



Covid 19 Öncesi ve Covid 19 Döneminde Firmaların Borçlanma Yapıları ve Kârlılık Arasındaki İlişkinin Yapay Sinir Ağları ile Analizi

Analysis of The Relationship Between The Debt Structures and Profitability of The Companies Before The Covid 19 and The Covid 19 Period with Artificial Neural Networks

Yusuf Işık

Öğr. Gör. Dr., Hatay Mustafa Kemal Üniversitesi, Kırıkhan MYO, isik.yusuf@hotmail.com, Orcid ID: 0000-0001-5842-4365

MAKALE BİLGİSİ

Anahtar Kelimeler

*Borçlanma düzeyleri,
Covid 19'un firmalara etkileri,
Borçlanma seviyesi ve kârlılık
arasındaki ilişki*

Makale Geçmişi:

*Geliş Tarihi: 9 Haziran 2022
Kabul Tarihi: 9 Haziran 2023*

ARTICLE INFO

Keywords

*Borrowing levels,
The effects of Covid 19 on
companies,
The relationship between
borrowing level and profitability*

Article History:

*Received: 09 June 2022
Accepted: 09 June 2023*

ÖZET

Covid 19 pandemisi, tüm dünyada olduğu gibi ülkemizi de etkisi altına almış olup tam anlamıyla etkisinin ne zaman biteceğine ilişkin somut bir kanıt söz konusu değildir. Bu etkileme en çok sağlık alanında olmakla birlikte neredeyse yaşamın her alanına sıçramıştır. İlk olarak makro ekonomik göstergelerle olsa da devamında mikro ekonomik göstergelerle ekonomide de kendini göstermiştir. Tüm dünyada ekonomi politikaları, Covid 19 pandemisini dikkate alarak şekillenmiş olup, özeldde firmalar da bu düzenleme karşısında kayıtsız kalmamıştır. Bu çalışmada Covid 19 pandemisinin getirdiği ekonomik koşullar altında firmaların borçlanma yapıları ile firma kârlılık seviyesi arasındaki ilişkinin tespiti amacıyla Covid 19 öncesi ve Covid 19 dönemi olarak ayrı ayrı analiz gerçekleştirilmiştir. Bu amaç doğrultusunda Borsa İstanbul (BİST) "Holdingle ve Yatırım Şirketleri" sektöründe faaliyetlerini yürüten firmaların Covid 19 öncesi ve Covid 19 dönemi mali tabloları üzerinden borçlanma yapılarını gösteren mali tablo verileri kullanılarak belirlenen oranlar ile aktif kârlılık düzeyi arasındaki ilişki yapay sinir ağları yöntemiyle analiz edilmiştir. Analiz sonuçları dönemsel olarak karşılaştırıldığında ise her iki dönemin değerleri için borçlanma yapıları ve kârlılık arasında sektör genelinde anlamlı bir ilişki olmadığı ifade edilebilir.

ABSTRACT

The Covid 19 pandemic has affected our country as well as the rest of the world, and there is no concrete evidence as to when its effect will end. Although this effect is mostly in the field of health, it has spread to almost every area of life. Although first with macroeconomic indicators, it also showed itself in the economy with microeconomic indicators. All over the world, economic policies have been shaped by taking into account the Covid 19 pandemic, and companies in particular have not been indifferent to this regulation. In this study, separate analyzes were carried out as pre-Covid 19 and Covid 19 periods in order to determine the relationship between the borrowing structures of companies and the level of firm profitability under the economic conditions brought by the Covid 19 pandemic. For this purpose, Borsa İstanbul (BIST) was analyzed by artificial neural networks method by using the financial statements determined by using the financial table data showing the borrowing structures of the companies carrying out their activities in the "Holdings and Investment Companies" sector in the "Holdings and Investment Companies" sector. When the analysis results are compared periodically, it can be stated that there is no

significant sector-wide relationship between debt structures and profitability for the values of both periods.

