



**ULUSLARARASI İKTİSATTA YAPAY SINIR  
AĞLARI YÖNTEMİNİN KULLANIMI: TÜRKİYE  
ALMANYA DIŞ TİCARET ÖRNEĞİ**

**2023  
DOKTORA TEZİ  
İKTİSAT**

**Şeyma Nur ÜNAL**

**Tez Danışmanı  
Prof. Dr. Hüseyin KARAMELİKLİ**

**ULUSLARARASI İKTİSATTA YAPAY SİNİR AĞLARI YÖNTEMİNİN  
KULLANIMI: TÜRKİYE ALMANYA DIŞ TİCARET ÖRNEĞİ**

**Şeyma Nur ÜNAL**

**Tez Danışmanı**

**Prof. Dr. Hüseyin KARAMELİKLİ**

**T.C.**

**Karabük Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**İktisat Anabilim Dalında**

**Doktora Tezi**

**Olarak Hazırlanmıştır**

**KARABÜK**

**Haziran 2023**

## İÇİNDEKİLER

İÇİNDEKİLER.....	1
TEZ ONAY SAYFASI.....	4
DOĞRULUK BEYANI .....	5
ÖNSÖZ .....	6
ÖZ.....	7
ABSTRACT.....	8
ARŞİV KAYIT BİLGİLERİ.....	9
ARCHIVE RECORD INFORMATION .....	10
KISALTMALAR .....	11
ARAŞTIRMANIN KONUSU .....	12
ARAŞTIRMANIN AMACI VE ÖNEMİ.....	12
ARAŞTIRMANIN YÖNTEMİ.....	12
KAPSAM VE SINIRLILIKLAR/KARŞILAŞILAN GÜÇLÜKLER .....	12
GİRİŞ.....	13
1. DIŞ TİCARET POLİTİKASI .....	14
1.1. Dış Ticaret Politikası ve Dış Ticaret Politikasının Amaç ve Araçları....	14
1.1.1. Dış Ticaret ve Dış Ticaret Politikası .....	14
1.1.2. Dış Ticaret Politikasının Amaçları .....	15
1.1.3. Dış Ticaret Politikası Araçları .....	15
1.1.4. Almanya Dış Ticaret Stratejileri.....	16
1.1.5. Türkiye Dış Ticaret Stratejileri .....	18
1.2. Türkiye Almanya Dış Ticareti .....	20
1.2.1. Türkiye Almanya Dış Ticaretinin Tarihsel Gelişimi .....	20
1.2.2. Türkiye Almanya Dış Ticaretinin Sektörel ve Mal Grubuna Göre Dağılımı .....	22

1.2.3.	Türkiye Almanya İthalat ve İhracat İlişkisi .....	26
1.2.4.	Türkiye- Almanya Milli Gelir İlişkisi.....	28
2.	ZAMAN SERİSİ, MAKİNE ÖĞRENİMİ VE YAPAY SİNİR AĞLARI....	30
2.1.	Zaman Serisi Tahmin Yöntemleri.....	30
2.1.1.	Naive Modeli .....	32
2.1.2.	Mean Modeli .....	33
2.1.3.	Drift Modeli .....	33
2.1.4.	ARIMA Modeli.....	33
2.2.	Makine Öğrenimi.....	34
2.2.1.	Öğrenme Algoritmaları .....	37
2.2.2.	Denetimli Öğrenme .....	38
2.2.3.	Denetimsiz Öğrenme .....	39
2.2.4.	Pekiştirmeli Öğrenme .....	40
2.3.	Yapay Sinir Ağları (Ann).....	42
2.3.1.	İleri Beslemeli Sinir Ağı.....	44
2.3.2.	Geri Yayılım Ağı .....	46
2.3.3.	Evrişimli Sinir Ağı (CNN) .....	48
2.3.4.	Yinelemeli Sinir Ağı (RNN).....	49
2.3.5.	Uzun Kısa Süreli Bellek (LSTM).....	51
2.3.6.	Kapı Özyinelemeli Geçit (Gru) .....	54
2.3.7.	NARX Sinir Ağı.....	55
2.3.8.	Aktivasyon Fonksiyonları.....	56
2.3.8.1	Sigmoid Fonksiyonu .....	57
2.3.8.2	Tanh Fonksiyonu .....	58
2.3.8.3	RELU Fonksiyonu .....	59
2.4.	Yapay Sinir Ağlarında Öğrenme ve Öğrenme Kuralları.....	60
2.4.1.	Hebb Kuralı .....	60
2.4.2.	Delta Kuralı .....	61
2.4.3.	Hopfield Kuralı.....	62
2.4.4.	Kohonen Kuralı.....	63
2.4.5.	Dereceli Azaltma (Gradient Descent) Kuralı .....	65
2.4.6.	Levenberg-Marquardt Öğrenme Algoritması.....	67

<b>3. ZAMAN SERİSİ VE YAPAY SİNİR AĞLARI İLE DIŞ TİCARET ANALİZİ</b> .....	<b>70</b>
<b>3.1. Model</b> .....	<b>70</b>
<b>3.2. Literatür</b> .....	<b>70</b>
<b>3.3. Performans Ölçümleri ve Seçim Kriterleri</b> .....	<b>75</b>
<b>3.3.1. MAE: Ortalama Mutlak Hata</b> .....	<b>75</b>
<b>3.3.2. MSE (Mean Squared Error) Ortalama Kare Hata</b> .....	<b>76</b>
<b>3.3.3. SE: Standart Hata (Standard Error) veya RMSE: Hata Karesinin Ortalamasının Kökü (Root Mean Square Error)</b> .....	<b>76</b>
<b>3.4. Uygulama</b> .....	<b>76</b>
<b>4. SONUÇ</b> .....	<b>90</b>
<b>KAYNAKÇA</b> .....	<b>93</b>
<b>TABLolar LİSTESİ</b> .....	<b>104</b>
<b>ŞEKİLLER LİSTESİ</b> .....	<b>105</b>
<b>EKLER</b> .....	<b>107</b>
<b>ÖZGEÇMİŞ</b> .....	<b>125</b>

## TEZ ONAY SAYFASI

Şeyma Nur ÜNAL tarafından hazırlanan “ULUSLARARASI İKTİSATTA YAPAY SİNİR AĞLARI YÖNTEMİNİN KULLANIMI: TÜRKİYE ALMANYA DIŞ TİCARET ÖRNEĞİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Prof. Dr. Hüseyin KARAMELİKLİ .....

Tez Danışmanı, İktisat Ana Bilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile İktisat Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 08/06/2023

Unvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Prof. Dr. Hüseyin KARAMELİKLİ (KBÜ) .....

Üye : Dr. Öğr. Üyesi Hüseyin Utku DEMİR (KBÜ) .....

Üye : Dr. Öğr. Üyesi Murat ERGÜL (KBÜ) .....

Üye : Dr. Öğr. Üyesi Ali UYSAL (CBÜ) .....

Üye : Dr. Öğr. Üyesi Muhammed TÜMAY (GŞÜ) .....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Müslüm KUZU .....

Lisansüstü Eğitim Enstitüsü Müdürü

## **DOĐRULUK BEYANI**

Doktora tezi olarak sunduĐum bu alıřmayı bilimsel ahlak ve geleneklere aykırı herhangi bir yola tevessül etmeden yazdıĐımı, arařtırmamı yaparken hangi tür alıntıların intihal kusuru sayılacaĐını bildiĐimi, intihal kusuru sayılabilecek herhangi bir bölüme arařtırmamda yer vermediĐimi, yararlandıĐım eserlerin kaynakada gösterilenlerden olduĐunu ve bu eserlere metin ierisinde uygun řekilde atıf yapıldıĐını beyan ederim.

Enstitü tarafından belli bir zamana baĐlı olmaksızın, tezimle ilgili yaptıĐım bu beyana aykırı bir durumun saptanması durumunda, ortaya ıkacak ahlaki ve hukuki tüm sonuçlara katlanmayı kabul ederim.

**Adı Soyadı:** řeyma Nur ÜNAL

**İmza** :

## ÖNSÖZ

Çalışmada Türkiye ve Almanya Dış Ticaretinin zaman serisi ve yapay sinir ağıları yöntemiyle analiz edilmesi amaçlanmaktadır. Araştırmanın dış ticaret için yol gösterici olduğuna ve uygulanan yöntemlerin sosyal bilimler alanına katkı sağlayacağı düşünülmektedir.

Tez çalışmamın her aşamasında ilgi ve önerileriyle beni yönlendiren, değerli danışman hocam Sayın Prof. Dr. Hüseyin KARAMELİKLİ' ye en içten saygı ve minnetlerimi sunarım. Desteklerini her zaman arkamda hissettiğim ve bana her daim yol gösteren değerli hocam Sayın Dr. Öğr. Üyesi Hüseyin Utku DEMİR 'e ve değerli hocam Sayın Dr. Öğretim Üyesi Ali UYSAL' a teşekkürü bir borç bilirim.

Bana her konuda destek olan, her zaman koşulsuz inanan, beni bugünlere kadar getiren canım aileme ve sevgili eşime en içten teşekkürlerimi sunarım.



## ÖZ

Zaman serisi verilerinin tahmini, bir yandan ekonomik eğilim ve koşullardaki benzeri görülmemiş değişiklikler ve diğer yandan eksik bilgiler nedeniyle zorlu bir iştir. Son yıllardaki piyasa oynaklığı, ekonomik ve finansal zaman serisi tahminleri için ciddi endişeler doğurmuştur. Bu nedenle, çeşitli tahmin yöntemleri kullanılırken tahminlerin doğruluğunun değerlendirilmesi ve daha spesifik olarak, uygulamalarda çeşitli sınırlamalara sahip oldukları için regresyon analizi kullanılarak tahmin yapılması gereklidir. Finansal uygulamalar öncelikle geçmiş verilere dayalı olarak gelecekteki olayları tahmin etmeyi içerir. Sinir ağları, bilgisayarların sınırlı insan yardımı ile akıllı kararlar almasına yardımcı olabilir. Ekonomi alanındaki yapay sinir ağları, uzman sistemlere kıyasla belirsizliği daha iyi ele alma yetenekleri nedeniyle son zamanlarda popülerlik kazanmıştır. Bu tez çalışmasında geleneksel tahmin tekniklerinin ve makine öğrenmesine dayalı algoritmaların performansını araştırmak amacıyla ampirik bir çalışma ve analiz gerçekleştirildi.

Çalışmada Türkiye ile Almanya dış ticaretinin (ithalat ve ihracat) Ocak 2002-2021 Aralık yılları arasındaki 99 fasıl grubu ele alınarak dış ticareti analiz edilmiştir. Bu analiz için Zaman Serisi yöntemleri ve NARX (Nonlinear Autoregressive Exogenous) sinir ağı kullanılmıştır. Tahmindeki hata oranlarında elde edilen minimizasyon açısından Drift, Mean, Naive, ARIMA ve NARX sinir ağı performansının Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Hata (MAE) kullanılarak karşılaştırıldı. Bulgulara göre tüm fasıl grupları için NARX sinir ağının başarılı sonuçlar verdiği görülmektedir. Uygulama sonrası elde edilen hata oranlarındaki azalma tüm fasıl grupları için Drift, Mean, Naive, ARIMA 'ya göre NARX'ın üstünlüğüyle sonuçlanmıştır. Diğer taraftan bölümlere baktığımızda ise Zaman Serisi yöntemlerinin de kendi içinde başarılı olduğu neticesine varılmıştır.

**Anahtar Kelimeler:** Zaman Serisi; Yapay Sinir Ağları; Dış Ticaret

## **ABSTRACT**

Estimating time series is challenging due to unprecedented economic trends and conditions and incomplete information. Market volatility in recent years has caused serious concerns about economic and financial time series forecasting. For this reason, when using various forecasting methods, it is necessary to evaluate the accuracy of the estimates, and, more specifically, it is required to make predictions using regression analysis, as they have various application limitations. Financial practices primarily require predicting future events based on past data. Neural networks can help computers make intelligent decisions with limited human assistance. Artificial Neural Networks in Economics have recently gained popularity due to their ability to handle uncertainty more efficiently than expert systems. This study aims to conduct empirical research and analysis to investigate the performance of traditional prediction techniques and algorithms based on machine learning.

Ninety-nine foreign trade groups were analyzed between Türkiye and Germany (import and export) between January 2002-December 2021. Time Series methods and NARX (Nonlinear Autoregressive Exogenous) neural network were used for this analysis. Regarding the minimization obtained in the error rates in the estimate, Drift, Mean, Naive, ARIMA, and NARX neural network performance was compared using Root Mean Square Error (RMSE) and Mean Absolute Error (MAE). According to the findings, it is indicated that the NARX neural network gives satisfactory results for all groups. The decrease in error rates after the application resulted in the superiority of NARX compared to Drift, Mean, Naive, and ARIMA for all groups. It has been concluded that the Time Series methods are also successful.

**Keywords:** Time Series; Artificial Neural Network; Foreign Trade

## ARŞİV KAYIT BİLGİLERİ

<b>Tezin Adı</b>	Uluslararası İktisatta Yapay Sinir Ağları Yönteminin Kullanımı: Türkiye Almanya Dış Ticaret Örneği
<b>Tezin Yazarı</b>	Şeyma Nur ÜNAL
<b>Tezin Danışmanı</b>	Prof. Dr. Hüseyin KARAMELİKLİ
<b>Tezin Derecesi</b>	Doktora
<b>Tezin Tarihi</b>	08/06/2023
<b>Tezin Alanı</b>	İktisat/ Uluslararası İktisat
<b>Tezin Yeri</b>	KBÜ/LEE
<b>Tezin Sayfa Sayısı</b>	125
<b>Anahtar Kelimeler</b>	Zaman Serisi, Yapay Sinir Ağları, Dış Ticaret

## ARCHIVE RECORD INFORMATION

<b>Name of the Thesis</b>	The Use of Artificial Neural Networks Method on International Economics: An Overview of Foreign Trade Between Türkiye and Germany
<b>Author of the Thesis</b>	Şeyma Nur ÜNAL
<b>Advisor of the Thesis</b>	Prof. Dr. Hüseyin KARAMELİKLİ
<b>Status of Thesis</b>	Ph.D.
<b>Date of the Thesis</b>	08/06/2023
<b>Field of the Thesis</b>	Economy / International Economics
<b>Place of the Thesis</b>	UNIKA/IGP
<b>Total Page Number</b>	125
<b>Kwywords</b>	Time Series, Artificial Neural Network, Foreign Trade

## **KISALTMALAR**

- ANN** : Artificial Neural Network
- GRU** : Gated Recurrent Unit
- LSTM** : Long -Short Term Memory
- IMF** : International Monetary Found
- MAE** : Mean Absolute Error
- NARX** : Non-linear Autoregressive Network with Exogenous Variables  
Doğrusal Olmayan Otoresif Dışsal Model
- RMSE** : Root Mean Square Error
- RNN** : Recurrent Neural Network
- TÜİK** : Türkiye İstatistik Kurumu
- YSA** : Yapay Sinir Ağı

## **ARAŞTIRMANIN KONUSU**

Uluslararası İktisatta Yapay Sinir Ağları Yönteminin Kullanımı: Türkiye Almanya Dış Ticaret Örneği olarak belirlenmiştir.

## **ARAŞTIRMANIN AMACI VE ÖNEMİ**

Türkiye-Almanya arasındaki dış ticaret önemli bir yer tutmaktadır. Bu amaçla çalışmanın, Almanya ile olan dış ticaretimize planlama açısından öngörü oluşturması hedeflenmektedir.

Tez çalışmasında, Türkiye ile Almanya dış ticaretinin (ithalat ve ihracat) 2002-2021 yılları arasındaki 99 fasıl grubu ele alınarak dış ticareti analiz edilecektir. Tez için kullanılacak olan veriler Türkiye İstatistik Kurumu (TÜİK) ve International Monetary Fund (IMF) sitelerinden alınmıştır.

## **ARAŞTIRMANIN YÖNTEMİ**

Yöntem olarak ARIMA, Regresyon, Mean, Drift, Naive ve NARX sinir ağı kullanılacaktır. Yöntemde giriş ve hedef verilerimizi RStudio ve Matlab ortamında eğiterek sonuç elde edilmektedir. Seçilen bağımsız değişken ihracat/ithalat, bağımlı değişkenler Türkiye'nin sanayi üretim endeksi, Almanya'nın sanayi üretim endeksi, reel döviz kuru olarak ele alınacaktır.

## **KAPSAM VE SINIRLILIKLAR/KARŞILAŞILAN GÜÇLÜKLER**

Araştırmanın kapsamını Türkiye ile Almanya dış ticaretinin 2002-2021 yılları arasındaki 99 fasıl grubu oluşturmaktadır. Bu fasıl grubu Eurostat'ın uyumlaştırılmış emtia tanımı ve kodlama sistemine göre ele alınmaktadır. Zaman serisi yöntemlerinin yanı sıra yapay sinir ağı yöntemi uygulanmasının çalışmayı daha ayrıntılı ve özgün kılacağı düşünülmektedir. Araştırmanın sınırı verilerin belirli yıllara ve modellere göre uygulanması olarak ifade edilebilir.

## GİRİŞ

Zaman serisi tahmini, herhangi bir tahmin yaklaşımı arasında en geniş literatüre ve uygulama sayısına sahiptir. Dış ticaret, enerji, turizm ve tarım gibi çeşitli alanlardaki politika düzeyindeki birçok karar, çok değişkenli zaman serisi tahminlerine bağlıdır.

Makine öğrenimi, tahminler ve çıkarım gibi önemli görevleri yerine getirmek, istatistiksel modeller oluşturmak için bilgisayar bilimi ilkelerini kullanan bir çalışma alanıdır. Bu modeller, belirli bir sistemin girdileri ve çıktıları arasındaki matematiksel ilişkiler kümesidir. Öğrenme süreci, modelin belirtilen görevi yerine getirebilmesi için model parametrelerini tahmin etme sürecidir. Makineler için öğrenme süreci, makinelere açıkça programlanmadan öğrenme yeteneği kazandırmaya çalışır. Giderek büyüyen finansal verilerde, yapay zekâ ve makine öğrenimi değişimlere göre hızlıca uyarlanabilmektedir. Bu uygulamalar süreçleri hızlandırabilir ve ham verilerin kullanılma şeklini iyileştirebilir.

Makine öğreniminin 1988'den sonra ekonomideki görünümü istikrarlı bir şekilde artmıştır. Başlangıçta, uzun veri kümelerinin yaygın olarak bulunduğu finansal zaman serilerinin tahmininde uygulanmıştır. O döneme ait makine öğrenimi sistemleri, verimli eğitim için ekonominin diğer alanlarında bulunmayan kapsamlı veri kümeleri gerektiriyordu. Ayrıca, dönemin bilgisayarlarının nispeten düşük işlem gücü nedeniyle eğitim çok zaman almaktaydı. Bugün, uzun veri setleri gerektirmeyen birçok yeni makine öğrenimi mimarisinin kullanımı, ekonomi tahmininde ilginç ve çok umut verici bir yoldur. Bu sadece finansal sorunlar için değil, aynı zamanda veri setlerinin doğası gereği boyut olarak sınırlı olduğu makroekonomi veya mikroekonomi uygulamaları için de geçerlidir (Gogas & Papadimitriou, 2021, s.1) .

Bu çalışmada, Türkiye ile Almanya dış ticaretinin (ithalat ve ihracat) 2002-2021 yılları arasındaki 99 fasıl grubu ele alınarak dış ticaret analizi yapılmıştır. Birinci bölümde dış ticaret politikası ve dış ticaret politikasının amaç ve araçları açıklanarak Almanya ve Türkiye'nin dış ticaretine yer verilmektedir. İkinci bölümde zaman serisi tahmin yöntemleri, makine öğrenimi, yapay sinir ağları, yapay sinir ağlarında öğrenme ve öğrenme kuralları açıklanmıştır. Üçüncü bölümde zaman serisi yöntemleri ve YSA ile yapılan çalışmalar ele alınmıştır. Çalışmalar yıllara göre ele alınıp uygulanan yöntemler hakkında bilgi verilmiştir. Daha sonra uygulama yapılarak zaman serisi ve YSA ile dış ticaret analiz edilmiştir. Tezin dördüncü bölümünde sonuca yer verilmiştir.

# 1. DIŐ TİCARET POLİTİKASI

Bu bölümde, dıő ticaret politikası ve dıő ticaret politikasının amaç ve araçları açıklanmaktadır. Almanya ve Türkiye'nin dıő ticaretine yer verilmektedir.

## 1.1. Dıő Ticaret Politikası ve Dıő Ticaret Politikasının Amaç ve Araçları

Dıő ticaret tarihsel olarak çok eskidir ve ülkeler arasındaki ekonomik ilişkileri yansıtır. Ekonomiler ve bir ülkenin dıő ilişkilerinin bir parçası olan dıő ticaret, gelişmekte olan ve gelişmiş toplumlar için hayati sektörlerdendir. Ayrıca, devlet için yeni pazarlar açarak pazarlama kapasitesinin genişletilmesine yardımcı olmaktadır. Ürünler ve seçenekler tabanını tüketim, yatırım ve genel olarak üretken kaynakların tahsisi alanlarında genişleterek ülkenin refahını artırmaya olanak sağlamaktadır (Frag et al., 2021, s.182).

### 1.1.1. Dıő Ticaret ve Dıő Ticaret Politikası

Uluslararası ticaret, gelişmekte olan bir ekonominin gelişme sürecinde stratejik öneme sahip bir faaliyettir. Tarifeler, teşvikler, kotalar, vergiler, gümrük ve idare, sübvansiyonlar, menşe kuralları, kamu alım rejimleri, yardım ve yatırım, ihracatın teşviki, ticaretin kolaylaştırılması ve çeşitlendirilmesi gibi konuları kapsayan ticaret politikası formülasyonu ve uygulamasıdır. Dıő ticaretin daha hızlı bir ekonomik gelişme hızı elde etmedeki rolü iyi bilinmektedir. Bu nedenle, dıő ticaretin planlaması genel kalkınma stratejisinden ayrılamaz (Vijayasri, 2013, s.112).

Dıő ticaret politikası ülkenin dıő ticaretini belirlenen amaçlar doğrultusunda düzenlemek hedefiyle alınan önlemler bütünü olup, hükümetlerin genel ekonomi politikalarının önemli bir aracıdır. İthalat ve ihracat kalemleri üzerindeki tüm hükümet faaliyetlerini kapsayan bir tür dıő ekonomi politikasıdır. Hükümetlerin; ülkenin doğrudan dıő ticaret akımlarını kısıtlandırmak, teşvik etmek veya bu işlemlerin yapılıő sistemlerini ayarlamak için aldıkları sistemli tedbirlere dıő ticaret politikası denmektedir (Dinçer, 2014, s.9).

Ticaret politikalarındaki ülkeler arası farklılıklar çeşitli şekillerde ifade edilebilir. Bir alternatif altında, ihracatın büyümesinde ülkeler arası farklılıklar ihracat



yöneliminin kapsamını yansıtmak için alınır. Böylece, ceteris paribus, ticaret politikalarındaki farklılıklar farklı ihracat büyüme oranları ile ilişkilendirilecektir (Balassa, 1978, s.182).

### **1.1.2. Dış Ticaret Politikasının Amaçları**

Devletlerin dış ticarete müdahale etmesinin çeşitli amaçları vardır (Çelik, 2015, s188) Bunlar;

- a) Dış Rekabetten Koruma
- b) Dış Ödeme Dengesizliklerini Düzeltme
- c) Ekonomik Büyüme ve Kalkınma
- d) İç piyasa Monopollerinin Kırılması
- e) Enflasyonun Önlenmesi
- f) Gelir Dağılımının Değiştirilmesi
- g) Ekonomik Küreselleştirme
- h) Gelir Sağlama
- i) Dış Piyasalarda Avantajlı Duruma Geçme
- j) Otarşi
- k) Sağlık ve Sosyal Nedenler
- l) Siyasi Nedenler

### **1.1.3. Dış Ticaret Politikası Araçları**

Sanayileşme veya kalkınma stratejilerinin dış ticaretle olan bağlantısını ithal ikamesi ile ihracata yönelik sanayileşme stratejileri olarak ayırmaktayız. Türkiye’de I. Beş Yıllık Kalkınma Planı döneminde 1963 yılından 1980 yılına kadar tüketim mallarından başlayan, ara ve yatırım mallarında yoğunlaşmayı amaçlayan ithal ikameci sanayileşme politikası kullanılarak devlet korumacılığı üzerine kurulmuştur. O zamanın dış ticaret politikasının tabanı, tarım ve imalat sanayiini ilerletme hedefine göre düzenlenmiştir. 1970’li yıllara baktığımız zaman ekonomi birtakım hizmetlerle

(bankacılık ve müteahhitlik) fiilen dış dünyaya açılarak sınırlarını genişletti. 1973'ten itibaren dünyada düşen tarım ürünleri fiyatları bir yandan, krizden şiddetli bir şekilde etkilenen imalat sanayii ve büyük holdingler diğer yandan, Türkiye'nin yeni bir dış ticaret politikasına yönelmesi gerektiğini işaret etmektedir (Kazgan, 2006, s.120) .

1960 sonrası planlamasına egemen olan ithal ikameci ve devletin denetiminde (ancak özel birikimin desteklediği) iktisat politikaları arasındaki dalgalanmalar ve nihayet 1980'de yeniden içe ve dışa karşı "piyasa ekonomisine dönüş ve dışa açılma" düşüncesiyle yola çıkılan; sonraki yirmi yıla adını yazdıran, fakat her aşamasında yoğun eleştirilerle karşılaşan Neo-liberal dönüşüm, iktisat politikalarında durmadan tekrarlanan senaryoların varlığını sergilemektedir (Baratov, 2005, s.211). Daha sonra piyasa ekonomisine geçişe yönelik adımlar atılmış ve neoliberal iktisat politikalarının uygulanacağı alanlar ve ölçütler belirlenmiştir.

1987-2001 yılları, Türkiye için iktisadi istikrarsızlıkların yaşandığı bir dönem olmuştur. 2002- 2004 döneminde, ihracattaki olumlu performansa rağmen, ithalattaki hızlı büyüme dış ticaret açığının gittikçe artmasına yol açmıştır. 2008 küresel kriz sonrası dünya ticaretinin %12 ile daralma göstermesiyle birlikte Türkiye'nin ihracatı olumsuz yönde etkilenmiştir (Akbulut, 2014, s. 72). 2010 yılında toplam ihracat 140 milyara ulaşırken Avrupa'nın payı birkaç yıl hariç %50'nin altında kalmıştır (Pamuk, 2014, s.307) .

#### **1.1.4. Almanya Dış Ticaret Stratejileri**

1921 yılında Alman dış ticareti çarpıcı bir gelişme göstermiştir. Almanya'nın tazminat ödeme kabiliyeti, dış ticaretinde genişleme kapasitesi göstermesine sebep olmuştur (Williams, 1922, s.482).

Savaş sonrasında karşılaşılan sorunlara ve Alman markasının yok olmasına sebep olan durum, artan enflasyon oranıydı. Enflasyonun kökleri Almanya'nın savaş çabalarını finanse etmek için biriktirdiği devasa borçtan kaynaklansa da 1923'teki hiperenflasyon, Almanya'daki Alman sanayi bölgesinin Ocak 1923'te Fransız-Belçika askeri işgali tarafından tetiklenmesine neden olmuştur (Britannica, 2022).

Eylül 1936'da Almanya, daha radikal Nasyonal Sosyalistler tarafından otarşiye ya da ekonomik kendi kendine yeterliliğe ulaşmanın bir aracı olarak müjdelenen yabancı

hammadeler ve ikame ürünler geliřtirmek için Dört Yıllık Planı bařlatmıřtır. Fakat bu durum gıda ve hammadde arzının bir kısmı için Almanya'yı diđer ülkelere bağımlı olmaktan kurtaramamıřtır. Döviz sıkıntısı çeken Almanya, ihtiyaç duyduđu malzemeleri yurt dıřından temin etmek için sayısız çareler tasarlamıřtır. Doğrudan takas iřlemleri kapsam olarak sınırlandırılırken, izlenen diđer yöntemler dolaylı takasa dönuřmüřtür. Ülkenin yabancı ülkelerle olan ticari anlaşmaları öncelikle, Almanya'nın belirli bir ülkeden aldıđı hammaddeleri, o ülkeye ürettiđi malların eşdeđer deđerinde satıřlar yoluyla borcunu ödediđi ikili ticaret dengesi ilkesine dayanmaktadır. Karmařık düzenlemeler ve kısıtlamalar, ülkenin dıř ticaretinin tüm iřleyiřini yönetmektedir (CQ Researcher, 2022).

1949'dan itibaren ihracat istikrarlı bir řekilde artmıřtır. Dünya pazar payı 1970'lerin bařlarında % 2'den % 10'a kadar yükselme göstermiřtir. Almanya'nın dünya pazarında bařarılı bir řekilde rekabet edebilme yeteneđi ile özdeřleşerek ekonomik gücü giderek artmıřtır. Almanya'nın dünya pazarına entegrasyonunu teřvik etmek ve ithalatın üzerinde önemli bir ihracat fazlası vermesi, iç ekonomik politikaları arasındadır. Sonraki on yıllar boyunca yavař büyüme ve ihracatın önemi, Alman ekonomisinin Batı Avrupa'ya daha fazla entegre olmasını sađlamıřtır. Almanya, sanayileřme derecesi ve cođrafi konumu sayesinde Avrupa Kıtası'nın en büyük ticaret ortađıdır (Lindlar & Holtfrerich, 1997, s.217).

2000 yılında Almanya'nın dıř ticareti dik yükseliř trendini sürdürmüřtür. Almanya dünya ticaretinde ABD'nin ardından ikinci sırada ve Japonya'nın önünde yer almıřtır (Abdin, 2001, s.71).

Avro bölgesinin en büyük ekonomisi olan Almanya'nın 2018'de GSYİH'si 4,0 trilyon ABD dolarıdır. Almanya, ülkenin GSYİH 'sinin üçte birinden fazlasını oluřturan ihracatıyla dünyanın önde gelen üretim ekonomilerinden biri ve üçüncü en büyük ihracatçıdır. Motorlu taşıtlar, römorklar ve kamyonlar Almanya'nın en önemli ihracat malları olmaya devam etmekle birlikte bunu makine ve kimyasal ürünler takip etmektedir. Almanya aynı zamanda dünya çapında üçüncü en büyük tarım ürünleri ihracatçısı olarak karřımıza çıkmaktadır (İnsights, 2019).

Alman firmalarının dıř pazarlardaki rekabet gücünü artırmak ve Almanya'nın yabancı yatırımcılar için bir iř yeri olarak çekiciliđi, Almanya'daki dıř ekonomi politikasının (FEP) ikiz amacıdır. Kapsamı, çok çeřitli "iç" politikaları kapsayacak

şekilde geleneksel “sınır” önlemlerinin çok ötesine uzanmaktadır. Rekabet politikası, teknoloji politikası ve düzenleme ve sübvansiyon politikaları gibi politikalar uluslararası rekabet açısından giderek daha alakalı hale gelmektedir. Teorik olarak, Almanya’daki FEP, Pazar odaklı yapının “dış” tamamlayıcısıdır. Yasal çerçeveyi belirleyen temel düzene ilişkin politika ve altta yatan ekonomik kurumlar, rekabet politikası, bireysel ekonomik özgürlüğün korunması; piyasaların düzgün çalışmasını sağlayan piyasa politikasıdır. Yapısal politika, neyin üretileceği ve nasıl üretileceğine dair özel kararlarla müdahale etmemesi gereken büyüme ve istikrar politikalarıyla aynı fikirdedir (Koopman, 2010, s.7).

### **1.1.5. Türkiye Dış Ticaret Stratejileri**

Dış ticaret politikasının kullandığı araçlar çok çeşitlidir. Gümrük tarifeleri geçmişten bu yana kullanılan birincil tarifedir. Diğer tarifeler ülkelere göre çeşitlilik göstermektedir. Dış ticaret kısıtlamalarının tamamı şöyle sıralanabilir: (Çelik, 2015, s.22).

