu şekildedir:

- ΔY_t : Y_t zaman serisinin ardışık iki dönem arasındaki farkını ve dolayısıyla Y_t 'deki değişimi gösterir.
- ϵ_{t-1} : Bir önceki dönemde uzun vadeli dengeden meydana gelen sapmayı temsil eder. Bu sapma $\epsilon_t = Y_t - \beta X_t$ formülü ile hesaplanır. β Katsayısının sıfırdan farklı olması, zaman serilerinin dengeden saptığını gösterir. Önceki dönemde oluşan ϵ_{t-1} farkı, sistemin bir önceki dönem dengesinden sapmasını ifade eder ve bu farkın zamanla kapanması beklenir.
- α_y : Dengeye dönüş hızını gösteren ayarlama parametresidir. Bu katsayının değeri arttıkça dengeye dönüş hızı artar. İşareti (pozitif veya negatif olması) ise zaman serileri arasındaki düzeltmenin yönünü belirler
- $\beta_1 \Delta Y_{t-1}$ ve $\beta_2 \Delta X_{t-1}$: önceki dönemde X_t ve Y_t serilerinde gerçekleşen değişimlerin Y_t üzerindeki kısa vadeli etkisini inceler.
- η_t : Modelin açıklayamadığı kısmı temsil eden hata terimidir (gürültü terimi).

Eş bütünleşik finansal varlıklar arasındaki denge durumunun bozulması halinde ($\epsilon_t \neq 0$), sistemin tekrar dengeye dönüş hızı ve yönünü α_y parametresi açıklar. İstatistiksel arbitraja dayalı ikili işlem stratejilerinde ECM önemli bir rol oynar. Model, eş bütünleşik olan iki finansal enstrüman arasında oluşan kısa vadeli sapmaları tespit eder ve fiyatların denge noktasına ne zaman ve hangi yönde geri döneceğini tahmin etmeye yardımcı olur. Nitekim Rad, Low ve Faff

(2016), finansal işlem sinyallerinin oluşturulmasını Vidyamurthy'nin (2004) ortaya koyduğu ECM modelini kullanarak şu şekilde açıklamaktadır:

Alım ve Satım Sinyallerinin Oluşturulması:

İstatistiksel arbitraj stratejilerinde, fiyat farkı serisinin dengeden sapması, finansal varlıklar üzerinde geçici bir fiyat hareketi olarak değerlendirilir ve bu durum bir işlem fırsatı yaratır. Bu sapma, pozitif veya negatif olarak sıfırdan farklı bir değer aldığı anda ortaya çıkar.

Fiyat farkı serisi $F_t = Y_t - \beta X_t$ pozitif olduğunda, birinci varlığın (Y_t) fiyatı, ikinci varlığın (X_t) fiyatına göre beklenenden daha yüksek seviyede demektir. Bu durumda:

- Birinci varlık uzun vadeli dengenin üzerinde, yani aşırı değerlendirilmiş durumdadır ve bu varlık için satış pozisyonu açılır
- İkinci varlık düşük değerlendirilmiş durumdadır ve bu varlık için alım pozisyonu açılır

Bu strateji uygulandığında, fiyatlar tekrar dengeye dönerken (fiyat farkı serisi sıfıra yaklaşırken) pozisyonlar kapatılarak fiyatlardaki düzeltme hareketinden kâr elde edilir.

1.3. Zaman Serisi Yaklaşımı

Elliott, Van Der Hoek ve Malcolm (2005) iki farklı finansal enstrüman arasındaki fiyat farkını, ortalamaya dönme eğiliminde olan bir zaman serisi şeklinde durum uzay modeli ile incelemişlerdir. Modelde, iki finansal varlık arasındaki fiyat farkının zaman içindeki değişimi, "gizli durum değişkeni" olarak adlandırılan ve doğrudan gözlemlenemeyen bir bileşen ile açıklanmaktadır. Bu gizli durum değişkeninin değeri, normal dağılıma sahip bir Markov süreci ile modellenmiştir. Bu modelde normal dağılımın tercih edilmesinin nedeni, fiyat farklarının genellikle belirli bir ortalama değer etrafında simetrik olarak dalgalanma göstermesidir. Markov süreci ise fiyat farkının, yalnızca bir önceki zaman dilimindeki değerine bağlı olarak değiştiğini ifade etmektedir. Krauss (2017) bu süreci şu şekilde özetlemektedir:

Gözlemlenemeyen (gizli) x_k değişkeni için durum denklemi şöyle tanımlanır:

$$x_{k+1} - x_k = (a - bx_k)\tau + \sigma\sqrt{\tau}\varepsilon_{k+1}$$

Denklemdaki a ve σ pozitif sabit değerlerdir. Modeldeki, a sürecin ortalama seviyesine dönme eğilimini, σ ise rastgele dalgalanmaların (volatilitenin) gücünü ifade eder. B parametresi ise modelin ortalama seviyesine(dengeye) dönüş hızını belirler. Dolayısı ile süreç b kuvveti ile $\mu = \frac{a}{b}$ ortalamasına geri döner. $\varepsilon_{(k+1)}$ Gauss gürültüsü sürecin rastgelelik bileşenidir ve Gauss dağılımına sahip bir rasgele değeri ifade eder.

Sürekli zaman için ise durum denklemi şu şekildedir:

$$dX_t = \rho(\mu - X_t)dt + \sigma dW_t$$

Denklemdaki ρ parametresi sürecin ortalama değer olan μ etrafına dönüş hızını ifade eder. σdW_t ise, rastgele dalgalanmaları temsil eden bir Brown modeli bileşenidir ve süreçte rastgelelik katar. Brown modeli, stokastik (rastgele) bir süreç olup, finansal piyasalar gibi rastgele dalgalanan sistemleri modellemek için kullanılır.

Ölçüm denklemi ise gözlemlenen fiyat farkının y_k olduğu durumda gizli durum değişkeni x_k ile Gauss gürültüsünden $D\omega_k$ oluşur:

$$y_k = x_k + D\omega_k, D > 0$$

(Elliott vd., 2005) zaman serisi modelinde gözlemlenen fiyat farkı belirli bir eşik değerinin dışına çıktığında işlem açılır. Bu yaklaşım, Kalman Filtresi kullanımı ve yeni verilere uyum sağlayan güncel tahminler sayesinde dinamik bir yapıya sahiptir ve pratikte etkili sonuçlar verebilmektedir. Ancak, modelin genellikle benzer hareket gösteren varlık çiftlerinde daha iyi performans göstermesi ve Gauss dağılımı varsayımına dayanması, uygulamadaki en büyük dezavantajlarını oluşturmaktadır

1.4. Diğer Yaklaşımlar

Finansal alanda ikili işlem stratejilerinde uygulanan temel yaklaşımların yanı sıra, literatürde makine öğrenmesi tabanlı yaklaşımlar ve kopula yöntemleri gibi farklı teknikler de yer almaktadır

1.4.1. Makine Öğrenimi Temelli Yaklaşımlar

Makine öğrenmesine dayalı farklı tekniklerin ikili alım-satım stratejilerindeki başarısı, çeşitli performans metrikleri üzerinden kanıtlanmıştır. Bu noktada Sharpe oranı, risk-getiri ilişkisini ölçen temel bir gösterge olarak öne çıkmaktadır. Sarmiento ve Horta (2020) tarafından yapılan araştırmada, makine öğrenmesine dayalı yöntemler temelli stratejilerin geleneksel yöntemlere kıyasla daha yüksek Sharpe oranları ürettiği gösterilmiştir. Bunun temelinde makine öğrenmesi yöntemlerinin ilgili işlem stratejilerine doğru bir şekilde entegre edilmesi sonucu gözlemlenen gelişmiş sinyal üretimi yatmaktadır. Makine öğrenmesi algoritmaları, alım satım noktalarının belirlendiği eşik değerleri ve z skoru hesaplamalarında daha hassas giriş ve çıkış noktalarının oluşturulmasını sağlarken, yanlış sinyalleri minimize etmekte ve piyasa dönüş noktalarını daha doğru tespit edebilmektedir. Nitekim Kim ve Kim (2019) derin pekiştirmeli öğrenme tekniğinin alım-satım ve stop-loss sınırlarını etkili bir şekilde optimize edebildiğini, böylece daha hassas giriş ve çıkış noktaları oluşturabildiğini göstermiştir. Araştırmaları, ML destekli stratejilerin maksimum düşüş riskini azaltırken getiri düzeyinde de artış sağladığını ortaya koymuştur. İkili işlem stratejilerinde optimal eşik değeri belirlenmesine yönelik bir diğer çalışma ise Bağcı ve Soylu (2024) tarafından gerçekleştirilmiştir. Bu çalışmada Binance borsasından alınan 50 kripto varlığın dakikalık verileri üzerinde uygulanan HFPT algoritması ile maksimum getiri sağlayan optimal eşik değerleri tespit edilmiştir. Portföylerin istatistiksel özelliklerinden oluşturulan veri seti üzerinde üzere çeşitli denetimli makine öğrenimi algoritmaları uygulanmış ve optimal eşik aralığı tahmin edilmiştir. Random Forest algoritmasının farklı korelasyon seviyelerindeki çiftler için en yüksek sınıflandırma başarısını gösterdiği ve doğru eşik aralığı belirlemenin getiri düzeyini artırdığını ortaya konmuştur. Ayrıca Fu, Kang, Hong ve Kim (2024) tarafından vurgulandığı gibi, geleneksel ikili alım-satım istatistiksel arbitraja dayanırken, ML teknikleri hem stratejinin kârlılığını hem de risk yönetimi yeteneklerini önemli ölçüde geliştirmiştir. Dinamik stop-loss seviyelerinin belirlenmesi, pozisyon büyüklüğünün optimize edilmesi ve portföy riskinin gerçek zamanlı izlenmesi gibi uygulamalar, stratejilerin dayanıklılığını artırmaktadır

1.4.2. Kopula Yaklaşımı

Liew ve Wu' ya (2013) göre, Kopula yaklaşımı finansal piyasalarda önemli bir işlem yaklaşımı olarak öne çıkmaktadır. Bu yaklaşım, geleneksel ikili işlem stratejilerinin dayandığı korelasyon ve eş bütünleşme tekniklerinin ötesine geçerek, finansal varlıklar arasındaki karmaşık ve doğrusal olmayan ilişkileri daha kapsamlı bir şekilde modelleyebilmektedir. Kopula yönteminin uygulanması iki temel aşamadan oluşmaktadır: İlk aşamada, incelenen her bir finansal varlığın marjinal dağılımları ayrı ayrı tahmin edilir. İkinci aşamada ise, bu marjinal dağılımlar

kullanılarak en uygun kopula fonksiyonu belirlenir ve böylece finansal varlıklar arasındaki ortak bağımlılık yapısı ortaya çıkarılır.

