



**T.C. İSTANBUL T CARET
 NİVERSİTESİ**

FEN B LİMLERİ ENSTİT S 

**YAPAY S NİR A LARI İLE ENFLASYONU ETKİLEYEN
FAKT RLER  ZERİNE BİR UYGULAMA**

Selin SABAK

**Danışman
Prof. Dr.  zlem DENİZ BAŐAR**

**Y KSEK LİSANS TEZİ
İSTATİSTİK ANABİLİM DALI
İSTANBUL- 2021**

KABUL VE ONAY SAYFASI

Selin SABAK tarafından hazırlanan "**Yapay Sinir Ağları ile Enflasyonu Etkileyen Faktörler Üzerine Bir Uygulama**" adlı tez çalışması 24/02/2021 tarihinde aşağıdaki jüri üyeleri önünde başarı ile savunularak, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü **İstatistik Anabilim Dalı**’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman **Prof. Dr. Özlem DENİZ BAŞAR**
İstanbul Ticaret Üniversitesi

Jüri Üyesi **Doç. Dr. Seda BAĞDATLI KALKAN**
İstanbul Ticaret Üniversitesi

Jüri Üyesi **Doç. Dr. Selay GİRAY YAKUT**
Marmara Üniversitesi

Onay Tarihi: 15/03/2021

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsünün 15.03.2021 tarih ve 2021/308 numaralı Yönetim Kurulu Kararının 1. maddesi gereğince, ders yüklerini ve tez yükümlülüğünü yerine getirdiği belirlenen "Selin SABAK" (TC: 33688790116) adlı öğrencinin mezun olmasına oy birliği ile karar verilmiştir.

Prof. Dr. Necip ŞİMŞEK
Enstitü Müdürü

AKADEMİK VE ETİK KURALLARA UYGUNLUK BEYANI

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

15.03.2021

Selin SABAK

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	i
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
ŞEKİLLER	vi
TABLolar	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	6
3. YAPAY SİNİR AĞLARI	9
3.1. Yapay Zekâ	9
3.2. Yapay Sinir Ağları	10
3.3. Yapay Sinir Ağlarının Genel Özellikleri	13
3.4. Yapay Sinir Ağlarının Tarihçesi	14
3.5. Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri	18
3.5.1. Biyolojik sinir ağları	18
3.5.2. Yapay sinir hücreleri	22
3.5.3. Katmanlar	23
3.5.3.1. Girdiler	23
3.5.3.2. Ağırlıklar	23
3.5.3.3. Gizli katman (Ara katman)	24
3.5.3.4. Toplama fonksiyonu	24
3.5.3.5. Aktivasyon fonksiyonu	24
3.5.3.6. Hücrenin çıktısı	27
3.6. Yapay Sinir Ağlarının Çeşitleri	27
3.6.1. Öğrenme metodlarına göre yapay sinir ağları	28
3.6.1.1. Danışmanlı öğrenme	29
3.6.1.2. Danışmansız öğrenme	29
3.6.1.3. Takviyeli öğrenme	30
3.7. Yapay Sinir Ağı Modelleri	30
3.7.1. Tek katmanlı yapay sinir ağları	30
3.7.1.1. Basit algılayıcı modeli (Perceptron)	32
3.7.1.2. Adaline modeli	33
3.7.2. Çok katmanlı yapay sinir ağları	33
3.8. Ağ Yapılarına Göre Yapay Sinir Ağları	34
3.8.1. İleri beslemeli ağlar	34
3.8.2. Geri beslemeli ağlar	35
3.9. Temel Öğrenme Kuralları	38
3.9.1. Hebb kuralı	38
3.9.2. Hopfield kuralı	39
3.9.3. Delta kuralı	39
3.9.4. Kohonen kuralı	39
3.10. Yapay Sinir Ağlarının Kullanım Alanları	40
3.11. Yapay Sinir Ağlarının Avantajları ve Dezavantajları	41

4. UYGULAMA.....	43
4.1. Uygulamanın Amacı ve Önemi.....	44
4.2. Uygulamada Kullanılan Veri Seti	44
4.2.1. Verilerin normalizasyonu	46
4.3. Yöntem ve Kullanılan Teknikler.....	47
4.4. Bulgular	48
4.4.1. Yapay sinir ağı mimarisi.....	48
4.4.2. Yapay sinir ağı analiz sonuçları	52
5. SONUÇ	54
KAYNAKLAR	56
EKLER.....	61
EK A. Yapay Sinir Ağları Kodları	61
EK A. Korelasyon Kodları	62
EK A. Veri Seti	63
ÖZGEÇMİŞ	64

ÖZET

Yüksek Lisans Tezi

YAPAY SİNİR AĞLARI İLE ENFLASYONU ETKİLEYEN FAKTÖRLER ÜZERİNE BİR UYGULAMA

Selin SABAK

İstanbul Ticaret Üniversitesi
Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı

Danışman: Prof. Dr. Özlem DENİZ BAŞAR
2021,64 sayfa

Enflasyon, fiyatlar genel seviyesindeki sürekli artış olarak tanımlanmaktadır. Diğer bir tanımı; toplam talep miktarının, toplam arzdan yüksek olmasıdır. Enflasyonist dönemlerdeki sürekli ve hızlı fiyat artışlarının varlığı fiyat istikrarının bozulmasını yansıtmaktadır. Güvenin sağlanması için fiyat istikrarı da önemli başlıklardan birisidir. Ekonomi dinamik bir seyir izlediğinden, sürekli değişiklikler görülebilir. Fakat asıl amaç; değişikliklerin minimum düzeyde tutulması, sert dalgalanmalara izin verilmemesidir. Buna bağlı olarak; enflasyon toplumun refahını ve düzenini etkileyen önemli bir unsur olduğundan gerek ekonomik gerekse sosyal alanlarda enflasyonun etkisinin önemli bir boyuta taşıyacağı yadsınamaz bir gerçektir.

Geçmişten günümüze bilgisayarlar ile yapılan çalışmalar insan beyninin modelleyerek, yapay zekâ kavramını hayatımızın bir parçası konumuna getirmiştir. Tarihsel süreç içerisinde yapay zekâ kavramı geliştirilerek yapay sinir ağları kavramını ortaya atılmıştır. Bu yeni kavram ile ilgili çalışmalara yoğunluk verilmiştir. Enflasyonun ortaya çıkardığı sonuçların önlenebilmesi gerekmektedir. Çünkü enflasyonun önemli bir maliyeti vardır ve ekonomide enflasyonun çıkardığı sorunlara çözüm üretmek gerekmektedir. Bu doğrultuda çalışmada, yapay sinir ağları yöntemi olan ileri beslemeli geri yayılım ağı kullanılarak enflasyonu etkileyen faktörler üzerine bir analiz yapılmıştır.

Anahtar Kelimeler: Enflasyon, ileri beslemeli geri yayılım ağı, yapay sinir ağları, yapay zekâ.

ABSTRACT

M.Sc. Thesis

AN APPLICATION ON THE FACTORS AFFECTING INFLATION WITH ARTIFICIAL NEURAL NETWORKS

Selin SABAK

**Istanbul Commerce University
Graduate School of Applied and Natural Sciences
Department of Statistics**

**Supervisor: Prof. Dr. Özlem DENİZ BAŞAR
2021,64 pages**

Inflation is defined as the continuous increase in the general level of prices. Another definition is that the aggregate demand is higher than aggregate supply. The existence of continuous and rapid price increases in inflationary periods reflects the deterioration of price stability. Price stability is one of the important topics to ensure confidence as well. As the economy follows a dynamic path, constant changes can be seen, however, the main purpose is that changes are kept to a minimum and hard fluctuations are not allowed. Accordingly, since inflation is an important factor affecting the welfare and order of society, it is an undeniable fact that the effects of inflation in both economic and social areas will be significant.

Studies conducted with computers from the past to the present have made the concept of artificial intelligence a part of our lives by modeling the human brain. In the historical process, the concept of artificial intelligence has been developed and the concept of artificial neural networks has emerged. So that studies have been focused on this concept. The consequences of inflation must be prevented. Because inflation has a significant cost and it is necessary to find solutions to the problems caused by inflation in the economy. In this study, an analysis on the factors affecting inflation has been made using the feed-forward backpropagation network, which is the method of artificial neural networks.

Keywords: Artificial intelligence, artificial neural networks, feed-forward backpropagation network, inflation.

TEŞEKKÜR

Bu araştırma için beni yönlendiren, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan değerli Danışman Hocam Prof. Dr. Özlem DENİZ BAŞAR'a teşekkürlerimi sunarım.

Lisansüstü eğitim sürecim boyunca desteklerini hissettiren değerli hocalarım Prof. Dr. Ünal Halit ÖZDEN ve Doç. Dr. Seda BAĞDATLI KALKAN'a teşekkür ederim.

Tezimin her aşamasında beni yalnız bırakmayan aileme sonsuz sevgi ve saygılarımı sunarım.

Selin SABAK
İSTANBUL, 2021

ŞEKİLLER

	Sayfa
Şekil 3.1. Biyolojik Sinir Hücresinin Yapısı	20
Şekil 3.2. Bir Sinir Hücresinin Matematiksel Modeli	21
Şekil 3.3. Doğrusal Aktivasyon Fonksiyonu	25
Şekil 3.4. Adım Fonksiyonu	26
Şekil 3.5. Sigmoid Fonksiyonu	26
Şekil 3.6. Hiperbolik Tanjant Fonksiyonu	27
Şekil 3.7. Tek Katmanlı Yapay Sinir Ağı.....	31
Şekil 3.8. İki Girdi ve Bir Çıktıdan Oluşan En Basit TKA Modeli	32
Şekil 3.9. Çok Katmanlı Bir Yapay Sinir Ağı.....	34
Şekil 3.10. Hopfield Ağı	37
Şekil 4.1. %70- %30 için Yapay Sinir Ağı Grafiği (İlk Çalıştırma)	50
Şekil 4.2. %70- %30 için Yapay Sinir Ağı grafiği (İkinci Çalıştırma)	51

TABLÖLAR

	Sayfa
Tablo 3.1. Geleneksel Yöntemler ve Yapay Sinir Ağlarının Bazı Özellikleri	13
Tablo 3.2. Yapay Sinir Ağlarının Tarihsel Geçmişi	17
Tablo 3.3. Biyolojik Sinir Ağı ve Yapay Sinir Ağı'nın Karşılaştırılması	22
Tablo 4.1. Çalıştırmada Kullanılan Değişkenlere İlişkin Bilgiler.	45
Tablo 4.2. Çalışmada Kullanılan Değişkenlere İlişkin Tamamlayıcı İstatistikler	48
Tablo 4.3. Değişkenlere İlişkin Korelasyon Bilgileri	49
Tablo 4.4. %70- %30 için Yapay Sinir Ağı Yapısı	49
Tablo 4.5. Yapay Sinir Ağı Modeli	52
Tablo 4.6. Ortalama Hata Karesi (MSE).....	53

SİMGELER VE KISALTMALAR

ÇKA : Çok Katmanlı Algılayıcı
TKA : Tek Katmanlı Algılayıcı
YSA : Yapay Sinir Ağları

1. GİRİŞ

Ekonomi tarihine bakıldığında, enflasyon ile ilgili gelişmeler 16. Yüzyıl Avrupasında ortaya çıkmıştır. Amerikanın keşfiyle, İspanyolların Avrupada ulaştıkları altınları kendi ülkelerine getirmesiyle ürün fiyatlarında artış meydana gelmiştir. Bu durum da enflasyon olgusunu ortaya çıkarmıştır (Aydoğan, 2004).

Enflasyon, bir ekonomideki mal ve hizmet fiyatlarının genel seviyesinde yaşanan sürekli artış olarak tanımlanmaktadır. Enflasyon, sadece bir veya birkaç mal ve hizmetin değil, bir tüketicinin yıl içinde kullandığı ortalama tüm mal ve hizmetlerde meydana gelen fiyat değişikliğini kapsamaktadır (TCMB, 2013). Diğer tanımı; toplam talep miktarının, toplam arzdan yüksek olmasıdır. Enflasyonist dönemlerdeki sürekli ve hızlı fiyat artışlarının varlığı ise fiyat istikrarının bozulmasını yansıtmaktadır. Genel fiyat düzeyindeki artış, satın alım gücüne azalış olarak yansıyacaktır. Yani enflasyon, para birimine karşılık gelen alım gücüne azalma olarak yansımaktadır. Buna bağlı olarak, ekonomi içinde de para birimlerine olan güven kaybının yaşanmasına neden olmaktadır. Ekonomide güvenin sağlanması için fiyat istikrarının sağlanması oldukça önemlidir. Ekonomi dinamik bir seyir izlediğinden, sürekli değişiklikler görülebilir. Fakat asıl amaç; değişikliklerin minimum düzeyde tutulması ve sert dalgalanmalara izin verilmemesidir. Enflasyon, toplumun refahını ve düzenini etkileyen önemli bir unsur olduğundan gerek ekonomik gerekse sosyal alanlarda enflasyonun etkisini önemli bir boyuta taşıyacağı yadsınamaz bir gerçektir.

Enflasyonun ekonomi üzerinde olumsuz etkileri olabilir. Örneğin, gelecekteki enflasyonla ilgili belirsizlik, yatırım ve tasarrufları caydırabilir. Tüketiciler, fiyatların gelecekte artacağından endişe duyarak istiflemeye başlarsa, yüksek enflasyon mal kıtlığına yol

açabilir. Ekonomistler, genel olarak, yüksek enflasyon ve hiperenflasyon oranlarının, para arzının aşırı büyümesinden kaynaklandığı konusunda hemfikirdir (Schwartz, 2009).

Küreselleşen dünyada insanlar birçok ekonomik sorunla karşı karşıya kalmıştır. Ekonomistler de konuları gereği incelemek, anlamak ve üretecekleri politikalarla problemleri ortadan kaldırmak durumundadırlar (Özdemir, 2010).

Enflasyon, gelir ve servet dağılımını değiştirmektedir. Gelirlerinin hiç olmazsa fiyatlar genel düzeyindeki artış kadar artmasını sağlayamayanlar, farklı bir ifadeyle gelirlerini enflasyona endeksleyemeyenler kaybetmektedirler. Bununla beraber borç verenler de enflasyonun etkisinden dolayı zararlı çıkabilmektedir. Bu, borç verenlerin enflasyonun alacağı değeri düşük öngörmeleri, verdikleri borç için istedikleri nominal faiz haddini bu öngörüye göre ayarladıkları ama enflasyonun daha yüksek bir düzeyde gerçekleştiği durumlarda ortaya çıkmaktadır (Özatay, 2011).

Enflasyonun ana nedenlerini iki aşamada inceleyebiliriz. Bunlardan biri talep enflasyonu diğeri ise arz enflasyonudur. Talep enflasyonu, para arzının artmasıyla birlikte ortaya çıkmaktadır. Bu durum da tüketimi arttırır. Bir ekonomide toplam arzın toplam talebi karşılayamaması durumunda, fiyatlarda yükselme meydana gelir. Buna bağlı olarak da ekonomi tam istihdam sürecindeyken mal, hizmet ve üretim piyasalarındaki üretim artışı enflasyona neden olmaktadır. Enflasyonu etkileyen diğeri bir unsur da arzdır. Üretim araçlarının maliyetlerindeki artışla maliyetin artması, arz enflasyonunu ortaya çıkarmıştır.

Enflasyon oranlarının yüksek olması, gelişmekte olan ülkeler için önemli bir makroekonomik sorundur. Söz konusu enflasyon oranının

yüksek olması, ekonomide büyük bir sorun olarak gösterilemez. Fakat bu oran yükselişinin uzun dönemde yaşanılıyor olması ve süreklilik kazanması, enflasyona konu olan ülkelerin ekonomilerinde daralma ve verimlilik kaybına neden olacaktır. Aynı zamanda, mali açıdan da olumsuz etkileyecektir. Enflasyonun diğer olumsuz etkilerine bakıldığında, yatırım ve tasarruflarda azalış olmasına neden olacak ve gelecekteki enflasyon üzerindeki belirsizlik gibi sonuçlar doğuracaktır. Belirsizlik sürecinde ekonomide öngörü sekteye uğrayacak ve durgunluk getirecektir. Buna ek olarak, Merkez Bankası para politikasını yürütmede, para biriktirme yerine kredi ve yatırım teşvikiyle, deflasyon ile ilgili verimsizliklerden kaçınmasına ve daha serbest bırakılmasına olanak sunmaktadır.