1. Gümrük Tarifeleri
2. Tarife Dışı Araçlar
  - a) Miktar Kısıtlamaları
    - İthalat Kotaları
    - İthalat Yasakları
    - İhracat Kotaları
    - Kambiyo Kontrolü
  - b) Tarife Benzeri Araçlar
    - Çoklu Kur Uygulamaları
    - Yerli Katkı Oranları
    - Sübvansiyonlar ve Telafi Edici Vergi
    - Damping ve Anti-damping Vergisi
    - Dolaylı Vergiler

- Mevsimlik Gümrük Tarifeleri
- İthalat Teminatları
- İthalat Vergileri
- İhracat Vergileri
- Fon Uygulamaları
- Fark Giderici Vergiler

c) Görünmez Engeller

3. İhracatın Teşvik Edilmesi

4. Karşılıklı Ticaret Sistemleri

d) Geleneksel Sistemler

- Takas
- Kliring
- Karşılıklı Satın Alma
- Aktarma Ticareti
- Değiş-Tokuş
- Geri Satın Alma
- Dengeleme Anlaşmaları
- Satın al-Sat

e) Yeni Sistemler

- Fason İmalat
- Yap-İşlet Devret
- Leasing
- Factoring
- Forfaiting
- Barter

## **1.2. Türkiye Almanya Dış Ticareti**

### **1.2.1. Türkiye Almanya Dış Ticaretinin Tarihsel Gelişimi**

Türkiye ile Almanya'nın geçmişi çok eskilere dayanmaktadır. Her iki ülkenin 1. Dünya Savaşı öncesine dayanan askerî ittifak ilişkileri; Osmanlı Devleti döneminde Anadolu ve Bağdat demiryolu projeleri gibi iş birliklerini gerçekleştirmeleri ve şimdiye dek doğrudan birbiriyle savaşmamış olmaları gibi çeşitli etkenler, Almanya ve Türkiye ilişkilerinin tarihsel olarak artı bir görüntüye sahip olmasını sağlamaktadır (Vatandaş, 2019, s.2).

Türkiye 1980 dönemlerinde siyasi sorunları önlemek, ekonomik iş birliği üzerindeki ticareti ve yabancı ülke ticaretini teşvik etmek için yasal düzenlemeler getirmiştir. Bu durum Türkiye ve Almanya'yı etkileyerek ülkelerin ekonomik ikili ilişkilerinde önemli gelişmeler kaydedilmesine yol açmıştır. Devletin aldığı ekonomik yaklaşımlar arasındaki bağlantı, Türk hükümetleri ve Türkiye-Almanya ilişkilerindeki dış politika anlayışları, ülkenin ticaretteki artışında belirgindir. 1983 yılında Almanya ile toplam ticaret hacmi 1,7 milyar ABD doları iken 1993'te 8,1 milyar dolara ulaşmıştır (İnat, 2016, s.26).

Almanya ekonomik gücü nedeniyle Avrupa'da siyasi, ekonomik ve ticari alanlarda kilit bir rol oynamaktadır. Tarihsel olarak Türkiye'nin en önemli ticaret ortakları ve yatırımcılarından biri olan Almanya, Avrupa Birliği (AB)'nin kurucu üyelerindedir. Türkiye ile AB arasında 1996 yılından itibaren yürürlükte olan Gümrük Birliği sayesinde Türkiye'den Almanya'ya ATR belgesi ile gümrük vergisiz ihracat yapılabilmektedir (İHKİB Arge Şubesi, y.y., s. 6). Yaşanan bu pozitif gelişmeler iki ülke arasındaki dış ticareti olumlu yönde etkileyerek ülkeler arasındaki ilişkiyi güçlendirmiştir.

**Tablo 1:** Almanya'nın yıllara göre Türkiye'den yaptığı ithalat (Milyar \$)

Yıl	Türkiye'den İthalat	Dünya'dan İthalat	Türkiye'den Yapılan İthalatın Almanya'nın Toplam İthalatı İçindeki Payı	Türkiye'nin Dünyaya İhracatı	Türkiye'den Yapılan İthalatın Türkiye'nin Toplam İhracatı İçindeki Payı
2001	5,8	486,0	%1,2	31,3	%18,6
2002	6,5	490,5	%1,3	35,8	%18,2
2003	8,1	601,8	%1,4	47,3	%17,2
2004	9,9	718,2	%1,4	63,1	%15,6
2005	10,4	779,8	%1,3	73,5	%14,2
2006	11,6	922,2	%1,3	85,5	%13,6
2007	13,3	1.059,3	%1,3	107,3	%12,4
2008	14,3	1.192,6	%1,2	132,0	%10,9
2009	11,6	928,9	%1,3	102,1	%11,4
2010	13,3	1.060,7	%1,3	113,9	%11,7
2011	16,4	1.261,6	%1,3	134,9	%12,2
2012	15,5	1.161,2	%1,3	152,5	%10,2
2013	16,4	1.187,3	%1,4	151,8	%10,8
2014	17,9	1.215,0	%1,5	157,6	%11,3
2015	16,1	1.053,4	%1,5	143,9	%11,2
2016	17,0	1.060,7	%1,6	142,5	%11,9
2017	18,4	1.167,8	%1,6	157,0	%11,7
2018	19,3	1.287,4	%1,5	167,9	%11,5
2019	17,7	1.236,3	%1,4	171,1	%10,4

**Kaynak:** (TİM, 2020, s.26)

2014 yılında en fazla ihracat yapılan beş ülke sırasıyla Almanya, Irak, İngiltere, İtalya ve İran olmuştur. Türkiye'nin 2017 yılında en fazla ihracat gerçekleştirdiği ülke 14 milyar 855 milyon 387,2 bin dolarla Almanya'dır. 2018 yılında Türkiye'den ihracatın en çok gerçekleştiği ülke 15,8 milyar dolarla Almanya olurken iki ülke arasında ekonomik ilişkilerde yeni bir çağ için girişimlere başlanmıştır. Türkiye-Almanya arasında 2018 yılında Türkiye-Almanya Ortak Ekonomik ve Ticaret Komitesi (JETCO) anlaşması imzalanmıştır. 2019 yılında Türkiye'nin en fazla ihracat gerçekleştirdiği ülke 16,62 milyar dolarla Almanya olmuştur (TİM İhracat 2021 Raporu, 2021, s.27).

**Tablo 2:** En çok ihracat yapılan 10 ülke (2020)

Almanya	Birleşik Krallık	ABD	Irak	İtalya	Fransa	İspanya	Hollanda	İsrail	Rusya Federasyonu
15,97 milyar \$	11,24 milyar \$	10,18 milyar \$	9,14 milyar \$	8,08 milyar \$	7,19 milyar \$	6,69 milyar \$	5,15 milyar \$	4,70 milyar \$	4,49 milyar \$

**Kaynak:** (TİM İhracat 2021 Raporu, 2021, s.30)

### 1.2.2. Türkiye Almanya Dış Ticaretinin Sektörel ve Mal Grubuna Göre Dağılımı

Almanya ve Türkiye arasındaki ekonomik ilişkiler uzun bir geleneğe sahiptir. Bu geleneğin en belirgin göstergesi Almanya'nın Türkiye'nin en önemli iş ortağı olmasıdır. (Tolksdorf, 2016, s.12).

İhraç edilen başlıca ürünler: Kara ulaşım araçları, giyim eşyası ve aksesuarları, tekstil elyafı ve mamulleri, meyve ve sebzeler, haberleşme cihazları, enerji üreten makine ve cihazlar, elektrikli makine ve cihazlar, metallere nihai ürünler, kauçuk ve mamulleri, motorların aksam parçaları.

İthal edilen başlıca ürünler: Kara ulaşım araçları, sanayi kollarında kullanılan makine ve cihazlar, elektrikli makine ve cihazlar, plastik ve plastikten mamul eşya, enerji üreten makine ve cihazlar, demir-çelik, eczacılık ürünleri ve organik kimyasal ürünler, silikonlar (Türkiye Cumhuriyeti Dışişleri Bakanlığı, 2021). 2020'de Almanya ile Türkiye arasındaki ikili ticaret tüm ürünler toplamı tabloda verilmektedir (ITC, 2022).



**Tablo 3: 2020’de Almanya ile Türkiye arasındaki ikili ticaret tüm ürünler**

HS4 Ürün kodu	Ürün etiketi	Almanya'nın Türkiye'den İthalatı			
		2020 değeri, bin ABD doları	2016-2020 yılları arasında yıllık değer artışı, %, payı	Almanya'nın ithalatındaki payı, %	Almanya tarafında n uygulana n eşdeğer advalore m tarifesi
<b>Topla m</b>	Tüm ürünler	17.559.879	0	1	
<b>84 meta veri</b>	Makineler, mekanik cihazlar, nükleer reaktörler, kazanlar; parçaları	2.668.250	-1	2	0
<b>87</b>	Demiryolu veya tramvay vagonları dışındaki araçlar ve bunların parça ve aksesuarları	2.509.480	-2	2	0
<b>61</b>	Örme veya tığ işi giyim eşyası ve giyim aksesuarları	2.174.375	-2	12	0
<b>62</b>	Örme veya tığ işi olmayan giyim eşyası ve giyim aksesuarları	1.489.923	2	9	0
<b>85</b>	Elektrikli makine ve teçhizat ve bunların aksam ve parçaları; ses kaydediciler ve çoğaltıcılar, televizyon	883.568	-3	1	0
<b>08</b>	Yenilebilir meyve ve kuruyemişler; narenciye	733.051	2	6	2
<b>73</b>	Demir veya çelikten eşyalar	622.220	3	3	0
<b>20</b>	Sebze, meyve, sert kabuklu yemişler	590.542	4	10	6
<b>63</b>	Diğer hazır tekstil ürünleri; yıpranmış giysiler	564.234	2	5	0
<b>40</b>	Kauçuk ve bunlardan mamul eşya	505.798	0	4	0
<b>39</b>	Plastikler ve bunlardan mamul eşya	486.981	3	1	0
<b>94</b>	Mobilya; yatak takımları, şilteler, şilte destekleri, minderler ve benzeri pelüş mobilyalar	393.108	-3	2	0
<b>76</b>	Alüminyum ve bunlardan mamul eşya	387.771	0	3	0
<b>99</b>	Başka yerde belirtilmeyen mallar	305.409	33	0	
<b>90</b>	Optik, fotoğrafik, sinematografik, ölçme, kontrol, hassas, tıbbi veya cerrahi	260.055	4	1	0
<b>88</b>	Uçak, uzay aracı ve bunların parçaları	206.430	0	2	0
<b>69</b>	Seramik ürünler	181.538	6	6	0
<b>71</b>	Tabii veya kültür inciler, kıymetli veya yarı kıymetli taşlar, kıymetli metaller	166.386	-4	1	0
<b>57</b>	Hahırlar ve diğer tekstil yer döşemeleri	149.514	2	13	0
<b>73</b>	Demir ve çelik	143.528	8	1	0

52	Pamuk	110.942	-4	16	0
74	Bakır ve bunlardan mamul eşya	108.215	2	1	0
07	Yenilebilir sebzeler ve bazı kökler ve yumrular	106.513	6	1	5
33	Uçucu yağlar ve reçineler; parfümeri, kozmetik	92.756	30	1	0
19	Hububat, un, nişasta; pastacı ürünleri	92.605	5	2	5
70	Cam ve cam eşyalar	88.583	-2	2	0
03	Balıklar ve kabuklular, yumuşakçalar ve diğer suda yaşayan omurgasızlar	86.280	-7	2	0
64	Ayakkabı, tozluk ve benzerleri; bu tür makalelerin bölümleri	69.763	10	1	0
30	Eczacılıkla ilgili ürünler	68.240	2	0	0
48	Kağıt ve karton; kağıt hamurundan, kağıttan veya kartondan eşya	63.172	6	1	0
28	İnorganik kimyasallar; değerli metallerin, nadir toprak metallerinin organik veya inorganik bileşikleri	60.861	4	1	0
82	Adi metallerden aletler, aletler, çatal-bıçak takımı	60.306	-3	1	0
55	Sentetik elyaflar	57.310	-4	5	0
60	Örme veya tığ işi kumaşlar	55.917	1	13	0
68	Taş, alçı, çimento, asbest, mika veya benzeri maddelerden ürünler	55.200	12	2	0
22	İçecekler, alkollü içkiler ve sirke	52.966	3	1	1
56	Vatka, keçe ve dokunmamış kumaşlar; özel iplikler, ip, halat ve kablolar ve bunlardan mamul eşya	51.736	7	3	0
83	Adi metalden muhtelif eşya	50.029	-6	1	0
25	Tuz, kükürt; toprak ve taş; sıva malzemeleri, kireç ve çimento	49.047	4	3	0
21	Çeşitli yenilebilir müstahzarlar	48.637	10	1	2
38	Çeşitli kimyasal ürünler	47.497	25	0	0
54	İnsan yapımı filamentler; suni ve sentetik benzerleri	46.237	-11	4	0
42	Deri eşyalar; saraçlık ve koşum takımı, seyahat eşyaları, el çantaları ve benzeri kaplar	45.594	-7	1	0
34	Sabun, organik yüzey aktif maddeler, yıkama müstahzarları, suni	42.404	10	1	0
27	Mineral yakıtlar, mineral yağlar ve bunların damıtılmasından elde edilen ürünler	39.997	12	0	0
24	Tütün ve mamul tütün ikameleri	37.831	-8	1	0
17	Şekerler ve şekerlemeler	34.604	0	2	29
12	Yağlı tohumlar ve yağlı meyveler; çeşitli tahıllar, tohumlar ve meyveler;	31.364	7	1	0
81	Diğer baz metaller; Sermetler, bunlardan eşya	29.986	-10	2	0

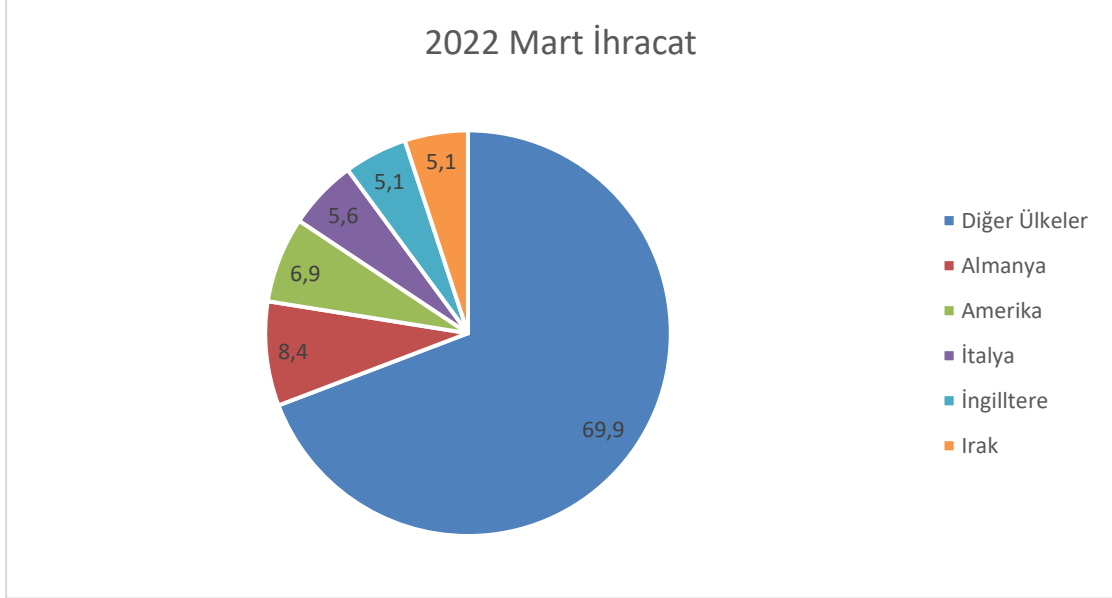
26	Cevherler, cüruf ve kül	28,673	11	0	0
86	Demiryolu veya tramvay lokomotifleri, vagonları ve bunların parçaları	24.816	16	1	0
58	Özel dokuma kumaşlar; püsküllü dokuma kumaşlar, dantel; duvar halıları	23.295	-4	10	378.753
59	Emdirilmiş, kaplanmış, kaplanmış veya lamine edilmiş dokuma kumaşlar; uygun türden tekstil ürünleri	21.007	-11	2	0
09	Kahve, çay, ve baharatlar	19.949	5	0	0
96	Çeşitli imalat eşyaları	16.438	8	1	0
32	Tabaklama veya boyama boyalar, pigmentler ve diğer renklendiriciler . . .	16.160	12	0	0
41	Ham postlar ve deriler (kürkler hariç) ve deri	14.055	2	3	0
29	Organik kimyasallar	13.982	-8	0	0
04	Süt ürünleri; kuş yumurtaları, doğal bal; hayvansal kökenli yenilebilir ürünler	12.376	24	0	28
44	Ahşap ve ahşap eşyaları; odun kömürü	11.268	-1	0	0
05	Tarifenin başka yerinde belirtilmeyen veya yer almayan hayvansal menşeli ürünler	11.232	-23	1	0
06	Canlı ağaçlar ve diğer bitkiler; ampuller, kökler ve benzerleri; kesme çiçekler ve süs yaprakları	10.744	-11	0	0
35	Albüminoid maddeler; modifiye nişastalar; yapıştırıcılar; enzimler	10.643	28	0	1
31	Gübreler	10.206	74	1	0
49	Basılı kitaplar, gazeteler, resimler ve basım endüstrisinin diğer ürünleri; el yazmaları	9.873	1	0	0
65	Başlıklar ve bunların aksamaları	8.442	14	1	0
89	Gemiler, tekneler ve yüzer yapılar	8,001	-34	1	0
93	Silah ve mühimmat; bunların parça ve aksesuarları	7.675	-5	3	0
10	Hububat	7.437	6	0	11
18	Kakao ve kakao müstahzarları	7,134	4	0	0
13	Sakızlar, reçineler ve diğer bitkisel özler ve özler	7.040	25	1	0
51	Yün, ince veya kaba hayvan kılı; at kılı ipliği ve dokuma kumaş	6.932	-21	2	0
15	Hayvansal veya bitkisel katı ve sıvı yağlar	6.601	2	0	3
95	Oyuncaklar, oyunlar ve spor malzemeleri; bunların parça ve aksesuarları	6.292	19	0	0
43	Kürkler ve suni kürkleri; bunlardan üretir	5,862	-10	7	0

11	Değirmencilik sektörünün ürünleri, nişastalar; buğday gluteni	5.674	-4	1	18
53	Diğer bitkisel tekstil lifleri; kağıt ipliği ve kağıt ipliğinden dokunmuş kumaşlar	4.213	5	6	0
66	Şemsiyeler, güneş şemsiyeleri, bastonlar, iskemleler	2.601	10	1	0
92	Müzik Enstrümanları; bu tür eşyaların parça ve aksesuarları	2.058	-22	0	0
14	Bitkisel örgü malzemeleri; Tarifede yer almayan bitkisel ürünler	1.947	36	2	0
23	Gıda endüstrisinden kaynaklanan kalıntılar ve atıklar; hazır hayvan yemi	1.493	46	0	5
97	Sanat eserleri, koleksiyoner parçaları ve antikalar	1.407	20	0	0
36	Patlayıcılar; piroteknik ürünler, yanıcı müstahzarlar	1.380	-22	1	0
75	Nikel ve bunlardan mamul eşya	1.217	-8	0	0
16	Et, balık veya kabuklular, yumuşakçalar veya diğer suda yaşayanlar	1.172	-12	0	7
79	Çinko ve bunlardan mamul eşya	1.125	37	0	0
67	Hazırlanmış kuş tüyü ve kuş tüyü ve kuş tüyünden eşya; yapay çiçekler	746	37	0	0
78	Kurşun ve bunlardan mamul eşya	661	-9	0	0
91	Saatler ve bunların aksam ve parçaları	508	7	0	0
50	İpek	230	4	1	0
46	Hasırdan, sazdan veya örülmeye elverişli diğer maddelerden imalatlar; sepetçilik ve hasır işi	228	1	0	0
37	Fotografik veya sinematografik ürünler	139	-37	0	0
80	Kalay ve bunlardan mamul eşya	127	-8	0	0
45	Mantar ve mantardan mamul eşya	27	38	0	0
01	Canlı hayvanlar	23	-14	0	9
47	Odun veya diğer lifli selülozik malzemelerin hamurları; geri kazanılmış atık ve hurda	11	-53	0	0
02	Et ve yenilebilir sakatat	5	-41	0	22
<b>Kaynak: (ITC, 2022)</b>					

### 1.2.3. Türkiye Almanya İthalat ve İhracat İlişkisi


Mart 2022'de ihracatın ana ortak ülkesi 1 milyar 907 milyon dolarla Almanya olmuştur. Ülkeyi 1 milyar 559 milyon dolarla ABD, 1 milyar 278 milyon dolarla İtalya, 1 milyar 168 milyon dolarla İngiltere ve 1 milyar 162 milyon dolarla Irak izlemiştir. Mart 2022'de ilk beş ülkenin toplam ihracat içindeki oranı %31,1 olmuştur.

Ocak-Mart 2022 döneminde ihracatın ana ortak ülkesi 5 milyar 286 milyon dolar ile Almanya oldu. Ülkeyi 4 milyar 56 milyon dolarla ABD, 3 milyar 384 milyon dolarla İtalya, 3 milyar 210 milyon dolarla İngiltere ve 3 milyar 115 milyon dolarla Irak izlemiştir. Ocak-Mart 2022'de ilk beş ülkenin toplam ihracat içindeki oranı %31,6'dır (TÜİK, 2022).



**Kaynak: (TÜİK, 2022)**

**Şekil 1: 2022 Yılı Mart ihracat miktarı**



**Kaynak: (TÜİK, 2022)**

**Şekil 2: 2022 Yılı Mart ithalat miktarı**

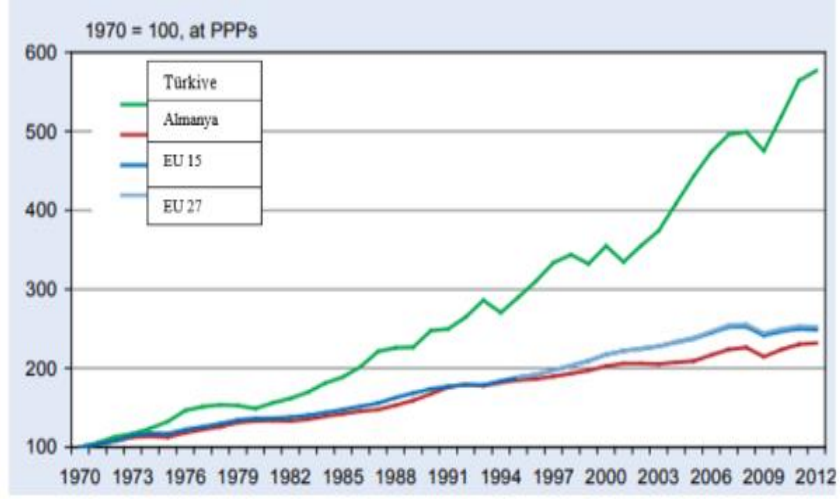
**Tablo 4: Almanya ile Türkiye arasındaki ticaret dengesi**

<b>Almanya ve Türkiye Ticaret Dengesi (EURO)</b>			
<b>HS4 Ürün Kodu</b>	<b>2020'de değer dengesi</b>	<b>2021'de değer dengesi</b>	<b>2022'de değer dengesi</b>
<b>84</b>	1.747.556	1.827.387	2.329.900
<b>88</b>	1.705.536	404.043	1.920.404
<b>85</b>	1.467.638	1.251.704	1.232.568
<b>30</b>	727.890	1.786.359	801.531
<b>90</b>	743.381	766.655	710.494
<b>39</b>	721.560	732.019	603.159
<b>87</b>	1.562.781	608.457	544.941
<b>99</b>	698.195	585.503	515.802
<b>38</b>	385.128	450.902	507.898
<b>72</b>	318.727	387.193	349.804
<b>29</b>	251.242	354.240	342.935
<b>48</b>	271.382	290.967	333.164
<b>32</b>	268.12	295.043	309.737
<b>34</b>	126.126	155.371	194.697
<b>33</b>	98.249	122.388	156.192
<b>82</b>	62.187	85.545	81.011
<b>35</b>	75.399	81.554	79.783
<b>18</b>	25.702	38.583	54.750
<b>28</b>	47.246	44.048	50.574
<b>24</b>	23.144	36.563	47.838
<b>59</b>	37.997	45.035	45.939
<b>83</b>	73.903	84.578	43.622
<b>96</b>	40.312	31.757	41.373
<b>51</b>	23.197	27.816	31.015

**Kaynak:** ITC, Trade Map 2022

#### 1.2.4. Türkiye- Almanya Milli Gelir İlişkisi

AB'deki tüm üye ülkelerin kişi başına düşen ortalama geliri Türkiye'dekinden 2,7 kat daha yüksektir. Türkiye ekonomisinin AB'ninkinden önemli ölçüde daha değişken olduğu bilinmektedir. Aşağıdaki şekilde Milli Gelir ilişkisi gösterilmektedir.



**Kaynak:** (TÜİK, 2022)

**Şekil 3:** Türkiye- Almanya- EU 15 Milli Gelir ilişkisi

## 2. ZAMAN SERİSİ, MAKİNE ÖĞRENİMİ VE YAPAY SİNİR AĞLARI

Bu bölümde zaman serisi tahmin yöntemleri, makine öğrenimi, yapay sinir ağları, yapay sinir ağlarında öğrenme ve öğrenme kuralları açıklanmıştır.

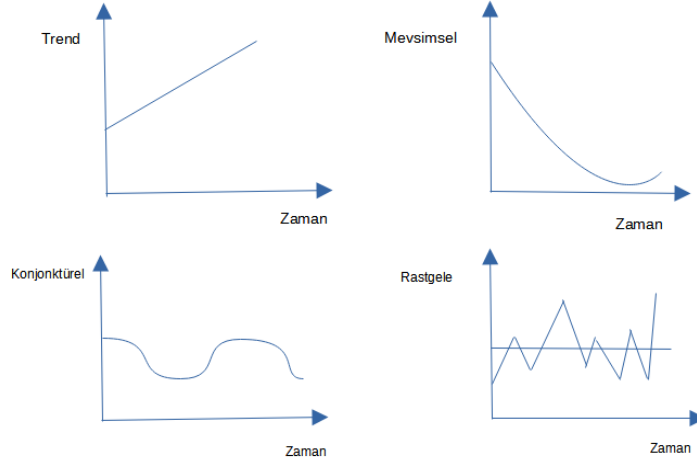
### 2.1. Zaman Serisi Tahmin Yöntemleri

Zaman gibi tek bir boyut boyunca sıralanan herhangi bir gözlem dizisi, bir zaman serisi olarak düşünülebilir. Zaman serisi analizindeki vurgu, zamanın farklı noktalarındaki gözlemler arasındaki bağımlılığın incelenmesidir. Fiyatlar, ücretler, satışlar, GSYİH ve bileşenleri, hisse senedi getirileri, faiz oranları ve döviz kurları gibi birçok ekonomik ve finansal değişken zaman içinde gözlemlenmektedir. Bu değişkenler arasındaki ilişkilerle ilgilenmenin yanı sıra, birinin mevcut ve geçmiş değerleri arasındaki ilişkilerle de ilgilenmektedir. Zaman serisi veri türleri arasında içerisinde sürekli olarak kaydedebilen verilere sürekli zaman serisi, sadece belirli aralıklarla elde edilebilen verilere kesikli zaman serisi denmektedir (Diebold, 2019, s.1).

Zaman serisi bileşenleri, biçimlerine göre bir veya birden fazla bileşenden etkilenmektedir. Trend bileşeni, verilerde doğrusal olmayabilecek uzun vadeli bir artış veya azalma göstermektedir. Bazen zaman arttıkça trend yön değiştirebilir. Döngüsel bileşen, veriler sabit süreli olmayan yükseliş ve düşüşler gösterdiğinde var olmaktadır. Döngülerin ortalama uzunluğu, mevsimsel bir modelin uzunluğundan daha uzundur. Uygulamada, trend bileşeninin döngüsel bileşeni de içerdiği varsayılmaktadır. Bazen trend ve döngüsel bileşenler birlikte trend döngüsü olarak adlandırılır. Mevsimsel bileşen; bir dizi düzenli gösterdiğinde (örneğin her ay / çeyrek / yıl) var olur. Mevsimsellik her zaman sabit ve bilinen bir dönemdir (Buteikis, n.d.).

Düzensiz bileşen; Zaman serilerinde görülebilecek başka bir hareket türüdür. Adından da anlaşılacağı gibi, bir zaman serisinde düzensiz veya rastgele hareketler önermek için hiçbir hipotez veya eğilim kullanılamaz. Bu sonuçlar öngörülemeyen, düzensiz, öngörülemez ve doğası gereği kontrol edilemez. Doğal afetler, pandemi gibi durumlar rastgele zaman serisi bileşeninin bazı örnekleridir (Jose, 2022, s.5).





**Kaynak:** (Jose, 2022, s.22)

**Şekil 4:** Farklı bileşenlere sahip bir Zaman Serisi grafiği

Durağanlık, ortalama, otokorelasyon, n sıralı dağılım gibi rastgele bir sürecin istatistiklerinin bir kısmının veya tamamının zaman içinde varyansını ifade eder. Katı duyuşal durağanlık ve geniş duyuşal durağanlık olmak üzere iki tür durağanlık tanımlayabiliriz. Gözlemler zamana bağılı değilse, yani istatistiksel özellikleri zamanla değişmeyecek, dolayısıyla sabit ortalamaya, varyansa ve kovaryansa sahip olacaklarsa, bir zaman serisinin durağan olduğu söylenebilir. Trendleri veya mevsimselliği olan zaman serileri durağan değildir. Çünkü eğilimlerin zamanla ilgili verilerinin hareketinde bir değişiklik olacak ve bu da zaman içinde ortalamanın değişmesine neden olacaktır. Mevsimsellik ise, zaman serilerindeki örüntü düzenli bir zaman aralığı için bir varyasyon gösterdiğinde ortaya çıkar ve bu da varyansın zaman içinde değişmesine neden olur. Zaman serisi verilerinin tahmin ve öngöründe bulunabilmesi için durağan olması gerekmektedir. Durağanlık varsayımını doğrulamanın ve zaman serisi verilerini durağan hale dönüştürmenin farklı yolları vardır.

Otokorelasyon: Zaman serisi gözlemleri genellikle önceki zaman noktalarındaki gözlemlerle ilişkilidir ve bu nedenle bağımsız olarak dağıtılmaz. Bu korelasyon, otokorelasyon veya seri korelasyon olarak adlandırılır. Daha önce belirtildiği gibi, otokorelasyon sergileyen zaman serileri, standart regresyon analizi varsayımlarını karşılamamaktadır. Otokorelasyonlu veriler tipik olarak durağan olmadığından, otokorelasyonu ortadan kaldırmak için genellikle verilerin farkının

alınması yeterlidir ve bu nedenle otokorelasyon test edilmeden önce gerekli veri dönüşümleri gerçekleştirilmelidir.

Otokorelasyon fonksiyonları (ACF'ler), durağanlığı ve otokorelasyonu kontrol etmek için kullanılabilir. Bir ACF, her gözlem ile önceki değerler arasındaki korelasyonu çeşitli gecikmelerde çizer. Burada gecikme, bir gözlem ile önceki değerleri arasındaki zaman noktalarının sayısıdır. ACF'ye eşlik eden kısmi ACF'dir (PACF). Bu bir gözlem ile daha düşük gecikmelerdeki korelasyonlarla açıklanmayan geçmiş değerler arasındaki korelasyondur (Schaffer et al., 2021, s.2).

Finansal zaman serisi analizi, zaman içinde varlık değerlemesi teorisi ve uygulamasıyla ilgilidir. Oldukça ampirik bir disiplindir, ancak diğer bilimsel alanlar gibi teori de çıkarım yapmanın temelini oluşturmaktadır. Bununla birlikte, finansal zaman serisi analizini diğer zaman serisi analizlerinden ayıran önemli bir özellik vardır. Hem finansal teori hem de ampirik zaman serileri bir belirsizlik unsuru içermektedir. Örneğin, varlık oynaklığının çeşitli tanımları vardır ve bir hisse senedi getirisi serisi için oynaklık doğrudan gözlemlenebilir değildir. Eklenen belirsizliğin bir sonucu olarak, istatistiksel teori ve yöntemler finansal zaman serisi analizinde önemli bir rol oynamaktadır (Tsay, 2002, s.1).

### 2.1.1. Naive Modeli

1940'larda ekonomistler, tahmin doğruluğunun ölçütü olarak naive modeller önermişlerdir. Naive modelinde bir sonraki dönemin seviyesi, bir önceki döneminkiyle aynı olacaktır (Mclaughlin, 1983, s.1). Başka bir deyişle tüm tahminler basitçe son gözlemin değeri olarak ayarlanmaktadır.

