

Evrişimsel Sinir Ağları ve Transfer Öğrenme Yaklaşımı Kullanılarak Altın Fiyat Yönünün Tahmini

Prediction of Gold Price Direction using Convolutional Neural Networks and a Transfer Learning Approach

Yahya ALTUNTAŞ^{*1} , Fatih OKUMUŞ² , Adnan Fatih KOCAMAZ³ 

^{1,3}Bilgisayar Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

²Yazılım Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

yahyaaltuntas@gmail.com, fatih.okumus@inonu.edu.tr, fatih.kocamaz@inonu.edu.tr

Received:Nov.15,2022

Accepted:Nov.30,2022

Published:Dec.07,2022

Özetçe— Finansal zaman serisi tahmini ile finansal varlıklar için doğru alım-satım kararları vererek karlılığın artırılması amaçlanmaktadır. Finansal varlıkların fiyatları pek çok faktörden etkilenen kırılgan bir yapıdadır. Bu nedenle, finansal zaman serisi tahmini uzun yıllardır farklı disiplinlerden araştırmacılar tarafından ilgi gören oldukça zorlu bir görevdir. Bu çalışmada, ons altın günlük fiyat yönünün tahmini için 2007 – 2021 yıllarını kapsayan 15 yıllık tarihsel fiyat verisi kullanılmıştır. Altın fiyat verileri mum grafikleri ve teknik analiz göstergeleri yardımıyla grafik görüntülere dönüştürülmüştür. Bu sayede altın fiyat yön tahmini iki-sınıflı görüntü sınıflandırma problemine indirgenmiştir. Görüntülerin sınıflandırılması için öncü ön-educitilmiş evrişimsel sinir ağı modellerinden AlexNet ince-ayarlanarak adapte edilmiştir. Gerçekleştirilen deney sonuçlarına göre, önerilen yaklaşımın sınıflandırma performansı doğruluk, duyarlılık, hassasiyet ve f-ölçütü performans metrikleri için sırasıyla %53,8, %66,97, %37,54 ve %42,05 olarak ölçülmüştür. Ayrıca önerilen yaklaşımın tahminlerine dayalı gerçekleştirilen ticaret stratejisinin karlılık analizleri de yapılmış ve yatırımcılar tarafından sıklıkla kullanılan Göreceli Güç Endeksi ve Al ve Tut yatırım stratejileri ile karşılaştırılmıştır. 3 yıllık vade boyunca gerçekleştirilen piyasa benzetim sonuçlarına göre önerilen yaklaşım %48,42 kar oranıyla diğer yatırım stratejilerinden daha iyi sonuç vermiştir.

Anahtar Kelimeler : finansal zaman serisi tahmini, algoritmik ticaret, fiyat yön tahmini, derin öğrenme, evrişimsel sinir ağları.

Abstract—With the financial time series forecasting, it is aimed to increase the profitability by making the right buying-selling decisions for financial assets. The prices of financial assets are in a fragile structure affected by many factors. Therefore, financial time series forecasting is a very challenging task that has attracted attention by researchers from different disciplines for many years. In this study, 15 years of historical price data covering the years 2007 – 2021 are used to predict the ounce gold daily price direction. Gold price data has been converted into graphic images with the help of candlestick charts and technical analysis indicators. In this way, gold price direction prediction is reduced to a 2-class image classification problem. AlexNet, one of the pioneering pre-trained convolutional neural network models for the classification of images, was fine-tuned and adapted. According to the experimental results, the classification performance of the proposed approach was measured as 53.8%, 66.97%, 37.54% and 42.05% for accuracy, sensitivity, specificity and f-score performance metrics, respectively. In addition, profitability analyzes of the trading strategy based on the predictions of the proposed approach were also made and compared with the Relative Strength Index and Buy and Hold investment strategies, which are frequently used by investors. According to the market simulation results carried out during the 3-year maturity, the proposed approach yielded better results than other investment strategies with a profit rate of 48.42%.

Keywords : financial time series forecasting, algorithmic trading, price direction predicting, deep learning, convolutional neural networks.

1. Giriş

Uzun yıllardır farklı disiplinlerden araştırmacılar finansal zaman serisi tahmini konusunda çalışmalar yapmaktadır. Önerilen modellerin amacı finansal varlıklar için uygun alım-satım seviyelerinin belirlenmesidir. Bu sayede, fiyat dalgalanmalarından faydalanarak, karlılığın artırılması amaçlanmaktadır. Bununla birlikte, finansal piyasaların politik olaylar, haberler, yatırımcı psikolojisi gibi çok sayıda değişkenden etkilenmesi nedeniyle kaotik, doğrusal-olmayan, karmaşık bir yapısı vardır (Cavalcante vd., 2016). Finansal zaman serilerinin bu karmaşık doğası, piyasa hareketlerinin tahminini ve problemin çözümünü zorlaştırmaktadır (Niu vd., 2020).

