

## PAPER DETAILS

TITLE: YAPAY SINIR AGLARI VE FINANS ALANINA UYGULANMASI: HISSE SENEDI FIYAT  
TAHMINLEMESİ

AUTHORS: Arzu TEKTAS,Abdlmecit KARATAS

PAGES: 0-0

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/29975>

# YAPAY SİNİR AĞLARI VE FİNANS ALANINA UYGULANMASI: HİSSE SENEDİ FİYAT TAHMİNLEMESİ

Arzu TEKTAŞ<sup>(\*)</sup>

Abdlmecit KARATAŞ<sup>(\*\*)</sup>

**zet:** Çalışmanın amacı işletme problemlerine uygulanabilecek yöntemler arasında yaygınlaşmakta olan yapay sinir ağılarını (YSA) tanıtmak, finans alanında uygulanabilirliğini araştırıp Türkiye ile ilgili bir uygulama yaparak katkıda bulunmaktır. YSA, verideki ilişki kalıplarını ve eğilimleri tanıyarak öngörm veya veri sınıflaması yapar. YSA, problemi modellemeye ve istatistiksel varsayımlar yapmaya gerek duymadan örneklerle öğrenir. Ancak optimal ağı topolojisini belirleyen bir yöntem yoktur. Ampirik çalışmada, YSA kullanarak yedi şirketin hisse senedi fiyatı tahmin edilmiştir. İlk aşamada YSA yöntemi haftalık ve günlük verilere uygulanmış, günlük veri kullanımı daha başarılı sonuçlar vermiştir. İkinci aşamada günlük verilerle YSA ve doğrusal regresyon yöntemleri denenmiştir. YSA'nın regresyondan daha başarılı sonuçlar vermesi, alternatif finansal analiz yöntemleri arasında değerlendirilebileceğini gösterir.

**Abstract:** This study discusses Artificial Neural Networks (ANN) as one of the recent methods in business decision-making; it reviews ANN applications in finance and carries out an empirical study in Turkey. ANNs are preferably used for detecting patterns and trends in data and thus making prediction or classification. ANN learns from examples without having to make statistical assumptions or model the complete problem. However, determining the optimal ANN topology requires experimentation. The empirical study predicts the closing prices of seven firms' common stocks. ANN is first applied to daily and weekly price data where daily data performs better. Secondly, daily prices are predicted using ANN and linear regression. Higher prediction performance achieved by ANN might imply that ANN can be considered as an alternative financial analysis tool.

## I. Giriş

Ekonomilerin ve kurumların dinamik yapıları, gelişen bilgi teknolojileri, artan bilgi kaynakları, veri çokluğu ve çeşitliliği gibi özelliklerle tanımlanabilen günümüz koşulları karmaşık karar ortamları yaratmıştır. Çeşit ve sayıca artan, belli bir kalıba oturtulması zorlaşan veri ve bilgiler aynı anda birbirleriyle çok yönlü ilişkiler oluşturarak etkileşmektedir. Böyle bir yapı, paralel işlem süreçlerinin yanı sıra yapıyı iyi tanıyarak, öğrenerek karar verebilen daha esnek sistemler gerektirebilir. Bu nedenle, belirtilen yapısal özelliklere sahip olup çok karmaşık ve zeki kararlar verebilen insan sinir sistemi yapısının benzetimleri araştırma alanı olarak ilgi çekmiştir. Son dönemlerde bu konularda yapılan çalışmalar, insanların bilgi süreçlerinin yapısal ve operasyonel prensiplerini taklit etmeğe dayanan veri madenciliği sistemlerinin

---

<sup>(\*)</sup> Yrd.Doç.Dr. Boğaziçi Üniversitesi Uluslararası Ticaret Bölümü

<sup>(\*\*)</sup> Yrd.Doç.Dr. Boğaziçi Üniversitesi Uluslararası Ticaret Bölümü


geliştirilmesine ağırlık vermiştir. Bu araştırmalar sonucu geliştirilen yapay sinir ağları adını, zeka gerektiren sayısız işlemleri yerine getirip sentezleyebilen insan beynindeki hücrelerden almıştır.

