



HİSSE SENEDİ FİYATLARININ VAR MODELİ VE YAPAY SİNİR AĞLARI ALGORİTMASI İLE TAHMİNİ: BIST100 PAY SENETLERİYLE BİR UYGULAMA

SALİH ÇAM^{1*}

¹ Dr., Çukurova Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, scam@cu.edu.tr, <https://orcid.org/0000-0002-3521-5728>.

ÖZ

Hisse senetleri gibi oynaklığı yüksek varlıklarla ilgili gelecek tahmini yapmak oldukça zordur. Geleneksel ekonometrik modeller finansal araçların tahmininde bir noktaya kadar başarılı sonuç verse de yapay zekâ tabanlı doğrusal olmayan yöntemler çoğu zaman daha etkin tahmin performansı göstermektedir. Bu çalışmada fiyat tahmini yapmak amacıyla VAR modelleri ve Yapay Sinir Ağları algoritması birlikte kullanılmıştır. Birleşik tahmin sürecinin tercih edilmesindeki amaç hisse senetlerinin taşıdığı doğrusal bilginin VAR modelleriyle, doğrusal olmayan bilginin ise Yapay Sinir Ağları algoritmasıyla modellenmesidir. Sonuçlar birleşik model ile elde edilen tahminlerin ekonometrik modellerin tahmininden daha üstün olduğunu göstermektedir. Model hata kareleri toplamına göre AKBNK, ALBRK, BUCIM, DOHOL, GSDHO, TSKB, SKBNK ve SNGYO hisse senetleri hariç diğer tüm pay senetlerinde VAR-YSA tahmin modeli daha iyi fiyat tahmini yapmıştır.

Anahtar Kelimeler: Hisse Senedi Fiyatları, Yapay Sinir Ağları Algoritması, Gecikmesi Dağıtılmış, Otoregresif Modeller

Editör / Editor:

Ayşe CİNGÖZ,
Erciyes Üniversitesi, Türkiye

*Sorumlu Yazar/ Corresponding Author:

Salih ÇAM,
scam@cu.edu.tr

STOCK PRICE FORECASTING USING VAR MODEL AND ARTIFICIAL NEURAL NETWORK ALGORITHM: AN APPLICATION WITH BIST100 STOCKS

ABSTRACT

Predicting the future price of highly volatile assets such as shares is difficult. Although traditional econometric models have some success in predicting financial assets, nonlinear methods based on artificial intelligence often provide better predictive performance. In this study, VAR models and artificial neural network algorithms are used together for the prediction of prices series. The main purpose of employing a hybrid method is to model the linear part in the stock price series with VAR models and the nonlinear part with the artificial neural network algorithm. The results show that the forecasts with the hybrid method are superior to the forecasts with the econometric models. According to the sum of squared errors, the forecasts of the hybrid model are superior to the linear econometric model for all stocks in the investment space except for AKBNK, ALBRK, BUCIM, DOHOL, GSDHO, TSKB, SKBNK and SNGYO.

JEL:

C01, C45, G12.

Geliş: 19 Eylül 2023

Received: September 19, 2023

Kabul: 1 Ağustos 2024

Accepted: August 1, 2024

Yayın: 30 Aralık 2024

Published: December 30, 2024

Atıf / Cited as (APA):

Çam, S. (2024),
Hisse Senedi Fiyatlarının VAR Modeli ve
Yapay Sinir Ağları Algoritması ile Tahmini:
BIST100 Pay Senetleriyle Bir Uygulama, Erciyes
Üniversitesi İktisadi ve İdari Bilimler Fakültesi
Dergisi, 69, 27-35,
doi: 10.18070/erciyesiibd.1362732

Keywords: Stock Prices, Artificial Neural Networks, Distributed Lag Models

I. GİRİŞ

Finansal piyasalar yüksek getiri olanağı sağlamakla beraber yüksek risk içermektedir (Bhowmik ve Wang, 2020; Chen, Lu ve Wang, 2022). Bir yatırımcı için temel amaç finansal bir piyasada yatırım yaparken getirisini maksimum yaparken yatırım riskini minimum yapmaktır. Fakat finansal bir piyasada yatırım doğal olarak yatırımcıya bir miktar risk yüklemektedir. Yatırımcının getiri beklentisi ne kadar yüksek ise yatırım riski de kadar yüksek olacaktır. Bu anlamda yatırımcı için risk ve getiri arasındaki denge önemlidir. Markowitz (1952)'in ilk defa ortaya koyduğu ortalama varyans modeli finans teorisinde bir mihenk taşıdır. Ortalama varyans modeli risk ile getiri arasındaki ilişkiyi matematiksel bir formda ifade ederek yatırımcının belli bir risk düzeyindeki portföyler arasında seçim yapmasını sağlamıştır (Elton ve Gruber, 1997; Cohen ve Natoli, 2003). Yatırım riskini minimum yapmak veya getiriyi maksimum düzeye çıkarmak önemli olsa da yatırımcı açısından portföyünde yer alacak varlıkların gelecek fiyat tahminleri de önemlidir. Bu bağlamda, varlık fiyatlarını etkileyen faktörleri anlamak ve fiyat hareketlerini tahmin etmek, yatırımcıların karar alma sürecini şekillendiren temel unsurlardan biri haline gelmektedir. Dolayısıyla, bir varlığın fiyatının ne olması gerektiği, yatırım süreci içerisinde hangi yöne hareket edeceği yatırım risk/getiri dengesine ek olarak değerlendirilmesi gereken bir husus olarak ön plana çıkmaktadır. Varlık fiyatlama modelleri bu bilgileri sağlama çabalarına yönelik ortaya atılmıştır ve bu modeller yatırım stratejileri geliştirmek noktasında önemli bir role sahiptir. Varlık fiyatlama modelinden hareketle yatırımcı bir finansal varlığın yatırım dönemi boyunca fiyatının yükseleceğini öngörüyorsa yatırım kararı alacaktır. Aksi halde söz konusu varlığa yatırım yapmaktan vazgeçecektir. İşte bu noktada bir finansal varlığın fiyatıyla ilgili başarılı bir "öngörü" yapmak yatırım kararında önemli bir yere sahiptir.

Finansal bir varlığın fiyatıyla ilgili iki farklı değerlendirme yapılabilir. İlki varlığın fiyatının ne olması gerektiğidir. İkincisi belli bir süre sonunda ilgili varlığın fiyatının ne olacağıdır. Bu anlamda bir varlığın değerinin ne olması gerektiği ile gelecek bir tarihte bu varlığın fiyatının ne olacağı birbirinden farklı olgulardır. Finans alanındaki çalışmalarda sıkça kullanılan varlık fiyatlama modelleri bir varlığın mevcut fiyatını açıklama amacı taşıyan teorik çerçevelerdir. Bunlar arasında Sharpe (1964)'ın önerdiği Finansal Varlık Fiyatlama Modeli (CAPM) ve Fama-French (1993) Faktör modelleri bir varlığın gerçek değerinin belirlenmesi amacıyla sıkça başvurulan modellerdir. Bu modeller getiri tahmini ve risk yönetimi gibi konularda geniş bir kullanım alanına sahiptir (Fama ve French 2004; Ferold, 2004; Basu ve Chawla, 2010; Bajpai ve Sharma, 2015; Ogiugo, Adesuyi vd., 2020; Sattar 2017; Chiah, Chai vd., 2016). Söz konusu modellerden CAPM, bir varlığın fiyatını belirleyen temel faktör olarak bu varlığın piyasayla olan ilişkisini kullanmaktadır. Model, yatırımcıların risk ve getiri arasındaki dengeyi değerlendirmelerine yardımcı olurken, finansal varlıkların fiyatlanmasına yönelik üç ana bileşen içermektedir: risksiz faiz oranı, piyasa risk primi ve beta katsayısı. Fakat CAPM karmaşık yapıya sahip bir varlığın fiyatını tahmin etmekte yetersiz kalabilmektedir (Bornholt, 2012). Finansal piyasalara daha uygun olduğu düşüncesi ile Eugene Fama ve Kenneth French (1993) CAPM'in göz ardı ettiği ama bir varlığın fiyat hareketleri üzerinde etkili olan bazı faktörler içeren modeller önermişlerdir. Üç faktör modeli ve beş faktör modeli bunlar arasında en çok kullanılanlarıdır (Faff, 2001; Eraslan, 2013; Al-Mwalla ve Karasneh, 2011; Li ve Duan, 2021; Abd-Alla ve Sobh, 2020; Cox ve Britten, 2019; Mosoeu ve Kodongo, 2022).

Fama-French (1993)'in Üç Faktör Modeli, Beş Faktör Modeli ve diğer varlık fiyatlama modelleri bir varlığın fiyatlanması konusunda önemli bilgiler sağlasa da karmaşık yapıdaki finansal yatırım araçlarının gelecek tahminini yapmak konusunda çoğu zaman yetersiz kalmaktadır (Blitz, 2020). Bu modellerin fiyat tahmininde yetersiz kalmalarının en önemli nedeni finansal varlıklarla ilgili sadece doğrusal ilişkileri ortaya koyabilme yeteneğine sahip olmalarıdır. Fakat biliyoruz ki bir finansal varlık hem doğrusal hem de doğrusal olmayan bilgiler taşımaktadır. Faktör modelleri de dâhil olmak üzere varlık fiyatlama modelleri regresyon temelli olduğu için doğrusal olmayan ilişkilerin tahmininde çok etkin sonuçlar üretmez. Bu noktada son dönemde birçok alanda kullanılan Yapay Sinir Ağları algoritması (YSA) gibi Yapay Zekâ temelli

uygulamalar doğrusal olmayan ilişkilerin tahmininde daha başarılı sonuçlar üretme potansiyeline sahiptir (Ünlü vd., 2009; Özçalıcı, 2016; Dayı, 2018; Çınaroğlu ve Avcı, 2020; Kurani, Doshi vd., 2023; Şahin, 2023; Vijh, Chandola vd., 2023). Burada önemli olan hem finansal varlıkların taşıdığı hem doğrusal hem de doğrusal olmayan bilgileri modellemektir. Dolayısıyla, finansal verilerdeki doğrusal ve doğrusal olmayan bilgileri daha iyi tahmin etmesi amacıyla doğrusal modeller ile doğrusal olmayan modellerin bir arada kullanılması tahmin sürecinde çok daha etkin bulguların elde edilmesini sağlamaktadır (Wang vd., 2013; Babu ve Reddy 2014; Abounoori ve Tazehabadi, 2009).