Son yıllarda makine öğrenmesinde yenilikçi bir araştırma alanı olan derin öğrenme, çok sayıda işlem katmanları sayesinde verinin temsillerini öğrenen, yani öznetelikleri kendiliğinden keşfeden, hesaplama modellerini ifade etmektedir (Lecun vd., 2015). Geleneksel makine öğrenmesi çalışmalarında model başarımı kullanılan özneteliklere bağlı iken, derin öğrenme sayesinde öznetelik çıkarımına gerek kalmaksızın öğrenme gerçekleştirilebilmektedir. Özneteliklerin kendiliğinden keşfediliyor olması, özellikle doğru özneteliklerin çıkarılmasının neredeyse imkânsız olduğu problemlerde önemli avantaj sağlamaktadır. Finansal zaman serisi verilerinde öznetelikleri belirlemek, problemin kaotik yapısı gereği, oldukça zorlu bir görevdir. Bu nedenle, son yıllarda finansal zaman serisi tahmini için derin öğrenme tabanlı çözümler önerilmektedir (Jiang, 2021).

Derin öğrenme tabanlı finansal zaman serisi tahmini konusunda yapılmış derleme çalışmaları en çok kullanılan derin öğrenme modelinin Özyineli Sinir Ağları (ÖSA) ve bir varyasyonu olan Uzun Kısa Süreli Bellek (UKSB) olduğunu ortaya koymaktadır (Durairaj ve Mohan, 2019; Sezer vd., 2020; Özbayoğlu vd., 2020; Li ve Bastos, 2020; Aldhyani ve Alzahrani, 2022). Zamansal bağımlılığı olan ardışık verilerin analizi için geliştirildiği düşünüldüğünde, ÖSA tabanlı modellerin finansal zaman serisi tahmini için en çok kullanılan yöntemler olması öngörülebilir bir durumdur. Bununla birlikte, UKSB dışında Evrimsel Sinir Ağları (ESA) ve Çok Katmanlı Algılayıcı (ÇKA) gibi farklı derin öğrenme modelleri de finansal zaman serisi tahmini problemine uygulanmıştır.

Özbayoğlu vd. (2020) yaptıkları derleme çalışmalarında finansal zaman serisi verilerinin farklı temsillerinin ESA ile tahmin edilmesinin yenilikçi bir alan olduğunu bildirmişlerdir. Chen vd., (2017) çeşitli görselleştirme tekniklerini kullanarak, Tayvan endeksi vadeli işlem zaman serisi verilerini ESA için girdi olarak iki boyutlu görüntü verilerine dönüştürdüler ve gelecek eğilimleri %57,78 doğrulukla sınıflandırabildiler. Dingli ve Fournier (2017) mevcut fiyata göre bir sonraki dönem fiyat yönünü tahmin etmek için ESA kullandılar. Yazarlar, bir sonraki haftanın fiyat yönünü %60 doğruluk oranıyla ve bir sonraki ayın fiyat yönünü %65 doğruluk oranıyla tahmin edebildiklerini belirtmişlerdir. Ayrıca, yalnızca yön tahminine odaklanarak çalışmalarında karlılık analizleri gerçekleştirmemişlerdir. Sezer ve Özbayoğlu (2018) on beş günlük periyotlar için hesapladıkları on beş farklı teknik analiz göstergesini kullanarak 15x15 boyutlu matris temsillerini elde ettiler. ESA tabanlı önerdikleri modelin ÇKA, UKSB ve Al ve Tut stratejisinden daha iyi performans gösterdiğini bildirdiler. Cao ve Wang (2019) yaptıkları çalışmada, zaman serisi tahmin problemi için bir ESA model algoritması uygulamış, model parametrelerinin tahmin sonuçlarını nasıl etkilediğini araştırmışlardır. ESA ve Destek Vektör Makinesine (DVM) dayalı bir hisse senedi endeksi tahmin modeli oluşturmuşlardır. Zulqarnain vd. (2020) yaptıkları çalışmada hisse senedi fiyatlarının yön tahmini için ESA ve Kapılı Yinelemeli Üniteler (KYÜ) modellerini bir arada kullanan melez bir yapı önermişlerdir. Liu ve Si (2022) finansal zaman serilerinden çizge modellerinin sınıflandırılması için, tek boyutlu ESA modelini kullandılar. Yazarlar, gerçekleştirdikleri karşılaştırmada tek boyutlu ESA modelinin diğer tahmin modellerine göre daha yüksek doğruluğa sahip olduğunu göstermişlerdir. Tüm bu çalışmalar zaman serilerinin görüntülere dönüştürülmesi ve bu görüntüler üzerinde analiz etmeyi hedeflemiştir. Ancak bu çalışmaların hiçbirinde ön eğitilmiş bir derin öğrenme modeli kullanılmamıştır.

