

YAPAY SİNİR AĞLARI VE DESTEK VEKTÖR MAKİNELERİ YÖNTEMLERİYLE BORSA ENDEKSİ TAHMİNİ

PREDICTING STOCK-EXCHANGE INDEX USING METHODS OF NEURAL NETWORKS AND SUPPORT VECTOR MACHINES

Yrd. Doç. Dr. Emre YAKUT¹
Doç. Dr. Bekir ELMAS²
Yrd. Doç. Dr. Selahattin YAVUZ³

ÖZET

Günümüzde yapay sinir ağları ve destek vektör makineleri finans alanında borsa endeks tahmini, finansal başarısızlık tahmini ya da şirket bonolarının sınıflandırılması gibi birçok alanda istatistikî yöntemlere alternatif olarak giderek artan bir şekilde kullanılmaktadır. Yapay sinir ağı, birbirlerine paralel olarak çalışan, birçok basit işlem elemanından oluşan ve fonksiyonu, ağı yapısı, bağlantı ağırlıkları ve elemanlarda gerçekleştirilen işlemler tarafından belirlenen bir sistemdir. Destek vektör makineleri de yapay sinir ağlarıyla yakından ilişkili olup, sigmoid bir kernel fonksiyonu kullanan DVM; iki katmanlı, ileri beslemeli bir yapay sinir ağına sahiptir.

Bu çalışmada amaç ileri beslemeli yapay sinir ağları ve destek vektör makineleri yöntemleriyle BIST endeksinin etkin bir tahminin yapılıp yapılmayacağına ortaya konmasıdır.

Çalışmada Borsa İstanbul (BIST) endeksinin tahmin edilmesi için BIST endeksinin bir, iki ve üç gün öncesine ait değerleri yanında Amerikan doları kuru, gecelik faiz oranı ve NIKKEI (Japonya Borsası), BOVESPA (Brezilya Borsası), FTSE (İngiltere Borsası), CAC (Fransa Borsası), DAX (Almanya Borsası) internet sitelerinden elde edilen 2005-2012 tarihleri arasındaki borsa endeksi değerleri kullanılarak, BIST endeks değeri ileri beslemeli yapay sinir ağları ve destek vektör makineleri yöntemleriyle tahmin edilmiştir. Sonuç itibarı ile yapay sinir ağları ve destek vektör makineleri yöntemlerinin borsa endeksinin tahmin edilmesinde modellenebileceğini göstermiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, Destek Vektör Makineleri, Endeks, BIST

Jel Kodları: C50, C45

ABSTRACT

Recently neural networks and support vector machines prediction techniques are seen to be used increasingly in many finance problems such as Stock-Exchange Index financial distress prediction or classification of corporate bond as an alternative for statistical methods.. Neural Networks is conducted as a system working parallel to each other, composed of many simple elements of operation. Additionally the function is determined by structure of the network, connection weights (weights of the synapses) and performed operations in elements. Support vector machines (SVMs) which is closely related to artificial neural networks; SVM model using a sigmoid kernel the function is obtained using a two layer and feed forward neural network.

In the study, the purpose is to find out whether it is possible to predict BIST index value effectively or not by using feed forward artificial neural network and support vector machines methods.

¹ Osmaniye Korkut Ata Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, emreyakut@osmaniye.edu.tr

² Atatürk Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, belmas@atauni.edu.tr

³ Erzincan Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, syavuz@erzincan.edu.tr

In the study, BIST index value has been predicted by using America exchange rate of dollar, overnight interest rate and stock exchange index values obtained from NIKKEI (Japan Stock Exchange), BOVESPA (Brazil Stock Exchange), FTSE (England Stock Exchange), CAC (France Stock Exchange), DAX (Germany Stock Exchange) websites between 2005-2012 besides three days values of BIST index by feed forward artificial neural network and support vector machines methods. As a result, it can be said that artificial neural networks and support vector machines methods can be used to predict stock exchange index.

Key Words: Artificial Neural Networks, Support Vector Machines, Index, BIST

Jel Codes: C50, C45

1. GİRİŞ

Geçmiş dönem endeks değerlerine dayanarak, endeksin gelecekte alacağı değerleri öngörebilmek, finans alanında oldukça ilgi gören bir konudur. Borsa endekslerinde oluşan hareketlerin yönünü kesin olarak modelleyebilecek bir yöntem yoktur. Borsa endeksinin tahminini zorlaştıran nedenler yüksek belirsizlik ve oynaklıktır. Bu nedenle borsa yatırımları diğer tüm yatırım alanlarından daha fazla risk taşır (Kutlu ve Badur, 2009:27).

Hisse senedi yatırımlarında, yapılan yatırımın performansının değerlendirilmesi büyük önem taşır. Performansın ölçülmesinde ise en basit ve en temel araç olarak piyasa endekslerinden yararlanılmaktadır. Endeksin hareketine göre, yapılan yatırımın başarılı olup olmadığına karar verilmektedir. Özellikle başka ülkelerde yatırım faaliyetlerinde bulunan uluslararası yatırımcılar için bu endekslerin önemi daha da fazladır (Dağlı, 2000: 204).

Hisse senedi fiyatları ile genel ekonomik durum arasındaki ilişki uzun yıllardan beri çeşitli ekonomi ve finans uzmanlarının araştırmalarına konu olmuştur. Bazı araştırmacılar ekonomik göstergelerin yardımı ile hisse senedi fiyatlarında meydana gelebilecek bir artış veya azalışın önceden tahmin edilebileceğini savunmuşlardır (Albeni ve Demir, 2005: 2).

Hisse senetlerinin işlem gördüğü borsalar, dinamik, doğrusal olmayan, kaotik yapıda olduklarından bu piyasalarda tahmin yapmak zordur. Bununla beraber borsalar üzerinde siyasi olaylar, şirketlerin politikaları, genel ekonomik durum, yatırımcı beklentileri, kurumsal yatırımcıların seçimleri, diğer borsaların hareketleri ve yatırımcıların psikolojilerini etkilemektedir (Kara, vd., 2011: 5311).

Yapay sinir ağı (YSA) ve destek vektör makineleri (DVM) uygulamaları borsa endeksi çalışmalarının başında gelmektedir. Son zamanlarda YSA ve DVM öngörü amacıyla yaygın olarak kullanılmaya başlanmıştır. Yapılan araştırmalar neticesinde YSA yönteminin öngörü için kullanılan diğer birçok yöntemlere göre başarılı olduğu gözlenmiştir.

Wittkemper ve Steiner (1996) ise hisse senetlerinin sistematik riskinin tahmininde; Malliaris ve Salchenberger (1996) gelecek volatilité değerlerinin öngörüsünde yapay sinir ağlarını kullanmışlardır. Saad vd. (1998) hisse senetlerinin fiyat tahmini problemlerinde; Hamzaçebi ve Bayramoğlu (2007), YSA'lar ile hisse senedi endekslerinin tahmininde YSA ele almışlardır. Çinko ve Avcı, (2007) İMKB-100 endeksinin tahminine yönelik çalışmalarında yapay sinir ağlarının regresyon modellerine göre daha iyi sonuçlar verdiğini gözlemlemiştir. Yıldız vd., (2008) tarafından yapılan çalışmada İMKB-100 endeksinin yön tahmini etmek amacıyla YSA kullanılmıştır. Analiz için İMKB en yüksek, en düşük kapanış değerleri ile ABD doları kuru analiz için kullanılmıştır. Kutlu ve Badur (2009), borsa endeksi tahmini yapmışlardır. Çalışmanın diğer bir yöntemi olan DVM, görüntü ve metin sınıflandırma, nesne tanıma, el yazısı tanıma, ses tanıma ve yüz tanıma gibi çeşitli

örüntü tanıma uygulamaların da sıkça kullanılmaktadır. DVM pratikte daha çok sınıflama ve regresyon amacıyla kullanılmaktadır. Kim (2003) yaptığı çalışmada KOSPI endeksinin yönünü günlük verilerinin tahmininde; Kara vd. (2011) yapay sinir ağları ve destek vektör makineleri yöntemlerini kullanarak BIST 100 endeksinin yönünü tahmininde; Akcan ve Kartal, (2011) İMKB sigorta sektörü endeksini oluşturan yedi adet şirketin hisse senedi fiyatlarını YSA ile tahmin etmişlerdir. Modelde İMKB-100 endeksi günlük kapanış değeri, tüketici fiyat endeksi, dolar efektif satış kuru, günlük cumhuriyet altını fiyatı makroekonomik değişkenleri kullanılmıştır.

