

Yapay Sinir Ağı Modeli ile BİST'e Kote 10 Bankanın Covid-19 Dönemindeki Finansal Verilerinin Tahminlenme Başarısı Üzerine Bir Araştırma

A Research on The Success of Forecasting The Financial Data of 10 Banks
Qualified to The BIST with The Artificial Neural Network Model

Öz

Yapay sinir ağı modeli, yapay zekâ ve makine öğrenmesi modellerinin temelini oluşturmaktadır. Yapay sinir ağı modelinden yola çıkılarak evrimsel sinir ağları, destek vektör makine ve genetik algoritmalar gibi pek çok farklı model türetilmiştir. Bu çalışma yapay zekâ teknolojilerinin temelini oluşturan, yapay sinir ağı modelinin Covid-19 döneminde, bankaların finansal verilerine dayanarak modelin tahmin gücünü test etmek amacıyla yapılmıştır. Çalışmada Borsa İstanbul BİST'e kote olan 10 bankanın, 2005-2021 yılları arasındaki finansal verileri kullanılmıştır. Verilerin analizi noktasında toplamda 17 yıllık veriden oluşan veri setinden Covid-19 dönemine ait olan 2020-2021 dönemine ait 2 yıllık veri test verisi olarak kullanılmıştır. Geriye kalan 15 yıllık verinin içerisinde 13 yıllık kısmı modelin eğitimi için geriye kalan rastgele seçilmiş 2 yıllık kısmı ise modelin Covid-19 dönemi dışındaki başarısını ölçmek üzere test verisi olarak kullanılmıştır. Çalışmada analiz edilen yapay sinir ağı modelleme yönteminin ekonomik volatilitenin düşük olduğu dönemler analize dahil edilen 10 bankaya ilişkin değişkenlerin gelecek değerini tahminlemede %84-%78 aralığında başarılı olduğu gözlemlenirken, Covid-19 döneminde bankacılık sisteminde ilgili değişkenlere ilişkin tahminlemede başarı oranının %50 ila %80 arasında değiştiği gözlemlenmiştir.

Abstract

The artificial neural network (ANN) modeling underlies artificial intelligence and machine learning models. Many different models, including convolutional neural networks, support vector machines, and genetic algorithms, have been derived based on the ANN model. This study attempts to test the predictive power of the ANN model using financial data on banks for the Covid-19 period. For this purpose, we employ the 2005-2021 financial data on 10 banks listed on the Istanbul Stock Exchange (ISE). In the context of the analysis, the 2020-2021 data were employed as the test data for the Covid-19 period, while the 13-year data of the remaining 15 years were used for training the model, and the remaining 2-year data was used to measure the model's success off the Covid-19 period. The results from the analyses reveal that, in estimating the future value of the variables related to the 10 banks, the ANN modeling is successful in the range of 84% to 78% during periods of low economic volatility, while the success rate varies between 50% and 80% for the Covid-19 period.

Giriş

1 Aralık 2019'da Çin'in Vuhan kentinde başlamış olan, sonrasında 11 Mart 2020'de ülkemizde ilk vakanın görülmesiyle birlikte 1 Nisan 2020 itibarıyla Türkiye'nin ve tüm dünyanın katı bir izolasyon sürecine girmesine neden olan Covid-19 pandemisi dünya çapında bir pandemi olma özelliği taşımaktadır. İnsanlık tarihine baktığımızda Asya gribi, İspanyol gribi, veba gibi pek çok salgın görülmektedir. Covid-19'un bu denli yayılabilmesinin sebebi şüphesiz ki dünya gelişmiş

Serkan Varsak

Dr. Öğr. Üyesi, Bilecik Şeyh Edebali
Üniversitesi, Bilecik, Türkiye
serkan.varsak@bilecik.edu.tr,
Orcid No: <https://orcid.org/0000-0002-5894-1490>

İbrahim Özkan

Doktora öğrencisi, Bilecik Şeyh Edebali
Üniversitesi, Bilecik, Türkiye
i.ozkan1990@gmail.com
Orcid No: <https://orcid.org/0000-0003-4792-6743>

Article Type / Makale Türü

Research Article / Araştırma Makalesi

Anahtar Kelimeler

Yapay Sinir Ağı, Covid-19, Finansal Tahmin
Başarısı

Keywords

Artificial Neural Network, Covid-19, Financial
Forecasting Success

JEL Codes: G17, G21, G10

Submitted: 23 / 11 / 2022

Accepted: 31 / 12 / 2022

ulaşım ağlarımızdır. Yerel ekonomilerin yerini alan küresel ticaret nedeniyle tedarik zincirlerindeki herhangi bir aksaklık dünya ekonomisi üzerinde negatif etkisini hızlıca gösterebilmektedir.

Covid-19 döneminde sosyal ve ekonomik hareketliliğin durma noktasına gelmesi de en başta tedarik zincirlerindeki aksamalarla birlikte pek çok olumsuz ekonomik sonuçlar doğurmuştur. Gıda ve sağlık sektörü dışındaki tüm sektörler neredeyse durma noktasına gelmiştir. Reel sektör üzerindeki olumsuz etkisi zamanla finans sektöründe de hissedilir duruma gelmiş ve gerek ulusal gerekse uluslararası ticarete ciddi ekonomik daralma yaşanmış ve bu durum kısa sürede sosyo-ekonomik refah üzerinde ki olumsuz makroekonomik etkilerini hissettirmeye başlamıştır.

Pandemik salgının finans sektörü üzerinde ki etkileri ve reel sektörün finansmanı konusunda yaşanan aksaklıklar ülke ekonomilerini daraltıcı para ve maliye politikaları uygulamaya zorlamış dünya ekonomisi finansal açıdan yeniden yapılanma dönemine girmiştir. Bu kapsamda pandemik salgının finans sektörü ve dolayısıyla reel sektör üzerinde ki olumsuz etkilerinin analizi ve uluslararası toplumu bekleyen olası pandemik felaketlerde yaşanan olumsuzlukların olası etkilerini önceden belirleyebilmenin önemi bir kere daha artmıştır. Bu bağlamda bu çalışmada Türkiye ekonomisinde BİST'e kote 10 bankanın pandemi öncesi pandemi dönemi ve pandemi sonrası verileri yapay sinir ağı modeli yardımı ile test edilmiştir.

1. Yapay Sinir Ağı Modeli

1.1. Kavramsal Olarak Yapay Sinir Ağı Modelleri

Yapay sinir ağları (YSA), insan beyninden ilham alınarak geliştirilmiş, ağırlıklı kanallar yolu ile bağlanan hem dağıtılmış hemde birbirine paralel kendi hafızasına sahip işlem öğelerinden oluşur. Biyolojik sinir ağ yapılarına öykünen dijital programlarıdır. Literatürde sinirsel işlem, yapay zeka, bağlantıcılık ve makine öğrenmesi gibi farklı isimler ile de anılmaktadırlar (Elmas, 2011, s. 23).

Literatürde yaygın kullanılan adı ile yapay sinir ağı modellerinin temelini insan beyninin bilgisayar algoritmalarından oldukça farklı hesaplama yaptığının keşfedilmesine dayanmaktadır. İnsan beyni paralel, karmaşık ve doğrusal olmayan bir bilgi işleme sistemidir. Bir yapay sinir ağı, deneyimsel bilgiyi kodlamak ve kullanılma hazırlamak üzere kurgulanmış, paralel dağılıma sahip basit bir işlemcidir. Sinir ağları iki yönüyle insan beynine benzemektedir. İlk olarak bilgi, ağ tarafından basit öğrenme sayesinde çevre birimlerden edinilir. Ayrıca sinaptik ağırlıklar olarak adlandırılan internöron bağlantı güçleri, kazanılmış bilgiyi depolamak için kullanılır (Haykin, 2009, s. 31-32).