Bu yöntemin en önemli avantajlarından biri, finansal piyasalarda sıkça karşılaşılan asimetrik dağılımları ve uç değer bağımlılıklarını başarılı bir şekilde tespit edebilmesidir. Bu sayede, geleneksel yöntemlere kıyasla daha hassas ve güvenilir alım-satım sinyalleri üretilebilmektedir. Bu özelliği, Kopula yaklaşımını özellikle risk yönetimi ve portföy optimizasyonu açısından kullanışlı bir araç haline getirmektedir

2. ALANYAZIN İNCELEMESİ

Alan yazınında ikili işlem stratejilerini inceleyen çalışmalar, yıllar içerisinde çeşitli metodoloji ve yaklaşımları birleştirerek, stratejilerin kârlılığını ve verimliliğini artırmak konusunda önemli gelişmeler kaydetmiştir. Bu bölümde, ikili işlem stratejilerinde kullanılan yaklaşımlar sınıflandırılmış ve her yaklaşım altında öne çıkan çalışmalar incelenmiştir.

2.1. Minimum Mesafe Yaklaşımı

Minimum mesafe yönteminin en kapsamlı akademik çalışması Gatev, Goetzmann ve Rouwenhorst (2006) tarafından gerçekleştirilmiştir. Araştırmacılar, 1962-2002 yılları arasında CRSP (Güvenlik Fiyatları Araştırma Merkezi) veri tabanını kullanarak ABD hisse senetleri üzerinde bir çalışma yürütmüşlerdir. Çalışmada, normalize edilmiş fiyat serileri oluşturulmuş ve en düşük kare farklarına sahip hisse senedi çiftleri seçilmiştir. Oluşturulan finansal varlık çiftlerinin fiyat farkı, formasyon döneminde tarihsel ortalamanın iki standart sapma üzerine çıktığında alım-satım pozisyonları açılmış ve fiyatlar ortalamaya döndüğünde bu pozisyonlar kapatılmıştır. Sektörel bazda yapılan analizlerde, aynı sektördeki hisse senetlerinin benzer getiri özelliklerine sahip olduğu gözlemlenmiştir. Uygulanan strateji, işlem maliyetleri düşüldükten sonra yıllık ortalama %11 ek getiri sağlamış ve etkin piyasalar hipotezi reddedilmiştir. Nath (2003) ise benzer bir mesafe yöntemini ABD Hazine tahvilleri üzerinde uygulamış, ancak işlem çiftlerinin seçiminde farklı bir yaklaşım benimsemiştir. Nath' in analizinde, tahviller arasında herhangi bir ön eleme yapılmadan tüm olası çiftler değerlendirilmiş ve mesafe ölçümleri tarihsel verilere dayalı bir dağılım kullanılarak incelenmiştir. Bu stratejide, iki finansal varlığın fiyat farkı %15'lik üst sınırı aştığında işlem pozisyonları açılmış, fiyatlar %5'lik alt sınırın altına düştüğünde ise stop-loss mekanizması devreye girerek pozisyonlar kapatılmıştır. Analiz sonuçları, tahvil ve bono gibi sabit getirili menkul kıymetlerde işlem maliyetleri ve karşı taraf bulma zorlukları gibi sebepler nedeniyle getiri düzeyinin sınırlı kaldığını göstermiştir.

Do, Faff ve Hamza (2006) ise, Gatev ve diğerlerinin (2006) çalışmasını genişleterek 1962-2010 yıllarını kapsayan daha geniş bir ABD hisse senedi veri tabanı kullanmıştır. Gerçekleştirilen analizde benzer yöntem, farklı formasyon ve işlem dönemleri için tekrar uygulanmıştır. Araştırma sonuçları, 2002 yılından sonra minimum mesafe yönteminin kârlılığının azaldığına işaret etmektedir. CRSP veri tabanı kullanılarak tüm ABD hisse senedi piyasasında gerçekleştirilen bir diğer önemli çalışma, Rad, Low ve Faff (2016) tarafından yürütülmüştür. Araştırmacılar bu çalışmada minimum mesafe yöntemi ile eş bütünleşme ve kopula tabanlı ikili işlem yöntemlerini kıyaslamıştır. Analiz bulguları, 2008 finansal krizi sonrasında Minimum Mesafe Yöntemi'nin kârlılığının azaldığını ve yüksek fiyat oynaklıklarının yaşandığı dönemlerde stratejinin zayıf performans sergilediğini ortaya koymuştur. Araştırmacılar, minimum mesafe yönteminin sadeliği nedeniyle tercih edildiğini, ancak karmaşık piyasa koşullarında diğer yöntemlere kıyasla performansının geride kaldığını belirtmişlerdir. Benzer bir sonuç Huck ve

Afawubo (2015) tarafından da vurgulanmış ve minimum mesafe yaklaşımının tahmin gücünün diğer yaklaşımlara göre daha düşük olduğu belirtilmiştir.

2.2. Eş Bütünleşme Yaklaşımı

Finansal piyasalarda eş bütünleşme yaklaşımının ikili işlem stratejilerindeki ilk uygulaması Hong ve Susmel (2003) tarafından Asya piyasalarındaki Amerikan Mevduat Makbuzları (ADR'ler) ve bunların dayanak varlıkları üzerinde gerçekleştirilmiştir. Çalışmada, seçilen uygun varlık çiftlerinde fiyat farkı beklenen seviyeye ulaştığında, "kazanan" olarak nitelendirilen ADR'ler satılıp dayanak varlıklar alınmıştır. Bir yıllık dönem sonunda stratejinin yıllık %33 kâr sağladığı gözlemlenmiştir. Literatürde eş bütünleşme yaklaşımı konusundaki en dikkat çekici çalışma ise Vidyamurthy (2004) tarafından yapılmıştır. Nitekim Vidyamurthy (2004) "Pairs Trading: Quantitative Methods and Analysis" adlı kitabında ilk olarak OLS regresyonu kullanarak finansal varlıklar arasındaki uzun vadeli denge ilişkisini incelemiş ve bu analizden elde edilen hata terimlerine ADF testi uygulamıştır. Eş bütünleşme ilişkilerinin tespitinin ardından, klasik yöntemi bir adım öteye taşıyarak Kalman filtresi uygulamış ve böylece fiyat dalgalanmalarını daha hassas bir şekilde modelleyebilmiştir. Caldeira ve Moura (2013) ise, Brezilya Bovespa Borsası'ndaki günlük kapanış verilerini kullanarak eş bütünleşme ilişkisinin tespitinde hem Engle-Granger iki aşamalı testini hem de Johansen testini uygulamıştır. İki yöntemin birlikte kullanılması ile, tüm hisse senetleri arasından uzun vadeli denge ilişkisi gösteren çiftler belirlenmiştir. Geliştirilen strateji, kayda değer bir yıllık ortalama getiri sağlamış ve güçlü bir Sharpe oranı elde etmiştir. Stratejinin düşük volatilité ve piyasa ile düşük korelasyon göstermesi, piyasa nötr bir karaktere sahip olduğunu ortaya koymuştur. Elde edilen sonuçlar, stratejinin küresel kriz dönemlerinde bile istikrarlı bir performans sergilemesi, eş bütünleşme yaklaşımının finansal stratejilerdeki uygulanabilirliğini güçlü bir şekilde desteklemiştir.

İkili işlem stratejilerinde eş bütünleşme yaklaşımının kayıplarını azaltmak için de çeşitli uygulamalar test edilmiştir. Örneğin Lin, McCrae ve Gulati (2006), işlem risklerini azaltmak amacıyla minimum getiri düzeyi hedefleyen kurallar geliştirmiştir. Bu amaçla eş bütünleşme ilişkisine sahip finansal varlıklarla yürütülen stratejilerde kayıpları sınırlandırmak ve her işlemde belirli bir minimum kâr seviyesini garanti etmek için alım-satım kurallarına ek özel koşullar eklenmiştir. Australia New Zealand Bank (ANZ) ve Adelaide Bank (ADB) hisse senetleri üzerinde yapılan simülasyonlar ve analizler, minimum getiri düzeyi kuralları belirleyen stratejilerin performansı artırdığını ve riski azalttığını göstermiştir. Chiu ve Wong (2015) ise dinamik programlama tekniği ve Hamilton-Jacobi-Bellman (HJB) denklemi ile dinamik ikili işlem stratejilerini test etmiştir. Dinamik programlama ile finansal varlık fiyatlarındaki değişimlerin zaman içinde optimize edilmesi hedeflenmiştir. Çalışmada, HJB denklemi kullanılarak eş bütünleşmiş varlıkların ortalamaya dönme (mean reversion) davranışı modellenmiş ve optimal işlem sinyalleri belirlenmiştir. Analiz sonuçları, uygulanan dinamik stratejilerin klasik yöntemlere kıyasla daha yüksek risk ayarlı getiri (risk-adjusted return) sağladığını göstermiştir. Buradan da anlaşılmaktadır ki, eş bütünleşme stratejilerinin sunduğu istatistiksel arbitraj fırsatları, dinamik modeller ile daha etkili bir şekilde değerlendirilmekte ve uzun dönemde istikrarlı getiri elde edilebilmektedir.

