

**ÇOK FAZLI AKIŞLARDA PARÇACIK HIZ VE YÖN TAHMİNİ İÇİN  
HESAPLAMALI ZEKÂ MODELLERİ**

**HATİCE TOMBUL**

**YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ**

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**AĞUSTOS 2013**

**ANKARA**

Fen Bilimleri Enstitü onayı

---

Prof. Dr. Necip CAMUŐCU

Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

---

Doç. Dr. Erdoğan DOĐDU

Anabilim Dalı Başkanı

Hatice TOMBUL tarafından hazırlanan OK FAZLI AKIŐLARDA PARACIK HIZ VE YÖN TAHMİNİ İİN HESAPLAMALI ZEKÂ MODELLERİ adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

---

Yrd. Doç. Dr. Ahmet Murat ÖZBAYOĐLU

Tez DanıŐmanı

Tez Jüri Üyeleri

Başkan: Doç. Dr. Erdoğan DOĐDU

Üye : Yrd. Doç. Dr. Ahmet Murat ÖZBAYOĐLU

Üye : Doç. Dr. CoŐku KASNAKOĐLU

## **TEZ BİLDİRİMİ**

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

**Hatice TOMBUL**

**Üniversitesi** : TOBB Ekonomi ve Teknoloji Üniversitesi  
**Enstitüsü** : Fen Bilimleri  
**Anabilim Dalı** : Bilgisayar Mühendisliği  
**Tez Danışmanı** : Yrd. Doç. Dr. Ahmet Murat ÖZBAYOĞLU  
**Tez Türü ve Tarihi** : Yüksek Lisans – Ağustos 2013

**Hatice TOMBUL**

**ÇOK FAZLI AKIŞLARDA PARÇACIK HIZ VE YÖN TAHMİNİ İÇİN  
HESAPLAMALI ZEKÂ MODELLERİ**

**ÖZET**

Kesinti taşınması ile ilgili çalışmalar ilk zamanlar, dik kuyular ve tek fazlı akışlar için yapılırken, günümüzde yatay ve açılı sondajlarda çok fazlı akışlar için yapılmaktadır. Çok fazlı akışlarda, sondaj parçacığının davranışını tahmin etmek için parçacığın hareket yönü ve hızı iki önemli husustur. Ancak literatürde hala halkasal borulardaki çok fazlı akışlarda kesintinin yönünün ve taşınma hızının tahmin edilmesi ile ilgili eksiklikler bulunmaktadır. Bu çalışmadaki başlıca hedef, eksantrik borulardaki kesinti taşınma hızlarını ve kesintilerin ilerledikleri yönleri tahmin etmeye çalışmaktır. Bu amaca ulaşmaya çalışırken, Orta Doğu Teknik Üniversitesi, Petrol ve Doğalgaz Mühendisliği Bölümü, Kesinti Taşıma ve Çok Fazlı Akış Laboratuvarındaki deney düzeneğinden elde edilmiş olan veriler üzerinde çalışılmıştır. Deney düzeneğinden gelen veriler ışığında boru eğimlerinin yatay, 15° ve 30° olduğu durumlarda kesinti taşınmasının yön ve hız karakteristiği tahmin edilmeye çalışılmıştır. Bu tahminler yapılırken geleneksel yöntemlerden Doğrusal Regresyon, Doğrusal Olmayan Regresyon ile hesaplamalı zekâ modellerinden İleri Beslemeli Yapay Sinir Ağları, Destek Vektör Makineleri ve Destek Vektör Regresyonu yöntemleri kullanılmıştır. Kullanılan bu yöntemlerden elde edilen sonuçlar, çeşitli performans metrikleri yardımıyla birbirleri ile karşılaştırılmıştır. Bu yöntemlerden, yön tahmini için en başarılı yöntem destek vektör makineleri olurken, hız tahmini için en başarılı yöntem destek vektör regresyonu olmuştur.

**Anahtar Kelimeler:** Kesinti Taşıma, Yatay ve Eğimli Kuyular, Eksantrik Halkasal Boru, Çok fazlı akış, Hesaplamalı Zekâ Modelleri

**University** : TOBB Economics and Technology University  
**Institute** : Institute of Natural and Applied Sciences  
**Science Programme** : Computer Engineering  
**Supervisor** : Asst. Prof. Dr. Ahmet Murat ÖZBAYOĞLU  
**Degree Awarded and Date** : M.Sc. – August 2013

**Hatice TOMBUL**

**COMPUTATIONAL INTELLIGENCE MODELS FOR PARTICLE  
DIRECTION AND VELOCITY ESTIMATION IN MULTI-PHASE FLOWS**

**ABSTRACT**

While in the early days, studies on cuttings transport are made for steep wells and single phase fluids; nowadays they are made for angled drills and multi-phase flows. In the multi-phase flows, motion direction and velocity of the particle are two important aspects for estimating the behaviour of the drill particle. However, in the literature there is still a lack of information on the estimation of direction and velocity of the particle in multi-phase flows. Main aim of this study is to try to predict the the direction and velocity of cuttings in eccentric tubes. For this purpose, we studied on the data which is obtained from the experimental setup in Middle East Technical University, Petroleum and Natural Gas Engineering Department, Cutting Transport and Multi-Phase Flow Laboratory. Direction and velocity characteristics of cutting transport is tried to be predicted for tubes with no angle (horizontal), 15 and 30 degrees of angles. In order to create a prediction model there are several methods are used from conventional methods such as linear and nonlinear regression to computational intelligence methods such as neural networks, support vector machines and support vector regression. Results obtained from these methods are compared to each other by using some performance metrics. It is found that for both direction prediction and velocity prediction, support vector machines and regression are the most successful methods among others.

**Keywords:** Cutting Transport, Horizontal and Inclined Wellbore, Eccentric Annular Pipe, Multiphase flow, Computational Intelligence Models

## TEŐEKKÜR

Bu alıőmanın tamamlanması iin bana yol gsteren, deęerli bilgilerini ve yardımlarını benden esirgemeyen, bunların yanında manevi olarak da her zaman bana destek veren tez danıőmanım Yrd. Do. Dr. Ahmet Murat ÖZBAYOęLU' na,

Tezimi okuyup deęerlendiren, dil ve üslup konusunda yardımlarını esirgemeyen, alıőmamın her aőamasında samimi ilgi ve abaları ile katkı saęlayan ve kıymetli tecrübelerini benimle paylaőan abim Dr. G. Serdar TOMBUL'a,

Tezimin en sıkıntılı anlarında hep yanımda olan, teővikleriyle beni yüreklendirmekle kalmayıp bu zorlu sürete bana daima sabır ve sevgi gsteren anneme ve babama,

alıőmam süresince bana yakınlık gsteren tüm arkadaşlarıma ve beni daima cesaretlendiren TOBB Ekonomi ve Teknoloji Üniversitesi hocalarıma teőekkürü bir bor bilirim.

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>III</b>
<b>ABSTRACT</b> .....	<b>IV</b>
<b>TEŞEKKÜR</b> .....	<b>V</b>
<b>İÇİNDEKİLER</b> .....	<b>VI</b>
<b>TABLoların LİSTESİ</b> .....	<b>VIII</b>
<b>ŞEKİLLERİN LİSTESİ</b> .....	<b>IX</b>
<b>KISALTMALAR</b> .....	<b>XIII</b>
<b>SEMBOL LİSTESİ</b> .....	<b>XIV</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 GENEL BAKIŞ .....	1
1.2 ÇALIŞMANIN AMACI .....	2
1.3 TEZ İÇERİĞİ.....	4
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>5</b>
2.1 KESİNTİ TAŞINMASI ÜZERİNE YAPILMIŞ ÇALIŞMALAR .....	5
2.2 PARÇACIK GÖRÜNTÜSÜNDEN HIZ TESPİTİ (PARTICLE IMAGE VELOCITY-PIV) VE YAPAY ZEKÂ UYGULAMALARI İÇEREN ÇALIŞMALAR .....	9
<b>3. DENEY DÜZENİĞİ</b> .....	<b>14</b>
3.1 KESİNTİ AKIŞ SİSTEMİ .....	14
3.2 GERÇEKLEŞTİRİLEN DENEYLER .....	23
3.3 DENEYSEL VERİLERİN DOĞRULUĞU .....	25
3.4 DENEYSEL VERİLERİN KONTROLÜ VE ANALİZ PROSEDÜRÜ.....	26
<b>4. VERİ HAZIRLAMA</b> .....	<b>27</b>
<b>5. KULLANILAN TEKNİKLER</b> .....	<b>31</b>
5.1 YAPAY ZEKÂ VE YAPAY SİNİR AĞLARININ DOĞUŞU .....	31
5.1.1 Yapay Sinir Ağlarının Tanımı ve Yapay Sinir Ağlarına Genel Bakış ...	31
5.1.2 Biyolojik Sinir Sistemi .....	32
5.1.3 Biyolojik Sinir Hücresinin Yapısı .....	32
5.1.4 Biyolojik Sinir Ağlarının Yapısı .....	33
5.1.5 Yapay Sinir Hücresinin Yapısı.....	34
5.1.6 Yapay Sinir Ağlarının Yapısı.....	38
5.1.7 Yapay Sinir Ağlarının Uygulama Alanları .....	39
5.1.8 Yapay Sinir Ağlarının Üstünlükleri .....	39
5.1.9 Yapay Sinir Ağlarının Çalışma Yapısı.....	40

5.1.10	Yapay Sinir Ağlarının Sınıflandırılması .....	42
5.2	REGRESYON ANALİZİ .....	48
5.2.1	Doğrusal (Linear) Regresyon .....	49
5.2.2	Doğrusal Olmayan (Nonlinear) Regresyon .....	54
5.3	DESTEK VEKTÖR MAKİNELERİ VE SINIFLANDIRMA .....	57
5.3.1	Doğrusal Sınıflandırma .....	57
5.3.2	Doğrusal Olmayan Sınıflandırma .....	62
5.3.3	Çok-Sınıflı Destek Vektör Makineleri .....	65
5.4	DESTEK VEKTÖR REGRESYONU .....	67
<b>6.</b>	<b>PERFORMANS METRİKLERİ .....</b>	<b>72</b>
6.1	HATA KARELERİ ORTALAMASININ KAREKÖKÜ (ROOT MEAN SQUARE ERROR- RMSE).....	72
6.2	ORTALAMA YÜZDE HATA (MEAN PERCENTAGE ERROR-MPE) .....	72
6.3	ORTALAMA MUTLAK YÜZDE HATA (MEAN ABSOLUTE PERCENTAGE ERROR- MAPE) .....	72
6.4	KORELASYON KATSAYISI (CORRELATION COEFFICIENT-R) .....	73
6.5	DETERMİNASYON KATSAYISI (DETERMINATION COEFFICIENT-R <sup>2</sup> ).....	73
6.6	TUTARSIZLIK HESABI (VARIANCE ACCOUNTED FOR- VAF).....	74
<b>7.</b>	<b>MODELLERİN UYGULANMASI VE SONUÇLAR .....</b>	<b>75</b>
7.1	MODELLER VE UYGULAMA .....	75
7.2	SONUÇLAR VE TARTIŞMA.....	79
7.2.1	Hız Tahmin Sonuçları .....	80
7.2.2	Hız Sonuçlarını Performans Metriklerine Göre Karşılaştırma.....	88
7.2.3	Açısal Yön Tahmin Sonuçları .....	92
7.2.4	Açısal Yön Sonuçlarını Performans Metriklerine Göre Karşılaştırma	100
7.2.5	Yön Tahmin Sonuçları .....	104
<b>8.</b>	<b>GELECEK ÇALIŞMALAR.....</b>	<b>114</b>
	<b>KAYNAKLAR.....</b>	<b>115</b>
	<b>ÖZGEÇMİŞ.....</b>	<b>120</b>



## TABLULARIN LİSTESİ

Tablo 1: Yönler .....	76
Tablo 2: Yatay Borularda Eğitim Verileri için Hız Sonuçları .....	89
Tablo 3: Yatay Borularda Test Verileri için Hız Sonuçları .....	90
Tablo 4: 15 Derece Açılı Borularda Eğitim Verileri için Hız Sonuçları.....	90
Tablo 5: 15 Derece Açılı Borularda Test Verileri için Hız Sonuçları.....	91
Tablo 6: 30 Derece Açılı Borularda Eğitim Verileri için Hız Sonuçları.....	91
Tablo 7: 30 Derece Açılı Borularda Test Verileri için Hız Sonuçları.....	92
Tablo 8: Yatay Borularda Eğitim Verileri için Açısal Yön Sonuçları .....	101
Tablo 9: Yatay Borularda Test Verileri için Açısal Yön Sonuçları .....	101
Tablo 10: 15 Derece Açılı Borularda Eğitim Verileri için Açısal Yön Sonuçları ...	102
Tablo 11: 15 Derece Açılı Borularda Test Verileri için Açısal Yön Sonuçları .....	102
Tablo 12: 30 Derece Açılı Borularda Eğitim Verileri için Açısal Yön Sonuçları ...	103
Tablo 13: 30 Derece Açılı Borularda Test Verileri için Açısal Yön Sonuçları .....	103
Tablo 14: Yatay Borularda DVM Yön Sınıflandırma Sonuçları ve Adetleri .....	104
Tablo 15: Yatay Borularda YSA(1 katman 100 nöron) Yön Sınıflandırma Sonuçları ve Adetleri.....	105
Tablo 16: Yatay Borularda YSA(2 katman 50 nöron) Yön Sınıflandırma Sonuçları ve Adetleri.....	106
Tablo 17: 15 Derece Borularda DVM Yön Sınıflandırma Sonuçları ve Adetleri....	107
Tablo 18: 15 Derece Borularda YSA(1 Katman 100 Nöron) Yön Sınıflandırma Sonuçları ve Adetleri.....	108
Tablo 19: 15 Derece Borularda YSA (2 katman 50 nöron) Yön Sınıflandırma Sonuçları ve Adetleri.....	109
Tablo 20: 30 Derece Borularda DVM Yön Sınıflandırma Sonuçları ve Adetleri....	110
Tablo 21: 30 Derece Borularda YSA(1 katman 100 nöron) Yön Sınıflandırma Sonuçları ve Adetleri.....	112
Tablo 22:30 Derece Borularda YSA(2 katman 50 nöron) Yön Sınıflandırma Sonuçları ve Adetleri.....	113

## ŞEKİLLERİN LİSTESİ

Şekil 2.1 : Particle Image Velocimetry için Standart Düzenek.....	9
Şekil 3.1 : Veri Kaydetme Sistemi.....	14
Şekil 3.2 : Kesinti Akış Sistemi .....	15
Şekil 3.3 : Sondaj Borusunun Eksantriklik Aralığı .....	15
Şekil 3.4 :Test Bölümü Dikey Konumda Olan KAS .....	16
Şekil 3.5 :Test Bölümü Yatay Konumda Olan KAS .....	17
Şekil 3.6 : Kamera için Oluşturulmuş Platform ve Halkasal Test Bölümü .....	17
Şekil 3.7 :DeneYleri Kaydedebilmek için Kullanılan Basler Scout Marka Kamera ..	18
Şekil 3.8 : Çalkalayıcı .....	18
Şekil 3.9 : Sıvı Pompaları.....	19
Şekil 3.10 : Fisher Kontrol Vanası.....	19
Şekil 3.11 : Hava Kompresörü ve Akümülatör Tankı.....	20
Şekil 3.12 : Hava Kurutucu.....	20
Şekil 3.13 : Sıvı ile Gazın Karıştığı Test Bölümünün Giriş Kısmı .....	20
Şekil 3.14 :Veri Toplama Sistemi İçin LabView 8.2 Kullanılarak Geliştirilen Uygulama .....	22
Şekil 3.15 :Veri Toplama Sistemi Geliştirilen Uygulamaya Ait Kontrol Paneli .....	22
Şekil 3.16 :Kesinti Akış Sisteminin Şematik Gösterimi .....	23
Şekil 3.17 : Akıtma Tankı Ve Spiral Metal Kırıntı Taşıyıcısı .....	25
Şekil 3.18 : Fisher Kontrol Vanası Ve Toshiba Akış Ölçer .....	25
Şekil 4.1 : Artarda Gelen İki Çerçveden İlki.....	28
Şekil 4.2 : Artarda Gelen İki Çerçveden İkincisi .....	28
Şekil 4.3 : Matlab Fonksiyonunun Sonuç Gösterimi .....	29
Şekil 4.4 : Verilerin Kaydedildiği Excel Tablosundan bir Satır Örneği .....	30
Şekil 5.1 : Biyolojik Sinir Hücresinin Yapısı .....	33
Şekil 5.2 : Bir Yapay Sinir Hücresinin Detaylı Grafik Gösterimi .....	35
Şekil 5.3 : Sigmoid Fonksiyonunu Kullanan Bir Aktivasyon Fonksiyonunun Çalışma Yapısı .....	35
Şekil 5.4 :Doğrusal Aktivasyon Fonksiyonunun Grafik Gösterimi .....	36

Şekil 5.5 :Sigmoid Aktivasyon Fonksiyonunun Grafik Gösterimi .....	37
Şekil 5.6 : Tanjant Hiperbolik Aktivasyon Fonksiyonunun Grafik Gösterimi .....	38
Şekil 5.7 : Yapay Sinir Ağlarının Yapısının Basit Gösterimi .....	39
Şekil 5.8 : İleri Beslemeli Ağ Yapısı .....	42
Şekil 5.9 : 5 Girdi ve 3 Çıktı Birimi Olan Tek Katmanlı Ağ .....	43
Şekil 5.10 : İki Katmanlı İleri Beslemeli Ağ Yapısı .....	44
Şekil 5.11 : Geri Beslemeli Ağ Yapısı .....	45
Şekil 5.12 : Geri Yayılımlı Öğrenme Kuralını Kullanan Ağ Yapısı.....	46
Şekil 5.13 : Basit Doğrusal Regresyon Modeli.....	50
Şekil 5.14 : Farklı Kesim ve Eğim Değerlerine Sahip Doğrusal Regresyon Modelleri.....	50
Şekil 5.15 : Doğrusal Regresyon Model Örnekleri.....	52
Şekil 5.16 : Doğrusal Olmayan Veri Seti İçin Doğrusal Regresyon Modeli .....	53
Şekil 5.17 : Doğrusal Olmayan Regresyon ile Modellenmiş Veri Seti .....	56
Şekil 5.18 : Rastgele Hatalar İçeren Ölçüm Verileri İçin Doğrusal Olmayan Regresyon Fonksiyonları .....	57
Şekil 5.19 : Girdi Uzayında Eğitim Verileri .....	58
Şekil 5.20 : Girdi Uzayında Verileri Ayırma Yüzeyleri .....	58
Şekil 5.21 :En Fazla Mesafe ile Birbirinden Ayrılan İki Veri Setini Ayıran Yüzey .	59
Şekil 5.22 : (a) Doğrusal Sınıflandırma (b) Doğrusal olmayan sınıflandırma: Girdi uzayından özellik uzayına dönüşüm .....	62
Şekil 5.23 : İki ve Daha Çok Sınıfın Birbirinden Ayrılması.....	65
Şekil 5.24 : Doğrusal DVM için $\epsilon$ -insensitive Kayıp Fonksiyonu .....	68
Şekil 7.1 :Yatay Borularda Doğrusal Regresyon Hız Sonuçları .....	82
Şekil 7.2 : Yatay Borularda Doğrusal Olmayan Regresyon Hız Sonuçları .....	83
Şekil 7.3 : Yatay Borularda YSA (1 Gizli Katman, 100 Nöron) Hız Sonuçları .....	83
Şekil 7.4 : Yatay Borularda DVR Hız Sonuçları .....	84
Şekil 7.5 : 15° Açılı Borularda Doğrusal Regresyon Hız Sonuçları .....	84
Şekil 7.6 :15° Açılı Borularda Doğrusal Olmayan Regresyon Hız Sonuçları .....	85
Şekil 7.7 : 15° Açılı Borularda YSA (1 Gizli Katman, 100 Nöron) Hız Sonuçları ...	85
Şekil 7.8 : 15° Açılı Borularda DVR Hız Sonuçları .....	86
Şekil 7.9 : 30° Açılı Borularda Doğrusal Regresyon Hız Sonuçları .....	86

Şekil 7.10 : 30° Açılı Borularda Doğrusal Olmayan Regresyon Hız Sonuçları .....	87
Şekil 7.11 : 30° Açılı Borularda YSA (1 Gizli Katman, 100 Nöron) Hız Sonuçları .	87
Şekil 7.12 : 30° Açılı Borularda DVR Hız Sonuçları .....	88
Şekil 7.13 :Yatay Borularda Doğrusal Regresyon Açısal Yön Sonuçları.....	94
Şekil 7.14 : Yatay Borularda Doğrusal Olmayan Regresyon Açısal Yön Sonuçları .	94
Şekil 7.15 : Yatay Borularda YSA (1 Gizli Katman, 100 Nöron) Açısal Yön Sonuçları .....	95
Şekil 7.16 : Yatay Borularda DVR Açısal Yön Sonuçları.....	95
Şekil 7.17 : 15° Açılı Borularda Doğrusal Regresyon Açısal Yön Sonuçları.....	96
Şekil 7.18 :15° Açılı Borularda Doğrusal Olmayan Regresyon Açısal Yön Sonuçları .....	96
Şekil 7.19 : 15° Açılı Borularda YSA (1 Gizli Katman, 100 Nöron) Açısal Yön Sonuçları .....	97
Şekil 7.20 : 15° Açılı Borularda DVR Açısal Yön Sonuçları .....	97
Şekil 7.21 : 30° Açılı Borularda Doğrusal Regresyon Açısal Yön Sonuçları.....	98
Şekil 7.22 : 30° Açılı Borularda Doğrusal Olmayan Regresyon Açısal Yön Sonuçları .....	98
Şekil 7.23 : 30° Açılı Borularda YSA(1 Gizli Katman, 100 Nöron) Açısal Yön Sonuçları .....	99
Şekil 7.24 : 30° Açılı Borularda DVR Açısal Yön Sonuçları .....	99
Şekil 7.25 : Yatay Borularda DVM Yön Sınıflandırma Sonuçları .....	104
Şekil 7.26 : Yatay Borularda YSA(1 katman 100 nöron) Yön Sınıflandırma Sonuçları .....	105
Şekil 7.27 : Yatay Borularda YSA(2 katman 50 nöron) Yön Sınıflandırma Sonuçları .....	106
Şekil 7.28 : 15 Derece Borularda DVM Yön Sınıflandırma Sonuçları.....	107
Şekil 7.29 : 15 Derece Borularda YSA(1 katman 100 nöron) Yön Sınıflandırma Sonuçları .....	108
Şekil 7.30 : 15 Derece Borularda YSA(2 katman 50 nöron) Yön Sınıflandırma Sonuçları .....	109
Şekil 7.31 :30 Derece Borularda DVM Yön Sınıflandırma Sonuçları.....	110

Şekil 7.32 :30Derece Borularda YSA(1 katman 100 nöron) Yön Sınıflandırma Sonuçları .....	111
Şekil 7.33 : 30 Derece Borularda YSA(2 katman 50 nöron) Yön Sınıflandırma Sonuçları .....	112

## KISALTMALAR

Bu çalışmada kullanılmış olan kısaltmalar açıklamaları ile birlikte aşağıda sunulmuştur.

### Kısaltmalar Açıklama

<b>ÇNF</b>	Çerçeve Numaraları Farkı
<b>DVM</b>	Destek Vektör Makineleri (Support Vector Machines)
<b>DVR</b>	Destek Vektör Regresyon (Support Vector Regression)
<b>Ft</b>	Uzunluk Birimi (Feet)
<b>GPM</b>	Dakikada Galon (Gallons Per Minute)
<b>KAS</b>	Kesinti Akış Sistemi
<b>MAPE</b>	Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
<b>MPE</b>	Ortalama Yüzde Hata (Mean Percantege Error)
<b>Psi</b>	Basınç Birimi (Pounds Per Square Inch)
<b>Q<sub>G</sub></b>	Gaz Fazı Akış Hızı (Gas Phase Flow Rate, L <sup>3</sup> /t)
<b>RMSE</b>	Hata Kareleri Ortalamasının Karekökü (Root MeanSquare Error)
<b>ROP</b>	Düzeneğe Her Saniyede Gönderilen Katı Parçacık, Taş, Çamur Miktarı (Rate of Penetration)
<b>RPM</b>	Dakikadaki Devir Sayısı (Revolutions per minute)
<b>SÇS</b>	Saniyedeki Çerçeve Sayısı
<b>V<sub>SL</sub></b>	Sıvı Yüzeysel Hızı (Liquid Superficial Velocity, L/t)
<b>YSA</b>	Yapay Sinir Ağı

## SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Simgeler</b>	<b>Açıklama</b>
<b>Psi</b>	Basınç Birimi (Pounds Per Square Inch)
<b>Q<sub>G</sub></b>	Gaz Fazı Akış Hızı (Gas Phase Flow Rate, L <sup>3</sup> /t)
<b>ROP</b>	Düzeneğe Her Saniyede Gönderilen Katı Parçacık, Taş, Çamur Miktarı (Rate of Penetration)
<b>RPM</b>	Dakikadaki Devir Sayısı (Revolutions per minute)
<b>V<sub>SL</sub></b>	Sıvı Yüzeysel Hızı (Liquid Superficial Velocity, L/t)

# 1. GİRİŞ

## 1.1 Genel Bakış

Birincil enerji kaynakları arasında stratejik öneme sahip olan petrol ve doğalgaz, dünya enerji talebinin büyük çoğunluğunu karşılamaktadır [1]. Bu kaynaklara duyulan ihtiyaç gün geçtikçe daha fazla artmakta, bu ihtiyacı karşılayabilmek için de gelişmiş donanımlar yardımıyla daha derin ve zor bölgelerde sondaj işlemlerinin yapılmasına gerek duyulmaktadır. Sondaj, özel bir takım araçlar kullanılarak, buzul kütlesi, kaya veya toprak zemin gibi her türlü katı ortamda ve her yönde silindirik kuyular açma işlemi olarak açıklanabilmektedir [2]. Yeraltında bulunan petrol, su ve doğalgaz gibi kaynakların çıkartılması veya yeraltındaki jeolojik yapıların incelenebilmesi gibi çeşitli sebeplerle sondaj kuyuları açılmaktadır [3]. Sondaj kuyuları, jeolojik yapılarından dolayı kuyu temizliğine ihtiyaç duymakta ve yapılan temizlik işlemi sonunda kuyular eski temizlik ve debilerine ulaşmaktadırlar [4]. Maliyet ve uygulama açısından kuyu temizliğinin ve sondaj işlemlerinde kesilen formasyonlara ait kesintilerin taşınma işlemlerinin verimli şekilde gerçekleştirilmesi oldukça önemlidir [5].

Kara ve deniz üzerinde yapılan sondaj işlemlerinde, yatay ve açılı sondaj giderek önem kazanmaktadır [6]. Yatay kuyularda, dikey eksenden yaklaşık 90° lik bir eğimle sondaj işlemi yapılmaktadır. Başarılı bir yatay ve açılı sondaj işlemi sırasında önemli olan hususlardan birisi yukarıda da bahsedildiği gibi kuyu temizliğidir çünkü kuyu temizliği direk olarak sondaj işleminin maliyetini, zamanını ve kalitesini etkilemektedir. Bu nedenle, maliyet, kalite gibi problemlerle karşılaşmamak için ortaya çıkan kesintilerin sondaj akışkanı yardımıyla taşınması gerekmektedir. Sondaj akışkanının taşıma kapasitesini en çok etkileyen parametrelerden bazıları, akışkanın hızı, biriken kesinti miktarı, basınç, sıcaklık, eksantrik borunun dönme hızı, eğim açısı, borunun eksantrikliği olarak sayılabilir [7].

Çok fazlı akışlarda, gaz fazı, sıvı fazı ve parçacık farklı akış davranışlarına sahiptirler. Çok fazlı akışlarda, sondaj parçacığının davranışını tahmin etmek için parçacığın hareket yönü ve hızı iki önemli husustur. Çok fazlı akışlarda, aynı anda



birden fazla noktadaki akışkan hız vektörlerini doğru şekilde ölçebilmek ve akışlardaki parçacık hareketini incelemek için PIV (Particle Image Velocimetry) tekniği kullanılabilir [8, 9]. Çok fazlı sistemlerde, PIV ile ölçüm yapılmasının nedenlerinden bir tanesi, bireysel fazların hız dağılımlarını eş zamanlı olarak belirlemeye çalışmaktır [10]. Yapay zekâ modelleri kullanılarak da, akış özelliklerini anlamaya yönelik çalışmalar yapılmaktadır. Akış özelliklerini tahmin edebilmek için; en yakın komşu algoritması, karar ağacı, geri yayımlı yapay sinir ağları, destek vektör makineleri veya bunlara dayanan metotlar geliştirilmiştir [11, 12]. Birçok yöntem kullanılarak, çok fazlı akışlarda parçacık akış hareketleri ve taşınma hızları incelenmiştir. Ancak, eksantrik borulardaki çok fazlı akışlarda parçacığın (sondaj kesintinin) akış yönünü ve taşınma hızını tahmin edebilmek için henüz bir çalışma yapılmamıştır.

## 1.2 Çalışmanın Amacı

Daha önceki bölümde bahsedilen eksiklikler göz önüne alındığında bu çalışmada, eksantrik borulardaki çok fazlı akışlar için kesintilerin karakteristiğini, yani kesintilerin ilerleme yönlerini ve taşınma hızlarını tahmin etmeye çalışmak hedeflenmiştir. Gerçek dünyada yatay ve eğimli kuyularda sondaj işlemi yapılırken, delgi işlemi tamamlandıktan sonra çeşitli sondaj kesintileri ortaya çıkmaktadır. Bu sondaj kesintilerinin ne yönde ve ne hızla ilerledikleri, kuyuların içerisini görme şansımız olmadığından bilinmemekte, ancak maliyeti ve kuyu temizleme zamanını azaltabilmek ve sondaj kalitesini arttırabilmek için bilinmesi önem arz etmektedir. Bu nedenle, akışı gözlemleyebilmek için saydam bir boru içeren eksantrik boruya sahip deney düzeneği sayesinde çok fazlı (kesinti-sıvı-gaz) akışlar için deneyler yapılmıştır. Bu deneyler, Orta Doğu Teknik Üniversitesi, Petrol ve Doğalgaz Mühendisliği Bölümü, Kesinti Taşıma ve Çok Fazlı Akış Laboratuvarında yürütülmüştür. Çalışma kapsamında, çok fazlı (kesinti-sıvı-gaz) akışlar için eksantrik boru düzeneğinden elde edilmiş olan deneysel veriler kullanılmıştır. Deneyler halkasal borunun yatay ve açılı (15 ve 30 derece) olduğu durumlar için gerçekleştirilmiştir. Deneyler sırasında, yüksek hızlı kamera kullanılarak akışlar

kaydedilmiştir. Deneyle sonucunda elde edilen dijital görüntüler sayesinde, akış içerisindeki kesintilerin taşınma hızı ve yönü hakkında bilgiler edinilmiştir. Deneylelerden hız ve açısal yön tahmini yapabilmek için; 15 derece açılı borular için 1080 adet, 30 derece açılı borular için 1087 adet, yatay borular için 885 adet veri toplanmıştır. Yön sınıflandırması yapmak için kullanılan veri sayısı ise; 15 derece açılı borular için 1235 adet, 30 derece açılı borular için 1552 adet, yatay borular için 1119 adettir. Hedeflenen sistemlerin eğitim ve testi için, her bir veri kümesinin yarısı sistemin eğitimi, kalan yarısı ise sistemin test edilmesi için kullanılmıştır. Deneysel verilerden elde edilen bilgiler ışığında, çeşitli teknikler kullanılarak, hız ve yön bilgileri ile alakalı tahminler yapılmaya çalışılmıştır.