İlgili literatürde yapay zeka ile ilgili yapılan analizlere önemli ölçüde destek veren çalışmalar yapay sinir ağları teknolojisi ile ilgili yapılan çalışmalardır. Dolayısıyla yapay zeka teknolojisinin bir alt dalı da yapay sinir ağı teknolojileridir. Nöronları işlevsel ve şeklen taklit eden YSA'lar biyolojik sinir ağları için simule programlar olmaları nedeniyle yapay zeka uygulamalarının temelini oluşturur (Yurtoğlu, 2005).

Yapay sinir ağı temelde beyin hücresi olan nöron'un kabaca taklidine dayanır. Beyin sinir sistemi ile gelen sinyali nöron denem hücrelere aktarır. Nöronlar kendisine gelen sinyali kendi bağlı olduğu diğer nöronlara iletir. Onlar da aynı şekilde diğer nöronlara aktarır. Yapay sinir ağı da beynin bu yapısını kısmen taklit eder (Kuyumcu, 2018, s. 311).

YSA teknolojileri, sinir ağları ve hücrelerinin dijital ortamda simule edilmesiyle oluşturulan bilgi işleme sistemleridir. Yapar sinir ağları birbiri ile bağlantılı, paralel çalışan her biri kendi bilgiişleme yeteneği ve belleği bulunan dağıtılmış bilgiişlem teknolojisidir. Yapay sinir ağının en önemli özelliği öğrenebilme yeteneğidir. Doğal olarak bu öğrenebilme yeteneği insan öğrenmesine göre oldukça dar kapsamlı ve sınırlıdır. Ancak yapay sinir ağı ile elde edilen veriler arasındaki ilişkileri öğrenebilir ve belirli kapsam ve sınırlı da olsa çözümler üretilebilir (Yıldız, 2009, s. 55).

Yapay sinir ağları (YSA), beyindeki nöronların kurdukları sinaps bağlantılarından esinlenilerek oluşturulmuş bir makine öğrenmesi algoritmasıdır. Yapay sinir ağları biyolojik sinir sistemlerinin çalışma prensiplerinden yola çıkarak geliştirilmiştir. Bu nedenle yapay sinir ağları, yani derin öğrenme kullanılarak geliştirilen bir yapay zekâ sistemi, aslında biyolojik canlılar gibi öğrenmektedir (Aksoylu, 2021, s. 309).

Yapay zeka yöntemi olan YSA'lar, insan beynini modelleyerek simule etme çabasıdır. Simulasyonlarda sinir hücrelerinin ağ yapısından hareket edilir. YSA'lar ile ilgili literatürde öncelikle tıp alanında yapılan çalışmaları, matematik, bilgisayar mühendisliği ve elektrik mühendisliği gibi alanlar araştırma evreni olarak seçmişlerdir (Yılmaz, 2020, s. 61).


Bir diğer çalışmada kavramsal olarak YSA, basit işlemcilerden oluşan algoritmalarıdır. YSA'lar farklı şekillerde numerik veriler ile ağırlıklandırılmış ya da bağlanmış sistemlerdir. YSA ile ilgili çalışmaların temel dayanak noktası insan beyninin düzenli olarak yaptığı karmaşık algoritmik yapıları hesaplayabilen ve ilerleyen aşamalarda zeki davranış kalıplarına sahip sistemler yaratma amacıdır. Çalışmalarda YSA'lar için çeşitli öğrenme yöntemleri kullanılır. Her bir yöntemde sistemin ağırlıkları değişime uğrar. Ağırlıklarda meydana gelen her bir değişim öğrenme olarak adlandırılır ve ağırlık değişimleri sonlandıysa öğrenmenin bu noktada durduğu kabul edilir. (Sağiroğlu, Beşdok, & Erler, 2003, s. 24). Bir diğer çalışmada ise YSA'lar, insan beyninin temel özellikleri; keşfetme, öğrenme ve yeni bilgi üretimi gibi yetenekleri kodlama yolu ile sistematize eden bir yöntem olarak tanımlanmaktadır (Öztemel, 2016, s. 29).

Yapay sinir ağları (YSA), mimari olarak insan beynini modelleyerek öğrenme kabiliyetini kazanmayı amaçlayan yapay zekâ yöntemlerinden biridir. Yapısında bulunan nöronlar sayesinde bilgi kendi hafızasında tutulmakta ayrıca ağırlıklar sayesinde katmanlarda bulunan nöronlar birbiriyle bağlanmaktadır. YSA, dağıtık bir mimariye sahiptir ve paralel olarak bilgiyi işler. YSA, sinir ağlarını simule eden bilgisayar programlarıdır ve YSA kendi kendine öğrenme yolu ile sistemin devamını sağlar (Yılmaz & Kaya, 2021, s. 30).


1.2. Metodolojik Olarak Yapay Sinir Ağı Modelleri

YSA'lar girdi, çıktı ve gizli katman adı verilen 3 farklı katmandan oluşur. Girdi katmanında toplanan veriler yapay sinir ağlarına iletilir ve istatistiksel olarak bağımsız değişken adı da verilen modelin dış belirleyicileridir. Çıktı katmanı ise oluşturulan verilerin dışarıya iletilmesini sağlayan sistemin bağımlı değişkenleridir. Ayrıca sistemin bir diğer unsuru olan gizli katman ise çıktı ve girdi katmanları arasında yer alan dış ortam ile bağlantısı olmayan, iki katman arasında veri alışverişini sağlayan katmandır. Toplam 3 katmanda oluşan YSA'larda ağ yapısı ve yapının performansının belirlenmesinde hata kareler ve mutlak hata ortalamaları kullanılır. Belirlenmesi gereken gizli katman sayısı, hata kareleri ve mutlak hata ortalamasının en küçük değeri üzerinden belirlenir (Küçükkocaoglu vd.; 2005, 10).

1.3. Matematiksel Gösterimi



Şekil 1. Kurmuş olduğumuz YSA Modelinin Yapısı



Şekil 2. Yapay Sinir Hücresi

Korelasyon katsayısı (r)

$$r = \frac{\sum(xy) - \frac{(\sum x)(\sum y)}{n}}{\sqrt{\left(\sum x^2 - \frac{(\sum x)^2}{n}\right) \left(\sum y^2 - \frac{(\sum y)^2}{n}\right)}}$$

Ortalama Mutlak Hata (Mean Absolute Error)

$$\frac{\sum_{i=1}^n |\hat{\theta}_i - \theta_i|}{n}$$

n = örneklem sayısı

θ_i = i sıra numaralı gerçek talep

$\hat{\theta}_i$ = i sıra numaralının tahmin edilen talebi

i = örneklem sırası

Hataların Karelerinin Ortalamasının Karekökü (Root Mean Squared Error)

$$\sqrt{\frac{\sum_{i=1}^n |\hat{\theta}_i - \theta_i|^2}{n}}$$

Göreceli Mutlak Hata (Relative Absolute Error)

$$\frac{\sum_{i=1}^n |\hat{\theta}_i - \theta_i|}{\sum_{i=1}^n |\bar{\theta} - \theta_i|}$$

$\bar{\theta}$ = gerçek taleplerin ortalaması

Göreceli Mutlak Hata Karekökü (Root Relative Squared Error)

$$\sqrt{\frac{\sum_{i=1}^n (\hat{\theta}_i - \theta_i)^2}{\sum_{i=1}^n (\bar{\theta} - \theta_i)^2}}$$

2. Finansal Tahminlemede Yapay Zeka Uygulamaları

20. yüzyılın ikinci yarısında finansal derinliğin artması ve dolayısıyla finansal araç sayısında yaşanan artışlar beraberinde finansal araçların, finans piyasaları üzerinde ki etkinliğinin ölçülmesi hususunda yeni yöntemlere olan ihtiyacı arttırmıştır. Bu anlamda yapay zeka uygulamaları bu alandaki ihtiyacı karşılamak üzere geliştirilmiştir. İktisat yazınında finansal

tahminlemede farklı disiplinlerde kullanılmış olan yapay zekâ modelleri üzerine yapılmış bazı çalışmalar aşağıda özetlenmiştir.