Hisse senetleri ve diğer finansal varlıklar sadece içinde bulunulan dönemden etkilenmemektedir. Bilindiği gibi bir hisse senedi hem piyasadan hem de şirketin kendisinden kaynaklı bazı riskler taşımaktadır ve birçok faktörden aynı anda etkilenmektedir. Söz konusu etkiler çoğu zaman bir veya birkaç dönem sonra ortaya çıkmaktadır (Dawar, Dutta vd., 2021; Waheed, Wei vd., 2018). Örneğin şirketin açıkladığı bir yatırım kararı hisse senedi fiyatına belki de birkaç dönem sonra yansımaktadır. Ayrıca yatırımcı beklentileri de genellikle gecikmeli olarak fiyatlar yansımaktadır. Finansal kriz beklentisi veya bozulan ekonomik göstergeler finansal piyasalara genellikle gecikmeli olarak geçmektedir. Bu gecikme bazı piyasalarda yavaş iken doğal olarak bazı piyasalarda çok daha hızlıdır. Finansal piyasalarda bir şok veya beklentinin fiyatlanması görece daha hızlıdır. Çünkü bu tür piyasalar düşük giriş ve çıkış sınırlıklarına sahiptir. Bu nedenle finansal piyasalar likidite oranı yüksek etkin piyasalar olarak tanımlanmaktadır. Sonuç olarak etkin piyasalarda fiyatlar halka açık tüm bilgileri fiyatlamasına rağmen bazı durumlarda bilginin fiyatlanması gecikmeli olarak gerçekleşmektedir. Bu da piyasayı yenmek veya fiyat tahmini yapmak noktasında öngörü yapmanın önünü açmaktadır. Tüm bilgi ve beklentiler aynı anda fiyatlandıysa ve piyasa tam etkin çalışsaydı bu tür piyasalarda ortalamanın üzerinde kar elde etmek neredeyse imkânsız olurdu (Zeren, Kara vd., 2013; Koyuncu ve Aslan, 2017). Buradan hareketle, bu çalışmada YSA ve beş faktör modeli birlikte kullanılarak Borsa İstanbul'da işlem gören hisse senedi fiyatları tahmin edilmektedir. Faktörlerin gecikmeli etkilerini tespit edebilmek amacıyla VAR analizi kullanılmıştır. VAR analizi ve AIC bilgi kriteri yardımıyla belirlenen gecikme sayıları daha sonra hem klasik ekonometrik tahmin sürecinde hem de YSA algoritması tahmin sürecinde kullanılmıştır. Sonuçta hibrit tahmin sürecinden elde edilen bulgular ile ardışık bağımlı ve gecikmesi dağıtılmış model bulguları karşılaştırılmıştır.

II. LİTERATÜR

Yatırım kararı öncesi bir varlığın fiyat tahminini yapmak oldukça önemlidir. Yatırımcı yatırım yapmayı düşündüğü varlıkla ilgili ne kadar iyi tahmin yaparsa yatırımdan kaynaklı riskini de o derece düşürecektir (Chen, Chen ve Wu, 2014). Bu anlamda finans literatüründe özellikle hisse senetlerinin fiyat veya getiri tahmini araştırmacıların sıklıkla üzerinde durduğu bir konudur (Karathanassis ve Philippos, 1988; Nargeleckenler, 2011; İlerslan, 2014; Khare vd., 2017; Özçalıcı, 2017; Lu vd., 2021; Arslankaya ve Toprak, 2021; Çoban ve Hayat, 2023). İçerdikleri yüksek risk ve birçok faktörden aynı anda etkilenmelerinden dolayı finansal varlıkların geleceğe yönelik fiyat tahminlerini yapmak oldukça zordur. Dolayısıyla araştırmacılar hisse senedi gibi riskli varlıkları tahmin etmek için birçok yöntem kullanmıştır. Bunlar arasında panel veri analizi veya geleneksel ekonometrik yöntemleri tek başına kullanan çalışmalar mevcuttur (Karaca ve Başçı, 2011; Güngör ve Kaygın, 2015; Akıncı ve Küçükçaylı, 2016; Şenol, Koç ve Şenol, 2018; Öndeş ve Levent, 2020; Baskan ve Uslu, 2020). Bunun yanında hisse senetlerinin kendi geçmiş değerlerinden etkilenmesine izin veren vektör otoregresif modeller de hisse senedi fiyat tahmin ve analizinde kullanılmıştır (Brandt ve Kang, 2004; Gupta ve Modise, 2013; Toparlı, Çatık ve Balcılar, 2019). Panel veri analizi ve VAR gibi geleneksel ekonometrik modeller değişkenler arasındaki doğrusal ilişkiyi yakalamak konusunda yatırımcıya önemli bilgiler sağlasa da hisse senedi gibi doğasında hem doğrusal hem de doğrusal olmayan ilişki barındıran serilerin tahmininde performansları düşmektedir. Bu noktada doğrusal olmayan modellerin yanı sıra, özellikle kişisel bilgisayarların yaygınlaşmasıyla birlikte yapay sinir ağları, genetik algoritma gibi makine öğrenmesine dayalı tekniklerinin de varlık fiyatlarının tahmininde kullanılması gittikçe yaygınlaşmıştır

(Qiu, Song ve Akagi, 2016; Loo 2020; D'Ecclesia ve Clementi, 2021; İlkçar, 2023; Özyayın, 2024). Makine öğrenmesini kullanan yapay sinir ağları algoritmaları değişkenler arasındaki doğrusal olmayan bilgiyi yakalarken ilişkide saklı doğrusal bilgiyi göz ardı edebilmektedir ve dolayısıyla tahmin performansları düşmektedir. Makine öğrenmesine ilişkin bu sorun sadece modellerin kendilerinden kaynaklanmaz. Çoğu zaman araştırmacıların yanlış model optimizasyonu, önemli parametrelerde yanlış fonksiyon kalıplarını seçmesi ve yanlış başlangıç noktası ile modellerin eğitilmesi yapay zeka modellerinin etkinliğini düşürmeye neden olmaktadır. Zira geleneksel ekonometrik modellerin aksine yapay sinir ağları gibi makine öğrenmesi kullanan modellerin standart bir tahmin prosedürü yoktur (Çam ve Kılıç, 2018). Makine öğrenmesini kullanan modellerin bu dezavantajını ortadan kaldırmak için araştırmacılar sıklıkla hibrit modeller kullanmıştır. Böylelikle bir finansal varlığın gelecek tahminini yaparken hem geleneksel modellerin güçlü yönlerinden hem de yapay öğrenme tekniklerinin güçlü yönlerinden faydalanmışlardır. Sonuç olarak finansal varlıkların fiyat veya getirilerini konu alan ve hibrit modeller kullanan önemli bir çalışmalar bütünü ortaya çıkmıştır (Donaldson ve Kamstra, 1997; Kara, Boyacıoğlu ve Baykan, 2011; Shaik, ve Sejpal, 2020; Mayatopani, 2021; Şahin, 2023; Özyayın, 2024).

III. YÖNTEM VE VERİ SETİ

Bu çalışmada Fama-French (2015) beş faktör modeli (FF5F), ardışık bağımlı ve gecikmesi dağıtılmış model ve yapay sinir ağları algoritması (YSA) kullanılmıştır. FF5F modelindeki faktörler ardışık bağımlı ve gecikmesi dağıtılmış modelde ve YSA algoritmasında açıklayıcı değişkenler olarak yer almıştır. Analizde Şubat 2010 ile Temmuz 2023 dönemini kapsayan aylık veriler kullanılmıştır. BIST100 endeksinde işlem gören hisse senetleri zaman içinde farklılık gösterdiği için analiz dönemi boyunca listede yer alan ve eksik verisi bulunmayan pay senetleri kullanılmıştır. Analizde kullanılan veriler Datastream veri tabanından elde edilmiştir.²

A. FAMA-FRENCH BEŞ FAKTÖR MODELİ

Fama-French (2015) beş faktör modeli, Fama-French (1993) üç faktör modeline iki yeni faktörün eklenmesiyle oluşturulmuştur. Bu modelde bir portföyün artık getirisi piyasa faktörü, firma büyüklüğü, değer, karlılık ve yatırım faktörleri tarafından açıklanmaktadır. FF5F modeli aşağıdaki şekilde ifade edilebilir.¹

$$R_i - RF_i = \alpha + \delta_1 [RM_i - RF_i] + \delta_2 SMB_i + \delta_3 HML_i + \delta_4 RMW_i + \delta_5 CMA_i + \varepsilon_i \quad (1)$$


Burada α ve δ_i , $i=(1,2,3,4,5)$ faktör yüklem katsayısı olarak da ifade edilen regresyon tahmininden elde edilen katsayılar, ε_i modelin hata terimidir. R_i hisse senedinde ait t dönemdeki getiri, RF_t t dönemindeki risksiz faiz oranıdır. RM_t t dönemindeki piyasa getirisiyken SMB_t küçük hisse senetlerinden oluşan çeşitlendirilmiş portföylerin getirileri ile büyük hisse senetlerinden oluşan çeşitlendirilmiş portföylerin getirileri arasındaki farktır. Ek olarak HML_t yüksek DD/PD (defter değeri/piyasa değeri) hisse senetlerinden oluşan çeşitlendirilmiş portföylerin getirileri ile düşük DD/PD hisse senetlerinden oluşan çeşitlendirilmiş portföylerin getirileri arasındaki fark, RMW_t yüksek karlılığa sahip hisse senetlerinden oluşan çeşitlendirilmiş portföylerin getirileri ile düşük karlılığa sahip hisse senetlerinden oluşan çeşitlendirilmiş portföylerin getirileri arasındaki farktır. Son olarak CMA_t muhafazakar ve agresif olarak adlandırılan düşük yatırımlı hisselerinden oluşan çeşitlendirilmiş portföylerin getirileri ile yüksek yatırımlı hisselerinden oluşan çeşitlendirilmiş portföylerin getirileri arasındaki farkı ifade etmektedir.