Makroekonomik değişkenler arasındaki ilişkiyi anlamak, ekonomistler ve politikacılar için oldukça önem taşımaktadır. Ekonomik karar birimlerinin nispi fiyatları reel olarak algılamalarını zorlayarak belirsizliği arttırması dolayısıyla enflasyon reel ekonomik değişkenleri etkileyeceği birçok ekonomist tarafından kabul görmektedir (Jansen, 1989).

Birçok iktisatçı, düşük ve stabil ilerleyen bir enflasyon oranını desteklemektedir. Düşük enflasyon, iş gücü piyasasının oluşabilecek bir yıkımda daha hızlı adapte olup kendini uyarlayarak, ekonomik durgunluğun şiddetini yavaşlatıp likidite etkisini azalacaktır. Enflasyon oranını düşük ve istikrarlı tutma görevi daha çok para otoritelerinin yükümlülüğündedir. Ve bu para otoriteleri; faiz oranlarının belirlenmesi, açık piyasa işlemleri ve bankacılık rezerv gereksinimlerinin belirlenmesiyle, para politikasını denetleyip kontrol eden merkez bankalarıdır.

Yüksek enflasyon oranı, gelişmekte olan ülkeler için her zaman ciddi bir sorun olmuştur. Enflasyon oranının yüksek olması ekonomide

belirsizlik yaratacaktır. Bu da ekonomideki karar vericilerin doğru karar almalarını engelleyen bir durumdur. Belirsizlik ortamında para politikalarının etkisi azalacaktır. Çünkü beklentilerin doğruluğu düşük olacağından para politikaları ile de uyuşmayacaktır. Buna bağlı olarak merkez bankası fiyat istikrarını sağlayarak enflasyonu düşürmek için daha esnek olma yoluna gitmiştir.

Bir ekonominin dinamik seyri için enflasyon önemli bir unsurdur. Çünkü enflasyon insanların yaşam kalitelerini aşağı çekerek, sınıf dengesizliklerini arttırmaktadır. Varlıklı ve yoksul insanlar arasındaki uçurumun artması, kutuplar arası çatışmaları da beraberinde getirmektedir. Alım gücünün azalması ile birlikte ekonomide de durgunluğa sebep olacaktır. Bu açıdan bakıldığında, enflasyonun toplumsal huzur ve nizama dokunan bir etkiye sahip olduğu söylenebilir.

Çalışmanın ikinci bölümünde, literatür özetine yer verilmiştir. Daha önce yapay sinir ağları ile yapılmış çalışmalara ait bilgiler bulunmaktadır.

Çalışmanın üçüncü bölümünde; yapay sinir ağlarının çıkış noktasının net anlaşabilmesi için yapay zekaya yer verilmiştir. Buna ek olarak yapay sinir ağlarının tarihçesi ve yöntemleri detaylı bir şekilde açıklanmıştır. Çalışmada kullanılan yapay sinir ağı modeli olan ileri beslemeli geri yayılım ağları detaylı bir şekilde ele alınmıştır.

Çalışmanın dördüncü bölümünde; çalışmanın amacı, önemi ve kullanılan veriye ilişkin bilgiler ele alınmıştır. Çalışmada kullanılan değişkenlere ve uygulanan analize ait bulgulara yer verilerek değerlendirilmiştir. Analizde, 2017 yılına ait enflasyonu etkileyen faktörlere ilişkin 91 adet veri kullanılmıştır. Çalışmada kullanılan veriler, R programı ile analiz edilmiştir.

Çalışmanın beşinci bölümünde; ulaşılan bulgular grafik ve tablolarla desteklenerek açıklanmıştır.

2. LİTERATÜR ÖZETİ

Yapay sinir ağlarına ilişkin ilk çalışmalara 1900'lü yılların başında başlanmıştır. Daha sonra 1960 yılına gelindiğinde, Widrow ve Hoff yapay sinir ağları ile ilgili çalışmalarını ilerletmişlerdir. 1980'li yıllara gelindiğinde yapay sinir ağları çalışmalarına daha fazla ağırlık verilmiştir. 1986 yılında ise Rumelhart bir yapay sinir ağı modeli olan ileri beslemeli modellerde hatanın geriye yayılma algoritmasını geliştirmiştir. İleriki dönemde yapay sinir ağları, gelişen teknoloji ile birlikte popüler hale gelmiştir. Yapay sinir ağlarının kullanıldığı literatür çalışmaları aşağıda verilmiştir.

Diler (2003), İMKB Ulusal-100 Endeksi'nin tahminlemesi üzerine bir çalışma yapmıştır. Bu çalışmada yapay sinir ağlarının piyasada uygulanabildiğini tartışmaya açmayı amaçlamıştır. Elde ettiği sonuçlar neticesinde tahmin oranının yüksek olduğu sonucuna ulaşmıştır.

Tektaş ve Karataş (2004), işletme problemlerine yönelik sorunların çözümü için yaygın olarak kullanılan yapay sinir ağları modelini tanıtmak istemişlerdir. Yapay sinir ağlarının diğer yöntemlere oranla daha iyi sonuç verdiği sonucuna ulaşmışlardır.

Paul D. McNelis (2005), modern finans teorilerinin çoğu belirsizlik altındaki mikroekonomik optimizasyon ve karar teorisinden geldiğini belirtmektedir. Yapmış olduğu çalışmada yapay sinir ağlarının doğrusal olmayan verilerde iyi bir alternatif olduğunu vurgulamıştır.

Baş (2006), sanayi üretim indeksinin tahmin modellerinin oluşturulmasına yönelik bir çalışma yapmıştır. Bu çalışmada yaygın kullanılan yapay sinir ağları yönteminin kullanımını araştırmıştır.

Doğrusal olmayan modellerde kullanım kolaylığıyla daha etkili olacağını belirtmiştir.

Akkaya vd. (2009), finansal başarısızlıkların tahmininde yapay sinir ağları modelini kullanmışlardır. Çalışma sonucunda yapay sinir ağları modellerinin etkin bir denetim aracı olabileceği sonucuna ulaşmışlardır.

Kutlu ve Badur (2009), çalışmada İMKB endeksi tahminlemesini yapay sinir ağları modeli olan ileri beslemeli yapay sinir ağları ile analiz etmişler ve yapay sinir ağları ile başarılı bir modelleme yapılabileceğini ortaya koymuşlardır.

Erilli vd. (2010), enflasyon öngörülerinin doğru bir şekilde elde edilip uygulanarak daha doğru kararlar alınabilmesi için yapay sinir ağlarını tercih etmişlerdir. Bu yöntemi seçmelerinin asıl nedeni; doğrusallık, belirli model kalıbı olmaması, normal dağılım şartı aranmaması ve uygulama kolaylığıdır.

Serttaş (2011), ürünlere olan talepleri etkileyen etmenleri yapay sinir ağları analizi ile tespit etmeye çalışmıştır. Çalışmada en uygun ağ modeli ile tahmin edilmiştir. Tahmin edilmek istenen ürün için doğru model kurularak ve istenilen parametreler değiştirilerek yeni sonuçlara ulaşılacağı sonucuna ulaşmıştır.

Erdoğan ve Özyürek (2012), yapay sinir ağlarını kullanarak İMKB 100 endeksinde fiyat tahminlemesi yapmayı amaçlamışlardır. Yapay sinir ağları uygulaması ile yaklaşık bir tahminde bulunabileceği sonucuna ulaşmışlardır.

Yakut vd. (2014), tarafından gerçekleştirilen çalışmada amaç, BIST değerlerinin tahminleme konusunda başarılı sonuçlar verip

vermediğinin bulunmak istenmesidir. Bu amaç doğrultusunda ileri beslemeli yapay sinir ağıları ve destek vektör makineleri yöntemleriyle analiz yapmışlardır. Çalışmanın sonunda, her iki yöntemin de borsa endeksinde modellenebileceği sonucuna ulaşmışlardır.

Sönmez vd. (2015), Türkiye'deki mevduat bankalarının karlılığını yapay sinir ağıları ile analiz etmişlerdir. Analizde yapay sinir ağılarını tercih etme sebepleri de doğrusal olmayan çok değişkenli verilerde başarılı sonuçlar vermesidir. Analiz sonucunda; başarılı sonuçlarından dolayı modelin, banka karlılığı tahmininde ciddi bir avantaj sağlayacağını düşünmüşlerdir.

Kocatepe ve Yıldız (2016), çalışmasında yapay sinir ağılarını kullanarak altındaki fiyat değişimini tahmin etmeye çalışmışlardır. Analizin tahmin başarısının oldukça yüksek olduğu sonucuna ulaşmışlardır.

3. YAPAY SİNİR AĞLARI

Yapay sinir ağıları, bir yapay zekâ teknoloji türüdür. İnsana benzer bir bilgi uygulamasıyla daha karmaşık olan veri analizi özelliklerini uygulamalara uyarlarlar. Yapay sinir ağıları, biyolojik sinir ağlarına dayalı matematiksel veya hesaplamalı bir model olarak da düşünülebilir. Yapay sinir ağıları, öğrenme aşamasında ağ içinde işlenen bilgilerle uyarlanabilir bir sistemdir.

Yapay sinir ağıları, deneyimlerden öğrenme, benzer durumlardan genellemeler yapma ve geçmişte kötü sonuçların elde edildiği durumları yargılama gibi algoritmalar uygular.

Yapay sinir ağıları, son on yılda tahmine dayalı modeller ve örüntü tanıma olarak büyük ilgi görmektedir. Yapay sinir ağıları, sistemi yöneten fiziksel ve kimyasal yasalar hakkında gerçek bilgi olmadan bir dizi deneysel veriden 'öğrenme' yeteneğine sahiptir. Bu nedenle, veri işlemede yapay sinir ağıları uygulanması özellikle sistemlerin doğrusal olmayan ve karmaşık davranışlar sergilediği durumlarda yüksektir (Kwon, 2011).

3.1. Yapay Zekâ

İnsan beyni oldukça karmaşık bir sistem olarak görülmektedir. Yapay zekâ da bu karmaşık sistemin işleyişini algılayıp taklit ederek, yakın denilebilecek olayları uygulayabilecek bilgisayar sistemleridir.

Zekâ; herhangi bir konu ile alakalı eğitilip ulaşılan verilerle, deneyim yoluyla ilerletilebilir. Daha önce deneyimlenmemiş veya birden ortaya çıkan bir soruna adapte olabilme, algılama ve düşünme yetisi ile değerlendirebilmeye uygulanabilmektedir (Elmas, 2008). Yapay zeka çalışmaları ile birlikte bilgisayarlara, zekaya ait olan bilgileri

aktarma amaçlanır. Anlama, tümevarım ve eski deneyimler gibi öğrenme yeteneği kazandırmanın amaçlandığı belirtilebilir.

Algılama ve idrak edebilme kabiliyeti olan zekanın farklı tanımları vardır. Kısaca zekâ, "Bir insanın belli bir duruma uyma, koşullara göre etkinlik araçları seçme yetkinliği; kavrama gücü, ayırt etme yetisidir" (Büyük Larousse, 12726).

Bilgisayarlar birçok alanda yaygın olarak kullanılmaktadır. İş dünyası, sağlık sektörü gibi bir çok alanda kullanım olanağı bulunmaktadır. Eski dönemlerde, karmaşık işlemler için kullanılan elektronik veri sistemi ilerleyen dönemlerde bilgisayarlarla birlikte verileri öğrenip, analiz ederek yorumlama yeteneğine sahip olmuştur. Cebirsel bir kalıbı olmayan ve sonuçlandırılmayan karmaşık işlemler, bilgisayar ile çözülebilmektedir. Bilgisayarları bu özelliklerle donatan ve bu yeteneklerin gelişmesini sağlayan çalışmalar yapay zeka olarak adlandırılmaktadır (Öztemel, 2003).

Bilgisayarlar çözülmesi zor olan cebirsel işlemleri sonuçlandırabilmelerinin yanında, algılanıp öğrenilen bilgileri uygulayabilme konusunda oldukça eksik kalmıştır. İnsan beyninin öne çıkaran yetileri, sinirsel algılayıcılarla edinilmiş ve bölümlendirilmiş verilerin değerlendirilebilmesidir. Uzman Sistemler (US), Bulanık Mantık (BM), Genetik Algoritma (GA) ve Yapay Sinir Ağları (YSA) gibi yapay zeka alt dalları özellikle son yıllarda, geniş bir araştırma ve kullanım alanı bulmaktadırlar (Elmas, 2008).

3.2. Yapay Sinir Ağları

Yapay sinir ağları; insan beyninin yetilerinden biri olan öğrenme yolu ile yeni bilgiler üretebilme, oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir destek almadan otomatik olarak

gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir (Öztemel, 2006).

Yapay sinir ağları, edinilmiş becerilerinin yanında ezber yapma ve bağlantı kurma gibi özelliklere de sahiptirler. Aldıkları bilgileri öğrenip, ağlar arasında bağlantı oluştururlar.

Yapay sinir ağlarının temel amacı, insan beyinde olduğu gibi bilgi işlemeyi ve öğrenmeyi taklit ederek öğrenmeyi sağlayan matematiksel algoritmaların geliştirilmesidir. YSA modelleri doğaları gereği ampiriktir, ancak kesin ve kesin olarak formüle edilmiş problemler için ve sadece deneyselliği açıklayabilen fenomenler için doğru çözümler verebilir (Leondes, 2007).

Yapay sinir ağları, karmaşık problemleri modellemek amacıyla çeşitli disiplinlerde uygulanmıştır. Verilerin paralel işlenmesini sağlayan yapay nöron düğümleri olarak adlandırılan bağlantılı basit işlem öğelerinden oluşmaktadır (Hecht- Nielseb, 1990; Schalkoff, 1997). Sinir ağına önem veren biyolojik sistemin temel özellikleri doğrusal olmama, yüksek benzerlik, dayanıklılık, öğrenebilme ve netliği olmayan bilgileri yönetebilme yeteneği ile genelleme yeteneğidir (Jain ve diğerleri, 1996). Bu özelliklere sahip yapay sinir ağları tercih edilir. Çünkü;

- (1) doğrusal olmayan verilere daha iyi uyum sağlar,
- (2) eksik veri ve hata olduğunda da kesin bir öngöre sağlar,
- (3) yüksek paralellik ile hızlı veri işleme sağlar,
- (4) öğrenme ve uyarlanabilirlik, sistemdeki tüm iç yapıyı güncelleme imkânı verir ve
- (5) genelleme, ağları öğrenme sürecine dahil olmayan veriler üzerinde modelin uygulanmasını sağlar.

Yapay sinir ađlarının b nyelerinde, biyolojik sinirlerde var olan sinir h creleri yer almaktadır. Bu sinirler, n ronların birbirleri ile bađlantı haline girmeleriyle birlikte ađlar meydana gelmektedir. Ađlar  đrendikleri verileri kaydedip girdiler arasında iliřki oluřturmaktadır. Nesnelere ait bilgiler vererek de bir  ıkıř elde edilmektedir.

Ađlar; eđitilebilir, adaptif ve kendini d zenleyerek  đrenme iřlemini gere ekleřtirebilen ve yorumlama yetisine sahip sinir ađları ile insan beyni yapısını uygulama ile modellemeye  alıřmaktadır. Ađların geliřtirilmesindeki asıl ama , ađ sisteminin tıpkı biyolojik sistem gibi d ř nerek karar almasını sađlamaktır.

Yapay sinir ađları bir ok alan ve  alıřmalarda kullanılmaktadır. Verilerin tahmin edilmesi, farklı durumlarla iliřkilendirilebilmesi ve sınıflandırılması gibi iřlemlerde yapay sinir ađlarından faydalanılmaktadır. Bunlara ek olarak; psikoloji, fizik, matematik, m hendislik ve felsefe gibi farklı alanlara ait  alıřmalarda da kullanım olanađı bulmaktadır.

Yapay sinir ađlarını geleneksel y ntemlerden ayıran bazı  zellikler bulunmaktadır. Tablo 3.1'te geleneksel y ntemler ve yapay sinir ađlarının bazı  zellikleri verilmiřtir.

