

İMKB Sigorta Endeksini Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Yapay Sınır Ağları İle Tahmini

Ahmet AKCAN*
Cem KARTAL**

ÖZET

Finans piyasalarında sigorta sektörü önemli bir yere sahiptir. Bir risk yönetimi aracı olarak sigorta, günümüz iş hayatının önemli bir parçası haline gelmiştir. Sektörün borsada işlem gören şirketleri de yatırımcılar tarafından büyük ilgi görmekle birlikte, gerek ekonomik dalgalanmalar, gerekse sektöre özgü dalgalanmalar nedeniyle, sigorta şirketlerinin hisse senetlerinin fiyatlarında ve dolayısıyla getirilerinde oynaklık gözlenmektedir. Bu nedenle, bu hisse senetlerinin fiyatlarının tahmin edilmesi yatırımcılar için önemli bir konudur. Bu çalışmada, İstanbul Menkul Kıymetler Borsası'nda sigorta sektörü endeksini oluşturan yedi adet şirketin hisse senedi fiyatları, günümüz finans piyasalarında tahminler yapmak amacıyla yaygın kullanımı olan Yapay Sınır Ağ Modelleri ile tahmin edilmeye çalışılmıştır. Bulgular, yapılan tüm tahminlerin başarılı olduğunu, özellikle de 1 aya kadar olan tahminlerin oldukça başarılı olduğunu ortaya koymuştur.

Anahtar Sözcükler: İstanbul Menkul Kıymetler Borsası, İMKB, Sigorta Şirketleri, Yapay Sınır Ağları, Tahmin.

JEL Sınıflandırması: C45, G17, G22.

The Forecasting of Stock Prices in ISE Insurance Index with Artificial Neural Networks

ABSTRACT

Insurance sector has an important role in financial markets. Insurance as a risk management tool has become an important part of today's business world. Publicly traded companies in the sector also seeing great interest by investors, But, because of both economic and sectoral fluctuations, volatility in insurance companies' stock prices and returns is observed. Therefore, it is an important issue for investors to predict stock prices. In this study, stock prices of seven companies which form ISE Insurance Sector Index tried to be estimated with artificial neural network models. The findings showed that all the predictions to be successful, especially on predictions that up to one month are quite successful.

Keywords: Istanbul Stock Exchange, ISE, Insurance Companies, Artificial Neural Networks, Forecasting.

JEL Classification: C45, G17, G22.

* Yrd.Doç.Dr. Ahmet Akcan, Kilis Üniversitesi, İİBF, İşletme Bölümü, Muhasebe ve Finansman A.B.D., ahmetakcan@kilis.edu.tr

** Öğr.Gör. Cem Kartal, Bahçeşehir Üniversitesi, Meslek Yüksekokulu, İşletme Programı, ckartal84@hotmail.com

1. Giriş

Risk yönetimi, 1970'lerin ilk yarısında doğup gelişen, pazar ekonomilerinin evrimini etkileyen önemli bir kavramdır.(Bolgün ve Akçay, 2005:13) Risk yönetiminde en fazla başvurulan seçeneklerden biri ise risk aktarmaktır. Risk aktarımının birçok yolu bulunmakla birlikte en yaygın yöntemlerden birisi sigortadır.

Sigorta şirketleri, gerçek ve tüzel kişilerin karşı karşıya oldukları çeşitli rizikoları azaltan ve sundukları hizmetin karşılığı olarak sigortalıların ödedikleri primlerden oluşan fonları çeşitli piyasalara aktaran aracı kuruluşlardır. Sigortanın amacı, öngörülemeyen olayların zararlı sonuçlarını önceden alınacak önlemlerle olabildiğince azaltmak ya da ortadan kaldırmak, böylece belirsizliklere karşı kişilere bir güvence sağlamaktır.(Güvel ve Güvel, 2008: 23)

Sigortacılık sektörü, gelişmiş ekonomilerde daha hızlı bir şekilde büyüme göstermekte ve ekonomik kalkınmada önemli rol oynamaktadır. Bu ekonomilerde yaşanan rizikoları karşılama ve teminat altına alma ihtiyacı arttıkça, nicelik olarak sigorta şirketlerinin sayısı da artmıştır. Sigorta şirketleri sundukları sigortacılık hizmetlerinde de farklılaştırma ve çeşitlendirmeye giderek nitelik olarak da gelişme göstermiş ve sektör zaman içerisinde büyük bir ilerleme kaydetmiştir.