Çalışmanın amacı, yapay sinir ağları ve destek vektör makineleri yöntemleriyle BIST endeksinin etkin bir tahminin yapıp yapılmayacağıının belirlenmesidir. Çalışma üç bölümden oluşmaktadır. Birinci bölümde yapay sinir ağları ve destek vektör makineleri genel hatları itibari ile tanıtılmıştır. İkinci bölümde BIST endeksinin günlük değerleri için yapay sinir ağları ve destek vektör makineleri ile 2011-2012 dönemine ait öngörü uygulaması yapılmıştır. Üçüncü bölümde ise, analizden elde edilen sonuçlara ilişkin tartışma yer almıştır.

1.1. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan kendiliğinden gerçekleştirmek amacı ile biyolojik sinir ağlarından esinlenilerek geliştirilen bilgisayar sistemleridir. (Fausett, 1994:3; Öztemel, 2003:30).

Yapay sinir ağlarının herhangi bir olay hakkındaki girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilmesi, algoritmik çözümü bulunamamış problemlerin çözümlenmesinde kullanımını artırmıştır.

Yapay sinir ağlarındaki en büyük problem karmaşık problemleri çözmek için çok katmanlı ve çok nöron içeren yapay sinir ağlarına ihtiyaç olmasıdır (Kohonen,1987: 1-79)

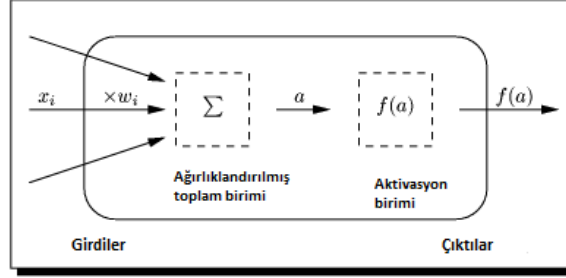
Yapay sinir hücreleri bir araya gelerek YSA'yı oluştururlar. Sinir hücrelerinin bir araya gelmesi rasgele olmaz. Genel olarak hücreler 3 katman halinde ve her katman içinde paralel olarak bir araya gelerek ağı oluştururlar. Bu katmanlar (Öztemel, 2003: 31-33):

- Girdi katmanı: Bu katmandaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer etmekle sorumludurlar. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmaz.
- Ara katmanlar: Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderirler. Bu bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ için birden fazla ara katman olabilir.
- Çıktı katmanı: Bu katmandaki proses elemanları ara katmandan gelen bilgileri işleyerek ağı girdi katmanından sunulan girdi seti (örnek) için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir.

Genel olarak yapay sinir ağları modellerini; a) Ağı yapısına, b) ileri beslemeli (feed forward), c) geri beslemeli (feed back), d) ağırlık matrislerinin simetrik veya asimetric oluşuna e) ağırlık matrisi değerlerinin sabit veya değişken oluşuna, f) Ağda yer alan düğümlerin özelliklerine, g) Kullanılan eşik fonksiyonuna, h) Düğüme sadece analog / ikil veya sürekli değerlerin uygulanabilmesine, j) Eğitim veya öğrenme kurallarına bağlıdır (Şen, 2004: s.183).

Basit bir yapay sinir ağı modeli Şekil 1’de verilmiştir. Girdi ve çıktı katmanından oluşan bir ağıdır. Her ağı bir veya daha fazla girdisi ve çıktısı vardır. Çıktı üniteleri (Ç) bütün girdi ünitelerine (X) bağlanmaktadır ve her bağlantının bir ağırlığı (W) vardır. Bu ağılarda proses elemanlarının değerinin sıfırdan farklı olmasını önleyen eşik değeri vardır ve bu değer daima 1’dir.

Şekil 1: Tek Katmanlı Algılayıcı Yapısı



Kaynak: (Hristev, 1998: 4).

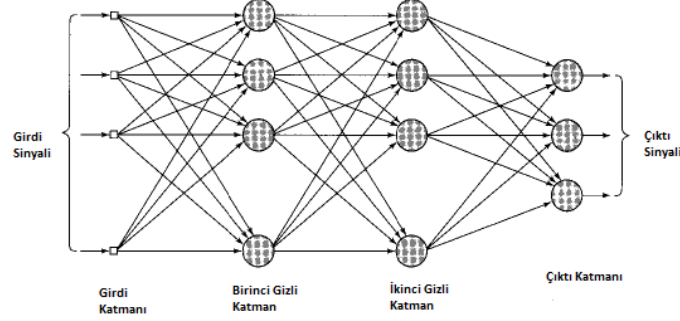
Tek katmanlı yapay sinir ağlarında ağırlıklandırılmış giriş değerleri eşik değeri (θ) ile toplanarak aktivasyon fonksiyonundan geçerek çıktıya ulaşır. Bu durum matematiksel olarak,

$$f(a) = \left(\sum_{i=1}^m W_i X_i + \theta \right)$$

şeklinde formülize edilir. Burada,

W_i : i'ninci girdi değerinin ağırlığını, θ : Eşik değerini, $f(a)$: Çıktı değerini, göstermektedir. Çok katmanlı yapay sinir ağları modeli Rumelhart ve arkadaşları tarafından geliştirilmiştir. Bu modele hata yayma modeli veya geri yayılım modeli (backpropagation network) ile denilmektedir (Öztemel, 2003:76). ÇKA modelinde geriye yayılım algoritması kullanılmaktadır. ÇKA ağına öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının geliştirilmiş halidir. Bu yüzden öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denmektedir. Geri yayılım algoritmasında kullanılan “delta kuralı” na göre bir nöronun gerçek çıktı değeri ile istenilen çıktı değeri arasındaki farkı azaltmak için giriş bağlantılarını yani ağırlıkları sürekli ayarlama ve geliştirme fikrine dayalı bir kuraldır (Kartalopoulos, 1996:46). Bu kuralda, öğrenme esnasındaki bağlantı ağırlıkları sürekli değiştirilerek, ağırlıklar için optimum değer bulunur. Bu ağ yapısında “Öğretmenli Öğrenme” yöntemi kullanılır. Öğretmenli öğrenmede hedef çıktı değerleriyle ilişkilendirilen her bir vektör, ağına öğrenmesi için ağına sunulur. Ağırlıklar, belirtilen öğrenme kuralına dayanarak düzeltilir (Hamid & Iqbal, 2004:1119). Şekil 2’de örnek bir geri yayılma ağı verilmiştir.

Şekil 2: Örnek Geri Yayılma Ağı



Kaynak: (Haykin, 1999: 159).

Literatürde yapay sinir ağları ile yapılan bazı çalışmalar aşağıda verilmiştir.

Diler (2003), İMKB 100 endeksinin günlük yönünü tahmin etmek için 1990–2003 dönemi arasında yedi teknik analiz göstergesi kullanarak yapay sinir ağları yöntemi ile tahmin işlemini gerçekleştirmiş, modelin tahmin başarısını %60,8 oranında tespit etmiştir. Altay ve Satman (2005), yapay sinir ağları ve regresyon yöntemlerini günlük, haftalık ve aylık verileri kullanarak İMKB 30 ve İMKB tüm endekslerinin yönünü tahmin etmeye çalışmışlardır. Yapay sinir ağlarının endeksin yönünü günlük, haftalık ve aylık olarak sırasıyla %57,8, %67,1 ve %78,3'lik bir başarı ile tahmin etmişlerdir.

1.2. Destek Vektör Makineleri

Bir destek vektör makinesi, verileri optimal olarak iki kategoriye ayıran $n -$ boyutlu bir hiperdüzlem oluşturmaktadır. DVM modelleri yapay sinir ağlarıyla yakından ilişkili olup, sigmoid bir kernel fonksiyonu kullanan DVM; iki katmanlı, ileri beslemeli bir yapay sinir ağına sahiptir (Haykin, 1999: 318).


