

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

**ÜROFLOVOMETRE-ELEKTROMİYOGRAFİ SİNYALLERİ  
SINIFLANDIRILARAK ALT ÜRİNER SİSTEM DİSFONKSİYONU İÇİN  
TIBBİ KARAR DESTEK SİSTEMİ OLUŞTURULMASI**

**YÜKSEK LİSANS TEZİ**

**Çağrı YILMAZER**

**Biyomedikal Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Prof. Dr. Osman EROĞUL**

**NİSAN 2019**



Fen Bilimleri Enstitüsü Onayı

.....  
**Prof. Dr. Osman EROĞUL**  
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığımı onaylarım.

.....  
**Prof. Dr. Osman EROĞUL**  
Anabilim Dalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün 151711020 numaralı Yüksek Lisans Öğrencisi **Çağrı YILMAZER**'in ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı **“ÜROFLOVMETRE-ELEKTROMİYOGRAFİ SİNYALLERİ SINIFLANDIRILARAK ALT ÜRİNER SİSTEM DİSFONKSİYONU İÇİN TIBBİ KARAR DESTEK SİSTEMİ OLUŞTURULMASI”** başlıklı tezi **17/04/2019** tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

**Tez Danışmanı :** **Prof. Dr. Osman EROĞUL** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi

**Jüri Üyeleri :** **Prof. Dr. Mehmet MUTLU (Başkan)** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi

**Doç. Dr. Aytekin ÜNLÜ** .....  
SBÜ Gülhane Eğitim ve Araştırma Hastanesi



## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Çağrı YILMAZER



## ÖZET

Yüksek Lisans Tezi

### ÜROFLOVMETRE-ELEKTROMİYOGRAFİ SİNYALLERİ SINIFLANDIRILARAK ALT ÜRİNER SİSTEM DİSFONKSİYONU İÇİN TIBBİ KARAR DESTEK SİSTEMİ OLUŞTURULMASI

Çağrı YILMAZER

TOBB Ekonomi ve Teknoloji Üniversitesi  
Fen Bilimleri Enstitüsü  
Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Osman EROĞUL

Tarih: Nisan 2019

Alt Üriner Sistem Disfonksiyonu (AÜSD) özellikle çocuklarda oldukça yaygın olarak görülen geniş bir hastalık grubudur. İdrar tutamama, sık idrara çıkma, sıkışma hissi ve zayıf idrar akımı en sık görülen AÜSD semptomlarıdır. AÜSD tespiti için çeşitli yöntemler kullanılmaktadır. Günümüzde pediatrik yaş grubunda AÜSD hastalıklarının teşhisinde ve uygulanacak tedavinin takip edilmesinde, üroflovmetre (UF) ve elektromiyografi (EMG) sinyallerinin eş zamanlı olarak kayıt altına alındığı UF-EMG testi sıklıkla kullanılmaktadır. Bu tezin amacı UF-EMG sinyallerini farklı sınıflandırma algoritmaları aracılığıyla sınıflandırarak en iyi sınıflandırma performansını gösteren sınıflandırma metodunu belirlemektir. Belirlenen en iyi sınıflandırma metodu aracılığıyla sağlık personeline hastaların teşhis ve tedavisinde yardımcı olmak, UF-EMG sonuçlarının yorumlanmasında kolaylık sağlamak hedeflenmiştir. Bu tez çalışmasında üç farklı sınıflandırma yöntemi kullanılmıştır. Bu yöntemler K-En Yakın Komşu algoritması, Destek Vektör Makineleri ve Yapay Sinir Ağları'dır. Tez çalışmasında UF-EMG sinyalleri analiz edilerek sınıflandırma algoritmalarının çıktıları altı farklı gruba ayrılmıştır. Bütün veri seti uzman hekim tarafından analiz edilmiş olup sonuçlar uzman hekim kararının altın standart olduğu dikkate alınarak hesaplanmış, en başarılı sınıflandırma performansını 'İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları' sisteminin gösterdiği belirlenmiştir.

Anahtar Kelimeler: Alt üriner sistem disfonksiyonu, Üroflovmetre, Elektromiyografi, Sınıflandırma, Yapay sinir ağları, K-en yakın komşu, Destek vektör makineleri





## **ABSTRACT**

Master of Science

### **DEVELOPMENT OF MEDICAL DECISION SUPPORT SYSTEM FOR LOWER URINARY TRACT DYSFUNCTION BY CLASSIFYING UROFLOWMETRY- ELECTROMYOGRAPHY SIGNALS**

**Çağrı YILMAZER**

TOBB University of Economics and Technology  
Institute of Natural and Applied Sciences  
Biomedical Engineering Science Programme

Supervisor: Prof. Dr. Osman EROĞUL

Date: April 2019

Lower Urinary Tract Dysfunction (LUTD) is a disease which is commonly seen among children. Frequent urination, urinary incontinence, feeling of tightness and poor urine flow, etc., are main symptoms of LUTD. There are different ways for diagnosis of LUTD. The most popular method is Uroflowmetry-Electromyography (UF-EMG) test in which both UF and EMG signals are recorded synchronously. The main purpose of this study is to classify UF-EMG signals with different classification methods and determine which method will show the best classification performance. These results are expected to provide physicians supplementary information for diagnosis and treatment. Three different classification methods were used for this study. These methods are Support Vector Machine (SVM), Artificial Neural Networks (ANN) and K-Nearest Neighbor (KNN). In this study UF-EMG signals are analyzed and the outputs of SVM, ANN and KNN are classified into six different groups. All dataset has been analyzed by specialists and results of the learning algorithms are calculated considering specialist judgment as gold standard and found that ‘Multi Layer Feed Forward Artificial Neural Network’ structure has showed best classification performance.

**Keywords:** Lower urinary tract dysfunction, Uroflowmetry, Electromyography, Classification, Artificial neural networks, K-nearest neighbor, Support vector machines



## TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocalarım Prof. Dr. Osman EROĐUL ve Arő. Gör. Galip ÖZDEMİR'e, lisans ve yüksek lisans eęitimim boyunca kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Biyomedikal Mühendislięi Bölümü öğretim üyelerine, destekleriyle her zaman yanımda olan annem Nimet YILMAZER, babam Gürsel YILMAZER'e ve bu sürecin başından sonuna kadar benden yardımlarını esirgemeyen bütün arkadaşlarıma teşekkür ederim. Yüksek lisans eęitimim boyunca tarafıma sağladığı burs imkanı ve çalışmalarımda her türlü maddi ve manevi destekleri için TOBB Ekonomi ve Teknoloji Üniversitesi'ne teşekkürlerimi sunarım.



## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> .....	iv
<b>ABSTRACT</b> .....	v
<b>TEŞEKKÜR</b> .....	vi
<b>İÇİNDEKİLER</b> .....	vii
<b>ŞEKİL LİSTESİ</b> .....	viii
<b>ÇİZELGE LİSTESİ</b> .....	x
<b>KISALTMALAR</b> .....	xi
<b>SEMBOL LİSTESİ</b> .....	xii
<b>1. GİRİŞ</b> .....	1
1.1 Tez Çalışmasının Amacı .....	2
1.2 Literatür Araştırması .....	3
<b>2. ÜRODİNAMİ</b> .....	5
2.1 Alt Üriner Sistem Disfonksiyonu.....	7
2.2 Ürodinamik Tanı Yöntemleri.....	8
2.2.1 Sistometri .....	8
2.2.2 Üroflovmetre .....	9
2.2.3 Basınç-akım çalışması .....	10
2.2.4 Pelvik elektromiyografi.....	10
2.2.5 Video ürodinami.....	11
2.2.6 Ambulatuvar ürodinami .....	11
2.3 Üroflovmetre – Elektromiyografi Testi.....	12
<b>3. MATERYAL VE YÖNTEM</b> .....	15
3.1 Verilerin Toplanması ve Özellikleri.....	15
3.2 Yapay Zeka .....	18
3.2.1 Makine öğrenmesi .....	20
3.2.1.1 Yapay sinir ağları .....	22
3.2.1.2 K-en yakın komşu algoritması .....	26
3.2.1.3 Destek vektör makineleri .....	30
3.2.2 Öznitelik çıkarımı.....	34
3.3 Algoritma Performanslarının Değerlendirilmesi.....	37
<b>4. BULGULAR VE DEĞERLENDİRME</b> .....	41
4.1 K-En Yakın Komşu Algoritması Sonuçları .....	41
4.2 Destek Vektör Makineleri Sonuçları.....	48
4.3 Yapay Sinir Ağları Sonuçları .....	56
4.4 Genel Değerlendirme Sonuçları .....	64
<b>5. SONUÇ</b> .....	67
<b>6. KAYNAKLAR</b> .....	69
<b>7. ÖZGEÇMİŞ</b> .....	73



## ŞEKİL LİSTESİ

### Sayfa

Şekil 1.1 : Üriner sistem .....	1
Şekil 2.1 : Ürodinamik test süreci şematik gösterimi [Url-2].....	5
Şekil 2.2 : Tanı amaçlı kullanılan ürodinami sistemi [Url-3] .....	6
Şekil 2.3 : Örnek sistometri testi sonucu [15].....	9
Şekil 2.4 : Sağlıklı bir bireyin üroflovmetre sonucu ve parametreler.....	10
Şekil 2.5 : Boşaltım sırasında elektromiyografi aktivitesi.....	11
Şekil 2.6 : UF-EMG testi sırasında EMG problemlerinin takıldığı bölgeler [Url-4] .....	13
Şekil 2.7 : Örnek bir UF-EMG testi sonucu .....	13
Şekil 3.1 : Derece 0 UF-EMG testi sonucu .....	15
Şekil 3.2 : Derece 1 UF-EMG testi sonucu .....	16
Şekil 3.3 : Derece 2 UF-EMG testi sonucu .....	16
Şekil 3.4 : Derece 3 UF-EMG testi sonucu .....	17
Şekil 3.5 : Derece 4 UF-EMG testi sonucu .....	17
Şekil 3.6 : Derece 5 UF-EMG testi sonucu .....	18
Şekil 3.7 : Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi .....	20
Şekil 3.8 : Makine öğrenmesi yöntemleri.....	21
Şekil 3.9 : Sınıflandırma algoritmalarının temel çalışma prensibi .....	22
Şekil 3.10 : İnsan sinir sistemi ve yapay sinir ağları çalışma benzerliği .....	23
Şekil 3.11 : YSA yapısı.....	24
Şekil 3.12 : YSA türleri: (a) Tek Katmanlı YSA, (b) Çok Katmanlı YSA .....	24
Şekil 3.13 : K-en yakın komşu algoritması çalışma prensibi .....	27
Şekil 3.14 : Öklid uzaklığı ve manhattan uzaklığı.....	29
Şekil 3.15 : (a) Doğrusal olarak ayrılabilen iki sınıflı veri seti için çizilebilecek hiperdüzlemler, (b) Optimum hiper-düzlem ve destek vektörler [39].....	31
Şekil 3.16 : Çekirdek fonksiyonu kullanılarak veri setinin daha yüksek boyutlu uzaya aktarılması.....	32
Şekil 3.17 : Çok sınıflı DVM sınıflandırıcı örneği .....	33
Şekil 3.18 : Sınıflandırma süreci.....	34

Şekil 3.19 : Çalışmanın akış şeması.....	36
Şekil 3.20 : Doğruluk ve kesinlik ilişkisi .....	39
Şekil 4.1 : KNN konfüzyon matrisi, manhattan uzaklığı 1 .....	42
Şekil 4.2 : KNN konfüzyon matrisi, manhattan uzaklığı 2 .....	42
Şekil 4.3 : KNN konfüzyon matrisi, manhattan uzaklığı 3 .....	43
Şekil 4.4 : KNN konfüzyon matrisi, manhattan uzaklığı 4 .....	43
Şekil 4.5 : KNN konfüzyon matrisi, manhattan uzaklığı 5 .....	44
Şekil 4.6 : KNN konfüzyon matrisi, öklid uzaklığı 1 .....	45
Şekil 4.7 : KNN konfüzyon matrisi, öklid uzaklığı 2 .....	45
Şekil 4.8 : KNN konfüzyon matrisi, öklid uzaklığı 3 .....	46
Şekil 4.9 : KNN konfüzyon matrisi, öklid uzaklığı 4 .....	46
Şekil 4.10 : KNN konfüzyon matrisi, öklid uzaklığı 5 .....	47
Şekil 4.11 : DVM linear çekirdek fonksiyonu, OVO en başarılı .....	49
Şekil 4.12 : DVM linear çekirdek fonksiyonu, OVO en başarısız.....	49
Şekil 4.13 : DVM linear çekirdek fonksiyonu, OVA en başarılı .....	50
Şekil 4.14 : DVM linear çekirdek fonksiyonu, OVA en başarısız.....	50
Şekil 4.15 : DVM polinomal çekirdek fonksiyonu, OVO en başarılı .....	52
Şekil 4.16 : DVM polinomal çekirdek fonksiyonu, OVO en başarısız.....	52
Şekil 4.17 : DVM polinomal çekirdek fonksiyonu, OVA en başarılı .....	53
Şekil 4.18 : DVM polinomal çekirdek fonksiyonu, OVA en başarısız.....	53
Şekil 4.19 : (a) Tek katmanlı YSA, (b) Çok katmanlı YSA .....	56
Şekil 4.20 : Tek katmanlı YSA konfüzyon matrisi 1 .....	57
Şekil 4.21 : Tek katmanlı YSA konfüzyon matrisi 2 .....	58
Şekil 4.22 : Tek katmanlı YSA konfüzyon matrisi 3 .....	58
Şekil 4.23 : Tek katmanlı YSA konfüzyon matrisi 4 .....	59
Şekil 4.24 : Tek katmanlı YSA konfüzyon matrisi 5 .....	59
Şekil 4.25 : Çok katmanlı YSA konfüzyon matrisi 1 .....	60
Şekil 4.26 : Çok katmanlı YSA konfüzyon matrisi 2.....	61
Şekil 4.27 : Çok katmanlı YSA konfüzyon matrisi 3.....	61
Şekil 4.28 : Çok katmanlı YSA konfüzyon matrisi 4.....	62
Şekil 4.29 : Çok katmanlı YSA konfüzyon matrisi 5.....	62



## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1 : Alt üriner sistem semptomları .....	7
Çizelge 3.1 : Sınıflandırma için kullanılan öznitelikler .....	36
Çizelge 3.2 : Konfüzyon Matris .....	37
Çizelge 4.1 : KNN Manhattan uzaklığı sonuçları .....	44
Çizelge 4.2 : KNN Öklid uzaklığı sonuçları .....	47
Çizelge 4.3 : KNN ortalama ve en başarılı sonuçlar .....	48
Çizelge 4.4 : DVM Linear çekirdek fonksiyonu sonuçları .....	51
Çizelge 4.5 : DVM Polinomal çekirdek fonksiyonu sonuçları .....	54
Çizelge 4.6 : DVM ortalama ve en başarılı sonuçlar .....	56
Çizelge 4.7 : Tek katmanlı YSA sonuçları .....	60
Çizelge 4.8 : Çok katmanlı YSA sonuçları .....	63
Çizelge 4.9 : YSA ortalama ve en başarılı sonuçlar .....	63
Çizelge 4.10 : En başarılı yöntemler ve sonuçlar .....	65



## KISALTMALAR

<b>AÜSD</b>	: Alt Üriner Sistem Disfonksiyonu
<b>UF</b>	: Üroflovmetre
<b>EMG</b>	: Elektromiyografi
<b>UF-EMG</b>	: Üroflovmetre-Elektromiyografi
<b>YSA</b>	: Yapay Sinir Ağları
<b>KNN</b>	: K-en Yakın Komşu Algoritması (K-Nearest Neighbor)
<b>DVM</b>	: Destek Vektör Makineleri
<b>AÜSS</b>	: Alt Üriner Sistem Semptomları
<b>OVO</b>	: One-vs-One
<b>OVA</b>	: One-vs-All
<b>GP</b>	: Gerçek Pozitif
<b>GN</b>	: Gerçek Negatif
<b>YP</b>	: Yanlış Pozitif
<b>YN</b>	: Yanlış Negatif



## SEMBOL LİSTESİ


Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
$\mu$	Mikro
$V$	Voltaj
$W$	Yapay sinir ağları gizli katman ağırlık vektörü
$X$	Yapay sinir ağları girdi vektörü
$\partial$	Hesaplanan hata değeri
$net$	Ağın girdi değeri
$\eta$	Güncelleme hızı
$o$	Beklenen sonuç
$y$	Hesaplanan sonuç
$w$	Destek vektör makineleri ağırlık vektörü
$k$	Kontrol edilecek komşu sayısı
$D$	Hesaplanan uzaklık değeri
$b$	Eğilim değeri
$\gamma$	Kernel boyutu
$d$	Polinomal çekirdek fonksiyonu derecesi
$n$	Sınıf sayısı



## 1. GİRİŞ

Üriner Sistem (boşaltım sistemi) temel olarak idrarın oluşumu ve dışarı atılmasında görev alan organlardan oluşur (Şekil 1.1). Üriner Sistem, üst üriner sistem ve alt üriner sistem olarak ikiye ayrılır. Üst üriner sistem böbrekler ve üreterlerden oluşur, alt üriner sistem ise mesane ve üretradan oluşur. Alt üriner sistemin iki ana işlevi; idrarın depolanması ve periyodik olarak dışarı atılmasıdır. Bu işlevler mesane ve üretral kaslara ait biyomekanik özellikler ile birlikte beyinde ve spinal kordda yer alan karmaşık nöronal kontrol sistemi sayesinde düzenlenmektedir [1].



Şekil 1.1 : Üriner sistem

Alt Üriner Sistem Disfonksiyonu (AÜSD), özellikle pediatrik yaş aralığında sık görülen işeme bozukluğu olarakta bilinen geniş bir hastalık grubu olarak tanımlanabilir. Aynı zamanda pediatrik yaş grubunda görülen idrar yolu enfeksiyonlarının ana nedenlerinden biridir. Alt üriner sistem komplikasyonları astım ile birlikte çocuk yaş grubunda görülen en önemli kronik hastalıktır [2].

AÜSD'nin nedeni hala tam olarak bilinmemekle birlikte mesane ve mesane çıkışı arasında bir koordinasyon bozukluğunun sebep olabileceği düşünülmektedir [3]. AÜSD; aşırı etkin mesane, disfonksiyonel işeme ve az etkin mesane olmak üzere üç grupta toplanır [4].

Belirgin üropati veya nörolojik bir neden olmamasına rağmen idrar tutamama, normalden sık idrara çıkma, sıkışma hissi, az idrar akımı, alt üriner sistem ağrısı gibi semptomları mevcuttur [5]. Pediatrik yaş grubunda görülme oranı %2 ile %25 aralığında değişmektedir [6]. Çocuk ürologisi uzmanlarına başvuran hastaların %40'ını AÜSD olan çocuklar oluşturmaktadır [3]. Bu sebeplerden dolayı AÜSD'nun hızlı, etkin ve doğru teşhisi oldukça önemlidir. AÜSD'li insanlar AÜSD semptomlarının bir sonucu olarak pek çok sosyal, fiziksel ve mental problemler ile karşı karşıya kalmaktadır. AÜSD için verimli bir tedavi yoktur, AÜSD tedavi yöntemleri yan etkilere sahip ve yüksek maliyetlidir [6].

AÜSD'nin teşhisi için çeşitli yöntemler kullanılmaktadır. AÜSD tanısı için hastaların fiziksel olarak incelenmesi, işeme günlüğü, işeme bozuklukları semptom skoru, üroflovmetre-elektromiyografi testi (UF-EMG), tam idrar tetkiki, idrar kültürü, lumbosakral grafi, üriner sistem ultrasonu, boşaltım sonrası artık idrar ölçümü gibi yöntemler kullanılır [4]. Üroflovmetre (UF) testi tek başına AÜSD'nin tanısı için sıkça kullanılmaktadır. Ancak AÜSD tanısı için UF tek başına hastanın işeme sırasındaki pelvik kasların aktivitesi hakkında bilgi vermediği için yetersiz kalabilmektedir.

AÜSD tanı yöntemleri içinde en popüler olan yöntemlerden biri ise UF ve elektromiyografi (EMG) sinyallerinin senkronize bir şekilde eş zamanlı olarak kaydedildiği UF-EMG testidir. UF-EMG testi AÜSD tespiti için kullanılan noninvaziv bir testtir. Hastanın kalça bölgesine takılan problar aracılığıyla işeme sırasında pelvik bölgede meydana gelen kas aktivitesi kayıt edilmektedir. Bu yöntem sayesinde ürolog hekim veya sağlık personeli AÜSD teşhisi için daha fazla bilgiye sahip olmaktadır.