Bir ülkenin sigorta sektöründeki gelişmeler, ülkelerin gelişmişlikleriyle paralellik göstermektedir. Gelişmiş ülkelerde sektörün daha büyük ve ürün çeşitliliğine sahip olduğu görülmektedir. Tablo 1'deki istatistikler de bu görüşü desteklemektedir. 2009 yılında, gerek hayat dalında prim üretiminde gerekse hayat dışı dallarda prim üretiminde sanayileşmiş ülkelerin büyük paya sahip olduğu görülmektedir. 2009 yılında Dünya genelinde hayat dalında üretilen primin yaklaşık %89'u, hayat dışı dallarda ise yaklaşık %86'sı sanayileşmiş ülkeler tarafından üretilmiştir. Toplam prim üretiminin ise yaklaşık %86,9'u sanayileşmiş ülkeler tarafından üretilmiştir. Gelişmekte olan ülkeler ise genel toplam içerisinde % 13,1 oranında bir paya sahiptir. Son yıllarda gelişmiş ülkelerde prim üretimi düşmekte iken, gelişmekte olan ülkelerde prim üretiminin artması nedeniyle, gelişmekte olan ülkelerin sektörden almış oldukları pay her yıl yükselmektedir. Örneğin; 2008 yılında gelişmekte olan ülkelerin toplam prim üretimindeki payları %12 olarak gerçekleşmişken, 2009 yılında bu oranın %13,1 olduğu görülmüştür.

Gelişmekte olan piyasalar kapsamında yer alan Türkiye'de, son 15 yılda sigortacılık sektöründe önemli gelişmeler olmuştur. Mevcut sigorta şirketleri büyüme göstermekle birlikte, sektöre yeni yabancı firmalar da bu dönemde giriş yapmıştır. Sigorta şirketleri arasında yaşanan şirket evlilikleri, sektörün büyümesinde önemli rol oynamıştır. Ayrıca meydana gelen doğal afetler sonucunda yaşanan bilinçlenme ve hukuki bazı yaptırımların olması da sektörün gelişmesinde pay sahibi olmuştur. Yine Bireysel Emeklilik Sistemi (BES)'nin yaygınlaşması da sektöre olan ilgiyi artırmış ve sektörün büyümesinde önemli rol

oynamıştır. 2009 yılı itibarıyla Türkiye, dünya prim üretiminin %0,3'ünü üretmiş ve dünya sıralamasında 36. sırada yer almıştır.

Tablo 1: 2009 Yılında Dünya Genelinde Prim Üretimi (Milyar ABD Doları)

	Hayat Alanı	Hayat Dışı Alan	Toplam
Sanayileşmiş Ülkeler	2.047,0	1.486,0	3.533,0
ABD	492,0	647,0	1.139,0
Japonya	399,0	107,0	506,0
İngiltere	218,0	92,0	310,0
Fransa	194,0	89,0	283,0
Almanya	112,0	127,0	239,0
İtalya	115,0	54,0	169,0
Hong Kong	20,0	3,0	23,0
Gelişmekte Olan Piyasalar	285,0	249,0	534,0
TOPLAM	2.332,0	1.735,0	4067,0
Türkiye	1,8	10,6	12,4

Kaynak: Başbakanlık Hazine Müsteşarlığı Sigorta Denetleme Kurulu, “Türkiye’de Sigortacılık ve Bireysel Emeklilik Faaliyetleri Hakkında Rapor” 2009, s. 8.

Tablo 2’de Türkiye’nin beş yılına ait prim üretimi istatistikleri gösterilmektedir. Tablo 2 analiz edildiğinde, tüm verilerin yıllar itibarıyla yükseliş eğiliminde olduğu görülmektedir. Tablo 2’den, 2005-2008 yılları arasında hayat dışı prim tutarlarının artış gösterdiği görülmektedir. Aynı gelişme 2007 yılı haricinde hayat dalı prim üretiminde de yaşanmakla birlikte, hayat dışı daldaki kadar hızlı olmamıştır. Bu nedenle hayat dalı prim payının yüzdelik olarak toplam içerisindeki payının azaldığı görülmektedir. 2009 yılında ise hayat dalı payında yeniden bir artış gözlenmiştir. Tablo 2, genel olarak değerlendirildiğinde, yıllar itibarıyla Türkiye sigorta sektörünün prim üretiminde gelişme gösterdiği sonucuna varılabilir.

Tablo 2: Türkiye’de Brüt Prim Üretimi 2005-2009

Yıllar	2005	2006	2007	2008	2009
Hayat Dışı Dalda Prim Üretimi (Milyon TL)	6.575	8.284	9.600	10.204	10.614
Hayat Dalında Prim Üretimi (Milyon TL)	1.242	1.386	1.331	1.576	1.822
Toplam Prim Tutarı (Milyon TL)	7.817	9.670	10.931	11.780	12.436
Hayat Dışı Dalda Payı (%)	84,11	85,67	87,82	86,62	85,35
Hayat Dalında Payı (%)	15,89	14,33	12,18	13,38	14,65
Toplam Prim Payı (%)	100,00	100,00	100,00	100,00	100,00

Kaynak: Başbakanlık Hazine Müsteşarlığı Sigorta Denetleme Kurulu, “Türkiye’de Sigortacılık ve Bireysel Emeklilik Faaliyetleri Hakkında Rapor” 2009, s.1.