Covid 19 pandemisi, ortaya çıktığı ilk andan itibaren belirsizlik ortamının getirdiği stres, etkisini hissedilir derecede tüm dünyada göstermiştir. Hızla değişen sağlık politikaları ve alınan önlemler, salgının etkisini tam anlamıyla ortadan kaldırmaya da bir nebze ferahlık getirmiştir. Salgın sürecinin en az sağlık alanı kadar önemli diğer bir ayağı da ekonomik belirsizliklerdir. Ortaya çıkan ekonomik belirsizliklerin şüphesiz ki tüm dünyada ülke ekonomileri üzerinde etkisi olmuştur. Bu kapsamda ülke çapında önlem alındığı gibi şirketler de kendi yönetimleri dahilinde önlemler almışlardır. Alınan önlemlerin etkinliği tartışılır olsa da sektörler kapsamında performansları genel olarak olumsuz olsa da, olumlu performansla sonuçlanan sektörler de olmuştur. Bu kapsamda Eşsiz ve Durucan (2021), çalışmalarında havayolu, konaklama, seyahat ve eğlence sektörlerinin pandemi koşullarından olumsuz olarak etkilense de “evde kal” kampanyası ile elektrik-elektronik sektörüne olan talebin arttığını; Shen, Fu, Pan ve Chen (2020) Çin Halk Cumhuriyetinde yaptığı araştırmada ulaşım, turizm ve restoran sektörlerinin çok daha fazla olumsuz yönde etkilendiğini; Xiong, Wu, Hou ve Zhang (2020), Ulaşım, gayrimenkul, turizm, sinema ve inşaat sektörlerinin çok daha fazla etkilendiğini; Ünal (2020) ise deri giyim, havayolu taşımacılığı, turizm, lojistik ve pazarlama sektörlerinin en fazla etkilendiğini ifade etmişlerdir. Dolayısıyla pandeminin, tüm sektörlerle aynı yönde veya derecede etki etmediği ifade edilebilir. Tüm sektörlerin faaliyetlerini sürdürürken ortak bir noktada buluştuğu sektör olarak “Mali Kuruluşlar” sektörü de pandemi koşullarından şüphesiz ki etkilenmiştir.

Bu çalışma ile, “Mali Kuruluşlar” sektörünün alt sektörü olan “Holdingler ve Yatırım Şirketleri” sektöründeki işletmelerin Covid 19 sürecine girmeden önce ve Covid 19 sürecindeki borçlanma yapıları ile aktif karlılığı arasında bir ilişki olup olmadığını, ilişki var veya yok ise bu ilişki veya ilişkisizliğin Covid 19 sürecinde de devam edip etmediğinin tespiti amaçlanmıştır.

1. LİTERATÜR ARAŞTIRMASI

Veri madenciliği yöntemlerinin muhasebenin çeşitli alanlarında kullanımına ilişkin çok sayıda örnekler mevcuttur. Yapay sinir ağları, karar ağacı, metin madenciliği, destek vektör makineleri ve diğer tüm yöntemler muhasebede bir şekilde yer bulmuştur. Foltin ve Garceau (1996) yapay sinir ağları yöntemi için geleneksel finansal analiz tekniklerinden farklı olarak sinir ağlarını diğer analitik araçlardan ayıran ve bazıları muhasebe açısından çok ilginç olan, vaka çalışması yoluyla genel kurallar oluşturabilmesi, veriler arasındaki benzerlikleri tanıyabilmesi ve teorik modelin herhangi bir önsel ayarı olmaksızın sonuçlar çıkarabilmesi gibi özelliklerin bulunduğunu belirtmişlerdir. Buna karşın Chatfield (1985), geleneksel finansal analiz tekniklerinin verileri yönetmeden önce bir model oluşturulmasına yönelik formülasyon gerektirdiğini ifade etmiştir. Bu iki ifade birlikte düşünüldüğünde makine öğrenmesi yöntemlerinin geleneksel yöntemlere karşı üstünlüğünden bahsedilebilir. Zira geleneksel yöntemlerde oluşturulacak formülasyonlarda insan kavramı devreye girdiği için olası hatalar da söz konusu olabilmektedir. Ancak iyi yapılmış bir veri madenciliği yöntemi algoritmasında insan kaynaklı olası hatalarla karşılaşılma ihtimali ortadan kalkmaktadır.

Bu bölümde yönetim muhasebesi açısından değerlendirilmesi açısından kârlılık ve borçlanma yapısı arasındaki ilişki üzerine yapılmış, diğer bir ifadeyle mali yapı ile işletme performansı arasındaki ilişkiyi analiz etmek için yapılmış ulusal ve uluslararası literatüre yer verilmiştir.

Kapıcı, Güçlü ve Karakaş (2021), çalışmalarında Covid 19 pandemi döneminde konaklama işletmeleri tedarikçilerinin performanslarını değerlendirmişlerdir. Bu kapsamda 5 yıldızlı bir konaklama işletmesine gıda tedarik eden 3 tedarikçi firma “Fiyat, Kalite, Teslimat, Esneklik, Tedarikçi Profili ve Pandemi Yaklaşımı” kriterlerinde Bulanık Analitik Hiyerarşi Prosesi ile değerlendirmişlerdir. Çalışma sonucunda belirlenen kriterler dahilinde tedarikçilerin birbirlerine özgü üstün yanlarının olduğu tespit edilmiştir.