### **1.1 Tez Çalışmasının Amacı**

Bu tez çalışmasında hastalardan alınan UF-EMG sinyalleri farklı sınıflandırma yöntemleri ile sınıflandırılarak AÜSD için karar destek sistemi oluşturulmuştur. Oluşturulan bu karar destek sisteminin hekimlere teşhis ,tanı ve tedavi sürecinde yardımcı olması hedeflenmektedir.



Tez çalışmasında UF-EMG sinyalleri üç farklı sınıflandırma yöntemi ile sınıflandırılmıştır. Kullanılan sınıflandırma yöntemleri Yapay Sinir Ağları (YSA) , K En Yakın Komşu Algoritması (KNN) ve Destek Vektör Makineleri (DVM)'dir. Bu sınıflandırma yöntemleri ile sınıflandırılan UF-EMG sinyalleri altı farklı dereceye ayrılarak UF-EMG sinyalleri ve AÜSD'nin teşhisi için en iyi sınıflandırma yöntemini belirlenmiştir.

## 1.2 Literatür Araştırması

Tez konusu ile alakalı literatürde yapılan çalışmalar incelendiğinde hem AÜSD hem de tanısı ile ilgili çalışmaların bilgisayar destekli tanıdan ve karar destek sistemi oluşturulmasından ziyade hastalığın fizyolojik nedenlerine odaklandığı görülmüştür. AÜSD olan çocuklarının UF-EMG paternlerinin belirlendiği [4] ve UF-EMG testinin AÜSD tanısında kullanıldığı ve ürodinamik bileşenleri ayırmakta yararlı bir test olduğunu ortaya koyan çalışmalar mevcuttur [7].

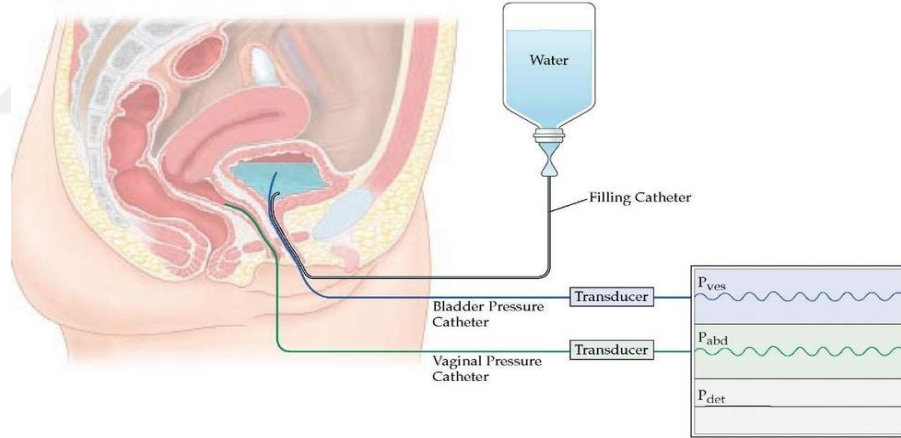
Literatürde ürodinami sorunlarının tanısı için EMG sinyallerinden bağımsız sadece UF sinyallerinin YSA kullanılarak sınıflandırıldığı bir çalışma mevcuttur. Altunay ve arkadaşları hastalardan alınan UF sinyallerini YSA kullanarak sınıflandırmışlardır. Yapılan çalışmada YSA çıktıları 'Sağlıklı', 'Muhtemel Patolojik' ve 'Patolojik' olarak üçe ayrılmıştır. YSA sistemine girdi olarak ilk yükselen eğimin değeri, son azalan eğimin değeri, birden fazla tepe noktası varlığı, genlik boşaltım süresi oranı ve UF eğrisinin aralıklılığı gibi öznitelikler verilmiş ve bu öznitelikler kullanılarak YSA sisteminin ortalama başarısı %79 olarak hesaplanmıştır [8]. Sistem sonuçlarını değerlendirirken sadece genel doğruluk (accuracy) oranı hesaplandığı görülmektedir.

Yalçınkaya ve arkadaşları ise AÜSD tanısında hekimlere yardımcı bir sistem oluşturarak hastalardan alınan UF-EMG sinyallerini YSA kullanarak sınıflandırmışlardır. YSA sistemine girdi olarak EMG sinyalinin varlığı, hastanın yaşı, hastanın cinsiyeti, ortalama akış hızı, sıfıra inme sayısı, maksimum akış hızı gibi öznitelikler verilmiştir. YSA çıktıları 'Derece 0' , 'Derece 1' , 'Derece 2' , 'Derece 3' , 'Derece 4' ve 'Derece Non-EMG' olmak üzere altı sınıfa ayrılmıştır. UF-EMG sinyallerini YSA ile sınıflandırılması sonucu genel başarı ortalaması %84,02 olarak hesaplanmıştır [9]. Bu sınıflandırma çalışmasında da sadece doğruluk hesaplanarak sınıflandırma performansı incelenmiş olup kesinlik, duyarlılık ve özgüllük gibi değerler hesaplanmamıştır.



## 2. ÜRODİNAMI

Ürodinami alt ve üst üriner sistemlerin semptomları ve/veya disfonksiyonu için objektif açıklamalar sağlamak için değerlendirilmesidir. Ürodinamik testler mesanenin ve üretranın idrarı ne kadar iyi depoladığı ve serbest bıraktığını inceleyen prosedürlerdir. Ürodinamik test süreci Şekil 2.1’de gösterilmiştir. Ürodinamik testler mesanenin ne kadar iyi çalıştığının yanı sıra sızıntı veya tıkanmaların nedenlerini araştırmaktadır. Ürodinami kişinin alt üriner sistemin fonksiyonları hakkında ayrıntılı bilgiler elde edilmesini sağlar, ancak hastalık hakkında kesin bir bilgi vermez. Ürodinami testleri sırasında temelde mesane sanki idrarla doluyormuş gibi belirli bir hızla sıvı ile doldurulup daha sonra boşaltılır ve bu sırada mesane, üretra ve sfinkterlerin tepkilerinin kayıt edilmesine dayanır [Url-1].



Şekil 2.1 : Ürodinamik test süreci şematik gösterimi [Url-2]

Ürodinami testleri;

- Alt idrar yolları için uygulanacak tedavinin yan etkileri önemli ise tanıdan emin olmak,
- Tekrarlayan idrar kaçırma atakları olan hastaya cerrahi bir operasyon planlanıyorsa,

- Hastada karışık tipte (baskı veya sıkışma hissetmeden) idrar kaçırması ve sıkışma semptomları var ise,
- Alt üriner sistem yakınmaları var ve tıkanıklık (örneğin prostat) düşündürüyorsa,
- Uygun tedaviye rağmen hastanın alt üriner sistem yakınmaları devam ediyorsa,
- Hastanın hem tıkanmaya bağlı alt üriner sistem şikayeti var ve hem de nörolojik bir hastalığı var ise,
- Nörolojik hastalığı olan tüm nörojenik mesane fonksiyon bozukluğu olan hastalara,
- Gündüz sıkışma ve sıkışma tipinde idrar kaçırması olan hastalara ve durumlara uygulanabilmektedir [Url-1].

İdrar kaçırma ve idrarı kontrol edememe, hapşırma veya öksürme anında idrar kaçırma, aniden gelen idrara çıkma ihtiyacı, idrar yaparken meydana gelen acı hissi, gün içinde normalde sık idrara çıkma, idrar yaparken zorlanma, damla damla idrar akışı ve zayıf idrar akışı gibi semptomları olan kişiler için de ürodinamik testler yapılmaktadır. Şekil 2.2’de teşhis için kullanılan ürodinami sistemlerine bir örnek gösterilmiştir.



Şekil 2.2 : Tanı amaçlı kullanılan ürodinami sistemi [Url-3]

## 2.1 Alt Üriner Sistem Disfonksiyonu

AÜSD, mesane fonksiyonlarının herhangi bir evresinde, depolama veya boşaltım, meydana gelen tüm hastalık gruplarını kapsayan geniş bir terimdir [10]. AÜSD; idrarı uygun bir şekilde depolayamayan, mesaneden idrarı uygun şekilde boşaltamayan, idrar tutamama vb. gibi hastalık gruplarının hepsini kapsamaktadır. Kısaca AÜSD mesanenin ana fonksiyonlarından herhangi birinin işlevsizliği olarak tanımlanabilir ve kategorize edilebilir [11].

AÜSD cinsiyetten bağımsız olarak hem kadınlarda hem erkeklerde sıklıkla rastlanır. Genel olarak bir yaş grubunu kapsamamak ile beraber özellikle pediatrik yaş grubunda oldukça sık rastlanan bir durumdur. İlkokul çağındaki çocukların %7-%10'u AÜSD semptomları sebebiyle uzmanlara başvurmaktadır [2]. Pediatrik üroloji uzmanına başvuran hastaların %40'ını AÜSD semptomları olan çocuklar oluşturmaktadır [3]. Fiziksel etki ve rahatsızlıkların yanı sıra bu problem çoğu çocukta özgüven eksikliğine, aile içi strese ve sosyal izolasyona sebep olabilir [12]. AÜSD olan çocukların gündüz idrar kaçırma, aciliyet, idrar retansiyonu, idrar yapma zorluğu ve kabızlık gibi şikayetleri olabilir [13].

Alt üriner sistem semptomları (AÜSS) depolama semptomları , boşaltım semptomları ve işeme sonrası semptomlar olarak üç kategoriye ayrılarak incelenebilir [14]. Çizelge 2.1'de AÜSS gösterilmiştir. AÜSS kişilerde AÜSD rahatsızlıklarından herhangi birinin olabileceğinin bir göstergesidir. Bu semptomlar hastalık ile ilgili kesin bilgi vermemek ile birlikte kişinin alt üriner sistemi ve fonksiyonları hakkında hekimlere önemli bilgiler vermektedir.

Çizelge 2.1 : Alt üriner sistem semptomları [14]

<b>Depolama Semptomları</b>	<b>Boşaltım Semptomları</b>	<b>İşeme Sonrası Semptomlar</b>
Normalden fazla tuvalete gitme ve sıkışma hissi İdrar kaçırma	Zayıf veya yavaş akış Bölünen akış	Tam boşalmama hissi İşeme sonrası sızdırma

## 2.2 Ürodinamik Tanı Yöntemleri

Ürodinamik tanı yöntemleri kişilerin alt ve üst üriner sistemlerinin fonksiyon/disfonksiyonlarını ve sebeplerini belirlemek için kullanılmaktadır. Ürodinamik çalışmalar bir dizi testten oluşur. Yapılan her bir test kişinin ürin sistemi hakkında farklı bilgiler ve bulgular vermektedir. Hastanın şikayetlerine göre uygun ürodinamik test veya testler seçilmeli ve uygulanmalıdır.

Ürodinamik sorunlar yaşayan kişilere , AÜSD'nin diğer yönleri hakkında bilgi edinmek, üst ve/veya alt idrar yollarında meydana gelecek bozuklukların olası sonuçlarını tahmin etmek, hasta için düşünülen tedavi yönteminde meydana gelebilecek istenmeyen yan etkileri tahmin etmek, hasta daha önce bir tedavi gördü ise yapılan tedavinin başarısız olma sebeplerini ve uygulanacak yeni tedavinin etki yönlerini araştırmak gibi sebepler için ürodinamik tanı yöntemleri uygulanmaktadır.

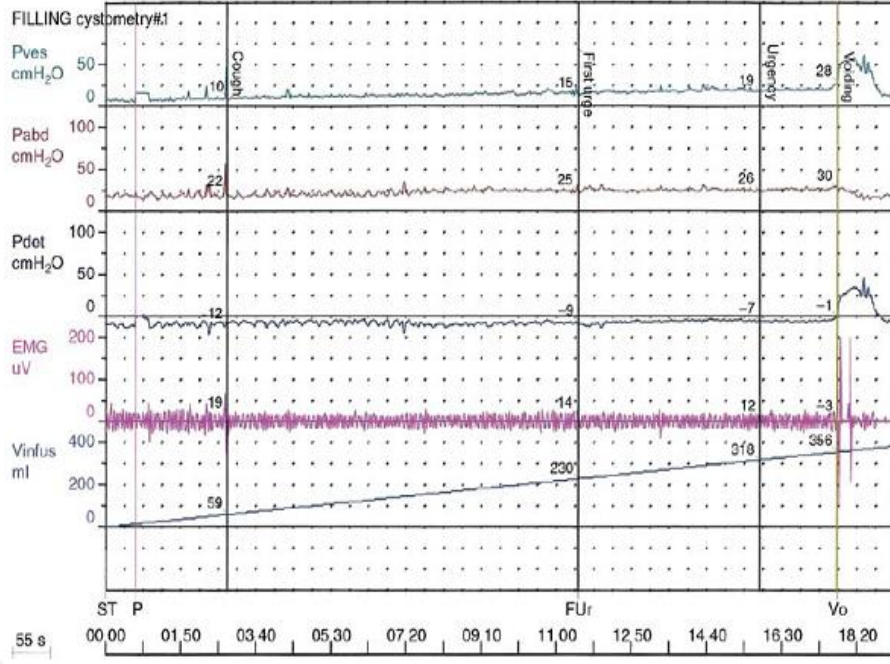
Hastalara tanı için uygulanan ürodinamik testler [15];

- Sistometri,
- Üroflovmetre,
- Basınç-Akım çalışmaları,
- Üretral basınç profili,
- Pelvik elektromiyografi
- Video ürodinami
- Ambulatuvar ürodinami'dir.

### 2.2.1 Sistometri

İşeme döngüsünün dolum fazının incelendiği tetkiktir. Mesane dolarken basınç/hacim ilişkisinin ölçülmesi ve incelenmesi prensibine dayanır. Mesanenin depolama fonksiyonu hakkında çok önemli bilgiler verir. Bilgisayara bağlı özel bir pompa yardımıyla mesane doldurulurken mesane içi ve karın içi basınçlar ölçülerek test gerçekleştirilir. Şekil 2.3'de örnek bir sistometri testi sonucu gösterilmiştir.

Sistometri testi; mesanenin maksimum kapasitesi, mesanenin kasılma gücü, mesanenin kasılması ile mesane boyunun açılması arasındaki koordinasyon, mesanenin kaçırma basıncı, mesane hassasiyeti, kompliyans, ilk idrar hissi (idrar ttamama hissi), kişinin istemli olarak işemeyi başlatma ve durdurabilme kabiliyeti gibi parametrelerin belirlenmesini sağlar.




Şekil 2.3 : Örnek sistometri testi sonucu[15]

Her türlü işeme bozukluklarının değerlendirilmesinde, mesane kapasitesinin arttığı ve azaldığı durumlarda, mesanede meydana gelen anormal kasılmalarda, işeme komplikasyonlarının ortaya konup hastanın tedavisinin düzenlenmesi durumlarında sistometri testi kullanılabilir.

### 2.2.2 Üroflovetre

Üroflovetre testi idrar akış hızının ölçüldüğü ürolojik bir tanı yöntemiştir. İdrar hacmindeki değişim oranı ölçülerek ve çizdirilerek hastanın alt idrar yolu fonksiyonları hakkında sayısal ve grafiksel bilgiler elde edilir. UF mesanenin boşaltma fonksiyonu hakkında bilgi verir. İdrar akış hızı özel bir dönüştürücü(transducer) aracılığıyla ölçülür ve ekranda bir akış grafiği ile rakamsal değerler görülür [16].

UF testi sonucunda maksimum akış hızı, ortalama akış hızı, idrar akış süresi, maksimum akış hızına ulaşma süresi ve akış sonrası kalan residüel idrar miktarı gibi kişinin üriner sistem fonksiyonları ve dinamikleri hakkında oldukça önemli parametreler elde edilir (Şekil 2.4).



Şekil 2.4 : Sağlıklı bir bireyin üroflowmetre sonucu ve parametreler

### 2.2.3 Basınç-akım çalışması


Boşaltım (işeme) esnasında hem mesane içi basıncın, hem de idrar akım hızı eğrisinin aynı anda kayıt edilmesine dayanır. İdrar akım hızındaki azalmanın sebebini anlamak için yapılan bir testtir. Basınç-Akım çalışmaları genellikle boşaltım ile ilgilenmesine rağmen idrar kaçırmaya sorunlarının sebeplerinde ışık tutabilir [15].

### 2.2.4 Pelvik elektromiyografi

EMG temelde kasların ve periferik sinirlerin elektriksel aktivitesinin ölçülmesi, kayıt edilmesi ve fonksiyonlarının belirlenmesidir. Ürodinamik çalışmalarda elektromiyografi mesane dolarken ve boşalırken eksternal sfinkterin elektriksel aktivitesini kayıt etmek için kullanılır. İğne veya yüzey elektrotlar yardımıyla sinyal alınabilir. Üretral sfinkterin, anal sfinkterin veya pelvik tabanın EMG ölçümü AÜSD tanısı için kullanılan bir yöntemdir (Şekil 2.5).

EMG yardımı ile iki farklı bilgi elde edilir. Bunlardan birincisi kas davranışlarının basit bir göstergisi diğeri ise kas patolojisinin elektriksel korelasyonudur. Ürodinamik testlerde genellikle EMG sinyallerinden elde edilen birinci bilgi kullanılır. Sağlıklı bireylerde mesane dolumu sırasında artan bir EMG aktivitesi beklenirken, boşaltım sırasında kasların gevşemesi ve azalan bir EMG aktivitesi beklenir.





Şekil 2.5 : Boşaltım sırasında EMG aktivitesi

### 2.2.5 Video ürodinami

Video ürodinami normal ürodinamik testler ile tıbbi görüntüleme yöntemlerinin (X-Ray, Ultrason Görüntüleme vb.) aynı anda yapılması ile ortaya çıkan bir tanı yöntemidir. Bu yöntem komplike AÜSD problemi olan hastalarda sıklıkla kullanılmaktadır. Video ürodinami yöntemi diğer yöntemlere göre daha kolay ve doğru tanı imkanı sağlamaktadır. Video ürodinami'nin en önemli avantajı anatomi görselleştirilirken eş zamanlı olarak basınç ölçümü yapılmasına olanak sağlamasıdır. Günümüzde manyetik rezonans görüntüleme ürodinamik testler ile birleştirilerek kullanılmaktadır [16].

### 2.2.6 Ambulatuvar ürodinami

Hastanın gün boyunca normal aktivitelerini yaparken doğal yollardan idrar ile dolan mesanesinden elde edilen verilerin kayıt edilip incelenmesidir. Ambulatuvar ürodinami'nin konvansiyonel ürodinamiye göre çeşitli avantaj ve dezavantajları vardır. En önemli avantajı, konvansiyonel ürodinami ile saptanamayan bazı durumlar ambulatuvar ürodinami aracılığı ile saptanabilir. Dezavantajı ise özel cihazlara ve gün içinde hastayı yönlendirecek tecrübeli bir ekibe ihtiyaç olmasıdır. Ayrıca istemsiz kasılmalara neden olabilmekte ve kateterlerin yerinden oynaması sonucunda ölçüm sonuçlarıolumsuz etkilenebilmektedir. Yapılan pek çok araştırmaya göre ambulatuvar ürodinami sonuçları, laboratuvarda yapılan diğer ürodinamik tetkiklere yakın sonuçlar vermektedir [15].

### 2.3 Üroflovmetre – Elektromiyografi Testi

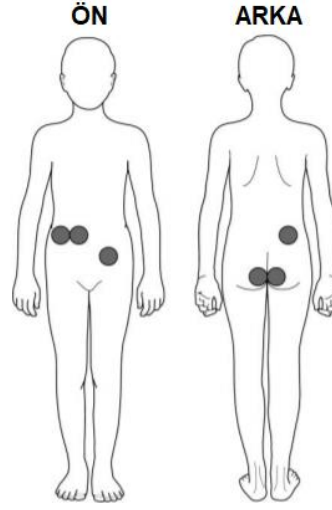
UF testi AÜSD değerlendirilmesinde ve hastanın akış paterni ve patolojisinin yorumlanmasında kullanılmaktadır. Ancak UF tek başına pelvik kas aktivitesi hakkında bilgi vermediği için bazı değerlendirmelerde yetersiz olduğu görülmüştür. Bazı bilim insanları hastanın boşaltım esnasında pelvik kas aktivitesinin bilinmeden sadece UF aracılığıyla alınan işeme akış paterni sonuçlarına dayanarak yapılan teşhislerin yanıltıcı olabileceğini ve hem hekimleri hem de hastaları yanlış sonuçlara yönlendirebileceğini düşünmektedir [17 , 18 , 19].