YAPAY SİNİR AĞLARI ALGORİTMASI

Yapay sinir ağları (YSA) algoritması insan beynindeki sinir hücrelerini taklit eden, örneklem üzerinden öğrenme gerçekleştiren ve doğrusal olmayan modellerdir (Erdoğan ve Özyürek, 2012; Yaku, Yakut ve Yavuz,

2014; Yüksel ve Akkoç 2016; Çam, Ballı vd., 2017; Aksoy, 2021). Bir YSA algoritması ağa verilen bir örnek veri seti yardımıyla eğitilir ve eğitimden öğrendiği bilgileri ağ sisteminin içinde saklar (Agatonovic-Kustrin ve Beresford, 2000). Bu özelliği, bir YSA algoritmasının daha önce hiç görmediği bir problem hakkında genelleme yapmasını sağlar. YSA modelleri genel olarak açıklayıcı değişkenlerin verilerinin yer aldığı bir girdi katmanı, toplam ve aktivasyon fonksiyonlarının yer aldığı bir gizli katman ve öğrenilmesi istenen bağımlı değişkene ait verilerin yer aldığı çıktı katmanından oluşur. Katman sayısı ve her katmanda yer alan nöron sayıları problemin karmaşıklığı ve eğitilen ağın performansına bağlı olarak değişebilir. Katmanlar arasında kullanılan aktivasyon ve toplam fonksiyonları yine problemin yapısına göre değişiklik gösterebilir. Diğer bütün sezgisel modellerde olduğu gibi bir YSA modelinde doğru ağ ve fonksiyon yapısını belirlemek için kullanılacak bir yol haritası yoktur. Bu modellerin yapısı problemden probleme değişiklik gösterebilir. Dolayısıyla en doğru ağ yapısını oluşturmak araştırmacının bilgi ve deneyimine bağlıdır. Bu tüm sezgisel yöntemler gibi YSA algoritmalarının zayıf yönüdür. Bir yapay sinir ağı eksik verilerde, durağan olmayan verilerde ve uç değerlere sahip verilerde dahi başarı ile tahmin yapabilmektedir. Bir yapay sinir ağının yapısını aşağıdaki şekilde ifade etmek mümkündür.

ŞEKİL 1 | YSA Algoritması Yapısı



Kaynak: Fırat ve Güngör, 2004

Burada x_i , $i=(1,2,\dots,n)$ girdi değişkenleri, y ise çıktı değişkenidir. Bir YSA modelinde birden fazla çıktı değişkeni olabilir. Herhangi bir çıktı değişkenine sahip YSA modelleri öğretmenli öğrenme gerçekleştirirken, bir çıktı verisi olmayan ağlar öğretmensiz öğrenme gerçekleştirir (Zupan, 1994). YSA modellerini matematiksel yapısı aşağıdaki şekilde temsil edilebilir.

$$\hat{Y}_i = F_2 \left[\left(V_i \cdot F_1 \left(W_i \cdot X_i \right) \right) \right] \quad (2)$$

Yukarıdaki modelde $X_i = [x_1, x_2, \dots, x_n]$ girdi değişkenlerini içeren girdi matrisi, Y_i bir veya daha fazla çıktı değişkenini içeren çıktı matrisi, F_1 girdi katmanı ile gizli katman arasındaki toplam fonksiyonu, F_2 ise gizli katman ile çıktı katmanı arasındaki aktivasyon fonksiyonudur. V_i gizli katmandaki bilgiyi çıktı katmanına aktaran ağırlıkları, W_i ise giriş katmanındaki bilgileri gizli katmana aktaran ağırlıklardır (Yu, Wang vd., 2007:29). Bir YSA'nın eğitilmesi, gerçek çıktı değerleri ile tahmini çıktı değerleri arasındaki hata payını minimum yapan V_i ve W_i ağırlıklarının hesaplanmasını ifade etmektedir.

C. ARDIŞIK BAĞLANIMLI VE GECİKMESİ DAĞITILMIŞ MODEL

Statik ekonometrik modeller bir bağımlı değişken ile bir veya birden çok açıklayıcı değişken arasındaki ilişkiyi tahmin etmek için kullanılmaktadır. Fakat bazı durumlarda açıklayıcı değişkenlerin bağımlı değişken üzerindeki etkisi gecikmeli olarak ortaya çıkar (Nerlove, 1958; Griliches, 1967). Bu durumda gecikmesi dağıtılmış modeller kullanmak daha etkin sonuçlar üretir. Bazı durumlarda ise bağımlı değişken hem kendisinin hem de açıklayıcı değişkenlerin gecikmeli değerlerinden etkilenir. Bu durumda ise değişkenler arasındaki ilişkileri tahmin etmek için gecikmesi dağıtılmış otoregresif modeller kullanılmalıdır. Gecikmesi dağıtılmış otoregresif bir model şu şekilde ifade edilir;

$$Y_t = \alpha + \delta_i \sum_{i=1}^k Y_{t-i} + \gamma_j \sum_{j=1}^l X_{t-j} + \varepsilon_t \quad (3)$$

¹Şubat 2010 ve Temmuz 2023 tarihleri arasında verileri eksiksiz olan hisse senetleri kullanılmıştır. Bazı hisse senetlerinin 2010 yılı verisi, bazı hisse senetlerinin de 2023 verilerinde eksiklikler olduğu için analizden çıkarılmıştır. Ayrıca Datastream veri tabanına olası eksik veri sağlanması nedeniyle olduğu düşünülen bazı hisse senetlerinin analiz dönemi içindeki verilerinde eksiklikler mevcuttur. Eksik gözlemlerin yanı sıra sonuçlar sağlayacağı düşüncesiyle bu hisse senetleri de analiz aşamasında veri setinden çıkarılmıştır.

Burada α, δ, γ sırasıyla modelin sabit ve eğim parametrelerini temsil etmektedir. Model kalıntıları ε_t sabit varyans ve sıfır ortalamalı normal dağılımı temiz dizidir. Modele göre Y_t bağımlı değişkeni hem kendisinin hem de X_t açıklayıcı değişkenin gecikmeli değerlerinin bir fonksiyonudur. Otopregresif bir modelde hata terimlerinin otokorelasyon ve değişen varyans problemleri içermemelidir. Bu ise Y_t ve X_t 'nin uygun gecikmelerinin modele eklenmesiyle mümkündür.

Gecikmesi dağıtılmış bir modelde katsayı tahmini sıradan bir ekonometrik modelin tahmininden farklıdır. En küçük kareler (EKK) yöntemi ile tahmin edilmiş bir modelde hata terimlerine ilişkin varsayımların yanı sıra açıklayıcı değişkenlere ilişkin de bir takım varsayımlar mevcuttur. Bunlardan bir tanesi açıklayıcı değişkenin olasılıksız ve hata terimleriyle ilişkisiz olmasıdır. Ekonometrik modelin sağ tarafında olasılıklı bir değişken var ise bu modelin katsayıları sapmalı ve tutarsız olacaktır. Bu anlamda eğer açıklayıcı değişkenler sadece X_t ve onun gecikmeli değerlerinden oluşuyorsa EKK tahmincileri sapmasız ve tutarlı olmaya devam edecektir. Çünkü X_t olasılıksız kabul edildiğinden X_t 'nin gecikmeli değerleri de olasılıksız olacaktır. Fakat sağ tarafta Y_t bağımlı değişkenin gecikmeli değerleri yer alıyorsa bazı tahmin sorunları ortaya çıkmaktadır. Bir ekonometrik modelde Y_t bağımlı değişkeni olasılıklı ve $E(Y_t, u_t) \neq 0$ olacağından bilindik anlamda EKK tahmincileri sapmalı ve tutarsız olacaktır. Bu durumda model üzerinde birtakım değişiklikler gereklidir. Otopregresif bir modelin tahmininde Kısmi Uyarlamalı Beklentiler yaklaşımı kullanılabilir. Kısmi uyarlamalı modele göre oluşturulmuş bir ekonometrik model aşağıdaki şekilde ifade edilmektedir.

$$Y_t^* = \alpha + \beta_1 X_t + u_t \quad (4)$$

Burada Y_t^* beklentileri temsil etmektedir. Beklentileri ifade eden Y_t^* direkt olarak gözlenemez. Dolayısıyla beklentiler şu şekilde formüle edilmiştir;

$$Y_t - Y_{t-1} = \delta(Y_t^* - Y_{t-1}) \quad (5)$$

$Y_t - Y_{t-1}$ gözlenen değişim olarak isimlendirilirken, $Y_t^* - Y_{t-1}$ gözlenemeyen değişimdir. Dolayısıyla gözlenen değişim gözlenemeyen değişimin bir fonksiyonudur. Burada δ uyarılma katsayısı olarak bilinir. Yukarıdaki eşiklikte Y_t yalnız bırakılırsa;

$$Y_t = \delta Y_t^* + (1 - \delta) Y_{t-1} \quad (6)$$

elde edilir. Denklem (6) gerçekleşmiş gözlem Y_t 'nin Y_t^* ve Y_{t-1} 'in tartılı ortalaması olduğunu ifade etmektedir. Son olarak denklem (4) denklem (6)'da yerine yazıldığında aşağıdaki model elde edilir.

$$Y_t = \delta(\alpha + \beta_1 X_t + u_t) + (1 - \delta) Y_{t-1} \\ = \delta\alpha + \delta\beta_1 X_t + (1 - \delta) Y_{t-1} + \delta u_t \quad (7)$$

Bu durumda u_t otokorelasyon içermeyen sabit varyanslı temiz dizi ise u_t 'nin doğrusal fonksiyonu olan δu_t de aynı özellikleri sağlayacaktır. Dolayısıyla son denklem EKK ile tahmin edilmesinde sapmasız ve tutarlı tahminciler üretecektir. Fakat bu modelin katsayıları sıradan EKK yönteminden biraz farklılık göstermektedir. Yukarıdaki regresyon modeli EKK ile tahmin edildikten sonra Y_{t-1} 'in katsayısından δ değeri hesaplanıp X_t 'nin katsayısı bu değere bölünerek sapmasız tahminci elde edilmektedir (Gujarati, 2022).