Bogomolov (2011), Avustralya Borsası'nda (ASX) üç farklı ikili işlem stratejisi yaklaşımının performansını karşılaştırmalı olarak incelemiştir. Çalışma, eş bütünleşme ve minimum mesafe yöntemlerinin işlem maliyetleri dikkate alındığında nispeten başarılı olduğunu; ancak stokastik

kontrol yönteminin daha fazla işlem gerçekleştirmesi nedeniyle kârlılığını koruyamadığına işaret etmektedir.

2.3. Zaman Serisi Yaklaşımı

Elliott, Van Der Hoek ve Malcolm (2005) ikili işlem stratejilerini zaman serileri bağlamında modellemek için ortalamaya dönen Markov özelliği gösteren ve normal dağılıma sahip bir model geliştirmişlerdir. Bu model, benzer iki finansal varlık arasındaki fiyat farkının Ornstein-Uhlenbeck süreci ile ortalamaya dönme eğilimi gösterdiğini öne sürmektedir. Araştırmacılar, Kalman filtresi kullanarak fiyat farkının açıklanamayan bileşenlerini tahmin etmiş ve buna dayalı alım-satım sinyalleri oluşturmuşlardır. Model, finansal varlıklar arasındaki fiyat farkının tahmin edilen değerden belirgin şekilde sapması durumunda alım veya satım pozisyonları açılmasını önermektedir. Çalışmada parametre tahmini için Expectation-Maximization (EM) algoritması kullanılmış ve iki farklı yaklaşım sunulmuştur: çevrimdışı Shumway-Stoffer yöntemi ve çevrimiçi Elliott-Krishnamurthy yöntemi. Araştırma, doğru sinyal üretimi açısından ortalamaya dönüş varsayımının ve model kalibrasyonunun kritik önemini vurgulamaktadır.

Ornstein-Uhlenbeck modelinin bir diğer uygulaması Cummins ve Bucca (2012) tarafından 2003-2010 dönemindeki WTI, Brent, ısıtma yağı ve gaz yağı verileri üzerinde gerçekleştirilmiştir. Bertram (2010) modelini temel alan bu çalışmada araştırmacılar, alım-satım seviyelerini analitik olarak belirleyerek beklenen getiriye maksimize etmeyi amaçlamışlardır. Ornstein-Uhlenbeck modeli, ortalamaya dönüş sinyallerinin tespitinde kullanılmıştır. Analiz sonuçları, Sharpe oranlarının genellikle 2'nin üzerinde olduğunu göstererek stratejilerin kârlılığını ortaya koymuştur. Bununla birlikte, 2008 finansal krizi sürecinde stratejilerin performansında ve kârlılığında önemli düşüşler gözlenmiştir. Bu bulgu, modelin dalgalı piyasa koşullarına karşı duyarlılığını göstermektedir.

2.4. Makine Öğrenmesine Dayalı Yaklaşımlar

İkili işlem stratejilerinde teknolojik gelişmelerle birlikte çeşitli makine öğrenmesine dayalı teknikler uygulanmaya başlanmıştır. Bu teknikler arasında Destek Vektör Makineleri (Support Vector Machines-SVM) algoritması öne çıkmaktadır. Wu (2015), Google'ın çift sınıf hisse senetleri (GOOG ve GOOGL) üzerine kurguladığı işlem stratejisinde SVM algoritmasını kullanarak, gerçekleşen fiyat farkları ile teknik göstergelerden türetilen işlem sinyallerini analiz etmiştir. Bu kapsamda temel ikili işlem yaklaşımlarını geliştirerek, momentum ve Göreceli Güç Endeksi (RSI) gibi teknik göstergeleri de modele entegre etmiştir. Ampirik bulgular, geliştirilen SVM tabanlı modelin yüksek tahmin performansı sergilediğini ortaya koymuştur. Geriye dönük testler neticesinde, önerilen stratejinin piyasa dalgalanmalarına karşı da güçlü bir direnç gösterdiği tespit edilmiştir. Chaudhuri, Ghosh ve Singh (2017), Hint borsasında işlem gören hisse senetlerinin günlük fiyatları ve teknik göstergeleri için SVM'nin yanı sıra Rastgele Orman (RF) ve Adaptif Nöro-Bulanık Çıkarım Sistemi (ANFIS) algoritmalarını uygulamıştır. Çalışmada momentum ve Bollinger Bantları gibi teknik göstergeler SVM modelinde kullanılmıştır. Elde edilen bulgular, Wu'nun (2015) sonuçlarıyla paralellik göstererek, SVM modelinin yüksek tahmin doğruluğuna ve diğer yöntemlere kıyasla daha düşük hata oranına sahip olduğunu ortaya koymuştur. Baek, Glambosky, Oh ve Lee (2020) ise SVM tekniğini Hata Düzeltme Modeli (ECM) çerçevesinde kullanmıştır. Araştırmada, ABD vadeli işlem piyasalarından elde edilen veriler kullanılarak COVID-19 pandemi döneminde test edilmiştir. SVM modeli, iki aşamalı Engle-Granger eşbütünlük yöntemi temelinde, eşbütünlük finansal varlık çiftlerinin uzun vadeli ilişkisini kullanarak hedge oranını optimize etmiştir. Yürütülen analiz sonuçları, önerilen

stratejinin bilhassa ani piyasa düşüşleri esnasında portföy korumasına önemli katkı sağladığını ve risk-ayarlı getirilerin yüksek olduğunu göstermiştir.

İkili işlem stratejilerinde kullanılan temel yöntemlerle yapay sinir ağları (Feedforward Neural Network- FNN ve Recurrent Neural Network - RNN) modellerinin karşılaştırmalı analizi literatürde giderek daha fazla yer edinmektedir. Van der Have, van Dijk, Kole, Eisma ve Diepen (2017), NYSE Arca borsasında işlem gören Borsa Yatırım Fonları (Exchange Traded Funds - ETFs) üzerine gerçekleştirdiği çalışmada, klasik eş bütünleşme ve minimum mesafe gibi işlem çiftlerini belirleme tekniklerini uygulayarak, ortalama geri dönüş (mean-reverting) özelliği gösteren çiftlerin belirlenmesinde kapsamlı bir analiz sunmuştur. Elliott ve diğerlerinin (2005) önerdiği stokastik yöntemlerin uygulandığı çalışmada, bu yöntemlerin lineer varsayımlarına karşın, RNN modelinin zaman serisi verilerindeki karmaşık ve uzun vadeli bağımlılıkları yakalamada daha başarılı olduğu tespit edilmiştir. Analiz sonuçları, RNN modelinin geleneksel yöntemlere kıyasla daha yüksek getiri sağladığını ve daha üstün risk-getiri performans metriklerine sahip olduğunu ortaya koymuştur. Chen, Wang ve Sun (2022) ise geleneksel ekonometrik yöntemler ile LSTM (Long Short-Term Memory) modeli gibi derin öğrenme yaklaşımlarını entegre ederek hisse senetleri ve kripto paraları kapsayan yenilikçi bir ikili işlem stratejisi geliştirmiştir. Çalışmada, çeşitli hisse senetleri ve kripto para birimlerinin Yahoo Finance verileri kullanılarak oluşturulan veri seti üzerinde korelasyon ve eş bütünleşme analizleri uygulanmıştır. LSTM modelinin, ARIMA, SARIMA, VAR ve Prophet gibi geleneksel zaman serisi modellerine kıyasla daha düşük hata oranı ve daha yüksek açıklayıcılık gücü sergilediği tespit edilmiştir. Model, özellikle yüksek piyasa dalgalanmalarının gözlemlendiği dönemlerinde daha istikrarlı performans göstermiştir.

3. METODOLOJİ

3.1. Veri Seti

Çalışmanın veri seti ikili işlem stratejilerinin farklı coğrafi ve ekonomik bölgeleri temsilen küresel endekslerin tarihsel verilerinden oluşmaktadır. Her bir endeksin günlük kapanış fiyatlarına ait tarihsel veriler, Python kütüphanesi olan “yfinance” aracılığıyla elde edilmiştir. Veri aralığı, 1 Ocak 2014 ile 1 Ocak 2024 arasındaki 10 yıllık bir dönemi kapsamaktadır. Veri işleme ve analiz işlemleri için Google Colab Platformu kullanılmıştır. Google Colab, bulut teknolojisi ile Python kodlarını çalıştırma imkanı sağlayarak, analiz sürecini hızlandırmıştır. Analiz kapsamında veri setine dahil edilen endeksler şu şekildedir:

- CAC 40 (FCHI), Fransa'nın en büyük 40 şirketini içeren piyasa endeksidir. Endeks, Fransız ekonomisinin genel performansını ve Avrupa piyasalarının bir kısmını yansıtmaya açısından önemli bir ölçüttür.
- DAX (GDAXI), Almanya: DAX (Deutscher Aktienindex), Frankfurt Menkul Kıymetler Borsası'ndaki en büyük 40 Alman şirketini içerir.
- S&P 500 (GSPC), ABD: S&P 500, ABD'nin en büyük 500 halka açık şirketinin performansını ölçer. Piyasa değeri ağırlıklı bir endekstir.
- Hang Seng Endeksi (HSI): Hang Seng Endeksi, Hong Kong Menkul Kıymetler Borsası'ndaki en büyük 50 şirketi içeren bir endekstir ve Asya piyasalarının genel performansını yansıtmaya açısından önemlidir.

- NASDAQ Composite (IXIC), ABD: NASDAQ Composite, NASDAQ borsasında işlem gören 3.000'den fazla şirketin performansını ölçer. Teknoloji şirketlerinin ağırlıkta olduğu bir endekstir.
- Nikkei 225 (N225), Japonya: Nikkei 225, Tokyo Menkul Kıymetler Borsası'ndaki en büyük 225 şirketin performansını ölçer. Japonya ekonomisi ve Asya-Pasifik bölgesindeki ekonomik aktiviteleri değerlendirmek için referans noktası oluşturur.