UF-EMG testi UF ve EMG sinyallerinin (pelvik bölge kas aktivitesi) eş zamanlı olarak kayıt edildiği girişimsel olmayan (noninvaziv) bir testtir. Bu test aracılığıyla hastanın hem akış paterni hem de pelvik kas aktivitesi eş zamanlı olarak kayıt altına alınıp incelenebilmektedir.

UF-EMG testi günümüzde AÜSD uygulanmasının kolay olması ve hastanın üriner sistemi hakkında detaylı bilgiler verdiği için sıklıkla kullanılmaktadır. Bu test özellikle pediatrik yaş grubunda AÜSD hastalıklarının teşhis ve tedavisinin takibinde UF-EMG testi yoğunlukla kullanılmaktadır [9].

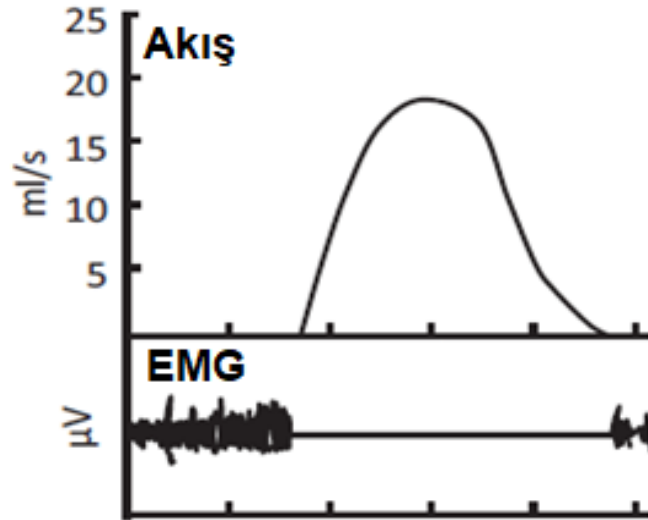
UF-EMG testi aracılığıyla hastanın akış patern özellikleri (maksimum akış hızı, ortalama akış hızı, idrar akış süresi, maksimum akış hızına ulaşma süresi ve akış sonrası kalan residüel idrar miktarı) elde edilirken, eş zamanlı olarak kayıt edilen EMG sinyalleri sayesinde işeme sırasında bu olayı kontrol eden kasların çalışma mekanizması ve aktiviteleri takip edilmiş olur. Böylelikle kişinin sağlıklı bir işeme mekanizmasına sahip olup olmadığına dair daha kesin bilgi sahibi olunur.

UF-EMG testi sırasında, öncelikle hastanın vücuduna EMG sinyallerinin alınması için belirli sayıda elektrod takılır. EMG elektrodlar genellikle kalçalarda anal açıklığa yakın bölgeye iki tane ve hastanın sırtının alt kısmına bir tane elektrod takılır. Bazı testlerde üç tane EMG elektrodu ise hastanın karın bölgesine takılır. Şekil 2.6'da EMG sinyallerini almak için takılan elektrodların yerleri gösterilmiştir. Bu elektrodlar aracılığıyla işeme sırasında hastanın özellikle pelvik bölgedeki kas aktivitesi üroflovmetri testi ile eş zamanlı olarak takip edilir [Url-4].



Şekil 2.6 : UF-EMG testi sırasında EMG problemlerinin takıldığı bölgeler [Url-4]

EMG elektrodları uygun bölgelere takıldıktan sonra hasta, içerisinde bilgisayara bağlı bir sensör bulunan özel bir tuvalete işeme işlemini gerçekleştirir. Bu sensör aracılığıyla hastanın işeme paterni sayısal ve görsel olarak çizilir. Şekil 2.7’de örnek bir UF-EMG testi sonucu gösterilmiştir. İşeme sonrası mesanede ne kadar idrar kaldığını ölçmek için hastanın mesanesi taranır. İşeme sonrası mesanede kalan idrar miktarı akış sonrası residüel idrar miktarı belirlenir ve test tamamlanmış olur.



Şekil 2.7 : Örnek bir UF-EMG testi sonucu




### 3. MATERYAL VE YÖNTEM

#### 3.1 Verilerin Toplanması ve Özellikleri

Bu tez çalışmasında kullanılan etik kurul izni alınmış veri seti Gülhane Eğitim ve Araştırma Hastanesi Ürodinami Merkezi'nden alınmıştır. Veriler MMS marka solar üroflow cihazı ile alınmıştır. Toplam 967 hastaya ait UF-EMG testi sonuçları bu tez çalışması kapsamında AÜSD hastalıkları tespiti için kullanılmıştır.

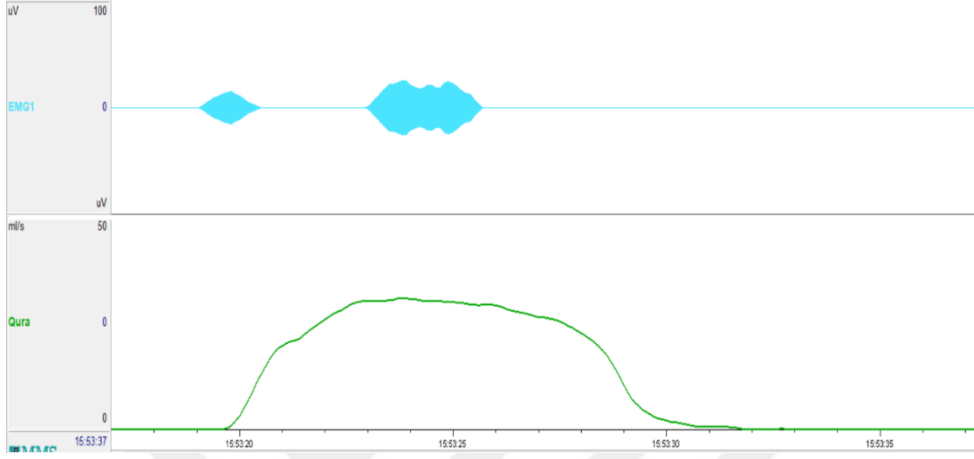
Veri seti uzman hekimler tarafından derecelendirilmiştir. EMG sinyalleri mikrovolt ( $\mu\text{V}$ ) seviyesinde ölçülmüştür. Verilerin örnekleme frekansı 10 hertz'dir. 'MMS Database' sisteminden uzman hekimlerin derecelendirdiği veriler bilgisayar ortamına '.asc' formatında aktarılıp sonrasında verilerin işlenmesi ve sınıflandırma işlemi MATLAB R2014a yazılımı kullanılarak gerçekleştirilmiştir.

**Derece 0 – Normal İşeme (Şekil 3.1):** Bu işeme paterninde üroflow eğrisi tek bir tepe oluşturarak düzgün bir şekil alır. Eğri sadece işeme sonlandığında sıfıra inmiştir. İşeme boyunca EMG aktivitesinin görülmediği sağlıklı bireylerde gözlenen durumdur [9].




Şekil 3.1 : Derece 0 UF-EMG testi sonucu

**Derece 1 (Şekil 3.2):** Kişinin işeme paternini bozmayan ancak işeme sürecinde EMG aktivitesinin görüldüğü paterndir. İşeme boyunca hastada EMG aktivitesi görülmesine rağmen hastanın üroflow eğrisi tek tepe oluşturur ve sadece işime sonlandığında sıfıra iner [9].




Şekil 3.2 : Derece 1 UF-EMG testi sonucu

**Derece 2 – Minimal Staccato (Şekil 3.3):** Hastanın işeme paternini minimum düzeyde bozan EMG aktivitesi olarak tanımlanabilir. İşeme boyunca EMG aktivitesi mevcut ve hastanın işeme paternini etkilemektedir. Üroflow eğrisi iki veya üç tepe oluşturmuş ve sadece işeme bittiğinde sıfıra inmiştir [9].




Şekil 3.3 : Derece 2 UF-EMG testi sonucu

**Derece 3 – Staccato (Şekil 3.4):** Kişinin işeme paternini orta düzeyde etkileyen EMG varlığı olarak tanımlanabilir. Bu paternde işeme boyunca EMG aktivitesi mevcut ve kişinin işemesi sağlıklı değildir. Üroflow eğrisi en az dört tepeden oluşmuştur ve eğri yalnızca işeme tamamen sonlandığında sıfıra inmiştir [9].




Şekil 3.4 : Derece 3 UF-EMG testi sonucu

**Derece 4 – İntermittance (Şekil 3.5):** Kişinin işeme paternini ileri seviyede etkileyen EMG aktivitesidir. Bu paternde işeme süresince EMG aktivitesi gözlemlenir ve kişinin işemesi sağlıklı değildir. Üroflow akış eğrisi birden çok tepeden oluşup işeme boyunca bir kaç kez sıfıra inmektedir [9].



Şekil 3.5 : Derece 4 UF-EMG testi sonucu

**Derece 5 – Non-EMG (Şekil 3.6):** Bu işeme paterninde kişinin üroflow eğrisi normal olmamasına rağmen işeme boyunca herhangi bir EMG aktivitesi görülmemektedir. Üroflow akış eğrisi birden fazla tepeden oluşur ancak işeme süresince EMG aktivitesi görülmez [9].



Şekil 3.6 : Derece 5 UF-EMG testi sonucu

Uzman hekimler tarafından incelenen ve derecelendiren veri seti ‘Derece 0 – Normal İşeme’, ‘Derece 1’, ‘Derece 2 – Minimal Staccato’, ‘Derece 3 – Staccato’, ‘Derece 4 - İntermittance’ ve ‘Derece 5 – Non-EMG’ olmak üzere altı farklı gruba ayrılmıştır. Çalışmada uzman hekimlerin sonuçları altın standart olarak kabul edilerek sınıflandırma işlemi ve istatistiksel hesaplamalar yapılmıştır.

### 3.2 Yapay Zeka

Yapay zeka, insanlar gibi çalışan ve olaylara reaksiyon göstererek karar veren akıllı makina sistemlerinin oluşturulması olarak tanımlanabilir. Yapay zeka teknolojisi günden güne gelişmekte ve gelişmeye devam etmektedir. Gelişen yapay zeka teknolojisi etkilerini pek çok farklı alanda göstermektedir.

Yapay zeka temelinde pek çok bilim alanının etkisi vardır ve multidisipliner bir alan olarak tanımlanabilir. Bilgisayar bilimleri ve mühendisliği, felsefe, matematik, kavrama bilimi ve psikoloji, sinir bilimi gibi farklı alanlar ortak bir bütün içerisinde yapay zeka kavramını etkilemektedir [20].



Yapay zeka kavramı kronolojik olarak incelendiğinde günümüzde pek çok alanda oldukça popüler olmasına çok yeni bir kavram değildir. Yapay zekanın oluşumu 1943-1956 yılları arasında kapsamaktadır. 1943 yılında Pitts ve McCulloch öneri mantıklarını gerçekleştirebilen sinirlerin basit bir matematiksel modelini çıkartmayı başarmıştır. 1950 yılında Allen Turing, Turing makinasını ortaya çıkarmıştır. Turing makinesi, karmaşık matematiksel hesapların belirli bir sistem tarafından çözülmesini sağlayan bir hesap makinesi olarak tanımlanabilir. 1950'li yıllarda Claude Shannon enformasyon teorisini ortaya atmıştır [21].

Yapay zeka kavramına dair ilk girişimler 1952-1969 yılları arasında gerçekleşti. 1956 yılında John McCarthy, Dartmouth Üniversitesinde gerçekleşen bir konferansta 'Yapay Zeka' terimini ortaya atmıştır. İlk yapay sinir ağı makinesini ise Marvin Minsky geliştirmiştir. Aynı yıllarda IBM firması santraç oynayabilen ilk programı geliştirdi. Ayrıca yine aynı dönemde ilk yapay zeka konferansı düzenlendi.


1965 yılında Robinson mantıklı düşünme konusunda tam bir algoritma geliştirdi. 1970'li yıllarda yapay zeka sistemleri hesap karmaşası sebebiyle duraksamıştır ve ilerleme kayıt edilmediği için yapay zeka çalışmaları için ayrılan fonlar kesintiye uğramıştır.

1980'li yıllarda tekrar fon artışı sayesinde yapay zeka endüstri haline gelmiştir. Yapay sinir ağları tekrar popüler çalışma alanları arasına dönmüştür [22]. 1987 yılında ise yapay zeka bilim haline gelmiştir.

1997 yılında IBM'in süper bilgisayarlarından '*Deep Blue*' dünya santraç şampiyonu Garry Kasparov'u yenmeyi başarmıştır. 1998 yılından itibaren internet kullanımında yaygınlaşmasıyla yapay zeka tabanlı pek çok program geniş kitlelere ulaşmıştır. 2000'li yıllarda ise yapay zeka tabanlı robotlar piyasaya gelmeye başlamıştır [21].

Günümüzde ise yapay zeka tabanlı uygulamaları hemen hemen her alanda kendine yer bulmaktadır. Yeni ürünler ortaya çıkmakta ve gündelik hayatta etkisini arttırarak hissettirmektedir. Başta otomasyon sistemleri olmak üzere pek çok alanda ürünler yapay zeka teknolojisinden faydalanılarak bilgisayarın işlem gücünden karar verme sürecinde yararlanılmaktadır. Yapay zeka teknolojisi sayesinde yeni ticari sistemler ortaya çıkmakta ve sistemlerin fonksiyonel özellikleri gelişmektedir.

Yapay zeka kapsamı farklı süreçleri içermektedir. Bu süreçler öğrenme, mantıksallaştırma ve kendini düzeltme yer alır. Yapay zeka günümüzde oldukça popüler olan makine öğrenmesi ve derin öğrenme kavramlarını kapsamaktadır (Şekil3.7) [20].



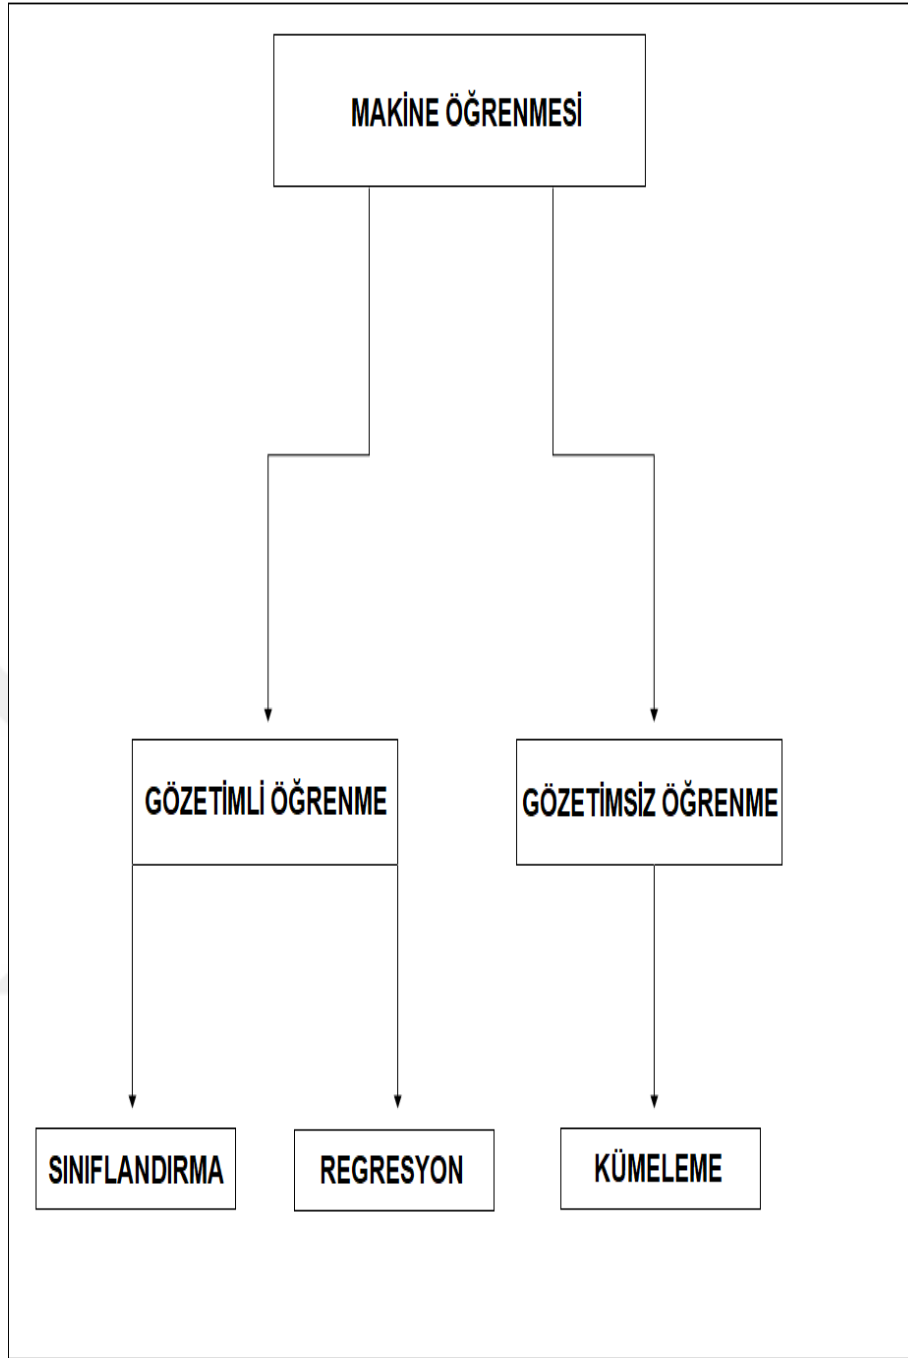
Şekil 3.7 : Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi

### 3.2.1 Makine öğrenmesi

Makine öğrenmesi, problemi probleme ait verilerden elde edilen bilgilere göre çözümleyen bilgisayar algoritmalarının genel adıdır. Makine öğrenmesinde, örnek veriler veya geçmiş deneyimler kullanılarak sistemin eğitilmesi sağlanır, sonrasında ise geliştirilen sistemin bilinmeyen örnekleri tahmin etmesi beklenir. Makine öğrenimi örnekler ve verilerden öğrenilen algoritmaları birleştirir. Sonuçların başarısı ise öğrenme sisteme verilen verilerin kalitesi ile orantılıdır [20].

Makine öğrenmesi gözetimli öğrenme (supervised learning) ve gözetimsiz (unsupervised learning) olmak üzere ikiye ayrılır. Gözetimli öğrenme, öğrenme kümesindeki sınıfların sayısı ve hangi verinin hangi sınıfta olduğunu bildiği öğrenme yöntemidir. Sınıflandırma ve regresyon metotları gözetimli öğrenmeye örnek verilebilir.

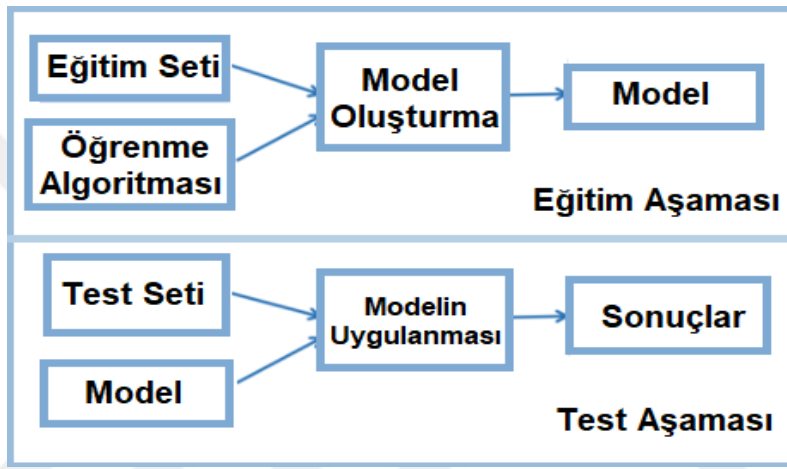
Gözetimsiz öğrenme ise öğrenme kümesindeki sınıfların sayısı ve girdilerin sonuçlarının bilinmediği öğrenme türüdür. Gözetimsiz öğrenme kısaca ham veriden bir anlam çıkarmaya çalışılması olarak tanımlanabilir. Kümeleme işlemleri gözetimsiz öğrenmeye örnek olarak verilebilir (Şekil 3.8).