Tablo 3.1. Geleneksel yöntemler ve yapay sinir ağlarının bazı özellikleri (Elmas, 2011).

Geleneksel Yöntemler	Yapay Sinir Ağları
Tümdengelimli usavurma: Çıkış üretmek için giriş bilgilerine bilinen kurallar uygulanır.	Tümevarımlı usavurma: Giriş ve çıkış bilgileri (eğitilen örnekler) verilir, kuralları kullanıcı koyar.
Hesaplama merkezi, eş zamanlı ve ardışıktır.	Hesaplama toplu, eşzamansız ve öğrenmeden sonra paraleldir.
Bellek paketlenmiş, hazır bilgi depolanmış ve yer adreslenebilir.	Bellek ayrılmıştır, dahilidir ve içerik adreslenebilir.
Hata toleransı yoktur.	Eğer bilgi, gürültülü veya kısmi ise kurallar bilinmiyorsa ya da karışık Hata toleransı uygulanabilir.
Hızlıdır.	Yavaştır.
Bilgiler ve Algoritmalar kesindir.	Yapay sinir sistemleri deneyimden yararlanır.

3.3. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının belli başlı özellikleri aşağıda belirtilmiştir.

- Yapay sinir ağları doğrusal değildirler. Bütün ağa dağılmışlardır, yani dağıtık bir yapıya sahiptirler.
- Öğrenme işlemi örnekler yoluyla gerçekleştirirler.
- Herhangi bir yöntem ve aşama gerektirmeden, öğrenme işlemi kendileri gerçekleştirirler.
- Ağların çalıştırılmadan önce eğitilmesi gerekmektedir.
- Hata toleransı oldukça yüksektir. Bu özelliklerinden dolayı eksik bilgiyle de çalışabilirler.
- Katmanlar arasında zaman kavramı olmadığından, aynı anda çalıştırılıp daha hızlı sonuç alınmasına olanak sağlar.
- Yapay sinir ağlarında ağa alınan verilerle ağırlıkların saptanması kolaylaşır. Bu sayede ağın ağırlık değerleri değiştirilerek, öğrenme işlemi yenilenebilir.

3.4. Yapay Sinir Ağlarının Tarihçesi

Yapay sinir ağları örnekler için bilgiler toplayarak genellemeler yapmaktadır. Daha sonra ilk defa karşılaşılan örneklerle de edindiği bilgiler doğrultusunda, örneklerle ilişkin bilgiler verebilmektedir. Yani öğrenebilme ve genelleme yapabilme özelliğine sahiptir. Bu yönüyle birçok bilim alanında uygulama olanağı bulmaktadır. Çözülmesi güç sorunları çözebilme yeteneğiyle de başarılı örnekler ortaya koymaktadır.

Yapay sinir ağları, herhangi bir koşul, varsayım ve bir kalıp zorunluluğu gerektirmemesi sebebiyle, son yıllarda öngörü problemlerini çözmek için birçok çalışmada kullanılmıştır. Özellikle doğrusal olmayan problemlerde kullanımı büyük kolaylık sağlamıştır.

Yapay sinir ağları, 1940'lı yılların ilk döneminde ortaya atılmıştır. Bunlar daha çok bilimsellikten uzak, mühendislik değeri olmayan çalışmalardır. İlk bilimsel çalışmalar, Mc Culloch ve Pitts'in 1943 yılında yayımladıkları bir makaledir. Bu şekilde ilk hesaplama modellerinin temelleri atılmıştır. Mc Culloch ve Walter Pitts, elektrik devrelerinden yararlanarak insan beyninin özelliği olan hesaplama ve analizden esinlenerek bu ağ hücresini geliştirmişlerdir. Bu yönde yapılan araştırmaları mühendislik alanına yöneltip, yapay sinir ağları için temelleri oluşturmaya başlamışlardır. XOR bir fonksiyondur. Bu fonksiyon algılayıcılar ile çözülememiştir. Fakat XOR çalışmasındaki başarısızlığı nedeniyle, belli bir süre yapay sinir ağlarına olan ilgi azalmıştır. Daha sonra 1949 yılında Donald Hebb, 'Hebbian öğrenme' teorisi adlı bir çalışma ile öğrenmeyle ilgili temel teoriyi ele almıştır. Bu çalışma ile insan beynindeki nöronların nasıl öğrendiklerini ortaya koymuştur.

1951 yılına gelindiğinde ilk nuro-bilgisayar üretilmiştir. B.G. Farley ve W.A. Clark 1954 yılında ortak bir çalışma yaparak, rassal ağlar ve adaptif tepki üretme terimini oluşturmuşlardır. Bu çalışma ile sinir hücresinde uyarılara karşılık gelen ve bu uyarılara uyum sağlayabilen bir model geliştirmişlerdir. 1958 yılında Rosenblatt, 1961 yılında ise Caianiello tarafından bu kavram sürdürülmüştür.

1958 yılında Rosenblatt algılama ile ilgili konular üzerinde durmuştur ve yapay sinir ağlarının temelini oluşturan perceptron yani algılayıcının tanımını yapmıştır. 1960'lı yıllara gelindiğinde Widrow ve Hoff YSA ile ilgili başarılı örnekler ortaya koyarak geliştirmişlerdir. 1964 yılında Hu meteorolojik verilerin tahmini için birtakım çalışmalar yapmış, adaptif ve doğrusal yapay sinir ağlarını kullanmıştır. 1969 yılında Marvin Minsky XOR probleminin tek katmanlı bir ağ yapısı ile çözülemeyeceğini ortaya koyarak, aslında şu an çok katmanlı olarak nitelendirdiğimiz yapay sinir ağı modelini ortaya atmıştır. 1974 yılında Paul Werbos, Widrow ve Hoff tarafından geliştirilmiş çalışmalara karşıt hata görevleri yapısını teklif etmiştir. Böylece, hesaplamalardaki tek katmanlı kısıt ortadan kalkmış, pek çok kısıtlı süreç hesaplanabilmıştır. 1975 yılında Werbos'un geri yayılım algoritması, çok katmanlı ağların eğitimini sağlamıştır.

1980'li yılların başında Hopfield yapay sinir ağları ile ilgili yaptığı çalışmaları geliştirip genelleştirerek, sonuçlandırılması zor ve karmaşık sorunların giderilebileceğini ortaya koymuştur. 1982 yılında ise çok katmanlı algılayıcıların, XOR problemlerini çözmesinin yanısıra, birçok sınırlılıklarını da ortadan kaldırmıştır. 1985 yılı, yapay sinir ağlarının tam anlamıyla ünlenerek ve yoğun çalışmaların başladığı bir yıl olmuştur.

1986 yılında, sinir ağlarının matematiksel modelde edindiği bilgilerle yeni bilgileri, tepkileri ve kararları güncelleyebildiği ve daha

sistematik bir hale gelmesini saęlayan 'geriye yayılım algoritması' ilk kez Geoffrey Hinton tarafından ortaya atılmış ve bu yapay sinir aęları literatürün en önemli adımlarından biri olmuştur.

1988 yılında Rumelhart, "Paralel Distrubuted Processing" adlı çalışmasında yeni öğrenme modeli olan ileri beslemeli modellerde hatanın geriye yayılma algoritmasını geliştirmiştir. Bu konuda daha önce iddia edilen XOR problemi ile doğrusal olmayan zaman serileri öngörüsü için yapay sinir aęları uygulamaları artmıştır. Diğer gelişmeler ise 1957 yılından sonra gelişme göstermiştir. Kolmogorov'un 'süper durum' teoreminden esinlenilmiştir. Bu şekilde sürekli fonksiyonların, doğrusal olmayan sonuçlarla doğrusal sonuçların birleştirilmesi ile hesaplanabileceğini göstermiştir (Öztemel, 2006).

Yapay sinir aęları ile ilgili yapılan çalışmalar kronolojik sıraya göre aşağıdaki Tablo 3.2'de sıralanmıştır.

Tablo 3.2. Yapay sinir ağlarının tarihsel geçmişi

Yıl	Yazar	Yapılan Çalışmanın Konusu
1940	Helmholtz, Pavlov, Poincare	Yapay sinir ağlarının ilk temellerinin atılması
1943	Mc Cullogh, Pitts	İlk hesaplama modellerinin ortaya atılması
1949	Donald Hebb	Hebbian Öğrenme ile öğrenme teorisinin ilk temellerinin ortaya atılması
1951	LEO / UNIVAC I	İlk nuro-bilgisayar üretimi
1954	B.G. Farley ve W.A Clark	Ortak çalışma olan rassal ağlar ve adaptif tepki üretme terimleri
1958	Farley ve Clark	Farley ve Clark tarafından üretilen terimlerin, 1958 yılında Rosentbalt, 1961 yılında ise Cainiello tarafından çalışmalarına dahil edilmesi
1960	Widrow, Hoff	YSA ile ilgili en başarılı örneklerin ortaya konulduğu yıl olması
1964	Hu	Meteoroloji verilerinin tahmini ile ilgili çalışmalar
1969	Marvin Minsky	Çok katmanlı sinir ağlarının temellerinin atılması
1974	Paul Werbos	Hata görevleri yapısının teklif edilmesi
1980	Hopfield	Çözülmesi zor problemlerin geleneksel programlar yerine YSA ile çözümleneceğini ortaya koyması
1982	Hopfield	Çok katmanlı algılayıcılarının sınırlılıklarının ortadan kaldırılması
1985	Amerikan Ulusal Fizik Akademisi	YSA nın tam anlamıyla gelişip tanındığı ve yoğun çalışmaların başladığı bir yıl olmuştur.
1986	Geoffrey Hinton	'Geriyeye Yayılım Algoritması' çalışması
1988	Rumelhart	Paralel Distrubuted Processing çalışması
1990	Ercan Öztemel	1990'lı yıllardan günümüze kadar yapay sinir ağları ilk dönemlerin aksine teorik ve laboratuvar çalışmaları olmaktan ziyade günlük hayatta kullanılan sistemlere entegre edilmeye ve yapılan uygulamalar ile birlikte pratik olarak insanlara yararlı olmaya başlamıştır.

3.5. Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri

Yapay sinir ağı birçok nörondan meydana gelmektedir. Ağ yapısı 3 ya da daha çok katmandan oluşmaktadır. Ağ içinde 1 girdi, 1 ya da daha fazla ara katman ve 1 de çıkış katmanı bulunmaktadır. Girdi katmanında, girdilere ait bilgiler bulunmaktadır. Girdi katmanı ve çıktı katmanı arasında birden fazla sayıda ara katman ya da diğer adıyla gizli katman bulunabilmektedir. Ağda yer alan her nöron bir sonraki katmana ağırlıklar aracılığıyla bağlıdır. Giriş katmanında olan nöron ile ağırlık değeri çarpılır ve ara katmana aktarılır. Ara katmanda yer alan transfer fonksiyonundan geçirilerek çıktı katmanına gönderilir (Kutlu ve Badur, 2009).

Yapay sinir ağlarında, bir problemde en uygun birleştirme fonksiyon türünü bulmak için herhangi bir formül bulunmamaktadır. Kullanılmak istenen birleştirme fonksiyonu, deneme yanılma yoluyla bulunmaktadır.

3.5.1. Biyolojik sinir ağları


Beynin çalışma sistemi, geçmiş zamandan itibaren üzerinde çalışılıp hala çözüme ulaşılamamış bir konudur. Beynin çalışma sisteminde binlerce sinir hücresi bulunmaktadır. Çalışma sistemi henüz gizliliğini korumaktadır. İnsan beyinde yaklaşık olarak 100 milyar sinir hücresi ve her bir sinir hücresinin 1.000 ile 10.000 arası ilişkili bağlantısı vardır. Beynin gücü bu çok sayıdaki sinir hücresi ve aralarındaki sonsuz sayıdaki bağlantılardan, genetik yapıları ile öğrenme yeteneklerinden kaynaklanmaktadır (Anderson and McNeill, 1992).

İnsan beyinin sinir sistemine baktığımızda, üç farklı adımdan meydana gelmektedir. Bunlar; reseptörler, sinir ağları ve

efektörlerdir. Reseptörler, dâhili ve harici dünyadan uyarıları alır ve daha sonra bilgiyi elektriksel uyarılarıyla nöronlara iletir. Sonra sinir ağları giriş katmanından aldığı nöronları ara katmandan geçirerek çıkış katmanına doğru iletir. Son adımda; efektörler, sinir ağından gelen elektriksel uyarıları dış ortama tepkilerle çevirir.

Sinir ağının temel elementine nöron adı verilir. Nöronlar, sinaps noktalarından birbirine bağlanır. Nöron başına bir akson vardır. Bir nöron üç bölümden oluşur: Dendritler, soma ve akson. Sinir hücrelerinin birkaç dendriti vardır. Elektriksel bir darbenin bir aksondan bir dendrite aktarılma yolu, akson ve dendritle temas noktasına sinaps denir. Yani aksondan dendrite atlamış olur. Reaksiyon farklı oranlarda ortaya çıkabilir. Böylece, dendrite ulaşan sinyalin miktarı kontrol edilebilir. Örneğin, bir aksondan gelen sinyal ve sinaps reaksiyonu hızlı bir şekilde gerçekleşmezse, sinyal düşebilir ya da yükselebilir. Böylece nöronların çıktılarını değiştirebilir.

Daha basit bir haliyle; dendritlerin sinir uçlarından ulaşılan sensör veriler çekirdekte ağırlıklandırılıyor. Çekirdek üzerinden akson boyunca çıkış terminallerine bir iletim sağlanıyor. Sonrasında ise başka bir sinir hücresine bağlanıyor. Bu şekilde sinir hücreleri arasında bir etkileşim gerçekleşiyor. Biyolojik sinir hücrelerinin yapısı Şekil 3.1’de görülmektedir.




Şekil 3.1. Biyolojik sinir hücresinin yapısı (Freeman ve Skapıra, 1991)

Şekil 3.1’de görüldüğü üzere dendritler, her bir hattın bir nörona bağlandığı çevredeki nöronlardan sinyal alan ağaç benzeri yapılardır. Akson, nörondan aldığı bir sinyali diğer nörona ileten bir silindirdir. Aksonun sonundaki dendritlerle olan etkileşimi ise sinaps yoluyla gerçekleşir. Sinapstaki nöronal sinyal genellikle kimyasal bir yayılma, bazen de elektriksel uyarılardır. Bir nöron, sadece belirli bir durum gerçekleştiğinde elektriksel bir iletimle ateşler. Gelen dürtü sinyali her sinapstan nörona kadar uyarıcıları ya ateşlemeye yardımcı olur ya da engel olur.

Hücre gövdesi, elektriksel bir darbenin aksondan ne zaman ateşlenebileceğine karar verir. Bunu da girdileri toplayarak yapar. Nedeni ise, tüm girişlerin elektrik akımının olması ve hepsinin tek bir noktada birleştirilmesidir. Dolayısıyla toplam girdi sinapstan geçirildikten sonra, belirli bir değerden büyükse, hücre bir olayı tetikler. Bu da karmaşık bir kimyasal reaksiyonla olur. Hücre

ateşlendiğinde, kimyasal dengesini eski haline getirmelidir. Böylece nöron az bir süre hareketsiz kalır. Bu nedenle, birkaç nöron herhangi bir zamanda inaktif kalabilirken diğerleri aktiftir.



Şekil 3.2. Bir sinir hücresinin matematiksel modeli (Kızrak, 2018)

Şekilde 3.2’de görüldüğü gibi; nöronlara giren bir giriş değeri var. Dendrit üzerinde ağırlıklar mevcut. Giriş değeri ve dendritteki ağırlık değeri çarpılarak sinir hücresine iletim sağlanıyor. Sinir hücresinde de tüm dendritlerden sağlanan ağırlık değerleri ve giriş değerlerinin çarpımları toplanıyor. Yani ağırlıklı toplama işlemi yapılıyor. Sonrasında bias değeri ile toplanarak, aktivasyon fonksiyonu ile çıkış yapılıyor.

Matematiksel olarak;

$$y = w \times x + b \quad (3.1)$$

‘Y’ değeri bağımlı değişken, ‘x’ değeri ise bağımsız değişkendir. ‘w’ ağırlığı temsil eder. ‘b’ de bias değeridir.