Tez kapsamında, çok fazlı akışlarda, akış içerisindeki kesintilerin akış yönü ve hızı gibi akış özelliklerini, deneylelerden elde edilen veriler ışığında tahmin edebilmek için, hesaplamalı zekâ tekniklerini kullanarak tahmin modelleri geliştirmek hedeflenmiştir. Yani bu çalışma, hesaplamalı zekâ modellerine dayanan parçacık hız ve yön tahmini için bir yaklaşım sunmaktadır. Sınıflandırma ve tahmin problemleri için, yapay sinir ağları ve destek vektör makineleri son zamanlarda kullanılan önemli metotlardan olmuşlardır. Bu çalışmada, parçacığın hız veya yön ile ilgili tahmin veya sınıflandırmalar yapmak için ileri beslemeli yapay sinir ağları, destek vektör makineleri, destek vektör regresyonu, doğrusal regresyon ve doğrusal olmayan regresyon teknikleri kullanılmıştır. Daha sonra elde edilen sonuçlar, çeşitli performans metrikleri kullanılarak karşılaştırılmıştır.

Bu çalışmayı literatürdeki çalışmalardan ayıran en önemli özellik, eksantrik borulardaki kesintilerin taşınma hızlarının ve yönlerinin tahmin ediliyor olmasıdır çünkü literatürde bu konu ile alakalı henüz herhangi bir çalışma bulunmamaktadır. Ayrıca, birden fazla tahmin modeli geliştirilerek sonuçların karşılaştırmalı olarak belirtilmiş olması da bu çalışmayı diğer çalışmalardan ayırmaktadır.

### 1.3 Tez İeriđi

Bu tez alıřması 8 blmden oluřmaktadır ve bu blmlerin ierikleri ařađıda kısaca aıklanmıřtır.

Blm 1' de genel tanıtıcı bilgiler, alıřmanın amacı ve her blmle alakalı zet bilgiler verilmiřtir. Blm 2' de ok fazlı akıřlarla ilgili daha nce yapılmıř benzer alıřmaların incelendiđi kaynak arařtırması kısmı bulunmaktadır. Bu kısımda incelenen kaynaklar, konularına gre iki ayrı bařlık altında incelenmiřtir. Blm 3'te, deneylerin gerekleřtirildiđi Kesinti Tařıma ve ok Fazlı Akıř laboratuvarındaki deney dzeneđi hakkında detaylı bilgiler bulunmaktadır. alıřma kapsamında kullanılan video erevelerinin elde edilmesi iin gerekleřtirilen deneyler ve deneysel prosedrn ne řekilde iřlediđi ayrıntılı olarak aıklanmıřtır. Blm 4' te deney dzeneđi sayesinde elde edilmiř video erevelerinden verilerin nasıl toplandıđı hakkında bilgiler verilmiřtir. Elde edilen verilerin ne řekilde kaydedildiđi ve nasıl kullanıldıđı aıklanmıřtır. Blm 5' te, tez kapsamında tahminleri veya sınıflandırmayı yapmak iin kullanılan teknikler ayrıntılı olarak aıklanmıřtır. Blm 6' da, gerekleřtirilen tahmin ve sınıflandırmalar sonucunda elde edilen sonuların, bařarı karřılařtırmalarını yapabilmek iin kullanılan performans metriklerinden bahsedilmiřtir. Blm 7' de, bu alıřma sonucunda elde edilmiř olan sonular grafiksel olarak gsterilmiř ve deđerlendirilmiřtir. Son olarak, blm 8' de ise, bu alıřmaya ek olarak yapılabilecek gelecek alıřmalardan bahsedilmiřtir.

## **2. KAYNAK ARAŞTIRMASI**

Bu bölümde, yatay, dikey veya açılı konumda olan halkasal borulardaki iki fazlı veya çok fazlı akışlar üzerinde yapılmış olan çalışmalardan bahsedilecektir. Bu çalışmalar iki ayrı başlık altında incelenecektir. Bu başlıklardan ilkinde kesinti taşınması üzerine yapılmış olan teorik ve deneysel çalışmalardan, ikincisinde ise PIV (Particle Image Velocimetry) ve hesaplamalı zekâ modelleri kullanılmış olan çalışmalardan bahsedilecektir.

### **2.1 Kesinti Taşınması Üzerine Yapılmış Çalışmalar**

Bu kısımda daha çok sondaj akışkanlarının akış mekanizmaları ve kesinti taşıma işlemleri üzerine yapılmış olan geleneksel çalışmalardan bahsedilecektir. Bu çalışmaların bir kısmı teorik çalışmaları içerirken, bir kısmı da teorik çalışmalarının yanında deneysel çalışmaları da içermektedir.

Bu bölümde ilk önce, kesinti taşınması ile ilgili yapılmış olan teorik araştırmalarından bahsedilecektir. Pilehvari ve arkadaşları [13] ile Brown ve arkadaşları [14], ayrı ayrı yaptıkları çalışmalarda benzer konulardan bahsetmişlerdir. Bu iki çalışmada da, sondaj işlemlerinin temel parçalarından birinin sondaj kesintilerinin etkili taşınması yani kuyu temizliğinin etkili yapılması olduğundan bahsedilmiştir. Kuyu temizliğinin etkili yapılmamasının, yüksek döndürme ve çekme kuvvetleri, hızlı matkap aşınması ve yavaş delme hızı gibi problemlere sebep olabileceğini belirtmişlerdir. 1997 yılında Azar ve arkadaşları [7], dikey borularda yapılan sondajlar için, kesinti taşımadaki önemli sorunları anlattıkları bir çalışma yapmışlardır. Bu çalışmada, dikey borularda sondaj işlemi yapılırken, kuyu temizliği üzerinde etkisi olan birçok faktörden bahsetmişlerdir. Bu faktörlerin en yaygın olanlarını şu şekilde sıralamışlardır: Halkasal akışkan hızı, kuyu eğim açısı, eksantriklik, delme hızı, sondaj akışkanının özellikleri, sondaj kesintilerinin karakteristiği. Azar ve arkadaşları bu çalışmada, bahsedilen faktörler ve bu faktörlerin gerçek saha çalışmalarındaki kısıtları üzerine tartışmışlardır. 2004 yılında ise Paredes ve arkadaşlarının yaptıkları çalışmada [15] amaçları, iki katmanlı katı-

sıvı akışın konseptini kullanarak yatay kuyulardaki kesinti taşımanın matematiksel modelini elde etmek, akış performansını tahmin etmek için hacim ortalamasının metodunu elde etmek ve yatay kuyu sondajı boyunca kesinti taşımanın tekniğini etkileyen bazı önemli parametrelerin etkilerini değerlendirmektir. Bu amaçlarını başarabilmek için, çok fazlı sistemler için taşıma denklemlerini elde etmede kullanılan bir teknik olan hacim ortalaması metodu (Whitaker, 1999) ve iki fazlı akış modelinin ana yaklaşımlarından biri kullanılarak bir model geliştirilmiştir.

Kesinti taşınması üzerine yapılmış çalışmalardan bir kısmının, teorik kısmının yanında deneysel araştırmaları da içerdiğinden daha önce bahsetmiştik. Bu kısımda daha çok bu çalışmaların deneysel araştırma kısımlarından bahsedilecektir. Tomren ve arkadaşları 1986 yılında yönlü kuyularda kesinti taşıma üzerine bir çalışma yapmışlardır [16]. Matkabın dönme hızı, açısı ve kuyunun eksantrikliği gibi faktörlerin taşıma performansını nasıl etkilediği üzerinde çalışmışlardır. Bu çalışmaları yapabilmek için deneyler yapmışlar, deney sırasında da 40 ft uzunluğunda test bölümüne sahip bir düzenek kullanmışlardır. Deneysel çalışmalarını, 0 ile 90° arasındaki açı değerlerinde ve gerçek sondaj kesintilerini kullanarak gerçekleştirdiklerini belirtmişlerdir. Çalışmalar sonunda, kesinti taşımayı en çok etkileyen faktörlerin sondaj sıvısının hızı, kuyu eğimi ve akış özellikleri olduğunu söylemişlerdir. Sifferman ve arkadaşları 1992 yılında yaptıkları çalışmada [17], açılı sondaj kuyularındaki kuyu temizliği için yaptıkları çok faktörlü deney çalışmasından bahsetmişlerdir. Deney sırasında kullandıkları, çamurun akış hızı ve yoğunluğu, çamurun yağ veya su tabanlı olmasına göre tipi, kesintinin boyutu, delme hızı, sondaj borusunun dönme hızı, sondaj borusunun eksantrikliği ve çapı, kuyunun açısı gibi faktörlerin kesinti yatağının kalınlığını etkilediğini ifade etmişlerdir. Bu çalışma sonucunda, sondaj parametrelerinin kesinti birikmesini ve yatak oluşmasını nasıl etkilediğini göstermişler, böylece kontrol edilebilir faktörler ile daha az kesinti birikmesinin sağlanabileceğini ifade etmişlerdir. Özbayoğlu ve arkadaşları yaptıkları çalışmada [18], yatay ve yüksek açılı kuyulardaki sondaj akışkanının hızının kritik bir hızdan düşük olduğu durumda sabit bir yatak oluşacağından bahsetmişlerdir. Bu yüzden de kritik hız olarak asgari bir hızın belirlenmesi gerekliliğine dikkat çekmişlerdir. Özbayoğlu ve arkadaşları bu çalışmada, hareketsiz yatak oluşumunu

engellemek için akışkanın sahip olması gereken asgari hızı tahmin etmeye çalışmışlardır. Bu tahmini yapabilmek için, Orta Doğu Teknik Üniversitesi, Petrol ve Doğalgaz Mühendisliği Bölümü'ndeki laboratuvarında, farklı açılarda ve akış hızlarında deneyler yapmışlardır. Yapılan deneyler sonucunda akışkan hızı 6,0 ft/s' den az olduğu zaman sabit yatak oluşumunun gerçekleştiği gözlemlenmiştir. Ayrıca açısı 50 dereceden az olan kuyularda da sabit yatak oluşabileceğini belirtmişlerdir. Peden ve arkadaşları [19], kuyu eğimi, kesintinin boyutu, sondaj akışkanının özelliği, sondaj borusunun büyüklüğü ve eksantrikliği gibi parametrelerin kesinti taşınması üzerindeki etkisini en küçük taşıma hızının konseptini kullanarak incelemişler. Bu konseptte göre, eğer hız en küçük taşınma hızına eşit veya bu hızdan daha büyükse, kesintinin yuvarlanarak veya akışkan içerisinde akarak taşınması ile kuyunun etkili şekilde temizleneceğini varsaymışlardır. Sonuç olarak ise, borunun büyüklüğünün ve eksantrikliğinin seviyesine bağlı olarak sıvı akış özelliğinin en küçük hız üzerinde en çok etkiye sahip olduğunu belirtmişlerdir. Ozbayoglu ve arkadaşları 2003 yılında yaptıkları çalışmada [20], yatay ve yüksek eğimli borularda kesintinin köpük ile taşınmasını analiz etmişlerdir. Kütle ve doğrusal momentumun korunumu prensipleri kullanılarak, 3 katmanlı bir model sunmuşlardır. Akış hızları, kesinti yatak yükseklikleri, kayış hızı, akan kesintinin konsantrasyonu ve basınç düşüşleri için sistem denklemlerini çözmek amacıyla bir bilgisayar simülatörü geliştirmişlerdir. Kesinti taşınması üzerine, yatayla 70°- 90° arasında eğime sahip büyük çaplı bir deney düzeneği kullanmışlardır. Deneyler sonucunda, kesinti yatağı kesit alanı ve basınç kayıplarına karşı köpük akış hızını gösteren grafikler sunmuşlardır. Deneyden elde edilen bu verileri, geliştirdikleri bilgisayar simülatöründe sonuçlarını doğrulayabilmek kullanmışlardır. Bu simülatörün, yatak kalınlığını ve basınç düşüşlerini birçok durumda %20' den daha az hata ile tahmin ettiğini bildirmişlerdir. 2005 yılında Ozbayoglu ve arkadaşları [21], yatay ve yüksek eğimli borulardaki köpük ile kesinti taşınmasının modellenmesi üzerine bu konu ile ilgili yapılan ilk çalışmalardan birini yapmışlardır. Bu çalışmada, yatay borulardaki kesinti taşınmayı açıklayan katmanlı bir model geliştirilmiştir. Kesinti yataklarının varlığından dolayı, köpük için yaygın reolojik (akışbilimsel) model parametreleri, karmaşık kanal geometrisi ve akışkan özelliklerinin fonksiyonu olarak analitik şekilde değiştirilmiştir. Bu parametreler kullanılarak, akışkan ile kuyu, katmanlar ile çamur

ve kesinti ile akışkan arasındaki sürtünme belirlenmiştir. Model performansının test edilmesi sonucunda, geliştirilen model, kuyulardaki geliştirilmiş kesinti yatak kalınlığını ve basınç kaybını %20' den daha az bir hata ile tahmin edebilmektedir.


Şimdiye kadar yapılmış olan çalışmalarda, açılı kuyulardaki kesinti taşıma mekanizmalarından ve kesintilerin taşınması için ortaya konmuş bazı mekanistik modellerden de bahsedilmektedir. Burada kesinti taşıma mekanizmalarından ve mekanistik modellerden bahseden çalışmalar incelenecektir. Ford ve arkadaşları yaptıkları çalışmada [22], Heriot-Watt Üniversitesi Petrol Mühendisliği bölümünde yürütülen açılı sondaj kuyularındaki sondaj kesintilerinin taşınması ile ilgili deneysel araştırmalarından bahsetmişlerdir. Araştırmalar sonucunda, iki farklı kesinti taşıma mekanizması belirlemişlerdir. Bu mekanizmalardan ilkinde kesintilerin yuvarlanma veya kayma hareketi yaparak yüzeye taşınacağından bahsetmişlerdir. İkinci mekanizmada ise kesintilerin dolaşımında olan akışkanla birlikte taşınabileceğini ancak bu mekanizma için gereken akışkan hızının ilk mekanizmaya göre daha fazla olduğunu belirtmişlerdir. Sonuçta mekanizmalar farklı sondaj parametrelerine sahip olsalar da, kuyu temizliği için aynı etkiyi yaratmışlardır. Clark ve arkadaşları 1994 yılında yaptıkları çalışmada [23], kesintilerin sondaj kuyusu boyunca çeşitli mekanizmalar tarafından yüzeye taşınabileceğinden ve belli mekanizmaların sondaj kuyusunun eğimine bağlı olduğundan bahsetmişlerdir. Yüksek açılı kuyularda sabit kesinti yataklarının oluşabileceğini ve bu kuyularda kesinti taşıma işleminin yuvarlanma mekanizması aracılığıyla yapılacağını ifade etmişlerdir. Orta açılı kuyularda ise hareketli kesinti yataklarının oluşabileceğinden ve kesinti taşıma işleminin de yine yuvarlanma mekanizması ile olacağını belirtmişlerdir. Neredeyse yatay konumda olan kuyularda, kesinti taşınmasının parçacığın çökmesi olarak belirlendiğini söylemişlerdir. Clark ve arkadaşları bu çalışmada, herhangi bir konumda kesinti taşınmasının analizinin kolay bir şekilde yapılabilmesi için, yukarıdaki akış mekanizmalarının davranışlarını bir arada toplayarak yeni bir model önermişlerdir. Kamp ve arkadaşları da 1999 yılında, mekanistik modeller üzerine bir çalışma yapmışlardır [24]. Bu çalışmada, yatay ve dikey sondajın planlanması için temel şeyin kesinti taşınması olduğundan bahsetmişlerdir. Geliştirdikleri katman model yaklaşımından bahsetmişler ve bu modeli sayısal simülasyonlar yapmak,

kesinti yatak yüksekliğini, basınç düşüşlerini ve taşıma hızını tahmin etmek için kullandıklarını ifade etmişlerdir. Buldukları tahmin sonuçlarını, korelasyon tabanlı modeller kullanılarak elde edilmiş tahmin sonuçları ile karşılaştırmışlardır. Çıkan sonuçlar neticesinde, sonuçlar arasındaki farklılıkları incelemişler ve şu anki modellerini bu incelemelerine dayanarak geliştirmeyi hedeflediklerini bildirmişlerdir.

## 2.2 Parçacık Görüntüsünden Hız Tespiti (Particle Image Velocimetry-PIV) ve Yapay Zekâ Uygulamaları İçeren Çalışmalar

PIV (Parçacık Görüntüsünden Hız Tespiti) tekniği kullanılarak, parçacık hız konusu üzerine yapılmış birçok çalışma bulunmaktadır. Çok fazlı akışlar için, PIV yönteminin kullanıldığı bazı çalışmalardan bu bölümde kısaca bahsedilecektir.

R. J. Adrian 2005 yılında “Parçacık Görüntüsünden Hız Tespitinin Yirmi Yılı” isimli bir kaynak taraması çalışması [8] yayınlamıştır. Bu çalışmaya göre, parçacık görüntüsünden hız tespiti metodunun gelişmesi, yeni ve daha iyi ölçümler yapabilmek için gerekli adımları tanımlayarak olmuştur. Modern manada PIV, aynı anda çok fazla noktadaki akışkan hız vektörlerinin doğru ve sayısal ölçümü anlamına gelmektedir. Lindken ve arkadaşları 1999 yılında yaptıkları çalışmada [10], çok fazlı akışlarda PIV tekniğini kullanarak hız ölçümleri yapmışlardır. Tek fazlı akışlarda, PIV ölçümleri için kullanılan standart düzenek Şekil 2.1’ de görülmektedir. Lazer tarafından gönderilmiş ayarlanmış ışık, iki boyutlu ışık levhasını oluşturmak için lens sistemi tarafından genişletilmiştir. Bu levha, incelenecek akıştaki ölçüm düzlemini tanımlamaktadır. Akışı görselleştirmek için, lazer ışığını yansıtan küçük izleyici parçacıklar ile akışkan takip edilmektedir.



Şekil 2.1 : Particle Image Velocimetry için Standart Düzenek [10]



Lindken ve arkadaşları yaptıkları bu çalışmada [10], parçacık görüntüsünden hız tespitinin prensibini ve çok fazlı sistemlerde ve suda ortaya çıkan kabarcıkların etrafındaki akışlardaki hızları ölçmek için PIV uygulamalarını anlatmışlardır. PIV kayıtlarını değerlendirmek için geliştirdikleri algoritmayı açıklamışlardır. Çok fazlı sistemlerde ölçüm yapmalarının amacının, bireysel fazların hız dağılımlarını eş zamanlı olarak belirlemek olduğunu belirtmişlerdir. Sistemde bulunan farklı fazlardan elde edilen bilgileri ayırmak için de dijital maskeleyme tekniği kullanmışlardır. Carlson ve arkadaşları [25] yaptıkları çalışmada, çok fazlı akışlardaki parçacık hızlarını bulabilmek için, ultrasonik noktadan hız tespiti (ultrasonic speckle velocimetry-USV) isimli bir teknik kullanmışlardır. Deneylerini gerçekleştirmek için, sudaki Magnetit ve Sonazoid süspansiyonlarını kullanmışlardır. Bütün deneyler akış yönünde bir hareket olan dikey bir boruda gerçekleştirilmiştir. Her deney için, sıvı akış hızının ölçümü de ayrıca yapılmıştır. Sıvı akış hızı, ortalama parçacık hızları ile karşılaştırılmıştır. Sonuç olarak sıvı ve parçacıkların hızları farklı olmasına rağmen, USV yöntemi başarılı ve doğru bir şekilde hızları ölçmüştür. Kadambi ve arkadaşları 1998 yılında yaptıkları çalışmada [26], iki fazlı akışlarda PIV tekniğini kullanarak parçacık boy ayırımı yapmışlardır. Parçacık boyutunu tahmin etmenin limitlerini belirlemek için, standart PIV sisteminin bileşenlerinden olan yüksek çözünürlüklü CCD kamera ve argon iyon lazer kullanılarak elde edilen hareketsiz parçacıkların görüntülerini kullanmışlardır. Kameranın bulanıklık etkileri ve lazer ışık levhası içindeki Gauss yoğunluk varyasyonlarının etkileri üzerinde ayrıca çalışarak, dengeli bir PIV kurulumu tasarlamışlardır. Bu PIV boyut tanıma sisteminin başarısını test etmek için monodispers ve polidispers parçacıklar kullanmışlardır. Sonuçta, parçacıkların büyük çoğunluğunun boyutu doğru olarak tahmin edilmiştir. Shi Hui-xian 2007 yılında, PIV kullanarak iki fazlı akışlardaki akış yapıları hakkında deneysel bir araştırma yapmıştır [9]. Sirkülasyonlu akış yatağı kanalındaki iki fazlı akış (gaz-katı) içerisindeki küme özelliklerini ve parçacık hareketini incelemek için PIV tekniğini uygulamıştır. Deneylere göre, kümeler farklı konumlarda görülebilmekte ve şekilleri ile hızları zamanla değişebilmektedir. Çeşitli kümelerin mikro yapısını ve görsel görüntülerini elde etmiştir. Gri seviye eşik (gray level threshold) metodu ile kümelerin sınırı belirlenmiştir. Daha sonra kümeler, kümelerin şekli ve konumu ile parçacıklar arasındaki uzaklığa göre

sınıflandırılmıştır. Yüksek yoğunluklu parçacıklar için, PIV ve MQD (En küçük kare farkı) çapraz korelasyon (cross-correlation) algoritması kullanılarak, parçacık hız vektör alanı elde edilmiştir. Sonuç olarak, merkezci (radial) yöndeki parçacık aksenal hızının dağıtım ve büyüklüğü istatistiksel olarak araştırılarak, parçacık hareketinin özellikleri ortaya konmuştur. Elde edilen sonuca göre, kanalın merkez bölgesindeki aksenal hızın büyüklüğünün, kanalın duvar bölgesine yakın kısmındaki hızdan daha büyük olduğu görülmüştür. Kumara ve arkadaşları 2010 yılında yaptıkları çalışmada [27], yatay ve neredeyse yatay konumda olan borulardaki su-yağ karışımı akışlar için deneysel araştırmalar yapmışlardır. Deneyler, oda sıcaklığında ve atmosfer dış basıncında, iç çapı 56 milimetre olan 15 metre uzunluğundaki paslanmaz çelik borularda gerçekleştirilmiştir. Akış alanının müdahalesiz ani hız ölçümlerini elde edebilmek için PIV yöntemi kullanılmıştır. Ani yerel hızlara dayanan ortalama hızlar, değişen hız elemanları ve Reynolds gerilimleri tahmin edilmiştir. Yağ ve su hacimsel akış oranları eşit olduğunda, daha yoğun yağ fazındaki en büyük ortalama aksenal hızı bulunmuştur. Yağ-su akışının PIV ölçümlerine göre, hız ile borunun açısı arasında ciddi bir bağıntı olduğu gösterilmiştir. Chen ve arkadaşları [28], üç boyutlu akışkan yataklardaki akışın yapısını karakterize etmek için PIV metodu kullanmışlardır. Bu metodu, farklı fazlarda ani hız dağılımı, hız değişimi, hızlandırma, kabarcık boyutları ve dağılımı, istatistiksel akış bilgisi gibi nicel sonuçlar ve nitel görselleştirmeler elde edebilmek için kullanmışlardır. Fotoğrafla ilgili geleneksel görüntü işleme teknikleri ile karşılaştırıldığında, şimdiki kullanılan tekniğin bütün yönleriyle dijitalleştirilmiş resim ve analitik şemaların işlem süresini birkaç saatten birkaç dakikaya düşürebileceğinden bahsetmişlerdir. PIV sistemi, indis eşleme tekniği ile birlikte kullanıldığında, ölçümlerin yüksek hacimsel oranlı katı içeren akışkanlaşma durumunda bile yapılabildiğini göstermişlerdir. Miyazaki ve arkadaşları 1999 yılında, PIV tekniğini kullanarak yatay borulardaki iki fazlı sarmal akışlarda parçacık hareketini ölçmüşlerdir [29]. Boru duvarının yakınındaki bölgelerde, parçacık konumunun düşük olasılık yoğunluklarını bulmuşlardır. Sarmal akışlarda parçacık ile borunun temasının azalabildiğini göstermişler, bunun da sarmal ağız kullanıldığında güç tüketiminin neden azaldığının en önemli sebebi olduğunu belirtmişlerdir. PIV tekniğini, ayrıca yüksek doğrulukla parçacığın aksenal hızlarını ölçebilmek için de

kullanmışlardır. Sonuç olarak, PIV tekniğinin, boru kesitindeki parçacık konumlarının ve parçacık aksenal hızlarının ölçümü için kullanışlı olduğunu göstermişlerdir.

Akış örüntülerini tahmin etmek için hesaplamalı zekâ modellerinden yararlanmış, yeni modeller önerilmiş olan çalışmalardan bazılarından burada bahsedilecektir. Ozbayoglu ve Yuksel 2011 yılında yaptıkları çalışmada [11], eksantrik borulardan elde edilen verileri kullanarak iki fazlı (sıvı ve gaz) akışlarda, akış örüntülerini ve sıvı hacimsel oranını analiz etmişlerdir. Akışı kaydetmek için yüksek hızlı dijital kamera kullanmışlar, sıvı hacimsel oranını ise dijital görüntü işleme teknikleri yardımı ile hesaplamışlardır. Bu çalışmada, yatay kuyulardaki sondaj akışkanlarının akış özellikleri deneysel olarak incelenmiş ve bu deneysel veriler kullanılarak, deneyler yapmadan bu akış özelliklerini tahmin edebilmek için birçok hesaplamalı zekâ modelleri geliştirilmiştir. Çalışmalarında kullanılmak üzere deney düzeneği yardımı ile 398 adet veri toplamışlardır. Sıvı hacimsel oranını tahmin etmek için kullandıkları hesaplamalı zekâ modellerinden (En Yakın Komşu, Karar Ağacı, Geri Yayılımlı Yapay Sinir Ağları, Destek Vektör Makineleri) en başarılı olan %92,5 doğrulukla destek vektör makineleri olmuştur. Yunlong ve arkadaşları 2008 yılında yaptıkları çalışmada [12], iki fazlı (su-hava) akışlarda, akış rejimini belirlemek için, çok özellikli resim birleştirme ve destek vektör makinelerine dayanan bir metot geliştirmişlerdir. Bu çalışmada, yatay borularda yüksek hızlı kameralar ile görüntüler almışlardır. İki fazlı akışlarda akış rejimini belirlemek için geliştirdikleri yöntemde, ilk önce yüksek hızlı fotoğraflık görüntü verisinin özellik değerlerinin elde edilmesi için görüntü işleme teknikleri uygulamışlardır ve böylece anlık sabitler ile gri seviyeli görüntü matrisinden doku özelliklerini çıkartmışlardır. Sonra, elde edilen orijinal özvektör verisinin boyutunu azaltmak için kaba küme teorisini (rough set theory) uygulamışlardır. Bunu yapmalarının nedeni hem sınıflandırma performansını arttırmak hem de destek vektör makinelerinin yapısını basitleştirmek ve eğitim ile öğrenme hızını iyileştirebilmektir. En son ise akış rejimini belirlemek için bu vektörleri kullanarak destek vektör makinelerini uygulamışlardır. Sonuçta, yatay borulardaki iki fazlı akışların akış rejimini hem hızlı hem de doğru olarak elde etmişlerdir. Özbayoglu ve Yuksel 2012 yılında yaptıkları çalışmada [30], sondaj

işlemlerinde akış örüntüsü ve sıvı hacimsel oranı gibi gaz-sıvı davranışlarının tahmin edilmesi üzerinde çalışmışlardır. Bu çalışmada, iki fazlı eksantrik halkasal borulardaki akışların akış özelliklerini deneysel olarak gözlemlemeye çalışmışlardır. Ayrıca, mekanistik modeller yerine dijital görüntü işleme tekniklerini kullanarak, bu akışların sıvı hacimsel oranını tespit etmeye çalışmışlardır. Rooki ve arkadaşları [31], 2012 yılında yaptıkları çalışmada yapay sinir ağları kullanarak, Newton yasasına uyan ve uymayan sıvılar içerisinde düşen katı parçacığın son hızını tahmin etmeye çalışmışlardır. Newton yasasına uyan ve Newton yasasına uymayan akışkanlar içinden düşen katı kürelerin son hızının tahmini için, mineral işleme, petrol ve gaz için sondaj yapma, katı-sıvı karıştırma gibi çeşitli uygulamalar gerektiğini belirtmişlerdir. Bu çalışmanın amacı, yapay sinir ağları kullanarak bu sıvılardaki küresel parçacıkların son hızını bularak farklı bir yaklaşım sağlamaya çalışmaktır. Bu çalışma için belirledikleri en iyi yapay sinir ağı modeli, 6 tane girdisi bulunan 1 girdi katmanı ve 12 tane nöron içeren 1 gizli katmanı olan bir yapay sinir ağı modelidir. Bu yapay sinir ağını test etmek için ise 69 tane test verisi kullanılmıştır. Sonuç olarak ne kadar başarılı bir çalışma yapıldığına karar verebilmek için, bütün veriler kullanılarak tahmin edilen ve ölçülen değerler karşılaştırılmıştır. Bunun sonucunda hataların ortalama karekökü değeri 0,038 m/s olarak bulunmuştur.

### 3. DENEY DÜZENEĞİ

Bu çalışma kapsamında, Orta Doğu Teknik Üniversitesi (ODTÜ), Petrol ve Doğalgaz Mühendisliği bölümünde imal edilmiş olan Kesinti Akış Sistemi'nden (KAS) yararlanılmıştır. KAS, sondaj işlemini temsil etmek için tasarlanmıştır. Bu bölümde Kesinti Akış Sistemi detaylı bir biçimde anlatılacaktır. Bu sistem kullanılarak gerçekleştirilen deneylerin süreçleri, deneysel verilerin doğruluğu gibi konular ise bu bölümde alt başlıklar halinde incelenecektir.

#### 3.1 Kesinti Akış Sistemi

Bu çalışmada kullanılan deney düzeneği Çiğdem Ömürlü [32], Hüsnü Ertan Yüksel [6] ve Reza Ettehadi Osgouei [33]' nin yüksek lisans veya doktora tezlerinde bahsettikleri deney düzeneği ile aynıdır.

Kesinti akış sistemi pompa, kompresör, kontrol vanaları, akış ölçer, basınç dönüştürücüsü gibi çeşitli donanımlardan oluşmuştur. Bu deney düzeneği aynı zamanda deney sırasında verileri kaydedebilmek için Şekil 3.1' deki gibi bir veri toplama sistemi de içermektedir.



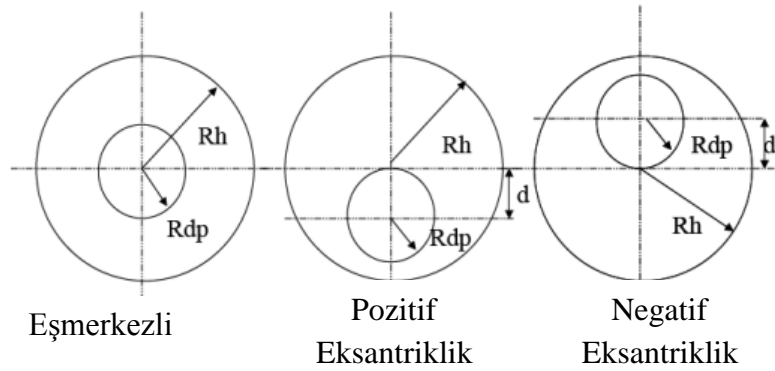
Şekil 3.1 : Veri Kaydetme Sistemi

KAS deney düzeneği kullanılarak gerçekleştirilen deneyler, bu çalışma kapsamında, katı-sıvı-gaz fazlardan oluşan akışlar için gerçekleştirilmiştir. Şekil 3.2’de, üç fazlı akışlarda kullanılabilen kesinti akış sistemi gösterilmektedir.



