

AŞIRI ÖĞRENME MAKİNELERİ İLE HİSSE SENEDİ FİYAT TAHMİNİ

*Hacettepe Üniversitesi
İktisadi ve İdari Bilimler
Fakültesi Dergisi,
Cilt 35, Sayı 1, 2017,
s. 67-88*

Mehmet ÖZÇALICI

Yrd.Doç.Dr., Kilis 7 Aralık Üniversitesi
İktisadi ve İdari Bilimler Fakültesi
Uluslararası Ticaret ve Lojistik Bölümü
mozcalici@kilis.edu.tr

Öz: Hisse senedi fiyatlarının doğru bir şekilde tahmin edilebilmesinin birçok faydalı tarafları mevcuttur. Yapay sinir ağları hisse senedi fiyat tahmininde başarıyla kullanılan yöntemlerden biridir.

Fakat öğrenme sürecinin yavaş olması, kullanıcının birçok parametreye karar vermek zorunda olması bu yöntemin dezavantajlarını oluşturmaktadır. Bu olumsuz durumları ortadan kaldırmak için Aşırı Öğrenme Makineleri (AÖM) adı verilen yöntem geliştirilmiştir. Literatürde henüz farklı çeşitlerde aktivasyon fonksiyonu içeren AÖM modellerinin hisse senedi tahmin performansı üzerindeki etkisi incelenmemiştir. Bu çalışmada on dört farklı aktivasyon fonksiyonunun kullanıldığı modeller oluşturulmuş ve modellerin performansları istatistiksel ve finansal açıdan değerlendirmeye tabi tutulmuştur. Çalışmada Goodyear, Amazon ve Walmart isimli şirketlere ve SP500 Endeksine ait geçmiş fiyat ve işlem hacmi bilgilerini kullanmak suretiyle 12 adet teknik göstere hesaplanmış ve modellerin girdi değişkeni olarak kullanılmıştır. Çıktı değişkeni ise bir sonraki güne ait kapanış fiyatlarını içermektedir. Modellerin performansı geleneksel yapay sinir ağları modeli ile karşılaştırılmıştır. Sonuçta %59.32 'ye varan oranda fiyatların yönü doğru bir şekilde öngörülebilmiştir. Ayrıca kâğıt üzerinde, al ve tut stratejisinden daha yüksek oranda getiriler elde edilmiştir. Sonuçlar, AÖM modelinin hisse senedi fiyat tahmininde güçlü bir alternatif olduğunu göstermektedir.

Anahtar Sözcükler: Aşırı öğrenme makineleri, yapay sinir ağları, fiyat tahmini.

PREDICTING STOCK PRICES WITH EXTREME LEARNING MACHINES

*Hacettepe University
Journal of Economics
and Administrative
Sciences
Vol. 35, Issue 1, 2017,
pp. 67-88*

Mehmet ÖZÇALICI

Assist.Prof.Dr., Kilis 7 Aralık
Üniversitesi
Faculty of Economics and Administrative
Sciences
mozcalici@kilis.edu.tr

Abstract: There are various benefits of forecasting stock prices before they actually occur. Artificial Neural Network is one of the methods that is used for forecasting stock prices. However, the difficulties such as the low speed of training process and the complexity of determining the parameters make it difficult to implement. In order to eliminate these difficulties a new method named Extreme Learning Machine (ELM) is developed. The performance of ELM with different activation functions have not examined in stock price forecasting problem. In this study, ELM models with fourteen different activation functions are designed and their performance are compared with statistical and financial measurements. 12 technical indicators are calculated using the historical price and volume information belong to Goodyear, Amazon and Wal-Mart as well as SP500 Index. The output of the model is the closing price of the next day. The performances of the models are compared with regular artificial neural network models. The stock prices are correctly forecasted up to 59.32% hit rate. Moreover, higher paper-returns are obtained from passive buy&hold strategy. The results obtained in this study shows that ELM is a powerful alternative for stock price forecasting.

Keywords: *Extreme learning machine, artificial neural networks, forecasting.*

GİRİŞ

Hisse senedi analizi, sadece kar elde etmek veya zarardan korunmak için değil aynı zamanda piyasanın gelecekteki trendini öngörmekte kullanıldığı için önemli ve üzerinde çalışılan bir konudur (Mahmud, Meesad, 2015). Bunun yanında fiyatların doğru bir şekilde tahmin edilmesinin akademik faydaları da mevcuttur (Atsalakis *vd.*, 2016). Ancak hisse senedi fiyatlarının birçok faktörden etkilenmesi fiyat tahminini zorlaştırmaktadır.

Hisse senedi fiyatlarını tahmin etmek ve analiz etmek için önceleri AR, MA, ARMA, ARIMA gibi istatistiksel yöntemler kullanılmıştır ve bu yöntemleri kullanmak suretiyle hisse senedi fiyat tahmini gerçekleştiren 150 tane çalışma Atsalakis ve Valavanis (2010) in çalışmasında bir arada okuyucuya sunulmuş ve sınıflandırılmıştır. Çalışmaları sonunda bu yöntemlerin hisse senedi fiyatlarını başarılı bir şekilde tahmin ettiğini raporlamaktadırlar. Ancak yakın zamanda yapay sinir ağları (YSA) (Kara *vd.*, 2011; Wang *vd.*, 2011), uyarlamalı sinirsel bulanık denetim sistemi (adaptive neuro-fuzzy inference system ANFIS) (Atsalakis, Valavanis, 2009; Chang *vd.*, 2011), destek vektör makineleri (support vector machines) (Huang *vd.*, 2005; Ince ve Trafalis, 2007) gibi bilgi-işlemsel zeka (computational intelligence) yöntemleri fiyat tahmininde kullanılmakta ve başarılı tahmin sonuçları raporlanmaktadır. Bu yöntemlerin en önemli avantajlarından biri klasik istatistiksel yöntemler gibi varsayımlara dayanmıyor olmalarıdır. Ayrıca literatürde yer alan bazı çalışmalarda yöntemlerin performansları karşılaştırmakta ve bilgi işlemsel zeka yöntemlerinin, geleneksel yöntemlerden daha yüksek başarı sağladığı raporlanmaktadır (Adhikari *vd.*, 2013; Chen, Li 2006; Kanas, Yannopoulos, 2001; Adebisi *vd.*, 2014; Isenah, Olubusove, 2014). Hisse senedi fiyat tahmininde başarıyla kullanılan yöntemlerden biri Yapay Sinir Ağlarıdır (YSA). YSA modeli her ne kadar hisse senedi fiyat tahmininde başarıyla kullanılsa da bazı dezavantajları mevcuttur. Yapay sinir ağları ile eğitim sürecinin hızı genellikle olması gerekenden çok yavaştır. Bunun temel nedenleri; (1) yavaş gradyan bazlı öğrenme algoritmaları ve (2) bu algoritmaların doğru sonuçlar ortaya çıkarmaları için mimarideki bütün ağırlıkları yenilemeli bir şekilde değiştirmek zorunda olmalarıdır (Huang *vd.*, 2006). Aynı zamanda kullanıcının eğitim sürecinde fazla sayıda parametreye karar vermesi gerekmektedir. Bu olumsuzlukları ortadan kaldırmak için Aşırı Öğrenme Makineleri (AÖM – Extreme Learning Machine (ELM)) adı verilen yeni bir yöntem geliştirilmiştir. Bu yöntem ile modelin eğitim hızı, YSA eğitim hızından aşırı derecede yüksektir (Huang *vd.*, 2006). Literatürde YSA ile AÖM yöntemlerinin performansını karşılaştıran çalışmalarda da aradaki zaman farkı gözlemlenebilir ve modelin isminde neden aşırı kelimesinin kullanıldığı anlaşılabilir (Dash *vd.*, 2014).

Yapılan literatür taraması sonucu AÖM yönteminin hisse senedi fiyat tahmininde kullanıldığı belirlenmiş ancak farklı aktivasyon fonksiyonlarının tahmin performansına

etkisinin incelenmediği ortaya çıkmıştır. Literatürde yer alan bu açığı kapatmak için on dört adet farklı aktivasyon fonksiyonunun yer aldığı AÖM modelleri geliştirilmiş ve bu modeller hisse senedi fiyat tahmininde kullanılmıştır. AÖM modellerinin tahmin performansı aynı zamanda yapay sinir ağları modeli ile karşılaştırılmıştır. Çalışmada modellerin ortaya çıkardığı tahmin sonuçları ile gerçek sonuçlar dört farklı performans ölçütü kullanmak suretiyle karşılaştırılmıştır.