Gelişmiş tahmin yöntemlerini uygulamak cazip gelse de, naive tahminlerini dikkate almayı unutmamak gerekir. Naive, bir tahmin, basitçe en son gözlemlenen değerdir. Başka bir deyişle,  $t$  anında,  $k - \text{adım} - \text{ileri}$  naive tahmin ( $F_{t+k}$ )  $t(y_t)$  zamanında gözlemlenen değere eşittir.

$$F_{t+k} = y_t$$

Denklem 1

### 2.1.2. Mean Modeli

Burada, gelecekteki tüm değerlerin tahminleri, geçmiş verilerin ortalamasına eşittir. Geçmiş verilerin  $y_1, \dots, y_T$ , ile gösterilmesine izin verildiği zaman, tahminleri şu şekilde yazılabilmektedir:

$$\hat{y}_{T+h|T} = \bar{y} = \frac{(y_1 + \dots + y_T)}{T}. \quad \text{Denklem 2}$$

$\hat{y}_{T+h|T}$  gösterimi  $y_1, \dots, y_T$  verilerine dayanan  $y_{T+h}$  tahmini için bir kısaltmadır.

### 2.1.3. Drift Modeli

Naive yönteminin bir varyasyonu, tahminlerin zaman içinde artmasına veya azalmasına izin vermektir. Burada zaman içindeki değişiklik miktarı (sapma olarak adlandırılır), tarihsel verilerde görülen ortalama değişiklik olarak ayarlanır (Hyndman & Athanasopoulos, 2019, s.40). Bu nedenle,  $T + h$  süresi için tahmin şu şekilde verilir:

$$y_T + \frac{h}{T-1} \sum_{t=2}^T (y_t - y_{t-1}) = y_T + h \left( \frac{y_T - y_1}{T-1} \right) \quad \text{Denklem 3}$$

### 2.1.4. ARIMA Modeli

Zaman serilerini tahmin etmek için birçok yaklaşım geliştirilmiştir. Geleneksel istatistiksel yöntemlerden otoregresif entegre hareketli ortalama (ARIMA), bir tahmin modelinin oluşturulmasında yaygın olarak kullanılır. ARIMA modeli, 1970'lerde bilim adamları Box ve Jenkins tarafından önerilen bir zaman serisi tahmin yöntemidir. Tam adı Otoregresif Entegre Hareketli Ortalama modelidir. ARIMA modelinin ana avantajı, yalnızca ilgili zaman serisi verilerine ihtiyaç duyması ve iyi kısa vadeli tahmin yeteneklerine sahip olmasıdır (Yang et al., 2021, s.3).

Teorik olarak durağan zaman serilerini tahmin etmek için kullanılacak en genel modeller ARIMA modelleridir. Fark alma, loglama gibi işlemler kullanılarak durağan olmayan bir zaman serisinden durağan bir zaman serisi elde edilebilir. Genel olarak, bir zaman serisinde ortalama ve standart sapma gibi istatistiksel özellikler mekansal ve zamansal değişime sahip değilse, zayıf durağan olduğu kabul edilir. Durağan bir zaman serisi, belirli bir eğilimi olmayan, zaman içinde sabit varyansa ve otokorelasyona (bir

seri ile kendisinin başka bir versiyonu arasındaki korelasyonlar zamana göre ayrılmıştır) sahiptir (Noureen et al., 2019, s.521).

İktisatta ve istatistiğin diğer uygulamalarında, otoregresif süreçler durağan olguları tanımlamak için uzun süredir uygulanmaktadır ve süreci geçmiş değerleriyle açıklama fikri, tahmin için çok yararlı olmuştur. Bununla birlikte, ekonominin etkileşimlerini anlamak için değişkenlerin eşzamanlı değerleri arasındaki ilişkileri bulmak istiyorsak, bir değişkenin değerini aynı zaman noktasındaki diğer değişkenlerin değerleriyle ilişkilendirerek çok daha fazla bilgi edinebiliriz (Johansen, 2000, s.360). Otoregresif entegre hareketli ortalama modelinde, bir değişkenin gelecekteki değerinin, birkaç geçmiş gözlemin ve rastgele hataların doğrusal bir fonksiyonu olduğu varsayılmaktadır. Zaman serisini oluşturan temel süreç şu şekildedir:

$$y_t = \theta_0 + \vartheta_1 y_{t-1} + \vartheta_2 y_{t-2} + \dots + \vartheta_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

Denklem 4

$y_t$  ve  $e_t$  sırasıyla t zaman periyodundaki gerçek değer ve rastgele hatadır.  $\vartheta_i (i = 1, 2, \dots, p)$  ve  $\theta_j (j = 1, 2, \dots, q)$  model parametreleridir. p ve q tam sayılardır ve genellikle modelin sıraları olarak adlandırılır. Rastgele hataların,  $\varepsilon_t$  sıfır ortalaması  $\sigma^2$  sabit varyansı ile bağımsız ve özdeş olarak dağıldığı varsayılmaktadır.

Denklem 1; ARIMA modelinin bazı önemli durumlarını içermektedir. Eğer  $q = 0$  ise, (1) p sırasının bir AR modeli haline gelir.  $p = 0$  olduğunda, model q sırasının bir MA modeline indirgenir. ARIMA model oluşturmanın merkezi görevlerinden biri, uygun model sırasını (p, q) belirlemektir (Zhang, 2003, s.162).

## 2.2. Makine Öğrenimi

Makine öğrenimi, bazı olayların örneklerinden oluşan, bir koleksiyona dayanan algoritmalar oluşturmakla ilgilenen bilgisayar biliminin bir alt alanıdır. Bu örnekler doğadan gelebilir, insanlar tarafından el yapımı olabilir veya başka bir algoritma tarafından oluşturulabilir. Makine öğrenimi, bir veri kümesi toplayarak ve bu veri kümesine dayalı olarak algoritmik istatistiksel bir model oluşturarak pratik bir sorunu çözme süreci olarak da tanımlanabilir (Andriy Burkov, 2019).

Makine öğrenimi, çevreden öğrenerek insan zekasını taklit etmek için tasarlanmış, gelişen bir hesaplama algoritma dalıdır. Bir makine öğrenimi algoritması, belirli bir sonucu üretmek için tam anlamıyla programlanmadan (yani “sabit kodlanmış”) istenen bir görevi başarmak için girdi verilerini kullanan bir hesaplama sürecidir. Bu algoritmalar bir anlamda “yumuşak kodlanmıştır”, çünkü mimarilerini tekrarlama (yani deneyim) yoluyla otomatik olarak değiştirir veya uyarlarlar. Böylece istenen görevi yerine getirmede daha iyi hale gelirler. Uyum sürecine, istenen sonuçlarla birlikte girdi verisi örneklerinin sağlandığı eğitim denmektedir (el Naqa & Murphy, 2015).


ML modelleri genellikle üç hatayla karşılaşmaktadır.

1. Bias: Bu hataya gerçekçi olmayan varsayımlar neden olmaktadır. Bias yüksek olduğunda, ML algoritması özellikler ve sonuçlar arasındaki önemli ilişkileri tanıyamamıştır. Bu durumda algoritmanın “yetersiz” olduğu söylenir.
2. Varyans: Bu hata, eğitim setindeki küçük değişikliklere duyarlılıktan kaynaklanır. Varyans yüksek olduğunda, algoritma eğitim setini aşabilir ve bu nedenle eğitim setindeki minimum değişiklikler bile yüksek farklı tahminler üretebilir. Algoritma, eğitim setindeki genel kalıpları modellemek yerine, gürültüyü sinyalle karıştırmıştır.
3. Noise: Bu hataya öngörülemeyen değişiklikler veya ölçüm hataları gibi gözlemlenen değerlerin varyansı neden olur. Herhangi bir model tarafından açıklanamayan indirgenemez hatadır.

$\{x_i\}_{i=1,\dots,n}$  gözlemlerinden oluşan bir eğitim seti  $\{y_i\}_{i=1,\dots,n}$  gerçek değerli sonuçları düşünüldüğünü varsayalım.  $y = f[x] + \varepsilon$ , olacak şekilde  $f[x]$  fonksiyonunun var olduğunu varsayalım, burada  $E[\varepsilon_i] = 0$  ve  $E[\varepsilon_i^2] = \sigma_\varepsilon^2$  beyaz gürültüdür. Tahmin hatasının varyansını  $E = [y_i - \hat{f}[x_i]^2]$  minimum yapmak anlamında  $f[x]$ 'e en uygun  $\hat{f}[x]$  işlevini tahmin etmek istiyoruz ( $\sigma_\varepsilon^2$  ile temsil edilen gürültü nedeniyle ortalama kare hatası sıfır olamaz) (Prado, 2018, s.94).

$$E \left[ (y_i - \hat{f}[x_i])^2 \right] = \left( E \left[ \hat{f}[x_i] - f[x_i] \right] \right)^2 + V \left[ \hat{f}[x_i] \right] + \sigma_\varepsilon^2$$

*bias      varyans      noise      Denklem 5*



**Kaynak:** (Ziganto, 2018)

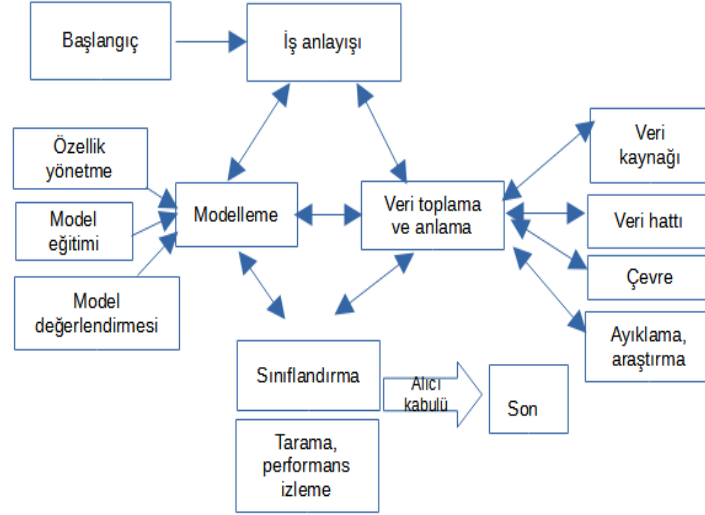
**Şekil 5:** Bias, Varyans gösterimi

ML, Yapay Zekanın (AI) bir alt alanı olarak kabul edilebilir. Öngörmeyi sağlayan temel yapı taşları algoritmalarıdır. ML, sistemlerin bunu yapmak için açıkça programlanmak yerine kendi başlarına öğrenmelerini sağlayarak daha akıllı davranışlarla sonuçlanır. Geçmiş verilerdeki kalıpları keşfeden ve bu kalıpları tahminler oluşturmak için kullanan modeller geliştirerek veriye dayalı tahminler üretir. ML'nin genel mimarisi şekil 6'da gösterilmiştir. İş anlayışı (alanın anlaşılması ve bilgisi), veri toplama ve anlama (verilerin toplanması ve anlaşılması), modelleme (özellik mühendisliği, model eğitimi ve değerlendirme gerektirir) ve dağıtım gibi birkaç adımdan oluşmaktadır (Dridi, 2021, s.1).

Makineler endüstriler, seyahat ve bilgi işlem gibi çoğu alanda insan hayatını kolaylaştırmıştır. Makine öğrenimi de bunları gerçekleştirenlerden biridir. Dama oyunu programıyla ünlü olan Arthur Samuel'e göre makine öğrenimi bilgisayarlara öğrenme yeteneği veren çalışma alanıdır. Makinelere verilerin nasıl daha fazla işleneceğini öğretmek için kullanılır. Makine öğreniminin amacı verilerden öğrenmektir (Mahesh, 2018, s.381) .

Finansal hizmetler, bankacılık ve sigortacılık gibi çeşitli uygulamalarda zengin verilerin, yenilikçi algoritmaların ve yeni yöntemlerin bulunabilirliği ile makine öğreniminin ve yapay zekanın faydalarından yararlanma potansiyeli çok yüksek olan önemli sektörlerden biri olmaya devam etmektedir. Makine öğrenimi teknikleri, derin öğrenme algoritmaları, değişkenler arasındaki ilişkilerin derin ve katmanlı bir

hiyerarşide modellendiği tahmin problemlerine yeni yaklaşımlar getirmiştir. Derin öğrenme yöntemleri, zaman serisi tahminindeki doğrusal olmama ve karmaşıklık gibi verilerin yapısını ve modelini belirleme yeteneğine sahiptir (Siami-Namini et al., 2019). Makine öğreniminin temel mimarisi şekil 6'da gösterilmektedir.



**Kaynak:** (Dridi, 2021, s.1)

**Şekil 6:** Makine öğreniminin temel mimarisi

### 2.2.1. Öğrenme Algoritmaları

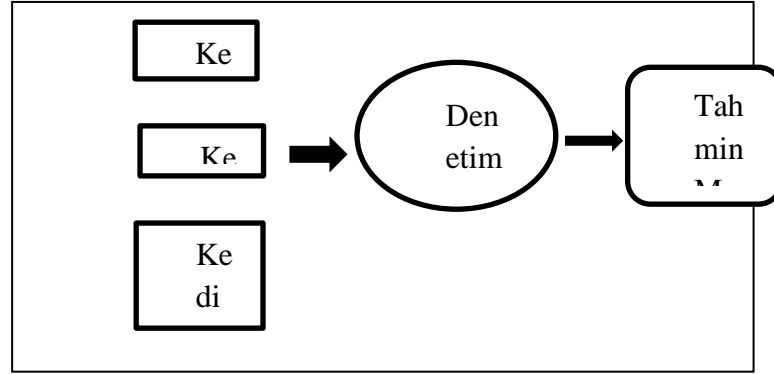
Öğrenmenin dış uyaranlara göre değişme ve önceki tüm deneyimlerin çoğunu hatırlama yeteneği olduğu söylenebilmektedir. Dolayısıyla makine öğrenimi, adaptif olarak değişme eğilimini artıran veya geliştiren her tekniğe maksimum önem veren bir mühendislik yaklaşımıdır. Bu nedenle makine öğreniminin temel amacı, bağlamla ilgili verilerle (genel bir ortam tarafından sağlanan) eğitilebilen (bir kez veya sürekli) geleceği anlamak ve etkileyen tüm unsurlar (dış faktörler) hakkında tam bilgi sahibi olmadan kararlar alıp matematiksel modelleri incelemek, tasarlamak ve geliştirmektir (Bonaccorso, 2017).

Diğer bir ifadeyle öğrenme kuramının amacı ağı bazı görevleri yerine getirmesi için eğitmektir (Banerjee Roy & Bhattacharya, 2022, s.54). Öğrenme, öğrenen ile çevre arasındaki etkileşimi içerdiğinden, öğrenme görevleri bu etkileşimin niteliğine göre

bölünebilir. Denetimli, denetimsiz ve pekiştirmeli öğrenme olarak üç farklı öğrenme türü bulunmaktadır.

### 2.2.2. Denetimli Öğrenme

Denetimli öğrenme algoritmaları etiketleme yoluyla kendileri için sağlanan girdi ve çıktı verilerine sahiptir. Örneğin Google görselleri kullanır ve "kedi" araması yaparsanız, size kedi resimlerini göstermek için bir resim sınıflandırıcı kullanır. Bu sınıflandırıcılar, denetimli öğrenme olarak bilinen bir paradigma altında eğitilir (Klass, 2019).



Şekil 7: Denetimli Öğrenme Mimari Örneği

Denetimli öğrenmede, kedi resimleri ve bu eğitim örnekleri için beklenen sonucun ne olduğunu açıklayan etiketler gibi çok sayıda eğitim örneğimiz vardır. Örneğin, önceki şekil "kedi" etiketiyle gelirken, bir köpeğin görüntüsü "kedi değil" etiketiyle gelirdi." Bu etiketli eğitim örneklerinden çok sayıda örnek varsa, kedileri diğer tüm köpeklerden ayıran ince istatistiksel kalıpları tespit etmek için bir sınıflandırıcı eğitebilir.


Başka bir örnek vermek gerekirse, öğrenmeyi bir süreç olarak görmek, denetimli öğrenme, "uzmanlık kazanmak için deneyimi kullanma", bir eğitim örneği olan "deneyimin", öğrenilen uzmanlığın uygulanacağı görünmeyen "test örneklerinde" eksik olan önemli bilgileri (örneğin spam / spam olmayan etiketler) içerdiği bir senaryoyu açıklamaktadır. Bu ortamda edinilen uzmanlığın, test verileri için eksik bilgilerin tahmin edilmesi amaçlanmaktadır. Bu gibi durumlarda çevreyi, ekstra bilgileri (etiketleri)



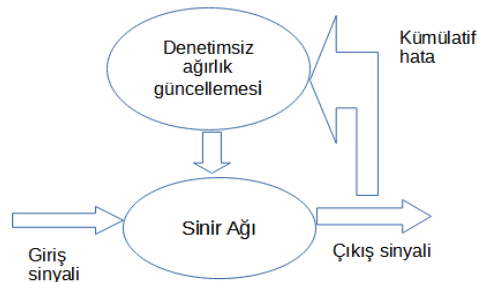
sağlayarak öğrenciyi “denetleyen” bir öğretmen olarak düşünebiliriz. Ancak denetimsiz öğrenmede eğitim ve test verileri arasında bir ayrım yoktur. Öğrenci, bu verilerin bir özetini veya sıkıştırılmış sürümünü bulmak amacıyla girdi verilerini işler. Bir veri kümesini benzer nesnelere alt kümelerine kümelemek, böyle bir görevin tipik bir örneğidir (Shalev-Shwartz & Ben-David, 214 C.E., s.23).

### 2.2.3. Denetimsiz Öğrenme

Denetimsiz bir algoritma sınıflandırılmamış, etiketlenmemiş verilerle çalışır. Etiketsiz veriler arasındaki gizli kalmış örüntüyü bulmaya çalışarak kendi kendine öğrenme biçimi sergilerler. Kümeleme ve ilişkilendirme problemlerinde kullanılmaktadır. Denetimsiz öğrenme, Makine Öğreniminde geniş çapta incelenmiştir. Kümeleme, boyutsallık azaltma veya yoğunluk tahmini algoritmaları, bilgisayarla görme uygulamalarında düzenli olarak kullanılmaktadır (Caron et al., 2018, s.3).



Şekil 8: Kümeleme görseli



**Kaynak:** (Dike et al., 2019, s.324)

Şekil 9. Denetimsiz öğrenme mimari örneği

Kümeleme, veri nesnelерinin (kalıplar, varlıklar, örnekler, gözlemler, birimler) belirli sayıda kümeye (gruplar, alt kümeler veya kategoriler) bölünmesine odaklanır. Özellikle sinirsel temelli olanlar olmak üzere, makine öğrenimi ve hesaplamalı zekâ ile ilgili kümeleme algoritmalarında kullanılmaktadır. Sinir ağıları, iyi öğrenme yetenekleri, adaptasyonları, uygulama kolaylıkları, paralelleştirmeleri, hızları ve esneklikleri ile tanınırlar. Küme analizinde uygulamalar birçok alanda başarılı olduklarını göstermişlerdir (Olivas et al., 2010, s.3). Tablo 5'e baktığımız zaman öğrenme algoritmalarını ve kullanım alanlarını görmekteyiz

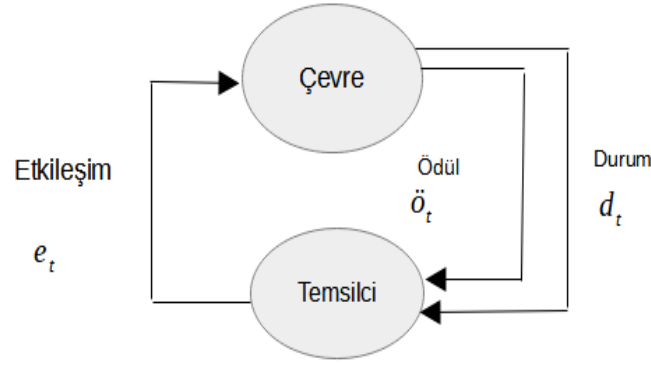
**Tablo 5 : Öğrenme algoritmaları**

<b>Denetimli Öğrenme</b>	<b>Yapay Sinir Ağları</b>	<b>Sınıflandırma ve Regresyon</b>
	Evrişimli Sinir Ağları	Video, Görüntü Tanıma
	Yinelenen Sinir Ağı	Zaman Serisi
<b>Denetimsiz Öğrenme</b>	Özdüzenleyici Haritalar	Özellik Tespiti, Boyut Azaltmak
	Derin Boltzmann Makinesi	Öneriler Sistemi
	Otokodlayıcı	Boyutsallık Azaltma

#### 2.2.4. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, standart denetimden farklıdır. Doğru giriş / çıkış çiftlerinde öğrenme asla sunulmaz veya optimal olmayan eylemler açıkça düzeltilmez. Pekiştirmeli öğrenme robot kontrolü, asansör planlaması, telekomünikasyon, tavla ve dama gibi çeşitli problemlere başarıyla uygulanmıştır. Ayrıca rakibe karşı oynanarak oyun oynamayı öğrenmek örneği verilmektedir. Performansı optimize etmek için örneklerin kullanılması ve büyük ortamlarla başa çıkmak için işlev yaklaşımının kullanılması bu öğrenme türünü başarılı kılmaktadır (Kaelbling et al., 1996, s.239).

Pekiştirmeli öğrenme sorunu bir ortamdan ve seçilen bir politikaya dayalı olarak çevre ile etkileşim kurmak için harekete geçen tek veya birden çok aracından oluşur. Her etkileşimden sonra, temsilci çevreden bir geri bildirim (ödül) alır ve durumunu günceller (Amiri et al., 2018, s.3).



**Kaynak:** Amiri et al., s.4

**Şekil 10.** Pekiştirmeli öğrenme mimarisi

Makine öğrenimi alanında, bir aracının tek geri bildirim ölçülebilir bir ödül sinyalinden oluştuğu bir ortamda nasıl davranacağını öğrenmesini sağlamayı amaçlayan genel bir algoritma sınıfıdır. Denetimli öğrenmeye kıyasla öğrenme sisteminin pekiştirmeli öğrenmede aldığı geri bildirim miktarı çok daha azdır. Denetimli öğrenmede, her öğrenme örneği için doğru çıktı bir eğitim setinde verilir. Öğrenme sisteminin performansı, doğru cevapların sayısına göre ölçülebilir ve bu da öngörücü bir doğrulukla sonuçlanır. Zorluğu ise, bu haritalamayı öğrenmede ve bu haritalamanın yeni, sınıflandırılmamış örneklerle genellenip genellenmemesinde yatmaktadır. Denetimsiz öğrenmede zorluk gibi sınıflar, doğal olarak ortaya çıkan verilerin yararlı bir bölümlenme oluşturmasında yatıyor. Pekiştirmeli ya da takviyeli öğrenmede ise performans hakkında yalnızca bir sayısal sinyal şeklinde bazı bilgiler mevcuttur. Geri bildirim sistemi öğretici olmaktan çok değerlendircidir. Bu sınırlı sinyali geri bildirim için kullanmak, öğrenme sırasındaki davranışı değerlendirmek ve iyileştirmek için daha fazla çaba sarf etme ihtiyacını doğurmaktadır (Otterlo & Wiering, 2012, s.8).

Denetimli öğrenme, hata sinyalleri yardımıyla iç bağlantı ağırlığı kombinasyonlarını ayarlayarak öğrenirken, denetimsiz öğrenme bir grup nöronla ilişkili bilgileri kullanır. Pekiştirmeli öğrenme ise yerel ağırlık parametrelerini değiştirmek için pekiştirme işlevini kullanmaktadır (Sathya & Abraham, 2013, s.35).

### 2.3. Yapay Sinir Ağları (Ann)

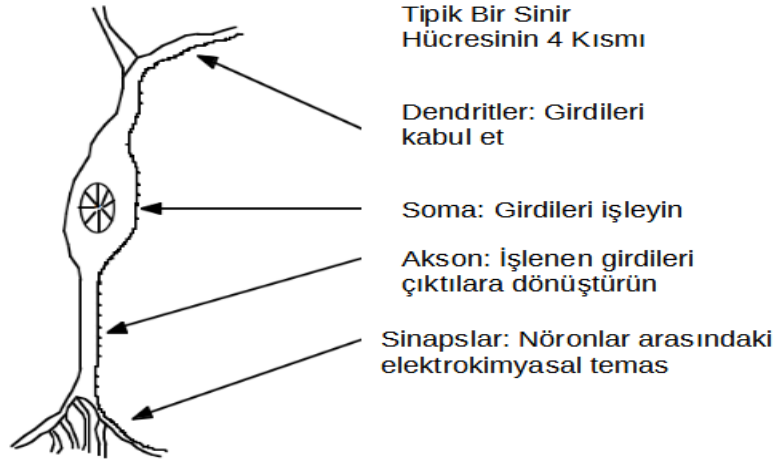
Yapay sinir ağları, girdi-çıkı modelleri sınıfıdır. Bu ağlar deneme yanılma süreciyle öğrenme yeteneğine sahiptir. Ekonometrik açıdan yapay sinir ağı modelleri, belirli bir doğrusal olmayan parametrik model sınıfını oluşturur. "Öğrenme" model parametrelerinin istatistiksel tahminine karşılık gelmektedir (Kuan & White, 1994, s.141) .

Günümüzde sosyal bilimler alanında olduğu gibi dış ticarete de tahminler için birçok farklı yöntem yapılmaktadır. Son dönemlerde bu yöntemlere alternatif olarak geliştirilen yapay sinir ağları modelleri, en düşük hata yüzdesi ile gerçeğe en yakın tahmin değerlerini vererek analiz yöntemi olarak kullanılabilir. YSA' lar insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler üretebilme, keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir. Yapay sinir ağları makine öğrenmesi gerçekleştirirler ve örnekleri kullanarak öğrenirler. Güvenle çalıştırabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir. Eksik bilgi ile çalışabilme ve belirsiz tam olmayan bilgileri işleyebilme avantajları bulunmaktadır (Öztemel, 2022, s15).

YSA'lar evrensel işlevsel tahmincilerdir. Yapay sinir ağları, geleneksel istatistiksel yöntemlerle etkili bir şekilde başa çıkabileceğinden daha genel ve esnek işlevsel biçimlere sahiptir. Herhangi bir tahmin modeli, girdiler (zaman serisinin geçmiş değerleri ve/veya diğer ilgili değişkenler) ve çıktılar (gelecekteki değerler) arasında temel (bilinen veya bilinmeyen) bir ilişki olduğunu varsayar. Genellikle geleneksel istatistiksel tahmin modellerinin, gerçek sistemin karmaşıklığından dolayı bu temel işlevi tahmin etmede sınırlamaları vardır. YSA'lar bu işlevi tanımlamak için iyi bir alternatif yöntem olabilir (G. Zhang et al., 1998, s.35).

Bir sinir ağının temel işleme unsuru bir nörondur. İnsan bilincinin bu yapı taşı, birkaç genel yeteneği kapsar. Temel olarak, biyolojik bir nöron diğer kaynaklardan girdi alır, bunları bir şekilde birleştirir, sonuç üzerinde genellikle doğrusal olmayan bir işlem gerçekleştirir ve ardından nihai sonucu verir. Şekil 11 bu dört parçanın ilişkisini göstermektedir. İnsanlarda bu temel nöron türünde, insanın düşünme sürecini elektriksel olarak çoğaltma girişimlerini daha da karmaşık hale getiren birçok varyasyon vardır. Yine de tüm doğal nöronlar aynı dört temel bileşene sahiptir. Bu bileşenler dendritler,

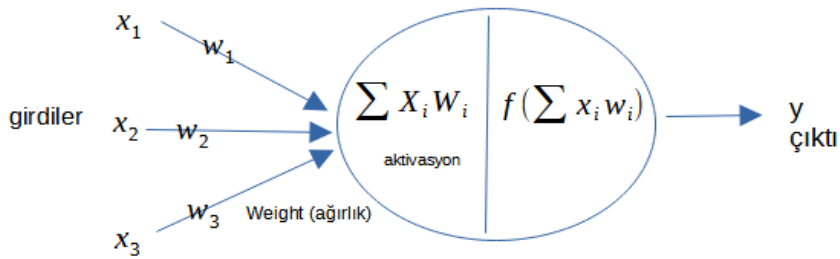
soma, akson ve sinapslar olarak biyolojik isimleriyle bilinmektedirler. Dendritler, soma'nın giriş kanalları gibi davranan saç benzeri uzantılarıdır. Bu giriş kanalları girdilerini diğer nöronların sinapslarından alır. Soma daha sonra bu gelen sinyalleri zaman içinde işler. Soma daha sonra işlenen değeri akson ve sinapslar yoluyla diğer nöronlara gönderilen bir çıktıya dönüştürür (Anderson & McNeill, 1992, s.2).



**Kaynak:** Anderson and McNeill, 1993, s.3

**Şekil 11:** Basit bir nöron gösterimi

Yapay nöron, biyolojik nöronun işlevini simüle etmek için tasarlanmış YSA'nın yapı bileşenidir. Girişler olarak adlandırılan, bağlantı ağırlıkları (ayarlanmış) ile çarpılan gelen sinyaller önce toplanır (birleştirilir) ve ardından o nöronun çıktısını üretmek için bir transfer fonksiyonundan geçirilir. Aktivasyon fonksiyonu, nöronun girdilerinin tartılmış toplamıdır ve en yaygın kullanılan transfer fonksiyonu sigmoid fonksiyonudur. Şekil 12'de YSA modeli verilmiştir (Agatonovic-Kustrin & Beresford, 2000, s.718).



**Kaynak:** Agatonovic and Beresford, 2000, s.719

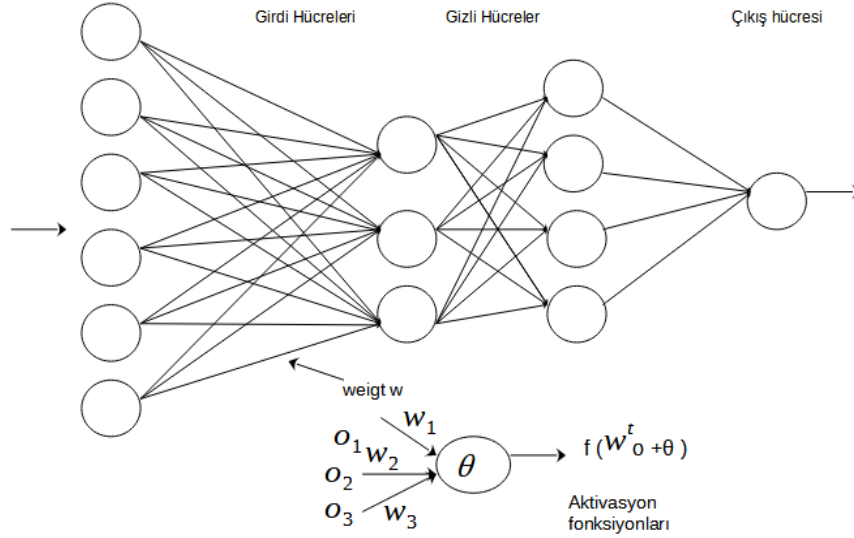
**Şekil 12:** Yapay bir nöron modeli

Tahmin ve değerlendirme modelleri oluşturmak için uygulanan YSA, “birçok değişkenli bilgi alanından diğerine, bu haritalamayı temsil eden bir dizi veri verildiğinde, elde edebilen, temsil edebilen ve şekil verebilen bir hesaplama mekanizması” olarak tanımlanmaktadır. YSA, katmanlar halinde gruplandırılmış, birbirine bağlı birçok nöronun (birbirine bağlı işlem elemanlarından) oluşur. Genellikle YSA'nın giriş, gizli ve çıkış katmanları olmak üzere üç tür katmanı vardır. Giriş katmanı, sorgulamayla ilgili verileri dışarıdan alır. Gizli katmanlar verinin transfer edildiği katmandır. Gizli katman(lar) dışarıya bağlanmaz ancak diğer katmanlara bağlanır. Çıktı katmanı sonucu dışarıya gönderir. Ağ türleri, katman sayısına (tek katmanlı ve çok katmanlı ağlar), nöronlar arasındaki bağlantı türüne (katmanlı, tam bağlantılı ve hücrese) ve öğrenme sürecine (ileri besleme ve geri besleme) göre sınıflandırılır (Alaloul et al., 2018, s.7).

### **2.3.1. İleri Beslemeli Sinir Ağı**

Tek nöronlar doğrusal algılayıcılardan daha güçlü olsalar da karmaşık öğrenme problemlerini çözecek kadar etkileyici değildirler. Beynimizin birden fazla nöronun oluşmasının bir nedeni vardır. Örneğin, tek bir nöronun el yazısıyla yazılmış rakamları ayırt etmesi imkansızdır. Bu yüzden çok daha karmaşık görevlerin üstesinden gelmek için makine öğrenimi modelimizin daha da ileri götürülmesi gerekmektedir (Buduma & Locascio, 2017, s.19).