Bu çalışmanın birinci amacı işletme problemlerine uygulanabilecek yöntemler arasında yaygınlaşmakta olan yapay sinir ağlarını ana hatlarıyla tanıtmak, çalışma prensiplerini ve en yaygın modellerini incelemektir. İkinci amacı ise sinir ağlarının finans alanında uygulamalarını araştırıp Türkiye’den bir uygulama ile katkıda bulunmaktır. Bulgular Türkiye’nin finansal koşullarından doğabilecek sonuçları da yakalayabilmek açısından faydalı olabilir.


## II. Sinir Ağlarının Biyolojik Temeli ve Yapay Sinir Ağları Modeli

Beyin, birbirlerine bir ağ şeklinde bağlı olan ve nöron adı verilen milyarlarca sinir hücresinden oluşur. Bir nöron hücresinin dallanan girdi yapısı (dandritler), hücre gövdesi ve dallanan çıktı yapısı (aksonlar) bulunur. Bir hücrenin aksonları diğer hücrenin dandritlerine sinapslarla bağlıdır. Bir nöron harekete geçirilince bir sinyal ateşler ve bunu sinapstan diğer nöronlara geçirir. Dandritlerden alınan sinyaller belli bir eşiğin üzerindeyse bu nöronlarda da ateşleme olur. Alınan sinyalin kuvveti sinapsın etkinliğine bağlıdır. Sinaps bağlantılarının ağırlığı değiştikçe öğrenme etkilenir. Nöronların birbiriyle bağlantılı bu işlemleri sonucunda beyinde karmaşık görevler gerçekleşir.

Yapay sinir ağları (YSA) da insanlar gibi tecrübeler yaşayarak öğrenir ve bu öğretileri karar vermede kullanır; çalışma prensipleri de beyindeki sinir ağlarına benzer. YSA katmanlardan oluşur (Şekil 1). Her katmandaki nöronlar bir sonraki katmanın nöronlarıyla bağlantılıdır. Amaç girdi katmanından gelen verilerdeki kalıpları tanıyarak gerçek çıktıya en yakın çıktıyı bulmaktır.



Şekil 1: Katmanları ve Birimler Arası Bağları Gösteren Tek Saklı Katmanlı Ağ



Şekil 2 : Bir Nöronun Yapısı

Girdi katmanı kendinden sonraki saklı katmanla bağlantı halindedir. Her bir bağlantının kuvveti, ilişkinin gücünü gösteren ağırlıklarla ( $W_i$ ) taşınır (Şekil 2). Her birimde nöronun doğrusal olmayan özelliklerini simgeleyen bir aktivasyon (transfer) fonksiyonu ( $F(X)$ ) mevcuttur. Birimlerde ağırlıklar ve aktivasyon fonksiyonu kullanılarak çeşitli süreçler gerçekleşir. Girdilerin ağırlıklı toplamı oluşturulur ve bir eşikle karşılaştırılarak nöronun aktive edilmesi sağlanır. Aktivasyon sinyali nörondaki aktivasyon fonksiyonundan geçirilerek nöronun çıktısı ( $Y$ ) oluşur. Kullanılan eğitim algoritmasına göre ağırlıkların ayarlanmasıyla nöronun öğrenme yetisi gelişir. Saklı katmandaki tüm birimlerdeki süreçler tamamlandıncı çıktı katmanı ile bağlantı kurulur ve bu katmandan çıktı elde edilir.

YSA ile ilgili bu süreçler, YSA'nın yaklaşımının geleneksel bilgi işleme tekniklerinden farklı olduğunu gösterir. Geleneksel tekniklerde problemin çözüm yöntemi bilinir ve algoritmik olarak tanımlanabilir. Sinir ağları ise problemi modellemeye çalışmak yerine verilerden ve hatalardan sürekli öğrenir. Öğrendikçe ağırlıkları uyarlayarak performansını (bir hata kriterine göre hesaplanan beklenen çıktı ile gerçekleşen çıktı arasındaki toplam fark) optimal düzeye çıkarmaya çalışır. Ağın gücü birçok işlemin paralel yapılabilmesinden, birimler arasındaki çok sayıda bağın görevi paylaşmasından ve birimleri bağlayan ağırlıkların uyarlanabilen yapısından gelmektedir.

### III. YSA'nın Kurulması ve Uygulanması

YSA'nın bir probleme uygulanabilmesi için bir dizi girdi ve çıktı değişkeni belirlenmesi, değişkenlerin geçmişteki değerlerini gösteren veri kümesi olması, bir ağ topolojisi oluşturulması ve ağın hatalarını öğrenip gelişebilmesi için belli bir eğitim algoritması ile eğitilmesi gerekir.