Çalışma beş bölüme ayrılmıştır. Bu giriş bölümünden sonra birincibölümde AÖM yönteminin fiyat tahmininde kullanıldığı çalışmaları tanıtan literatür taraması yer almaktadır. İkinci bölümde yapay sinir ağları ve aşırı öğrenme makinelerinin kısa tanıtımı gerçekleştirilmektedir. Üçüncü bölümde uygulama yer almaktadır. Son bölümde ise sonuç, tartışma ve sonraki çalışmalar için öneriler yer almaktadır.

1. LİTERATÜR TARAMASI

Literatürde Aşırı Öğrenme Makineleri yöntemi ile hisse senedi fiyat tahmini gerçekleştiren çalışmalar henüz az sayıdadır. Bu konu ile ilgili yapılan çalışmalar şu şekilde özetlenebilir. Dash *vd.* (2014) finansal zaman serisi tahmininde AÖM yöntemini kullanmışlardır. Çalışmalarında farklı ülkelere ait hisse senetleri ve menkul kıymet borsa indeks verilerini kullanmışlardır. Çalışmalarında önerdikleri yöntemin performansını istatistiksel tahmin yöntemleri ile ölçmüşlerdir. Armoni Arama tabanlı önerdikleri melez yöntemin başarısının yüksek olduğunu raporlamışlardır. Li *vd.*, (2016) ise çalışmalarında aşırı öğrenme makineleri ile hisse senedi indeks tahmini gerçekleştirmişlerdir. Girdi değerleri olarak hisse senedi piyasası ile ilgili yayınlanan haberlerin yanı sıra teknik göstergeleri de kullanmışlardır. Çalışma sonunda AÖM ile gerçekleştirilen tahminlerin, Destek vektör makineleri ve yapay sinir ağları ile yapılan tahminlerden hem daha hızlı hem de daha yüksek doğruluğa sahip olduğunu raporlamaktadırlar. Özçalıcı (2016) ise yaptığı çalışmada hangi özelliklere sahip hisse senetlerinin daha yüksek doğru oranı (yüzdellik değeri) ile tahmin edildiğini araştırmıştır. Bu amaçla BIST 50 Endeksinde yer alan senetlerin hepsinin fiyatlarını aşırı öğrenme makineleri yöntemi ile tahmin etmiş ve sonuçta daha yüksek risk ve düşük getirili senetlerin kapanış fiyatının daha başarılı bir şekilde tahmin edilebildiğini raporlamıştır.

Bunun yanı sıra Aşırı Öğrenme Makineleri yöntemi diğer işletmecilik problemlerinin çözümünde de başarıyla kullanılmaktadır. Bu çalışmaları şu şekilde özetlemek mümkündür. Sun *vd.* (2008) çalışmalarında moda üzerine perakende satış yapan bir firma için satış tahmin modeli geliştirmişlerdir. Geliştirdikleri model, AÖM üzerine kuruludur. Önerdikleri yöntemin Yapay Sinir Ağları tabanlı diğer modellerden daha iyi sonuç ortaya çıkardığını raporlamaktadırlar. Wong ve Guo (2010) orta dönemli satış tahmini için AÖM ve Armoni Arama (Harmony Search) algoritmasını bir arada kullanmışlardır. Önerdikleri yöntemi moda perakende satışı yapan tedarik zinciri

üzerinde denemişlerdir. Çalışmalarında performans ölçütü olarak istatistiksel performans göstergelerini kullanmışlardır. Çalışmalarında girdi olarak geçmiş fiyat hareketlerini kullanmaktadırlar. Çalışma sonunda önerdikleri yöntemin başarılı bir şekilde tahmin gerçekleştirdiğini raporlamaktadırlar. Xia *vd.* (2012) yılında perakende işletmesi için AÖM yöntemi ile satış tahmini gerçekleştirmiştir. Özellikle kılık kıyafet (moda) satışı yapan işletmelerde, stoksuzluk maliyetine maruz kalmamak için satış tahmininin önemine vurgu yapmaktadırlar. Çalışmalarında aylık verileri kullanmışlardır. Çalışmalarında melez bir yöntem önermişler ve bu yöntemin diğer yöntemlere oranla daha başarılı sonuçlar ortaya çıkardığını raporlamaktadırlar.

Bunların yanı sıra çeşitli fiyat tahminleri için de AÖM yöntemi kullanılmaktadır. Örneğin, Xia *vd.* (2012) AÖM ile elektrik fiyat tahmini gerçekleştirmişlerdir. Çalışmalarında AÖM yöntemi ile gerçekleştirilen tahmin sonuçları, yapay sinir ağları, destek vektör makineleri, ARCH, GARCH ve bulanık YSA gibi yöntemlerle gerçekleştirilen tahmin sonuçları ile karşılaştırılmış ve önerdikleri yöntemin daha iyi sonuç verdiğini raporlamışlardır. Yan *vd.* (2014) uranyum kaynağının fiyatının tahmin etmek için AÖM nin de dahil olduğu üç adet yöntemden oluşan melez bir yöntem önermektedirler. Çalışmalarında Ortalama karesel hataların karekökü, ortalama mutlak hata ve yön istatistiği isimli performans ölçülerini kullanmışlardır. Ayrıca İleri beslemeli radyal bazlı yapay sinir ağlarını da tahminde kullanmışlardır. 1982 ile 2012 yılları arasındaki 360 aya ilişkin fiyat bilgisini kullanmışlardır. Çalışma sonunda önerdikleri yöntemin performans ölçülerine göre YSA modelinden daha iyi sonuçlar ortaya çıkardığını raporlamışlardır.

AÖM yönteminin yaratıcısı Huang *vd.* (2011) tarafından gerçekleştirilen çalışmada yöntemin ve bu yöntemin çeşitli varyasyonlarını detaylı bir şekilde incelenmiştir. Sonuç olarak AÖM yönteminin bir öğrenme tekniği olarak, regresyon ve sınıflandırma problemlerinin çözümünde yüksek başarı potansiyeline sahip olduğu raporlanmaktadır. Buradan hareketle bu çalışmada farklı aktivasyon fonksiyonlarına sahip AÖM modellerinin, hisse senedi fiyat tahminindeki performansı araştırılmaktadır.

2. METODOLOJİ

2.1. Yapay Sinir Ağları

Yapay sinir ağlarını şu şekilde tanımlamak mümkündür: Yapay sinir ağları, eğitimle elde edilen bilgileri saklayan ve kullanabilen basit işlem birimlerinden oluşan paralel bir dağıtık işlemcidir (Haykin, 2005: 24). Yapay sinir ağları, veri setinde var olan örüntüleri ortaya çıkarabilmekte ve başarılı bir şekilde genelleştirebilmektedir. Girdi ve çıktı arasında bağlantıların sahip olduğu ağırlık değerlerini ve eşik değerlerini değiştirmek suretiyle, ilişkileri ortaya çıkarabilmektedir (Huang *vd.*, 2008).

Yapay sinir ağırları sinyal işleme, özellik çıkarımı (feature extraction), sınıflandırma, örüntü keşfi (pattern recognition), zaman serilerinin tahmini gibi birçok alanda kullanılmaktadır (Palit, Popovic, 2005: 80). Yapay sinir ağırları doğrusal olmayan zaman serilerini modelleyebildikleri, gürültülü veri setlerini analiz edebildiği ve farklı çeşitlerde veri setini kullanabildikleri için zaman serileri tahmininde de başarılı bir şekilde uygulanmaktadır (Armano *vd.*, 2005).

Yapay sinir ağlarının tarihi gelişimi hakkında detaylı tartışma (Palit, Popovic, 2005: 79-80) de yer almaktadır. Burada YSA'nın tarihçesine, tekrardan kaçınmak adına değinilmeyecektir. Sadece yapay sinir ağlarının tarihçesinin 1949 tarihine kadar gidebileceği ifade edilmektedir.