Şekil 3.2 : Kesinti Akış Sistemi

Kesinti akış sisteminde ölçümlerin yapılabildiği bölüm halkasal test bölümüdür. Halkasal test bölümü, yaklaşık 15 fit uzunluğunda ve 2,91 inç iç çapa sahip saydam akrilik (şeffaf renkli termoplastik bir madde) bir boru içermektedir ve bu boru eksantrik boru olarak adlandırılmaktadır. Bu borunun eksantrik olarak adlandırılmasının sebebi, bu saydam akrilik borunun içerisinde içi dolu ve bu borunun merkezine oturmayan bir boru bulunmasıdır. Sondaj borusunun eksantrikliği, Şekil 3.3’ te de görüldüğü gibi eşmerkezlilikten, pozitif ve negatif eksantrikliğe kadar değişebilir.



Şekil 3.3 : Sondaj Borusunun Eksantriklik Aralığı [33]

Yukarıda bahsettiğimiz eksantrik borunun içerisindeki içi dolu ve dış borunun merkezine oturmayan iç boru, 1,85 inç dış çapa sahip saydam olmayan bir iç sondaj borusudur. Saydam olmayan bu boru, çeşitli hızlarda döndürülebilmesi için bir motora bağlanmıştır. Bu borunun istenilen hızda döndürülebilmesi tıpkı sondaj işlemi sırasında matkabin çalışması gibi düşünülebilir. Deney düzeneğinin bir ucu yukarı aşağı doğru hareket edebilmekte, bu da düzeneğin  $10^\circ$  ile  $90^\circ$  arasında bir eğimde sabitlenerek deneyler yapılmasına imkân sağlamaktadır. Deney düzeneği  $10^\circ$ ' de sabitlendiğinde düzenek Şekil 3.4' teki gibi neredeyse dikey konumda,  $90^\circ$ 'de sabitlendiğinde ise Şekil 3.5' teki gibi yatay konumdadır. Yatay ve açılı konumları Şekil 3.4 ve Şekil 3.5' te gösterilmiş olan deney düzeneğinin halkasal test bölümündeki akışları kaydedebilmek için kullanılan kameraya ait düzenek de Şekil 3.6' da verilmiştir.




**Şekil 3.4** : Test Bölümü Dikey Konumda Olan KAS





Şekil 3.5 : Test Bölümü Yatay Konumda Olan KAS



Şekil 3.6 : Kamera için Oluşturulmuş Platform ve Halkasal Test Bölümü



Deneyleeri kaydedebilmek iin, test b6l6m6nde kameranın konulacađı platform Őekildeki gibi hazırlanmıŐ ve buraya y6ksek hızlı dijital kamera yerleŐtirilmiŐtir. Őekil 3.7’ de verildiđi gibi, renkli g6r6nt6 alabilen Basler Scout marka bir kamera Fujinon lens ile birlikte kullanılmıŐtır. Bilgisayar ile bađlantısı ise Gigabit Ethernet teknolojisi sayesinde halledilmiŐtir. Bu kamera 1032x350 boyutlarında en fazla 60 ereve/saniye video kaydı gerekleŐtirebilmektedir.



Őekil 3.7 : Deneyleeri Kaydedebilmek iin Kullanılan Basler Scout Marka Kamera[34]

Test b6l6m6n6n sonunda saydam boru, azami kapasitesi 700 bbl (barrel-varil) olan toplama tankına bađlanmıŐtır. Burada bulunan alkalayıcı sayesinde test b6l6m6nden gelen karıŐımın sıvı faz kısmı ayrılır ve bu kısım tankta toplanır. Sıvı fazın ayrılmasını sađlayan alkalayıcı Őekil 3.8’ de g6r6lmektedir. alkalayıcı tarafından ayrıldıktan sonra tankta toplanan sıvı, pompalanarak deney d6zeneđinde tekrardan dolaŐtırılması sađlanır. Sıvının d6ng6 ierisindeki kontrol6n6 sađlayabilmek iin maksimum kapasitesi 250 gal/min olan iki adet sıvı pompası ile Fisher kontrol vanası belli aralıklarla kullanılmaktadır. Fisher kontrol vanası sıvının d6ng6 ierisindeki dolaŐımını kontrol eder. Sıvı pompası ve Fisher kontrol vanası sırasıyla Őekil 3.9 ve Őekil 3.10’ da g6sterilmiŐtir.



Őekil 3.8 : alkalayıcı



**Şekil 3.9 : Sıvı Pompaları**



**Şekil 3.10 : Fisher Kontrol Vanası**

Sisteme basınçlı hava (basınçlı gaz) sağlamak için kompresör (125 psi gönderme basıncında çalışan kapasite 0-1200 ft<sup>3</sup>/min ) kullanılmaktadır. Basınçlı hava akümülatör tanklarında saklanır ve hava kurutucu ile kurutulur. Kompresörün akümülatörde bulunan bir parçası, hava basıncıyla çalıştırılan donanımlara hava sağlar. Belirli bir basınç altında sıkıştırılan hava test bölümünün giriş bölümüne taşınır ve bu bölümde sıvı ile gaz birleşerek test bölümüne verilir. Hava kompresörü ile akümülatör tankı Şekil 3.11' de, hava kurutucu Şekil 3.12' de, gaz ile sıvı fazın karıştığı test bölümünün giriş kısmı ise Şekil 3.13' te görülmektedir.



**Şekil 3.11 : Hava Kompresörü ve Akümülatör Tankı**



**Şekil 3.12 : Hava Kurutucu**




**Şekil 3.13 : Sıvı ile Gazın Karıştığı Test Bölümünün Giriş Kısmı**

Sıvı ile gaz karışmadan önce gaz debisi, yüksek gaz debileri (200-1200ft<sup>3</sup>/min ) için Fisher kontrol vanası ile kontrol edilir. Düşük gaz debileri (0-200 ft<sup>3</sup>/min) için gaz debisi ise Brass Gaz Topu vanası kullanılarak kontrol edilir. Gaz basıncının güvenilir ölçüde olup olmadığı test bölümüne girmeden önce basınç düzenleyici ile kontrol edilir. Gaz ve sıvı taşıma borularının her ikisinde de tek yönlü akışa izin vermek ve ters yönde sıvı akışını önlemek için ana hatlar üzerine monte edilmiş kontrol vanaları vardır. Gaz ve sıvı fazların akış debileri, kütle akış ölçer (sıvı için Toshiba, gaz için Cole Parmer) kullanılarak ölçülür. Sıvı ve gaz fazlarının en uygun karışımı oluşturabilmeleri için bu fazlar belli bir açıda (ters V) karıştırılır.

2 çift basınç musluğu test bölümünün iki kenarına ve ortasına uygun uzaklıklarla yerleştirilmiştir, böylece deney düzeneğinden doğru basınç ölçümleri alınabilmektedir. Bu iki basınç musluğuna bağlı ince borular bulunmaktadır. Basınç muslukları, su ile dolmuş bu ince borulardaki basınç kaybını ölçmek için farklı basınç dönüştürücülerine (Honeywell Inc. ve Cole Parmer Inc.) bağlanmıştır. Test akışkanlarından dolayı basınç musluklarının kirlenmesini önlemek için, musluk boruları düzenli olarak akıtılmalıdır.

Test bölümünün yan tarafında veri toplama ve kontrolü amacıyla bir kontrol paneli bulunur. İki adet bilgisayar, National Instrument SCXI-1000 veri kaydedici ve uygun yazılımlar ile katı, sıvı, gaz fazlarının debileri, saniyede gönderilen katı parçacık miktarı, iç boru dönme hızı ve yüksek hızlı kamera, kontrol panelinden kontrol edilir. Veri toplama sistemi kullanılarak, anlık basınç, fazların akış debileri, tank ağırlığı, düzeneğe her saniyede gönderilen katı parçacık, taş, çamur miktarı (ROP) ve iç boru dönme hızı (RPM) ölçülmektedir. “LabView 8.2” veri toplama yazılımı kullanılarak Şekil 3.14’ teki gibi bir uygulama gerçekleştirilmiştir. Bu uygulama, veri kaydetme ve saklama, gerçek zamanlı veri görüntüleme, çevrimiçi analiz, süreç izleme gibi işlemler için kullanılır. Düzenli olarak ölçümlere denetlemesi gerçekleştirilerek, ölçümlerin hassasiyetinin doğrulanması sağlanır. Gerçek zamanlı veri toplama için LabView 8.2 yazılımı kullanılarak geliştirilen uygulamaya ait kontrol paneli ise Şekil 3.15’ te verilmiştir.





Şekil 3.14 : Veri Toplama Sistemi İçin LabView 8.2 Kullanılarak Geliştirilen Uygulama



Şekil 3.15 : Veri Toplama Sistemi Geliştirilen Uygulamaya Ait Kontrol Paneli

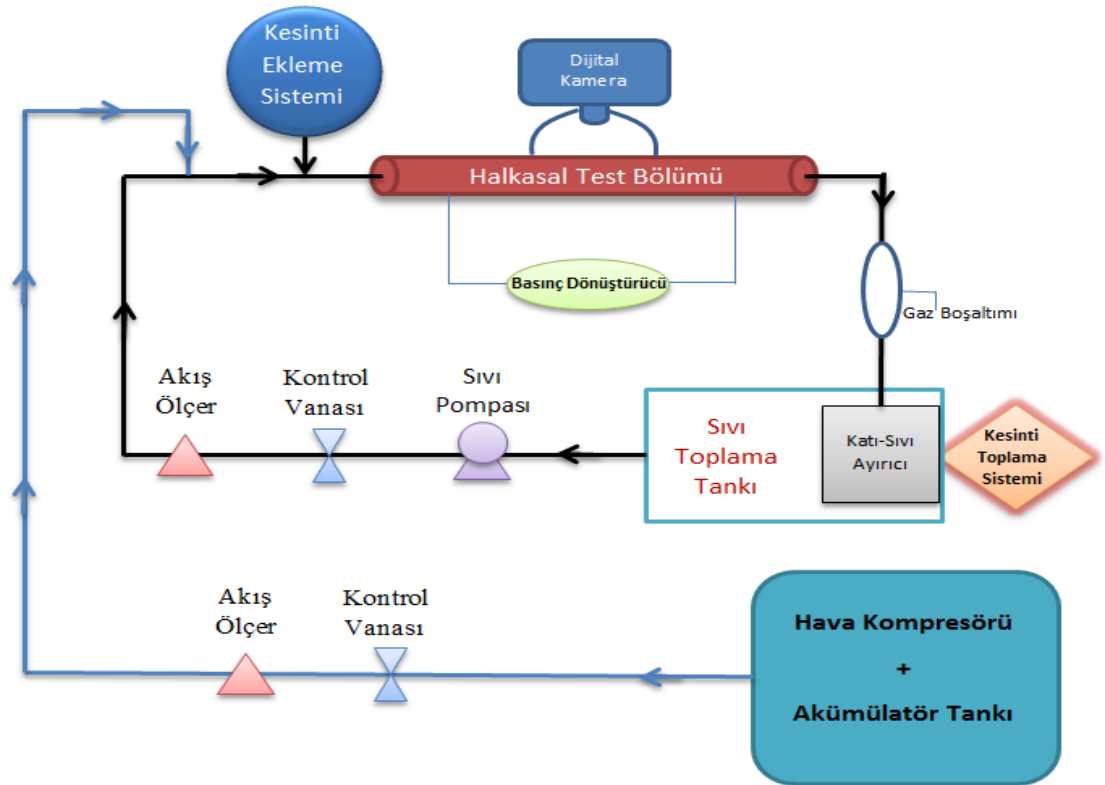
LabView 8.2 yazılımı kullanılarak geliştirilen uygulama ile deney düzenğinde deneyler yapılırken, sistem donanımlarının anlık durumları grafiksel bir arayüzle takip edilebilmektedir. Böylelikle sistemin deney sırasında daha kolay bir şekilde

kontrol edilebilmesi sağlanmış olmaktadır. Ayrıca, anlık veriler üzerinde analizler yapılarak gereksiz verilerin göz ardı edilmesi de sağlanmaktadır.

### 3.2 Gerçekleştirilen Deneyler

Gerçekleştirilen deneyler 3 fazlı akışlar üzerinde yapılmıştır. 3 fazlı deneyleri gerçekleştirebilmek için su, hava ve kesinti kullanılmıştır. Deneyler farklı gaz ve su debilerinde, farklı ROP ve RPM değerlerinde, test bölümünün neredeyse yatay ( $89,6^\circ$ ),  $15^\circ$ ,  $30^\circ$  açılı olduğu konumlarda yürütülmüştür. Deneylerin gerçekleştirildiği oda sıcaklığı  $25-35^\circ\text{C}$ ' dir ve fazların akış debilerine bağlı olarak test bölümündeki basınç  $15,7-27,7$  psi arasında değişiklik göstermektedir. Ayrıca tüm test bölümlerinin eksantriklik oranı da  $0,623$ ' tür.

Gerçekleştirilen deneylere ait süreçler aşağıda alt başlıklar halinde verilmiştir. Anlatılan süreçlerin zihinde daha iyi canlandırılabilmesi açısından kesinti akış sisteminin şematik gösterimi Şekil 3.16' da verilmiştir.




Şekil 3.16 : Kesinti Akış Sisteminin Şematik Gösterimi

### Üç Fazlı (Kesinti-Akışkan-Hava) Akış İçin Yapılmış Deneyler

Üç fazlı akışlar için yapılan deneyler daha önce bahsedilen pozisyonlarda su, hava ve kesinti kullanılarak eksantrik borularda gerçekleştirilmiştir. Üç fazlı akışlarda gerçekleştirilen prosedüre göre, sıvı ile gaz debileri sabitlendikten sonra kesintiler akıtma tankından sisteme verilmiştir. Kesintilerin akıtma tankından sisteme gönderilmesi için Şekil 3.17' de görülen spiral metal kırıntı taşıyıcısından yararlanılmıştır. Spiral metal kırıntı taşıyıcı, spiral taşıyıcı, kanal kaplama, motor ve kontrol panelinden oluşmuştur.

Üç fazlı akışlar için deneysel prosedür şu şekilde olmuştur:

- Sıvı pompası kullanılarak sıvı 0-250 gpm aralığında sabit bir akış hızında pompalanır.
- Pompalanan sıvı, kütle akış ölçer ve Şekil 3.18' de görülen Fisher kontrol vanası üzerinden geçer.
- Sıvı sabit bir debide iken, kompresör aracılığıyla halkasal test bölümüne istenilen oranda hava verilir.
- Test bölümüne verilen havanın debisi, kütle akış ölçer ve Fisher kontrol vanası yardımı ile sabit bir değere ayarlanır.
- Hava ve sıvı debileri sabitlenir sabitlenmez, kesintiler tanktan sisteme gönderilir.
- Kesinti, hava ve sıvı akış debileri sabitlenir sabitlenmez, debilerini, kritik noktadaki basınçlarını, test bölümündeki basınç düşüşlerini, basınç kayıplarını ve bunun gibi verileri kaydedebilmek için veri toplama sistemi aktifleştirilir.
- Veri toplama işlemi yapılırken, yüksek hızlı kamera da aynı zamanda test bölümünde akış aktivitelerini kaydetmektedir. Böylece bu kayıtlar kullanılarak akış örüntülerinin analizi yapılabilmektedir.
- Bu prosedür farklı sıvı, gaz ve kesinti debilerinde ve farklı boru dönme hızlarında yürütülür.



Şekil 3.17 : Akıtma Tankı Ve Spiral Metal Kırıntı Taşıyıcısı



Şekil 3.18 : Fisher Kontrol Vanası Ve Toshiba Akış Ölçer

### 3.3 Deneysel Verilerin Doğruluğu

Sıvı ve gaz kütle akış debileri, mikro-hız kütle akış ölçerleri ile ölçülmüştür. Bu akış ölçerler, kütle akışını %1 hassasiyet ile ölçmek için tasarlanmıştır. Elde edilen veriler, hassasiyetin dalgalanmalardan ve dinamik karışıklıktan etkilendiğini göstermektedir. Sıvı kütle akış ölçümleri için, çok düşük akış debilerinde (<10 gpm) ve yüksek akış debilerinde (>170 gpm) hassasiyet  $\pm\%5$  olarak çıkmaktadır. Gaz akış hızı ölçümlerinde ise, çok düşük akış debilerinde (<10 ft<sup>3</sup>/min) hassasiyet  $\pm\%15$  olmakta yani sistem içerisindeki çeşitli doğal dalgalanmalar yüzünden hassasiyet çok



düşmektedir. Daha yüksek gaz akış debilerinde ise dalgalanmalar yine gözlenir ama bu dalgalanmaların büyüklüğü daha azdır, bu da hassasiyeti  $\pm\%10'$  a yükseltmektedir.

Basınç kaybı ölçümlerinde, basınç dönüştürücülerinin ölçüm hassasiyeti  $\pm\%25'$  tir. Akış debilerindeki dalgalanmalar yüzünden, düşük gaz akış hızlarında ölçülen basınç kaybı doğruluğu  $\pm\%1$  veya daha az olmaktadır. Yüksek gaz akış debilerinde, Cole Parmer basınç dönüştürücünün hassasiyeti daha düşük olduğu için Honey Well basınç dönüştürücüsünden elde edilen değerlerin daha doğru olduğu kabul edilmektedir.

Kesinti-su-hava akışı ile gerçekleştirilen deneylerin tümü bir kere daha tekrarlanmıştır. Böylece, elde edilen verilerin doğruluğundan emin olunmuştur.

### **3.4 Deneysel Verilerin Kontrolü ve Analiz Prosedürü**

Daha önceki bölümlerde de bahsedildiği gibi, deney düzeneğinde gerçek zamanlı veri toplamak için bir veri toplama sistemi kullanılmaktadır. Bu veri toplama sistemi için, LabView 8.2 yazılımı kullanılarak geliştirilen uygulamadan ve uygulamanın kontrol panelinden de daha önceki kısımlarda bahsetmiştik. Sistemin veri analizi için gerçekleştirdiği adımlar şunlardır:

- Her girdi kanalından saniyede 1000 sinyal kaydet.
- Ölçülen sinyaldeki gürültüyü veya istenmeyen sinyalleri filtrele. (Filtre genellikle, 50 veya 60 Hertz AC (Alternating Current) güç kaynağından gelen gürültüyü ortadan kaldırmak için kullanılır.)
- Kaydedilen sinyallerden sıvı-gaz yüzeysel hızları ve ROP değerleri gibi gerekli değişkenleri hesapla.
- Filtrelenmiş sinyallerin ortalamasını hesapla ve bunları her saniyeye bir veri gelecek şekilde bir Excel dosyasına kaydet.


#### 4. VERİ HAZIRLAMA

Bu çalışma kapsamında kullanılan verilerin elde edildiği deneyler, Orta Doğu Teknik Üniversitesi, Petrol ve Doğalgaz Mühendisliği Bölümü, Kesinti Taşıma ve Çok Fazlı Akış Laboratuvarındaki deney düzeneğinde gerçekleştirilmiştir. Test bölümündeki akışları kaydetmek için, yüksek hızlı dijital kamera kullanılmış ve dijital görüntüler elde edilmiştir. Yüksek hızlı dijital kamera tarafından, test bölümündeki akışlar saniyede 60 çerçeve (60 frame/second) alınarak kaydedilmiştir. Kaydedilen bu çerçevelerin (frame) hepsi 1032x350 boyutlarındadır. Deneylerin kaydedilmesi, test bölümünün yatay ve açılı ( $15^\circ$  ve  $30^\circ$ ) olduğu durumlarda ayrı ayrı gerçekleştirilmiştir. Ayrıca, deneylerin kaydedilmesi sırasında, farklı RPM (Rotations Per Minute), ROP (Rate of Penetration),  $V_{SL}$  (Liquid Superficial Velocity) ve  $Q_G$  (Gas Phase Flow Rate) değerlerinde kayıtlar alınmasına dikkat edilmiştir.


ODTÜ Kesinti Taşıma ve Çok Fazlı Akış Laboratuvarında kaydedilmiş videolar, daha önce yapılmış olan çalışmalarda kullanılmak üzere, tek tek çerçevelerine ayrılmıştır. Bu çalışma kapsamında kullanılacak olan veriler, yukarıda bahsedildiği gibi daha önceki çalışmalarda başkaları tarafından kullanılmış çerçevelerden elde edilen bilgiler olacaktır. Çerçevelerdeki parçacıkların hareketlerinden yararlanılarak bir veri kümesi oluşturabilmek için Matlab R2012b kullanılarak bir fonksiyon oluşturulmuştur. MATLAB®'da geliştirilen bu fonksiyon sayesinde, parçacığın bulunduğu konuma ait koordinat bilgileri, parçacığın hareket yönünün bilgisi, hareket eden parçacığın istenen iki noktası arasındaki Öklid uzaklığı, hareket açısı ve hızı bulunmakta ve bunlar bir MS Excel dosyasına fonksiyon tarafından kaydedilmektedir. Akışlarda, akışların üst kısmı genellikle daha hızlı akarken, akışın alt kısımları daha yavaş akmaktadır. Çalışma kapsamında, akış içerisindeki parçacıklar seçilirken hızlı akan tabakalardan ve daha yavaş akan tabakalardan eşit oranda veri toplanmaya çalışılmıştır.

Matlab yardımı ile geliştirilmiş olan fonksiyon çalıştırıldığında, ilk önce kullanıcının iki çerçeveyi seçmesini beklemektedir. Çerçeveler seçilirken aralarındaki çerçeve farkının 1 olmasına dikkat edilerek seçilmiştir. Yani ilk çerçeve seçildikten sonra, ikinci çerçeve hemen arkasından gelen çerçeve olmuştur. Böylece, çerçeve farkı

sabitlenmiş ve tahminlerin daha sağlıklı yapılabilmesi sağlanmıştır. Çerçeveseler seçildikten sonra, ilk çerçeve fonksiyon tarafından otomatik olarak açılmakta ve bizden o çerçeve içerisindeki parçacıklardan bir tanesini seçmemizi beklemektedir. Seçimimizi yaparak istediğimiz parçacığın üzerine tıkladığımızda, fonksiyon tıkladığımız parçacığa ait konum bilgilerini  $(X_1, Y_1)$  otomatik olarak almaktadır. Hemen sonrasında, seçilen ikinci çerçeve fonksiyon tarafından açılmaktadır. Bir önceki çerçevede tıklanan parçacık, bu çerçevede de bulunarak tıklanması beklenmektedir. Böylece parçacığın, ilk çerçeveden sonra hareket ederek bir sonraki çerçevede nereye geldiği tespit edilmeye çalışılmaktadır. İkinci çerçevede istenen parçacık bulunup tıklandıktan sonra, yine aynı şekilde parçacığa ait konum bilgileri  $(X_2, Y_2)$  fonksiyon tarafından kaydedilmektedir. Test bölümünün 15 derece açılı, RPM, ROP,  $V_{SL}$  ve  $Q_G$  değerlerinin sırasıyla 0, 80, 2 ve 100 olduğu durumda, deneyler sonucunda elde edilmiş ve çerçeve farkı 1 olan iki çerçeve Şekil 4.1 ve Şekil 4.2’de verilmiştir. Şekil 4.1’ de verilen kırmızı yuvarlak içerisinde alınmış parçacık, Şekil 4.2’ de kırmızı yuvarlak içine alınmış konuma hareket etmiştir.



Şekil 4.1 : Artarda Gelen İki Çerçeveden İlki



Şekil 4.2 : Artarda Gelen İki Çerçeveden İkincisi

Şekil 4.1’ de kırmızı yuvarlak içerisinde verilen parçacığa tıkladığında, parçacığın konumunu veren  $X_1, Y_1$  koordinatları elde edilirken, Şekil 4.2’ de parçacığın bir sonraki konumunu gösteren kırmızı yuvarlak içerisindeki parçacığa tıklanıldığında ise parçacığın yeni konumunu veren  $X_2, Y_2$  koordinatları elde edilmektedir. Matlab fonksiyonu bu koordinatları elde ettikten sonra, Şekil 4.3’ te gösterilen ekran çıktısını kullanıcıya sunmaktadır. Burada ilk resim ve ikinci resim için gösterilmiş olan x, y koordinatları yukarıda bahsedilmiş olan  $X_1, Y_1$  ve  $X_2, Y_2$  koordinatlarıdır.



Şekil 4.3 : Matlab Fonksiyonunun Sonuç Gösterimi

Şekil 4.3’ te uzaklık olarak gösterilen değer, Öklid uzaklığının değeridir. Parçacığın yatay ve dikey olarak konumunu veren  $X_1, X_2$  ve  $Y_1, Y_2$  koordinatları kullanılarak denklem (4.1)’ de verilen eşitlik yardımı ile parçacığın iki çerçevedeki yerleri arasındaki dik uzaklık yani Öklid uzaklığı hesaplanmıştır. Öklid uzaklığının hesaplanmasının nedeni, parçacığın hız hesabı yapılırken kullanılıyor olmasıdır.

$$\text{Öklid Uzaklığı} = \sqrt{(X_2 - X_1)^2 + (Y_2 - Y_1)^2} \quad (4.1)$$

Şekil 4.3’ te çerçeve numaralarının farkının 1 olarak gösterildiği görülmektedir. Bu çalışmada, seçilen çerçeveler ardışık seçildiğinden çerçeve farkı sabit olarak hep 1 olacaktır. Şekil 4.3’ te derece olarak verilmiş olan değer hareketin açısal olarak yön değeridir. Yani parçacığın, yatayla yaptığı açı bilgisi neticesinde, hareket yönünü anlamaya yöneliktir. Bu değer hesaplanırken, denklem (4.2)’ deki gibi koordinatlar kullanılarak  $\tan \theta$  değeri hesaplanmıştır. Sonrasında bu değer arctanjant’ı alınmış

ve radyan cinsinden  $\theta$  değeri bulunmuştur. Bu değer de, derece cinsine çevrilmiş ve tüm tahminler derece cinsinden yapılmıştır.

$$\tan\theta = \frac{Y_2 - Y_1}{X_2 - X_1} \quad (4.2)$$

Şekil 4.3' te 0,34321 olarak hesaplanmış olan hız hesabında denklem (4.3)' te verilen eşitlik kullanılmıştır.

$$\text{Hız} = \text{Öklid Uzaklığı}((X_1, Y_1), (X_2, Y_2)) \times FNF \times SFS \quad (4.3)$$

Burada ÇNF, çerçeve numaralarının farkını; SÇS ise saniyedeki çerçeve sayısını temsil etmektedir. Burada hesaplanan hız piksel cinsindedir, bu yüzden bu değer metre/saniye cinsine çevrilmiş ve hız ile ilgili tüm tahminler metre/saniye cinsinden yapılmıştır. Şekil 4.3' teki ikinci kutucukta görülen sağ-aşağı yazısı ise parçacığın ilerlediği yönü göstermektedir. Burada bahsedilen yön, açısal yönden farklı olarak parçacığın ilerlediği yönü açısal olarak değil; doğu, batı veya kuzey gibi direk olarak vermektedir. Bu yönler ileriki bölümlerde daha ayrıntılı olarak anlatılacaktır. Sonuçta tüm değerler hesaplanmış ve bu değerler oluşturulmuş Matlab fonksiyonu tarafından, Ms Excel dokümanına Şekil 4.4' te görüldüğü gibi kaydedilmiştir. Bu doküman incelendiğinde, yön bilgisinin sağ-aşağı şeklinde değil, 2 olarak kaydedildiği görülmektedir. Çünkü yönler bu çalışma için sayılarla ilişkilendirilmiş, bu durum da ileriki bölümlerde ayrıntılı olarak anlatılacaktır. Şekilde 4.4' te gösterildiği gibi kaydedilmiş verileri içeren Excel dosyaları, bu çalışmadaki tüm tahmin ve sınıflandırma işlemlerinde veri kümesi olarak kullanılmıştır.

1	Frame1	Frame2	RPM	ROP	VSL	QG	X1	Y1	X2	Y2	Uzaklik	FrameFarki	Yön	Açı	Hız
2	44	45	0	80	2	100	565	117	581	125	17,88854	1	2	26,56505	0,34321

**Şekil 4.4 :** Verilerin Kaydedildiği Excel Tablosundan bir Satır Örneği

## **5. KULLANILAN TEKNİKLER**

### **5.1 Yapay Zekâ ve Yapay Sinir Ağlarının Doğuşu**

Yapay zekâ; insanın düşünme, bilgi edinme, algılama, karar verme gibi özelliklerinin bilgisayara aktarılmasıdır. Yapay zekâ konusundaki ilk çalışmalar Warren McCulloch ve Walter Pitts tarafından 1943 yılında yapılmıştır [34]. Yaptıkları bu çalışmada, yapay sinir hücrelerini kullanan bir hesaplama modeli ile insana özgü öğrenme becerisinin bilgisayarlara kazandırılabilceğini savunmuşlardır. Böylece yapay zekâ tekniklerinden birisi olan yapay sinir ağları (YSA) fikri ortaya çıkmıştır. 1943 yılında başlayan çalışmalar uzun süre devam etmiş ve 1985 yılında çalışmalar yoğunlaşmış ve YSA'lar iyice tanınmaya başlamıştır [35].

#### **5.1.1 Yapay Sinir Ağlarının Tanımı ve Yapay Sinir Ağlarına Genel Bakış**

Yapay zekâ çalışmaları kapsamında ilgilenilen teknolojilerden bir tanesinin de yapay sinir ağları olduğundan bahsetmiştik. Yapay sinir ağları, biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan ve biyolojik sinir ağlarına benzer çeşitli performans özellikleri içeren bir bilgi işleme sistemidir [35]. Yapay sinir ağları öğrenebilen sistemlerin temelini oluşturmaktadır. Yapay sinir ağları, insan beyninin çalışma yapısını taklit etmektedir, yani basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır diyebiliriz. İnsanoğlu nasıl ki yaşayarak öğrenir ve öğrendikleriyle kararlar verir, YSA'lar da kendisine gönderilen girdi verileri ile öğrenir ve öğrendikleri ile kararlar verir. Yani, YSA'lar normalde bir insanın öğrenme, düşünme, hatırlama ve gözlemlene ihtiyacı duyduğu problemlere çözüm üretmektedir.

Bilim adamları, insan sinir sisteminin davranışlarını kopyalayabilmek için yapısının da kopyalanması gerektiğini düşünmüşlerdir. Bu yüzden de yapay sinir ağları modeli çıkarılırken, biyolojik sinir sisteminin yapısı göz önüne alınmıştır [36]. Bir YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanması ile oluşmakta ve öğrenme algoritması yardımı ile öğrenme işlemini gerçekleştirmektedir. Yapay sinir ağı öğrenme algoritmalarından birini kullanarak öğrenme sürecini tamamladığı

zaman çalışmaya hazır hale gelmiş olmaktadır. Çalıştığı sürece de kendisine verilen bilgiler ile öğrenmeye devam etmekte ve böylece daha sonraki girdiler için daha sağlıklı kararlar verebilmektedir.

### **5.1.2 Biyolojik Sinir Sistemi**

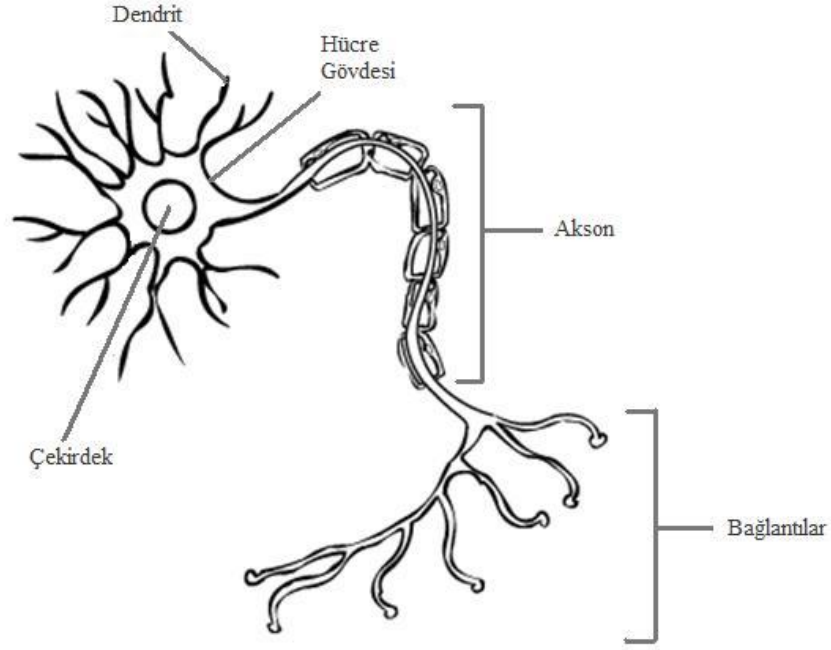
Yapay sinir ağlarının yapısı, biyolojik sinir ağlarından esinlenerek ortaya çıktığı için, YSA' ların çalışma mantığını daha iyi anlayabilmek için biyolojik sinir sisteminin yapısına bakmak gereklidir.

