

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sinir Ağları İle Kârlılıklarının Öngörüsü

Vesile ÖMÜRBEK*
Özen AKÇAKANAT**
Esra AKSOY***

Alınış Tarihi: 20 Ağustos 2018

Kabul Tarihi: 20 Şubat 2019

Öz: Bankalar her geçen gün yenilikçi yaklaşımlara adapte olarak faaliyet göstermektedir. Bankacılık sektörü ülke ekonomisi için önemli bir pozisyonda yer almaktadır. Bankaların temel amaçlarından biri göstermiş oldukları faaliyet çalışmalarında, sürdürülebilir kârlılığı ve verimliliği koruyarak büyüme. Bu çalışmada aktif büyüklüklerine göre bankalar dikkate alınmıştır. Bu bağlamda çalışmanın temel amacı aktif büyüklüğüne göre büyük ölçekli bankaların kârlılık öngörüsünü yapmaktır. Bu amaca ulaşmak için de yapay sinir ağları yöntemi bir araç olarak kullanılmıştır. Banka kârlılık öngörüsünde yapay sinir ağının eğitimi ve öngörüler Matlab (Sürüm 7.12) programı ile yapılmıştır. Çalışmada, 2003 Mart-2017 Haziran arası üç aylık dönem verileri dikkate alınmıştır. Bununla birlikte ortalama özkaynak kârlılığı bağımlı değişken olarak alınmıştır. Çalışmada kârlılığı etkilediği düşünülen on tane de bağımsız değişken kullanılmıştır. Yapay sinir ağı modelinde gerçekleştirilen analizle; test verilerine ait değerlerin ve gerçek değerlerin birbirine yakın olduğu gözlenmiştir. Bu sebepten dolayı kurulan ağlarla 2017 Eylül-2018 Haziran dönemleri için kârlılık öngörüsü yapılmıştır. Sonuç olarak bankalar için önemli olan kârlılık öngörülerinin, yapay sinir ağı modeli ile yapılabileceği görülmüştür.

Anahtar Kelimeler: Yapay Sinir Ağları, Banka Kârlılığı, Öngörü

Artificial Neural Networks Based Estimation of the Profitability of Large Scale Banks by Active Size

Abstract: Banks are constantly adapting to innovative approaches. The banking sector is in an important position for the country's economy. One of the main objectives of the banks is to grow by maintaining sustainable profitability and efficiency in their activities. In this study, banks were taken into consideration according to their asset size. In this context, the main objective of the study is to make forecasting of the profitability of large-scale banks according to their asset size. In order to achieve this goal, artificial neural networks method was used as a tool. The training and predictions of the artificial neural network were performed with Matlab (Version 7.12) program. In this study, data for three-months period between March 2003 and June 2017 are taken into consideration. In addition, average return on equity was taken as a dependent variable. In this study, ten independent variables which are thought to affect profitability were used. Findings of the artificial neural network model highlight that the actual values and the test data are very close to each other. Hence, profitability forecast was made for the period of September 2017 and June 2017 for the established networks. As a result, it is seen that the profitability forecasting, which are important for banks, can be done with artificial neural network model.

Keywords: Artificial Neural Networks, Bank Profitability, Forecast

* Doç. Dr., Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü

** Dr. Öğr. Üyesi, Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Bankacılık ve Finans Bölümü

*** Arş. Gör., Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Bankacılık ve Finans Bölümü

I. Giriş

Bankacılık sektörü ekonominin gelişmesi için etkin ve önemli bir rol oynamaktadır. Bankalar, yapmış oldukları sermaye birikimi ve ekonomik zenginliğin sağlanması bakımından ekonomide önemli bir aktör konumundadır (Taşkın, 2011: 289). Son dönemlerde para ve sermaye piyasalarının önemli aktörü konumuna gelen bankalar kurum ve şahıs işlemlerinde geniş bir ürün yelpazesi sunmaktadır (Sümer, 2016: 505). Ülke ekonomisinde tasarrufların yatırımlara dönüşmesine aracı rol oynayan bankaların ekonomik gelişime büyük katkılarda bulunması beklenmektedir. (Demirhan, 2010: 157). Bankaların temel amacı kuruluşta konulan sermaye ile faaliyetler gerçekleştirerek sürdürülebilir kâr elde etmektir (Kartal, 2018: 6). Bu doğrultuda kârlılık, iktisadi alanda faaliyet gösteren işletmelerin temel amacı ve var olma şartıdır. Bankalar için kârlılık performansı, kurumsal bir başarı göstergesi olarak kabul edilir (Güneş, 2015: 266). Bununla beraber özellikle ticari bankalar kârlarını en yüksek seviyeyi amaçlayan ve piyasadaki mevcut paylarını arttırmaya çalışan firmalar olarak nitelendirilirler (Gündoğdu, 2011: 243).

Bankaların iyi bir strateji ve plan ile ilerleyebilmesi ve özellikle kârlılıklarının ne düzeyde gerçekleşeceğini önceden öngörü yapabilmesi işletme açısından önem arz eden bir durumdur. Burada öngörünün amacı karar vermedeki riski en aza indirmek ve bankanın sürdürülebilir faaliyetlerini iyi yönetebilmektir.

Bu çalışmanın amacı da aktif büyüklüklerine göre ele alınan büyük ölçekli banka kârlılıklarının ileriki dönemler için öngörüsünün yapılmasıdır. Kârlılık öngörüsü için Yapay Sinir Ağları (YSA) yöntemi kullanılmıştır. Uygulamada, TBB'nin istatistik raporlarında yer alan 2017 itibarıyla aktif büyüklüklerine göre sıralanan büyük ölçekli yedi bankanın verileri ele alınmıştır. Verilerden ortalama özkaynak kârlılığı bağımlı değişken olarak belirlenmiştir. Bağımsız değişkenler ise iki grup olarak ele alınmıştır. İlk grup içsel değişkenler ikinci grup ise dışsal değişkenler olarak tanımlanmıştır.