Özparlak (2021), yapay sinir ağları analizi kullanmak suretiyle Covid 19 salgını döneminde finansal tablolara ilişkin yapılabilecek manipülasyonların tespit edilmesi yönünde araştırma yapmıştır. Araştırma kapsamında 264 BİST firma verileri kullanılmış olup çalışma sonucunda finansal bilgi manipülasyonu yapılabileceğine ilişkin kanıtlara rastlanmıştır.

Tiwari, Bharadwaj ve Joshi (2021), çalışmalarında bulut bilişim ve yapay zekâ kullanımının bankacılık sektörüne ilişkin kârlılık ve operasyonel faydaları üzerindeki etkisini araştırmış, araştırma sonucunda ise bulut teknolojiler ile yapay zekâ uygulamalarının kullanımı ile operasyonel işlemlerin daha da kolaylaşacağı ve gelecekte çok daha farklı şekillerde yaygınlaşacağı üzerine ifadelerde bulunmuşlardır.

Akpınar (2016), çalışmasında işletmelerin sermaye yapılarının firma performansına etkisinin olup olmadığını araştırmıştır. Bu kapsamda BİST 100 firmaları verisine “Panel Veri Analizi” uygulamıştır. Araştırma sonucunda sermaye yapısının firma performansını etkilemediği sonucuna ulaşmıştır.

Uluçol, Lebe ve Akbaş (2014), çalışmalarında BİST’te işlem gören işletmelerin finansal kaldıraç oranları ile öz sermaye kârlılıkları arasındaki ilişkiyi araştırmışlardır. Çalışma, bilişim, gıda, madencilik, tekstil ve inşaat sektöründeki firmaların 1991-2012 dönemi arasındaki 22 çeyrek döneme ait finansal kaldıraç oranları kullanılarak yapılmış olup, araştırma sonucunda sektörel olarak finansal kaldıraç ve öz sermaye kârlılığı arasında pozitif ve negatif yönlü ilişkiler tespit edilmiştir.

Fethi ve Pasiouras (2010), yapay zekanın banka verimliliğine etkileri üzerine yaptıkları çalışmalarında yapay sinir ağları, destek vektör makineleri ve çok kriterli karar verme tekniklerinin bankaların performansını tahmin etmedeki rollerini araştırmak üzere 1998-2008 yılları arasında yayınlanan 179 çalışmayı ele almışlardır. Genel olarak ele aldıkları çalışmalarda şubeleri ile birlikte bankaların etkinlik ve üretkenlik artışlarının tahmini ile bankaların kredi notlarının tahmini ve düşük performans göstergelerinin tespitine yönelik çalışmalar olduğu tespit edilmiştir.

Bu çalışmada diğer çalışmalardan farklı olarak borçlanma yapılarının firma performansı arasındaki ilişki düzeyi Covid 19 öncesi ve Covid 19 dönemi verileri üzerinden karşılaştırmalı olarak araştırılmıştır.

2. METODOLOJİ

Bu bölümde araştırma kapsamında kullanılan verilere ilişkin evren, örneklem ve yöntem bilgilerine yer verilmiştir.

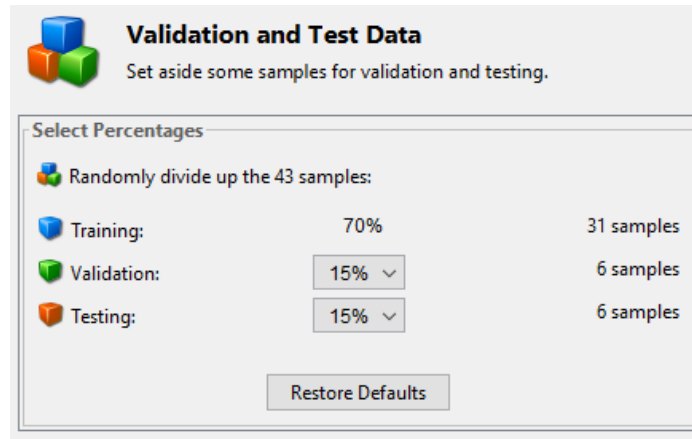
2.1. Örneklem ve Evren

Araştırmada BİST Holdingler ve Yatırım Şirketleri sektöründe faaliyet gösteren firmaların 2018-2021 arasındaki 4 dönemine ait yıllık konsolide finansal tabloları kullanılmıştır. Bu kapsamda söz konusu sektörde 48 firma yer almakta olup Kamu Aydınlatma Platformu (KAP) sisteminden araştırma kapsamındaki 4 firmanın en az bir dönemine ilişkin verisine ulaşılamamış, 1 firmaya ait verilerde ise tutarsızlık tespit edilmiştir. Bu sebeple verilerine eksiksiz ulaşılan 43 firma üzerinden analiz gerçekleştirilmiştir.