Biyolojik sinir sistemi; alıcı sinirler, tepki sinirleri ve merkezi sinir ağı olmak üzere üç katmanlı bir yapıya sahiptir. Alıcı sinirler çevreden gelen girdileri elektrik sinyaline çevirerek beyne iletir. Tepki sinirleri beyinden gelen elektrik sinyallerine göre bir tepki oluşturur. Merkezi sinir sistemi ise alıcı sinirler ile tepki sinirleri arasında ileri ve geri besleme yapar [35].

Biyolojik sinir sistemi, beynimizdeki çok sayıda sinir hücresinin birleşmesinden oluşmuştur. Sinir hücreleri nöron olarak bilinmektedir. Biyolojik sinir hücresinin (nöronların) yapısı aşağıdaki başlık altında incelenecektir.

### **5.1.3 Biyolojik Sinir Hücresinin Yapısı**

Biyolojik sinir sisteminin temel yapıtaşı sinir hücreleri yani nöronlardır. Nöron, temel prensibi elektrik sinyallerinin toplanma, işleme ve dağıtılması olan beynin bir hücresidir [37]. Tipik bir nöronun şematik diyagramının verildiği Şekil 5.1' den de görüleceği gibi biyolojik sinir sisteminin temel yapıtaşı olan nöronlar, dendritler (dendrites), akson (axon), hücre gövdesi (soma) ve bağlantılar (synapses) olmak üzere 4 kısımdan oluşmuştur [36].



Şekil 5.1 : Biyolojik Sinir Hücresinin Yapısı[38]

Sinir hücresinin ucunda bulunan dendritler, başka hücrelerden gelen uyarıları alarak çekirdeğe iletirler. Hücre gövdesi, hücrenin yaşaması için gerekli işlevleri yerine getirir ve hücre çekirdeğini (nucleus) içerir. Çekirdek, dendritlerden gelen uyarıları bir araya getirir ve akson'a iletir. Akson, toplanan bu sinyalleri işleyerek nöronun diğer ucunda bulunan bağlantılara gönderir. Bağlantılar da, yeni üretilen sinyalleri diğer nöronlara iletirler.

#### 5.1.4 Biyolojik Sinir Ağlarının Yapısı

Biyolojik sinir ağları, insan beynindeki çok sayıda sinir hücresinin birleşmesiyle oluşur ve insan beyninin çalışmasını sağlayan temel taşlardır. Biyolojik sinir ağları girdi bilgilerini beş duyu organından alır ve gelen bilgiler ışığında algılama mekanizmalarını çalıştırarak olaylar arasındaki ilişkileri öğrenir.




### 5.1.5 Yapay Sinir Hücresinin Yapısı

Biyolojik sinir sisteminin temel yapıtaşının sinir hücreleri yani nöronlar olduğundan daha önce bahsetmiştik. Biyolojik sinir sistemini örnek alan YSA' ların yapıtaşı da yapay nöronlar olmuştur. Yani yapay sinir ağlarının en temel ve en küçük bilgi işleme birimi yapay nöronlardır. Yapay sinir hücresi, yapay nöronların kendi aralarında bağ kurmasından oluşmuştur. Bir yapay sinir hücresi; “girdiler”, “ağırlıklar”, “birleştirme fonksiyonu”, “aktivasyon (transfer) fonksiyonu” ve “çıktılardan” oluşmaktadır [35]. Yapay nöronlara diğer hücrelerden veya dış dünyadan gelen veriler girdi olarak adlandırılmaktadır. Girdiler nöron çekirdeğine gönderilirler ve çekirdeğe gönderilen girdiler, çekirdeğe ulaşmadan geldikleri bağlantıların ağırlıkları ile çarpılıp o şekilde çekirdeğe iletilirler. Girdilerin hücre üzerindeki etkileri de bu ağırlıklar tarafından belirlenir. Bağlantıların ağırlıkları ile çarpılan bu girdiler, birleştirme fonksiyonu sayesinde toplanır ve denklem (5.1)' de verilen eşitlik ile net girdi hesaplanır.


$$Net\_Toplam = \sum_i^n x_i w_i \quad (5.1)$$

Birleştirme fonksiyonu, ağın yapısına göre değişiklik gösterebilir. Hesaplanan net girdi aktivasyon fonksiyonuna iletilir. İletilen bu girdi, aktivasyon fonksiyonu tarafından işlenir ve böylece hücrenin giriş değerine göre çıktısı belirlenir. Aktivasyon fonksiyonu işleminden önce, sisteme bir hata terimi eklenebilmektedir. Şekil 5.2' de bir yapay sinir hücresinin grafiksel gösterimi verilmiştir. Denklem (5.1)' de hesaplanan Net\_Toplam değeri, Şekil 5.2' de “v” olarak gösterilmiştir.



Şekil 5.2 : Bir Yapay Sinir Hücresinin Detaylı Grafik Gösterimi [39]

Hücresinin gerçekleştireceği işleve göre çeşitli aktivasyon fonksiyonları kullanılabilir. En uygun fonksiyon ise denemeler yapılarak bulunur. Aktivasyon fonksiyonu olarak genellikle doğrusal, sigmoid ve hiperbolik tanjant fonksiyonları sık sık kullanılır [40]. Sigmoid fonksiyonunu kullanan bir aktivasyon fonksiyonunun çalışma yapısı, Şekil 5.3’ te gösterilmiştir. Sigmoid fonksiyonu, birleştirme fonksiyonundan gelen ve şekilde “v” olarak gösterilen değeri alır. (Burada birleştirme fonksiyonu olarak toplama fonksiyonu kullanılmıştır). Bu değer, sigmoid fonksiyonu tarafından 0 ile 1 arasında bir değere dönüştürülerek aktivasyon fonksiyonunun çıktısı oluşturulmuş olur.



Şekil 5.3 : Sigmoid Fonksiyonunu Kullanan Bir Aktivasyon Fonksiyonunun Çalışma Yapısı [40]

Aktivasyon fonksiyonları nöronun çıkış genliğini genellikle  $[0,1]$  ve  $[-1,1]$  olmak üzere istenilen değerler arasında sınırlandırılır [35]. En çok kullanılan aktivasyon fonksiyonlarını inceleyelim:

## 1. Doğrusal Aktivasyon Fonksiyonu


Doğrusal bir problemi çözmek için kullanılır ve hücrenin net girdisi ne ise hücre çıkışı olarak da onu verir. Doğrusal bir aktivasyon fonksiyonu;

$$v = \sum_i^n x_i w_i \text{ veya } v = \sum_i^n x_i w_i + \theta \quad (5.2)$$

olmak üzere,

$$y = Av \quad (5.3)$$

olarak tanımlanabilir. Burada A, sabit bir katsayıdır. Şekil 5.4 ile doğrusal aktivasyon fonksiyonuna ait grafik gösterimi verilmiştir.



Şekil 5.4 : Doğrusal Aktivasyon Fonksiyonunun Grafik Gösterimi [41]


## 2. Sigmoid Aktivasyon Fonksiyonu

Bu fonksiyon doğrusal olmadığı için oldukça yaygın olarak kullanılmaktadır. Çünkü doğrusal fonksiyonlarda girdi ile çıktı orantılıdır bu da yapay sinir ağlarının başarısızlıkla sonuçlanmalarının nedenidir. Sigmoid fonksiyonu sürekli, doğrusal olmayan ve türevi alınabilir bir fonksiyondur [35]. Sigmoid aktivasyon fonksiyonu, birleştirme fonksiyonundan gelen değeri alır ve bu değeri 0 ile 1 arasında bir değere

dönüştürür. Dönüştürülen bu değer aktivasyon fonksiyonunun çıktısı olur ve girdi olarak başka bir nörona iletilir. Sigmoid fonksiyonu genellikle;

$$y = \frac{1}{1 + e^{-v}} \quad (5.4)$$

fonksiyonunu kullanır. Şekil 5.5 ile sigmoid aktivasyon fonksiyonuna ait grafik gösterimi verilmiştir.




Şekil 5.5 : Sigmoid Aktivasyon Fonksiyonunun Grafik Gösterimi [41]

### 3. Tanjant Hiperbolik Aktivasyon Fonksiyonu

Tanjant hiperbolik fonksiyonu, sigmoid aktivasyon fonksiyonuna benzemektedir. Sigmoid fonksiyonunun, girdinin her bir değeri için 0 ile 1 arasında bir çıktı ürettiğinden bahsetmiştik. Tanjant hiperbolik fonksiyonunun çıktı aralığı ise -1 ve 1 aralığındadır [35]. Tanjant hiperbolik fonksiyonu;

$$y = \frac{1 - e^{-2v}}{1 + e^{2v}} \quad (5.5)$$

denklemleri ile ifade edilebilir. Tanjant hiperbolik fonksiyonuna ait grafik gösterimi Şekil 5.6 verilmiştir.




Şekil 5.6 : Tanjant Hiperbolik Aktivasyon Fonksiyonunun Grafik Gösterimi [41]

### 5.1.6 Yapay Sinir Ağlarının Yapısı

Sinir hücreleri grup halinde iken binlerce nöron içerirler ve bu şekilde grup halinde işlem yaptıklarında bir ağ oluşturmuş olurlar. Yapay nöronlar da bağlantılar ile birbirlerine bağlanarak bir ağ oluşturmuş olurlar. Yani yapay sinir ağları, biyolojik sinir ağlarını örnek alarak oluşturulmuşlardır. Nöronlar aynı doğrultuda dizilerek katmanlar oluştururlar. Yapay sinir ağları da, giriş katmanı, gizli katman (ara katman) ve çıkış katmanı olmak üzere 3 katmandan oluşmaktadır [36]. Katmanlı bir yapıya sahip olan yapay sinir ağlarının yapısının basit bir gösterimi Şekil 5.7' de verilmiştir.

Giriş katmanı, adından da anlaşılacağı gibi dış dünyadan gelen girdilerin alındığı katmandır. Gelen girdiler bu katmandan diğer katmanlara iletilirler. Gizli katman, giriş katmanından çıkan bilgilerin geldiği katmandır. Bu katmanda girdi katmanından gelen bilgiler işlenir ve çıktı katmanına gönderilir. Bir yapay sinir ağında gizli katman bulunmak zorunda olmadığı gibi birden fazla gizli katman da olabilir. Ancak gizli katmanı olmayan yapay sinir ağları karmaşık işlevleri hesaplayamazlar. Bu yüzden, eğer karmaşık hesaplar yapılacaksa bir veya daha fazla gizli katman bulunmalıdır. Çıkış katmanı ise, gizli katmandan gelen verileri alıp işleyen ve giriş katmanından gelen verilere karşılık çıktıları üreten katmandır.



**Şekil 5.7 :** Yapay Sinir Ağlarının Yapısının Basit Gösterimi

### 5.1.7 Yapay Sinir Ağlarının Uygulama Alanları

Yapay sinir ağları çözümü zor olan karmaşık problemlerin çözümü için uygulanmıştır. YSA'lar özellikle öğrenme, sınıflandırma, regresyon, tahmin, eniyileştirme gibi konularda uygulanmış ve başarılı sonuçlar alınmıştır.

Yapay sinir ağları istatistik, ekonomi, tıp, mühendislik gibi birçok alanda kullanılmaktadır. Yapay sinir ağlarının gerçek hayatta ayrıca, kalite kontrol, petrol ve gaz arama, finansal öngörü, laboratuvar araştırmaları, iflas tahmini gibi konularda da başarılı olarak kullanıldığı yapılan çalışmalardan görülmektedir [40].

### 5.1.8 Yapay Sinir Ağlarının Üstünlükleri

YSA'ların biyolojik sinir ağlarının çalışmasını taklit etmeleri, bu YSA'ların biyolojik sinir sisteminin özelliklerine de sahip olmalarını sağlamıştır. Bu özelliklerden bazıları;

- doğrusal olmama,
- paralellik,
- öğrenebilirlik,

- genelleme
- uyarlanabilirlik

olarak sayılabilir [35].

Örneğin, YSA'ların doğrusal olmama özelliği sayesinde, doğrusal olmayan zor problemlerin çözümünde YSA' lar kullanılabilmiştir. YSA sisteminin paralel olması, seri işlem yapan bilgi işleme sistemlerine göre hız konusunda avantaj sağlamıştır. YSA' ların en önemli özelliklerinden bir tanesi yukarıda da bahsettiğimiz gibi öğrenilebilirlik. YSA'lar bu özelliklerinden dolayı tam tanımlı olmayan problemlerin çözümlerinde kullanılabilirler. YSA, probleme ait eğitim verilerini kullanarak problemi öğrenir ve öğrenme sonucunda istenilen davranışları sergiler. YSA bu problemde öğrendikleri dışında, karşılaşmamış olduğu test örnekleri için de genelleme özelliği sayesinde beklenen tepkiyi verir. YSA'lar ayrıca uyarlanabilirlik özelliği sayesinde problemdeki değişikliklere göre ağırlıklarını ayarlar ve değişikliğe uğramış problem için uygun hale gelir.

### **5.1.9 Yapay Sinir Ağlarının Çalışma Yapısı**

Daha önce de bahsettiğimiz gibi yapay sinir ağlarının en önemli özelliği öğrenme yeteneğine sahip olmalarıdır. Biyolojik sinir sistemlerinde öğrenme, nöronlar arasındaki sinaptik bağlantılar ile olur. İnsanlar doğdukları andan itibaren, yaşayarak öğrenmeye başlarlar, böylece beyin sürekli bir gelişme içerisinde olur. İnsanlar yaşadıklarından tecrübe elde etmeye başladıkça, nöronlar arasındaki sinaptik bağlantılar ayarlanır, yeni bağlantılar oluşur, böylece öğrenme gerçekleşir. YSA'larda da öğrenme benzer şekilde gerçekleşmektedir. Oluşturulan YSA, verilen öğretim verileri ile eğitilir. Yani eğitim algoritması işlenen girdi/çıkış verilerini kullanarak bağlantı ağırlıklarını bir yakınsama sağlanana kadar tekrar tekrar ayarlayarak öğrenmenin gerçekleştirilmesini sağlar. Eğitilmiş olan YSA, problemde değişiklikler olursa tekrar tekrar eğitebilir. Sonuçta YSA değişiklikleri de değerlendirerek öğrenme işlemini tamamladıktan sonra, buna uygun bir çıktı üretir.

Özetle çalışma mantığını anlatmak istersek; giriş katmanına gelen girdiler giriş katmanı ile gizli katman arasındaki bağlantı ağırlıkları ile çarpılır ve gizli katmana gönderilir. Gizli katmana gelen girdiler, bu seferde gizli katman ile çıkış katmanı arasındaki bağlantı ağırlıkları ile çarpılır. En son ise, çarpılan değerler toplanarak tek bir çıkış üretilir.

Bilgi tüm ağda bağlantı ağırlıklarında saklandığı için, tüm ağdaki ağırlıkların ve bağlantıların nasıl belirleneceği önemlidir. Ancak, yapay sinir ağlarında başlangıçta en uygun ağırlıkların nasıl belirleneceğinin ve yeni bağlantıların yapılıp yapılmamasına nasıl karar verileceğinin de bir yöntemi veya formülü yoktur. Uygun ağırlıkların ve bağlantıların belirlenebilmesi için, sistemin davranışlarını öğrenebilmesi ve buna göre kendisini güncelleyerek ağırlıkları belirlemesi gerekmektedir. Çünkü bağlantı ağırlıkları değiştirilerek öğrenme işlemi gerçekleştirilir ve ağırlıklar değişmiyorsa o sırada öğrenme işlemi de gerçekleşmiyordur demektir.

Ağırlıklar belirlenip, ağı eğitme işlemi bittikten sonra, ağı öğrenip öğrenmediğini ölçmek için ağ test edilir. Ağ test edilirken, ağı eğitimi sırasında kullanılmayan yani ağı görmediği veriler kullanılır. Ağa bu veriler verildikten sonra, ağ belirlediği en uygun ağırlık değerleri yardımı ile çıkışı üretir. Çıkışın ne kadar doğru olduğu, ağı ne kadar başarılı öğrendiği ile paraleldir. Test sonucunda çıkan değerler, olması beklenen sonuçların değeri ile karşılaştırılır ve böylece sağlıklı kararlar verip vermediği görülür. Kabul edilebilir ölçüde başarılı kararlar vermişse, o YSA modeli kullanılabilir.



### 5.1.10 Yapay Sinir Ağlarının Sınıflandırılması

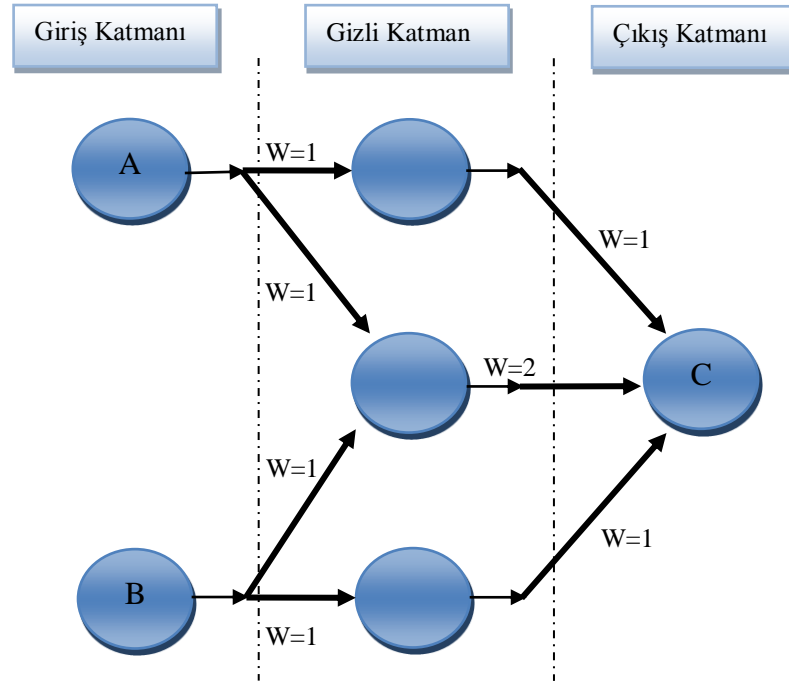
Yapay sinir ağları, yapıları ve öğrenme algoritmaları gibi çeşitli özelliklerine göre sınıflandırılmaktadırlar.

#### 1. Yapılarına Göre Yapay Sinir Ağları

Yapılarına göre yapay sinir ağları iki başlık altında incelenecektir.

##### i. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağlarda giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla bir iletim vardır. Yani sonraki katmandan alınan çıkışlar geriye giriş olarak gelmez, böylece işlem elemanları arasındaki bağlantılar bir döngü oluşturmazlar. Bu ağlar için, genellikle geri yayılım algoritması kullanılmaktadır. İleri beslemeli ağ gösterimi Şekil 5.8’ de verilmiştir.

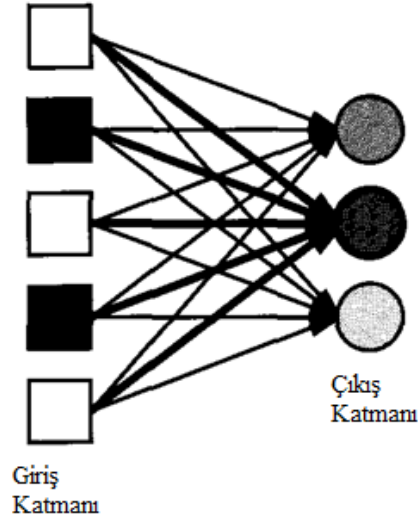


Şekil 5.8 : İleri Beslemeli Ağ Yapısı

Çok katmanlı perseptron (Multilayer Perceptron-MLP) ve LVQ (Learning Vector Quantization) ileri beslemeli ağlara örnek olarak verilebilir [35].

İleri beslemeli ağlar genellikle katmanlar halinde düzenlenmiştir ve bu ağlar katman sayısına göre 2' ye ayrılmaktadırlar.

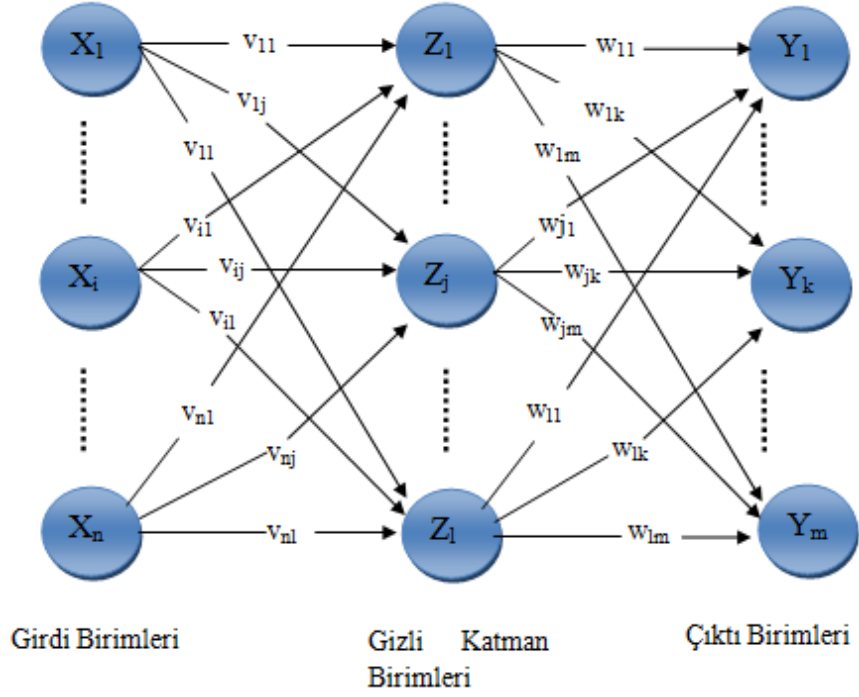
- Tek Katmanlı İleri Beslemeli Sinir Ağları (Perseptron): Bütün girişlerin direk olarak çıkışlara bağlandığı ağa “tek katmanlı sinir ağı” veya “perseptron ağı” denir. Her çıktı birimi diğerlerinden bağımsız olduğu için, her ağırlık çıktıların sadece birini etkiler. 5 tane girdiyi paylaşan 3 tane çıktı birimini içeren tek katmanlı bir ağ Şekil 5.9’ da verilmiştir.



Şekil 5.9 : 5 Girdi ve 3 Çıktı Birimi Olan Tek Katmanlı Ağ [37]

Şekilde belli bir çıktı birimine baktığımızda, gelen bağlantılar üzerindeki ağırlıkların diğer çıktı birimleri üzerinde bir etkisi olmadığı görülür.

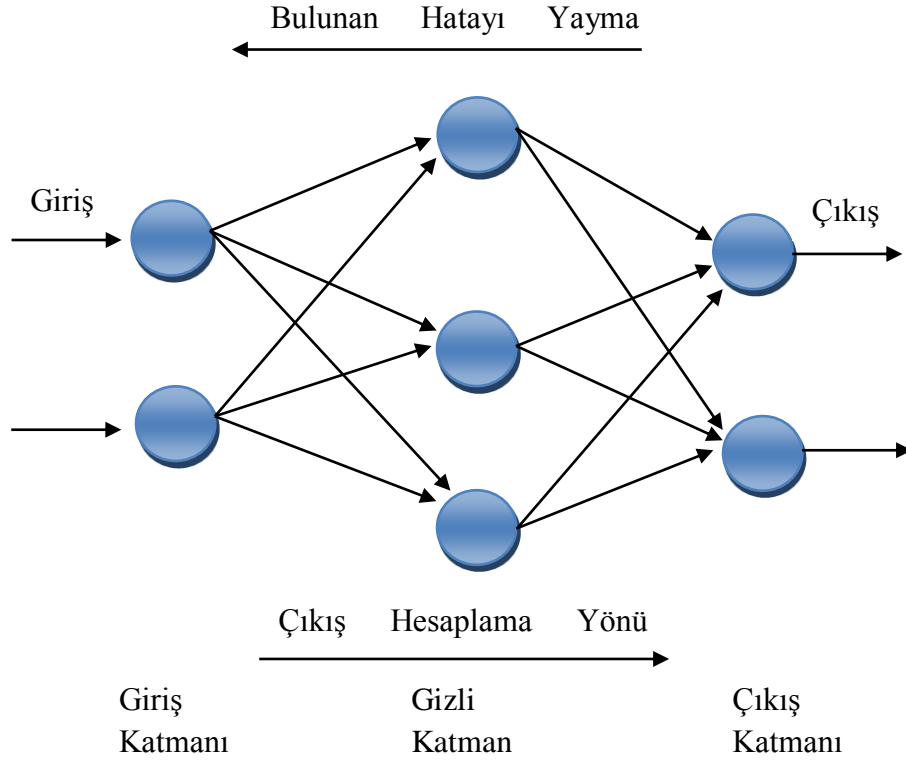
- Çok Katmanlı İleri Beslemeli Sinir Ağları: Bu tip ağlarda, ağların gizli katman sayıları dikkate alınacaktır. En yaygın olan durum, tek bir gizli katmanın olmasıdır. İki katmanlı ileri beslemeli ağ yapısı Şekil 5.10’ da görülmektedir. Gizli katman eklemenin avantajı, ağın temsil ettiği hipotez uzayının genişleyecek olmasıdır [37].



Şekil 5.10 : İki Katmanlı İleri Beslemeli Ağ Yapısı

## ii. Geri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağların aksine, katmanlar arasında tek yönlü değil çift yönlü bağlantılar vardır. Yani çıkış katmanından veya gizli katmanlardan alınan çıkışlar, bir önceki katmana giriş olarak gönderilebilir, böylece işlem elemanları arasındaki bağlantılar döngü oluştururlar. Bu döngü yüzünden, girdi karşılığında oluşturulacak olan çıktının oluşması zaman alır. Hopfield ve SOM (Self Organizing Map) bu tip ağlara örnek olarak verilebilir [35]. Geri beslemeli ağ yapısı Şekil 5.11’ de verilmiştir.



Şekil 5.11 : Geri Beslemeli Ağ Yapısı

Geri besleme, bir katmandaki hücrelerin arasında da, katmanlar arasındaki hücreler arasında da olabilir.

## 2. Öğrenme Algoritmalarına Göre Yapay Sinir Ağları


Öğrenme algoritmalarına göre yapay sinir ağları, üç başlık altında incelenecektir.

### i. Danışmanlı Öğrenme

Danışmanlı öğrenmede, yapay sinir ağı kullanılmaya başlanmadan önce eğitilmelidir. Bu tip YSA' larda eğitim yapılırken, hem giriş bilgileri hem de bu giriş bilgileri sonucunda çıkması gereken çıkış bilgileri sisteme verilir. Bağlantı ağırlıkları ayarlanarak ağın en uygun çıktıyı vermesi sağlanır. Bunun için de bir danışmana ihtiyaç vardır. Danışmanlı öğrenmenin bazı kuralları vardır. Bunlar [41]:

- Perceptron Öğrenme Kuralı
- Delta Öğrenme Kuralı

- Genişletilmiş Delta Öğrenme Kuralı
- Geri Yayılımlı (Back Propagation) Öğrenme Kuralı: Geri yayılımlı öğrenme kuralı en yaygın kullanılanlardan biridir. Çok katmanlı perseptron ile aynı yapıya sahiptir ve öğrenme yöntemi olarak geri yayılım algoritmasını kullanır. Bu yüzden, ileri beslemeli ve çok katmanlı bir ağ mimarisine gereksinim duyar. Geri yayılımlı öğrenme kuralını kullanan yapay sinir ağları, geriye doğru ağırlık ayarlamaları yapmaktadır. Bu yöntemi kullanan ağlar, giriş katmanı, çıkış katmanı ve en az bir tane olmak üzere gizli katmandan oluşurlar. Bir katmanda bulunan düğümlerden hiç biri birbiri ile bağlı değildir, ancak her biri, sonraki katmandaki her düğüme bağlıdır. Her katmandaki düğümlerin çıkışları ise, önceki katmana giriş olarak geri döner. Geri yayılımlı öğrenme kuralını kullanan bir ağın yapısı Şekil 5.12’ de verilmiştir. Gizli katmanda bulunan düğüm sayıları değişkendir. Düğüm sayısı ne kadar çok olursa ağın öğrenme süresi o kadar uzar ama hatırlama yeteneği artar.



Şekil 5.12 : Geri Yayılımlı Öğrenme Kuralını Kullanan Ağ Yapısı [41]

Şekil 5.12’ den de görüleceği gibi bu tip ağlarda iki türlü bağlantı vardır. Ağırlıkların yardımıyla girişlere karşı çıkışların üretildiği ileri yönlü bağlantılar ve elde edilen bu

çıkışlar ile olması gereken (gerçek) çıkışlar arasındaki hata değerinin geriye yayılmasını sağlayan geriye doğru bağlantılardır. Bu algoritma en çok kullanılan algoritmadır [36].

## **ii. Danışmansız Öğrenme**

Danışmansız öğrenmede, danışmanlı öğrenmenin aksine sadece giriş bilgileri verilir, olması gereken çıkış bilgileri verilmez. Hedeflenen bir çıkış bilgisi olmadığından ağırlık değerleri, giriş verileri arasındaki matematiksel ilişkilere göre ayarlanır. Bu öğrenmede ağ, sınıflandırma kuralların kendi kendine geliştirir. SOM danışmansız öğrenmeye örnek olarak verilebilir.

Danışmansız öğrenme kuralları şunlardır [41]:

- Karma Öğrenme Kuralı
- Yarışmacı Öğrenme Kuralı
- Yarışmacı Sinirsel Öğrenme Kuralı
- Özörgütlemeli Harita Ağı Kuralı

## **iii. Destekleyici Öğrenme**

Ağın her bir tekrarlama sonucu elde ettiği sonuçları iyi veya kötü olarak bildirimde bulunduğu bir öğrenme şeklidir. Geri bildirimde bulunduğu bu bilgilere göre ağ kendini yeniden düzenler.

## **3. Öğrenme Zamanına Göre Yapay Sinir Ağları**

Öğrenme zamanına göre yapay sinir ağları 2 başlık altında incelenecektir.

### **i. Statik Öğrenme**

Bu öğrenme kuralını kullanan ağlar ilk önce eğitilmeli, daha sonra kullanılmalıdır. Bu ağların kullanımı sırasında bağlantı ağırlıklarında herhangi bir değişiklik olmaz.

## ii. Dinamik Öğrenme

Bu öğrenme kuralını kullanan ağlar, çalıştığı süre boyunca öğrenme işlemine devam ederler.

Çok fazla çeşitleri bulunan yapay sinir ağları modellerinden en bilinenleri, MLP (Multilayer Perceptron), RBF (Radial Basis Function), LVQ (Learning Vector Quantization), Hopfield, Recurrent, SOM (Self-Organizing Map), ART (Adaptive Resonance Theory) olarak sayılabilir [40].

Tez kapsamında, yapay sinir ağı modeli oluşturulurken ileri beslemeli (feed forward) ağ yapısından ve geri yayılım (back propagation) algoritmasından yararlanılmıştır.