IV. ANALİZ VE BULGULAR

Hem doğrusal hem de doğrusal olmayan bileşenleri içeren finansal zaman serilerinin karmaşık yapısı, sofistike modellerin kullanılmasını gerektirmektedir. Finansal serilerde geleneksel ekonometrik (doğrusal) modeller yaygın olarak kullanılmış olsa da, bu modeller doğrusal olmayan dinamikleri yakalamak konusunda çoğu zaman başarısız olmaktadır. Buna karşılık doğrusal olmayan modeller, karmaşık yapıdaki ilişkilerin doğrusal olmayan kısımların modellenmesinde daha iyi sonuçlar üretmektedir. Bu anlamda en iyi tahmin performansı için hem doğrusal hem de doğrusal olmayan modellerin birlikte kullanılması birçok avantaj sağlamaktadır. Bu çalışmada hem doğrusal hem de doğrusal olmayan modellerin güçlü yönlerinden yararlanmak için

birleşik bir tahmin prosedürü kullanılmıştır. Bu tahmin sürecinde hisse senedi fiyat tahmininin doğruluğunu artırmak için vektör otopregresyon modeli ve yapay sinir ağları algoritmasından faydalanılmıştır. Kullanılan yaklaşım, zaman serisini doğrusal ve doğrusal olmayan bileşenlere ayırarak modellerin tahmin sürecindeki dezavantajlarını azaltmayı ve güçlü yönlerini birlikte kullanmayı amaçlamaktadır. Çünkü VAR gibi geleneksel modeller, bir pay senedinin karmaşık yapısındaki bilginin doğrusal kısmını modellerken YSA gibi yapay zekâ tabanlı doğrusal olmayan modeller hisse senedinin taşıdığı bilginin geriye kalan kısmı yakalar. Bu noktadan hareketle bu çalışmanın analizinde VAR modelleri ve YSA algoritması birlikte kullanılarak BIST100 endeksinde işlem gören pay senetlerinin fiyat tahmini yapılmıştır. İlk aşamada FF5F modelindeki faktörlerin ilgili hisse senedinin fiyatı üzerindeki etkisi VAR modelinde uygun gecikmesiyle tespit edilmiştir. VAR modelinde uygun gecikme sayısı AIC bilgi kriteri yardımıyla belirlenmiştir. Uygun gecikme sayısının belirlenmesi hata terimlerinin otokorelasyon ve değişen varyans gibi sorunların meydana gelmemesi adına önemlidir. Dolayısıyla her hisse senedi için VAR modelinde gecikme sayıları belirlendikten sonra otokorelasyon ve değişen varyans kontrolleri yapılmıştır. Modelin kullanılabilir olmasına karar verildikten sonra ikinci aşamadaki tahmin sürecine geçilmiştir. İkinci aşamada belirlenen gecikme sayısı dikkate alınarak ve YSA algoritması kullanılarak hisse senedinin fiyatı tahmin edilmiştir. YSA algoritmaları her bir hisse senedi için girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmanlı model olarak tahmin edilmiştir. Nöron sayıları genel olarak 10 ile 20 arasında ve en iyi tahmin performansı gösterecek şekilde seçilmiştir. Girdi katmanı ile gizli katman arasında toplam fonksiyonu kullanılırken, gizli katman ile çıktı katmanı arasında genellikle sigmoid fonksiyon kullanılmıştır. YSA algoritmalarının her tahminde farklı sonuç üretmesi çok yüksek olasılıktır. Dolayısıyla en iyi tahmin performansı gösteren YSA algoritması birkaç denemeden sonra seçilmiştir. Maalesef çoğu sezgisel tahmin yönteminde optimal modeli seçerken izlenebilecek standart bir prosedür bulunmamaktadır. Dolayısıyla elde edilen veriye en iyi uyum sağlayan model farklı fonksiyon ve parametre sayılarının denenmesiyle elde edilmektedir.

TABLO 1 | Hisse Senetleri ve Tanımlayıcı İstatistikler

Hisse	Ort.	Maks.	Min.	Jarque-Bera	Prob.
AEFES	20.25	91.50	10.39	31.91	0.0000
AGHOL	23.19	128.00	7.61	9.14	0.0103
AKBNK	6.16	25.00	3.56	8.97	0.0113
AKCNS	12.15	103.00	3.05	307.80	0.0000
AKSA	11.08	89.01	0.48	5.66	0.0590
ALARK	8.81	91.45	1.06	17.10	0.0002
ALBRK	1.15	3.40	0.58	660.31	0.0000
ARCLK	22.83	148.40	3.36	2.32	0.3137
ASELS	6.63	74.30	0.57	61.95	0.0000
ASUZU	25.20	268.49	1.32	212.76	0.0000
BAGFS	6.68	43.41	1.72	89.87	0.0000
BIMAS	37.29	203.50	5.98	Feb-81	0.2453
BRSAN	17.26	306.00	1.55	116.15	0.0000
BRYAT	138.44	1969.00	4.44	1334.47	0.0000
BUCIM	1,21	7.35	0.47	90.29	0.0000
CCOLA	51.14	299.70	10.37	2.89	0.2354
CEMTS	1.60	12.76	0.14	23.85	0.0000
CIMSA	17.27	174.90	3.68	48.54	0.0000
DOAS	19.00	232.00	0.98	24.15	0.0000
DOHOL	1.62	11.91	0.37	138.19	0.0000
ECILC	5.47	40.92	0.73	51.23	0.0000
ECZYT	18.70	189.60	1.48	40.93	0.0000
EGEEN	671.53	6130.00	5,87	112.99	0.0000
ENKAI	5.43	32.76	1.12	54.94	0.0000


TABLO 1 (Devamı) | Hisse Senetleri ve Tanımlayıcı İstatistikler

Hisse	Ort.	Maks.	Min.	Jarque-Ber	Prob.
EREGL	7.55	44.10	0.69	10.04	0.0066
FROTO	85.07	925.30	4.06	7.75	0.0208
GARAN	8.50	37.92	4.22	73.91	0.0000
GLYHO	2.28	12.59	0.54	68.46	0.0000
GSDHO	0.59	4.51	0.09	36.07	0.0000
GUBRF	0.95	1.03	0.87	198.69	0.0000
HALKB	9.66	18.41	4.29	439.93	0.0000
HEKTS	2.91	37.62	0.02	57.68	0.0000
IPEKE	7.14	40.12	0.81	73.94	0.0000
ISCTR	2.68	14.06	1.04	34.04	0.0000
ISGYO	2.24	19.89	0.46	1502.39	0.0000
ISMEN	1.55	20.20	0.07	43.54	0.0000
IZMDC	1.62	9.11	0.24	205.63	0.0000
KARSN	2.32	12.92	0.78	71.83	0.0000
KCHOL	16.89	119.10	3.24	5.05	0.0799
KONYA	527.28	4224.00	82.62	396.12	0.0000
KORDS	13.36	96.30	1.89	12.12	0.0023
KOZAA	9.09	60.70	0.86	20.63	0.0000
KOZAL	4.20	28.04	0.43	266.99	0.0000
KRDMD	3.45	23.32	0.33	21.64	0.0000
MGROS	33.76	271.10	12.70	23.88	0.0000
OTKAR	31.77	284.50	1.81	193.02	0.0000
OYAKC	5.69	54.95	1.89	12195.41	0.0000
PETKM	3.50	19.96	0.51	200.06	0.0000
SAHOL	9.72	53.00	3.91	6.40	0.0408
SASA	4.96	60.75	0.03	111.30	0.0000
SELEC	5.95	42.66	1.05	24.80	0.0000
SISE	6.38	48.70	0.67	7.50	0.0235
SKBNK	1.21	3.66	0.63	3681.28	0.0000
SNGYO	1.04	6.00	0.18	25.03	0.0000
TAVHL	20.15	115.50	3.54	6.32	0.0424
THYAO	13.51	93.30	1.79	2.54	0.2803
TKFEN	10.31	44.98	2.71	0.60	0.7402
TOASO	26.70	260.00	1.96	39.23	0.0000
TSKB	1.18	5.64	0.34	5587.07	0.0000
TTKOM	6.65	63.79	0.67	12332.73	0.0000
TTRAK	5.82	24.56	2.38	69.04	0.0000
ULKER	1.33	4.69	0.41	97.66	0.0000
VAKBN	1.00	4.87	0.25	76.58	0.0000
VESBE	10.58	71.25	1.10	12.80	0.0017
YKBNK	4.72	37.00	0.88	4568.57	0.0000