Türkiye sigorta sektörü, İstanbul Menkul Kıymetler Borsası (İMKB)'nda yedi şirket ile temsil edilmektedir. Bu şirketler ve İMKB'deki sembolleri Tablo 3'te yer almaktadır (İMKB, 2011).

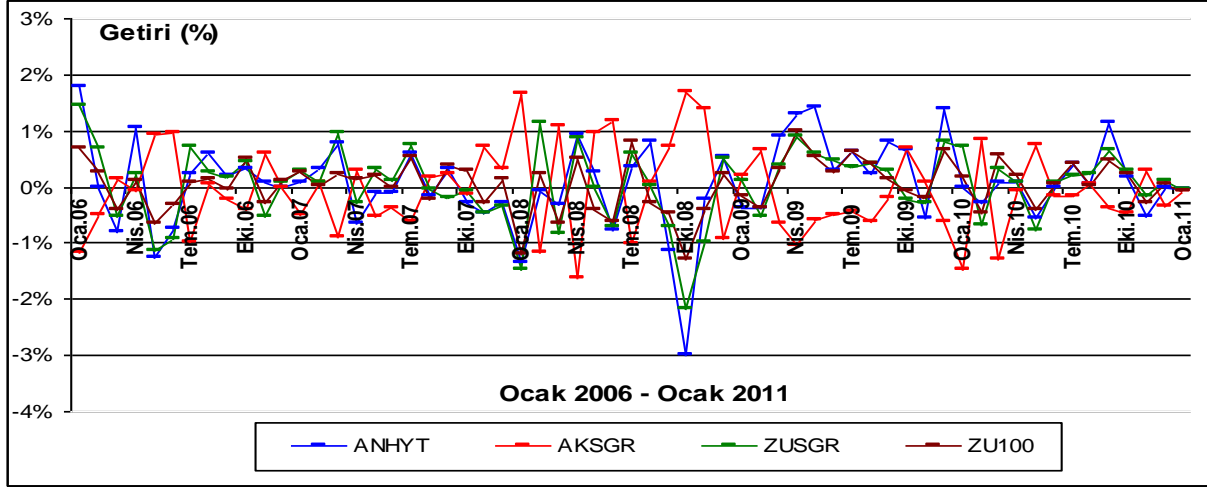

Tablo 3: İMKB Sigorta Sektörü'nde Yer Alan Şirketler

Şirket	İMKB'deki Sembolü
Aksigorta	AKGRT
Anadolu Hayat Emeklilik	ANHYT
Anadolu Sigorta	ANSGR
Aviva Sigorta	AVIVA
Güneş Sigorta	GUSGR
Ray Sigorta	RAYSG
Yapı Kredi Sigorta	YKSGR

Sigorta sektöründe yaşanan olumlu gelişmeler, yatırımcıların İMKB Sigorta Sektörü'nde yer alan bu şirketlere talebini artırmakla birlikte, gerek yaşanan genel ekonomik dalgalanmalar, gerekse sigorta sektörünün kendi iç dinamiklerinden kaynaklanan dalgalanmalar, hisse senetlerinin aylık getirilerinde oynaklığa sebep olmaktadır.

Grafik 1: Ocak 2006 - Ocak 2011 Dönemi Aylık Getiriler Grafiği -1



Grafik 2: Ocak 2006 - Ocak 2011 Dönemi Aylık Getiriler Grafiği -2**Grafik 3: Ocak 2006 - Ocak 2011 Dönemi Aylık Getiriler Grafiği -3**

Grafik 1, Grafik 2 ve Grafik 3'ten de görüleceği üzere, İMKB'de işlem gören sigorta şirketlerinin hisse senedi getirilerindeki değişimler tutarlılık göstermemektedir. Bu durumun İMKB'nin genelinde olduğu bilinmektedir. Grafiklerde yer alan İMKB Ulusal 100 Endeksi ve İMKB Sigorta Sektörü Endeksi de bu yönde bilgiler vermektedir.

İMKB gibi gelişmekte olan piyasalarda dalgalanmaların sık yaşanması görece doğal karşılanabilir. Ancak bu kabul, yatırımcıların fiyat dalgalanmalarına karşın risk altında oldukları gerçeğini ortadan kaldırmamaktadır. Bu nedenle yatırımcılar, fiyatların önceden tahmin edilmesine büyük önem vermekte ve belirsizlikleri azaltarak, risklerin portföyleri üzerindeki etkilerini minimize etmeye çalışmaktadırlar. Bu konuda bilinen birçok tahmin yöntemi olmakla birlikte, günümüzde kullanımına sıkça rastlanan tahmin yöntemlerinin başında Makine Öğrenme Teknikleri gelmektedir.