2.2. Yöntem

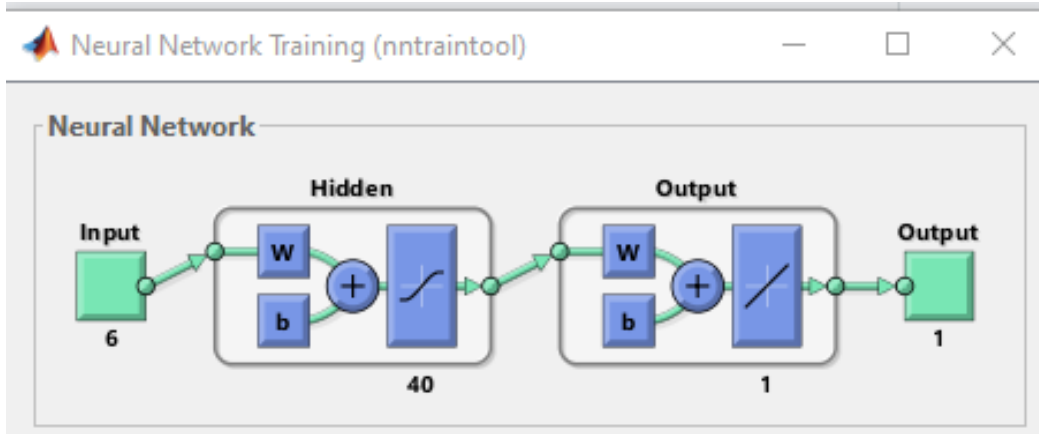
Analiz kapsamında kullanılan 2018-2021 yılları arasındaki dönemler, 2018-2019 covid 19 öncesi dönem ve 2020-2021 covid 19 dönemi olarak sınıflandırılmıştır. Bu sınıflandırma çerçevesinde çalışmanın ana temasını oluşturan borçlanma yapılarına ilişkin mali tablo enstrümanları, “Kısa Vadeli Yabancı Kaynak, Uzun Vadeli Yabancı Kaynak, Özkaynak ve Pasif Toplamı” olarak belirlenmiştir. Ancak bu enstrümanlardaki tutarlar tüm işletmeler için düşünüldüğünde yüksek dalgalanmalar söz konusu olabilecek ve yanıltıcı sonuçlar verebilecektir. Bu sebeple mali tablo enstrümanları doğrudan kullanılmamış, bu enstrümanlar kullanılmak suretiyle “Kısa vadeli borçlanma oranı, uzun vadeli borçlanma oranı, finansman oranı, finansal kaldıraç, net işletme sermayesinin pasife oranı, devamlı sermayenin pasife oranı” olmak üzere 6 rasyo hesaplanmıştır. Hesaplanan rasyolar $x^* = (x - x_{\min}) / (x_{\max} - x_{\min})$ formülü ile normalizasyona tabii tutularak analize hazır hale getirilmiştir. Bu rasyolar ile ilk olarak covid 19 öncesi dönem verileri ile firma karlılığı arasındaki ilişkiyi temsil edecek en optimal nöron sayısındaki yapay sinir ağı tespit edilmiştir. Daha sonra covid 19 dönemi öncesi yapı için tespit edilen yapay sinir ağında covid 19 dönemi verileri test edilerek birbirini takip eden dönemler arasındaki ilişkinin ölçüsü olacak regresyon derecesi incelenmiştir.

Yapılan analiz Matlab R2016a programı kullanılmak suretiyle gerçekleştirilmiş olup analizin gerçekleştiği öğrenme, doğrulama ve test değerleri Şekil 1’deki gibidir.