Nöronların katmanlar halinde gruplandığı ve yalnızca ileri bağlantıların var olduğu en popüler yapay sinir ağı mimarilerinden biridir (Mendes et al., 2002) . İleri besleme aşamasında, giriş katmanı nöronu giriş deseni değerini gizli katmana geçirir. Gizli katman nöronlarının her biri, girdisinin ağırlıklı bir toplamını hesaplar ve toplamı etkinleştirme işlevinden geçirir ve etkinleştirme değerini çıktı katmanına sunar. Katmanlar arasındaki ağırlıklar başlangıçta küçük rastgele değerlerdir. Çıktı katmanındaki her nöronun ağırlıklı toplamının hesaplanmasının ardından, toplam aktivasyon fonksiyonundan geçirilerek ağ için çıktı değerlerinden biri elde edilir (Arslan & Ince, 1996, s.250) . Şekil 13'te bir girdi verildiğinde, nöronların art arda kendi aktivasyonlarını hesapladığı görülmektedir.



**Kaynak:**(Hammer, 2000, s.6)

**Şekil 13:** Çok katmanlı bir yapıya sahip bir ileri besleme ağı

$w_{ij} \in \mathbb{R}$ ,  $w$  tüm ağırlıkların vektörüdür. Ön işlemcisz nörönlara giriş nörönlari denir ve  $I$  kümesini oluşturur. Diğer tüm nörönlara hesaplama birimleri denir. Hesaplama birimlerinin boş olmayan bir alt kümesi belirtilir ve  $O$  ile gösterilen çıktı birimleri olarak adlandırılır. Çıktı nörönlari olmayan tüm hesaplama birimlerine gizli nörönlari denir. Her hesaplama birimi  $i$ , bir bias  $\theta_i \in \mathbb{R}$  ve bir etkinleştirme işlevi  $f_i : \mathbb{R} \rightarrow \mathbb{R}$  ile donatılmıştır.  $\theta$  ve  $f$  karşılık gelen vektörlerdir. *w.l.o.g.C*  $NCN$  ve girdi nörönlari  $\{1, \dots, m\}$ .

Fonksiyondaki  $m$  girişleri ve  $n$  çıkışları olan bir ağı işlevi hesaplar.

$$f : \mathbb{R}^m \rightarrow \mathbb{R}^n, f(x_1, \dots, x_m) = (o_{i_1}, \dots, o_{i_n}) \quad \text{Denklem 5}$$

$i_1, \dots, i_n$  çıktı birimleridir ve  $o_i$  nörön  $i$  tarafından herhangi biri için özyinelemeli olarak tanımlanır.

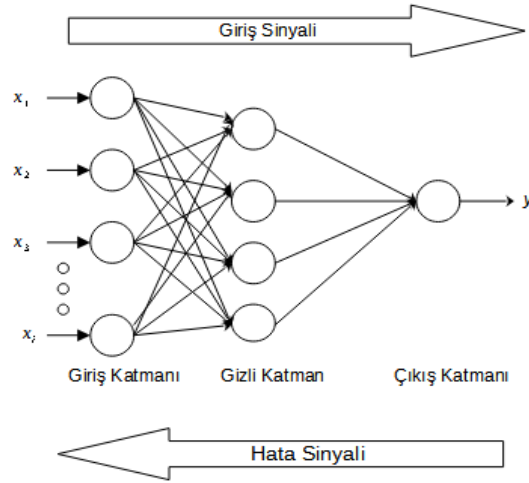
$$o_i = \begin{cases} x_i \\ f_i(\sum_{j \rightarrow i} w_{ji} o_j + \theta_i) \end{cases} \quad \begin{array}{|l} i \text{ aksi halde bir} \\ \text{girdi birimiyse,} \end{array}$$

$\sum_j w_{j \rightarrow i} o_j + \theta_i$  terimine nörön  $i$ 'nin aktivasyonu denir (Hammer, 2000, s.7)

Denklem 7

### 2.3.2. Geri Yayılım Ağı

Geri yayılma algoritması, yapay nöronların katmanlar halinde düzenlendiği ve sinyallerini “ileri” gönderdiği ve ardından hataların geriye doğru yayıldığı anlamına gelmektedir. Ağ, girdi katmanındaki nöronlar tarafından girdiler alır ve ağın çıktısı bir çıktı katmanındaki nöronlar tarafından verilir. Bir veya daha fazla ara gizli katman olabilir. Geri yayılma algoritması denetimli öğrenmeyi kullanır, bu da algoritmaya ağın hesaplamasını istediğimiz girdi ve çıktıların örneklerini verdikten sonra hatanın (gerçek ve beklenen sonuçlar arasındaki fark) hesaplandığı anlamına gelmektedir. Geri yayılma algoritmasının fikri, YSA eğitim verilerini öğrenene kadar bu hatayı azaltmaktır. Eğitim rastgele ağırlıklarla başlar ve amaç onları hatanın minimum olacağı şekilde ayarlamaktır (Dongare et al., 2008).




**Kaynak:** (J. Yang et al., 2008, s.12)

**Şekil 14:** Üç katmanlı geri yayımlı sinir ağı

Sıklıkla kullanılan bir ağ yapısı olan geri yayılım algoritması, ağ ağırlıklarının, performans fonksiyonunun negatif gradyanı yönünde ilerlediği gradyan iniş algoritmasıdır. Birçok çeşidi olan geri yayılım algoritması, gradyan iniş ve Newton metodu gibi standart optimizasyon yöntemlerine dayanmaktadır (Hamzaçebi & Kutay, 2004, s.229). Geri yayılım, sinir ağının her bir katmanı aracılığıyla yinelemeli olarak yapılır. Maliyet için ağırlıklı toplam ve aktif ağırlıklı toplam denklemleri türetilmiştir. Kavram kanıtı için maliyet işlevi basitleştirilmiştir (Prado, 2018, s.).





**Şekil 15:** Geri Yayılım Ağı örneği

$$R^L = W^L a^{L-1} + b^L$$

$$a^L = \sigma(Z^L)$$

$$P = (a^L - y)^2 \quad \text{Denklem 6}$$

Maliyet fonksiyonunun tek bir ağırlıktaki değişikliklere ne kadar duyarlı olduğunu belirleyebiliriz. Başlangıç çıktıdan, zincir kuralını her aktivasyon katmanına uygulayabiliriz. Bir ağırlık için gizli katman ve çıktı katmanı türevimiz:

$$\frac{\partial p_k}{\partial w^L} = \frac{\partial r^L}{\partial w^L} \frac{\partial a^L}{\partial r^L} \frac{\partial p_k}{\partial a^L} \quad \text{Denklem 7}$$

Fonksiyonların tanımı ile kısmi türevler için kolayca çözebiliriz:

$$\frac{\partial p_k}{\partial a} = 2(a^L - y)$$

$$\frac{\partial a^L}{\partial r^L} = \sigma'(r^L)$$

$$\frac{\partial r}{\partial w^L} = a^{L-1}$$

$$\frac{\partial p_k}{\partial w^L} = a^{L-1} \sigma'(r^L) 2(a^L - y) \quad \text{Denklem 10}$$

Bu yöntem, sistemdeki her ağırlık, etkinleştirme numarası ve biası boyunca yinelenir. Daha önce, belirli bir maliyet fonksiyonunun türevini bir değişkenle hesaplamıştık. Bununla birlikte, bu katmandaki her ağırlığı hesaba katmak için türevlerin ortalaması alınır:

$$\frac{\partial p}{\partial w^L} = \frac{1}{n} \sum_{k=0}^{n-1} \frac{\partial P_k}{\partial w^L} \quad \text{Denklem 11}$$

Benzer şekilde, maliyet fonksiyonunun, gizli katman ile çıktı katmanı arasındaki tek bir yanlılığa göre duyarlılığını ve bir katmandaki her yanlılığı hesaba katan türevi hesaplayabiliriz:

$$\frac{\partial p_k}{\partial b^L} = \frac{\partial r^L}{\partial b^L} \frac{\partial a^L}{\partial r^L} \frac{\partial p}{\partial a^L} \sigma'(r^L) 2(a^L - y) \quad \frac{\partial r}{\partial b^L} = \frac{1}{n} \sum_{k=0}^{n-1} \frac{\partial r_k}{\partial b^L} \quad \text{Denklem 12}$$

Çıktı katmanının ve önceki gizli katmanın ötesine geçtiğimizde zincir kuralı bir kez daha uygulanır ve türev hesapta kısmi olarak değişir. Örneğin, aşağıdaki türev, bir girdi etkinleştirme numarasına göre maliyet işlevinin kısmi değerlerini açıklar.

$$\frac{\partial p_k}{\partial a^{L-1}} = \frac{\partial r^L}{\partial a^{L-1}} \frac{\partial a^L}{\partial r^L} \boldsymbol{\theta} = \mathbf{w}^L \boldsymbol{\sigma}'(r^L) 2(a^L - y) \quad \text{Denklem 13}$$

Sinir Ağları birkaç bin girdiye, çıktıya ve düğüme sahip olma eğilimindedir. Karmaşıklık eklemek formülleri biraz değiştirirse de kavramlar aşağıda görüldüğü gibi aynı kalmaktadır.

$$P_m = \sum_{j=0}^{n_{L-1}} (a_j^L - y_j)^2$$

$$a_j = \sigma(r_j^L)$$

$$r_j^L = \dots + w_{jk}^L a_k^{L-1} + \dots$$

$$\frac{\partial p_m}{\partial w_{jk}^L} = \frac{\partial r_j^L}{\partial w_{jk}^L} \frac{\partial a_j^L}{\partial r_j^L} \frac{\partial p_m}{\partial a_j^L}$$


$$\frac{\partial p_m}{\partial a^{L-1}} = \sum_{j=0}^{n_{L-1}} \frac{\partial r_j^L}{\partial a_k^{L-1}} \frac{\partial a_j^L}{\partial r_j^L} \frac{\partial p_m}{\partial a_j^L} \quad \text{Denklem 14}$$

### 2.3.3. Evrişimli Sinir Ağı (CNN)

Bir Evrişimli Sinir Ağı (CNN), görsel görüntüleri analiz etmek için en yaygın olarak uygulanan derin, ileri beslemeli yapay sinir ağlarının bir sınıfıdır. Evrişimsel sinir ağları, biasları ve öğrenilebilir ağırlıkları olan nöron yığınlarından oluştuğu için normal derin ağa çok benzemektedir. Bu ağda bulunan her nöronda girdilerin alındığı, nokta çarpımlar gerçekleştirdiği ve isteğe bağlı olarak doğrusal olmayan bir şekilde takip ettiği belirtilmelidir. ConvNet'in geleneksel nöral ağ yapısı, genellikle çeşitli derin öğrenme sorunları için kullanılmaktadır. Yapıları nedeniyle nesne tanıma nesnelere bölümlenme, algılama ve bilgisayar görüşü için evrişimli sinir ağları kullanılır. Aslında doğrudan görüntü tarihi öğrenir, bu nedenle normal derin nöral ağlarda yaygın olarak kullanılan manuel özellik çıkarma işlemi yapmak gerekmemektedir.

Evrişimli sinir ağlarının kullanımı, üç ana faktörden dolayı popüler hale gelmiştir. Bunlardan ilki, tüm veri özellikleri doğrudan evrişimli sinir ağları tarafından öğrenildiği için manuel veri çıkarma ihtiyacını ortadan kaldıran evrişimli sinir ağlarının yapısıdır. Artan popüleritesinin ikinci nedeni, son teknoloji nesne tanıma sonucu üretmeleridir. Üçüncü nedeni ise diğer derin sinir ağlarının oluşturulmasına yardımcı olmak için birçok yeni nesne tanıma görevi için evrişimli sinir ağlarının kullanabilmesidir (Millstain, 2018, s.36). CNN'lerin en faydalı yönü YSA'daki parametre sayısını azaltmasıdır. CNN'nin bir diğer önemli yönü, girdi daha derin katmanlara doğru yayıldığında soyut özellikler elde etmektir (Albawi et al., 2018, s.1).

Sinir ağının önemli bir dalı olan CNN alıcı alan kavramını ve paylaşılan ağırlıkları artırır, bu da sadece parametrelerini büyük ölçüde azaltmakla kalmaz aynı zamanda ağ modelinin karmaşıklığını da azaltır. Her katmanın özellikleri öncekinden oluşturulmaktadır. Tipik CNN yapısı esas olarak giriş katmanı, kıvrımlı katman, havuz katmanı tam bağlantı katmanı ve çıkış katmanından oluşmaktadır (Zhiqiang & Jun, 2017, s.11105). Konvolüsyon matrisleri görüntü işleme ve tasarımda uygulanmaktadır. Bir giriş görüntüsü olduğunda, bir konvolüsyon katmanı uygulanır sonra uygulanan RELU veya rektifiye edilmiş doğrusal birim fonksiyonu ile havuzlama uygulanmaktadır. YSA için giriş katmanı olacak uzun bir vektör halinde düzleştirilmektedir.



**Kaynak:** Zhiqiang and Jun, 2017, s. 11105

**Şekil 16:** Evrişimli Sinir Ağı mimarisi

#### 2.3.4. Yinelemeli Sinir Ağı (RNN)

Yinelemeli bir sinir ağı, seri verilerle ilgilenen bir tür sinirsel bilgi işlem mimarisidir. Derin ileri mimarilerden farklı olarak, yalnızca giriş kalıplarını çıktı

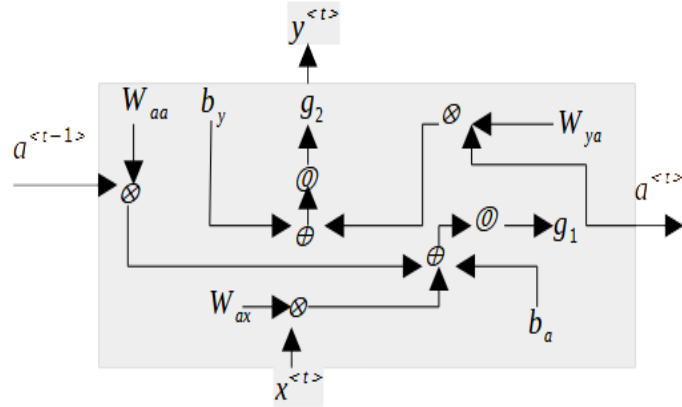
sonuçlarıyla eşleştirmekle kalmaz, aynı zamanda gizli durumları gizli birimler arasındaki bağlantıları kullanarak çıktılar. Bu gizli bağlantıları kullanarak, RNN modelleri zamansal bağımlılık, zaman boyutu boyunca nesnelere arasında parametrelerin paylaşılmasıyla sonuçlanır. Konuşma analizi, resim yazısı ve dil çevirisi gibi çeşitli alanlarda uygulanarak daha iyi performans elde edilmiştir. Derin ileri mimarilere benzer şekilde, hesaplaması aynı zamanda ileri geçiş ve geri yayılma aşamalarından oluşmaktadır. İleri geçişli hesaplamada, RNN hem girişi hem de gizli durumu alır. Geri yayılım hesaplamasında, zaman adımları boyunca kaybı geri yaymak için geri yayılım-zaman algoritmasını kullanır (Gao et al., 2020, s.843).

RNN' ler, döngüsel bağlantılar içeren sinir ağlarıdır. Bu döngüsel bağlantılar, geçmişin korunmasına izin verir ve değişken uzunluklu dizilerin modellenmesi için çok uygundur (Godin et al., 2018, s.9). Dizi problemleri için tasarlanmış özel bir sinir ağı türüdür. Standart bir ileri beslemeli çok katmanlı algılayıcı ağ verildiğinde tekrarlayan sinirsel ağ, mimariye döngülerin eklenmesi olarak düşünülebilir. Örneğin, belirli bir katmanda, her nöronu bir sonraki katmana iletmenin yanı sıra sinyalinin daha sonra (yana doğru) iletebilir. Ağın çıktısı, bir sonraki giriş vektörü ile ağa bir giriş olarak geri bildirim verebilir. Yinelenen bağlantılar ağa durum veya bellek ekler ve giriş dizilerinden daha geniş soyutlamalar öğrenmesine izin verir. Yinelenen sinir ağları, zaman içinde ağlara geri bildirim ve bellek ekleyen döngüleri olan bağlantılara sahiptir. Bu bellek, bu tür bir ağın bireysel kalıplardan ziyade girdi dizileri arasında öğrenmesine ve genellemesine izin vermektedir (Brownlee, 2016, s.170).

Bu ağlar, gizli durumlara sahipken önceki çıktılarının girdi olarak kullanılmasına izin veren bir sinir ağları sınıfıdır. Her bir  $t$  zamanında,  $a^{<t>}$  aktivasyonu ve  $y^{<t>}$  çıktısı aşağıdaki gibi ifade edilir:

$$a^{<t>} = g_1(W_{aa}a^{<t-1>} + W_{ax}x^{<t>} + b_a) \text{ ve } y^{<t>} = g_2(W_{ya}a^{<t>} + b_y) \text{ Denklem 15}$$

$W_{ax}, W_{aa}, W_{ya}, b_a, b_y$  geçici olarak paylaşılan katsayılarıdır ve  $g_1, g_2$  aktivasyon fonksiyonlarıdır.



**Kaynak:** Amidi & Amidi, 2022

**Şekil 17:** Yinelemeli Sinir Ağ yapısı

Herhangi bir uzunluktaki girdilerin işlenmesi imkânı, girdi büyüklüğüyle artmayan model boyutu, geçmiş bilgileri dikkate alarak hesaplama, zaman içinde paylaşılan ağırlıklar gibi avantajları vardır. Yavaş hesaplama, uzun zaman önceki bilgiye erişme zorluğu, mevcut durum için gelecekteki herhangi bir girdinin düşünülmemesi gibi dezavantajları bulunmaktadır (Amidi & Amidi, n.d., 2022).

Geleneksel RNN modelinin ortak dezavantajı şudur: zaman adımları arttıkça, ağ önceki durumların çok gerideki zaman adımlarından bağlam türetemez, bu uzun vadeli bağımlılık olarak bilinmektedir. Bir ağın derin katmanları ve tipik RNN'nin tekrarlayan davranışı nedeniyle, patlayan ve kaybolan gradyanlar problemlerine de oldukça sık rastlanılmaktadır (Lynn et al., 2019, s.14537).

Kaybolan (patlayan) gradyan sorununun üstesinden gelmek için, gradyanın çarpımsal etkisini kesmek gerekmektedir. Bir LSTM hücresi ve Kapılı Tekrarlayan Birim (GRU) bunu yapmaktadır (Troiano et al., 2020, s.97) .

### 2.3.5. Uzun Kısa Süreli Bellek (LSTM)

Uzun bir süre boyunca, yinelenen sinir ağlarının (RNN'ler) teorik olarak büyüleyici olduğu düşünülüyordu. Standart ileri beslemeli ağlardan farklı olarak RNN'ler, yalnızca statik giriş verileri yerine rastgele giriş dizileriyle ilgilenebilir. Bu, ilgili olayları zaman içinde ezberleme yeteneği ile birleştiğinde, tekrarlayan ağları prensipte standart ileri beslemeli ağlardan daha güçlü hale getirmektedir. Potansiyel uygulamalar

kümesi çok büyüktür. Belleğin nasıl kullanılacağını öğrenmeyi gerektiren herhangi bir görev, tekrarlayan ağlar için potansiyel bir görevdir. Potansiyel uygulama alanları arasında zaman serisi tahmini, ritim algılama (müzik ve konuşmada) bulunmaktadır. Bu uygulamalarda uzun zaman aralıklarında bilgi depolamayı öğrenmek için geleneksel gradyan tabanlı tekrarlayan ağ algoritmaları çok uzun sürmektedir. Bu başarısızlığın ana nedeni, geri yayılan hatanın hızla azalmasıdır. "Uzun Kısa Süreli Bellek" (LSTM) algoritması, sabit hata akışını uygulayarak bu ve ilgili sorunların üstesinden gelmektedir. Gradyan inişini kullanan LSTM, bilgilerin ne zaman saklanacağını ve ne zaman erişileceğini açıkça öğrenmektedir (Gers, 2001, s.2).

Yinelenen Sinir Ağları, gizli katmanlar arasında geri bildirim izin veren RNN'lerdir. Girdi dizilerini işlemek için dahili durumlarını (bellek) kullanabilir. Ele alınan çerçevede, genel bir RNN şu şekilde yazılabilir:

$$\mathbf{H}_t = f(\mathbf{H}_{t-1}, \mathbf{X}_t), \quad \text{Denklem 8}$$

$$\hat{Y}_{t+h/t} = g(H_t)$$

Burada  $\hat{Y}_{t+h/t}$ , yalnızca zamana kadar gözlemler verildiğinde  $Y_{t+h}$ 'nin tahminidir  $t$ ,  $f$  ve  $g$  tanımlanacak işlevlerdir ve  $h_t$ ,  $k$  boyutlu (gizli) durum dediğimiz şeydir. Zaman serisi perspektifinden bakıldığında, RNN'ler bir tür doğrusal olmayan durum-uzay modeli olarak görülebilmektedir.

RNN'ler, girdilerin gizli durumu (bellek) aracılığıyla görünme sırasını hatırlayabilir ve ayrıca veri dizilerini modelleyebilir. Böylece her numunenin zaman serisi modellerinde olduğu gibi öncekilere bağlı olduğu varsayılabilir. Bununla birlikte, kaybolan / patlayan gradyan probleminden muzdarip oldukları için RNN'lerin tahmin edilmesi zordur. Her tahmin penceresi için maliyet işlevinin şu şekilde ayarlanması gerekmektedir.

Burada  $\theta$ , tahmin edilecek parametrelerin vektörüdür.  $\frac{\sigma\theta(0)}{\sigma\theta}$  gradyanının çok küçük veya farklı olabileceğini göstermek kolaydır. Çıkış kapısı,  $t$  zamanında LSTM bloğunun son çıkışına aktivasyonu sağlamaktadır. Genellikle, gizli durumun ( $H_t$ ) boyutu, gizli nöronların sayısı ile ilişkilidir. RNN olarak adlandırılan sinir ağının bir varyantı Uzun-Kısa Süreli Bellek (LSTM) ağıdır.

Algoritma LSTM hücresinin nasıl çalıştığını analitik olarak açıklamaktadır.  $f_t$  unutmaya kapısının çıktısını temsil etmektedir. Önceki gizli durumun  $H_{(t-1)}$  yeni bilgilerle ( $X_t$ ) birleşimidir.  $f_t \in [0,1]$  olduğunu ve  $c_{t-1}$ 'den gelen sinyali zayıflatmaktadır. Giriş ve çıkış kapıları aynı yapıya sahiptir. İşlevleri, yeni girdinin yanı sıra önceki zaman dilimindeki 'ilgili' bilgileri de çevirmektir.  $P_t$  girdilerin ve önceki bilgilerin birleşimini ölçeklendirir. Bu sinyal daha sonra giriş kapısının ( $i_t$ ) çıkışı ile birleştirilir. Yeni gizli durum, çıkış kapısından gelen sinyalin zayıflamasıdır. Son olarak, tahmin, gizli durumların doğrusal bir kombinasyonudur. RNN' ler aşağıdaki algoritma ile tanımlanabilir (Chan & Mátyás, n.d., s.136).

1.  $c_0 = 0$  ve  $H_0 = 0$  ile başla.
2.  $X_t$  girişi verildiğinde  $t \in \{1, \dots, T\}$  için, yapılan:
 
$$f_t = \text{Lojistik}(W_f X_t + U_f H_{t-1} + b_f)$$

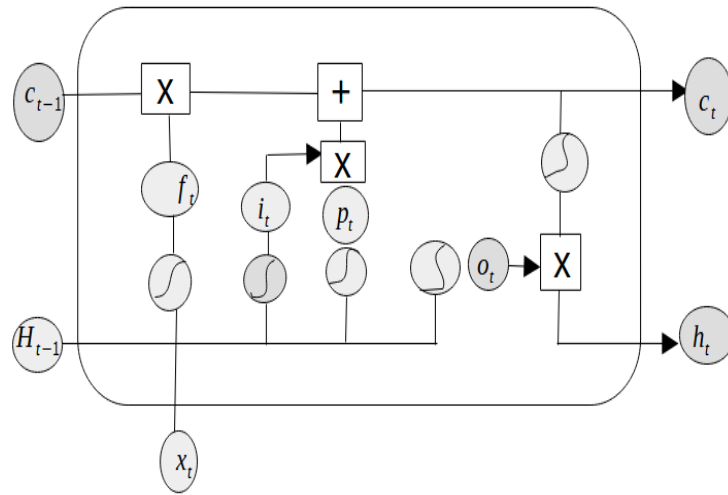
$$i_t = \text{Logistik}(W_i X_t + U_i H_{t-1} + b_i)$$

$$o_t = \text{Logistik}(W_o X_t + U_o H_{t-1} + b_o)$$

$$p_t = \text{Tanh}(W_c X_t + U_c H_{t-1} + b_c)$$

$$c_t = (f_t \otimes c_{t-1}) + (i_t \otimes p_t)$$

$$H_t = o_t \otimes \text{Tanh}(c_t)$$



**Kaynak:** Asokan,2022, s.18

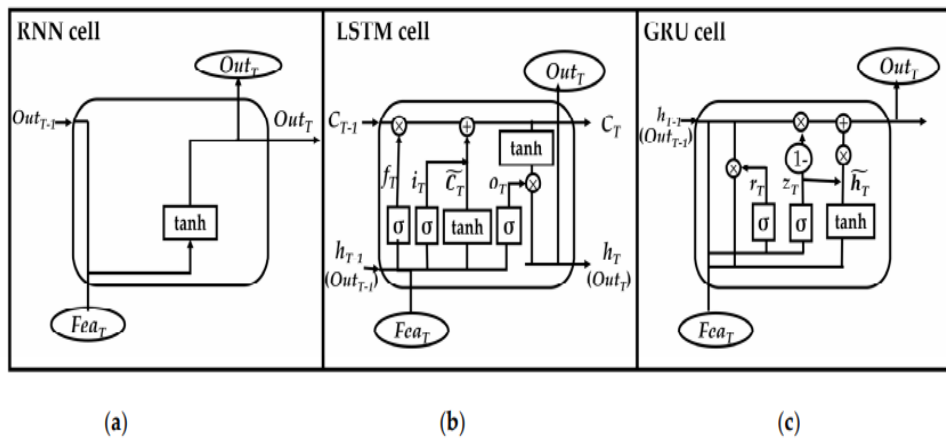
**Şekil 18:** LSTM hücresinin mimarisi

LSTM' in en önemli anlayışı, hücrenin durumu ve kapılarıdır. Bu hücre durumu, göreceli bilgileri dizi zincirinden aşağı ileten bir taşıma izi görevi görmektedir. Bu, ağın "belleği" olarak görülebilir. Önermedeki hücre durumu, dizinin işlenmesi boyunca uygulanabilir bilgileri taşıyabilir. Bu nedenle, daha önceki zamanlardan gelen bilgiler, kısa süreli belleğin mallarını azaltarak zaman yolundan sonra yol alabilir. Hücre durumu yolculuğuna devam ettikçe, bilgi aracılığıyla hücre durumuna eklenir veya kaldırılır. Kapılar, hücre durumunda hangi bilgilere izin verilip verilmediğine karar veren farklı sinir ağlarıdır. Eğitim sürecinde kapılar hangi bilgileri öğrenmek, saklamak ya da unutmak için uygundur (Asokan, 2022, s.18).

### 2.3.6. Kapı Özyinelemeli Geçit (Gru)

GRU, LSTM performansını korurken LSTM ağ yapısını optimize eden LSTM tabanlı bir modeldir. LSTM ağ yapısı ile karşılaştırıldığında, GRU ağı, uzun aralıklı uzun gecikme süresi serilerinin tahmin problemini çözebilen, güncelleme kapısı ve sıfırlama kapısı dahil olmak üzere yalnızca iki kapı yapısına sahip olan bir ağıdır. Güncelleme kapısı, önceki anın bilgilerinin şimdiki ana ne ölçüde getirildiğini kontrol etmek için kullanılmaktadır. Sıfırlama kapısı, bir önceki anın bilgisini göz ardı etme derecesini kontrol etmek için kullanılır (W. Li et al., 2021, s.187).

Kapı özyinelemeli geçitlerde hücre durumundan kurtulması ve bilgi aktarmak için gizli durumu kullanmaktadır. İki kapı, bir sıfırlama kapısı ve güncelleme kapısı vardır:



**Kaynak:** Li et al., 2020, s.6

**Şekil 19:** (a)RNN (b)LSTM (c)GRU



T-1 ( $h_{T-1}$ ) zaman adımının çıktısı, zaman adımı girişi  $T(Fea_t)$  hücreye girer. Burada  $\sigma$  sembolü, 0 ile 1 arasında sayıları veren bir sigmoid katmanı temsil eder ve şu şekilde verilir:  $\sigma(x) = (1 + e^{-x})^{-1}$ . 0, "hiçbir şeyin geçmesine izin verme" anlamına gelirken, 1, "her şeyin geçmesine izin verme" anlamına gelmektedir. Üç kapıda önemli bir rol oynamaktadır (Li et al., 2020, s.6).



### 2.3.7. NARX Sinir Ağı

NARX (Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ) bir dinamik yapay sinir ağ modeli olarak bilinmektedir. Çoğunlukla doğrusal olmayan sistemlerde girişlerin ve çıkışların modellenmesinde kullanılmaktadır (İşler & Aslan, 2021, s. 1869). Dinamik sinir ağları, zaman serisi tahmininde iyidir. Zaman serisi tahminleri için ileri besleme zaman gecikmesi şeklinde tasarlanarak uygulanabilir. NARX modelinde 2 çeşit geri bildirim kullanımı vardır: Series-Parallel (SP) Mode: çıkışın geri dönüşümü (regressor) sistemin gerçek çıkış değerlerinden oluşmaktadır. Parallel (P) Mode: çıkışın geri dönüşümü (regressor) sistemin tahmini çıkış değerlerinden oluşmaktadır (Alizadeh, 2011, s. 16).

NARX sinir ağları, dışarıdan girdili, geri beslemeli ve zaman gecikmesine sahip döngü mekanizmalı dinamik sinir ağı olarak oluşmaktadır. "X" dışsal girdileri temsil eder ve tekrarlayan sinir ağlarının içindedir. NARX' in herhangi bir varsayıma ihtiyaç duymadan, doğrusal ve durağan olmayan serileri modelleyebilme özelliği vardır. NARX' in eşitliği aşağıdaki gibidir.

$$y_t = (f(y_{(t-1)}, y_{(t-2)}, y_{(t-3)}, \dots, y_{(t-d)}, x_{(t-1)}, x_{(t-2)}, x_{(t-3)}, \dots, x_{(t-d)}) \text{ Denklem 9}$$


Denklemdaki  $t$  = zaman,  $d$  zamansal gecikme,  $y_{(t-1)}, y_{(t-2)}, y_{(t-3)}, \dots, y_{(t-d)}$  ağ çıktılarını teslim etmektedir.  $x_{(t-1)}, x_{(t-2)}, x_{(t-3)}, \dots, x_{(t-d)}$  ise ağ girdilerini göstermektedir. Başka kullanılan geri beslemeli ağların aksine, NARX ağları bütün gizli katmanlardan değil yalnızca çıktı katmanındaki nöronlardan geribildirim almaktadır. Modelde çıkışa zaman gecikmesi uygulanarak tekrar girdi olarak kullanılmaktadır. Modeldeki bağımlı çıktı değişken  $y(t)$  'nin tahmini için, çıktı değişkeninin önceki değerleri ve bağımsız harici (dışsa) girdi değişkenler birlikte çözümlenmektedir (Sertok, 2022, s.29).



**Kaynak:**(Sertok, 2022, s.30)

**Şekil 20:** NARX Ağlarının paralel mimarisi

Tapped Delay Line: Zamansal gecikme hattı iken  $y(n)$  ve  $u(n)$  vektörleri çıktığı ve girişi gösterir.



**Kaynak:** (Lin et al., 1996, s.1331)


**Şekil 21:** Dört çıkış gecikmeli bir NARX Ağı

### 2.3.8. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, ağırlıklı girdi ve bias toplamını hesaplamak için sinir ağlarında kullanılan fonksiyonlardır. Bir nöronun ateşlenip ateşlenemeyeceğine karar vermek için kullanılır. Sunulan verileri, genellikle alçalma eğimlerini işleyen bazı

gradyan işlemleri yoluyla manipüle eder ve daha sonra verilerdeki parametreleri içeren sinir ağı için bir çıktı üretmektedir (Nwankpa et al., 2018, s.3).