Bu çalışmada, ons altın günlük fiyat verileri, mum grafikleri ve teknik analiz göstergeleri yardımıyla renkli grafik görüntülere dönüştürülmüştür. Her bir güne ait kapanış fiyat bilgisi, bir sonraki günün kapanış fiyat bilgisi ile karşılaştırılarak, oluşturulan grafik görüntüler fiyatın yönüne göre AŞAĞI ve YUKARI olarak etiketlenmiştir. Bu sayede, altın fiyat yön tahmini, iki-sınıflı bir görüntü sınıflandırma problemine dönüştürülmüştür. AlexNet (Krizhevsky vd.,2017), ön-eğitilmiş ESA modeli ince-ayarlanarak yön tahmininde kullanılmıştır. Bildiğimiz kadarıyla, bu çalışma ön-eğitilmiş ESA modellerinin finansal zaman serisi tahmininde kullanıldığı ilk çalışmadır. Model karlılığı teknik analistler ve yatırımcılar tarafından çoğunlukla kullanılan geleneksel alım-satım stratejilerinden Göreceli Güç Endeksi ve Al ve Tut ile karşılaştırılmıştır. Piyasa benzetim sonuçları ve gerçekleştirilen karlılık analizleri önerilen yaklaşımın geleneksel alım-satım stratejilerinden daha karlı sonuçlar ürettiğini göstermektedir.

Altın fiyat yönünün tahmini için önerdiğimiz bu çalışmanın organizasyonu şu şekildedir: Çalışmada kullanılan veri seti, veri etiketleme yöntemi, zaman serisi verilerinin grafik görüntülere dönüştürülme prosedürü, ESA mimarisi ve transfer öğrenme yaklaşımı Bölüm 2’de açıklanmıştır. Gerçekleştirilen deneyler sonucunda elde edilen bulgular Bölüm 3’te ele alınmıştır. Çalışmanın genel değerlendirmesine ve gelecekte yapılması planlanan çalışmalara Bölüm 4’te değinilmiştir.

2. Materyal ve Metot

2.1. Veri Seti

Çalışma kapsamında 15 yıllık ABD doları bazında ons altın günlük fiyat verileri kullanılmıştır. Tüm veriler www.investing.com'dan elde edilmiştir. Veriler 01/01/2007 – 31/12/2021 tarihleri arasında piyasanın işlem gördüğü 3.909 güne aittir. Veriler CSV dosya formatındadır ve sırasıyla tarih, açılış değeri, en yüksek, en düşük ve kapanış değeri bilgilerinden oluşmaktadır.

Çalışmada kullanılan veriler 3:1:1 oranında eğitim, doğrulama ve test bölümlerine ayrılmıştır. 9 yıl eğitim, 3 yıl doğrulama ve 3 yıl test işlemleri için kullanılmıştır. Test işlemi sadece sınıflandırma performans ölçümleri için değil, ayrıca karlılık analizleri için de kullanılmıştır. Ons altın günlük fiyat verilerine ait değişim grafiği Şekil 1'de verilmiştir. Eğitim, doğrulama ve test periyodları grafik üzerinde gösterilmiştir.



Şekil 1. 2007 – 2021 yıllarına ait ons altın günlük fiyat değişim grafiği

2.2. Verilerin Etiketlenmesi

Bu çalışmada, alım-satım kararlarının fiyat yön tahminine dayandırıldığı bir algoritmik altın ticaret modeli önerilmektedir. Günlük altın fiyatının yönünün tahmini, tahmin yapılacak güne ait kapanış fiyatının, bir sonraki işlem gününde yükseleceğinin veya düşeceğini tahmin edilmesidir. Fiyat yön tahmini, iki-sınıflı bir sınıflandırma problemidir. Böylece, algoritmik altın ticaret modelimiz iki-sınıflı bir görüntü sınıflandırma problemine indirgenmiştir. Çalışmada kullanılan veriler Denklem (1)'e göre etiketlenmiştir.

$$etiket_T = \begin{cases} \text{YUKARI, eğer fiyat}_T < \text{fiyat}_{T+1} \\ \text{AŞAĞI, eğer fiyat}_T > \text{fiyat}_{T+1} \end{cases} \quad (1)$$

Burada, etiket_T T gününe ait verinin etiketini, fiyat_T ve fiyat_{T+1} sırasıyla T ve T+1 günlerine ait kapanış fiyatlarını temsil etmektedir.