Şekil 1. Training, Validation ve Testing Seçim ve Yüzdeleri

Şekil 1’de görüldüğü üzere analiz dahilindeki verilerin %70’i ağız öğrenmesi, %15’i ağız doğrulama işlemi ve %15’i ise ağız testi için program tarafından rastgele seçilmiştir. Bu kapsamda yapılan analizde ağız mimarisi olarak “Feed-forward backprop”, ağız eğitim fonksiyonu olarak “Levenberg Marquardt”, adaptasyon öğrenme fonksiyonu olarak “Gradient Descent With Momentum” ve performans fonksiyonu olarak “Ortalama karesel hata” değerleri kullanılmıştır. Bu seçenekler dahilinde kullanılan ağız girdi ve çıktı değerleri Şekil 2’deki gibidir.



Şekil 2. Arayüz nntart fonksiyonu ile oluşturulan yapay sinir ağına ait blok diyagram

Şekil 2’ye göre yapay sinir ağının öğrenmesinde 1-50 arasında nöron sayıları değiştirilmek suretiyle en iyi öğrenmenin gerçekleştiği gizli nöron sayısı 40 olarak tespit edilmiştir. Dolayısıyla analiz, 40 gizli nöron sayısındaki sinir ağında yapılmıştır.

3. BULGULAR

Bu bölümde analizle ilgili temel istatistik değeri ve yapılan analiz değerlerine yer verilmiş olup Tablo 1 mali yapı oranları ve kârlılık oranına ilişkin temel istatistik değeri göstermektedir.

Tablo 1. Mali yapı oranlarının Covid 19 öncesi ve sonrası değeri

Analiz Kapsamındaki Rasyolar	2018 -2019 Covid 19 Öncesi Dönem			2020- 2021 Covid 19 Dönemi			Ortalamadaki Değişim (%)
	Ortalama	Min	Mak	Ortalama	Min	Mak	
KVYK/Pasif	0,2830	0,0004	0,8102	0,2881	0,0030	0,7753	0,018
UVYK/Pasif	0,1820	0,0022	0,6773	0,1499	0,0047	0,5183	-0,176
Finansman Oranı							
Özkaynak/Yabancı Kaynak	0,5350	0,1277	0,9811	0,5620	0,1292	0,9783	0,050
Finansal Kaldıraç							
Yabancı Kaynak/ Aktif	0,4650	0,0189	0,8723	0,4380	0,0217	0,8708	-0,058
Net İşletme Sermayesi/Pasif	0,1434	-0,3499	0,6906	0,1429	-0,3622	0,6975	-0,004
Devamlı Sermaye/Pasif	0,7170	0,1898	0,9996	0,7119	0,2247	0,9970	-0,007
Aktif Karlılığı	-0,0042	-0,6929	0,3100	0,0640	-0,0953	0,4823	16,239

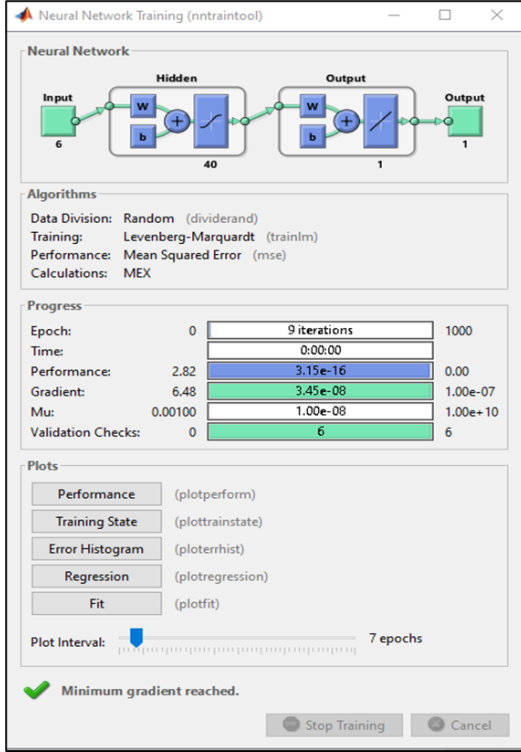
Tablo 1’e göre Covid 19 öncesi ve sonrası döneme ilişkin mali yapı oranlarının ortalama değeriindeki değişimde en fazla artış finansman oranında %5, en fazla azalış ise uzun vadeli yabancı kaynakların pasife oranında %17,6 olarak gerçekleşmiştir. Aktif karlılığı ortalama değeri ise Covid 19 öncesi dönem %04’lük bir zarar söz konusu iken, Covid 19 döneminde %6,4’lük bir ortalama kârlılık görülmektedir.

Yapay sinir ağı ile yapılan analiz verilerinde ise Covid 19 öncesi dönem için bağımsız değişken olarak mali yapı oranları, bağımlı değişken olarak ise aktif kârlılığı kullanılmıştır. Bağımsız değişken ile bağımlı değişken arasındaki ilişki 1-50 nöron sayısında analiz edilmiş olup Şekil 3’te görüldüğü üzere en yüksek ilişki 40 nöron sayısında ağız tespit edilmiştir.