#### A. Girdi-Çıktı Değişkenleri ve Veri Kümesi

Bir probleme YSA uygulanması için öncelikle bağımlı (çıktı) ve bağımsız (girdi) değişkenler belirlenir. Etkili değişkenlerin saptanmasında

uzmanlık, deneyim ve bu konudaki literatür taraması belirleyici rol oynar. Ağ modeli denendikçe değişken sayısı azaltılabilir.

Değişkenlerin belirlenmesinin ardından veri toplanması gerekir. Veri kümesindeki her vak'a girdi ve çıktı değişkenlerinin değerlerinden oluşur. Veri yapısının geleceği yansıtılması, öngörüm sırasında karşılaşılabilecek durumları da kapsamı performansı açısından önemlidir. Veri kümesindeki vak'a sayısının belirlenmesinde değişken sayısı ve fonksiyonun karmaşıklık derecesi etkilidir. Bu konudaki hüristik yaklaşımlardan biri de ağdaki bağlantı sayısının yaklaşık on katı kadar vak'anın veri kümesinde bulunmasıdır. Veri kümesinden eğitimde ve modeli test etmede yararlanır. Verinin çoğu girdiler ile çıktı arasındaki ilişki kalıplarının yakalanması için eğitim amaçlı kullanılır; yaklaşık % 15-20'si ise ağa sonradan tanıtılarak ağın performansı ölçülür.

### B. Ağ Topolojisi

Değişkenler seçilip veriler düzenlendikten sonra kullanılacak ağ modelinin ve ağ konfigürasyonunun yani katmanlar ve bu katmanlardaki nöron sayısının belirlenmesi gerekir. Her katmanda belli sayıda nöronun sonraki katman(lar)daki nöronlarla bağlanmasıyla ağ topolojisi oluşturulur.

Ağ en başta uygun bir başlangıç topolojisiyle çalıştırılır. Ağ bir girdi, bir saklı ve bir çıktı katmanlı yapmak; girdi katmanındaki birim sayısını girdi değişkenleri sayısı kadar, çıktı katmanındakileri çıktı değişken sayısı kadar almak, saklı katmandaki birim sayısını da girdi ve çıktı birimlerinin toplamının yarısına eşitlemek hüristik olarak uygun bir başlangıç topolojisi sayılmaktadır (Malhotra, 2003: 89). Aynı veri kümesi için değişik konfigürasyonlar denenerek hata azaltılabilir. Eğer ağ kabul edilebilir bir performans düzeyine ulaşmazsa saklı katmana yeni nöronlar eklenebilir veya katman sayısı artırılabilir. Ağlar çoğunlukla ileri beslemelidir. Bu ağlarda sinyaller girdiden çıktıya doğru tek yönde ilerler. Geri besleme yoktur yani bir katmanın çıktısı aynı katmanı etkilemez.

Problemin yapısına uygun sinir ağı modeli seçmek iyi performans elde edebilmek için çok önemlidir. Özellikle işletme uygulamalarında en çok kullanılan ağ modeli ileri beslemeli olan Çok Katmanlı Pörseptron (Multi Layer Perceptron-MLP)'dur. MLP, bir girdi, en az bir saklı ve bir çıktı katmanından oluşur. Nöronlar yalnızca kendilerinden sonra gelen katmandaki nöronlarla bağlanır. Katmanlar ve her katmandaki birim sayısı belirlendikten sonra uygun bir eğitim algoritması kullanılarak ağdaki tahmin hatasını en aza indireyecek ağırlıklar ve eşikler bulunur. Bunun için eğitim amaçlı seçilmiş olan vak'alar kullanılır. Bu vak'aların tamamı koşturularak ağın konfigürasyonundaki yanılma payı da belirlenebilir.


MLP'nin yetersiz olabileceği durumlarda ağ daha detaylandırmak mümkündür. Temeli MLP'ye dayanan iki farklı model vardır. Genellenmiş İleri Beslemeli MLP modelinde MLP'ye ek olarak birbiri ardından gelmeyen

katmanlar arasında da ileri doğru bağlantı kurulur. Böylece standard MLP'nin bilgi işleme gücü artırılabilir. Modüler İleri Besleme modelinde birkaç paralel MLP oluşturulur ve bu MLP'ler çıktı seviyesinde birleşir. Bu yapı, katmanlar arasındaki ağırlıkların sayısını azaltarak ağırlık verimliliğini etkileyebilir.