2.3. Verilerin Grafik Görüntülere Dönüştürülmesi

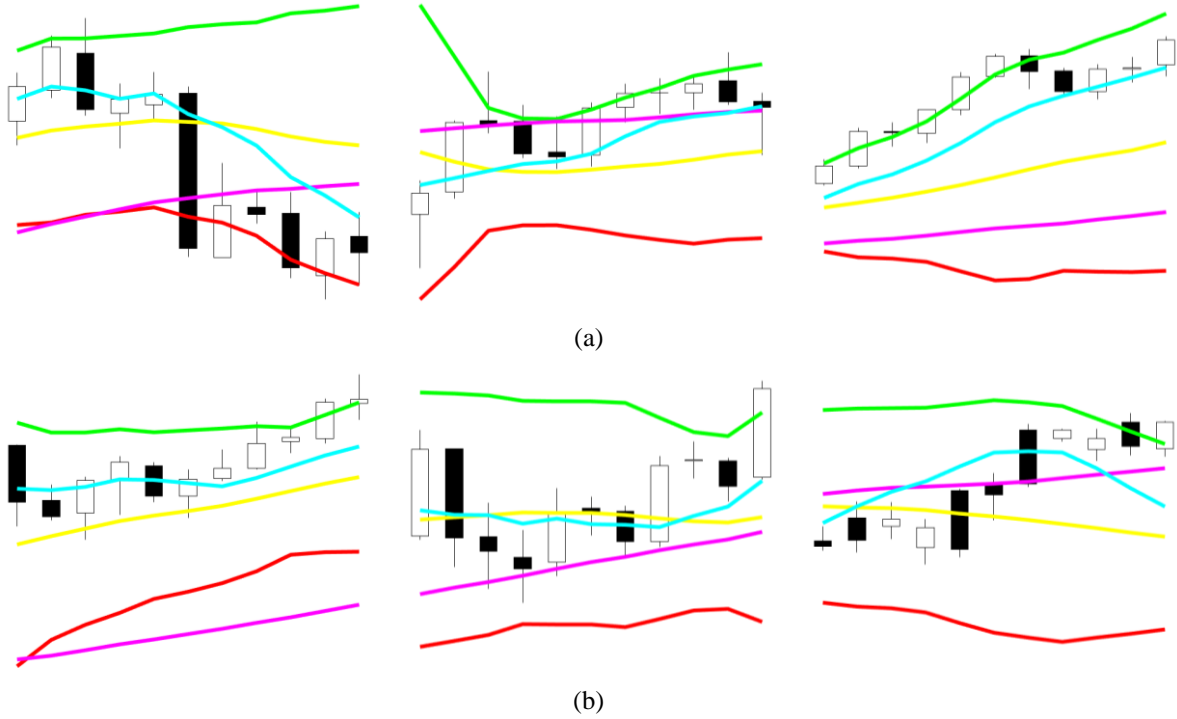
Zaman serisi verilerinin grafik görüntülere dönüştürülmesinde mum grafikleri ile teknik analiz göstergelerinden 7 ve 50 günlük basit hareketli ortalamalar ve Bollinger bantları kullanılmıştır. Bu teknik analiz göstergeleri ve zaman aralıkları teknik analistler tarafından sıklıkla kullanılmaktadır. Görüntü oluşturma aşamasında kullanılan mum grafikleri, basit hareketli ortalama ve Bollinger bantları aşağıda kısaca açıklanmıştır.

Mum grafikleri, bir finansal varlığa ait açılış, kapanış, en yüksek ve en düşük fiyat bilgilerinin gösterildiği teknik analizde sıklıkla kullanılan bir grafik türüdür. Mumun üst iğnesi en yüksek fiyatı, mumun alt iğnesi en düşük fiyatı temsil eder. Mum gövdesinin alt ve üst sınırları ise açılış ve kapanış fiyatlarını temsil etmektedir. Eğer kapanış fiyatı açılış fiyatından yüksek ise, mum gövdesi boyanmaz. Böylece mum gövdesinin üstü kapanış fiyatını, altı ise açılış fiyatını temsil eder. Eğer kapanış fiyatı açılış fiyatından düşük ise, mum gövdesi boyanır. Böylece mum gövdesinin üstü açılış fiyatını, altı ise kapanış fiyatını temsil eder.

Basit hareketli ortalama, bir finansal varlığın belirlenen dönem içerisindeki günlük kapanış fiyatlarının ortalaması alınarak hesaplanır. Örneğin 7 günlük basit hareketli ortalama 7 günlük kapanış fiyatlarının ortalamasıdır (Achelis, 1995). Bir finansal varlığın fiyatının basit hareketli ortalamasının üzerinde veya altında olması, piyasanın trendi hakkında bilgi sağlar.

Bollinger bantları, hareketli ortalamanın üstüne ve altına yerleştirilen volatilité bantdır. Orta bant, 20 günlük basit hareketli ortalamadır. Üst ve alt bantlar, 20 günlük basit hareketli ortalamaya, 20 günlük fiyatın standart sapmasının 2 katının sırasıyla eklenip çıkarılması ile hesaplanır (Achelis, 1995). Volatilitenin yükselip azalmasına bağılı olarak Bollinger bantları genişlemekte veya daralmaktadır.

11 günlük mum grafikleri ve teknik analiz gösterge deęerleri PNG dosya formatında ayrı bir görüntü dosyası olarak kaydedilmiştir. Oluşturulan görüntü veri setinden örnek görüntüler Şekil 2’de gösterilmiştir.



Şekil 2. Veri setinden örnek görüntüler: (a) YUKARI ve (b) AŞAĞI

50 günlük basit hareketli ortalama veri setindeki ilk 49 gün için hesaplanamadığından bu günlere ait görüntü dönüşümleri yapılmamıştır. Ayrıca veri setindeki son gün ve fiyatın deęişmedięi 7 gün için etiketleme yapılmadığından yine bu günler için de görüntü dönüşümleri yapılmamıştır. Görüntü veri seti toplam 3.852 görüntüden oluşmaktadır. Oluşturulan görüntü verilerinin sınıfsal dağılımları Tablo 1’de gösterilmiştir.