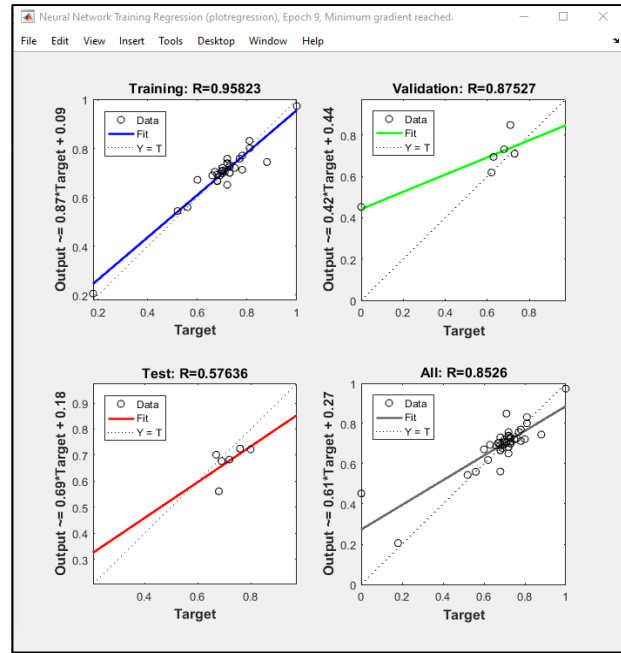
Şekil 3’e göre Covid 19 dönemi öncesi için 6 veri giriş seti, 40 gizli yapay sinir ağı katmanı ve 1 çıktı katmanı ile yapılan analizde öğrenme, doğrulama ve test işlemleri gerçekleştirilmiştir. Verilerin öğrenme, doğrulama ve test işlemleri için ayrılması, MATLAB programı tarafından rastgele seçilmiş olup, en optimal sonuç veren 40 katmanlı sinir ağının girdi ve çıktı katmanları arasındaki ilişki Şekil 4’te verilmiştir.

Şekil 4’te görüldüğü üzere Covid 19 dönemi öncesine ait verilerin analiz sonuçları $R_{Training} = 0,95823$, $R_{Validation} = 0,87527$, $R_{Test} = 0,57636$ ve $R_{All} = 0,8526$ olarak belirlenmiştir. Can ve Şahin (2021) bu değeri 1’e ne kadar yakın ise girdi

ve çıktı katmanları arasında o kadar pozitif yüksek düzeyde ilişki olduğunu, -1'e ne kadar yakın ise de negatif yönlü pozitif ilişki olduğunu belirtmişlerdir. Ayrıca değerlerin 0'a yakın olması girdi ve çıktı katmanları arasındaki ilişkinin çok zayıf olduğunu, hatta ilişkisizlik olduğunu belirtmişlerdir. Dolayısıyla bu verilere bakıldığında 40 gizli katmanlı sinir ağı ile %96'lık öğrenme düzeyinde yapılabilecek analizde test edilen değerlerde girdi ve çıktı katmanları arasındaki ilişki düzeyi %58 olarak tespit edilmiştir. Doğrulama oranının %88'lerde olması ise şirketlerin genel olarak sektörden farklı bir borçlanma politikası yürüttüğünü göstermektedir. Analizin bu kısmı Covid 19 öncesi dönem verilerini temsil etmektedir. Bu aşamada en optimal sinir ağı olarak tespit edilen 40 gizli nöron yapısındaki ağ yapısında Covid 19 dönemine ilişkin veriler benzer şekilde teste tabi tutulmuş, analiz girdi çıktı katmanlarına ilişkin görsel Şekil 5'te verilmiştir