Veri setine ait betimleyici istatistikler şu şekildedir:

Tablo 1. Veri Setinin Betimleyici İstatistikleri

	İlk Gözlem Tarihi	Son Gözlem Tarihi	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	Medyan	Maksimum
IXIC	2014-01-01	2024-01-01	2609	10782,4	451,9786	10000	10782,4	11564,8
N225	2014-01-01	2024-01-01	2609	22326	188,3244	22000	22326	22652
FCHI	2014-01-01	2024-01-01	2609	5652	376,6489	5000	5652	6304
GDAXI	2014-01-01	2024-01-01	2609	12391,2	225,9893	12000	12391,2	12782,4
GSPC	2014-01-01	2024-01-01	2609	3521,6	301,3191	3000	3521,6	4043,2
HSI	2014-01-01	2024-01-01	2609	25260,8	150,6595	25000	25260,8	25521,6

Ham veri setinde tüm endekslerdeki hafta sonları, resmî tatiller gibi eksik veri noktaları temizlenmiştir. Farklı endekslerde oluşan eksik noktalar ise, zaman serisi analizine engel olabileceği için ileriye dönük doldurma (forward-fill) yöntemi ile kendisinden önce gelen en son geçerli veri noktası ile doldurulmuştur.

3.2. Durağanlık Kontrolü ve İkili İşlem Çiftlerinin Seçimi

Veri setini oluşturan zaman serilerinin durağan olup olmadığını belirlemek için Augmented Dickey-Fuller (ADF) testi uygulanmıştır (Dickey & Fuller, 1979). Bu kapsamda veri setindeki tüm zaman serileri için aşağıdaki modelin regresyon analizi gerçekleştirilmiştir:

$$\Delta y_t = \alpha + \beta_t + \gamma y_{t-1} + \sum_{i=1}^p \phi_i \Delta y_{t-i} + \epsilon_t$$

ADF testinde analiz edilen zaman serisi y_t ile ifade edilir ve serinin durağanlığını sağlamak için birinci farkı alınır. Modelde, α (alfa) sabit terimi serinin sabit bir ortalamaya sahip olup olmadığını kontrol ederken, β (beta) terimi serinin doğrusal bir trend içerip içermediğini analiz eder. Gecikmeli değerlerin katsayısı olan γ (gamma) ise, serinin durağan olup olmadığını belirlemede kullanılır. Ayrıca, otokorelasyonu gidermek amacıyla farkların katsayıları ϕ modele dahil edilir. Modeldeki rastgele bileşen ise hata terimi (ϵ) olarak tanımlanır.

Testin hipotezleri şu şekildedir:

H₀: Zaman serisi birim kök içerir (durağan değildir).

H_1 : Zaman serisi birim kök içermez (durağandır).

Altı farklı finansal endeks için yapılan ADF test sonuçları aşağıdaki gibidir:

Tablo 2: Finansal Endekslerin Zaman Serisi Durağanlık Analizi (ADF Testi)

Endeks	ADF İstatistiği	p-değeri
FCHI	-1,2086	0,6699
GDAXI	-1,5092	0,529
GSPC	-0,2772	0,9287
HSI	-1,6135	0,4761
IXIC	-0,3411	0,9195
N225	-0,6611	0,8566

Tabloda yer alan sonuçlara göre p-değerleri tüm endeksler için %5 anlamlılık seviyesinden büyüktür. Bu nedenle, tüm zaman serilerinde H_0 reddedilmeyerek endekslerin durağan olmadığı kabul edilmiştir. Bu nedenle tüm endekslerde her gözlem değerinden bir önceki gözlem değerini çıkarılarak ($X_t - X_{t-1}$) fark alma işlemi uygulanmıştır.

Zaman serilerinin durağan hale getirilmesinin ardından zaman serileri arasındaki uzun vadeli denge ilişkisinin belirlenmesi ve ikili işlem çiftlerinin seçimi için Augmented Engle-Granger İki Aşamalı Eş Bütünleşme Testinden yararlanılmıştır. Bu kapsamda:

$$y_t = \beta_0 + \beta_{1xt} + \epsilon_t$$

y_t ve x_t eş bütünleşme testi uygulanan iki zaman serisidir. β_0 ve β_1 doğrusal regresyon katsayılarını temsil ederken, artık (residual) terim olan ϵ_t ise iki serinin uzun vadeli denge ilişkisine olan sapmasını temsil eder. ϵ_t 'nin durağan olması eşbütünleşmenin varlığına işaret etmektedir. Her çift için eşbütünleşme testi gerçekleştirilmiş ve 0.01 anlamlılık düzeyinde anlamlı p değerine sahip olan ve eş bütünleşme istatistiği en güçlü olan çiftler aşağıda sıralanmıştır:

Tablo 3: En Güçlü Eş Bütünleşme İstatistiklerine Sahip Eş Bütünleşme Testi Sonuçları

Endeks 1	Endeks 2	p-değeri	Koentegrasyon İstatistiği
GDAXI	N225	0	-59,13708947
FCHI	N225	0	-58,67746173
GDAXI	IXIC	0	-56,15649553
FCHI	IXIC	0	-55,53675479

Eş bütünleşme testi sonuçlarına göre, p-değeri 0.01'den küçük olan çiftler tespit edilmiştir. Tablo 3'te sunulan ikili endeksler arasında güçlü ve istatistiksel olarak anlamlı uzun vadeli ilişkilerin varlığı kabul edilmiş ve ikili işlem stratejileri bu endekslerde test edilmiştir.

3.3. İkili İşlem Stratejilerinin Oluşturulması

İkili işlem stratejilerinin karşılaştırmalı analizi, üç farklı yöntem kullanılarak gerçekleştirilmiştir: temel strateji, makine öğrenmesine dayalı tahmin stratejileri ve dinamik eşik modeli. Temel stratejide, önceden belirlenmiş eşik değerleri ve işlem kuralları, makine öğrenmesi yöntemleri

kullanılmadan uygulanmış olup, bu yaklaşım makine öğrenmesine dayalı modellerin göreceli performansının değerlendirilmesinde referans noktası oluşturmuştur. Makine öğrenmesi stratejileri, temel modellerin tahmin gücünü artırmak amacıyla çeşitli algoritmalarından yararlanmaktadır. Bu bağlamda, Lojistik Regresyon, Rastgele Orman, XGBoost ve Destek Vektör Makinesi (SVM) algoritmaları, farklı eşik değerleri için karşılaştırmalı olarak incelenmiştir. Dinamik eşik modeli ise hem temel hem de makine öğrenmesi yaklaşımlarının unsurlarını entegre ederek sinyal üretiminde esneklik sağlamaktadır. Bu modelde, sabit eşiklerle oluşturulan stratejilerin uygulanması yerine, piyasa koşullarına göre dinamik olarak ayarlanan giriş ve çıkış sinyalleriyle elde edilen sonuçlar analiz edilmiştir.

Analizlerin gerçekleştirilebilmesi için veri seti şu şekilde üç farklı döneme ayrılmıştır:

Eğitim Seti: 2014-01-01 ve 2018-12-31;

Doğrulama Seti: 2019-01-01 ve 2020-12-31;

Test Seti: 2021-01-01 ve 2024-01-01

Eğitim seti, makine öğrenimi algoritmalarının eğitilmesi ve temel stratejilerin belirlenmesi amacıyla oluşturulmuştur. Bu aşamada, makine öğrenimi algoritmaları, daha isabetli alım-satım sinyalleri oluşturmak için verilerdeki temel ilişkileri tespit etmiştir. Doğrulama aşaması, modellerin hassasiyetinin test edildiği ve aşırı öğrenmenin önlendiği ara dönem olmuştur. Test dönemi ise, oluşturulan model ve stratejilerin gerçek veriler üzerindeki nihai performansını değerlendirmek için kullanılmış ve gerçekleştirilen analizler ile sonuçların elde edilmesini sağlamıştır

3.3.1. Temel Strateji

Temel stratejide, işlem sinyalleri makine öğrenimi yöntemleri kullanılmadan, statik eşik değerleri ile oluşturulmuştur. Bu yaklaşımda, endekslerdeki fiyat farklarından hesaplanan z skorları, önceden belirlenmiş giriş-çıkış eşik değerleriyle karşılaştırılarak işlem sinyalleri üretilmiştir. Bu süreçte şu adımlar takip edilmiştir:

- *Endeksler İçin Fiyat Farkı Serilerinin Oluşturulması*

$$S_t = A_t - B_t$$

İlk olarak, her bir endeks için günlük kapanış fiyatları kullanılarak ardışık günler arasındaki fiyat farkları hesaplanmıştır. Endeksler arasındaki bu farklar, günlük değişimleri gösteren zaman serileri meydana getirmiştir. Elde edilen fiyat farkı serileri, daha sonra z-skor hesaplamasında kullanılmak üzere standart sapma ve ortalama değerlerinin hesaplanmasında temel girdi olarak kullanılmıştır.