Hisse senetleri doğrusal ve doğrusal olmayan bilgiler taşıdığından YSA algoritması gibi bir sezgisel modelin klasik ekonometrik model tahminiyle karşılaştırılması hangi modelin daha iyi tahmin performansı gösterdiğini belirleyecektir. Bu amaçla YSA algoritmasından elde edilen tahmin sonuçları gecikmesi dağıtılmış model tahmininden elde edilen sonuçlarla karşılaştırılmıştır. Karşılaştırma için kullanılan ölçüt (OHK) hata karelerinin ortalamasıdır. Analiz döneminde kullanılan 65 hisse senedi ve bu hisse senetlerine ait tanımlayıcı istatistikler Tablo 1'de özetlenmiştir. Buna göre AEFES'in analiz dönemindeki ortalama fiyatı 20.25 TL olmuştur. Aynı dönemde bu pay senedinin minimum fiyatı 10.39 TL olurken maksimum fiyatı 91.50 TL olarak gerçekleşmiştir. Pay senedine ait Jarque-Bera² test istatistiği 31.91 ve ilgili test için


birinci tip hata olasılığı 0.0000 olarak hesaplanmıştır. Bu olasılık değeri AEFES pay senedine ait getiri serisinin normal dağılmadığını göstermektedir. Örneklem uzayındaki pay senetleri karşılaştırıldığında oynaklığı en yüksek pay senetlerinden bir tanesi 12.52 standart sapma değeriyle EGEEN olmuştur. EGEEN analiz dönemi içinde 671.53 TL ile 6130.00 TL arasında değişen fiyatlardan işlem görmüştür. İlgili pay senedinin Jarque-Bera test istatistiği tüm güven düzeyleri için ret edilmektedir. Dolayısıyla bu pay senedi normal dağılmamaktadır. Aynı dönem içinde oynaklığı en az olan pay senedi GUBRF olurken ARCLK, BIMAS, CCOLA, THYAO ve TKFEN'e ait normallik sınaması test istatistiği %10'a kadarki hiçbir güven düzeyinde ret edilememiştir. Bu hisseler ek olarak %1 güven düzeyi için AGHOL, AKBNK, AKSA, GARAN, KCHOL, SAHOL, SISE ve TAVHL gibi hisse senetleri fiyat serilerinin de normal dağılımdan geldiği görülmektedir. Bir serinin normal dağılımdan gelip gelmediği, basıklık ve simetri gibi merkezi eğilim ölçütleri tahmin sürecini etkilen parametrelerdir. Bu anlamda örneklem uzayında hem normal dağılım gösteren hem de normal dağılım göstermeyen hisse senetlerinin yer alması burada kullanılan tahmin sürecini daha sağlıklı bir değerlendirmesine olanak sağlayacaktır.

ŞEKİL 2 | Hisse Senetleri Ait Ortalama ve Standart Sapma Değerleri



Pay senetleri yüksek oynaklığa sahip yatırım araçlarıdır ve genel olarak yüksek riskli pay senetlerinin yüksek getiri oranlarına sahip olması beklenmektedir. Şekil 2 pay senetlerinin analiz dönemindeki ortalama getiri oranlarını ve standart sapma değerlerini göstermektedir. Grafiki sağ tarafındaki ölçek değerleri pay senetlerinin risklerini gösterirken sol tarafındaki ölçek ortalamaların değerlerini göstermektedir. Grafikten daha açık görüldüğü üzere SASA, HEKTS, EGEEN ve BRYAT pay senetleri en yüksek risk oranına sahip hisse senetleridir. İlk bakışta yüksek getiriye sahip pay senetlerinin daha yüksek standart sapma değerine sahip olduğu görülse de bu durum bütün senetler için geçerli görünmemektedir. Örneğin HEKTS ve IPEKE'ye göre daha yüksek getiriye sahipken risk oranı daha düşüktür. Bir finansal varlığa yatırım yaparken en iyi birleşim yüksek ortalama getiri ve düşük risk oranıdır. Fakat pay senetlerinin fiyat tahminleri zor olduğu için bu özellikleri gösteren bir senet bazen yüksek bir doğrulukla tahmin edilemediğinden yatırım yapılacak portföyde yer almaz.

ŞEKİL 3 | Hisse Senetleri Getiri Serisi Kutu Grafiki



²Jarque-Bera normallik sınamasının boş hipotezi "Veriler normal dağılım gösterir" şeklindedir.

Şekil 3'te analizde kullanılan hisse senetlerinin fiyat serilerine ait kutu grafikleri yer almaktadır. Şekil 3 incelendiğinde GUBRF hariç tüm senetlerin uç değerlere (outlier) sahip olduğu görülmektedir. Şekil 3, hisse senetleri fiyatlarının dağılımı ile ilgili önemli bilgiler içermektedir. Tüm hisse senetleri birden fazla uç değere sahiptir ve kutu grafiklerinin alt kuyrukları ile üst kuyrukları arasında belirgin bir asimetrik yapı söz konusudur. Zira grafiklerin negatif sınır değerleri ile pozitif sınır değerleri farklıdır. Bu anlamda fiyat serilerinin grafikleri Jarque-Bera normallik testi sonuçlarını desteklemektedir. Hisse senetlerinin fiyat veya getiri serilerinin normal dağılımı beklenen bir durumdur. Birçok tahmin tekniği tahmini yapılan serilerin dağılımları ile ilgili güçlü varsayımlar yapar. Fakat hisse senetleri gibi oynaklığı yüksek ve karmaşık finansal varlıkların fiyat veya getiri serileri hakkında genel bir varsayım yapmak neredeyse imkânsızdır. Bir hisse senedinin belli bir dönemdeki getirileri normal dağılsa bile bu hisse senedinin başka bir dönemde de benzer dağılım özellikleri sağlayacağını beklemek gerçekçi değildir. Gerçekten de elimizde normal dağılımdan gelen bir hisse senedinin gelecekte de normal dağılımdan gelen getiri serilerine sahip olacağını garanti eden hiçbir kanıt yoktur. Dolayısıyla söz konusu yüksek oynaklığa sahip hem doğrusal hem de doğrusal olmayan bilgiler içeren bir finansal varlığın fiyat tahminini yapmaktan çok dikkatli olmak gerekmektedir. Yukarıda tablo ve grafiklerde yer alan bilgiler bir hisse senedinin fiyat tahmininin kolay olmadığı ile ilgili ipuçları vermektedir. Tanımlayıcı istatistiklerden anlaşılacağı üzere

bu finansal varlıklar yüksek oynaklığa sahiptir. Klasik ekonometrik modeller doğrusal bir ilişkiyi tahmin etmek konusunda oldukça başarılı olabilir. Fakat daha önce belirtildiği gibi finansal varlıklar neredeyse tüm ekonomik birimlerden etkilenen ve genelde bu birimler ile arasındaki ilişki doğrusal değildir. Bu noktada klasik ekonometrik modellerle desteklenmiş doğrusal olmayan modeller iç içe geçmiş bu karmaşık ilişkileri daha iyi tahmin edebilir. YSA algoritması gibi yapay zekâ uygulamaları ekonometrik modellerden gelen doğrusal bilgiyi kullanarak ve kendinden kaynaklı genelleme özelliğini bu bilgilerle birleştirerek yüksek doğrulukla tahmin yapabilir.

Tablo 2'deki bilgilerin gecikmesi dağıtılmış otoregresif model ile birleşik YSA algoritmasının sonuçlarını göstermektedir. Tablonun ilk sütunu EKK regresyon modelinden elde edilmiş ortalama hata kareler toplamını vermektedir. İkinci sütun tahmin edilen her bir modelin gecikme sayısını göstermektedir. Daha önce belirtildiği gibi optimal gecikme sayıları VAR modeli yardımıyla AIC bilgi kriteri kullanılarak belirlenmiştir. Belirlenen gecikme sayıları daha sonra hem EKK tahmininde hem de YSA algoritmasının tahmin sürecinde kullanılmıştır. Üçüncü sütun YSA algoritmasının eğitiminde kullanılan veriye uyumunu göstermektedir. YSA algoritmasının öğrenme sürecinde analiz dönemindeki verinin %70'i eğitim, %30'u ise test için kullanılmıştır. EKK modelleri ile YSA algoritması karşılaştırılırken hata kareleri veya ortalama hata kareleri kullanılmaktadır. Burada da iki modeli karşılaştırırken ortalama hata kareleri kullanılmıştır. Son

TABLO 2 | VAR-YSA ve Ardışık Bağlımlı Otoregresif Model Sonuçları

Hisse	OHK OLS	k	OHK Eğitim	Ortalama Uyum	Hisse	OHK OLS	k	OHK Eğitim	Ortalama Uyum
AEFES	3.774	3	1.672	0.941	ISCTR	0.071	1	0.025	0.988
AGHOL	9.176	1	6.206	0.958	ISGYO	1.322	1	1.189	0.972
AKBNK	0.096	6	1.089	0.950	ISMEN	0.097	1	0.009	0.943
AKCNS	4.207	1	1.819	0.907	IZMDC	0.305	1	0.305	0.956
AKSA	7.415	1	5.990	0.946	KARSN	0.223	1	0.063	0.954
ALARK	7.415	6	1.825	0.952	KCHOL	1.055	8	0.189	0.957
ALBRK	0.016	1	1.187	0.952	KONYA	31842.3	1	3.111	0.930
ARCLK	12.388	1	3.295	0.922	KORDS	7.444	1	2.125	0.962
ASELS	4.160	1	1.389	0.966	KOZAA	1.506	7	0.093	0.974
ASUZU	170.397	1	4.831	0.977	KOZAL	0.879	1	0.494	0.862
BAGFS	2.207	1	2.114	0.936	KRDMD	0.732	1	0.532	0.985
BIMAS	16.971	1	8.228	0.982	MGROS	19.475	1	1.063	0.963
BRSAN	15.293	5	2.055	0.992	OTKAR	67.034	1	0.456	0.980
BRYAT	3636.103	1	3.070	0.953	OYAKC	4.232	1	0.018	0.989
BUCIM	0.065	1	1.283	0.969	PETKM	0.394	1	0.153	0.969
CCOLA	29.379	1	4.989	0.948	SAHOL	0.918	1	0.531	0.962
CEMTS	0.158	1	0.115	0.943	SASA	3.539	1	2.358	0.975
CIMSA	28.126	1	0ct-16	0.932	SELEC	1.337	1	0.569	0.969
DOAS	19.198	5	2.252	0.970	SISE	1.197	1	0.554	0.973
DOHOL	0.095	1	0.734	0.958	SKBNK	0.046	1	0.928	0.975
ECILC	1.307	1	1.201	0.959	SNGYO	0.081	1	0.608	0.978
ECZYT	35.512	1	1.200	0.980	TAVHL	5.635	2	0.194	0.953
EGEEN	34982.76	1	7.675	0.984	THYAO	4.272	1	1.500	0.988
ENKAI	0.940	1	0.453	0.952	TKFEN	2.193	1	0.915	0.884
EREGL	2.316	1	1.020	0.978	TOASO	20.886	1	6.228	0.950
FROTO	282.283	1	1.214	0.950	TSKB	0.083	1	0.815	0.981
GARAN	0.495	5	0.040	0.972	TTKOM	12.277	1	0.591	0.987
GLYHO	0.198	1	0.150	0.944	TTRAK	0.593	1	0.377	0.972
GSDHO	0.020	1	0.841	0.971	ULKER	0.104	1	0.045	0.989
GUBRF	79.844	1-J	0.606	0.959	VAKBN	0.049	1	0.024	0.966
HALKB	0.571	1	0.544	0.953	VESBE	4.809	1	1.081	0.971
HEKTS	1.405	1	0.916	0.973	YKBNK	2.782	10	1.240	0.969
IPEKE	1.600	1	0.858	0.919					
Min.	0.016		0.009						
Mak.	34982.76		8.228						