Şekil 3.8 : Makine öğrenmesi yöntemleri

Makina öğrenmesi ve istatistikte, yeni veya bilinmeyen bir verinin hangi sınıfa ait olduğunun belirlenmesi işlemine sınıflandırma denir. Sınıflandırma bir veri kümesinde bulunan değerlerin belirli sınıflara ayrılması olarak da tanımlanabilir. Sınıflandırma algoritmaları daha önceden sınıfları belli olan verilerin özelliklerinden yola çıkarak hangi sınıfa ait olduğu bilinmeyen yeni veriyi doğru sınıfa yerleştirmeyi amaçlar.

Sınıflandırma algoritmaları çalışma prensibi olarak eğitim ve test olmak üzere iki aşamadan oluşur (Şekil 3.9). Sınıfları belli olan veriler aracılığıyla bir model oluşturulur ve oluşturulan bu model daha önce hangi sınıfa ait olduğu bilinmeyen veriler yardımı ile test edilerek sonuçlar elde edilir. Eğitim ve test veri setleri birbirinden bağımsızdır. Eğitim seti yardımıyla model eğitilir ve sonrasında test verileriyle oluşturulan model test edilir. Model test edildikten sonra konfüzyon (hata) matrisi çizilerek doğruluk, kesinlik, duyarlılık ve özgüllük gibi değerler hesaplanarak algoritmaların sınıflandırma performansı ve sonuçların güvenilirliği test edilir.

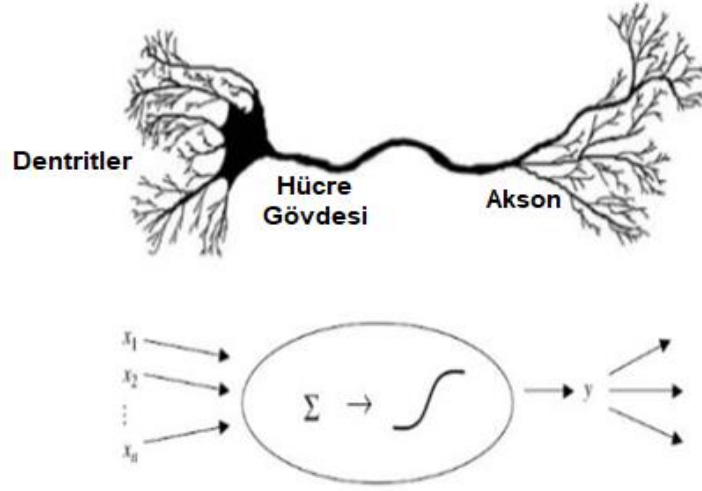


Şekil 3.9 : Sınıflandırma algoritmalarının temel çalışma prensibi

Makine öğrenmesi’nde sınıflandırma yapmak için kullanılacak farklı algoritmalar bulunmaktadır. Bu tez çalışmasında kullanılan sınıflandırma yöntemleri, Yapay Sinir Ağları (YSA), K-en Yakın Komşu algoritması (KNN) ve Destek Vektör Makinaları (DVM)’dir.

### 3.2.1.1 Yapay sinir ağları

Yapay sinir ağları, insan sinir sistemi ve işleyişinden etkilenerek geliştirilmiş, belirli ağırlıklara sahip bağlantılar sayesinde birbirine bağlanan ve her biri kendi hafızasına sahip işlem elemanlarından oluşan bilgi işleme yapıları; kısaca, biyolojik sinir sistemini ve işleyişini taklit eden bilgisayar programları olarak tanımlanabilir (Şekil 3.10) [23]. YSA’ların uygulama alanları oldukça geniştir. Ses, el yazısı ve parmak izi tanıma, görüntü işleme, fizyolojik işaretleri izleme, tanıma ve yorumlama, askeri sistemler, planlama, kontrol ve araştırma, öngörü, tahmin ve optimizasyon için YSA sıklıkla tercih edilmektedir.




Şekil 3.10 : İnsan sinir sistemi ve yapay sinir ağları çalışma benzerliği

YSA yapıları biyolojik sinir sistemi yapısından ve çalışma prensibinden esinlenerek geliştirilmiştir. Sinir hücreleri birbirleri arasında sinapsları yardımı ile iletişim kurarlar. Sinir hücreleri işlediği bilgileri aksonlarını kullanarak diğer sinir hücrelerine iletirler. Yapay sinir hücreleri ise dış dünyadan gelen bilgileri toplama fonksiyonu kullanarak toplar ve aktivasyon fonksiyonu aracılığıyla çıktıyı üretir. Ağın bağlantıları sayesinde ağdaki diğer elemanlara, nöronlara , gönderir [24].


Nöronlar arasındaki bağlantılar ağın yapısını oluşturur. YSA yapısı üç katmandan oluşur (Şekil 3.11). Bu katmanlar 'Girdi Katmanı', 'Gizli Katman(lar)' ve 'Çıktı Katmanı'dır. Girdi katmanı, dışarıdan sisteme verilen bilgileri alır. Girdi katmanında bir bilgi işlemi olmaz. Girdi katmanı aldığı bilgileri gizli katmanlara iletir. Gizli katman sayısı yapılacak işleme göre değişebilmektedir. Bir gizli katman ile pek çok problemi çözmek mümkündür. Girdi-çıktı arasındaki ilişkiye ve problemin karmaşıklığına göre sistemde bir veya birden fazla gizli katman bulunabilir.

Çıktı katmanı gizli katmanlardan gönderilen verileri işleyerek ağın çıktısını dış dünyaya iletir. Gizli katman sayısı ve gizli katmanlardaki nöron sayısı için belirli bir sayı yoktur, deneme yanılma yolu ile belirlenmektedir. Tek bir nöron ile bile sorular çözülebilir, anca daha karmaşık problemler için optimum nöron sayısının tespit edilmesi sistem doğruluğu açısından önemlidir.



Şekil 3.11 : YSA yapısı

YSA yapı olarak ve çalışma prensibi olarak çeşitli sınıflara ayrılır. Tek katmanlı YSA (Perseptron) yalnızca girdi katmanı ve çıktı katmanından oluşan herhangi bir gizli katman bulundurmayan YSA sistemleridir (Şekil 3.12a). Çok katmanlı YSA ise yapısında girdi ve çıktı katmanı ile birlikte bir veya birden fazla gizli katman bulunduran YSA sistemleridir (Şekil 3.12b).



Şekil 3.12 : YSA türleri: (a) Tek Katmanlı YSA, (b) Çok Katmanlı YSA

YSA çalışma prensibine göre ise üç farklı kategoriye ayrılır. Bu kategoriler 'İleri Beslemeli Ağ', 'Kaskat Bağlantılı Ağ' ve 'Geri Beslemeli Ağ'dır. İleri beslemeli ağ yapısında her bir katmanda bulunan nöronlar sadece bir önceki katmanda bulunan nöronlardan bilgi alır. Kaskat bağlantı ağ yapısında nöronlar sadece önceki katmanlardaki nöronlardan bilgi alır. Geri beslemeli yapay sinir ağ yapısında ise en az bir nöron sonraki katmanlarda bulunan nöronlardan da bilgi alır.

YSA'nın temel çalışma prensibi bağlantı ağırlık değerlerinin hesaplanmasına dayanır. YSA'lar sisteme yeni veriler ve örnekler gösterildikçe, bağlantı ağırlık değerlerini değiştirirler. Burada amaç ağa gösterilen veriler için doğru sonuçları verecek ağırlık değerlerini hesaplamaktır. Nöronların bağlantı ağırlık değerlerinin belirlenmesi işlemine ağırlık eğitilmesi denir. Ağırlık doğru ağırlık değerlerini hesaplaması verilerin sunduğu problemler hakkında, genellemeler yapabilmeye başlar, YSA'nın bu genelleştirme işlevine kavuşması durumuna ise ağırlık öğrenmesi denir. Yapay sinir ağının öğrenme sürecinde sistemin verdiği sonuçları hesaplamak, sonuçları hedef değerler ile karşılaştırmak ve bu değerleri kullanarak sistemin hatasını hesaplamak, hataları hesapladıktan sonra bağlantı ağırlıklarını değiştirerek aynı işlemleri tekrar etmek olmak üzere üç temel adım bulunmaktadır [24].

Bu tez çalışmasında 'İleri Beslemeli Geri Yayılımlı Tek Katmanlı YSA' ve 'İleri Beslemeli Geri Yayılımlı Çok Katmanlı YSA' yapıları kullanılmıştır. Geri yayılım yöntemi, önceden sonucu bilinen veriler ve sonuçlarını kullanarak YSA'nın eğitilmesi olarak tanımlanabilir [9]. Eğitim aşamasında sistem hataları hesaplanır, hesaplanan hatalar kullanılarak en aza inderecek şekilde katmanlardaki nöronların ağırlık katsayıları belirlenir.

$j$ . gizli katman nöronunun ve  $k$ . çıktı katmanı nöronunun sonuçları sırasıyla aşağıdaki denklemler kullanılarak hesaplanır (Denklemler 3.1, Denklemler 3.2) [25];

$$net_j = \sum_i (W_{ij} X_i) \quad (3.1)$$

$$o_k = f(net_k) \quad (3.2)$$

$X_p = \{X_1, X_2, X_3 \dots X_n\}$  geri yayılımlı YSA sisteminin girdi vektörünü,  $W_{ij} = \{W_{11}, W_{12}, \dots W_{nm}\}$  gizli katman ağırlık vektörünü,  $net$  ağırlık girdi değerlerini göstermektedir.

Her bir nöron için hata Denklem 3.3 kullanılarak hesaplanır, bu formülde  $\partial_k$   $k$ . nöron için hesaplanan hatayı,  $y_k$   $k$ . nöron için beklenen sonucu,  $o_k$  ise  $k$ . nöron için hesaplanan sonucu ifade eder [25];

$$\partial_k = (y_k - o_k) \quad (3.3)$$

Gizli katman(lar) ve sonuç katmanı ağırlıklarının  $\eta$  güncelleme hızı olmak üzere hesaplanması ise aşağıdaki formüller ile gerçekleştirilir (Denklem 3.4, Denklem 3.5) [25];

$$W_{kj}^o(t+1) = W_{kj}^o(t) + \eta \partial_k^o i_{kj} \quad (3.4)$$

$$W_{kj}^h(t+1) = W_{kj}^h(t) + \eta \partial_k^h x_{kj} \quad (3.5)$$

YSA ağırlıkları belirlenen formüller ve hataların belirlenmesi ile hesaplanır, hatanın en aza indirilmesi sonucu ağırlıklar sabitlenir ve sistem çıktı verir.

### 3.2.1.2 K-en yakın komşu algoritması

KNN, kolay uygulanabilir olması ve öğrenme aşamasının kullanışlı olması gibi nedenlerden dolayı sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Sınıflandırma işleminde  $k$  değeri incelenecek eleman-komşu sayısını belirler. Sisteme yeni bir girdi geldiğinde, bu girdi ile sistem içerisinde bulunan veriler arasındaki göre mesafeler hesaplanır ve seçilen  $k$  değerine bu yeni girdi en yakın mesafedeki kümelerden birine ilave edilir.

KNN basit, kullanışlı ve başarılı örüntü sınıflandırma yöntemlerinden biridir ve genel olarak makine öğrenme yöntemleri arasında sınıflandırma problemlerini çözmek için yaygın olarak kullanılmaktadır [26, 27, 28]. KNN sınıflandırma yöntemi veri madenciliği, yapay zekâ, istatistik, biyoinformatik farklı uygulama alanlarında da kullanılmaktadır [29, 30].

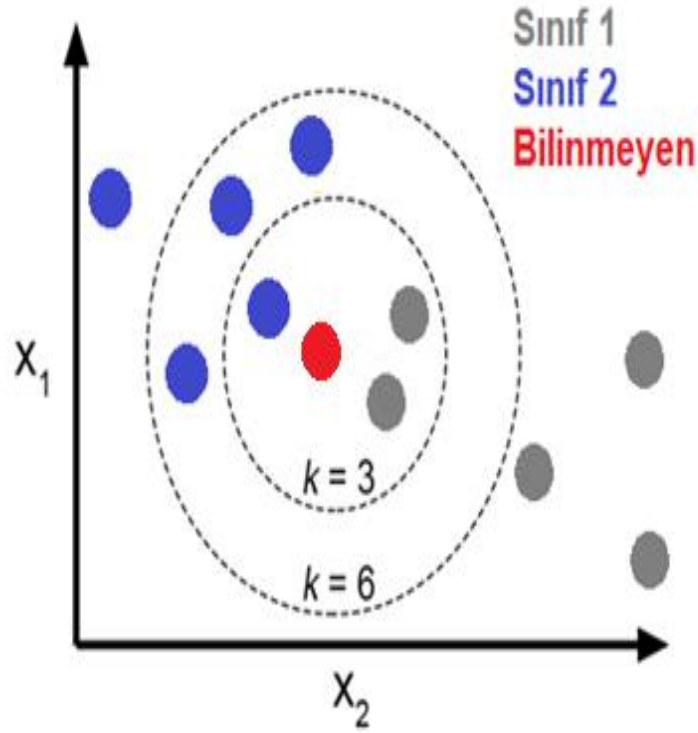
KNN algoritması, uygulanabilirlik, analitik olarak takip edilme, karmaşık eğitim verileri karşısında başarılı performans göstermesi vb. avantajları sayesinde sınıflandırma uygulamalarında yaygın olarak kullanılmaktadır [26]. Bu avantajların yanında, fazla belleğe ihtiyaç duyması, öznelik uzayının boyutu arttıkça işlem yükünün artması, algoritma performansının  $k$  incelenecek komşu sayısı, öznelik sayısı ve uzaklık ölçüm yöntemi gibi parametrelere bağlı olarak etkilenmesi gibi dezavantajları da bulunmaktadır [26, 31].



KNN algoritması temel çalışma prensibi sisteme verilen ve hangi sınıfa ait olduğu bilinmeyen verinin, eğitim setinde yer alan ve sınıfları belli olan veriler ile arasındaki benzerliğine (yakınlığına) göre sınıflandırmasıdır (Şekil 3.13).

KNN algoritması beş adımda çalışır:

1.  $k$  değeri yani incelenecek komşu sayısı sisteme tanımlanır. Böylece bilinmeyen verinin en yakın kaç komşusuna bakılacağı belirlenmiş olur.
2. Sistem uzayındaki verilerden sınıfı bilinmeyen hedef veriye olan uzaklıklar hesaplanır.
3. Hesaplanan uzaklıklar küçükten büyüğe sıralanır ve minimum uzaklık dikkate alınarak hedef veriye en yakın komşular bulunur.
4. Hedef veriye en yakın komşular bulunduktan sonra komşu sınıfları toplanır.
5. Sınıfı bilinmeyen veriye en uygun sınıf oylama ile belirlenir.



Şekil 3.13 : K-en yakın komşu algoritması çalışma prensibi

KNN algoritması'nın başarısı için uygun  $k$  değerinin belirlenmesi algoritmanın performansı açısından oldukça önemlidir. Şekil 3.13'de görüldüğü gibi  $k=3$  seçildiğinde bilinmeyen verinin Sınıf 1'e ait olduğu görülmektedir. Ancak  $k=6$  seçildiğinde bilinmeyen veri Sınıf 2'ye ait olmaktadır.

Uygun  $k$  değeri seçilmesi algoritmanın başarısı için çok önemlidir. Sınıflandırma işlemi sırasında  $k=1$  seçilirse, bilinmeyen veri kendisine en yakın komşu sınıfa atanır,  $k$  değeri örnek sayısına yaklaştıkça sistem uzayındaki bütün veriler dikkate alınmakta ve oylamaya göre sınıf seçimi yapılmaktadır [32].

KNN algoritması performansı için bir diğer önemli etken mesafe hesaplama yöntemidir. Veriler arasında mesafe hesaplarken farklı yöntemler kullanılabilir. Öklid Uzaklığı, Manhattan Uzaklığı, Minkowski Uzaklığı ve Chebyshev Uzaklığı yaygın olarak kullanılan mesafe ölçüm yöntemleridir [32].

Öklid uzaklığı, sınıflandırma ve kümeleme yöntemlerinde oldukça sık kullanılan bir mesafe hesaplama yöntemidir. Öklid uzaklığı, uzaydaki iki nokta arasındaki doğrusal uzaklıktır.  $X$  ve  $Y$  noktaları arasındaki Öklid uzaklığı  $X=(x_1, x_2, \dots, x_k)$  ve  $Y=(y_1, y_2, \dots, y_k)$  olmak üzere, Denklem 3.6'ya göre hesaplanır [33]:

$$D = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3.6)$$

Manhattan uzaklığı, sınıflandırma ve kümeleme algoritmalarında yaygın olarak tercih edilen bir uzaklık hesaplama yöntemidir. Manhattan uzaklığı uzaydaki iki nokta arasındaki mesafe farklarının mutlak değerlerinin toplamı olarak ifade edilebilir.  $X$  ve  $Y$  noktaları arasındaki Manhattan uzaklığı  $X=(x_1, x_2, \dots, x_k)$  ve  $Y=(y_1, y_2, \dots, y_k)$  olmak üzere, Denklem 3.7'ye göre hesaplanır [33]:

$$D = \sum_{i=1}^k |x_i - y_i| \quad (3.7)$$


Minkowski uzaklığı, kümeleme ve sınıflandırma gibi makine öğrenmesi ve veri madenciliği uygulamalarında yaygın olarak tercih edilen öklid uzaklığı ve manhattan uzaklığı gibi uzaklık hesaplama yöntemlerinin genel formülüdür.  $X$  ve  $Y$  noktaları arasındaki Minkowski uzaklığı  $X=(x_1, x_2, \dots, x_k)$  ve  $Y=(y_1, y_2, \dots, y_k)$  olmak üzere, Denklem 3.8'e göre hesaplanır.  $p$  değişkeninin değişen değerleri için farklı uzaklık hesaplama yöntemlerini tanımlamak için minkowski uzaklığı kullanılmaktadır. Minkowski uzaklığı formülünde  $p=2$  seçildiği durum, öklid uzaklığı formülünü,  $p=1$  seçildiği özel durum anhattan uzaklığı formülünü ve  $k \rightarrow \infty$  seçildiği durum, Chebyshev uzaklığı formülünü vermektedir. [33].

$$D = (\sum_{i=1}^k |x_i - y_i|^p)^{1/p} \quad (3.8)$$

Chebyshev uzaklığı ölçütü maksimum değer uzaklığı olarak da tanımlanabilir. Minkowski uzaklığı formülünde,  $k \rightarrow \infty$  olduğu özel durumdur. Uzaydaki iki nokta arasındaki farkların mutlak değerlerinin maksimum değeridir. Herhangi iki nokta,  $X$  ve  $Y$  noktaları arasındaki Chebyshev uzaklığı  $X=(x_1, x_2, \dots, x_k)$  ve  $Y=(y_1, y_2, \dots, y_k)$  olmak üzere, Denklem 3.9'ye göre hesaplanır [34]:

$$D = \max_{i=1}^k |x_i - y_i| \quad (3.9)$$

Bu tez çalışmasında, KNN algoritması veriler arası mesafe ölçümü için öklid uzaklığı (Denklem 3.6) ve manhattan uzaklığı (Denklem 3.7) kullanılmıştır (Şekil 3.14).



Şekil 3.14 : Öklid uzaklığı ve manhattan uzaklığı

### 3.2.1.3 Destek vektör makineleri

DVM istatistiksel öğrenme yöntemine bağlı olarak çalışan kontrol edilebilir bir sınıflandırma yöntemidir. DVM sınıflandırma konusunda kullanılan oldukça basit ve etkili yöntemlerden biridir. DVM yönteminde kullanılan matematiksel hesaplamalar ilk başta iki sınıflı doğrusal verilerin bulunduğu problemlerin sınıflandırılması için belirlenmiş olup, sonrasında geliştirilen yöntemler ile çok sınıflı ve doğrusal olmayan problemlerin sınıflandırılması için de kullanılmaya başlanmıştır. DVM temelde iki sınıflı birbirinden en uygun şekilde ayırabilen hiper-düzlemin bulunması ve iki sınıf arasında bir sınır çekilmesi prensibine dayanmaktadır [35].

DVM yöntemi sınıflandırma problemini kareli optimizasyon problemine çevirerek sonuca ulaşır, bu özellik diğer sınıflandırma algoritmaları ile karşılaştırıldığında DVM'e önemli bir avantaj sağlamaktadır. Bu sayede problemin çözümü sırasında eğitim aşamasında gerçekleşen işlem sayısı azalmakta ve diğer sınıflandırma yöntemlerine göre daha hızlı sonuç vermektedir [36].