Yapay sinir ağırları literatürde tanıtıldığından beri işletmecilik alanında başarıyla da kullanılmaktadır. Smith ve Gupta (2000) yapay sinir ağlarının işletme alanındaki kullanımını detaylı bir şekilde incelemektedir. Özetlemek gerekirse, pazarlama (piyasa bölümlendirmesi), perakendecilik (satış tahmini), bankacılık ve finans (hisse senedi alım satımı, tahmin, iflas tahmini, hileli tabloların belirlenmesi), sigortacılık (hileli taleplerin belirlenmesi, risk primi tahmin edilmesi), telekomünikasyon (müşteri kaçışının (churn) tahmin edilmesi), yöneylem araştırması (planlama ve zaman çizelgelerinin hazırlanması, talep tahmini) gibi işletmecilik alanında yapay sinir ağırları uygulanabilmektedir.

Şekil 1' de Yapay Sinir Ağlarının genel yapısı yer almaktadır. Bu yapıya sahip yapay sinir ağlarının çalışma prensibini şu şekilde özetlemek mümkündür. Bir yapay sinir ağı modeli, girdi katmanı, çıktı katmanı ve gizli katmandan oluşmaktadır. Gizli katmanın birden fazla katmandan oluşması mümkündür. Her katmanda nöronlar bulunmaktadır. Girdi katmanında, kullanılan değişken sayısı kadar nöron vardır. Çıktı katmanında da kullanılan çıktı sayısı kadar nöron bulunmaktadır. Ancak gizli katmanda ne kadar nöronun yer alması gerektiğine ilişkin belirli bir kural yoktur. Her bir nöron kendisinden önceki katmandaki nöronların çıktı değerlerini girdi değeri olarak kullanmaktadır. Ara katmanda ve çıktı katmanda yer alan nöronlar belirli bir aktivasyon fonksiyonuna göre kendisine gelen sinyalleri işlemekte ve varsa bir sonraki katmana iletmektedir. Bir ara katmanı ve ara katmanında yeteri kadar nöron bulunan bir yapay sinir ağı modeli her çeşit doğrusal olmayan fonksiyonu modelleyebilmektedir (Fausett, 1994).

Aktivasyon fonksiyonları yapay sinir ağlarının çıktısını şekillendiren bir fonksiyondur (Haykin, 2005: 32). Yapay sinir ağı hangi tip problemin çözümünde kullanılacaksa buna uygun aktivasyon fonksiyonunun seçilmesi gerekmektedir. Örneğin sınıflandırma problemi çözülecekse, bu durumda hard limit gibi iki çıktı üretecek fonksiyonların kullanılması gerekmektedir. Hisse senetlerinin tahmini sonucunda

sürekli değerlerin üretilmesi gerektiğinden saf doğrusal gibi sürekli çıktı üreten aktivasyon fonksiyonlarından birisinin seçilmesi gerekmektedir.

Yapay sinir ağlarının çeşitli avantajlı tarafları mevcuttur. Bu avantajlar şu şekilde sıralanabilir: doğrusal olmamak (nonlinearity), girdi-çıkıtı haritalama (input-output mapping) ve uyum sağlanabilirlik (adaptivity) (Haykin, 2005: 24-26). Bununla birlikte yapay sinir ağlarının bazı kısıtları da mevcuttur. Denetimli öğrenme kullanıldığı modellerde çok fazla sayıda örneğe (dolayısıyla eğitim için daha uzun zamana) ihtiyaç duyulması, nihai modelin kolay yorumlanamıyor olması, yerel optimuma kolay düşülebilir olması ve kabul edilebilir bir sonucun bulunup bulunamayacağına garantisinin olmaması bu dezavantajlar arasında sıralanabilir (Sumathi, Surekha, 2010: 94)

2.2. Aşırı Öğrenme Makineleri

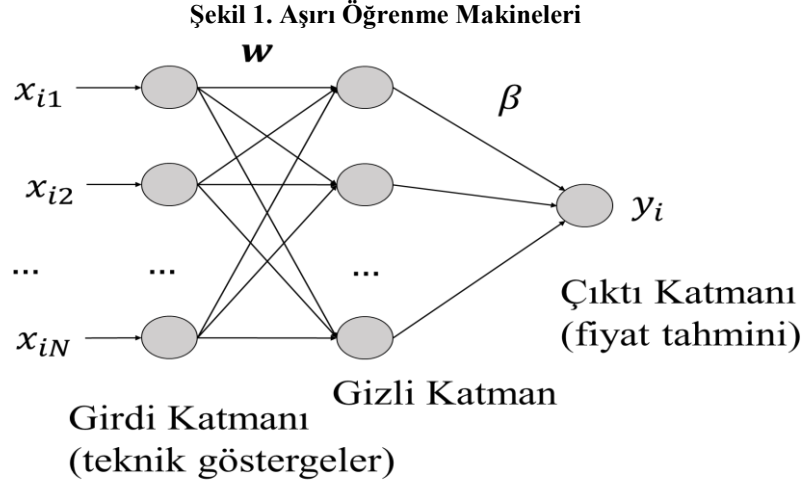
Aşırı öğrenme makineleri temelde bir adet gizli katmanı olan yapay sinir ağlarına benzemektedir. Bu nedenle Aşırı Öğrenme Makinelerinin çalışma prensibi belirli bir dereceye kadar Yapay Sinir Ağlarının çalışma prensipleri ile aynıdır. Ancak aşırı öğrenme makinelerinde gizli katmandaki ağırlıklar (w) rassal bir şekilde atanmaktadır ve bu değerler eğitimin ileriki aşamasında değişikliğe uğramamaktadır (güncellenmemektedir). Buna karşın gizli katman ile çıktı katmanı arasındaki ağırlıklar (β) tek bir seferde doğrusal bir model yardımıyla analitik ve hızlı bir şekilde belirlenmektedir.

Temel AÖM modeli Şekil 1' den de görüldüğü gibi, tek gizli katmanı olan ileri beslemeli yapay sinir ağları tabanlıdır ve YSA ile farkı şu şekilde açıklanabilir. Geleneksel tek katmanlı ileri beslemeli yapay sinir ağı modelinde N adet girdi ve çıktı değerlerinin bulunduğu bir veri mevcuttur. Gizli katmanında \tilde{N} adet nöron bulunan standart ileri beslemeli yapay sinir ağları ve aktivasyon fonksiyonu denklem (1) 'deki gibidir.

$$\sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \mathbf{x}_i + b_i) = 0, j = 1, \dots, N \quad (1)$$

Bu modelde β_i çıktı ağırlığı, w_i girdi ağırlık matrisini ve b_i ifadeleri i nöronundaki eşik değerlerini temsil etmektedir (Liv d 2016). Geleneksel olarak (örneğin LM eğitim algoritması ile) bu modeldeki β ağırlıkları yenilemeli bir şekilde hesaplanmaktadır. Ancak Huang vd. (2006) modeldeki β ağırlıklarını analitik bir şekilde tek seferde hesaplayacak yeni bir yöntem önermektedirler ve bu yöntem ile elde edilecek çözümün emsalsiz (unique) olduğunu kanıtlamaktadırlar. Bu yöntemin adı AÖM olarak adlandırılmaktadır ve Huang ve arkadaşları tarafından özellikle 2006 yılından bu yana detaylı bir şekilde incelenmektedir.

Temel olarak YSA modelinin daha hızlı eğitilmesi sağlandığından ve YSA bazlı bir model olduğundan, yapay sinir ağlarının kullanılabilmesi ve yukarıda sıralanan her alanda aşırı öğrenme makineleri modelinin de kullanılması mümkündür.



Aşırı Öğrenme Makineleri için de Yapay Sinir Ağlarında olduğu gibi modelin çıktısını şekillendirecek aktivasyon fonksiyonuna ihtiyaç duyulmaktadır ve bu fonksiyon çeşidi kullanıcı tarafından belirlenmek durumundadır. Farklı aktivasyon fonksiyonu çeşitleri mevcuttur. Bunlardan on dört tanesine ilişkin formüller Tablo 1 de bir araya getirilmiştir. Ayrıca kullanıcının kendisi de farklı aktivasyon fonksiyonu geliştirebilir ve bunu AÖM yönteminde kullanabilir. Ancak bu çalışmada MATLAB platformunda (Neural Networks Toolbox) hazır bulunan 14 adet aktivasyon fonksiyonu kullanılmıştır.

