



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**TÜRKİYE’DE FAALİYET GÖSTEREN
BAZI SİGORTA ŞİRKETLERİNİN PRİM
ÜRETİMLERİNİN YAPAY SİNİR AĞLARI
İLE TAHMİNİ**

BUSE ÖZGÜR

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı
İstatistik Programı

DANIŞMAN

Prof. Dr. Ufuk YOLCU

İSTANBUL, 23



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**TÜRKİYE’DE FAALİYET GÖSTEREN
BAZI SİGORTA ŞİRKETLERİNİN PRİM
ÜRETİMLERİNİN YAPAY SİNİR AĞLARI
İLE TAHMİNİ**

BUSE ÖZGÜR

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı
İstatistik Programı

DANIŞMAN

Prof. Dr. Ufuk YOLCU

İSTANBUL, 23

MARMARA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Marmara Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Öğrencisi Buse ÖZGÜR'ün “Türkiye Faaliyet Gösteren Bazı Sigorta Şirketlerinin Prim Üretimlerinin Yapay Sinir Ağları İle Tahmini” başlıklı tez çalışması, 10 Ocak 2023 tarihinde savunulmuş ve jüri üyeleri tarafından başarılı bulunmuştur.

Jüri Üyeleri

Prof. Dr. Ufuk YOLCU (Danışman)
Marmara Üniversitesi (İMZA).....

Doç. Dr. Ufuk Beyaztaş (Üye)
Marmara Üniversitesi (İMZA).....

Doç. Dr. Atıf Ahmet Evren (Üye)
Yıldız Teknik Üniversitesi (İMZA).....

ONAY

Marmara Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 31/05/2011 tarih ve 12345 sayılı kararı ile Buse ÖZGÜR'ün İstatistik Anabilim Dalı İstatistik Programında Yüksek Lisans derecesi alması onanmıştır.

Fen Bilimleri Enstitüsü Müdürü
Prof. Dr. Bülent EKİCİ

TEŞEKKÜR

Yüksek lisans tez döneminde, desteğini esirgemeyen, her an ulaşabildiğim ve tüm bilgi birikimini, tecrübesini ve düşünceleriyle bana yol gösteren danışmanım ve değerli hocam Prof. Dr. Ufuk Yolcu'ya çok teşekkür ederim.

Bu günlere gelmemde ve bu çalışmayı yürüttüğüm süre zarfında maddi ve manevi desteğini bir gün olsun benden esirmeyen aileme ve özellikle canım annem'e, yoğun çalışmalarım sırasında her türlü desteği sağlayıp, yanımda olan sektördeki iş arkadaşlarıma, verdiği fikir ve yönlendirmeleri ile hayatta ki en güzel şanslarımdan biri olan özellikle Onur Hakan Uluyol'a, Başak Karakaş, Adem Yılmaz ve Mustafa Yıldırım'a çok teşekkür ederim.

Ayrıca, hep yanımda olan, desteklerini hiç esirgemeyen her türlü sıkıntıyı çeken, arkadaşlarım Ramazan Can Durak, Buse Dökmen, Şeyma Arslan ve Dilara Ceren Bozkır'a teşekkür ederim.

Ocak 2023

Buse ÖZGÜR

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
ÖZET	iv
ABSTRACT	vi
SEMBOLLER.....	viii
KISALTMALAR	ix
ŞEKİL	x
TABLO LİSTESİ.....	xii
1.GİRİŞ.....	1
2.GENEL SİGORTACILIK BİLGİLERİ.....	2
2.1 Sigorta ve Elementer Sigortacılık	2
2.2. Sigortanın Tanımı.....	3
2.3. Sigortanın Önemi.....	3
2.5 Sigorta Branşları	4
2.6.Dünya’da Sigortacılık Tarihi.....	4
2.7 Dünya’da Sigortacılık Sektörü	6
2.8 Türkiye’de Sigortacılık Tarihi	8
2.9 Türkiye’de Sigortacılık Sektörü.....	9
2.10 Türk Sigorta Sektörünün Ekonomideki Yeri	10
3.YAPAY SİNİR AĞLARI	10
3.1 Yapay Sinir Ağlarının Temel Yapısı.....	10
3.2 Yapay Sinir Ağlarının Özellikleri	12
3.3 Yapay Sinir Ağlarının Avantajları	13
3.4 Yapay Sinir Ağlarının Dezavantajları.....	13
3.4 Yapay Sinir Ağı Bileşenleri.....	14
3.4.1 Mimari Yapı.....	14
3.4.2 Aktivasyon Fonksiyonu.....	16
3.4.3 Öğrenme Algoritması	18
3.5 Yapay Sinir Ağı Modelleri	18
3.5.1 Tek Katmanlı Algılayıcılar	19
3.5.2 Basit Algılayıcı Model	19
3.5.3 ADALINE Modeli.....	20
3.5.4 Çok Katmanlı Algılayıcılar	21

3.5.5 İleri Beslemeli Yapay Sinir Ağları	21
3.6.6 Geri Beslemeli Yapay Sinir Ağları.....	22
4. MATERYAL YÖNTEM.....	23
4.1 Levenberg – Marquardt Öğrenme Algoritması	24
4.2 Bayesci Düzenleme Öğrenme Algoritması	27
5. LİTERATÜR İNCELEMESİ.....	28
6. UYGULAMA	29
6.1 Uygulama Tanımı	29
6.1.1 Veri Setleri.....	29
6.1.2 Prim Tahmin Problemin Tanımlanması	30
6.1.3 Uygulamanın Konusu.....	30
6.1.4 Uygulamanın Amacı.....	30
6.1.5 Uygulamanın Önemi	31
6.1.6 Uygulama Modelleri	31
6.2 Şirket ve Branş Bazlı Uygulama Sonuçlarının Değerlendirmesi	34
7.SONUÇ VE ÖNERİLER	58
8.KAYNAKÇA	61



ÖZET

TÜRKİYEDE FAALİYET GÖSTEREN BAZI SİGORTA ŞİRKETLERİNİN PRİM ÜRETİMLERİNİN YAPAY SİNİR AĞLARI İLE TAHMİNİ

Sigorta sektörü, finans piyasalarına fon oluşturmaları ve risk karşılamaları özellikleri ile ülke ekonomisi ve kalkınması üzerinde doğrudan etkisi olan bir sektör olarak görülebilir. Bu bakımdan, sigorta sektörünün hacmini oluşturan temel unsur olan prim büyüklüklerinin olabildiğince doğru ve güvenilir bir şekilde öngörülmesi, dolaylı olarak ülke ekonomisi ve kalkınması açısından ortaya çıkması muhtemel risklerin öngörülmesi ve gerekli tedbirlerin alınması anlamını taşımaktadır. Sigorta primleri de dahil olmak üzere farklı finansal alanlarda ortaya çıkan zaman serilerinin öngörülmesinde klasik zaman serisi öngörü yöntemleri sıklıkla kullanıyor olmasına karşın, bu yöntemlerin model yapısı, gözlem sayısı, durağanlık, özel dağılım vb. varsayımları gerektirmeleri nedeniyle, birçok finansal zaman serisinin öngörülmesinde yetersiz kaldığı söylenebilir. Özellikle son yıllarda, bilgisayar teknolojisinin gelişimi ve doğrusal olmayan uyarlanabilir öğrenme özellikleri sayesinde, yapay sinir ağları bu tip finansal zaman serilerinin öngörülmesi amacıyla birçok çalışmada kullanılmış ve güçlü bir öngörü aracı olarak başarılı öngörü sonuçları üretilmiştir. Bu noktadan hareketle, bu tez çalışmasında Türkiye’de faaliyet gösteren bazı sigorta şirketlerinin prim üretimlerinin farklı yapay sinir ağları ile öngörülmesi ve elde edilen sonuçların karşılaştırmalı olarak değerlendirilmesi planlanmaktadır. Bu bağlamda, ileri ve geri beslemeli olmak üzere temel olarak iki farklı yapay sinir ağının sigorta prim üretimlerine ilişkin öngörü aracı olarak kullanımı gerçekleştirilmiştir. Kullanılan iki yapay sinir ağının farklı eğitim algoritmaları ile eğitiminin yanı sıra çıktı katmanı birimlerinde kullanılan farklı aktivasyon fonksiyonları ile sekiz farklı yapay sinir ağı yapısı ve dolayısıyla sigorta şirketleri prim üretimlerine ilişkin sekiz farklı öngörü aracı oluşturulmuştur. Öngörü sürecinde, veri setlerini oluşturan zaman serileri, yapay sinir ağlarının eğitimi gerçekleştirmek amacıyla kullanılmış “eğitim kümesi” ve yapay sinir ağlarının öngörü performansını değerlendirmek ve öngörülerin güvenilirliğini ortaya koymak amacıyla kullanılmış “test kümesi” veri seti olmak üzere iki ayrı bölüme ayrılmıştır. Yapay sinir ağlarının öngörü performansları "Hata Kareler Ortalaması" (HKOK), "Ortalama Mutlak Yüzdelik Hatası" (OYMH) ve "Medyan Mutlak Yüzdelik Hatası" (MMYH) gibi farklı hata ölçütleri test

kümesi üzerinden değerlendirilmiştir.

Anahtar Kelimeler: Sigorta Prim Üretim Hacmi, Yapay Sinir Ağları, Öngörü, Zaman Serileri, Eğitim Algoritması, Aktivasyon Fonksiyonu



ABSTRACT

FORECASTING USING ARTIFICIAL NEURAL NETWORKS OF PREMIUM PRODUCTION OF SOME INSURANCE COMPANIES OPERATING IN TURKEY

The insurance sector can be seen as a sector that has a direct impact on the country's economy and development with its ability to fund financial markets and meet risk. In this respect, predicting the premium sizes, which is the main factor that constitutes the volume of the insurance sector, as accurately and reliably as possible, indirectly means foreseeing the risks that may arise in terms of the economy and development of the country and taking the necessary measures. Although classical time series forecasting methods are frequently used to predict time series emerging in different financial areas, including insurance premiums, these methods' model structure, number of observations, stationarity, special distribution, etc. It can be said that they are insufficient in predicting many financial time series due to the fact that they require assumptions. Especially in recent years, thanks to the development of computer technology and nonlinear adaptive learning features, artificial neural networks have been used in many studies to predict such financial time series and successful prediction results have been produced as a powerful predictive tool. From this point of view, in this thesis, it is planned to predict the premium production of some insurance companies operating in Turkey with different artificial neural networks and to evaluate the results comparatively. In this context, basically two different artificial neural networks, forward and feedback, were used as a predictive tool for insurance premium production. In addition to training the two artificial neural networks with different training algorithms, eight different artificial neural network structures with different activation functions used in the output layer units, and thus eight different predictive tools for insurance companies' premium production were created. In the forecasting process, the time series that make up the data sets are divided into two parts, the "training set" used to train the artificial neural networks and the "test set" data set, which is used to evaluate the prediction performance of the artificial neural networks and reveal the reliability of the predictions. The predictive performances of artificial neural networks were evaluated over the test set of different error criteria such as "Mean Error Squares" (MSE), "Mean Absolute Percentile Error" (MAPE) and "Median Absolute Percentile Error" (MdAPE).

Keywords: Insurance Premium Production Volume, Artificial Neural Networks, Foresight, Time Series, Training Algorithm, Activation Function



SEMBOLLER

$\in$	: Bir kümenin elemanıdır.
Σ	: Toplam
$\geq$	: Büyük eşittir.
$\leq$	: Küçük eşittir.
t	: Zaman
x_i	: Girdi Değerleri
w_i	: Ağırlık Değerleri
T	: Eşik Değeri
f	: Doğrusal Aktivasyon Fonksiyonu
$>$	: Büyüktür.
$<$	: Küçüktür.
$H(n)$	: Hessian Matrisi
$E(n)$	: Uygunluk fonksiyonu
$J(n)$	: Jakobien Matrisi

KISALTMALAR

GSYH	: Gayri safı yurt ii hasıla
TSB	: Trkiye Sigorta ve Reasrans Őirketleri Birlięi
ANN	: Artificial Neural Network
YSA	: Yapay Sinir Aęları
GYA	: Geri Yayılım Algoritması
LM	: Levenberg – Marquardt
NA	: Newton ęrenme Algoritması



ŞEKİL

Şekil 3.1 Biyolojik Sinir Hücresi

Şekil 3.2 Yapay Sinir Hücresi Yapısı

Şekil 3.3 Genel Yapay Sinir Hücresi Yapısı

Şekil 3.4 Tek Katmanlı Algılayıcı YSA Modeli

Şekil 3.5 Basit Algılayıcı Model Yapısı

Şekil 3.6 ADALINE Model Yapısı

Şekil 3.7 Çok Tabakalı YSA Yapısı

Şekil 3.8 İleri Beslemeli YSA Yapısı

Şekil 3.9 Geri Beslemeli YSA Yapısı

Şekil 4.1 İBYSA mimarisi

Şekil 4.2 Elman-GBYSA mimarisi

Şekil 6.1 A Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.2 A Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.3 A Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.4 A Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.5 A Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.6 A Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.7 B Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.8 B Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.9 B Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.10 B Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.11 B Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.12 B Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.13 C Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.14 C Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.15 C Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.16 C Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.17 C Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.18 C Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.19 D Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.20 D Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.21 D Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.22 D Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.23 D Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.24 D Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.25 E Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.26 E Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.27 E Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.28 E Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.29 E Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.30 E Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.31 F Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.32 F Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.33 F Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.34 F Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.35 F Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.36 F Sigorta Çeyreklik Trafik Branşı Öngörüsü



TABLO LİSTESİ

Tablo 2.1 Gelişmiş ve Gelişmekte Olan Ülkelerde Yıl Bazında Prim Değişimi(Milyon ABD Doları)

Tablo 2.2 Türkiye Sektör Prim Üretimi (Milyar TL)

Tablo 3.1 Hücre Yapısı

Tablo 3.2 Aktivasyon Fonksiyonu Türü Yapay Sinir Hücresi Çıktı İlişkisi

Tablo 6.1 Genel Sonuç Değerlendirmesi



1.GİRİŞ

Sigortacılık sosyal, ekonomik ve siyasi konularla birlikte temelde dayanıklı ve kararlılıkla büyümekte olan ülkelerde özellikle karlı faaliyetlerin yürütülmesinde çok büyük öneme sahiptir. Ülkelerin gelişmişlik ve refah düzeylerinin belirlenmesinde sigorta sektörü önemli bir gösterge olarak kabul edilir. Bu tez kapsamında konan çalışmanın konusu, Türkiye’de faaliyet gösteren bazı sigorta şirketlerinin prim hacimlerinin/büyükliklerinin farklı yapay sinir ağları ile öngörülmesini oluşturmaktadır. Literatürde finansal zaman serilerinin öngörülmesinde yapay sinir ağları yaygın bir şekilde kullanılıyor ve önemli bir kaynak oluşturuyor olmasına karşın, özellikle bu alanda sınırlı sayıda çalışma ortaya konulmuştur. Bu bakımdan tez çalışması, literatür de ki bu boşluğu doldurmaya yönelik olarak, bazı sigorta şirketlerinin prim üretimlerinin yapay sinir ağları ile öngörülmesini karşılaştırmalı bir yaklaşımla ortaya koymaktadır. Bu sayede piyasada bulunan bazı sigorta şirketleri ve bunların prim üretimleri için de karşılaştırılmalı bir analiz olmaktadır.

Sigorta; geçmişte ödenen bir meblağ karşılığında herhangi birinin ya da bir şeyin hayatı, sağlığı, eşyaları üzerine gelecekte karşılarına çıkabilecek tehlikeler karşısındaki finansal riskleri en düşük seviyeye indirmek için, şirketler ve müşteriler arasında imzalanan poliçelerdir. Poliçe sonucunda meydana gelebilecek bir kaza ya da olumsuz bir olay halinde müşterinin karşılaşılabileceği zararları ya da olumsuzlukların karşılığını, sigorta ettirenden bir finansal tazminat olarak talep edebilecektir. Şirketin, sigortalıyı başına gelebilecek durumlara karşı koruma sözüne karşılık, sigortalının da poliçe ile belirlenen prim adı altındaki bir meblağı ödeme sorumluluğu vardır.