Bir sinir ağında bir aktivasyon fonksiyonu kullanılmazsa, çıkış sinyali basitçe birinci dereceden bir polinom olan basit bir doğrusal fonksiyon olacaktır. Her ne kadar doğrusal bir denklem basit ve çözülmesi kolay olsa da karmaşıklıkları vardır. Verilerden karmaşık eşlemeleri öğrenme ve tanıma becerisine sahip değildirler. Aktivasyon fonksiyonu olmayan sinir ağı, çoğu zaman sınırlı performans ve güce sahip doğrusal bir regresyon modeli görevi görmektedir. Bir sinir ağının yalnızca doğrusal bir işlevi öğrenmesi ve hesaplaması değil, aynı zamanda görüntüler, videolar, ses, konuşma, metin vb. karmaşık veri türlerini modellemek gibi daha karmaşık görevleri yerine getirmesi hedeflenmektedir. Bu nedenle model, birden fazla gizli katmana sahip olduğu karmaşık, yüksek boyutlu ve doğrusal olmayan veri kümelerini ayrıca bilgiyi çıkarmak için karmaşık bir mimariyi anlamlandıran derin öğrenme gibi aktivasyon fonksiyonlarını ve yapay sinir ağı tekniklerini kullanmaktadır (Sharma et al., 2020, s.311).



**Kaynak:** Li et all. 2020, s. 7

**Şekil 22:** Aktivasyon fonksiyonları


### 2.3.8.1 Sigmoid Fonksiyonu

Sigmoid Fonksiyonu şu şekilde verilir.


$$f(x) = \frac{e^{x_i}}{1+e^{x_i}} = \frac{1}{1+e^{-x_i}} \quad f'(x_i) = \frac{e^{-x_i}}{(1+e^{x_i})^2} \quad \text{Denklem 10}$$

Sigmoid Fonksiyonu doğrusal olmayıp [0,1] aralığındadır ve eğrisi bir S şekline benzemektedir. Monoton olmasına ve çıktısı çok dik olmasına rağmen, girdideki küçük değişiklikler, girdi 0'a yakınken çıktıda büyük değişiklikleri beraberinde getirecektir.

Ancak çıktı her iki ucuna doğru 0 veya 1'e, girişe çok daha az yanıt verir. Yani bu bölgedeki gradyan çok küçük, hatta 0'a yakın olacaktır. Buna "kaybolan gradyanlar" denmektedir. Bu durumda, ağ daha fazla öğrenmeyi reddedecek, nöronun ağırlıklarına ve yinelemeli olarak verilerine neredeyse hiçbir sinyal akmayacaktır. Sigmoid, sınıflandırma problemlerinde, özellikle de sonucun 0 veya 1 olduğu ikili sınıflandırmanın çıktı katmanında hala çok popülerdir. Çünkü sigmoid işlevi yalnızca 0 ile 1 arasında yer alırken, değer 0,5'ten büyükse sonucun 1, aksi takdirde 0 olacağı kolayca tahmin edilebilir (Feng & Lu, 2019, s.4).



(a) Fonksiyon Eğrisi



(b) Türevin Eğrisi

**Kaynak:** (Feng & Lu, 2019, S.2)

**Şekil 23:** Sigmoid fonksiyonu ve türevi

### 2.3.8.2 Tanh Fonksiyonu

LeCun ve arkadaşları tarafından geliştirilen Tanh fonksiyonu, gizli katmanlarda daha verimli olmuştur. Sonuçlar negatif olduğunda sigmoid eksi için bir çözüm olarak

gelir ve sigmoid 0'a yakın bir sonuç üretir. Bu, o gizli katmanla ilişkili zor bir ağırlık değişikliği anlamına gelir. Bu nedenle “ölü” bir düğüm haline gelmektedir. Tanh fonksiyonu sigmoid ile aynı özelliklere sahiptir. Ancak -1 ile 1 arasında sınırlandırılmıştır. Tanh denklemi aşağıdaki gibi verilmektedir:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{Denklem 20}$$

Tanh fonksiyonunun temel özellikleri şunlardır:

- Sayıları [-1, 1] aralığına getirir.
- Ortam 0'a eşittir
- Doygunluğa ulaştığında gradientleri yok eder.(Mercioni & Holban, 2020, s.142)


### 2.3.8.3 RELU Fonksiyonu

RELU tanımı şu şekilde yapılmaktadır

$$f(x) = \max(0, x) = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases} \quad \text{Denklem 11}$$

Grafik şekil 24'te gösterilmiştir. Aktivasyon fonksiyonu doygun değildir ve türev fonksiyonu,  $x > 0$  girildiğinde sabit olan fonksiyondur.

$$f'(x) = \begin{cases} 1 & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases}$$



**Kaynak:** Ding et all, 2018, s.1838

**Şekil 24:** RELU fonksiyonunun grafiği ve türevleri

Bunlar daha çok Rektifiye Lineer Birimler (RELU' lar) olarak bilinirler. RELU (Doğrultulmuş Doğrusal Birim) aktivasyonlarda üstel fonksiyonların hesaplanmasına gerek yoktur. RELU aktivasyon fonksiyonlarına sahip sinir ağları, gradyan inişli antrenman süresi açısından doymuş aktivasyon fonksiyonlarına sahip olanlardan çok daha hızlı birleşmektedirler. RELU işlevi, bir ağın aralıklı gösterimi kolayca elde etmesini sağlamaktadır. Daha spesifik olarak, girdi  $x < 0$  olduğunda çıktı 0'dır, bu da nöron birimlerinin aktivasyonunda aralıklıyı sağlar ve veri öğreniminin verimliliğini artırır. Zaman girişi  $x \geq 0$  özellikleri veri büyük ölçüde korunabilir. RELU fonksiyonunun türevleri sabit 1 olarak kalır, bu da yerel optimizasyona girmekten kaçınılabilir. Sigmoid ve hiperbolik teğet aktivasyon fonksiyonlarında meydana gelen kaybolan gradyan etkinliğini çözebilmektedir. RELU etkinleştirme işlevlerine sahip derin sinir ağları, büyük etiketli veri kümesiyle tamamen denetlenen görevler üzerinde denetimsiz bir ön eğitim gerektirmeden en iyi performanslarına ulaşabilmektedirler (Ding et al., 2018, s.1838).

## **2.4. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Kuralları**

Öğrenme yeteneği, biyolojik veya başka türlü akıllı sistemlere özgü bir özelliktir. Yapay sistemlerde öğrenme, sistemin belirli bir görevi yerine getirebilmesi için dış uyarılara yanıt olarak, sistemin iç temsilini güncelleme süreci olarak görülmektedir. Bu, bağlantıların ağırlıklarını ayarlamayı, bazı bağlantı bağlantılarını budamayı veya oluşturmayı ve bireysel nöronların ateşleme kurallarını değiştirmeyi içeren ağ mimarisinin değiştirilmesini içermektedir (Basheer & Hajmeer, 2000, s.7). Öğrenme kuralı, bu kuralı ağ üzerinden uygulayarak yapay sinir ağının performansını artırır. Böylece öğrenme kuralı, eğitim sürecinde belirli koşullar karşılandığında bir ağın ağırlıklarını ve yanlılık seviyelerini güncellemektedir. Sinir ağının gelişiminin çok önemli bir parçasıdır.


### **2.4.1. Hebb Kuralı**

Hebb öğrenme stratejisi, iki düğüm arasındaki bağlantı gücünün, iki düğümün değerlerinin korelasyonuna göre ayarlanmasını önermektedir (Kothari & Oh, 1993, s.182). En eski öğrenme kuralı, Hebb'in öğrenme önermesidir. Hebb bunu nörobiyolojik

deneylerden elde edilen şu gözleme dayandırmıştır: Bir sinapsın her iki tarafındaki nöronlar eşzamanlı ve tekrar tekrar aktive edilirse, sinapsın gücü seçici olarak artar. Matematiksel olarak Hebb kuralı şu şekilde tanımlanabilir:

$$W_{ij} = (t + 1) = W_{ij}(t) + \eta y_j(t) x_i(t), \quad \text{Denklem 12}$$

$x_i$  ve  $y_j$  nöronların çıkış değerleri,  $i$  ve  $j$  sırasıyla sinaps ile bağlanan  $w_{ij}$  ve  $\eta$  öğrenme oranıdır. Bu kuralın önemli bir özelliği, öğrenmenin lokal olarak yapılmasıdır. Sinaps ağırlığındaki değişiklik yalnızca onunla bağlantılı iki nöronun aktivitelerine bağlıdır. Hebb kuralı kullanılarak eğitilmiş tek bir nöron, bir yönelim seçiciliği sergilemektedir.



**Kaynak:** Jain et all, 1996, s.36

**Şekil 25:** Hebb Kuralı

Tek bir nöronun oryantasyon seçiciliği Hebb kuralı kullanılarak eğitilmiştir. Şekil 25 bu özelliği göstermektedir. Tasvir edilen noktalar iki boyutlu olarak çizilir. Öğrenme süreci olarak ağırlık vektörü, verilerdeki maksimum varyansın  $w$  yönüne giderek yaklaşır. Aslında,  $w$  en büyük özdeğere karşılık gelen verilerin kovaryans matrisinin özvektörüdür (Jain et al., 1996, s.36).

#### 2.4.2. Delta Kuralı

Delta Kuralı, Hebb Kuralının bir başka varyasyonudur. İstenen çıktı değeri ile nöronun gerçek çıktısı arasındaki farkı azaltmak, giriş bağlantılarının gücünü değiştirmek için en yaygın uygulanan yollardan biridir. Bu kural, ağırlık ortalaması kare hatasını en aza indirecek şekilde bağlantı ağırlıklarını değiştirir. Hata, her seferinde bir katman önceki katmanlara geri yayılır. Ağ hatalarını geri yayma işlemi, ilk katmana ulaşılan kadar devam etmektedir. İleri besleme, geri yayılma adı verilen ağ türü, adını

hata ekibini hesaplamının bu yönteminden almaktadır. Bu kural aynı zamanda Widrow-Hoff Öğrenme Kuralı ve En Az Ortalama Kare Öğrenme Kuralı olarak da adlandırılmaktadır (Alsmadi et al., 2009, s.297).

Delta kuralı,  $w_{ij}(n)$ 'ye uygulanan bir  $\Delta w_{ij}(n)$  düzeltmesidir ve şu şekilde verilmektedir:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}$$

$\eta$  öğrenme parametresidir ve eksi işareti, ağırlık uzayındaki gradyan inişini açıklar. Delta kuralı, hata yardımıyla şu şekilde ifade edilebilir:

$$\Delta w_{ji}(n) = \eta \delta_j(n) h_i(n)$$

Denklem 13

Burada  $\delta_j(n) = e_j(n) \varphi'(v_j(n))$  eğimdir. Delta kuralının ilginç bir özelliği, nöron  $j$ 'nin çıkışındaki hata sinyalinin yardımıyla ağırlık ayarını vermesidir. Bu nedenle, çıkış sinyalini üreten nöron  $j$ 'nin çıkış katmanında mı yoksa gizli bir katmanda mı olduğuna bağlı olarak iki farklı durumun göz önünde bulundurulması gerekmektedir (Batres-Estrada, 2015, s.32).

### 2.4.3. Hopfield Kuralı

Hopfield nöral ağ, geri bildirim ağlarında en basit ve en uygulanabilir model olup, tek katmanlı bir geri bildirim sinir ağıdır. Hopfield sinir ağı modeli bir tür tekrarlayan sinir ağıdır. Giriş ve çıkış arasında bir geri besleme bağlantısı vardır (Z. Yu et al., 2020, s.67087)


Hopfield ağları, otomatik çağrışımsal içerik adreslenebilir anılar olarak kullanılmaktadır. Bu tür ağların amacı, daha önce sunulan modellerden birine benzeyen veya gürültülü bir versiyonu olan bir örnekten öğrenilmiş bir modeli elde etmektir. Bunu yapmak için ağ, bir modelin her bir ögesini bir ikili nöronla ilişkilendirir. Bu nöronlar tamamen bağlantılıdır. Eş zamansız ve paralel olarak güncellenirler. Bir girdi modeli ile başlatılırlar ve ağ aktivasyonları öğrenilen en yakın modele yakınsar. Hopfield ağı, fark denklemi tarafından yönetilen bir çekici sinir ağıdır.

$$x_i = \text{sgn} \sum_j w_{ij} x_j(t)$$

Denklem 14



$x_i(t)$  nöronunun  $\pm 1$  durumu,  $w_{ij}$  simetrik ağırlık matrisi ve  $x_i(n) = \pm 1$  güncellemelerin eşzamansız olarak gerçekleştirildiği  $i$  nöronunun  $n$  güncellemesidir. Ağ başlangıç durumunda kurulur, serbest bırakılır ve dinamikler ağı en yakın sabit noktaya götürür. Bir Hopfield ağına öğrenme kuralının işi, kalıpların gürültülü veya eksik başlangıç girdilerinden geri çağrılabilmesi için gerekli kalıpları ağ dinamiğinin sabit noktaları olarak saklayan bir ağırlık matrisi  $w_{ij}$  bulmaktır (Storkey & Valabregue, 1999). Bu ağ, nesnelere depolanması ve geri çağrılması için otomatik ilişkilendirilebilir bir bellek işlevi görür ve gürültüyü azaltmak için kullanılabilir.



**Kaynak:** Mellsen et al., 1994, s. 280

**Şekil 26 :** Hopfield Sinir Ağı mimarisi


Şekil 26' da N birimlerinden (numaralandırılmış açık daireler) oluşan doğrusal olarak düzenlenmiş bir Hopfield ağı gösterilmektedir. Her birimin çıkışı, ağıdaki diğer herhangi bir birimin girişine bağlanır (ince çizgiler). Birimlerin üzerindeki kesişen çizgilerdeki siyah noktalar,  $w_{ij}$  ağırlıklarını temsil eder. Ağırlıklardan ikisi, *i. e.*,  $w_{23}$  ve  $w_{N1}$  şekilde açıkça gösterilmiştir. Her ünite harici bir  $I_i$  Her ünite harici bir  $x_i$  sinyali ile çalışmaktadır (ünitelerin üzerine kalın çizgiler çizilir) (Mellsen et al., 1994, s.280).

#### 2.4.4. Kohonen Kuralı

Kohonen kuralı kendi kendini organize eden nöronları tanımlayan matematiksel modeller, başlangıçta Von Der Malsburg tarafından önerildi ve Kohonen tarafından geliştirildi. Deneysel sonuçlara göre beyindeki bilgilerin iki boyutlu bir yüzeyde

depolandığı ve ilgili bilgilerin o yüzeydeki komşu yerleri kapladığı öne sürülmüştür (Niebur & Germond, 1992, s.866).

Şekil 27'de 3 boyutlu giriş vektörlerini 16 nöron içeren 2 boyutlu bir harita üzerinde haritalayan bir Kohonen ağı gösterilmektedir. Bu kare ağdaki bir nöronun, sınırları boyunca bulunan nöronlar dışında, birinci dereceden komşular olarak adlandırılan dört doğrudan komşusu vardır. Şekil 27'de nöron 5'in tam komşuluğu gösterilmiştir. 1. Dereceden komşular nöron 1,4,6 ve 9'dur. 2. dereceden komşular 0,2,7, 10, 13 ve 8 numaralı nöronlardır, 3. dereceden komşular 7, 12 ve 14'tür ve son olarak 15 numaralı nöron 4. dereceden bir komşudur. Nöronların sayısı, giriş vektörünün boyutuna veya eğitim setinin boyutuna bağlı değildir. Bununla birlikte, az sayıda nöron, her biri büyük bir dizi eğitim vektörü sunan, yalnızca az sayıda kabaca ayırt edici küme oluşturabilir. Uygulamaya bağlı olarak, bu özellik ayrımcılığı, büyük bir eğitim seti için yeterince ayrıntılı bir sınıflandırma sunmayabilir.




**Kaynak:** Niebur and Germond, 1992, s. 867

**Şekil 27 :** Kohonen Ağı

Bu ağ, çıktı verisine ihtiyaç duymadan öğrenebilen, kendi kendini organize eden bir harita ağıdır. Verileri aynı kategorilere ayırmak için kümeleme ilkesinden yararlanır. Sadece bir giriş katmanı ve bir çıkış katmanından oluşmaktadır (Shakir Hilaiwah et al., 2021, s.558). Genel rekabetçi öğrenme yasasının doğrusal bir versiyonu olan Kohonen öğrenme kuralı, genellikle kendi kendini organize eden bir özellik haritası bulmak için kullanılmaktadır (McInerney & Dhawan, 1994, s.614) .

## 2.4.5. Dereceli Azaltma (Gradient Descent) Kuralı

Problemi basitleştirerek tüm eğitim örnekleri üzerinde karesel hatayı nasıl minimize edebileceğimizi görselleştirilebilmektedir. Diyelim ki doğrusal nöronumuzun yalnızca iki girdisi (ve dolayısıyla yalnızca iki ağırlığı,  $w_1$  ve  $w_2$ ) vardır. O zaman yatay boyutların  $w_1$  ve  $w_2$  ağırlıklarına, dikey boyutun ise hata fonksiyonunun değerine karşılık geldiği üç boyutlu bir uzay hayal edebiliriz. Bu uzayda, yatay düzlemdaki noktalar ağırlıkların farklı ayarlarına karşılık gelir ve bu noktalardaki yükseklik, ortaya çıkan hataya karşılık gelmektedir. Yaptığımız hataları tüm olası ağırlıklar üzerinden ele aldığımız zaman, bu üç boyutlu uzayda bir yüzey, örneğin şekil 28’de gösterildiği gibi ikinci dereceden bir çanak elde ederiz (Buduma & Locascio, 2017, s28) .




**Kaynak:** Budama and Locascio, 2017, s.28

**Şekil 28:** Doğrusal bir nöron için ikinci dereceden hata yüzeyi

Bu yüzeyi, minimum hatanın elipslerin merkezinde olduğu bir dizi eliptik kontur olarak da görselleştirebiliriz. Bu kurulumda, boyutların iki ağırlığa karşılık geldiği iki boyutlu bir düzlemde çalışıyoruz. Konturlar, aynı E değerini değerlendiren  $w_1$  ve  $w_2$  ayarlarına karşılık gelir. Konturlar birbirine ne kadar yakınsa, eğim o kadar dik olur. Aslında, en dik iniş yönünün her zaman konturlara dik olduğu ortaya çıkmaktadır. Bu yön, gradyan olarak bilinen bir vektör olarak ifade edilmektedir. Artık hata işlevini en aza indiren ağırlıkların değerlerinin nasıl bulunacağına dair üst düzey bir strateji geliştirebiliriz. Örneğin ağırlıklarımızı rastgele başlattığımızda kendimizi yatay düzlemde bir yerde buluruz. Mevcut konumumuzdaki eğimi değerlendirerek, en dik iniş yönünü bulabilir ve bu yönde bir adım atabiliriz. O zaman kendimizi eskisinden daha

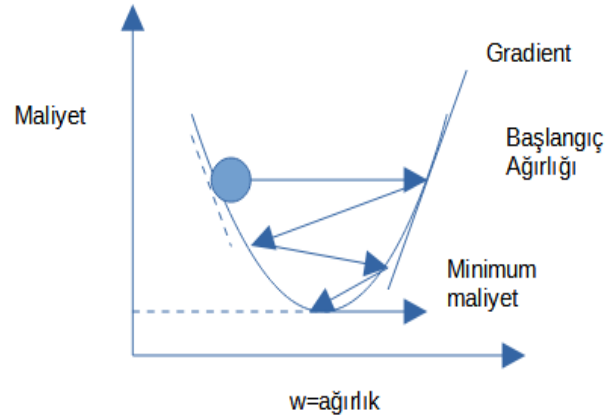
azına yakın olan yeni bir konumda bulacağız. Bu yeni konumdaki eğimi alarak ve bu yeni yönde bir adım atarak en dik iniş yönünü yeniden değerlendirebiliriz. Şekil 29 'da gösterildiği gibi, bu stratejiyi izlemenin sonunda bizi minimum hata noktasına getireceğini görmekteyiz. Bu algoritma gradyan inişi olarak bilinir ve bu bireysel nöronları eğitme sorununu ve tüm ağırları eğitmenin daha genel zorluğunu çözmek için kullanılabilir.



**Kaynak:** Budama and Locascio, 2017, s.29

**Şekil 29:** Hata yüzeyini bir dizi kontur olarak görselleştirme

Dereceli azaltma, optimizasyonu gerçekleştirmek için en popüler algoritmalarından biridir ve sinir ağlarını optimize etmenin en yaygın yolu olarak bilinmektedir (Ruder, 2016, s.1). Gradyan inişi, nesnel işlevin dışbükey olmamasına rağmen, derin sinir ağlarının eğitiminde küresel bir minimum bulur. Dereceli azaltma kuralında, ağırlıklarda uygun yinelemeli ayarlamalar yaparak bir maliyet işlevini (toplam kare hatası gibi) en aza indiren bir öğrenme algoritması geliştirmektedir. Buradaki fikir, maliyet  $Ew_{ij}$  yeterince küçük olana kadar  $w_{ij} \rightarrow w_{ij} + \Delta w_{ij}$  ağırlıklarına bir dizi küçük güncelleme uygulamaktır. Seçilen maliyet fonksiyonunu en iyi şekilde azaltmak için ağırlık vektörünün değişmesi gereken yönü belirlenmesi gerekmektedir.  $Ew_{ij}$  maliyetinin  $w_{ij}$  değiştiği, yani  $E$ 'nin  $w_{ij}$ 'e göre eğimi değiştiği nasıl değiştiği önemli olmaktadır. Ardından, ağırlıkları eğime karşı küçük adımlarla tekrar tekrar ayarlayarak, ağırlık uzayında hareket ederek, eğimler boyunca minimum maliyet fonksiyonuna doğru inilmektedir (Bullinaria, 2015, s. 9).



**Kaynak:** Lanham, M. Oreilly, 2022

**Şekil 30:** Gradient Descent kuralı gösterimi

Yüksek ölçülü veriler, yüksek ölçülü giriş vektörlerini yeniden oluşturmak için küçük bir merkezi katmana sahip çok katmanlı bir sinir ağını eğiterek düşük boyutlu kodlara dönüştürülebilir. Gradyan alçalması, bu tür 'otomatik kodlayıcı' ağlardaki ağırlıkların ince ayarlanması için kullanılabilir, fakat bu yalnızca başlangıç ağırlıkları iyi bir çözüme yakınsa iyi çalışmaktadır (Hinton & Salakhutdinov, 2006, s.504).

#### 2.4.6. Levenberg-Marquardt Öğrenme Algoritması

Kenneth Levenberg ve Donald Marquardt tarafından bağımsız olarak geliştirilen Levenberg-Marquardt algoritması, doğrusal olmayan bir fonksiyonu en aza indirme probleminde sayısal bir çözüm sunmaktadır. Hızlıdır ve kararlı yakınsamaya sahiptir. Yapay sinir ağları alanında bu algoritma küçük ve orta ölçekli problemlerin eğitimi için uygundur (H. Yu & Wilamowski, 2012, s.12).

Levenberg-Marquardt (LM) Metodu: Maksimum komşuluk üzerine kurulmuş en az kareler hesaplama metodu olarak bilinmektedir. Genellikle bu metot yavaş yakınsama problemlerinden etkilenmemektedir. LM algoritması optimizasyon problemlerinde eğimli düşüş algoritmasına göre (Gradient Descent) daha etkin ve daha hızlıdır. LM algoritması, Gauss Newton ve gradyan iniş yöntemlerinin avantajlarını birleştiren ikinci dereceden bir yöntemdir. Sinir ağları eğitim algoritmalarının çoğu gibi, klasik LM de yerel minimumda sıkışabilmektedir. Klasik birinci mertebeden yöntemlerde bu problem

momentum faktörü uygulanarak çözülebilir. Bu tür bir değişiklik, yerel minimumu aşmaya ve en uygun çözüme doğru yönü bulmaya yardımcı olmaktadır. Momentum faktörü keyfi olarak seçilebilir ve eğitim boyunca sabit kalabilir veya yakınsama sürecine göre dinamik olarak ayarlanabilir (Melssen et al., 1994).

Bayesian Regulation Metodu: Bayesian regülasyonu Levenberg Marquardt optimizasyonuna göre ağırlık ve bias değerlerini güncellemektedir. Karesel hata ve ağırlıkların kombinasyonunu asgari düzeye indirir ve ağı üretmek için doğru kombinasyonu belirlemektedir (Aşkın et al., 2011, s.908).

LM algoritması, doğrusal olmayan gerçek değerli fonksiyonların karelerinin toplamı olarak ifade edilen çok değişkenli bir fonksiyonun minimumunu bulan yinelemeli bir tekniktir (Liu, 2010, s.457).

LM yönteminde, ağırlıklardaki ( $\vec{w}$ ) değişim ( $\Delta$ ) çözümlenerek elde edilir. E ise ortalama hata karesi.

$$\alpha\Delta = -\frac{1}{2}\nabla E$$

$$E = \frac{1}{N}\sum_{k=1}^N[\vec{y}(x_k) - \vec{d}_k]^2 \quad (1)$$

N örneklerin sayısıdır,  $\vec{y}(x_k)$  örneğine karşılık gelen ağ çıktısıdır.  $x_k$  ve  $\vec{d}_k$  bu örnek için istenen çıktıdır. Matrisin elemanları, ağın çıkış sayısının nerede olduğu ile verilir.

$$\alpha_{ij} = (\mathbf{1} + \lambda\delta_{ij}) \sum_{r=1}^p \sum_{k=1}^N \left[ \frac{\partial y_r(x_k)}{\partial w_i} \frac{\partial y_r(x_k)}{\partial w_j} \right] \quad (2) \quad \text{Denklem 15}$$

İlk rastgele ağırlıklardan başlayarak, hem  $\alpha$  hem de  $\nabla E$  (1) 'in değerleri için bir düzeltmeyi değerlendirmek ve ağırlıkları çözmek ile ( $\vec{w}^l = \vec{w} + \Delta$ ) elde edilir. Bu LM öğrenme döngüsü olarak bilinmektedir. Bu döngünün her yinelemesi, istenen hedefe ulaşılan veya minimum bulunana kadar hatayı azaltmaktadır (Lera & Pinzolas, 2002, s.1201).

YSA modellerinde oluşturulan gizli katmanlardaki nöron sayısını belirlemek için mutlak bir kural bulunmamaktadır. Çoğunlukla belirli sayıdan başlayıp ve kademeli artırılıp modeller denenerek uygun sayı bulunur. Oluşturulan ağın olması gerekenden az belirlenen gizli nöron sayısı, modellerden yetersiz sonuçlar almasına ve modellerin

verileri ezberlemesine neden olabilir (Gabralı & Aslan, 2020, s.31). Bu gibi durumlar YSA modellerinde ve yapılan analizlerde karşımıza çıkabilmektedir.

### 3. ZAMAN SERİSİ VE YAPAY SİNİR AĞLARI İLE DIŞ TİCARET ANALİZİ

Bu bölümde zaman serisi yöntemleri ve YSA ile yapılan çalışmalar ele alınmıştır. Çalışmalar yıllara göre ele alınıp uygulanan yöntemler hakkında bilgi verilmiştir. Daha sonra model kurularak YSA ve zaman serisiyle dış ticaret analizi yapılmıştır.

#### 3.1. Model

Dış ticaret modeli için aşağıdaki denklem kullanılmıştır. İki ülke arasında dış ticaret modeli oluştururken, ihracat-ithalat oranlarını, sanayi üretim endekslerini ve reel döviz kurunun modelin önemli belirleyicisi olarak tanımlamaktadır. Modelde kullanılan değişkenler logaritmik tabanlı değerlerdir.

$$\ln\left(\frac{X}{M}\right) = \alpha + \ln(Y_{TR}) + \ln(Y_{GR}) + \ln(RER) \quad RER = \frac{kur \times P_{GR}}{P_{TR}} \quad \text{Denklem 26}$$

Denklem 26'da görüldüğü gibi, Almanya'nın sanayi üretim endeksi ( $Y_{GR}$ ) ve Türkiye ( $Y_{TR}$ )'deki yanı sıra lira-euro reel döviz kurunun (RER) iki ülke arasında dış ticaretin belirleyicileri olduğu ifade edilmektedir.  $P_{GR}$  Almanya'nın tüketici fiyat endeksi  $P_{TR}$  Türkiye'nin tüketici fiyat endeksi olarak belirlenmiştir.  $\ln\left(\frac{X}{M}\right)$  Türkiye'nin ihracatının Almanya'dan ithalat oranı olarak tanımlanmaktadır. Liranın değer kaybetmesi Türk ihracatını arttırması, ithalatını azaltması durumu dış ticareti etkilemektedir.

#### 3.2. Literatür

Kohzadi vd. (1995) Kanada'nın 1950'den 1990'a kadar aylık canlı hayvan ve buğday fiyatlarını ileri beslemeli sinir ağı ve ARIMA ile fiyat tahmin performansını karşılaştırmışlardır. Ortalama hata karelerinde ileri beslemeli sinir ağından ARIMA yöntemine göre daha düşük sonuçlar elde etmişlerdir (Kohzadi et al., 1995).

Binner vd. (2005) yazılarında, sekiz ülke için ABD, Meksika, Almanya, İtalya, İspanya, Fransa, Hindistan ve Japonya 2020 yılının Nisan-Haziran çeyreğine ilişkin GSYİH rakamları, tahmin etmeyi hedeflemektedirler. YSA modellerinden çok katmanlı bir yapay sinir ağı modeli geliştirilmiştir. Test sırasında model tarafından %2'den daha



az bir tahmin hatası elde edilerek, tahmin edilen GSYİH rakamları cari yılın Nisan-Haziran çeyreğinin tüm ülkeler için GSYİH’de keskin düşüşler yaşanacağı tespit edilmiştir. Yıllık GSYİH büyümesi çift haneli negatif büyüme oranlarına ulaşması beklendiği sonucuna varılmıştır (Binner et al., 2005).

Erilli, vd. (2010) çalışmasında; 1987-2007 aylık verileri ile tüketici fiyat endeksi için yapay sinir ağları yaklaşımı kullanılarak öngörü değerleri elde etmişlerdir. Bu çalışmada ileri ve geri beslemeli yapay sinir ağlarının öngörü sonuçlarının yine yapay sinir ağları kullanılarak, kombine edildiği yeni bir melez yaklaşım önerilmiştir. Türkiye TÜFE zaman serisine uygulanarak önerilen yaklaşımın HKOK değerini düşürdüğü gözlemlenmiş ve bu değer 0,5726 olarak bulunmuştur. YSA metoduyla enflasyonun tahmin edilebileceği sonucuna ulaşmışlardır (Eğrioğlu et al., 2010).

Karahan (2011); 2004-2010 aylık verileri ile Kayseri iline ait kuru kayısı ihracatını yapay sinir ağları metodu ile tahmin etmiştir. Çalışmada kuru kayısı ihracatı için bağımsız değişkenler ABD doları, kayısı ihracat fiyatı, aylık pazar sayısı ve mevsimsel etki kullanılmıştır.  $R^2$  değeri 0,7488, Korelasyon değeri 0,8653, gelecek altı aylık dönem için yapılan tahminin toplam MSE değeri 880347 ve MAPE değeri 0,151 olarak elde edilmiştir. 2011 yılının ilk altı ayı için yapılan talep tahmini güvenli ve tutarlı sonuçlar vermiştir (Karahan, 2011).

Choudhary ve Haider (2012) Ekonomik İş birliği ve Kalkınma Örgütü (OECD) için aylık enflasyon oranlarını tahmin araçları olarak çeşitli YSA modellerinin gücünü değerlendirmişlerdir. YSA modellerinin, enflasyon için %45 oranında üstün bir tahmin edici olduğunu, Otoregresif birinci dereceden modelin (AR1) ise ülkelerin %23’ü için daha iyi performans gösterdiği sonucuna ulaşmışlardır. Ayrıca, çeşitli YSA modellerinin aritmetik kombinasyonlarını geliştirerek bunların enflasyonu tahmin etmek için güvenilir araçlar olarak da hizmet edebileceği tespit edilmiştir (Ali Choudhary & Haider, 2012).

Oancea ve Ciucu (2013) çalışmalarında 03.01.2005-19.02.2013 tarihleri arasındaki Romanya ulusal bankasından alınan verilerle EURO ve USD olmak üzere iki para biriminin döviz kurlarını analiz etmişlerdir. Testler sonucunda tekrarlayan ağırlıklı klasik ileri besleme ağırlıklı daha iyi performans gösterdiği sonucuna ulaşmışlardır (Oancea & Cristian Ciucu, 2013).