sütun gerçek fiyat serileri ile tahmin edilen fiyat serilerinin bir uyum göstergesi olarak korelasyon katsayısı hesaplanmıştır. Bu korelasyon katsayısı hem eğitim hem de test verisini içermektedir. Tablodaki bilgilere göre EKK tahmincisinin minimum ortalama hata kareler toplamı 0.016 olarak hesaplanırken YSA algoritmasında minimum ortalama hata kareleri toplamı 0.009 olarak gerçekleşmiştir. EKK için maksimum ortalama hata kareleri toplamı 34982.76 olurken YSA algoritması için bu sayı sadece 8.23 olarak gerçekleşmiştir. Tablodaki veriler ışığında VAR modellerinin optimal gecikme sayısı 1 ile 8 arasında değişmektedir. Tüm hisse senetleri içinden ISMEN ve KCHOL hisse senetleri 8 gecikmeye sahipken gecikmelerin önemli bir kısmı 1 olarak gerçekleşmiştir. Buna karşılık hiç sıfır gecikme hesaplanmamıştır. Gerçek fiyat serileri ile tahmin serileri arasındaki uyum KOZAL dışında %90'nın altına düşmediği görülmektedir. Analizde 65 adet hisse senedi yer almaktadır ve bu hisse senetlerinin 6 tanesinde EKK tahmincisi YSA-VAR modellerinden daha iyi tahmin performansı gösterirken geriye kalan 59 hisse senedinde YSA-VAR modeli çok daha iyi tahmin üretmiştir. Tüm hisse senetleri arasında EKK tahmincisinin başarılı olduğu hisse senetleri AKBNK, BUCIM, DOHOL, GSDHO, SKBNK ve SNGYO olarak gerçekleşmiştir. Bu hisse senetlerinin tahmin sürecinde YSA sırasıyla %95, %96.9, %95.8, %97.1, %97.5 ve %97.8 oranında uyum yakalamayı başarmıştır. Yani EKK tahmincileri bu hisse senetlerinde daha iyi tahmin üretse de YSA algoritmaları da güçlü tahminler üretmiştir. EKK tahmincilerinin YSA algoritmasından daha iyi performans gösterdiği bu hisse senetlerini yakından incelemek karşılaştırma açısından daha iyi fikir verebilir.

TABLO 3 | YSA ve EKK Tahminlerinin Güçlü Olduğu Hisse Senetleri


Hisse	Ort.	Maks.	Min.	Aralık(%)	Prob.
AKBNK	6.16	25.00	3.56	602.25	0.0113
BUCIM	1.21	7.35	0.47	1447.79	0.0000
DOHOL	1.62	11.91	0.37	3105.92	0.0000
GSDHO	1.59	4.51	0.09	5046.58	0.0000
SKBNK	1.21	3.66	0.63	483.39	0.0000
SNGYO	1.04	6.00	0.18	3222.58	0.0000
AKCNS	12.15	103.00	3.05	3272.56	0.0000
FROTO	85.07	925.30	4.06	22694.49	0.0208
MGROS	33.76	271.10	12.70	2035.11	0.0000
OTKAR	31.77	284.50	1.81	15639.59	0.0000

Tablo 3'te YSA algoritmasının ve EKK tahmincisinin daha iyi performans gösterdiği bazı hisse senetleri yer almaktadır. EKK tahmincisinin hangi özelliklere sahip hisse senetlerinde daha iyi performans sergilediğini tespit etmeye çalıştığımız bu noktada tablonun üst kısmında yer alan hisse senetleri fiyat serilerinde ortak bir özellik göze çarpmamaktadır. Bu hisse senetlerinden bir tanesi %5 ve %10 güven seviyelerinde normal dağıldığı kabul edilse bile benzer bir durum YSA algoritmasının başarılı olduğu ve rastgele seçilmiş FROTO hisse senedi için de geçerlidir. Hisse senetlerinin analiz dönemi başından sonuna kadar minimum fiyat ile maksimum fiyat düzeyi arasındaki yüzde değişimi de tahmin performansının daha iyi olmasını açıklamaktan uzaktır. Hem EKK tahmincisinin hem de VAR-YSA sürecinin iyi olduğu hisse senetlerinde çok geniş aralıklarda bir fiyat değişim oranı mevcuttur. Tüm bu bilgiler göz önüne alındığında EKK'nın daha iyi performans göstermesi için gerekli koşulların belirlenmesi güçtür. Başka bir ifade ile YSA algoritmasının daha kötü tahmin performansı göstermesinin sistematik bir açıklaması yoktur. Zaten ortalama hata kareleri incelendiğinde EKK yöntemi söz konusu hisse senedi fiyat tahmininde YSA algoritmasından çok düşük oranlara sahip değildir. YSA algoritması da bu hisse senetlerini gayet başarılı tahmin etmesine rağmen ortalama hata kareler toplamı biraz daha yüksek hesaplanmıştır. Nihayetinde fiyat tahminini yaptığımız 65 hisse senedinin %90.75'inde VAR-YSA tahmin süreci çok daha iyi tahmin üretmiştir.

EKK tahmincisinin başarılı performans gösterdiği AKBNK, BUCIM, DOHOL, GSDHO, SKBNK ve SNGYO hisse senetleri fiyat serilerinin dağılım grafikleri ayrıca incelenmiştir. Buna göre dağılım grafikleri Şekil 4'de verilen hisse senetlerinin simetrik olmadığı

görülmektedir. Grafikler de hisse senetlerine ilişkin normallik testlerini desteklemektedir. Ayrıca dağılım grafikleri finansal serilerin genelde kalın kuyruk dağılıma sahip olduğunu göstermektedir. Sonuçta grafikler de EKK tahmincilerinin neden bu hisse senetlerinde daha başarılı olduğunun kanıtlarını taşımamaktadır.

ŞEKİL 4 | Hisse Senetleri Getiri Grafiği



Hisse senetlerinin fiyatlarını tahmin etmek oldukça zordur. Bunun nedenleri arasında hisse senetlerinin neredeyse bütün makroekonomik olgulara etkilenmesi, spekülasyona açık yatırım araçlarından olması, likidite oranının yüksek olması, piyasa risklerinin yanında firma bazlı riskleri taşıması gibi durumlar sayılabilir. Her ne kadar hisse senetlerini fiyat tahminleri zor olsa da yapay sinir ağları algoritması gibi yapay zekâya dayalı modeller örnek verilerden elde ettikleri bilgileri kendi içinde saklamaları ve hiç görmedikleri örneklerde genelleme yapabilme özellikleri bu gibi serilerin tahmininde başarılı olmalarını sağlamaktadır. Özellikle ekonometrik modellerin güçlü yönleriyle yapay sinir ağlarının güçlü yönleri birleştirildiğinde tahmin becerileri çok daha yüksek olmaktadır. Burada verinin karmaşık yapısı ve tahmin sürecindeki zorluklar birleşik tahmin modelleriyle aşılabilmektedir. Tabii ki tüm tahmin modelleri gibi yapay sinir ağları da covid-19 gibi ani ve tüm ekonomik yapıyı bir anda bozabilecek şokları yakalamak konusunda başarısız olabilir. Bu tahmin sürecinin doğal bir sonucudur. Dolayısıyla pandemi, savaş ve ekonomik krizler gibi ani şoklar tahmin başarısını düşürme potansiyeline sahip olsa da geleneksel tahmin yöntemlerinin YSA algoritmalarıyla birleştirilmesi öngörü başarısını artırdığı açıktır.

V. SONUÇ

Yatırımcıların gelecek beklentileri yatırım yapma noktasında belirleyicidir. Bir yatırımcının bir pay senedinin değerlendirileceği yönünde beklentiye sahipse o pay senedine yatırım yapabilir. Fakat beklenti bir pay senedinin değer kaybı yaşayacağı yönünde ise yatırımcı o senede çoğunlukla yatırım yapmaktan vazgeçer. Yatırımcı doğal olarak getirisini maksimum yaparken üstlendiği yatırım riskini minimum düzeye çekmek istemektedir. Bu doğrultuda çeşitlendirilmiş portföylere yatırım yaparken elinde tuttuğu hisse senetlerinin fiyat tahminini de yapmayı amaçlamaktadır. Bu noktada, doğru tahmin edilmiş bir fiyat öngörüsü yatırımcının getiri maksimizasyonu amacına hizmet edecektir. Tabii ki pay senetlerinin gelecekte ne kadar değerlendirileceğini veya ne kadar değer kaybedeceğini tam olarak kestirmek mümkün değildir. Yatırımcının gelecek ile ilgili tahmin isteği bu alanda birçok ekonometrik ve sezgisel modelin kullanılmasının önünü açmıştır. Gecikmesi dağıtılmış modeller de bu tahmin çabalarıyla finansal çalışmalarda sıkça kullanılmıştır. Fakat geleneksel ekonometrik modeller doğrusal ilişkilerin tahmininde etkin sonuçlar üretirken doğrusal olmayan ilişkilerin tahmininde yetersiz kalabilmektedir. Bu noktada Yapay sinir ağları algoritması gibi doğrusal olmayan modeller daha etkin tahmin sonuçları üretmektedir. Hisse senetleri fiyat serileri hem doğrusal hem de doğrusal olmayan bilgiler içerdiğinden geleneksel ekonometrik modeller ve yapay sinir