Her bir banka için ayrı ayrı model ağı kurulmuştur ve Matlab programında analiz edilmiş, en iyi ağa ulaşıldıktan sonra bulunan en iyi ağ ile birlikte geleceğe yönelik kârlılık öngörülerini yapılmıştır.

II. Literatür İncelemesi

Literatüre bakıldığında banka kârlılığı üzerine oldukça fazla çalışma bulunmaktadır. Banka kârlılıkları üzerine farklı yöntemler kullanılmıştır. Yaygın olarak kullanılan yöntemler arasında panel veri analizi, çoklu doğrusal regresyon analizi ve YSA bulunmaktadır.

Yapay sinir ağları finansal alanlarda oldukça geniş bir kullanıma sahiptir. Bu alanlardan bazıları; makroekonomik tahminler, borsa benzetim çalışmaları endekslerinin tahmin edilmesi, kredi kartı hilelerin tespiti, kredi kartı kurumlarında iflas tahminleri, banka kredilerinin değerlendirilmesi, risk analizi, döviz kuru tahminleri, emlak kredilerinin yönetilmesidir. Aynı zamanda endüstriyel uygulamalarda, askeri uygulamalarda, sağlık uygulamalarında ve

benzer birçok alanda yaygın olarak kullanılmaktadır (Öztemel, 2012: 205-206). Finansal alanlarda yapılan bazı çalışmalar Tablo 1.'de gösterildiği gibidir.

Tablo 1. Yapay Sinir Ağları Alanında Yapılan Bazı Çalışmalar

Uygulama Alanı	Yazarlar
Muhasebe ve Finans	(Coakley ve Brown, 2000: 119-144).
Hisse Senedi Fiyat Tahminlemesi	(Tektaş ve Karataş, 2004: 337-349).
Ekonomik Tahminler	(Şeker vd., 2004: 79-83).
Nakit Tahmini	(Kumar ve Walia, 2006: 61-77).
Bankalarda Kobi Kredilerini Değerlendirmesi	(Yazıcı, 2007).
Finansal Güç Derecelerinin Tahmini	(Boyacıoğlu ve Kara, 2007: 197-217).
Borsa Endeksi Tahmini	(Kutlu ve Badur, 2009: 25-40).
İMKB Üzerine Bir Uygulama	(Akkaya vd., 2009: 187-216).
Bankaların Finansal Başarısızlıklarının Geleneksel Ve Yeni Yöntemlerle Öngörüsü	(Çelik, 2010: 129-143).
İMKB Sigorta Endeksini Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Tahmini	(Akcan ve Kartal, 2011: 27-40).
Kurumsal Finansal Sıkıntı Tahminleri	(Gholizadeh vd., 2011: 595-605).
Kredi Risk Yönetimi/Tahmini	(Pacelli ve Azzollini, 2011: 103-112). (Budak ve Erpolat, 2012: 23-30).
Finansal Tablolardaki Hile Riskinin Belirlenmesi	(Uğurlu, 2011).
Türkiye Endeksinin Öngörüsü	(Tosunoğlu ve Keskin Benli, 2012: 541-547).
Fiyat Tahminlemesi	(Erdoğan ve Özyürek, 2012: 85-92).
Bankaların Finansal Başarısızlıklarının Tahmini	(Altunöz, 2013: 189-217).
Mevduat Bankalarının Kârlılığının Tahmini	(Sönmez vd., 2015: 9-45).
Nakit Yönetimi	(Şuleş, 2016: 125-140).
Bankacılık Alanında Müşteri Kaybının Öngörülmesi	(Zorić, 2016: 116-124).
Finansal Tahmin	(Enyindah ve Uzochukwu, 2016: 28-32).
Altın Fiyatlarının Tahmini	(Yüksel ve Akkoç, 2016: 39-50).
Döviz Piyasası Baskısı Modellerinin Analizi	(Dayı ve Akdemir, 2016: 151-168).

III. Yapay Sinir Ağları

İnsan beyni oldukça karmaşık, doğrusal olmayan ve paralel (bilgi işleme sistemi) bir bilgisayardır. Beyin, en hızlı dijital bilgisayardan çok daha hızlı bir şekilde, belirli hesaplamalar yapmak için nöronlar olarak bilinen yapısal bileşenleri düzenleme kabiliyetine sahiptir (Haykin, 1999: 1).

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sinir Ağları İle Kârlılıklarının Öngörüsü


1940'lı yıllarda tasarlanan yapay sinir hücre modeli, "VE", "VEYA" veya "DEĞİL" ve benzeri mantık işlemlerinin sayısal bir şekilde modellenebileceğini göstermiştir. Bununla birlikte biyolojik sinir sisteminin incelenmesi ve onlara benzer şekilde çalışan yapay sinir ağı modellerinin geliştirilmesi ile farklı alanlardaki araştırmacıların ortak çalışma konusu durumuna gelmiştir (Şen, 2004: 9). YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler üretebilme gibi kabiliyetini herhangi bir yardım olmaksızın otomatik olarak ortaya çıkarmak niyetiyle geliştirilen bilgisayar sistemleridir (Öztemel, 2012: 29). Yapay sinir ağları, öğrenme olarak tanımlanan adımda eldeki mevcut gözlemlerden yeni gözlemler üretebilme yeteneğine sahiptir (Delen vd., 2006: 437).