Yurdakul (2014) Türkiye'nin 1980-2007 dönemine ait üçer aylık veriler ve harcama yöntemi ile Gayri Safi Yurt İçi Hasıla, TÜFE bazlı Reel Efektif Döviz Kuru, mal ve hizmet ihracatı ve bankacılık sektörü kredi hacmi değişkenleri açıklayıcı değişken olarak kullanılmıştır. 1980-2012 yıllarına ait veriler ile 2013-2014-2015 yıllarına ait ithalat verileri tahmin edilmiştir. Geri yayılım algoritmasında dört girdili denemelerde R kare değeri 0.93 bulunmuştur. Denenen mimarilerde Tanjant Sigmoid aktivasyon fonksiyonunun en iyi tahminleri ürettiği sonucunu elde etmişlerdir (Yurdakul, 2014) .

Yıldırım vd. (2014) YSA ile yaptıkları değerlendirmelere göre, odun dışı orman ürünlerine olan talebin artacağı eğiliminde olacağı görülmüştür.  $R^2$  değerinin %84 ve %98 ile sonuçlandığı MAPE değerinin 4.66 ve %2 ile sonuçlandığı görülmektedir (Yıldırım et al., 2014)

Constantino vd. (2016) de çalışmalarında, Ocak 2004 – Aralık 2013 arasında Güney Afrika, ABD, Mozambik, Portekiz ve Birleşik Krallık'tan gelen turist sayılarından elde ettikleri 120 veriyi; TÜFE, GSMH ve döviz kurlarını değişken olarak kullandıkları yapay sinir ağı modelinde test etmişlerdir. Yapılan testlerin sonucunda %6,5'luk MAPE değeriyle YSA'nın talep tahminlemede güvenilir model olduğu sonucunu elde etmişlerdir (Constantino et al., 2016)

Ertuğrul ve Pekin (2016) temel gıda olarak buğday arpa ve çeltik ürünlerini ele alarak, bu ürünlerin fiyatlarını TÜİK veri tabanından 2000-2014 yılları arası için aylık bazda temin etmeye çalışmışlardır. Hata oranları (MSE) karşılaştırılmıştır. Buğday ve arpa fiyatları veri setleri için Holt üstel düzleştirme, ARIMA ve YSA modelleri birbirine yakın sonuçlar verirken çeltik fiyatları için YSA modelinde daha iyi sonuç elde etmişlerdir (Ertuğrul & Pekin, 2016)

Kurt vd. (2017) Türkiye'nin kâğıt-karton sanayisinin 2016-2025 yıllarındaki ihracatını tahmin etmek için 1990-2015 yıllarını kapsayan ve modelin bağımlı değişkeni olarak Türkiye kağıt-karton ihracatı, bağımsız değişken olarak da Türkiye kâğıt karton üretimi, atık kâğıt miktarları, endüstriyel odun miktarları, tomruk üretimi, nüfus, GSYİH, tüfe, üfe, döviz kurları ve ekonomik büyüme oranı olarak seçilmiştir. Kâğıt-karton ihracatının 2025 yılında 2011 yılına oranla %48,2'lik bir artış, 2015 yılına göre ise %3'lük bir azalış göstereceği tahmin edilmektedir (Kurt et al., 2017).

Özdağ vd. (2017) çalışmalarında Türkiye-Almanya arasında gerçekleşen mobilya ihracat ve ithalatının 2017-2023 yılları arasında tahmini için ülkelerin nüfusu, GSYİH'si, reel döviz kuru endeksi seçilen bağımsız değişkenleridir. Sektör ithalatı-ihracatı zaman bağımlı değişkenler olarak kullanılmıştır. 2023 yılında sektör ihracatının 10 yıl önce gerçekleşen değere göre yaklaşık %60'lık bir artış ile 240 milyon dolar seviyelerinde gerçekleşmesi beklenmektedir. Sektör ithalatının ise 2013 yılına göre 2023 yılında yaklaşık %40'lık bir artış ile 140 milyon dolar olacağı tahmin edilmiştir (Özdağ et al., 2017).

Uysal (2017) çalışmasında 1998- 2015 yılları arasındaki Türkiye'nin Dış Ticaret Açığı verilerini tahmin edebilmek için, geçmiş yıllardaki GSYİH, enflasyon ve döviz kuru verileri ileri beslemeli ve elman yapay sinir ağlarının eğitim verileri olarak kullanmıştır. Tahminler sonucunda ileri beslemeli sinir ağının hatanın karesinin ortalaması toplamda  $R^2=0,99$ , elman sinir ağının  $R^2=0,98$  olarak elde edilirken bu bağlamda ileri beslemeli sinir ağında elman sinir ağına göre daha yüksek doğrulukla sonuç üretildiği saptanmıştır (Uysal, 2017).

Abraham vd. (2017) Mato Grosso'da üretilen soya fasulyesi talebini tahmin etmek için 2001–2016 yılları arasındaki verilerin %80'ini eğitim, %5'ini doğrulama ve %15'ini ağı test etmek için değerlendirdi. Hem eğitimin hem de testin minimum korelasyon değerini (0.9) aştığını göstermektedir; bu, modelin soya fasulyesi veri analizi ile pozitif olarak ilişkili olduğu anlamına gelmektedir. Hesaplanan ortalama hata (ME) %12.57'dir ve talebin 7,9 ile 10,1 milyon ton arasında değişmesi beklenmektedir (Abraham et al., 2017).

Karagülle (2018) 18 Aralık 2015- 31 Aralık 2017 tarihleri arasında geçerli veriler ile elektrik fiyatları tahmini elde edilmiştir. Farklı kombinasyonları denenen modeller, örneklem dışı veride ortalama mutlak yüzde hata (MAPE) ile karşılaştırılmıştır. NARX yönetimi ile kurulan modelle %9,65 MAPE hata oranı ile diğer yöntemlerden daha iyi bir sonuç elde edilmiştir (Karagülle, 2018).

Alam (2019), Suudi Arabistan Krallığı'nın 1968-2017 yılları arasındaki yıllık toplam ihracat ve ithalatı, YSA ve ARIMA modelleri kullanılarak tahmin edilmiştir. YSA, ARIMA (0,1,1) ve ARIMA (1,1,2)'nin Suudi Arabistan Krallığı'nın toplam yıllık ihracat ve ithalatını tahmin etmek için en uygun modeller olduğu sonucuna varılmıştır (Alam, 2018).

Namina vd. (2019), Ocak 1985'ten Ağustos 2018'e kadar Yahoo finanstan N225, IXIC, HSI, GSPC, DJI, borsa verileriyle aylık finansal zaman serilerini çıkarmışlardır. RMSE değerleri LSTM tabanlı modeller, yüksek marjlı ARIMA tabanlı modellerden daha iyi performans (% 84 -% 87 arasında azalma hata oranları) göstermektedir (Siami-Namini et al., 2019).

Selçi ve Akgül (2020) İhracat bağımlı değişkeninin tahminini gerçekleştirmek üzere gayri safi sermaye oluşumu, sanayi, tasarruf, kur, lojistik, gayrisafi yurtiçi hasıla, kişi başına düşen gayrisafi yurtiçi hasıla, ticari servis ihracatı ve mal ihracatı bağımsız değişkenlerdir. 2002-2017 yılları arasındaki on altı yılı kapsayan toplamda 256 adet veri ele alınmıştır. Gizli katman sayısı 9 olduğunda  $R^2=0,99$ ,  $RMSE=36116$ ,  $MAE=26133$  ve  $MAPE= %45.141$  dir. YSA'nın Türkiye'nin ihracat değerlerinin tahmininde güçlü istatistikî sonuçlar üreterek başarılı olduğu sonucuna varılmıştır (Selçi Burcu & Akgül, 2020).

Shahvaroughi ve Razavi (2021) YSA'yı Ulusal Menkul Kıymetler Borsası, Hindistan'da test etmişlerdir. Çok katmanlı algılayıcı (MLP) sinir ağı tekniği kullanılarak bir tahmin modeli oluşturulmuştur. MLP tahmin modelini eğitmek ve test etmek için 2015, 2016 ve 2017 yılları kullanılmıştır. 0,059 medyan normalleştirilmiş hatası, 6.398 medyan standart sapması bulunmuştur. MLP sinir ağının, Ulusal Menkul Kıymetler Borsası, Hindistan LIX15 endeksi altında listelenen şirketleri tahmin ettiği kabul edilmiştir (Shahvaroughi Farahani & Razavi Hajiagha, 2021).

Asokan (2022) Dünyadaki 3 gelişmekte olan ülkenin hisse senedi endeksi için 5 yıllık günlük veriler Ocak 2018'den Mart 2022'ye kadar S & P 500, FTSE 100 ve Şangay Menkul Kıymetler Borsası'nı (SSE) içermektedir. Mevsimsel bir ARIMA modeli, LSTM sinir ağı ve hibrit bir ARIMA-GARCH modeli kullanılmıştır. Model performansını ölçmek için kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) oranları hesaplanmıştır. Deneysel sonuçlar, LSTM ve Hibrit ARIMA-GARCH modelinin SARIMA modelinden daha iyi performans gösterdiğini kanıtlamıştır (Asokan, 2022).

Goverdhan vd. (2022) Hisse senedi fiyat Eylül 2012'den Eylül 2022'ye kadar Yahoo borsa verilerini toplayarak ARIMA, XGBoost (Extreme Gradient Boost) ve LSTM' e dayalı bir öneri aracını modellemeyi amaçlamışlardır. Modellerin performansı

MSE, MAE, RMSE gibi metrikler kullanılarak değerlendirilmiştir. XGBoost' un % 98,92 doğrulukla en iyi performansı gösterdiği sonucuna varılmıştır (Goverdhan et al., 2022).

### 3.3. Performans Ölçümleri ve Seçim Kriterleri

Matlab 'da verilerin uygulandığı Training; eğitim sırasında ağa sunulur ve ağ hatasına göre ayarlanırken Validation; ağ genelleştirmeyi ölçmek ve genelleme sırasında eğitimi durdurmak için kullanılmaktadır. Testing; bunların eğitim üzerinde hiçbir etkisi yoktur ve bu nedenle ağ performansı için bağımsız bir ölçüm sağlamaktadır.

$R^2$  Determinasyon Katsayısı veya Belirleme Katsayısı ise;

$R^2$  0 ile 1 arasında değişir:  $R^2 = 0$  ise, model her zaman hedef değişkeni tahmin edemez ve  $R^2 = 1$  ise model hedef değişkeni mükemmel şekilde tahmin eder. 0 ile 1 arasındaki herhangi bir değer, modeli kullanarak hedef değişkenin yüzde kaçının özelliklerle açıklanabileceğini göstermektedir.  $R^2 < 0$  ise, modelin hedef değişkenin ortalamasını sürekli olarak tahmin eden modelden daha iyi olmadığını gösterir (Dumor & Yao, 2019, s12) .

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \text{Denklem 27}$$

$R^2$ , modelin doğruluk oranı karar verme katsayısı olarak bilinmektedir. Bu katsayı değerinin yüksek olması tahmin ilişkisinin iyi olduğu göstermektedir. MSE, RMSE ve MAE ise birer hata ölçüsü olması sebebiyle düşük sonuçlar, performans ile ters orantılı olarak yüksek performansı gösteren ölçütler olarak kabul edilmektedir. Örneğin RMSE sıfıra eşit olması durumunda başarılı olduğu sonucuna varılmaktadır (Çınaroğlu, 2017, s.184).

#### 3.3.1. MAE: Ortalama Mutlak Hata

Ölçüm değerleri ile model tahminleri arasındaki mutlak hatayı hesaplamaktadır. MAE değeri ne kadar sıfıra yaklaşırsa, modelinin tahmin yeteneğinin o kadar iyi olduğu sonucuna ulaşılmaktadır (Erdal & Yapraklı, Şükrü, 2016, s.28). Belirli  $i$  zamanı göstermek üzere  $o_i$  zaman aralığında gözlemlenen ve  $t_i$  tahmin edilen zaman serisi olmak üzere hata olarak ifade edilmektedir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |o_i - t_i| \quad \text{Denklem 28}$$

Modellerin öngörü doğruluğunun ölçümünde kullanılan istatistikler; Ortalama Kare Hata (Mean Squared Error- MSE), Kök Ortalama Kare Hata (Root Mean Squared Error - RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE), hata değerlerinin büyüklükleri benzer ise “Ortalama Kare Hata” (MSE) kullanılabilir. MSE istatistiği, hataların karelerini aldığı için büyük sapmaların olması durumunda yüksek değerler göstermektedir. Bu durumda, “Ortalama Mutlak Hata” (MAE) tercih edilebilir (Çuhadar, 2006, s.111).

### 3.3.2. MSE (Mean Squared Error) Ortalama Kare Hata

Belirli t zamanı göstermek üzere  $r_t$  zaman aralığında gözlemlenen ve  $p_t$  tahmin edilen zaman serisi olmak üzere hata,  $e_t$  formülü ile ifade edilmektedir (Gültepe, 2019, s.13).

$$e_t = r_t - p_t \quad MSE = \frac{1}{n} \sum_{i=1}^n e_t^2 \quad \text{Denklem 29}$$

### 3.3.3. SE: Standart Hata (Standard Error) veya RMSE: Hata Karesinin Ortalamasının Kökü (Root Mean Square Error)

Ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek amacıyla kullanılmaktadır. RMSE değerinin sıfıra yakın olması modelin tahmin yeteneğinin artması demektir (Erdal & Yapraklı, Şükrü, 2016, s.25).

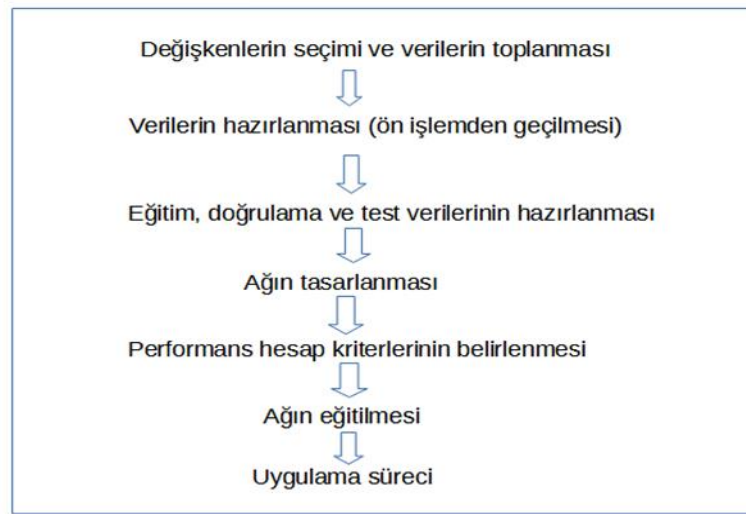
$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} (y_i - \hat{y})^2} \quad \text{Denklem 30}$$

## 3.4. Uygulama

Bir makine öğrenimi tahmincisi eğitimin amacı, görünmeyen veriler üzerinde iyi performans gösterebilmesidir. Tüm veri kümesinin bir kısmını tutarak bu görünmeyen veriler simüle edilir. Bu tutma seti, test seti olarak adlandırılır (Peter et al., 2021, s.262). Tahmin ve değerlendirme modelleri oluşturmak için uygulanan YSA, “Birçok değişkenli bilgi alanından diğerine, bu haritalamayı temsil eden bir dizi veri

verildiğinde, elde edebilen, temsil edebilen ve şekil verebilen bir hesaplama mekanizması” olarak tanımlanmaktadır.


Çalışmanın amacı Türkiye-Almanya arasındaki dış ticareti analiz etmektir. Bu bağlamda iki ülke arasındaki ticaret ilişkisi açıklanmaya çalışılmıştır. TÜİK ve IMF ‘den alınan dış ticaret verileri için Drift, Naive, Mean, ARIMA metotları ve NARX ağlarından elde edilen sonuçlar tartışılmaktadır. Her ağ hiperparametreler açısından aynı ayarlarla çalıştırılır. Bütün bilgiler RStudio ve Matlab’da yapılmıştır. Şekil 31’de uygulanan yöntemin şeması verilmektedir.



**Şekil 31:** Uygulanan yöntemin şeması

RStudio ‘da zaman serisi yöntemlerini ve YSA modelini uygulamak için eğitim ve test verileri ayrılmıştır. 2002 yılından başlayarak 228 veri eğitim, geriye kalan 12 aylık veri ise test için kullanılmıştır.

Çalışmada tasarlanan modelin çıktı verisi ihracat/ithalat, girdi verileri Türkiye sanayi üretim endeksi, Almanya sanayi üretim endeksi, reel döviz kuru olarak alınmıştır. Veriler uygulanan metotlar için ağa sunulmadan önce logaritma işlemine tabi tutulmuştur. Sinir ağı için katman ve nöron sayısının belirlenmesinde herhangi bir yöntem bulunmamaktadır. Çalışma için kullanılan veri sayısı çok katmanlı sinir ağına gerek olmadığını göstermektedir. Deneme yanılma yolu ile katman ve nöron sayısı belirlenmektedir. Tasarlanan modelin mimarisi şekil 32’de gösterilmiştir.



**Şekil 32:** Tasarlanan modelin mimarisi

**Tablo 6:** Modelin istatistiksel analizi

	Ortalama	Standart sapma	Minimum	Maksimum
<b>İhracat/İthalat</b>	0.7160	0.1291	0.4659	1.1991
<b>Almanya sanayi üretim endeksi</b>	103.676	11.266	76.927	129.870
<b>Türkiye'nin sanayi üretim endeksi</b>	122.548	40.097	51.350	216.648
<b>Kur</b>	2.534	0.5091	1.924	4.767

Tasarlanan modelin ardından tablo 6'da kullanılmış olan modelin istatistiksel analizi gösterilmiştir. Verilerin ortalama, standart sapma, minimum ve maksimum değerleri uygulama için oluşturulmuştur.

Çalışmada veriler için Eurostat Harmonize Emtia Tanımı ve Kodlama Sistemi'ndeki 2002-2021 yılları arasındaki 99 fasıl ele alınmıştır. Bu bölümler;

- Bölüm 1: Canlı Hayvanlar; Hayvansal Ürünler
- Bölüm 2: Bitkisel Ürünler
- Bölüm 3: Hayvansal, Bitkisel veya Mikrobiyal Yağlar ve Bunların Parçalanma Ürünleri; Hazırlanmış Yemeklik Yağlar, Hayvan veya Bitki Mumları.
- Bölüm 4: Hazır Gıda Maddeleri; İçecekler, Alkollü İçecekler ve Sirke; Tütün ve Üretilmiş Tütün İkameleri, Nikotin İçerip İçermediğine Bakılmaksızın, Yanmadan Solunmaya Yönelik Ürünler.
- Bölüm 5: Mineral Ürünler, Kimya veya İlgili Endüstrilerin Ürünleri




- Bölüm 6: Kimya veya Benzeri Endüstrilerin Ürünleri.
- Bölüm 7: Plastikler ve Bunların Ürünleri; Kauçuk ve Benzeri Ürünler
- Bölüm 8: Ham Postlar ve Deriler, Deri, Kürk Derileri ve Bunların Eşyaları; Saraçlık ve Koşum Takımı, Seyahat Eşyaları, El Çantaları ve Benzeri Kaplar; Hayvan Bağırsağı Ürünleri (İpekböceği Hariç)
- Bölüm 9: Odun ve Odun Ürünleri; Odun Kömürü, Mantar ve Mantar Ürünleri; Saman veya Diğer Örgü Malzemeleri İmalatı, Sepet Eşyaları ve Hasır İşleri
- Bölüm 10: Odun Hamuru veya Diğer Lifli Selülozik Malzeme; Geri Kazanılmış (Atık ve Hurda) Kâğıt veya Karton; Kâğıt ve Karton ve Bunların Ürünleri
- Bölüm 11: Tekstil ve Tekstil Eşyaları
- Bölüm 12: Ayakkabılar, Başlıklar, Şemsiyeler, Güneş Şemsiyeleri, Bastonlar, Koltuk Bastonları, Kamçılar, Bitkiler ve Bunların Aksesuarları; Hazırlanmış Tüyler ve Bunlardan Yapılan Eşyalar, Yapay Çiçekler
- Bölüm 13: Taş, Alçı, Çimento, Asbest, Mika veya Benzeri Malzemelerden Mamuller; Seramik Ürünler, Cam ve Cam Eşyalar
- Bölüm 14: Doğal veya Kültür İncileri, Değerli veya Yarı Değerli Taşlar, Değerli Metaller, Değerli Metallerle Kaplanmış Metaller ve Bunların Ürünleri; Taklit Mücevherler, Madeni Para
- Bölüm 15: Baz Metaller ve Baz Metal Ürünleri
- Bölüm 16: Makine ve Mekanik Aletler; Elektrikli Ekipmanlar, Parçaları, Ses Kayıt Cihazları ve Çoğaltıcıları, Televizyon Görüntü ve Ses Kayıt Cihazları ve Çoğaltıcıları ve Bu Tür Eşyaların Parça ve Aksesuarları
- Bölüm 17: Araçlar, Uçaklar, Gemiler ve İlgili Nakliye Ekipmanları
- Bölüm 18: Optik, Fotografik, Sinematografik, Ölçme, Kontrol Etme, Hassas, Tıbbi veya Cerrahi Alet ve Aparatlar; Saatler ve Saatler, Müzik Aletleri; Bunların Parça ve Aksesuarları
- Bölüm 19: Silah ve Mühimmat; Parçaları ve Aksesuarları
- Bölüm 20: Çeşitli Mamul Ürünler
- Bölüm 21: Sanat Eserleri, Koleksiyon Parçaları ve Antikalar

Sonuçlar, hata kareler ortalamasının karekökü (RMSE) ve ortalama mutlak hataya (MAE) göre karşılaştırılmıştır. R programında Drift, Mean, Naive, ARIMA ve regresyon modeline dayalı ARIMA uygulanmıştır. Matlab'da Türkiye ve Almanya dış


ticaretinin mal gruplarına göre yapay sinir ağı yöntemi ile analizinde NARX sinir ağı kullanılmıştır. Bu sinir ağı dışsal girdilerle birlikte tahmin yapan bir ağ olup, verilerin logaritması alınarak analiz elde edilmiştir. Veriler Matlab ortamında %80 eğitim, %10 doğrulama, %10 test verileri olarak sinir ağına uygulanmıştır. LM öğrenme algoritması uygulanarak 2, 4 gecikme süreleriyle en iyi sonuca ulaşılmıştır.

Dış girdiler ile Doğrusal Olmayan Otoregresif Ağ (NARX) geri beslemeli tekrarlayan dinamik bir ağıdır. NARX ağının anlık görüntüsü şekil 33'te gösterilmiştir. Matlab'ın oluşturduğu açık döngünün şemasını göstermektedir. Şekle göre 3 dışsal (eksojen) girdi, gizli katmanda 10 nöron, 2 gecikme olduğunu ve her iki katmanda da Tansig fonksiyonunun kullanıldığını göstermektedir. Açık döngüde çıkış sistemi gerçek değerlerden oluşmaktadır. Bu tür öğrenme süreçlerinin ilkesi şudur; tekrarlayan bir sinir ağı "zamanda geriye döner" ve çok sayıda katmana sahip çok katmanlı bir algılayıcı olarak temsil edilir. Her katman geçmiş bir dokunuşa karşılık gelir.




Şekil 33: NARX YSA açık döngü mimarisi

Şekil 34' te verilen kapalı döngü 10 nöron 2 gecikme, aktivasyon fonksiyonundan oluşmaktadır. Kapalı döngü tahmini değerleri çıktı olarak vermektedir.



Şekil 34: NARX YSA kapalı döngü mimarisi

Ağı eğitmek için eğitim veri setinden ilk gözlemi seçer ve ardından sonraki gözlemi seçerek ağı yeniden eğitmeye devam eder. Epoch sayısı, tüm eğitim veri kümesi boyunca öğrenme algoritmasının kaç kez çalışacağını tanımlamaktadır. Bu, hatalar en aza indirilene kadar ağı tekrar çalışmasına izin vermektedir.



Şekil 35: NARX doğrulama performansı


Şekil 35'te en iyi doğrulama performansının, ortalama karesel hatanın 0,030487 değerini kaydettiği epoch 7'de elde edildiği görülmektedir. Öğrenme süreci, hedef doğruluğa ulaşıldığında tamamlanırken, çalışılan ağ 7 epoch da eğitilmiştir. Sinir ağı modeli eğitimi sonucunda en iyi öğrenmeyi bu aşamada gerçekleştirmiştir. YSA' nın başlatılması ve eğitimi sonucunda bilgilendirici grafikler elde edilmiştir:

- Train; eğitim ayarlarını açıklamaktadır. Aynı zamanda zaman, epoch (döngü) değeri, ağı gösterdiği 7'dir. Geri yayılma, doğrudan bir aktivasyon akışı, YSA' nın ayarlanması altında meydana gelen toplam, ortalama kare hatası olan ağırlıklardır.

- Validation; (doğrulama) değerinden sonra çalışılan veriler 7 ye eşit epoch değerlerini değiştirmez, yani en iyisi performans, en küçük doğrulama hatasıyla (nokta daire içine alınmış) çağdan alınır;


- Test; (test)en iyi öğrenme performansını

- Best; en iyi performansı gösterir.




Şekil 36: Hata Otokorelasyon fonksiyonu

Şekil 36’da NARX ağ performansını doğrulamak için kullanılmaktadır. Burada x eksenini ve y eksenini, sırasıyla doğrulanmış durumlar için gecikme değerlerini ve korelasyon değerlerini temsil eder. Bu işlev, tahmin hatalarının zamanla nasıl ilişkili olduğunu açıklar. Tahmin modeli mükemmelse, korelasyon 0’dır. Gecikme, basitçe korelasyonların veri serisindeki farklı noktalarda ölçüldüğü anlamına gelmektedir. Örneğin, korelasyon gecikme = 5 ve ardından gecikme = 10 olarak ölçülürse, korelasyonun 5 gecikme sonra ölçüldüğü anlamına gelir.



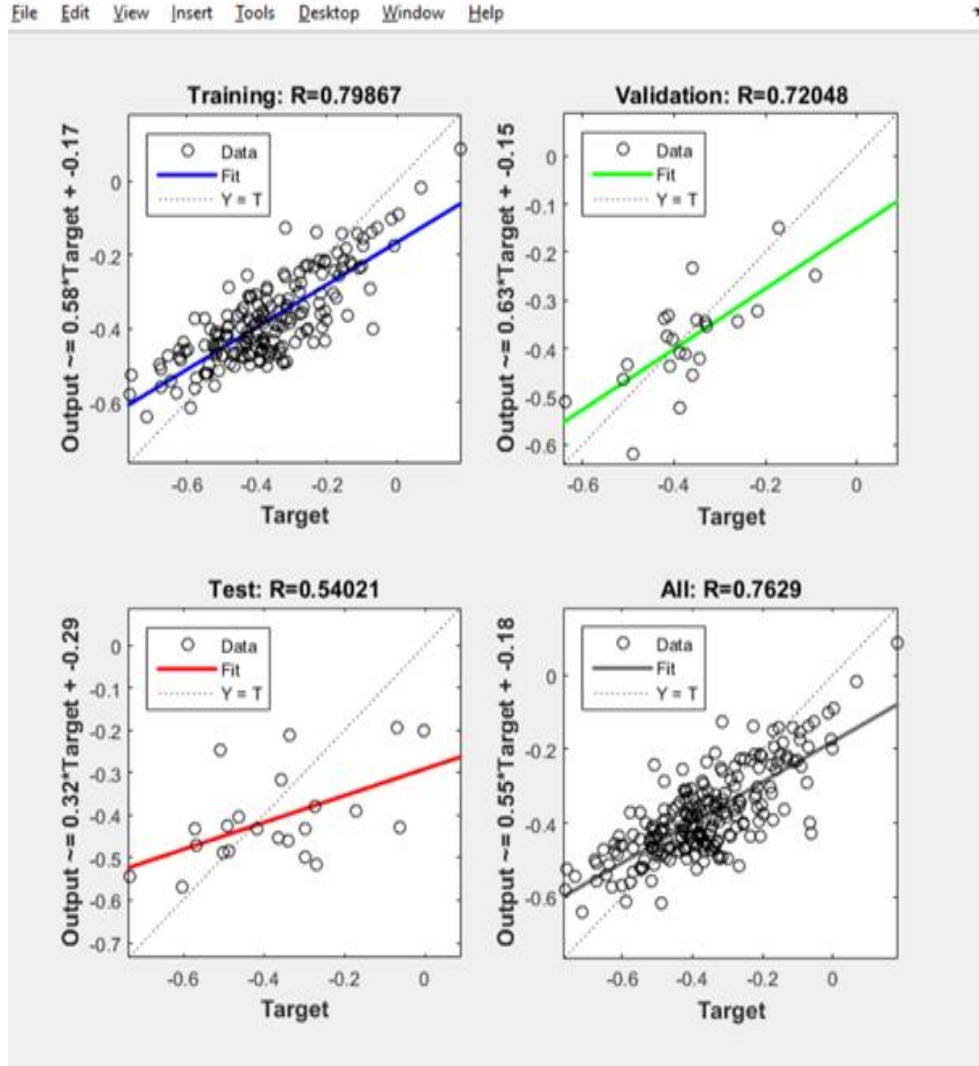
Şekil 37: NARX Hata histogramı

Hata histogramı, tasarlanmış tahmin yöntemimizin verimliliğini ve yüksek düzeyde tahmin doğruluğunu göstermektedir. Şekil 37’de uygulama sonucunda NARX hata histogramının değer aralığı verilmektedir.



Şekil 38: Zaman serisi yanıtı


Ağın, çıktıların ve hedeflerin yanıtı, gözlenen (hedef) değerlerin zamana karşı model tarafından hesaplanan (çıkıtı) değerleri ile çizildiği grafikler yardımıyla gözlenmiştir. Süreçte elde edilen hatalar da zamana karşı grafiğe dökülmüştür. Şekil 38’de zamana karşı tahmin hatalarının çoğu-0.5 ile 0.5 arasında olduğu görülmektedir.



**Şekil 39:** NARX Regresyon katsayısı


Şekil 39’ da her sonuç için regresyon katsayısı R hesaplanmıştır ve grafikler çizilmiştir. Eğitim 0.79867, doğrulama 0.72048, test 0.54021’dir. Tüm veri kümesi için korelasyon katsayısı R değeri 0.7629 olarak bulunmuştur.

RStudio’da uygulanan Benchmark modelleri ve Regresyon ARIMA ve ARIMA sonuçları grafiklerle gösterilmektedir. Şekil 40’ da zaman serisinin ayrışımına yer verilmiştir. Mevsimsel, rastgele, trend ’in 2002 yılından 2022 yılına kadar uygulanan verilerin sonuçları gösterilmektedir.

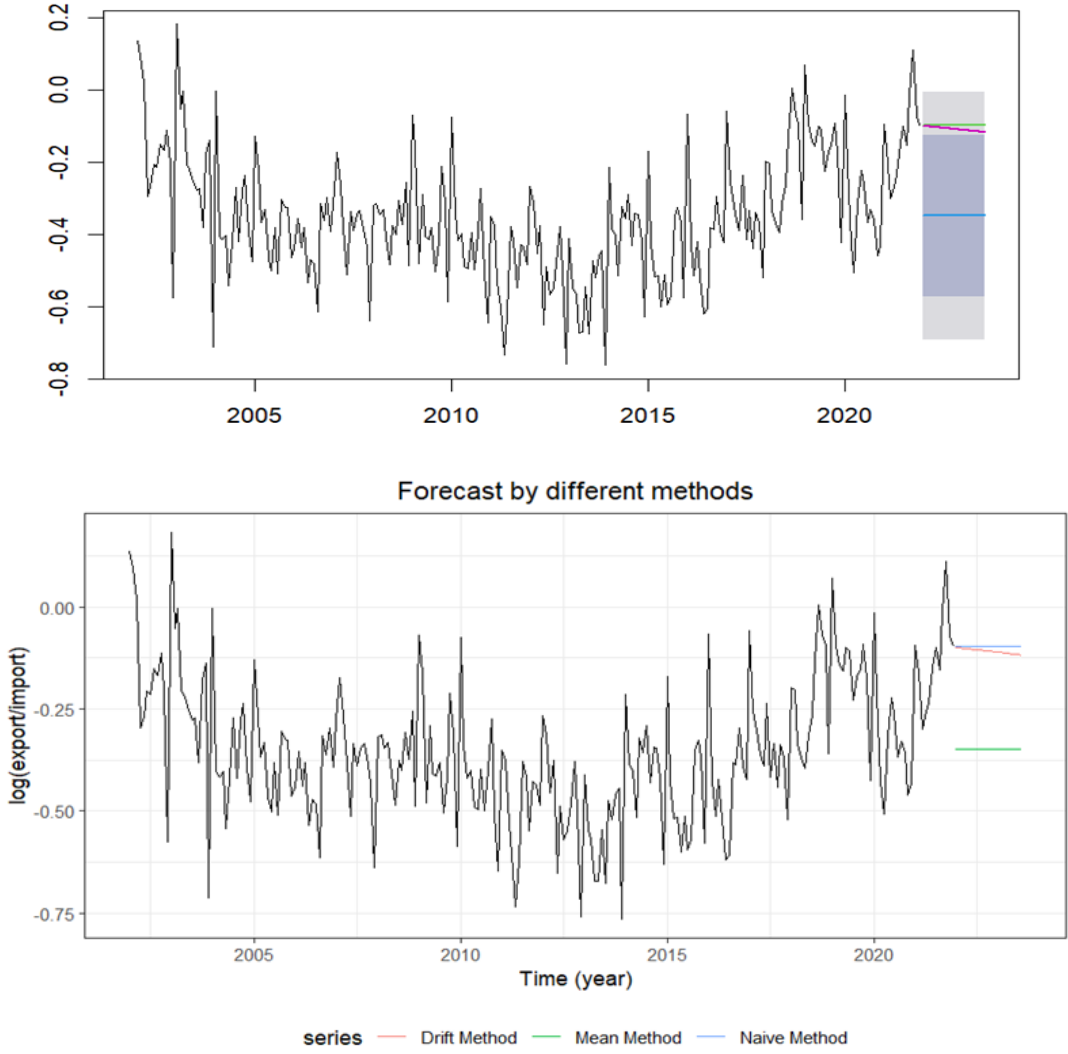


**Şekil 40:** Zaman Serisi ayrışımı

Zaman serisi analizi için kullanılan tekniklerden biri ARIMA modelidir. Bu, ARIMA kullanarak zaman serisi verilerini analiz edebileceğimiz ve mevcut serilerden tahmin değerleri alabildiğimiz genel süreçtir. Analiz için ARIMA (1,1,2) (2,1,1) modelinin en uygun yöntem olduğu görülmektedir. Şekil 41’de ARIMA (1,1,2) (2,1,1) modeli gösterilmektedir.