## 5.2 Regresyon Analizi

Regresyon analizi değişkenler arasındaki ilişkiyi tahmin edebilmek için kullanılan istatistiksel bir tekniktir. Bağlı ve bağımsız değişkenler arasındaki ilişkiye odaklanıldığında modelleme ve analiz için birçok teknik mevcuttur. Regresyon analizi özellikle bağlı değişkenin değerinin bağımsız değişkenlerden herhangi birinin değiştirilip diğerlerinin sabit tutulmasıyla nasıl değişeceğini anlaşılmasında kullanılmaktadır. Regresyon analizindeki tahmin hedefi bağımsız değişkenlerin bir fonksiyonudur ve regresyon fonksiyonu olarak adlandırılır.

Regresyon modelleri genellikle yeterli veri setine sahip olunmayan durumlarda, gerçekleştirilen testlerin dışındaki herhangi bir bağımsız değişken değerinde, zaman gibi, bağımlı değişken değerini elde etmek için kullanılırlar.

Regresyon modelinde aşağıdaki değişkenler mevcuttur:

- Bilinmeyen parametreler,  $\beta$  olarak tanımlanmıştır.
- Bağımsız değişkenler,  $X$ .
- Bağlı değişkenler,  $Y$ .

Bir regresyon modeli  $X$  ve  $\beta$ 'nin bir fonksiyonu olarak  $Y$  deęeri bulunur.

$$Y \approx f(x, \beta) \quad (5.6)$$

Bu şekilde belirlenen fonksiyon ile baęımlı deęiřkenin yaklařık deęerleri bulunmuř olur. Regresyon analizini gerekleřtirebilmek iin  $f$  fonksiyonunun hangi formda olacaęı belirlenmelidir. Bu fonksiyon doęrusal veya doęrusal olmayan bir şekilde seilebilir ve buna gre de regresyon modeli doęrusal regresyon ve doęrusal olmayan regresyon olarak adlandırılır. Bunun dıřında daha modern yntemler olarak yapay sinir aęları ve destek vektr makineleri da regresyon analizi iin kullanılmaktadır.

### 5.2.1 Doęrusal (Linear) Regresyon

Doęrusal regresyon baęımsız deęiřken sayısına gre ikiye ayrılır. Bir tane baęımsız deęiřken olması durumunda basit doęrusal regresyon, birden fazla baęımsız deęiřken olması durumunda ise oklu doęrusal regresyon olarak adlandırılır.

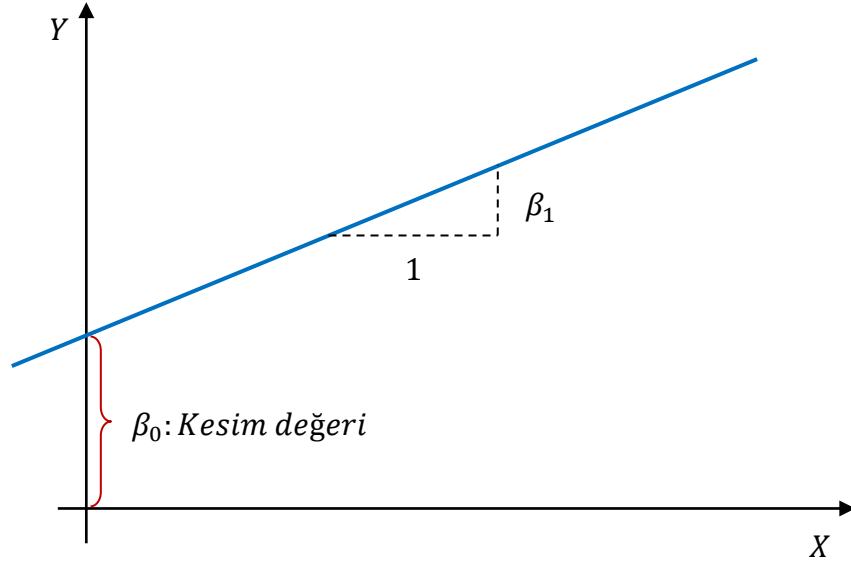
Doęrusal regresyonda veriler, doęrusal ngr fonksiyonları ile modellenir ve bilinmeyen model parametreleri de eldeki veriler kullanılarak hesaplanır. Bu tr modeller de doęrusal regresyon modelleri olarak adlandırılır.

Birok pratik uygulamada doęrusal regresyon modelleri sıklıkla kullanılmaktadır. Bunun nedeni parametrelerine doęrusal olarak baęlı modellerin bulunması, parametreleri ile doęrusal olmayan bir baęıntısı olan modellerin bulunmasından daha kolay olmasıdır. Doęrusal regresyon modellerinde bilinmeyen parametrelerin bulunması genellikle en kk kareler yntemi ile yapılmaktadır. Sadelik aısından tek baęımsız deęiřkene sahip bir basit regresyon modelini ele alalım;

$$Y \approx f(x, \beta) = \beta_0 + \beta_1 x \quad (5.7)$$


Denklem (5.7) ile gsterilen doęrusal ngr fonksiyonu bir tane baęımsız deęiřkene sahiptir. Burada  $\beta_0$  deęeri kesim deęeri olarak adlandırılır ve  $x$  deęiřkeninin sıfır olduęu durumdaki  $Y$ ' nin deęerine eřittir.  $\beta_1$  deęeri de doęrunun eęim deęeridir. Basit doęrusal regresyon modelinin grafiksel gsterimi Őekil 5.13' te verilmiřtir.





Şekil 5.13 : Basit Doğrusal Regresyon Modeli ( $Y = \beta_0 + \beta_1x$ )

$\beta_0$  ve  $\beta_1$  değerlerini değiştirmek suretiyle sonsuz sayıda doğru elde etmek mümkündür. Birçok uygulamada bu değerler bilinmemektedir ve eldeki veriler kullanılarak bulunmalıdır. Doğrusal regresyonda amaç  $Y$  değerinin  $x$  değerine bağlı değişiminin bulunması için basit bir doğru ile yaklaşım sağlamaktır.



Şekil 5.14 : Farklı Kesim ve Eğim Değerlerine Sahip Doğrusal Regresyon Modelleri

Şekil 5.14' te 'o' ile gösterilen değerler  $X$  değerlerine karşılık ölçülen  $Y$  değerleridir. Bu değerleri en iyi modelleyecek doğrunun bulunması için denklem (5.7)' de

gösterilen iki parametrenin  $\beta_0$  ve  $\beta_1$  uygun bir şekilde seçilmesi gerekmektedir. Bu yöntemlerden birisi en küçük kareler yöntemidir. En küçük kareler yöntemi, gerçek veriler ile oluşturulan fonksiyondan elde edilen değerlerin farkından hesaplanan hata miktarlarının karelerinin toplamının en küçükleştirilmesi prensibine dayanmaktadır. En küçük kareler yöntemi en uygun sonucu,

$$S = \sum_{i=1}^n r_i^2 \quad (5.8)$$

fonksiyonunun en küçük olduğu durumda bulur. Burada  $r_i$  değerleri kalıntı (residual) olarak adlandırılır ve gerçek değer ile hesaplanan değer arasındaki fark olarak hesaplanır:

$$r_i = y_i - f(x_i, \beta) \quad (5.9)$$

Denklem (5.7) ile verilen model için hesaplanan fonksiyon iki boyutlu uzayda bir doğruyu tanımlamaktadır. Tez kapsamında kullanılan veriler birden fazla bağımsız değişkene bağlıdır ve regresyon modeli daha genel bir biçimde tanımlanmalıdır. Veri setinde n adet veri olsun,  $\{y_i, x_{i1}, \dots, x_{im}\}_{i=1}^n$ . Bağımlı değişken  $y_i$  ile  $x_i$  arasındaki doğrusal bağıntı,

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_m x_{im} + \epsilon_i \quad , \quad i = 1 \dots n \quad (5.10)$$

şeklinde, bozucu terim  $\epsilon_i$  kullanılarak ifade edilebilir. Vektör formatında,

$$y_i = x_i^T \beta + \epsilon_i \quad , \quad i = 1 \dots n \quad (5.11)$$

şeklinde yazılabilir.

Her bir veri noktası için n adet denklem birleştirilirse;


$$Y = X\beta + \epsilon \quad (5.12)$$

formunda yazılır. Burada,

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, X = \begin{bmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_n^T \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix}, \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \end{bmatrix}, \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}. \quad (5.13)$$

Bu şekilde, tek bağımsız değişkene bağlı bir model bir doğru tanımlarken, iki bağımsız değişkene bağlı bir model bir düzlem ifade eder. Aynı şekilde, n adet bağımsız değişken n+1 boyutta bir düzlem ifade etmektedir.


Doğrusal regresyon modelleri bir doğru ile modellenebilecek sistemler için yaklaşık değer hesaplamalarında kullanılabilir en hızlı yöntemlerden birisidir. Şekil 5.15'te doğrusal veri setlerinde doğrusal regresyon modellerinin uygulanabilirliği gösterilmiştir.



Şekil 5.15 : Doğrusal Regresyon Model Örnekleri

Şekil 5.15' te gösterildiği üzere doğrusal veri setleri için doğrusal regresyon modelleri yaklaşık sonuçlar verebilmektedirler. Doğrusal fonksiyon modelleri her bir veri değerine en yakın geçecek şekilde en küçük kareler yöntemi kullanılarak

belirlenmiştir. Ancak veri setinin doğrusal olmadığı durumlarda doğrusal regresyon modelleri Şekil 5.16’ da gösterildiği gibi doğruluktan uzaklaşmaktadırlar.



Şekil 5.16 : Doğrusal Olmayan Veri Seti İçin Doğrusal Regresyon Modeli

Bu tipte bir veri seti için doğrusal regresyon modellerinin kullanılması büyük hatalara yol açabilmektedir. Örneğin,  $x=2$  bölgesi civarında doğrusal regresyon modeli yakın sonuçlar verebilirken  $x=3$  bölgesinde olması gereken değerden çok farklı sonuçlar elde edilecektir. Sonuç olarak gerek gözlemlenen bölge içerisinde gerekse de gözlemlenen bölgenin dışındaki başka bir nokta için değer tahmini yapılması durumunda doğrusal regresyon modellerinin güvenilirliği, doğrusal olmayan veri setleri için azalmaktadır.

### 5.2.2 Doğrusal Olmayan (Nonlinear) Regresyon

Doğrusal regresyon modellerinde belirlenen fonksiyonlar belirsiz parametreleri ile doğrusal bir bağıntı içerisinde bulunmaktadır. Ancak birçok durumda gözlemlenen veriler doğrusal bir karakteristik göstermezler ve doğrusal regresyondaki gibi bir doğru ile modellenemezler. Bu gibi durumlarda doğrusal olmayan regresyon modelleri kullanılmaktadır. Doğrusal olmayan regresyonun temel prensibi doğrusal regresyon ile aynıdır, yani sonuç değişkeni Y ile bağımsız değişken X arasındaki bağıntıyı bulmaktır.

Doğrusal olmayan regresyon adından da anlaşılacağı gibi belirsiz parametrelerden birine veya birkaçına doğrusal olmayan bir şekilde bağlıdır. Bir doğrusal olmayan regresyon modeli;

$$Y_i \approx f(x_i, \beta) + \epsilon_i, \quad i = 1, \dots, n \quad (5.14)$$

formundadır. Burada,  $Y_i$  bağımlı değişken veya sonuç değişkeni,  $f$  ise bağımsız değişken  $x_i$  ve belirsiz parametrelerin bir fonksiyonudur.  $\epsilon_i$  değeri ise rastgele belirlenen hata değeri, gürültü veya bozucu etki olarak eklenmiştir.

Bilinmeyen parametreler vektörü  $\beta$ , eldeki veriler kullanılarak uygun bir hata fonksiyonunu enküçükleştirme ile elde eder.

Doğrusal olmayan regresyon modelinin tanımı, bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişkiye değil, belirsiz parametreler ile olan ilişkisine dayanmaktadır. Örneğin ikinci dereceden (quadratic) bir regresyon modeli;

$$Y = \beta_0 + \beta_1 x + \beta_2 x^2 \quad (5.15)$$

doğrusal olarak ele alınabilir.  $x_1 = x$  ve  $x_2 = x^2$  değişken değişimi yapılırsa problem bir doğrusal regresyon problemine dönüşür ve belirsiz  $\beta_i$  parametreleri doğrusal regresyon metodu ile hesaplanabilir.

Doğrusal olmayan regresyonda karşılaşılan en büyük zorluk uygun bir fonksiyonun belirlenmesidir. Modelleneyecek veri hakkında çok fazla bilgi olmadığı durumlarda bir model fonksiyonu oluşturmak zor olabilir.

## 1. Üssel Fonksiyonlar

Bu model fonksiyonu,

$$f(x, \beta) = \beta_1 e^{-\beta_2 x} \quad (5.16)$$

şeklinde ifade edilebilir. Bu model,  $f$  fonksiyonunun

$$\frac{\partial f(x, \beta)}{\partial x} = cf(x, \beta) \quad (5.17)$$

şeklindeki birinci mertebeden bir diferansiyel denklemi ile karakterize edilebilir. Burada  $c$  bir sabit sayıdır. Fiziksel işlemler genellikle daha yüksek mertebeden diferansiyel denklemler ile ifade edilirler ve sonuç olarak daha yüksek mertebeden üssel fonksiyonlar ile tanımlanırlar. Bu fonksiyonlar genel haliyle,

$$f(x, \beta) = \beta_1 + \sum_{i=1}^k \beta_{2i} e^{-\beta_{2i+1} x} \quad (5.18)$$

şeklinde yazılabilir. Burada  $k$ , diferansiyel denklemin mertebesini göstermektedir.

## 2. Kesirli Fonksiyonlar

Yaygın olarak kullanılan modellerden biriside kesirli fonksiyonlardır. En genel formda,

$$f(x, \beta) = \frac{\sum_{i=1}^k \beta_i x^{i-1}}{1 + \sum_{i=1}^m \beta_{i+k} x^i} \quad (5.19)$$

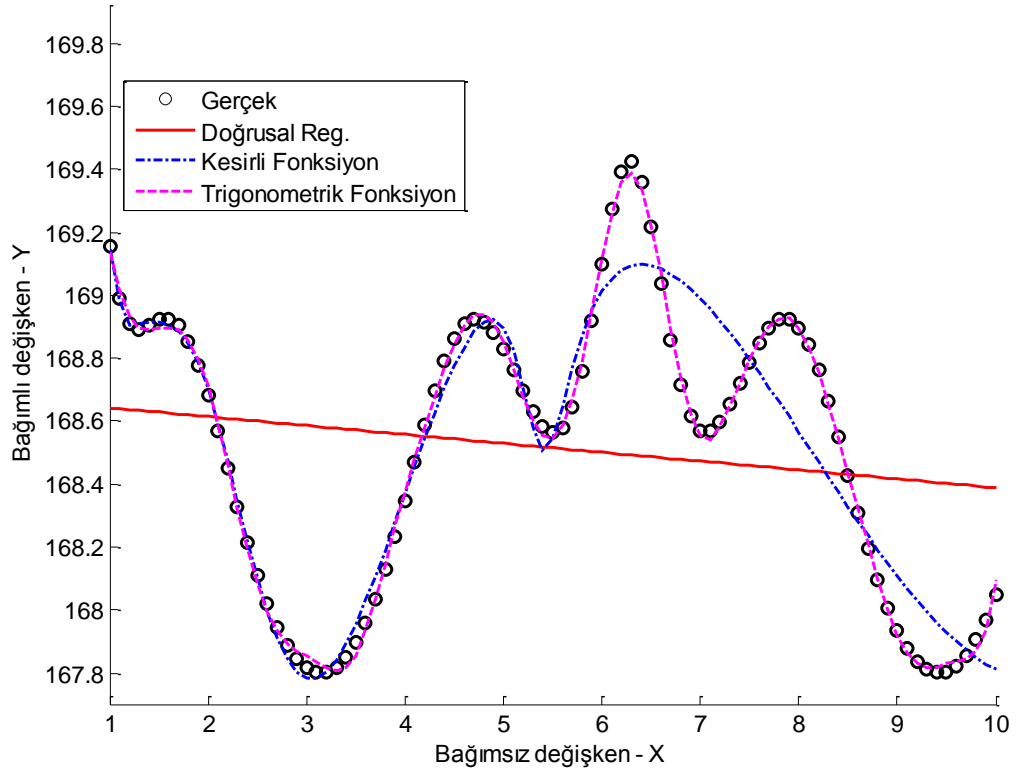
şeklinde verilmektedir [43]. Kesirli fonksiyonlar çok esnek bir yapıya sahiptirler ve çok çeşitli fonksiyonlara yakınsama sağlayabilirler.

## 3. Trigonometrik Fonksiyonlar

Fourier serisi açılımına benzer şekilde sinüs ve kosinüs fonksiyonlarının toplamı şeklinde bir trigonometrik fonksiyon da denklem (5.20)' de verilmiştir.

$$f(x, \beta) = \beta_0 + \sum_{i=1}^k \{\beta_{4i-3} \sin(\beta_{4i-2} x) + \beta_{4i-1} \cos(\beta_{4i} x)\} \quad (5.20)$$

Doğrusal regresyon ile Şekil 5.16' da verilen doğrusal olmayan fonksiyonun modellenmesi çok fazla hataya sebep olmuştur. Trigonometrik fonksiyonlar ve kesirli fonksiyonlar kullanılarak modellenen fonksiyon Şekil 5.17' de gösterilmiştir.

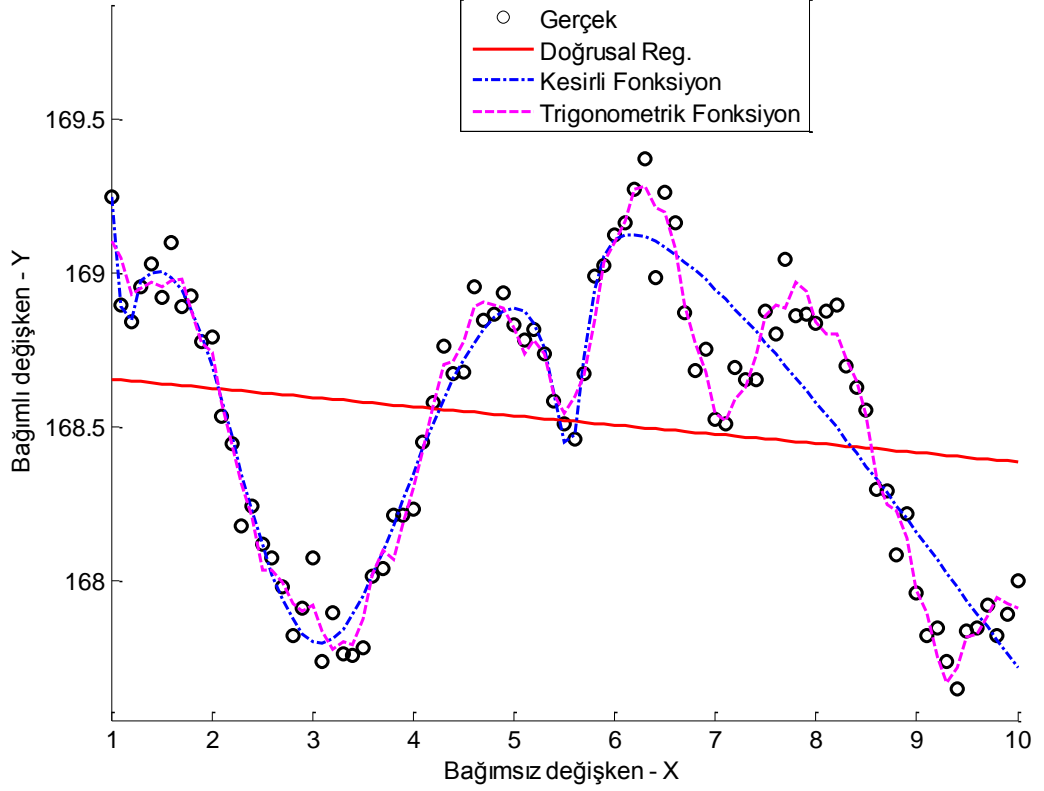


Şekil 5.17 : Doğrusal Olmayan Regresyon ile Modellenmiş Veri Seti

Her iki durumda da 40 adet bilinmeyen parametre kullanılarak modelleme yapılmıştır. Bu veri seti için trigonometrik fonksiyonların daha uygun olduğu gözlemlenmiştir. Ancak her veri seti için düzgün sonuçlar verebilecek fonksiyonlar bulmak çok zordur.

Tez kapsamında yapılan çalışmada bağımsız değişken sayısı 8'dir ve her bir 8 değişken için 40 adet bilinmeyen parametre kullanılması doğrusal olmayan regresyon için bir fonksiyon tanımlamayı çok zorlu kılmaktadır.

Ölçümlerde belirsizlik, hata gibi rastgele gerçekleşen durumlar olduğu göz önüne alındığında doğrusal olmayan regresyon’da hatalı sonuçlar döndürebilir.



Şekil 5.18 : Rastgele Hatalar İçeren Ölçüm Verileri İçin Doğrusal Olmayan Regresyon Fonksiyonları

### 5.3 Destek Vektör Makineleri ve Sınıflandırma


#### 5.3.1 Doğrusal Sınıflandırma

Gerçek dünyada problemler genellikle iki ayrı sınıfın tespiti şeklinde olmaktadır. Örneğin, döviz kurlarının ekonomik verilere bağlı olarak azalıp artması, hava durumu verilerine göre hava sıcaklıklarının artıp düşeceği gibi durumlar iki duruma bağlı olarak tespit edilmeye çalışılabilir. Destek vektör makineleri eğitim verilerini kullanarak olayı genelleştirerek farklı verilerde doğru kararlar verebilmek için öğrenen bir yapay zekâ modelidir. Eğitim verileri olarak “ $x_i$ ” olarak tanımlanan girdi vektörü setleri bulunmaktadır ve bu vektör setlerinden herbiri farklı özellikleri




tanımlamaktadır. Bu giriş vektörleri “ $y_i$ ” olarak tanımlanan çıktı verileri ile eşleşmektedir.

Şekil 5.19’ da eğitim verileri etiketli veri noktaları olarak girdi uzayında gösterilmiştir.



Şekil 5.19 : Girdi Uzayında Eğitim Verileri

Burada öğrenme işlemi etiketlenmiş verileri birbirinden ayıracak bir doğru bulmaktır. Birbirinden ayrılabilir veri setleri için bu doğru birçok şekilde Şekil 5.20’de gösterildiği gibi bulunabilir.



Şekil 5.20 : Girdi Uzayında Verileri Ayırma Yüzeyleri


Görüldüğü gibi Şekil 5.20’ deki verileri sınıflandırmak için birçok ayırma yüzeyi mevcuttur. Bu ayırma yüzeylerinden  $f_1$  ve  $f_3$  sınıflandırma yapmaktadır ancak sınıflandırılacak verilere yakın bulunmaktadır. En iyi ayırma yüzeyi farklı

etiketlenmiş verilere en uzak olacak şekilde bulunacak ayırma yüzeyidir. Destek vektör makineleri ayırma yüzeyleri ile sınıflandırılacak veriler arasındaki mesafeyi en büyük yapacak şekilde ayırma yüzeyi belirler ve bu şekilde en geniş sınırlarla sınıflandırma işlemini gerçekleştirir.

Destek vektör makineleri yalnızca iki veri setini ayırmak için kullanılabilirler. Çoklu ayırma için çeşitli yöntemler mevcuttur ve ileride değinilecektir. İkili sınıflandırma için girdi verileri  $x_i$  ( $i = 1, \dots, n$ ) ve karşılık çıktı verileri  $y_i = \pm 1$  şeklinde etiketlenerek verilsin. Burada istediğimiz  $y_i = 1$  ve  $y_i = -1$  verilerini birbirinden ayıracak en geniş mesafeli ayırma yüzeyini bulmaktır. Herhangi bir ayırma yüzeyi,

$$w \cdot x + b = 0 \quad (5.21)$$

şeklinde ifade edilebilir. Burada “.” nokta çarpımını ve “ $w$ ” yüzeye dik vektörü ifade etmektedir. “ $b$ ” değeri de orijinden olan uzaklığı göstermektedir.



**Şekil 5.21** : En Fazla Mesafe ile Birbirinden Ayrılan İki Veri Setini Ayıran Yüzey

Eğitim verisi eğer doğrusal olarak ayrılabilen türden ise, aralarında bir veri kalmayacak şekilde ve mesafeyi en büyük yapacak şekilde iki yüzey seçebiliriz. Bu yüzeyler;

$$w \cdot x + b = 1 \quad (5.22)$$

ve

$$w \cdot x + b = -1 \quad (5.23)$$

denklemleri ile ifade edilebilir. Şekil 5.21' den de görülebileceği gibi kesikli çizgilerle verilen bu iki yüzey arasındaki dik mesafe,

$$\sigma = \frac{2}{\|w\|} \quad (5.24)$$

olarak bulunabilir. Burada, aradaki mesafeyi arttırabilmek için yapılması gereken ise  $\|w\|$  değerinin en küçükleştirilmesi ile mümkündür. Ayrıca, veri noktalarının bu yüzeyler arasına düşmemesi için aşağıdaki kısıtlar verilmelidir.

$$(1. \text{ Sınıf } x_i \text{'ler}) \rightarrow w \cdot x_i + b \geq 1, \quad (5.25)$$

ve

$$(2. \text{ Sınıf } x_i \text{'ler}) \rightarrow w \cdot x_i + b \leq -1. \quad (5.26)$$

En genel haliyle;

$$y_i(w \cdot x_i + b) \geq 1, \quad 1 \leq i \leq n \quad (5.27)$$

şeklinde yazılabilir. Bu denklemi eniyileştirme problemi içerisine koyarsak;

- $y_i(w \cdot x_i + b) \geq 1, \quad 1 \leq i \leq n$  şartını sağlamak kaydıyla,
- $\|w\|$  değerini en küçükleştir

şeklinde kısıtlandırılmış bir eniyileştirme problemi oluşturmuş oluruz.

$\|w\|$  ifadesi bir vektör normudur ve karekök içeren bir ifadedir. Bu nedenle bu iyileştirme probleminin çözümü kareköklere bağlı olduğundan zordur. Eğer  $\|w\|$  ifadesi yerine  $\frac{1}{2}\|w\|^2$  şeklinde bir ifade kullanılırsa problem bir karesel

(quadratic) programlama eniyileştirme problemine dönüşmektedir. Aynı şekilde burada;

- $y_i(w \cdot x_i + b) \geq 1$ , ( $\forall i$ ) şartını sağlamak kaydıyla,
- $\frac{1}{2} \|w\|^2$  değeri en küçükleştirilmeye çalışılmaktadır.

Bu kısıtlandırılmış eniyileştirme problemi Lagrange çarpanları kullanılarak Lagrange fonksiyonunun en küçükleştirilmesi problemine dönüştürülebilir [43].

$$L(w, b) = \frac{1}{2}(w \cdot w) - \sum_{i=1}^n \alpha_i (y_i(w \cdot x_i + b) - 1) \quad (5.28)$$

Burada  $\alpha_i \geq 0$  değişkenleri Lagrange çarpanlarıdır. En küçük noktada  $b$  ve  $w$  için kısmi türevler alınıp sıfır'a eşitlenirse;

$$\frac{\partial L}{\partial b} = - \sum_{i=1}^n \alpha_i y_i = 0 \quad (5.29)$$

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^n \alpha_i y_i x_i = 0 \quad (5.30)$$


Denklem (5.30)' dan  $w$  değişkeni elde edilip denklem (5.28)' de yerine konursa ikili formülasyon (dual formülasyon) elde edilir.

$$\tilde{L}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (5.31)$$

Denklem (5.31) ile verilen fonksiyon  $\alpha_i \geq 0$  ve  $\sum_{i=1}^n \alpha_i y_i = 0$  kısıtlarını sağlayacak şekilde en büyükleştirilmelidir. Bu denklem kısıtlarıyla birlikte kısıtlandırılmış karesel (quadratic) programlama ile en iyileştirilebilir.

### 5.3.2 Doğrusal Olmayan Sınıflandırma

Bazı durumlarda veriler bir doğru ile birbirinden ayıramayabilir. Girdi uzayında doğrusal olarak ayıramayan veriler her zaman daha yüksek bir boyutta bir uzayda birbirlerinden ayrılabilirler. Bu uzay özellik uzayı olarak adlandırılır.



Şekil 5.22 : (a) Doğrusal Sınıflandırma (b) Doğrusal olmayan sınıflandırma: Girdi uzayından özellik uzayına dönüşüm [44]

Verileri girdi uzayından özellik uzayına eşlemek için,

$$x_i \cdot x_j \rightarrow \phi(x_i) \cdot \phi(x_j) \quad (5.32)$$

değişiminin yapılması gerekmektedir. Kernel fonksiyonunun seçimi ile belirlendiğinden,  $\phi(x_i)$ ' nin fonksiyonel formunun bilinmesine gerek yoktur.

Denklem (5.31) ile verilen ikili formülasyon doğrusal olmayan ayırma için aynı kısıtları sağlamak kaydıyla aşağıdaki şekilde tekrardan yazılabilir ve en büyüleştirilmelidir.

$$\tilde{L}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (5.33)$$

Sapma(bias) terimi  $b$  ayrıca bulunmalıdır.  $y_i = +1$  verileri için;

$$\min_{\{i \mid y_i=+1\}} [w \cdot x_i + b] = \min_{\{i \mid y_i=+1\}} [\sum_{j=1}^n \alpha_j y_j K(x_i, x_j)] + b = 1 \quad (5.34)$$

Denklem (5.30) kullanılarak benzer eşitlik  $y_i = -1$  verileri için de kullanılırsa;

$$b = -\frac{1}{2} \left[ \max_{\{i | y_i = -1\}} (\sum_{j=1}^n \alpha_j y_j K(x_i, x_j)) + \min_{\{i | y_i = 1\}} (\sum_{j=1}^n \alpha_j y_j K(x_i, x_j)) \right] \quad (5.35)$$

elde edilir [43].

Böylece, ikili sınıflandırma için destek vektör makinesi oluşturmak için  $(x_i, y_i)$  verileri denklem (5.33)' te yerine konularak kısıtları sağlamak şartıyla en büyükleştirilirse  $\alpha_i$ 'nin optimum değerleri bulunmuş olur. Bulunan bu değerler denklem (5.35)' te yerine yazıldığında sapma terimi  $b$  bulunmuş olur.

Kernel fonksiyonları destek vektör makinelerinin kullanılmasında büyük rol oynamaktadır. Bazı çok kullanılan kernel fonksiyonları aşağıda kısaca açıklanmıştır.

### 1. Polinom Kernel

Çok terimli (polynomial) eşleştirme doğrusal olmayan modellemeler için kullanılan yaygın yöntemlerden birisidir ve aşağıdaki gibi genel olarak gösterilir.

$$K(x, x') = (\langle x, x' \rangle + 1)^d \quad (5.36)$$

Burada  $d$  ile gösterilen polinomun derecesidir.

### 2. Gauss Merkezci (Radial) Tabanlı Fonksiyon

Merkezcil (radial) tabanlı fonksiyonlar DVM (SVM) ile sınıflandırmada en yoğun olarak kullanılan kernel fonksiyonlarıdır. İki veri için merkezcil tabanlı fonksiyon aşağıdaki şekilde yazılabilir.

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (5.37)$$

Burada  $\|x - x'\|$  özellik uzayındaki iki vektörün Öklid mesafesini belirtmektedir.  $\sigma$  ise serbest parametredir.

### 3. Eksponansiyel Merkezci(Radial) Tabanlı Fonksiyon

Veri setinde süreksizlik olması durumunda kullanılması uygun olan bir merkezci tabanlı fonksiyondur. Gauss Merkezci (Radial) tabanlı fonksiyona benzemektedir, tek farkı Öklid mesafesinin karesinin olmayışıdır.

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (5.38)$$

### 4. Çok Katmanlı Perceptron (Sigmoid Fonksiyonlar)

Köklü bir kullanıma sahip olan çok katmanlı perceptron, bir gizli katman ile kernel fonksiyonu olarak kullanılabilir.

$$K(x, x') = \tanh(\rho\langle x, x' \rangle + \nu) \quad (5.39)$$

Burada  $\rho$  ve  $\nu$  değerleri sırasıyla ölçek ve ofset değerlerini göstermektedir.