Sinir sisteminin modellenmesi ile ortaya çıkan yapay sinir ağı paralel çalışma ve öğrenebilme kabiliyeti açısından biyolojik sinir sisteminin özelliğini göstermektedir. Başka özelliklerinin yanında paralel çalışmasından dolayı bilgileri hızlı bir biçimde işleyebilmesi ve donanımının kolay bir şekilde gerçekleştirilebilir olması yapay sinir ağlarını diğer yöntemlere göre daha cazip bir hale getirmektedir (Şen, 2004: 8).

Yapılan çalışmalardaki problemlerin çeşidine göre geliştirilmiş birçok ağ çeşidi görülmekle birlikte sınıflandırma ve tahmin problemlerinde Çok Katmanlı Algılayıcılar (Multi Layer Perceptron) oldukça yaygın olarak kullanılmaktadır. Bu ağ aynı zamanda geri yayımlı ağ (backpropagation network) olarak da bilinmektedir. Çok katmanlı algılayıcılar 1986'da Rumelhart ve arkadaşları tarafından geliştirilmiştir (Church ve Curram, 1996: 257). Çok katmanlı algılayıcı ağları öğretmenli öğrenme stratejisine göre çalışmaktadır. Yani; bu ağlara eğitim esnasında hem girdiler hem de o girdilere karşılık üretilmesi beklenen çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir (Öztemel, 2012: 77). Ağ yalnızca kendisine sunulan öğrenme verisi ile eğitimini gerçekleştirdiği için parametrik bir model söz konusu değildir. Bu nedenle oluşturulan model yalnızca verileri kullandığı ölçüde iyi olmakla beraber model için açıklayıcı değişkenlerin seçimi çok önemlidir (Church ve Curram, 1996: 257).

Çok katmanlı yapay sinir ağı modelinde girdi katmanı (input layer), ara katmanlar (hidden layer) ve çıktı katmanı (output layer) yer almaktadır. Çok katmanlı algılayıcı ağında hazırlanan bilgiler girdi katmanından ağa sunulur ve ara katmanlardan geçerek çıktı katmanına ulaşır ve ağa sunulan girdilere karşılık ağın cevabı dış dünyaya iletilir (Öztemel, 2012: 77).

Çok katmanlı ağlarda öğrenme aşamasında, gerçek çıktı değeri ile ağın ürettiği çıktı değeri arasındaki hatayı en aza indirmek için ağırlıklar sürekli olarak değiştirilir. Hata minimuma indiği anda öğrenme süreci gerçekleştirilmiş olur (Velo vd., 2014: 3). Bu nedenle bu ağlar için birçok öğrenme algoritması kullanılmaktadır. Şekil 1'de bir çıktı katmanına sahip çok katmanlı algılayıcı ağı gösterilmektedir.



Şekil 1: Tek Çıktı Katmanına Sahip Çok Katmanlı Algılayıcı Ağı

Geleceği tahmin veya öngörü sözcükleri ile belirtilen kavram, bir değişkenin ileriki dönemde alabileceği değerlerin önceden yaklaşık olarak belirlenmesi olarak ifade edilebilir. Gelecekle ilgili karar vermeyi gerektiren durumlarda, tahmin, karar vericinin en büyük destekçisi ve yardımcısı olacaktır. Tahminin amacı, karar vermedeki oluşabilecek riski en aza indirmektir. Var olan iyi yönetim sisteminin en önemli karakteristiklerinden biri, belirsizlik ortamında en iyi performansa ulaşabilmesidir (Hamzaçebi, 2011: 1).

Geleceği tahmin amaçlı kurulan bir tahmin sistemini iki adımda incelemek mümkündür. Bu adımlardan birincisi model kurma, diğeryse tahmin aşamasıdır. Yapılacak tahminler, kurulan modele göre gerçekleşeceğinden dolayı model kurma aşaması oldukça önemlidir. Kurulan doğru model, gerçeğe daha yakın tahminlerin üretilmesini sağlayacaktır (Hamzaçebi, 2011: 1).

Bankaların sürdürülebilirliği ve sektörde iyi bir konumda yer alması için kârlılık kavramı oldukça önemlidir. Bundan yola çıkarak bu çalışmada da yapay sinir ağlarını kullanarak oluşturulacak modelle banka kârlılığının gelecek dönemler için öngörülere yapılacaktır.

IV. Banka Kârlılığının Yapay Sinir Ağları Yöntemi Kullanılarak Öngörülerinin Yapılması

Bu çalışmada 2003 Mart-2017 Haziran arası 3 aylık dönem verileri dikkate alınarak yapay sinir ağları yöntemi ile aktif büyüklüklerine göre büyük ölçekli bankaların kârlılık öngörüsü yapılmıştır. Çalışmaya başlamadan önce yapılan literatür taramasıyla banka kârlılığını etkileyen değişkenler belirlenmiş ve bu değişkenlerden en yaygın olarak kullanılanları uygulama için belirlenmiştir. (Güneş, 2015: 273; Saldanlı ve Aydın, 2016: 5; Gülhan ve Uzunlar, 2011: 356; Reis vd, 2016: 28; Samırkaş vd, 2014: 127; Sönmez vd, 2015: 21-23; Sarıtaş, 2016: 94; Alp vd, 2010: 6). Bankaların kârlılığını etkileyen faktörler bankaya özgü içsel değişkenler ve makroekonomik (dışsal) değişkenler

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sınır Ağları İle Kârlılıklarının Öngörüsü

olarak ele alınıp, kullanılan değişkenler Tablo 2.'de olduğu gibidir. Uygulamayı kapsayan dönemler arasında meydana gelen 2008 finansal krizinin de kârlılığa önemli ölçüde etkisi olduğu düşünülmektedir. Bundan dolayı 2008 finansal krizi çalışmaya kukla değişkeni olarak eklenmiştir.