Tablo 3.3. Biyolojik sinir ağı ve yapay sinir ağının karşılaştırılması

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir Hücresi (Nöron)	İşlemci Eleman (Yapay Sinir Hücresi, Düğüm)
Sinaps	Bağlantı Ağırlıkları
Dendrit	Toplam Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Çıktı

Tablo 3.3.'de biyolojik sinir ağları ile yapay sinir ağlarının benzerlikleri gösterilmiştir. Biyolojik sinir ağlarının, yapay sinir ağlarındaki karşılıkları da denebilir.

3.5.2. Yapay sinir hücreleri

Yapay sinir ağları, biyolojik sinir hücreleri ile benzer yapıda olduğundan sinirlere (proseslere) sahiptirler. Yapay sinirler aralarında bir bağlantı oluşturarak yapay sinir hücrelerini meydana getirirler. Ağı oluşturan proses elemanları, bilgileri işleme yetenekleri ve birbirleriyle kurdukları bağlantılarıyla farklı modeller oluşturmaktadırlar. Biyolojik yapıda olduğu gibi, yapay sinir hücreleri giriş sinyallerini alıp bu sinyalleri işleyip çıktıya iletirler.

Yapay sinir ağı içerisinde yer alan sinir hücreleri, bir ya da birden fazla girdiden ve bir çıktıdan oluşmaktadır.

Yapay sinir hücresinin 6 temel katmanı vardır:

1. Girdi Katmanı
2. Ağırlıklar
3. Gizli Katman (Ara Katman)
4. Toplama Fonksiyonu
5. Aktivasyon Fonksiyonu
6. Çıktı Katmanı

Yapay sinir ağılarında sinir nöronları katmanlarda yer almaktadır. Değinildiği gibi giriş katmanı dışarıdan aldığı bilgileri gizli katmana aktarmakta ve buradan örnekler elde etmektedir. Çıkış katmanında ise üretilen çıktılar dış dünyaya iletilmektedir. Çok katmandan oluşan bir ağ mevcutsa, ağın girişinde ve çıkışında gizli katmanlar bulunmaktadır. Buradaki en önemli nokta ise gizli katman sayısının ağa en iyi destek olacak şekilde seçilmesidir. Toplam fonksiyonunda ise net girdi hesaplanarak, aktivasyon fonksiyonu net girdiyi işleyerek çıktı üretir. Üretilen çıktı da dış dünyaya iletilir.

3.5.3. Katmanlar

Yapay sinir ağları, yapay sinir hücrelerinin birbirlerine bağlanması ile oluşan ağlardır. Temeline baktığımızda, yapay sinir ağlarının oldukça basit yapıları bulunmaktadır. Sinir hücrelerinin bir ucu ağın giriş katmanından alınırken, diğer sinir hücreleri de çıkış katmanı aracılığıyla dış dünyaya aktarılır. Giriş ve çıkış katmanı arasında kalan sinir hücrelerinin tamamı görünmediğinden, bu kısım ara katman ya da gizli katman olarak adlandırılır (Elmas,2018).

3.5.3.1. Girdiler

Dışarıdan gelen bilgiler bu katmanda yer almaktadır. Yapay sinir hücresine bilgiler dış dünyadan gelebileceği gibi, diğer hücrelerden ya da kendi kendisinden de bilgiler gelebilir. Bu katman üzerinde herhangi bir işlem yoktur.

3.5.3.2. Ağırlıklar

Ağırlıklar, yapay sinir hücresine gelen bilgilerin önemi ve etkisi açısından önem taşımaktadır. Ağırlıkların aldığı değerin büyük veya küçük olmasının bir önemi yoktur. Ağırlığın pozitif veya negatif

olması, etkisinin yönünü ifade ederken, sıfır olması ise etkisinin olmadığı anlamına gelmektedir. Ağırlık değerleri sabit ya da değişken değerler alabilmektedir.

3.5.3.3. Gizli katman (Ara katman)

Giriş katmanından aldıkları verileri işleyerek bir sonraki katmana aktarırlar. Ağ içerisinde bir ya da fazla sayıda gizli katman bulunabilir. Bu katmanlar, sinir ağının türlerine göre farklılık gösterir. Katmanın içerisindeki nöron sayıları da ağların türlerine göre değişkenlik gösterebilmektedir.

3.5.3.4. Toplama fonksiyonu

Bu katmanda, bir hücreye gelen net girdi hesaplanmaktadır. Ağ gelen girdiler ile ağırlıkları çarpılarak toplanır. Sonrasında aktivasyon fonksiyonunun eşik değeri bu toplama eklenerek, hücrenin net girdisi hesaplanmaktadır.


3.5.3.5. Aktivasyon fonksiyonu

Giriş katmanındaki değerler ile ağırlıkların çarpımı toplama fonksiyonuna iletilir. Aktivasyon fonksiyonda ise toplama fonksiyonda gelen girdilere ait bilgiler işlenir ve ağın çıkışına doğru iletilir. Aynı zamanda aktivasyon fonksiyonu, transfer fonksiyonu olarak da adlandırılmaktadır. Daha çok doğrusal olmayan fonksiyonlarda tercih edilmektedir. Bunun asıl nedeni, girdi ve çıktılarının doğru orantılı olmasıdır. Yapay sinir ağlarına ilişkin ilk denemelerin başarısızlıkla sonuçlanmasının temel nedeni de budur (Minsky and Papert, 1969).

Toplam fonsiyonundan alınan net girdiyi işleyerek, buna karşılık gelen çıktıyı üretmektedir. Bu işlemi yaparken de çıkış için istenilen değerler sınırlanmaktadır. İstenilen değerler genellikle $[0,1]$ arasında bir değer almaktadır.

Doğrusal Aktivasyon Fonksiyonu


Doğrusal aktivasyon fonksiyonu, doğrusal bir sorunun çözümü için yararlanılan bir fonksiyondur. Ağa gelen net girdileri, direkt olarak dış dünyaya iletmektedir. Doğrusal aktivasyon fonksiyonu Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Doğrusal aktivasyon fonksiyonu

Adım Fonksiyonu


Ağa gelen net girdi değerinin, eşik değerinin altında veya üstünde olması durumuna göre hücre çıktısının değeri $[1,0]$ arasında bir değer almaktadır. Adım fonksiyonu Şekil 3.4'te gösterilmiştir.



Şekil 3.4. Adım fonksiyonu

Sigmoid Fonksiyonu


Yapay sinir ağlarında sinir düğümlerinin çıktısını almak için kullanılan bir fonksiyondur. Diğer bir adı da transfer fonksiyonudur. Sigmoid fonksiyonu Şekil 3.5'te gösterilmiştir.



Şekil 3.5. Sigmoid aktivasyon fonksiyonu

Hiperbolik Tanjant Fonksiyonu

Hiperbolik tanjant fonksiyonu, ağı gelen net girdi tanjant fonksiyonu ile hesaplanmaktadır. Bu fonksiyon çeşidinde çıktı değeri $[-1,1]$ arasında bir değer almaktadır. Hiperbolik tanjant fonksiyonu Şekil 3.6'da gösterilmiştir.



Şekil 3.6. Hiperbolik tanjant fonksiyonu

3.5.3.6. Hücrenin çıktısı

Hücresin çıktısı, aktivasyon fonksiyonu aracılığıyla üretilen bir çıktı değeridir. Ulaşılan sonuç doğrultusunda bu değer ya sinir hücresi için bir girdi olarak ya da direkt çıkışa doğru iletilmektedir. Sinir ağının bir ya da daha fazla sayıda girdisi ve tek bir çıktısı olmaktadır.

3.6. Yapay Sinir Ağlarının Çeşitleri

Yapay sinir ağları çeşitleri, öğrenme kurallarına doğrultusunda şekillenmektedir. Öğrenme kurallarına göre yapay sinir ağları danışmanlı, danışmansız ve takviyeli olmak üzere üçe ayrılmaktadır.

3.6.1. Öğrenme metodlarına göre yapay sinir ağları

Yapay sinir ağlarındaki öğrenmede, dışarıdan bilgiler giriş katmanına aktarılır. Ağırlıkları ile çarpılan değişkenler, aktivasyon fonksiyonundan geçirilerek çıkış noktasına aktarılır. Alınan sonuç ile de beklenen sonuç karşılaştırılır. Eğer ulaşılan sonuç beklenen sonuçtan büyük ise bu işlem tekrarlanır. Bu işlem hata oranı olarak belirlenen sınıra gelene kadar tekrarlanır.

Yapay sinir ağlarında öğrenme işlemi, sinir hücreleri arasındaki ağırlık değerlerinin değiştirilmesiyle sonuçlandırılmaktadır. Yani sinir hücrelerinin bağlantı noktalarındaki ağırlık değerleri bazı yöntemlerle değiştirilebilir. Bu şekilde de ağların eğitimi gerçekleştirilebilir. Öğrenebilen bu ağlar, daha önce öğrendiği bilgiler ışığında yeni şekilleri tanıyabilir veya yeni giriş yapan verilerin hangi sınıfa dahil edileceği konusunda karar verebilir.

Ağın öğrenme sürecini maddeler halinde ele alacak olursak;

- Öncelikle ağın öğrenmesini istediğimiz verilerin toplanması gerekmektedir. Verilerin sisteme girilerek, ağın öğrenmesi sağlanır. Ağa girilen verilerin öğrenme işlemi sağlandıktan sonra, bir test datası oluşturulur. Test datası oluşturmanın asıl nedeni; ağa girdiğimiz verileri, ağın ne ölçüde öğrendiğini sınamaktır.
- Ağın; giriş, gizli(ara) ve çıkış katmanları oluşturulur.
- Ağın öğrenme katsayısını etkileyen parametreler belirlenir. Bunlar; toplama ve aktivasyon fonksiyonu, momentum katsayısı ve ağırlıklardır.
- Ağda yer alan ağırlık değeri ilk aşamada rastgele verilir. Ağın öğrenme işleminin başlaması ile de ağırlık değeri çıkan sonuca göre güncellenir.
- Ağın ağırlık katsayısını belirlemek için daha önce de

- belirttiğimiz test datasını giriş katmanına ekleyip, ağırlık katsayılarını sonucu baz alarak güncelleyebiliriz.
- Oluşan hatayı azaltmak için geri yayılım yöntemini kullanarak ağırlık değerleri güncellenir.
- Ulaşılan değerle beklenen değer arasındaki fark istenilen sonuca yakın olduğunda, ağırlık öğrenme işlemi gerçekleşmiş olarak kabul edilir.

Öğrenme işlemi bitiren ağırlık artık farklı veri setleri gösterilebilir. Yeni eklediğimiz veri setleri için tekrar ağırlık güncellemesi yapılması da gerekmez. Çünkü ilk aşamada ağırlık öğrenme sürecini tamamladığı kabul edilir.

Yapay sinir ağlarında öğrenmenin üç algoritması bulunmaktadır;

3.6.1.1. Danışmanlı öğrenme

Danışmanlı öğrenmede, yapay sinir ağlarını kullanmaya başlamadan önce ağırlık eğitilmesi gerekmektedir. Eğitim işlemi için ağırlık tanımlanan her girdi grubu için bir çıkış grubu ağırlık tanımlanmalıdır. Yani probleme ait girdi ve çıktı değerlerinin ağırlık tanımlanması gerekmektedir. Girdi ve çıktı verilerinin uyumlu olabilmesi için ağırlık katsayıları güncellenmelidir.

Danışmanlı öğrenme algoritmalarına, Widrow- Hoff tarafından geliştirilen 'Delta Kuralı' ve Rumelhart ve McClelland tarafından geliştirilen 'Geri Besleme' örnek gösterilebilir.

3.6.1.2. Danışmansız öğrenme

Danışmansız öğrenmede, ağırlık girdi değerlerine karşılık gelen bir çıktı belirtilmez. Bu öğrenmede ağırlık sadece girdi modeli tanımlılır ve ağırlık

bunu öğrenir. Ağ yapısının da alınan girdi verilerinin birbiriyle uyumu neticesinde sınıflanması beklenir. Ağırlık katsayıları da bu sınıflandırmanın yapılabileceği şekilde güncellenir. Sınıflandırma işlemi de ağırlık katsayısına bağlı olarak anlaşılır. Ağırlık katsayılarının güncelleme işlemleri tamamlandığında, ağın öğrenmesinin de tamamlandığı kabul edilir. Danışmansız öğrenme algoritmalarına, Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) ve Kohonen tarafından geliştirilen SOM (Self Organizing Map) örnek gösterilebilir.

3.6.1.3. Takviyeli öğrenme

Takviyeli öğrenme metodu çok kullanılmamakla birlikte detay da verilmemektedir. Ağa girilen verilere karşılık ulaşılan çıktıya bakılarak, sonucun doğru veya yanlış, iyi veya kötü yorumlaması yapılabilir. Daha çok karmaşık problemleri daha uygun hale getirerek sonuçlandırmak amacıyla geliştirilmiş algoritmalarlardır. Hinton ve Sejnowski tarafından geliştirilen Bolzman Kuralı veya Genetik Algoritmalar bu algoritmaya örnek gösterilebilir.

3.7. Yapay Sinir Ağı Modelleri


Yapay sinir ağı modelleri, ağda yer alan katman sayısına göre tek katmanlı yapay sinir ağları ve çok katmanlı yapay sinir ağları olmak üzere ikiye ayrılmaktadır.

3.7.1. Tek katmanlı yapay sinir ağları

Tek katmanlı yapay sinir ağları, birçok girdi ve çıktıdan oluşabilir. Fakat genel yapısı itibariyle, sadece girdi ve çıktı katmanından oluşmaktadır. Genellikle iki girdi ve bir çıktıdan oluşur. Giriş

katmanında yer alan girdiler, bağlantı noktaları boyunca uzanır ve ağırlık ile çarpılarak bir eşik değerinden geçirilir.

Bu yapıdaki ağlar, zor sorunlar karşısında yeterli değildir. 1960'lı yıllarda Rosenblatt tarafından bulunan eski bir yöntemdir. Buna bağlı olarak da karmaşık problemlerin çözümü konusunda oldukça zorlayıcıdır. Şekil 3.7'de tek katmanlı yapay sinir ağı yapısı gösterilmiştir.




Şekil 3.7. Tek katmanlı yapay sinir ağı (Şengül, 2015)

Tek katmanlı sinir ağlarının kullanılabilmesi için bazı şartların sağlanması gerekmektedir. Hücre içinde yer alan girdi ve çıktı arasındaki ilişkinin doğrusal olması şartı aranır. Aksi durumda çözülmesi mümkün değildir. XOR problemiyle benzer olan, başka bir ifade ile doğrusal olmayan durumlara ve olaylara çözüm üretemezler.

Tek katmanlı algılayıcılarda ağırlıklar en başta rastgele seçilebilir. Ya da daha önce belirlenen ağırlıklar varsa o da kullanılabilir. Sonrasında bir diskriminant denklemi oluşturup çıkış ağırlıkları

hesaplanarak, model yakınsayana dek bu işlem devam ettirilir. Bu şekilde de algılayıcılar eğitilmiş olur.



Şekil 3.8. İki girdi ve bir çıktıdan oluşan en basit TKA modeli
(Öztemel, 2006)

Bu ağlarda, sinir ağı değerlerinin ve buna bağlı olarak çıktı değerinin sıfır olmasını önlemek için eşik değeri daima 1'dir. Şekil 3.8'de gösterilmiştir.

Aksi durumda eşik değeri sıfır olursa, öğrenme işlemi gerçekleştirilememiş olur. Bu yüzden eşik değeri oldukça önemlidir.

Tek katmanlı algılayıcılarda iki model öne çıkmaktadır;

- Perceptron Modeli
- Adaline Modeli

3.7.1.1. Basit algılayıcı modeli (Perceptron)

Frank Rosenblatt tarafından 1958 yılında geliştirilen model, bir sinir hücresinin birden fazla girdi ile çıktı üretmesi sistemine dayanmaktadır. Girdinin ağırlıklı değerinin toplamı ile eşik değerin karşılaştırılması sonucunda elde edilir. Çıktı değerinin toplam eşikten büyük olması durumunda 1, küçük olması durumunda ise 0 seçilir. Marvin Minsky ve Seymour Papert bu algılayıcıların çok kısıtlı bir kullanımı olduğunu belirtmişlerdir. Buna örnek olarak da XOR problemi gösterilebilir. Algılayıcılar üzerine yapılan bu kısıt 1980'li

yıllara gelindiğinde Çok Katmanlı Algılayıcı modelinin geliştirilmesi ile giderilmiştir.