Sigorta şirketlerinde, geleceklerini korumaya almak isteyen birey veya bireyler arasında imzalanan sözleşmeye poliçe adı verilir. Bu sözleşme, karşılıklı olarak yapılan bir anlaşma olduğundan her iki tarafının da ortak noktada buluşması gerekir.

Bireylerin ve kurumların sahip oldukları varlıklara teminat sağlayan, sağlıktan eğitime kadar birçok alanda olası riskleri üstlenerek değer yaratan sigorta işlemleri; ekonomik büyüme ve gelişmenin de önünü açıyor.

Sigorta ettirenin karşılaşılabilecekleri farklı durumlara karşı birçok farklı sigorta poliçesi türü mevcuttur. Araçlar için karşılaşılabilecekleri herhangi bir kaza, ya da oluşabilecek

herhangi bir hasara karşılık *kasko sigortası*, konutlarda oluşabilecek her türlü zarara karşı *konut sigortası*, özel sağlık kurumlarında alınabilecek sağlık hizmetlerinin bedelini kapsayan *özel sağlık sigortası*, olası bir deprem durumuna karşılık *DASK*, trafikte oluşabilecek kazalarda karşı tarafa verilen zararı karşılayabilmek için *trafik sigortası*, para biriktirerek gelecekte oluşabilecek her türlü duruma karşılık hayatlarını güvence altına almak için bireysel emeklilik vs. gibi birçok poliçe türü mevcuttur.

Genel olarak insanlar, gelecekte bir tehlike ile karşılaşabilecekleri ve bazı zararlara uğrayabilecekleri fikrinden uzak ve bir sigorta kapsamında düzenlenebilecek bir poliçe ile oluşabilecek riskleri indirme eğiliminde değillerdir. Ancak, bir sigorta kapsamında düzenlenebilecek bir poliçe, olabilecek tüm risklere karşı önceden tedbir aldığı için karşılaşılacak olumsuzluklar durumunda hayat kurtarıcı olabilir.

Bu tezin ikinci bölümünde sigortacılığa değinilerek, sigorta kavramı ve sigortacılığın tanımı, tarihi, Türkiye ve Dünyadaki yeri, ülkeler arasındaki durumu betimlenecektir. Üçüncü bölümde yapay sinir ağlarından YSA'nın temel özellikleri ve bileşenleri hakkında bilgiler verilmiş ve bu tez kapsamında kullanılan, ileri beslemeli YSA ve geri beslemeli Elman YSA tanıtılmıştır. Dördüncü bölümde materyal ve yöntem başlığı altında ileri ve geri beslemeli yapay sinir ağlarının genel mimari yapıları ve öğrenme algoritmaları verilmiştir. Beşinci bölümde, sigortacılık alanında prim hacimlerinin/büyükliklerinin öngörülmesini kapsayan bilimsel çalışmalara ilişkin bir literatür incelemesini sunmaktadır. Altıncı bölümde, Türkiye'de faaliyet gösteren bazı sigorta şirketlerinin prim hacimlerinin/büyükliklerinin farklı yapay sinir ağları ile öngörülmesini kapsayan uygulamaya ilişkin bilgiler verilmiş olup uygulama sonuçları bazı tablo ve grafiklerle birlikte derlenerek değerlendirilmiştir. Son bölümde ise, elde edilen bulgu ve sonuçlar bütüncül bir yaklaşımla tartışılmış ve gelecek çalışmalara ilişkin bir perspektif ortaya konmuştur.

2.GENEL SİGORTACILIK BİLGİLERİ

2.1 Sigorta ve Elementer Sigortacılık

Sigorta, insanların hayatları boyunca başlarına gelebilecek her türlü zararın, ya da karşılaşılacakları tüm risklerin güvence altına alınmasını ifade eder. Kişilerin para biriktirmelerini ve geleceklerini güvence altına alınması sağlar. Sigorta, oluşabilecek tüm

risk ve zararlardan doğan maddi hasarı karşılar. Söz konusu riskler farklı özellikler taşımakta ve bu durum farklı sigorta türlerinin oluşmasına neden olmakla birlikte temelde iki ana sigorta sınıfından bahsetmek mümkündür. Bunlar; kâr amacı olmayan ve devlet tarafından organize edilen sosyal güvenlik sigortası, kâr elde etmek isteyen özel sigortalar şirketleri tarafından oluşturulan özel sigortalar olarak iki şekilde sınıflandırılabilir.

Sigorta, ekonomik ve sosyal olarak tüm durumları kapsar. Her insanın başına gelebilecek zarar, diğer bir ifade ile tehlikeleri sigortacılık alanında “riziko” olarak ifade edilir [1,2].

2.2. Sigortanın Tanımı

Sigortanın birçok tanımından söz edilebilir ancak bunların en kapsamlısı Türk Ticaret Kanunu gereğince yazılmış olanıdır. 14 Şubat 2011 tarihli ve 27846 Sayılı Resmî Gazete' de yayımlanan Türk Ticaret Kanunu'nun 1401. Maddesinde "Sigorta bir akittir ki bununla sigortacı bir prim karşılığında diğer bir kimsenin para ile ölçülebilir bir menfaatinin halele uğratan bir tehlikenin meydana gelmesi halinde tazminat vermeyi yahut bir veya birkaç kimsenin hayat müddetleri sebebiyle veya hayatlarında meydana gelen belirli birtakım hadiseler dolayısıyla bir para ödemeyi veya sair edalarda bulunmayı üzerine alır." olarak tanımlanmıştır [3].

2.3. Sigortanın Önemi

Sigortacılık alanı, bir ülke hakkında birçok bilgi verir. Gelişmişlik düzeyi, ekonomik ve sosyal durumunun ne seviye de olduğunu simgeler. Ayrıca eğitim alanı da sigortacılık alanı ile ilişkilendirilebilir. Çünkü eğitim seviyesi arttıkça, insanlar başlarına gelebilecek riskleri ve tehlikeleri daha iyi anlayarak korunma ihtiyacı doğrultusunda sigorta iş ve işlemlerini daha çok önceliklendirilecektir. Ülkemizde sigortacılık gün geçtikçe gelişmekte olan bir hizmet alanı haline gelmiştir. Sektör, hukuki alanda yapılan revizyonlar ile birlikte belli bir seviyeye ulaşarak, her geçen gün gelişimini devam ettirmektedir. Yine de, diğer bir yandan ülke ekonomisinin büyüklüğünü görebilmek için GSYİH oranına bakmak ilgili seviyenin ne olduğu konusunda bir fikir verecektir. Mevcut veriler Türkiye'nin bu alanda çoğu ülkenin gerisinde olduğuna işaret etmektedir [4]. Bunlara ek olarak, sigorta ve sigortacılık, gelecek hakkında ki planları güvence altına alabilmek ve herhangi bir aksamaya uğramadan ilerletilebilmesinde büyük öneme sahiptir. Sigortanın sağladığı faydalar;

- Yaşanan maddi zararların karşılanması,
- Planlanan hedeflere ulaşırken daha az stres ve korku yaşamak,
- Maddi ve manevi kayıpların önüne geçmek,
- Maddi destek sağlayan yatırım fonlara daha fazla bütçe ayırabilmek,
- Verilen kredi hacminin büyütülmesi

Şeklin de sıralanabilir [4] s.37. 38.

2.5 Sigorta Branşları

Ülkemizde sigortacılık kendi içerisinde kabaca hayat branşları ve elementer branşlar olarak ikiye ayrılır. Bu iki başlık 5684 numaralı sigortacılık kanunu ile tanımlanmıştır [4].

İnsan hayatının güvence altına alınmasına dair sigorta ürünleri hayat branşının altında bir araya gelirken; geri kalanlar hayat dışı başlığı içerisinde toplanır.

Sigorta branşlarını bu iki ana başlık altında ele alınabilir.

Hayat Dışı(Elementer): Kasko, Trafik, Yangın, DASK, Nakliyat, Sağlık, Tarım,

Mühendislik, Motor Dışı

Hayat: Hayat Sigortaları

2.6.Dünya’da Sigortacılık Tarihi

Dünya genelinde sigortacılığın ana temelleri yaklaşık 4000 yıl önce Babiller’de ortaya atılmıştır. Bu dönemde, ticaretin merkezi Babil’de, kervan tacirlerine alacak sağlayan sermayedarlar, kervanların hırsızlığa uğraması veya kefarete ödemesi gereken durumalar da tacirler borçlarını yok saymakta, buna karşılık borcu tacirlerden iade aldıktan sonra, taşıdıkları tehlikeye karşılık asıl borç tutarı üzerinden belli kısmını nakit almaktaydılar. Bu işleyiş sonrasında Kral Hammurabi ile kanunlaştırdı. Bu kanun ile tacirlerin de korunmasına ve malların daha eşit ve adaletli bir şekilde korunduğu anlamına da geldi, denilebilir [4].

Hindu'lar M.Ö. 600'lü yıllarında içerisinde sigorta kriteri bulunan kredi sözleşmelerini yürürlüğe almaya başladılar. Sözleşme içerikleri, toplumlardaki sigortaya olan yaklaşımı ve düşünceleri geliştirerek sigortacılıkta ilk ve önemli adımlar ortaya atılmıştır. Bu tür kredi sözleşmeleri ortaçağda daha da yaygınlaşarak nakliyat sigortası branşı olarak bilinen sigortaların yapıtaşlarından olmuştur [4].

İlerleyen zamanlarda deniz ticaretinde gelişim sağlandığı görüldü. Özellikle Doğu Akdeniz'de ticaret ile birlikte sigortacılık da değişti. Romalılar ve Yunanlılar, ticari amaçla yapılan deniz seferlerinde mallarının limana sağlam bir şekilde ulaşması için, belirli bir para karşılığında bir nevi mallarını sigortalatmışlar. Bu maliyet ile birlikte yüksek miktarda faiz de alındığı için ilerleyen dönemlerde kilise bu duruma karşı çıkarak yasaklamıştır [4].

Milattan sonra 1250 yıllarında prime dayalı sigorta, İtalya'nın Venedik, Floransa ve Cenova şehirlerinde kullanılmaya başladı fakat günümüzde ki sigortanın gündeme gelebilmesi için 14.yy'ı beklemek gerekti. Ekonomik şartların farklılaşmasıyla ticaret, 14.yy ile birlikte ciddi anlam da gelişme yaşadı. O dönemlerde deniz ticaretinde önde gelen İtalya'da, sigorta kavramına ihtiyaç duyuldu ve aslında deniz sigortasının varoluşunun temelleri buraya dayanmaktadır. 23 Ekim 1347 tarihinde ilk sigorta poliçesi olarak bilinen mukavele İtalya'nın Cenova Limanı'ndan Mayorka'ya "Santa Clara" adlı geminin yükünü tedarik etmek sebebiyle düzenlendi. 1424 yılında, yine Cenova şehrinde ilk sigorta şirketi kuruldu. İtalya'daki gelişimden sonra, deniz sigortalarının özellikle 18.yy'da İngiltere'de yaygınlaşmaya başladığı gözlemlenmektedir [4].

Tekne ve taşıdığı ürünlerin emniyetinden doğan bu ihtiyaç neticesinde teknede bulunan kaptan, tayfa ve yolcularında sigortalanabilir olması fikri ortaya atılmıştır. Bu nedenle hayat sigortası alanındaki uygulamalar genişlemeye başlandı [4].

17.yy.'da gündeme gelen "Tontines" adı verilen sistemde, bir araya gelen bir takım arkadaş grubu, herkesin eşit miktarda ortaya koydukları para ile, bir zaman dilimi belirleyip bu zaman dilimi içerisinde vefat eden kişinin ortaya koyduğu parayı diğer arkadaşlar arasında bölüşmesi neticesinde ölüm rizikosu adı verilen hayat sigortası ortaya çıkmıştır [4].

17.yy.'da sigortacılığın gelişmesine katkı sağlayan iki önemli olay meydana gelmiştir. Bunlardan ilki, istatistiksel yöntem ve tekniklerin hesaplamalara dahil edilmesi, ikincisi ise, Londra'da yaşanan, birden fazla konutun ve kilisenin kül olmasına sebep olan büyük yangındır. Bu olay kara sigortalarının doğmasına neden olup buna benzer olayların önüne geçebilmek için tedbir alınmasına sebebiyet vermiştir. Gelişen bu olaylarla birlikte 1667 yılında "Fire Office "(Yangın Bürosu) kurulması ardından da ilk yangın sigorta şirketi "Friendly Society" faaliyete geçmiştir. Daha sonra 1688 yılında İngiltere'de "Lloyd's" isimli başka bir şirketin kurulmasıyla sigortacılıkta yeni bir dönem başlamıştır. Edward Lloyd adında bir kişinin işlettiği kıraathanede, gemi sahipleri, iş adamları ve tacirler, deniz ticareti ile alakalı aralarında tartışıp konuştukları bir ortam oluşmuştur. Bir gemi veya geminin taşıdığı ürün üzerine sözleşme hazırlayan kişilere "Underwriter" ismiyle belgeler düzenleyerek çalışmaya başlamışlardır. Lloyd'un vefatından sonra kendi ismi ile bir birlik ortaya çıkmıştır. İlk yıllarında sadece deniz sigortaları ile başlayan çalışmalar ilerleyen dönemlerde kara sigortaları alanın da kapsayacak şekilde devam etmiştir. Zamanla çeşitli sigortaların yapılabildiği bir kurum haline gelmiştir. Lloyd'un şirketinin en dikkat çeken özelliği Lloyd's üyelerinin tüm varlıklarıyla mesuliyet taşımaları ve hiçbir şekilde sigortalı ile direk ilişki ve iletişim kurmamaları, ilişkinin "Broker" adı verilen aracı, kişi veya şirketlerle tedarik edilmesidir. Broker'lar Lloyd's ile bir araya gelip iş yürütebilmek için birliğe kayıt olarak müşterinin tüm ihtiyaçlarını izleyip takip etmekteydiler [4].

Daha önce belirtildiği gibi, birçok sigorta branşının ortaya çıkmasına belli olaylar neden olmuştur. Örneğin, global sigortacılığın ortaya çıkmasına deniz kazaları etken olurken yangınlar ise kara sigortacılığına, bunun akabinde katarda yaşanan kazalar ise kaza sigortacılığına öncülük etmiştir. Bir diğer alanda ise günümüzde sıkça karşılaştığımız iş kazaları ve saha çalışmaları da mühendislik sigortasının gelişmesine yol açmıştır [4].

20. yüzyıl ile birlikte birçok farklı alanda sigorta ihtiyacına cevap verebilecek büyük şirketler sektörde rol almaya başlamışlardır [4].

2.7 Dünya'da Sigortacılık Sektörü

Tablo 2.1'de döviz kurlarındaki devalüasyona bağlı olarak ABD doları kuruna bağlı olarak GSYH geçen yıla göre %0,4 değer azalarak 874 ABD dolarına gerilemiştir [5].

Bu sebeple, 2021 yılında sigorta istekleri bir azalışa neden olarak, elementer prim havuzunda %2,6 bir yükselişle, hayat prim havuzunda %4,5 ve toplam prim üretiminde de %3,4 oranında büyümüştür.

Tablo 2.1 Gelişmiş ve Gelişmekte Olan Ülkelerde Yıl Bazında Prim Değişimi(Milyon ABD Doları)

(Milyon \$)	Türkiye		Dünya		(Million \$)
	2020	2021	2020	2021	
Hayat Dışı Prim Üretimi	8.765	8.645	3.489.608	3.863.029	Non Life Premium
Hayat Prim Üretimi	2.039	1.881	2.797.436	2.997.569	Life Premium
Toplam Prim Üretimi	10.8	10.53	6.287.044	6.860.598	Total Premium
Hayat Dışı Payı (%)	81,13	82,13	55,50	56,31	Non Life Share (%)
Hayat Payı (%)	18,87	17,87	44,50	43,69	Life Share (%)
Prim / GSYH (%)	1,5	1,3	7,4	7	Premium / GDP
Kişi Başına Prim Üretimi (USD)	128	124	809	874	Premium Per Capita (USD)

Dünya genelinde ise 2022 yılında prim hacmindeki küçülmemin gayri safi milli hasılatın %33 oranında kaldığı görülmektedir. Çin'in sigorta prim üretiminde geçen yıla göre anlamlı bir büyüme gözlenmiştir. Bu da büyümekte olan diğer ülkelerin toplam prim üretimi başarısında büyüyen piyasalara oranla daha pozitif sonuçlarına doğmasına neden olmuştur [5].