Tablo 2. *Çalışmada Kullanılan Değişkenler*

BAĞIMLI DEĞİŞKENLER	BAĞIMSIZ DEĞİŞKENLER
Ortalama Özkaynak Kârlılığı	İçsel Değişkenler
	Özkaynaklar/Toplam Aktifler
	Toplam Mevduat/Toplam Aktifler
	Toplam Krediler ve Alacaklar/Toplam Aktifler
	Takipteki Krediler /Toplam Krediler ve Alacaklar
	Likit Aktifler/Kısa Vadeli Yükümlülükler
	Faiz Dışı Gelirler(net)/Toplam Aktifler
	Personel Giderleri/ Diğer Faaliyet Giderleri
	Dışsal Değişkenler
	GSYİH
	Enflasyon Oranı
	2008 Krizi (Kukla Değişken)

Çalışmada 7 bankaya ait 3'er aylık toplam 54 ortalama özkaynak kârlılığı verileri bağımlı değişken olarak kullanılmıştır. Diğer belirlenen 10 değişken ise Tablo.2'de gösterildiği gibi bağımsız değişken olarak ele alınmıştır. Her banka için ayrı ayrı toplam 7 model kurulmuştur. Kurulan modellerin uygun gecikme uzunluğu dört olarak belirlenmiştir ve bağımsız değişkenlerin 4 dönem gecikmeli değerleri kullanılmıştır. Çalışmada kullanılan 54 dönemlik verinin, yaklaşık %85'i eğitim, %15'i de test verisi olarak seçilmiştir. Çalışmada ele alınan aktif büyüklüklerine göre büyük ölçekli bankaların listesi Tablo 3'deki gibidir (www.tbb.org.tr).

Tablo 3. 30.06.2017 İtibariyle Aktif Büyüklüklerine Göre Banka Sıralamasında Büyük Ölçekli Bankalar

	Banka	Kuruluş Yılı	Toplam Aktifler (Milyon TL)
B1	Türkiye Cumhuriyeti Ziraat Bankası A.Ş.	1863	399.947
B2	Türkiye İş Bankası A.Ş.	1924	340.510
B3	Türkiye Garanti Bankası A.Ş.	1946	308.683
B4	Akbank T.A.Ş.	1948	290.562
B5	Yapı ve Kredi Bankası A.Ş.	1944	265.125
B6	Türkiye Halk Bankası A.Ş.	1938	264.808
B7	Türkiye Vakıflar Bankası T.A.O.	1954	236.623

Kaynak: Türkiye Bankalar Birliği İstatistik Raporları

Uygulamada kullanılan bankalara ait içsel değişken verileri Türkiye bankalar birliği istatistik raporlarından elde edilmiş olup; makroekonomik (dışsal) değişkenler ise TUIK'den elde edilmiştir.

Çalışmada her bir banka için ayrı ayrı ağ yapısı oluşturularak uygulama yapılmıştır. Kullanılan ağ yapılarından altı tanesinde bir giriş katmanı, bir gizli katman ve bir çıkış katmanı bulunurken bir tanesinde, bir giriş katmanı, iki gizli katman ve bir çıkış katmanı bulunmaktadır. Bu ağ yapıları çeşitli denemelerle belirlenmiştir. En iyi ağ yapısı belirlenirken tahmin performans ölçümleri dikkate alınmıştır.

Yapılmış olan çalışmalarda en fazla kullanılan tahmin performans ölçümleri:

RMSE (Hata Kareleri Ortalamasının Karekökü) 1 nolu eşitlik,

MAPE (Ortalama Mutlak Yüzdellik Hata) 2 nolu eşitlik ve

MSE'dir (Hata Kareleri Ortalaması) 3 nolu eşitlik (Zhang ve Hu, 1998: 500; Cho, 2003: 328).

Değerlendirme yapılırken kullanılan alternatif ağlardan öngörü performans ölçüm değeri en küçük olan ağ en iyi ağ yapısı olarak kullanılmış ve öngörü verileri elde edilmiştir.

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sinir Ağları İle Kârlılıklarının Öngörüsü

$$RMSE = \sqrt{\frac{\sum (y_t - \hat{y}_t)^2}{T}} \quad (1)$$

$$MAPE = \frac{1}{T} \sum \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (2)$$

$$MSE = \frac{\sum (y_t - \hat{y}_t)^2}{T} \quad (3)$$

Burada;

y_t = Gerçek gözlem değerleri,

\hat{y}_t = Tahmin edilen değerleri,

T = Tahmin sayısıdır.

Lewis (Lewis, 1982: 40'dan aktaran, Frechtling, 2001: 26) ortalama mutlak yüzdelik hata (MAPE) değerleri %10'un altında olan modeller için "çok iyi", %10 ile %20 arasında olan modeller için "iyi", %20 ile %50 arasında olan modelleri "kabul edilebilir", %50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır.

Banka kârlılık öngörüsü yapay sinir ağının eğitimi Matlab programı ile yapılmıştır. Uygulamada her bir oluşturulan model ağı için; adaptasyon öğrenme işlevi (Adaption Learning Function) olarak, "LearnGDM", transfer fonksiyonu (Transfer Function) olarak giriş, gizli ve çıktı katmanını Tansig, performans fonksiyonu olarak da "MSE" (Hata Kareleri Ortalaması) seçilmiştir. Girdi değişkenlerinin arasındaki sayısal değerlerin çok farklı olması ağın sonucunu yanlış yönde etkileyebilmektedir (Zhang vd., 1998; Demuth vd., 2009'dan alıntılan, Sönmez vd., 2015: 27). Bu nedenle, ağın girdi değerleri genellikle [-1, 1] aralığına ya da [0, 1] aralığına ölçeklendirilmektedir. Böylece hem farklı birimlerde ölçülmüş veriler aynı ölçeğe indirgenmiş olmakta hem de sayısal olarak çok büyük veya çok küçük değerlerin etkisi ortadan kaldırılmış olmaktadır (Sönmez vd., 2015: 27). Bu sebepten dolayı eğitim sürecine başlamadan önce bütün değişkenler 0 ile 1 aralığına ölçeklenmesi için değerler ortak paydaya bölünerek normalize edilmiştir.