Bu çalışma, Makine Öğrenme Teknikleri arasında Yapay Zeka kısmında yer alan Yapay Sinir Ağları (YSA) ile oynaklığın yüksek olduğu İMKB Sigorta Sektörü içerisinde yer alan şirketlerin hisse senedi fiyatlarının tahmin edilmesine odaklanmıştır. Çalışmanın izleyen kısımlarında; öncelikle literatür incelemesine yer verilmiştir. Ardından sırasıyla; YSA teorisi, uygulama ve bulgulara yer verilmiştir. Son olarak; elde edilen bulgulara ilişkin değerlendirmelerde bulunulmuştur.

2. Yapay Sinir Ağları

Yapay Zeka alanında en çok bilinen ve uygulamasına en çok rastlanan modeller “Yapay Sinir Ağı” (YSA) modelleridir. YSA’lar doğrusal olmayan özelliğe kavuşturulabilen ve paralel dağıtılmış modeller olup, kendisine sunulan bir girdi seti ile bir çıktı setini eşleştirebilen modellerdir (Haykin, 1999: 24). YSA’lar; tahmin, sınıflandırma ve kümeleme işlemlerinin kapsamında sayılabilecek tüm problemlerin çözümlenmesinde kullanılan, doğrusal olmayan modellerdir. Literatür incelendiğinde, 1980’li yıllardan itibaren işletme, iktisat ve finans bilimi alanlarına giren problemlerin çözümlenmesinde YSA’lardan yararlanıldığı görülmektedir.

Literatürde, YSA’ların, sigorta sektörüne ilişkin çeşitli problemlerin çözümünde kullanıldığı görülmektedir. Hsu (2011), yatırım amaçlı sigorta fonlarının yatırımcılar tarafından satın alınma kararlarının tahmininde; Shah ve Guez (2009), hayat sigortası poliçeleri için ölüm oranlarının tahmin edilmesinde; Dalkilic, Tank ve Kula (2009), Braun ve Lai (2005), sigorta şirketlerinin poliçelerine toplam talebin tahmin edilmesinde; Chiet vd. (2009), sigorta şirketlerinin iflas tahmininde; Kramer (1995), hayat dışı dalda poliçe düzenleyen sigorta şirketlerinin değerlemesinde; Yan ve Bonissone (2006), Yoo ve Kang (1994), poliçe yaptırmak isteyenlerin risk algı düzeylerinin otomatik olarak belirlenmesinde Yapay Sinir Ağı Modelleri’ni kullanmışlardır. Sonuçlar genel olarak değerlendirildiğinde, YSA’ların sigorta sektörüne ilişkin problemlerin çözümünde birçok modele göre daha başarılı olduğu ortaya konulmuştur.

YSA’ların problemlerin çözümünde gösterdiği başarı, özellikle doğrusal olmayan bir model olmasından ve algoritmalar ile eğitilebilmesinden kaynaklanmaktadır. Ayrıca, istatistikî modellerde olduğu gibi analizden önce sağlanması gerekli varsayımlarının olmaması nedeniyle, verilerde bilgi kaybının yaşanmaması (Gonzalez, 2007: 27) ve deneme yanılma yoluyla uyarlanabilen modeller olmaları (Kaastra ve Boyd, 1996: 225) nedeniyle de başarısı yüksek olan modellerdir.


YSA’lar, işlem elemanlarının oluşturduğu katmanlardan meydana gelmektedir. Tahmin için kullanılan en uygun YSA modeli, Çok Katmanlı Algılayıcı (ÇKA)’dır. ÇKA, dışarıdan verileri alan girdi katmanından, ağıın çıktılarını dışarıya veren çıktı katmanından ve bu ikisi arasında yer alan en az bir gizli katmandan meydana gelmektedir (Hamzaçebi, 2008:

4551). Şekil 1’de bir ÇKA mimarisine ve çalışma prensibine ilişkin bir örnek gösterilmektedir.

Şekil 1’de yer alan in_1, in_2, \dots, in_n simgeleri problemin çözümünde kullanılacak girdi işlem elemanlarını temsil etmektedir ve yer aldıkları katmana “girdi katmanı” adı verilmektedir. Bir ÇKA’da bir adet çıktı katmanı yer almaktadır. Girdi işlem elemanı sayısı ise problemin çözümünde kullanılacak girdi değişkeni sayısı kadar olmaktadır. Şekil 1’deki N simgeleri, gizli işlem elemanlarını temsil etmekte olup, yer aldıkları katmanlara “gizli katman” adı verilmektedir. Bir ÇKA’da en az bir adet gizli katman yer alır. Örnek şekilde, görüldüğü üzere iki adet gizli katman bulunmaktadır. Gizli katmanda yer alacak gizli işlem elemanı sayısı probleme göre değişmekte olup deneme yanılma yoluyla tespit edilmektedir.