DVM'nin ilgi çekici özelliği; veri seti üzerinde ortalama hata karesini minimize ederek türetilen ampirik risk minimizasyonu prensibinden ziyade, istatistiksel öğrenme teorisindeki yapısal risk minimizasyonu niteliğinde çalışmasıdır. DVM'nin temel varsayımlarından biri, eğitim kümesindeki tüm örneklerin bağımsız ve benzer olarak dağılmış olmasıdır (Song, vd., 2012: 440).

DVM, sınıflandırma ve regresyon problemlerinde çalıştırılabilir. DVM regresyon metodundaki temel fikir, eldeki eğitim verilerinin karakterini mümkün olduğunca gerçeğe yakın bir şekilde yansıtan ve istatistiksel öğrenme teorisine uyan doğrusal ayırıcı fonksiyonun bulunmasıdır. Sınıflandırmaya benzer bir şekilde regresyonda da doğrusal olmayan durumların işlenebilmesi için çekirdek fonksiyonları kullanılır (Çomak, 2008: 37).

Destek Vektör Makinelerinde karşılaşılabilecek iki durum, verilerin lineer olarak ayrılabilirleri bir yapıda olması veya lineer olarak ayrılabilen yapıda olmasıdır.


Lineer Ayrılabilir Durumu: Eğitim için kullanılacak N elemandan oluşan verinin $\theta = \{x_i, y_i\}$, $i = 1, 2, \dots, N$ olduğu varsayalım. Burada $y_i \in \{-1, 1\}$ etiket değerleri ve $x_i \in R^d$ özellikler vektörüdür. Lineer olarak ayrılabilir durumda, bu iki değerli veriler direkt olarak bir aşırı düzlem ile ayrılabilir. Bu aşırı düzleme ayırıcı aşırı düzlem adı verilir. Destek Vektör Makinelerinin amacı bu aşırı düzlemin iki ayrı sınıfta bulunan örnek grubuna eş uzaklıkta olmasını sağlamaktır.

Şekil 3: Lineer Ayrılabilme Durumunda Optimum Ayırıcı Aşırı Düzlem



Lineer Ayrılama Durumu: Lineer ayrılabilme durumunda veriler iki sınıfa doğrusal bir düzlem ile ayrılabilirdi. Uygulamada bu durum her zaman geçerli olmayabilir. Yani doğrusal bir düzlem ile veriler birbirinden ayrılmayabilir.

Şekil 4: Birbirinden Doğrusal Olarak Ayrılamayan Veriler



Kaynak: (Özkan, 2008:195).

Verilerin doğrusal olarak ayrılamadığı durumlarda doğrusal sınıflandırıcı yerine doğrusal olmayan sınıflandırıcılar kullanılabilir. Bu bağlamda Doğrusal Olmayan Özellik Uzayı: $x \in R^n$ gözlem vektörünü daha yüksek dereceden bir uzayda z vektörüne dönüştürerek, bu yeni uzayda doğrusal sınıflandırıcıları elde etmek söz konusu olabilir. Bu z vektörünün yer aldığı özellik uzayı F ile gösterilsin. Bu durum da \emptyset ifadesi $R^n \rightarrow R^F$ eşlemesini yapmak üzere $z = \emptyset(x)$ biçiminde ifade edilebilir (Yakut, 2012: 49).

$$x \in R^n \rightarrow z(x) = [a_1, \emptyset_1(x), \dots, a_n, \emptyset_n(x)]^T \in R^F$$

Doğrusal olmayan ayrılabilirlik durumu düşünüldüğü zaman, eğitim örnekleri orijinal giriş uzayında doğrusal olarak ayrılamazlar. Bu tip durumlarda DVM, doğrusal olmayan haritalama fonksiyonu yardımıyla orijinal giriş uzayından doğrusal olarak kolayca sınıflandırma yapabileceği yüksek boyutlu nitelik uzayına dönüşüm yapar. Böylece çekirdek fonksiyonları kullanılarak bütün değerlerin tekrar tekrar çarpım değerlerinin hesaplanarak bulunması yerine doğrudan çekirdek fonksiyonunda değerin yerine koyularak nitelik uzayındaki değerinin bulunması sağlanır. Bu sayede, son derece yüksek boyutlu bir nitelik uzayı ile uğraşma olasılığı kalmaz. Çekirdek fonksiyonlarının diğer bir avantajı da, eğitime aşamasında bir eğitim örneği için fonksiyon kurulup değerler bulunduktan sonra diğer örnekler için artık kalıp değerleri eğitim örneği dışında tamamen hazır olduğu için çok daha kolay hesaplanmasıdır (Kecman, 2001: 169).

DVM yaygın olarak kullanılan dört çekirdek fonksiyonu vardır. Bu fonksiyonlar:

1. Doğrusal Fonksiyon,
2. Polinomiyal Fonksiyon
3. Sigmoid Fonksiyon,

4. Radyal Tabanlı Fonksiyon

Literatürde destek vektör makineleri ile yapılan bazı çalışmalar aşağıda verilmiştir.

Kim (2003), tarafından yapılan çalışmada Kore Borsası (KOSPI) endeks yönünün günlük verilerle tahmini için destek vektör makineleri ve yapay sinir ağlarını kullanılmıştır. Verilerin %80'sini eğitim ve %20'sini test kümesi olarak ele almıştır. Analiz sonucuna göre DVM (%57,83), YSA (%54,73) başarı sonucuna ulaşmıştır. Huang vd., (2005), Japonya Borsasında (NIKKEI-225 endeksinin) haftalık değişim yönünü tahmin etmek için DVM yöntemini kullanmışlardır. NIKKEI borsasının değişim yönünü tahmin etmek için Standart and Poor-500 endeksi ve Japon Yeni Amerikan Doları kuru modelde girdi değişkenler olarak kullanılmıştır. Özdemir vd. (2011) endeks getirisi yönünün ikili sınıflandırma yöntemiyle tahmin edilmesinde DVM'yi kullanmışlardır.

2. YÖNTEM

2.1. Borsa Endeks Değeri Tahmini Sistem Modelleri

Bu çalışmada amaç ileri beslemeli yapay sinir ağları ve destek vektör makineleri yöntemleriyle BIST endeksinin etkin bir tahminin yapılıp yapılamayacağını ortaya konulmasıdır. Çalışmada yapay sinir ağları için ileri beslemeli yapay sinir ağlarından geri yayılım algoritması ve destek vektör makineleri yöntemlerinden ise sigmoid bir kernel fonksiyonu denenmiştir. Yapay sinir ağları ve destek vektör makineleri son yıllarda kullanımının gittikçe artmasının yanı sıra, örneklerden öğrenme yapabilmesi, genelleme yapabilmesi ve istatistiksel yöntemlere kıyasla daha az varsayımları içermesinden dolayı analizde çalışma yöntemleri olarak seçilmiştir.

Borsa endeksini etkileyen çalışmalar incelendiğinde: Brigham (1995), faiz oranlarının hisse senetleri ve tahviller arasındaki rekabeti etkileyen en önemli unsur olduğunu ifade etmiştir. Fang-Loo (1996), hisse senetleri ile döviz kurunda meydana gelen değişimler arasında negatif yönlü bir ilişki olduğunu beyan etmişlerdir. Seler (1996), borsa endeksinin pazartesi ve salı günlerinin artış oranları, perşembe ve cuma günleri artış oranlarından daha düşük olduklarını ileri sürmüştür. Borsa endeksi üzerinde etkili olan değişkenler ekonomideki büyüme hızı, altın fiyatları, faiz oranı, enflasyon v.b. makroekonomik değişkenlerdir. (Durukan, 1999:25). Özalp ve Anagün (2003), hisse senedinin fiyatını; işlem adedi, işlem hacmi, dolar kuru, bileşik endeksi, TEFE, TÜFE gibi ekonomik göstergelerin değerlerindeki değişmelerin etkilediğini ileri sürmüşlerdir. Yüksel ve Gülerüz (2010), bir ülkenin menkul kıymetler borsası hem genel hem de sektörel ekonomiyi ilgilendiren iç ve dış faktörlerden etkilendiğini ifade etmişlerdir.