Aşırı Öğrenme Makinelerinin en önemli avantajı çok hızlı bir şekilde eğitimi gerçekleştirebilmesidir (Huang *vd.*, 2006). Bununla birlikte daha az sayıda parametrenin belirlenmesi bir avantaj olarak düşünülebilir. Yapay sinir ağlarında özellikle eğitimle ilgili parametrelere de kullanıcının karar vermesi gerekmektedir. AÖM yönteminde ise eğitim analitik bir şekilde gerçekleşmektedir. Bununla birlikte hangi aktivasyon fonksiyonunun kullanılması gerektiğine karar verilmesi ve ara katmandaki nöron sayısına karar verilmesi gerektiği bir dezavantaj olarak değerlendirilebilir.

Tablo 1. AÖM Yönteminde Kullanılan Aktivasyon Fonksiyonları

	Aktivasyon Fonksiyonu	Denklemi
1	Sigmoid Fonksiyon	$a = \frac{1}{1 + \exp(-n)}$
2	Sinüs Fonksiyonu	$a = \text{sine}(n)$
3	Kosinüs fonksiyonu	$a = \text{cosine}(n)$
4	Kesin Sınırlayıcı (Hard Limit)	$a = \begin{cases} 1, & \text{eğer } n \geq 0 \\ 0, & \text{diğer durumlarda} \end{cases}$
5	Üçgensel Bazlı	$a = \begin{cases} 1 - \text{abs}(n), & \text{eğer } -1 \leq n \leq 1 \\ 0, & \text{diğer durumlarda} \end{cases}$
6	Radyal Bazlı	$a = \exp(-n^2)$
7	Normalleştirilmiş Radyal Bazlı	$a = \frac{\exp(-n^2)}{\sum \exp(-n^2)}$
8	Elliot Sigmoid	$a = \frac{0.5 * n}{(1 + \text{abs}(n))} + 0.5$
9	Log-sigmoid	$a = \frac{1}{(1 + \exp(-n))}$
10	Saf Doğrusal	$a = n$
11	Soft Max	$a = \frac{\exp(n)}{\sum(\exp(n))}$
12	Ters (Inverse)	$a = \frac{1}{n}$
13	Doygun (Saturated) Doğrusal	$a = \begin{cases} 0, & \text{eğer } n \leq 0 \\ n, & \text{eğer } 0 \leq n \leq 1 \\ 1, & \text{eğer } 1 \leq n \end{cases}$
14	Pozitif doğrusal	$a = \begin{cases} n, & \text{eğer } n \geq 0 \\ 0, & \text{eğer } n < 0 \end{cases}$

3. UYGULAMA

3.1. Veri Seti

Çalışmada veri seti olarak New York Stock Exchange Borsasında işlem gören üç farklı hisse senedi ve SP500 indeks verileri kullanılmıştır. Hisse senetleri seçilirken (Global Endüstri Sınıflandırma Standardı (Global Industry Classification Standard) göz önünde bulundurulmuştur. 1999 yılında geliştirilen bu standartta endüstride yer alan firmalar sınıflandırılmaktadır ve 24 adet endüstri grubu ile 157 tane endüstri alt grubu bulunmaktadır (MSCI, 2016). Hisse senetleri seçilirken, faaliyette buldukları alanlar göz önünde bulundurulmuş ve farklı endüstrilerdeki firmalar kullanılmıştır. Seçilen hisse senetleri şunlardır; Goodyear (Lastik ve Kauçuk (Tires & Rubber) alt sektörü), Amazon.com (İnternet ve Doğrudan Pazarlama Perakende alt sektörü - Internet & Direct Marketing Retail) ve Wal-Mart (Hipermarket alt sektörü). Bu hisse senetlerinin seçilmesinin nedeni büyük bir borsada işlem görüyor olmalarıdır. Yüksek işlem hacmine sahip başka bir ifade ile çok sayıda alıcı ve satıcının var olduğu bir borsada, fiyatların objektif bir şekilde belirlenecektir. Buna karşın daha az gelişmiş bir borsada işlem gören hisse senetlerinin fiyatlarının, bireysel bazı yatırımcıların kararlarından etkilenmesi muhtemeldir.

Veri seti MATLAB Datafeed araç kutusu yardımıyla, Yahoo.com sitesinden elde edilmiştir. Elde edilen veri setinde her bir işlem günü için sırasıyla; tarih, açılış fiyatı, en yüksek fiyat, en düşük fiyat, kapanış fiyatı ve işlem hacmi değerleri yer almaktadır. Bir araya getirilen veri seti eğitim ve test veri seti olmak üzere iki gruba ayrılmıştır. Eğitim setinde AÖM ve YSA modellerinin eğitimi gerçekleştirilirken, test setinde, yaratılan modeller test edilmektedir. Dolayısıyla test setindeki performans (örneklem dışı performans) önem arz etmektedir.

Veri setinde en son kapanış fiyatı, analizin gerçekleştiği günden önceki güne ait olan kapanış fiyatıdır. Bu şekilde mümkün olan en güncel zaman dilimi kullanılmış olmaktadır. Eğitim seti 1 Şubat 2001 de başlamakta ve 3 Ağustos 2016 tarihinde sona ermektedir ve toplamda 3900 adet işlem günü mevcuttur. Test seti ise 4 Ağustos 2016 tarihinde başlamakta ve 27 Kasım 2016 tarihinde sona ermektedir ve toplamda 60 adet gözlem bulunmaktadır.

Tahmin çalışmasında Tablo 2 de yer alan girdi değişkenleri kullanılmıştır. Bu değişkenler literatür taraması sonucu bir araya getirilmiştir (Armano *vd.*, 2005; Kara *vd.*, 2011; Li *vd.*, 2016). Bu teknik göstergeler literatürde sıklıkla kullanılan değişkenler olduğu için seçilmiştir. Çıktı değişkeni ise bir sonraki güne ait kapanış fiyatıdır.

Tablo 2. Çalışmada Kullanılan Girdi Değişkenleri ve Formülleri

Değişken	Formül
10 günlük basit hareketli ortalama	$BHO_t = \frac{K_m + K_{m-1} + \dots + K_{m-(t-1)}}{t}$
10 günlük üssel hareketli ortalama	$SMA_t = \alpha * K_{t-1} + (1 - \alpha) * SHO_{t-1}$
10 günlük üçgensel hareketli ortalama	$\dot{U}HO_t = \frac{BHO_1 + \dots + BHO_t}{t}$
MACD	$MACD_t = MA_{t-26} - MA_{t-12}$
Momentum	$M_t = K_t - K_{t-n}$
Chaikin Volatility	$CO_t = MA_{ADL(3)} - MA_{ADL(10)}$
K Stokastik	$\%K_t = \frac{K_t - LLP_{t-n}}{HHP_{t-n} - LLP_{t-n}} * 100$
D Stokastik	$\%D_t = EMA_{\%K-n}$
Görelî güç endeksi	$RSI_t = \frac{100}{1 + \frac{U}{D}}$
Adline	$AD_{line} = \sum \left[\frac{(K - L) - (Y - K)}{(Y - L)} * H \right]$
Fiyat Değişim Oranı	$PROC_t = \frac{K_t - K_{t-n}}{K_{t-n}} * 100$
William Adline	$WAD = Bugünkü A \setminus D + Dünkü A \setminus D$

K : Kapanış Fiyatı, U: son n gün boyunca yüksek kapanan gün sayısı, D: son n gün boyunca düşük kapanan gün sayısı, L: düşük fiyat, Y: yüksek fiyat, H: işlem hacmi

Girdi değişkenleri formülleri gereği farklı ölçeklerde hesaplanmaktadır. Bu durum daha yüksek aralıkta değişen değişkenlerin analizde baskın hale gelmesine neden

olacaktır. Bu durum yanıltıcı tahmin sonuçlarının elde edilmesine neden olabilir. Bu nedenle tahminden elde edilecek performansı yükseltmek için veri setinin normalleştirilmesi gerekmektedir (Asadi vd., 2012). Bu çalışmada veri seti sıfır ve bir değerleri arasında aşağıdaki formülü kullanmak suretiyle normalleştirilmiştir.

$$x_{yeni} = \frac{x_{eski} - x_{min}}{x_{max} - x_{min}} \quad (2)$$

Formülde x_{yeni} normalleştirmeden sonraki değeri, x_{min} değişkenin minimum değerini, x_{max} ise değişkenin maksimum değerini temsil etmektedir.