3.7.1.2. Adaline modeli


1950'lilerin sonlarına doğru Bernard Widrow ve Hoff, sinir ağıları ile ilgili bazı çalışmalar yaparak adaline modelini geliştirdiler. Bu çalışma sonucunda En Küçük Kareler algoritması adı verilen bir öğrenme kuralı oluşturdular. Bu kural yapısal olarak diğer algılayıcılarından pek de farklı değildir. Sadece doğrusal problemlere çözüm üretebilmektedir. Adaline modeli, tek katmanlı doğrusal sınıflandırıcı olan perceptrona benzemektedir. Öğrenme kuralı bundan farklıdır.

Giriş ve ağırlık değerleri çarpılıp bias değeriyle toplanır. Çıkan değer 0'dan büyükse çıkış değeri 1, küçük veya eşitse 0 atanır.

3.7.2. Çok katmanlı yapay sinir ağıları

Yapay sinir ağlarında daha önce bahsedildiği gibi tek katmanlı algılayıcılarda doğrusal olma şartı aranmaktaydı. Fakat ağın öğrenmesini istediğimiz olaylarda, girdi ve çıktı arasındaki ilişkinin doğrusal olmaması durumunda çok katmanlı algılayıcılar devreye girmektedir. Çok katmanlı algılayıcılar, Rumelhart ve arkadaşları tarafından çalışılarak geliştirilmiş bir modeldir. Hataları geriye yayma (*Backpropagation Network*) veya geriye yayılım olarak da adlandırılmaktadır. Özellikle sınıflandırma, tanıma ve genelleme yapılması gereken durumlarda önemli bir seçenek olmuştur. Bu model, '*Delta Öğrenme Kuralı*' olarak adlandırılan bir öğrenme yöntemini kullanmaktadır. Bu kural daha çok *Adaline* ve *Basit Algılayıcı* modellerinin gelişmiş halidir.

Girdi ve çıktı arasındaki ilişkinin doğrusal olup olmamasının önemini anlamak için XOR problemini anlamak gerekir. XOR fonksiyonu sadece doğrusallık söz konusu olduğunda uygulanabildiği için, doğrusal olmayan problemlere çözüm üretememiştir. Buna ek olarak da bu yönü nedeniyle bilimsel çalışmaların duraksamasına neden olmuş ve yapay sinir ağlarına olan ilgi azalmıştır. Şekil 3.9'da çok katmanlı bir yapay sinir modeli görülmektedir.



Şekil 3.9. Çok katmanlı bir yapay sinir ağı (Elmas, 2018)

3.8. Ağ Yapılarına Göre Yapay Sinir Ağları

Yapay sinir ağlarının ağ yapıları, sinirler arasındaki bağlantıların yönüne göre birbirlerinden ayrılmaktadır. Buna bağlı olarak yapay sinir ağları ağ mimarisine göre ikiye ayrılmaktadır. Bunlar; ileri beslemeli ağlar ve geri beslemeli ağlardır.

3.8.1. İleri beslemeli ağlar

Gerçek değerli ve n boyutlu girdi vektörleri şu şekilde ifade edilir; j gizli katmanı, i girdi katmanını ve w_{ij} ağırlığı temsil etmektedir. j gizli katmanında yer alan sinir, i girdisini w_{ij} ($i=1,2,...,n, j=1,2,...$)

ağırlığına göre alır. j katmanındaki sinirler x girdi sinirlerinin w_{ij} ağırlık değerleriyle çarpılarak bir sonraki sinirlere aktarılır. İlk gizli katman ağırlıklarıyla sinir hücrelerine bağlıdır. Aynı şekilde ikinci gizli katman da ağırlıklarıyla önceki katmana bağlıdır. Bu sinir ağırları, girdilerin ve girdilere ait ağırlıkları hesaplayarak bir sonraki katmana iletir. Son olarak da aynı işlem çıkış katmanındaki sinir hücreleri ile de yapıldıktan sonra işlem tamamlanmış olur. Bu ağ türü, çok katmanlı ileri beslemeli ağlar olarak da adlandırılır (Elmas, 2018).

Rosenbaltt'ın algılayıcıları ortaya atmasıyla birlikte, ileri süreçte ileri beslemeli ağlar ile ilgili birçok öneri sunulmuş ve buna bağlı çalışmalar yapılmıştır. Bu ağlar yaygın bir kullanım alanı bulmuştur.

İleri beslemeli ağlarda, dışarıdan gelen bilgiler girdi katmanına gösterilir. Girdi katmanından alınan sinyaller, herhangi bir işlem yapılmadan ara katmana gönderilir. Oradan da çıktı katmanına tek yönlü bağlantılar yoluyla gönderim sağlanır. Aynı katmanda bulunan nöronlar arasında etkileşim bulunmaz. Yani işlem girişten çıktıya doğru ilerler.

3.8.2. Geri beslemeli ağlar

Geri yayılım ağları, bir yapay sinir ağı modelidir. 1970'li yılların ilk çeyreğinde oldukça rövaşta olan, en karışık, çözülmesi zor ve varsayım gerektiren çalışmaları sonuca bağlayabilen bir yapay sinir ağı modelidir (Elmas, 2018).


Geri beslemeli yapay sinir ağları, çıktı ve gizli katmanlardaki çıktıların, girdi katmanlarına ya da önceki ara katmanlara geri iletim yoluyla beslendiği bir ağ yapısıdır. Böylece girdiler hem ileri yönde hem de geri yönde dağıtılmış olur. Geri beslemeli yapay sinir ağlarının devingen hafızaları vardır ve çıktı değeri hem mevcut girdi

değerini hem de önceki girdileri yansıtır. Bu ağlar çeşitli tipteki problemlerin tahmininde oldukça başarılıdır (Uygunoğlu ve Yurtcu, 2006).

Geri beslemeli ağlar daha çok danışmansız öğrenme yolu ile çözümlenebilecek problemler için kullanılmaktadır. Bu tip ağlarda geri besleme işlemi gerçekleşmektedir. Giriş katmanından ileri yönlü bir çözümleme yaparken, geri yönde de bir çözümleme yapılabilir. Ağa gösterilen girdiye karşı üretilen çıktı değeri, beklenen çıktılar ile karşılaştırılır. Aralarında oluşan fark ise hata olarak nitelendirilir. Alınan hata ağın ağırlık değerlerine dağıtılır ve hatanın azaltılması sağlanır. Bu durum geriye hesaplama ile yapılır. Bu tip ağlar için Jordan, Hopfield, Elman ve SOM (Self Organizing Map) ağları örnek olarak belirtilebilir.

Geri beslemeli yapay sinir ağlarında, çıktı ya da gizli katmanlardaki sinir hücreleri çıktıları, giriş katmanına ya da önceki girdi katmanındaki sinir hücrelerine tekrar girdi olarak aktarırlar. Bu şekilde veri hem ileri yönde hem de geri yönde iletilmiş olur. Geri beslemeli yayılım ağlarının ileri beslemeli ağlardan en önemli farkı, geri beslemeli ağlarının devingen doğrusal olmayan sistemleri modelleyebilmesidir (Yıldız, 2006).

Geri beslemeli ağ yapıları, daha çok danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Şekil 3.10'da gösterilen hopfield ağı bu geri besleme ağına gösterilebilecek en iyi örneklerden biridir.



Şekil 3.10. Hopfield Ağı (Elmas, 2018)

Geri yayılım ağlarında her bir nöron sayısı ve katman sayıları özenle seçilmelidir. Çünkü net bir yöntem ve kalıp olmadığından, sayıların neyin baz alınarak seçileceği bilinmemektedir. Bunun için sadece takip edilmesi gereken bazı genel kurallar vardır. Genel kurallar aşağıda sıralanmıştır.

- Ağ içerisinde yer alan girdi ve çıktı değerleri arasındaki farkın artmasıyla, ara katman (gizli katman) sayısı da arttırılmalıdır.
- Ağda incelenen olay birden fazla katmana bölünebiliyorsa, ara katman sayısı da arttırılmalıdır. Fakat fazla katmana bönenemiyorsa, ara katman sayısı arttırıldığında da bu öğretme işlemi doğru olmayan sonuçlara yol açacaktır.
- Ağda işletim elemanları için bir üst sınır gereklidir. Bunun için de eğitim için gerekli verinin miktarı ve ara katmandaki işletim eleman sayısı önemlidir. Üst sınıra ulaşmak için ilk olarak eğitim kümesindeki girdi ve çıktı çiftlerinin sayısı bulunur. Ulaşılan bu sayı ağda yer alan toplam giriş ve çıkış düğümlerinin sayısına bölünür. Ulaşılan sonuç, beş ile on arasında bir dereceleme genellikle işitsel veriler için kullanılmaktadır. İşitsel veriler, 20-50 arasında bir faktör gerektirirken, çıktı ile net bir ilişkisi olan girdi verisi faktörü 2

civarına kadar düşürülebilir. Gizli katmanların az miktarda işleme elemanına sahip olması önemli bir faktördür (Elmas, 2018).

3.9. Temel Öğrenme Kuralları

Günümüz teknolojisinin ilerlemesi ve gelişmesiyle birlikte yapay zekaya olan ilgi de gün geçtikçe artmaktadır. Yapay sinir ağları, yapay zekâ kavramının temel yapıtaşı olduğu için bu konuya eğilimi olan kişilerin de ilgi odağı olmaktadır. Yapay sinir ağlarıyla ilgili uygulama çalışmalarının ilerlemesiyle, mimari yapı ve öğrenme kurallarıyla ilgili de gelişmeler yaşanmıştır. Yapay sinir hücrelerinde öğrenmenin asıl amacı, ağdaki sinir hücrelerinin girişteki ağırlık oranlarını düzenlemektir. Buna '*ağın eğitilmesi*' denir. Ağın eğitilmesi için ağa girilecek değer başlangıçta rastgele seçilir. Yapay sinir ağlarına veri yüklendikçe ağırlık değeri değiştirilir. Bu işlemin sürekli yapılması, doğru ağırlık değerinin bulunmasını sağlayacaktır. Buna bağlı olarak da konuyla alakalı genelleme yapma yetisi gelişecektir. Ulaşılmayı hedeflenen bu özelliğe '*ağın öğrenmesi*' denir.

3.9.1. Hebb kuralı

Sinir ağlarında yer alan gözetimsiz öğrenme, daha çok Donald Hebb tarafından yazılan önermeye dayanmaktadır. Bir A hücresi aksonu bir B hücrelerini heyecanlandıracak kadar yakın olduğunda ve onu ateşlemede tekrar tekrar veya sürekli olarak yer aldığında, bir veya her ikisinde bir miktar büyüme süreci veya metabolik değişiklik gerçekleşir. A'nın B'yi ateşleyen hücrelerden biri olarak etkinliği artacak şekilde hücreler (Hebb, 1949).

3.9.2. Hopfield kuralı

Hopfield öğrenme kuralı, John Hopfield tarafından 1982 yılında ortaya atılıp geliştirilmiştir. Hopfield ağ yapıları birçok ağ yapılarına göre değişiklik göstermektedir. Bu ağ yapısında giriş, hopfield ve çıkış katmanı bulunmasına rağmen, ayrı katmanlar değildirler. Yani her her sinir hücresi birbirine bağlıdır. Bunun yanında, bağlantı noktaları çift yönlü ve uyumludur. Ağ içinde yer alan her bağlantı için bir ağırlık değeri bulunmaktadır (Elmas, 2018).

3.9.3. Delta kuralı

Delta kuralı, hesaplanan sinir hücrelerinin çıkış değerleriyle tahmin edilen çıkış değerleri arasındaki farkı düşürebilmek için bağlantı ağırlıklarının düzenlenip güncellenmesini amaçlamaktadır. Bu kural ile çıkış değerlerine ait hata değerlerini minimize etmesi hedefler. Delta kuralı, En küçük Ortalama Karesi (Least Mean Square – LMS) kuralı olarak da bilinmektedir.

3.9.4. Kohonen kuralı

Kohonen kuralı, biyolojik sistemde yer alan öğrenme metodundan türemiştir. Yapay sinir hücreleri, ağırlıklarını değiştirebilmek için birbiriyle yarış halindedir. En büyük çıktıyı değerini türeten hücre kazanan hücre olup bağlantı ağırlıkları değiştirilmektedir. Bu, o hücrenin yakınındaki hücrelere karşı daha güçlü bir duruma gelmesi anlamına gelmektedir. Hem kazanan elemanların hem de komşuları sayılan elemanların (hücrelerin) ağırlıklarını değiştirmesine izin verilmektedir (Öztemel, 2006).

3.10. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları birçok problemin çözümü için kullanım olanağı bulmuştur. Bunlara ek olarak bilgi sınıflama ve yorumlama başta olmak üzere, birçok karmaşık sorunların giderilmesinde uygulanmaktadır. Yapay sinir ağlarının kullanım olanağı bulunduğu alanlar özetle şu şekilde sıralanabilir (Elmas, 2018);

- Denetim
- Sistem modelleme
- Ses tanıma
- El yazısı tanıma
- Parmak izi tanıma
- Elektrik işareti tanıma
- Meteorolojik yorumlama
- Otomatik araç denetimi
- Fizyolojik (Kalp fonksiyonları gibi) izleme, tanıma ve yorumlama

Yukarıda belirtilmiş olan alanların dışında yapay sinir ağları, her türlü bilgiyi işleme, analiz etme ve yorumlama amacı ile de kullanılmaktadır.

Genel olarak, yapay sinir ağları uygulamalarının birçoğu aşağıdaki sınıflardan birine dahildir:

- Öngörü
- Sınıflandırma
- Veri birleştirilmesi
- Veri kavramlaştırılması
- Veri süzülmesi
- Resim veya Görüntü işleme

3.11. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay sinir ağlarının, kullanım kolaylıklarının yanında olumsuz bazı getirileri de bulunmaktadır. Yapay sinir ağlarının en öne çıkan avantajı, varsayım koşulu gerektirmeden farklı algoritmaları kullanması ve öğrenme kabiliyeti söylenebilir. Doğrulsallık şartı gerektirmeden, eksik bilgiyle de çalışabilmesi ve hata toleransı olması büyük kolaylık sağlar. Bu avantajların yanında bazı sakıncalı riskleri de vardır. Sistem çalışmasının analiz edilememesi ve ağın arka planda nasıl çalıştığının bilinmemesi en büyük dezavantajlarıdır.

Yapay sinir ağlarının avantaj ve dezavantajları aşağıdaki gibidir.

Avantajları;

- Yapay sinir ağları örnekler üzerinden öğrenebilir, bir kez eğitildiklerinde yeni bir veri kümesine hemen cevap verebilirler. Bir örnekten hareketle benzer örnekleri açıklayabilirler.
- Yapay sinir ağları herhangi bir cebirsel modele gerek duymazlar.
- Yapay sinir ağlarında verilerin ağa tanıtılıp öğretilmesinde herhangi bir varsayım gerekmemektedir. Bu yönüyle özellikle uygulamada büyük bir önem taşımaktadır.
- Geleneksel bilgisayar sistemleri, uygulamada oluşabilecek sorunlar karşısında hassasiyeti yüksektir. Sistemde oluşabilecek herhangi bir sorun, çözüme ulaşmama veya sonuçlarda ciddi hatalara neden olabilmektedir. Ancak yapay sinir ağlarında bazı nöronların zarar görmesi, sistemi geleneksel yöntemde olduğu kadar etkilemez. Çünkü hata toleransı yüksektir.

- Ağın ağırlık katsayısı ve yapısı gibi bazı parametreleri değiştiğinde problemin çözümü için kendini uyarlayabilme özelliğine sahiptir.
- Uyumlu bir yapıya sahip olduklarından, adaptif öğrenme yeteneğine sahiptir.