Şekilde yer alan $z_1, z_2, \dots, z_{m-1}, z_m$ simgeleri çıktı işlem elemanlarını temsil etmektedir ve yer aldıkları katmana “çıkıtı katmanı” adı verilmektedir. Bir ÇKA’da bir adet çıktı katmanı yer almaktadır. Problemden çözülmek istenen değişken sayısı kadar gizli işlem elemanı yer alabilir.

Şekil 1: ÇKA Mimarisi ve Çalışma Prensibi



Kaynak: Paul Hasler and Jeff Dugger; “Analog VLSI Implementations of Neural Networks,” *The Handbook of Brain Theory and Neural Networks*, (Editor: Michael A. Arbib), MIT Press, 2. Edition, England, 2003, p. 101.

Şekil 1’den de görüleceği üzere, bir ÇKA’da çeşitli hesaplama işlemleri yapılmaktadır. Bir ÇKA’nın temel yapısı, girdiler arasında bağlantı kuran işlem elemanlarından, bağlantı ağırlıklarının belirlenmesini sağlayan öğrenme algoritmalarından ve ÇKA’ya doğrusal olmayan yapıyı kazandıran transfer fonksiyonundan oluşmaktadır. Her bir işlem elemanı, diğer işlem elemanlarıyla bağlantılı olup bir ağırlık değerine sahiptir. Ağırlıklar, işlem elemanları arasındaki bağlantıların kuvvetini gösterir ve gizli katmandaki ve çıktı katmanındaki işlem elemanlarının net girdisinin hesaplanmasında kullanılır. Her işlem elemanının bir ağırlığa ve diğer işlem elemanlarıyla bağlantıya sahip olması, bilginin tüm bu bağlantılar aracılığıyla işlem elemanları ve katmanlar arasında ağırlıkla kadar iletilmesini ve ağırlıkla dağıtılmış bir hafızaya sahip olmasını sağlamaktadır. Bağlantı ağırlıklarıyla çarpılan veriler, daha sonra gizli işlem elemanlarına giriş yapmakta ve burada işlem elemanına gelen net girdiyi hesaplamak amacıyla birleştirme işlevinden geçirilmektedir. Daha sonra, net girdiler bir transfer fonksiyonu yardımıyla işlenerek işlem elemanının girdiye karşılık üreteceği çıktı belirlenmektedir. Gizli katmandaki transfer fonksiyonundan geçen çıktılar, çıktı katmandaki işlem elemanlarına gönderilmekte ve tekrar bağlantı ağırlıkları ile çarpılma ve birleştirme işlevinden geçirilmektedir. Çıktı katmanındaki çıktı işlem elemanlarından elde edilen net girdiler ise transfer fonksiyonu yardımı ile net çıktılara dönüştürülmekte ve ağırlıkla üretilmiş olduğu çıktılar elde edilmektedir. Elde edilen çıktılar, algoritmaların yardımıyla ağırlıkla eğitilmesi için önceden belirlenmiş hedef çıktılarla eşleştirilerek, hataların küçültülmesi, diğer bir ifade ile hedef çıktılarının üretilmesi için ağırlıkların yeniden belirlenmesi amaçlanmaktadır. Bu işlemin sonucunda eğitim tamamlanmış olmakta ve eğitimin tüm ağırlıkla içerisinde yayılması anlamına gelen test işlemleri gerçekleştirilerek modelin kurulumu tamamlanmaktadır (Bayramoğlu, 2010: 307-308).

3. Ampirik Uygulama

Bu ampirik çalışmada, sigorta sektöründe faaliyet gösteren ve İMKB’de hisse senetleri işlem gören yedi sigorta şirketinin hisse senedi fiyatlarının 01 Mart-30 Nisan tarihleri arasındaki değerlerinin; 15 günlük (11 iş günü), 1 aylık (23 iş günü), 1,5 aylık (34 iş günü) ve 2 aylık (44 iş günü) periyotlar halinde YSA’lar ile tahmin edilmesi amaçlanmıştır. Bu şirketler Tablo 3’te verilmiştir. Analizler, tahmin problemlerinde en yaygın şekilde kullanımı olan YSA modellerinden Çok Katmanlı Algılayıcı (ÇKA) Modeli ile yapılmıştır. Analizler sırasında MATLAB 7.0 programından yararlanılmıştır.

Modelin kurulumu için; modele girdi olarak 4 adet makro ekonomik ve 8 adet mikro ekonomik değişken olmak üzere toplam 12 adet girdi değişkeni literatür incelemesi yapılarak belirlenmiştir. Girdi değişkenleri ve bu değişkenlere ilişkin açıklamalar Tablo 4’te gösterilmektedir.