Tablo 3’de çalışmada incelenen hisse senetleri ve Endeksin kapanış fiyatının tanımlayıcı istatistikleri eğitim ve test seti için ayrı ayrı yer almaktadır. Her bir kapanış fiyatının değişim aralığının (en yüksek – en düşük) her bir zaman serisinde farklı olduğu görülmektedir. Ortalama ve standart sapma değerleri de zaman serilerinin değişkenliği hakkında bilgi vermektedir. Basıklık değeri örneğin sivrilikliğini veya basıklığını ölçmektedir. Normal bir dağılımda basıklık değeri 3 olacaktır. Basıklık değerinin 3 değerinden büyük (küçük) olduğu durumlarda veri setinde uç değerlerin bulunduğu (bulunmadığından) bahsedilebilir. Çarpıklık değeri, veri setinin örnek ortalaması etrafındaki asimetriyi ölçmektedir. Negatif çarpıklık değeri, veri setinin örnek ortalamasının solunda yayıldığını göstermektedir (verilerin çoğu ortalamadan sağında yer almaktadır). Pozitif çarpıklık değerinde, veri seti örnek ortalamasının sağ tarafında yayılmaktadır (verilerin çoğu ortalamadan sol tarafında yer almaktadır).

Tablo 3. Hisse Senetleri ve Endekse ait Kapanış Fiyatının Tanımlayıcı İstatistikleri

	Goodyear		Amazon		Wal-Mart		SP500	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
En Yüksek	36.63	32.86	767.74	844.36	90.47	74.30	2175.03	2190.15
En Düşük	3.51	27.96	5.97	757.25	42.27	67.39	676.53	2125.77
Ortalama	17.64	30.76	158.41	793.99	58.06	71.30	1351.85	2160.25
Std Sapma	7.98	1.50	167.67	29.84	10.72	1.84	354.07	20.20
Basıklık (Kurtosis)	2.00	1.72	4.91	1.49	2.70	2.23	2.70	1.64
Çarpıklık (Skewness)	0.37	-0.36	1.54	0.35	0.91	-0.55	0.78	-0.21

3.2. Performans Ölçütleri

Çalışmada tahmin modellerinin ürettiği fiyatlar ile gerçek fiyatlar dört farklı performans ölçütü ile karşılaştırılmıştır. Bu performans ölçütleri Ortalama Karesel Yanılgı (OKY), Ortalama Mutlak Hata Yüzdesi (OMHY), isabet oranı ve getiri oranıdır.

$$OKY = \frac{1}{n} \sum_{i=1}^n (A_t - F_t) \quad (3)$$

$$OMHY = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \quad (4)$$

Formüllerde A_t , t gününe ilişkin gerçek fiyatı, F_t ise t gününe ilişkin tahmin edilen fiyatı temsil etmektedir. Gözlem sayısı ise formüllerde n ile gösterilmiştir (Bu çalışmada $n = 30$ dur). Söz konusu iki adet istatistiksel performans ölçüsü ne kadar küçük çıkarsa tahmin çalışması o kadar başarılı olmuş demektir. Eğer model gerçek fiyatlarla aynı sonuçları üretebilmişse bu durumda her iki performans göstergesinin değeri sıfır olacaktır.

İstatistiksel performans ölçüleri her ne kadar modelin başarısını ortaya çıkarmak konusunda genel bir görüş sunsa da tahmin çalışması için yeterli değildir. Çünkü bu ölçütler fiyat yönü hakkında bilgi sunmamaktadır (Atsalakis vd., 2016). Bu nedenle isabet oranı adı verilen bir ölçünün kullanılmasında fayda vardır.

$$IO = \frac{\text{doğru tahmin edilen yön}}{\text{toplam gözlem sayısı}} \quad (5)$$

Formüle de açıklandığı üzere isabet oranı (IO) doğru tahmin edilen yön sayısının, toplam gözlem sayısına bölünmesi ile elde edilmektedir. Formülü çalıştırabilmek için ilk olarak yön tahminlerinin yapılması gerekmektedir. Tahmin edilen fiyatlar üzerinden fiyat yönünü hesaplamak için tahmin adı verilen yeni bir değişken hesaplanmaktadır. Bir sonraki güne ilişkin tahmin edilmiş fiyat, bugüne ilişkin tahmin edilmiş fiyattan yüksekse (düşükse) *tahmini yön* 1 (0) değerini almaktadır. Aynı şekilde bir sonraki güne ilişkin gerçek fiyat, bugüne ilişkin gerçek fiyattan yüksekse (düşükse) *gerçek yön* 1 (0) değerini almaktadır. Gerçek yön ve tahmini yön değişkenleri aynı değeri aldığı anda doğru tahmin gerçekleştirilmiş demektir.

Önerilen modellerin performansını finansal açıdan incelemek için aktif getiri oranları pasif al ve tut stratejisi ile karşılaştırılmıştır. Pasif stratejide yatırımcı, test sürecinin başladığı gün hisse senedine yatırım yapmakta, test süreci boyunca yatırımı tutmakta ve test süreci sonunda yatırımı elden çıkarmaktadır. Sonuçta elde ettiği getiri oranı şu formül yardımıyla hesaplanacaktır:

$$\text{Getiri Oranı} = \frac{\text{Fiyat}_{\text{son}} - \text{Fiyat}_{\text{ilk}}}{\text{Fiyat}_{\text{ilk}}} \quad (6)$$

Aktif yatırım stratejisinde ise yatırımcı tahmin modelinin bir sonraki gün için fiyat artışı tahmin ettiği bir gün hisse senedini satın almakta ve bir sonraki gün satmaktadır. Eğer AÖM modeli gerçekten fiyat artışını doğru bir şekilde tahmin edebilmişse, bu durumda yatırımcı bu yatırımdan getiri sağlayacaktır. Eğer model fiyat

artışını (veya azalışını) doğru bir şekilde tahmin edemediyse, yatırımdan zarar edilecektir. Test süreci sonunda bütün alım satımlardan elde edilen getiri oranları toplanmak suretiyle aktif getiri oranı elde edilmiştir.

3.3. Analiz Sonuçları

Çalışmada on dört farklı aktivasyon fonksiyonu ile Aşırı Öğrenme Makineleri Modelleri oluşturulduktan sonra söz konusu modeller, test veri seti üzerinde denenmiştir. Test veri seti daha önce modelin karşılaşmadığı bir veri setidir. Dolayısıyla bu test seti üzerindeki performans örneklem dışı performanstır ve eğitim sürecinde gerçekleştirilen performanstan daha fazla pratik öneme sahiptir.

Çalışmada kullanılan aşırı öğrenme makineleri ve yapay sinir ağlarına ilişkin parametreler Tablo 4 de yer almaktadır. AÖM yönteminin bir diğer avantajı da kullanıcının daha az sayıda parametreye karar vermesidir (Huang *vd.*, 2015). Aşağıdaki tabloda bu durum açıkça görülmektedir. Yapay sinir ağlarının eğitilmesinde kullanılacak parametre sayısı fazla iken, AÖM yönteminde kullanıcı daha az sayıda parametreye karar vermek durumunda kalmaktadır.

Tablo 4. Çalışmada Kullanılan Analizlere İlişkin Parametreler

Yapay Sinir Ağları		Aşırı Öğrenme Makineleri	
Parametre	Değer	Parametre	Değer
Gizli Katman Nöron Sayısı	20	Gizli Katman Nöron Sayısı	20
Aktivasyon Fonksiyonu	Sigmoidal	Aktivasyon Fonksiyonu	14 farklı aktivasyon fonksiyonu
Eğitim Fonksiyonu	Resilient Backpropagation		
Min Gradient	1e-5		
Başlangıç Delta	0.07		
Delta Artış	1.2		
Delta Azalış	0.5		
Maximum Delta	50		

Çalışmada 14 adet farklı aktivasyon fonksiyonunun kullanıldığı modeller ile bir adet yapay sinir ağları modeli olmak üzere toplam 15 adet model ile tahmin gerçekleştirilmiş ve her bir hisse senedi için sonuçlar tablolar halinde kullanıcıya sunulmuştur.