Tablo 1. Görüntülerin sınıfsal dağılımları

Sınıf Etiketi	Eđitim Veri Seti	Doęrulama Veri Seti	Test Veri Seti	TOPLAM
YUKARI	1.180	405	433	2.018
AŞAĞI	1.110	375	349	1.834


2.4. Evrişimsel Sinir Ağları ve Transfer Öğrenme

ESA mimarisi görüntünün özniteliklerini otomatik olarak öğrenmek ve sınıflandırmak için geliştirilmiştir. Bir ESA mimarisi iki bölümden oluşur. Birinci bölüm, verilerin ayırt edici özelliklerinin öğrenildięi evrişim, aktivasyon ve havuzlama katmanlarından; ikinci bölüm ise tam bağılı katmanlardan ve öğrenilen özniteliklerin sınıflandırıldığı softmax katmanından oluşmaktadır (Lecun vd., 2015).

Evrişim katmanındaki filtreler sayesinde verilerin birbiriyle ilişkili uzamsal bağımlılıkları keşfedilir. Evrişim işlemi sonucunda girdilerin ağırlıklı toplamı elde edilir. Bu katmanı, lineer bağımlılıklardan kurtulmak için bir aktivasyon katmanı takip eder. En çok tercih edilen aktivasyon fonksiyonu Düzeltilmiş Doğrusal Birim (ReLU), negatif deęerleri 0 olarak ayarlar. Aktivasyon haritaları bu katmanda elde edilir. Ardından, verideki deęerli bilgileri kaybetmeden boyut küçültmek için havuzlama katmanı gelir. Maksimum veya ortalama bir havuzlama yapılabilir. Girdi boyutu, filtre boyutu, adım ve dolgu gibi hiper-parametre deęerlerine bağılı olarak evrişim işlemleri birbiri ardına tekrarlanır. Öğrenilen öznitelikler tam bağılı katmana aktararak düzeltilir. Mimariye bağılı olarak, bir veya daha fazla tam bağılı katman olabilir. Son tam bağılı katman bir softmax katmanına geçirilir ve öğrenilen özniteliklerin sınıf olasılık deęerleri hesaplanarak model tahmini gerçekleştirilir.

Bir veri seti üzerinde eğitilmiş ESA modelleri farklı problemlerin çözümünde kullanılabilir. İnce-ayarlar olarak adlandırılan bu işlem sayesinde daha az veri ile daha hızlı bir şekilde eğitim tamamlanabilir (Fırıldak ve Talu, 2019). Bu çalışmada öncü ESA modellerinden AlexNet ons altın günlük fiyat yön tahmini için ince-ayarlar yaklaşımı ile kullanılmıştır.

AlexNet mimarisinin giriş görüntü boyutu 227x227 piksel çözünürlüktür. Mimari 1 giriş, 5 evrişim, 7 ReLU, 2 normalizasyon, 3 havuzlama, 3 tam bağlı katman, 2 bırakma katmanı, 1 softmax ve 1 çıktı katmanından oluşur. AlexNet mimarisinin genel yapısı ve hiper-parametre değerleri Şekil 3'te gösterilmiştir.



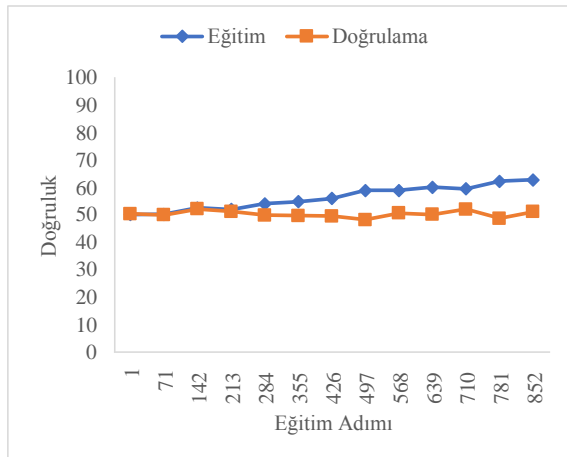
Şekil 3. AlexNet mimarisi (Altuntaş vd., 2019)

3. Bulgular

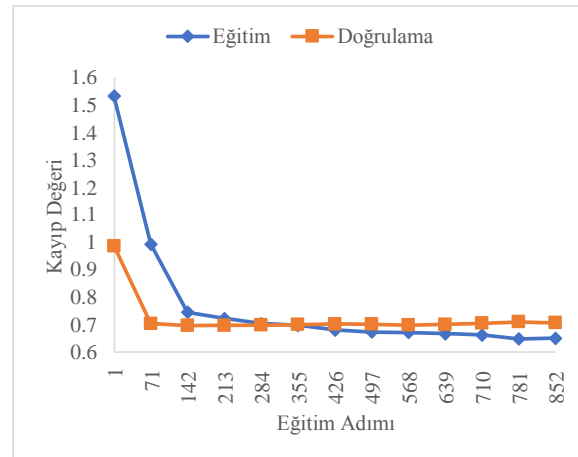
3.1. Deneysel Kurulum

Bu çalışmada, ons altın günlük fiyat yönünün tahmini için öncü ESA mimarilerinden AlexNet modelinin ince-ayrılanmasına dayanan bir yaklaşım önerilmiştir. Altın fiyat verilerinin etiketlenmesi, grafik görüntülere dönüştürülmesi, AlexNet modelinin ince-ayrılanması ve karlılık analizleri için piyasa benzetim prosedürü MATLAB © (R2020b) ortamında gerçekleştirilmiştir. Çalışmada kullanılan bilgisayar 2.6 GHz i5 işlemci, 512 GB SSD sabit disk, 8 GB DDR4 sistem belleği ve 4GB ekran kartına sahiptir.