Ağırlık yapısını oluşturmak çok kolay değildir ve bir miktar deneme yanılma gerektirir. Son zamanlarda ilgili yazılımların sayısının artması ve yaygınlaşması ağırlık kullanımına olumlu katkıda bulunmuştur. Yazılımlar çok sayıda deneme yanılma çalışmasını kısa sürede yaparak kullanıcının karmaşık ve zaman alan matematiksel modelleri çözmesine gerek kalmadan uygun ağırlık topolojisini bulmayı kolaylaştırır. Statistica, NeuroSolutions, ForecastXL, BrainMaker bu yazılımlardan birkaçıdır. Bazı yazılımların deneme sürümlerine internet ortamından erişmek mümkündür.

### C. Ağırlık Eğitimi

Ağırlık, geçmiş döneme ait çeşitli girdi-çıkı değerleri bulunan veriyi kullanıp eğitilerek girdiler ile çıktı arasındaki ilişkiyi öğrenir. Eğitilirken, bir eğitim algoritması kullanarak öngörüm hatalarının en aza inmesini sağlayacak ağırlıklar ayarlar. Kısacası, eğitim için girdi ve çıktının yanısıra hata tanımı ve eğitim kuralına ihtiyaç vardır. Eğitim kuralı, ağırlıkların sistematik olarak hatayı en aza indirecek şekilde değiştirilmesidir. En yaygın olan ve MLP'lerle en çok kullanılan eğitim kuralı geri yayma (back propagation) algoritmasıdır (Fausett, 1994). Geri yaymada ağırlık yeni vak'a girildikçe eğitim yapılır. Çıktılar ileriye doğru gider, ağırlık uyarlamaları sonucu oluşan hata ise geriye yollar. Yani, ağırlık bir veri kalıbıyla ilk karşılaşmasında onu anlamaya çalışırken ağırlıkları rasgele atar. Bulduğu sonucu gerçek değerle karşılaştırır ve ağırlıklarda ona göre ayarlama yapar (Şekil 3).



Şekil 3: Geri Yayımlı Eğitim Kuralı İle Öğrenme Süreci

Her saklı katman biriminin içinde bir aktivasyon fonksiyonu vardır. Fonksiyon ağ aktivitesinin istenilen sonuca yaklaşıp durulmasına yardım eder. Ağı davranışı ağırlıkların yanısıra fonksiyona da bağlıdır. Fonksiyon genellikle sigmoiddır. Sigmoid fonksiyonda girdi değıştikçe çıktı da sürekli ama doğrusal olmayan biçimde değışir.

Algoritmanın her iterasyonunda eğitim vak'aları birer birer ağı verilir, hedef ve gerçek değerler karşılaştırılır, hata hesaplanır. Hata oranına göre eski ağırlıklar uyarlanır ve aynı süreç tekrar eder. Hatanın belli bir seviyeye inmesi veya azalmasının durması gibi kriterlerle eğitim sona erer. Öğrenme sürecinde elde edilen tüm bilgiler ağırlıklarda özümser. Sonunda ağ, veriyi kullanarak problemi çözecek kalıpları bulmuş olur. Öğrenme sürecinde ağı sürekli ve çok sayıda vak'a sunulması girdi çıktı kalıbını anlayabilmesi için şarttır.

Eğitilen ağın yeni vak'lara genellenebilmesi ağın güvenilirliği açısından çok önemlidir. Bu nedenle eğitim vak'aları dışında kalan test vak'aları, ağın daha önce görmediği vak'alarla performansını değerlendirmesi için kullanılır. Tutarlı sonuçlar elde edildiği durumda eğitilmiş ağ yeni verilerle öngörüm yapmak için çalıştırılır.