### 5. Fourier Serileri

Fourier serisi,  $2N+1$  boyuttaki özellik uzayının bir açılımı olarak ele alınabilir.  $\left[-\frac{\pi}{2}, \frac{\pi}{2}\right]$  aralığında tanımlanan kernel fonksiyonu,

$$K(x, x') = \frac{\sin\left(N + \frac{1}{2}\right)(x - x')}{\sin\left(\frac{1}{2}(x - x')\right)} \quad (5.40)$$

olarak verilmiştir. Ancak, bu kernel fonksiyonu düzenleme yeteneğinin zayıf olmasından dolayı iyi bir seçim değildir.

### 6. Eğriler (Splines)

Eğriler esnekliklerinden dolayı modelleme için çok popüler bir seçenektir. Kübik bir spline denklemi aşağıdaki şekilde tanımlanmıştır.

$$K(x, x') = 1 + \langle x, x' \rangle + \frac{1}{2} \langle x, x' \rangle \min(x, x') - \frac{1}{6} \min(x, x')^3 \quad (5.41)$$

## 7. B-Eğrileri

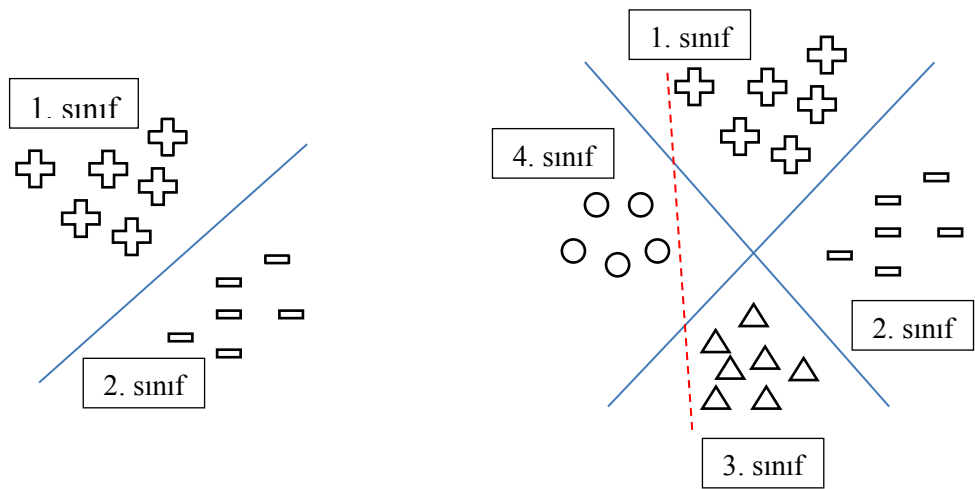
B-eğrileride diğer birçok kullanılan eğri formülüdür. Kernel fonksiyonu  $[-1,1]$  kapalı aralığında tanımlanmıştır ve aşağıdaki gibi verilmiştir.

$$K(x, x') = B_{2N+1}(x - x') \quad (5.42)$$

Bu kernel fonksiyonları birbiri ile toplanarak veya çarpılarak daha karmaşık modellemelerde kullanılabilir. Yukarıda anlatılanlar dışında Laplace, ANOVA, Logaritmik, Kesirsel gibi birçok kernel fonksiyonu da mevcuttur. Ayrıca problemin türüne göre çeşitli kombinasyonları ile bu kerneller birbirleri ile de kullanılabilirler.

### 5.3.3 Çok-Sınıflı Destek Vektör Makineleri

Önceki bölümlerde gösterildiği üzere destek vektör makineleri yalnızca iki sınıfın ayrımını yapmak üzere tasarlanmış bir yöntemdir. Ancak, her zaman iki sınıfın ayrılması yeterli olmamakta ve birden fazla sınıfın ayrıştırılması gerekebilmektedir.



Şekil 5.23 : İki ve Daha Çok Sınıfın Birbirinden Ayrılması



Şekilde görüldüğü gibi iki sınıfın birbirinden ayrılması olayı destek vektör makineleri ile kolayca yapılabilmektedir. Ancak birden fazla sınıfın olduğu durumlarda sınıfları birbirinden ayırmak için farklı yöntemler kullanılmalıdır. Çoklu sınıflandırmada yapabilmek için kullanılan en yaygın yaklaşım şekli çoklu sınıflandırmanın birden fazla ikili sınıflandırma şekline dönüştürülmesidir. Bu dönüşüm için literatürde en yaygın kullanılan yöntemler aşağıda listelenmiştir [45, 46].

### 1. Birine Karşı Hepsi Yöntemi

Bu yöntemde seçilen sınıflardan birisi için destek vektör makineleri kullanılarak verilen değer o sınıftan olup olmadığı bulunmaya çalışılır. Örneğin, 1. sınıfı ele alırsak, giriş verisinin bu sınıfta mı yoksa başka sınıfta mı olduğu tespit edilmeye çalışılır. Eğer 1. sınıf içerisinde değilse bir sonraki sınıf için test başlatılır ve 2. sınıfta olup olmadığı test edilir ve tüm sınıflar bu şekilde sırasıyla diğerlerine karşı karşılaştırılır. Şekil 5.23' te kırmızı kesikli çizgi ile dördüncü sınıfın diğer sınıflarla karşılaştırılması gösterilmiştir. N adet sınıfın olduğu bir sistemde N adet karşılaştırma yapılması gerekmektedir. Bu tez kapsamında da birine karşı hepsini karşılaştırmak suretiyle çoklu sınıflandırma gerçekleştirilmiştir.

### 2. Birebir Karşılaştırma Yöntemi

Bu yöntemde iki sınıfın birbiri ile karşılaştırması yapılır. Birinci sınıf, önce ikinci sınıf ile sonra üçüncü sınıf ile ve diğer bütün diğer sınıflar ile sırayla karşılaştırılır.

<i>1-2</i>	<i>2-3</i>	<i>3-4</i>	...	<i>(N-1) - N</i>
<i>1-3</i>	<i>2-4</i>	<i>3-5</i>	...	
<i>1-4</i>	<i>2-5</i>	<i>3-6</i>	...	
<i>⋮</i>	<i>⋮</i>	<i>⋮</i>		
<i>1-N</i>	<i>2-N</i>	<i>3-N</i>	...	

Yukarıda gösterildiği gibi her bir sınıf birbiri ile kıyaslandığında N adet sınıf için  $\frac{N(N-1)}{2}$  adet sınıflandırma yapılmaktadır.

### 3. Yönlendirilmiş birbirini izlemeyen grafik (Directed acyclic graph) yöntemi [47].

Çoklu ikili sınıflandırma yerine Crammer and Singer [48] çoklu sınıflandırma problemini tek bir eniyileştirme problemine dönüştüren bir yöntem olan çok sınıflı destek vektör makinaları yöntemi geliştirmişlerdir.

#### 5.4 Destek Vektör Regresyonu

Eğitim verisi  $\{(x_1, y_1), \dots, (x_n, y_n)\} \subset \mathcal{X} \times \mathbb{R}$  verilmiş olsun, burada  $\mathcal{X}$ , giriş verilerinin tanımlandığı uzayı göstermektedir ( $\mathcal{X} = \mathbb{R}^d$  gibi.). Örneğin, para birimlerinin alış-satış kurlarının günlere göre ve ekonomik verilere göre davranışı eğitim verisi olarak gösterilebilir. Vapnik'in [49] önerdiği  $\epsilon - SV$  regresyon analizinde, amacımız öyle bir  $f(x)$  fonksiyonu bulunsun ki tüm eğitim verileri kullanıldığında çıkış verileri  $y_i$ 'den en fazla  $\epsilon$  kadarlık bir kaçıklıkla değerler üretebilsin ve aynı zamanda mümkün olduğunca düz olsun. Diğer bir deyişle,  $\epsilon$  değerinden daha küçük olduğu sürece hataların hiçbiri bizi ilgilendirmiyor, ancak bu değerden daha büyük hatalar olduğunda ise kabul edilemez oluyor.  $\epsilon$  değeri bir nevi bulunacak fonksiyon ile eğitim için kullanılan verilerden ne kadar farklı sonuçlar elde edebileceğimizi kısıtlamış oluyoruz.

Doğrusal fonksiyon  $f$ 'i aşağıdaki gibi tanımlayalım.

$$f(x) = \langle \omega, x \rangle + b, \quad \omega \in \mathcal{X} \text{ ve } b \in \mathbb{R} \quad (5.43)$$

Burada,  $\langle \cdot, \cdot \rangle_{\mathcal{X}}$  uzayında tanımlı nokta çarpımını göstermektedir. Denklem (5.43) için düzlük, küçük  $\omega$  bulunması anlamına gelmektedir [50]. Bunu sağlamanın bir yolu  $\|\omega\|^2 = \langle \omega, \omega \rangle$  normunu en küçükleştirmektir [51]. Bu problemi convex eniyileştirme problemi şeklinde yazarsak;

$$\left. \begin{aligned} y_i - \langle \omega, x_i \rangle - b &\leq \epsilon \\ \langle \omega, x_i \rangle + b - y_i &\leq \epsilon \end{aligned} \right\} \text{ şartını sağlayacak şekilde,} \quad (5.44)$$

$$\frac{1}{2} \|\omega\|^2 \quad \text{eniyileştir.}$$

Denklem (5.44)' deki varsayım,  $\epsilon$  hassasiyetinde bütün  $(x_i, y_i)$  çiftlerini yaklaşık olarak hesaplayabilecek bir  $f$  fonksiyonun var olduğu, diğer bir deyişle eniyileştirme

probleminin gerçekleştirilebilir olduğudur. Ancak, bazı durumlarda bir miktar hatanın olmasına da izin vermek isteyebiliriz. Bunun için, Cortes ve Vapnik'in [52] destek vektör makinelerine uyguladığı yumuşak kenar boşluğu (soft margin) kayıp fonksiyonuna benzer şekilde denklem (5.44)' teki eniyileştirme problemindeki uygun olmayan kısıtların üstesinden gelebilmek için  $\xi_i, \xi_i^*$  değişkenlerini tanımlayabiliriz [50]. Böylece, Vapnik'in [49] formülasyonu elde edilmiş olur.


$$\left. \begin{aligned} y_i - \langle \omega, x_i \rangle - b &\leq \epsilon + \xi_i \\ \langle \omega, x_i \rangle + b - y_i &\leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \right\} \text{ şartını sağlayacak şekilde,} \quad (5.45)$$

$$\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad \text{eniyileştir.}$$

Burada, C sıfırdan büyük sabit bir sayı olup  $f$  fonksiyonun düzgünlüğü ile  $\epsilon$ 'dan büyük hataların gözardı edilebilirliğinin arasındaki dengeleme sabitidir. Bu  $\epsilon$ -insensitive olarak bilinen kayıp fonksiyonunun kullanılmasına karşılık gelmektedir.  $\epsilon$ -insensitive kayıp fonksiyonu  $|\xi|_\epsilon$  aşağıdaki şekilde tanımlanmıştır.

$$|\xi|_\epsilon = \begin{cases} 0, & \text{eğer } |\xi| \leq \epsilon \text{ ise} \\ |\xi| - \epsilon, & \text{aksi durumda} \end{cases} \quad (5.46)$$

Denklem (5.46) ile verilen  $\epsilon$ -insensitive kayıp fonksiyonu Şekil 5.24' te gösterilmiştir.



Şekil 5.24 : Doğrusal DVM için  $\epsilon$ -insensitive Kayıp Fonksiyonu

Birçok durumda denklem (5.45)' te verilen eniyileştirme problemi ikili formülasyonu ile daha kolay bir şekilde çözülebilir. İkili formülasyon, destek vektör makinelerinin doğrusal olmayan fonksiyonlara genişletilebilmesini sağlar ve böylece karmaşık problemlerin çözümü gerçekleştirilebilir.

İkili eniyileştirmede temel fikir Lagrange fonksiyonunun hedef fonksiyon ve kısıtlarından ikili değişken setlerinin işleme katılması ile oluşturulmasıdır. Lagrange fonksiyonunu Lagrange çarpanlarını kullanarak aşağıdaki şekilde yazabiliriz.

$$\begin{aligned}
L = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \\
- \sum_{i=1}^l \alpha_i (\epsilon + \xi_i - y_i + \langle \omega, x_i \rangle + b) \\
- \sum_{i=1}^l \alpha_i^* (\epsilon + \xi_i^* + y_i - \langle \omega, x_i \rangle - b)
\end{aligned} \tag{5.47}$$

Burada,  $\eta_i, \eta_i^*, \alpha_i, \alpha_i^*$  Lagrange çarpanlarıdır. Denklem (5.47)' de verilen ikili değişkenler aşağıdaki şartı sağlamak zorundadır.

$$\eta_i, \eta_i^*, \alpha_i, \alpha_i^* \geq 0 \tag{5.48}$$

Optimalliğin sağlanabilmesi için Lagrange fonksiyonunun ana değişkenlere  $(\omega, b, \xi_i, \xi_i^*)$  göre kısmi türevinin sıfır olması gerekmektedir.

$$\frac{\partial L}{\partial b} = \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \tag{5.49}$$

$$\frac{\partial L}{\partial \omega} = \omega - \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i = 0 \tag{5.50}$$

$$\frac{\partial L}{\partial \xi} = C - (\alpha_i - \eta_i) = 0 \quad (5.51)$$

$$\frac{\partial L}{\partial \xi^*} = C - (\alpha_i^* - \eta_i^*) = 0 \quad (5.52)$$

Denklem (5.49), (5.50), (5.51) ve (5.52), denklem (5.47)' de yerine konursa ikili eniyileştirme problemi oluşmuş olur.

$$\sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \text{ ve } \alpha_i, \alpha_i^* \in [0, C] \text{ sağlayacak şekilde,} \quad (5.53)$$

$$-\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle - \epsilon \sum_{i=1}^l (\alpha_i - \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \text{ eniyileştir.}$$

İkili eniyileştirme problemi (5.53) oluşturulurken ikili değişkenler  $\eta_i$  ve  $\eta_i^*$  denklem (5.51) ve (5.52)' den yok edilmişti. Yeniden formüle edilirse, ikili değişkenler  $\eta_i$  ve  $\eta_i^*$  aşağıdaki şekilde yazılabilir.

$$\eta_i = C - \alpha_i \text{ ve } \eta_i^* = C - \alpha_i^* \quad (5.54)$$

Denklem (5.50) yeniden düzenlenirse;

$$\omega = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (5.55)$$

şeklinde yazılabilir ve denklem (5.43)' te kullanılırsa;

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (5.56)$$

elde edilir.

Denklem (5.56)' da bilinmeyen tek değişken olarak b kalmıştır. Karush-Kun-Tucker (KKT) koşullarına [53, 54] göre çözüm noktasında ikili değişkenler ile kısıtlar arasındaki çarpım sıfır olmalıdır.

$$\alpha_i(\epsilon + \xi_i - y_i + \langle \omega, x_i \rangle + b) = 0 \quad (5.57)$$

$$\alpha_i^*(\epsilon + \xi_i^* + y_i - \langle \omega, x_i \rangle - b) = 0 \quad (5.58)$$

$$(C - \alpha_i)\xi_i = 0 \quad (5.59)$$

$$(C - \alpha_i^*)\xi_i^* = 0 \quad (5.60)$$

Bu denklemler birçok kullanışlı sonuca varmamızı sağlar. Birincisi, sadece  $(x_i, y_i)$  ile karşılık  $\alpha_i = C$  ( $\alpha_i^* = C$ ),  $\epsilon - insensitive$  bandının dışında kalır. İkincisi,  $\alpha_i \cdot \alpha_i^* = 0$  eşitliğini sağlamak için aynı anda sıfırdan farklı olan  $\alpha_i, \alpha_i^*$  ikili değişkenleri olamaz. Böylece aşağıdaki sonuca varabiliriz.

$$\epsilon - y_i + \langle \omega, x_i \rangle + b \geq 0 \text{ ve } \xi_i = 0 \text{ eğer } \alpha_i < C \text{ ise} \quad (5.61)$$

$$\epsilon - y_i + \langle \omega, x_i \rangle + b \leq 0 \quad \text{eğer } \alpha_i > 0 \text{ ise} \quad (5.62)$$

Benzer analiz  $\alpha_i^*$  ile de yaparsak  $b$ 'yi aşağıdaki aralıktaki gibi bulabiliriz.

$$\begin{aligned} \max\{-\epsilon - y_i - \langle \omega, x_i \rangle \mid \alpha_i < C \text{ veya } \alpha_i^* > 0\} &\leq b \\ &\leq \min\{-\epsilon - y_i - \langle \omega, x_i \rangle \mid \alpha_i > 0 \text{ veya } \alpha_i^* < C\} \end{aligned} \quad (5.63)$$

Tüm değişkenler bulunduktan sonra denklem (5.43) kullanılarak regresyon analizi yapılabilir. Şu ana kadar yapılan işlemlerin tamamı doğrusal destek vektör regresyonu içindir. Destek vektör sınıflandırılmasında da anlatılan kernel uygulaması kullanılarak regresyonu doğrusal olmayan bir boyuta taşımak mümkündür.

## 6. PERFORMANS METRİKLERİ

Bu çalışma kapsamında, kullandığımız her bir yöntemin tahmin doğruluğu, aşağıdaki performans metrikleri yardımıyla değerlendirilmiştir. Bu metriklerin her biri, tahmin hatalarını farklı matematiksel değerlerle ifade etmektedir. Ayrıca, bu metrikler sayesinde, kullanılan tekniklerin performans bakımından karşılaştırılmaları kolaylaşmıştır.

### 6.1 Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE)

Bu metrik, hata karelerinin etkisini dikkate almaktadır ve farklı tahmin yöntemlerinin karşılaştırılmasında yaygın olarak kullanılmaktadır [55]. Denklem (6.1) kullanılarak RMSE değeri bulunmaktadır.

$$RMSE = \sqrt{\frac{\sum(\hat{y}_i - y_i)^2}{n}} \quad (6.1)$$

### 6.2 Ortalama Yüzde Hata (Mean Percentage Error-MPE)

Bu metrik, tahmin hatasının göreceli bir ölçüsüdür. Pozitif ve negatif hataların ortalamasına tabidir. Denklem (6.2) kullanılarak MPE değeri bulunmaktadır.

$$MPE = \frac{\left(\sum_{i=1}^n \left(\frac{\hat{y}_i - y_i}{y_i}\right) \times 100\right)}{n} \quad (6.2)$$

### 6.3 Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE)

Yaygın olarak kullanılan bir tahmin etkinlik ölçüsüdür ve özellikle farklı modellerin karşılaştırılmasında daha çok kullanılır. Denklem (6.3) kullanılarak MAPE değeri bulunmaktadır.

$$MAPE = \frac{100}{n} \times \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (6.3)$$

Bu yöntemlerde, açısız yön için yüzde hata hesabı yapılırken,

$$Açısız Yüzde Hata = \frac{100}{n} \times \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{180} \right| \quad (6.4)$$

denklemini kullanılmıştır. Çünkü bazı durumlarda açısız yön değeri sıfır çıkmakta, bu da MPE ve MAPE değerlerinin hesaplanmasını imkânsız kılmaktadır. Açısız yön için yüzde hesabı yapılırken, %100 olarak belirlenen hata 180 derecelik bir hatayı göstermektedir.

#### 6.4 Korelasyon Katsayısı (Correlation Coefficient-r)

İki değişken arasında ilişki olup olmadığını ve iki değişken arasındaki ilişkinin derecesini belirlemek için korelasyon tekniklerinden yararlanır. Korelasyon katsayısı “r” ile gösterilmekte ve -1 ile 1 arasında bir değer alabilmektedir. 0’ dan 1’e veya -1’ e doğru gidildikçe ilişkinin gücü artmakta, iki yönden de 0’ a yaklaşıldığında ise ilişkinin gücü azalmaktadır [56]. Korelasyon katsayısı,

$$r = \frac{\sum y_i \hat{y}_i - \frac{(\sum y_i) \times (\sum \hat{y}_i)}{n}}{\sqrt{\left( \sum (y_i)^2 - \frac{(\sum y_i)^2}{n} \right) \times \left( \sum (\hat{y}_i)^2 - \frac{(\sum \hat{y}_i)^2}{n} \right)}} \quad (6.5)$$

şeklinde hesaplanmaktadır.

#### 6.5 Determinasyon Katsayısı (Determination Coefficient-R<sup>2</sup>)

Determinasyon katsayısı, bağımlı değişkendeki değişimlerin, bağımsız değişken tarafından açıklanabildiği kısmını ifade etmektedir ve kısaca R<sup>2</sup> ile gösterilmektedir. r değeri -1 ile 1 arasında değerler alabilirken, R<sup>2</sup>, 0 ile 1 arasında değerler alabilmektedir. Açıklayıcı değişken sayısı arttıkça, determinasyon katsayısı 1’ e yaklaşacaktır.



Denklem (6.7), (6.8) ve (6.9) ile verilen eşitlikler, denklem (6.6)' da yerine yazılırsa, determinasyon katsayısı hesaplanmış olmaktadır.

$$R^2 = \frac{bS_{xy}}{S_{yy}} \quad (6.6)$$

$$b = \frac{\sum xy - \frac{\sum x \sum y}{n}}{\sum x^2 - \frac{(\sum x)^2}{n}} \quad (6.7)$$

$$S_{xy} = \sum xy - \frac{\sum x \sum y}{n} \quad (6.8)$$

$$S_{yy} = \sum y^2 - \frac{(\sum y)^2}{n} \quad (6.9)$$

## 6.6 Tutarsızlık Hesabı (Variance Accounted For- VAF)

Genellikle modelin doğruluğunu test etmek için kullanılan bir yöntemdir. Tahmin edilen ve gerçek değerler aynı olduğu zaman sonuç olarak %100 verirken, farklılıklar attıkça sonuç değeri gittikçe düşmektedir.

$$VAF_i = \left( 1 - \frac{var(y_i - \hat{y}_i)}{var(y_i)} \right) * 100 \quad (6.10)$$

## 7. MODELLERİN UYGULANMASI VE SONUÇLAR

### 7.1 Modeller ve Uygulama

Bu çalışmada, çok fazlı akışlardaki parçacık hareket yönünü ve hızını tahmin etmek için çeşitli tahmin modelleri kullanılmıştır. Parçacık hızını ve açısal yönü tahmin edebilmek için doğrusal regresyon, doğrusal olmayan regresyon, yapay sinir ağları, destek vektör regresyonu kullanılırken; parçacığın doğu, batı şeklinde ilerlediği yönün tahminini yapmak için ise yapay sinir ağları ve destek vektör makineleri kullanılmıştır. İlk bahsedilen parçacık hızının ve açısal yönünün tahmin edilmeye çalışılması bir tahmin problemidir, ancak parçacığın ilerlediği yönün doğu, batı ve benzeri şekilde belirlenmeye çalışması ise bir sınıflandırma problemidir. Tahmin problemlerinde kullanılmak üzere deneylerden elde edilen resimlerden, 15 derece açılı borular için 1080 adet, 30 derece açılı borular için 1087 adet, yatay borular için 885 adet veri toplanmıştır. Sınıflandırma problemleri için deneylerden elde edilen veri sayısı ise; 15 derece açılı borular için 1235 adet, 30 derece açılı borular için 1552 adet, yatay borular için 1119 adettir. Bu çalışma kapsamında kullanılan tüm programlar MATLAB<sup>®</sup> programı kullanılarak geliştirilmiştir.

Çalışma kapsamında kullanılan yapay sinir ağı, ileri beslemeli yapay sinir ağı olarak belirlenmiştir. İleri beslemeli yapay sinir ağı, hem sınıflandırma hem de tahmin problemleri için kullanılmıştır. Yapay sinir ağlarının çok sınıflı sınıflandırma yapabilmeleri açısından, bu çalışma için avantajlı olacağı düşünülerek seçilmiştir. Bu çalışmada, yapay sinir ağını eğitebilmek için 8 tane yön belirlenmiş ve bu yönler Tablo 1' deki gibi numaralarla eşleştirilmiştir. Bunun amacı, doğrudan yazıları kullanarak optimizasyon yapılamayacağından yapay sinir ağlarının eğitilmesinin de mümkün olamayacağındandır.

**Tablo 1:** Yönler

<b>Yönler</b>	<b>İlişkilendirildikleri Sayı</b>
Kuzeydoğu	1
Güneydoğu	-1
Kuzeybatı	3
Güneybatı	-3
Doğu	0
Batı	4
Kuzey	2
Güney	-2

Yönler, doğu, batı, kuzey şeklinde ağa öğretilmemiş; tablodaki eşleştirmeye göre doğu ise 0, batı ise 4 şeklinde öğretim yapılmıştır. Yapay sinir ağları doğası gereği çıktı olarak tam sayı vermediğinden, sonuçta çıkan değer en yakın tamsayıya yuvarlanarak yine -3 ile 4 arasında bir sayı vermesi sağlanmış ve parçacığın yönü bu şekilde tahmin edilmiştir. Yönler sayılar ile ilişkilendirilirken, yakın yönlerin en yakın tamsayıları almasına dikkat edilmiştir. Örneğin, doğu yönü 0 olarak belirlendiğinde, kuzeydoğu ve güneydoğu yönleri sırasıyla 1 ve -1 olarak belirlenmiştir. Yapay sinir ağlarında önemli olan, yeterli gizli katman sayısını ve her gizli katmanda olması gereken gizli nöron sayısını doğru tahmin etmektir. En iyi sonucu veren yapay sinir ağını bulmak için deneme-yanılma yöntemi kullanılmaktadır. Ancak burada dikkat edilmesi gereken husus, yapay sinir ağlarının her çalıştırılmada farklı sonuçlar vermesidir. Bunun nedeni her seferinde çözüme başlarken ağırlık matrislerinin ( $w$  değerlerinin) değerlerinin rastgele olarak seçilmesidir. Eğitim belli bir performans marjını sağladığında ise otomatik olarak durdurulduğundan, bazı eğitimlerde daha iyi, bazılarında ise daha kötü sonuçlar elde edilebilmektedir. Sonuçta elde edilen değerler ise yerel optimum değerler olduğundan, bu çalışmada elde edilen sonuçlardan daha iyi sonuçların elde edilebileceği göz önünde bulundurulmalıdır. Tez kapsamında yapılan çalışmalarda defalarca yapılan eğitimlerden bulunan en iyi sonuçlar kullanılmıştır.

Bu çalışmadaki veriler için en iyi sonucu veren gizli katman ve nöron sayısına sahip yapay sinir ağının sonuçları gösterilecektir. Bu da, tek bir gizli katman, gizli katmanın da 100 tane gizli nöron içerdiği ve tek bir çıktı katmanının bulunduğu durumdur. Sınıflandırma problemlerinde ayrıca, iki gizli katmanın, her bir gizli

katmanın da 50 tane gizli nöron içerdiği ve tek bir çıktı katmanının bulunduğu durum da gösterilmiştir. Yapay sinir ağlarının bir avantajı da, bir kerede birden fazla çıktı verebilmesi özelliğidir. Yani, hem açısız yön hem de hız tahmini olarak kullanılacak olan YSA' yı, her iki problem için ayrı ayrı eğitip sonuç üretmesini beklemeye gerek yoktur. Tek bir kez çalıştırılan yapay sinir ağı, her iki problem için de çıktısını eş zamanlı olarak üretebilmektedir.

Destek vektör makineleri, ileri beslemeli yapay sinir ağlarından farklı şekilde bir sınıflandırma yapmaktadır. İleri beslemeli yapay sinir ağları daha önce de bahsedildiği gibi çok sınıflı sınıflandırma yapabilirken, destek vektör makineleri ikili sınıflandırma yapmaktadır. Tablo 1' de belirlenen yönler aynı zamanda destek vektör makinelerine de yönleri öğretmek için kullanılmıştır. Destek vektör makineleri bir seferde yalnızca iki sınıflı ayırabilme özelliğine sahip olduğundan, Tablo 1' de verilen birden fazla yönü birbirinden ayırabilmek için bölüm 5.3.3 altında bahsedilen birine karşı hepsi yöntemini kullanmaktadır. Yapay sinir ağları ile gerçekleştirilen her çözüm bir öncekinden farklı olurken, destek vektör makineleri ile her seferinde aynı sonuçlar elde edilmektedir. Bunun nedeni ise destek vektör makineleri başlangıç koşullarını hep sabit alırken, yapay sinir ağlarında bu gelişigüzel olarak ele alınmaktadır. Destek vektör makinelerinin en büyük avantajı global minimum' u bulmasıdır ve bu da çoğu zaman yapay sinir ağlarından daha başarılı sonuçlar vermesini sağlamaktadır. Sınıflandırma ve tahmin problemlerinde, merkezci (radial) tabanlı fonksiyon kerneli diğer kerneller ile karşılaştırıldığında daha başarılı sonuçlar vermiştir ve bu çalışmada da merkezci tabanlı fonksiyon kerneli kullanılmıştır. Çalışma kapsamında MATLAB® programının Bioinformatics Toolbox'ında bulunan eğitim ve sınıflandırma fonksiyonları kullanılmıştır ancak bu toolbox' ta destek vektör regresyonu için bir komut bulunmadığından tahmin probleminde Steve R. Gunn tarafından geliştirilen SVM kütüphanesi [57] MATLAB ortamına eklenerek kullanılmıştır.

Destek vektör makineleri (regresyon analizi de dâhil) ile yapay zekâ modeli oluşturulurken Gauss Merkezci (Radial) Tabanlı kernel fonksiyonu ile  $\epsilon$  –insensitive kayıp fonksiyonu kullanılmıştır. Kullanılan kernel fonksiyonu girdi

olarak  $\sigma$  değerini kullanmakta ve böylece oluşturulacak eğrinin yayılma miktarını belirlemektedir. Bu değer varsayılan değeri 1 olarak alınmıştır. Deneme yanılma ile de bazı değerler denense de en uygun sonucu bulmak için çapraz doğrulama yöntemi kullanılmıştır. Çapraz doğrulama ile test veri seti 10 parçaya bölünmüş ve bu küçük veri setlerinin herbiri ile model oluşturularak diğer veri setleri ile denenmiş ve bu işlem her bir küçük set için sırasıyla yapılmıştır. Böylece, sonucu en iyileyecek şekilde  $\sigma$  değeri her seferinde değiştirilerek bir eniyileştirme algoritması içerisinde çapraz doğrulama işlemi gerçekleştirilmiştir. Sonuçta, birçok  $\sigma$  değeri otomatik olarak denenerek model performansını en yüksek yapacak şekilde hesaplanmıştır.

Doğrusal regresyonda, girdi verilerinin doğrusal olarak çıktı verilerine bağlı olduğu ele alınarak bir doğru çizilmesi yine MATLAB'ın fonksiyonları kullanılarak gerçekleştirilmiştir. Doğrusal olmayan regresyonda ise, denklem (7.1)' de verilen eşitlik ile en uygun doğrusal olmayan fonksiyon modeli bulunmaya çalışılmıştır. Toplanan veriler arasında bir bağlantı kurabilmek çok mümkün olmadığı için çeşitli denemelerle bu fonksiyonun kullanılmasına karar verilmiştir. Kullanılan veriler doğrusal şekilde ayrılabilen veriler olmadığından, doğrusal regresyonun iyi bir sonuç vermesi beklenmemektedir. Ancak bazı durumlarda doğrusal olmayan regresyon, doğrusal regresyona göre daha başarısız sonuçlar vermiştir.

$$\begin{aligned}
 \text{modelfun} &= @(\mathbf{b},\mathbf{x}) \quad (b(1)*(\sin(x(:,1).^b(2)))) \quad + \\
 &b(3)*(\sin(x(:,2).^b(4))) \quad + \quad b(5)*(\sin(x(:,3).^b(6))) \quad + \\
 &b(7)*(\sin(b(8)*x(:,4))) \quad + \quad b(9)*\sin(b(10)*x(:,5))) \quad + \\
 &b(11)*\sin(b(12)*x(:,6))) + b(13)*\sin(b(14)*x(:,7)))); \quad (7.1)
 \end{aligned}$$

Tüm kullanılan yöntemlerde girdi verisi olarak tablodan RPM, ROP, VSL, QG,  $X_1$ ,  $Y_1$  ve çerçeveler arasındaki fark kullanılmıştır. Çıktı verisi olarak ise, sınıflandırma problemlerinde yön bilgisi, tahmin problemlerinde ise açı ve hız değerleri kullanılmıştır.