İkinci Dünya Savaşı'ndan sonra ilk kez salgın hastalığın neden olduğu dünya çapında oluşan ekonomik durgunluk kaynaklı zor koşullar altında hayat dışı sigorta dayanıklılık göstererek önceki seviyesini korumuş ve hatta bir miktar artış sağlamıştır. Küresel GSYİH %3,7 azalırken, hayat dışı sigorta primleri %1,5 artarak 3490 milyar ABD dolarına yükselmiş ve büyümeye devam etmiştir. Gelişmiş piyasa primleri, son 25 yılda ilk kez gelişmekte olan piyasalardan daha hızlı büyümüştür. ABD ve Kanada'da primler %1,5 arttı. Gelişmiş Asya Pasifik, %6,6'lık kazançla Güney Kore'nin liderliğinde, primlerde %2,6 artışla yine en yüksek büyüme gösteren gelişmiş bölge oldu. Güney Kore'nin büyümesi, daha yüksek tıbbi maliyetlerin ve araç bakım ücretlerinin primleri yükselttiği istisnai bir motor sigortası pazarının sonucudur. Çin (+%4,4) sağlık sigortası alanında %15'lik bir genişlemenin ardından gelişen pazar büyümesine hakim oldu, ancak Çin motor primleri pazarın tarife dışı bırakılmasından sonra %3 düştü. Diğer gelişmekte

olan piyasalarda hayat dışı primlerin geniş bir aralıkta da olsa ortalama olarak %2 düştüğü gözlemlendi [6].

2.8 Türkiye’de Sigortacılık Tarihi

- Türkiye’de sigortacılığın doğuşu, 19. yy’da ortaya çıkan büyük kayıplar ve yangınlar nedeniyle olduğu söylenebilir [7].
- 1870 yılında İstanbul Beyoğlu’nda yaşanan yangın ile birlikte sigortacılığa önem daha da artmıştır [7].
- Aralarında İngiliz (Sun, Northern ve North British), Fransız ve Alman şirketlerinin de bulunduğu yabancı sermayeli şirketler 1872 yılında Türkiye’de sigortacılık faaliyetlerine başladı [7].
- 1916 yılında 43 tanesi yabancı 1’i de Türk olmak üzere toplamda 44 sigorta şirketi kurulmuş oldu. Bu sayı zaman içerisinde 80’e kadar çıktı [7].
- 1918 yılında “İttihadi Millî” adında Türk kanunlarına göre ilk sigorta şirketi kuruldu [7].
- 1925 yılında sigortacılık alanındaki ilk millileşme akımı Anadolu Sigorta Şirketi’nin kurulması ile, İş Bankası tarafından gerçekleştirilmiştir [7].
- Sonraki yıllarda sigorta sektörünü yönetebilmek ve buradan doğan primlerin bir kısmını ülke içinde tutabilmek için 1160 sayılı “Mükerrer Sigorta Hakkındaki Kanun” yürürlüğe girmiştir [7].
- Milli reasürans’ın kurulmasına yine İş Bankasının güvencesiyle 1929 yılında kurulmuştur [7].
- Millî reasürans’tan sonra sırasıyla birçok sigorta şirketi kurulmuştur. Doğan Sigorta ise bu şirketler arasındaki ilk özel sermayeli şirket olarak hayatımıza girmiştir [7].
- 1939 yılında Ticaret Bakanlığına bütün sigorta şirketleri bağlanmıştır [7].
- 1959 yılında yürürlüğe giren 7397 sayılı Sigorta Murakebe kanunu ile sigortacılık sektörü büyük bir biçimde şekillenmiştir [7].
- Sigortacılık sektöründeki önemli gelişmelerden biri de 1 Ocak 1995 tarihinde kullanılmaya başlanan poliçe takip sistemidir [7].
- 27 Ekim 2003 yılında ‘Bireysel Emeklilik Tasarruf ve Yatırım Sistemi Kanunu’ ile Bireysel Emeklilik Sistemi yapılanması başlamıştır [7].

2.9 Türkiye’de Sigortacılık Sektörü

- Türkiye’de sigortacılık sektörünün güncel olarak ne konumda olduğu 2021 yılı verileri üzerinden ele alınabilir [5].
- 2021 yılı için Türkiye’de 41 elementer, 21 hayat ve yaşam, 3 adet reasürans şirketi ile birlikte toplamda 65 sigorta şirketi hizmetlerine devam etmektedir. Yıl içerisinde sektörde genel toplamda 87,5 milyar TL prim üretimi yapılmıştır. 2020 yılına göre %28,5 bir büyüme gerçekleşmiş olup toplam üretimde pastanın büyük dilimi %22,2 *kara araçları sorumluluk* ürününe aittir. 2021 yılı itibariyle Türk sigorta sektörünün üstlendiği tazminat tutarı 63,6 milyar TL’dir. Bu tutarın 58,6 milyon TL’si elementer sigortalardan gelirken, 5 milyon TL’si hayat sigortalardan gelmektedir [5].
- 2021 yılında aktif olarak görev yapan 65 sigorta şirketinin elementer ve hayat toplam prim üretimi %27 yükselişle 104,9 milyar TL olmuştur. Sektörün aktif çalışan sigorta şirketleri 2021 yılında %38,7 oranında artışla prim miktarı 427 milyar TL’ye yükselmiştir [5].
- Sigorta Reasürans ve Emeklilik Şirketleri, 2021 yılında 427 milyar TL ile bankacılık sektöründen sonra gelerek sektörde 2. sırada yer almaktadır [5].

Sektör	2015	2016	2017	2018	2019	2020	2021
Bankalar	2.357	2.595,4	3.257,8	3.867	4.490,8	6.106,4	9.215,5
Sigorta, Reasürans ve Emeklilik Şirketleri	98,4	122,2	152,3	178,4	236,6	307,8	427
Menkul Kıymet Yat. Fonları	37,2	41,8	54,2	46,8	113,8	128,5	267,4
Finansal Kiralama Şirketleri	40,6	48,5	58,1	68,5	58,2	70,3	106
Faktöring Şirketleri	26,7	33,1	43,7	34,6	37	48	65
Tüketici Finansman Şirketleri	27,2	32,8	39,1	39,7	27,6	36,1	48,7
Aracı Kurumlar	15,3	21,2	23,1	21,9	28	41,3	53,7
Gayrimenkul Yatırım Ortaklıkları	21,3	25	26,9	19,4	32,7	55,3	87,3
Girişim Sermayesi Yatırım Ortaklıkları	1,3	1,1	2,6	1,5	3	7,6	6,5
Genel Toplam	2.625	2.921,1	3.657,8	4.277,8	5.027,7	6.801,3	10.277,1

Tablo 2.2 Türkiye Sektör Prim Üretimi (Milyar TL)

EK-A Tablo 1’de yıl bazında prim üretimleri verilmiştir. Toplam prim üretimi içinde elementer (hayat dışı) üretim her yıl hayat üretimlerine oranla daha çok artmıştır.

2.10 Türk Sigorta Sektörünün Ekonomideki Yeri

Sigorta sektörünün büyüklüğünün içinde bulunduğu ülkenin gelişmişliği ile doğrudan ilişkili olduğu kabul edilir. Müşteri sayısı (sigortalı sayısı) ve müşteri başına düşen prim tüketimi ne kadar çok ise ilgili ülkenin o derece gelişmiş olduğu söylenebilir [8].

3.YAPAY SİNİR AĞLARI


Ortaya konan bu tez çalışması kapsamında, Türkiye’de aktif olarak çalışan bazı sigorta şirketlerinin farklı alanlardaki prim üretim büyüklüklerine ilişkin veri setleri analiz edilerek öngörülmüştür. Veri setlerinin öngörülmesinde öngörü aracı olarak, farklı özelliklere sahip, ileri beslemeli ve geri beslemeli olmak üzere temelde iki farklı YSA kullanılmıştır. Bu bakımdan bu bölüm YSA hakkında temel bazı bilgileri içermektedir.

3.1 Yapay Sinir Ağlarının Temel Yapısı

İnsan beyni, insanların başarılı olduğu bilişsel, algısal ve kontrol görevlerinde temel olan devasa sinir ağlarının varlığının kanıtını sunar. Beyin, algısal eylemler (örneğin yüzlerin tanınması, konuşma) ve kontrol faaliyetleri (örneğin vücut hareketleri ve vücut işlevleri) gibi hesaplama gerektiren yeteneklere sahiptir. Beynin en önemli üstün özelliklerinden biri paralel hesaplama yapabilme yeteneğidir ki bu özelliğini kesin olmayan bilgi işleme yeteneği ile birleştirerek son derece az bilgi ile oldukça hızlı ve doğru kararları doğuran işlemler gerçekleştirebilir. İnsan beyninin birbirine bağlı 10 milyardan fazla nörondan oluştuğu bilinmektedir. Her nöron, bilgiyi almak, kullanmak ve iletirmek için biyokimyasal reaksiyonları aktif bir şekilde kullanan birer hücredir (Şekil 3.1). Bir biyolojik sinir hücresi yapısında *dendritler* adı verilen ağaç benzeri sinir lifi ağları, hücre çekirdeğinin bulunduğu hücre gövdesine yani *somaya* bağlanır. *Akson* adı verilen ve hücre gövdesinden uzanan ve sonunda ipliklere ve alt ipliklere ayrılan tek uzun lif sinaptik terminaller yani *sinapslar* yoluyla diğer nöronlara bağlanır. Sinapslarda sinyallerin bir nörondan diğerine iletilmesi, bağlantının gönderici ucundan belirli verici maddelerin salındığı karmaşık bir kimyasal süreçtir. Sinyali gönderen hücrenin etkisi alıcı hücrenin gövdesi içindeki elektrik potansiyelini yükseltmesi veya azaltması şeklinde ortaya çıkar. Etki, potansiyel bir eşiğe ulaşırsa, aksone bir darbe gönderilir ve hücre "*ateşlenir*". Biyolojik bir sinir sistemi bileşenleri ve bunlara karşılık gelen yapay sinir sistemi bileşenleri Tablo 3.1 ile verilmiştir.

YSA, biyolojik sinir sistemlerinin matematiksel modellerinin genellemeleri olarak geliştirilmiştir. Yapay sinir ağlarına olan ilgi akımı, McCulloch ve Pitts [9] tarafından basitleştirilmiş nöronların tanıtılmasından sonra ortaya çıkmıştır. YSA, insan beyninin sahip olduğu temel özelliklerden olan öğrenme süreci ile yeni bilgi üretebilme karşılaştığı yeni bilgileri keşfedebilme gibi işlemleri herhangi bir dışsal yardıma gereksinim duymadan gerçekleştirebilme yeteneğine sahip olan algoritmalarıdır [10].

Sinir ağlarının ana işleme unsurlarına yapay nöronlar veya basitçe nöronlar veya düğümler adı verilmektedir. Nöronun basitleştirilmiş bir matematiksel modelinde, sinapsların etkileri, ilişkili giriş sinyallerinin etkisini modüle eden bağlantı ağırlıkları ile temsil edilir ve nöronlar tarafından sergilenen doğrusal olmayan karakteristik, bir transfer fonksiyonu ile temsil edilir. Nöron uyarı etkisi daha sonra transfer fonksiyonu tarafından dönüştürülen giriş sinyallerinin ağırlıklı toplamı olarak hesaplanır. Yapay bir nöronun öğrenme kabiliyeti, ağırlıkların seçilen öğrenme algoritmasına göre ayarlanmasıyla sağlanır [11].



Şekil 3.1 Biyolojik Sinir Hücresi

Tablo 3.1 Hücre Yapısı

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

YSA gerçekte biyolojik sinir ağlarından esinlenerek ortaya konmuş ve oldukça gelişmiş türlerinin oluşturulmuş olmasına rağmen, YSA halen hem genel yapıları hem de yetenekleri bakımından biyolojik sinir sistemleri ile arasında oldukça büyük farklılıklar olduğu ve halen biyolojik sinir sistemlerinin oldukça ilkel bir taklidi olduğu söylenebilir [12].

3.2 Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağlarının uygulamaya göre farklılık gösterebilirler. Genel özelliklerini sıralayacak olursak;

- Yapay sinir ağlarının çalışması sadece doğrusal yönde değildir ve tüm ağı kapsayacak şekildedir. Bu nedenle kompleks problemlerin de çözülmesi daha kolay hale getirmektedir. Bu nedenle karşılaşılabilecek birçok problemi çözümleme işlemi daha kolay olur [11].
- Yapay sinir ağları bir makine öğrenimi gerçekleştirir ve mevcut girdileri öğrenerek emsal olaylar karşısında emsal kararlar almaya çalışırlar [11].
- Ağ içerisinde paralel yapı olduğu için ağın sahip olunan tüm bilginin hücre içerisinde bağlantılara ulaşmasını sağlar ve hatalı bilgi üretmenin önüne geçer ya da minimal düzeyde hata üretir [11].
- Yapay sinir ağları girdilerden yola çıkarak, hiç bilmediği olaylar karşısında da bunlara benzer sonuçlar üretebilir. Örneklerden yola çıkarak genelleme yapabilirler [11].
- Hata toleransı, ağlarda karşılaşılan eksik ve hatalı durumlarda tüm yapıyı bozmadan belirli ölçüde bozularak ağı öğrenme işlemini gerçekleştirmeye devam etmesi anlamını taşır [11].
- Yapay sinir ağları efektif davranış sergileyebilen modellerdir. Karşımıza çıkabilen sorunlara çözmek için yaşanan değişikliklere hızlıca adapte olurlar [11].
- Yapay sinir ağları önceden eğitilmiş bir ağı eksik olan verilerini tamamlamayaabilir. Örneğin, yarısı çizilmiş bir resmin geri kalanını tamamlayabilir [11].
- Sözel bilgileri işleyemezler, sayısal bilgiler ile çalışabilmektedirler [11].

Yapay sinir ağlarının güvenilirliğini ortaya koymak için performans testine ihtiyaç

duyulur. Bu noktadan hareketle bir YSA için işlem süreci eğitim ve test olmak üzere iki aşamadan oluşmaktadır. Eğitim ve test aşamasına yönelik iki ayrı örnek setleri oluşturulur. Birincisi ağı eğitmek için diğeri de ağın performansını test etmek için kullanılır. Her ağ önce eğitim setiyle eğitilir. Ağ bütün örnekler ya da yeterli sayıda örnek için yeteri derecede doğru yanıtlar/çıktılar ürettiğinde eğitim sonlandırılır. Sonrasında ağı test setindeki daha öncesinde (eğitim sürecinde) tanımadığı örnekler ağı gösterilerek ağı verdiğı yanıtlar (ürettiğı çıktıları) incelenir. Eğer ağ daha önce tanımadığı veri noktaları için kabul edilebilir doğrulukta yanıtlar üretiyorsa, ağın performansı iyi kabul edilir. Ağın performansı yetersizse yeniden eğitmek veya yeni örneklerle eğitmek gibi bir farklı çözümler denenebilir [13].

3.3 Yapay Sinir Ağlarının Avantajları

- Yapay sinir ağları problem çözebilme yetenekleri ve hesaplama biçimleri ile zamanı oldukça efektif kullanabilmektedirler [13].
- Yapay sinir ağları sadece doğrusal olarak çalışmadığı için karşılaşılan pek çok problem için gerçeğe yakın sonuçlar üretebilmektedir [13].
- Yapay sinir ağları bilmediğı farklı ortamlara hızlıca uyum sağlayabilme yeteneğine sahiptir [13].
- Sınıflandırma ve öngörü yeteneğı, hata toleransı vs. birçok özelliğı sebebiyle güçlü modeller oluştururlar [13].
- Verilerde değışiklik olması ya da yeni verilen eklenmesi hainde tekrar eğitilerek çıktı üretebilirler [13].
- Yapay sinir ağları, paralel olarak çalışabilme yeteneğine sahip oldukları için günlük hayata yakınsayabilirler [13].