Odom ve Sharda (1990) çalışmalarında iflas tahminine yönelik yapay sinir ağı modeli geliştirmişlerdir. Moody's Endüstriyel Manuales'tan alınan örneklemede 65'i iflas eden 64'ü iflas etmemiş toplamda 125 firmanın 1975-1982 yılları arasındaki finansal verileri kullanılarak diskriminant analizi ve yapay sinir ağı modelini üç farklı kombinasyonda karşılaştırmışlardır. Her üç kombinasyonda da yapay sinir ağı modeli diskriminant analizinden daha başarılı tahminler ortaya koymuştur.

Kim (2006)'in yapmış olduğu çalışmada finansal tahmin için evrimsel örnek seçimine sahip yapay sinir ağları modelini kullanmıştır. Kore hisse fiyat endeksi (KOSPI)'nin 1991-1998 yılları arasındaki verilerine dayanan kapanış fiyatı, düşük fiyat, yüksek fiyat gibi 8 farklı değişkeni temel alan modelde Genetik Algoritma tabanlı öğrenme ve örnek seçim algoritmasının (GAIS) Geleneksel Genetik Algoritma tabanlı öğrenmeden önemli ölçüde daha iyi performans gösterdiği sonucuna ulaşılmıştır.

Küçüköğlü, Benli ve Küçüksözen (2007)'in finansal bilgi manipülasyonu ve belirlenmesi için YSA modelinin kullanımına yönelik yapmış oldukları çalışmada İMKB'ye kote 126 şirketin 1992-2002 yılları arasındaki satışlardaki büyüme endeksi, ticari alacaklar endeksi, brüt kâr marjı endeksi gibi 10 farklı finansal oran verilerini içeren bir örneklem kullanmışlardır. Probit modeli ile yapılan çalışmanın sonucunda, modelin tahmin gücü ortalama %61 seviyesinde iken yapay sinir ağı modelinde %86,17 düzeyinde doğru tahmine ulaşmışlardır.

Akkaya, Demirelli ve Yakut (2009)'un yapay sinir ağları modeli ile işletmelerde finansal başarısızlık tahminlenmesi üzerine yapmış oldukları çalışmada İMKB'ye kote 53 işletmenin 1998-2007 dönemi için; finansal yapı rasyosu, faaliyet rasyosu, karlılık rasyosu ve likidite rasyoları ile 25 farklı değişkeni içeren finansal verileri kullanmışlardır. Çalışmanın sonucunda kurmuş oldukları yapay sinir ağı modeli başarılı işletmeleri %82 başarısız işletmeleri %80 oranında doğru tahminlemiştir.

Yıldız ve Akkoç (2009)'un banka finansal başarısızlıklarının sinirsel bulanık ağ yöntemi ile öngörüsü üzerine yaptıkları çalışmada 1997-2001 yılları arasında TMSF'ye devredilen 19, TMSF'ye devredilmeyen ve faaliyetlerini sürdüren 21 toplamda 40 adet bankaya ait sermaye, şube ve faaliyet rasyoları ile sektör payı, aktif kalitesi, gurup payı, likidite, gelir-gider yapısı, karlılık gibi 9 başlık altında 49 adet değişken içeren finansal verileri kullanmışlardır. Çalışma sonuçları finansal başarısızlık öngörü çalışmalarında sıklıkla kullanılan istatistiksel bir yöntem olan ayırma analizi modelinin sonuçlarıyla karşılaştırılmıştır. Karşılaştırma sonucunda sinirsel bulanık ağ modeli eğitim ve test verilerinin tahmininde ayırma analizi modelinden daha yüksek oranda başarı göstermiştir.

Çelik (2010)'in geleneksel ve yeni yöntemler ile bankaların finansal başarısızlıklarının tahminlenmesi üzerine yaptıkları çalışmada 1997-2002 yılları arasında 36 bankaya ait 36 farklı oranı kullanarak bir yapay sinir ağı modeli kurmuşlardır. Kurdukları model 1 yıl öncesine kadar %100 başarı oranı ile 2 yıl öncesine kadar %91,7 başarı oranı ile finansal başarısızlığı doğru tahminlemiştir.

Ekinci vd. (2010)'nin ekonomik kriz döneminde firma başarısı tahmini üzerine yapmış oldukları çalışmada aktif varlıkları 8 milyon TL'nin altında olan 18 imalat sektörü firmasının 2000-2001 yıllarına ait 14 farklı finansal orandan oluşan verileri kullanmışlardır. Kurdukları yapay sinir ağı modeli firmaların başarısız olma durumunu %100 başarı oranı ile doğru tahminlemiştir.

Mahfoud ve Mani (2013)'nin genetik algoritmalar kullanarak finansal tahmin üzerine yapmış oldukları çalışmada S&P 400 Hisse Senetleri verilerini kullanmışlardır. Kurdukları genetik algoritma modelinde 331 örnek hisse senedi verisinin %70'ini eğitim %20'sini gizli katman verisi %10'unu da test verisi olarak kullanmışlardır. Çalışmanın sonucunda ulaştıkları sonuç Genetik Algoritmaların Yapay sinir ağlarına göre bazı durumlarda ufak da olsa bir avantaj sağlayabildiği yönündedir.

Altunöz (2013) bankaların finansal başarısızlıklarının YSA modeli ile tahmin edilebilirliği üzerine yapmış olduğu çalışmada 36 adet özel sermayeli ticaret bankasının sermaye rasyosu, karlılık ve aktif rasyoları, gelir-gider oranı, likidite oranı, faaliyet rasyoları, temelinde 36 adet finansal

orandan oluşan 1997-2002 yılları arasındaki finansal verilerini kullanmıştır. Çalışmanın sonucunda, kurmuş olduğu yapay sinir ağı modelinin 1' yıl öncesine kadar %88 oranında 2' yıl öncesine kadar %77 oranında finansal başarısızlığı doğru tahmin edebildiği sonucuna ulaşmıştır.

Altınırnak ve Karamaşa (2016)'nın bankaların finansal başarısızlıklarının incelenmesinde makine öğrenme tekniklerinin karşılaştırılması üzerine yapmış oldukları çalışmada TBB ve BDDK'nın sağlamış olduğu verileri kullanmışlardır. Çalışma verileri iflas eden 17 ve iflas etmeyen 13 olmak üzere toplamda 30 özel sermayeli ticari bankanın 1996-2000 yılları arasındaki, likidite oranları, karlılık oranları, büyüklük oranları, mali yapı oranları gibi 7 ana başlık altında 46 farklı finansal oranı içermektedir. Çalışmanın sonucunda destek vektör makine algoritmasının çok katmanlı algılayıcı yapay sinir ağı algoritmasına göre finansal başarısızlığı daha yüksek oranda doğru tahmin etmekte olduğu sonucuna ulaşmışlardır.

Zoric (2016)'in bankacılık sektöründeki müşteri kaybının sinir ağları kullanarak tahmin edilmesi üzerine yaptıkları çalışmada bir Hırvat bankasının 1886 adet müşterinin çalışmanın yapıldığı yıla ait verileri yapay sinir ağı modelinde işlenerek analiz edilmiştir. Çalışmanın ana hipotezi, daha fazla banka hizmeti (ürün) kullanan müşterilerin daha sadık olduğu ve bankanın üçten az ürün kullanan müşterilere odaklanması ve onlara ihtiyaçlarına göre ürünler sunması gerektiğidir. Müşterinin bankadan ayrılma olasılığını belirleyebilmek için kurulan modelde müşterilerin: cinsiyet, yaş, özel durum, ortalama aylık gelir, internet bankacılığı kullanımı ve iki veya daha fazla banka ürünü kullanımı özellikleri değişken olarak kullanılmıştır. Bankacılık ürünleri ise döviz hesabı, kredi, birikim, internet bankacılığı, mobil bankacılık, SMS, düzenli siparişler ve tasarruf başlıkları altında kategorize edilmiştir. Çalışmanın sonucunda kurulan yapay sinir ağı modeli müşteri kaybını %93-95 aralığında doğru tahmin etmiştir.