- *Hareketli Ortalama ve Standart Sapmaların Belirlenmesi*

N dönemlik zaman serileri için hareketli ortalama (μ_t) ve standart sapma (σ_t) değerleri şu şekilde hesaplanmıştır:

$$\mu_t = \frac{1}{n} \sum_{i=t-n+1}^t S_i$$

Hareketli ortalama hesaplanırken, belirlenen dönem sayısı kadar geriye gidilerek o aralıktaki tüm değerler toplanır ve bu toplam dönem sayısına bölünür. Standart sapma hesaplanırken ise, her bir dönemin değerinden, o dönemin hareketli ortalaması çıkarılır. Elde edilen farkların

kareleri alınarak toplanır. Bu toplam, dönem sayısının bir eksiğine bölünür. Bu hesaplama yöntemi, verilerin hareketli ortalama etrafındaki dağılımını ölçer.

$$\sigma_t = \sqrt{\frac{1}{n-1} \sum_{i=t-n+1}^t (S_i - \mu_t)^2}$$

- *Z skorunun Hesaplanması:*

Z skoru (Z_t), ilgili dönemin değerinin (S_t) o dönemdeki hareketli ortalamadan (μ_t) çıkarılıp, standart sapmaya (σ_t) bölünmesiyle elde edilir.

$$Z_t = \frac{S_t - \mu_t}{\sigma_t}$$

- *İkili Endeks Çiftleri İçin İşlem Sinyallerinin Oluşturulması:*

İşlem sinyalleri şu şekilde oluşturulmuştur:

Alış Sinyalleri (1) : Eğer $Z_t <$ giriş eşik değerinden büyük ise A endeksi için alış pozisyonu açılarak B endeksi satılır


Satış Sinyalleri (-1) : Eğer $Z_t >$ giriş eşik değerinden büyük ise ise A endeksi için satış pozisyonu açılarak B endeksi alınır

Pozisyonların Kapatılması (0) :Eğer $Z_t <$ çıkış eşik değerine küçük veya eşit ise tüm pozisyon kapatılır.

- *İşlem getirileri (Profit and Loss -PnL) ise şu şekilde hesaplanır:*

$$PnL_t = \text{İşlem Sinyalleri}_t \times (S_t - S_{t-1})$$

Şekil 1:GDAXI ve N225 Endeksleri İçin Hesaplanan Z-Skoru Grafiği ve Strateji Sınırları



3.3.2. Makine Öğrenimine Dayalı Tahminde Kullanılan Algoritmalar

Bu bölümde, temel stratejide belirlenen işlem kurallarına uygun olarak fiyat değişimlerinin yönünü tahmin etmek için dört farklı makine öğrenimi algoritması kullanılmıştır. Temel stratejilere dayalı daha doğru işlem sinyalleri üretmek amacıyla Lojistik Regresyon, Rastgele Orman, XGBoost ve Destek Vektör Makinesi (SVM) algoritmaları eğitim seti ile eğitilmiştir

Lojistik Regresyon Algoritması :Hedef değişkenin belirli bir sınıfa ait olma olasılığını lineer olarak tahmin eden doğrusal modeldir. Lojistik dağılım fonksiyonu (sigmoid function) şu şekildedir:

$$P(y = 1, x) = \sigma w^T x + b = \frac{1}{1 + e^{-(w^T x + b)}}$$

Denklemdede, $P(y = 1, x)$, x değişkeni karşısında hedef değerin 1 olma olasılığını, σ Sigmoid işlevini, w ağırlıklandırma faktörünü, b ise hata-sapma terimini ifade etmektedir. Gerçekleştirilen analizde model lojistik kayıp fonksiyonunun en aza indilmesini hedefler. Değişken sayısının m olduğu, ve x özellik vektörleri ile y değerinin tahmin fonksiyonu şu şekildedir:

$$\min_{w,b} \left(-\frac{1}{m} \sum_{i=1}^m [y_i \log(\sigma w^T x_i + b)) + (1 - y_i) \log(1 - \sigma(w^T x_i + b))] \right)$$

Rastgele Orman (Random Forest) Algoritması: Rastgele orman algoritması, oluşturduğu karar ağaçları ile hem sınıflandırma (en sık tekrar eden sonuç) hem de regresyon (tahminlerin ortalaması) yöntemlerini bir arada kullanmaktadır. Bu yöntem sayesinde, farklı karar ağaçlarında ortaya çıkabilecek hata oranlarının minimize edilmesi amaçlanmaktadır. Algoritmanın veri işleme ve çalışma prensibi şu aşamalardan oluşmaktadır: İlk olarak, her bir karar ağacı için eğitim setindeki verilerden bootstrap (yeniden örnekleme) yöntemi ile örneklem seçimi gerçekleştirilir. Sonraki aşamada, karar ağaçları bu örneklemeler üzerinde eğitilir. Her bir karar ağacının oluşturulması sürecinde, aşırı öğrenme (overfitting) riskini azaltmak amacıyla veri setindeki tüm özellikler yerine belirli özellikler seçilir. Seçilen özelliklerin sınıflandırılmasında, Gini safsızlık indeksi ile homojenlik düzeyi ve bilgi kazancı (information gain) kriterleri kullanılarak oluşturulan sınıfların veriyi temsil kabiliyeti değerlendirilir. Algoritma, nihai tahmine tüm oluşturulan karar ağaçlarının çıktılarını değerlendirerek ulaşır.

XGBoost (Extreme Gradient Boosting): XGBoost (eXtreme Gradient Boosting), gradyan artırma prensibine dayalı bir karar ağacı algoritmasıdır. Bu algoritmada karar ağaçları sıralı bir şekilde oluşturulur ve her yeni ağaç, bir önceki ağacın tahmin hatalarını minimize etmek üzere tasarlanır. XGBoost'un temel amacı, aşağıda verilen kayıp fonksiyonunu minimize etmektir:

$$\text{Obj} = \sum_{i=1}^n L(y_i, y'_i) + \sum_{k=1}^K \Omega(f_k)$$

Algoritmada , n gözlem dönemi ve K adet karar ağacı için, $L(y_i, y'_i)$ fonksiyonu tahmin edilen değerler (y'_i) ile gerçek değerler (y_i) arasındaki farkı hesaplayan kayıp fonksiyonunu temsil ederken, $\Omega(f_k)$ terimi modelin karmaşıklığını penalize eden düzenleme (regularizasyon) terimidir.

Destek Vektör Makinesi (Support Vector Machine - SVM): Destek Vektör Makineleri (Support Vector Machines - SVM), denetimli öğrenme algoritmalarından biri olup, temel amacı veri kümesindeki farklı sınıflara ait noktaları optimal şekilde ayıran hiper düzlemi tespit etmektir. Bu hiper düzlem, veri kümesindeki sınıflar arasındaki marjinin maksimum olduğu konumda oluşturulur. Destek vektörleri adı verilen ve sınıf sınırlarına en yakın olan veri noktaları, modelin sınıflandırma kararlarında belirleyici rol oynar. Doğrusal olarak ayrılabilir veri kümelerinde SVM, hiper düzlemi matematiksel optimizasyon teknikleri kullanarak şu şekilde oluşturmaktadır:

$$w^T x + b = 0$$

w: ağırlıklandırma vektörü,

x: özellik vektörü,

b: hiper düzlemden sapma payını temsil eder.

Optimal hiper düzlem, veri sınıfları arasındaki marjı maksimum yapan düzlemdir. Marj, hiper düzlem ile her iki sınıftan en yakın veri noktaları (destek vektörleri) arasındaki mesafe olarak tanımlanır. SVM algoritması, x_i özellik vektörü ve y_i sınıflandırma vektörünü $y_i \in \{-1, 1\}$ temsil eden $x_i y_i (w^T x_i + b) \geq 1$ koşulunda en uygun hiper düzlemi bulmak için aşağıdaki optimizasyon problemini çözer:

$$\min_{w,b} \frac{1}{2} \|w\|^2$$

Veri setinin doğrusal olarak ayıramadığı durumlarda ise optimizasyon problemine gölge değişken eklenerek $x_i y_i (w^T x_i + b) \geq 1 - \xi_i$ ve $\xi_i \geq 0$ koşullarında denklem şu şekilde olur:

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i$$

Denklemden C marjı maksimize ederek sınıflandırma hatasını minimize etmeye yarayan düzenleme parametresiyken, gölge değişken (ξ_i) ise yanlış sınıflandırmaların derecesini ölçer.

Makine Öğrenimine Dayalı İşlemlerin Oluşturulması

Makine öğrenimi temelli işlem algoritmalarının oluşturulması için ilk olarak eğitim setindeki her bir veri noktası, özellik ve hedef vektörlerine dönüştürülmüş ve aşağıdaki hesaplamalar gerçekleştirilmiştir:

- Temel işlem stratejisine benzer şekilde 60 günlük penceler için kapanış fiyatlarının hareketli ortalamaları (μ_t) ve standart sapmaları (σ_t) hesaplanmıştır.
- Her işlem günü için benzer şekilde Z değerleri oluşturulmuştur.
- Günlük fiyat değişimleri (ΔS_t) hesaplanmıştır
- Hedef değişken olan $y_{(t)}$ ikili sınıflandırma problemi şeklinde tanımlanmıştır ve farklı modeller fiyat değişimlerinin yönünü tahmin ederek işlem sinyalleri üretmiştir.
- $\Delta S_{t+1} > 0$ ise $y_t = 1$,
- $\Delta S_{t+1} < 0$ ise $y_t = 0$,
- Lojistik Regresyon, Rastgele Orman, XGBoost ve Destek Vektör Makinesi (SVM) algoritmaları belirlenen işlem koşulları ile eğitim seti üzerinde farklı giriş eşik değerleri için ($\theta = 0, 0.1, 0.2, \dots, 1$) eğitilmişlerdir.
- Eğitim tamamlandıktan sonra, her model test aşamasında (2021–2024) gerçek veriler üzerinde deneyerek performans ölçütleri oluşturulmuştur.