**Şekil 41:** ARIMA modeli kullanarak tahmin



**Şekil 42:** Farklı tahmin yöntemleri

Şekil 42’de farklı tahmin modellerinin sonuçları gösterilmektedir. Drift, Mean ve Naive metotlarının uygulanan yıllara göre sonuçları verilmektedir.



**Şekil 43:** Eğitimi tamamlanan NARX Sınır Ağının dış ticaret analizi



Şekil 43'te NARX sinir ağının yaptığı tahmin değerleri ile gerçek tahmin değerlerinin karşılaştırmasının yapıldığı grafik gösterilmiştir. 2002-2021 yılları arasındaki 99 fasıl grubunun verilerine baktığımız zaman NARX sinir ağının ürettiği verilerin dış ticaret verilerine göre yakın olduğu görülmektedir. Yapılan uygulamada zaman serisi ve YSA yöntemi ile dış ticaret analiz edilmiştir. Sonuçlar Eurostat uyumlaştırılmış emtia tanımı ve kodlama sistemi bölümlerinin 99 fasıl grubunu 21 bölümde ele alarak Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hataya (MAE) göre karşılaştırma yapılmıştır.

**Tablo 7: Zaman Serisi Yöntemleri ve YSA yöntemi ile dış ticareti analizi (RMSE)**

	Mean	Drift	Naive	ARIMA	Regresyon with ARIMA	YSA 10-1 2 gecikme	YSA 10-1 4 gecikme
<b>Tüm Fasıllar</b>	0.257	0.340	0.324	0.251	0.208	0.314	0.104
1: Canlı hayvanlar; hayvansal ürünler	0.549	0.744	0.743	0.500	0.779	0.888	1.450
2: Bitkisel ürünler	0.560	0.550	0.555	0.555	0.655	0.822	0.928
3: Hayvansal, bitkisel veya mikrobiyal yağlar ve bunların parçalanma ürünleri; hazırlanmış yemeklik yağlar, hayvan veya bitki mumları	1.686	1.244	1.253	1.340	1.343	1.522	1.886
4: Hazır gıda maddeleri; içecekler, alkollü içecekler ve sirke; tütün ve üretilmiş tütün ikameleri, nikotin içerip içermediğine bakılmaksızın, yanmadan solunmaya yönelik ürünler	0.149	0.169	0.176	0.181	0.161	0.171	0.173
5: Mineral ürünler, kimya veya ilgili endüstrilerin ürünleri	0.436	0.909	0.890	0.505	0.577	0.542	0.828
6: Kimya veya benzeri endüstrilerin ürünleri	0.330	0.224	0.225	0.229	0.361	0.295	0.228
7: Plastikler ve bunların ürünleri; kauçuk ve benzeri ürünler	0.512	0.193	0.213	0.173	0.107	0.381	0.132
8: Ham postlar ve deriler, deri, kürk derileri ve bunların eşyaları; saraçlık ve koşum takımı, seyahat eşyaları, el çantaları	0.853	0.501	0.489	0.408	0.394	0.460	0.554
9: Odun ve odun ürünleri; odun kömürü, mantar ve mantar ürünleri; saman veya diğer örgü malzemeleri imalatı, sepet eşyaları ve hasır işleri	2.197	1.028	1.024	0.345	0.413	0.450	0.889
10: Odun hamuru veya diğer lifli selülozik malzeme; geri kazanılmış (atık ve hurda) kâğıt veya karton; kâğıt ve karton ve bunların ürünleri	1.072	0.215	0.219	0.185	0.260	0.548	0.341
11: Tekstil ve tekstil eşyaları	0.405	0.182	0.184	0.183	0.216	0.097	0.208
12: Ayakkabılar, başlıklar, şemsiyeler, güneş şemsiyeleri, bastonlar, koltuk bastonları, kamçılar, bitkiler ve yapay çiçekler	0.693	0.804	0.793	0.692	0.873	1.181	1,128
13: Taş, alçı, çimento, asbest, mika veya benzeri malzemelerden mamuller; seramik ürünler, cam eşyalar	0.257	0.548	0.530	0.166	0.225	0.202	0.175
14: Doğal veya kültür incileri, değerli veya yarı değerli taşlar, değerli metaller, değerli metallerle kaplanmış metaller ve bunların ürünleri; taklit mücevherler, madeni para	1.346	2.238	2.064	2.162	2.008	2.204	0.809
15: Baz metaller ve baz metal ürünleri	0.644	0.279	0.302	0.333	0.330	0.415	0.165
16: Makine ve mekanik aletler; elektrikli ekipmanlar, parçaları; ses kayıt cihazları ve çoğaltıcıları, televizyon görüntü ve ses kayıt cihazları ve çoğaltıcıları	0.323	0.229	0.227	0.124	0.314	0.223	0.146
17: Araçlar, uçaklar, gemiler ve ilgili nakliye ekipmanları	0.499	0.770	0.753	0.840	0.314	0.526	0.490
18: Optik, fotografik, sinematografik, ölçme, kontrol etme, hassas, tıbbi veya cerrahi alet ve aparatlar; saatler ve saatler, müzik aletleri; bunların parça ve aksesuarları	0.712	0.275	0.290	0.241	0.240	0.364	0.548
19: Silah ve mühimmat; parçaları ve aksesuarları	2.355	1.006	0.999	1.312	1.178	0.766	2.340
20: Çeşitli mamul ürünler	0.979	0.155	0.159	0.196	0.335	0.253	0.182
21: Sanat eserleri, koleksiyon parçaları ve antikalar	1.929	1.595	1.588	1.611	1.693	2,367	4,381

**Tablo 8:** Zaman Serisi Yöntemleri ve YSA yöntemi ile dış ticareti analizi (MAE)

	Mean	Drift	Naive	ARIMA	Regresyon with ARIMA	YSA 10-1 2 gecikme	YSA 10-1 4 gecikme
<b>Tüm Fasıllar</b>	0.234	0.321	0.305	0.225	0.184	0.301	0.079
1: Canlı hayvanlar; hayvansal ürünler	0.459	0.616	0.615	0.422	0.663	0.603	0.891
2: Bitkisel ürünler	0.424	0.412	0.413	0.413	0.483	0.585	0.727
3: Hayvansal, bitkisel veya mikrobiyal yağlar ve bunların parçalanma ürünleri; hazırlanmış yemeklik yağlar, hayvan veya bitki mumları	1.321	0.802	0.803	0.866	0.900	1.003	1.339
4: Hazır gıda maddeleri; içecekler, alkollü içecekler ve sirke; tütün ve üretilmiş tütün ikameleri	0.111	0.130	0.138	0.151	0.124	0.135	0.138
5: Mineral ürünler, kimya veya ilgili endüstrilerin ürünleri	0.310	0.801	0.779	0.369	0.380	0.342	0.674
6: Kimya veya benzeri endüstrilerin ürünleri	0.273	0.173	0.175	0.189	0.301	0.200	0.178
7: Plastikler ve bunların ürünleri; kauçuk ve benzeri ürünler	0.508	0.182	0.202	0.161	0.089	0.300	0.103
8: Ham postlar ve deriler, deri, kürk derileri ve bunların eşyaları; saraçlık ve koşum takımı, seyahat eşyaları, el çantaları	0.801	0.419	0.402	0.339	0.305	0.349	0.435
9: Odun ve odun ürünleri; odun kömürü, mantar ve mantar ürünleri; saman veya diğer örgü malzemeleri imalatı, sepet eşyaları ve hasır işleri	2.179	0.989	0.986	0.241	0.328	0.341	0.812
10: Odun hamuru veya diğer lifli selülozik malzeme; geri kazanılmış (atık ve hurda) kâğıt veya karton; kâğıt ve karton	1.063	0.163	0.185	0.156	0.222	0.422	0.241
11: Tekstil ve tekstil eşyaları	0.368	0.145	0.149	0.152	0.191	0.079	0.180
12: Ayakkabılar, başlıklar, şemsiyeler, güneş şemsiyeleri, bastonlar, yapay çiçekler	0.606	0.680	0.667	0.570	0.774	0.161	0.878
13: Taş, alçı, çimento, asbest, mika veya benzeri malzemelerden mamuller; seramik ürünler, cam ve cam eşyalar	0.236	0.540	0.520	0.140	0.200	0.190	0.139
14: Doğal veya kültür incileri, değerli veya yarı değerli taşlar, değerli metaller, değerli metallere kaplanmış metaller ve bunların ürünleri; taklit mücevherler, madeni para	1.298	2.155	1.996	2.093	1.954	2.173	0.616
15: Baz metaller ve baz metal ürünleri	0.614	0.240	0.263	0.293	0.283	0.375	0.127
16: Makine ve mekanik aletler; elektrikli ekipmanlar parçaları, ses kayıt cihazları ve çoğaltıcılar televizyon görüntü ve ses kayıt cihazları	0.299	0.194	0.192	0.100	0.240	0.191	0.116
17: Araçlar, uçaklar, gemiler ve ilgili nakliye ekipmanlar	0.432	0.726	0.710	0.761	0.239	0.516	0.430
18: Optik, fotografik, sinematografik, ölçme, kontrol etme, hassas, tıbbi veya cerrahi alet ve aparatlar; saatler ve saatler, müzik aletleri; bunların parça ve aksesuarlar	0.676	0.222	0.246	0.199	0.184	0.249	0.368
19: Silah ve mühimmat parçaları ve aksesuarlar	2.134	0.860	0.862	1.104	1.059	0.693	1.676
20: Çeşitli mamul ürünler	0.967	0.138	0.139	0.173	0.302	0.201	0.145
21: Sanat eserleri, koleksiyon parçaları ve antikalar	1.513	1.225	1.220	1.262	1.222	1.613	4.155

## 4. SONUÇ

Dış ticaret, finansal hizmetler, bankacılık ve sigortacılık gibi çeşitli uygulamalarda zengin verilerin, yenilikçi algoritmaların ve yeni yöntemlerin bulunabilirliği ile makine öğrenimi ve yapay zekanın faydalarından yararlanma potansiyeli çok yüksek olan sektörlerden biri olmaya devam etmektedir. Dış ticaret yapısında zaman içinde meydana gelecek değişimlerin incelenmesi, ithalat-ihracat konularında gerçekçi analizlerin yapılması son derece önemlidir. Bu çalışmada Türkiye ve Almanya dış ticaretinin mal gruplarına göre yapay sinir ağı yöntemi ile analizinin tarihsel süreç içerisindeki değişimi incelenmiştir. Zaman serisi yöntemleri ve YSA yöntemi ile dış ticaret analiz edilerek en iyi mimariyi belirlemek bu tezin ana amacı olarak benimsenmiştir.

Çalışmanın seçilen çıktı değişkeni ihracat/ithalat, girdi değişkenleri Türkiye sanayi üretim endeksi, Almanya sanayi üretim endeksi, reel döviz kurudur. Zaman serilerini tahmin etmek için birçok yaklaşım geliştirilmiştir. Tahmin modelinin oluşturulmasında yaygın olarak kullanılan ARIMA, Regresyon ve Benchmark yöntemleri bu çalışmada kullanılan yöntemler arasındadır. Uygulanan diğer yöntem ise NARX sinir ağıdır. Geliştirilen modele, geçmişe ait Ocak 2002 ile Aralık 2021 tarihleri arasındaki Türkiye İstatistik Kurumu (TÜİK) ve International Monetary Fund (IMF) kaynaklarından alınan veriler analiz edilmiştir. NARX (Nonlinear Autoregressive With External Input) ağı için ara katman nöron sayısı 10 olarak alınırken, gecikme sayısı 2 ve 4 olarak alınmıştır. Eğitim oranı %80, Doğrulama oranı %10, Test oranı %10 olarak belirlenmiştir. Performans ölçütü olarak RMSE ve MAE değerleri dikkate alınmıştır.

Tahmin için yöntemler karşılaştırıldığında tüm fasıl grupları için tek gizli katmanlı NARX yönteminin diğer yöntemlerden daha iyi sonuç verdiği söylenebilir. Ayrıca karşılaştırılan RMSE 0.104 ve MAE 0.079 performans ölçütlerine bakıldığı zaman NARX 4 gecikmeli sinir ağının 2 gecikmeli sinir ağına göre daha başarılı olduğu görülmektedir. Bölüm 11: Tekstil ve Tekstil Eşyaları için YSA 10-1 2 gecikmeli sinir ağı analiz için kullanılan yöntemler RMSE 0.097 MAE 0.079 değeriyle diğer yöntemleri yenmiştir. Bölüm 14: Doğal veya Kültür İncileri, Değerli veya Yarı Değerli Taşlar, Değerli Metaller, Değerli Metallerle Kaplanmış Metaller ve Bunların Ürünleri; Taklit Mücevherler, Madeni Para için yapılan analizde YSA 10-1 4 gecikmeli sinir ağı RMSE 0.809 MAE 0.616 değerleriyle diğer yöntemlerden daha başarılıdır. Bölüm 15: Baz

Metaller ve Baz Metal Ürünleri 10-1 4 gecikmeli YSA modeli RMSE 0.165 MAE 0.127 değerleriyle uygulanan diğer yöntemleri yendiği sonucuna ulaşılmıştır. Son olarak Bölüm 19: Silah ve Mühimmat; Parçaları ve Aksesuarları 10-1 2 gecikmeli model RMSE 0.766 MAE 0.693 değerleriyle diğer yöntemlerden daha iyi sonuç vermiştir. Görüldüğü gibi, uygulanan modelin ürettiği dış ticaret tahmin değerleri birbirine oldukça yakın olmasına karşın, gerçeğe yakınlık anlamında yapay sinir ağları analizi bu veriler için daha iyi sonuçlar vermektedir.

Bölüm 1: Canlı Hayvanlar; Hayvansal Ürünlerde ARIMA yönteminin RMSE 0.500 ve MAE 0.422 değerleri en iyi performansı göstermiştir. Bölüm 7: Plastikler ve bunların ürünleri; kauçuk ve benzeri ürünler Regresyon yönteminde RMSE 0.107 ve MAE 0.089 değerleri performans sonuçları uygulanan diğer yöntemleri yendiği görülmektedir. Bölüm 8: Ham postlar ve deriler, deri, kürk derileri, seyahat eşyaları, el çantaları Regresyon yönteminde RMSE değeri 0.394 MAE değeri 0.305 değerleri en iyi performansı göstermiştir. Bölüm 9: Odun ve Odun Ürünleri; Odun Kömürü, Mantar ve Mantar Ürünleri; Sepet Eşyaları ve Hasır İşleri'nde ARIMA yöntemi RMSE 0.345 MAE 0.241 değerleri ile en iyi sonucu vermektedir. Bölüm 10: Odun Hamuru Geri Kazanılmış (Atık ve Hurda) Kâğıt veya Karton; Kâğıt ve Karton ve Bunların Ürünlerinde ARIMA yönteminde RMSE 0.185 MAE değeri 0.156'dır. Bölüm 12: Ayakkabılar, Başlıklar, Şemsiyeler, Güneş Şemsiyeleri, Bastonlar, Koltuk Bastonları, Kamçılar, Bitkiler ve Bunların Aksesuarları; Hazırlanmış Tüylere ve Bunlardan Yapılan Eşyalar, Yapay Çiçekler'in ARIMA metodunda RMSE 0.692 MAE değeri 0.570 olarak elde edilmiştir. Bölüm 13: Taş, Alçı, Çimento, Asbest, Mika veya Benzeri Malzemelerden Mamuller; Seramik Ürünler, Cam ve Cam Eşyalar ARIMA yöntemi RMSE değeri 0.166 MAE değeri 0.140 elde edilerek diğer yöntemlerden daha iyi sonuca ulaşılmıştır. Bölüm 16: Makine ve Mekanik Aletler; Elektrikli Ekipmanlar, Parçaları; Ses Kayıt Cihazları ve Çoğaltıcıları, Televizyon Görüntü ve Ses Kayıt Cihazları ve Çoğaltıcıları ve Bu Tür Eşyaların Parça ve Aksesuarlarında RMSE değeri 0.124 MAE ise 0.100 olarak elde edilmiştir. Bölüm 18: Optik, Fotografik, Sinematografik, Ölçme, Kontrol Etme, Hassas, Tıbbi veya Cerrahi Alet ve Aparatlar; Saatler ve Müzik Aletler'ine baktığımız zaman RMSE 0.240 MAE 0.184 ile Regresyon yöntemi başarılıdır.

Bölüm 2: Bitkisel Ürünler Drift yönteminde RMSE 0.550 MAE 0.412 performansı ile uygulanan Mean, Naive ARIMA, Regresyon ve YSA yöntemlerinden daha iyi bir performans göstermiştir. Bölüm 3: Hayvansal, Bitkisel veya Yemeklik

Yağlar, Hayvan veya Bitki Mumlarında yapılan RMSE 1.244 MAE 0.802 sonuçlarıyla Drift yöntemi diğer yöntemleri yenmiştir. Bölüm 4: Hazır Gıda Maddeleri; İçecekler, Alkollü İçecekler ve Sirke; Tütün ve Üretilmiş Tütün İkamelerinde Mean metodu RMSE değeri 0.149 MAE değeri 0.111 olarak elde edilmiştir. Bölüm 5: Mineral Ürünler, Kimya veya İlgili Endüstrilerin Ürünleri'nde Mean yönteminin RMSE sonucu 0.436 MAE sonucu 0.310 olarak elde edilmiştir. Bölüm 6: Kimya veya Benzeri Endüstrilerin Ürünlerinde RMSE 0.224 MAE 0.173 değeriyle en iyi sonucu veren Drift yöntemidir. Bölüm 20: Çeşitli Mamul Ürünlerde Drift modelinin performansı RMSE 0.155 MAE 0.138 değerleriyle ARIMA, Mean, Naive, YSA modeline göre daha iyi sonuç vermiştir. Bölüm 21: Sanat eserleri, koleksiyon parçaları ve antikalar da RMSE 1.588 MAE 1.220 değerleriyle Naive yönteminin diğer yöntemlerden üstün geldiği görülmektedir.

Yapılan bu çalışmada Türkiye Almanya dış ticaretinin zaman serisi ve yapay sinir ağları metoduyla analizi yapılarak, ithalat ihracat ilişkileri için öngörü sağlanması amaçlanmıştır. Yapay sinir ağları öğrenme ve analiz konusunda başarılı olsa da yapılan denemelerde farklı sonuçlar vermesi, kullanılan verilerin kısa zaman diliminde olması çalışmanın dezavantajlarından. Bunlara ek olarak açık sistemlerde yapay zekanın zaman serisini tahmin etmesi zor olsa da uygulanan NARX sinir ağının performans kriterlerine bakıldığı zaman toplam fasılda başarılı olduğu görülmektedir. Hata oranı en az olan model ile elde edilmiş dış ticaret ilişkisi incelendiğinde, uygulanan yöntemlerin güvenilir bir sonuç vermesi açısından literatüre katkı yapabileceği görülmektedir.

Ticaret verilerinde, genel ticaret toplamında sonuç yapay sinir ağıyla daha iyi bulunurken detaya indiğimizde alt gruplarda farklı sonuçlar ortaya çıkabilmektedir. Dolayısıyla araştırmacıların bu konuyu dikkate alarak çalışmalarına yön vermesi gerekmektedir. Bunun yanı sıra daha uzun bir zaman dilimi kullanılarak, diğer ülkelerin de dış ticaret ilişkileri için modelin uygulaması ve faydası yaygınlaştırılabilir.

## KAYNAKÇA

- Abdin, M. (2001). Development of German Foreign Trade in 2000. *Stahl Und Eisen*, 121(7), 71–77.
- Abraham, E., Reis, J., Colossetti, A., Souza, A., & Tolo, R. (2017). Neural Network System to Forecast the Soybean Exportation on Brazilian Port of Santos. *IFIP Advances in Information and Communication Technology*, 514(August). <https://doi.org/10.1007/978-3-319-66926-7>
- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. In *Journal of Pharmaceutical and Biomedical Analysis* (Vol. 22). [www.elsevier.com/locate/jpba](http://www.elsevier.com/locate/jpba)
- Alaloul, W. S., Liew, M. S., Wan Zawawi, N. A., Mohammed, B. S., & Adamu, M. (2018). An Artificial neural networks (ANN) model for evaluating construction project performance based on coordination factors. *Cogent Engineering*, 5(1), 1–18. <https://doi.org/10.1080/23311916.2018.1507657>
- Alam, T. (2018). Forecasting Exports and Imports Through Artificial Neural Network and Autoregressive Integrated Moving Average. *Decision Science Letters*, 249–260.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2018). Understanding of a convolutional neural network. *Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017, 2018-January*, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Ali Choudhary, M., & Haider, A. (2012). Neural network models for inflation forecasting: An appraisal. *Applied Economics*, 44(20), 2631–2635. <https://doi.org/10.1080/00036846.2011.566190>
- Alsmadi, M. K., Omar, K. bin, Noah, S. A., & Almarashdah, I. (2009). Performance comparison of multi-layer perceptron (Back Propagation, Delta Rule and Perceptron) algorithms in neural networks. *2009 IEEE International Advance Computing Conference, IACC 2009*, 296–299. <https://doi.org/10.1109/IADCC.2009.4809024>
- Amidi, A., & Amidi, S. (n.d.). *Recurrent Neural Network Hand Book*.
- Amiri, R., Mehrpouyan, H., Fridman, L., Mallik, R. K., Nallanathan, A., & Matolak, D. (2018). A Machine Learning Approach for Power Allocation in HetNets

- Considering QoS. *IEEE International Conference on Communications, 2018-May*.  
<https://doi.org/10.1109/ICC.2018.8422864>
- Anderson, D., & Mcneill, G. (1992). *ARTIFICIAL NEURAL NETWORKS TECHNOLOGY A DACS State-of-the-Art Report*.
- Andriy Burkov, B. (2019). *The Hundred-Page Machine Learning* (Draft).
- Arslan, A., & Ince, R. (1996). The neural network approximation to the size effect in fracture of cementitious materials. *Engineering Fracture Mechanics*, 54(2), 249–261. [https://doi.org/10.1016/0013-7944\(95\)00140-9](https://doi.org/10.1016/0013-7944(95)00140-9)
- Aşkın, D., İskender, İ., & Mamızadeh, A. (2011). *Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformör Sargısının Termal Analizi*. 26(4), 905–913.
- Asokan, M. (2022). *A study of forecasts in Financial Time Series using Machine Learning methods Traditional vs Machine learning approach* [Linköping University]. [www.liu.se](http://www.liu.se)
- Balassa, B. (1978). Exports and Economic Growth Farther Evidence. In *Journal of Development Economics* (Vol. 5). Holland Publishing Company.
- Banerjee Roy, N., & Bhattacharya, K. (2022). *Application of Signal Processing Tools and Artificial Neural Network in Diagnosis of Power System Faults* (Taylor Francis Group, Ed.; CRC Press).
- Baratov, K. (2005). *Türkiye İktisat Tarihi 1908-2002*. İmge Kitabevi.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. In *Journal of Methods Microbiological Journal of Microbiological Methods* (Vol. 43). [www.elsevier.com/locate/jmicmeth](http://www.elsevier.com/locate/jmicmeth)
- Batres-Estrada, G. (2015). *Deep Learning for Multivariate Financial Time Series*.
- Binner, J. M., Bissoondeal, R. K., Elger, T., Gazely, A. M., & Mullineux, A. W. (2005). A comparison of linear forecasting models and neural networks: An application to Euro inflation and Euro Divisia. *Applied Economics*, 37(6), 665–680. <https://doi.org/10.1080/0003684052000343679>
- Bonaccorso, G. (2017). *Machine learning algorithms : reference guide for popular algorithms for data science and machine learning*.
- Britannica. (2022). *Years of crisis, 1920-23*.
- Brownlee, J. (2016). *Deep Learning With Python Develop Deep Learning Models On Theano And TensorFlow Using Keras i Deep Learning With Python*.



- Buduma, N., & Locascio, N. (2017). *Fundamentals of deep learning : designing next-generation machine intelligence algorithms* (Oreilly).
- Bullinaria, A. , J. (2015). *Hebbian Learning and Gradient Descent Learning*. Neural Computation:05.
- Buteikis, A. (n.d.). *03 Time series with trend and seasonality components*. <http://web.vu.lt/mif/a.buteikis/>
- Caron, M., Bojanowski, P., Joulin, A., & Douze, M. (2018). *Deep Clustering for Unsupervised Learning of Visual Features*. <http://arxiv.org/abs/1807.05520>
- Çelik, K. (2015). *Uluslararası İktisat*. Celepler Matbaacılık Yayın Dağıtım.
- Chan, F., & Mátyás, L. (n.d.). *Econometrics with Machine Learning*.
- Çınaroğlu, S. (2017). Sağlık Harcamasının Tahmininde Makine Öğrenmesi Regresyon Yöntemlerinin Karşılaştırması. *Uludağ University Journal of The Faculty of Engineering*, 22(2), 179–200. <https://doi.org/10.17482/uumfd.338805>
- Constantino, H. A., Fernandes, P. O., & Teixeira, J. P. (2016). Tourism demand modelling and forecasting with artificial neural network models: The Mozambique case study. *Tékhné*, 14(2), 113–124. <https://doi.org/10.1016/j.tekhne.2016.04.006>
- CQ Researcher. (2022). *Foreign Trade in German Economy*. CQ Researcher.
- Çuhadar, M. (2006). *Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama)*.
- Diebold, F. X. (2019). *Time Series Econometrics a Concise Course*. [sas.upenn.edu/~fdield/teaching706/TimeSeiesEconometrics.pdf](http://sas.upenn.edu/~fdield/teaching706/TimeSeiesEconometrics.pdf)
- Dike, H. U., Zhou, Y., Deveerasetty, K. K., & Wu, Q. (2019). Unsupervised Learning Based On Artificial Neural Network: A Review. *2018 IEEE International Conference on Cyborg and Bionic Systems, CBS 2018*, 322–327. <https://doi.org/10.1109/CBS.2018.8612259>
- Dinçer, Zeki, M. (n.d.). *Uluslararası İktisat Teorisi ve Politikası*. İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi.
- Ding, B., Qian, H., & Zhou, J. (2018). Activation functions and their characteristics in deep neural networks. *Proceedings of the 30th Chinese Control and Decision Conference, CCDC 2018*, 1836–1841. <https://doi.org/10.1109/CCDC.2018.8407425>

- Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2008). Introduction to Artificial Neural Network. *Certified International Journal of Engineering and Innovative Technology (IJEIT)*, 9001(1), 2277–3754.
- Dridi, S. (2021). *Unsupervised Learning-A Systematic Literature Review a Preprint*.
- Dumor, K., & Yao, L. (2019). Estimating China's trade with its partner countries within the belt and road initiative using neural network analysis. *Sustainability (Switzerland)*, 11(5), 1–22. <https://doi.org/10.3390/su11051449>
- Eğrioğlu, E., Yolcu, U., Aladağ, Ç. H., Uslu, V. R., & Erilli, N. A. (2010). Türkiye de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı ile Öngörüsü. *Doğuş Üniversitesi Dergisi*, 1(11), 42–55. <https://doi.org/10.31671/dogus.2019.175>
- El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? In *Machine Learning in Radiation Oncology* (pp. 3–11). Springer International Publishing. [https://doi.org/10.1007/978-3-319-18305-3\\_1](https://doi.org/10.1007/978-3-319-18305-3_1)
- Erdal, H., & Yapraklı, Şükrü, T. (2016). Firma Başarısızlığı Tahminlemesi: Makine Öğrenmesine Dayalı Bir Uygulama. *Bilişim Teknolojileri Dergisi*, 9(1), 21–0. <https://doi.org/10.17671/btd.21000>
- Ertuğrul, İ., & Bekin, A. (2016). Comparative Analyses of Forecasting Models of Artificial Neural Network and Time Series Analyses for Selected Main Food Prices in Turkey. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(13), 253–280. <https://doi.org/10.9775/kauibfd.2016.013>
- Farag, F. S., Ab-Rahim, R., & Mohd-Kamal, K.-A. (2021). Foreign Trade and Economic Growth Relationship: Empirical Evidence from Libya. *International Journal of Academic Research in Business and Social Sciences*, 11(4), 181–190. <https://doi.org/10.6007/ijarbss/v11-i4/9659>
- Feng, J., & Lu, S. (2019). Performance Analysis of Various Activation Functions in Artificial Neural Networks. *Journal of Physics: Conference Series*, 1237(2). <https://doi.org/10.1088/1742-6596/1237/2/022030>
- Gabralı, D., & Aslan, Z. (2020). Güneş Enerjisi Potansiyelinin Çoklu Lineer Regresyon ve Yapay Sinir Ağları ile Modellenmesi. *AURUM Mühendislik Sistemleri ve Mimarlık Dergisi*, 4(1), 23–36.
- Gao, J., Li, P., Chen, Z., & Zhang, J. (2020). A Survey on Deep Learning for Multimodal Data Fusion. In *Neural Computation* (Vol. 32, Issue 5, pp. 829–864). MIT Press Journals. [https://doi.org/10.1162/neco\\_a\\_01273](https://doi.org/10.1162/neco_a_01273)
- Gers, F. (2001). *Long Short-Term Memory in Recurrent Neural Networks*.