Modellerde kullanılacak değişkenlerin belirlenmesinde, yukarıda bahsedilen çalışmalardan hareketle borsa endeksinin tahminlenmesinde sırasıyla bir, iki ve üç önceki günün endeks değerlerinin yanında Amerikan dolar kuru, gecelik faiz oranı ve Japonya, Brezilya, İngiltere, Fransa ve Almanya'nın da borsa endeksi değerleri dikkate alınmıştır. Çıktı (bağımlı) değişkenlerinin t zamandaki değerlerinin, girdi değişkenlerinin t-1 (bir gün öncesinden), t-2 (iki gün öncesinden) ve t-3 (üç gün öncesinden) zamanındaki değerlerinden etkilendiği varsayılarak 2005-2010 yılları arasındaki verilerle modellerin eğitim ve test aşaması olmak üzere ikiye ayrılmıştır.

Bu çalışmada ele alınan girdi değişkenleri aşağıda verilmiştir.

- Bir önceki günün endeks değeri (BÖE),
- İki önceki günün endeks değeri (İÖE),

- Üç önceki günün endeks değeri (ÜÖE),
- Önceki günlere ait Amerikan dolar değeri (Ö\$)
- Önceki günlere ait faiz oranı (ÖFO),
- Hafta günlerini belirten 5 kukla değişken (P, S, Ç, PE, C). Değişken değerleri 1 ya da 0 olarak alınmıştır. Cuma günü için C değeri 1 ve P, S, Ç, PE değerleri 0 olarak kullanılmıştır.
- Önceki günlere ait olan Japonya (J), Brezilya (B), İngiltere (İ), Fransa (F), Almanya (A) borsa endeks değerleri alınmıştır.

Kutlu ve Badur'un (2009) çalışmasında kullanılan değişkenlere ek olarak iki ve üç gün önceki BIST endeksi değerleri alınarak 9 farklı Model kullanılmıştır.

Model 1: f_{Model1} (BÖE, Ö\$, ÖFO)

Model 2: f_{Model2} (BÖE, Ö\$, ÖFO, P, S, Ç, PE, C)

Model 3: f_{Model3} (BÖE, Ö\$, ÖFO, P, S, Ç, PE, C, J, B, İ, F, A)

Model 4: f_{Model4} (İÖE, Ö\$, ÖFO)

Model 5: f_{Model5} (İÖE, Ö\$, ÖFO, P, S, Ç, PE, C)

Model 6: f_{Model6} (İÖE, Ö\$, ÖFO, P, S, Ç, PE, C, J, B, İ, F, A)

Model 7: f_{Model7} (ÜÖE, Ö\$, ÖFO)

Model 8: f_{Model8} (ÜÖE, Ö\$, ÖFO, P, S, Ç, PE, C)

Model 9: f_{Model9} (ÜÖE, Ö\$, ÖFO, P, S, Ç, PE, C, J, B, İ, F, A)

2.2. Veri Kümesi

Veriler BIST ve NIKKEI (Japonya Borsası), BOVESPA (Brezilya Borsası), FTSE (İngiltere Borsası), CAC (Fransa Borsası), DAX (Almanya Borsası) internet sitelerinden 03.01.2005 ile 31.12.2012 tarihleri arasından 1998 işgününe ait veri değerleri alınmıştır. 2005-2010 yılları arasındaki veriler alınarak modeller kurulmuş 2011-2012 dönemine ait ileriye yönelik öngörü değerleri elde edilmiştir.

Verilerin %80'lik kısmıyla eğitim kümesi ve geri kalan %20'lik kısmıyla da test kümesi oluşturulmuştur. Yapay sinir ağları ve destek vektör makineleri yöntemlerinin kullanımı için Statistica 8.0 yazılımından yararlanılmıştır. Tahmini endeks değerleri ile gerçek endeks değerleri karşılaştırılarak R^2 , MPE, MSPE, RMSPE ve MAPE ile değerlendirilmiştir.

2.3. YSA Ağ Parametreleri

Modeller için ileri beslemeli yapay sinir ağı bir gizli katman kullanılmıştır. Gizli katmandaki nöron sayısı 4 olarak belirlenmiştir. Kullanılan ağı parametreleri şunlardır.

Tablo 1: Kullanılan Ağın Parametreleri

Ağın türü	Çok Katmanlı Perseptron
Öğrenme Algoritması	Geri Yayılım
Öğrenme Kuralı	Momentum
Giriş Katmanındaki Düğüm Sayısı	3-8-13
Gizli Katman Sayısı	1
Gizli Katmandaki Düğüm Sayısı	4
Çıkış katmanındaki Düğüm Sayısı	1
Öğrenme Oranı	0,01
Devir Sayısı	500
Gizli Katmanlar için Transfer Fonksiyonu	Tansig
Çıktı Katman İçin Transfer Fonksiyonu	Purelin
Geri Yayılım Ağının Eğitim Fonksiyonu	Trainlm

YSA uygulamasında kullanılan Çok Katmanlı Perseptron günümüzde en yaygın olarak kullanılan çok katmanlı algılayıcıdır (Öztemel, 2003:112). Tablo 1’de bahsedilen yapay sinir ağları parametrelerinin belirlenmesinde çok defa deneme yanılma yöntemi kullanılmış ve çok sayıda test işlemi gerçekleştirilmiştir. Bu kapsamda gizli katman sayısı, gizli katmanlardaki düğüm sayısı, momentum terimi, aktivasyon fonksiyonu, devir sayısı gibi parametrelerin çeşitli kombinasyonları denenerek gerek eğitim seti üzerinde gerekse test seti üzerinde daha iyi performansı gösteren ağ saptanmıştır. Öğrenme oranı yapay sinir ağlarında ağın öğrenme performansı ile yakından ilişkilidir. Literatürde bahsedilen öğrenme oranı 0,4’e kadar çıkabilmektedir. Öğrenme oranının yüksek seçilmesi ağın öğrenme kabiliyetini azaltacaktır.

2.4. Destek Vektör Makineleri Kullanarak Doğrusal Regresyon Fonksiyonu

$(x_1, y_1), \dots, (x_k, y_k)$ ile gösterilen k örnek kütleli verilen eğitim verisi için, $f(x, \alpha) = (w, x) + b$ ($w \in \mathbb{R}^N$ ve $b \in \mathbb{R}$) ile bir karar fonksiyonu gösterilebilir. Doğrusal bir karar fonksiyonu (w, x) , \mathbb{R}^N uzayında nokta çarpımı ifade etmektedir. w ’nin küçük bir değeri, $f(x, \alpha) = (w, x) + b$ ’in seviyesini göstermektedir ve $\|w\|^2$ ile tanımlanan Öklid normunun minimize edilmesiyle gerçekleşmektedir. Regresyon için optimizasyon problemi şu şekilde ifade edilebilir: (Pal ve Goel, 2006:50).

$$\begin{aligned} & \text{Min} \frac{\|w\|^2}{2} \\ & y_1 - (w, x_i) - b \leq \varepsilon \\ & (w, x_i) + b - y_i \leq \varepsilon \end{aligned}$$

Optimizasyon problemi, ε ’dan küçük olan tüm eğitim çiftleri üzerinde bir hata sağlayan bir fonksiyonun var olduğu varsayımına dayanmaktadır. ε duyarlılığa sahip olduğunda, problem uygundur. Daha fazla hataya izin vermek için ξ ve ξ' aylak değişkenleri tanımlanabilir ve böylelikle optimizasyon problemi şu şekilde yazılabilir.

$$\begin{aligned} & \text{Min} \frac{\|w\|^2}{2} + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ & y_1 - (w, x_i) - b \leq \varepsilon + \xi_i \end{aligned}$$

$$(w, x_i) + b - y_i \leq \varepsilon + \xi_i^*$$

$$\text{ve } \xi_i, \xi_i^* \geq 0$$

3. MODELLERİN SONUÇLARI

Bu çalışmada 9 farklı Modeller Statistica 8.0 yazılımının YSA ve DVM eklentisi ile analiz edilmiştir. Tahmin edilen değerlerin yaklaştığını ölçmek için, Burada; y_t = Gerçek gözlem değerleri, \hat{y}_t = Tahmin edilen değerleri, T= Tahmin sayısıdır.