Kışhada vd. (2016)'nin Malezya'da İslami Bankacılık 'ta müşteri sadakati değerlendirmesi için yapay zekâ kullanımına yönelik yaptıkları çalışmada araştırma verileri Malezya, Kuala Lumpur İslami Banka müşterilerine ait 2016 yılında yapılmış olan 6 bölüm, 61 sorudan oluşan ve 5'li likert tipi tutum ölçeği kullandıkları 373 anket verisine dayanmaktadır. Çalışma sonuçlarına göre kurmuş oldukları yapay sinir ağı %98 doğrulukla müşteri sadakatini tespit edebilmektedir.

Patil ve Dharwadkar (2017)'in makine öğrenimi kullanarak bankacılık verilerinin analizi üzerine yapmış oldukları çalışmada sınıflandırma yapmak için banka müşteri verileri ve alman kredi verileri olmak üzere iki veri seti kullanmışlardır. Sınıflandırma amacıyla denetimli yapay sinir ağı kullanılan çalışmada veri kümesi1 ve veri kümesi2 için sırasıyla %72 ve %98 doğruluk sağladığı, geliştirilen modelin iki veri seti için verimli çalıştığı, bu modeli kullanarak müşterilerin veya kredi durumlarının verimli bir şekilde belirlenebileceği sonucuna varılmıştır.

Hasan, Kalıpsız ve Akyokuş (2017)'un büyük verilerde finansal piyasa tahmini üzerine yapmış oldukları çalışmada S&P 500 hisse senetlerinin 1999-2013 yılları arasındaki açılış fiyatı, en düşük fiyat, en yüksek fiyat, kapanış fiyatı ve volüme değişkenlerinden oluşan veri setini kullanmışlardır. Çalışmada toplamda 3900 kayıttan oluşan veri setinin 3300 kaydı eğitim ve 600 kaydı test için kullanılmıştır. Yapay sinir ağı ve tekrarlayan sinir ağı ve lojistik regresyonun sonuçlarının karşılaştırıldığı çalışmada. Tekrarlayan sinir ağı modelinin, yapay sinir ağı ve lojistik regresyona göre daha iyi bir performans gösterdiği görülmüştür.

Atlan vd. (2018)'nin Bitcoin'in Türkiye piyasasındaki değerinin yapay zekâ teknikleri ile tahmini üzerine yaptıkları çalışmada 2017-2018 aralığından seçilmiş toplamda 365 adet bitcoin fiyatını kullanarak polinomları kullanarak veri noktalarını temsil eden en iyi eğriyi gösteren matematiksel bir yöntem olan eğri uydurma ve Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) modelini kıyaslamışlardır. Çalışmanın sonucunda ANFIS modelinin polinomsal eğri uydurmaya göre daha iyi sonuçlar verdiği ve bitcoin fiyatlarını %4-5 aralığında hata payı ile doğru tahminleme yaptığı görülmüştür.

Özer, Sarı ve Başakın (2018)'in bulanık mantık ve yapay sinir ağları ile borsa endeks tahmini üzerine yaptıkları çalışmada gelişmekte olan 4 ülke ve gelişmiş 4 ülkenin 2012-2016 yılları arasındaki borsa kapanış verileri kullanılmıştır. Kurdukları modelde verilerin %60'ını eğitim %40'ını test olarak ayırıp yapay sinir ağı modelinin ve bulanık mantık modelinin başarısını test etmişlerdir. Çalışmanın sonucunda her iki yöntemde yakın tahmin sonuçları verdiği görülmüştür.

Söyler ve Kızılkaya (2018)'nın para krizlerinin yapay zekâ yöntemleri ile tahmini için Türkiye örneği üzerinden yapmış oldukları çalışmada bağımlı değişken olarak para krizini temsilen döviz piyasası baskı indeksi EMP ve bağımsız değişkenler olarak da M1, M2, BIST 100 % değişim gibi 8 farklı değişken kullanılmıştır. Çalışmanın sonucunda kullanılan yöntemlerin test performansları incelendiğinde Türkiye için para krizi tahmininde kullanılan yapay sinir ağı modelinin, Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) modeline göre daha başarılı sonuçlar verdiği gözlemlenmiştir.

Sakız ve Kutlugün (2018)'ün blok zinciri teknolojisi ve yapay zekâ algoritmaları ile bitcoin fiyat tahminleme üzerine yapmış oldukları çalışmada 2017-2018 aralığına ait btc alış fiyatları aylık ortalama kapanış verileri kullanılmıştır. Araştırmanın sonucunda 2018 yılı şubat ayı bitcoin fiyatı tahmini 170.730.000 \$, olarak tahmin edilmiş ve bu rakamın gerçek fiyata göre çok yüksek olmasından dolayı kurulan yapay sinir ağı modelinin başarısız olduğu sonucuna ulaşılmıştır.

Yürük ve Ekşi (2019)'un yapay zekâ yöntemleri ile işletmelerin finansal başarısızlığının tahmin edilmesi üzerine yapmış oldukları çalışmada BİST imalat sektörünü ele almışlardır. Kamuyu aydınlatma platformu (KAP)'ın sunmuş olduğu 12 aylık finansal tablolardan ve raporlardan elde edilen veriler 2008-2016 yılları arasındaki veriler kullanılmıştır. Likidite oranları, finansal yapı oranları, faaliyet ve karlılık oranları olmak üzere 4 ana başlık altında 26 finansal oran modelde değişken olarak kullanılmıştır. İlgili çalışmada, iki yıl arka arkaya zarar etmiş olma, BİST gözaltı pazarında olmak, iflas, faaliyetlerini durdurmak ve toplam aktif tutarında %10 kayıp yaşamış olmak gibi kriterler finansal başarısızlık kriteri olarak kabul edilmiştir. Çalışmanın sonucunda kurulan modellerden yapay sinir ağının, destek vektör makine modeline göre daha iyi performans gösterdiği sonucuna varılmıştır.

Korkmaz (2020)'ın yapay zekâ yöntemleriyle sınıflandırma ve finans sektöründe kurumsal müşteriler üzerin yapmış olduğu çalışmada bir bankadan alınan makyajlanmış gerçek kurumsal müşteri verileri kullanılmıştır. 16 bilinmeyen açıklayıcı değişkenin kullanıldığı çalışmada yapay sinir ağı modeli, destek vektör makine modeli ve lojistik regresyon modeli karşılaştırılmıştır. Çalışmanın sonucunda kurumsal veri kümesi için destek vektör makine ve yapay sinir ağının lojistik regresyona göre daha başarılı olduğu ve kendi aralarında ise yakın bir başarı oranına sahip olduğu görülmüştür. Dengeli kurumsal veri için ise yapay sinir ağı modelinin destek vektör makine modelinden daha başarılı olduğu ve destek vektör makine modelinin de lojistik regresyon modelinden daha başarılı olduğu sonucuna ulaşılmıştır.