3.4 Yapay Sinir Ağlarının Dezavantajları

- Sinir ağı, çıktının belirlenmesine ilişkin uygun açıklamayı vermez. Ağı olan güveni azaltır [13].
- Veriler analiz edilirken ağı gelişim süresi bilinmiyor [13].
- Uygun ağ yapısının garantisi yoktur. Yapıyı belirlemek için uygun bir kural yoktur [13].

3.4 Yapay Sinir Ağı Bileşenleri

Yapay sinir ağlarının çalışma mekanizmasını belirleyen üç temel unsur ya da bileşenden söz edilebilir. Bunlar; *mimari yapı*, *aktivasyon fonksiyonu* ve *öğrenme algoritmasıdır*. Her bir bileşen YSA'nın performansı üzerinde etkin bir rol oynarlar.


3.4.1 Mimari Yapı

Yapay sinir ağlarının mimari yapısının en temel birimini sinir hücreleri yani nöronlar ya da düğümler oluşturur. Her bir sinir hücresine diğer sinir hücrelerinden ya da girdi katmanından gelen girdi sinyalleri işlenerek diğer sinir hücre ya da hücrelerinin girdilerini oluşturacak çıktılarına dönüştürülür. Her bir sinir hücresine gelen girdi sinyalleri önceki katmandaki tek bir sinir hücresinden iletilebileceği gibi birden fazla sinir hücresinden de aktarılmış sinyallerin bir birleşiminden ya da toplamından oluşabilir. Bir ya da birden fazla sinir hücresinin çıktılarının diğer bir sinir hücresine girdi olarak iletilmesi işlemi *sinyal akışı* olarak adlandırılır.

Bir yapay sinir hücresi ilk olarak McCulloch ve Pitts tarafından 1943 yılında tanıtılmıştır. [9]. Şekil 3.1 bu ilk yapay sinir hücresinin temel yapısını göstermektedir. Yapay sinir hücresinin ilgili andaki (t) girdi değerleri ($x_i, i = 1, 2, \dots, n$) girdilerin varlığına veya yokluğuna bağlı olarak 1 ya da 0 olacaktır. $t + 1$ anına ilişkin sinir hücresinin çıktı değeri (o) eşitlik (3.1) ile elde edilir.


$$o^{t+1} = \begin{cases} 1, & \text{eğer } \sum_{i=1}^n w_i x_i^t \geq T \\ 0, & \text{eğer } \sum_{i=1}^n w_i x_i^t < T \end{cases} \quad (3.1)$$

Eşitlik (3.1)'de , diğer bir ya da birden fazla sinir hücresinin çıktıları ile oluşturulan x_i girdileri bu girdilere karşılık gelen ağırlık değerleri ($w_i = \pm 1, i = 1, 2, \dots, n$) ile çarpılarak toplanır ve elde edilen nihai değer bir eşik değeri (T) ile birlikte değerlendirilir. Eğer ilgili değer eşik değerinden büyükse sinir hücresinin $t + 1$ anına ait çıktısı (o^{t+1}) 1 değerini, aksi halde 0 değerini alacaktır.



Şekil 3.2 Yapay Sinir Hücresi Yapısı

Bir yapay sinir ağının mimarisini oluşturan ve Şekil 3.3 ile verilen her bir genel yapay sinir hücresinde işlemler eş zamanlı olarak gerçekleştirilir. Bu sinir hücrelerinin çıktıları $[0,1]$ aralığında değerler alırlar. w_i ağırlıkları her bir ana ilişkin gerçekleştirilen sinyal akışı sonrasında güncellenir ve sinyal akışı dışında ağ mimarisinin yapı taşları olan yapay sinir hücreleri arasında bir etkileşim söz konusu olmaz.



Şekil 3.3 Genel Yapay Sinir Hücresi Yapısı

Şekil 3.3'den de görülebileceği gibi genel yapay sinir hücresi birden fazla girdi ve tek bir çıktı bağlantısına sahip bir işlem birimidir. Yapay sinir hücresinin hem girdi hem de çıktı sinyal akışının tek yönlü olarak gerçekleştiği varsayılır. Bu anlamda sinyal akışının tamamen ileri yönlü olduğu ay yapıları *ileri beslemeli yapay sinir ağları* olarak adlandırılır. Bununla birlikte yapay sinir hücre ya da hücrelerinin çıktı sinyallerinin geriye doğru da iletildiği yani gerideki hücrelere girdi olarak iletildiği sinir ağı yapıları da mevcuttur ki bu tür ağlar *geri beslemeli yapay sinir ağları* olarak bilinirler.

YSA'nın mimari yapısında girdi ve çıktı sayısı genellikle probleme özgü olarak kullanıcı kararı dışında belirlenirken, eğer mimari yapıda kullanımı öngörülüyorsa girdi ve çıktılar arasında kullanılacak gizli tabaka ve gizli tabaka birim sayısı kullanıcı tarafından belirlenebilir parametrelerdir.

3.4.2 Aktivasyon Fonksiyonu

YSA'nın bir diğer temel bileşeni aktivasyon fonksiyonudur. Aktivasyon fonksiyonu girdiler ile çıktılar arasındaki eşleşmeyi sağlayan bir fonksiyondur. Fonksiyonun yapısına göre bu eşleşme doğrusal ya da doğrusal olmayan yapıda olabilir. Aktivasyon fonksiyonun seçimi YSA performansını oldukça ve doğrudan etkileyen faktörlerden biridir. Bir yapay sinir hücresinin çıktısını hesaplamada kullanılan aktivasyon fonksiyonu genel yapay sinir hücresi yapısını gösteren Şekil 3.3'de $f(\mathbf{w}^t \mathbf{x})$ ile verilmişti. Bir sinir hücresine gelen girdi sinyallerinden oluşan *girdi vektörü* ile ilgili sinir hücresine girdi sinyali gönderen diğer yapay sinir hücrelerinin bağlantılarını sağlayan *ağırlıkların* skaler bir çarpımı sinir hücresinin *net* aktivasyon değeri elde edilir. Farklı YSA yapılarında farklı aktivasyon fonksiyonları kullanılmaktadır. Bunlar YSA'nın farklı tabakalarında farklılık gösterebileceği gibi aynı tabakanın her bir biriminde de farklı türde kullanılabilirler. Bu fonksiyonlar genel olarak *tek kutuplu*, *çift kutuplu* ya da *doğrusal* yapıdadırlar. Bununla birlikte *sürekli* ve *kesikli* yapıda aktivasyon fonksiyonlarından da söz edilebilir. Bazı aktivasyon fonksiyon türlerine karşılık yapay sinir hücresinin üreteceği çıktıların yapısına ilişkin bir özet bilgi Tablo 3.2 ile sunulabilir.

Tablo 3.2 Aktivasyon Fonksiyonu Türü Yapay Sinir Hücresi Çıktı İlişkisi

Aktivasyon Fonksiyonu Türü		Yapay Sinir Hücresi Çıktı Değeri
Tek kutuplu	Sürekli	$o \in (0,1)$
	Kesikli	$o \in \{0,1\}$
Çift kutuplu	Sürekli	$o \in (-1,1)$
	Kesikli	$o \in \{-1,1\}$

YSA literatürün de sıklıkla kullanılan aktivasyon fonksiyonları şu şekilde sıralanabilir.

- Doğrusal aktivasyon fonksiyonu:

$$f(net) = net \quad (3.2)$$

- Adımsal aktivasyon fonksiyonu:

$$f(net) = \begin{cases} 0, & net > 0 \\ 1, & net < 0 \end{cases} \quad (3.3a)$$

ya da

$$f(net) = \begin{cases} -1, & net > 0 \\ 1, & net < 0 \end{cases} \quad (3.3b)$$

- λ eğim parametresini göstermek üzere Lojistik aktivasyon fonksiyonu:

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} \quad (3.4a)$$

ya da

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} - 1 \quad (3.4b)$$

- Radyal Temelli aktivasyon fonksiyonu:

$$f(net) = \exp(-\lambda net^2) \quad (3.5)$$

- Tanjant hiperbolik aktivasyon fonksiyonu:

$$f(net) = \frac{\exp(net) - \exp(-net)}{\exp(net) + \exp(-net)} \quad (3.6)$$

- Sinüs, Kosinüs aktivasyon fonksiyonu:

$$f(net) = \sin(net) \quad (3.7a)$$

$$f(net) = \cos(net) \quad (3.7b)$$

3.4.3 Öğrenme Algoritması

YSA'nın en belirgin ve üstün özelliği bir bilgi kaynağından öğrenebilme yeteneğine sahip olmasıdır. Burada bilgi kaynağını veri oluşturmaktadır. YSA işleyişinde öğrenme işlemi yapay sinir hücreleri arasındaki bağlantıları oluşturan ağırlıkların en uygun değerlerinin bulunması işlemidir. Bu işlemler bütünü *ağın eğitimi* olarak anılır. Ağın eğitimi bir başka ifade ile öğrenme ağırlıklarının önceden belirlenmiş bir ölçüte dayalı olarak iteratif bir süreç içerisinde adım adım yinelenerek en iyi ya da uygun değerlerine ulaşmasını amaçlayan bir algoritma ile gerçekleştirilir. Bu algoritma YSA literatürünün de *eğitim algoritması* olarak bilinir. Temelde YSA'nın en iyi ağırlıklarının elde edilmesi bir optimizasyon problemidir. Bu noktada bu problem için farklı optimizasyon algoritmaları kullanılmaktadır. Bunlardan bazıları türeve dayalı klasik optimizasyon algoritmaları iken bazıları da genetik algoritmalar, parçacık sürü optimizasyonu, yapay arı kolonisi ve tabu arama algoritması gibi sezgisel ve meta-sezgisel algoritmalar da sıklıkla kullanılmaktadırlar.

İster klasik olsun ister sezgisel olsun bu öğrenme algoritmalarının tamamı, farklı *öğrenme kurallarına* göre eğitim sürecini gerçekleştirirler. Temelde *denetimli* (supervised) ve *denetimsiz* (unsupervised) olmak üzere iki öğrenme kuralından bahsedilebilir. Denetimli öğrenme elde edilecek bir çıktı değerine karşılık gelen bir hedef değer olduğu durumdur. Bu tür bir öğrenme kuralında öğrenme algoritması, YSA çıktı ile hedeflenen değer arasındaki farkı yani hatayı her bir adımda azaltacak bir strateji ile çalışır ve ağırlıkları bu doğrultuda günceller. Kısacası, denetimli bir öğrenme kuralı ile çalışan öğrenme algoritması YSA çıktıları ile hedefleri arasındaki farkın bir fonksiyonunu minimum yapacak ağırlık değerlerini bulmayı amaçlar. Denetimsiz öğrenme kuralında ise elde edilecek bir çıktı değerine karşılık gelen bir hedef değer varlığından söz edilemez. Girdi değerleri kendi içlerindeki benzerliklere göre kümelendirilirler yani bu tür bir öğrenme kuralında girdi veri setlerindeki istatistiksel düzeni ya da örüntüyü en iyi bir şekilde yakalayacak çıktı yapısını oluşturacak ağırlıkların belirlenmesi gerçekleştirilir


3.5 Yapay Sinir Ağı Modelleri

Yapay sinir ağlarını, en temel anlamda, mimari yapılarına göre tek ve çok katmanlı yapay sinir ağları olarak sınıflandırmak mümkündür. Bununla birlikte, YSA, yapay sinir

hücreleri arasındaki sinyal akışının yönü ya da yönlerine bağlı olarak ileri ve geri beslemeli yapay sinir ağları olarak da ayrı bir sınıflandırmaya tabi tutulabilir.

3.5.1 Tek Katmanlı Algılayıcılar


Bu algılayıcılar, ilk bulunan YSA modeli olduğu için sınırlı bir yapıda çalışabilirken, bu ilk modelden sonra geliştirilen tüm modellere yapıtaşı olmuştur. Tek katmanlı algılayıcılar, bir veya birden çok girdiden oluşur ve ağın tek bir sinir hücresinden oluşan çıktı katmanı söz konusudur (Şekil 3.5). Her bir girdi değeri de bir ağırlık değeriyle çıktı katmanına bağlanır. Tek katmanlı algılayıcıların *basit algılayıcı model (Perceptron)* ve *ADALİNE/MADALİNE* gibi farklı modellerinden bahsedilebilir [11,14,15].



Şekil 3.4 Tek Katmanlı Algılayıcı YSA Modeli

3.5.2 Basit Algılayıcı Model


Basit algılayıcılar birden fazla girdi ile tek bir çıktı üretme prensibine dayanarak çalışır. Ağın sonucu 1 veya 0'dan oluşur. Sonuç değerinin oluşması, toplama fonksiyonundan elde edilen değer eşik değeri ile karşılaştırılması ile gerçekleştirilir. Yani toplama fonksiyonu ile elde edilen değer bir eşik fonksiyonundan geçirilerek nihai çıktıya dönüştürülür [11,14,15].



Şekil 3.5 Basit Algılayıcı Model Yapısı

3.5.3 ADALINE Modeli

Bernard Widrow, ADALINE (Adaptive Linear Neuron) modelini 1959’da Stanford üniversitesinde geliştirilerek ortaya koymuştur [16]. Temeli en küçük kareler ortalaması yöntemine dayanmaktadır. Bütün yapay sinir ağları içerisinde en basit olanıdır. ADALINE modelinin yapısı basit algılayıcı modele benzer, ondan tek farklılığı öğrenme kuralının farklılığıdır [17].



Şekil 3.6 ADALINE Model Yapısı


3.5.4 MADALINE Modeli

Widrow ve Hoff, birçok uyarlanabilir (adaptive) birim içeren MADALINE yapay sinir ağı modelini de geliştirdiler [17]. Genellikle iki katmandan oluşan MADALINE (Many

Adaline) adından da anlaşılacağı gibi birden çok ADALINE'dan oluşmuş bir yapay sinir ağıdır. Her katmanda farklı ve çok sayıda ADALINE olabilir. [17].

3.5.4 Çok Katmanlı Algılayıcılar

Tek katmanlı ve tek bir yapay sinir hücresinden oluşan YSA özellikle doğrusal olmayan problemlerin çözümünde yetersiz kalabilmektedirler. Bu tür bir sorunla başa çıkabilmek adına, çok katmanlı algılayıcılar ve YSA geliştirilmiştir. Genel olarak bir ya da çok yapay sinir hücresinin oluşturduğu birden fazla katman *çok katmanlı yapay sinir ağlarını* (ÇKYSA) oluşturur. Bir ÇKYSA mimarisi *girdi katmanı*, *gizli katman* ve *çıkı katmanı* olmak üzere genellikle üç ana katmandan oluşur. *Katman* terimi literatürde sıklıkla *tabaka* olarak da anılmaktadır. Bu nedenle bu tez kapsamında bu iki terim de zaman zaman kullanılmıştır. ÇKYSA tek bir girdi tabakası ve tek bir çıkı tabakasına sahipken bir ya da birden fazla çıkı tabakasına sahip olabilir. Bir ÇKYSA için gizli tabaka sayısının ve her bir tabakadaki yapay sinir hücresi ya da birim sayısının belirlenmesi gerçekte yapay sinir ağının mimari yapısının belirlenmesi anlamını taşımaktadır. Şekil 3.4 bir çok katmanlı yapay sinir ağı mimarisi sunmaktadır.




Şekil 3.7 Çok Tabakalı YSA Yapısı

3.5.5 İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları (İBYSA) Werbos [18] tarafından literatüre kazandırılan ve Rumelhart vd.[18] tarafından geliştirilen çok katmanlı algılayıcılardır. İleri beslemeli ağlar, girdi tabakası, gizli tabaka(lar) ve çıkı tabakası olmak üzere üç tabakadan oluşur.

İleri beslemeli YSA tabakalar ve bu tabakalar da ağıın en temel birimleri olan yapay sinir hücrelerinden oluşur. Aynı tabakadaki nöronlar arasında bir bağlantı bulunmaz. İleri beslemeli yapay sinir ağlarında nöronlar arası iletişim tek yönlü olarak ileri doğru çalışmaktadır. Bu yapının bir prototipi Şekil 3.5 ile verilmiştir. Girdi tabakasında girdiler hiçbir işleme tabi tutulmadan gizli katmana aktarılır. Her bir girdinin ağırlıklarla (W_h) çarpılarak toplanmasından oluşan değerlere yan değerlerinin (θ_h) eklenmesiyle (Σ) her bir gizli tabaka biriminin *net* değerleri oluşturulur ve bu *net* değerleri bir aktivasyon fonksiyonundan geçirilerek (f_1) ilgili gizli tabaka biriminin çıktısına dönüştürülür. Bu çıktılar, çıktı tabakası birimi için girdileri oluşturur ve benzer şekilde ilgili ağırlık (W_o) ve yan (θ_o) değerleri vasıtasıyla çıktı tabakası biriminin net değeri elde edilir. Bu değer de yine bir aktivasyon fonksiyonundan (f_2) geçirilerek YSA'nın nihai çıktısı elde edilir.