Tablo 5’de Goodyear hisse senedi ile test sürecinde gerçekleştirilen performans sergilenmiştir. İstatistiksel performans göstergelerine (OKY ve OMYH) göre en iyi performans saf doğrusal aktivasyon fonksiyonunu kullandığı AÖM yönteminde

gerçekleştirilmiştir. YSA modelinde hisse senedinin fiyatındaki yön %56 oranında doğru bir şekilde önceden tahmin edilebilmiştir. Test dönemi boyunca al ve tut pasif stratejisi kullanıldığında elde edilecek getiri oranı %0.24 oranında olacaktır. Buna karşın doygun (saturated) doğrusal bazlı aktivasyon fonksiyonun kullanıldığı modelde %18.37 oranında getiri sağlanabilmiştir. Eğitim zamanları göz önünde bulundurulduğunda AÖM yönteminin Yapay Sinir Ağlarına göre oldukça kısa süre eğitimlerini tamamladıkları anlaşılmaktadır.

Tablo 5. Goodyear Hisse Senedi İçin Performans Göstergeleri

	OKY	OMHY (%)	İsabet Oranı (%)	Getiri Oranı (%)	İşlem Zamanı (Saniye)
Sigmoid Fonksiyon	0.0007	2.3794	44.07	1.02	0.0041
Sinüs Fonksiyonu	0.0010	3.0158	52.54	7.81	0.0043
Kosinüs fonksiyonu	0.0006	2.3477	54.24	6.68	0.0038
Kesin Sınırlayıcı (Hard Limit)	0.0148	12.8264	40.68	-6.63	0.0048
Üçgensel Bazlı	0.0269	18.0148	47.46	3.02	0.0034
Radyal Bazlı	0.0054	6.9244	47.46	13.83	0.0037
Normalleştirilmiş Radyal Bazlı	0.0013	3.5521	44.07	0.53	0.0049
Elliot Sigmoid	0.0016	4.0209	44.07	4.27	0.0034
Log-sigmoid	0.0004	1.9197	50.85	1.65	0.0039
Saf Doğrusal	0.0004	1.5616	40.68	-2.81	0.0029
Soft Max	0.0005	2.1120	42.37	1.78	0.0047
Ters (Inverse)	0.1142	38.9383	42.37	-3.04	0.0038
Doygun (Saturated) Doğrusal	0.0143	12.7843	64.41	18.37	0.0041
Pozitif doğrusal	0.0005	2.0350	52.54	0.19	0.0030
Yapay Sinir Ağları	0.0031	4.5782	55.93	8.09	1.0685
Pasif Strateji : %0.24					

Tablo 6'da Amazon adlı hisse senedi için test sürecinde gerçekleştirilen performans tablo halinde sunulmuştur. İstatistiksel performans göstergelerine göre (OKY ve OMYH) en iyi performans saf doğrusal aktivasyon fonksiyonun kullanıldığı AÖM yönteminde gerçekleştirilmiştir. Sigmoid aktivasyon fonksiyonu ve log-sigmoid aktivasyon fonksiyonunun kullanıldığı AÖM modelinde hisse sendi fiyatında yön %59.32 oranında önceden doğru bir şekilde tahmin edilebilmiştir. Dönem boyunca pasif stratejiyi takip eden bir yatırımcı %1,36 oranında getiri sağlayabilirken, log-sigmoid aktivasyon fonksiyonunun kullanıldığı AÖM modelinin ürettiği tahminlere göre hareket eden bir yatırımcı %10.89 oranında getiri sağlayabilmektedir. Eğitim süreleri AÖM modellerinde YSA modellerine göre daha kısa sürede tamamlanmaktadır.

Tablo 6. Amazon Hisse Senedi İçin Performans Göstergeleri

	OKY	OMHY (%)	İsabet Oranı (%)	Getiri Oranı (%)	İşlem Zamanı (saniye)
Sigmoid Fonksiyon	0.0006	1.8375	59.32	6.71	0.0040
Sinüs Fonksiyonu	0.0039	5.6801	45.76	4.75	0.0036
Kosinüs fonksiyonu	0.0009	2.5282	50.85	4.12	0.0042
Kesin Sınırlayıcı (Hard Limit)	0.0722	26.3126	49.15	-1.85	0.0032
Üçgensel Bazlı	0.0815	28.8504	47.46	-2.58	0.0036
Radyal Bazlı	0.0073	7.1247	49.15	0.01	0.0039
Normalleştirilmiş Radyal Bazlı	0.0018	3.2425	45.76	-1.42	0.0047
Elliot Sigmoid	0.0026	4.5440	47.46	1.62	0.0030
Log-sigmoid	0.0005	1.7367	59.32	10.89	0.0042
Saf Doğrusal	0.0001	0.8054	52.54	4.67	0.0029
Soft Max	0.0008	2.3964	57.63	4.42	0.0045
Ters (Inverse)	0.1839	43.6948	54.24	-4.86	0.0033
Doygun (Saturated) Doğrusal	0.0768	27.4094	52.54	-3.42	0.0032
Pozitif doğrusal	0.0010	2.2155	54.24	5.81	0.0033
Yapay Sinir Ağları	0.3722	58.2243	50.85	-5.07	1.2548
Pasif Strateji : % 1.36					

Tablo 7’de Wal-Mart adlı hisse senedi için test sürecinde gerçekleştirilen performans yer almaktadır. İstatistiksel performans göstergelerine (OKY ve OMHY) göre en iyi performansın saf doğrusal aktivasyon fonksiyonunun kullanıldığı AÖM yöntemi ile gerçekleştirildiği görülmektedir. Inverse aktivasyon fonksiyonunun kullanıldığı AÖM yöntemi kullanıldığında hisse senedindeki yön %55.93 oranında doğru bir şekilde tahmin edilebilmiştir. Al ve tut stratejisine uygulandığında söz konusu hisse senedi için ilgili dönemde %11.97 oranında bir zarar ortaya çıkmaktadır. Ters (inverse) aktivasyon fonksiyonunun kullanıldığı AÖM yönteminde ise %2.47 oranında getiri sağlanmaktadır. Yine AÖM yönteminde, eğitim sürelerinin yapay sinir ağlarına göre oldukça kısa sürede tamamlandığı ortaya çıkmaktadır.

Tablo 7. Wal-Mart Hisse Senedi için Performans Göstergeleri

	OKY	OMHY (%)	İsabet Oranı (%)	Getiri Oranı (%)	İşlem Zamanı (saniye)
Sigmoid Fonksiyon	0.0003	2.4143	45.76	-4.95	0.0042
Sinüs Fonksiyonu	0.0006	3.3268	50.85	-2.85	0.0054
Kosinüs fonksiyonu	0.0005	2.8263	45.76	-2.42	0.0040
Kesin Sınırlayıcı (Hard Limit)	0.0063	11.2100	54.24	-0.51	0.0034
Üçgensel Bazlı	0.0068	12.1764	54.24	1.17	0.0037
Radyal Bazlı	0.0008	3.9292	44.07	-4.83	0.0040
Normalleştirilmiş Radyal Bazlı	0.0017	5.4998	44.07	-1.05	0.0046
Elliot Sigmoid	0.0017	5.9067	40.68	-4.85	0.0033
Log-sigmoid	0.0003	2.0957	42.37	-4.05	0.0043
Saf Doğrusal	0.0002	1.9128	44.07	-3.94	0.0034
Soft Max	0.0005	2.7920	47.46	-4.54	0.0044
Ters (Inverse)	0.0113	14.0015	55.93	2.47	0.0032
Doymun (Saturated) Doğrusal	0.0083	11.9544	50.85	-2.18	0.0038
Pozitif doğrusal	0.0005	3.0606	52.54	-0.95	0.0037
Yapay Sinir Ağları	0.0197	16.890	54.24	1.46	0.0477
Pasif Strateji : -11.97					

Son olarak bireysel hisse senetlerinden ayrı olarak, SP500 endeksi için tahmin gerçekleştirilmiş ve sonuçlar Tablo 8’de listelenmiştir. İncelenen modeller arasında saf doğrusal aktivasyon fonksiyonuna sahip AÖM modelinde en yüksek istatistiksel tahmin performansı sergilenmiştir. Endeks fiyatlarındaki yön yapay sinir ağları modelinde %52.54 oranında doğru bir şekilde tahmin edilebilmiştir. Pasif strateji ile Endeks için söz konusu dönemde %3.75 oranında zarar ortaya çıkmaktadır. Doymun (Saturated) Doğrusal aktivasyon fonksiyonu kullanıldığında ise %1.09 oranında getiri elde edebilmek mümkün olmuştur. AÖM yöntemi ile eğitimin SP500 Endeksi için de çok kısa sürede tamamlandığı görülmektedir.