AlexNet modelinin ince-ayrılanması için kullanılan hiper-parametre değerleri şu şekilde ayarlandı: Son tam bağlı katman 2 çıkışlı bir tam bağlı katman ile değiştirildi. Maksimum epoch sayısı 100, mini batch sayısı 32, öğrenme katsayısı 10^{-4} olarak ayarlandı. Bir epoch 71 eğitim adımı sürdü. Her epochda (71 eğitim adımında) bir kez doğrulama prosedürü çalıştırıldı. Durdurma kriteri olarak 10 doğrulama sonunda başarımlar artmazsa eğitim bitirildi. İnce-ayrılma prosedürü 12. epochda 852 eğitim adımında tamamlandı. İnce-ayrılma prosedürü 15 dakika 25 saniye sürdü. Eğitim adımları boyunca modelin eğitim ve doğrulama setleri üzerinde elde ettiği doğruluk ve kayıp değerleri Şekil 4'te gösterilmiştir.



(a)



(b)

Şekil 4. Eğitim adımları boyunca modelin (a) doğruluk ve (b) kayıp değeri değişim grafikleri

3.2. Sınıflandırma Sonuçları

Ons altın günlük fiyat yönünün tahmini için önerdiğimiz ince-ayrılanmış AlexNet ESA mimarisi yaklaşımımızın sınıflandırma başarımını ölçmek için sınıflandırma performans metriklerinden Doğruluk, Duyarlılık, Hassasiyet ve F-ölçütü kullanılmıştır. Çalışmada kullanılan sınıflandırma performans metriklerine ait matematiksel ifadeler aşağıda verilmiştir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + YN + DN} \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3)$$

$$\text{Hassasiyet} = \frac{DN}{DN + YP} \quad (4)$$

$$F - \text{ölçütü} = \frac{2 * DP}{2 * DP + YP + YN} \quad (5)$$

İki-sınıflı sınıflandırma problemlerinde sınıflandırma performansını ölçmek için sınıflardan biri pozitif diğeri negatif olarak ele alınır. Tahmin modelince doğru tahmin edilen pozitif örneklerin sayısı Doğru Pozitif (DP), doğru tahmin edilen negatif örneklerin sayısı Doğru Negatif (DN), yanlış tahmin edilen pozitif örneklerin sayısı Yanlış Negatif (YN) ve yanlış tahmin edilen negatif örneklerin sayısı Yanlış Pozitif (YP) olarak adlandırılır (Altuntaş ve Kocamaz, 2021).

Bu çalışmada YUKARI sınıfı pozitif ve AŞAĞI sınıfı negatif olarak ele alınmıştır. Gerçekleştirilen sınıflandırma performans metrikleri ölçümlerine göre, önerilen yaklaşımın Doğruluk, Duyarlılık, Hassasiyet ve F-ölçütü değerleri sırasıyla %53,8, %66,97, %37,54 ve %42,05 olarak ölçülmüştür.

3.3. Karlılık Analiz Sonuçları

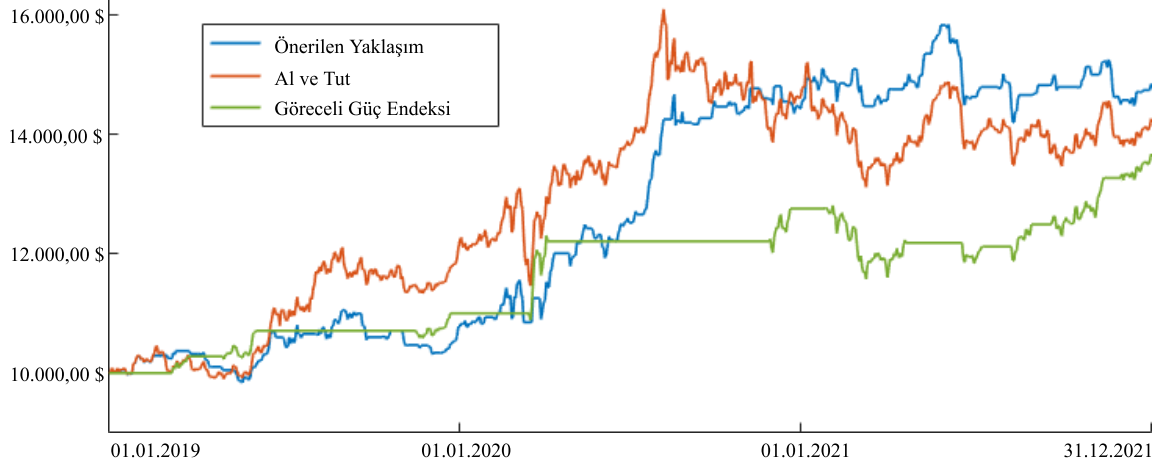
Finansal zaman serisi tahmin çalışmalarının nihai hedefi doğru alım-satım kararları vererek karlılığı arttırmaktır. Finansal piyasalarda gerçekleştirilen her alım-satım işleminin kar-zarar etkisi, bir başka deyişle büyüklüğü, eşit değildir. Finansal piyasalarda gerçekleştirilen az sayıda başarısız işlem ile oluşan zarar, çok sayıda başarılı işlem ile elde edilen kardan büyük olabilir. Bu nedenle, yüksek sınıflandırma başarımlarına sahip bir model zarar eden bir model olabilir. Finansal zaman serisi tahmin problemi bir sınıflandırma problemine indirgenmiş olsa da, sınıflandırma performans metrikleri finansal zaman serisi tahmin modellerinin gerçek performanslarını ölçmek için yeterli değildir.