Doğruluk ölçütleri ve formülleri Tablo 2’de gösterilmiştir (Hatipoğlu, vd., 2013: 66):

Tablo 2: Doğruluk Ölçütleri ve formülleri

$MSE = \frac{1}{T} \sum (y_t - \hat{y}_t)^2$	Hataların Kareli Ortalaması
$MAE = \frac{1}{T} \sum y_t - \hat{y}_t $	Ortalama Mutlak Hata
$MPE = \frac{1}{T} \sum \frac{(y_t - \hat{y}_t)}{y_t}$	Ortalama Yüzde Hata
$MSPE = \frac{1}{T} \sum \left[\frac{(y_t - \hat{y}_t)}{y_t} \right]^2$	Ortalama Yüzde Hata Kareleri
$RMSPE = \sqrt{\frac{1}{T} \sum \left[\frac{(y_t - \hat{y}_t)}{y_t} \right]^2}$	Ortalama Yüzde Hata Kareleri Kökü
$MAPE = \frac{1}{T} \sum \left \frac{(y_t - \hat{y}_t)}{y_t} \right $	Ortalama Mutlak Yüzde Hata

Tablo 3: YSA Belirlilik Katsayısı (R2) ve Yüzde Doğruluk Ölçüt Değerleri


YSA	R KARE	MPE	MSPE	RMSPE	MAPE	MSE	RMSE
M1	0,972	0,008873	0,000310	0,017611	0,013548	1081212	1039,813
M2	0,972	-0,006234	0,000283	0,016837	0,013454	1099639	1048,637
M3	0,958	0,015254	0,000465	0,021554	0,017785	1738745	1318,615
M4	0,964	0,002747	0,000416	0,020398	0,014927	1440669	1200,279
M5	0,955	0,004122	0,000462	0,021490	0,000462	1612441	1269,819
M6	0,963	0,002494	0,000422	0,020552	0,000422	1517172	1231,735
M7	0,943	-0,001928	0,000647	0,025445	0,000647	2263292	1504,424
M8	0,924	0,011056	0,000824	0,028710	0,000824	2740904	1655,568
M9	0,911	-0,018450	0,001124	0,033521	0,001124	4256648	2063,165

Analizde kullandığımız YSA ve DVM yöntemleri için 2005-2010 yılları arasındaki toplam 1496 verinin %80’lik kısmına karşılık gelen 1196 veri ile eğitim aşaması; geri kalan %20’lik kısmına karşılık gelen 300 veri ile test aşaması gerçekleştirilmiştir.


Yapay sinir ağları modellerinin karşılaştırılmasında kullanılan belirleme katsayısı, ortalama yüzde hata, ortalama yüzde hata kareleri, ortalama yüzde hata kareleri kökü, ortalama mutlak yüzde hata, hataların kareleri ortalaması ve hataların kareli ortalamasının karekökü kriterlerinin 2011-2012 dönemine ait değerleri Tablo 3’de gösterilmiştir. Sonuçlara göre yapay sinir ağları modeli kullanıldığında 9 farklı model için R^2 değerleri 0,91 ile 0,97 arasında değer elde edilmiştir. Determinasyon katsayısı R^2 ile gösterilir. Korelasyon katsayısının karesi determinasyon katsayısını verir. Bu değerler mesela %90 çıkması halinde toplam değişimin %90’ını kurulan modelle, yani bağımsız değişken veya değişkenler tarafından belirlenmiştir. %10’u ise ya tesadüfen meydana gelmiş veya dikkate alınmayan başka değişkenlerce belirlenmiştir (Başar ve Oktay, 2007: 103). 9 farklı Model için R^2 (determinasyon katsayısı) düzeyinde bir karşılaştırma yapıldığında borsa endeksini en iyi tahmin eden modellerin M1 ve M2 modelleri olduğu söylenebilir. Bu modellerin R^2 değerleri %97 olarak gerçekleştiğini söyleyebiliriz.

Tahmin performans ölçümleri için literatürde en çok kullanılan formüller MAPE (Mutlak Hata Oranları Ortalaması) ve MSE (Hata Kareleri Ortalaması) değerlerine bakılmaktadır (Zhang and Hu, 1998:500, Cho, 2003:328). Lewis (2002), MAPE değerleri %10’un altında olan modelleri “çok iyi”, %10 ile %20 arasında olan modelleri “iyi”, %20 ile %50 arasında olan modelleri “kabul edilebilir” ve %50’nin altında olan modelleri ise “yanlış ve hatalı” olarak gruplamıştır. Buradan hareketle M1 ve M2 modellerinin MAPE değerleri %10’un altında gerçekleşmesi sebebiyle bu modellerin Lewis’e göre çok iyi modeller oldukları ifade edilebilir.

Grafik 1: Model 1: Karşılaştırmalı YSA Tahmini - Gerçek Değerler



Grafik 2: Model 2: Karşılaştırmalı YSA Tahmini - Gerçek Değerler

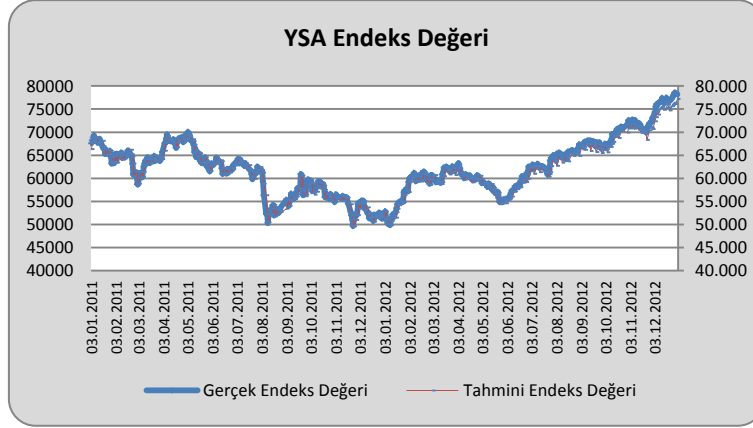


Grafik 1 ve Grafik 2’de YSA’dan elde edilen en iyi iki modelin tahmin sonuçları ile gerçek verilere ait rakamların karşılaştırmalı grafikleri verilmiştir. Bu grafiklerle geliştirilen modellerin çok iyi olduklarını ve güvenle kullanılabilceğini göstermektedir. Klasik istatistiksel yöntemler (regresyon) tahminleme aşamasında kısmen başarılı olabildikleri için son yıllarda örneklerden öğrenme yapabilen, genelleme yeteneğine sahip ve istatistiksel yöntemlere göre daha az varsayımları olan makine öğrenmesi yöntemlerinden olan YSA ve DVM yöntemleri tercih edilmiştir.

YSA’nın kısıtlı olduğu konulara değinilecek olursa probleme uygun yapısının belirlenmesi genellikle deneme yanılma yoluyla yapılması önemli bir problemdir. Bazı ağlarda ağıın parametre değerlerinin her katmanda olması gereken proses elemanı sayısı, katman sayısı vb. belirlenmesinde de bir kural olmaması diğer bir problemdir (Öztemel, 2003:34).

YSA'dan elde edilen 2011-2012 dönemine ait öngörü sonuçları ile gerçek veriler arasında anlamca fark olmadığını göstermektedir. Ayrıca bu iki modelin korelasyon katsayısı $R=0,985$ bulunmuştur. Buna göre iki grup veri (Ölçülen veriler-YSA Verileri) arasında kuvvetli bir ilişki vardır sonucuna varılmıştır. Grafikler incelendiğinde YSA'dan elde edilen verilerin ölçülen değerlerle benzer olduğu görülmektedir. Model 2'nin Model 1'e göre R^2 düzeyinde %0,03 olarak biraz daha iyi olduğunu söyleyebiliriz.

Grafik 3: Model 2 için Oluşan Değerler ile YSA Öngörülerinin Karşılaştırılması




Grafik 3'de; bir önceki günün endeks değerini (BÖE), önceki günün Amerikan dolar değerini (ÖŞ), önceki günün gecelik faiz oranını (ÖFO) ve haftanın günlerini belirten 5 kukla değişkenin değerlerini girdi olarak alan M2 modeline ait gerçek ve tahmini endeks değerleri arasındaki sapma gözlenebilmektedir.