DVM özellikle büyük hacimli veri setlerinde sınıflandırma konusunda önemli bir avantaj sağlamaktadır. Aynı zamanda optimizasyon temelli bir algoritma olduğu için sınıflandırma başarısı, hesaplama karmaşıklığı ve kullanılabilirlik yönlerinden diğer sınıflandırma algoritmalarına göre daha başarılıdır [37].

DVM veri setinin doğrusal olarak ayrılabilir ve doğrusal olarak ayrılamama durumuna göre ikiye ayrılmaktadır. Doğrusal olarak ayrılabilen iki sınıf arasında sonsuz sayıda doğru geçer (Şekil 3.15a). DVM'nin amacı iki gruba da en uzak olacak ayırıcı bir sınır doğrusunu bulmaktır. Doğrusal olarak ayrılan veriler için DVM gruplara en uygun uzaklıkta optimum hiper-düzlemi çizmeye çalışır.

Optimum hiper-düzlemi belirlemek için sınırları oluşturacak vektörlerin belirlenmesi gerekir. Bu vektörler 'Destek Vektörler' olarak adlandırılır. 'Destek Vektörler' aracılığı ile sınır çizgileri belirlendikten sonra belirlenen sınır çizgileri birbirine yaklaştırılarak ortak bir sınır çizgisi bulunur. Üretilen bu ortak sınır çizgisi iki sınıfta en uzak mesafede olmalıdır. İki boyutlu veri kümelerinde grupları birbirinden ayıran bir sınır çizgisi iken çok boyutlu veri kümelerinde grupları bir hiper-düzlem ayırır. Bu ortak sınır çizgisi grupları birbirinden ayıran en uygun uzaklıktaki optimum hiper-düzlemi ifade eder (Şekil 3.15b).

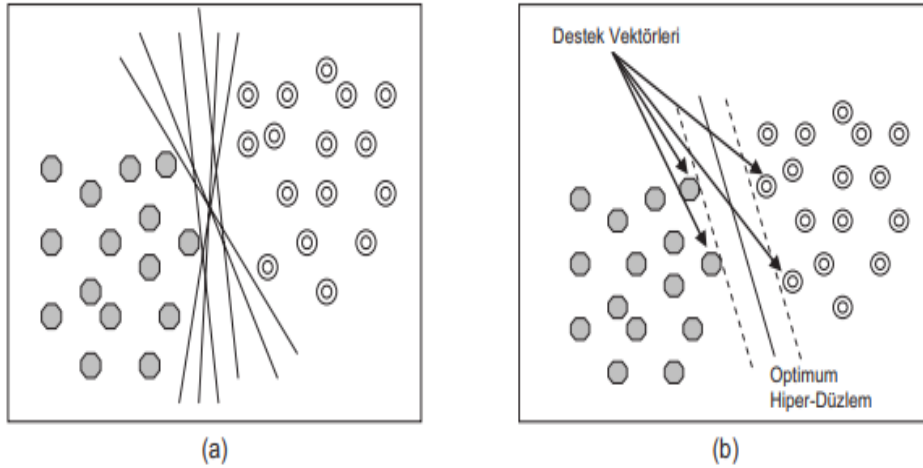
Doğrusal olarak ayrılabilen iki sınıflı  $n$  tane örnek içeren bir sınıflandırma probleminde eğitim veri setinin  $\{x_i, y_i\}, i = 1, \dots, n$  olduğu kabul edilirse, iki sınıfı ayıracak en uygun hiper-düzleme ait eşitsizlik Denklem 3.10 ve Denklem 3.11'deki gibi olur. Destek vektörleri ise Denklem 3.12'deki gibi ifade edilir [38].

$$f(x_i) = w \cdot x_i + b \geq +1, y_i = +1 \quad (3.10)$$

$$f(x_i) = w \cdot x_i + b \leq -1, y_i = -1 \quad (3.11)$$

$$w \cdot x_i + b = \pm 1 \quad (3.12)$$


Bu eşitsizliklerde  $x \in R^N$  olup  $N$ -boyutlu bir uzayı,  $y \in \{-1, +1\}$  veri sınıflarını,  $w$  ağırlık vektörünü ve  $b$  eğilim değerini göstermektedir [38].



Şekil 3.15 : (a) Doğrusal olarak ayrılabilen iki sınıflı veri seti için çizilebilecek hiper-düzlemler, (b) Optimum hiper-düzlem ve destek vektörler [39]

DVM başlangıçta doğrusal olarak ayrılabilen verilerin sınıflandırılması için kullanılmıştır. Ancak sonrasında doğrusal olarak ayrılamayan veri setlerinin sınıflandırılması için geliştirilmiştir. Gerçek hayatta pek çok problemde verilerin doğrusal olarak sınıflandırılması genellikle mümkün değildir. Doğrusal olarak ayrılamayan veri setleri için Kernel (Çekirdek) fonksiyonları kullanılmaktadır. Çekirdek fonksiyonları aracılığıyla veriler farklı boyutta bir uzaya aktarılır ve yapılan bu işlem sonrası yeni boyutlu uzayda verileri ayıracak optimum hiper-düzlem aranır.

Şekil 3.16’da görüldüğü üzere girdi uzayında doğrusal olarak ayrılamayan veri seti, çekirdek fonksiyonu aracılığıyla yüksek boyutlu özellik uzayına aktarılır ve sınıflar arasında optimum hiper-düzlem belirlenir. Bu örnekte 2 boyutlu girdi uzayı 3 boyutlu bir uzaya aktarılmıştır.



Şekil 3.16 : Çekirdek fonksiyonu kullanılarak veri setinin daha yüksek boyutlu uzaya aktarılması

Literatürde linear çekirdek fonksiyonu (Denklem 3.13), polinomal çekirdek fonksiyonu (Denklem 3.15) ve radyal tabanlı çekirdek fonksiyonu (Denklem 3.14) ve sıklıkla kullanılmaktadır. Çekirdek fonksiyonu formüllerinde  $\gamma$  radyal tabanlı tabanlı çekirdek fonksiyonu için kernel boyutunu,  $d$  polinomal çekirdek fonksiyonu için polinom derecesini, ifade etmektedir.

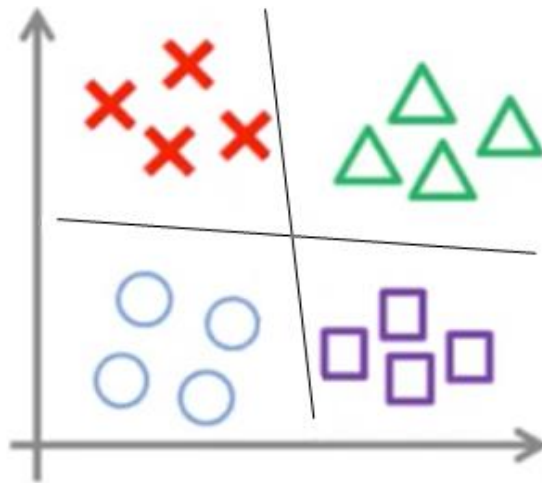
$$k(x, y) = x^T \cdot y \quad (3.13)$$

$$k(x, y) = ((x \cdot y) + 1)^d \quad (3.14)$$

$$k(x, y) = e^{-\gamma \|x - y\|^2} \quad (3.15)$$

Linear çekirdek fonksiyonu skaler çarpım fonksiyonu olarak da bilinir. Polinomal çekirdek fonksiyonu sade ve anlaşılabilir olduğu söylenebilir ancak polinom derecesindeki artış algoritmanın daha karmaşık hale gelmesine sebep olmaktadır. Bu durum algoritmanın çalışma süresini artırmakta ve zaman zaman başarısını da etkilemektedir. Radyal tabanlı çekirdek fonksiyonu, polinom fonksiyonu gibi sade ve anlaşılabilir olarak ifade edilebilir. Aynı zamanda kernel boyutu değişkeninde meydana gelen değişimler algoritmanın performansını daha az etkilemektedir [39,40].


DVM ilk kullanılmaya başlandığı yıllarda iki sınıflı veri setlerinin sınıflandırılması işlemi için kullanılmıştır ve daha sonra çok sınıflı veri setleri için genelleştirilmiştir. Şekil 3.17'de çok sınıflı bir DVM örneği gösterilmiştir. DVM çalışma prensibi olarak uzayı yalnızca iki gruba ayırmaktadır. DVM ile çok sınıflı problemlerin sınıflandırılması için temelde iki farklı yöntem kullanılmaktadır. Bu yöntemler One-vs-One (OVO) ve One-vs-All (OVA)'dır. OVO metodunda eğitime kümesine uygun olarak DVM'ler ikili çıkışlar üzerine eğitilir ve sınıflar birbirleri ile karşılaştırılır. OVO metodunda ana düşünce problemin ikili gruplara indirilerek ayrı ayrı DVM uygulanması esasına dayanır. OVA metodunda bir sınıfa ait olan veriler diğer tüm sınıflara ait veriler ile karşılaştırılır ve sınıflandırılır. OVA yönteminde problem tek gruptan bütün gruplara doğru modellenir.  $n$  sınıflı bir problemin OVO ile sınıflandırılması için gereken DVM sayısı  $n(n-1)/2$  iken OVA ile sınıflandırılması için gerek DMV sayısı  $n$ 'dir. OVO yönteminde yapılan işlem sayısı OVA yöntemine göre daha fazladır bu algoritmanın çalışma hızını etkilemektedir.



Şekil 3.17 : Çok sınıflı DVM sınıflandırıcı örneği

### 3.2.2 Öznitelik çıkarımı

Öznitelik çıkarımı sınıflandırma algoritmalarının önemli bir bölümüdür. Başarılı bir sınıflandırma performansı için verilerden ayırt edici öznitelikleri çıkarmak ve kullanmak oldukça önemlidir. Öznitelik çıkarımı ham datanın öğrenme algoritmalarına girdi olarak kullanılacak formata dönüştürülmesi olarak tanımlanabilir (Şekil 3.18).



Şekil 3.18 : Sınıflandırma süreci

Bu tez çalışmasında EMG ve UF sinyallerinden çeşitli öznitelikler çıkarılmıştır. Çıkarılan öznitelikler kullanılarak sınıflandırma yapılmıştır. Kullanılan öznitelikler uzman hekimlerin de AÜSD hastalıklarının tanı sürecinde UF-EMG sinyallerini incelerken dikkate aldıkları sinyal özelliklerinden seçilmiştir.

UF sinyalleri gerek patolojik gerekse normal durumlarda çeşitli karakteristik özelliklere sahiptir. Toplam akış süresi , akış hızı , UF sinyalinde meydana gelen tepe sayısı vb. pek çok sinyal karakteristiği hastalar ile sağlıklı bireyler arasında ayırım yapılmasında önemli rol oynamaktadır. EMG sinyalinin en önemli özelliği ise sağlıklı bireylerde boşaltım sırasında pelvik kaslar gevşediği için herhangi bir EMG aktivitesi görülmesinin beklenmemesidir. Boşaltım sırasında EMG sinyalinin varlığı AÜSD hastalıkları için önemli bir ayırt edici özniteliktir.



Literatürde yalnızca UF sinyalleri kullanılarak yapılan bir AÜSD hastalıkları sınıflandırma çalışmasında ilk yükselen eğimin değeri, son azalan eğimin değeri, birden fazla tepe noktası varlığı, genlik boşaltım süresi oranı ve UF eğrisinin aralıklılığı gibi öznitelikler kullanılmıştır [8].

Literatürde AÜSD hastalıkları tespiti için yapılan başka bir sınıflandırma çalışmasında UF-EMG sinyalleri incelenmiş ve EMG sinyalinin varlığı, hastanın yaşı, hastanın cinsiyeti, ortalama akış hızı, işime boyunca sifira inme sayısı, maksimum akış hızı ve o hıza ulaşma süresi, tepe sayısı ve ortalama akış hızı gibi öznitelikler kullanılmıştır [9]. Bu tez çalışmasında kullanılan öznitelikler hem literatürdeki benzer çalışmalarda kullanılan öznitelikler dikkate alınarak hem de uzman hekimlerin tanı sırasında dikkat ettiği noktalar dikkate alınarak belirlenmiştir.


UF eğrileri hem normal hem de patolojik durumlar için belirli şekillere sahiptir. UF eğrilerinden elde edilen veriler kişinin alt üriner sistem durumu hakkında önemli bilgiler vermektedir. Bu tez çalışmasında UF sinyalinden elde edilen ortalama akış hızı, maksimum akış hızı, UF eğrisinin tepe sayısı, maksimum akış hızına ulaşma süresi, ve işeme boyunca sifira inme sayısı gibi öznitelikler çıkarılarak AÜSD teşhisi için sınıflandırma algoritmalarında kullanılmıştır.

EMG sinyali literatürde AÜSD teşhisi için yapılan çalışmalarda genellikle kullanılmamıştır. AÜSD'yi teşhis etmek için UF-EMG sinyallerini sınıflandıran bir çalışma mevcuttur ancak o çalışmada işeme sırasında EMG sinyalinin sadece var olup olmadığı bir öznitelik olarak kullanılmıştır [9]. Bu tez çalışmasında EMG sinyalinin varlığının yanı sıra sinyalin maksimum genlik değeri, ortalama değeri, varyansı ve enerjisi de incelenerek sınıflandırma için öznitelik olarak kullanılmıştır.

UF ve EMG sinyallerinden çıkarılan öznitelikler Çizelge 3.1'de gösterilmiştir. Sinyallerden çıkarılan özniteliklerin yanı sıra hastanın yaşı ve cinsiyeti de sınıflandırma için kullanılan özniteliklere eklenmiştir. Sonuç olarak bu tez çalışmasında altı tanesi EMG sinyalinden, altı tanesi UF sinyalinden ve iki tanesi hastaların kişisel özelliklerinden olmak üzere toplam 14 adet öznitelik kullanılmıştır. Çıkarılan öznitelikler sınıflandırma algoritmalarına girdi olarak verilmiş ve sonuçlar elde edilmiştir. Çalışmanın genel akış şeması Şekil 3.19'da gösterilmiştir.

Çizelge 3.1 : Sınıflandırma için kullanılan öznitelikler

<b>Sinyal Öznitelikleri</b>	
<b>EMG Sinyali</b>	<b>UF Sinyali</b>
Varyans Değeri	Ortalama Akış Hızı
Sinyalin Enerjisi	Maksimum Akış Hızı
Sinyalin Varlığı	Maksimum Hıza Ulaşma Süresi
Ortalama Genlik Değeri	Tepe Sayısı
Maksimum Genlik Değeri	Sıfıra İnme Sayısı
<b>Kişisel Öznitelikler</b>	
Yaş	Cinsiyet



Şekil 3.19 : Çalışmanın akış şeması

### 3.3 Algoritma Performanslarının Değerlendirilmesi

Sınıflandırma algoritmalarının sonuçlarının değerlendirilmesi elde edilen sınıflandırma sonuçlarının gerçekçiliği açısından oldukça önemlidir. Konfüzyon matrisi (Çizelge 3.2) , makine öğrenimi ve sınıflandırma probleminde hata matrisi olarakta bilinmektedir ve algoritmanın performansının görselleştirilmesini sağlayan bir matris düzenidir. Konfüzyon matrisi algoritmanın verdiği sonuçların güvenilirliği açısından önemli bilgiler vermektedir. Doğruluk (Accuracy), kesinlik (Precision), özgüllük (Specificity) ve duyarlılık (Sensitivity) gibi değerler hesaplanarak algoritmaların performansları belirlenmiştir.

Çizelge 3.2 : Konfüzyon Matris

<b>Konfüzyon Matris</b>		<b>Gerçek Durum</b>	
		<b>Pozitif</b>	<b>Negatif</b>
<b>Sınıflandırma Sonucu</b>	<b>Pozitif</b>	Gerçek Pozitif (GP)	Yanlış Pozitif (YP)
	<b>Negatif</b>	Yanlış Negatif (YN)	Gerçek Negatif (GN)

**Gerçek Pozitif (GP):** Tahmin edilen değer pozitif ve gerçek değerde pozitif ise bu değerler gerçek pozitif olarak adlandırılır. GP doğru sınıflandırılmış pozitif örnek sayısını ifade etmektedir [41].

**Yanlış Pozitif (YP):** Tahmin edilen değer pozitif ve gerçek değer negatif ise bu değerler yanlış pozitif olarak adlandırılır. YP yanlış sınıflandırılmış pozitif örnek sayısını ifade etmektedir [41].

**Yanlış Negatif (YN):** Tahmin edilen değer negatif ve gerçek değer pozitif ise bu değerler yanlış negatif olarak adlandırılır. YN yanlış sınıflandırılmış negatif örnek sayısını ifade etmektedir [41].

**Gerçek Negatif (GN):** Tahmin edilen değer negatif ve gerçek değerde negatif ise bu değer gerçek negatif olarak adlandırılır. GN doğru sınıflandırılmış negatif örnek sayısını ifade eder [41].

Doğruluk, sınıflandırma modellerini değerlendirmek için kullanılan ölçümlerden birisidir. Doğruluk sınıflandırma modelinin doğru tahmin ettiği veri sayısının toplam veri sayısına olan oranıdır (Denklem 3.16). Doğruluk değeri sınıflandırma algoritmasının performansı açısından önemli bir kriterdir.

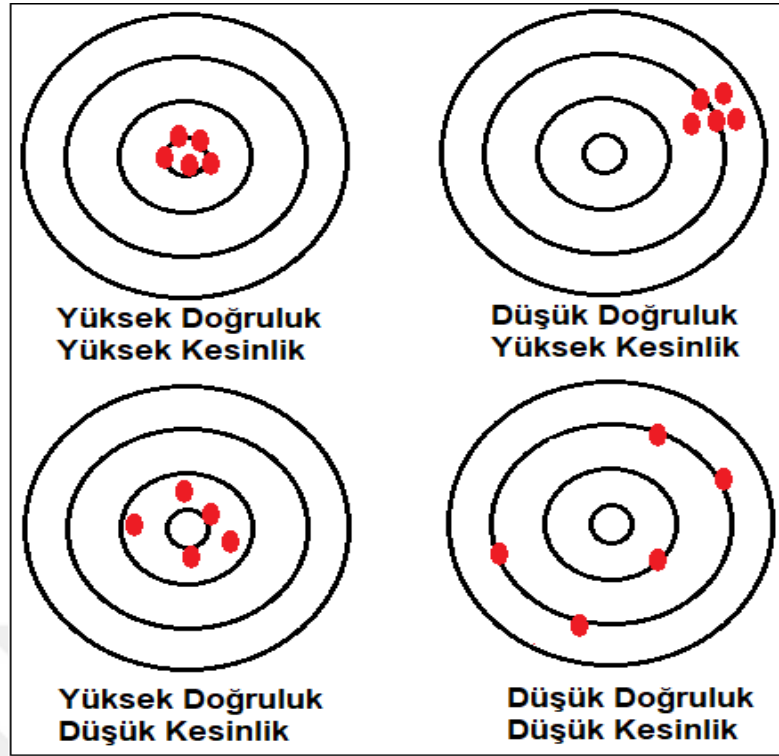
$$Doğruluk = \frac{GP+GN}{GP+YP+YN+GN} \quad (3.16)$$

Kesinlik, tekrar edilen testler sonucu yöntemin benzer sonuçlar vermesidir. Kesinlik temel olarak her bir sınıfı doğru bir şekilde sınıflandırmak için modelin ne kadar kesin olduğunu söyler (Denklem 3.17).

$$Kesinlik = \frac{GP}{GP+YP} \quad (3.17)$$

Doğruluk ve kesinlik birbirinden bağımsız ve farklı değerlerdir. Doğruluk ve kesinlik arasındaki temel fark, doğruluk ölçümünün gerçek değere ne kadar yakın olduğunu, kesinlik ise yöntemin tekrar edilen uygulamalar sonucu test sonuçlarının birbirine yakınlığının bir ölçüsüdür. Bir yöntemin yüksek doğruluğa sahip olması demek aynı zamanda kesinlik durumu hakkında fikir vermez aynı şekilde yüksek kesinliğe sahip olması yöntemin doğruluğu ile ilgili fikir vermez.

Yöntemin gerçekçi bir şekilde değerlendirilmesi açısından hem yüksek doğruluk hem de yüksek kesinliğe sahip olması beklenmektedir. Doğruluk, yöntemin doğru veya beklenen sonuca ne kadar yakın olduğunu gösterir. Kesinlik, iki veya daha fazla ölçümün birbirine ne kadar yakın olduğunu gösterir. Doğruluk ve kesinlik değerleri birbirlerini etkilemez. Bir yöntem yüksek doğruluk ile sonuç verirken, verdiği sonuçlar uygulama sayısı ile değişebilmektedir. Doğruluk kesinlik ilişkisi Şekil 3.20’de gösterilmiştir.