Bu çalışmada, ons altın günlük fiyat yön tahmini için önerdiğimiz yaklaşımın gerçek performansını ölçebilmek için piyasa benzetimleri gerçekleştirilmiş ve karlılık analizleri yapılmıştır. Ayrıca önerilen yaklaşım, geleneksel alım-satım stratejilerinden Göreceli Güç Endeksi ve Al ve Tut ile karşılaştırılmıştır. Göreceli Güç Endeksi, aşırı alım ve aşırı satım seviyelerinin belirlenmesi için kullanılan, 0 ile 100 aralığında değer alan, bir teknik analiz osilatörüdür (Murphy, 1986). Al ve Tut stratejisi, yatırım yapılacak finansal varlığın yatırım dönemi başında alındığı, yatırım dönemi boyunca tutulduğu ve yatırım dönemi sonunda satıldığı bir yatırım stratejisidir.

Önerilen yaklaşımın karlılık analizleri 01.01.2019 – 31.12.2021 tarihleri arasında 3 yıl için gerçekleştirilmiştir. Piyasa benzetim senaryomuzda, alım-satım işlemlerine 10.000 \$ sermaye ile başlanılmıştır. Test dönemi boyunca her bir gün için önerilen tahmin modeline fiyat yön tahmini yaptırılmıştır. Tahmin modelinin ilk YUKARI tahmininde tüm sermaye ile alım işlemi gerçekleştirilmiştir. Alım işlemi yapıldıktan sonra ilk AŞAĞI tahmininde eldeki tüm varlık satılmıştır. Önerilen yaklaşım, geleneksel alım-satım stratejilerinden Göreceli Güç Endeksi ve Al ve Tut ile karşılaştırılmıştır. Göreceli Güç Endeksi değeri 70 ve üzerinde olduğunda satış, 30 ve altında olduğunda alış işlemi gerçekleştirilmiştir. Al ve Tut stratejisinde ise karlılık analizlerinin yapıldığı dönem başında (01.01.2019) alış ve dönem sonunda (31.12.2021) satış işlemi gerçekleştirilmiştir. Gerçekleştirilen karlılık analizlerinde işlem sayısı, dönem sonu sermaye ve kar oranı Tablo 2’de sunulmuştur. Ayrıca önerilen modelin ve karşılaştırma yapılan alım-satım stratejilerinin test dönemi boyunca sermaye değişimleri Şekil 5’de verilmiştir.

Tablo 2. Karlılık Analiz Sonuçları

Alım-Satım Stratejisi	Başlangıç Sermayesi	Gerçekleştirilen İşlem Sayısı	Dönem Sonu Sermaye	Kar Oranı (%)
Al ve Tut	10.000 \$	2	14.255,23 \$	42,55
Göreceli Güç Endeksi	10.000 \$	20	13.670,87 \$	36,71
Önerilen Yaklaşım	10.000 \$	202	14.841,66 \$	48,42



Şekil 5. Önerilen yaklaşım ve karşılaştırılan yatırım stratejilerine ait sermaye değişim grafikleri