Uygulamada kullanılan ağ yapılarının özellikleri, ağ yapısı Tablo 4.'de verilmiştir.

Tablo 4. Kurulan Ağ Yapıları ve Özellikleri

BANKALAR	TOPLAM VERİ SAYISI	EĞİTİM İÇİN AYRILAN VERİ SAYISI	TEST İÇİN AYRILAN VERİ SAYISI	ÖĞRENME YÜZDESİ	GİRİŞ KATMANINDAKİ NÖRON SAYISI	GİZLİ KATMANDAKİ NÖRON SAYISI	ÇIKTI KATMANINDAKİ NÖRON SAYISI
B1	54	46	8	%97	10	1	1
B2	54	46	8	%97	10	1	1
B3	54	46	8	%97	10	1	1
B4	54	46	8	%96	10	1	1
B5	54	46	8	%99	10	2	1
B6	54	46	8	%97	10	1	1
B7	54	46	8	%95	10	1	1

Her bir banka için uygulama sonuçları yani tahmin performans ölçüm değerleri Tablo 5.' de verilmiştir.

Tablo 5. Uygulama Sonuçları

BANKALAR	TOPLAM VERİ SAYISI	TEST İÇİN AYRILAN VERİ SAYISI	MAPE(%)	MSE	RMSE
B1	54	8	4,60	0,00000092	0,000961
B2	54	8	11,26	0,00000267	0,001633
B3	54	8	9,97	0,00000328	0,001814
B4	54	8	6,10	0,00000865	0,000930
B5	54	8	9,37	0,000001324	0,001150
B6	54	8	7,91	0,000001463	0,001209
B7	54	8	9,18	0,00000589	0,002427

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sinir Ağları İle Kârlılıklarının Öngörüsü

Tablo 5.'de test verileri için bütün bankaların gerçek değerlerle simülasyon değerleri arasında performans ölçüm değerleri verilmiştir. Bankaların ortalama mutlak yüzdelik hata (MAPE) değerlerine bakıldığında B2 bankası hariç %10'un altında olduğu için "çok iyi" model sınıfına girmiştir. B2 Bankasının ise MAPE değeri %11.26 olarak hesaplanmış ve %10 ve %20 arasında yer aldığı için "iyi" model sınıfına girmiştir ve literatüre göre her bir banka için önerilen modellerin "çok iyi" ve "iyi" olduğu söylenebilir. Bu durumda da aynı modeli kullanarak devam eden dönemler için öngörülebilir yapılabilir.

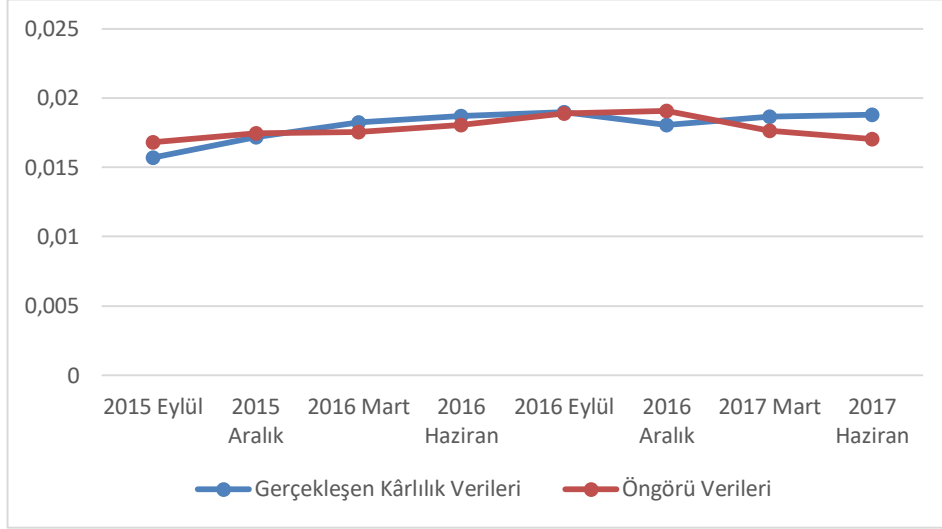
Örnek olması açısından B1 bankasına ait önerilen yapay sinir ağı modelinin test verilerine ait simülasyon değerleri ve gerçekleşen değerler Tablo 6.'da verilmiştir. Diğer bankaların ise sadece devam eden dönemler için öngörü verileri verilecektir.

Tablo 6. B1 Bankası Gerçekleşen Kârlılık Verileri ve Simülasyon Verileri

DÖNEMLER	KÂRLILIK VERİLERİ	SİMÜLASYON KÂRLILIK VERİLERİ
2015 EYLÜL	15,70597251	16,78373024
2015 ARALIK	17,16231427	17,43707251
2016 MART	18,22609554	17,56170294
2016 HAZİRAN	18,7213029	18,03122741
2016 EYLÜL	18,98752736	18,89187846
2016 ARALIK	18,06052137	19,05789643
2017 MART	18,67174711	17,61836331
2017 HAZİRAN	18,78699118	17,02059873

*Atatürk
Üniversitesi*

Test verilerine ait gerçek ve simülasyon değerleri Grafik 1.'de verilmektedir.