#### IV. YSA'nın Finans Alanında Uygulamaları

Finans alanında yapay sinir ağlarının kullanımı 1990'lı yılların sonlarına doğru yaygınlaşmaya başlamıştır. Finans alanıyla ilgili problemlerin veri yoğunluğu, belirsizliğin yüksek olması, değişkenler arasında kolay kalıpsallaştırılamayan saklı ilişkilerin varlığı gibi özellikleri YSA kullanmayı uygun hale getirmektedir. YSA'lar sınıflandırma veya regrasyon amaçlı kullanılırlar. Birçok uygulamada YSA'nın diskriminant ve regrasyon analizi gibi geleneksel yöntemlere oranla daha iyi sonuçlar verdiği gözlenmiştir (Fadlalla ve Lin, 2001: 116). Fadlalla ve Lin'in incelediği uygulamaların hemen hepsinde konfigürasyon bir saklı katmanı bulunan ileri beslemeli ağlardan oluşmuş ve bu ağlarda geri yayma (back propagation) algoritması kullanılmıştır. YSA modelinin kullanıldığı finans uygulamalarının bazıları döviz değişim kurunun öngörümü, çeşitli banka kredilerinin geri ödenebilirliği, finansal kurumların batma riskinin tahmini ile ilgilidir. YSA'nın kullanım alanları arasında bulunan hisse senedi fiyat tahmini ile borsa endeksi değer tahmini ve hareketin yönü gibi çalışmalar da menkul kıymet fiyatlandırma alanında artan bir öneme sahiptir. Bansal vd. (1993) finans alanında birbirine alternatif iki model olan doğrusal regrasyon ve YSA'yı karşılaştırmış, öngörüm doğruluğu açısından doğrusal regrasyonun daha iyi sonuçlar verdiği, veri güvenilirliğinin azaldığı durumlarda YSA'lı tahminlerin daha tutarlı olduğu sonucuna varmışlardır. Schöneburg (1990) Alman menkul piyasasından üç önemli şirketin verilerini çalışarak, kısa dönemlik hatta günlük bazda hisse senedi fiyatlarını YSA modeli yardımıyla tahmin edebilmenin olasılığını analiz etmiş, on gün gibi kısa zaman dilimi içinde tahminlerin doğruluk oranının %90'a kadar ulaşabildiğini belirtmiştir. Brownstone (1996) İngiltere'de Financial Times 100 Endeksi'nin 5 gün ve 25 gün sonraki hareketlerini YSA ve çoklu doğrusal regrasyon yöntemleriyle tahmin etmeye çalışmış; YSA kullanılarak yapılan tahminlerin doğruluk oranı daha yüksek çıkmıştır. YSA yöntemiyle, Leigh vd. (2002) New York Menkul Kıymetler Borsası Endeksi'ni; Kim ve Han (2000) borsa endeksinin gelecekte alacağı değeri tahmin etmeye çalışmışlardır. Dhar ve Chou (2001) firmaların gelecekte elde edecekleri kazançların ve getirilerin tahmininde kullanılan doğrusal olmayan yöntemleri karşılaştırmışlar ve daha önce yapılmış olan çalışmaların doğrusal istatistik yaklaşımları içerdiğini, son yıllarda yapılan çalışmalarda ise doğrusal olmayan yöntemlerin benimsendiğini vurgulamışlardır. Dhar ve Chou doğrusal regrasyon ile YSA yöntemlerini, firmaların gelecekte elde edecekleri kazançların ve getirilerin tahmininde kullanmışlar ve YSA'nın daha iyi tahmin gücü olduğu bulgusuna ulaşmışlardır. Shazly ve Shazly (1999) YSA modeli oluşturarak İngiliz Sterlini, Alman Markı, Japon Yeni ve İsviçre Frangının 3 aylık spot fiyatını tahmin etmeye çalışmışlardır. Uyguladıkları YSA modeli, spot döviz fiyatlarının değişiminin yönünü ve kırılma noktalarını tespit etmekte oldukça başarılı olmuştur.

### V. Ampirik Çalışma

Son yıllarda finans alanında yapılagelen bilimsel çalışmaların önemli bir kısmı, menkul kıymetlerin gelecekteki fiyatlarının dolayısıyla getirilerinin tahmini üzerinde yoğunlaşmıştır. Bu çalışmada da YSA modeli kullanarak İstanbul Menkul Kıymetler Borsası (İMKB)'nda işlem gören yedi şirketin hisse senedi fiyatları tahmin edilmeye çalışılmış; aynı verilere çoklu doğrusal regresyon modeli de uygulanarak iki modelin performansı karşılaştırılmıştır.