ağları gibi yapay zekâ uygulamaları birlikte kullanıldığında çok daha yüksek tahmin performansları elde edilmektedir. Bu çalışmada hisse senetlerinin barındırdığı doğrusal ilişkiyi tahmin etmek amacıyla VAR modelleri kullanılırken, doğrusal olmayan kısım için yapay sinir ağları algoritması kullanılmıştır. Tahmin sonuçlarına göre %5 güven düzeyi temel alındığında analizde kullanılan pay senetleri içinden AKSA, ARCLK, BIMAS, COLA, KCHOL ve TKFEN normal dağılım hisse senetleri olmuştur. Diğer hisse senetlerinin getirileri normal dağılıma uymamaktadır. Tüm yatırım uzayı düşünüldüğünde 65 hisse senedinin fiyat tahmininde 6 tanesi hariç tüm hisselerde VAR ve yapay sinir ağları algoritması birleşik modeli gecikmesi dağıtılmış otoregresif modellerden daha iyi tahmin üretmiştir. AKBNK, BUCIM, DOHOL, GSDHO, SKBNK ve SNGYO senetlerinin fiyat tahmininde gecikmesi dağıtılmış otoregresif modeller daha başarıyla, bu hisse senetlerinin tahmin sürecinde yapay sinir ağları algoritması sırasıyla %95, %96.9, %95.8, %97.1, %97.5 ve %97.8 oranında uyum yakalamayı başarmıştır. Analizden elde edilen tüm bulgular birlikte değerlendirildiğinde VAR ve yapay sinir ağları algoritmasının birleşik tahmin süreci tek başına ekonometrik modelin tahmin performansından çok daha etkin olduğu sonucuna varılmıştır. Dolayısıyla hisse senetleri fiyatları gibi karmaşık bilgiler içeren ve birçok faktörden aynı anda etkilenen serilerin tahmininde sadece doğrusal modeller kullanmak veya sadece doğrusal olmayan modeller kullanmak yetersiz kalmaktadır. Burada olduğu gibi tahmin modellerini güçlü yönlerinden faydalanarak hisse senedi fiyat veya getiri tahmini yapmak yatırımcıya daha güvenilir sonuçlar sağlayacaktır.

KAYNAKÇA

- [1] Abd-Alla, M. H., ve Sobh, M. (2020). Empirical test of fama and french three-factor model in the Egyptian stock exchange. *Financial Assets and Investing*, 11(2), 5-18.
- [2] Abounoori, E., ve Tazehabadi, A. G. (2009, April). Forecasting stock price using macroeconomic variables: A hybrid ARDL, arima and artificial neural network. in *2009 International Conference on Information and Financial Engineering* (pp. 149-153). IEEE.
- [3] Agatonovic-Kustrin, S., ve Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717-727.
- [4] Akıncı, G. Y., ve Küçükçaylı, F. (2016). Hisse senedi piyasası ve döviz kuru mekanizmaları üzerine bir panel veri analizi. *Muhasebe ve Finansman Dergisi*, (71), 127-148.
- [5] Aksoy, B. (2021). Pay senedi fiyat yönünün makine öğrenmesi yöntemleri ile tahmini: Borsa İstanbul örneği. *Business and Economics Research Journal*, 12(1), 89-110.
- [6] Al-Mwalla, M., ve Karasneh, M. (2011). Fama and french three factor model: Evidence from emerging market. *European Journal of Economics, Finance and Administrative Sciences*, 41(14), 132-140.
- [7] Arslankaya, S., ve Toprak, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *International Journal of Engineering Research and Development*, 13(1), 178-192.
- [8] Babu, C. N., ve Reddy, B. E. (2014). A moving-average filter based hybrid ARIMA-ANN Model for forecasting time series data. *Applied Soft Computing*, 23, 27-38.
- [9] Bajpai, S., ve Sharma, A. K. (2015). An empirical testing of capital asset pricing model in India. *Procedia-Social and Behavioral Sciences*, 189, 259-265.
- [10] Baskan, T. D., ve Uslu, A. (2020). Hisse senedi fiyatları ile finansal oranlar arasındaki ilişkinin panel veri analizi yöntemiyle incelenmesi: Türkiye ve Almanya ulaştırma sektörü uygulaması. *International Journal of Social, Political and Economic Research*, 7(2), 372-393.
- [11] Basu, D., ve Chawla, D. (2010). An empirical test of CAPM—The case of Indian stock market. *Global Business Review*, 11(2), 209-220.
- [12] Bhowmik, R., ve Wang, S. (2020). Stock market volatility and return analysis: A systematic literature review. *Entropy*, 22(5), 522.
- [13] Blitz, D. (2020). Factor Performance 2010–2019: A lost decade?. *The Journal of Beta Investment Strategies*, 11(2), 57-65.
- [14] Bornholt, G. N. (2012). The failure of the capital asset pricing model (CAPM): An update and discussion. Available at SSRN 2224400.
- [15] Brandt, M. W., ve Kang, Q. (2004). On the relationship between the conditional mean and volatility of stock returns: A latent VAR approach. *Journal of Financial Economics*, 72(2), 217-257.
- [16] Chen, D. H., Chen, C. D., ve Wu, S. C. (2014). VaR and the cross-section of expected stock returns: An emerging market evidence. *Journal of Business Economics and Management*, 15(3), 441-459.
- [17] Chen, W., Lu, X., ve Wang, J. (2022). Modeling and managing stock market volatility using MRS-MIDAS model. *International Review of Economics & Finance*, 82, 625-635.
- [18] Chiah, M., Chai, D., Zhong, A., ve Li, S. (2016). A better model? An empirical investigation of the Fama-French five-factor model in Australia. *International Review of Finance*, 16(4), 595-638.

- [19] Cohen, M. H., ve Natoli, V. D. (2003). Risk and utility in portfolio optimization. *Physica A: Statistical Mechanics and its Applications*, 324(1-2), 81-88.
- [20] Cox, S., ve Britten, J. (2019). The Fama-French Five-Factor Model: Evidence from the Johannesburg stock exchange. *Investment Analysts Journal*, 48(3), 240-261.
- [21] Çam S., Balli, E., ve Sigeze, Ç. (2017). Petrol fiyatlarındaki oynaklığın ARCH/GARCH modelleri ve yapay sinir ağları algoritması ile tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 13(13), 588-597.
- [22] Çam, S., ve Kılıç, S. B. (2018). Altın fiyatı günlük getirilerinin yapay sinir ağları algoritması ve markov zincirleri modelleri ile tahmini. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 681-694.
- [23] Çınaroğlu, E., ve Avcı, T. (2020). THY hisse senedi değerinin yapay sinir ağları ile tahmini. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 34(1), 1-19.
- [24] Çoban, Ç., ve Hayat, E. (2023). Hisse Senedi piyasası analizinde farklı derin sinir ağı modellerinin karşılaştırılması. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(2), 120-139.
- [25] D'Ecclesia, R. L., ve Clementi, D. (2021). Volatility in the stock market: ANN versus parametric models. *Annals of Operations Research*, 299(1), 1101-1127.
- [26] Dawar, I., Dutta, A., Bouri, E., ve Saeed, T. (2021). Crude oil prices and clean energy stock indices: Lagged and asymmetric effects with quantile regression. *Renewable Energy*, 163, 288-299.
- [27] Dayı, F. (2018). Hisse senedi getirilerinin tahmininde yapay sinir ağı modeli kullanımı: imkb'de bir uygulama. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 10(19), 572-592.
- [28] Donaldson, R. G., ve Kamstra, M. (1997). An artificial neural network-GARCH model for international stock return volatility. *Journal of Empirical Finance*, 4(1), 17-46.
- [29] Elton, E. J., ve Gruber, M. J. (1997). Modern portfolio theory, 1950 to date. *Journal of Banking and Finance*, 21(11), 1743-1759.
- [30] Eraslan, V. (2013). Fama and French three-factor model: Evidence from Istanbul stock exchange. *Business and Economics Research Journal*, 4(2), 11.
- [31] Erdoğan, E., ve Özyürek, H. (2012). Yapay Sinir Ağları İle Fiyat Tahminlemesi. *Sosyal ve Beşeri Bilimler Dergisi*, 4(1), 85-92.
- [32] Faff, R. (2001). An examination of the Fama and French three-factor model using commercially available factors. *Australian Journal of Management*, 26(1), 1-17.
- [33] Fama, E. F., ve French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3-56.
- [34] Fama, E. F., ve French, K. R. (2004). The Capital asset pricing model: theory and evidence. *Journal of Economic Perspectives*, 18(3), 25-46.
- [35] Fama, E. F., ve French, K. R. (2015). A five-factor asset pricing model. *Journal of Financial Economics*, 116(1), 1-22.
- [36] Fırat, M., ve Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *Teknik Dergi*, 15(73).
- [37] Griliches, Z. (1967). Distributed lags: A survey. *Econometrica: Journal of the Econometric Society*, 16-49.
- [38] Gujarati, D. N. (2022). *Basic Econometrics*. Prentice Hall.
- [39] Gupta, R., ve Modise, M. P. (2013). Does the source of oil price shocks matter for South African stock returns? A structural VAR approach. *Energy Economics*, 40, 825-831.
- [40] Güngör, B., ve Kaygin, C. Y. (2015). Dinamik panel veri analizi ile hisse senedi fiyatını etkileyen faktörlerin belirlenmesi. *Kafkas University. Faculty of Economics and Administrative Sciences. Journal*, 6(9), 149.
- [41] İlarıslan, K. (2014). Hisse senedi fiyat hareketlerinin tahmin edilmesinde Markov zincirlerinin kullanılması: İMKB 10 bankacılık endeksi işletmeleri üzerine ampirik bir çalışma. *Yaşar Üniversitesi E-Dergisi*, 9(35), 6158-6198.
- [42] İlkçar, M. (2023). İşlem hacmi ve mevsimsel değerler dikkate alınarak derin yapay sinir ağı ile türk hava yolları BIST hisse fiyatı tahmini. *International Journal of Informatics Technologies*, 16(1).
- [43] Kara, Y., Boyacıoğlu, M. A., ve Baykan, Ö. K. (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(5), 5311-5319.
- [44] Karaca, Y. D. D. S. S., ve Başı, Y. D. D. E. S. (2011). Hisse senedi performansını etkileyen rasıyolar ve İMKB 30 endeksinde 2001-2009 dönemi panel veri analizi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 16(3), 337-347.
- [45] Karathanassis, G., ve Philippos, N. (1988). Estimation of bank stock price parameters and the variance components model. *Applied Economics*, 20(4), 497-507.
- [46] Khare, K., Darekar, O., Gupta, P., ve Attar, V. Z. (2017, May). Short term stock price prediction using deep learning. In *2017 2nd IEEE international conference on recent trends in electronics, information & communication technology (RTEICT)* (pp. 482-486). IEEE.
- [47] Koyuncu, T., ve Aslan, A. (2017). Etkin piyasa hipotezi ve gelişmiş borsalar üzerine bir uygulama: panel veri analizi. *Kapadokya Akademik Bakış*, 1(1), 17-30.
- [48] Kurani, A., Doshi, P., Vakharia, A., ve Shah, M. (2023). A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting. *Annals of Data Science*, 10(1), 183-208.
- [49] Li, K., ve Duan, Y. (2021, April). Research on the application of Fama and French three-factor and five-factor models in American industry. In *Journal of Physics: Conference Series* (Vol. 1865, No. 4, p. 042105). IOP Publishing.
- [50] Loo, W. K. (2020). Predictability of HK-REITs returns using artificial neural network. *Journal of Property Investment & Finance*, 38(4), 291-307.