3.3.3. Dinamik Eşik Stratejisi

Dinamik eşik stratejisi işlem sinyallerinin oluşturulduğu eşik değerleri tarihsel verilere göre stratejilerin uygulandığı dönem boyunca dinamik olarak ayarlayan stratejidir. Bu strateji farklı tarih aralıkları için en uygun eşiklerin kümesini hem z skoru hem de fiyat oynaklıklarını göz

önünde bulundurarak oluşturup, işlemler için en uygun eşik değerlerini seçmeye odaklanır. Tahmin edilen eşik değerlere göre işlem stratejileri oluşturularak, yürütülen stratejinin değişen piyasa koşullarına uyum sağlaması amaçlanır. Dinamik eşik stratejisinin oluşturulması için aşağıdaki adımlar takip edilmiştir:

Optimal Eşik Değerlerin Belirlenmesi

Optimum eşik değerlerin belirlenmesi için ilk adım veri setinin sabit büyüklükteki (d) periyodlara ayrılmasıdır. Periyodların oluşturulmasının ardından her bir periyod için performansı maksimize eden optimum eşik değerleri θ^* şu şekilde bulunur:

$$\theta^* = \arg \max_{\theta} \frac{E[R_t(\theta)]}{\sigma[R_t(\theta)]}$$

Eşitlikteki $[R_t(\theta)]$, θ eşik değerinin kullanılması elde edilen getiriyi, $E[R_t(\theta)]$ beklenen getiriyi, $\sigma[R_t(\theta)]$ ise getirilerin standart sapmasını temsil etmektedir. Analizde Sharpe oranı, θ^* olarak kullanılmış ve en yüksek Sharpe oranına sahip eşik değerleri ile işlem yapılması hedeflenmiştir.

Regresyon Modeli Eğitimi ve İşlem Sinyalleri

Analiz kapsamında seçilen özellik vektörleri (x_t), z-skoru (Z_t) ve standart sapmadan (σ) oluşmaktadır. Bu özellikler kullanılarak optimum eşikleri (θ'_t) tahmin etmek için farklı algoritmalar (f) kullanılabileceği gibi analiz kapsamında rastgele orman algoritması kullanılmıştır.

$$\theta'_t = f(x_t)$$

İşlem sinyalleri ise tahmin edilen eşik değerlerine göre olarak oluşturulmuştur. Eğer z-değeri tahmin edilen eşik değerin üzerinde ise satış sinyalleri ($Z_t > \theta'_t$), eşik değerin altında ise ($Z_t < \theta'_t$) alım sinyalleri üretilmiştir.

3.4. Performans Ölçütleri

Sharpe Oranı: Sharpe oranı uygulanan stratejilerin risk ayarlı getirilerini ölçmektedir. Dolayısı ile Sharpe oranının artması alınan riske göre elde edilen getirilerin görece yüksek olması olarak değerlendirilir. Sharpe oranı şu şekilde hesaplanmıştır :

$$\text{Sharpe Oranı} = \frac{\text{Ortalama Getiri}}{\text{Standart Sapma} (\sigma)}$$

Ortalama getisi ise n gözlem sayısı ve i için gözlemlenen kar/zarar (profit&loss - PnL) değerleri için şu şekilde hesaplanmıştır :

$$\text{Ortalama Getiri} = \frac{1}{n} \sum_{i=1}^n PnL_i$$

Aşırı Getirininin T İstatistiği :Bu rasyo uygulanan makine öğrenimi temelli stratejilerin ortalama getirisinin temel stratejinin ortalama getirisine kıyasla istatistiksel olarak anlamlı olup olmadığını değerlendirmek için uyarlanmıştır. Bu istatistik, stratejiler arasındaki performans farkının önemli derecesini gösterir. Şu şekilde hesaplanmıştır:

$$T \text{ istatistiği} = \frac{\text{Ortalama Getiri}}{\frac{\text{Standart Sapma} (\sigma)}{\sqrt{n}}}$$

Aşırı getirinin t istatistiği ise aşağıdaki şekilde hesaplanmıştır :

$$= \frac{\text{Ortalama Getiri}_x - \text{Ortalama Getiri}_y}{\frac{\text{Standart Sapma } (\sigma_x)}{\sqrt{n}}}$$

X: makine öğrenimi algoritması temelli strateji

Y:temel strateji

F1 Skoru: Sınıflandırma problemlerine dayalı makine öğrenimi modellerinin performansını değerlendirmek için yaygın olarak kullanılan bir ölçüm aracıdır. kesinlik (precision) ve duyarlılık (recall) oranlarının harmonik ortalaması alınarak elde edilen F1 değeri şu şekilde hesaplanır :

$$F1 = 2 \times \frac{\text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}}$$

Kesinlik ve duyarlılık oranları ise karışıklık matrisi (Confusion Matrix) ile türetilmektedir. Karmaşıklık matrisinin bileşenleri şu şekildedir:

Tablo 4 : Karmaşıklık matrisinin bileşenleri

	Pozitif Tahminler	Negatif Tahminler
Gerçekte Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)
Gerçekte Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)

Kaynak: (Chicco ve Jurman, 2020: 13)

- Doğru Pozitif (TP): Modelin pozitif olarak tahmin ettiği ve gerçekten pozitif olan örnekler
- Yanlış Pozitif (FP): Modelin pozitif olarak tahmin ettiği ancak gerçekte negatif olan örnekler
- Yanlış Negatif (FN): Modelin negatif olarak tahmin ettiği ancak gerçekte pozitif olan örnekler
- Doğru Negatif (TN): Modelin negatif olarak tahmin ettiği ve gerçekten negatif olan örnekler

Karmaşıklık matrisi modelin güçlü ve zayıf yanlarının değerlendirilmesi ile gerçekleşen hataların tespit edilmesine imkan sağlar. Böylece incelenen modelin hangi alanlarda geliştirilmesi konularında ipucu verir.

Kesinlik oranı, modelin oluşturduğu pozitif sinyallerin güvenilirliğini ölçerek tüm pozitif tahminler arasında, gerçekte pozitif olanların oranını verir ve şu şekilde hesaplanır:

$$\text{Kesinlik oranı} = \frac{TP}{TP + FP}$$

Duyarlılık oranı ise gerçekte pozitif olan tüm örnekler arasında model tarafından doğru tahmin edilenlerin oranını gösterir:

$$\text{Duyarlılık oranı} = \frac{TP}{TP + FN}$$

F1 skoru, analiz kapsamında uygulanan temel stratejide Temel stratejide z değerlerine göre oluşturulan işlem sinyallerinin gerçek fiyat hareketleriyle ne kadar örtüştüğünü

değerlendirirken, makine öğrenmesi temelli uygulanan stratejilerde kullanılan algoritmaların fiyat değişimlerini tahmin etme başarısını ölçer. Böylece makine öğrenmesi modellerinin, stratejilerdeki tahmin performansı ve tutarlılığı değerlendirilmiş olur.

Sortino Oranı : Bu oran, yatırımların risk-getiri performansını ölçen ve Sharpe oranına alternatif olan bir değerlendirme ölçütüdür. Sharpe oranı risk hesaplamasında tüm getirilerin standart sapmasını kullanırken, Sortino oranı sadece negatif getirilerin standart sapmasını dikkate alarak aşağı yönlü riski ölçer. Sortino oranının yükselmesi daha başarılı bir risk ayarlı getirinin varlığına işaret eder. Bu nedenle, Sortino oranı kayıplardan kaçınmak isteyen yatırımcılar için daha anlamlı bir performans ölçütü sunmaktadır.

Aşağı yönlü sapmalar şu şekilde hesaplanır :

$$\sigma_d \sqrt{\frac{1}{n} \sum_{i=1}^n \min(0, R_i - R_f)^2} \quad (R_i: i \text{ zamanındaki getiri}, R_f: \text{risksiz getiri oranı})$$

$$\text{Sortino Oranı: } \frac{R_i - R_f}{\sigma_d}$$

Gerçekleştirilen analizlerde farklı stratejiler ve modeller arasında tutarlılık ve karşılaştırılabilirlik sağlanabilmesi amacı ile risksiz getiri oranı sıfır kabul edilmiştir.

Maksimum Düşüş Oranı (Maximum Drawdown- MDD): MDD yatırımların potansiyel riskinin anlaşılabilmesi için yatırımın en yüksek değerinden en düşük değerine kadar kaşıştığı en büyük kaybı ölçer. MDD aşağıdaki formül kullanılarak hesaplanır :

$$MDD = \frac{\text{yatırımın en düşük değeri} - \text{yatırımın en yüksek değeri}}{\text{yatırımın en yüksek değeri}} \times 100$$

3.5. Sonuçlar

Farklı endeks çiftleri üzerinde uygulanan çeşitli makine öğrenmesi modellerine dayalı ampirik analiz bulguları aşağıda sunulmaktadır. Oluşturulan tablolarda, her endeks çifti için modellerin en yüksek performans gösteren sonuçlarına yer verilmiştir. Analiz bulguları, temel strateji ile karşılaştırıldığında, makine öğrenmesi yaklaşımlarının ikili işlem stratejilerinde daha yüksek etkinlik sağladığına işaret etmektedir.

3.5.1.GDAXI ve N225 Endekslerine İlişkin Analiz Sonuçları

GDAXI ve N225 endekslerinde gerçekleştirilen analiz sonuçlarına göre SVM modeli sınıflandırma performansı açısından 0.79 F1 skoru ile diğer modeller arasında en yüksek başarıyı elde etmesine rağmen, 0.82'lik maksimum düşüş değeri ile en riskli strateji olmuştur. Buna karşılık, temel strateji 0.31'lik maksimum düşüş değeri ile en güvenli yaklaşım olarak öne çıkmıştır.Risk-getiri dengesini optimize etme açısından, dinamik eşiklendirme modeli 0.72 Sharpe oranı ve 1.70 Sortino oranı ile dengeli bir performans sergilerken, getirilerin istatistiksel anlamlılığı, Lojistik Regresyon modelinde 5.13 t-istatistiği değeri en yüksek değeri almıştır.Buna karşılık Rastgele Orman modeli, 0.27 t-istatistiği ve 0.49'luk Sharpe oranı ile diğer yaklaşımlara kıyasla daha zayıf bir performans sergilemiştir.