Şekil 3. Covid 19 öncesi verilerin yapay sinir ağı eğitimi

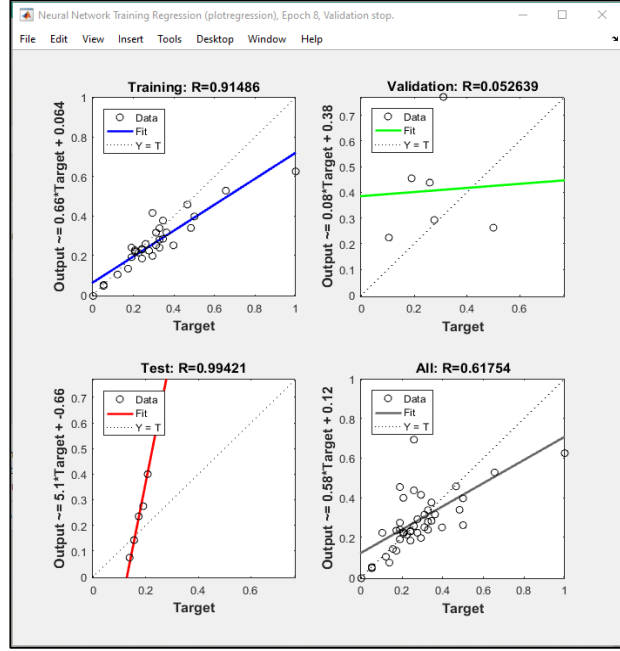


Şekil 4. Covid 19 öncesi dönem yapay sinir ağı regresyon grafiği

Şekil 5'te görüldüğü üzere Covid 19 dönemi verilerinin analizinde 6 giriş seti, 40 gizli yapay sinir ağı katmanı ve 1 çıktı katmanı olarak Covid 19 dönemi öncesi veriler için belirlenen en optimal ağ yapısı kullanılmıştır. Ancak Covid 19 dönemi öncesinde yapıldığı gibi 1-50 arasındaki tüm katmanlar Covid 19 dönemi sonrası veriler için de tek tek analiz edilerek en optimal ağ yapısı araştırılmış olup, 40 nöronlu yapının verdiği sonuçtan daha optimal bir sonuçla karşılaşılmaştır. Sadece bu ifade bile yapay sinir ağı analizi için Covid 19 öncesi ve sonrası dönem verilerinin birbirleri ile ilişkili yapıda olduklarını göstermektedir.



Şekil 5. Covid 19 dönemi verilerinin yapay sinir ağı eğitimi



Şekil 6. Covid 19 dönemi yapay sinir ağı regresyon grafiği

Yapılan analizde girdi ve çıktı katmanları olan borçlanma yapısı ve aktif karlılık arasındaki ilişkiyi gösteren regresyon analiz sonuçları Şekil 6'da gösterilmiştir.

Şekil 6'ya göre %91 oranında gerçekleşen ağız öğrenme düzeyinde doğrulama %5 iken test edilen değerlerin tutarlılığı %99 olarak karşımıza çıkmıştır. Dolayısıyla buradan Covid 19 dönemi öncesinde olduğu gibi şirketlerin borçlanma yapılarının sektörden ortalamalarından bağımsız olarak şekillendiği sonucuna varılabilir.

Covid 19 öncesi ve Covid 19 dönemi yapay sinir ağı analiz sonuçları karşılaştırıldığında ise her iki dönemin değerleri için borçlanma yapıları ve kârlılık arasında sektör genelinde anlamlı bir ilişki olmadığı ifade edilebilir.

4. SONUÇ

Holdingleer ve yatırım şirketleri sektöründeki firmaların Covid 19 dönemi öncesi ve Covid 19 dönemlerindeki borçlanma yapıları ve karlılık arasındaki ilişkinin yapay sinir ağı ile analizini amaçlayan bu çalışmada 2018-2019 dönemleri Covid 19 öncesi dönem, 2020-2021 dönemleri ise Covid 19 dönemi olarak KAP'tan alınan yıllık mali tablolar üzerinden analiz gerçekleştirilmiştir. Yapılan analizde iki süreç izlenmiştir. Öncelikle Covid 19 öncesi dönem mali tablolarından elde edilen borçlanma yapılarına ilişkin rasyolar ile aktif karlılığı arasındaki ilişki yapay sinir ağı ile analiz edilerek en optimal sonucu veren sinir ağı tespit edilmiştir. Daha sonra ise Covid 19 dönemi mali tablolarından elde edilen rasyolar tespit edilen yapay sinir ağına analiz edilmek suretiyle sonuçları karşılaştırılmıştır.

Covid 19 dönemi öncesinde program tarafından rastgele veri seçilmesi suretiyle yapılan analizde ağız öğrenmesi %96 düzeyinde ve doğrulanma %87 düzeyinde olmasına rağmen, yine rastgele seçilen grubun test edilmesinde %58'lik bir ilişki düzeyi tespit edilmiştir. Covid 19 dönemi verilerinin aynı ağıda test edilmesi ile de ağız öğrenmesi %91 oranında ağız testi %99 oranında yüksek düzeyde ilişkiyi gösterse de ağız doğrulamasında rastgele seçilen değerlerin doğrulama oranı %5 olarak yok denecek kadar çok düşük bir ilişkiyi göstermiştir.