Tablo 4’te yer alan ve şirketlerin bilanço ve gelir tablolarından hesaplanarak elde edilen girdi değişkenleri, her şirket için ayrı ayrı hesaplanmış ve tahmin aşamasında sadece şirketin kendi oranları modele dahil edilmiştir. Diğer bir deyişle, her model için makro ekonomik değişkenler aynı olup, mikro ekonomik değişkenler şirketlerin kendi performanslarını yansıtmaktadır.

Tablo 4: Analizde Kullanılan Girdi Değişkenleri

Girdi Değişkenleri
Makro Ekonomik Değişkenler
İMKB 100 Endeksi Günlük Kapanış Değeri
Tüketici Fiyat Endeksi (TÜFE) (2003=100)
TCMB Dolar Efektif Satış Kuru
TCMB Günlük Cumhuriyet Altını Fiyatı
Mikro Ekonomik Değişkenler
Fiyat / Kazanç Oranı
Piyasa Değeri / Defter Değeri Oranı
Aktif Karlılığı Oranı
Alınan Net Prim Büyüme Hızı Oranı
Alınan Primler / Toplam Aktifler Oranı
Özsermaye Karlılığı Oranı
Hisse Başına Kar Tutarı
Net Kar / Alınan Primler Oranı

Tablo 4’de gösterilen tüm girdi değişkenleri, günlük frekansa indirgenerek değişkenlerin 05.01.2009-28.02.2011 tarihleri arasındaki 508 iş gününe ait gözlem değerleri modelin eğitim ve test aşamasında kullanılmak üzere ikiye ayrılmıştır. İlk 356 değer (ilk %70), bağlantı ağırlıklarının belirlenmesi amacıyla eğitim aşamasında, kalan 152 gözlem değeri (son %30) ise bağlantı ağırlıklarının ÇKA’nın tamamı için geçerliliğinin sınanması amacıyla test aşamasında kullanılmıştır. Modelleme sırasında çıktı değişkenlerinin t zamandaki değerleri, girdi değişkenlerinin t-1 zamandaki değerleri ile ilişkilendirilmiştir. Modelin parametreleri deneme yanılma yoluyla belirlenmiş olup, tüm şirketler için aynı parametrelere sahip yedi adet model kullanılmıştır.

Kurulan ÇKA modelinin girdi işlem elemanı sayısı, girdi değişkenleri ile aynı sayıda olup 12’dir. Gizli katman sayısı 1, gizli katmandaki işlem elemanı sayısı 16’dır. Gizli katmandaki işlem elemanlarında doğrusal olmayan Tanjant Hiperbolik Fonksiyonu kullanılmıştır. Böylece ÇKA’ya doğrusal olmayan yapı kazandırılmıştır. Girdi katmanından gizli katmana bilgi aktarımında ve gizli katmandan çıktı katmanına bilgi aktarımında uygulanan birleştirme işlevinde “toplama” yöntemi seçilmiştir. Her bir şirket için ayrı ayrı tahmin yapıldığı için çıktı katmanındaki işlem elemanı sayısı 1’dir. Bu işlem elemanında

Lineer Tanjant Hiperbolik Fonksiyonu kullanılmıştır. ÇKA'nın eğitimi için literatüre uygun olarak Geri Yayılım (Backpropagation) Algoritması tercih edilmiştir.

ÇKA'nın eğitiminin tamamlanması ile birlikte, test aşamasına geçilmiştir. Tablo 6'daki istatistiklerden, ÇKA'nın eğitim ve test çıktılarının birbirleri ile uyumlu olduğunun tespit edilmesiyle birlikte modellerin tahmin için kullanılabilmesine karar verilmiştir. Bu hesaplamada, Tablo 5'te gösterilen MAPE performans ölçütünden elde edilen bilgilere riayet edilmiştir.

Tablo 5: Performans Ölçütleri

Performans Ölçütü	Formül
Mean Absolute Error (MAE)	$\frac{\sum_{p=1}^P d_p - z_p }{P}$
Mean Absolute Percentage Error (MAPE)	$\sum_{p=1}^P \left \frac{d_p - z_p}{d_p} \right \times \frac{100}{P}$

Tablo 6: Kurulan ÇKA Modellerinin Eğitim ve Test Aşaması Sonuçları

	Aşama	Eğitim	Test
	Performans Ölçütü	MAPE (%)	MAPE (%)
Model No	Şirket	(%)	(%)
1	Aksigorta	1.7244	1.7618
2	Anadolu Hayat Emeklilik	1.9922	1.9896
3	Anadolu Sigorta	1.3532	1.4213
4	Aviva Sigorta	2.0121	1.9924
5	Güneş Sigorta	2.1251	2.1736
6	Ray Sigorta	2.0416	2.0735
7	Yapı Kredi Sigorta	0.7813	0.8246

Tablo 6 incelendiğinde, eğitim ve test aşamalarındaki MAPE değerlerinin birbirleriyle yakın oranlarda oldukları görülmektedir. Bu durum, modelin eğitim aşaması sonrasında gerçekleştirilen test aşamasının başarı olduğunu, yani ağı eğitiminin tüm ağ içerisinde genelleştirildiği anlamına gelmektedir. Bu nedenle uygulamanın tahmin aşamasına geçilmiştir. Tahmin sonuçları ve değerlendirmeler, çalışmanın bulgular ve değerlendirme kısmında sunulmuştur.