Şekil 3.20 : Doğruluk ve kesinlik ilişkisi

Duyarlılık, sınıflandırma modellerini değerlendirmek için kullanılan önemli parametrelerden birisidir. Pozitif olarak tahmin edilen GP verilerin oranının bir ölçüsüdür (Denklem 3.18). Duyarlılık, gerçek durumu pozitif olan verilerin ne kadarının pozitif olarak sınıflandırıldığını gösterir.

$$Duyarlılık = \frac{GP}{GP+YN} \quad (3.18)$$

Özgüllük, negatif olan verilerin ne kadarının doğru şekilde tespit edildiğini gösterir (Denklem 3.19). Negatif olarak tahmin edilen GN verilerin oranının bir ölçüsüdür.

$$Özgüllük = \frac{GN}{GN+YP} \quad (3.19)$$



## 4. BULGULAR VE DEĞERLENDİRME

Uzman hekimler tarafından derecelendirilmiş 967 hasta verisi MATLAB ortamına aktarılmıştır. MATLAB ortamında UF-EMG sinyallerinden sınıflandırma işlemi için kullanılacak öznitelikler çıkarılmıştır. Çıkarılan öznitelikler kullanılarak UF-EMG sinyalleri KNN, DVM ve YSA algoritmaları ile sınıflandırılmıştır. Tüm veri setinin %80'i sistemlerin eğitimi için eğitim veri seti olarak, kalan %20'si sistemlerin test edilmesi test veri seti olarak kullanılmıştır.

Sınıflandırma algoritmalarının sonuçları kullanılarak konfüzyon matrisleri elde edilmiştir. Elde edilen konfüzyon matrisleri üzerinden doğruluk, kesinlik, duyarlılık ve özgüllük değerleri hesaplanarak sınıflandırma algoritmalarının performans değerlendirmesi yapılmıştır. Performans değerlendirmesi sonucu AÜSD tanısı için en başarılı sınıflandırma algoritması belirlenmiştir.

### 4.1 K-En Yakın Komşu Algoritması Sonuçları

KNN algoritması uygulamasında veriler arası uzaklık mesafelerini hesaplamak için 'Öklid' ve 'Manhattan' uzaklıkları kullanılmıştır. KNN sisteminin eğitim verisi ve test verisi tüm veri setinin içerisinde rastgele seçilmiştir. En başarılı sonucu veren ' $k$ ' komşu değerleri genel doğruluk oranına göre belirlenmiştir.

KNN algoritmasından elde edilen sonuçlar kullanılarak konfüzyon matrisleri çizilmiştir (Şekil 4.1 – 4.10). Çizilen konfüzyon matrisleri üzerinden doğruluk, kesinlik, duyarlılık ve özgüllük değerleri KNN algoritmasının performans değerlendirmesini yapmak için hesaplanmıştır. Çizelge 4.1 ve Çizelge 4.2'de hesaplanan doğruluk, kesinlik, duyarlılık ve özgüllük değerleri gösterilmiştir.

**Manhattan 1**

**Confusion Matrix**

1	33 16.8%	3 1.5%	2 1.0%	0 0.0%	0 0.0%	14 7.1%	63.5% 36.5%
2	7 3.6%	25 12.7%	4 2.0%	5 2.5%	4 2.0%	3 1.5%	52.1% 47.9%
3	3 1.5%	4 2.0%	14 7.1%	7 3.6%	1 0.5%	3 1.5%	43.8% 56.3%
4	0 0.0%	0 0.0%	1 0.5%	21 10.7%	3 1.5%	4 2.0%	72.4% 27.6%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 4.1%	4 2.0%	66.7% 33.3%
6	2 1.0%	0 0.0%	0 0.0%	1 0.5%	3 1.5%	18 9.1%	75.0% 25.0%
	73.3% 26.7%	78.1% 21.9%	66.7% 33.3%	61.8% 38.2%	42.1% 57.9%	39.1% 60.9%	60.4% 39.6%
	1	2	3	4	5	6	
	<b>Target Class</b>						

Şekil 4.1 : KNN konfüzyon matrisi, manhattan uzaklığı 1

**Manhattan 2**

**Confusion Matrix**

1	27 13.7%	11 5.6%	1 0.5%	0 0.0%	0 0.0%	9 4.6%	56.3% 43.8%
2	5 2.5%	28 14.2%	9 4.6%	3 1.5%	2 1.0%	3 1.5%	56.0% 44.0%
3	3 1.5%	6 3.0%	19 9.6%	5 2.5%	5 2.5%	3 1.5%	46.3% 53.7%
4	1 0.5%	0 0.0%	3 1.5%	16 8.1%	2 1.0%	2 1.0%	66.7% 33.3%
5	0 0.0%	0 0.0%	0 0.0%	2 1.0%	10 5.1%	1 0.5%	76.9% 23.1%
6	0 0.0%	0 0.0%	0 0.0%	3 1.5%	0 0.0%	18 9.1%	85.7% 14.3%
	75.0% 25.0%	62.2% 37.8%	59.4% 40.6%	55.2% 44.8%	52.6% 47.4%	50.0% 50.0%	59.9% 40.1%
	1	2	3	4	5	6	
	<b>Target Class</b>						

Şekil 4.2 : KNN konfüzyon matrisi, manhattan uzaklığı 2



**Manhattan 3**

**Confusion Matrix**

Output Class	1	2	3	4	5	6	
1	35 17.8%	2 1.0%	3 1.5%	0 0.0%	0 0.0%	6 3.0%	76.1% 23.9%
2	8 4.1%	30 15.2%	8 4.1%	4 2.0%	1 0.5%	0 0.0%	58.8% 41.2%
3	2 1.0%	6 3.0%	16 8.1%	9 4.6%	5 2.5%	3 1.5%	39.0% 61.0%
4	0 0.0%	0 0.0%	5 2.5%	14 7.1%	1 0.5%	3 1.5%	60.9% 39.1%
5	0 0.0%	0 0.0%	0 0.0%	2 1.0%	12 6.1%	3 1.5%	70.6% 29.4%
6	1 0.5%	0 0.0%	0 0.0%	4 2.0%	2 1.0%	12 6.1%	63.2% 36.8%
	76.1% 23.9%	78.9% 21.1%	50.0% 50.0%	42.4% 57.6%	57.1% 42.9%	44.4% 55.6%	60.4% 39.6%
	1	2	3	4	5	6	
	Target Class						

Şekil 4.3 : KNN konfüzyon matrisi, manhattan uzaklığı 3

**Manhattan 4**

**Confusion Matrix**

Output Class	1	2	3	4	5	6	
1	26 13.2%	4 2.0%	2 1.0%	2 1.0%	0 0.0%	9 4.6%	60.5% 39.5%
2	12 6.1%	27 13.7%	6 3.0%	2 1.0%	1 0.5%	2 1.0%	54.0% 46.0%
3	1 0.5%	2 1.0%	19 9.6%	11 5.6%	3 1.5%	7 3.6%	44.2% 55.8%
4	0 0.0%	0 0.0%	0 0.0%	15 7.6%	1 0.5%	3 1.5%	78.9% 21.1%
5	0 0.0%	0 0.0%	1 0.5%	2 1.0%	12 6.1%	1 0.5%	75.0% 25.0%
6	5 2.5%	0 0.0%	0 0.0%	7 3.6%	1 0.5%	13 6.6%	50.0% 50.0%
	59.1% 40.9%	81.8% 18.2%	67.9% 32.1%	38.5% 61.5%	66.7% 33.3%	37.1% 62.9%	56.9% 43.1%
	1	2	3	4	5	6	
	Target Class						

Şekil 4.4 : KNN konfüzyon Matrisi, manhattan uzaklığı 4

**Manhattan 5**  
**Confusion Matrix**

1	34 17.3%	4 2.0%	4 2.0%	0 0.0%	0 0.0%	6 3.0%	70.8% 29.2%
2	12 6.1%	26 13.2%	4 2.0%	1 0.5%	1 0.5%	1 0.5%	57.8% 42.2%
3	4 2.0%	4 2.0%	18 9.1%	6 3.0%	1 0.5%	5 2.5%	47.4% 52.6%
4	0 0.0%	0 0.0%	3 1.5%	15 7.6%	2 1.0%	3 1.5%	65.2% 34.8%
5	0 0.0%	1 0.5%	0 0.0%	0 0.0%	10 5.1%	6 3.0%	58.8% 41.2%
6	2 1.0%	0 0.0%	0 0.0%	3 1.5%	6 3.0%	15 7.6%	57.7% 42.3%
	65.4% 34.6%	74.3% 25.7%	62.1% 37.9%	60.0% 40.0%	50.0% 50.0%	41.7% 58.3%	59.9% 40.1%
	1	2	3	4	5	6	
	<b>Target Class</b>						

Şekil 4.5 : KNN konfüzyon matrisi, manhattan uzaklığı 5

Çizelge 4.1 : KNN Manhattan uzaklığı sonuçları

<b>KNN Manhattan Uzaklığı</b>				
<i>k</i>	Doğruluk	Kesinlik	Duyarlılık	Özgüllük
17	<b>0.6042</b>	<b>0.6223</b>	<b>0.6018</b>	<b>0.920</b>
32	0.5989	0.6464	0.5906	0.918
27	0.6041	0.6142	0.5817	0.919
30	0.5685	0.6043	0.5850	0.913
6	0.5989	0.5961	0.5890	0.918

**Öklid 1**  
**Confusion Matrix**

Output Class	1	19 9.6%	11 5.6%	6 3.0%	2 1.0%	0 0.0%	4 2.0%	45.2% 54.8%
	2	12 6.1%	30 15.2%	10 5.1%	0 0.0%	0 0.0%	3 1.5%	54.5% 45.5%
	3	11 5.6%	0 0.0%	5 2.5%	6 3.0%	2 1.0%	4 2.0%	17.9% 82.1%
	4	0 0.0%	0 0.0%	6 3.0%	9 4.6%	2 1.0%	7 3.6%	37.5% 62.5%
	5	0 0.0%	1 0.5%	0 0.0%	0 0.0%	6 3.0%	3 1.5%	60.0% 40.0%
	6	6 3.0%	0 0.0%	6 3.0%	6 3.0%	6 3.0%	14 7.1%	36.8% 63.2%
			39.6% 60.4%	71.4% 28.6%	15.2% 84.8%	39.1% 60.9%	37.5% 62.5%	40.0% 60.0%
		1	2	3	4	5	6	
		Target Class						

Şekil 4.6 : KNN konfüzyon matrisi, öklid uzaklığı 1

**Öklid 2**  
**Confusion Matrix**

Output Class	1	23 11.7%	9 4.6%	2 1.0%	1 0.5%	1 0.5%	2 1.0%	60.5% 39.5%
	2	15 7.6%	23 11.7%	10 5.1%	0 0.0%	1 0.5%	4 2.0%	43.4% 56.6%
	3	9 4.6%	7 3.6%	11 5.6%	4 2.0%	2 1.0%	7 3.6%	27.5% 72.5%
	4	0 0.0%	2 1.0%	3 1.5%	8 4.1%	4 2.0%	3 1.5%	40.0% 60.0%
	5	0 0.0%	0 0.0%	1 0.5%	3 1.5%	8 4.1%	5 2.5%	47.1% 52.9%
	6	3 1.5%	1 0.5%	3 1.5%	6 3.0%	3 1.5%	13 6.6%	44.8% 55.2%
			46.0% 54.0%	54.8% 45.2%	36.7% 63.3%	36.4% 63.6%	42.1% 57.9%	38.2% 61.8%
		1	2	3	4	5	6	
		Target Class						

Şekil 4.7 : KNN konfüzyon matrisi, öklid uzaklığı 2

**Öklid 3**  
**Confusion Matrix**

Output Class	1	20 10.2%	8 4.1%	9 4.6%	2 1.0%	3 1.5%	5 2.5%	42.6% 57.4%
	2	22 11.2%	29 14.7%	6 3.0%	1 0.5%	0 0.0%	8 4.1%	43.9% 56.1%
	3	5 2.5%	2 1.0%	9 4.6%	4 2.0%	3 1.5%	5 2.5%	32.1% 67.9%
	4	1 0.5%	0 0.0%	2 1.0%	10 5.1%	3 1.5%	6 3.0%	45.5% 54.5%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 4.6%	3 1.5%	75.0% 25.0%
	6	2 1.0%	0 0.0%	2 1.0%	6 3.0%	2 1.0%	10 5.1%	45.5% 54.5%
			40.0% 60.0%	74.4% 25.6%	32.1% 67.9%	43.5% 56.5%	45.0% 55.0%	27.0% 73.0%
		1	2	3	4	5	6	
		Target Class						

Şekil 4.8 : KNN konfüzyon matrisi, öklid uzaklığı 3

**Öklid 4**  
**Confusion Matrix**

Output Class	1	28 14.2%	5 2.5%	10 5.1%	1 0.5%	0 0.0%	10 5.1%	51.9% 48.1%
	2	14 7.1%	27 13.7%	13 6.6%	1 0.5%	2 1.0%	1 0.5%	46.6% 53.4%
	3	3 1.5%	1 0.5%	7 3.6%	3 1.5%	0 0.0%	5 2.5%	36.8% 63.2%
	4	3 1.5%	0 0.0%	5 2.5%	3 1.5%	7 3.6%	9 4.6%	11.1% 88.9%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 2.5%	3 1.5%	62.5% 37.5%
	6	1 0.5%	0 0.0%	5 2.5%	10 5.1%	4 2.0%	11 5.6%	35.5% 64.5%
			57.1% 42.9%	81.8% 18.2%	17.5% 82.5%	16.7% 83.3%	27.8% 72.2%	28.2% 71.8%
		1	2	3	4	5	6	
		Target Class						

Şekil 4.9 : KNN konfüzyon matrisi, öklid uzaklığı 4

**Öklid 5**  
**Confusion Matrix**

1	24 12.2%	8 4.1%	8 4.1%	0 0.0%	3 1.5%	9 4.6%	46.2% 53.8%
2	6 3.0%	30 15.2%	8 4.1%	4 2.0%	0 0.0%	5 2.5%	56.6% 43.4%
3	11 5.6%	1 0.5%	11 5.6%	3 1.5%	2 1.0%	3 1.5%	35.5% 64.5%
4	3 1.5%	0 0.0%	5 2.5%	7 3.6%	2 1.0%	7 3.6%	29.2% 70.8%
5	1 0.5%	0 0.0%	0 0.0%	1 0.5%	9 4.6%	4 2.0%	60.0% 40.0%
6	5 2.5%	1 0.5%	2 1.0%	7 3.6%	3 1.5%	4 2.0%	18.2% 81.8%
	48.0% 52.0%	75.0% 25.0%	32.4% 67.6%	31.8% 68.2%	47.4% 52.6%	12.5% 87.5%	43.1% 56.9%
	1	2	3	4	5	6	
	<b>Target Class</b>						

Şekil 4.10 : KNN konfüzyon matrisi, öklid uzaklığı 5

Çizelge 4.2 : KNN Öklid uzaklığı sonuçları

<b>KNN Öklid Uzaklığı</b>				
<i>k</i>	<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>Özgüllük</b>
3	0.4213	0.4199	0.4046	0.8812
4	0.4365	0.4388	0.4235	0.8855
<b>18</b>	<b>0.4416</b>	<b>0.4742</b>	<b>0.4366</b>	<b>0.8848</b>
11	0.4112	0.4072	0.3818	0.8802
17	0.4314	0.4093	0.4117	0.8834

AÜSD hastalıkları için KNN algoritması sınıflandırma sonuçları incelendiğinde veriler arası mesafe ölçüm methodlarının sınıflandırma başarısı açısından önemli bir kriter olduğu görülmüştür. ‘Manhattan Uzaklığı’ seçimi ‘Öklid Uzaklığı’ seçimine göre daha iyi bir sınıflandırma performansı göstermiştir.

Çizelge 4.3 incelendiğinde manhattan uzaklığı yöntemiyle KNN algoritmasının UF-EMG sinyallerini ortalama %59.48 doğruluk ile, en başarılı test sonucunda ise %60.42 doğruluk ile sınıflandırmıştır. Öklid uzaklığı yöntemiyle KNN algoritmasının UF-EMG sinyallerini ortalama %42.84 doğruluk ile, en başarılı test sonucunda ise %44.16 doğruluk ile sınıflandırdığı görülmektedir. Hem ortalama değer olarak hem de en iyi sınıflandırma değeri olarak bakıldığında doğruluk, kesinlik, duyarlılık ve özgüllük değerlerinde veriler arası uzaklık hesaplaması için ‘Manhattan Uzaklığı’ tercihinin verdiği sonuçların daha iyi olduğu görülmüştür.

Çizelge 4.3 : KNN ortalama ve en başarılı sonuçlar

KNN Ortalama ve En İyi Sonuçlar				
YÖNTEM	Doğruluk	Kesinlik	Duyarlılık	Özgüllük
Öklid Uzaklığı Ortalama	0.4284	0.4298	0.4116	0.8830
Öklid Uzaklığı En Başarılı	0.4416	0.4742	0.4366	0.8848
Manhattan Uzaklığı Ortalama	<b>0.5948</b>	<b>0.6166</b>	<b>0.5896</b>	<b>0.9176</b>
Manhattan Uzaklığı En Başarılı	<b>0.6042</b>	<b>0.6223</b>	<b>0.6018</b>	<b>0.9201</b>

## 4.2 Destek Vektör Makineleri Sonuçları

DVM sınıflandırma metodunda ‘Linear’ ve ‘Polinomal’ çekirdek fonksiyonları olmak üzere iki farklı çekirdek fonksiyonu kullanılmış ve yöntemin sınıflandırma performansı incelenmiştir. Çok sınıflı DVM sınıflandırıcı için hem OVO hem de OVA yöntemleri iki çekirdek fonksiyonu ile kullanılarak konfüzyon matrisleri çizilmiş en iyi ve en kötü sonuçları içeren konfüzyon matrisleri gösterilmiştir.

Test aşaması sonrası elde edilen konfüzyon matrisleri (Şekil 4.11 – 4.18) aracılığıyla doğruluk, kesinlik, duyarlılık ve özgüllük değerleri hesaplanmıştır (Çizelge 4.4, Çizelge 4.5). Aynı zamanda çok sınıflı DVM sınıflandırıcıları için OVO ve OVA algoritmalarının çalışma hızı arasındaki fark algoritma çalışma süreleride hesaplanmıştır.