4. Sonuç

Bu çalışmada, ons altın günlük fiyat yön tahmini için 2007-2021 yıllarına ait 15 yıllık tarihsel fiyat verisi kullanılmıştır. Çalışma kapsamında altın fiyat yön tahmini iki-sınıflı görüntü sınıflandırma problemi olarak ele alınmıştır. Bu amaçla, tarihsel altın fiyat verileri mum grafikleri ve teknik analiz göstergeleri yardımıyla grafik görüntülere dönüştürülmüştür. Oluşturulan görüntü verileri fiyatın bir sonraki işlem günündeki yönü dikkate alınarak AŞAĞI ve YUKARI olarak etiketlenmiştir. Görüntü verilerinin sınıflandırılması için ön-egitimli AlexNet ESA modeli ince-ayrılarak probleme uyarlanmış ve altın fiyat yön tahmini için ön-egitimli ESA modelinin kullanıldığı yeni bir yaklaşım önerilmiştir. Gerçekleştirilen deney sonuçlarına göre, önerilen yaklaşımın doğruluk, duyarlılık, hassasiyet ve F-ölçütü sınıflandırma performans metriği değerleri sırasıyla %53,8, %66,97, %37,54 ve %42,05 olarak ölçülmüştür. Ayrıca önerilen yaklaşım tahminlerine dayalı bir algoritmik altın ticaret modeli için piyasa benzetimleri gerçekleştirilmiş ve karlılık analizleri yapılmıştır. 3 yıllık test dönemi boyunca gerçekleştirilen karlılık analiz sonuçları önerilen yaklaşımın %48,42 kar oranı ile diğer alım-satım stratejilerinden daha karlı olduğunu göstermektedir.

Gelecek çalışmalarda ESA mimarilerine dayalı algoritmik ticaret modelleri farklı finansal varlıklar için uyarlanacaktır. Ayrıca modellerin hatalı tahminlerini azaltarak karlılığını arttırmak için hibrit çözümler geliştirilecektir.

Kaynaklar

- Achelis, S.B. (1995). *Technical Analysis from A to Z*. Second Edition. McGraw-Hill, New York, USA.
- Aldhyani, Theyazn H.H., and Ali Alzahrani. (2022). Framework for Predicting and Modeling Stock Market Prices Based on Deep Learning Algorithms. *Electronics* 2022, Vol. 11, Page 3149 11(19): 3149.
- Altuntaş, Yahya, Cömert, Zafer and Kocamaz, Adnan Fatih. (2019). Identification of Haploid and Diploid Maize Seeds Using Convolutional Neural Networks and a Transfer Learning Approach. *Computers and Electronics in Agriculture* 163(40): 1–11.
- Altuntaş, Yahya, and Kocamaz, Adnan Fatih. (2021). Deep Feature Extraction for Detection of Tomato Plant Diseases and Pests Based on Leaf Images. *Celal Bayar Üniversitesi Fen Bilimleri Dergisi* 17(2): 145–52.
- Cao, Jiasheng, and Jinghan Wang. (2019). Stock Price Forecasting Model Based on Modified Convolution Neural Network and Financial Time Series Analysis. *International Journal of Communication Systems* 32(12): e3987.
- Cavalcante, Rodolfo C. et al. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications* 55: 194–211. <http://dx.doi.org/10.1016/j.eswa.2016.02.006>.
- Chen, Jou Fan et al. (2017). Financial Time-Series Data Analysis Using Deep Convolutional Neural Networks. *Proceedings-2016 7th International Conference on Cloud Computing and Big Data, CCB D 2016*: 87–92.
- Dingli, Alexiei, and Fournier, Karl Sant. (2017). Financial Time Series Forecasting – A Deep Learning Approach. *International Journal of Machine Learning and Computing* 7(5): 118–22.
- Durairaj, M., & Krishna Mohan, B. H. (2019). A review of two decades of deep learning hybrids for financial time series prediction. *International Journal on Emerging Technologies*, 10(3), 324–331.

- Fırıldak, K. & Talu, M.F. (2019). Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Computer Science*, 4(2), 88-95.
- Jiang, W. (2021). Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications*, 184(March 2020), 115537.
- Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. (2017). ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM* 60(6): 84–90.
- Lecun, Yann, Yoshua Bengio, and Geoffrey Hinton. (2015). Deep Learning. *Nature* 521(7553): 436–44.
- Li, A. W., & Bastos, G. S. (2020). Stock market forecasting using deep learning and technical analysis: A systematic review. *IEEE Access*, 8, 185232–185242.
- Liu, Liying, and Si, Yain Whar. (2022). 1D Convolutional Neural Networks for Chart Pattern Classification in Financial Time Series. *Journal of Supercomputing* 78(12): 14191–214.
- Murphy, John J. (1986) *Technical Analysis of the Futures Market*. New York Institute of Finance.
- Niu, Tong et al. (2020). Developing a Deep Learning Framework with Two-Stage Feature Selection for Multivariate Financial Time Series Forecasting. *Expert Systems with Applications* 148: 113237.
- Özbayoğlu, A. M., Güdelek, M. U., & Sezer, Ö. B. (2020). Deep learning for financial applications: A survey. *Applied Soft Computing Journal*, 93, 106384.
- Sezer, Ömer Berat, and Ahmet Murat Özbayoğlu. (2018). Algorithmic Financial Trading with Deep Convolutional Neural Networks: Time Series to Image Conversion Approach. *Applied Soft Computing* 70: 525–38.
- Sezer, Ö. B., Güdelek, M. U., & Özbayoğlu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing Journal*, 90, 106181.
- Zulqarnain, Muhammad et al. (2020). Predicting Financial Prices of Stock Market Using Recurrent Convolutional Neural Networks. *International Journal of Intelligent Systems and Applications* 12(6): 21–32.