Her iki dönemin analiz sonuçlarının karşılaştırılması ile birlikte holdingleer ve yatırım şirketleri sektöründeki firma değerlerinin sektör içinde homojen bir yapıda olmadığı, firmaların borçlanma yapıları ile aktif karlılıkları arasında bir ilişkinin olmadığı sonuçlarına varılabilmektedir. Benzer sonuç olarak Akpınar (2016) çalışmasında ulaşılarak, sermaye yapısı ile firma performansı arasında bir ilişkinin olmadığını belirlerken, Uluçay, Lebe ve Akbaş (2014) finansal kaldıraç ve öz sermaye karlılığı arasında pozitif ve negatif yönlü ilişkinin olduğuna dair sonuçlara ulaşmışlardır.

Bu çalışma sonucu dikkate alınarak makine öğrenmesi yöntemlerinden karar ağacı yöntemi ile yapılacak sınıflandırma ile veya yapay sinir ağlarının sınıflandırma algoritması ile sektörel bazda yapılacak bir analiz ile sonuçlar sektörel açıdan da karşılaştırılabilir.

YAZAR BEYANI

Araştırma ve Yayın Etiği Beyanı: Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.

Etik Kurul Onayı: Bu araştırma etik kurul izni gerektiren analizleri kapsamadığından etik kurul onayı gerektirmemektedir.

Yazar Katkıları: Yazar çalışmanın tümünü tek başına gerçekleştirmiştir.

Çıkar Çatışması: Yazar açısından ya da üçüncü taraflar açısından çalışmadan kaynaklı çıkar çatışması bulunmamaktadır.

KAYNAKÇA

- Akpınar, O. (2016). Sermaye yapısının firma performansına etkisi: Borsa İstanbul'da bir uygulama. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11(1), 290-302.
- Can, N. & Şencan Şahin, A. (2021). Yapay sinir ağları metodu ile günlük çığ noktası sıcaklığı tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11(4), 1154-1163.
- Chatfield, C. (1985). The initial examination of data. *Journal of the Royal Statistical Society. Series A (General)* 148(3): 214–253
- Eşsiz, F. P., & Durucan, A. (2021). Covid-19 salgınının seçilmiş sektörler üzerindeki etkileri: Türkiye ekseninde bir değerlendirme. *International Journal of Public Finance*, 6(2), 193-210.
- Fethi, M. D., & Pasiouras, F. (2010). Assessing bank efficiency and performance with operational research and artificial intelligence techniques: A survey. *European Journal of Operational Research*, 204(2), 189-198.
- Foltin, C., & L. Garceau. (1996). Beyond expert systems: Neural networks in accounting. *National Public Accountant* 41(6), 26–32.
- Kapıcı, S., Güçlü, İ. ve Karakaş, Y. E. (2021). COVID-19 pandemi sürecinde konaklama işletmelerinde tedarik zincirinde tedarikçi performansının değerlendirilmesi. *Business & Management Studies: An International Journal*, 9(4), 1217-1237.
- Özparlak, G. (2021). Finansal tablo manipülasyonlarının tespitinde yapay sinir ağlarının kullanılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (60), 331-357.
- Shen, H., Fu, M., Pan, H., Yu, Z., & Chen, Y. (2020). The impact of the COVID-19 pandemic on firm performance. *Emerging Markets Finance and Trade*, 56(10)
- Tiwari, S., Bharadwaj, S., & Joshi, S. (2021). A study of impact of cloud computing and artificial intelligence on banking services, profitability and operational benefits. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(6), 1617-1627.
- Uluyol, O., Lebe, F., & Akbaş, Y. E. (2014). Firmaların finansal kaldıraç oranları ile öz sermaye karlılığı arasındaki ilişki: Hisseleri borsa İstanbul (BİST)'da işlem gören şirketler üzerinde sektörler bazında bir araştırma. *İşletme Araştırmaları Dergisi*, 6(1), 70-89.
- Ünal, S. (2020). Covid-19 Salgınında borsa istanbul şirketlerinin fiyatlamalarının etkinliği. *Ekonomi, Politika & Finans Araştırmaları Dergisi*, 5(Özel Sayı), 13-31.
- Xiong, H., Wu, Z., Hou, F., & Zhang, J. (2020). Which firm-specific characteristics affect the market reaction of Chinese listed companies to the COVID-19 pandemic?. *Emerging Markets Finance and Trade*, 56(10), 2231-2242.