- [51] Lu, W., Li, J., Wang, J., ve Qin, L. (2021). A CNN-BiLSTM-AM method for stock price prediction. *Neural Computing and Applications*, 33(10), 4741-4753.
- [52] Mayatopani, H. (2021). Implementation of ANN and GARCH for stock price forecasting. *Journal of Applied Data Sciences*, 2(4), 109-134.
- [53] Mosoou, S., ve Kodongo, O. (2022). The Fama-French five-factor model and emerging market equity returns. *The Quarterly Review of Economics and Finance*, 85, 55-76.
- [54] Nargelecekenler, M. (2011). Hisse senedi fiyatları ve fiyat/kazanç oranı ilişkisi: panel verilerle sektörel bir analiz. *Business and Economics Research Journal*, 2(2), 165-184.
- [55] Nerlove, M. (1958). *Distributed Lags and Demand Analysis for Agricultural and Other Commodities* (No. 141). US Government Printing Office.
- [56] Ogiugo, H. U., Adesuyi, I. O., ve Ogbuide, S. O. (2020). Empirical test of capital asset pricing model on securities return of listed firms in Nigeria. *Insights into Regional Development*, 2(4), 825-836.
- [57] Öndeş, T., ve Levet, M. (2020). Makroekonomik faktörlerin hisse senedi getirileri üzerindeki etkisi: BIST'de yer alan bankalar üzerine bir uygulama. *Muhasebe ve Finansman Dergisi*, (88), 155-174.
- [58] Özyayın, O. (2024). Türkiye'nin seçilmiş makro finans değişkenleri üzerine nedensellik analizi: Yapay sinir ağları ve doğrusal nedensellik yöntemleri. *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*, 11(2), 349-365.
- [59] Özçalıcı, M. (2016). Yapay sinir ağları ile çok aşamalı fiyat tahmini: BIST30 senetleri üzerine bir araştırma. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 31(2), 209-227.
- [60] Özçalıcı, M. (2017). Aşırı öğrenme makineleri ile hisse senedi fiyat tahmini. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 35(1), 67-88.
- [61] Perold, A. F. (2004). The Capital asset pricing model. *Journal of Economic Perspectives*, 18(3), 3-24.
- [62] Qiu, M., Song, Y., ve Akagi, F. (2016). Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market. *Chaos, Solitons & Fractals*, 85, 1-7.
- [63] Sattar, M. (2017). CAPM vs. Fama-French Three-Factor Model: An evaluation of effectiveness in explaining excess return in Dhaka stock exchange. *International Journal of Business and Management*, 12(5), 119.
- [64] Shaik, M., ve Sejjal, A. (2020). The comparison of GARCH and ANN model for forecasting volatility: Evidence based on Indian stock markets: Predicting volatility using GARCH and ANN models. *The Journal of Prediction Markets*, 14(2), 103-121.
- [65] Sharpe, W. F. (1964). Capital Asset Prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, 19(3), 425-442.
- [66] Şahin, C. (2023). Garch ve yapay sinir ağları modelleri yardımıyla volatilité tahmini: Türk borsası örneği. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(2), 572-595.
- [67] Şenol, Z., Koç, S., ve Şenol, S. (2018). Hisse senetleri fiyatlarını etkileyen faktörlerin dinamik panel veri analiziyle incelenmesi. *Gümüşhane Üniversitesi Sosyal Bilimler Dergisi*, 9(25), 119-135.
- [68] Toparlı, E. A., Çatık, A. N., ve Balcılar, M. (2019). The impact of oil prices on the stock returns in Turkey: A TVP-VAR approach. *Physica A: Statistical Mechanics and its Applications*, 535, 122392.
- [69] Ünlü, Ö. G. U., Yıldız, B., ve Yalama, A. (2009). İlk halka arzlarda uzun dönem getirilerinin tahmini: yapay sinir ağları ile İMKB için ampirik bir çalışma. *Istanbul University Econometrics and Statistics e-Journal*, (10), 29-47.
- [70] Vijh, M., Chandola, D., Tikkiwal, V. A., ve Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia Computer Science*, 167, 599-606.
- [71] Waheed, R., Wei, C., Sarwar, S., ve Lv, Y. (2018). Impact of oil prices on firm Stock return: Industry-wise analysis. *Empirical Economics*, 55, 765-780.
- [72] Wang, L., Zou, H., Su, J., Li, L., ve Chaudhry, S. (2013). An ARIMA-ANN hybrid model for time series forecasting. *Systems Research and Behavioral Science*, 30(3), 244-259.
- [73] Yakut, Y. B. E. T. Y., Yakut, E., ve Yavuz, S. (2014). Yapay sinir ağları ve destek vektör makineleri yöntemleriyle borsa endeksi tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1), 139-157.
- [74] Yu, L., Wang, S., ve Lai, K. K. (2007). *Foreign-exchange-rate forecasting with artificial neural networks* (Vol. 107). Springer Science & Business Media.
- [75] Yüksel, R., ve Akkoç, S. (2016). Altın fiyatlarının yapay sinir ağları ile tahmini ve bir uygulama. *Doğuş Üniversitesi Dergisi*, 17(1), 39-50.
- [76] Zeren, F., Kara H. ve Arı A. (2013). Piyasa etkinliği hipotezi: İMKB için ampirik bir analiz. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (36).
- [77] Zupan, J. (1994). Introduction to artificial neural network (ANN) methods: What they are and how to use them. *Acta Chimica Slovenica*, 41, 327-327.

as an artificial neural network would provide more accurate predictions. Therefore, we combine a vector autoregressive model, which can model the linear part of the data, and an artificial neural network model, which can model the nonlinear part of the data, to obtain a more accurate prediction of asset prices. The hybrid model used in the analysis would capture linear information thanks to the vector autoregressive model and non-linear information thanks to the artificial neural network algorithm.

Method: A linear econometric model and a nonlinear forecasting method are used to predict the future price of stocks traded in the Borsa İstanbul100 index. We determine an appropriate lag for the autoregressive distributed lag model by using the VAR method and the AIC information criteria. Following the VAR method, we estimate a distributed lag model to compare its results with the hybrid methodology and the artificial neural network algorithm used in this study. The distributed lag model is estimated using the constant lags specified by vector autoregressive model and the AIC information criterion. After estimating the linear econometric model, we also estimate the hybrid the artificial neural network algorithm and compare the results of the traditional method and the proposed method.

Findings: In this study, the Fama-French (2015) five-factor model (FF5F), autoregressive distributed lag model as well as the artificial neural network algorithm are used. The factors of the FF5F model are included as explanatory variables in the autoregressive distributed lag model as well as in the ANN algorithm. Monthly data covering the period from February 2010 to July 2023 is used for the analysis. Since the stocks traded in the BIST100 index vary over time, only the stocks that are quoted throughout the analysis period are used. The data used for the analysis obtained from the Datastream database. The estimation results obtained from the hybrid analysis show that AKSA, ARCLK, BIMAS, CCOLA, KCHOL and TKFEN are normally distributed among the stocks used in the analysis. The returns of the remaining shares are not normally distributed. Considering the entire investment space, it is found that the combined model of VAR and neural network algorithm provides better predictions than the lagged autoregressive models for all but six stocks. The proposed method provided better prediction results for 65 stocks in the investment space. While the lagged distributed autoregressive models were more successful in predicting the price of AKBNK, BUCIM, DOHOL, GSDHO, SKBNK and SNGYO stocks, the artificial neural network algorithm achieved coefficients of determination of 95%, 96.9%, 95.8%, 97.1%, 97.5% and 97.8%, respectively, in predicting these stocks. When predicting with the artificial neural network algorithm and the VAR model together, the share price movements were predicted more than 90% correctly. The mean square errors of this model are also lower than the mean square errors of the traditional econometric model. In this sense, the proposed forecasting method achieves much better results in terms of both coefficient of determination and mean square errors.

Conclusion: We conclude that the combined prediction of VAR and artificial neural network algorithm is much more effective than the prediction performance of the econometric model alone. Therefore, it is insufficient to use only linear models or only non-linear models when forecasting time series such as stock prices, which contain complex information and are influenced by many factors at the same time. Predicting stock prices or returns by utilizing the strengths of forecasting models as in this study will provide investors with more reliable results.

Extended Abstract

Introduction: The prediction of financial time series is associated with some difficulties due to the complexity of financial time series. A financial time series, such as the price of an asset, usually consists of a linear part and a non-linear part of the information hidden in the data. Therefore, a conventional linear econometric model is not able to predict the future price of an asset. To capture both linear and non-linear information in the financial series, using a traditional econometric model in conjunction with an artificial intelligence-based method such