Tablo 4: DVM Belirlilik Katsayısı (R^2) ve Yüzde Doğruluk Ölçüt Değerleri

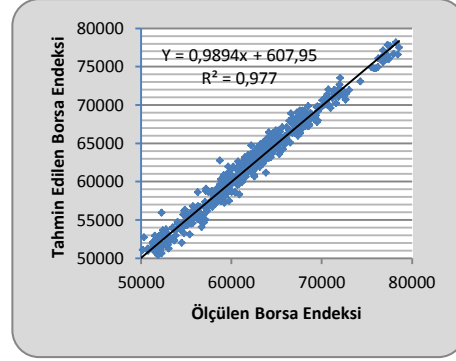
DVM	R KARE	MPE	MSPE	RMSPE	MAPE	MSE	RMSE
M1	0,939	-0,016238	0,000547	0,023383	0,019975	2330289	1526,528
M2	0,970	-0,003464	0,000311	0,017646	0,013709	1162788	1078,326
M3	0,977	-0,000753	0,000261	0,016148	0,012648	957332,6	978,4338
M4	0,898	0,028238	0,001304	0,036115	0,030038	4967967	2228,894
M5	0,915	0,011400	0,000969	0,031136	0,024228	3443679	1855,715
M6	0,957	-0,001901	0,000514	0,022682	0,017666	1863286	1365,022
M7	0,944	0,005111	0,000734	0,027087	0,019566	2523425	1588,529
M8	0,909	0,005321	0,001072	0,032737	0,024372	3763867	1940,069
M9	0,938	0,003623	0,000697	0,026398	0,020085	2479781	1574,732

Destek Vektör Makineleri modelleri için elde edilen değerler Tablo 4'de gösterilmiştir. Sonuçlara göre DVM modeli kullanıldığında 9 farklı model için R^2 değerleri 0,898 ile 0,977 arasında değer elde edilmiştir. 9 farklı Model için R^2 düzeyinde bir karşılaştırma esas alındığında borsa endeksini en iyi tahmin eden modellerin M2 ve M3 modelleri oldukları ifade edilebilir. Bu modellerin R^2 değerleri sırasıyla %97-%97,7 olarak gerçekleştiğini ifade edebiliriz. Bununla birlikte M2 ve M3 modellerinin MAPE değerleri %1 civarında gerçekleştikleri için Lewis'e göre çok iyi modeller olduklarını söyleyebiliriz.

Grafik 4: Model 2: Karşılaştırmalı DVM Tahmini - Gerçek Değerler




Grafik 5: Model 3: Karşılaştırmalı DVM Tahmini - Gerçek Değerler



Grafik 4 ve Grafik 5’de DVM’den elde edilen en iyi iki modelin tahmin sonuçları ile gerçek verilere ait rakamların karşılaştırmalı grafikleri verilmiştir. DVM’den elde edilen 2011-2012 dönemine ait öngörü sonuçları ile gerçek veriler arasında anlamca fark olmadığını göstermektedir. M2 ve M3 modellerine ait korelasyon katsayısı sırasıyla $R_2=0,985$ ve $R_3=0,988$ olarak hesaplanmıştır. Buna göre iki grup veri (Ölçülen veriler-DVM Verileri) arasında kuvvetli bir ilişki vardır sonucuna varılmıştır. Grafikler incelendiğinde DVM’den elde edilen verilerin ölçülen değerlerle benzer olduğu görülmektedir. Model 3’ün Model 2’ye göre R^2 düzeyinde %0,83 olarak biraz daha iyi olduğunu söyleyebiliriz.

Grafik 6: Model 3 için Oluşan Değerler ile DVM Öngörülerinin Karşılaştırılması



Grafik 6’da; bir önceki günün endeks değerini (BÖE), önceki günün Amerikan dolar değerini (Ö\$), önceki günün gecelik faiz oranını (ÖFO) ve haftanın günlerini belirten 5 kukla değişkenin değerlerini ve bir önceki günün Japonya’nın (J), Brezilya’nın (B), İngiltere’nin (İ), Fransa’nın (F) ve Almanya’nın (A) borsa endeks değerlerini girdi olarak alan M3 modeline ait gerçek ve tahmini endeks değerleri arasındaki sapma gözlenebilmektedir.

3.1. İstatistiksel Analizi

Yapay sinir ağları ve destek vektör makineleri yöntemlerinden elde edilen değerler ile gerçek değerler arasında anlamlı fark bulunup bulunmadığını ölçmek için hipotez testi yapılmıştır. Bu karşılaştırmayı yapabilmek için gerekli formüller ve elde edilen değerler sırasıyla Tablo 5 ve Tablo 6’da verilmiştir.

Tablo 5: Büyük Örneklem için Z Testi

Boş Hipotez	$H_0 = \mu_1 - \mu_2 = \text{Boş hipotez}$
Test İstatistiği	$Z = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$
Alternatif Hipotez	Red Alanı
$H_a = \mu_1 - \mu_2 > \text{Boş hipotez}$	eğer $Z > Z$ kritik değer H_0 red sağ kuyruk testi
$H_a = \mu_1 - \mu_2 < \text{Boş hipotez}$	eğer $-Z < -Z$ kritik değer H_0 red sol kuyruk testi
$H_a = \mu_1 - \mu_2 \neq \text{Boş hipotez}$	eğer $Z > Z$ kritik değer eğer $-Z < -Z$ kritik değer H_0 red

Tablo 6: YSA ve DVM Yöntemlerinin Ortalama ve Std. Sapma Değerleri

Yöntemler	YSA		DVM	
	Ortalama değer	Std Sapma	Ortalama değer	Std Sapma
M1	62792,77	6035,68	61151,77	5446,92
M2	61831,54	5904,86	61981,25	5893,01
M3	63198,85	6258,98	62177,29	6173,91
M4	62403,02	6064,34	63999,00	6602,76
M5	62430,58	5733,72	62894,66	6032,90
M6	62374,67	6181,68	62110,62	6284,10
M7	62066,49	5895,66	62551,26	6432,16
M8	62848,28	5714,19	62514,36	6023,01
M9	61064,75	6087,15	62420,28	6024,31

Tablo 6’da YSA ve DVM yöntemleriyle elde edilen 2011-2012 dönemine ait öngörü sonuçlarının ayrı ayrı dokuz farklı model için ortalama ve standart sapma değerleri verilmiştir. 2011-2012 dönemine ait borsa endeksi gerçek verilerinin ortalama değeri 62228,19 ve standart sapma değeri 6161,52 olarak elde edilmiştir.

Borsa endeksinin öngörüsü için hipotezleri,

$H_0 = \mu_1 - \mu_2 = 0$ Gerçek verilerle ile tahmin edilen veriler arasında anlamlı bir fark yoktur. Veriler aynı veri setinden seçilmiştir.

$H_a = \mu_1 - \mu_2 \neq 0$ Gerçek verilerle ile tahmin edilen veriler arasında anlamlı bir fark vardır. Veriler aynı veri setinden seçilmemiştir.

Tablo 7: Gerçek ve Tahmini Veriler Arasında: YSA ve DVM Yöntemlerinin Z Değerleri ve Hipotez Sonuçları

Z DEĞERİ	YSA	DVM	YSA	DVM
M1	1,466588	-2,932627	KABUL	RED
M2	-1,04136	-0,648933	KABUL	KABUL
M3	2,476163	-0,130749	RED	KABUL
M4	0,453082	4,393201	KABUL	RED
M5	0,538762	1,7316504	KABUL	KABUL
M6	0,376022	-0,299333	KABUL	KABUL
M7	-0,42485	0,81264	KABUL	KABUL
M8	1,653306	0,7441254	KABUL	KABUL
M9	-3,00964	0,4994281	RED	KABUL

Tablo 7’de YSA ve DVM yöntemlerine ait her bir model için Z değerleri verilmiştir. %95 güven aralığında karşılık gelen Z_{kritik} değeri $\pm 1,96$ ’dır. Test istatistiği ve kritik Z değeri dikkate alındığında: YSA için M3 ve M9 modelleri ve DVM için M1 ve M4 modelleri Z_{kritik} değerlerinden büyük oldukları için H_0 hipotezi red edilerek tahmin edilen verilerin gerçek verileri temsil etmediğini ifade edebiliriz. Bununla birlikte YSA için M1, M2, M4, M5, M6, M7 ve M8; DVM için M2, M3, M5, M6, M7, M8 ve M9 modellerinin Z_{kritik} değerlerinden küçük oldukları için H_0 hipotezi kabul edilerek; bu durumun istatistiksel anlamda gerçek verilerin ve tahmin edilen verilerin arasında anlamlı bir fark olmadığını, her iki örnek grubunun aynı yığından geldiğini böylelikle tahmin edilen verilerin gerçek verileri temsil edebilecek yeterlilikte olduklarını ve tahmin amacıyla bu modellerin kullanılabilirliklerini söyleyebiliriz.