		One vs One							
Output Class		Target Class						Accuracy	Precision
		1	2	3	4	5	6		
1	39 19.8%	2 1.0%	0 0.0%	0 0.0%	0 0.0%	3 1.5%	88.6%	11.4%	
2	3 1.5%	36 18.3%	2 1.0%	0 0.0%	0 0.0%	0 0.0%	87.8%	12.2%	
3	1 0.5%	2 1.0%	27 13.7%	1 0.5%	0 0.0%	1 0.5%	84.4%	15.6%	
4	0 0.0%	0 0.0%	0 0.0%	25 12.7%	1 0.5%	1 0.5%	92.6%	7.4%	
5	0 0.0%	1 0.5%	0 0.0%	0 0.0%	21 10.7%	1 0.5%	91.3%	8.7%	
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	30 15.2%	100%	0.0%	
		90.7%	87.8%	93.1%	96.2%	95.5%	83.3%	90.4%	
		9.3%	12.2%	6.9%	3.8%	4.5%	16.7%	9.6%	

Şekil 4.11 : DVM linear çekirdek fonksiyonu , OVO en başarılı

		One vs One							
Output Class		Target Class						Accuracy	Precision
		1	2	3	4	5	6		
1	39 19.8%	5 2.5%	0 0.0%	0 0.0%	0 0.0%	2 1.0%	84.8%	15.2%	
2	3 1.5%	40 20.3%	2 1.0%	0 0.0%	0 0.0%	0 0.0%	88.9%	11.1%	
3	2 1.0%	2 1.0%	25 12.7%	2 1.0%	0 0.0%	2 1.0%	75.8%	24.2%	
4	0 0.0%	0 0.0%	0 0.0%	22 11.2%	0 0.0%	3 1.5%	88.0%	12.0%	
5	0 0.0%	0 0.0%	0 0.0%	2 1.0%	15 7.6%	3 1.5%	75.0%	25.0%	
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	28 14.2%	100%	0.0%	
		88.6%	85.1%	92.6%	84.6%	100%	73.7%	85.8%	
		11.4%	14.9%	7.4%	15.4%	0.0%	26.3%	14.2%	

Şekil 4.12 : DVM linear çekirdek fonksiyonu , OVO en başarısız

		One vs All							
		1	2	3	4	5	6	Accuracy	Missed
Output Class	1	37 18.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 1.5%	92.5%	7.5%
	2	5 2.5%	38 19.3%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	86.4%	13.6%
	3	1 0.5%	2 1.0%	27 13.7%	0 0.0%	0 0.0%	2 1.0%	84.4%	15.6%
	4	0 0.0%	0 0.0%	0 0.0%	25 12.7%	0 0.0%	0 0.0%	100%	0.0%
	5	0 0.0%	1 0.5%	1 0.5%	0 0.0%	15 7.6%	0 0.0%	88.2%	11.8%
	6	0 0.0%	0 0.0%	0 0.0%	1 0.5%	7 3.6%	31 15.7%	79.5%	20.5%
	Overall		86.0%	92.7%	93.1%	96.2%	68.2%	86.1%	87.8%
		1	2	3	4	5	6		
		Target Class							

Şekil 4.13 : DVM linear çekirdek fonksiyonu, OVA en başarılı

		One vs All							
		1	2	3	4	5	6	Accuracy	Missed
Output Class	1	33 16.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	97.1%	2.9%
	2	2 1.0%	17 8.6%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	85.0%	15.0%
	3	8 4.1%	23 11.7%	27 13.7%	0 0.0%	0 0.0%	1 0.5%	45.8%	54.2%
	4	0 0.0%	0 0.0%	1 0.5%	17 8.6%	0 0.0%	0 0.0%	94.4%	5.6%
	5	0 0.0%	1 0.5%	0 0.0%	2 1.0%	14 7.1%	2 1.0%	73.7%	26.3%
	6	0 0.0%	0 0.0%	0 0.0%	5 2.5%	5 2.5%	37 18.8%	78.7%	21.3%
	Overall		76.7%	41.5%	96.4%	70.8%	73.7%	88.1%	73.6%
		1	2	3	4	5	6		
		Target Class							

Şekil 4.14 : DVM linear çekirdek fonksiyonu, OVA en başarısız



Çizelge 4.4 : DVM Linear çekirdek fonksiyonu sonuçları

<b>Linear Çekirdek Fonksiyonu</b>				
<b>One vs One (OVO)</b>				
<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>Özgüllük</b>	<b>Zaman(sn)</b>
0.8934	0.8840	0.8954	0.9784	76.36
0.8832	0.8901	0.8858	0.9759	107.63
<b>0.9035</b>	<b>0.9078</b>	<b>0.9109</b>	<b>0.9804</b>	<b>102.16</b>
0.8578	0.8540	0.8744	0.9715	61.21
0.8934	0.8927	0.9116	0.9786	73.90
<b>One vs All (OVA)</b>				
<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>Özgüllük</b>	<b>Zaman(sn)</b>
0.8223	0.8094	0.8207	0.9649	3.02
0.8324	0.8477	0.8001	0.9653	3.13
<b>0.8781</b>	<b>0.8849</b>	<b>0.8704</b>	<b>0.9751</b>	<b>2.21</b>
0.8325	0.8399	0.8235	0.9644	3.19
0.7360	0.7911	0.7454	0.9477	2.40

		One vs One							
Output Class		Target Class						Accuracy	Precision
		1	2	3	4	5	6		
1	39 19.8%	5 2.5%	2 1.0%	1 0.5%	0 0.0%	5 2.5%	75.0%	25.0%	
2	1 0.5%	38 19.3%	4 2.0%	0 0.0%	1 0.5%	0 0.0%	86.4%	13.6%	
3	4 2.0%	4 2.0%	16 8.1%	0 0.0%	0 0.0%	3 1.5%	59.3%	40.7%	
4	0 0.0%	0 0.0%	1 0.5%	20 10.2%	3 1.5%	0 0.0%	83.3%	16.7%	
5	0 0.0%	1 0.5%	0 0.0%	0 0.0%	15 7.6%	2 1.0%	83.3%	16.7%	
6	0 0.0%	0 0.0%	0 0.0%	1 0.5%	1 0.5%	30 15.2%	93.8%	6.3%	
		88.6%	79.2%	69.6%	90.9%	75.0%	75.0%	80.2%	19.8%
		11.4%	20.8%	30.4%	9.1%	25.0%	25.0%		

Şekil 4.15 : DVM polinomal çekirdek fonksiyonu, OVO en başarılı

		One vs One							
Output Class		Target Class						Accuracy	Precision
		1	2	3	4	5	6		
1	31 15.7%	4 2.0%	2 1.0%	1 0.5%	0 0.0%	7 3.6%	68.9%	31.1%	
2	7 3.6%	27 13.7%	5 2.5%	2 1.0%	1 0.5%	0 0.0%	64.3%	35.7%	
3	2 1.0%	6 3.0%	19 9.6%	1 0.5%	1 0.5%	0 0.0%	65.5%	34.5%	
4	0 0.0%	0 0.0%	1 0.5%	14 7.1%	1 0.5%	0 0.0%	87.5%	12.5%	
5	0 0.0%	0 0.0%	0 0.0%	2 1.0%	22 11.2%	4 2.0%	78.6%	21.4%	
6	1 0.5%	0 0.0%	0 0.0%	4 2.0%	3 1.5%	29 14.7%	78.4%	21.6%	
		75.6%	73.0%	70.4%	58.3%	78.6%	72.5%	72.1%	27.9%
		24.4%	27.0%	29.6%	41.7%	21.4%	27.5%		

Şekil 4.16 : DVM polinomal çekirdek fonksiyonu, OVO en başarısız

		One vs All							
Output Class		Target Class						Accuracy	Precision
		1	2	3	4	5	6		
1	40 20.3%	4 2.0%	1 0.5%	1 0.5%	2 1.0%	1 0.5%	81.6%	18.4%	
2	5 2.5%	25 12.7%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	80.6%	19.4%	
3	2 1.0%	5 2.5%	20 10.2%	0 0.0%	0 0.0%	0 0.0%	74.1%	25.9%	
4	0 0.0%	0 0.0%	1 0.5%	25 12.7%	0 0.0%	2 1.0%	89.3%	10.7%	
5	1 0.5%	0 0.0%	0 0.0%	1 0.5%	17 8.6%	1 0.5%	85.0%	15.0%	
6	0 0.0%	1 0.5%	0 0.0%	1 0.5%	3 1.5%	37 18.8%	88.1%	11.9%	
		83.3%	71.4%	87.0%	89.3%	77.3%	90.2%	83.2%	
		16.7%	28.6%	13.0%	10.7%	22.7%	9.8%	16.8%	

Şekil 4.17 : DVM polinomal çekirdek fonksiyonu, OVA en başarılı

		One vs All							
Output Class		Target Class						Accuracy	Precision
		1	2	3	4	5	6		
1	31 15.7%	2 1.0%	1 0.5%	1 0.5%	2 1.0%	4 2.0%	75.6%	24.4%	
2	7 3.6%	27 13.7%	6 3.0%	0 0.0%	0 0.0%	0 0.0%	67.5%	32.5%	
3	1 0.5%	8 4.1%	19 9.6%	1 0.5%	0 0.0%	1 0.5%	63.3%	36.7%	
4	0 0.0%	0 0.0%	1 0.5%	15 7.6%	1 0.5%	0 0.0%	88.2%	11.8%	
5	0 0.0%	0 0.0%	0 0.0%	2 1.0%	22 11.2%	3 1.5%	81.5%	18.5%	
6	2 1.0%	0 0.0%	0 0.0%	5 2.5%	3 1.5%	32 16.2%	76.2%	23.8%	
		75.6%	73.0%	70.4%	62.5%	78.6%	80.0%	74.1%	
		24.4%	27.0%	29.6%	37.5%	21.4%	20.0%	25.9%	

Şekil 4.18 : DVM polinomal çekirdek fonksiyonu, OVA en başarısız

Çizelge 4.5 : DVM Polinomal çekirdek fonksiyonu sonuçları

<b>Polinomal Çekirdek Fonksiyonu</b>				
<b>One vs One (OVO)</b>				
<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>Özgüllük</b>	<b>Zaman(sn)</b>
0.7868	0.7837	0.7745	0.9570	113.17
0.7817	0.7967	0.7745	0.9556	151.31
0.8020	0.8017	0.8108	0.9606	147.26
0.7208	0.7385	0.7139	0.9432	140.97
<b>0.8021</b>	<b>0.8019</b>	<b>0.7971</b>	<b>0.9598</b>	<b>143.82</b>
<b>One vs All (OVA)</b>				
<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>Özgüllük</b>	<b>Zaman(sn)</b>
0.8121	0.8094	0.8039	0.9623	2.45
0.7868	0.7974	0.8000	0.9569	2.40
<b>0.8323</b>	<b>0.8197</b>	<b>0.8231</b>	<b>0.9645</b>	<b>2.82</b>
0.7411	0.7539	0.7333	0.9475	2.62
0.8020	0.8069	0.8046	0.9588	2.80

DVM ile sınıflandırma yapılırken iki farklı çekirdek fonksiyonu kullanılmıştır. Çizelge 4.6 incelendiğinde linear çekirdek fonksiyonu ve OVO yöntemi ile DVM'in UF-EMG sinyallerini ortalama %88.62, en başarılı test sonucu ise %90.35 olarak hesaplanmıştır. Polinomal çekirdek fonksiyonu ve OVO yöntemi ile DVM'in UF-EMG sinyallerini ortalama %77.86, en başarılı test sonucu ise %80.21 olarak hesaplanmıştır.

Linear çekirdek fonksiyonu ve OVA yöntemi ile DVM'in UF-EMG sinyallerini ortalama %82.02, en başarılı test sonucu ise %87.81 olarak hesaplanmıştır. Polinomal çekirdek fonksiyonu ve OVA yöntemi ile DVM'in UF-EMG sinyallerini ortalama %79.28, en başarılı test sonucu ise %82.23 olarak hesaplanmıştır.

Bu sonuçlara göre 'Linear Çekirdek' fonksiyonu ve OVO yöntemi ile DVM'in UF-EMG sinyallerini 'Polinomal Çekirdek' fonksiyonuna göre daha başarılı bir sınıflandırma performansı gösterdiği görülmektedir.

Genel olarak performans değerlendirilmesi incelendiğinde linear çekirdek fonksiyonunun daha başarılı bir sınıflandırma performansı gösterdiği görülmüştür. DVM ile çok sınıflı sınıflandırma için OVO ve OVA yöntemleri kullanılmıştır.

Linear çekirdek fonksiyonu ile OVO yönteminin daha başarılı sonuçlar verdiği gözlemlenmiştir. Ancak algoritmaların çalışma süreleri incelendiğinde OVA yönteminin OVO yöntemine göre daha hızlı çalıştığı görülmüştür. Bu farkın sebebi OVO yönteminde daha fazla matematiksel işlem olmasıdır.

Polinomal çekirdek fonksiyonu sonuçları incelendiğinde ise sonuçlar birbirine oldukça yakın olmasına rağmen OVA yöntemi daha başarılı sonuçlar vermiştir. OVA yöntemi daha başarılı olmasının yanı sıra OVO yöntemine göre daha hızlı sonuç vermektedir.

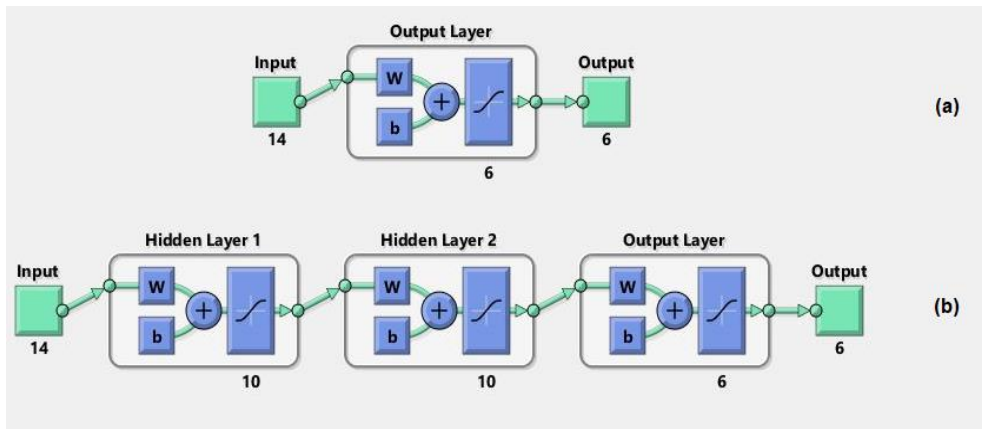
DVM ile sınıflandırma yöntemlerinde çekirdek fonksiyonu olarak en başarılı sonuçlar linear çekirdek çekirdek fonksiyonu ile elde edilmiştir. Çok sınıflı sınıflandırma yöntemleri arasında ise kullanılan çekirdek fonksiyonuna göre hem OVO hem de OVA yöntemleri başarılı sonuçlar vermiştir ancak iki çekirdek fonksiyonu yönteminde de OVA yöntemi OVO yöntemine göre sonuçları daha hızlı vermiştir. Yöntemler arasındaki çalışma hızı farkının temel sebebi OVO yönteminde daha çok matematiksel işlem yapılmasıdır.

Çizelge 4.6 : DVM ortalama ve en başarılı sonuçlar

DVM Ortalama ve En Başarılı Sonuçlar					
YÖNTEM	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	Zaman(sn)
Linear OVO Ortalama	0.8862	0.8857	0.8956	0.9769	84.25
Linear OVO En Başarılı	0.9035	0.9078	0.9109	0.9804	107.63
Linear OVA Ortalama	0.8202	0.8346	0.8120	0.9637	2.79
Linear OVA En Başarılı	0.8781	0.8849	0.8704	0.9751	2.21
Polinomal OVO Ortalama	0.7786	0.7845	0.7768	0.9552	139.30
Polinomal OVO En Başarılı	0.8021	0.8019	0.7971	0.9598	143.82
Polinomal OVA Ortalama	0.7948	0.7974	0.7929	0.9581	2.61
Polinomal OVA En Başarılı	0.8223	0.8194	0.8231	0.9645	2.82

### 4.3 Yapay Sinir Ağları Sonuçları

YSA sınıflandırma metodunda 'Tek Katmanlı YSA' (Şekil 4.19a) ve 'Çok Katmanlı YSA' (Şekil 4.19b) ileri beslemeli YSA yapıları kullanılmıştır. YSA sistemindeki en önemli problemlerden birisi olan aşırı öğrenme (overfitting)'nin önüne geçmek adına verisetinin %80'i eğitim, %10'u validasyon ve %10'u test aşaması için kullanılmıştır. Validasyon aşaması erken bir test aşaması olarak tanımlanabilir. Test öncesi validasyon yapılarak YSA sisteminin aşırı öğrenmesini önlemek amaçlanmıştır.



Şekil 4.19 : (a) Tek katmanlı YSA, (b) Çok katmanlı YSA

Optimum gizli katman ve nöron sayılarının belirlemek adına farklı gizli katman ve nöron sayıları denenmiştir. Farklı gizli katman ve her bir gizli katmanla bulunacak nöron sayılarını belirlemek için yapılan denemeler sonucu en başarılı sonuçları veren gizli katman ve nöron sayıları kullanılmıştır. En başarılı sonuçlar iki gizli katmanlı YSA yapısında elde edilmiştir.

Gizli katmanlarda kullanılacak nöron sayısı belirlenirken aynı şekilde her bir gizli katman için farklı nöron sayıları kombinasyonları denenmiştir. Bu nedenle tez çalışmasında çok katmanlı YSA yapısında iki adet gizli katman kullanılmıştır. Gizli katmanlarda ise on adet nöron kullanılmıştır.

YSA sisteminin test aşaması sonucunda elde edilen konfüzyon matrisleri çizilmiştir (Şekil 4.20 – 4.29). Elde edilen konfüzyon matrisleri kullanılarak doğruluk, kesinlik, hassasiyet ve özgüllük değerleri hesaplanarak YSA yönteminin sınıflandırma performansı değerlendirilmiştir (Çizelge 4.7, Çizelge 4.8).

**Tek Katmanlı YSA 1**

**Test Confusion Matrix**

<b>Output Class</b>	1	24 24.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	3 3.1%	13 13.4%	2 2.1%	0 0.0%	0 0.0%	0 0.0%	72.2% 27.8%
	3	0 0.0%	1 1.0%	17 17.5%	0 0.0%	0 0.0%	2 2.1%	85.0% 15.0%
	4	0 0.0%	0 0.0%	1 1.0%	13 13.4%	0 0.0%	0 0.0%	92.9% 7.1%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 6.2%	1 1.0%	85.7% 14.3%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 14.4%	100% 0.0%
			88.9% 11.1%	92.9% 7.1%	85.0% 15.0%	100% 0.0%	100% 0.0%	82.4% 17.6%
		1	2	3	4	5	6	
		<b>Target Class</b>						

Şekil 4.20 : Tek katmanlı YSA konfüzyon matrisi 1

**Tek Katmanlı YSA 2**  
**Test Confusion Matrix**

<b>Output Class</b>	1	22 22.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	2 2.1%	17 17.5%	1 1.0%	0 0.0%	0 0.0%	0 0.0%	85.0% 15.0%
	3	3 3.1%	1 1.0%	11 11.3%	0 0.0%	0 0.0%	0 0.0%	73.3% 26.7%
	4	0 0.0%	0 0.0%	1 1.0%	11 11.3%	0 0.0%	0 0.0%	91.7% 8.3%
	5	0 0.0%	0 0.0%	0 0.0%	1 1.0%	11 11.3%	2 2.1%	78.6% 21.4%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 14.4%	100% 0.0%
			81.5% 18.5%	94.4% 5.6%	84.6% 15.4%	91.7% 8.3%	100% 0.0%	87.5% 12.5%
		<b>Target Class</b>						
		1	2	3	4	5	6	

Şekil 4.21 : Tek katmanlı YSA konfüzyon matrisi 2

**Tek Katmanlı YSA 3**  
**Test Confusion Matrix**

<b>Output Class</b>	1	14 14.4%	1 1.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	93.3% 6.7%
	2	2 2.1%	19 19.6%	0 0.0%	0 0.0%	0 0.0%	2 2.1%	82.6% 17.4%
	3	0 0.0%	1 1.0%	14 14.4%	0 0.0%	0 0.0%	1 1.0%	87.5% 12.5%
	4	0 0.0%	0 0.0%	2 2.1%	12 12.4%	0 0.0%	0 0.0%	85.7% 14.3%
	5	0 0.0%	0 0.0%	0 0.0%	1 1.0%	11 11.3%	0 0.0%	91.7% 8.3%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 17.5%	100% 0.0%
			87.5% 12.5%	90.5% 9.5%	87.5% 12.5%	92.3% 7.7%	100% 0.0%	85.0% 15.0%
		<b>Target Class</b>						
		1	2	3	4	5	6	

Şekil 4.22 : Tek katmanlı YSA konfüzyon matrisi 3



**Tek Katmanlı YSA 4**  
**Test Confusion Matrix**

Output Class	1	18 18.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	4 4.1%	16 16.5%	3 3.1%	0 0.0%	0 0.0%	2 2.1%	64.0% 36.0%
	3	0 0.0%	1 1.0%	13 13.4%	0 0.0%	0 0.0%	1 1.0%	86.7% 13.3%
	4	0 0.0%	0 0.0%	0 0.0%	13 13.4%	0 0.0%	1 1.0%	92.9% 7.1%
	5	0 0.0%	0 0.0%	0 0.0%	1 1.0%	6 6.2%	3 3.1%	60.0% 40.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.0%	14 14.4%	93.3% 6.7%
			81.8% 18.2%	94.1% 5.9%	81.3% 18.8%	92.9% 7.1%	85.7% 14.3%	66.7% 33.3%
		1	2	3	4	5	6	
		<b>Target Class</b>						

Şekil 4.23 : Tek katmanlı YSA konfüzyon matrisi 4

**Tek Katmanlı YSA 5**  
**Test Confusion Matrix**

Output Class	1	15 15.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.0%	93.8% 6.3%
	2	2 2.1%	21 21.6%	1 1.0%	0 0.0%	0 0.0%	0 0.0%	87.5% 12.5%
	3	1 1.0%	1 1.0%	15 15.5%	0 0.0%	0 0.0%	0 0.0%	88.2% 11.8%
	4	0 0.0%	0 0.0%	1 1.0%	15 15.5%	0 0.0%	0 0.0%	93.8% 6.3%
	5	0 0.0%	0 0.0%	0 0.0%	1 1.0%	10 10.3%	0 0.0%	90.9% 9.1%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.0%	12 12.4%	92.3% 7.7%
			83.3% 16.7%	95.5% 4.5%	88.2% 11.8%	93.8% 6.3%	90.9% 9.1%	92.3% 7.7%
		1	2	3	4	5	6	
		<b>Target Class</b>						