Tablo 8. SP500 Endeks için Performans Göstergeleri

	OKY	OMHY (%)	İsabet Oranı (%)	Getiri Oranı (%)	İşlem Zamanı (Saniye)
Sigmoid Fonksiyon	0.0003	1.4479	47.46	-5.52	0.0054
Sinüs Fonksiyonu	0.0022	4.1653	45.76	-3.66	0.0049
Kosinüs fonksiyonu	0.0005	1.8724	44.07	-4.13	0.0049
Kesin Sınırlayıcı (Hard Limit)	0.0156	10.7562	35.59	-6.53	0.0041
Üçgensel Bazlı	0.0189	13.3353	50.85	-0.27	0.0040
Radyal Bazlı	0.0062	6.9187	49.15	-4.09	0.0043
Normalleştirilmiş Radyal Bazlı	0.0014	3.1017	49.15	-5.11	0.0052
Elliot Sigmoid	0.0016	3.4324	42.37	-4.61	0.0034
Log-sigmoid	0.0002	1.2015	37.29	-8.53	0.0050
Saf Doğrusal	0.0001	0.6342	47.46	-3.14	0.0039
Soft Max	0.0003	1.3835	38.98	-7.52	0.0052
Ters (Inverse)	0.1140	33.437	47.46	-0.64	0.0039
Doğgun (Saturated) Doğrusal	0.0222	13.6043	47.46	1.09	0.0039
Pozitif doğrusal	0.0003	1.2874	42.37	-4.17	0.0039
Yapay Sinir Ağları	0.0221	12.7699	52.54	-0.05	0.0580
Pasif Strateji : -%3.75					


Şekil 2 ve 5 arasındaki şekillerde test sürecinde gerçekleştirilen fiyat tahminleri ile gerçek fiyatlar grafikler halinde gösterilmiştir. Her bir zaman serisi için bütün modellere ait grafiklerin çizilmesi çalışmanın hacmini gereğinden fazla yükseltecektir. Bu nedenle her bir zaman serisi için sadece bir adet serinin grafiği çizilmiştir. Goodyear hisse senedi için yapay sinir ağları en yüksek isabet oranı ile tahmin gerçekleştirilmiştir. Bu nedenle bu senet için yapay sinir ağları modeli ile gerçekleştirilen tahminlerin grafiği çizilmiştir. Amazon hisse senedi için en yüksek getiri oranına sahip model olan log-sigmoid AÖM modelinin grafiği çizilmiştir. Wal-Mart hisse senedi için en yüksek getiriye sahip olan ters (inverse) aktivasyon fonksiyonu AÖM modelinin grafiği çizilmiştir. SP500 Endeksi için ise en yüksek istatistiksel performansa sahip saf doğrusal modelin grafiği çizilmiştir.

Şekiller iki bölümden oluşmaktadır. Şekillerin yukarısında yer alan bölümde gerçek fiyat ile tahmin edilen fiyat grafik üzerinde gösterilmektedir. Şekillerin alt tarafında ise gerçek fiyat ile tahmin edilen fiyat arasındaki farkı içeren hata dağılımı görülmektedir. Şekillerde görsel açıdan da modellerin gerçek fiyatlara yakın tahmin değerleri üretebildiği görülmektedir.


Şekil 2. Goodyear Senedi için Yapay Sinir Ağları Tahmin Edilen ve Gerçek Fiyatlar



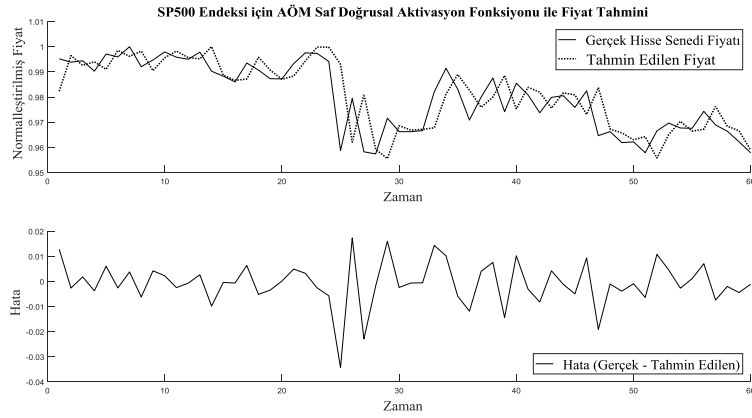
Şekil 3. Amazon Senedi için Log-Sigmoid-AÖM Yöntemi ile Tahmin Edilen ve Gerçek Fiyatlar



Şekil 4. Wal-Mart Senedi için Ters Aktivasyon Fonksiyonu (Inverse) - AÖM Yöntemi ile Tahmin Edilen ve Gerçek Fiyatlar



Şekil 5. SP500 Endeksi için Saf Doğrusal - AÖM Yöntemi ile Tahmin Edilen ve Gerçek Fiyatlar



SONUÇ VE ÖNERİLER

Hisse senedi piyasası, yatırımcıların fazla fonlarını değerlendirdikleri önemli yatırım alanlarından biridir. Borsada işlem yapan yatırımcıların en önemli amacı, sahip oldukları atıl fonlarını yüksek getiri sağlayacak senetlere yatırmaktır. Borsalarda yanlış yatırım kararlarının alınması, ekonomik kaynakların boşa gitmesine neden olmaktadır. Bu nedenle borsada işlem gören hisse senetlerinin fiyatlarının doğru bir şekilde tahmin edilmesi önem arz etmektedir.

Çalışmada hisse senedi fiyat tahmini için literatürde yeni kullanılmaya başlanan Aşırı Öğrenme Makineleri yöntemi seçilmiştir. Bu yöntem Yapay Sinir Ağları tabanlı bir yöntemdir ve yapar sinir ağlarının bazı dezavantajlarını ortadan kaldırmak için tasarlanmıştır. Bu çalışmanın literatüre yaptığı en önemli katkı on dört adet farklı aktivasyon fonksiyonunun hisse senedi tahminindeki performansını bir arada karşılaştırmaktır.

Çalışmada erişilen sonuçları şu şekilde özetlemek mümkündür. İstatistiksel performans göstergeleri göz önünde bulundurulduğunda saf doğrusal aktivasyon fonksiyonuna sahip AÖM modeli incelenen finansal zaman serilerinin hepsinde en iyi tahmin performansını sergilemiştir. İsbet oranı için ise belirgin bir desen bulunamamıştır. Buna rağmen üç adet hisse senedinde AÖM yöntemi YSA yönteminden daha yüksek isabet oranları sergilerken, Endeks’de ise YSA modelinin daha iyi isabet oranı performansı sergilediği belirlenmiştir. Çalışmada, %59.32 ‘ye varan oranında hisse senedi fiyatındaki yön doğru bir şekilde önceden tahmin edilebilmiştir.

Çalışmada aynı zamanda tahmin modellerinin finansal performansı da incelenmiştir. Sonuçta farklı aktivasyonlara sahip AÖM modeli hem piyasanın hem de yapay sinir ağlarının getiri oranından daha yüksek getiri oranı sağlamıştır. Al ve tut stratejisinin, yatırımcısını zarara uğrattığı durumlarda bile (piyasanın gerilediği durumlar), AÖM ile eğitilen modellere göre hareket eden yatırımcı pozitif getiri sağlayabilmektedir. Bununla birlikte, hesaplamaları kolaylaştırmak adına, komisyon ve vergilerin dikkate alınmadığını ifade etmek gerekmektedir.