Analiz için gıda ve çimento sektörlerinde faaliyet gösteren, halka açık olan ve hisse senedi fiyat istatistiklerine ulaşılabilen şirketler seçilmiştir. Çimento ve gıda sektörlerinin seçilmesinin nedeni, bu sektörlerin piyasa koşullarından çok fazla etkilenmemesidir (Müslümov ve Karataş, 2001: 92). Bu bağlamda İMKB'de işlem gören çimento ve gıda şirketleri arasından üçü çimento geri kalanı gıda olmak üzere toplam yedi şirket rasgele seçilerek analiz edilmiştir. Hisse senedi fiyat bilgileri ve endeks değerleri internet ortamında finansal veri derleyen bir kuruluştan alınmıştır. Döviz kuru, tüketici fiyat endeksi ve aylık mevduat faiz oranı ise T.C. Merkez Bankası Elektronik Veri Dağıtım Sistemi (EVDS)'nden elde edilmiştir.

Türkiye'de ekonomik ve finansal göstergeler zaman içinde ciddi dalgalanmalar göstermekte; özellikle Şubat 2001 krizinden önceki ve sonraki verilerde önemli oranda sapmalar bulunmaktadır. Bu sapmalar verilerde sorun yaratmakta, hem YSA hem de doğrusal regresyon yöntemlerinin isabetli tahminler yapmalarını engellemektedir. Bu nedenlerle 2002 yılı öncesi analiz dışında bırakılarak 2002 ve 2003 yılları baz alınmıştır.

Haftalık ve günlük bilgilerden oluşturulmuş iki veri seti kullanılmıştır. Haftalık analizlerde bağımlı değişken (çıktı) olarak, analiz edilen şirketlerin hisse senetlerinin Cuma günü kapanış fiyatları alınmıştır. Zaman serilerinde temettü ve bedelsiz hisse problemini ortadan kaldırmak için düzeltilmiş fiyat bilgileri kullanılmıştır. Bağımsız değişkenler (girdiler) olarak aylık enflasyon endeksi, TCMB tarafından ağırlıklandırılmış bir aylık mevduat faiz oranı, İMKB 100 Endeksi, İMKB Sınai Endeksi ve T.C. Merkez Bankası Amerikan Doları satış kuru kullanılmıştır. Borsa, faiz ve döviz üçgeni bir bütün olarak düşünüldüğünde faiz ve dövizde modelde bağımsız değişkenler olarak yer vermek tamamlayıcı bir yaklaşım oluşturmaktadır. Türkiye'de faiz ve enflasyon verileri aylık olarak yayınlandığından bu veriler ilgili ayın haftalarına eşit dağıldıkları varsayılarak haftalık olarak kullanılmışlardır.

İkinci veri seti ise aynı dönem için günlük veriler kullanılarak oluşturulmuştur. Günlük veri setinde de düzeltilmiş hisse senedi fiyat bilgileri kullanılmıştır. Bu veri setinde bağımlı değişken (çıktı) hisse senedi kapanış fiyatı; bağımsız değişkenler ise T.C. Merkez Bankası Amerikan Doları satış kuru, İMKB 100 Endeksi ve İMKB Sınai Endeksi'dir. Günlük faiz ve enflasyon bilgileri olmadığından veya ay içinde günlük değerleri eşit varsaymanın anlamlı olmayacağı düşünüldüğünden haftalık veri setinde kullanılan bu iki değişken günlük analizde kapsam dışı bırakılmıştır.

Her iki veri seti için kullanılan YSA modeli tek saklı katmanlı MLP'dir. MLP, geri yaymalı eğitim algoritması ve sigmoid aktivasyon fonksiyonu ile desteklenmiştir. Tüm haftalık ve günlük veri kümelerinde MLP yanısıra gelişmiş MLP modelleri de denenmiş ancak modellerin tahmin başarısında önemli değişiklik olmamıştır. Her veri kümesi için girdi katmanında değişken sayısı kadar birim, çıktı katmanında bir birim alınmıştır. Saklı katmandaki birim sayısı ise her modeli değişik sayılarla çalıştırarak deneme yanılma yöntemiyle bulunmuştur. Tüm analizler için NeuroSolutions yapay sinir ağı yazılım paketi kullanılmıştır.