Dezavantajları;

- Ağın arka planda nasıl çalıştığı bilinmemektedir. Buna bağlı olarak da ulaşılan değerlerin yorumlanması zorlaşabilir.
- Mevcut bir sorunun giderilmesi için net bir çözüm yoluna ulaşamayabilirler. Bu durumun asıl nedeni, ağları eğitmek için belirli bir fonksiyonun olmamasıdır. Varsayalım bir fonksiyon olsa bile yeterli miktarda veriye ulaşamayabilir.
- Ağları eğitmek için yeterli miktarda süreye gereksinimleri vardır ve bu sürenin maddi değeri fazladır.
- Farklı durumlara adapte olması güç olabilir.
- Ağın arka planda nasıl çalıştığı ve nasıl çözüm üretildiği bilgilerine ulaşma imkânı yoktur.
- Ağ eğitildikten sonra ne zaman biteceğini belirlemek ya da kestirmek mümkün değildir.

4. UYGULAMA

Enflasyonun; ekonomi, finans, işletme ve mühendislik uygulamalarında yapay sinir ağları büyük bir ilgi odağı haline gelmiştir. Enflasyon oranları ile ilgili önemli sayıda çalışma bulunmaktadır. Birçok makroekonomik göstergelerin tahmini ve analizi için yapay sinir ağları modelleri kullanılmaktadır. Bunun en önemli nedeni sağladığı kullanım kolaylığıdır.

Enflasyonun gerek finansal gerekse ekonomik bakımdan etkili ve önemli bir yeri vardır. Bunun yanı sıra, enflasyon oranlarının tutarlı bir şekilde hesaplanıp analiz edilmesi, ülkelerin gelişmişlik düzeyleri bakımından büyük bir önem taşımaktadır. Enflasyon oranlarının belirli bir seviyenin üstüne çıkması, ekonomiyi olumsuz yönde etkilemektedir. Artan maliyet ile mevcut paranın alım oranı azalacak ve hayat standardı da düşecektir. Buna bağlı olarak, enflasyon oranının ideal seviyede olması ekonominin en önemli göstergelerinden biridir.

Sinir ağı, modellemek için tasarlanmış bir makinedir. Beynin belirli bir görevi veya işlevi yerine getirme şeklidir. Ağ daha çok yazılım, algılayıcılar araçlar yoluyla test edilir. Bunun dışında, dijital bir bilgisayarda deneme yapılır. Ağlar, deneysel verileri depolamak ve onu kullanılabilir kılmak için doğal bir eğilime sahip basit işlem birimlerinden oluşan, büyük ölçüde paralel dağıtılmış bir işlemcidir. İlk aşamada bilgi, ağ tarafından öğrenme süreciyle çevresinden edinilir. İkinci aşamada sinaptik ağırlıklar da bilinen bağlantı güçleri, elde edilen bilgiyi depolamak için kullanılır. Öğrenme sürecini gerçekleştirmek için kullanılan prosedüre bir öğrenme algoritması denir. Bunun işlevi, istenen bir tasarım hedefine ulaşmak için ağın sinaptik ağırlıklarını düzenli bir şekilde değiştirmektir (Widrow and Stearns, 1985; Haykin, 2002).

4.1. Uygulamanın Amacı ve Önemi

Enflasyon ülkelerin büyüyüp kalkınması için önemli etkenlerden biridir. Para otoriteleri ekonomik göstergeleri belirli bir seviyede tutmayı amaçlamaktadır. Enflasyon da bunlardan biridir. Enflasyonu etkileyen birçok faktör bulunmaktadır. Enflasyon seviyesinin belirli bir seviyede seyri normal olmakla birlikte, sert dalgalanmalar ekonomiye zarar vermektedir.

Enflasyon, ülkelerin ekonomileri açısından oldukça önemlidir. Bunu kontrol altına alınması için enflasyonu etkileyen faktörlerin belirli bir seviyede ilerliyor olması gereklidir. Bu faktörler direkt olarak enflasyona ve ekonomiye yansıyacaktır. Bu gibi durumlar ekonomiye yansımalarının yanında, kişilerin satım alım gücünü düşürecek ve yaşam kalitesine de olumsuz yansıyacaktır. Uygulama sonuçları da buna bağlı olarak önem taşımaktadır.

Bu çalışmada, enflasyonu etkileyen faktörlerin, ekonomik ve finansal göstergelerden yararlanılarak, yapay sinir ağları analiziyle bir uygulama yapılmak istenmiştir. Elde edilen veriler ile bir yapay sinir ağı modeli oluşturulması amaçlanmaktadır.

Uygulamada kullanılan veriler Worldbank (Dünya Bankası) üzerinden elde edilmiştir. Veri setinde 8 adet değişken ve her bir değişken için 91 adet gözlem değeri bulunmaktadır.

4.2. Uygulamada Kullanılan Veri Seti

Bu çalışmada, enflasyonu etkileyen faktörler ülkeler bazında yapay sinir ağları ile analiz edilmiştir. Enflasyon değişkeni bağımlı değişken olarak alınmış ve üzerinde etkisi olduğu düşünülen bağımsız değişkenler; gayri safi milli hasıla (GSMH), işsizlik (ISS), nüfus artışı

(NA), özel sektörlere verilen yurtiçi kredi (OSVYK), para arzı (PA), ücretli ve maaşlı çalışanlar (UMC) ve eğitim ve devlet harcamaları (EDH) olarak belirlenmiştir. Çalışma, ülkelerin tamamı dikkate alınarak düzenlenmek istenmiştir. Ancak yapılacak olan analizde kayıp gözlemlerin bulunmasının istenmemesi ve yine uygulanacak olan yöntemin çok sayıda veri yardımıyla sağlıklı sonuçlar elde edilmesine imkân sağlamasından dolayı, en fazla gözlemin elde edilebildiği 2017 yılı verileri esas alınmıştır. İlgili yıl için 91 ülkeye ilişkin veriler derlenmiştir. Veriler Dünya Bankası (World Bank Group) web sitesinden oluşturulmuştur.

Uygulamada yer alan değişkenlere ait açıklama tablosu aşağıdaki Tablo 4.1'deki gibidir:

Tablo 4.1. Çalışmada kullanılan değişkenlere ilişkin bilgiler

Sembol	Değişken Adı	Açıklaması
ENFLASYON	Enflasyon	Tüketici fiyat endeksi ile ölçülen enflasyon, yıllık gibi belirli aralıklarla sabitlenebilen veya değiştirilebilen bir mal ve hizmet sepeti satın almanın ortalama tüketiciye maliyetindeki yıllık yüzde değişimi yansıtır.
GSMH	Gayri Safi Milli Hasıla	Hane halkı nihai tüketim harcamalarının ve gayri safi sermaye oluşumunun toplamıdır.
ISS	İşsizlik	İşsizlik, işsiz olan ancak iş arayan ve iş arayan işgücünün payıdır.
NAO	Nüfus Artış Oranı	T yılı için yıllık nüfus artış hızı yüzde olarak ifade edilen, t-1'den t'ye kadar olan yıl ortası nüfusun üstel büyüme oranıdır.

OSVYK	Özel Sektörlere Verilen Yurtiçi Kredi	Hisse senedi olmayan menkul kıymet satın alımları ve ticari krediler ve geri ödeme talebi oluşturan diğer alacak hesapları gibi finansal kuruluşlar tarafından özel sektöre sağlanan finansal kaynakları ifade eder.
PA	Para Arzı	Ekonomide dolaşan toplam para miktarıdır.
UMC	Ücretli ve Maaşlı Çalışanlar	Çalışanlar, yerleşiklerin açık veya onlara doğrudan bağlı olmayan temel bir ücret veren örtük iş sözleşmelerine sahip olduğu 'ücretli istihdam işleri' olarak tanımlanan iş türlerine sahip olan işçilerdir.
EDH	Eğitim ve Devlet Harcamaları	Eğitimle ilgili genel devlet harcamaları, GSYİH'nın yüzdesi olarak ifade edilir.

Çalışmada, enflasyonu etkileyen faktörler olan GSMH, ISS, NA, OSVYK, PA, UMC ve EDH değişkeni bağımsız (girdi) olarak kullanılmıştır. Enflasyon verisi ise bağımlı (çıktı) değişkeni olarak kullanılmıştır. Çalışmada kullanılan değişkenlerin ülkeler bazında ortalama değerlerine ait bilgiler aşağıdaki grafiklerdeki gibidir. Çalışmada 2017 yılına ait veriler kullanılmış ve her bir bağımsız değişkenin 2017 yılına ait oran bilgileri grafik üzerinde gösterilmiştir.

4.2.1. Verilerin normalizasyonu

Yapay sinir ağları uygulamalarında, girdi olarak seçilecek olan verilerin öncelikli olarak normalleştirilmesi gerekmektedir. Bu normalleştirme işlemi, veri seti için en önemli parametrelerden biridir. Oluşturulacak olan veri setini doğru tasarlayarak, bazı kurallara bağlı kalmak oldukça önemlidir. Sonrasında konu veri seti için bir veri sorgulaması yapmak, veri setini daha verimli ve esnek kullanılacak hale getirecektir.

Bir sinir ağıını eğitmeden önce verilerin normalleştirilmesi uygulama için önemli bir aşamadır. Normalleştirme ile veri birimleri ortadan kaldırılarak, farklı konumlardaki verilerin kolayca karşılaştırılmasına olanak sağlar.

Verileri normalleştirmek için girdi olarak alınan değerin 0 ile 1 arasına çekilmesi gerekmektedir. Birçok normalleştirme yöntemi olmasının yanında, bu çalışmada yaygın olarak kullanılan Min-Max. Yöntemi kullanılarak verileri normalleştirme işlemi yapılmıştır. Max-Min. değerlerinin normalleştirilmesiyle, en yüksek ve en düşük değere sahip her değerin konumu hesaplanmıştır. Bu yöntemin formülize edilmiş hali aşağıda gösterilmiştir.

$$x_{standart} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4.1)$$

4.3. Yöntem ve Kullanılan Teknikler

Çalışmada yöntem olarak yapay sinir ağları modeli olan ileri beslemeli geri yayılım ağı kullanılmıştır. Uygulamanın ilk aşamasında; enflasyonu etkileyen faktörlerin aralarındaki korelasyona bakılmış, sonrasında yapay sinir ağları analizi yapılmıştır.

Veri setinde yer alan değişkenlere ilişkin tamamlayıcı istatistikler aşağıdaki gibidir:

Tablo 4.2. Çalışmada kullanılan değişkenlere ilişkin tamamlayıcı istatistikler

	ENFLASYON	GSMH	ISS	NA	OSVYK	PA	UMC	EDH
Min.	-1.537	1,830E+12	0.140	-16.919	3,59	15.80	5.342	2.088
1st Qu	1.863	1,664E+13	3.703	0.6291	23.68	39.88	27.133	3.720
Median	3.280	7,99E+13	5.221	13.336	44.88	56.86	56.821	4.308
Mean	3.923	2,47E+15	6.510	13.692	52.64	65.83	53.386	4.468
3rd Qu	4.546	1,24E+15	8.115	22.590	64.06	79.04	79.185	5.133
Max.	18.220	2,97E+16	27.071	38.392	168.69	247.24	99.582	7.963

Tablo 4.2'ye baktığımızda, en düşük min. değere sahip değişkenin NA, en düşük max. değere sahip değişkenin GSMH olduğu görülmektedir. Ortalama ve ortanca değerleri arasındaki farkın en fazla olduğu değişken GSMH olduğundan, sapma olduğundan bahsedilebilir.

4.4. Bulgular

Çalışmaya ait bulgular, uygulamalar çerçevesinde verilmiştir.

4.4.1. Yapay sinir ağı mimarisi

Uygulamanın ilk adımında enflasyonu etkileyen faktörlerin kendi aralarındaki korelasyona bakılarak aralarındaki ilişki incelenmiştir. Sonrasında ise yapay sinir ağı modeli olan ileri beslemeli geri yayılım ağı ile analiz yapılmıştır.

Değişkenlere ilişkin korelasyon bilgileri Tablo 4.3'te gösterilmiştir.

Tablo 4.3. Değişkenlere ilişkin korelasyon bilgileri

	ENFLASYON	GSMH	ISS	NA	OSVYK	PA	UMC	EDH
ENFLASYON	1,00	- 0,08	- 0,03	0,09	- 0,30	- 0,31	- 0,27	- 0,08
GSMH	- 0,08	1,00	- 0,05	- 0,12	0,37	0,53	- 0,00	- 0,06
ISS	- 0,03	- 0,05	1,00	- 0,26	0,09	0,01	0,24	0,20
NA	0,09	- 0,12	- 0,26	1,00	- 0,26	- 0,33	- 0,64	- 0,10
OSVYK	- 0,30	0,37	0,09	- 0,26	1,00	0,79	0,57	0,37
PA	- 0,31	0,53	0,01	- 0,33	0,79	1,00	0,42	0,10
UMC	- 0,27	- 0,00	0,24	- 0,64	0,57	0,42	1,00	0,33
EDH	- 0,08	- 0,06	0,20	- 0,10	0,37	0,10	0,33	1,00
Total	0,01	1,59	1,20	-0,62	2,62	2,20	1,65	1,75


Matematiksel olarak bakıldığında, korelasyon katsayısı $[-1, +1]$ arasında bir değer almaktadır. Ulaşılan sonuç -1 'e yakınsa negatif ilişki, $+1$ 'e yakında pozitif ilişki, 0 'a yakınsa ilişki yok demektir. Buna bağlı olarak tabloda; enflasyon ile korelasyon oranının en yüksek olduğu değişkenin NA olduğu görülmektedir. Diğer değişkenlere baktığımızda; Enflasyon ile GSMH, ISS, OSVYK, NA, PA, UMC VE EDH değişkenlerinin korelasyon oranlarının negatif yönlü bir ilişki içinde olduğu görülmektedir.

Uygulamada yapay sinir ağı modeli olan ileri beslemeli geri yayılım ağı kullanılmıştır. R software yazılımı üzerinde uygulama yapılmıştır.


Tablo 4.4. %70- %30 için yapay sinir ağı yapısı

Ağ Modeli	Çok Katmanlı
Öğrenme Algoritması	İleri Beslemeli Geri Yayılım Ağı
Giriş Katmanındaki Nöron Sayısı	7
Gizli Katman Sayısı	2
1. Gizli Katmandaki Nöron Sayısı	9
2. Gizli Katmandaki Nöron Sayısı	9
Çıktı Katmanındaki Nöron Sayısı	1
Aktivasyon Fonksiyonu	Doğrusal Aktivasyon Fonksiyonu

Tablo 4.4.'e bakıldığında, %70- %30 yapay sinir ağı modeli ileri beslemeli geri yayımlı bir modeldir. Girdi katmanında 7 nöron bulunmaktadır. İki gizli katman bulunmaktadır. İlk gizli katmanda 9 nöron, ikinci gizli katmanda da 9 nöron bir çıkış nöronu bulunmaktadır. Yapay sinir ağı modelinde aktivasyon fonksiyonu olarak doğrusal aktivasyon fonksiyonu kullanılmıştır.



Şekil 4.1. %70- %30 için yapay sinir ağı grafiği (ilk çalıştırma)



Şekil 4.2. %70- %30 için yapay sinir ağı grafiği (ikinci çalıştırma)

Yukarıda gösterilen Şekil 4.1. ve Şekil 4.2’de girdiler 7 nöronlu, gizli katman 9’ar nöronlu 2 gizli katmandan ve 1 çıkışı olan iki yapay sinir ağı bulunmaktadır.

Modelin ilk çalıştırılmasıyla oluşan grafik Şekil 4.1’de gösterilmiştir. Ortalama hata karesi 0,086073 ve iterasyon sayısı 632 sonucuna ulaşılmıştır.

Modelin ikinci çalıştırılmasıyla oluşan grafik Şekil 4.2’de gösterilmiştir. Ortalama hata karesi 0,008716 ve iterasyon sayısı 1317 sonucuna ulaşılmıştır.

Her iki çalışma sonucunda; ikinci çalıştırma ile ulaşılan sonuç doğrultusunda modelin olumlu yanıt verdiği sonucuna ulaşılmıştır.