Çağlar ve Yavuz (2021)'in finansal ekonomi haberlerinin bitcoin piyasasına etkisinin YSA ile analizi üzerine yapmış oldukları çalışmada en etkin 5 uluslararası gazete olarak belirledikleri Moskovskiy Komsomolets, The Wall Street, Nihon Keizai Shinbun, Financial Times, Handelsblatt ve gazetelerinin 2009-2018 yılları arasındaki haberlerini incelemişlerdir. Olumsuz yorum içeren haberleri (1), o tarihte haber olamayan içeriği (2) ve olumlu yorum içeren haberleri (3) şeklinde kategorize edip sayısallaştırarak kurmuş oldukları yapay sinir ağı modelinde bitcoin fiyatlarının tahminlenmesinde gazete haberlerine ek olarak, bitcoin cüzdan sayısı, bitcoin cüzdanı günlük işlem sayısı, zorluk derecesi, gibi 14 farklı değişkeni de birlikte kullanarak yaptıkları analizler sonucunda Bitcoin fiyat tahmini ile ilgili literatürde yer alan çalışmalardan daha yüksek doğruluk tahmini oranına ulaşmışlardır. Yapılan analiz sonucu gazete haberlerinin Bitcoin fiyatlarının tahminlenmesinde yüksek bir etkisi olmadığı ve The Wall Street gazetesinin Bitcoin ile ilgili haberlerinin analizdeki diğer yayın kuruluşu haberlerine oranla daha güçlü bir etki oluşturduğunu sonucuna ulaşmışlardır. Arda ve Küçükoğlu (2021) yapay zekâ yöntemleri ile hisse senedi fiyat öngörülerini üzerine yapmış oldukları çalışmada BIST 30'un 2014-2016 yılları arasındaki verilerini kullanmıştır. Çalışmada Poisson regresyonu, Bayes doğrusal regresyon, hızlı karar ormanı regresyonu, hızlı orman yüzdelerik dağılım regresyonu, nöral ağ regresyonu, karar ağacı regresyonu ve doğrusal regresyon olmak üzere toplamda 7 farklı yapay zekâ modeli kullanılmıştır. Kısa, orta ve uzun vade yatırımları değerlendirmek üzere üç farklı deney yapılmış kısa vadede en etkin modelin hızlı orman yüzdelerik regresyon, orta vadede destekli karar ormanı regresyonu ve kısa vadede Poisson regresyonu modelinin verdiği gözlemlenmiştir. Araştırmanın sonucunda her durumda etkin tahmin yapan yapay zekâ modelinin olmadığı sonucuna ulaşmışlardır.

Yurttabir ve Sen (2021) finansal performans tahmininde prophet modeli üzerine yapmış oldukları çalışmada imalat sektörünü ele almışlardır. Net Dönem Kar/Zarar oranının bağımlı değişken olarak kullanıldığı çalışmada, net kâr marjı, özkaynak karlılık oranı, aktif karlılık oranı, hasılat, cari oran, brüt kar/zarar, asit test oranı ve vergi öncesi kar/zarar bağımsız değişken olarak kullanılmıştır. Çalışmada kamu aydınlatma platformu (KAP)'ın sunmuş olduğu BİST'dE imalat alanında işlem gören 173 şirketin 2009-2020 yıllarına ait verilerinden faydalanılmıştır. Çalışmaları literatürde finansal performans tahmininde Facebook Prophet yöntemiyle yapılmış bir çalışmaya rastlanmadığı için bu boşluğa katkı sağlamayı amaçlamıştır. Ulaştıkları sonuçları ise şirketlerin geniş bir veri bilimi ekibine sahip olmamaları durumunda prophet modelinin tercih edilebileceği, yöntemin fazla çaba gerektirmeden şirketlere zaman kazandırabileceği sonuçlarına varmışlardır.

3. Veri Metodoloji

Yapay sinir ağı modelinin Covid-19 dönemindeki finansal tahmin gücünü test etmek için banka verileri üzerinden bir uygulama yapmaktır. Araştırma yöntemi olarak BİST'e kote olmuş 10 bankanın 2005-2021 yılları arasındaki finansal oranlarını kullanarak Covid-19 dönemindeki durumlarının kurulan YSA modeli tarafından tahmin edilmesini ve elde edilen sonuçların modelin normal dönemdeki tahmin gücü ile kıyaslanarak yorumlanmasını kapsamaktadır. Bist'e kotasyonunu tamamlamış 12 banka olmasına rağmen 2 bankada ki veri kaybı nedeniyle ilgili bankalar analiz dışı tutulmuştur.

3.1. Verilerin Analizi

Verilerin analizi noktasında Yeni Zelanda Waikato Üniversitesi tarafından geliştirilmiş açık kaynak kodlu bir yazılım olan Weka makine öğrenimi yazılımından yararlanılarak kurmuş olduğumuz yapay sinir ağı modelleri test edilmiştir. Elimizde bulunan toplamda 17 yıllık veriden oluşan veri setinden Covid-19 dönemine ait olan 2020-2021 dönemine ait 2 yıllık veri test verisi olarak kullanılmıştır. Geriye kalan 15 yıllık verinin içerisinde 13 yıllık kısmı modelin eğitimi için geriye kalan rastgele seçilmiş 2 yıllık kısmı ise modelin Covid dönemi dışındaki başarısını ölçmek üzere test verisi olarak kullanılmıştır.

3.2. Kullanılan Değişkenler

Yukarıdaki tabloda görülen 12 banka da BİST'e kote'dir fakat Albaraka Türk Katılım Bankası A.Ş. ve ICBC Turkey Bank A.Ş. olmak üzere 2 bankanın verilerinde eksiklikler mevcut olduğundan bu iki banka çalışmanın dışında tutulmuştur.

Yeni sıralamamız aşağıdaki gibi olmuştur:

Tablo 1. Analize Dahil Edilen Bankalar ve Kodları

Kod	Şirket Unvanı
B1	Banka 1*
B2	Banka 2*
B3	Banka 3*
B4	Banka 4*
B5	Banka 5*
B6	Banka 6*
B7	Banka 7*
B8	Banka 8*
B9	Banka 9*
B10	Banka 10*

*İlgili banka isimleri KVKK gereği hukuki olarak olumsuz bir sonuç yaratmaması adına gizli tutulmuş, ilgili banka verileri kodlama ile analize dahil edilmiştir.

Derlediğimiz verilerde bulunan değişkenler aşağıda görüldüğü üzere normal şartlarda 32 adettir. Bankacılık sisteminde hali hazırda var olan tüm rasyolar analize dahil edilmiş ancak X1, X9, X15, X16, X17, X18, X24, X25 olmak üzere toplamda 8 adet finansal oran araştırmaya konu yıllar

içerisinde mevzuat değişikliği vb nedenlerle eksik olduğundan verilerden çıkarılmış kalan 24 oran analize dahil edilmiştir. Çalışmanın literatür kısmında detaylı olarak özetlendiği üzere; Odom ve Sharda (1990), Akkaya, Demirelli ve Yakut (2009), Yıldız ve Akkoç (2009), Çelik (2010), Ekinci vd. (2010), Altunüz (2013), Altınırnak ve Karamaşa (2016), Yürük ve Ekşi (2019) çalışmalarında tarafımızca belirlenen değişkenler ile yapay sinir ağı modellerinin etkinliğini test etmişlerdir. Analize dahil edilen değişkenler ilgili çalışmalar baz alınarak belirlenmiştir. Literatürden farklı olarak çalışmamızda veri kaybı yaşanan rasyolar modelin tahminleme başarısını arttırmak adına analize dahil edilmemiştir.