Şekil 4.24 : Tek katmanlı YSA konfüzyon matrisi 5

Çizelge 4.7 : Tek katmanlı YSA sonuçları

Tek Katmanlı YSA			
Doğruluk	Kesinlik	Duyarlılık	Özgüllük
0.8979	0.8937	0.9151	0.9798
0.8877	0.8820	0.9005	0.9782
0.8247	0.8280	0.8373	0.9655
0.8969	0.9013	0.9046	0.9791
<b>0.9072</b>	<b>0.9107</b>	<b>0.9066</b>	<b>0.9811</b>

**Çok Katmanlı YSA 1**  
**Test Confusion Matrix**

	1	2	3	4	5	6	
1	13 13.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	3 3.1%	21 21.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	87.5% 12.5%
3	0 0.0%	0 0.0%	17 17.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	17 17.5%	0 0.0%	1 1.0%	94.4% 5.6%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 9.3%	1 1.0%	90.0% 10.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 2.1%	13 13.4%	86.7% 13.3%
	81.3% 18.8%	100% 0.0%	100% 0.0%	100% 0.0%	81.8% 18.2%	86.7% 13.3%	92.8% 7.2%
	1	2	3	4	5	6	
		Target Class					

Şekil 4.25 : Çok katmanlı YSA konfüzyon matrisi 1

**Çok Katmanlı YSA 2**

**Test Confusion Matrix**

<b>Output Class</b>	1	16 16.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	3 3.1%	20 20.6%	1 1.0%	0 0.0%	0 0.0%	0 0.0%	83.3% 16.7%
	3	0 0.0%	0 0.0%	16 16.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	11 11.3%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 8.2%	1 1.0%	88.9% 11.1%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.0%	20 20.6%	95.2% 4.8%
			84.2% 15.8%	100% 0.0%	94.1% 5.9%	100% 0.0%	88.9% 11.1%	95.2% 4.8%
		1	2	3	4	5	6	
		<b>Target Class</b>						


Şekil 4.26 : Çok katmanlı YSA konfüzyon matrisi 2

**Çok Katmanlı YSA 3**


**Test Confusion Matrix**

<b>Output Class</b>	1	22 22.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	2 2.1%	19 19.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.5% 9.5%
	3	0 0.0%	0 0.0%	14 14.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1 1.0%	8 8.2%	0 0.0%	1 1.0%	80.0% 20.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 9.3%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.0%	20 20.6%	95.2% 4.8%
			91.7% 8.3%	100% 0.0%	93.3% 6.7%	100% 0.0%	90.0% 10.0%	95.2% 4.8%
		1	2	3	4	5	6	
		<b>Target Class</b>						

Şekil 4.27 : Çok katmanlı YSA konfüzyon matrisi 3



Şekil 4.28 : Çok katmanlı YSA konfüzyon matrisi 4



Şekil 4.29 : Çok katmanlı YSA konfüzyon matrisi 5

Çizelge 4.8 : Çok katmanlı YSA sonuçları

Çok Katmanlı YSA			
Doğruluk	Kesinlik	Duyarlılık	Özgüllük
0.9278	0.9310	0.9162	0.9853
0.9381	0.9458	0.9374	0.9872
<b>0.9484</b>	<b>0.9428</b>	<b>0.9503</b>	<b>0.9898</b>
0.9175	0.9170	0.9306	0.9838
0.9278	0.9280	0.9229	0.9855

YSA sonuçlarını incelediğimizde, hem tek katmanlı hem de çok katmanlı YSA sistemlerinin genel doğruluk açısından başarılı sonuçlar verdiği ancak Çizelge 4.9 incelendiğinde çok katmanlı YSA algoritmasının ortalama doğruluk değeri %93.20, en başarılı test sonucu ise %94.84 olarak hesaplanmıştır. Tek katmanlı YSA algoritmasının ortalama doğruluk değeri %88.29 , en başarılı test sonucu ise %90.72 doğruluk ile sınıflandırmıştır.

Bu sonuçlar göz önüne alındığında çok katmanlı YSA sisteminin UF-EMG sinyalleri sınıflandırmasında tek katmanlı YSA sistemine göre daha başarılı sonuçlar verdiği görülmektedir. Sonuçlar genel olarak incelendiğinde çok katmanlı YSA sisteminin tek katmanlı YSA sistemine göre daha başarılı bir sınıflandırma performansı gösterdiği belirlenmiştir.

Çizelge 4.9 : YSA ortalama ve en başarılı sonuçlar

YSA Ortalama ve En İyi Sonuçlar				
YÖNTEM	Doğruluk	Kesinlik	Duyarlılık	Özgüllük
<b>Tek Katmanlı YSA Ortalama</b>	0.8829	0.8831	0.8928	0.9767
<b>Tek Katmanlı YSA En Başarılı</b>	0.9072	0.9107	0.9066	0.9811
<b>Çok Katmanlı YSA Ortalama</b>	<b>0.9320</b>	<b>0.9329</b>	<b>0.9315</b>	<b>0.9863</b>
<b>Çok Katmanlı YSA En Başarılı</b>	<b>0.9484</b>	<b>0.9428</b>	<b>0.9503</b>	<b>0.9898</b>

#### 4.4 Genel Değerlendirme Sonuçları

Kullanılan sınıflandırma algoritmaları ve yöntemler için ortalama sonuçlar ve en başarılı test sonuçları Çizelge 5.1’de gösterilmiştir. Çizelge 5.1 incelediğinde KNN algoritmasının hem Manhattan uzaklığında hemde Öklid uzaklığında başarısız bir sınıflandırma performansı gösterdiği görülmüştür. Ancak manhattan uzaklığının öklid uzaklığı’na göre daha başarılı sonuçlar verdiği görülmüştür. KNN algoritması UF-EMG sinyallerini manhattan uzaklığı yöntemi ile ortalama %59.48 doğruluk, en başarılı test sonucunda ise %60.42 doğruluk ile sınıflandırmıştır.

DVM çekirdek fonksiyonu başarıları incelendiğinde linear çekirdek fonksiyonunun, polinomal çekirdek fonksiyonuna göre daha başarılı sonuçlar verdiği görülmüştür. Çok sınıflı DVM sınıflandırması için kullanılan OVO ve OVA yöntemleri arasında başarı olarak bariz bir fark olmamasına rağmen algoritmalarının çalışma süreleri arasında fark görülmektedir. DVM linear çekirdek fonksiyonu ve OVO yöntemi ile UF-EMG sinyallerini ortalama %88.62 doğruluk, en başarılı test sonucu ise %90.35 doğruluk ile sınıflandırdığı hesaplanmıştır.

YSA UF-EMG sinyallerini başarılı bir şekilde sınıflandırmıştır. Tek katmanlı ve çok katmanlı YSA sistemlerinin sonuçları incelendiğinde çok katmanlı YSA yönteminin hem ortalama hem de en başarılı sonuç olarak tek katmanlı YSA sistemine göre daha başarılı bir sınıflandırma performansı gösterdiği görülmüştür. Çok katmanlı YSA sistemi UF-EMG sinyallerini ortalama %93.20 doğruluk, en başarılı test sonucunda ise %94.84 doğruluk oranı ile sınıflandırmıştır.

UF-EMG sinyallerini ‘Çok Katmanlı İleri Beslemeli YSA’ sisteminin KNN ve DVM yöntemlerine göre hem ortalama hem de en başarılı sınıflandırma performansını verdiği görülmüştür. Literatürde yapılan benzer çalışmalar ve sonuçları incelendiğinde, Çalışkan ve arkadaşları UF-EMG sinyallerini YSA kullanarak %82.04 doğruluk oranı sınıflandırmıştır [9]. Bu tez çalışmasında çok katmanlı YSA sistemi ile UF-EMG sinyalleri ortalama %93.20 doğruluk ile daha yüksek bir başarı oranı ile sınıflandırılmıştır.

Çizelge 4.10 : En başarılı yöntemler ve sonuçlar

SONUÇLAR				
YÖNTEM	Doğruluk	Kesinlik	Duyarlılık	Özgüllük
<b>Çok Katmanlı YSA Ortalama</b>	<b>0.9320</b>	<b>0.9329</b>	<b>0.9315</b>	<b>0.9863</b>
<b>Çok Katmanlı YSA En Başarılı</b>	<b>0.9484</b>	<b>0.9428</b>	<b>0.9503</b>	<b>0.9898</b>
<b>Linear OVO Ortalama</b>	0.8862	0.8857	0.8956	0.9769
<b>Linear OVO En Başarılı</b>	0.9035	0.9078	0.9109	0.9804
<b>Manhattan Uzaklığı Ortalama</b>	0.5948	0.6166	0.5896	0.9176
<b>Manhattan Uzaklığı En Başarılı</b>	0.6042	0.6223	0.6018	0.9201





## 5. SONUÇ

Bu tez çalışmasında AÜSD için UF-EMG sinyalleri sınıflandırılarak bir karar destek sistemi oluşturulması amaçlanmıştır. Uzman hekimler tarafından incelenen 967 hasta verisi bilgisayar ortamına aktararak öznitelikler çıkarılmış ve sınıflandırma algoritmalarına tanıtılmıştır. UF-EMG sinyalleri KNN, DVM ve YSA algoritmaları kullanılarak sınıflandırılmıştır. Her bir algoritmanın sınıflandırma performansı konfüzyon matrisleri çizilerek ve konfüzyon matrisleri üzerinden doğruluk, kesinlik, duyarlılık ve özgüllük parametreleri hesaplanarak değerlendirilmiştir.

Bu tez çalışmasında UF-EMG sinyalleri sınıflandırılarak AÜSD tanısı için hekimlere yardımcı olacak bir karar destek sistemi oluşturulması amaçlanmıştır. UF-EMG sinyalleri üç farklı sınıflandırma algoritması ile sınıflandırılarak en başarılı sınıflandırma performansını gösteren algoritma belirlenmiştir. UF-EMG sinyallerinin sınıflandırılmasında en başarılı performansı 'Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları' sisteminin gösterdiği belirlenmiştir.

Geliştirilen yöntemin ürologların AÜSD hastalıkları tanı, tedavi ve takibinde tıbbi karar destek sistemi olarak kullanabileceği gösterilmiştir. Veri seti genişletilerek, füzyon algoritma ve derin öğrenme yöntemleri kullanılarak tıbbi karar destek sisteminin sınıflandırma performansının geliştirilebileceği düşünülmektedir.



## KAYNAKLAR

- [1] **Aydođdu, Ö., & Burgu, B.** (2010). Alt Üriner Sistem Gelişimi, Fizyolojisi ve Nöroanatomi. *Türkiye Klinikleri Urology-Special Topics*, 3(2), 43-48.
- [2] **de Jong, T. P., Klijn, A. J., & Vijverberg, M. A.** (2012). Lower urinary tract Dysfunction in children. *European Urology Supplements*, 11(2), 10-15.
- [3] **PEKBAY, N. Y., & DAYANÇ, M.** (2017). Kız Çocuklarda Üriner ve Fekal İnkontinans: Fizyoterapi ve Rehabilitasyon. *Türkiye Klinikleri Journal of Physiotherapy and Rehabilitation-Special Topics*, 3(3), 141-147.
- [4] **IRKILATA, H. C., ÖRS, A. Ö., KİBAR, Y., SAKALLIOĞLU, O., & DAYANÇ, M.** (2007). Alt üriner sistem işlev bozukluğu olan çocuklarda üroflow-EMG paternleri.
- [5] **Şen, G.** (2017). Alt Üriner Sistem Disfonksiyonu Olan Çocuklarda Hiperkalsiüri ve Hiperürükozurinin Araştırılması.
- [6] **Yang, C. C., Weinfurt, K. P., Merion, R. M., & Kirkali, Z.** (2016). Symptoms of lower urinary tract dysfunction research network. *The Journal of urology*, 196(1), 146-152.
- [7] **Van Batavia, J. P., Combs, A. J., Hyun, G., Bayer, A., Medina-Kreppin, D., Schlusel, R. N., & Glassberg, K. I.** (2011). Simplifying the diagnosis of 4 common voiding conditions using uroflow/electromyography, electromyography lag time and voiding history. *The Journal of urology*, 186(4s), 1721-1727.
- [8] **Altunay, S., Telatar, Z., Erođul, O., & Aydur, E.** (2009). A New Approach to urinary system dynamics problems: Evaluation and classification of uroflowmeter signals using artificial neural networks. *Expert Systems with Applications*, 36(3), 4891-4895.
- [9] **Yalçinkaya, F., Çalışkan, O., Erođul, O., Irkilata, C., Köprü, B., & Cođuplugil, E.** (2017, October). Classification of uroflowmetry and EMG signals of pediatric patients using Artificial Neural Networks. In *2017 Medical Technologies National Congress (TIPTEKNO)* (pp. 1-4). IEEE.
- [10] **Marciano, R. C., Cardoso, M. G. F., Vasconcelos, M. A., Paula, J. J., Pinho, N. C., Oliveira, A. C. & Lima, E. M.** (2018). Behavioral disorders and impairment of quality of life in children and adolescents with lower urinary tract dysfunction. *Journal of pediatric urology*, 14(6), 568-e1.

- [11] **Ryan, S. T.** (2016). Diagnosis and Management of Lower Urinary Tract Dysfunction. *The Surgical clinics of North America*, 96(3), 441-452.
- [12] **Yüksel, S., Yurdakul, A. Ç., Zencir, M., & Çördük, N.** (2014). Evaluation of lower urinary tract dysfunction in Turkish primary schoolchildren: an epidemiological study. *Journal of pediatric urology*, 10(6), 1181-1186.
- [13] **Altan, M., Çitamak, B., Bozaci, A. C., Mammadov, E., Doğan, H. S., & Tekgül, S.** (2017). Is there any difference between questionnaires on pediatric lower urinary tract dysfunction?. *Urology*, 103, 204-208.
- [14] **Khan, S. J., & Khastgir, J.** (2016). Assessment of lower urinary tract symptoms. *Surgery (Oxford)*, 34(7), 333-341.
- [15] **Koçak T.,** Ürodinami Ders Notları, İstanbul Üniversitesi İstanbul Tıp Fakültesi Üroloji Anabilim Dalı
- [16] **Homma, Y., Batista, J., Bauer, S., Griffiths, D., Hilton, P., Kramer, G., ... & Rosier, P. F. W. M.** (2002). Urodynamics. *Incontinence*, 317-72.
- [17] **Wenske S, Combs AJ, Van Batavia JP, Glassberg KI.** Can Staccato and interrupted/Fractionated Uroflow Patterns Alone Correctly Identify the Underlying Lower Urinary Tract Condition? *J Urol.* 2012;187:2188–93.
- [18] **Elmissiry M, Abdelkarim A, Badawy H, Elsalmy S, Ali GA.** Refractory enuresis in children and adolescents:How can urodynamics affect management and what is the optimum test? *J Pediatr Urol.* 2013;9:348–52.
- [19] **Chrzan R, Czernik J, Apoznański W, Patkowski D, Siekanowicz P.** Uroflowmetry in children – is it necessary to repeat the study in a single patient? *Eur J Pediatric Surg.* 2005;15:26–9.
- [20] **Mijwel, Maad.** (2016). Yapay Zekâ Nedir?
- [21] **Russell, S. J., & Norvig, P.** (2016). *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited,.
- [22] **Nabiyev, V. V.** (2005). *Yapay zeka: problemler-yöntemler-algoritmalar*. Seçkin Yayıncılık.
- [23] **Elmas, Ç.** (2003). *Yapay sinir ağları:(kuram, mimari, eğitim, uygulama)*. Seçkin Yayıncılık.
- [24] **Öztemel, E.** (2003). *Yapay sinir ağları*. PapatyaYayıncılık, İstanbul.
- [25] **Freeman, J. A., & Skapura, D. M.** (1991). *Neural networks algorithms. Applications and programming techniques*. Addison-Wesley Publishing.
- [26] **Bhatia, N. and Vandana,** “Survey of nearest neighbor techniques”, *International Journal of Computer Science and Information Security*, 8(2):302-305 (2010).

- [27] **Qiu, X.Y., Kang, K. and Zhang, H.X.**, “Selection of kernel parameters for K-NN”, *IEEE International Joint Conference on Neural Networks (IJCNN)*, 61-65 (2008).
- [28] **Batista, G.E.A.P.A. & Silva, D.F.**, “How k-nearest neighbor parameters affect its performance”, *Simposio Argentino de Inteligencia Artificial (ASAI 2009)*, 95–106 (2009).
- [29] **Keller, J. M., Gray, M.R. and Givens, J.A.**, “A fuzzy K-nearest neighbor algorithm”, *IEEE Transactions on Systems, Man and Cybernetics*, SMC15(4):580-585 (1985).
- [30] **Mao, C., Hu, B., Wang, M. and Moore, P.**, “Learning from neighborhood for classification with local distribution characteristics”, *IEEE International Joint Conference on Neural Networks (IJCNN)*, 1-8 (2015)
- [31] **Liu, H. and Zhang, S.**, “Noisy data elimination using mutual k-nearest neighbor for classification mining”, *Journal of Systems and Software*, 85(5):1067-1074 (2012).
- [32] **Taşcı, E., & Onan, A.** (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*.
- [33] **Kresse, W. and Danko, D.M.**, “Springer Handbook of Geographic Information”, *Springer-Verlag*, Berlin, (2012).
- [34] **Xu, G., Zong, Y. and Yang, Z.**, “Applied Data Mining”, *CRC Press*, New York, (2013).
- [35] **Cortes, C., Vapnik, V.**, 1995, Support-Vector Network, *Machine Learning*, 20(3): 273–297
- [36] **Osowski, S., Siwekand, K., and Markiewicz, T.** (2004). MLP and SVM Networks – a Comparative Study. *Proceedings of the 6th Nordic Signal Processing Symposium – NORSIG*.
- [37] **Nitze, I., Schulthess, U. And Asche, H.** (2012). Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. *Proceedings of the 4th GEOBIA*, Janeiro - Brazil. 35-40.
- [38] **Osuna, E.E., Freund, R., Girosi, F.**, 1997, Support Vector Machines: Training and Applications, *A.I. Memo No. 1602, C.B.C.L. Paper No. 144*, Massachusetts Institute of Technology and Artificial Intelligence Laboratory, Massachusetts.
- [39] **Kavzoğlu, T., & Çölkesen, İ.** (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
- [40] **Hsu, C.W., Chang, C.C., Lin, C.J.**, 2010, A Practical Guide to Support Vector Classification

[41] HALTAŞ, A., ALKAN, A., & KARABULUT, M. (2015). “Metin Sınıflandırmada Sezgisel Arama Algoritmalarının Performans Analizi”. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 30(3).

[Url-1] <http://centralhospital.com/Haberler/idrar-yolu-hastaliklarinda-tani-yontemi-urodinami/> Alındığı Tarih: 05.11.2018

[Url-2] <https://gcurology.com.au/urodynamics> Alındığı Tarih: 12.11.2018

[Url-3] <http://adsmed.com/urun/solar-blue/> Alındığı Tarih: 15.01.2019

[Url-4] <https://www.uwhealth.org/healthfacts/parenting/> Alındığı Tarih: 23.01.2019

[Url-5] <https://www.ibm.com/ibm/history/exhibits/vintage> Alındığı Tarih 10.02.2019



## ÖZGEÇMİŞ

**Ad-Soyad** : Çağrı Yılmaz  
**Uyruğu** : T.C.  
**Doğum Tarihi ve Yeri** : 27.10.1992 / Kocaeli  
**E-posta** : cagriyilmazer23@gmail.com

### ÖĞRENİM DURUMU:

- **Lisans** : 2016, TOBB Ekonomi ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü (Tam Burslu)

### MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2016-2019	TOBB Ekonomi ve Teknoloji Üniversitesi	Tam Burslu YL Öğrencisi

### YABANCI DİL:

İngilizce, 2016 YDS: 73.75

### TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Yılmaz Ç**, Özdemir G, Eroğul O, “Diagnosis of Lower Urinary Tract Dysfunction from Uroflowmetry-Electromyography signals” *World Congress on Medical Physics & Biomedical Engineering*, IUPESM 2018, 3-8 June 2018, Prag Czech Republic