## 7.2 Sonular ve Tartışma

Tez süresince geliştirilmiş olan modellerin tahmin sonuçları aşağıda verilmiştir. Tahminler yatay konumda, 15° ve 30° açılı konumda olan borulardan elde edilmiş veriler için ayrı ayrı yapılmıştır. Her bir tahmin sonucu gösterilirken, eğitim verilerinden elde edilen sonuçlar, test verilerinden elde edilen sonuçlar ve verilerin tamamı dikkate alınarak elde edilmiş olan sonuçlar aşağıdaki grafiklerde ayrı ayrı gösterilmiştir.

Burada hız sonuçları olarak verilen grafikler, parçacığın hızının tahmin edildiği model sonuçlarını göstermektedir. Hız o kadar değişik ve farklı değerler alabilmektedir ki, bu da kullanılan modeller tarafından yapılacak olan tahminleri güçleştirmektedir. Örneğin, aynı çerçeve içerisindeki bir parçacık, neredeyse bir sonraki çerçevede görülemeyecek kadar hızlı ilerlerken; diğer bir parçacık ise neredeyse duruyormuş gibi yavaş ilerlemektedir. Bu da, hız tahmin probleminin çok zorlayıcı bir problem olmasına neden olmaktadır. Açısal yön olarak bahsedilenler ise, parçacığın yatayla kaç derece açı yaparak ilerlediğini, buna bağlı olarak da parçacığın hangi yöne doğru ilerlediğini tahmin etmek için elde edilmiş sonuçları vermektedir. Bu çalışmada 0 ile 180 derece açı arasında değerler üzerinde tahminler yapılmaya çalışıldığından, tahmini oldukça zor olan bir problemdir. Çünkü 0 ile 180 derece arasındaki tüm küsuratlı değerler de, tahmin edilecek aralığa dahil olmaktadır. Açısal yön dışında, yönlerin Tablo 1’ de olduğu gibi sayılarla eşleştirilerek sisteme öğretildiği ve buna göre tahminlerin yapıldığı problemler de bulunmaktadır. Örneğin, model çıktısı 1 olduğunda, bu bize parçacığın kuzeydoğu yönünde hareket ettiğini göstermektedir. Parçacık yön tahmininde, parçacıkların düzenli bir davranış sergilememeleri, problemin zor bir probleme dönüşmesine neden olmakta, bu da modellerin tahmin kabiliyetini düşürmektedir. Özellikle boru açısının derecesi arttıkça, yerçekiminin etkisiyle akışın tersine doğru hareket eden parçacıklar bulunmaktadır. Normalde akışla aynı yönde ilerlemesi beklenen parçacıkların, bu gibi durumlarla başka yönlerde ilerlemeleri, tahmin probleminin zorlaşmasına sebep olmaktadır.

Aşağıda verilen grafiklerde, eğitim verileri olarak bahsedilenler, yapay zekâ modellerinin eğitimi sırasında kullanılmış olan verilerdir. Bu veriler aynı zamanda, test için kullanılmış ve eğitilen yapay zekâ modelinin ne kadar başarılı öğrendiği kontrol edilebilmiştir. Test verisi olarak bahsedilenler, modelin daha önce görmediği, eğitim sırasında hiç kullanılmamış olan verilerdir. Daha önce eğitim verileri ile eğitilmiş olan model, bu eğitimde öğrendiklerinden yola çıkarak test verileri için kararlar vermektedir. Burada tüm veriler olarak kastedilen ise, eğitim ve test verilerinin bir arada kullanıldığı durumdur. Yani, model eğitim verileri ile eğitilir ama hem eğitim hem de test verileri bir arada kullanılarak test edilir. Modellerin performans metrikleri de eğitim verileri ile test verileri sonucunda elde edilen veriler kullanılarak ayrı ayrı hesaplanmış ve yapay zekâ modellerinin performansları bu şekilde değerlendirilmiştir.

Sonuçlar elde edilirken ve performans metrikleri hesaplanırken kullanılan hız birimi metre/saniye, açı birimi ise derece açı cinsindedir.

### **7.2.1 Hız Tahmin Sonuçları**

Bu bölümde, yatay borulardan, 15 derece ve 30 derece açılı borulardan elde edilmiş verilere ait hız tahmin sonuçlarının grafiksel gösterimleri sırasıyla verilmiştir. Grafiklerde, eğitim verilerine, test verilerine ve bu verilerinin tamamına ait hız tahmin sonuçları ayrı ayrı gösterilmiştir. Hız tahmini sırasında kullanılan verilerin, %50' si modelleri eğitmek için kullanılırken, kalan %50' si ise modellerin test edilmesi için kullanılmıştır. Tahminler yapılırken, doğrusal regresyon, doğrusal olmayan regresyon, yapay sinir ağı ve destek vektör regresyonu modelleri kullanılmıştır.

Aşağıdaki grafiklerde, mavi çemberler ile gösterilen değerler bulunan değerlere karşı olması gereken değerleri göstermektedir. Kırmızı düz çizgi ise bu mavi çemberlerin doğru sonuçlar verdiğiinde olması gereken yerleri temsil etmektedir. Yani mavi çemberler bu kırmızı çizgiden ne kadar uzakta ise bulunan değer gerçek değerden o kadar uzaklaşmış demektir. Mesela, Şekil 7.1 incelendiğinde eğitim verileri grafiğine

bakılırsa ölçülen değer olarak 4 çizgisi üzerindeki mavi çember, bulunan değerlerde 1,12 gibi bir değere karşılık gelmektedir. Bu değer için bulunan değer yanlış olmuştur. Eğer bulunan değer de 4 olmuş olsaydı mavi çember kırmızı çizgi üzerinde olacaktı ve bulunan sonuç doğru diyebilecektik. Tabi ki sonuçların %100 doğru olması beklenmediğinden 4 civarındaki sonuçları doğru kabul etmek yanlış olmayacaktır. Zaten, veri toplama sırasında dahi grafiksel olarak parçacığın yeri kesin olarak tespit edilemeyeceğinden bu şekilde bir yaklaşım yanlış olmayacaktır.


Modellerin tahmin sonuçları incelenirken, eğitim verilerinden elde edilen sonuçların, test verilerinden elde edilmiş sonuçlara göre daha başarılı olmasını beklemekteyiz. Çünkü eğitim verileri, modelin eğitimi için daha önceden modele gösterilmekte, test verileri ise herhangi bir amaçla önceden modele gösterilmemekte, sadece modelin test edilmesi için kullanılmaktadır. Şekil 7.1' e bakıldığında, eğitim verilerinin tahmin sonucu ile test verilerinin tahmin sonucu arasında çok fazla bir fark olmadığı görülmektedir. O halde, eğitim sırasında doğrusal regresyon modeli çok başarılı bir öğrenme gerçekleştirmemiştir diyebiliriz. Şekil 7.2' ye bakıldığında ise, Şekil 7.1' dekine göre, tüm sonuçların daha iyi olduğu gözlemlenmiştir. Demek ki, kullanılan veriler doğrusal bir dağılım göstermemekteler ve bu yüzden lineer olmayan bir model için daha uygunlardır yorumu yapılabilmektedir. Şekil 7.3' te, kullanılan YSA modeli tek bir gizli katmana, gizli katman da 100 tane nörona sahiptir. Sonuçlar incelendiğinde bu yapay sinir ağına ait eğitim ve test verilerinin tahmin sonuçlarının çok farklı çıkmadığı görülmektedir. Bu sonuçlar, Şekil 7.4' teki DVR sonuçları ile karşılaştırıldığında, şimdiye kadar bahsedilen modellerden elde edilen sonuçların DVR' ye göre daha başarısız olduğu görülmektedir. DVR modelinde eğitim verileri ve test verileri kullanılarak yapılmış olan tahmin sonuçlarına bakılırsa, eğitim verilerinden elde edilmiş olan sonuçların, test verilerinden elde edilmiş olan sonuçlara göre çok daha başarılı olduğu görülmektedir. O halde, DVR eğitim sırasında gösterilen verilerin hemen hepsini iyi bir şekilde öğrenmiş ve sonrasında doğru tahminlerde bulunmuştur.

Şekil 7.5 ve Şekil 7.6' da, hem eğitim hem de test verilerine ait sonuçların iyi olmadığı görülmektedir. Parçacıkların yerçekimi veya borunun eğim açısı gibi




etkilerle çok farklı hareket davranışları göstermesi tahmin problemini zorlaştırmakta ve buna bağlı olarak da modellerin tahmin kabiliyeti düşmektedir. Şekil 7.7’ de kullanılan YSA modeline ait grafikler incelendiğinde, eğitim verileri kullanılarak elde edilmiş sonuçların, test verileri kullanılarak elde edilmiş sonuçlardan daha iyi olduğu görülmektedir. Şekil 7.8’ de, DVR modelinin eğitim verilerine dayanan tahmin sonuçlarına bakıldığında, neredeyse hatasız tahminler yaptığı görülmektedir. Ancak test verilerinin sonuçları, eğitim verilerinin sonuçları kadar başarılı değildir. O halde, model eğitim verilerini fazla öğrenmiş veya ezberlemiştir denilebilmektedir.


Şekil 7.9 ve Şekil 7.10’ de verilen grafikler incelendiğinde, sonuçların çok başarılı olmadığı görülmektedir. Bu tahminler, 30 derece açılı borulardan elde edilmiş veriler olduğu için, parçacıkların ters yönde hareket etmesi de rastlanılan bir durumdur. Bu yüzden parçacıkların hareketinin tahmin edilmesi güçleşmektedir. Şekil 7.11’ de verilen grafikler incelendiğinde, bu modelin eğitim verilerinin sonuçlarının, lineer ve lineer olmayan regresyona göre daha iyi olduğu açıkça görülmektedir. Son olarak, Şekil 7.12’ te verilen DVR modeline ait tahmin sonuçları, diğerlerinde olduğu gibi 30 derece açılı borulardan elde edilmiş veriler üzerindeki tahminlerde de en başarılı yöntem olmuştur. Özellikle eğitim verilerine ait sonuçlara bakıldığında, çok küçük hatalarla tahminlerin yapılabildiği görülmektedir.




Şekil 7.1 : Yatay Borularda Doğrusal Regresyon Hız Sonuçları




Şekil 7.2 : Yatay Borularda Doğrusal Olmayan Regresyon Hız Sonuçları




Şekil 7.3 : Yatay Borularda YSA (1 Gizli Katman, 100 Nöron) Hız Sonuçları




Şekil 7.4 : Yatay Borularda DVR Hız Sonuçları




Şekil 7.5 : 15° Açılı Borularda Doğrusal Regresyon Hız Sonuçları




Şekil 7.6 : 15° Açılı Borularda Doğrusal Olmayan Regresyon Hız Sonuçları



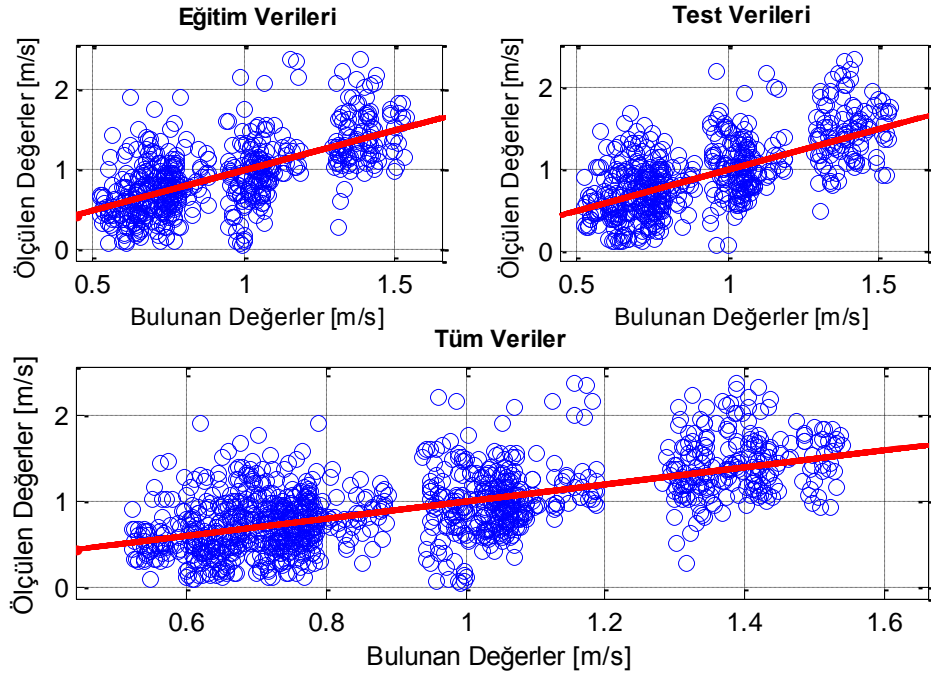
Şekil 7.7 : 15° Açılı Borularda YSA (1 Gizli Katman, 100 Nöron) Hız Sonuçları




Şekil 7.8 : 15° Açılı Borularda DVR Hız Sonuçları




Şekil 7.9 : 30° Açılı Borularda Doğrusal Regresyon Hız Sonuçları



Şekil 7.10 : 30° Açılı Borularda Doğrusal Olmayan Regresyon Hız Sonuçları



Şekil 7.11 : 30° Açılı Borularda YSA (1 Gizli Katman, 100 Nöron) Hız Sonuçları



Şekil 7.12 : 30° Açılı Borularda DVR Hız Sonuçları

## 7.2.2 Hız Sonuçlarını Performans Metriklerine Göre Karşılaştırma

Sonuçların karşılaştırılmasının yapılması için, RMSE, MPE, MAPE,  $r$ ,  $R^2$ , VAF yöntemleri kullanılmıştır. Bu metrikler hesaplanırken, eğitim ve test verileri ayrı ayrı ele alınmış ve sonuçlar irdelenmiştir. Yukarıda incelediğimiz grafiklere ait performans metriklerinin sonuçlarına bakıldığında, parçacık hız tahmini için oluşturulan modellerden, destek vektör regresyonunun gerek yatay borularda gerekse 15 ve 30 derece açılı borularda diğer yöntemlere nazaran çok daha başarılı sonuçlar verdiği gözlemlenmiştir.

Tablo 2 ve Tablo 3' te yatay borulardan elde edilmiş verilere ait, eğitim ve test verileri kullanılarak yapılmış olan tahmin sonuçları gösterilmektedir. Tablo 2 ve Tablo 3' te verilen sonuçlar incelendiğinde, eğitim verilerinden elde edilen hız sonuçlarına ait hata değerlerinin, test verilerinden elde edilen hata değerlerinden daha küçük olduğu gözlemlenmektedir. Yani model görmediği test verileri ile kullanıldığında başarı oranı düşmektedir. Tablo 2 ve Tablo 3' te test verilerine ait

sonular incelendiĐinde, en bařarısız yntem YSA olurken, en bařarılı yntemin DVR olduĐu grlmektedir.

Tablo 4 ve Tablo 5’ te 15 derece aılı borulardan elde edilmiř verilere ait sonular verilmiřtir. Tablo 4 ve Tablo 5’ te eĐitim verilerine ait sonular incelendiĐinde, tm performans metrikleri tarafından en bařarılı yntem DVR olarak gsterilirken, en bařarısız yntem ise doĐrusal olmayan regresyon olmuřtur. Ayrıca tablolar ayrı ayrı ele alındıĐında, eĐitim verilerinin sonularının, test verilerinin sonularından daha bařarılı olduĐu da aıka grlmektedir.

Tablo 6 ve Tablo 7, 30 derece aılı borulardan elde edilmiř verilere ait sonuları gstermektedir. EĐitim verilerinden elde edilmiř sonuları gsteren Tablo 6 ve Tablo 7 incelendiĐinde, hata metriklerine gre en iyi yntemin DVR, en kt yntemin ise doĐrusal olmayan regresyon olduĐu grlmektedir.

**Tablo 2:** Yatay Borularda EĐitim Verileri iin Hız Sonuları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>DoĐrusal Regresyon</b>	0.4854	27.9351	45.4372	0.6981	0.4873	48.7292
<b>DoĐrusal Olmayan Regresyon</b>	0.4624	27.6637	45.6589	0.7312	0.5347	53.4687
<b>YSA</b>	0.6480	-5.0293	49.8908	0.7666	0.5877	8.6114
<b>DVR</b>	0.2001	8.3793	16.6375	0.9581	0.9180	91.2882



**Tablo 3:** Yatay Borularda Test Verileri için Hız Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	0.4998	34.5680	54.1072	0.6925	0.4796	47.9590
<b>Doğrusal Olmayan Regresyon</b>	0.4854	35.9091	56.2846	0.7139	0.5097	50.9611
<b>YSA</b>	0.7810	-3.7084	60.6165	0.6899	0.4759	-27.1544
<b>DVR</b>	0.2958	16.3137	30.4830	0.9061	0.8211	81.7809

**Tablo 4:** 15 Derece Açılı Borularda Eğitim Verileri için Hız Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	0.3040	16.5660	34.5051	0.7277	0.5296	52.9587
<b>Doğrusal Olmayan Regresyon</b>	0.3287	20.9822	39.8098	0.6710	0.4503	45.0261
<b>YSA</b>	0.2606	6.3326	26.1953	0.8161	0.6660	65.8599
<b>DVR</b>	0.0224	0.9415	1.9508	0.9990	0.9979	99.7788

**Tablo 5:** 15 Derece Açılı Borularda Test Verileri için Hız Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	0.3159	21.4186	39.6165	0.6990	0.4886	48.8641
<b>Doğrusal Olmayan Regresyon</b>	0.3397	28.2773	45.3778	0.6456	0.4168	41.5698
<b>YSA</b>	0.3296	12.4617	37.9413	0.7069	0.4997	44.4324
<b>DVR</b>	0.2728	17.3288	33.9399	0.7909	0.6255	61.9265

**Tablo 6:** 30 Derece Açılı Borularda Eğitim Verileri için Hız Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	0.3261	27.0120	46.0266	0.6836	0.4673	46.7329
<b>Doğrusal Olmayan Regresyon</b>	0.3472	31.1651	50.7338	0.6296	0.3964	39.6355
<b>YSA</b>	0.2767	1.9710	28.5507	0.8104	0.6568	62.8761
<b>DVR</b>	0.0574	3.8698	5.6389	0.9925	0.9850	98.4248

**Tablo 7:** 30 Derece Açılı Borularda Test Verileri için Hız Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	0.3075	18.0483	38.1866	0.7273	0.5290	52.8620
<b>Doğrusal Olmayan Regresyon</b>	0.3365	23.4739	44.6063	0.6597	0.4352	43.4137
<b>YSA</b>	0.3248	2.1124	34.3784	0.7461	0.5567	50.8392
<b>DVR</b>	0.2623	13.8921	31.7290	0.8113	0.6581	65.7810

### 7.2.3 Açısal Yön Tahmin Sonuçları

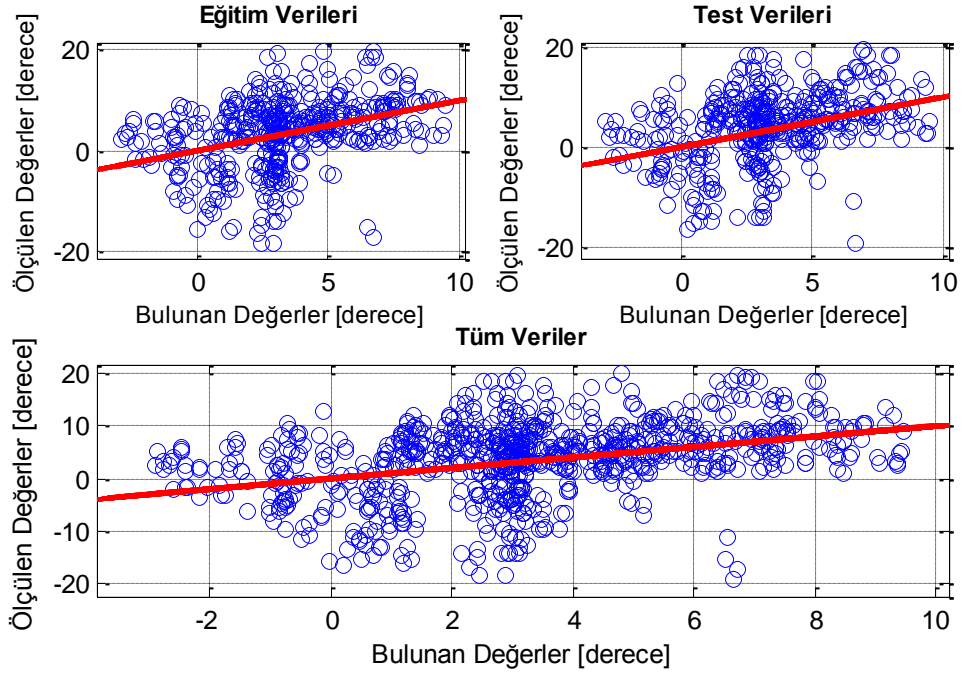
Bu bölümde, yatay borulardan, 15 derece açılı borulardan ve 30 derece açılı borulardan elde edilmiş verilere ait açısal yön tahmin sonuçlarının grafiksel gösterimleri sırasıyla verilmiştir. Sonuçlar, hız tahmin sonuçlarında olduğu gibi, eğitim verileri ve test verileri için ayrı ayrı gösterilmiştir. Açısal yön tahmini yapılırken, eldeki verilerin yarısı eğitim, kalan yarısı ise test için kullanılmıştır. Açısal yön tahminleri yapılırken, doğrusal regresyon, doğrusal olmayan regresyon, yapay sinir ağı, destek vektör regresyonu modelleri kullanılmıştır. Verilerin elde edildiği parçacıkların, çok farklı hareket davranışlarına sahip olması ve benzer koşullarda farklı hareketlerde bulunması, tahmin probleminin zorluğunu arttırmaktadır. Özellikle boru açısı arttıkça, akışlara etki eden yerçekimi kuvveti arttığı için parçacıkların geriye doğru hareket ettikleri bile gözlemlenmiştir. Tüm bunlar göz önüne alındığında, tahmin sonuçlarındaki hatalar kabul edilebilir olabilmektedir.

Şekil 7.13 ve Şekil 7.14' de verilen grafikler incelendiğinde, doğrusal olmayan regresyona ait sonuçların, doğrusal regresyona ait sonuçlardan daha iyi çıktığı


görülmektedir. Bu da, kullanılan verilerin doğrusal bir dağılıma sahip olmadığını göstermektedir. Şekil 7.14’ de verilen YSA modeli incelendiğinde, eğitim verilerine ait sonuçların, test verilerine ait sonuçlardan daha iyi olduğu görülmektedir. Bu model, doğrusal ve doğrusal olmayan regresyon modellerinin sonuçları ile karşılaştırıldığında, YSA modeline ait tahmin başarısının daha düşük olduğu görülmektedir. Şekil 7.16’ da DVR modelinin eğitim verilerine ait sonuçları incelendiğinde, verilerin neredeyse tamamına yakınının hatasız tahmin edildiği görülmektedir. Ancak aynı başarı, test verilerinin tahmin sonuçları için söylenememektedir.

Şekil 7.17 ve Şekil 7.18’ de verilen doğrusal ve doğrusal olmayan regresyonlara ait grafikler incelendiğinde, beklenenin aksine test verileri kullanılarak yapılmış olan tahmin sonuçlarının, eğitim verileri kullanılarak yapılmış olan tahmin sonuçlarından daha iyi olduğu görülmektedir. Şekil 7.19 ile verilen YSA modelinin grafikleri incelendiğinde, YSA’ nın eğitim verilerine ait sonuçları doğrusal ve doğrusal olmayan regresyonların sonuçlarından daha iyiyken, test verilerine ait sonuçları daha kötüdür. DVR modeline ait tahmin sonuçları Şekil 7.20 ile verilmiştir. DVR modelinin sonuçları incelendiğinde, eğitim verileri kullanılarak yapılmış olan tahminlerin, tamamına yakınının doğru olduğu gözlemlenmektedir. Model aynı başarıyı test verileri için gösteremese de, yine de başarılı tahminlerde bulunduğu söylenebilmektedir.


Şekil 7.21 ve Şekil 7.22 ile verilen modellerin sonuçları incelendiğinde, bu modellere ait önceki sonuçlara benzer olarak, başarılı olmayan sonuçlar elde edildiği görülmektedir. Ancak bu sonuçlar, Şekil 7.23’te verilen YSA’ ya ait sonuçlar ile karşılaştırıldığında, YSA modelinden daha başarılı oldukları görülmektedir. Son olarak, diğer durumlarda en başarılı olarak belirlenen DVR modeline ait grafik Şekil 7.24’ te verilmiştir. DVR’ ye ait buradaki grafikler incelendiğinde, eğitim verileri ile yapılan tahminlerin çok başarılı olduğu görülmektedir. Test verileri ile yapılan tahminin sonuçları, eğitim verileri ile yapılan tahminin sonucu kadar başarılı değildir, ancak diğer modellerle karşılaştırıldığında yine en başarılı tahminler bu model tarafından yapılmıştır.




Şekil 7.13 : Yatay Borularda Doğrusal Regresyon Açısıl Yön Sonuçları




Şekil 7.14 : Yatay Borularda Doğrusal Olmayan Regresyon Açısıl Yön Sonuçları




Şekil 7.15 : Yatay Borularda YSA (1 Gizli Katman, 100 Nöron) Açısıl Yön Sonuçları




Şekil 7.16 : Yatay Borularda DVR Açısıl Yön Sonuçları




Şekil 7.17 : 15° Açılı Borularda Doğrusal Regresyon Açısıl Yön Sonuçları



Şekil 7.18 : 15° Açılı Borularda Doğrusal Olmayan Regresyon Açısıl Yön Sonuçları




Şekil 7.19 : 15° Açılı Borularda YSA (1 Gizli Katman, 100 Nöron) Açısıl Yön Sonuçları




Şekil 7.20 : 15° Açılı Borularda DVR Açısıl Yön Sonuçları







Şekil 7.21 : 30° Açılı Borularda Doğrusal Regresyon Açısıl Yön Sonuçları



Şekil 7.22 : 30° Açılı Borularda Doğrusal Olmayan Regresyon Açısıl Yön Sonuçları



Şekil 7.23 : 30° Açılı Borularda YSA (1 Gizli Katman, 100 Nöron) Açısal Yön Sonuçları



Şekil 7.24 : 30° Açılı Borularda DVR Açısal Yön Sonuçları

#### 7.2.4 Açısal Yön Sonuçlarını Performans Metriklerine Göre Karşılaştırma

Bu bölümde, hız sonuçları için hesaplanan performans metriklerine benzer şekilde açısal yön sonuçları için performans metrikleri hesaplanmıştır. Yine aynı şekilde eğitim ve test verileri için bütün yöntemlere göre değerler ayrı ayrı hesaplanmış ve aşağıda her bir akış açısı için tablo olarak gösterilmiştir. Yatay borularda hem grafiklerden hem de performans metriklerinden RMSE, MAPE ve VAF değerlerine bakıldığında destek vektör regresyonu ile oluşturulan yapay zekâ modelinin diğer yöntemlerden daha üstün olduğu gözlemlenmiştir. Eğitim verilerine bakıldığında hem yatay borularda hem de 15 ve 30 derece açılı borularda SVR ile bulunan değerler gerçek değerlerine çok yakın çıkmakta ve diğer yöntemlere büyük fark atmaktadır. Genelde test verileri ile elde edilen sonuçlar eğitim verileri için elde edilen sonuçlardan daha kötü olsa da, destek vektör regresyonu test verileri kullanıldığında dahi diğer yöntemlere göre çok daha başarılı sonuçlar vermiştir.

Tablo 8 ve Tablo 9’ da, yatay borulardaki eğitim verilerinin tahmin sonuçları verilmiştir. Bu sonuçlar incelendiğinde, en başarısız yöntem doğrusal regresyon olmuştur. O halde, eğitim verileri doğrusal bir dağılım göstermemektedir yorumu yapılabilmektedir. Bu eğitim verilerinin en fazla öğretildiği model, performans metriklerinin sonuçlarına göre DVM olmuştur.

Tablo 10 ve Tablo 11’ de, 15 derece açılı borulardan elde edilmiş verilerin tahmin sonuçları verilmektedir. Tablo 10’ da verilen sonuçlar incelendiğinde, en başarısız yöntem doğrusal regresyon olurken, en başarılı yöntem DVM olmuştur. Eğitim verileri için DVM’ nin korelasyon katsayısı 0,9981 olarak hesaplanmış, bu da tahmin değerleri ile gerçek veriler arasındaki korelasyonun ne kadar yüksek olduğunu göstermiştir. Aynı değer, test verileri için 0,4199 olarak hesaplanmış, bu da test verileri için yapılan tahmin doğruluğunun daha düşük olduğunu göstermiştir.

Tablo 12 ve Tablo 13 ile 30 derece açılı borulardan elde edilmiş olan veriler kullanılarak yapılan tahminlerin sonuçları gösterilmiştir. Bu iki tabloda verilen sonuçlar dikkate alındığında, en başarılı yöntem yine değişmemiş ve DVM olmuştur. Eğitim verileri için 0,9901 korelasyon değeri ile tahminler yapmış olan DVR, test

verileri için bu değeri 0,4487' ye düşürmüştür. Ancak bu düşüş, her iki veri seti için DVR' nin en başarılı yöntem olmasını engelleyememiştir.