Grafik 1: Gerçek Kârlılık Verileri ve Simülasyon Verilerinin Grafikselleştirilmesi

Grafikselleştirilmesinde de görüldüğü gibi bankanın 2015 Eylül ve 2017 Haziran arası dönemler için gerçek ve simülasyon değerleri birbirine oldukça yakın olduğu görülmektedir.

Çalışmanın sonucunda B1 bankasına ait MAPE değeri 0,046 (%4,60) “çok iyi” model sınıfına girdiği için devam eden dönemlere yönelik öngörüleme yapılmıştır. B1 Bankasına ait kârlılık öngörülleri aşağıdaki gibidir.

Tablo 7. B1 Bankası Devam Eden Dönemler İçin Kârlılık Öngörülleri

DÖNEMLER	ÖNGÖRÜ DEĞERLERİ
2017 EYLÜL	16,16851
2017 ARALIK	16,63648
2018 MART	16,80837
2018 HAZİRAN	17,38308

Yedi bankanın 2017 Eylül-2018 Haziran dönemleri için kârlılık öngörülleri ise Tablo.8’de gösterildiği gibidir.

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sinir Ağları İle Kârlılıklarının Öngörüsü

Tablo 8. *Bankaların Öngörü Verileri*

ÖNGÖRÜ VERİLERİ				
BANKALAR	2017 Eylül	2017 Aralık	2018 Mart	2018 Haziran
B1	16,1685069	16,6364793	16,80836669	17,38308021
B2	10,8826748	10,6446944	11,3757399	10,90129706
B3	12,4103619	12,637981	12,17888649	12,45793437
B4	15,7253391	15,3488191	16,35818567	15,19718053
B5	12,4494909	-1,1184736	2,048016885	-1,91001363
B6	13,5420571	13,6234745	13,56255782	13,60983856
B7	13,4166081	12,8461756	13,18518352	13,71295833

Analiz sonuçlarına bakıldığında B3 ve B6 bankalarının kârlılıkları stabil olarak devam ederken; B1, B2, B4 ve B7 bankalarının ise belirli dönemlerde kârlılık düzeyinde azalma görülmüştür. B5 bankasında ise 2017 Aralık ve 2018 Haziran dönemleri arasında kârlılık düzeyinde düşüşler yaşandığı görülmektedir.

V. Sonuç

Para piyasalarının temel kurumu olarak ifade edilen bankalar tasarrufların ekonomiye yönlendirilmesinde ve finansman ihtiyacının karşılanmasında baş aktörlerden biridir. Bankalar kâr amacı güderek faaliyetlerini devam ettiren finansal kuruluşlardır. Bankalar etkin risk, gider ve sermaye yönetimi ile vermiş oldukları hizmet maliyetlerinin en aza indirilmesine odaklanarak ve faaliyetlerini en iyi şekilde devam ettirerek kârlılığı ve verimlilik doğrultusunda büyümeyi hedeflemektedirler (İş Bankası Faaliyet Raporu, 2016: 58). Bankaların kârlılıkları; başta banka yönetimi ve bankanın iç işleyişinden etkilenmekle birlikte dış dinamiklerden de etkilenebilmektedir (Dağlıdır, 2010: 25). Bu çalışmada da bankaların iç dinamiklerinin yanında kârlılığı etkilediği düşünülen dış dinamikler de çalışmaya dâhil edilmiştir. Bu sayede yapılacak olan kârlılık öngörülleri, belirsizliği azaltarak riskin en az düzeye indirilmesini sağlayacaktır. Bankalar kârlılık analizi yaparak gelecek dönem için kârlılık stratejilerini bu doğrultuda belirleyebilirler. Bankalar dönem içinde elde etmiş oldukları kârlılığın, planlanan kârlılığa oranla ne seviyede gerçekleştiğini görerek, banka için bir karara varmaktadırlar. Bankalar böylece kârlılık alanındaki vizyonlarına ne düzeyde yakın olduklarını görebilmektedirler. Bankalar gerçekleşen kârlılıklarına göre geleceğe yönelik kârlılık planı hazırlamaktadırlar. Bu plan doğrultusunda banka için kısa ve uzun vadeli stratejiler geliştirmektedirler (Sönmez vd, 2015: 10).

Bu çalışmada yapay sinir ağı modelleri ile banka kârlılığı öngörülleri amaçlanmıştır. Bu amaçla aktif büyüklüklerine göre ele alınan büyük ölçekli banka gruplarının verileri doğrultusunda yapay sinir ağı modeli kurulmuştur. Yedi ayrı bankanın kurulan yapay sinir ağı modeli ile öncelikle test verileri elde

edilmiştir. Elde edilen test verileri ile gerçek veriler arasında ortalama mutlak yüzdelik hata hesaplanmıştır. Hesaplanan ortalama mutlak yüzdelik hatalara göre “çok iyi” ve “iyi” modeller elde edilerek bu modellerle devam eden dönemler için kârlılık öngörülleri elde edilmiştir. Genel olarak bakıldığında kurulan her bir ağ modelinin güvenilirlik oranlarının en az %88 olması yapılan çalışmanın öngörü için geçerli sonuçlar üretebileceğini göstermektedir. Bununla birlikte yapılan çalışmada bağımlı değişkeni etkileyen, on tane bağımsız değişkenlerinde analize dâhil edilmesi yapay sinir ağlarının bu analiz için uygun bir seçim olduğunu göstermektedir. Analiz sonuçlarına bakıldığında B3 ve B6 bankalarının kârlılıkları stabil olarak devam ederken; B1, B2, B4 ve B7 bankalarının ise belirli dönemlerde kârlılık düzeyinde azalma görülmüştür. B5 bankasında ise 2017 Aralık ve 2018 Haziran dönemleri arasında kârlılık düzeyinde düşüşler yaşandığı görülmektedir.