4. SONUÇ

Bu çalışmada BIST endeksi tahmini ileri beslemeli yapay sinir ağı ve destek vektör makinelerinden sigmoid tipli bir kernel fonksiyon kullanılarak gerçekleştirilmiştir.

Yapay sinir ağları yöntemi günümüzde pek çok alanda uygulanmakta ve tahmin modellerinde de başarılı sonuçlar elde ettiği görülmektedir. YSA kullanımının kolay, esnek, hızlı ve tutarlı sonuçlar vermesinden dolayı araştırmada bu yöntem tercih edilmiştir. Son yıllarda sınıflandırma, regresyon ve zaman serileri tahmininde de başarılı uygulamaları olan destek vektör makineleri bu çalışmanın ikinci yöntemi olarak seçilmiştir.

Elde edilen sonuçlar itibari ile bakıldığında YSA yöntemi seçildiğinde M2 modelinde belirlenen öngörü için en yüksek R^2 değerine ulaşılmış olup ve borsa endeksi öngörüsü için bir gün öncesine ait verilerin dikkate alınması önemlidir. DVM yöntemi seçildiğinde M3 modelinde belirlenen öngörü için en yüksek R^2 değerine ulaşılmıştır. YSA yönteminde olduğu gibi, DVM yönteminde de borsa endeksi öngörüsü için bir gün öncesine ait verilerin alınması ile modellerin daha iyi performans gösterdiği gözlenmiştir.

Tablo 8: YSA ve DVM Yöntemlerinin R² Düzeyinde Karşılaştırılması

M1	M2	M3	M4	M5	M6	M7	M8	M9	Ort.
%3,51	%0,21	%-1,94	%7,35	%4,37	%0,63	%-0,11	%1,65	%-2,88	%1,36

Yöntemler açısından R² düzeyinde bir kıyaslama yapıldığında, YSA yönteminin DVM yöntemine göre M3, M7 ve M9 modelleri hariç geri kalan altı modelde de biraz daha iyi performans gösterdiğini söyleyebiliriz. Tüm modeller dikkate alındığında YSA'nın, DVM'ye göre ortalama %1,36'lık daha iyi performans göstermiştir. Diğer yapılan literatür çalışmalarına bakıldığında; Yakut (2012), İMKB'de işlem gören toplam 120 sanayi işletmesinin finansal başarısızlık tahmini için yapay sinir ağlarının, destek vektör makinelerine göre daha yüksek doğrulukla sınıflandırma yaptığını gözlemlemiştir. Kara vd. (2011) yapay sinir ağları ve destek vektör makineleri yöntemlerini kullanarak on farklı teknik analiz göstergesi ile İMKB 100 endeksinin yönünü tahmin etmeye çalışmışlardır. Yapay sinir ağlarının ortalama tahmin başarısının (%75,7), destek vektör makinelerinkinden (%71,2) anlamlı şekilde daha iyi olduğu sonucuna ulaşılmıştır. Xiong, Zhang ve Chen (2010), sınıflandırma problemi için yaptıkları çalışmada YSA için %96'lık ve DVM için %94,71'lik bir toplam sınıflandırma başarısı elde etmişlerdir. Gazzah ve Amara (2008), Arab Alfabesini tanıyan yazıcılar için, YSA performansının, DVM performansına göre daha iyi sınıflandırma başarısı gerçekleştirdiklerini ifade etmişlerdir. Benzer şekilde Moraes vd., (2013), Ren (2012) ve Wu vd., (2008) yaptıkları çalışmalarda YSA'nın, DVM'ye daha iyi performans gösterdiklerini tespit etmişlerdir.

YSA ve DVM yöntemlerinden elde edilen sonuçlara göre, gerçek değerler ve tahmini değerler arasındaki farklar hipotez testiyle istatistiksel olarak karşılaştırılmış ve %95 güven aralığında iki değer arasında genel itibari ile anlamlı bir fark olmadığı ortaya konmuştur.

Haftanın günlerinin endeks tahmini üzerinde etkisinin ve dış borsaların endeks tahmini üzerinde olumlu bir etkisinin olup olmadığını belirlemek için büyük örneklem için Z testi kullanılmıştır.

$H_0 = \mu_1 - \mu_2 = 0$ Modeller arasında anlamlı bir fark yoktur veya haftanın günlerinin ya da dış borsaların endeks tahmini üzerinde etkisi yoktur

$H_a = \mu_1 - \mu_2 \neq 0$ Modeller arasında anlamlı bir fark vardır veya haftanın günlerinin ya da dış borsaların endeks tahmini üzerinde etkisi vardır.

Tablo 9: Haftanın Günlerinin ve Dış borsaların Endeks Değeri Üzerindeki Etkisinin Z Testi ile Hesaplanması

Modeller	Z değerleri	Modeller	Z değerleri
YSA.M1 - YSA.M2	2,55	DVM.M1 - DVM.M2	-2,32
YSA.M1 - YSA.M3	-1,05	DVM.M1 - DVM.M3	-2,79
YSA.M4 - YSA.M5	-0,07	DVM.M4 - DVM.M5	2,77
YSA.M4 - YSA.M6	0,07	DVM.M4 - DVM.M6	4,64
YSA.M7 - YSA.M8	-2,13	DVM.M7 - DVM.M8	0,09
YSA.M7 - YSA.M9	2,65	DVM.M7 - DVM.M9	0,33

Haftanın günlerinin ve dış borsaların endeks değeri üzerindeki etkisinin olup olmadığını belirlemek için Z değerler hesaplanmıştır. %95 güven aralığında YSA'nın kullanıldığı, M1-M2, M7-M8 ve M7-M9 modellerinin; DVM'nin kullanıldığı M1-M2, M1-M3, M4-M5 ve M4-M6 modellerinin hesaplanan Z değerleri $\geq Z_{kritik}$ olmasından dolayı, H_0 hipotezi red edilmiştir. Böylelikle bu karşılaştırılan modeller arasında haftanın günlerinin ya da dış

borsaların endeks tahmini üzerindeki etkisi istatistiksel açıdan anlamlı olduğunu tespit edilmiştir.

Elde edilen bu bilgiler ışığında aşağıdakiler söylenebilir:

- Haftanın günlerinin endeks tahmini üzerinde etkisinin olduğu gözlenmiştir.
- Dış borsaların endeks tahmini üzerinde olumlu bir etkisi olduğu düşünülmektedir.
- Her iki yöntemde de olduğu gibi bir gün öncesindeki verilerden hareketle oluşturulan modellerin, iki gün öncesindeki verilerle oluşturulan modellerden; iki gün öncesindeki verilerden hareketle oluşturulan modellerin, üç gün öncesindeki verilerle oluşturulan modellerden daha yüksek tahmin sonuçları ürettiği gözlenmiştir.

Sonuçlar hem YSA hem de DVM yöntemlerinin borsa endeksi tahmininde kullanılabileceğini göstermiştir. Ayrıca bir sonraki çalışmada veri madenciliği tekniklerinden C5.0 algoritması, ANFIS metodu, doğrusal ve doğrusal olmayan regresyon modelleri ile karşılaştırılması düşünülmektedir.