4. Ampirik Bulgular ve Değerlendirme

Ampirik analiz sonucunda elde edilen bulgular Tablo 7 ve Tablo 8’de sunulmaktadır. Her iki tabloda yer alan sonuçlar, Tablo 5’de gösterilen performans ölçütleri ile hesaplanmıştır. MAPE performans ölçütü sonuçları yüzde (%) olarak; MAE performans ölçütü ise sonuçları Kuruş olarak göstermektedir. Tablo 7’de kurulan yedi modelin 15 gün ve 1 aylık tahminler için ortalama yüzde ve Kuruş cinsinden sapma sonuçları gösterilmektedir. Tablo 7 incelendiğinde; Model 2, 3, 5, 7’nin 15 günlük tahminleri, Model 4 ve 6’nın ise 1 aylık tahminleri daha başarılı olduğu söylenebilir. Model 1’in sonuçlarının ise her iki tahmin dönemi için de birbirine çok yakın olduğu görülmektedir. Tablo 7’deki sonuçlar, gerek yüzde gerekse Kuruş olarak kabul edilen sınırlar içerisinde olup, başarılı öngörüler olarak değerlendirilebilir.

Tablo 7. Tahmin Sonuçları – 1

	Tahmin Frekansı	15 Gün	15 Gün	1 Ay	1 Ay
	Performans Ölçütü	MAPE	MAE	MAPE	MAE
Model No	Şirket	(%)	(Kuruş)	(%)	(Kuruş)
1	Aksigorta	1.8654	3	1.8661	3
2	Anadolu Hayat Emeklilik	2.0177	10	2.0791	10
3	Anadolu Sigorta	1.4365	2	1.5273	2
4	Aviva Sigorta	2.1651	27	1.9192	24
5	Güneş Sigorta	2.3626	5	2.5829	6
6	Ray Sigorta	2.1850	4	2.1170	3
7	Yapı Kredi Sigorta	0.8497	14	0.9122	15

Tablo 8’de, kurulan yedi modelin 1,5 aylık ve 2 aylık tahminler için ortalama yüzde ve Kuruş cinsinden sapma sonuçları gösterilmektedir. Tablo 8 incelendiğinde; tüm modellerin 1,5 aylık tahmin döneminde, 2 aylık tahmin dönemine göre daha düşük yüzde ve Kuruş sapmaları ile gerçekleştiği görülmektedir. Sonuçlar, göreceli uzun dönemler için, gerek yüzde gerekse Kuruş olarak kabul edilen sınırlar içerisinde olup, başarılı öngörüler olarak değerlendirilebilir.

Tablo 8. Tahmin Sonuçları – 2

	Tahmin Frekansı	1,5 Ay	1,5 Ay	2 Ay	2 Ay
	Performans Ölçütü	MAPE	MAE	MAPE	MAE
Model No	Şirket	(%)	(Kuruş)	(%)	(Kuruş)
1	Aksigorta	2.2146	4	2.7376	5
2	Anadolu Hayat Emeklilik	2.4866	12	3.0367	15
3	Anadolu Sigorta	2.2291	3	2.9308	3
4	Aviva Sigorta	2.5752	32	3.0232	37
5	Güneş Sigorta	3.3598	8	4.2170	10
6	Ray Sigorta	2.6426	4	2.9093	5
7	Yapı Kredi Sigorta	1.4783	24	2.0128	32

Yapılan tahminlerin Kuruş olarak sapmalarının sigorta şirketleri arasında oldukça farklılık gösterdiği görülmektedir. Bu farklılık, şirketlerin hisse senetlerinin fiyatları arasındaki farklılıktan kaynaklanmaktadır. Bu değerlerin her şirket için kabul edilebilir değerler içerisinde olduğu yüzdelik sapma değerleriyle birlikte değerlendirildiğinde kolaylıkla anlaşılabilir. Tablo 7 ve Tablo 8’de görüldüğü üzere, Kuruş cinsinden sapma değerlerinde şirketler arasında yaşanan farklılık yüzdelik sapma değerlerinde bulunmamaktadır. Bu durum, Tablo 7’deki sonuçlar başta olmak üzere, tüm sonuçların kabul edilebilir sınırlar içerisinde olduğunu ortaya koymaktadır.