Tablo 5. GDAXI ve N225 Endeks Çifti için Model Performans Sonuçları ve Karşılaştırmalı Analizi

Model	Eşik Değeri	F1 Skoru	Sharpe Oranı	Maksimum Düşüş	Sortino Oranı	t-İstatistiği (Aşırı Getiri)
Temel Strateji	0,4	0,640394	0,641439	0,308547	1,182179	5,132051
Lojistik Regresyon	0,4	0,786808	0,680484	0,783039	1,517806	
Temel Strateji	0,2	0,640394	0,658681	0,371778	1,350529	0,265352
Rastgele Orman	0,2	0,750542	0,493226	0,721080	0,832783	
Temel Strateji	0,3	0,640394	0,660118	0,308547	1,322115	3,357183
XGBoost	0,3	0,778878	0,622869	0,684056	1,434932	
Temel Strateji	0,3	0,640394	0,660118	0,308547	1,322115	4,590427
SVM	0,3	0,795408	0,700153	0,822019	1,466213	
Dinamik Eşiklendirme	-	0,767705	0,715542	0,494333	1,695719	5,08

3.5.2.FCHI ve N225 Endekslerine İlişkin Analiz Sonuçları

FCHI ve N225 endekslerinde, SVM modeli 0.78 F1 skoru ile en başarılı sınıflandırma performansını göstermiştir. Dinamik eşiklendirme modeli 0.69 Sharpe oranı ve 1.49 Sortino oranı ile risk ayarlı getirilerde tutarlı bir performans ortaya koymuştur. En düşük dalgalanmaya sahip strateji, tüm eşik değerlerinde 0.31'lik maksimum düşüş oranı ile temel strateji olmuştur. Lojistik regresyon, 6.53'lük t-istatistiği değeri ile istatistiksel açıdan en güvenilir sonuçları üretirken, rastgele orman algoritmasının performansı, düşük t-istatistiği ve 0.74 Sortino rasyosu ile diğer modellere kıyasla yetersiz kalmıştır.

Tablo 6. FCHI ve N225 Endeks Çifti için Model Performans Sonuçları ve Karşılaştırmalı Analizi

Model	Eşik Değeri	F1 Skoru	Sharpe Oranı	Maksimum Düşüş	Sortino Oranı	t-İstatistiği (Aşırı Getiri)
Temel Strateji	0,5	0,619259	0,575832	0,311019	1,080216	6,526943
Lojistik Regresyon	0,5	0,772448	0,667733	0,610527	1,47015	
Temel Strateji	0,1	0,619259	0,628616	0,311019	1,269272	0,031946
Rastgele Orman	0,1	0,744681	0,466533	0,620114	0,742913	
Temel Strateji	0,3	0,619259	0,615383	0,311019	1,236447	3,457219
XGBoost	0,3	0,764263	0,583842	0,630632	1,308236	
Temel Strateji	0,4	0,619259	0,597205	0,311019	1,176226	6,076947
SVM	0,4	0,781176	0,676169	0,640148	1,493091	
Dinamik Eşiklendirme	-	0,710611	0,69181	0,345279	1,488391	4,49

3.5.3. GDAXI ve IXIC Endekslerine İlişkin Analiz Sonuçları

GDAXI ve IXIC endekslerinde sınıflandırma performansında en yüksek başarıyı 0.80 F1 skoru ile dinamik eşiklendirme modeli göstermiştir. Bu model sınıflandırma başarısı ile beraber risk ayarlı getirilerde de 0.67 Sharpe oranı ile model en iyi performansı sunmuştur. Dinamik

eşiklendirme modelinin tahmin başarısını, yakın performanslarla Lojistik Regresyon ve SVM modelleri 0.79'luk F1 skorlarıyla takip etmiştir. Lojistik Regresyon ve XGBoost modelleri %10'luk maksimum düşüş değerleriyle en başarılı risk yönetimini gerçekleştirmişlerdir. Lojistik Regresyon modeli, 6.30 t-istatistiği ile yüksek getiri anlamlılık düzeyine ulaşmıştır. Rastgele Orman modeli ise, 0.74'lük F1 skoruyla kabul edilebilir bir sınıflandırma performansı sergilemesine rağmen, 0.48 Sharpe oranı ve 0.92 Sortino oranıyla diğer modellerin gerisinde bir risk-getiri performansı göstermiştir

Tablo 7. GDAXI ve IXIC Endeks Çifti için Model Performans Sonuçları ve Karşılaştırmalı Analizi

Model	Eşik Değeri	F1 Skoru	Sharpe Oranı	Maksimum Düşüş	Sortino Oranı	t-İstatistiği (Aşırı Getiri)
Temel Strateji	0,4	0,635329	0,604592	0,512224	1,3747	6,303917
Lojistik Regresyon	0,4	0,792982	0,659891	0,100264	1,478848	
Temel Strateji	0,1	0,635329	0,617795	0,568144	1,194561	1,109259
Rastgele Orman	0,1	0,742179	0,477466	0,25659	0,924199	
Temel Strateji	0,4	0,635329	0,604592	0,512224	1,3747	4,515574
XGBoost	0,4	0,764072	0,580685	0,10294	1,244818	
Temel Strateji	0,4	0,635329	0,604592	0,512224	1,3747	6,182528
SVM	0,4	0,785634	0,649213	0,11327	1,287796	
Dinamik Eşiklendirme	-	0,79726	0,673047	0,315954	1,275902	5,33

3.5.4.FCHI ve IXIC Endekslerine İlişkin Analiz Sonuçları

FCHI ve IXIC Endekslerinde risk-getiri optimizasyonunda en başarılı sonuçlar dinamik eşiklendirme modelinde gözlemlenmiştir. Model, 0.69 Sharpe oranı ve 1.86 Sortino oranının yanı sıra, 0.05'lik maksimum düşüş değeri ile risk yönetiminde de oldukça iyi bir performans sergilemiştir.

Sınıflandırma performansları kapsamında Lojistik Regresyon, XGBoost ve SVM modelleri yaklaşık 0.77'lik F1 skorları ile benzer düzeyde performans gösterirken, oldukça düşük maksimum düşüş değerleri ile etkili risk yönetimi gerçekleştirmişlerdir. İstatistiksel güvenilirlik açısından en anlamlı sonuçları 7.58 t-istatistiği ile XGBoost algoritmasına dayalı strateji sağlamıştır. Rastgele Orman modeli ise 0.44 Sharpe oranı ve 0.85 Sortino oranı ile diğer modellere göre daha düşük bir risk-getiri performansı göstermiş, 0.65'lik maksimum düşüş değeri ile de görece yüksek riskli bir profil sergilemiştir.

Tablo 8. FCHI ve IXIC Endeks Çifti için Model Performans Sonuçları ve Karşılaştırmalı Analizi

Model	Eşik Değeri	F1 Skoru	Sharpe Oranı	Maksimum Düşüş	Sortino Oranı	t-İstatistiği (Aşırı Getiri)
Temel Strateji	0,3	0,647115	0,556714	0,589409	1,353363	5,688244
Lojistik Regresyon	0,3	0,774737	0,569392	0,156019	1,32171	
Temel Strateji	0,1	0,647115	0,55548	0,417567	1,330053	2,379302
Rastgele Orman	0,1	0,741127	0,443776	0,65268	0,847061	
Temel Strateji	0,4	0,647115	0,545985	0,589409	1,279357	7,579676
XGBoost	0,4	0,769591	0,637157	0,10324	1,484533	
Temel Strateji	0,2	0,647115	0,564334	0,589409	1,394157	5,990026
SVM	0,2	0,772043	0,594898	0,13092	1,428201	
Dinamik Eşiklendirme	-	0,766571	0,688095	0,049427	1,864561	5,07

4. SONUÇ

Araştırma bulguları, çeşitli makine öğrenmesi modellerinin ve dinamik eşiklendirme yaklaşımının farklı borsa endeks çiftlerinin ikili işlem stratejileri performansına dair sonuçlar sunmaktadır. Elde edilen sonuçlar, makine öğrenmesi modellerinin yatırım stratejilerindeki başarısını modellerin sınıflandırma performansı, getiri düzeyi ve risk yönetimi unsurları üzerinden çok yönlü olarak değerlendirmektedir. Bu kapsamda dinamik eşik değerleri kullanan yöntem, tüm endeks çiftleri için en uygun risk getiri dengesini sağlamıştır. SVM ve Lojistik Regresyon yöntemleri yüksek tahmin başarısıyla öne çıkarken, temel yöntem düşük riskli bir seçenek sunmaktadır. Rastgele Orman yöntemi ise model performansı açısından yetersiz kalmıştır.

Dinamik Eşiklendirme stratejisi, tüm endeks çiftlerinde en dengeli risk-getiri profilini sunarak, yüksek sınıflandırma başarısı, makul risk-getiri oranları ve düşürülmüş aşağı yönlü risk metrikleri ile diğer modellerin önüne geçmiştir. Özellikle, maksimum düşüş değerlerini uygun ölçülerde tutabilmesi, bu stratejinin hem agresif hem de dengeli yatırım yaklaşımları için uygun olduğuna işaret etmektedir. Dinamik Eşiklendirme'nin başarısının ardında yatan temel faktör, farklı piyasa koşulları ve dalgalanmalarında gerçekleşen değişimlere adapte olabilme ve strateji eşik değerlerini güncelleyebilme yeteneğidir.

SVM ve Lojistik Regresyon modelleri ise sınıflandırma performansı açısından başarılı sonuçlar elde etmiştir. SVM, tüm endeks çiftlerinde en yüksek sınıflandırma başarısına ulaşmıştır. Ancak, SVM'nin maksimum düşüş değerlerinde gözlemlenen yüksek değerler, modelin kullanımını yüksek risk toleransına sahip yatırımcılar veya daha riskli yaklaşımlarla sınırlandırmaktadır. Bununla birlikte modelin eğitim verilerine çok iyi uyum göstermesi, gerçek piyasa verilerinde beklenmedik dalgalanmalara karşı savunmasız kalmasına ve aşırı uyum riskine de dikkat çekmektedir. Öte yandan, Lojistik Regresyon, SVM'ye yakın sınıflandırma performansı sergilerken, daha düşük maksimum düşüş oranlarıyla risk-getiri dengesini sağlama açısından görece istikrarlı bir performans sergileyerek iyi bir alternatif olarak öne çıkmıştır.