Şekil 3.8 İleri Beslemeli YSA Yapısı

3.6.6 Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağları (GBYSA) da tıpkı ileri beslemeli ağlar gibi Werbos [18] tarafından literatüre kazandırılan ve Rumelhart vd. [18] tarafından geliştirilen bir tür çok katmanlı algılayıcıdır. Bu yapay sinir ağlarında en son çıktı veya gizli tabakada üretilen çıktılar, girdi ya da bir önceki gizli tabaka birimlerine girdi olarak tekrar beslenirler. Böylelikle nöronlarda veya katmanlardaki bilgileri, hem ileri hem de geri yönde iletmış olurlar. Geri besleme, nöronların kendi içerisinde olduğu gibi katmanlar arası nöronlar içerisinde de olabilir. Bu yeteneği sayesinde, doğrusal olmayan süreçler de başarıyla sonuç verir. Elman [19] tarafından önerilen geri beslemeli ağlar ise yapısında bulunan üç tabakanın yanı sıra gizli tabaka çıktılarını ağa girdi olarak gösteren *bağlam* ya da *içerik*

(context) tabakasını da içermektedir. Ağ böylece bir geri besleme mekanizmasını işletmektedir. Bir Elman-GBYSA mimarisi Şekil 3.6 ile verilmiştir.



Şekil 3.9 Geri Beslemeli YSA Yapısı


4. MATERYAL YÖNTEM

Bu tez çalışması ile, Türkiye’de aktif olarak faaliyet gösteren 6 sigorta şirketlerinin 3 farklı alandaki prim üretim büyüklüklerine ilişkin veri setleri farklı yapay sinir ağları ile analiz edilmiş ve bu veri setlerine ilişkin öngörüler elde edilmiştir. Birer öngörü aracı olarak kullanılan iki farklı yapay sinir ağı hem farklı yapıları hem de farklı özellikleri ile ele alınmış ve birbirinden farklı sekiz öngörü aracı oluşturulmuştur.

Temelde kullanılan iki yapay sinir ağı, Şekil 4.1 ve Şekil 4.2 ile verilen, İBYSA ve GBYSA olarak belirlenmiştir. Her iki YSA türünde de tek bir gizli tabaka ve çıktı tabaka biriminde (4.1) ve (4.2) ile verilen iki farklı aktivasyon fonksiyonu (*doğrusal* ve *lojistik*) kullanılmıştır.


$$f(x) = x \quad (4.1)$$

$$f(x) = \frac{1}{1+\exp(-x)} \quad (4.2)$$



Şekil 4.1 İBYSA mimarisi

Bu şekilde oluşturulan dört farklı YSA yapısının eğitimleri birer geri yayılım öğrenme algoritması olan *Levenberg-Marquardt* eğitim algoritması ve *Bayesci Düzenleştirme Geri Yayılım* eğitim algoritması (Bayesian regularization backpropagation) kullanılmıştır. Böylece toplamda farklı özellik ve yapılarla sahip 8 yapay sinir ağı öngörü aracı olarak kullanılmıştır.



Şekil 4.2 Elman-GBYSA mimarisi

4.1 Levenberg – Marquardt Öğrenme Algoritması

İleri ve geri beslemeli ağların her ikisinde de kullanılan öğrenme algoritmaları, uygunluk fonksiyonu olarak da bilinen ve ağın çıktısı ile hedef değeri arasındaki farktan oluşan hatanın bir ölçütünü en küçük yapacak ağırlıkları elde edebilmek için, performans fonksiyonunun gradyanını kullanırlar. Bu amaçla kullanılan en yaygın öğrenme

algoritmaları geri yayılım öğrenme algoritması (GYÖA) ailesidir. GYÖA, ağ mimarisi boyunca oluşturduğu gradyen hesaplamalarını geriye doğru yayarak öğrenimi gerçekleştirir. *Gradyen azalması* algoritması en basit GYÖA olarak bilinir ancak bu algoritma pek çok problem için optimuma oldukça yavaş yaklaşmaktadır.

Gradyen azalması algoritmasına göre daha hızlı yakınsayan ve genellikle yüksek performans sergileyebilen, *eşlenik gradyen*, *Newton* ve *Levenberg - Marquardt* öğrenme algoritmaları klasik sayısal optimizasyon yöntemlerini kullanırlar.

Bahsedilen bu öğrenme algoritmaları, önceki algoritmaların üstün yönlerini geliştirme kötü yönlerini ise ortadan kaldırmaya yönelik olarak tasarlanarak, mevcut algoritmalara alternatif algoritmalar sunarlar. Benzer şekilde Levenberg – Marquardt (LM) algoritması da, Newton ve Gradyen Azalması algoritmalarının üstün özelliklerini barındırırken ve bunların içerdiği kısıtlama ve yetersizlikleri ortadan kaldıran özelliklere sahiptir [40].

Newton öğrenme algoritması (NÖA), eşlenik gradyen öğrenme algoritmasına alternatif olarak literatüre kazandırılmıştır. NÖA için ana işlev, uygunluk fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinden oluşan, *Hessian* matrisini oluşturmaktır. Eşitlik (4.3) ile verilen *Hessian* matrisi, ağırlık uzayının farklı doğrultularındaki gradyen değişimini ifade eder.

$$H(n) = \frac{\partial^2 E(n)}{\partial w^2(n-1)} \quad (4.3)$$

Eşitlik (4.3)'de H , Hessian matrisini temsil ederken E değerlendirme ya da uygunluk fonksiyonunu ifade etmektedir. w ise YSA'nın ağırlığıdır. Uygunluk fonksiyonu, toplam hata ya da karesel hata ortalaması gibi, YSA çıktıları ile hedef değerleri arasındaki farkın farklı yapıdaki fonksiyonları olarak tanımlanabilir. Bu tez kapsamında da, çoğu ileri beslemeli YSA'da olduğu gibi, ortalama karesel hata ya da bir başka ifade ile hata kareler ortalaması uygunluk fonksiyonu olarak tercih edilmiştir.

$$E(n) = E_{ort}(n) \sum_{n=1}^N \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.4)$$

Eşitlik (4.4)'de N , öğrenme örneği sayısını, $e_j, j = 1, 2, \dots, C$, hata değerini, C , ağın çıkış katmanındaki bütün yapay sinir hücrelerini içeren kümeyi göstermektedir. d_j ilgili

öğrenme örneği için ilgili çıktı tabakası yapay sinir hücresince temsil edilen hedef değeri ve y_j YSA'nın karşılık gelen çıktısını temsil etmektedir. Bu durumda hata Eşitlik (4.5) ile elde edilebilir.

$$e_j(n) = d_j(n) - y_j(n) \quad (4.5)$$

Ağırlıkların güncellemesi Hessian matrisinin elde edilmesi ve akabinde bunun tersi alınarak gerçekleştirilebilir. Ancak bir YSA eğitiminde Hessian matrisi hesaplaması kolay olmayan ve karmaşık işlemler gerektiren bir işlemdir. Bu sorunun üstesinden gelebilmek adına *Quasi-Newton* (Q-N) yöntemleri olarak bilinen ve ikinci dereceden türevlerin hesaplanmasına ihtiyaç duymayan, bunun yerine eğitim sürecinin her bir yinelemesinde Hessian matrisinin yaklaşık bir yapısını kullanan, algoritmalar geliştirilmiştir.

LM eğitim algoritması da tıpkı Q-N yöntemleri gibi, Hessian matrisi yerine onun yaklaşık bir yapısını kullanır. LM algoritması, Hessian matrisinin yaklaşık bir yapısını Eşitlik (4.6)'da verildiği gibi üretir.

$$H(n) = J^T(n)J(n) + \mu I \quad (4.6)$$

Eşitlik (4.6)'da, μ Marquardt parametresi, I birim matrisini temsil eder. Hataların ağırlıklara göre birinci türevleri Jakobien (J) matrisini oluşturur ve bu matris Eşitlik (4.7) ile elde edilir.

$$J(n) = \frac{\partial \mathbf{e}(n)}{\partial \mathbf{w}(n-1)} \quad (4.7)$$

Burada $\mathbf{e}$, YSA hata vektörüdür. Jakobien matrisi, Hessian matrisine göre daha kolay hesaplanabilir olduğundan uygulamada tercih edilir. YSA için gradyen ise Eşitlik (4.8)'deki gibi elde edilir,

$$\mathbf{g}(n) = J^T(n)\mathbf{e}(n) \quad (4.8)$$

Böylece YSA ağırlıkları ise Eşitlik (4.9) ile verilen ifadeye dayalı olarak değiştirilerek güncellenir.

$$\mathbf{w}(n+1) = \mathbf{w}(n) - [H(n)]^{-1}\mathbf{g}(n) \quad (4.9)$$

Skaler bir sayı olan Marquart parametresi, μ , sıfır değerini aldığı anda, algoritma yaklaşık Hessian matrisini kullanan *Newton algoritması*; büyük bir değer aldığı anda ise, küçük adımlı *gradyen azalması algoritması*na dönüşecektir.

Genel olarak LM algoritmasının yavaş yakınsama problemini içermediği söylenebilir. Temel olarak hedef, uygunluk fonksiyonu en küçük yapacak YSA ağırlıklarını elde edilmesidir [21,22].

4.2 Bayesci Düzenleme Öğrenme Algoritması

Bir YSA eğitimi için Bayesci çerçeve, ağı parametrelerinin yani ağırlıkların olasılıksal dağılımına dayanmaktadır [23].

Yani, bir hata fonksiyonunu en aza indirerek optimal bir ağırlık kümesinin seçildiği geleneksel ağı eğitiminin aksine, Bayes yaklaşımı ağı ağırlıklarının bir olasılık dağılımını içerir ve sonuç olarak, YSA'nın parametre tahminleri de bir olasılık dağılımına dayalı olacaktır [24,25].

Bu algoritma için de eğitim sürecinde, hedef ve çıktı değerleri arasındaki mesafe yani hata için bir uygunluk fonksiyonu benzer şekilde Eşitlik (4.10) ile oluşturulabilir.

$$E(n \setminus w, M) = \text{mean}(e_j^2(n)) \quad (4.10)$$

Bu eşitlikte, w YSA'nın optimize edilmeye çalışılan ağırlıklarını ve M ise, tabaka sayısı,

her tabakadaki birim sayısı ve her birim tarafından uygulanan aktivasyon fonksiyonu türünün bir bütününden oluşan bir sinir ağı mimarisini temsil etmektedir. bayesci düzenleme (BD) öğrenme algoritması aşırı uyumdan kaçınmak için erken durdurma düzenlemesi ile elde edilebilecek daha düşük varyans özelliğine sahip olmasının yanı sıra yine erken durdurma ile oluşabilecek artan yanlılığı ise bertaraf eder [24]. BD öğrenme algoritması büyük ağırlıkları meydana getirebileceği derin dalgalanmaları önlemek için amaç fonksiyonuna bir ceza terimi ekler ve uygunluk fonksiyonu Eşitlik (4.11)'deki hale dönüşür [26,27,28,29].

$$F = \beta E(n \setminus w, M) + \alpha E(w \setminus M) \quad (4.11)$$

Eşitlik (4.11)'de $(w \setminus M)$ terimi aşağıdaki gibi tanımlanır.

$$E(w \setminus M) = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (4.11)$$

Ayrıca α ve β fonksiyonun hiperparametreleridir.

5. LİTERATÜR İNCELEMESİ

Oluşturulan tez çalışmasının araştırma sorusu olarak; finansal bir zaman serisi oluşturacak sigorta prim üretiminin yapay sinir ağları ile ne düzeyde etkin ve güvenilir şekilde öngörülebileceğidir. Sigorta sektörüne yönelik olarak, Hawley, Johnson ve Raina [31] ve ayrıca Wilson ve Wilson [32] sigorta sektöründe iflas tahmini için yapay sinir ağlarını kullanarak bir çalışma gerçekleştirmişlerdir. Huang, Dorsey ve Boose [27] hayat sigortası mali sıkıntı tahmini için bir yapay sinir ağı modelinin kullanımını önermişlerdir. Kitchens [33] çalışmasında otomobil sigortasında kayıplarını tahmin etmek için yapay sinir ağının kullanımını tercih etmiş ve ilgili metodolojiyi önermişlerdir. Bayır [34] çalışmasında yapay sinir ağlarını kullanarak bir tahmin modellemesi üzerinde uygulama yapmıştır. Türkiye’deki imalat sanayi ihracat değerleri için yapay sinir ağları ve çoklu doğrusal regresyon analizi ile tahmin modelleri kurularak karşılaştırılmış. Doğan [35] Türkiye’de faaliyet gösteren özel bir sigorta şirketine ilişkin portföy değerlendirmesini yapay sinir ağları ile gerçekleştirilmiştir. (Uslu) [36] çalışmasında klasik zaman serileri yöntemleri ile yapay sinir ağları kestirimlerinin karşılaştırıldığı çalışma ortaya koymuştur. Uzun dönemli Türkiye elektrik enerjisi tüketimi kestiriminde zaman serisi yöntemlerinden, “Box-Jenkins” ve “Yapay Sinir Ağları” yöntemlerinin kestirim başarılarını karşılaştırarak en yüksek başarıyı sağlayan yöntem belirlenmeye çalışılmıştır. Bahia [37] ise Irak ulusal sigorta kurumuna ilişkin gelir tahminini ortaya koymak için yapay sinir ağlarını kullanmıştır. Kitchens ve Harris [33] sigorta taleplerini genetik uyarlanabilir sinir ağları ile tahmin etmişlerdir. Sakthivel ve Rajitha [38] ise hayat dışı sigortalarda gelecek hasar sıklığının tahmininde yapay sinir ağlarından faydalanmışlardır. Çetinkaya [39] ise 2006-2019 yılları arasındaki çeyrek dönemli gözlenen Türkiye’deki hayat sigortası prim üretimlerini klasik zaman serisi çözümleme yaklaşımları ve yapay sinir ağları ile öngörmüş ve elde edilen sonuçları karşılaştırmalı olarak değerlendirmiştir. Høysæter ve Larsplass [40] birden çok sigorta poliçesinde müşteri taleplerinin öngörülmesi için yapay sinir ağlarının da dahil olduğu farklı öngörü araçlarını kullanmış ve sonuçları karşılaştırmalı olarak değerlendirmiştir. Günümüze geldiğimizde Kılınç [36] kalp krizini tahmin etmek için yapay sinir ağı yöntemlerini kullanmıştır. Sigortacılık

sektörünün çeşitli alanlarında yapılan çalışmalar incelendiğinde birçok çalışmada yapay sinir ağları oluşturulan öngörü modellerinin görülmektedir.