Tablo 2. Oranlar

X	ORANLAR
X1	Özkaynaklar / (Kredi + Piyasa + Operasyonel Riske Esas Tutar)
X2	Özkaynaklar / Toplam Aktifler
X3	(Özkaynaklar- Duran Aktifler) / Toplam Aktifler
X4	Net Bilanço Pozisyonu / Özkaynaklar
X5	(Net Bilanço Pozisyonu + Net Nazım Hesap Pozisyonu) / Özkaynaklar
X6	TP Aktifler / Toplam Aktifler
X7	TP Pasifler / Toplam Pasifler
X8	YP Aktifler / YP Pasifler
X9	TP Mevduat / Toplam Mevduat
X10	TP Krediler / Toplam Krediler
X11	Toplam Mevduat / Toplam Aktifler
X12	Alınan Krediler / Toplam Aktifler
X13	Finansal Varlıklar (net) / Toplam Aktifler
X14	Toplam Krediler / Toplam Aktifler
X15	Toplam Krediler / Toplam Mevduat
X16	Takipteki Krediler (brüt) / Toplam Krediler
X17	Takipteki Krediler (net) / Toplam Krediler
X18	Özel Karşılıklar / Takipteki Krediler
X19	Duran Aktifler / Toplam Aktifler
X20	Tüketici Kredileri / Toplam Krediler
X21	Likit Aktifler / Toplam Aktifler
X22	Likit Aktifler / Kısa Vadeli Yükümlülükler
X23	TP Likit Aktifler / Toplam Aktifler
X24	Net Dönem Karı (Zararı) / Toplam Aktifler
X25	Net Dönem Karı (Zararı) / Özkaynaklar
X26	Sürdürülen Faaliyeler Vergi Öncesi Kar (Zarar) / Toplam Aktifler
X27	Özel Karşılıklar Sonrası Net Faiz Geliri / Toplam Aktifler
X28	Özel Karşılıklar Sonrası Net Faiz Geliri / Toplam Faaliyet Gelirleri (Giderleri)
X29	Faiz Dışı Gelirler (net) / Toplam Aktifler
X30	Diğer Faaliyet Giderleri / Toplam Aktifler
X31	Personel Giderleri / Diğer Faaliyet Giderleri
X32	Faiz Dışı Gelirler (net) / Diğer Faaliyet Giderleri

3.3. Uygulama ve Bulgular

Modellerinin kurulmasında Weka 3.8.6 bilgisayar yazılımından yararlanılmıştır. Verilerin son iki yılı (Covid-Dönemi) içeren kısmı onaylama amacıyla veri setinden çıkarılmıştır. Geriye kalan verilerin %66 sı eğitim ve %33'ü de test olarak ayrılmıştır.

Kurduğumuz 24-17-10 şeklinde nöron dağılımına sahip olan modelde ilk olarak eğitim verisi olan 15 yıllık veriyi işlediğimizde 15 yıllık veriyi işlediğimizde, kurulan model %80 oranında doğru

sınıflandırma yapabilmektedir. Fakat modele 15 yıllık veriyi eğitim verisi olarak verip geriye kalan 2 yıllık pandemi dönemini test verisi olarak verdiğimizde modelin başarı oranı %50'ye düşmektedir. Diğer denenen modeller ve elde edilen istatistiki sonuçlar aşağıdaki tabloda verilmiştir.

Tablo 3. Yapay Sinir Ağı Modeli Analiz Sonuçları

Sıra	Veri Seti	Nöron Dağılımı	Başarı	KS	MAE	RMSE	RAE	RRSE
1	Eğitim	24,18,10	80%	0.7808	0.0484	0.1654	27%	55%
2	Eğitim+Test	24,18,10	55%	0.5	0.0864	0.2413	48%	80%
3	Eğitim	24-17-10	82%	0.8029	0.0433	0.1647	24%	55%
4	Eğitim+Test	24-17-10	75%	0.7222	0.0725	0.2119	40%	71%
5	Eğitim	24,16,10	82%	0.8031	0.0458	0.1638	25%	54%
6	Eğitim+Test	24,16,10	65%	0.6111	0.0799	0.2329	44%	78%
7	Eğitim	24,15,10	82%	0.8028	0.8028	0.0448	25%	53%
8	Eğitim+Test	24,15,10	60%	0.5556	0.0863	0.2483	48%	83%
9	Eğitim	24,14,10	84%	0.8251	0.0498	0.172	28%	57%
10	Eğitim+Test	24,14,10	50%	0.4444	0.105	0.2832	58%	94%
11	Eğitim	24,13,10	82%	0.8027	0.047	0.1707	26%	57%
12	Eğitim+Test	24,13,10	80%	0.7778	0.057	0.1768	32%	59%
13	Eğitim	24,12,10	82%	0.8032	0.0418	0.1563	23%	52%
14	Eğitim+Test	24,12,10	65%	0.6111	0.0786	0.2268	44%	76%
15	Eğitim	24,11,10	78%	0.7594	0.051	0.1732	28%	57%
16	Eğitim+Test	24,11,10	60%	0.5556	0.0811	0.2273	45%	76%
17	Eğitim	24,10,10	78%	0.7596	0.0558	0.1818	31%	60%
18	Eğitim+Test	24,10,10	50%	0.4444	0.1005	0.2728	56%	91%

*KS: Kappa statistic, MAE: Mean absolute error, RMSE: Root mean squared error, RAE: Relative absolute error. RRSE: Root relative squared error

Modelin nöron dizilimi 24,15,10 şeklindedir. Fakat aynı model için normal dönemi eğitim verisi olarak, Covid dönemini de test verisi olarak verdiğimizde başarı oranı %50'ye düşmektedir. Tablodan da anlaşılacağı üzere çalışmada test edilmiş olan modellerin normal dönem için sınıflandırma başarısı %84-%78 aralığında değişmektedir.

İlgili çalışmada test edilen modellerin Covid-19 dönemi ve normal dönem kıyaslandığında ise sınıflandırma başarısı en yüksek olan modelin %80 başarı oranı ile 12 numaralı model olduğu gözlemlenebilir. İlgili çalışmada modelin nöron dizilimi 24,13,10 şeklindedir. Normal dönem ve Covid-19 dönemini kapsayan diğer modellerin sınıflandırma başarı oranları sırasıyla %50 ila %80 arasında değişmektedir.

Tablo.3 de raporlandığı üzere 24,15,10 nöron dizilimli yapay sinir ağı modeli ile 24,13,10 dizilimli model arasındaki tek fark gizli katmanında fazladan 2 adet nöronun yer almasıdır. Literatürü destekler nitelikte yapay sinir ağlarının gizli katmanlarında bulunan nöron sayılarının elde edilecek sonuçları ne denli değiştirdiği görülmektedir.

Sonuç ve Değerlendirme

BİST'e kote olan 10 adet bankanın 2005-2021 yılları arasındaki finansal verilerini kullanarak yaptığımız çalışmada verilerin Covid-19 dönemi dışında kalan (2005-2019) aralığını kapsayan 15 yıllık verinin 13 yıllık kısmı oluşturduğumuz yapay sinir ağının eğitimi için, program tarafından rastgele seçilmiş 2 yıllık kısmı ise yapay sinir ağının test verisi olarak ayrılmıştır. Sonrasında Covid-19 dönemi içerisinde bulunan (2020-2021) 2 yıllık veri modelin Covid döneminde sınıflandırma başarısı oranını test etmek amacıyla ayrılmıştır.

Oluşturulan yapay sinir ağı modelinin normal süreçte bankaların finansal oranlarını baz alarak verilen bankaları sınıflandırma başarısı, literatürde bulunan benzer çalışmalara yakın başarı oranları elde etmiştir. Fakat Covid-19 süreci bankaların finansal yapısında sıra dışı birtakım

değişmelere neden olmuştur. Beklendiği üzere normal dönem verileri ile eğitilmiş olan yapay sinir ağı modelimizi, Covid-19 sürecini içeren verileri test etmek için çalıştırdığımızda ise modelin sınıflandırma başarısı düşmektedir.

Yapılan analizde elde edilen bulgular göstermiştir ki Covid-19 öncesi normal dönem diyebileceğimiz dönem için en başarılı yapay sinir ağı modeli'nin 9 numaralı model olduğu görülmektedir. Modelin nöron dizilimi 24,15,10 şeklindedir. Fakat aynı model için normal dönemi eğitim verisi olarak, Covid-19 dönemini de test verisi olarak verdiğimizde başarı oranı %50'ye düşmektedir. Tablodan da anlaşılacağı üzere çalışmada test edilmiş olan modellerin normal dönem için sınıflandırma başarısı %84-%78 aralığında değişmektedir.