Modelde gizli katman ve çıkış katmanına bakıldığında nöronlar arasındaki rakamlar ağırlıkları temsil etmektedir. Verilerin %70'i ağı eğitmek için, %30'u da ağı test etmek amacıyla 70:30 olarak bölünmüştür. Girişten çıkış doğru siyah renkle ilerleyen oklar ileri beslemeyi göstermektedir. Geri yöne doğru devam eden mavi oklar da geri yayılımı temsil etmektedir. İleri besleme sonrası geri yayılım ile hata ağa dağıtılmaktadır.

Verilerin %70 oranı ağın eğitimi için, %30 oranı da test verisi olarak kullanılmıştır. Modelin özeti Tablo 4.5'te gösterilmiştir.

Tablo 4.5. Yapay sinir ağı modeli

Parametre	Değer
Modeli Mimarisi	8-18-1
İterasyon Sayısı	1317
Verinin Gruplandırılması	%70 Eğitim %30 Test Verisi
Hata Fonksiyonu (Cost Function)	Ortalama Hata Karesi (Mean Square Error)
Öğrenme Algoritması	İleri Beslemeli Geri Yayılım Algoritması (Feed-Forward Backpropagation Network)

4.4.2. Yapay sinir ağı analiz sonuçları

Yapay sinir ağı analizinde yararlanılan veriler ilk aşamada R software yazılımına yüklenmiştir. Sonrasında veriler normalleştirilerek ağa tanıtılmıştır. Öncelikle enflasyonu etkileyen faktörlerin aralarındaki korelasyona bakılmıştır. Değişkenlere ilişkin korelasyon bilgileri aşağıdaki Tablo 4.3'te gösterilmiştir. Sonrasında yapay sinir ağı analizi yapılmıştır.

Verilerin %70'i ağı eğitmek için, %30'u da ağı test etmek amacıyla 70:30 olarak bölünmüştür. Şekil 4.9 ve Şekil 4.10'da gösterilmiştir.

Ağın performans ölçümü ortalama hata kareleri (MSE) olarak esas alınmıştır. Yapay sinir ağı için ortalama hata karesi hesaplanmıştır. Ulaşılan ortalama hata karesine ilişkin sonuç Tablo 4.6'da verilmiştir.

Tablo 4.6. Ortalama hata karesi (MSE)

Ortalama Hata Karesi (MSE)	
Model1	%70-%30
İterasyon Sayısı	632
İleri Beslemeli Geri Yayılım	0,086073
Model2	%70-%30
İterasyon Sayısı	1317
İleri Beslemeli Geri Yayılım	0,008716

Tablo 4.6. incelendiğinde, %70 eğitim ve %30 test verisi için en düşük ortalama hata karesine sahip 2 model görülmektedir. Model1 için iterasyon sayısı 632 iken MSE değeri 0,086073 olarak bulunmuştur.

Model2 için iterasyon sayısı 1317 iken MSE değeri 0,008716 olarak bulunmuştur. İterasyon sayısı arttıkça ağın eğitilmesi artacak ve ortalama hata karesi düşecektir. %70 eğitim ve %30 test verisi için en iyi model, 1317 iterasyon sayısına sahip olan Model2'dir.

5. SONUÇ

Geçmişten günümüze bilgisayarlar ile yapılan çalışmalar insan beynini modelleyerek, yapay zekâ kavramını hayatımızın bir parçası konumuna getirmiştir. Tarihsel süreç içerisinde yapay zekâ kavramı geliştirilerek yapay sinir ağları kavramını ortaya atılmıştır. Bu yeni kavram ile ilgili çalışmalara yoğunluk verilmiştir.

Enflasyon bütün ülkeler için önem ve risk taşıyan bir konudur. Bireyler her zaman mevcut paraları ile ileriye yönelik plan yaptıklarından hem hayatı kolaylaştıran hem de ekonomik büyümeyi istikrarlı hale getirmek için enflasyon her zaman önem arz eden bir konu olmuştur.

Çalışmada enflasyonu etkileyen faktörler ele alınarak bir yapay sinir ağı modeli olan ileri beslemeli geri yayılım ağı ile bir analiz yapılmak istenmiştir. Enflasyon değişkeni bağımlı değişken olarak alınmış ve üzerinde etkisi olduğu düşünülen bağımsız değişkenler; gayri safi milli hasıla (GSMH), işsizlik (ISS), nüfus artışı (NA), özel sektörlere verilen yurtiçi krediler (OSVYK), para arzı (PA), ücretli ve maaşlı çalışanlar (UMC) ve eğitim ve devlet harcamaları (EDH) olarak belirlenmiştir. Çalışma ülkelerin tamamı baz alınarak düzenlenmiştir. Ayrıca yapılan analizde kayıp gözlemlerin bulunmaması istendiğinden ve uygulanacak olan yöntemin sağlıklı sonuçlar vermesine imkân sağlamasından dolayı, en fazla gözlemin elde edildiği 2017 yılı verileri esas alınmıştır. 2017 yılına ait 91 ülkeye ait veriler derlenmiştir. Veriler Dünya Bankası (World Bank Group) web sitesinden oluşturulmuştur. Öncelikli olarak değişkenler arasındaki ilişkileri görebilmek için korelasyon analizi yapılmış ve enflasyon ile ilişkisinin en yüksek olduğu değişken para arzı (PA) olarak saptanmıştır.

Bu alıřmada, yapay sinir aęları modeli olan ileri beslemeli geri yayılım ile enflasyonu etkileyen faktörler analiz edilmiřtir. Son yıllarda saęladıęı olanaklar ile oldukça popöler hale gelen ve esnek bir modelleme olanaęı saęlayan yapay sinir aęı modeli uygulanmıřtır. Yapay sinir aęları uygulamada kolaylık saęlamasının yanında oldukça başarılı sonuçlar vermektedir.

Yapay sinir aęları modeli olan ileri beslemeli geri yayılım aęı giriş deęerleri aęırlık katsayıları ile arpılarak gizli katman ile ıkıřa aktarılmaktadır. Fakat geri yayılım ile modelin aęırlık katsayıları güncellenerek uygun hale getirilecektir.

Analizi iin verilerin %70 oranı eęitilmesi, %30 oranı ise test edilmesi iin kullanılmıřtır. Aęı eęitip alıřtırdıęımızda ulařtıęımız ortalama hata karesi 0,086073 olmuřtur. Aęı tekrar eęiterek alıřtırdıęımızda ulařtıęımız ortalama hata karesi 0,008717 olmuřtur. Her iki sonuca baktıęımızda; aęı ne kadar eęitirsek o kadar iyi bir sonuç alabiliriz.

alıřmada, aęın eęitimi iin gerekli olan iterasyon sayısı arttıķa MSE deęerinin düřtüęü görölmektedir. Yapay sinir aęları analizinde eęitim grubu ve veri sayısı arttıķa, MSE deęerinin daha iyi sonuç verdięi görölmektedir. Sonuç olarak yapay sinir aęları modelinin başarılı bir sonuç verdięi görölmektedir.

KAYNAKLAR

- Addison, P.D., 1999. Multiple Regression: A Primer. Pine Forge Press. Inc. London.
- Alpar, R., 2003. Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş I. Nobel Yayın Dağıtım, 408 s, Ankara.
- Ağyar, Z., 2015. Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama. Mühendis ve Makine, 56(662), 22-23.
- Akkaya, G. C., Demireli, E., Yakut, Ü. H., 2009. İşletmelerde Finansal Başarısızlık Tahminlemesi: Yapay Sinir Ağları Modeli ile İMKB Üzerine Bir Uygulama. Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi, 10(2), 187.
- Akkol, S., Akıllı, A., Cemal, İ., 2017. Comparison of Artificial Neural Network and Multiple Linear Regression for Prediction of Live Weight in Hair Goats. Yüzüncü Yıl Üniversitesi, Tarım Bilimleri Dergisi, 27(1): 21-29, Araştırma Makalesi/Research Article (Original Paper).
- Aktaş, R., Doğanay, M., Yıldız, B., 2013. Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırılması. Ankara Üniversitesi SBF Dergisi: 58-4.
- Anderson, D., McNeill, G., 1992. Artificial Neural Networks Technology. Kaman Sciences Corporation, New York.
- Aydoğan, E., 2004. 1980'den Günümüze Türkiye'de Enflasyon Serüveni. Yönetim ve Ekonomi Dergisi, Cilt:11, Sayı:1, Yıl:2004, s92.(91-110).
- Baş, N., 2006. Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama. T.C. Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Büyük Larousse, 24. cilt, sayfa 12726.
- Diler, A. İ., 2003. İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi. İMKB Dergisi, Cilt:7, Sayı: 25,26. Ocak-Haziran 2003.
- Elmas, Ç., 2018. Yapay Zekâ Uygulamaları: Yapay Sinir Ağları, Makine Öğrenmesi, Derin Öğrenme, Derin Ağlar, Bulanık Mantık, Sinirsel Bulanık Mantık, Genetik Algoritma. Seçkin Yayıncılık, 4. Baskı, Ankara.

- Elmas, Ç., 2011. Yapay Zekâ Uygulamaları: Yapay Sinir Ağı, Bulanık Mantık, Genetik Algoritma. Seçkin Yayıncılık.
- ERDOĞAN, E., ÖZYÜREK, H., 2012. Yapay Sinir Ağları ile Fiyat Tahminlenmesi, Sosyal ve Beşerî Bilimler Dergisi, Cilt 4, No 1, ISSN: 1309-8012.
- Erilli, N. A., Eğrioğlu, E., Yolcu, U., Aladağ, Ç. H., Uslu, V. R., 2010. Türkiye’de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı ile Öngörüsü. Doğu Üniversitesi Dergisi, Cilt 11, No 1, 2010, 42-55.
- Erol, İ., 2002. Para-Banka Teori ve Politika. Orient Yayınları, 4. Baskı, Manisa.
- Freeman, J. A., Skapura, D.M., 1991. Neural Networks: Algorithm, Applications and Programming Techniques. Addison- Wesley Publishing Company.
- Gabralı, D., Aslan, Z. 2020. Güneş Enerjisi Potansiyelinin Çoklu Lineer Regresyon ve Yapay Sinir Ağları ile Modellenmesi. Aurum Mühendislik Sistemleri ve Mimarlık Dergisi, Cilt 4, Sayı 1. 23-36.
- Groß, J., 2003. Linear regression, Springer-Verlag, Berlin Heidelberg, 394 p.
- Gujarati, D. N., Porter, D. C., 2012. Temel Ekonometri. Literatür Yayıncılık, İstanbul.
- Hebb, D. O., 1949. The Organization of Behavior: A Neuropsychological Theory. NY: Wiley, Xix, 335 pp.
- Hecht-Nielsen, R., 1990. Neurocomputing. Addison-Wesley, Reading, MA, Boston.
- Jain, A.K., Mao, J., 1996. "Artificial Neural Networks: A Tutorial", IEEE Computer Special Issue on Neural Computing. Vol: 29, No:3.
- Jansen, D.W., 1989. Does inflation uncertainty affect output growth? Further evidence. Federal Reserve Bank of St. Louis Review, July, pp.43-54
- Karakul, A., 2018. "Türkiye’de Kentlere İlişkin Bazı Göstergelerin Öğrenci Başarısına Etkisinin Çok Değişkenli Doğrusal

- Regresyon ile Modellenmesi", ÇOMU Uluslararası Sosyal Bilimle Dergisi, 3 (1):53-77.
- Kılıç, S., 2013. Doğrusal Regresyon Analizi. Journal of Mood Disorders, Journal of Mood Disorders 2013; 3 (2): 90- 2.
- Kocatepe, C. İ., Yıldız, O., 2016. Ekonomik Endeksler Kullanılarak Türkiye'deki Altın Fiyatındaki Değişim Yönünün Yapay Sinir Ağları ile Tahmini. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 4, 926-934.
- Koutsoyiannis, A., 1989. Ekonometri Kuramı: Ekonometri Yöntemlerinin Tanıtımına Giriş ve Teori. Verso Yayıncılık, Ankara.
- Köksal, B. A., 1985. İstatistik Analitik Metodları. Çağlayan Kitapevi, İstanbul.
- Kutlu, B., Badur, B., 2009. Yapay Sinir Ağları ile Borsa Endeksi Tahmini. İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü: Yönetim Dergisi, Cilt: 20, Sayı: 63.
- Kwon, S. J., 2011. Artificial Neural Networks. Nova Science Publishers, Inc. New York.
- Leondes, C. T., 2007. Biomechanical Systems Technology. A 4-Volume Set, World Scientific, pp. 220.
- MCNeils, P. D., 2005. Neural Networks in Finance: Gaining Predictive Edge in the Market, California.
- Minsky, M.L., Papert, S.S., 1969. Perceptrons, MA: MIT Press, Cambridge.
- Niazian, M., Sadat-Noorin, SA, Abdipour, M., 2018. Artificial neural network and multiple regression analysis models to predict essential oil content of ajowan (Carum copticum L.), Volume 9, May 2018, Pages 124-131.
- Özatay, F., 2011. Parasal İktisat: Kuram ve Politika. Efil Yayınevi, Ankara.
- Özdemir, H., 2010. İktisata Giriş. Data Yayınları, Ankara, 2-3.
- Öztemel, E., 2006. Yapay Sinir Ağları. Papatya Yayıncılık.

- Rumelhart, D. E., Hilton, D. E., Williams, R. J., 1986. Learning Representation by Backpropagating Errors. Nature 323(9), pp. 533-536.
- Schwartz, Leon V., 2009. Inflation: Causes and Effects. Nova Science Publishers, Inc. New York.
- Serttaş, Z. S., 2011. Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması. T.C. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Sönmez, F., Zontul, M., Bülbül, Ş., 2015. Mevduat Bankalarının Karlılığının Yapay Sinir Ağları ile Tahmini: Bir Yazılım Tasarımı. BDDK Bankacılık ve Finansal Piyasalar Dergisi, Cilt:9, Sayı:1.
- Tabachnick, B.G., Fidell, L. S., 2015. Çok Değişkenli İstatistik Kullanımı. Nobel.
- Takma, Ç., Atıl, H., Aksakal, V., 2012. Çoklu Doğrusal Regresyon ve Yapay Sinir Ağı Modellerinin Laktasyon Süt Verimlerine Uyum Yeteneklerinin Karşılaştırılması. Kafkas Üniversitesi Veteriner Fakültesi Dergisi, 18 (6): 941-944.
- TCMB., 2013. Enflasyon ve Fiyat İstikrarı. Türkiye Cumhuriyet Merkez Bankası Yayınları, 6s., Ankara.
- Tektaş, A., Karataş, A., 2004. Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi. Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, Yıl: 2004, Cilt: 18, Sayı: 3-4.
- Tolon, M., Güneri Tosunoğlu, N., 2008. Tüketici Tatmini Verilerinin Analizi: Yapay Sinir Ağları ve Regresyon Analizi Karşılaştırması. Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 10 / 2 (2008). 247-259.
- Türköz, M., Tosun, H., 2008. Harran Kili Şişme Potansiyelinin Belirlenmesinde Yapay Sinir Ağları ve Çoklu Regresyon Modellerinin Kullanımı. Eskişehir Osmangazi Üniversitesi Müh. Mim. Fak. Dergisi C.XXI, S.1.
- Uygunoğlu, T., Yurtcu, S., 2006. Yapay zekâ tekniklerinin inşaat mühendisliği problemlerinde kullanımı. Yapı Teknolojileri Elektronik Dergisi, (1):61-70.

- Ünver, Ö., Gamgam, H., 1999. Uygulamalı İstatistik Yöntemleri. Siyasal Kitapevi, Ankara.
- Yaffee, R.A., 2002. Robust regression analysis: some popular statistical package options, (<http://www.nyu.edu/its/socsci/Docs/RobustReg2.pdf>) (08.03.2010).
- Yakut, E., Elmas, B., Yavuz, S., 2014. Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, Y.2014, C.19, S.1, s.139-157.
- Yücedağ, N., 2019. İvesi Koyunlarında Laktasyon Süt Verimlerinin Çoklu Doğrusal Regresyon ve Yapay Sinir Ağı Modelleriyle Karşılaştırılmalı İncelenmesi. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Yıldız, Ö., 2006. Döviz Kuru Tahmininde Yapay Sinir Ağlarının Kullanımı, Yüksek Lisans Tezi, Osmangazi Üniversitesi, Sosyal Bilimler Enstitüsü: Eskişehir.
- Yılmaz, Ş.H., Özcan, B., 2020. Yapay Sinir Ağı ve Regresyon ile Satın Alma Gücü Paritesine Göre Kişi Başı Gayrisafi Yurt İçi Hasıla Tahmini. USBAD Uluslararası Sosyal Bilimler Akademik Dergisi, Cilt 2, Sayı 3, s. 69.
- Zorlu, K., 2013. Örgütsel Adalet ve Güven Arasındaki İlişkiler Kullanılarak Yapay Sinir Ağları ve Çoklu Doğrusal Regresyon Yöntemlerinin Karşılaştırılması. Kırşehir Ahi Evran Üniversitesi, Kurumsal Akademik Arşiv.
- Widrow, B., Hoff, M. E., 1960. 'Adaptive Switching Circuitst', WEST-CON Conversion, Record Part IV, pp. 96-104.
- World Bank Group, 2020. data.worldbank.org, (Erişim Tarihi: 14.11.2020).