Sigorta günümüzde sosyal ve ekonomik açıdan önemli bir yere sahiptir. Hem sosyal yaşam hem de ekonomik açıdan önemli bir yere sahiptir. Literatürde ortaya konan çalışmalar derlendiğinde görülmektedir ki, geçmiş yıllara ait çalışmalar bulunmasına rağmen son yıllarda, sigorta prim hacmi ya da büyüklüğünün öngörülmesi üzerinde yapay sinir ağlarının kullanıldığı bir çalışma ortaya konmuş değildir. Bu noktada, bu tez önerisi ile ortaya konması planlanan çalışmanın önemi iki farklı bakış açısı ile ortaya konulabilir; birincisi, sigorta prim hacminin öngörülmesi amacıyla, öngörü başarısı birçok finansal zaman serisi probleminde ortaya konmuş, farklı yapıda ve özellikte yapay sinir ağlarının kullanımı ile tatmin edici, etkili, anlaşılır ve güvenilir öngörü sonuçları elde edilebilecek, bir başka ifadeyle; geleceğe ilişkin sigorta prim büyüklükleri doğruya olabildiğince yakın bir şekilde öngörülebilecektir. İkinci bakış açısı ise, sigorta sektörünün ülke ekonomileri ve kalkınma düzeyleri ile doğrudan bir neden-sonuç ilişkisi içinde olması dolayısıyla, elde edilecek gerçekçi ve güvenilir öngörüler ile ülke ekonomisi ve kalkınma düzeyine ilişkin geleceğine yönelik bir perspektif ve tahmin modeli oluşturulabilecektir. Bu noktada, Türkiye’de faaliyet gösteren ve sektörün öncü rolünü üstlenen sigorta şirketlerinin prim üretim hacimlerinin yapay sinir ağları analiz edilmesi sonucunda, ülke ekonomisi ile doğrudan ilişkilendirilebilecek gerçekçi öngörüler ortaya konabilecektir. Faaliyet gösteren şirketlerin finansal yapıları değerlendirilerek sektör hakkında bilgi verip, geleceğe dair fikirlerde bulunulabilecektir ve bir tahmin modeli oluşturulabilecektir. Bu bakımdan bu tezin sonraki çalışmalara ışık tutacak ve yardımcı olacak nitelikte olması beklenmektedir.

6. UYGULAMA

6.1 Uygulama Tanımı

6.1.1 Veri Setleri

Uygulamada, 2015-2021 yılları arasında Türkiye’de faaliyet gösteren ve prim hacmi göz önünde bulundurularak ilk 10’a giren şirketler arasından seçilen 6 şirketin 3 farklı branş bazında prim üretimleri aylık ve çeyreklik dönemlerde analiz edilerek yapay sinir ağları ile öngörölmüştür. Türkiye Sigortalar Birliği (TSB) web sitesinden

(<https://www.tsb.org.tr/tr>) edinilen veriler aylık ve çeyreklik olarak düzenlenip, her bir şirket ve her bir branş için aylık bazda 84, çeyreklik bazda 28 gözleme sahip zaman serileri oluşturulmuştur.

6.1.2 Prim Tahmin Problemin Tanımlanması

Bu tezin temel amaçlarından biri, pandemi dönemi sonrasında ve ekonomik hareketlilikler dolayısıyla oluşan enflasyon dalgalanmalarının getirdiği belirsizliğin prim üretim öngörülerinde oluşturduğu belirsizliği bir miktar da olsa ortadan kaldırarak, sektör ve farklı alan kullanıcılarına mümkün olduğunca doğru ve güvenilir öngörüler sunabilmektir.

6.1.3 Uygulamanın Konusu

Uygulama konusu, Türkiye’de faaliyet gösteren ve prim hacmi göz önünde bulundurularak ilk 10’a giren şirketler arasından seçilen 6 şirketin 3 farklı branş bazında prim üretimleri aylık ve çeyreklik dönemlerde analiz edilerek yapay sinir ağları ile öngörülmesidir. Bu doğrultuda ileri ve geri beslemeli olmak üzere temel olarak iki farklı yapay sinir ağının Levenberg-Marquardt ve Bayesci Düzenleştirme Geri Yayılım eğitim algoritmaları ile eğitilmesi ve ağların çıktı tabakalarında sigmoid ve doğrusal olmak üzere iki farklı aktivasyon fonksiyonun kullanılması ile 8 farklı öngörü aracı uygulamada kullanılmış ve ilgili zaman serileri için en üstün YSA modelleri belirlenmiştir. Öngörü sürecini oluşturan uygulamalar sırasında, veri setlerini oluşturan zaman serileri, yapay sinir ağlarının eğitimini gerçekleştirmek amacıyla kullanılacak “eğitim kümesi” ve yapay sinir ağlarının öngörü performansını değerlendirmek ve öngörülerin güvenilirliğini ortaya koymak amacıyla kullanılacak “test kümesi” veri seti olmak üzere iki ayrı bölüme ayrılmıştır. 84 gözlem değerine sahip aylık veri setleri için test kümesi büyüklüğü 12 olarak belirlenmiş yani bir senelik bir öngörü periyodu oluşturulmuştur. 28 gözlem içeren çeyreklik veri setleri için de benzer şekilde bir senelik bir öngörü periyodu oluşturularak 4 gözlem test kümesi olarak belirlenmiştir.

6.1.4 Uygulamanın Amacı

Türkiye’de faaliyet gösteren bazı sigorta şirketlerinin prim üretimlerinin farklı yapay sinir ağları ile öngörülmesi ve elde edilen sonuçların karşılaştırmalı olarak değerlendirilerek ilgili veri setleri için YSA’na dayalı en uygun öngörü modelinin belirlenmesidir.

6.1.5 Uygulamanın Önemi

Sigorta sektörü, finans piyasalarına fon oluşturmaları ve risk karşılaması özellikleri ile ülke ekonomisi ve kalkınması üzerinde doğrudan etkisi olan bir sektör olarak görülebilir. Bu bakımdan, sigorta sektörünün hacmini oluşturan temel unsur olan prim büyüklüklerinin olabildiğince doğru ve güvenilir bir şekilde öngörülmesi, dolaylı olarak ülke ekonomisi ve kalkınması açısından ortaya çıkması muhtemel risklerin öngörülmesi ve gerekli tedbirlerin alınması anlamını taşımaktadır.

6.1.6 Uygulama Modelleri

Daha önce de belirtildiği gibi ilgilenilen veri setleri İleri ve Elman-geri beslemeli YSA olmak üzere iki YSA türü ile analiz edilmiş olmasına karşın bu YSA yapılarında farklı eğitim algoritmaları ve aktivasyon fonksiyonlarının kullanımı ile YSA'na dayalı 8 farklı öngörü modeli oluşturulmuştur. Bu modeller şu şekilde sıralanabilir:

Model 1: İBYSA - LM Eğitim Algoritması - Doğrusal Aktivasyon Fonksiyonu

Model 2: İBYSA - LM Eğitim Algoritması - Sigmoid Aktivasyon Fonksiyonu

Model 3: İBYSA - BD Eğitim Algoritması - Doğrusal Aktivasyon Fonksiyonu

Model 4: İBYSA - BD Eğitim Algoritması - Sigmoid Aktivasyon Fonksiyonu

Model 5: GBYSA - LM Eğitim Algoritması - Doğrusal Aktivasyon Fonksiyonu

Model 6: GBYSA - LM Eğitim Algoritması - Sigmoid Aktivasyon Fonksiyonu

Model 7: GBYSA - BD Eğitim Algoritması - Doğrusal Aktivasyon Fonksiyonu

Model 8: GBYSA - BD Eğitim Algoritması - Sigmoid Aktivasyon Fonksiyonu

6.6 Genel Uygulama Sonuçları

Uygulamada model derecesi olarak adlandırabileceğimiz YSA girdi tabakası birim sayısı (GTBS) ya da kısacası model girdi sayısı 1 ile 12 arasında değiştirilerek alınmıştır. Benzer şekilde YSA gizli tabaka birim sayısı (HTBS) da yine 1 ile 12 arasında değiştirilmiştir. Böylece her bir YSA öngörü modeli için $12 \times 12 = 144$ farklı çözümleme gerçekleştirilmiştir. Tablo 6.1 her bir sigorta şirketinin her bir branşı için en iyi öngörü

sonuçlarını üç hata metriği cinsinde özetlemektedir. Tablo 6.1 ayrıca en iyi öngörü sonuçlarının elde edildiği YSA modellerini ve bu modellerin mimari yapısını da içermektedir.


Tablo 6.1 incelendiğinde, tatmin edici bir öngörü aracından temel beklentinin %10 civarı ve altında bir hata ile öngörüler üretmesi olduğu dikkate alındığında, bazı veri setleri için OMYH metriği bakımından bu hata seviyesinin üstünde hataların gözlemlendiği görülmektedir. Ancak bu durum ilgili öngörü araçlarının tatmin edici sonuçlar üretmediği anlamını taşımamaktadır. Özellikle Mutlak yüzdelik hataların medyan cinsinde bir değerini veren MdMYH metriği bakımından hemen tüm veri setlerinin aranan seviyede ve daha altında hatalarla tahminler ürettiği görülmektedir. Bu iki metrik arasında oluşan bu temel farklılık, öngörü modellerinin özellikle aylık verilerde 12 aylık öngörü periyodu içerisinde birçok ay için oldukça düşük hata seviyesine sahip tahminler üretmesine karşın bir ya da birkaç ay için yapılan öngörü hatalarının yüksek olması ortalama cinsinde yüzdelik hata düzeyini yanıltıcı bir şekilde yukarı çekmektedir. Bu bakımdan, MdMYH hata kriteri bakımından, toplamda 18 aylık 18 çeyreklik olmak üzere toplam 36 veri setinin analizinde yalnızca 6 veri seti için öngörüler %10 düzeyinin üzerinde hata ile tahmin edilmiştir ki bunların 5'i %10 civarı ve hemen üzerinde olduklarından yine de kabul edilebilir bir seviyede hata düzeyine sahiptirler. Burada vurgulanmak istenen %10 üzerinde bir hata ile elde edilen öngörüler için de aylık bazda birkaçı dışında hemen tüm aylar için hata düzeyi kabul edilebilir seviyenin altında gerçekleştiğidir. Bu durum ayrıca bir sonraki alt bölümde bazı grafik ve yorumlarla da desteklenmiştir.

Şirket	Dönem	Branş	Hata Metriği			En İyi Model	En İyi Mimari	
			HKOK	OMYH	MdMYH		GTBS	HTBS
A	M	Sağlık	54587	31.47%	17.87%	Model 7	2	9
		Kasko	16341	11.83%	4.79%	Model 6	11	10
		Trafik	69123	17.92%	9.49%	Model 5	4	6
	Q	Sağlık	53781	40.22%	4.13%	Model 3	4	4
		Kasko	49842	10.04%	2.60%	Model 5	1	3
		Trafik	85987	9.45%	1.66%	Model 3	4	4
B	M	Sağlık	80866	11.93%	6.41%	Model 3	6	2
		Kasko	10224	6.83%	4.34%	Model 8	11	11
		Trafik	33682	12.55%	6.99%	Model 3	7	2
	Q	Sağlık	49862	3.71%	1.94%	Model 3	4	3
		Kasko	25721	4.78%	2.91%	Model 5	4	4
		Trafik	30251	5.81%	4.98%	Model 4	1	4
C	M	Sağlık	11014	8.46%	7.01%	Model 2	11	2
		Kasko	25723	10.78%	8.41%	Model 3	12	4
		Trafik	27018	9.99%	3.46%	Model 4	5	2
	Q	Sağlık	32656	5.67%	1.25%	Model 2	3	2
		Kasko	22029	3.60%	2.01%	Model 6	4	4
		Trafik	13798	1.99%	1.42%	Model 4	3	4
D	M	Sağlık	22824	17.94%	7.90%	Model 8	9	2
		Kasko	20327	14.95%	10.02%	Model 1	12	8
		Trafik	27949	10.34%	6.13%	Model 4	4	3
	Q	Sağlık	7697	4.99%	3.67%	Model 4	3	3
		Kasko	28559	5.18%	0.74%	Model 4	2	3
		Trafik	11320	1.85%	1.00%	Model 2	3	4
E	M	Sağlık	11833	14.42%	9.38%	Model 4	12	10
		Kasko	17191	9.45%	6.50%	Model 2	12	3
		Trafik	18846	14.47%	12.88%	Model 2	6	5
	Q	Sağlık	20613	6.72%	2.78%	Model 4	4	3
		Kasko	13637	4.31%	4.54%	Model 5	4	4
		Trafik	19624	7.48%	5.79%	Model 2	4	4
F	M	Sağlık	4652	17.69%	11.82%	Model 4	11	4
		Kasko	19360	9.63%	4.34%	Model 2	4	4
		Trafik	45085	14.22%	12.89%	Model 3	6	2
	Q	Sağlık	41447	2.36%	2.81%	Model 2	3	3
		Kasko	4670	0.81%	0.86%	Model 4	4	3
		Trafik	27138	10.75%	11.02%	Model 3	3	4

Tablo 6.1 Genel Sonuç Değerlendirmesi


6.2 Şirket ve Branş Bazlı Uygulama Sonuçlarının Değerlendirmesi

Bu tez kapsamında Türkiye’de faaliyet gösteren ve prim hacmi bakımından ilk 10’a giren şirketler arasından seçilen 6 şirketin 3 farklı branş bazında prim üretimleri aylık ve çeyreklik dönemlerde farklı YSA modelleri ile analiz edilerek öngörülmüştür. Bu alt başlık altında her bir şirket ve her bir branş için aylık ve çeyreklik bazda en iyi öngörü performanslarının elde edildiği durumlara ilişkin gerçek gözlemler ile öngörü değerlerinin birlikte grafikleri (Şekil 6.1-6.36) sunularak detaylı bir performans değerlendirilmesi gerçekleştirilmiştir.




Şekil 6.1 A Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.1’de verilen A Sigorta, aylık bazda sağlık branşının gözlemlere karşılık öngörülleri incelendiğinde, 12. ayda gerçekleşen prim üretimine uzak bir öngörü elde edildiği gözlemlenmiştir. Bu durumun temel nedeni yıl sonunda şirket içerisinde olması gerekenden çok daha fazla toplu bir prim ödemesinin gerçekleşmiş olması görülebilir. Yani bu aydaki gerçekleşen prim ödemesi diğer aylardaki genel davranışı sergilemeyerek genel veri yapısından ayrılmaktadır. Buna karşın 2. ve 9. aylar için de diğer aylarla karşılaştırıldığında öngörülerin gerçek gözlemlenen prim tutarlarına uzak olduğu ancak bu durumun kabul edilebilir seviyelerde olduğu görülmektedir. Diğer dokuz ayda ise öngörülerin gerçek gözlemlere oldukça uyumlu olduğu söylenebilir.




Şekil 6.2 A Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.2 ile verilen A Sigorta, aylık bazda kasko branşının gözlemlenenlere karşılık öngörülerini incelendiğinde 7. ve 10. ayda gerçekleşene yakın bir öngörü elde edilmiş olsa da kabul edilebilir düzeyde bir miktar sapma gözlemlenmiştir. Bunun dışındaki aylarda öngörülerin gerçekleşen gözlemlerle oldukça uyumlu olduğu söylenebilir.




Şekil 6.3 A Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.3 ile verilen A Sigorta, aylık bazda trafik branşının gözlemlere karşılık öngörülleri incelendiğinde, veri yapısının genel davranışını yansıtmayan ve öngörülemezcek prim artışlarının gözlemlendiği 3. ve 8. aylar dışında 10 ay için, gerçekleşen prim miktarları ile oldukça uyumlu öngörü sonuçları elde edildiği görülmektedir. Özellikle 10. ayda şirket özelinde toplu havuz trafik poliçeleri girişi bulunmaktadır.




Şekil 6.4 A Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.4 ile verilen A Sigorta, çeyreklik bazda sağlık branşının gözlemlere karşılık öngörülleri incelendiğinde, 1., 3. ve 4. çeyreklerde öngörülerin gerçekleşen çeyreklik prim miktarları ile oldukça uyumlu olduğu gözlenirken, 2. çeyrek için öngörü değerlerinin gerçek değerlerden oldukça uzak ve yüksek seviyede olduğu görülmektedir.




Şekil 6.5 A Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.5 ile verilen A Sigorta, çeyreklik bazda kasko branşının gözlemlere karşılık öngörülleri incelendiğinde, 3. çeyrek için öngörü değerlerinin gerçek değerlerden oldukça uzak ve düşük seviyede olduğu gözlenmesine karşın diğer üç çeyrekte 1 öngörülerin gerçekleşen prim miktarları ile mükemmel derecede uyumlu olduğu görülmektedir.




Şekil 6.6 A Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.6 ile verilen A Sigorta, çeyreklik bazda trafik branşının gözlemlere karşılık öngörülerini incelendiğinde, ilk 3 çeyrekte öngörülerin gerçek değerlere neredeyse mükemmel bir uyumu söz konusuysa, 4. çeyrekte gerçeğe uzak bir öngörü yapıldığı gözlemlenmiştir ve ilgili prim miktarı daha düşük öngörülmüştür. Bu durumun gerçekte ay bazında düşünüldüğünde 12. ayda yaşanan toplu havuz trafik poliçelerinden kaynaklandığı söylenebilir.