- Godin, F., Degraeve, J., Dambre, J., & de Neve, W. (2018). Dual Rectified Linear Units (DReLU): A replacement for tanh activation functions in Quasi-Recurrent Neural Networks. *Pattern Recognition Letters*, 116, 8–14. <https://doi.org/10.1016/j.patrec.2018.09.006>
- Gogas, P., & Papadimitriou, T. (2021). Machine Learning in Economics and Finance. In *Computational Economics* (Vol. 57, Issue 1). Springer. <https://doi.org/10.1007/s10614-021-10094-w>
- Goverdhan, G., Khare, S., & Article, R. (2022). *Time Series Prediction: Comparative Study of ML Models in the Stock Market*. <https://doi.org/10.21203/rs.3.rs-2183122/v1>
- Gültepe, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. *European Journal of Science and Technology*, 16, 8–15. <https://doi.org/10.31590/ejosat.530347>
- Hammer, B. (2000). *Lecture Notes in Control and Information Sciences 254* Editor: M. Thoma (M. Thoma, Ed.; Springer-Verlag).
- Hamzaçebi, C., & Kutay, F. (2004). Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3), 0. <https://doi.org/10.17341/gummfd.19292>
- Hinton, E. , G., & Salakhutdinov, R. ,R. (2006). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313(5786), 502–504. <https://doi.org/10.1126/science.1129198>
- Hyndman, R., & Athanasopoulos, G. (2019). *Forecasting : principles and practice*.
- İnat, K. (2016). Economic Relations Between Germany and Turkey. *Insight Turkey*, 18(1), 21–34.
- İnsights. (2019, October). *Australian Government Department of Foreign Affairs and Trade*.
- ITC. (2022, May 16). *Trade Map*.
- Jain, A. A., Mao, J., & Mohiuddin, K. M. (1996). Artificial Neural Networks:A Tutorial. *Theme Feature*, 31–44.
- Johansen, S. (2000). Modelling of cointegration in the vector autoregressive model. In *Economic Modelling* (Vol. 17).
- Jose, J. (2022). *INTRODUCTION TO TIME SERIES ANALYSIS AND ITS APPLICATIONS*. <https://www.researchgate.net/publication/362389180>

- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement Learning: A Survey. In *Journal of Artificial Intelligence Research* (Vol. 4).
- Karagülle, Y. E. (2018). *Forecasting Electricity Prices in Turkey: A Comparison of Classical Econometric and Machine Learning Techniques* [Yüksek Lisans Tezi]. İstanbul Teknik Üniversitesi.
- Karahan, M. (2011). *İstatistiksel tahmin yöntemleri: Yapay sinir ağları metodu ile ürün talep tahmini uygulaması*. Selçuk Üniversitesi.
- Kazgan, G. (2006). *Tanzimat'tan 21. Yüzyıla Türkiye Ekonomisi*. İstanbul Bilgi Üniversitesi Yayınları.
- Klass, J. (2019). *Machine Learning for Finance* (B. R. Pohlmann, Frank Clarke, Ed.; Packtpub).
- Kohzadi, N., Boyd, M. S., Kaastra, I., Kermanshahi, B. S., & Scuse, D. (1995). *Neural Networks for Forecasting: An Introduction*. 463–474.
- Koopman, G. (2010). German Foreign Economic Policy in the Age of Globalisation. In *Centre for Comparative Economics* (Vol. 44, Issue December 2008).
- Kothari, S. C., & Oh, H. (1993). Neural Networks for Pattern Recognition. *Advances in Computers*, 37, 119–166.
- Kuan, C., & White, H. (1994). Artificial Neural Network: Economic Perspective. *Econometric Reviews*, 13, 139–143.
- Kurt, R., Karayılmazlar, S., İmren, E., & Çabuk, Y. (2017). Yapay Sinir Ağları İle Öngörü Modellemesi: Türkiye Kağıt-Karton Sanayi Örneği. *Bartın Orman Fakültesi Dergisi*, 19(2), 99–106. <https://doi.org/10.24011/barofd.334773>
- Lera, G., & Pinzolas, M. (2002). Neighborhood based Levenberg-Marquardt algorithm for neural network training. *IEEE Transactions on Neural Networks*, 13(5), 1200–1203. <https://doi.org/10.1109/TNN.2002.1031951>
- Li, W., Wu, H., Zhu, N., Jiang, Y., Tan, J., & Guo, Y. (2021). Prediction of dissolved oxygen in a fishery pond based on gated recurrent unit (GRU). *Information Processing in Agriculture*, 8(1), 185–193. <https://doi.org/10.1016/j.inpa.2020.02.002>
- Li, X., Ma, X., Xiao, F., Wang, F., & Zhang, S. (2020). Application of gated recurrent unit (GRU) neural network for smart batch production prediction. *Energies*, 13(22). <https://doi.org/10.3390/en13226121>
- Lin, T., Horne, B. G., Tiño, P., & Giles, C. L. (1996). Learning long-term dependencies in NARX recurrent neural networks. *IEEE Transactions on Neural Networks*, 7(6), 1329–1338. <https://doi.org/10.1109/72.548162>

- Lindlar, L., & Holtfrerich, C.-L. (1997). Geography, exchange rates and trade structures: Germany's export performance since the 1950s. *European Review of Economic History*, 1(2), 217–246. <https://doi.org/10.1017/s1361491697000105>
- Liu, H. (2010). On the Levenberg-Marquardt training method for feed-forward neural networks. *Proceedings - 2010 6th International Conference on Natural Computation, ICNC 2010*, 1, 456–460. <https://doi.org/10.1109/ICNC.2010.5583151>
- Lynn, H. M., Pan, S. B., & Kim, P. (2019). A Deep Bidirectional GRU Network Model for Biometric Electrocardiogram Classification Based on Recurrent Neural Networks. *IEEE Access*, 7, 145395–145405. <https://doi.org/10.1109/ACCESS.2019.2939947>
- Mahesh, B. (2018). Machine Learning Algorithms-A Review Machine Learning Algorithms-A Review View project Self Flowing Generator View project Batta Mahesh Independent Researcher Machine Learning Algorithms-A Review. *International Journal of Science and Research*. <https://doi.org/10.21275/ART20203995>
- McInerney, M., & Dhawan, A. (1994). Training the self-organizing feature map using hybrids of genetic and Kohonen methods. *IEEE International Conference on Neural Networks - Conference Proceedings*, 2, 641–644. <https://doi.org/10.1109/icnn.1994.374250>
- Mclaughlin, R. (1983). *Forecasting Model: Sophisticated or Naive?*
- Melssen, W. J., Smits, J. R. M., Buydens, L. M. C., & Kateman, G. (1994). Chemometrics and intelligent laboratory systems: Laboratory information management Part II. Tutorial Using artificial neural networks for solving chemical problems Kohonen self-organising feature maps and Hopfield networks. In *Chemometrics and Intelligent Laboratory Systems* (Vol. 23).
- Mendes, R., Cortez, P., Rocha, M., & Neves, J. (2002). Particle swarms for feedforward neural network training. In *Proceedings of the International Joint Conference on Neural Networks* (Vol. 2, pp. 1895–1899). <https://doi.org/10.1109/ijcnn.2002.1007808>
- Mercioni, A. , M., & Holban, S. (2020). The Most Used Activatiob Functions: Classic Versus Current. *15 Th International Conference on Development and Application Systems*.
- Millstain, F. (2018). *Convolutional Neural Networks in Python* (F. Millstain, Ed.).
- Niebur, D., & Germond, A. J. (1992). Power System Static Security Assessment Using the Kohonen Neural Network Classifier. *IEEE Transactions on Power Systems*, 7(2), 865–872. <https://doi.org/10.1109/59.141797>

- Noureen, S., Atique, S., Roy, V., & Bayne, S. (2019). Analysis and application of seasonal ARIMA model in Energy Demand Forecasting: A case study of small scale agricultural load. *Midwest Symposium on Circuits and Systems, 2019-August*, 521–524. <https://doi.org/10.1109/MWSCAS.2019.8885349>
- Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). *Activation Functions: Comparison of trends in Practice and Research for Deep Learning*. <http://arxiv.org/abs/1811.03378>
- Oancea, B., & Cristian Ciucu, Ş. (2013). Time Series Forecasting Using Neural Networks. *Challenges of the Knowledge Society. IT in Social Science*, 1402–1048.
- Olivas, S. E., Guerro, J., Sober, M., Benedito, J., & Loez, A. (2010). *Handbook of research on machine learning applications and trends : algorithms, methods and techniques*. Information Science Reference.
- Otterlo, M., & Wiering, M. (2012). *Reinforcement Learning and Markov Decision Processes*.
- Özdağ, M. E., Yeşilkaya, M., & Çabuk, Y. (2017). Türkiye-Almanya Mobilya Dış Ticaretinin Yapay Sinir Ağları İle Tahmini. *Journal of Bartın Faculty of Forestry*, 19(2), 136–143. <https://doi.org/10.24011/barofd.354497>
- Öztemel, ercan. (2022). *Yapay Sinir Ağları* (Papatya Yayıncılık). Papatya Bilim Üniversitesi Yayıncılığı.
- Pamuk, Ş. (2014). *Türkiye'nin 200 Yıllık İktisadi Tarihi* (Türkiye İş Bankası).
- Peter, M., Aldo, D. A., Cheng, F., & Ong, S. (2021). *Mathematics for Machine Learning* (Cambridge University). Cambridge University. <https://mml-book.com>.
- Prado, M. de L. (2018). *Advances in Financial Machine Learning*.
- Ruder, S. (2016). *An overview of gradient descent optimization algorithms*. <http://arxiv.org/abs/1609.04747>
- Sathya, R., & Abraham, A. (2013). Comparison of Supervised and Unsupervised Learning Algorithms for Pattern Classification. *International Journal of Advanced Research in Artificial Intelligence*, 2(2). <https://doi.org/10.14569/ijarai.2013.020206>
- Schaffer, A. L., Dobbins, T. A., & Pearson, S. A. (2021). Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions. *BMC Medical Research Methodology*, 21(1). <https://doi.org/10.1186/s12874-021-01235-8>

- Selçi Burcu, Y., & Akgül, Y. (2020). Türkiye'nin İhracat Değerlerinin Yapay Sinir Ağları ile Tahmini Üzerine Bir İnceleme. *Nicel Bilimler Dergisi*, 2(December), 29–42.
- Sertok, S. (2022). *Seyahat Süresi Değişkenliğinin Analizi ve Yapay Sinir Ağları ile Seyahat Süresinin Tahmini Analysis of Travel Time Variability and Prediction of Travel Time Using Artificial Neural Networks* [Yüksek Lisans]. Hacettepe Üniversitesi.
- Shahvaroughi Farahani, M., & Razavi Hajiagha, S. H. (2021). Forecasting stock price using integrated artificial neural network and metaheuristic algorithms compared to time series models. *Soft Computing*, 25(13), 8483–8513. <https://doi.org/10.1007/s00500-021-05775-5>
- Shakir Hilaiwah, A. I., Abed Alwally Abed Allah, H., Akhudir Abbas, B., & Sutikno, T. (2021). Live to learn: learning rules-based artificial neural network. *Indonesian Journal of Electrical Engineering and Computer Science*, 21(1), 558–565. <https://doi.org/10.11591/ijeecs.v21.i1>
- Shalev-Shwartz, S., & Ben-David, S. (214 C.E.). *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press. <http://www.cs.huji.ac.il/~shais/UnderstandingMachineLearning>
- Sharma, S., Sharma, S., & Athaiya, A. (2020). Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 4, 310–316. <http://www.ijeast.com>
- Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2019). A Comparison of ARIMA and LSTM in Forecasting Time Series. *Proceedings - 17th IEEE International Conference on Machine Learning and Applications, ICMLA 2018*, 1394–1401. <https://doi.org/10.1109/ICMLA.2018.00227>
- Storkey, A. J., & Valabregue, R. (1999). *The basins of attraction of a new Hopfield learning rule*.
- TİM. (2020). *TİM Almanya Hedef Pazar Ülke Analizi*.
- TİM İhracat 2021 Raporu. (2021). *TİM*.
- Tolksdorf, H. (2016). Economic challenges and opportunities for Turkey and Germany - A German perspective. *CESifo Forum*, 17(2), 12–14.
- Troiano, L., Bhandari, A., Villa, E. (Elena), & Safari, an O. M. Company. (2020). *Hands-On Deep Learning for Finance*.
- Tsay, R. S. (2002). *Analysis of financial time series*. Wiley.
- TÜİK. (2022, March). *Dış Ticaret İstatistikleri*. TÜİK.

- Uysal, D. (2017). *Sosyal Bilimlerde Yapay Sinir Ağlarının Kullanımı ve Bir Uygulama* [Yüksek Lisans]. Karabük Üniversitesi.
- Vatandaş, S. (2019). *Ekonomik İş birliği ve Türkiye-Almanya İlişkilerinin Geleceği*. <https://www.insamer.com/tr/uploads/pdf/analiz-ekonomik-is-birligi-ve-turkiye-almanya-iliskilerinin-gelecegi.pdf>
- Vijayasri, G. v. (2013). The Importance of International Trade in the World. *International Journal of Marketing, Financial Services & Management Research*, 2(9), 111–119. [indianresearchjournals.com/pdf/ijmfsmr/2013/september/12.pdf](http://indianresearchjournals.com/pdf/ijmfsmr/2013/september/12.pdf)
- Williams, J. H. (1922). German Foreign Trade and the Reparation Payments. In *Source: The Quarterly Journal of Economics* (Vol. 36, Issue 3). <https://about.jstor.org/terms>
- Yang, H., Li, X., Qiang, W., Zhao, Y., Zhang, W., & Tang, C. (2021). A network traffic forecasting method based on SA optimized ARIMA–BP neural network. *Computer Networks*, 193. <https://doi.org/10.1016/j.comnet.2021.108102>
- Yang, J., Hines, E. L., Guymier, I., Iliescu, D. D., Leeson, M. S., King, G. P., & Li, X. (2008). A genetic algorithm-artificial neural network method for the prediction of longitudinal dispersion coefficient in rivers. In *Advancing Artificial Intelligence Through Biological Process Applications* (pp. 358–374). IGI Global. <https://doi.org/10.4018/978-1-59904-996-0.ch019>
- Yildirim, I., Ozsahin, S., & Okan, O. T. (2014). Prediction of non-wood forest products trade using artificial neural networks. *Journal of Agricultural Science and Technology*, 16, 1493–1504.
- Yu, H., & Wilamowski, B. M. (2012). Neural Network Training with Second Order Algorithms. *Computer Systems Interaction*, 463–476.
- Yu, Z., Abdulghani, A. M., Zahid, A., Heidari, H., Imran, M. A., & Abbasi, Q. H. (2020). An overview of neuromorphic computing for artificial intelligence enabled hardware-based hopfield neural network. *IEEE Access*, 8, 67085–67099. <https://doi.org/10.1109/ACCESS.2020.2985839>
- Yurdakul, E. M. (2014). *Türkiye’de İthalatın Gelişimi ve İthalatın Yapay Sinir Ağları Yöntemi İle Tahmin Edilebilirliğine Yönelik Bir Analiz* [Doktora Tezi]. T.C. Adnan Menderes Üniversitesi.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. In *Neurocomputing* (Vol. 50). [www.elsevier.com/locate/neucom](http://www.elsevier.com/locate/neucom)
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. In *International Journal of Forecasting* (Vol. 14).



Zhiqiang, W., & Jun, L. (2017). A Review of Object Detection Based on Convolutional Neural Network. *Proceedings of the 35th Chinese Control Conference* , 11104–11109.

Ziganto, D. (2018). *Model Tuning (part 2- validation & cross-validation)*. Dzginto.Github.Io.

## TABLULAR LİSTESİ

<b>Tablo 1:</b> Almanya'nın yıllara göre Türkiye'den yaptığı ithalat (Milyar \$) .....	21
<b>Tablo 2:</b> En çok ihracat yapılan 10 ülke (2020).....	22
<b>Tablo 3:</b> 2020'de Almanya ile Türkiye arasındaki ikili ticaret tüm ürünler .....	23
<b>Tablo 4:</b> Almanya ile Türkiye arasındaki ticaret dengesi .....	28
<b>Tablo 5 :</b> Öğrenme algoritmaları.....	40
<b>Tablo 6:</b> Modelin istatistiksel analizi.....	78
<b>Tablo 7:</b> Zaman Serisi Yöntemleri ve YSA yöntemi ile dış ticareti analizi (RMSE)..	88
<b>Tablo 8:</b> Zaman Serisi Yöntemleri ve YSA yöntemi ile dış ticareti analizi (MAE)....	89

## ŞEKİLLER LİSTESİ

Şekil 1: 2022 Yılı Mart ihracat miktarı .....	27
Şekil 2: 2022 Yılı Mart ithalat miktarı .....	27
Şekil 3: Türkiye- Almanya- EU 15 Milli Gelir ilişkisi .....	29
Şekil 4: Farklı bileşenlere sahip bir Zaman Serisi grafiği .....	31
Şekil 5: Bias, Varyans gösterimi .....	36
Şekil 6: Makine öğreniminin temel mimarisi.....	37
Şekil 7: Denetimli Öğrenme Mimari Örneği.....	38
Şekil 8: Kümeleme görseli .....	39
Şekil 9. Denetimsiz öğrenme mimari örneği .....	39
Şekil 10. Pekiştirmeli öğrenme mimarisi .....	41
Şekil 11: Basit bir nöron gösterimi.....	43
Şekil 12: Yapay bir nöron modeli .....	43
Şekil 13: Çok katmanlı bir yapıya sahip bir ileri besleme ağı.....	45
Şekil 14: Üç katmanlı geri yayımlı sinir ağı .....	46
Şekil 15: Geri Yayılım Ağı örneği .....	47
Şekil 16: Evrişimli Sinir Ağı mimarisi.....	49
Şekil 17: Yinelemeli Sinir Ağ yapısı.....	51
Şekil 18: LSTM hücresinin mimarisi .....	53
Şekil 19: (a)RNN (b)LSTM (c)GRU.....	54
Şekil 20: NARX Ağlarının paralel mimarisi .....	56
Şekil 21: Dört çıkış gecikmeli bir NARX Ağı .....	56
Şekil 22: Aktivasyon fonksiyonları.....	57
Şekil 23: Sigmoid fonksiyonu ve türevi .....	58
Şekil 24: RELU fonksiyonunun grafiği ve türevleri .....	59
Şekil 25: Hebb Kuralı.....	61
Şekil 26 : Hopfield Sinir Ağı mimarisi .....	63
Şekil 27 : Kohonen Ağı.....	64
Şekil 28: Doğrusal bir nöron için ikinci dereceden hata yüzeyi.....	65
Şekil 29: Hata yüzeyini bir dizi kontur olarak görselleştirme.....	66

<b>Şekil 30:</b> Gradient Descent kuralı gösterimi .....	67
<b>Şekil 31:</b> Uygulanan yöntemin şeması .....	77
<b>Şekil 32:</b> Tasarlanan modelin mimarisi .....	78
<b>Şekil 33:</b> NARX YSA açık döngü mimarisi .....	80
<b>Şekil 34:</b> NARX YSA kapalı döngü mimarisi .....	80
<b>Şekil 35:</b> NARX doğrulama performansı .....	81
<b>Şekil 36:</b> Hata Otokorelasyon fonksiyonu.....	82
<b>Şekil 37:</b> NARX Hata histogramı.....	82
<b>Şekil 38:</b> Zaman serisi yanıtı .....	83
<b>Şekil 39:</b> NARX Regresyon katsayısı .....	84
<b>Şekil 40:</b> Zaman Serisi ayrışımı .....	85
<b>Şekil 41:</b> ARIMA modeli kullanarak tahmin .....	85
<b>Şekil 42:</b> Farklı tahmin yöntemleri.....	86
<b>Şekil 43:</b> Eğitimi tamamlanan NARX Sinir Ağının dış ticaret analizi.....	86

## EKLER

**Ek 1:** Zaman Serilerine ve NARX Sinir Ağının farklı gecikme sürelerine göre performans değişimi

<b>Harmonized Commodity Description and Coding System, 2022</b>			
<b>Tüm Fasıllar</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.169
		Test set	0.234
<b>Drift</b>		Training	0.128
		Test set	0.321
<b>Naive</b>		Training	0.129
		Test set	0.305
<b>ARIMA</b>		Training	0.074
		Test set	0.225
<b>Regression with ARIMA</b>		Training	0.083
		Test set	0.184
<b>YSA 10-1</b> 2 gecikmeli		Training	0.072
		Test set	0.301
<b>YSA 10-1</b> 4 gecikmeli		Training	0.082
		Test set	0.079

**Ek 2:** Bölüm 1

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	1.045
		Test set	0.459
<b>Drift</b>		Training	0.595
		Test set	0.616
<b>Naive</b>		Training	0.595
		Test set	0.615
<b>ARIMA</b>		Training	0.551
		Test set	0.422
<b>Regression with ARIMA</b>		Training	0.536
		Test set	0.663
<b>YSA 10-1</b> 2 gecikmeli		Training	0.513
		Test set	0.603
<b>YSA 10-1</b> 4 gecikmeli		Training	0.688
		Test set	0.891

**Ek 3: Bölüm 2**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.961
		Test set	0.560
<b>Drift</b>		Training	0.950
		Test set	0.550
<b>Naive</b>		Training	0.950
		Test set	0.555
<b>ARIMA</b>		Training	0.950
		Test set	0.555
<b>Regression with ARIMA</b>		Training	0.732
		Test set	0.655
<b>YSA 10-1</b>	2 gecikmeli	Training	0.863
		Test set	0.822
<b>YSA 10-1</b>	4 gecikmeli	Training	0.950
		Test set	0.928

**Ek 4: Bölüm 3**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	1.557
		Test set	1.686
<b>Drift</b>		Training	2.125
		Test set	1.244
<b>Naive</b>		Training	2.125
		Test set	1.253
<b>ARIMA</b>		Training	1.508
		Test set	1.340
<b>Regression with ARIMA</b>		Training	1.471
		Test set	1.343
<b>YSA 10-1</b>	2 gecikmeli	Training	1.357
		Test set	1.522
<b>YSA 10-1</b>	4 gecikmeli	Training	1.289
		Test set	1.886

**Ek 5: Bölüm 4**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.407
		Test set	0.149
<b>Drift</b>		Training	0.256
		Test set	0.169
<b>Naive</b>		Training	0.256
		Test set	0.176
<b>ARIMA</b>		Training	0.219
		Test set	0.181
<b>Regression with ARIMA</b>		Training	0.217
		Test set	0.161
<b>YSA 10-1</b>	2 gecikmeli	Training	0.165
		Test set	0.171
<b>YSA 10-1</b>	4 gecikmeli	Training	0.224
		Test set	0.173

**Ek 6: Bölüm 5**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.790
		Test set	0.436
<b>Drift</b>		Training	0.778
		Test set	0.909
<b>Naive</b>		Training	0.778
		Test set	0.890
<b>ARIMA</b>		Training	0.614
		Test set	0.505
<b>Regression with ARIMA</b>		Training	0.610
		Test set	0.577
<b>YSA 10-1</b>	2 gecikmeli	Training	0.711
		Test set	0.542
<b>YSA 10-1</b>	4 gecikmeli	Training	0.700
		Test set	0.828

**Ek 7: Bölüm 6**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.270
		Test set	0.330
<b>Drift</b>		Training	0.351
		Test set	0.224
<b>Naive</b>		Training	0.351
		Test set	0.225
<b>ARIMA</b>		Training	0.245
		Test set	0.229
<b>Regression with ARIMA</b>		Training	0.246
		Test set	0.361
<b>YSA 10-1</b>	2	Training	0.261
	gecikmeli	Test set	0.295
<b>YSA 10-1</b>	4	Training	0.213
	gecikmeli	Test set	0.228

**Ek 8: Bölüm 7**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.325
		Test set	0.512
<b>Drift</b>		Training	0.138
		Test set	0.193
<b>Naive</b>		Training	0.139
		Test set	0.213
<b>ARIMA</b>		Training	0.104
		Test set	0.173
<b>Regression with ARIMA</b>		Training	0.093
		Test set	0.107
<b>YSA 10-1</b>	2	Training	0.111
	gecikmeli	Test set	0.381
<b>YSA 10-1</b>	4	Training	0.090
	gecikmeli	Test set	0.132



**Ek 9: Bölüm 8**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>	Training	0.553	0.436
	Test set	0.853	0.801
<b>Drift</b>	Training	0.636	0.468
	Test set	0.501	0.419
<b>Naive</b>	Training	0.636	0.468
	Test set	0.489	0.402
<b>ARIMA</b>	Training	0.458	0.341
	Test set	0.408	0.339
<b>Regression with ARIMA</b>	Training	0.452	0.335
	Test set	0.394	0.305
<b>YSA 10-1</b> 2 gecikmeli	Training	0.379	0.300
	Test set	0.460	0.349
<b>YSA 10-1</b> 4 gecikmeli	Training	0.433	0.332
	Test set	0.554	0.435

**Ek 10: Bölüm 9**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>	Training	1.276	0.947
	Test set	2.197	2.179
<b>Drift</b>	Training	1.218	0.771
	Test set	1.028	0.989
<b>Naive</b>	Training	1.218	0.771
	Test set	1.024	0.986
<b>ARIMA</b>	Training	0.863	0.595
	Test set	0.345	0.241
<b>Regression with ARIMA</b>	Training	0.843	0.579
	Test set	0.413	0.328
<b>YSA 10-1</b> 2 gecikmeli	Training	0.768	0.543
	Test set	0.450	0.341
<b>YSA 10-1</b> 4 gecikmeli	Training	0.790	0.589
	Test set	0.889	0.812

**Ek 11: Bölüm 10**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.514
		Test set	1.072
<b>Drift</b>		Training	0.389
		Test set	0.215
<b>Naive</b>		Training	0.389
		Test set	0.219
<b>ARIMA</b>		Training	0.294
		Test set	0.185
<b>Regression with ARIMA</b>		Training	0.292
		Test set	0.260
<b>YSA 10-1</b>	2 gecikmeli	Training	0.395
		Test set	0.548
<b>YSA 10-1</b>	4 gecikmeli	Training	0.267
		Test set	0.341

**Ek 12: Bölüm 11**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.173
		Test set	0.405
<b>Drift</b>		Training	0.166
		Test set	0.182
<b>Naive</b>		Training	0.166
		Test set	0.184
<b>ARIMA</b>		Training	0.138
		Test set	0.183
<b>Regression with ARIMA</b>		Training	0.134
		Test set	0.216
<b>YSA 10-1</b>	2 gecikme	Training	0.131
		Test set	0.097
<b>YSA 10-1</b>	4 gecikme	Training	1.181
		Test set	0.208

**Ek 13: Bölüm 12**

<b>Harmonized Commodity Description and Coding System, 2022</b>				
			RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.816	0.684
		Test set	0.693	0.606
<b>Drift</b>		Training	0.110	0.824
		Test set	0.804	0.680
<b>Naive</b>		Training	1.110	0.824
		Test set	0.793	0.667
<b>ARIMA</b>		Training	0.816	0.616
		Test set	0.692	0.570
<b>Regression with ARIMA</b>		Training	0.788	0.595
		Test set	0.873	0.774
<b>YSA 10-1</b>	2 gecikme	Training	0.677	0.599
		Test set	1.181	0.161
<b>YSA 10-1</b>	4 gecikme	Training	0.75	0.527
		Test set	1,128	0.878

**Ek 14: Bölüm 13**

<b>Harmonized Commodity Description and Coding System, 2022</b>				
			RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.196	0.151
		Test set	0.257	0.236
<b>Drift</b>		Training	0.170	0.130
		Test set	0.548	0.540
<b>Naive</b>		Training	0.170	0.130
		Test set	0.530	0.520
<b>ARIMA</b>		Training	0.141	0.112
		Test set	0.166	0.140
<b>Regression with ARIMA</b>		Training	0.138	0.110
		Test set	0.225	0.200
<b>YSA 10-1</b>	2 gecikmeli	Training	0.118	0.102
		Test set	0.202	0.190
<b>YSA 10-1</b>	4 gecikmeli	Training	0.173	0.136
		Test set	0.175	0.139

**Ek 15: Bölüm 14**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	1.155
		Test set	1.346
<b>Drift</b>		Training	0.644
		Test set	2.238
<b>Naive</b>		Training	0.645
		Test set	2.064
<b>ARIMA</b>		Training	0.572
		Test set	2.162
<b>Regression with ARIMA</b>		Training	0.581
		Test set	2.008
<b>YSA 10-1</b>	2 gecikmeli	Training	0.457
		Test set	2.204
<b>YSA 10-1</b>	4 gecikmeli	Training	0.404
		Test set	0.809

**Ek 16: Bölüm 15**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.323
		Test set	0.644
<b>Drift</b>		Training	0.217
		Test set	0.279
<b>Naive</b>		Training	0.213
		Test set	0.302
<b>ARIMA</b>		Training	0.169
		Test set	0.333
<b>Regression with ARIMA</b>		Training	0.168
		Test set	0.330
<b>YSA 10-1</b>	2 gecikmeli	Training	0.126
		Test set	0.415
<b>YSA 10-1</b>	4 gecikmeli	Training	0.140
		Test set	0.165

**Ek 17: Bölüm 16**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.208
		Test set	0.323
<b>Drift</b>		Training	0.194
		Test set	0.229
<b>Naive</b>		Training	0.194
		Test set	0.227
<b>ARIMA</b>		Training	0.135
		Test set	0.124
<b>Regression with ARIMA</b>		Training	0.300
		Test set	0.314
<b>YSA 10-1</b>	2 gecikmeli	Training	0.125
		Test set	0.223
<b>YSA 10-1</b>	4 gecikmeli	Training	0.105
		Test set	0.146

**Ek 18: Bölüm 17**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.472
		Test set	0.499
<b>Drift</b>		Training	0.431
		Test set	0.770
<b>Naive</b>		Training	0.431
		Test set	0.753
<b>ARIMA</b>		Training	0.310
		Test set	0.840
<b>Regression with ARIMA</b>		Training	0.300
		Test set	0.314
<b>YSA 10-1</b>	2 gecikmeli	Training	0.301
		Test set	0.526
<b>YSA 10-1</b>	4 gecikmeli	Training	0.158
		Test set	0.490

**Ek 19: Bölüm 18**

<b>Harmonized Commodity Description And Coding System, 2022</b>			
		RMSE (Hata Kareler Ortalamasının Kare Kökü)	MAE (Ortalama Mutlak Hata)
<b>Mean</b>		Training	0.524
		Test Set	0.712
<b>Drift</b>		Training	0.514
		Test Set	0.275
<b>Naive</b>		Training	0.513
		Test Set	0.290
<b>ARIMA</b>		Training	0.379
		Test Set	0.241
<b>Regression With ARIMA</b>		Training	0.388
		Test Set	0.240
<b>YSA 10-1</b>	2 gecikme	Training	0.304
		Test Set	0.364
<b>YSA 10-1</b>	4 gecikme	Training	0.244
		Test Set	0.548

**Ek 20: Bölüm 19**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	2.430
		Test set	2.355
<b>Drift</b>		Training	3.168
		Test set	1.006
<b>Naive</b>		Training	3.999
		Test set	0.999
<b>ARIMA</b>		Training	2.310
		Test set	1.312
<b>Regression with ARIMA</b>		Training	2.279
		Test set	1.178
<b>YSA 10-1</b>	2 gecikmeli	Training	0.716
		Test set	0.766
<b>YSA 10-1</b>	4 gecikmeli	Training	2.590
		Test set	2.340


**Ek 21: Bölüm 20**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	0.346
		Test set	0.979
<b>Drift</b>		Training	0.224
		Test set	0.155
<b>Naive</b>		Training	0.224
		Test set	0.159
<b>ARIMA</b>		Training	0.179
		Test set	0.196
<b>Regression with ARIMA</b>		Training	0.174
		Test set	0.335
<b>YSA 10-1</b>	2 gecikmeli	Training	0.165
		Test set	0.253
<b>YSA 10-1</b>	4 gecikmeli	Training	0.144
		Test set	0.182


**Ek 22: Bölüm 21**

<b>Harmonized Commodity Description and Coding System, 2022</b>			
		RMSE (hata kareler ortalamasının kare kökü)	MAE (ortalama mutlak hata)
<b>Mean</b>		Training	3.234
		Test set	1.929
<b>Drift</b>		Training	4.184
		Test set	1.595
<b>Naive</b>		Training	4.184
		Test set	1.588
<b>ARIMA</b>		Training	3.055
		Test set	1.611
<b>Regression with ARIMA</b>		Training	3.014
		Test set	1.693
<b>YSA 10-1</b>	2 gecikmeli	Training	3,137
		Test set	2,367
<b>YSA 10-1</b>	4 gecikmeli	Training	2,048
		Test set	4,381

### Ek 23. Zaman Serisi Grafiđi




### Ek 24. Mevsimsel Zaman Serisi







### Ek 25. Aylık Zaman Serisi




### Ek 26. İhracat/İthalat Zaman Serisi




## Ek 27. Traing Set




## Ek 28. Histogram




### Ek 29. apraz Kovaryans ve Korelasyon Fonksiyonu




### Ek 30. Ayrıştırılmış Eğitim Seti Zaman Serilerinin Mevsimsel Bileşeni




### Ek 31. İhracat-İthalat Zaman serisi




### Ek 32. Üstel Düzeltme Algoritması




### Ek 33. Eğitim Fonksiyonu



### Ek 34. Otokorelasyon Fonksiyonu (ACF) ve Kısmi Otokorelasyon Fonksiyonu (PACF)



**Ek 35. ARIMA Tahmin**



## **ÖZGEÇMİŞ**

Şeyma Nur ÜNAL Karabük Zübeyde Hanım Anadolu Lisesi'ni bitirdikten sonra 2013 yılında Ordu Üniversitesi Ünye İktisadi ve İdari Bilimler Fakültesi İktisat Bölümü'nden mezun olmuştur. 2016 yılında Karabük Üniversitesi Sosyal Bilimler Enstitüsü'nde iktisat yüksek lisans eğitimini tamamlamıştır. Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, İktisat Anabilim Dalında doktora çalışmasına devam etmektedir.