Çalışmada test edilen modellerin Covid-19 ve normal dönemi kapsayanlarını ele aldığımızda ise sınıflandırma başarısı en yüksek olan modelin %80 başarı oranı ile 12 numaralı model olduğu görülmektedir. Modelin nöron dizilimi 24,13,10 şeklindedir. Normal dönem ve Covid-19 dönemini kapsayan diğer modellerin sınıflandırma başarı oranları da %50 ila %80 arasında değişmektedir.

Analizden çıkartılabilecek bir diğer sonuç ise 24,15,10 nöron dizilimli yapay sinir ağı modeli ile 24,13,10 dizilimli model arasındaki tek fark gizli katmanında fazladan 2 adet nöronun bulunmasıdır. Literatürde pek çok farklı kaynakta da belirtildiği gibi yapay sinir ağlarının gizli katmanlarında bulunan nöron sayılarının elde edilecek sonuçları ne denli değiştirdiği görülmektedir. Fakat gene pek çok kaynakta da belirtildiği gibi yapay sinir ağı modellerinin gizli katmanı bizim için bir kapalı kutu olduğu için, gerçekleşen matematiksel işlemleri gözlemleyip ona göre katman sayısı belirleme şansımız bulunmamaktadır. Bu kapsamda literatürdeki pek çok çalışmada olduğu gibi bu çalışmada da deneme yanılma yöntemi ile pek çok farklı nöron dizilimi ele alınmıştır.

Yapılan analiz ilgili literatürü destekler nitelikte, bankacılık ve finans sektörü için olumlu veya olumsuz olarak yorumlamadan, "sıra dışı" verilerin bulunduğu Covid-19 dönemi dahil edildiği tüm modellerde, modelin başarısını düşürmüştür. Deneme yanılma yöntemleri ile elde edilen modellerden en optimal sonucu 12 numaralı model vermiştir. Mahfoud ve Mani (2013), Altınırnak ve Karamaşa (2016), Odom ve Sharda (1990) ve Patil ve Dharwadkar (2017)'in çalışmalarında da olduğu yapay sinir ağı modeli ile yapılan analizden elde edilen sonuçlar ekonomik volatilitenin düşük olduğu dönemlerde ilgili değişkenler ile yapılan tahminlemede başarılı sonuçlar elde edilebileceği sonucuna ulaşılmıştır.

Çalışmada analiz edilen yapay sinir ağı modelleme yönteminin ekonomik volatilitenin düşük olduğu dönemler analize dahil edilen 10 bankaya ilişkin değişkenlerin gelecek değerini tahminlemede %84-%78 aralığında başarılı olduğu gözlemlenirken, Covid-19 döneminde bankacılık sisteminde ilgili değişkenlere ilişkin tahminlemede başarı oranının %50 ila %80 arasında değiştiği gözlenmiştir. Sonuç olarak yapay sinir ağı modelleri ile Türkiye ekonomisinde BİST'e kote olmuş 10 bankanın analize dahil edilen değişkenlerinin önceden tahminlenmesinde konjonktürel dalgalanmaların yüksek olduğu dönemlerde tahminleme yapmak zorlaşırken, ekonomik dalgalanmaların düşük olduğu dönemlerde ilgili değişkenlerin tahminlenme gücünün yüksek olduğu sonucuna varılmıştır. Dolayısıyla konjonktürel volatilitenin yüksek olduğu dönemlerde dışa açık ekonomilerde ekonomik ajanların yatırım ve tüketim kararları öngörülebilir olmaktan uzaklaşmaktadır. Gerek tüzel gerek gerçek kişiler bu dönemlerde irrasyonle davranışlar sergileyebilmektedir. Bu durumun varlığı yapay zeka analizinin ekonomik volatilitenin yüksek olduğu dönemlerde tahminleme başarısını düşürmektedir.

Dolayısıyla politika yapımcıların ve finansal aktörlerin YSA modelleri ile yapılan tahminlemeler ile elde edilen analiz bulgularından, ekonomik volatilitenin düşük olduğu dönemlerde, finansal karar alma süreçlerinde ve finansal piyasa verilerine ilişkin tahminlemelerde faydalanabilecekleri sonucuna ulaşılmıştır.

Kaynakça

Akkaya, G. C., Demirelli, E., ve Yakut, Ü. H. (2009). İşletmelerde Finansal Başarısızlık Tahminlemesi: Yapay Sinir Ağları Modeli İle İMKB Üzerine Bir Uygulama. Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi, 10(2), 187-216.
<https://dergipark.org.tr/tr/pub/ogusbd/issue/10996/131592> adresinden alındı

- Aksoylu, M. Ü. (2021). Projelerle Yapay Zekâ ve Bilgisayarlı Görü (1 b.). İstanbul: Kodlab.
- Altınırnak, S., ve Karamaşa, Ç. (2016). Comparison Of Machine Learning Techniques For Analyzing Banks Financial Distress. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 19(36), 291-303.
- Altunöz, U. (2013). Bankaların Finansal Başarısızlıklarının Yapay Sinir Ağları Modeli Çerçevesinde Tahmin Edilebilirliği. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 28(2), 189-217.
- Arda, E., ve Küçükkoğlu, G. (2021). Yapay Zeka Yöntemleri İle Hisse Senedi Fiyat Öngörülleri. *Ekonomi, Politika ve Finans Araştırmaları Dergisi*, 6(2), 565-586. doi:10.30784/epfad.878664
- Atlan, F., Pençe, İ., Çeşmeli, M. Ş., ve Kalkan, A. (2018). Bitcoin'in Türkiye Piyasasındaki Değerinin Yapay Zeka Teknikleri ile Tahmini. 5th International Management Information Systems Conference, 59-62. https://imisc.figshare.com/articles/journal_contribution/Bitcoin_in_Tu_rkiye_Piyasas_ndaki_Deg_erinin_Yapay_Zeka_Teknikleri_ile_Tahmini/7471376 adresinden alındı
- Ceran, M. (2019). Bankacılıkta Dijitalleşme Kapsamında Öğrenen Yapay Zeka Desteğiyle Sorunlu Kredilerin Belirlenmesi. İstanbul, Yayınlanmamış Doktora Tezi: T.C. Marmara Üniversitesi Bankacılık ve Sigortacılık Enstitüsü Bankacılık Anabilim Dalı.
- Çağlar, B., ve Yavuz, U. (2021). Finansal Haberlerin Bitcoin Fiyatlarına Etkisinin Yapay Sinir Ağları İle Analizi. *Bilişim Teknolojileri Dergisi*, 14(1), 65-78. doi:10.17671/gazibtd.703688
- Çelik, M. K. (2010). Bankaların Finansal Başarısızlıklarının Geleneksel ve Yeni Yöntemlerle Öngörüsü. *Celal Bayar Üniversitesi Yönetim ve Ekonomi Dergisi*, 17(2), 129-143.
- Donepudi, P. K. (2017). AI and Machine Learning in Banking: A Systematic Literature Review. *Asian Journal of Applied Science and Engineering*, 6(3), 157-162. https://www.researchgate.net/publication/349859207_AI_and_Machine_Learning_in_Banking_A_Systematic_Literature_Review adresinden alındı
- Ekinci, Y., Temur, G. T., Çelebi, D., ve Bayraktar, D. (2008). Ekonomik Kriz Döneminde Firma Başarısı Tahmini: Yapay Sinir Ağları Tabanlı Yaklaşım. *Endüstri Mühendisliği Dergisi*, 21(YA/EM 2008 Özel Sayısı), 17-29.
- Elmas, Ç. (2011). Yapay Zeka Uygulamaları (2 b.). Ankara: Seçkin Yayıncılık.
- Gümüş, E., Medetoğlu, B., ve Tutar, S. (2020). Finans ve Bankacılık Sisteminde Yapay Zekâ Kullanımı: Kullanıcılar Üzerine Bir Uygulama. *Bucak İşletme Fakültesi Dergisi*, 3(1), 28-53.
- Hasan, A., Kalıpsız, O., ve Akyokuş, S. (2017). Büyük Verilerde Finansal Piyasa Tahmini : Derin Öğrenme. 2017 International Conference on Computer Science and Engineering (UBMK), 510-515. doi:https://doi.org/10.1109/UBMK.2017.8093449
- Haykin, S. (2009). *Neural Network and Learning Machines* (3 b.). McMaster University, Hamilton, Ontario, Canada: Pearson Yayınları.
- Kim, K. J. (2006). Artificial Neural Networks With Evolutionary Instance Selection for Financial Forecasting. *Expert Systems With Applications*(30), 519-526.
- Kishada, Z. M., Wahab, N. A., ve Mustapha, A. (2016). Consumer Loyalty Assessment in Malaysian İslamic Banking Using Artificial İntelligence. *Journal of Theoretical and Applied Information Technology*, 87(1), 80-91.
- Korkmaz, G. (2020). Yapay Zekâ Yöntemleriyle Sınıflandırma ve Finans Sektöründe Kurumsal Müşterilere Dönük Bir Uygulama. *Akademik Yaklaşımlar Dergisi*, 11(2), 91-109.
- Kuyumcu, B. (2018). *OpenCv Görüntü İşleme ve Yapay Öğrenme* (3 b.). İstanbul: Level Kitap.
- Küçükkocaoğlu, G., Benli, Y. K., ve Küçüksözen, C. (2007). Finansal Bilgi Manüplasyonunun Tespitinde Yapay Sinir Ağı Modelinin Kullanımı. *İMKB Dergisi*, 9(36), 2-30.
- Mahfoud, S., ve Mani, G. (2010). Financial Forecasting Using Genetic Algorithms. *Applied Artificial Intelligence : An International Journal*, 543-566. doi:http://dx.doi.org/10.1080/088395196118425
- Odom, M. D., ve Sharda, R. (1990). A neural network model for bankruptcy prediction. 1990 IJCNN International Joint Conference on Neural Networks(2), 163-168. doi:10.1109/IJCNN.1990.137710.