#### A.Bulgular

Çalışmada öncelikle, seçilecek zaman diliminin YSA performansına etkisini anlayabilmek için haftalık ve günlük veri bazında performans analizleri yapılmış, daha sonra yüksek performans veren zaman dilimi kullanılarak YSA ve çoklu doğrusal regresyon yöntemleri karşılaştırılmıştır. Karşılaştırma kriteri olarak her iki modelde de performans ölçütü olarak kullanılan korelasyon katsayısı alınmıştır.

İlk aşamada her şirketin haftalık ve günlük verilerine YSA yöntemi uygulanarak fiyat tahmini başarı oranları karşılaştırılmıştır (Tablo 1). Haftalık veri yerine günlük veri kullanmanın tahmin başarısını yükselttiği görülmektedir. Bu da Türkiye gibi dalgalanmaların sık yaşandığı finansal ortamlarda, zaman serisinin kısa dönem aralıklarla tanımlanmasının yapay sinir ağına daha fazla kalıp tanıma ve yakalama şansı verdiği ve böylece performansı artırdığı şeklinde yorumlanabilir. Her iki sektörden birer şirketin fiyat tahmin grafikleri Ek'te verilmiştir.

Tablo 1: YSA Performansının Haftalık ve Günlük Veriler Kullanarak Korelasyon Katsayısına Göre Karşılaştırılması

| Sektör  | Şirketler | YSA Haftalık | YSA Günlük |
|---------|-----------|--------------|------------|
| Çimento | Konya     | 0.845        | 0.963      |
|         | Bolu      | 0.890        | 0.926      |
|         | Ünye      | 0.870        | 0.912      |
| Gıda    | Kent      | 0.774        | 0.881      |
|         | Pınar     | 0.771        | 0.903      |
|         | Kerevitaş | 0.691        | 0.817      |
|         | Tat       | 0.909        | 0.966      |

Tablo 2 şirketler için günlük veriler kullanarak çalıştırılan YSA ve doğrusal regresyon modellerinin korelasyon katsayılarını içermektedir. Buradan

YSA modeli kullanarak elde edilen korelasyon katsayılarının daha anlamlı olduğu görülmektedir. Yedi şirket için tek bir zaman aralığında elde edilen bu sonuçlar genellemeden oldukça uzaktır ancak hisse senedi fiyat tahminlemesi için YSA'nın da alternatif modeller arasında yer alabileceğini göstermektedir.

Tablo 2: YSA ve Doğrusal Regrasyon Performansının Günlük Veriler Kullanarak Korelasyon Katsayısına Göre Karşılaştırılması

| Sektör  | Şirketler | YSA Günlük | Regrasyon Günlük |
|---------|-----------|------------|------------------|
| Çimento | Konya     | 0.963      | 0.905            |
|         | Bolu      | 0.926      | 0.863            |
|         | Ünye      | 0.912      | 0.906            |
| Gıda    | Kent      | 0.881      | 0.893            |
|         | Pınar     | 0.903      | 0.807            |
|         | Kerevitaş | 0.817      | 0.408            |
|         | Tat       | 0.966      | 0.907            |

Türkiye için yapılmış bu örnek çalışmanın bulgularının literatürle de uyumlu olduğu görülmektedir.

## VI. Sonuç

Bu çalışmanın birinci amacı işletme problemlerine uygulanabilecek yöntemler arasında yaygınlaşmakta olan yapay sinir ağlarını tanıtmak, çalışma prensiplerini ve sıklıkla kullanılan modellerini incelemektir. İkinci amaç ise sinir ağlarının finans alanında uygulamalarını araştırıp Türkiye'den bir uygulama ile katkıda bulunmaktır.

YSA, geleneksel istatistiksel yöntemlerden farklı olarak, verinin özellikleri ile ilgili istatistiksel varsayımlar yapmaz, algoritma veya matematiksel model geliştirmeye gerek duymaz. Verideki ilişki kalıplarını ve eğilimleri tanıyarak öğrenir. YSA'nın ağırlıkları ve öğrenme hızını uyarlayabilmesi ona esneklik kazandırır ve gerçek dünyadaki değişikliklere tepki verebilmesi kolaylaşır. Diğer taraftan, YSA'nın optimal ağ topolojisini belirleyen bir yöntem yoktur, deneme-yanılma ve deneyim gereklidir. YSA, genel sonuçları ve her girdi değişkeninin sonuca katkısını açıklamakta da güçlü değildir.