Şekil 6.7 B Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.7 ile verilen B Sigorta, aylık bazda sağlık branşının gözlemlere karşılık öngörülerini incelendiğinde, öngörülerin gerçekleşen prim üretimlerinden nispeten uzak olduğu 1., 5., 10. ve 12. aylarda dışında, gerçekleşen prim üretimleri ile öngörülerin genel olarak uyumlu olduğu gözlemlenmiştir.




Şekil 6.8 B Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.8 ile verilen B Sigorta, aylık bazda kasko branşının gözlemlere karşılık öngörülerini incelendiğinde, 3. ve 8. aylar dışında, gerçekleşen prim üretimleri ile öngörülerin genel olarak oldukça uyumlu olduğu ve bu aylar için tatmin edici öngörü performansının sergilendiği söylenebilir.




Şekil 6.9 B Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.9 ile verilen B Sigorta, aylık bazda sağlık branşının gözlemlere karşılık öngörülleri incelendiğinde, 6. ve 11. aylar dışında, gerçekleşen prim üretimleri ile öngörüllerin genel olarak oldukça uyumlu olduğu ve genel olarak ilgili veri seti için tatmin edici öngörü sonuçlarının üretildiği söylenebilir.




Şekil 6.10 B Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.10 ile verilen B Sigorta, çeyreklik bazda sağlık branşının gözlemlere karşılık öngörülleri incelendiğinde, elde edilen öngörüllerin gerçekleşen prim üretimleri ile neredeyse mükemmel bir uyuma sahip olduğu ve bu çeyreklik veri seti için oldukça üstün öngörü sonuçları elde edildiği gözlenmiştir.




Şekil 6.11 B Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.11 ile verilen B Sigorta, çeyreklik bazda kasko branşının gözlemlere karşılık öngörülerini incelendiğinde, 1. ve 4. çeyrekler için öngörülerin gerçekleşen prim değerlerine mükemmel uyum gösterdiği gözlenirken, 2. çeyrek için de oldukça tatmin edici öngörü sonuçları elde edilmiştir.




Şekil 6.12 B Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.12 ile verilen B Sigorta, çeyreklik bazda trafik branşının gözlemlere karşılık öngörülerini incelendiğinde, tüm dönemler için öngörülerin gerçek gözlemlere oldukça uyumlu olduğu gözlemlenmiştir.




Şekil 6.13 C Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.13 ile verilen C Sigorta, aylık bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, genel anlamda öngörülerin gerçekleşen prim üretimleri ile oldukça uyumlu olduğu ve 3. ve 4. aylar için elde edilen öngörülerin gerçek prim üretimlerinden bir miktar sapma göstermesine rağmen bu öngörülerin de kabul edilebilir düzeyde bir hata seviyesinde oldukları söylenebilir.




Şekil 6.14 C Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.14 ile verilen C Sigorta, aylık bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, bütüncül bir bakış açısıyla, öngörülerin gerçekleşen pirim üretim değerleri ile uyumlu olduğu ve ilgili veri seti için başarılı öngörü sonuçlarının elde edildiği söylenebilir.




Şekil 6.15 C Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.15 ile verilen C Sigorta, aylık bazda trafik branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 2., 6. ve 8. aylar dışındaki dokuz ay için de oldukça başarılı öngörü sonuçlarının elde edildiği, öngörüler ile gerçekleşen pirim değerlerinin yüksek uyumuna dayalı olarak, gözlemlenmiştir. Buna karşın, 2., 6. ve 8. aylar için de elde edilen öngörülerinin kabul edilebilir hatalar ile üretildiği söylenebilir.




Şekil 6.16 C Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.16 ile verilen C Sigorta, çeyreklik bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 1. çeyrek dışındaki dönemler için dönemler için öngörülerin gerçekleşen pirim miktarlarına mükemmel uyum gösterdiği gözlenmektedir. 1. çeyrek için de öngörülerin kabul edilebilir bir hata düzeyi ile elde edildiği söylenebilir.




Şekil 6.17 C Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.17 ile verilen C Sigorta, çeyreklik bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, özellikle 2., 3. ve 4. çeyrekte öngörülerin gerçekleşen primi değerleri ile oldukça uyumlu olduğu ve veri setinin tamamı için hata düzeyi düşük oldukça başarılı öngörü sonuçlarının elde edildiği gözlenmiştir.




Şekil 6.18 C Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.18 ile verilen C Sigorta, çeyreklik bazda trafik branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, tüm çeyrekler için gerçekleşen prim üretimleri ile mükemmele yakın uyum gösteren oldukça başarılı öngörülerin elde edildiği görülebilir.




Şekil 6.19 D Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.19 ile verilen D Sigorta, aylık bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 2., 4. ve 6. aylar dışında ilk on bir ayda öngörülerin gerçekleşen prim üretim değerlerine mükemmele yakın uyum gösterdiği ve bu dönem için oldukça başarılı öngörü sonuçlarının elde edildiği gözlemlenmiştir. İlgili aylardaki öngörü sonuçlarının ise yine kabul edilebilir hata düzeylerine sahip olduğu söylenebilir. 12. ayda şirkete ciddi bir prim girişi olup, bu aydaki prim üretimi yılın geri kalan değerleri ile uyumsuz olduğundan, bu ay için başarılı olarak görülemeyecek bir prim öngörüsü gerçekleşmiştir.




Şekil 6.20 D Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.20 ile verilen D Sigorta, aylık bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 7. ve 8. Aylar dışında kalan on ay için oldukça başarılı öngörü sonuçlarının elde edildiği, öngörüler ile gerçekleşen prim üretim değerlerinin yüksek uyumuna dayalı olarak söylenebilir. Özellikle son iki ayın da içinde olduğu bazı aylarda bu uyum mükemmel yakın olup olağan üstü bir öngörü başarısına işaret etmektedir.




Şekil 6.21 D Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.21 ile verilen D Sigorta, aylık bazda trafik branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, ilk beş ayda üstün öngörü sonuçlarının elde edildiği ve sonraki dönemde ise nispeten uyumun düşmesine rağmen yine de öngörülerin genel eğilimi ile gerçekleşen prim üretimlerinin genel eğilimlerinin aynı yönlü ve yakın seyrettiği ve bu dönem için kabul edilebilir hata düzeyinde öngörüler üretildiği söylenebilir.




Şekil 6.22 D Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.22 ile verilen D Sigorta, çeyreklik bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 1. çeyrek dışında kalan üç çeyrekte öngörülerin gerçekleşen prim üretimleri ile mükemmel bir uyuma sahip olduğu ve bu çeyrekler için olağanüstü öngörü performansının sergilendiği söylenebilir. Birinci çeyrek için de gerçek gözlem değerine oldukça yakın bir öngörü elde edildiği gerçeği ile, veri seti bütüncül olarak değerlendirildiğinden oldukça başarılı öngörü performansından söz edilebilir.




Şekil 6.23 D Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.23 ile verilen D Sigorta, çeyreklik bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülleri incelendiğinde, 3. çeyrek dışında kalan üç çeyrekte öngörülerin gerçekleşen prim üretimleri ile mükemmel bir uyuma sahip olduğu ve bu çeyrekler için olağanüstü öngörü performansının sergilendiği söylenebilir.




Şekil 6.24 D Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.24 ile verilen D Sigorta, çeyreklik bazda trafik branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, tüm çeyrekler için öngörülerin gerçekleşen pirim üretim değerlerine oldukça yakın değerlere sahip olduğu ve dolayısıyla ilgili bransa ait öngörü performansının oldukça yüksek olduğu söylenebilir.




Şekil 6.25 E Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.25 ile verilen E Sigorta, aylık bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 7. ay dışındaki on bir ay için öngörülerin gerçekleşen pirim üretimleri ile oldukça uyumlu olduğu ve bunun da veri setinin bütünü için başarılı öngörü sonuçlarının elde edildiği söylenebilir.




Şekil 6.26 E Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.26 ile verilen E Sigorta, aylık bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, öngörülerin gerçekleşen pirim üretim değerleri ile son iki ay dışında genel olarak uyumlu olduğu gözlemlenmiştir. Özellikle ilk sekiz aylık dönem için öngörüler ile gözlemler arasında mükemmel yakın bir uyumdan söz edilebilir. Son iki ay için elde edilen öngörülerin de kabul edilebilir hata düzeyleri ile üretildiği söylenebilir.




Şekil 6.27 E Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.27 ile verilen E Sigorta, aylık bazda trafik branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 11. ay dışında öngörülerin gerçekleşen prim üretim değerlerine uyumlu olduğu gözlemlenmiştir. Bu uyum özellikle ilk altı aylık dönemde yüksek düzeydedir ve bu dönemde oldukça tatmin edici öngörü performansı söz konusudur.




Şekil 6.28 E Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.28 ile verilen E Sigorta, çeyreklik bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 2. çeyrek dışında kalan üç çeyrekte öngörülerin gerçekleşen prim üretimleri ile mükemmel bir uyuma sahip olduğu ve bu çeyrekler için olağanüstü öngörü performansının sergilendiği söylenebilir.




Şekil 6.29 E Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.29 ile verilen E Sigorta, çeyreklik bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, tüm çeyrekler için öngörülerin gerçekleşen prim üretimleri ile mükemmel bir uyuma sahip olduğu ve tüm veri seti için olağanüstü öngörü performansının sergilendiği söylenebilir.




Şekil 6.30 E Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.30 ile verilen E Sigorta, çeyreklik bazda trafik branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, 2. çeyrek dışındaki çeyrekler için öngörülerin gerçekleşen prim üretimleri ile oldukça yüksek bir uyuma sahip olduğu ve genel olarak ilgili branş için başarılı bir öngörü performansının sergilendiği söylenebilir.




Şekil 6.31 F Sigorta Aylık Sağlık Branşı Öngörüsü

Şekil 6.31 ile verilen F Sigorta, aylık bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, özellikle ilk on ay boyunca 6. ay dışındaki dokuz ay için öngörülerin gerçekleşen prim üretim değerleri ile oldukça uyumlu olduğu gözlenirken, 11. ve 12. aylarda öngörülerin yüksek hatalarla elde edildiği gözlemlenmiştir. Bu durumun nedeni olarak, 9. aydan sonra, önceki dönemlerden farklı olarak, şirkete oldukça yüksek bir prim girişinin olması gösterilebilir.




Şekil 6.32 F Sigorta Aylık Kasko Branşı Öngörüsü

Şekil 6.32 ile verilen F Sigorta, aylık bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, elde edilen öngörü değerlerinin gerçekleşen prim üretim değerleri ile oldukça uyumlu olduğu ve ilgili branşa ait veri seti için oldukça başarılı öngörü sonuçlarının elde edildiği söylenebilir.




Şekil 6.33 F Sigorta Aylık Trafik Branşı Öngörüsü

Şekil 6.33 ile verilen F Sigorta, aylık bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, dört ay (1., 6., 9. ve 12. aylar) dışında kalan sekiz ay için başarılı bir öngörü performansının elde edildiği, öngörüler ile gerçekleşen prim üretim değerlerinin uyumuna dayalı olarak, söylenebilir. Bahsedilen dört ay için ise, öngörülerin gerçek değerlerden bir miktar sapma ile elde edildiği de belirtilmelidir.




Şekil 6.34 F Sigorta Çeyreklik Sağlık Branşı Öngörüsü

Şekil 6.34 ile verilen F Sigorta, çeyreklik bazda sağlık branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, elde edilen öngörülerin gerçekleşen prim üretimleri ile neredeyse mükemmel bir uyuma sahip olduğu ve böylece ilgili branşa ait veri setinin üstün başarı ile öngörülebildiği söylenebilir.



Şekil 6.35 F Sigorta Çeyreklik Kasko Branşı Öngörüsü

Şekil 6.35 ile verilen F Sigorta, çeyreklik bazda kasko branşının gerçekleşen gözlemlere karşılık öngörülerini incelendiğinde, elde edilen öngörülerin gerçekleşen pirim üretimleri ile mükemmel bir uyuma sahip olduğu ve böylece ilgili branşa ait veri setinin olağan üstün bir başarı ile neredeyse hatasız olarak öngörülebildiği söylenebilir.



Şekil 6.36 F Sigorta Çeyreklik Trafik Branşı Öngörüsü

Şekil 6.36 ile verilen F Sigorta, çeyreklik bazda trafik branşının gerçekleşen gözlemlere karşılık öngörülmesi incelendiğinde, ilki iki çeyrek için elde edilen öngörülerin gerçekleşen prim üretimleri ile iyi bir uyuma sahip olduğu ve böylece bu çeyrekler için başarılı öngörü performansının sergilendiği söylenebilir. 3. ve 4. çeyrekler için ise nispeten hata düzeyi yüksek ve fakat yine de kabul edilebilir öngörülerin elde edildiği de belirtilmelidir.

7.SONUÇ VE ÖNERİLER

Sigorta sektörüne ilişkin verilerin ülkelerin gelişmişlik ve refah düzeylerinin bir göstergesi olarak kullanılabileceği söylenebilir. Bu bakımdan, sigorta sektörüne ilişkin verilerin doğru ve güvenilir bir şekilde öngörülmesi hem sektörel hem de ülke ekonomi ve sosyolojisi bakımından geleceğe ilişkin doğru ve etkin kararlar almada önemli bir unsur haline gelmektedir. Bu noktadan hareketle, bu tez çalışmasında, Türkiye’de aktif olarak faaliyet gösteren ve prim hacmi göz önünde bulundurularak ilk 10’a giren şirketler arasından seçilen 6 şirketin 3 farklı alandaki prim üretim büyüklüklerinin öngörülmesi amaçlanmıştır. Bu amaçla, 2015-2021 yılları arasında aylık bazda 84 gözleme sahip ve çeyreklik bazda 28 gözleme sahip veri setleri oluşturularak son bir yıla ilişkin prim üretim büyüklükleri öngörülmüştür. Öngörü aracı olarak, İBYSA ve GBYSA olmak üzere iki temel YSA yapısı kullanılmış ve bu sinir ağlarının LM ve BD eğitim algoritmaları ile eğitilmesi ve çıktı tabaka birimlerinde doğrusal ve sigmoid aktivasyon fonksiyonlarının kullanılması ile toplamda yapay sinir ağlarına dayalı 8 farklı modeli oluşturulmuştur.

Finansal zaman serisi literatürü incelendiğinde, ilgili finansal zaman serilerinin öngörülmesinde yapay sinir ağları yaygın bir şekilde kullanılıyor olmasına karşın özellikle ülkemiz sigorta sektörüne ilişkin prim üretim büyüklüklerini şirket ve branş bazlı olarak bu derecede geniş çaplı olarak ele alan bir çalışma mevcut değildir. Bu bakımdan tez çalışması, literatürde mevcut olduğu düşünülen bu boşluğu doldurmayı da hedeflemiştir.

Türkiye’de aktif olarak faaliyet gösteren sigorta şirketleri arasından prim üretim yüksek, altı farklı sigorta şirketinin aylık ve çeyreklik bazda üç farklı branşının öngörülmesi amacıyla gerçekleştirilen analizler sonucunda:

➤ Aylık bazda;

- *Sağlık* branşına ait elde edilen öngörü sonuçları genel olarak MdMYH kriteri bakımından 6-10% bandında bir hata ile elde edilebilirken, bu hata düzeylerinin kabul edilebilir seviyede olduğu söylenebilir. Bununla birlikte özellikle bir şirkete (A şirketi) ait sağlık branşı yaklaşık 17% bir yüzdelik hata medyanı ile öngörülebilmiş olup bu öngörü performansı iyileştirilmeye muhtaç gözükmemektedir.
- *Kasko* branşına ait öngörüler genel, olarak 4-10% bandında bir hata ile elde edilebilirken, bu hata düzeylerinin kabul edilebilir seviyede olduğu ve özellikle üç şirket için (A, B ve F şirketleri) bu seviyenin yaklaşık olarak 4% düzeyinde olduğu göz önüne alındığında bu branş için başarılı öngörü performanslarının sergilendiği söylenebilir.
- *Trafik* branşına ait elde edilen öngörü sonuçları iki şirket dışında genel olarak MdMYH kriteri bakımından yaklaşık olarak 3-9% bandında bir hata ile üretilebilirken, bu hata düzeylerinin kabul edilebilir seviyede olduğu ve başarılı bir öngörü performansına işaret ettiği söylenebilir. Bununla birlikte özellikle iki şirkete (E ve F şirketleri) ait trafik branşı pirim üretim büyüklüğü yaklaşık 12% bir yüzdelik hata medyanı ile öngörülebilmiş olup bu öngörü performansı iyileştirilmeye muhtaç gözükmemektedir.