Statik eşik değerleri ve makine öğrenmesi yöntemleri kullanılmadan uygulanan temel strateji riske karşı daha temkinli olan yatırımcılar için daha güvenli bir seçenek olarak değerlendirilebilir. Tüm endeks çiftlerinde en düşük maksimum düşüş oranlarına sahip olması, temel stratejinin diğer stratejilere nazaran "güvenli liman" rolünü üstlendiğini göstermektedir. Ancak, düşük sınıflandırma başarısı ve risk-getiri oranları, stratejinin getiri potansiyelinin sınırlı olduğunu göstermektedir. Bu sebeple, Temel Strateji, portföy çeşitlendirmesi amacıyla veya düşük risk toleransına sahip yatırımcılar tarafından tercih edilebilir.

Rastgele Orman ve XGBoost modelleri, zayıf risk-getiri dengesi sebebi ile diğer modellerin gerisinde kalmıştır. Rastgele Orman, tüm endeks çiftlerinde en düşük risk-getiri oranlarına ve istatistiksel anlamlılık değerlerine sahip olmuştur. Her ne kadar kabul edilebilir bir sınıflandırma performansı sergilese de, risk-getiri dengesi ve istatistiksel güvenilirlik açısından incelenen endeks çiftlerinde ve uygulanan strateji açısından öne çıkan bir seçenek olmamıştır. Benzer şekilde, XGBoost da SVM ve Lojistik Regresyon'un gerisinde kalmış, görece yüksek maksimum düşüş oranlarıyla risk yönetimi konusunda daha düşük bir performans sergilemiştir.

Yatırımcıların risk alma düzeyleri ile yatırım amaçları göz önüne alınarak, farklı yöntemlerin önerilmesi mümkündür. Agresif yatırımcılar, yüksek F1 skoruna sahip SVM modeli ile stop-loss gibi çeşitli risk yönetimi uygulamalarını birlikte kullanarak potansiyel getirilerini artırabilirler. Makul düzeyde dengeli bir risk ve getiri yaklaşımı benimseyen yatırımcılar için Dinamik Eşiklendirme veya Lojistik Regresyon modelleri uygun seçenekler olabilir. Bu modeller, kabul edilebilir getiriler sunarken risk seviyesini kontrol altında tutmuştur. Son olarak, riskten kaçınan ve sermaye korumasına öncelik veren yatırımcılar, Temel Stratejiyi portföy çeşitlendirmesi ile birlikte uygulayarak daha düşük riskli yatırım alternatifi elde edebilirler. Bu yaklaşım, potansiyel kayıpları sınırlandırırken, istikrarlı getiriler sunabilir.

Gelecekteki araştırmalarda, mevcut çalışmanın kapsamını genişletmek ve modellerin performansını iyileştirmek de için çeşitli adımlar atılabilir. Modellerin farklı koşullar ve stres durumlarına dayanıklılığını test etmek, onların değişen piyasa şartlarında tutarlılığını anlamak için önemlidir. SVM ve XGBoost gibi modellerde özellikle aşağı yönlü riskler göz önünde bulundurularak uygulanabilecek hiperparametre optimizasyonu ile model performanslarının artırılması hedeflenmelidir. Ayrıca Dinamik Eşiklendirme ile diğer modellerin sinyallerini birleştiren bütünlük yaklaşımını denemenmelidir. Farklı modellerin güçlü yönlerini bir araya getiren çeşitli teknikler, daha etkili tahminler üretebilir.

KAYNAKÇA

- Baek, S., Glambosky, M., Oh, S. H., & Lee, J. (2020). Machine learning and algorithmic pairs trading in futures markets. *Sustainability*, 12(7).
- Bağcı, M., & Soylu, P. K. (2024). *The Optimal Threshold Selection for High-Frequency Pairs Trading via Supervised Machine Learning Algorithms*. doi:10.13140/RG.2.2.26440.53769
- Bertram, W. K. (2010). Analytic solutions for optimal statistical arbitrage trading. *Physica A: Statistical mechanics and its applications*, 389(11), pp. 2234-2243.
- Bogomolov, T. (2011). Pairs trading in the land down under.
- Caldeira, J. F., & Moura, G. V. (2012). Selection of a portfolio of pairs based on cointegration: the Brazilian case. *Federal University of Rio Grande do Sul, Federal University of Santa Catarina*.

- Caldeira, J. F., & Moura, G. V. (2013). Selection of a portfolio of pairs based on cointegration: A statistical arbitrage strategy. *Revista Brasileira de Finanças*, 11(1), 49-80.
- Chaudhuri, T. D., Ghosh, I., & Singh, P. (2017). Application of Machine Learning Tools in Predictive Modeling of Pairs Trade in Indian Stock Market. *IUP Journal of Applied Finance*, 23(1).
- Chen, C. W., Chen, M., & Chen, S. Y. (2014). Pairs trading via three-regime threshold autoregressive GARCH models. *Modeling Dependence in Econometrics: Selected Papers of the Seventh International Conference of the Thailand Econometric Society, Faculty of Economics, Chiang Mai University* (pp. 127-140). Thailand: Springer International Publishing.
- Chen, Z., Wang, Z., & Sun, P. (2022). A Novel Machine Learning-assisted Pairs Trading Approach for Trading Risk Reduction. *2022 IEEE 1st Global Emerging Technology Blockchain Forum: Blockchain & Beyond (iGETblockchain)* (pp. 1-6). IEEE.
- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 1-13.
- Chiu, M. C., & Wong, H. Y. (2015). Dynamic cointegrated pairs trading: Mean-variance time-consistent strategies. *Journal of Computational and Applied Mathematics*, 290, 516-534.
- Cummins, M., & Bucca, A. (2012). Quantitative spread trading on crude oil and refined products markets. *Quantitative Finance*, 12(12), pp. 1857-1875.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, 74(366a), pp. 427-431
- Do, B., Faff, R., & Hamza, K. (2006). A new approach to modeling and estimation for pairs trading. *Proceedings of 2006 financial management association European conference*, 1, pp. 87-99.
- Elliott, R. J., Van Der Hoek, J., & Malcolm, W. P. (2005). Pairs trading. *Quantitative Finance*, 5(3), pp. 271-276.
- Engle, R. F., & Granger, C. W. (1987). Co-integration and error correction: representation, estimation, and testing. *Econometrica: journal of the Econometric Society*, 251-276.
- Fu, N., Kang, M., Hong, J., & Kim, S. (2024). Enhanced Genetic-Algorithm-Driven Triple Barrier Labeling Method and Machine Learning Approach for Pair Trading Strategy in Cryptocurrency Markets. *Mathematics*, 12(5), 780.
- Gatev, E., Goetzmann, W. N., & Rouwenhorst, K. G. (2006). Pairs trading: Performance of a relative-value arbitrage rule. *The Review of Financial Studies*, 19(3), 797-827.
- Hong, G., & Susmel, R. (2003). Pairs-trading in the Asian ADR market. *University of Houston, Unpublished Manuscript*.
- Huck, N., & Afawubo, K. (2015). Pairs trading and selection methods: is cointegration superior? *Applied Economics*, 47(6), 599-613.
- Kim, T., & Kim, H. Y. (2019). Optimizing the Pairs-Trading Strategy Using Deep Reinforcement Learning with Trading and Stop-Loss Boundaries. *Complexity*, 1.
- Krauss, C. (2017). Statistical arbitrage pairs trading strategies: Review and outlook. *Journal of Economic Surveys*, 31(2), 513-545.
- Liew, R. Q., & Wu, Y. (2013). Pairs trading: A copula approach. *Journal of Derivatives & Hedge Funds*, 19, pp. 12-30.
- Lin, Y. X., McCrae, M., & Gulati, C. (2006). Loss protection in pairs trading through minimum profit bounds: A cointegration approach. *Advances in Decision Sciences*.
- Nath, P. (2003). High frequency pairs trading with US treasury securities: Risks and rewards for hedge funds. *available at SSRN 565441*.

- Rad, H., Low, R. K., & Faff, R. (2016). The profitability of pairs trading strategies: distance, cointegration and copula methods. *Quantitative Finance*, 16(10), pp. 1541-1558.
- Sarmiento, S. M., & Horta, N. (2020). Enhancing a pairs trading strategy with the application of machine learning. *Expert Systems with Applications*, 158.
- Van der Have, R., van Dijk, D. J., Kole, H. G., Eisma, I. H., & Diepen, G. (2017). Pairs trading using machine learning: An empirical study. *Erasmus School of Economics*, 12.
- Vidyamurthy, G. (2004). *Pairs trading: Quantitative methods and analysis* (Vol. 217). John Wiley & Sons.
- Wu, J. (2015). *A pairs trading strategy for GOOG/GOOGL using machine learning*.
- Zeng, Z., & Lee, C. G. (2014). Pairs trading: optimal thresholds and profitability. *Quantitative Finance*, 14(11), 1881-1893.
- Zhu, J. (2022). The Performances of Different Strategies Based on Time Series Analysis for Chinese. *2022 International Conference on mathematical statistics and economic analysis (MSEA 2022)* (pp. 470-476). Atlantis Press.

Çatışma Beyanı: Makalenin yazarı, bu çalışma ile ilgili taraf olabilecek herhangi bir kişi, kurum veya kuruluşun finansal ilişkileri bulunmadığını dolayısıyla herhangi bir çıkar çatışmasının olmadığını beyan eder.

Destek ve Teşekkür: Çalışmada herhangi bir kurum ya da kuruluştan destek alınmamıştır.

Etik Kurul İzni: Araştırmaya yönelik etik kurul izni gerekmemektedir.

Katkı Oranı Beyanı: Makale tek yazarlıdır.