- Özer, A., Sarı, S. S., ve Başakın, E. E. (2018). Bulanık Mantık ve Yapay Sinir Ağları İle Borsa Endeks Tahmini : Gelişmiş ve Gelişmekte Olan Ülkeler Örneği. *Hitit Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 99-124. doi:http://dx.doi.org/10.17218/hititsosbil.390490
- Öztemel, E. (2016). Yapay Sinir Ağları (4 b.). Ankara: Papatya Yayıncılık Eğitim.
- Patil, P. S., ve Dharwadkar, N. V. (2017). Analysis of Banking Data Using Machine Learning. *International conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)*, 876-881.
- Sağıroğlu, Ş., Beşdok, E., ve Erler, M. (2003). Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları. Kayseri: UFUK Kitap Kırtasiye Yayıncılık Tic. Ltd. Şti.
- Sakız, B., ve Kutlugün, E. (2017). Blok Zinciri Teknolojisi Ve Yapay Zeka Algoritmaları İle Bitcoin Fiyat Tahminleme. *International Conference On Eurasian Economies 2017*, 438-444. https://www.avekon.org/papers/2070.pdf adresinden alındı
- Singh, C., ve Lin, W. (2021). Can artificial intelligence RegTech and CharityTech provide effective solutions for anti-money laundering and counter-terror financing initiatives in charitable fundraising. *Journal of Money Laundering Control*, 24(3), 464-482. doi:10.1108/JMLC-09-2020-0100
- Söyler, H., ve Kızılkaya, O. (2018). Para Krizlerinin Yapay Zeka Yöntemleri İle Tahmini : Türkiye Örneği. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 18(EYİ Özel Sayısı), 649-666. doi:DOI: 10.18092/ulikidince.347202
- Şeker, M., Selim, Y., ve Berkay, A. (2004). Yapay Sinir Ağlarının Ekonomik Tahminlerde Kullanılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 10(Özel Sayı), 79-83.
- Yıldız, B. (2009). Finansal Analizde Yapay Zekâ (1 b.). Ankara: Detay Yayıncılık.
- Yıldız, B., ve Akkoç, S. (2009). Banka Finansal Başarısızlıklarının Sinirsel Bulanık Ağ Yöntemi İle Öngörüsü. *BDDK Bankacılık ve Finansal Piyasalar*, 3(1), 9-36.
- Yılmaz, A. (2020). Yapay Zekâ (8 b.). İstanbul: Kodlab.
- Yılmaz, A., ve Kaya, U. (2021). Derin Öğrenme (3 b.). İstanbul: Kodlab.
- Yurtoğlu, H. (2005). Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği. Ankara: Devlet Planlama Teşkilatı.
- Yurttabir, A., ve Sen, İ. K. (2021). Prophet Model İn Financial Performance Forecast: İmplementation İn Manufacturing Sector. *Journal of Economics, Finance and Accounting (JEFA)*, 8(4), 160-166. doi:10.17261/Pressacademia.2021.1470
- Yürük, M. F., ve Eksi, İ. H. (2019). Yapay Zekâ Yöntemleri İle İşletmelerin Finansal Başarısızlığının Tahmin Edilmesi: Bist İmalat Sektörü Uygulaması. *Mukaddime*, 10(1), 393-422. doi:10.19059/mukaddime.533151
- Zinisha, O., İvanenko, İ., ve Avdeeva, R. (2019). Artificial Intelligence As A Factor To İmprove Bank Efficiency. *Indo American Journal of Pharmaceutical Sciences*, 6(3), 6917-6919. doi:http://doi.org/10.5281/zenodo.2616485
- Zoric, A. B. (2016). Predisting Consumer Churn On Banking İndüstri Using Neural Network. *Interdisciplinary Description of Complex Systems*, 14(2), 116-124.

Extended Abstract

Aim and Scope

This study was carried out in order to test the predictive power of the artificial neural network model, which is the basis of artificial intelligence technologies, based on the financial data of banks in the covid-19 period. In the study, the financial data of 12 banks listed on Borsa Istanbul (BIST) between the years 2005-2021 were used. However, Albaraka Türk Katılım Bankası A.Ş. and ICBC Turkey Bank A.Ş. Since there are deficiencies in the data of 2 banks, these two banks were excluded from the study.

Methods

At the point of data analysis, artificial neural network models that we have established by using Weka machine learning software, an open source software developed by New Zealand Waikato University, have been tested. From the data set consisting of 17 years of data in total, we have used the 2-year data for the period of 2020-2021, belonging to the covid-19 period, as test data. Out of the

remaining 15 years of data, the 13-year part was used for training the model and the remaining 2-year part was used as test data to measure the success of the model outside the covid period.

Findings

When the models tested in the relevant study are compared with the COVID-19 period and the normal period, it can be observed that the model with the highest classification success is model number 12 with a success rate of 80%. In the related study, the neuron array of the model is 24,13,10. The classification success rates of other models covering the normal period and the COVID-19 period range from 50% to 80%, respectively. As reported in Table.3, the only difference between the artificial neural network model with 24,15,10 neuron arrays and the model with 24,13,10 arrays is that there are 2 extra neurons in the hidden layer. In support of the literature, it is seen how the number of neurons in the hidden layers of artificial neural networks changes the results to be obtained.

Conclusion

While it is observed that the artificial neural network modeling method analyzed in the study is successful in estimating the future value of the variables related to the 10 banks included in the analysis during the periods of low economic volatility, it is observed that the success rate in estimating the relevant variables in the banking system in the period of COVID-19 is between 50% and 80%. observed to vary between As a result, it has been concluded that while it is difficult to predict the variables included in the analysis of the 10 banks listed in the Turkish economy with artificial neural network models in the periods when the cyclical fluctuations are high, the prediction power of the related variables is high in the periods when the economic fluctuations are low.