KAYNAKÇA

- AKCAN, A. ve KARTAL, C. (2011). “İMKB Sigorta Endeksini Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları İle Tahmini”, Muhasebe ve Finansman Dergisi, 27–40.
- ALBENİ, M. ve DEMİR, Y. (2008). “Makro Ekonomik Göstergelerin Mali Sektör Hisse Senedi Fiyatlarına Etkisi (İMKB Uygulaması)”, Muğla Üniversitesi SBS Dergisi, 14: 1-18.
- ALTAY, E. ve SATMAN, M.H. (2005). “Stock Market Forecasting: Artificial Neural Network and Linear Regression Comparison in an Emerging Market”, Journal of Financial Management and Analysis, 18(2): 18-33.
- BAŞAR, A. ve OKTAY, E. (2007). “Uygulamalı İstatistik 2”, Aktif Yayınevi, (4. Baskı), Ankara.
- BRIGHAM, E. (1995). Fundamentals of Financial Management, [Elektronik Sürüm], 7th, The Dryden Press, Orlando, USA.
- CHO, V. (2003). “A Comparison Of Three Different Approaches To Tourist Arrival Forecasting”, Tourism Management, 24: 323-330.
- ÇİNKO, M. ve AVCI, E. (2007). “A Comparison of Neural Network and Linear Regression Forecasts of The ISE-100 Index”, Öneri, 7(28): 301-307.
- ÇOMAK, E. (2008). Destek Vektör Makinelerinin Etkin Eğitimi İçin Yeni Yaklaşımlar, Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- DAĞLI, H. (2000). “Hisse Senedi Piyasa Endeksleri Ve Türkiye”, Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 3(4): 189-206.
- DİLER, A.İ. (2003). “İMKB Ulusal 100 Endeksinin Yönünün Yapay Sinir Ağları Hata İyileştirme Yöntemi ile Tahmin Edilmesi”, İMKB Dergisi, 7(25-26): 65-81.
- DURUKAN, M.B. (1999). “İstanbul Menkul Kıymetler Borsasında Makroekonomik Değişkenlerin Hisse Senedi Fiyatlarına Etkisi.”, İMKB Dergisi, 3(11): 20-41.

- FANG, H. ve LOO JEAN, C.H. (1996). "Foreign Exchange Risk and Common Stock Returns: A note on International Evidence", *Journal of Business Finance and Accounting*, 23.
- FAUSETT, L. (1994). "Fundamentals of Neural Networks: Architectures, Algorithms and Applications", USA, Prentice Hall.
- GAZZAH, S. ve AMARA, N.B. (2008). "Neural Networks and Support Vector Machines Classifiers for Writer Identification Using Arabic Script", *The International Arab Journal of Information Technology*, 5(1): 92-101.
- HAMİD, S.A. ve IQBAL, Z. (2004). "Using Neural Networks for Forecasting Volatility of S&P 500 Index Futures Prices", *Journal of Business Research*, 57: 1116-1125.
- HAMZAÇEBİ, C. ve BAYRAMOĞLU, M.F. (2007). "Yapay Sinir Ağları ile İMKB 100 Endeksinin Tahmini" Dokuz Eylül Üniversitesi 27. Yöneyem Araştırması ve Endüstri Mühendisliği Ulusal Kongresi, Temmuz 2-4, İzmir.
- HATİPOĞLU, T., BORAN, S., ÖZCAN, B. ve FIĞLALI, A. (2013). "Yapay Sinir Ağı Yaklaşımıyla Çinko Kalınlığının Tahminlenmesi", *SAÜ. Fen Bilimler Dergisi*, 17(1): 60-68.
- HAYKIN S. (1999). *Neural Networks: A Comprehensive Foundation* [Elektronik Sürüm], Prentice Hall Inc, New Jersey.
- HRISTEV, R.M. (1998). *The ANN Book* [Elektronik Sürüm], GNU Public License, (Edition 1), Boston USA.
- HUANG, W., NAKAMORI, Y. ve WANG, S.Y. (2005). "Forecasting Stock Market Movement Direction with Support Vector Machine", *Computers & Operations Research*, 32(10): 2513-2522.
- KARA, Y., BOYACIOĞLU, 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: 5311-5319.
- KARTALOPOULOS, S.V. (1996). *Understanding Neural Network and Fuzzy Logic*, Newyork: Basic Concepts and Applications, IEEE Press.
- KECMAN, V. (2001), *Learning and Soft Computing: Support Vector Machines. Neural Networks and Fuzzy Logic Models* [Elektronik Sürüm], MIT Press, Cambridge- Massachusetts.
- KIM, K.J. (2003). "Financial Time Series Forecasting Using Support Vector Machines", *Neurocomputing*, 55: 307-319.
- KOHONEN, T. (1987). "Int. Conf. on AI", *State of the Art in Neural Computing*, pp. 1-79, 1-90.
- KUTLU, B. ve BADUR, B. (2009). "Yapay Sinir Ağları ile Borsa Endeksi Tahmini" *Yönetim*, 20(63): 25-40.
- LEWIS, C.D. (1982). "Industrial and Business Forecasting Methods" Londra, Butterworths Publishing.
- MALLIARIS, M. ve SALCHENBERGER, L. (1996). "Using Neural Networks to Forecast The S&P100 Implied Volatility", *Neurocomputing*, 10(2): 183-195.
- MORAES, R., VALIATI, J.F., NETO, W.P.G. (2013). "Document-Level Sentiment Classification: An Empirical Comparison Between SVM and ANN", *Expert Systems with Application*, 40: 621-633.

- SONG, O., HU, W. ve XIE, W. (2002). "Robust Support Vector Machine with Bullet Hole Image Classification" [Kurşun Deliklerini Destek Vektör Makineleri ile Sınıflandırma], IEEE Transactions on Systems, Man and Cybernetics – Part C: Applications and Reviews, 32(4): 440.
- ÖZALP, A. ve ANAGÜN, A.S. (2003). "Yapay Sinir Ağı Performansına Etki Eden Faktörlerin Analizinde Taguchi: Hisse Senedi Fiyat Tahmini Uygulaması", İstatistik Araştırma Dergisi, 2(1): 29-45.
- ÖZKAN, Y. (2008). Veri Madenciliği Yöntemleri, Papatya Yayıncılık, İstanbul.
- ÖZTEMEL, E. (2003). Yapay Sinir Ağları, Papatya Yayınları, İstanbul.
- PAL, M. ve GOEL, A. (2006). "Prediction Of The End Depth Ratio And Discharge İn Semi Circular And Circular Shaped Channels Using Support Vector Machines", Flow Measurement And Instrumentation, 17: 50-57.
- REN, J. (2012). "ANN vs. SVM: Which one performs better in Classification of MCCs in mammogram imaging", Knowledge-Based Systems, 26: 144-153.
- SAAD, E.W., DANIL, V.P. ve DONALD, C.W. (1998). "Comparative Study of Stock Trend Prediction Using Time Delay, Recurrent and Probabilistic Neural Networks," IEEE Transactions on Neural Networks, 9(6): 1456-1470.
- SELER, İ.T. (1996). "Haftanın günleri: İMKB'ye Etkileri Üzerine Bir İnceleme, Sermaye Piyasası ve İMKB Üzerine Çalışmalar", İşletme ve Finans Yayınları, Ankara.
- ŞEN, Z. (2004). Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları, İstanbul.
- WITTKEMPER, H.G. ve MANFRED, S. (1996). "Using Neural Networks to Forecast the Systematic Risk of Stocks," European Journal of Operational Research, 90(3): 577-588.
- WU, T.K., HUANG, S.C. ve MENG, Y.R. (2008). "Evaluation of ANN and SVM Classifiers As Predictors to The Diagnosis of Students with Learning", Expert Systems with Applications, 34: 1846-1856.
- XIONG, Y., ZHANG, Z. ve CHEN, F. (2010). "Comparison of ANN and SVM Methods for Urban Land Use/Cover Classifications from Remote Sensing Images", 2010 International Conference on Computer and System Modeling (ICCSM 2010), v13-56.
- YAKUT, E. (2012). "Veri Madenciliği Tekniklerinden C5.0 Algoritması, Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama", Doktora Tezi, Atatürk Üniversitesi Sosyal Bilimleri Enstitüsü, Erzurum.
- YILDIZ, B., YALAMA, A. ve COŞKUN, M. (2008). "Forecasting the Istanbul Stock Exchange National 100 Index Using an Artificial Neural Network", World Academy of Science, Engineering and Technology, No:46, 36-39.
- YÜKSEL, E. ve GÜLERYÜZ, G. (2010). "İstanbul Menkul Kıymetler Borsası'nda Eşareketlilik Ve Asimetrik Ayarlama", Maliye Finans Yazıları, 24(88): 97-113.
- ZHANG, G. ve HU, M.Y. (1998). "Neural Network Forecasting of the British Pound/US Dollar Exchange Rate, Omega International journal of Management Science, 26(4): 495-506.