EKLER

EK A. Yapay Sinir Ağları Kodları

```
> library('neuralnet')
> library(MASS)
> library("neuralnet", lib.loc="/Library/Frameworks/R.framework/
Versions/3.5/Resources/library")
> library(readxl)
> data <- read_excel("~/Desktop/data/data.xlsx")
> View(data)
> set.seed(1)
> max_data=apply(data,2,max)
> min_data=apply(data,2,min)
> data_scaled=scale(data,center = min_data,scale = max_data -
min_data)
> View(data_scaled)
> index = sample(1:nrow(data),round(0.70*nrow(data)))
> train_data=as.data.frame(data_scaled[index,])
> test_data=as.data.frame(data_scaled[-index,])
> n=names(data)
> f = as.formula(paste("Enflasyon ~", paste(n[!n %in%
"Enflasyon"], collapse = "+")))
> names(train_data) <- make.names(names(train_data))
> net_data = neuralnet(f,data=train_data, hidden=c(9,9),linear.
output=T)
> plot(net_data)
> predict_net_test = compute(net_data,test_data[1:7])
> predict_net_test_start = predict_net_test$net.result*(max
(data$ Enflasyon)-min(data$ Enflasyon))+min(data$ Enflasyon)
> test_start =as.data.frame((test_data$ Enflasyon)*(max(data$
Enflasyon)-min(data$A))+ min(data$ Enflasyon))
> MSE.net_data = sum((test_start - predict_net_test_start)^2)/
nrow(test_start)
```

EK B. Korelasyon Kodları

```
> library('neuralnet')
> library(MASS)
> library("neuralnet",lib.loc="/Library/Frameworks/R.framework/
Versions/3.5/Resources/library")
> library(readxl)
> data <- read_excel("~/Desktop/data/data.xlsx")
> View(data)
> summary(data)
> dataShort <- data[1:8]
> cor(dataShort)
> library(corrplot)
> forcorrplot <- cor(dataShort)
> corrplot(forcrrplot)
> corrplot(forcrrplot, method = "color")
> corrplot(forcrrplot, method = "color", order = "hclust")
> corrplot.mixed(forcrrplot, upper = "number", lower = "color",
order = "hclust")
```

EK C. Veri Seti

ÜLKELER	Enflasyon	GSMH	ISS	NA	OSVYK	PA	UMC	EDH
Afghanistan	4,975951506	23218748182	11,18400002	2,548346644	3,590379919	34,44821047	17,54999924	4,058869839
Albania	1,986661332	15597826697	13,75	-0,091972294	34,75782654	81,58551239	42,80699921	3,611720085
Armenia	0,969553269	13757842257	17,70499992	0,294612228	51,54258581	46,37868298	59,6609993	2,707590103
Australia	1,948647409	1,47376E+12	5,59100008	1,684523108	140,1927534	116,8426506	83,10099792	5,124249935
Azerbaijan	12,93998411	63079943899	5	0,981261805	22,09960381	32,46886431	31,62400055	2,473819971
Burundi	16,0525353	3398464408	1,486999989	3,181367524	15,46373354	27,33703208	5,342000008	4,762020111
Benin	1,769412474	13604232725	2,459000111	2,750055592	16,57791951	39,23159856	10,66100025	3,535589933
Burkina Faso	1,482998972	14664788494	6,21600008	2,890850806	27,29978342	46,93549956	12,59300041	5,603469849
Bulgaria	2,064355063	57440100393	6,164000034	-0,730443175	49,98645169	84,84275429	88,10099792	4,09250021
Belarus	6,031837252	79934956964	5,650000095	-0,034421419	26,2361144	37,87920492	95,6309967	4,794990063
Brazil	3,44637335	2,52136E+12	12,82199955	0,807147162	59,50382094	93,50881082	67,69599915	6,32254982
Bhutan	4,95508367	2353445265	2,35800004	1,195337374	51,29828135	68,56227254	27,80800056	7,225739956
Central Europe and the Baltics	2,075935537	1,42793E+12	5,293337874	-0,2481934	46,62682964	65,43381055	81,61408035	4,09250021
Chile	2,182718469	2,58069E+11	6,958000183	1,425185044	113,1637907	78,5179545	72,56800079	5,41945982
Cote d'Ivoire	0,685881065	33629287101	3,273000002	2,54780739	19,59538193	38,71147267	26,60199928	3,80347991
Cameroon	0,642673522	36804974833	3,414000034	2,637694363	14,50091677	20,51629538	23,04199992	3,154819965
Congo, Rep.	0,450063823	13808176608	9,762999535	2,570629914	20,67489348	33,24542942	22,4809996	5,46505022
Colombia	4,312141032	3,97187E+11	8,871999741	1,503387796	49,8054214	48,62284832	48,90499878	4,535510063
Cabo Verde	0,784415251	2237907270	12,23999977	1,188624222	62,5315654	104,4536536	60,42300034	5,181749821
Costa Rica	1,625707485	51860188359	4,812000198	1,02767609	61,76236451	88,76507398	75,68800354	7,315720081
Czech Republic	2,450533985	1,94592E+11	2,890000105	0,265642664	51,54692629	83,74615411	67,259799725	3,854020119
Djibouti	0,568112117	1829753094	10,38199997	1,599962382	21,25844548	113,0338186	52,30799866	3,748559952
Europe & Central Asia (excluding high income)	3,175309864	3,72669E+12	7,419552779	0,615781816	53,48602879	54,56688158	79,25781596	4,09250021
Fragile and conflict affected situations	2,278115309	2,11822E+12	7,010501493	2,218654078	19,0370138	63,54360733	27,46311916	3,787309885
United Kingdom	2,557755776	3,10652E+12	4,335000038	0,679374474	133,9656422	147,6155441	84,20090014	5,442090024
Georgia	6,035317253	20607124653	13,93900013	0,013386075	58,0573195	48,66030056	48,36299896	3,574429989
Ghana	12,37192155	60214532694	4,22300005	2,22053243	13,85756576	26,09745965	25,06900024	3,617980024
Guatemala	4,424536552	64560127241	2,461999893	1,6276538	35,18815461	48,13986422	59,54299927	2,951819897
Guyana	1,904656155	3701876781	12,04399967	0,49851809	45,50155343	62,01407316	67,15499878	6,230070114
Heavily indebted poor countries (HIPC)	5,318716052	7,33144E+11	4,474979094	2,805975711	20,38259924	33,67541226	19,22000187	3,787309885
Croatia	1,129372103	57862287325	11,20800018	-1,200610165	57,24839395	71,3816191	87,62999725	3,917129993
Haiti	10,68008872	11779252551	13,73499966	1,305066708	17,63625898	50,8683271	26,6420002	2,689450026
Hungary	2,348242812	1,31639E+11	4,156000137	-0,265860932	32,80848022	59,76193786	89,66500092	4,667099953
IBRD only	3,316087622	2,74816E+13	5,825838453	0,924225418	99,59165197	128,1336104	50,12590056	4,307660103
IDA & IBRD total	3,347578348	2,96728E+13	5,583298493	1,259617885	94,8518305	124,3223091	45,26757451	4,088590145
IDA total	3,627096107	2,21698E+12	4,721280509	2,267379098	23,7109295	47,27970473	28,20069348	4,031330109
IDA only	4,447699374	1,15903E+12	4,433094781	2,250677717	29,86066095	45,92545775	25,36811666	3,80347991
Iceland	1,760415592	16684005160	2,742000103	2,345582676	87,67602973	65,95373181	88,08300018	7,658219814
Israel	0,244210526	3,04729E+11	4,215000153	1,938725674	65,59641813	85,61278684	87,5739975	6,092619896
Jordan	3,323894476	45287042254	15,11499977	2,356016488	76,13894351	112,1691672	84,96499634	3,284049988
Japan	0,467211747	4,96998E+12	2,799999952	-0,164484036	168,6888598	247,2370636	89,58100128	3,182179928
Kazakhstan	7,440004373	1,8812E+11	4,900000095	1,360381269	29,18759774	36,63945932	75,56500244	2,750819921
Kenya	8,005722791	71414190045	2,694999933	2,356812573	34,43976195	36,73375816	47,93799973	5,366680145
Latin America & Caribbean (excluding high income)	3,279556947	6,06047E+12	8,153010263	0,969199356	44,87635255	67,7633485	62,17949755	4,522819996
Latin America & Caribbean	2,312249	6,58334E+12	8,088009058	0,964288762	48,74914335	63,35920962	62,71222753	4,355510063
Least developed countries: UN classification	5,147333779	1,02494E+12	4,428566571	2,371929065	28,78004156	45,38831371	24,08201385	3,909319997
Lower middle income	3,627096107	5,39405E+12	5,220624545	1,463794545	43,92999833	67,08573114	33,09495997	4,430510044
Low & middle income	3,61478676	2,8575E+13	5,567007236	1,269967525	96,22070053	128,4398323	44,63294524	4,073729992
Lesotho	4,447699374	3691090389	24,13400078	0,787780034	19,18425944	35,21423054	83,10700226	7,963319778
Late-demographic dividend	2,177275727	1,90917E+13	5,260606921	0,624215079	120,705072	157,7290236	56,82107516	4,535510063
Moldova	6,570229975	12441067144	4,09800005	-1,691932579	22,76205343	51,24452513	65,18199921	5,618440151
Mexico	6,04145724	1,3142E+12	3,420000076	1,163967779	35,32163327	38,79465746	68,55000305	4,522819996
Middle income	3,316087622	2,80105E+13	5,625645368	1,123943912	97,00580937	129,2861172	47,17675217	73,69499969
Mali	1,759857429	16595396549	7,329999924	2,999115367	25,93138324	26,73351126	18,61100006	3,787309885
Myanmar	4,572536553	64880388350	1,550999999	0,633962381	23,64478346	52,7818002	32,76699829	2,087680101
Mongolia	4,310762541	12816360255	6,359000206	1,861276285	53,07239832	56,85929569	49,89899826	4,088590145
Mozambique	15,11320739	26378735082	3,308000088	2,900629142	24,54250464	47,9631971	14,22000027	5,505559945
Mauritius	3,666997027	13963933955	6,75199855	0,090186811	102,3740881	114,1301989	79,39600372	5,02312994
Malaysia	3,871201158	3,06708E+11	3,410000086	1,360192981	117,2241027	124,2480101	74,49299826	4,677569866
Niger	2,796373189	12320197409	4,086999989	3,839154453	11,43023449	24,33985425	55,15999794	2,581650019
Nicaragua	3,850671663	13862336232	3,299999952	1,274855157	42,71406233	41,92973686	54,57600021	4,57679844
Norway	1,875100596	4,5191E+11	4,162000179	0,807673182	146,4868716	65,00752473	93,47699738	7,911980152
Nepal	3,627096107	25852846247	1,396000028	1,333612899	78,87854105	104,1067648	19,95199966	5,18370152
New Zealand	1,850787675	1,9919E+11	4,702000141	2,122962382	154,0737432	101,8422315	81,43800354	6,283669949
Other small states	2,516080911	3,51171E+11	9,560610403	2,050988328	72,71477158	79,56624557	69,12815554	5,02312994
Pakistan	4,08537368	2,60039E+11	3,944999933	2,074997082	17,0554493	57,1820957	40,82799911	2,89951992
Peru	2,80283917	2,04081E+11	3,460000038	1,661934247	42,41461431	47,48923667	44,90399933	3,931309938
Poland	2,075935537	5,37531E+11	4,887000084	0,012480099	52,47098174	66,59035714	79,58499908	4,559569836
Qatar	0,394878914	1,30001E+11	0,140000001	2,615829323	77,2851022	99,29431289	99,58200073	2,86383009
Romania	1,339021211	2,00505E+11	4,927000046	-0,585281876	26,47339333	40,75771748	73,69499969	3,095390081
Russian Federation	3,683329444	1,93942E+12	5,211999893	0,106871954	52,07659751	59,36315299	93,38500214	4,689909935
Rwanda	8,274372533	9035751678	1,062999964	2,63966475	20,59200555	19,96860777	31,38699913	3,110830069
South Asia	4,520228675	2,68101E+12	5,12543454	1,223397434	45,69103298	71,8296207	26,80222884	3,47919488
Senegal	1,318153148	22744261199	6,614999771	2,800658333	29,6647848	37,56826078	33,97000122	4,624969959
Sierra Leone	18,2198092	6101727690	4,5	2,154231955	51,16521033	23,61900673	11,06299973	4,635769844
El Salvador	1,012354033	26885920000	4,385000229	0,501858163	51,37378523	53,54856473	59,75999832	3,725229979
Serbia	3,131062486	50863119066	13,47700024	-0,532191341	40,33871674	50,96560782	69,42700195	3,715090036
Small states	1,904656155	4,35402E+11	9,238747021	1,74819898	68,94503386	78,12174187	67,84733884	5,141875029
Sweden	1,794499047	5,6102E+11	6,717999935	1,34744506	131,2817426	73,43320885	90,14199829	7,568830013
Chad	-1,53709963	15098381201	1,848000005	3,077531708	9,76154408	15,79705882	6,702000141	2,454819918
Europe & Central Asia (IDA & IBRD countries)	2,755649238	4,52294E+12	7,125450737	0,496829472	51,92164603	56,49400472	79,11145154	4,004815102
Togo	-0,981889869	5400173324	2,125999928	2,479318302	39,2789314	57,0025791	16,95000766	4,989759922
Latin America & the Caribbean (IDA & IBRD countries)	2,80283917	6,38548E+12	8,185221544	1,00079934	48,71227928	63,37367429	62,41526684	4,535510063
Timor-Leste	0,557215537	2512573501	4,565999985	1,947068453	16,12849623	27,85115249	30,90699959	7,060490131
South Asia (IDA & IBRD)	4,520228675	2,68101E+12	5,12543454	1,223397434	45,69103298	71,8296207	26,80222884	3,47919488
Uganda	5,640931922	33418660298	1,789999962	3,749875169	13,4819167	23,32870646	21,26099996	2,272049904
Ukraine	14,43832275	1,38184E+11	9,510000229	-0,386347533	38,27106413	50,52603868	84,28800201	5,412260056
Upper middle income	3,279556947	2,26167E+13	5,926728761	0,784727051	110,56392			

ÖZGEÇMİŞ

Adı Soyadı : Selin SABAK

Doğum Yeri ve Yılı : PENDİK, 18/03/1991

Medeni Hali : Bekar

Yabancı Dili : İngilizce

E-posta : selinsabakk@gmail.com



Eğitim Durumu

Lise : Tuğrulbey Lisesi, 2009

Lisans : Munzur Üniversitesi,
İdari ve İktisadi Bilimler Fakültesi, İktisat Bölümü, 2014

Mesleki Deneyim

Yapı Kredi Bankası 2015-...(devam ediyor)

Yayınları

Sabak, S., Erişlik, K., (2020). Ülkelerin Mutluluk Düzeylerine Göre Gruplandırılması, 3. Uluslararası İstatistik Matematik ve Analitik Yöntemler Kongresi, 12-13 Mart, 75.

Sabak, S., Deniz Başar, Ö., (2020). Enflasyonu Etkileyen Faktörlerin Ülkeler Bazında Yapay Sinir Ağları Analizi ile İncelenmesi, İstanbul Ticaret Üniversitesi Dış Ticaret Enstitüsü Working Paper Series Dergisi, Yayınlanan.