**Tablo 8:** Yatay Borularda Eğitim Verileri için Açısal Yön Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	6.4650	-5.2e-16	2.7398	0.3663	0.1342	13.4211
<b>Doğrusal Olmayan Regresyon</b>	6.1254	-0.0128	2.6079	0.4721	0.2229	22.2799
<b>YSA</b>	6.3978	0.2308	2.3387	0.6045	0.3654	15.5688
<b>DVR</b>	1.1373	-0.1542	0.3723	0.9879	0.9759	97.4803

**Tablo 9:** Yatay Borularda Test Verileri için Açısal Yön Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	6.3407	-0.3198	2.7052	0.3797	0.1442	14.4130
<b>Doğrusal Olmayan Regresyon</b>	6.0600	-0.3282	2.6200	0.4682	0.2192	21.9227
<b>YSA</b>	7.6271	0.0065	3.0683	0.4811	0.2314	-24.8660
<b>DVR</b>	5.6624	-0.5949	2.2149	0.6110	0.3734	33.6398

**Tablo 10:** 15 Derece Açılı Borularda Eğitim Verileri için Açısal Yön Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	9.2445	5.4e-16	3.8045	0.1949	0.0380	3.7967
<b>Doğrusal Olmayan Regresyon</b>	9.1830	-0.0019	3.7372	0.2254	0.0508	5.0706
<b>YSA</b>	8.9624	0.4099	3.6379	0.4665	0.2176	10.1908
<b>DVR</b>	0.9035	-0.3781	0.4051	0.9981	0.9963	99.6025

**Tablo 11:** 15 Derece Açılı Borularda Test Verileri için Açısal Yön Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	8.7877	0.0650	3.6374	0.1510	0.0228	2.1005
<b>Doğrusal Olmayan Regresyon</b>	8.7346	-0.0454	3.5215	0.1855	0.0344	3.2706
<b>YSA</b>	10.4269	0.4132	4.3763	0.2588	0.0670	-37.1504
<b>DVR</b>	8.2967	-0.5667	3.2025	0.4199	0.1763	14.0380


**Tablo 12:** 30 Derece Açılı Borularda Eğitim Verileri için Açışal Yön Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	9.0362	-2.4e-16	3.7081	0.2244	0.0503	5.0346
<b>Doğrusal Olmayan Regresyon</b>	9.0952	-0.0572	3.7230	0.1955	0.0382	3.8027
<b>YSA</b>	11.9150	-3.2567	5.0113	0.3643	0.1327	-25.1454
<b>DVR</b>	1.6371	-0.0774	0.6022	0.9901	0.9803	96.9055

**Tablo 13:** 30 Derece Açılı Borularda Test Verileri için Açışal Yön Sonuçları

<b>MODELLER</b>	<b>RMSE</b>	<b>MPE</b>	<b>MAPE</b>	<b>r</b>	<b>R<sup>2</sup></b>	<b>VAF</b>
<b>Doğrusal Regresyon</b>	9.1423	0.3378	3.7342	0.1339	0.0179	1.2467
<b>Doğrusal Olmayan Regresyon</b>	9.2507	0.3118	3.8079	0.0582	0.0034	-1.1857
<b>YSA</b>	12.8159	-2.9782	5.3571	0.2371	0.0562	-60.8201
<b>DVR</b>	8.2288	-0.2563	3.2954	0.4487	0.2013	19.8928

## 7.2.5 Yön Tahmin Sonuçları




Şekil 7.25 : Yatay Borularda DVM Yön Sınıflandırma Sonuçları

Tablo 14: Yatay Borularda DVM Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
		-3	-2	-1	0	1	2	3	4
Gerçek Değerler	-3	1	0	0	0	0	0	0	0
	-2	0	14	16	0	0	0	0	0
	-1	0	0	701	0	0	0	0	0
	0	0	0	62	51	0	0	0	0
	1	0	0	110	0	105	0	0	0
	2	0	0	30	0	0	28	0	0
	3	0	0	0	0	0	0	0	0
	4	0	0	0	0	0	0	0	1

Yön sınıflandırması yaparken, yatay borularda toplamda 1119 adet veri kullanılmış olup eğitim verileri bu veriler içerisinde seçilen 560 adet veridir. Eğitim verileri ile oluşturulan DVM sınıflandırma modeli ile eğitim verileri test edildiğinde Şekil 7.25'te verilen histogramdan da anlaşılacağı gibi 0 hata ile tespit edilebilen veri sayısı 560, test verileri ile test edildiğinde 0 hata ile tespit edilebilen veri sayısı ise 341'dir. Daha önceki bölümlerde belirtildiği üzere yönler -3' ten 4' e kadar numaralandırılmış ve hata farkları bu değerlere göre hesaplanmıştır. Yani, -2 yönünde olması gerekirken DVM modeli ile bulunan yön değeri -1 ise arada 45 derecelik bir fark vardır ve bu kadarlık bir hata ile tahmin yapılmış demektir.

Toplamda 218 adet yön hatalı olarak tespit edilmiştir ancak bu hatalı değerler çok farklı sonuçlar vermemiştir. Bu sonuçlar dikkate alındığında, DVM ile oluşturulan modelin %80,5' lik bir doğruluk payı ile yön tahmini yapabildiği tespit edilmiştir. Tablo 14 ise, her bir yön değeri için, tahmin süresince elde edilmiş sonuçları ve bu sonuçların kaçar kez elde edildiğini göstermektedir. Tablo incelendiğinde, -1 yönünde ilerleyen parçacık verisinden 701 adet olduğu ve tahmin neticesinde tamamının doğru bulunduğu görülmektedir. -1 yönünde ilerleyen parçacık verisi sayısının çok olması, bu başarıyı sağlayan bir etkidir.



Şekil 7.26 : Yatay Borularda YSA (1 katman 100 nöron) Yön Sınıflandırma Sonuçları


Tablo 15: Yatay Borularda YSA (1 katman 100 nöron) Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
		-3	-2	-1	0	1	2	3	4
Gerçek Değerler	-3	0	0	1	0	0	0	0	0
	-2	0	7	21	2	0	0	0	0
	-1	5	43	507	119	25	1	1	0
	0	0	4	47	58	4	0	0	0
	1	0	2	49	68	92	3	1	0
	2	0	2	6	5	12	27	4	2
	3	0	0	0	0	0	0	0	0
	4	0	0	0	1	0	0	0	0

Yapay sinir ağları ile gerçekleştirilen eğitimde, DVM' de kullanılan ile aynı miktarda ve özellikle veri kullanılmıştır. Histogram' daki verilere bakıldığında hatasız yön



tahmini yapılan veri sayısı eğitim verileri için 381, test verileri için 310' dur. Bu modelde, 100 nöron içeren 1 adet gizli katman ve 1 adet çıkış katmanı kullanılmıştır. Sonuç olarak oluşturulan modelin %61,8' lik bir doğruluk payı ile tahmin yaptığı hesaplanmıştır. Daha önce DVM modelinin, 701 adet -1 yönünde ilerleyen parçacık verisinin tamamını doğru tahmin ettiğinden bahsetmiştik. Aynı özellikteki veri için Tablo 15 incelendiğinde ise, YSA modeli kullanıldığında doğru tahmin sayısının 507'e düştüğü görülmektedir.




Şekil 7.27 : Yatay Borularda YSA (2 katman 50 nöron) Yön Sınıflandırma Sonuçları

Tablo 16: Yatay Borularda YSA (2 katman 50 nöron) Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
		-3	-2	-1	0	1	2	3	4
Gerçek Değerler	-3	0	0	0	1	0	0	0	0
	-2	0	9	15	6	0	0	0	0
	-1	6	19	513	118	34	9	2	0
	0	2	6	36	58	10	0	0	1
	1	3	6	26	67	99	13	1	0
	2	1	0	6	4	8	33	6	0
	3	0	0	0	0	0	0	0	0
	4	0	0	0	0	1	0	0	0

Bu modelde gizli katman sayısı 2 olarak ele alınmış ve her bir gizli katmanda 50 nöron olacak şekilde yön tahmin modeli oluşturulmuştur. İlk bakışta tek katmanlı YSA modeli ile benzer sonuçlar verdiği gözlemlense de, histogramdan alınan bilgiler

incelendiğinde eğitim verileri için daha iyi sonuç verdiği ancak test verileri için daha düşük bir performans sergilediği rahatlıkla söylenebilir. Bu modelde eğitim verileri için 412, test verileri için ise 300 adet hatasız yön tahmini yapılmıştır. Bu model ile toplamda %63,6 'lık doğruluk payı ile yön tahmini gerçekleştirilmiştir. Daha önceki modellerde, -1 yönünde ilerleyen parçacığa ait 701 adet yön bilgisi için, DVM tamamını doğru tahmin ederken, tek katmanlı YSA' nın 507 tanesini doğru tahmin ettiğinden bahsetmiştik. Tablo 16 incelendiğinde ise, bu model için doğru tahmin sayısının 513 olduğu görülmektedir.




Şekil 7.28 : 15 Derece Borularda DVM Yön Sınıflandırma Sonuçları

Tablo 17: 15 Derece Borularda DVM Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
		-3	-2	-1	0	1	2	3	4
Gerçek Değerler	-3	18	0	19	0	0	0	0	0
	-2	0	5	8	0	0	0	0	0
	-1	0	0	771	0	1	0	0	0
	0	0	0	70	59	0	0	0	0
	1	0	0	121	1	129	0	0	0
	2	0	0	3	0	0	3	0	0
	3	0	0	7	0	0	0	9	0
	4	0	0	6	0	0	0	0	5

Toplamda 1235 adet veri kullanılmış olup eğitim verileri bu veriler içerisinde seçilen 618 adet veridir. DVM sınıflandırma modeli ile test yapıldığında Şekil 7.28’de verilen histogramda da görülebileceği gibi 0 hata ile tespit edilebilen veri sayısı eğitim verileri için 618, test verileri için ise 381’ dir. Buradan görüldüğü gibi, DVM modeli eğitim verilerinin tamamını doğru tahmin ederken, test verilerinin de yarıdan fazlasını doğru olarak tahmin etmiştir. Bu sonuçlardan DVM ile oluşturulan modelin %80,9’ luk bir doğruluk payı ile yön tahmini yapabildiği tespit edilmiştir. Tablo 17 ile verilen sonuçlar incelendiğinde, -1 yönünde ilerleyen parçacık verisinden 772 adet olduğu ve tahmin neticesinde bunların 771 tanesinin doğru bulunduğu görülmektedir.

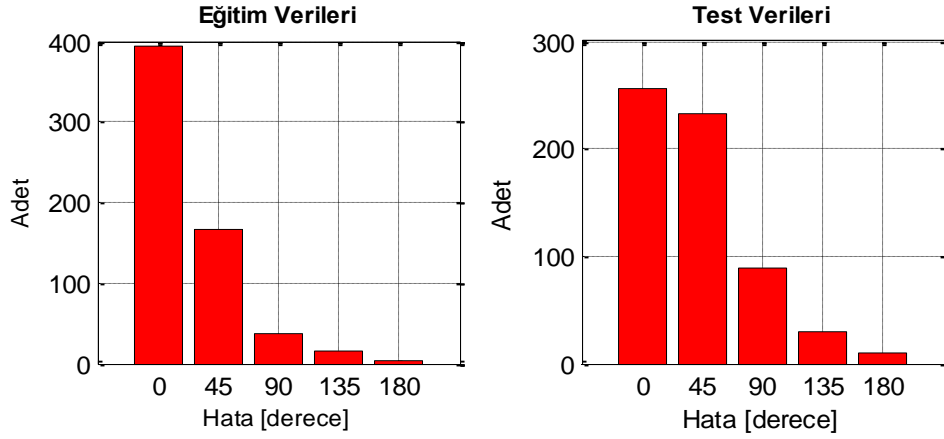


Şekil 7.29 : 15 Derece Borularda YSA (1 katman 100 nöron) Yön Sınıflandırma Sonuçları

Tablo 18: 15 Derece Borularda YSA (1 Katman 100 Nöron) Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
		-3	-2	-1	0	1	2	3	4
Gerçek Değerler	-3	13	6	8	4	3	3	0	0
	-2	0	4	4	4	0	0	0	1
	-1	18	60	479	165	36	12	1	1
	0	1	5	43	64	11	3	1	1
	1	3	7	53	91	84	9	3	1
	2	0	0	1	1	1	3	0	0
	3	0	2	1	3	1	6	3	0
	4	0	0	1	1	1	3	4	1

Yapay sinir ağları ile gerçekleştirilen eğitim de, yine aynı miktarda veri ile gerçekleştirilmiştir. Şekil 7.29’ daki histogramlarda görüldüğü gibi, hatasız yön tahmini yapılan veri sayısı eğitim verileri için 390, test verileri için 261’ dir. Eğitim verileri sayısı 618 olmasına rağmen, eğitim verilerinde bile fazlaca hatalı tahmin yapılmış ve düşük bir tahmin oranına ulaşılmıştır. 100 nöron ve 1 adet gizli katman içeren bu modelin, %52,7’ lik bir doğruluk payı ile tahmin yaptığı hesaplanmıştır. Tablo 18 incelendiğinde, hangi yön için kaç tane doğru tahmin sayısı olduğuna ve yanlış yapılan tahminlerin neler olduğu bilgisine ulaşılabilmektedir. Tabloda, -1 yönünde ilerleyen parçacık için tahmin sonuçları incelenirse 479 adet verinin doğru bulunduğu görülmektedir. DVM modelinin, aynı özellikteki veriler için doğru tahmin sayısı 771 iken, bu oranın tek gizli katmana sahip olan YSA modeli için düştüğü görülmektedir.




Şekil 7.30 : 15 Derece Borularda YSA (2 katman 50 nöron) Yön Sınıflandırma Sonuçları

Tablo 19: 15 Derece Borularda YSA (2 katman 50 nöron) Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
		-3	-2	-1	0	1	2	3	4
Gerçek Değerler	-3	7	12	5	7	4	2	0	0
	-2	0	3	3	5	2	0	0	0
	-1	6	45	476	181	43	15	5	1
	0	0	3	25	80	17	3	1	0
	1	2	6	54	106	77	6	0	0
	2	0	0	0	3	1	2	0	0
	3	0	2	2	3	3	2	4	0
	4	0	1	1	0	5	1	1	2

Şekil 7.30 ile verilen modelde, eğitim verileri için 395, test verileri için ise 256 adet hatasız yön tahmini yapılmıştır. Performansı arttırabilmek için, bu modelde gizli katman sayısı 2 olarak ele alınmış ve her bir gizli katmanda 50 nöron olacak şekilde yeni bir yön tahmin modeli oluşturulmuştur. Ancak yapılan değişiklikler sonucu çok fazla değiştirmemiş, tek katmanlı YSA modeli ile benzer sonuçlar vermiştir. Tek bir gizli katmana sahip YSA modeli, -1 yönündeki verilerin 479 tanesini doğru bulurken, gizli katman sayısının 2 olduğu bu modelde doğru tahmin sayısı 476 olmuştur. Bu model ile toplamda %52,7 'lik bir doğruluk oranı ile yön tahmini gerçekleştirilmiştir.




Şekil 7.31 : 30 Derece Borularda DVM Yön Sınıflandırma Sonuçları

Tablo 20: 30 Derece Borularda DVM Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
		-3	-2	-1	0	1	2	3	4
Gerçek Değerler	-3	198	0	0	187	0	0	0	0
	-2	0	6	0	6	0	0	0	0
	-1	0	0	313	325	0	0	0	0
	0	0	0	0	226	0	0	0	0
	1	0	0	0	62	63	0	0	0
	2	0	0	0	4	0	4	0	0
	3	0	0	0	46	0	0	45	0
	4	0	0	0	34	0	0	0	33

Toplamda 1552 adet veri kullanılmış olup eğitim verileri bu veriler içerisinde seçilen 776 adet veridir. DVM sınıflandırma modeli ile test yapıldığında Şekil 7.31’de verilen histogramda da görülebileceği gibi 0 hata ile tespit edilebilen veri sayısı eğitim verileri için 776, test verileri için ise 112’ dir. Buradan görüldüğü gibi, DVM modeli eğitim verilerinin tamamına yakınına doğru bulunurken, bu oran test verilerinde düşmektedir. Bu sonuçlardan DVM ile oluşturulan modelin %57,2’ lik bir doğruluk payı ile yön tahmini yapabildiği tespit edilmiştir. Bundan önce boru açısının 30 dereceden az olduğu durumlarda sonuçların daha iyi olduğu gözlemlenmiştir. Buradaki sonuçların daha kötü olmasının nedeni, açının büyüklüğü sebebiyle yerçekimi etkisi artmış, buna bağlı olarak akışın tersine ilerleyen parçacık verileri bulunmaktadır. Verilerin bu şekilde farklı davranışlara sahip olması, tahmin yapmayı güçleştirmekte ve başarıyı düşürmektedir. Tablo 20 incelendiğinde, -1 yönünde ilerleyen 638 tane verinin 313 tanesinin hatasız bulunduğu, 325 tanesinin ise 45 derece hata ile tahmin edildiği görülmektedir.




Şekil 7.32 : 30 Derece Borularda YSA (1 katman 100 nöron) Yön Sınıflandırma Sonuçları

**Tablo 21:** 30 Derece Borularda YSA (1 katman 100 nöron) Yön Sınıflandırma Sonuçları ve Adetleri

		Tahmin Edilen Değerler							
Gerçek Değerler		-3	-2	-1	0	1	2	3	4
	-3	208	83	44	28	15	5	2	0
	-2	1	3	3	2	2	1	0	0
	-1	12	98	357	137	27	6	1	0
	0	0	4	27	148	45	2	0	0
	1	1	9	26	52	35	2	0	0
	2	0	0	0	3	3	2	0	0
	3	1	4	18	26	22	12	6	2
	4	1	2	5	20	27	7	4	1

Yapay sinir ağları ile gerçekleştirilen eğitim de yine aynı miktarda veri ile gerçekleştirilmiştir. 1 gizli katman ve 100 nörona sahip bu tahmin modeli ile hatasız yön tahmini yapılan veri sayısı eğitim verileri için 426, test verileri için 334' tür. Test verilerinden elde edilen tahmin başarısının, DVM' ninkine yakın olduğu görülmektedir. Bu sonuçlardan YSA ile oluşturulan bu modelin %49' luk bir doğruluk payı ile yön tahmini yapabildiği tespit edilmiştir. Tablo 21 incelendiğinde, doğru bulunanların yanında, yön değerlerinin her biri için çok farklı sonuçların da bulunabildiği görülmektedir. Sonuçlar DVM ile karşılaştırıldığında, -1 yönü için hatasız bulduğu tahmin sayısı daha fazlayken, tüm yönler için sonuçlar incelendiğinde DVM' den daha başarısız olduğu görülmektedir.



**Şekil 7.33 :** 30 Derece Borularda YSA (2 katman 50 nöron) Yön Sınıflandırma Sonuçları

**Tablo 22 :** 30 Derece Borularda YSA (2 katman 50 nöron) Yön Sınıflandırma Sonuçları ve Adetleri

		<b>Tahmin Edilen Değerler</b>							
<b>Gerçek Değerler</b>		<b>-3</b>	<b>-2</b>	<b>-1</b>	<b>0</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>
	<b>-3</b>	194	74	36	43	30	8	0	0
	<b>-2</b>	0	1	3	2	5	1	0	0
	<b>-1</b>	7	35	395	151	42	8	0	0
	<b>0</b>	0	2	20	141	59	2	2	0
	<b>1</b>	0	0	14	58	43	10	0	0
	<b>2</b>	0	0	0	1	2	5	0	0
	<b>3</b>	1	4	10	27	26	23	0	0
	<b>4</b>	0	1	4	12	28	21	1	0

Şekil 7.33 ile verilen 2 gizli katmanı olan YSA modelinde, eğitim verileri için 406, test verileri için ise 373 adet hatasız yön tahmini yapılmıştır. 1 gizli katmanı olan YSA' ya göre daha başarılı tahminler yaptığı görülmektedir. Bu model ile toplamda %50,2 'lik bir doğruluk oranı ile yön tahmini gerçekleştirilmiştir.



## 8. GELECEK ÇALIŞMALAR

Eksantrik borulardaki çok fazlı akıřlarda, parçacığın hızının ve yönünün tahmin edilebilmesi ile ilgili literatürde henüz bir çalışma bulunmamaktadır. Bu eksiklik nedeniyle, bu çalışmadan elde edilen sonuçların başka sonuçlarla karşılaştırılması mümkün olmamıştır. Ancak, bu çalışma kapsamında elde edilen sonuçların daha iyileştirilmesi sağlanmaya çalışılabilir. Bu çalışmadaki veri sayısı daha fazla artırılarak, modellerin daha sağlıklı sonuçlar vermesi sağlanabilir. Çünkü boru içerisindeki parçacıklar çok deęişken hareketler göstermekte, bu da modellerin daha fazla bilgiye ihtiyaç duymasına sebep olmaktadır. Örneğin yan yana duran iki parçacıktan bir tanesi ileri doğru bir hareket gösterirken, dięeri geri doğru bir hareket gösterebilmektedir veya bir parçacık çok hızlı ilerlerken, yanındaki parçacığın ilerleme hızı çok düşük olabilmektedir. Bu yüzden veri sayısı ne kadar çok olursa, kullanılan modeller de o kadar iyi sonuç verecektir. Bu çalışmada, video çerçevelerinden veri elde edilirken el yordamı kullanılmıştır. İleride yapılacak çalışmalarda bu veriler, görüntü işleme teknikleri kullanılarak daha sağlıklı şekilde elde edilebilir. Boru içerisindeki akıřlarda, akıřların üst kısımlarının daha hızlı, alt kısımlarının ise daha yavaş aktığından daha önce bahsetmiřtik. Gelecek çalışma olarak, çok fazla veri yardımı ile bu tabakaların belirlenmesi sağlanabilir. Bu çalışma kapsamındaki tüm tahminler parçacığın bir çerçeve sonrasında hangi yöne ve ne kadar bir hızla ilerlediğini belirlemek için yapılmıştır. İleride yapılacak çalışmalarda, parçacığın bir sonraki çerçevede deęil de, birkaç çerçeve sonra nerede olacağı, nasıl bir davranış sergileyeceęi de tahmin edilmeye çalışılabilir.

## KAYNAKLAR

- [1] T.P.A.O.G Müdürlüğü., *2011 Yılı Hampetrol ve Dogal Gaz Sektör Raporu*, 2012.
- [2] Sönmez, H., *Sondaj Tekniği*, Hacettepe Üniversitesi.
- [3] Aydoğan, D., *Sondaj Tekniği*: İstanbul Üniversitesi.
- [4] Gürsu Sondaj, Erişim Adresi: <http://www.sondajisleri.com/sondaj-isleri/su-kuyusu-acma.html>, Erişim Tarihi: 5 Şubat 2013.
- [5] Özdemir, A., *Petrol Ve Doğalgaz Sondaj Tekniğinin Esasları*, Sondajcılar Birliği Bilimsel ve Teknik Danışma Kurulu.
- [6] Yüksel, H.E., 2010, *Halkasal Eksantrik Borularda Akış Özelliklerinin Dijital Görüntü İşleme Ve Yapay Zeka Teknikleri Kullanarak Tespiti*, Yüksek Lisans Tezi, Tobb Ekonomi Ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [7] Azar, J.J., Sanchez, R. Alfredo, The University of Tulsa, *Important Issues in Cuttings Transport for Drilling Directional Wells*, in *Latin American and Caribbean Petroleum Engineering Conference*, Society of Petroleum Engineers: Rio de Janeiro, Brazil, 1997.
- [8] Adrian, R.J., *Twenty Years Of Particle Image Velocimetry*. *Experiments in Fluids*, 39(2): p. 159-169, 2005
- [9] Shi, H.-x., *Experimental Research of Flow Structure in A Gas-Solid Circulating Fluidized Bed Riser by PIV*, *Journal of Hydrodynamics*, 19(6): p. 712-719, Ser. B, 2007
- [10] Lindken, R., L. Gui, and W. Merzkirch, *Velocity Measurements in Multiphase Flow By Means Of Particle Image Velocimetry*. *Chemical Engineering and Technology*, 22(3): p. 202-206, 1999.
- [11] Ozbayoglu, A.M. and H.E. Yuksel, *Estimation of Multiphase Flow Properties Using Computational Intelligence Models*. 2011.
- [12] Zhou, Y., F. Chen, and B. Sun, *Identification Method of Gas-Liquid Two-phase Flow Regime Based on Image Multi-feature Fusion and Support Vector Machine*. *Chinese Journal of Chemical Engineering*, 16(6): p. 832-840, 2008.
- [13] Pilehvari, A.A., J.J. Azar, and S.A. Shirazi, *State-Of-The-Art Cuttings Transport in Horizontal Wellbores*, *SPE Drilling and Completion*, 14(3): p. 196-200, 1999.

- [14] Brown, N.P., P.A. Bern, and A. Weaver, *Cleaning Deviated Holes: New Experimental And Theoretical Studies*, 1989.
- [15] Gilberto, E.-P., S.-M. Rubén, and C.-C. Octavio, *Averaging Model For Cuttings Transport in Horizontal Wellbores*, *Journal of Petroleum Science and Engineering*. 55: p. 301-316.
- [16] Tomren, P.H., A.W. Iyoho, and J.J. Azar, *Experimental Study Of Cuttings Transport in Directional Wells*, *SPE Drilling Engineering*, 1(1): p. 43-56, 1986.
- [17] Sifferman, T.R. and T.E. Becker, *Hole Cleaning in Full-Scale Inclined Wellbores*, *SPE Drilling Engineering*, 7(2): p. 115-120, 1992.
- [18] Ozbayoglu, E.M., et al. *Estimating Critical Velocity To Prevent Bed Development For Horizontal-Inclined Wellbores*, 2007.
- [19] Peden, J.M., J.T. Ford, and M.B. Oyeneyin, *Comprehensive Experimental Investigation Of Drilled Cuttings Transport In Inclined Wells Including The Effects Of Rotation And Eccentricity*, 1990.
- [20] Ozbayoglu, E.M., et al. *Cuttings Transport with Foam in Horizontal & Highly-Inclined Wellbores*. 2003.
- [21] Ozbayoglu, M.E., et al., *Using Foam in Horizontal Well Drilling: A Cuttings Transport Modeling Approach*, *Journal of Petroleum Science and Engineering*, 46(4): p. 267-282, 2005.
- [22] Ford, J.T., et al. *Experimental Investigation Of Drilled Cuttings Transport in Inclined Boreholes*. 1990.
- [23] Clark, R.K. and K.L. Bickham, *Mechanistic Model For Cuttings Transport*. 1994.
- [24] A.M. Kamp, S., M. Rivero, SPE, PDVSA Intevep, *Layer Modeling For Cuttings Transport in Highly Inclined Wellbores*, in *Latin American And Caribbean Petroleum Engineering Conference*, Society of Petroleum Engineers: Caracas, Venezuela, 1999.
- [25] Carlson, J. and R.K. Ing. *Ultrasonic Particle Velocimetry in Multiphase Flows*, 2002.
- [26] Kadambi, J.R., et al., *Particle Sizing Using Particle Imaging Velocimetry For Two-Phase Flows*, *Powder Technology*, 100(2-3): p. 251-259, 1998.
- [27] Kumara, W.A.S., B.M. Halvorsen, and M.C. Melaaen, *Particle Image Velocimetry For Characterizing The Flow Structure of Oil-Water Flow in Horizontal and Slightly Inclined Pipes*. *Chemical Engineering Science*, 65(15): p. 4332-4349, 2010.

- [28] Chen, R.C. and L.S. Fan, *Particle Image Velocimetry For Characterizing The Flow Structure in Three-Dimensional Gas-Liquid-Solid Fluidized Beds*. Chemical Engineering Science, 47(13-14): p. 3615-3622, 1992.
- [29] Kaoru, M., et al., *PIV Measurement of Particle Motion in Spiral Gas-Solid Two-Phase Flow*. Experimental Thermal and Fluid Science. 19: p. 194-203.
- [30] Ozbayoglu, A.M. and H.E. Yuksel, *Analysis of Gas-Liquid Behavior in Eccentric Horizontal Annuli With Image Processing And Artificial Intelligence Techniques*. Journal of Petroleum Science and Engineering, 81: p. 31-40, 2012.
- [31] Rooki, R., et al., *Prediction Of Terminal Velocity Of Solid Spheres Falling Through Newtonian And Non-Newtonian Pseudoplastic Power Law Fluid Using Artificial Neural Network*. International Journal of Mineral Processing, 110-111(0): p. 53-61, 2012.
- [32] Ömürlü, Ç., 2006, *Mathematical Modeling of Horizontal Two-Phase Flow Through Fully Eccentric Annuli*, Yüksek Lisans Tezi, Petrol ve Doğalgaz Mühendisliği Bölümü, Orta Doğu Teknik Üniversitesi, Ankara, p. 124.
- [33] Osgouei, R.E., 2010, *Determination of Cuttings Transport Properties of Gasified Drilling Fluids*, Doktora Tezi, Petrol ve Doğalgaz Mühendisliği Bölümü, Orta Doğu Teknik Üniversitesi, Ankara, p. 269.
- [34] "Basler Scout Camera", Erişim Adresi: <http://www.vision-systems.com/articles/2011/11/basler-scout-sca1600-28-cameras.html>, Erişim Tarihi: 23 Temmuz 2013.
- [35] Saraç, T., *Yapay Sinir Ağları*, Gazi Üniversitesi, 2004.
- [36] Haykin, S.S., *Neural Networks : A Comprehensive Foundation*, Prentice Hall, Upper Saddle River, N.J. :, c1999.2nd ed, 1999.
- [37] Russell, S. and P. Norvig, *Artificial Intelligence: A Modern Approach*, Pearson Education, 2003.
- [38] Kakıcı, A. "Yapay Sinir Ağlarının Mimarisi ve Yapı Elemanları", Erişim Adresi: <http://www.ahmetkakici.com/yapay-sinir-aglari/yapay-sinir-aglarinin-mimarisi-ve-yapi-elemanlari/>, Erişim Tarihi: 16 Haziran 2013.
- [39] "YSA Grafik Gösterimi", Erişim Adresi: <http://www.bilesim.com.tr/>, Erişim Tarihi: 16 Haziran 2013.
- [40] Yurtoglu, H., *Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği*, Ekonomik Modeller Ve Stratejik Araştırmalar Genel Müdürlüğü. p. 113, 2005.

- [41] Duman, N., 2006, *Yapay Sinir Ağları ve Bir Uygulama*, Yüksek Lisans Tezi, Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Sivas.
- [42] Kakıcı, A. "Yapay Sinir Ağlarının Sınıflandırılması", Erişim Adresi: <http://www.ahmetkakici.com/yapay-sinir-aglari/yapay-sinir-aglarinin-siniflandirilmesi/>, Erişim Tarihi: 10 Haziran 2013.
- [43] Campbell, C. and Y. Ying, *Learning With Support Vector Machines*, Synthesis Lectures On Artificial Intelligence And Machine Learning, Vol. 10. 1-95, 2011.
- [44] Rodrigo, M., V. João Francisco, and P.G.N. Wilson, *Document-Level Sentiment Classification: An Empirical Comparison Between SVM And ANN*. Expert Systems With Applications, 40: p. 621-633, 2013.
- [45] Duan, K.B. and S.S. Keerthi, *Which Is the Best Multiclass SVM Method? An Empirical Study*. Lecture Notes In Computer Science, 2005(3541): p. 278-285.
- [46] Hsu, C.W. and C.J. Lin, *A Comparison Of Methods For Multiclass Support Vector Machines*. IEEE Transactions on Neural Networks, 13(2): p. 415-425, 2002.
- [47] Platt, J.C., N. Cristianini, and J. Shawe-Taylor. *Large Margin DAGs for Multiclass Classification*, MIT Press, 2000.
- [48] Crammer, K. and Y. Singer, *On the Algorithmic Implementation of Multiclass Kernel-based Vector Machines*, Journal of Machine Learning Research, 2(2): p. 265, 2002.
- [49] Vapnik, V.N., *The Nature Of Statistical Learning Theory*, New York, Springer, 1995.
- [50] Smola, A.J. and B. Schölkopf, *A Tutorial On Support Vector Regression*. Statistics and Computing, 14(3): p. 199-222, 2004.
- [51] Smola, A.J., *Learning With Kernels*, GMD-Forschungszentrum Informationstechnik, 1998.
- [52] Cortes, C. and V. Vapnik, *Support-Vector Networks*, Machine Learning, 20(3): p. 273-297, 1995.
- [53] Karush, W., *Minima of Functions of Several Variables with Inequalities as Side Constraints*, Dept.~of Mathematics, Univ.~of Chicago, 1939.
- [54] Kuhn, H.W.a.A.W.T. *Nonlinear Programming*. in *Second Berkeley Symposium on Mathematical Statistics and Probability*, Statistical Laboratory of the University of California, Berkeley: University of California Press, 1950.

- [55] Erkan, H., 2008, *Talep Tahmin Doğruluğunu Arttırmak İçin Talebi Etkileyen Faktörlerin Analizi Ve İlaç Sektöründe Ekonometrik Bir Model Önerisi*, Doktora Tezi, Marmara Üniversitesi, *Sosyal Bilimler Enstitüsü*, p. 258, İstanbul.
- [56] Eryiğit, O., *Korelasyon ve Regresyon Analizi* Notları.
- [57] *Support Vector Machines*, Erişim Tarihi: 9 Mart 2013, Erişim Adresi: <http://www.isis.ecs.soton.ac.uk/resources/svminfo/>.

## ÖZGEÇMİŞ

### Kişisel Bilgiler

Soyadı, adı : TOMBUL, Hatice  
Uyruğu : T.C.  
Doğum tarihi ve yeri : 01.07.1985, Ankara  
Medeni hali : Bekâr  
Telefon : 0 (312) 246 12 32  
e-mail : [htombul@etu.edu.tr](mailto:htombul@etu.edu.tr)

### Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Lisans	TOBB ETÜ, Bilgisayar Mühendisliği	2009
Y.Lisans	TOBB ETÜ, Bilgisayar Mühendisliği	2013

### İş Deneyimi

Yıl	Yer	Görev
2011-Halen	Başkent Üniversitesi	Araştırma Görevlisi

### Yabancı Dil

İngilizce (iyi) , Rusça (başlangıç)