➤ Çeyreklik bazda;

- *Sağlık* branşına ait elde edilen öngörü sonuçları genel olarak MdMYH kriteri bakımından 2-4% bandında bir hata ile elde edilebilirken, bu hata düzeylerinin oldukça düşük seviyede olduğu ve bu düzeyde hata içeren bir öngörü performansının oldukça başarılı olduğu söylenebilir. Özellikle B ve C şirketleri için yüzdelik hata medyanı seviyesi 2%'nin de altına düşerek üstün bir mükemmele yakın bir öngörü performansına işaret etmektedir.
- *Kasko* branşına ait öngörüler genel, olarak 2-4% bandında bir hata ile elde edilebilirken, bu hata düzeylerinin oldukça düşük seviyede olduğu ve özellikle iki şirket için (D ve F şirketleri) bu seviyenin 1% bile altında olduğu göz önüne alındığında bu branş için neredeyse mükemmel öngörü performanslarının sergilendiği söylenebilir.

- *Trafik* branşına ait elde edilen öngörü sonuçları bir şirket dışında genel olarak MdMYH kriteri bakımından yaklaşık olarak 1-5% bandında bir hata ile üretilebilirken, bu hata düzeylerinin oldukça düşük seviyede olduğu ve başarılı bir öngörü performansına işaret ettiği söylenebilir. Ayrıca özellikle üç şirkete (A, C ve D şirketleri) ait trafik branşı primi üretim büyüklükleri yaklaşık olarak 1% düzeyinde bir yüzdelik hata medyanı ile öngörölmüş olup bu olağan üstü bir öngörü performansına işaret etmektedir. Bununla birlikte özellikle bir şirkete (F şirketi) ait trafik branşı prim üretim büyüklüğü yaklaşık 11% bir yüzdelik hata medyanı ile öngörölebilmış olup bu öngörü performansı iyileştirilmeye muhtaç gözükmektedir.

Genel olarak, elde edilen öngörü sonuçları, bu çalışmada oluşturulan ve YSA'na dayalı öngörü modelleri ile Türkiye'de aktif olarak faaliyet gösteren ve prim hacmi göz önünde bulundurularak ilk 10'a giren şirketler arasından seçilen 6 şirketin 3 farklı alandaki prim üretim büyüklüklerinin başarı ile öngörölebildiğini ortaya koymaktadır. Böylece sigorta sektöründe öngörü çalışmalarında yapay sinir ağlarının kullanımı ile anlamlı ve faydalı sonuçlar elde edilebilecek ve böylelikle de şirket kârlılığını olumlu yönde etkileyebilecek aksiyonların alınması gereken durumlarda önceden fikir sahibi olunması sağlanabilecektir. Ayrıca, %10 üzerinde bulunan hatalar verinin stabil olarak ilerlememesinden ve ay bazında değişkenlik göstermesi ile alakalı olduğu tespit edilmiştir.

Bununla birlikte, pandemi süreci ve güncel ekonomik dalgalanmaların etkisi ile oluşan ve genel prim üretim eğilimlerinden farklılıklar gösteren prim büyüklüklerini tahmin etme konusunda kullanılan öngörü araçlarının geliştirilmesi gerektiği sonucuna varılabilir. Gelecek çalışmalarda bu alanda farklı yöntemler denenebilir. Bunlar arasında dayanıklı (robust) eğitim algoritmalarına ya da dayanıklı mimari yapı özelliklerine sahip yapay sinir ağlarının kullanımı da tercih edilebilir. Ayrıca daha derin mimarilere sahip derin sinir ağlarının kullanımı da öngörü doğruluğunu arttırabilecek potansiyel alternatifler olarak görölebilir.

8.KAYNAKÇA

- [1] <https://www.sigortaciniz.com/sigorta-tarihi>
- [2] Yayla Ş.O. (2019). *Sigortacılık ve Türkiye’de Sigorta Sektörünün Durumu*, Yüksek Lisans Tezi.
- [3] <https://www.resmigazete.gov.tr/eskiler/2011/02/20110214-1-1.htm>
- [4] Sigortacılık Kanunu, www.mevzuat.gov.tr › MevzuatMetin › 1.5.5684.doc [Erşim 10.09.2021]
- [5] Türkiye Sigortalar Birliği, Sektör Raporu 2020
- [6] Swiss Re Institute, **Sigma Dergisi**, No 3/2021
- [7] <https://www.alomaliye.com/2018/03/16/dunyada-ve-turkiyede-sigortacilik/>
- [8] Sayın H.O.(2008) Türkiye’de Sigorta Sektörünün Gelişimi Açısından Vergilendirmenin Rolü ve Önemi, S.37,38. Yüksek Lisans Tezi.
- [9] McCulloch, W. S., & Pitts, W. (1943).A logical calculus of the ideas immanent in nervous activity
- [10] Öztemel E.(2003) Yapay Sinir Ağları. Papatya Yayıncılık, 238s., İstanbul
- [11] Derin Öğrenme DeepLearning,
<https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>
- [12] Yolcu U.(2008), Yapay Sinir Ağına Dayalı Yüksek Dereceli Bulanık Zaman Serisi Öngörü Modeli, Yüksek Lisans Tezi
- [13] Öztürk K.,Şahin M. E.(2018). Yapay Sinir Ağları ve Yapay Zeka’ya Genel Bir Bakış
- [14] Adıyaman F.(2007). Talep Tahmininde Yapay Sinir Ağlarının Kullanılması
- [15] Akbaba H. K.(2019) Beyaz Akaryakıt Satış Miktarının Yapay Sinir Ağları İle Modellenmesi.
- [16] Scott E. Fahlman and Christian Lebiere, The Cascade-Correlation Learning Architecture.
- [17] Abraham A. Artificial Neural Networks
- [18] Werbos, P.J. (1974) Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences.
- [19] Ataseven B., Yapay Sinir Ağları ile Öngörü Modellemesi

[20] (Bolat ve Kalenderli, 2003; Bolat, S., Kalenderli, Ö., 2003. Levenberg-Marquardt Algoritması Kullanılan Yapay Sinir Ağı İle Elektrot Biçim Optimizasyonu. “International XII. Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN 2003”)

[21] (Ngia, 2000, Oğuz, 2001; Ngia, S. H., 2000. Efficient Training of Neural Nets for Nonlinear Adaptive Filtering Using a Recursive Levenberg-Marquardt Algorithm. IEEE Trans. on Signal Process., 48, 1915-1927.

[22] Oğuz, M., 2001. Yalıtkan Maddelerde Elektriksel Delinme Dayanımının Yapay Sinir Ağları İle Belirlenmesi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.).

[23] (Kayri, M. Predictive Abilities of Bayesian Regularization and Levenberg–Marquardt Algorithms in Artificial Neural Networks: A Comparative Empirical Study on Social Data. Math. Comput. Appl. 2016, 21, 20. <https://doi.org/10.3390/mca21020020>)

[24] (Sorich, M.J.; Miners, J.O.; Ross, A.M.; Winker, D.A.; Burden, F.R.; Smith, P.A. Comparison of linear and nonlinear classification algorithms for the prediction of drug and chemical metabolism by human UDP-Glucuronosyl transferase isoforms. J. Chem. Inf. Comput. Sci. 2003, 43, 2019–2024. ////

[25] Xu, M.; Zengi, G.; Xu, X.; Huang, G.; Jiang, R.; Sun, W. Application of Bayesian regularized BP neural network model for trend analysis. Acidity and chemical composition of precipitation in North. Water Air Soil Pollut. 2006, 172, 167–184.) [***].

[26] (Kelemen, A.; Liang, Y. Statistical advances and challenges for analyzing correlated high dimensional SNP data in genomic study for complex. Dis. Stat. Surv. 2008, 2, 43–60)

[27] (Titterington, D.M. Bayesian methods for neural networks and related models. Stat. Sci. 2004, 19, 128–139.

[28] Mackay, J.C.D. Information Theory, Inference and Learning Algorithms; University Press: Cambridge, UK, 2008.

- [29] Gianola, D.; Manfredi, E.; Simianer, H. On measures of association among genetic variables. *Anim. Genet.* 2012, 43, 19–35.
- [30] Okut, H.; Wu, X.L.; Rosa, G.J.M.; Bauck, S.; Woodward, B.W.; Schnabel, R.D.; Taylor, J.F.; Gianola, D. Predicting expected progeny difference for marbling score in Angus cattle using artificial neural networks and Bayesian regression models. *Genet. Sel. Evolut.* 2013, 45, 1–8.).
- [31] Hawley, D. D., Johnson, J. D., & Raina, D. (1990). Artificial Neural Systems: A New Tool for Financial Decision-Making. *Financial Analysts Journal*, 46(November/December), 63-72.
- [32] Wilson, R. L., & Sharda, R. (1994). Bankruptcy Prediction Using Neural Networks. *Decision Support Systems*, 11, 545-557.
- [33] Kitchens F., Harris T. (2015). Genetic Adaptive Neural Networks for Prediction of Insurance Claims, *International Journal of Engineering and Advanced Research Technology*, 1(6), 27-30.
- [34] Bayır F.(2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*, Yüksek Lisans Tezi.
- [35] Dogan G. (2010). Yapay Sinir Ağları Kullanılarak Türkiye’deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Ankara
- [36] Uslu Ç. S. (2011). Zaman Serisi Analizi İle Yapay Sinir Ağları Kestirimlerinin Karşılaştırılması
- [37] Bahia I.S.H. (2013). Using Artificial Neural Network Modeling in Forecasting Revenue: Case Study in National Insurance Company/Iraq, *International Journal of Intelligence Science*, 3, 136-143.
- [38] Sakthivel K.M., Rajitha C.S. (2017). Artificial Intelligence for Estimation of Future Claim Frequency in Non-Life Insurance, *Global Journal of Pure and Applied Mathematics*, 13,6.
- [39] Çetinkaya T., (2019). Hayat Sigortası Prim Üretimlerini Tahminleme Yöntemlerini Karşılaştırarak Gelecek Yıllar Prim Üretimini Tahminleme, Yüksek Lisans Tezi.
- [40] Høysæter D., Larsplass E. (2020). Predictive modelling of customer claims across multiple insurance policies, Master’s thesis in Business Analytics MSc in Economics & Business Administration, Norwegian School of Economics.

- [41] Kılınç E. E.(2022). Yapay Sinir Ağı Yöntemleri Kullanarak Kalp Krizinin Tahmin Edilmesi
- [42] Sigortacılık ve Özel Düzenleme ve Denetleme Kurumu, Sigortacılık ve Özel Emeklilik Faaliyetleri Hakkına Rapor(2021).
- [43] TSB, <https://www.tsb.org.tr/tr/istatistikler> [Erişim 25.03.2021]
- [44] <https://machinelearningmastery.com/implement-backpropagation-algorithm-scratch-python/>
- [45] Sayın H.O.(2008) Türkiye’de Sigorta Sektörünün Gelişimi Açısından Vergilendirmenin Rolü ve Önemi, S.37,38. Yüksek Lisans Tezi.
- [46] Sigorta sektörünün finansal yapısı ve bu yapıya bağlı olarak gelecekteki performansı



EKLER

EK 1-Tablo 1

	2015	2016	2017	2018	2019
A. TEMEL GÖSTERGELER – GENERAL INDICATORS (*)					
1. GSYH (Cari Fiyatlarla) – GDP with Current Price (Milyar/Billion)	2.337,5	2.590,5	3.106,5	3.701,0	4.280,4
2. ABD \$ Döviz Alış Kuru (Yıllık Ortalama) – USD Exchange Rate (Annual Average)	2,7225	3,0240	3,6510	4,8130	5,6708
3. Nüfus – Population (Milyon/Million)	78,7	79,8	80,8	82,0	83,2
4. Konut Sayısı – Number of Dwellings (Milyon/Million)	17,7	17,7	17,7	17,7	17,7
5. Trafığa Kayıtlı Araç Sayısı – Number of Registered Vehicle (Milyon/Million)	20,0	20,0	22,2	22,9	23,2
B. GENEL VERİLER – GENERAL FIGURES					
1. PRİM – PREMIUM(**)					
Türkiye Prim Üretimi					
Toplam Prim Üretimi – Gross Premium Volume (Milyar/Billion)	31,1	40,5	46,6	54,6	68,8
Hayat Dışı – Non-Life	27,3	35,4	39,7	47,7	57,4
Hayat – Life	3,8	5,0	6,8	6,9	11,4
Direkt Prim Üretimi – Direkt Premium Volume (Milyar/Billion)	30,3	39,5	44,0	50,4	63,4
Hayat Dışı – Non-Life	26,6	34,5	37,2	43,5	52,1
Hayat – Life	3,7	5,0	6,8	6,8	11,2
Direkt Prim Üretimi – Direkt Premium Volume (Milyar/Billion)	11,1	13,1	12,1	10,5	11,2
Hayat Dışı – Non-Life	9,8	11,4	10,2	9,0	9,2
Hayat – Life	1,4	1,6	1,9	1,4	2,0
Dünya Direkt Prim Üretimi – World Direct Premium Volume (Milyar/Billion\$)	4.597,6	4.702,9	4.957,5	6.149,0	6.292,6
Hayat Dışı – Non-Life	2.050,7	2.120,9	2.233,5	3.266,8	3.376,3
Hayat – Life	2.546,9	2.582,0	2.724,0	2.882,2	2.916,3
Dünya Prim Üretiminde Türkiye'nin Payı – Turkey's Share in World Direct Pr.Vol(%)	0,25	0,28	0,26	0,22	0,19
Hayat Dışı – Non-Life	0,48	0,54	0,46	0,28	0,27
Hayat – Life	0,06	0,06	0,07	0,05	0,07
Direkt Prim Üretimi / GSYH – Direct Premium Volume / GDP (%)					
Dünya – World	6,23	6,30	6,13	6,09	7,23
Türkiye – Turkey	1,30	1,52	1,42	1,36	1,48
Direkt Prim Reel Artış Oranı – Direct Premium Real Growth Rate (%)					
Hayat Dışı – Non-Life					
Dünya – World	4,2	3,3	2,9	3,7	3,5
Türkiye – Turkey	11,62	20,39	2,91	0,50	3,99
Hayat – Life					

Dünya - World	4,4	1,4	3,4	2,6	2,2
Türkiye - Turkey	6,45	24,45	21,49	-12,34	42,84
Toplam – Total					
Dünya - World	4,3	2,2	3,2	3,2	2,9
Türkiye - Turkey	10,96	20,89	0,16	-1,46	9,26
Kişi Başı Direkt Prim Üretimi – Direct Premium Per Carite (\$)					
Dünya - World	621	638	650	682	818
Türkiye - Turkey	141	164	149	128	134
2. VARLIK TOPLAMI – ASSET SIZE (Milyar/Billion)					
Finansal Sektör Varlık Toplamı – Non-Life Insurance Company	2.625,0	2.921,0	3.657,9	4.277,8	5.027,7
Sigorta, Reasürans ve Emeklilik Şirketleri – Insurance, Reinsurance and Pension Companies	98,4	122,2	152,3	178,4	236,6
Sigortacılık ve Emekliliğin Payı – Share of Insurance and Pension as Asset Size (%)	3,75	4,18	4,16	4,17	4,71
3. FAAL ŞİRKET SAYISI					
Hayat Dışı Sigorta Şirketi – Non Life Insurance Company	60	61	62	62	63
Hayat Sigorta Şirketi – Life Insurance Company	36	37	38	38	38
Emeklilik Şirketi – Pension Company	4	4	4	5	5
Reasürans Şirketi – Reinsurance Company	19	18	18	17	17
	1	2	2	2	3
(*) TÜİK verileridir. Data released by Turkish Statistical Institute (TÜİK)					
EK 1-Tablo 2					