Literatürde Li *vd.* (2016) temel AÖM modeli ile en yüksek %52.2 oranında bir tahmin performansına ulaştıklarını raporlamaktadırlar. Bu çalışmada elde edilen sonuçlar ile bir arada düşünüldüğünde, AÖM yönteminin hisse senedi fiyat tahmininde kullanılabilir güçlü bir alternatif olduğunu söylemek mümkün hale gelmektedir. Bu yöntemin sergilediği başarı oranı, optimizasyon yöntemlerinin kullanılması ile birlikte daha da artabilir.

Çalışmanın bazı kısıtları mevcuttur. İlk olarak 12 adet girdi değişkeni literatür taraması sonucu belirlenmiştir. Ancak, finans literatüründe teknik gösterge sayısı oldukça fazladır. Başka girdilerin kullanılmasının tahmin performansı üzerindeki etkisi sonraki çalışmalarda irdelenebilir. Çalışmada basit bir getiri oranı hesaplama yöntemi kullanılmıştır. Daha karmaşık ve riske karşı koruma sağlayacak alım satım algoritmalarının kullanılması tahmin modelinin finansal performansını etkileyebilir.

KAYNAKÇA

- Adebiyi, A.A., A.O. Adewumi, C.K. Ayo (2014), “Comparison of ARIMA and Artificial Neural Network Models for Stock Price Forecasting”, *Journal of Applied Mathematics*, 7.
- Adhikari, R., R.K. Agrawal, L. Kant (2013), “PSO Based neural Networks vs Traditional Statistical Models for Seasonal Time Series Forecasting, IEEE International Advanced Computing Conference (IACC) 2013.
- Armano, G., M. Marchesi, A. Murru (2005), “A Hybridgenetic-Neural Architecture for Stock Indexes Forecasting”, *Information Sciences*, 170, 3-33.
- Asadi, S., E. Hadavandi, F. Mehmanpazir, M.M. Nakhostin (2012), “Hybridization of Evolutionary LevenbergMarquardt Neural Networks and data Pre-Processing for Stock Market Prediction”, *Knowledge-Based Systems*, 35, 245-258.
- Atsalakis, G.S., K.P. Valavanis (2009), “Forecasting Stock Market Short-Term Trends using a Neuro-Fuzzy Based Methodology”, *Expert Systems with Applications*, 36, 10696-10707.
- Atsalakis, G., K.P. Valavanis (2010), “Surveying Stock Market Forecasting Techniques – Part – I: Conventional Methods”, in Zopounidis (ed.) *Computation Optimization in Economics and Finance Research Compendium*, Nova Science Publishers, 49-104.
- Atsalakis, G., E.E. Protopapadakis, K.P. Valavanis (2016), “Stock Trend Forecasting in Turbulent Market Periods using Neuro-Fuzzy Systems”, *Operational Research*, 16, 245-269.
- Chang, J.R., L.Y. Wei, C.H. Cheng (2011), “A hybrid ANFIS Model Based on AR and Volatility for TAIEX Forecasting”, *Applied Soft Computing*, 11, 1388-1395.
- Chen, Q., C. Li (2006), “Comparison of Forecasting Performance of AR, STAR and ANN Models on the Chinese Stock Market Index”, *Advances in Neural Networks – ISNN 2006*.
- Dash, R., P.K. Dash, R. Bisoi (2014), “A self Adaptive Differential Harmony Search Based Optimized Extreme Learning Machine for Financial time Series Prediction”, *Swarm and Evolutionary Computation*, 19, 25-42.
- Fausett, L. (1994), *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*, Englewood Cliffs: Prentice-Hall.
- Haykin, S. (2005), *Neural Networks – A Comprehensive Foundation*, India: Pearson Education.
- Huang, G.B., Q.Y. Zhu, C.K. Sieq (2006), “Extreme Learning Machine: Theory and Applications”, *Neurocomputing*, 70, 489-501.
- Huang, C.J., D.X. Yang, Y.T. Chuang (2008), “Application of Wrapper Approach and Composite Classifier to the Stock Trend Prediction”, *Expert Systems with Applications*, 34, 2870-2878.
- Huang, G.B., D.H. Wang, Y. Lan (2011), “Extreme Learning Machines: a Survey”, *International Journal of Machine Learning and Cybernetics*, 2, 107-122.
- Huang, G., G.B. Huang, S. Song, K. You (2015), “Trends in Extreme Learning Machines: A Review”, *Neural Networks*, 61, 32-48.
- Huang, W., Y. Nakamori, S.Y. Wang (2005), “Forecasting Stock Market Movement Direction with Support Vector Machine”, *Computers & Operations Research*, 32, 2513-2522.

- Ince, H., T.B. Trafalis (2007), “Kernel Principal Component Analysis and Support Vector Machines for Stock Price Prediction”, *IIE Transactions*, 39, 629-637.
- Isenah, G.M., O.E. Olubusove (2014), “Forecasting Nigerian Stock Market Returns Using ARIMA and Artificial Neural Networks”, *CBN Journal of Applied Statistics*, 5(2), 25-48.
- Kanas, A., A. Yannopoulos (2001), “Comparing Linear and Nonlinear Forecasts for Stock Returns”, *International Review of Economics and Finance*, 10(4), 383-398.
- Kara, Y., M.A. Boyacıoğlu, Ö.K. Baykan (2011), “Predicting Direction of Stock Price Index Movement Using Artificial Neural Networks and Support Vector Machines: The Sample of the Istanbul Stock Exchange”, *Expert Systems with Applications*, 38, 5311-5319.
- Li, X., H. Xie, R. Wang, Y. Cai, J. Cao, F. Wang, H. Min, X. Deng (2016), “Empirical Analysis: Stock Market Prediction via Extreme Learning Machine”, *Neural Computing & Applications*, 27, 67-78.
- Mahmud, M.S., P. Meesad (2015), “An Innovative Recurrent Error-Based Neuro-Fuzzy System with Momentum for Stock Price Prediction”, *Soft Computing*, 20(10), 4173-4191.
- MSCI (2016). <https://www.msci.com/gics>, E.T. :10.11.2016.
- Özçalıcı, M. (2016), “Hisse Senetlerinin Doğru Tahmin Oranları ile Kümelenirilmesi”, *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 38(1), 279-293.
- Palit, A.K., D. Popovic (2005), *Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications*, London: Springer-Verlag.
- Smith, K.A., J.N.D. Gupta (2000), “Neural Networks in Business: Techniques and Applications for the Operations Researcher”, *Computers & Operation Research*, 27, 1023-1044.
- Sumathi, S., P. Surekha (2010), *Computational Intelligence Paradigms: Theory and Applications using MATLAB*. Taylor and Francis Group, LLC. [NN_02]
- Sun, Z.L., T.M. Choi, K.F. Au, Y. Yu (2008), “Sales Forecasting Using Extreme Learning Machine with Applications in Fashion Retailing”, *Decision Support Systems*, 46(1), 411-419.
- Wang, J.Z., J.J. Wang, Z.G. Zhang, S.P. Guo (2011). “Forecasting Stock Indices with back Propagation Neural Network”, *Expert Systems with Applications*, 38, 14346-14355.
- Wong, W.K., Z.X. Guo (2010), “A Hybridintelligent Model for Medium-Term Sales Forecasting in Fashion Retail Supply Chains Using Extreme Learning Machine and Harmony Search Algorithm”, *International Journal of Production Economics*, 128, 614-624.
- Xia, M., Y. Zhang, L. Weng, X. Ye (2012), “Fashion Retailing Forecasting Based on Extreme Learning Machine with Adaptive Metrics of Inputs”, *Knowledge-Based Systems*, 36, 253-259.
- Xia, C., Z.Y. Dong, K. Meng, Y. Xu, K.P. Wong, H.W. Ngan (2012), “Electricity Price Forecasting with Extreme Learning Machine and Bootstrapping”, *IEEE Transactions on Power Systems*, 27(4), 1-8.
- Yan, Q., S. Wang, B. Li B. (2014), “Forecasting Uranium Resource Price Prediction by Extreme Learning Machine with Empirical Mode Decomposition and Phase Space Reconstruction”, *Discrete Dynamics in Nature and Society*, 2014, 1-10.