5. Sonuç

Günümüzde sigorta şirketleri, finans dünyası için büyük önem taşımaktadır. Sigorta şirketlerinin gerek sisteme fon sağlamaları, gerek risk yönetiminde yer almaları, gerekse yatırımcılar için bir yatırım seçeneği olmaları, bu önemin nedenleri olarak sayılabilir.

Bu ampirik çalışma, sigorta şirketlerinin hisse senetlerinin yatırımcılar açısından bir yatırım alternatifini olmasından yola çıkmıştır. Çalışma, İstanbul Menkul Kıymetler Borsası’nda işlem gören ve İMKB Sektör Endeksi’ni oluşturan yedi şirketin hisse senedi fiyatlarının önceden tahmin edilerek, yatırımcılara bilgi sağlanmasının mümkün olup olmadığını araştırmıştır. Bu amaçla, Makine Öğrenme Teknikleri’nden Yapay Sinir Ağı Modelleri ile 15 gün – 2 ay aralığında tahminler yapılmıştır.

Elde edilen sonuçlar, iki aya kadar yapılan tüm tahminlerin başarılı olduğunu, özellikle de 1 aya kadar olan tahminlerin oldukça başarılı olduğunu ortaya koymaktadır. Sonuç olarak; Yapay Sinir Ağı Modelleri kullanılarak, İMKB’de sigorta şirketlerinin hisse senetleri hakkında önceden bilgi sağlanarak yatırımcılara yön verilebileceği ortaya konulmuştur.

KAYNAKLAR

- Braun, H. - Lai, L. L., (2005), "A Neural Network Linking Process for Insurance Claims", Proceedings of the Fourth International Conference on Machine Learning and Cybernetics, Guangzhou, 18-21 August.
- Başbakanlık Hazine Müsteşarlığı Sigorta Denetleme Kurulu, (2009), "Türkiye'de Sigortacılık ve Bireysel Emeklilik Faaliyetleri Hakkında Rapor"
- Bayramoğlu, F. M. - Hamzaçebi C., (2010), "Ham Petrol Fiyat Hareketlerinin Sınıflandırılmasında Yapay Zeka Teknolojilerinin Kullanımı," İleri Teknolojiler Çalıştayı 2010 Bildiriler Kitabı, 30 Nisan, Kocaeli.
- Bolgün K. E., - Akçay M. B., (2005), "Risk Yönetimi", Scala Yayıncılık, İstanbul
- Chiet, N.S.- Jaama, S. H.- Noriszura, I.- Shamsuddin, S. M., (2005), "Insolvency Prediction Model Using Artificial Neural Network for Malaysian General Insurers", *IEEE*, 978-1-4244-5612-3/09
- Dalkilic T. E.- Tank F.- Kula K. S., (2009), "Neural Networks Approach for Determining Total Claim Amounts In Insurance", *Insurance: Mathematics and Economics*, Vol. 45, No.2, p.236-241
- Gonzalez, S., (2000-07), "Neural Networks for Macroeconomic Forecasting: A Complementary Approach to Linear Regression Models", Working Paper
- Güvel, E. A. -Güvel, A. Ö., (2008), Sigortacılık, 4. Baskı, Seçkin Yayıncılık, İstanbul
- Hamzaçebi, C., (2008), "Improving Artificial Neural Networks' Performance in Seasonal Time Series Forecasting", *Information Sciences*, Vol. 178, No. 23, p.4550-4559
- Haykin, S., (1999), Neural Networks: A Comprehensive Foundation, 2nd Edition, Pearson Prentice Hall
- Hsu, K., (2011), "Using a Back Propagation Network Combined with Grey Clustering to Forecast Policyholder Decision to Purchase Investment-Linked Insurance", *Expert Systems with Applications*, Vol. 38, No.6, p.6736- 6747
- İMKB, (2011), "Endeks Kapsamındaki Şirketler", www.imkb.gov.tr/Data/StocksData.aspx, (Erişim Tarihi: 03.04.2011).
- Kaastra I. ve Boyd M., (1996), "Designing a Neural Network for Forecasting Financial and Economic Time Series," *Neurocomputing*, Vol. 10, p.215-236
- Kramer, B., (1995), "A Neural Network Model for the Evaluation of Dutch Non-life Insurance Companies", *IEEE*, 0-8186-7174-2/95

- Shah, P. -Guez A., (2009), "Mortality Forecasting Using Neural Networks and an Application to Cause-Specific Data for Insurance Purposes", *Journal of Forecasting*, Vol. 28, No.6, p.535- 548
- Yan, W. - Bonissone, P. P., (2006), "Designing a Neural Network Decision System for Automated Insurance Underwriting", 2006 International Joint Conference on Neural Networks Sheraton Vancouver Wall Centre Hotel, Vancouver, BC, Canada July 16-21
- Yoo, J. - Kang B., (1994), "A Hybrid Approach to Auto-Insurance Claim Processing System", *IEEE*, 0-7803-2129-4/94