Ampirik çalışma YSA'nın yapabilecekleri ve geleneksel yöntemlerle karşılaştırılması hakkında genel fikir vermektedir. Çalışmanın ilk aşamasında bir saklı katmanlı MLP modeli kullanarak İMKB'de kayıtlı olan yedi şirketin hisse senedi fiyatları tahmin edilmektedir. YSA öncelikle günlük ve haftalık veri kümelerine uygulanmış; günlük veri kullanmanın performansı artırdığı görülmüştür. Bu da Türkiye gibi dalgalanmaların sık yaşandığı finansal

ortamlarda, zaman serisinin kısa dönem aralıklarla tanımlanmasının yapay sinir ağına daha fazla ilişki kalıbı tanıma ve yakalama şansı verdiği ve böylece performansı artırdığı şeklinde yorumlanabilir. İkinci aşamada ise günlük verilerin kullanıldığı YSA ve doğrusal regresyon modelleri karşılaştırılmıştır. YSA modeli kullanılarak elde edilen korelasyon katsayılarının daha anlamlı olması genellenemez ancak hisse senedi fiyat tahminlemesi için YSA'nın da alternatif yöntemler arasında yer alabileceğini gösterir. Çalışmanın bulgularının literatürle uyumlu olduğu görülmektedir.

Çalışma, bundan sonra Türkiye'de yapılabilecek benzer çalışmalara başlangıç olarak 2002-2003 zaman diliminde, az sayıda şirket kullanılarak yapılmıştır. Bulguları genelleştirebilmek için, analiz kümesine bir sektördeki tüm şirketler veya farklı sektörlerden ağırlıklandırılmış örneklem yöntemiyle belirlenmiş şirketler dahil edilebilir. Böylece finansal dalgalanmalardan farklı düzeyde etkilenmiş sektörler karşılaştırılarak makro sonuçlara varılabilir. Bu çalışmada kullanılan YSA modellerinden farklı model ve topolojiler geliştirilerek bunun yanı sıra Türkiye ortamını yansıtacak farklı değişkenler ekleyerek fiyat tahminlerinde daha tutarlı sonuçlar elde edilebilir.

### Kaynaklar

- Bansal, A., Kauffman, R.J. ve Weitz, R.R. (1993) "Comparing the Modeling Performance of Regression and Neural Networks as Data Quality Varies: A Business Value Approach", *Journal of Management Information Systems*, Vol. 10, Issue 1, ss. 11-33.
- Brownstone, D. (1996) "Using Percentage Accuracy to Measure Neural Network Predictions in Stock Market Movements", *Neurocomputing*, Volume 10, Issue 3, ss. 237-250.
- Dhar, V. ve Chou, D. (2001) "A Comparison of Nonlinear Methods of Predicting Earnings Surprises and Returns", *IEEE Transactions on Neural Networks*, Vol. 12, No.4, ss. 907-921.
- Fausett, L.(1994), *Fundamentals of Neural Networks*, Newyork, Prentice Hall.
- Kim, K. ve Han, I. (2000) "Genetic Algorithms Approach to Feature Discretization in Artificial Neural Networks for the Prediction of Stock Price Index" *Expert Systems with Applications*, 19, ss.125-132.
- Leigh, W., Purvis, R. ve Ragusa, J.M. (2002) "Forecasting the NYSE Composite Index with Technical Analysis, Pattern Recognizer, Neural Network, and Genetic Algorithm: A Case Study in Romantic Decision Support", *Decision Support Systems*, 32, ss. 361-377.
- Malhotra, R. ve Malhotra, D.K. (2003) "Evaluating Consumer Loans Using Neural Networks", *OMEGA*, 31, ss.83-96.
- Müslümov, A. ve Karataş, A. (2001) "The Effects of the Asian Crisis to Turkish Manufacturing Industry: The Case of Textile, Food and Cement Industries", *Doğuş Üniversitesi Dergisi*, 4, ss. 91-104.

- Schöneburg, E. (1990) "Stock Price Prediction Using Neural Networks: A Project Report", *Neurocomputing*, Volume 2, Issue 1, ss.17-27.
- Stergiou, C. ve Siganos, D. (1996) "Neural Networks and Their Uses", *Surveys and Presentations in Information Systems Engineering SURPRISE, 96 Journal*, vol 4.

Ek: İki Şirketin Günlük ve Haftalık Verilerle Fiyat Tahminlemesi