Bu çalışma ile birlikte bankalar için önemli olan kârlılık kavramının geleceğe ait öngörülerinin yapılması için kullanılacak alternatif bir yöntem olduğunu vurgulanmıştır. Aynı zamanda çalışmanın bir diğer amacı da, farklı finansal alanlarda çalışma yapan araştırmacılara, yapay sinir ağlarının kullanımı ile ilgili olarak yol gösterilmesidir.

Kaynaklar

- Akcan, A. ve Kartal, C. (2011), “İMKB Sigorta Endeksini Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları İle Tahmini”, *Muhasebe ve Finansman Dergisi*, Temmuz, ss.27-40.
- Akkaya G., C., Demireli, E., 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), ss. 187-216.
- Alp A., Ban, Ü., Demirgüneş, K. ve Kılıç, S. (2010), “Türk Bankacılık Sektöründe Kârlılığın İçsel Belirleyicileri”, *İMKB Dergisi*, 12(46), ss.1-13.
- Altunöz, U. (2013), “Bankaların Finansal Başarısızlıklarının Yapay Sinir Ağları Modeli Çerçevesinde Tahmin Edilebilirliği”, *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 28(2), ss. 189-217.
- Birgül Kutlu B. ve Badur, B. (2009), “Yapay Sinir Ağları İle Borsa Endeksi Tahmini”, *Yönetim*, 20(63), ss.25-40.
- Boyacıoğlu M., A.ve Kara Y.(2007), “Türk Bankacılık Sektöründe Finansal Güç Derecelerinin Tahmininde Yapay Sinir Ağları ve Çok Değişkenli İstatistiksel Analiz Tekniklerinin Performanslarının Karşılaştırılması”, *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 22(2), ss.197-217.

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sinir Ağları İle Kârlılıklarının Öngörüsü

- Budak, H. ve Erpolat, S. (2012), “Kredi Riski Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karşılaştırılması”, *AJIT-e: Online Academic Journal of Information Technology*, 3(9), ss.23-30.
- Cho, V. (2003), “A Comparison of Three Different Approaches to Tourist Arrival Forecasting”, *Tourism Management*, 24 (3), p. 323-330.
- Church, K. B. and Curram, S. P. (1996), “Forecasting Consumers’ Expenditure: A Comparison Between Econometric and Neural Network Models”, *International Journal of Forecasting*, 12 (2), p. 255-267.
- Coakley James R. and Brown Carol E. (2000), “Artificial Neural Networks in Accounting and Finance: Modeling Issues”, *International Journal of Intelligent Systems in Accounting, Finance & Management*, 9, p. 119-144.
- Çelik, M., K. (2010), “Bankaların Finansal Başarısızlıklarının Geleneksel ve Yeni Yöntemlerle Öngörüsü”, *Celal Bayar Üniversitesi İ.İ.B.F Yönetim ve Ekonomi*, 17(2), ss. 129-143.
- Dağıdır, C. (2010), “Türk Bankacılık Sektöründe Kârlılık ve Makro Ekonomik Değişkenlerle İlişkisi”, *Ekonomi Bilimleri Dergisi*, 2(1), ss. 25-33.
- Dayı, F. ve Akdemir, E. (2016), “Döviz Piyasası Baskısı Modellerinin Yapay Sinir Ağı İle Mukayesesi: Türkiye Uygulaması”, *Akademik Araştırmalar ve Çalışmalar Dergisi*, 8(15), ss. 151-168.
- Delen, D., Sharda, R. and Bessonov, M. (2006), “Identifying Significant Predictors of Injury Severity in Traffic Accidents Using a Series of Artificial Neural Network”, *Accident Analysis & Prevention*, 38 (3), p. 434-444.
- Enyindah, P., and Onwuachu Uzochukwu C. (2016), “A Neural Network Approach to Financial Forecasting”, *International Journal of Computer Applications*, 135(8), p. 28-32.
- Erdoğan, E. ve Özyürek, H. (2012), “Yapay Sinir Ağları İle Fiyat Tahminlemesi”, *Sosyal ve Beşeri Bilimler Dergisi*, 4(1), ss. 85-92.
- Frechtling, D. C. (2001), “An Assessment of Visitor Expenditure Methods and Models”, *Journal of Travel Research*, 45 (1), p. 26-35.
- Gholizadeh, M., H., Langroudi, M., M., N., Bahmani, A. and Dizaji, B., S. (2011), “Corporate Financial Distress Prediction Using Artificial Neural Networks and Using Micro-Level Financial Indicators”, *Interdisciplinary Journal Of Contemporary Research In Business*, 3(5), p. 595-605.
- Gülhan Ü. ve Uzunlar, E. (2011), “Bankacılık Sektöründe Kârlılığı Etkileyen Faktörler: Türk Bankacılık Sektörüne Yönelik Bir Uygulama”, *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 15 (1), ss. 341-368.
- Gündoğdu F. ve Aksu, H. (2011), “Mevduat Bankacılığında Kârlılık ve Makroekonomik Değişkenler İlişkisi: Türkiye Üzerine Bir Uygulama”, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10. Ekonometri ve İstatistik Sempozyumu Özel Sayısı, ss. 243-270.

- Güneş, N. (2015), “Banka Kârlılığının Belirleyicileri: 2002-2012 Dönemi Türk Mevduat Bankaları Üzerine Bir İnceleme”, *Süleyman Demirel Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 20 (3), ss. 265-282.
- Hamzaçebi, C. (2011), *Yapay Sinir Ağları*, Ekin Yayınevi, Bursa.
- Haykin, S. (1999), *Neural Networks A Comprehensive Foundation*, Prentice Hall.
- Kartal, M. T. (2018), Bankaların Finans Sektöründeki Önemi (Importance of Banks in Finance Sector), *Finansal İktisat (Financial Economics)*, 5-27, 2018/8. Available at SSRN: <https://ssrn.com/abstract=3232801>.
- Kumar, P., Walia, E.(2006), “Cash Forecasting: An Application of Artificial Neural Networks in Finance”, *International Journal of Computer Science & Applications*, III (I), p. 61-77.
- Öztemel, Ercan.(2012), *Yapay Sinir Ağları*, Papatya Yayıncılık Eğitim, 3.Basım, İstanbul.
- Pacelli, V., and Azzollini M. (2011), “An Artificial Neural Network Approach for Credit Risk Management”, *Journal of Intelligent Learning Systems and Applications*, 3, p. 103-112.
- Reis, Ş., G., Kılıç, Y. ve Buğan, M., F. (2016), “Banka Kârlılığını Etkileyen Faktörler: Türkiye Örneği” *Muhasebe ve Finans Dergisi*, Ekim, ss.21-36.
- Saldanlı, A. ve Aydın, M. (2016), “Bankacılık Sektöründe Kârlılığı Etkileyen Faktörlerin Panel Veri Analizi İle İncelenmesi: Türkiye Örneği”, *İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi*, 24, ss.1-9.
- Samırkaş, M., C., Evcı, S. ve Ergün, B. (2014). Türk Bankacılık Sektöründe Kârlılığın Belirleyicileri. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 5(8), ss.117-134.
- Sarıtaş, H., Kangallı Uyar S., G. ve Gökçe, A. (2016), “Banka Kârlılığı İle Finansal Oranlar ve Makroekonomik Değişkenler Arasındaki İlişkilerin Sistem Dinamik Panel Veri Modeli ile Analizi: Türkiye Araştırması”, *Eskişehir Osmangazi Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 11(1), ss. 87- 108.
- Sönmez F., Zontul M. ve Bülbül, Ş. (2015), “Mevduat Bankalarının Kârlılığının Yapay Sinir Ağları İle Tahmini: Bir Yazılım Modeli Tasarımı”, *BDDK Bankacılık ve Finansal Piyasalar*, 9(1), ss. 9-45.
- Şuleş, P. (2016), “Cash Management of a Company Using Neural Networks”, *Littera Scripta*, 9(3), p.125-140.
- Sümer, G. (2016), “Türk Bankacılık Sektörünün Tarihsel Gelişimi ve AB Bankacılık Sektörü İle Karşılaştırılması”, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(2), ss. 485-508.
- Şeker, M., Yıldırım, E. S., Berkay, A. (2004), “Yapay Sinir Ağlarının Ekonomik Tahminlerde Kullanılması”, *Pamukkale Üniversitesi Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, Özel Sayı 10, ss.79-83.

Aktif Büyüklüklerine Göre Değerlendirilen Büyük Ölçekli Bankaların Yapay Sinir Ağları İle Kârlılıklarının Öngörüsü

- Şen, Z. (2004), Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları, İstanbul.
- Taşkın, F., D. (2011), “Türkiye’de Ticari Bankaların Performansını Etkileyen Faktörler”, *Ege Akademik Bakış*, 11(2), ss. 289- 298.
- Tektaş A., ve Karataş, A. (2004), “Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi”, *İktisadi ve İdari Bilimler Dergisi*, 18(3-4). ss. 337-349.
- Tosunoğlu, N., G. ve Keskin Benli Y. (2012), “Morgan Stanley Capital International Türkiye Endeksinin Yapay Sinir Ağları ile Öngörüsü”, *Ege Akademik Bakış*, 12(4), ss. 541-547.
- Uğurlu, M. (2011), Finansal Tablolardaki Hile Riskinin Belirlenmesi: Yapay Sinir Ağı Modeliyle Bir Bankada Uygulama, Dumlupınar Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, Doktora Tezi, Kütahya.
- Velo, R., López, P. and Maseda, F. (2014), “Wind Speed Estimation Using Multilayer Perceptron”, *Energy Conversion and Management*, 81, p.1-9.
- Yazıcı, M. (2007), Bankalarda Kobi Kredilerini Değerlendirmeye İlişkin Bir Yaklaşım: Yapay Sinir Ağları, Kadir Has Üniversitesi Sosyal Bilimler Enstitüsü Finans ve Bankacılık Doktora Programı, Doktora Tezi, İstanbul.
- Yüksel, R. ve Akkoç S. (2016), “Altın Fiyatlarının Yapay Sinir Ağları İle Tahmini ve Bir Uygulama”, *Doğuş Üniversitesi Dergisi*, 17 (1), ss.39-50.
- Zhang, G. and Hu, M. Y. (1998), “Neural Network Forecasting of The British Pound/US Dollar Exchange Rate”, *Omega International Journal of Management, Science*, 26 (4), p. 495-506.
- Zorić, A., B. (2016), “Predicting Customer Churn In Banking Industry Using Neural Networks”, *Interdisciplinary Description of Complex Systems*, 14(2), p.116-124.
- <https://www.tbb.org.tr/bankacilik/banka-ve-sektor-bilgileri/istatistiki-raporlar/59>, (Erişim Tarihi: 27.12.2017)
- <https://www.isbank.com.tr/TR/hakkimizda/yatirimciiliskileri/finansalbilgiler/Documents/FaaliyetRaporlari/FaaliyetRaporu2016.pdf>, (Erişim Tarihi: 27.12.2017)
- <http://www.tuik.gov.tr/PreTabloArama.do?metod=search&araType=vt>, (Erişim Tarihi: 25.12.2017)